



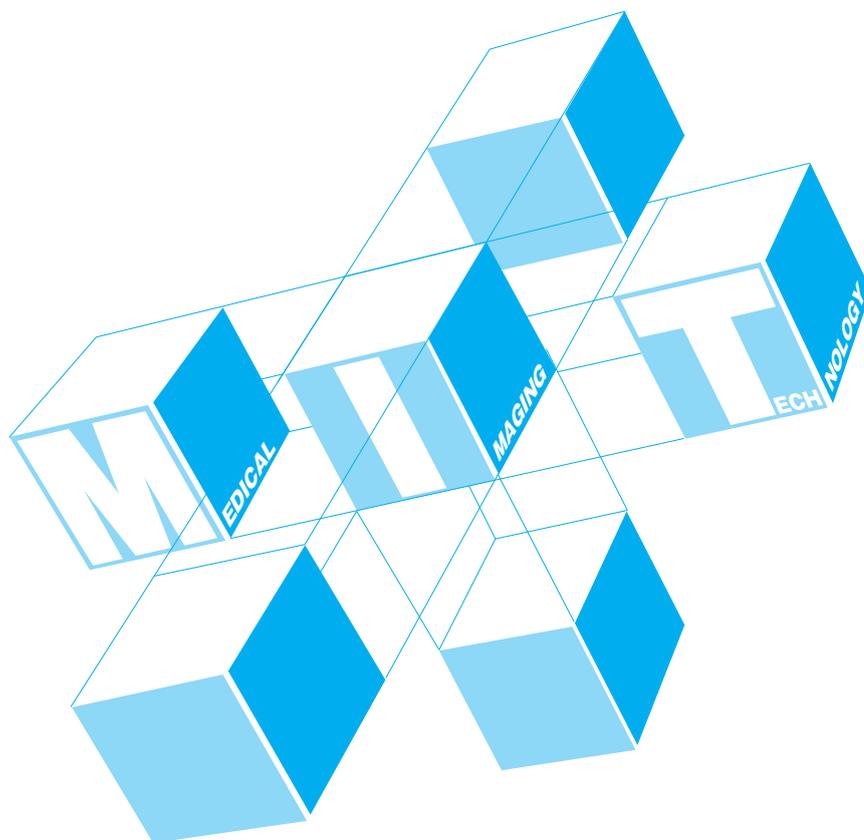
JAMIT Annual Meeting 2019

第38回日本医用画像工学会大会

会 期：2019年7月24日(水)～7月26日(金)

会 場：奈良春日野国際フォーラム 薨～I・RA・KA～

大会長：佐藤 嘉伸(奈良先端科学技術大学院大学)



- 主 催 日本医用画像工学会
(The Japanese Society of Medical Imaging Technology)
- 後 援 一般社団法人 日本画像医療システム工業会
(JIRA:Japan Medical Imaging and Radiological Systems Industries Association)
一般社団法人 保健医療福祉情報システム工業会
(JAHIS:Japanese Association of Healthcare Information Systems Industry)
一般社団法人 電子情報技術産業協会
(JEITA:Japan Electronics and Information Technology Industries Association)
- 協 賛
- | | |
|--------------|-------------------|
| IEEE関西支部 | 医用画像情報学会 |
| 医用画像認知研究会 | 応用物理学会 |
| 可視化情報学会 | 画像電子学会 |
| 看護理工学会 | 三次元画像コンファレンス実行委員会 |
| 情報処理学会 | 電子情報通信学会 |
| 日本医学物理学会 | 日本医学放射線学会 |
| 日本医療情報学会 | 日本核医学会 |
| 日本核医学技術学会 | 日本画像医学会 |
| 日本コンピュータ外科学会 | 日本磁気共鳴医学会 |
| 日本写真学会 | 日本生体医工学会 |
| 日本超音波医学会 | 日本脳神経CI学会 |
| 日本放射線技術学会 | |

学会長ご挨拶

第38回日本医用画像工学会大会は奈良先端科学技術大学院大学教授 佐藤嘉伸大会長の運営のもとで、2019年7月24日（水）から26日（金）の3日間、奈良春日野国際フォーラムにて開催されることになりました。一年以上前から準備をされてきた大会関係者や事務局の皆様、そして企業の業務委員会の皆様のご尽力に厚く御礼申し上げます。

医用画像工学の領域においても人工知能（Artificial Intelligence: AI）は有力な技術となるため、診断支援、画像処理、画像再構成をはじめとして多くの応用研究が盛んに行われております。今回の大会でも「AI時代の医用画像工学」というテーマで様々なアプローチでの研究が報告されることとなりますので大変楽しみです。また、特別講演では、今のAI時代の礎を築かれた福島邦彦先生のネオコグニトロンのご講演を拝聴できるのでとても期待しております。このようなAI技術と密接な関係があるのはビッグデータですが、国立情報学研究所（National Institute of Informatics: NII）では医療ビッグデータ研究センターを立ち上げ、国家レベルで匿名化された医療画像情報を収集して医療画像ビッグデータクラウド基盤の構築を始めています。このような最新の動向もシンポジウムの中で聞くことができるようになっていきますので、医用画像データとAIの今後も俯瞰できるのではないかと期待しております。また、もう一つの特別講演では奈良県立医科大学学長の細井裕司先生から、医学とまちづくりをテーマとするお話もうかがえることになっており、新しい切り口の医学のあり方のご提案とも推察され、とても興味があります。

今回の大会では佐藤嘉伸大会長のご提案で、すべての一般演題において2分程度の口頭発表（ティーザー）とポスター発表の両方を行う事になっています。今までのJAMITとは違った形式での発表となりますが、すべての研究論文の要点を聞くことができると共に、興味ある内容はポスターでじっくり議論できるという、いいとこ取りの斬新な試みも取り入れられています。

今大会の中では、上記のような企画の他、恒例となりましたハンズオンによるAI講習会をはじめとして、盛りだくさんの企画が用意されていますので、会員の皆様には実りの大きい大会となると思っております。この大会における皆様の活発な意見交換により、医用画像工学の研究が大きく進展することを期待しています。

日本医用画像工学会

会長 尾川 浩一（法政大学）

大会長ご挨拶

第38回日本医用画像工学会（JAMIT）大会を2019年7月24～26日に奈良にて開催させていただくことになりました。大会のテーマは「AI時代の医用画像工学」としました。

AI（人工知能）は、もはや単なるブームでなく、AI以前の方法では達成できない、人間を上回りうる高性能を得るための必要不可欠な技術として定着し、さらに発展を続けています。JAMIT大会では、2016年の千葉大会の頃から、AIが大会のメインピックとなってきました。医用画像を専門としない一般の方々からみても、今や医用画像診断は、自動運転などと並んで、AIの社会実装が最も期待される分野となっています。イメージングにおいてもAIを利用した画像再構成、超解像、モダリティ変換など、その影響力は多大です。

本大会では、AIに関する特別企画として、AIの中心技術である深層学習、その中でも、中心的方法である畳み込みニューラルネット（CNN）の基礎を与えた「ネオコグニトロン」を開発された福島邦彦先生に、特別講演をしていただきます。さらに、シンポジウムでは、国立情報学研究所と医学系各学会の連携による国家規模の医用画像ビッグデータAI解析に関するAMEDプロジェクトを取り上げます。これら歴史的研究や最新の大規模プロジェクトに加えて、2017年の岐阜大会から始まり、例年、好評を博しております深層学習ハンズオンもさらに強化され、参加者一人一人がAIの基礎を勉強する場を設けています。今年は、一般演題についても、AIに関係する演題が半数に達しており、まさしく医用画像工学はAI時代に突入しています。

本学会は、医工連携、医療IT、産学連携などとも密接に関係しております。ここ奈良の地で、それらに加えて、「まちづくり」という視点を加えた「医学を基礎とするまちづくり、Medicine-Based Town (MBT)」のプロジェクトが進行しています。このプロジェクトを推進している奈良県立医大・学長の細井裕司先生に特別講演をしていただきます。「まち」に、医科大学や医師等が持つ医学の知識・叡智を注ぎ込んで、付加価値の高いまちMBTをつくります。また、この過程が新産業創生、地方創生の原動力となります。このプロジェクトは、実際に、種々の連携体制の下、奈良県橿原市において実践されており、今後の展開が大いに期待されます。

その他の話題については、2つめのシンポジウムにおいて、医用画像を中心として、時空間多重スケール、病理、機能の多元データを統合することにより人体の総理解を目指す、科研費・新学術領域「多元計算解剖学」の成果報告を行います。ミニシンポジウムにおいては、生きた状態を4次元でイメージングする最新のバイオ顕微鏡画像を、AIを含む情報技術によって解析し新しい生命科学の創成を目指すプロジェクトを紹介します。もう一つのミニシンポジウムでは、本学会のメインピックの一つであるCTやMRのイメージングと深層学習を統合した新しい研究の流れに焦点を当てます。2017年岐阜大会、2018年筑波大会に引き続き、企業協賛のランチョンセミナーも企画されています。ランチョンセミナーでは研究病院の臨床現場のAI導入に関する興味深い話が聞けるものと思います。

開催場所である奈良春日野国際フォーラム Ⅰ・Ⅱ・Ⅲは、奈良公園内にあり、また、世界遺産である東大寺と春日大社の中間地点に位置しており、奈良観光にも大変便利な場所にあります。奈良において、医用画像工学の将来と共に、奈良時代の歴史にも思いを馳せていただければと思います。

第38回日本医用画像工学会大会

大会長 佐藤 嘉伸

（奈良先端科学技術大学院大学）

交通案内

徒 歩

近鉄奈良駅 2 番出口より徒歩 20 分

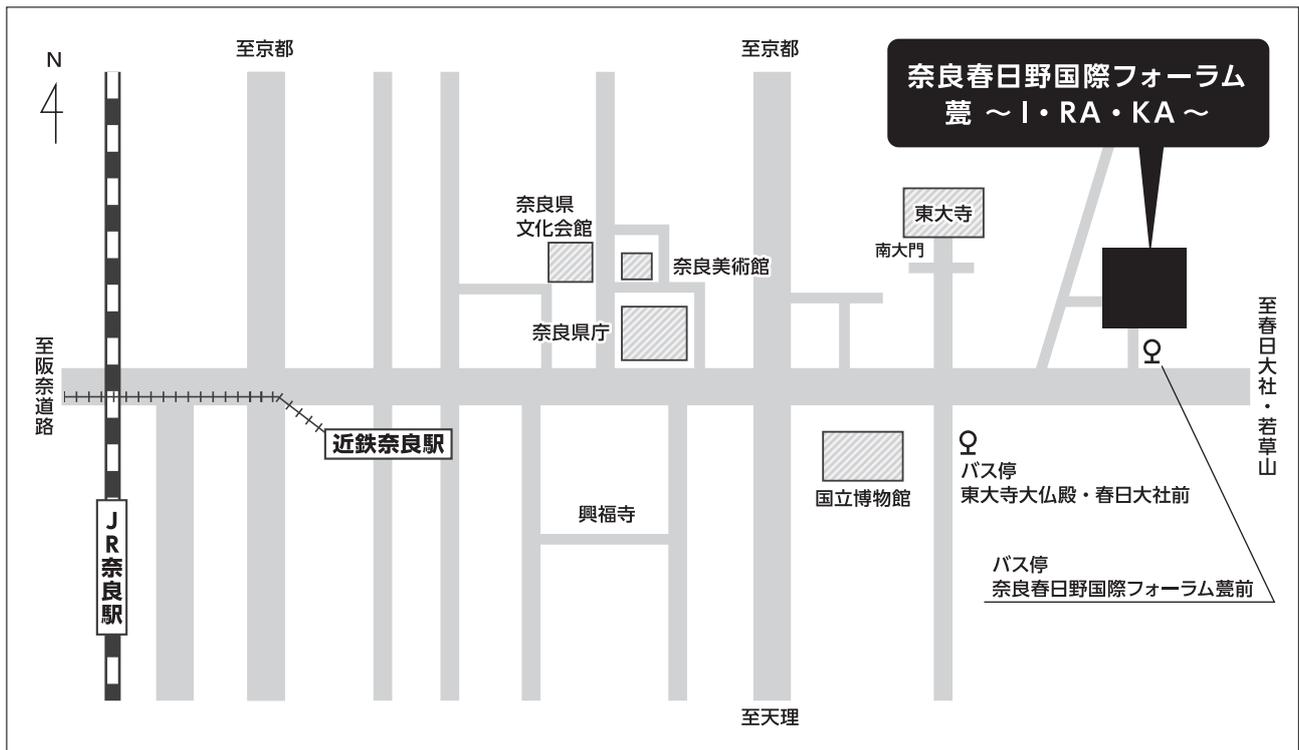
バ ス

(1) 近鉄奈良駅 5 番出口より奈良交通バス 1 番のりば

(2) JR 奈良駅より奈良交通バス東口 2 番のりば

(1), (2) とも

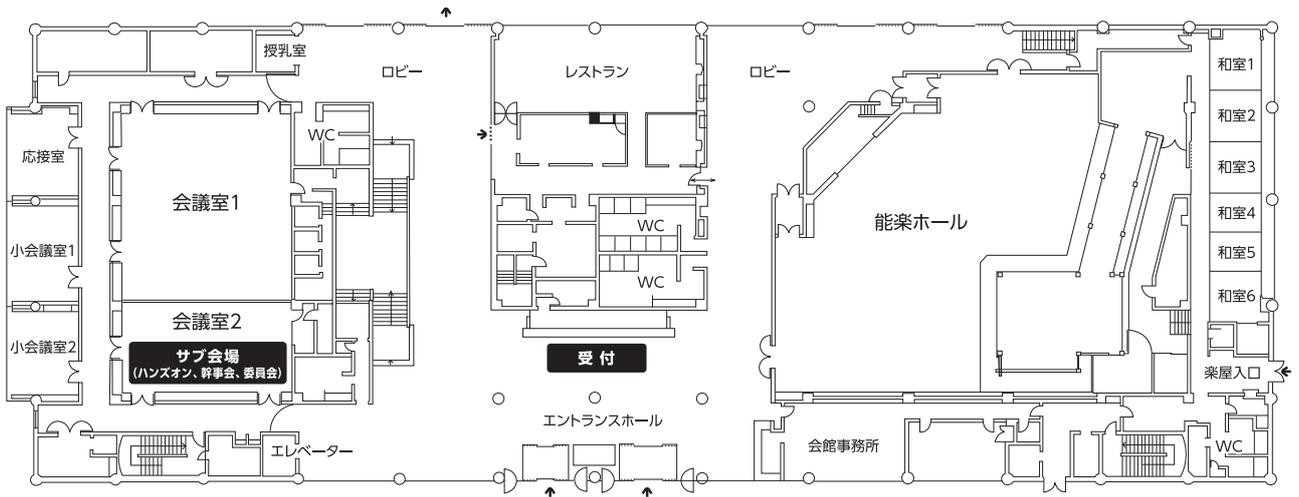
「春日大社本殿」行き「奈良春日野国際フォーラム薨前」下車すぐ又は、
「市内循環（外回り）」バス「東大寺大仏殿・春日大社前」下車、
大仏殿交差点東 へ徒歩 3 分



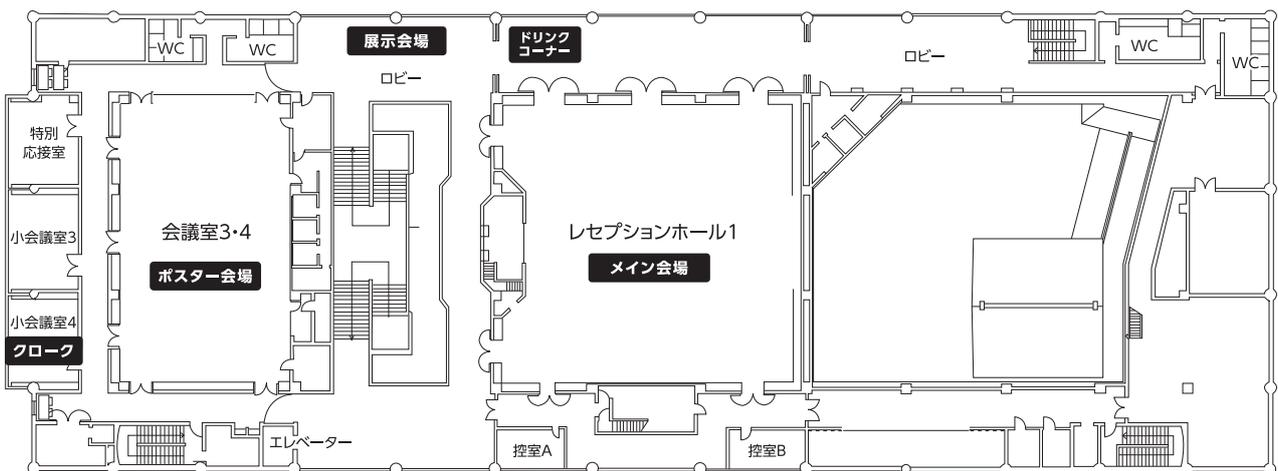
会場案内図

奈良春日野国際フォーラム薨～I・RA・KA～ 奈良市春日野町 101

本館 1F



本館 2F



参加者へのご案内

1. 会 期：2019年7月24日（水）～7月26日（金）

2. 会 場：奈良春日野国際フォーラム 麓～I・RA・KA～

〒630-8212 奈良市春日野町101 TEL:0742-27-2630（問い合わせ先）
<http://www.i-ra-ka.jp/iraka/access/>

講演会場：メイン会場：本館2階 レセプションホール1
ポスター会場：本館2階 会議室3・4
展示会場：本館2階 ロビー
ハンズオンセミナー：本館1階 会議室2
ご参加いただくには参加証の提示が必要です。

3. 参加登録

1) 登録：当日

7月24日（水） 12：40～18：00 本館1階エントランスホール
7月25日（木） 8：30～17：00
7月26日（金） 8：30～15：00

2) 参加費

正会員（賛助会員含む）：10,000円 学生会員：4,000円 非会員：20,000円
（会場での受付のみ／事前登録はありません）

4. 総 会

日時：7月25日（木） 13：00～14：00 会場：メイン会場（レセプションホール1）

5. 予稿集について

印刷物としての「予稿集」は作成しません。ダウンロード（PDF）形式で当日、参加者に配布します。
会場で予稿集をご覧になるにはノートPCなどを各自ご持参下さい。

6. 発表者へのご案内

1) 一般演題の発表は、発表時間前半にメイン会場（レセプションホール1）にて各演題口演2分、後半にポスター会場（会議室3・4）にてインタラクティブセッションです。

2) ポスターはW1200mm×H1800mmのパネルに収まるサイズにて作成してください。

ポスターの貼付と撤去は下記の時間内に行ってください。

一般演題セッション1・2： 貼付：7月24日（水）12：30～16：10
撤去：7月25日（木）10：30～12：00

一般演題セッション3・4・5： 貼付：7月25日（木）12：30～16：10
撤去：7月26日（金）15：20～17：15

3) 口演用のスライド（3枚以内程度。口演は2分で打ち切ります）を定められた期日までにご提出ください。

スライドの作成、提出の仕方、提出期日、その他注意点につきましては、大会ホームページ「参加者へのご案内」をご確認ください。

7. 座長へのご案内

担当セッションが始まる10分前までに、座長席近くにお越しになり待機してください。

8. 発表者資格

一般演題の筆頭発表者は、日本医用画像工学会の会員に限ります。非会員の方は必ず6月末日までに入会申込みをし、7月20日までに会費を納入してください。

9. 入会手続き及びお問い合わせ

日本医用画像工学会事務局（<http://www.jamit.jp/>）

〒104-0033 東京都中央区新川1-5-19 6階（株）メイプロジェクト内
TEL: 03-6264-9071 FAX: 03-6264-8344 E-mail: jamit@may-pro.net

10. 利益相反 (COI) について

筆頭発表者が、日本医用画像工学会における「利益相反の取扱いに関する規程」において開示の対象となる場合、この規定に基づいて、発表者の申告した利益相反の状態が予稿集に開示されます。また、発表の際には発表者本人が開示します。

11. 各種役員会

- | | | | |
|----------|----------|-------------|-----------------|
| 1) 広報委員会 | 7月24日(水) | 12:30~13:00 | 会場:サブ会場(1階会議室2) |
| 2) 幹事会 | 7月25日(木) | 11:45~12:45 | 会場:サブ会場(1階会議室2) |
| 3) 編集委員会 | 7月26日(金) | 11:45~12:45 | 会場:サブ会場(1階会議室2) |

12. 特別講演

- 特別講演1:7月25日(木) 14:00~14:50 会場:メイン会場
軟骨伝導の発見からMBT(医学を基礎とするまちづくり)へ
細井 裕司(奈良県立医科大学 理事長・学長)
座長:佐藤 嘉伸(奈良先端科学技術大学院大学/JAMIT2019大会長)
- 特別講演2:7月26日(金) 13:00~13:50 会場:メイン会場
ネオコグニトロンと畳み込みニューラルネットワーク
福島 邦彦(ファジィシステム研究所 特別研究員)
座長:尾川 浩一(法政大学/日本医用画像工学会 会長)

13. 第9回 JAMIT チュートリアル講演会(教育委員会企画)

(コニカミノルタ科学技術振興財団 JAMIT ハンズオンセミナー 連携企画)

「Beyond Deep Learning」

第38回日本医用画像工学会大会のプログラムの一環として「第9回日本医用画像工学会(JAMIT)チュートリアル講演会~Beyond Deep Learning~」を第1日目の午後に開催いたします。チュートリアルでは、医用画像工学に携わる若手研究者や最新の動向を得たい第一線の研究者を対象として、現在の研究に役立つテーマを専門の研究者が講演します。

- 日時:7月24日(水) 13:20~16:10 会場:メイン会場
座長:中田 典生(東京慈恵会医科大学)/小田 昌宏(名古屋大学)
講演1:世間の流行に左右されない深層学習所感
鈴木 賢治(東京工業大学/イリノイ工科大学)
講演2:様々な大規模計算環境の得手・不得手~何ができて何ができない?~
平野 靖(山口大学)
講演3:医師が取り組んだ深層学習:臨床からスパコンまで
花岡 昇平(東京大学)

14. コニカミノルタ科学技術振興財団 JAMIT ハンズオンセミナー

深層学習の実行環境は、比較的簡単に構築できます。本ハンズオンでは、参加者は、事前に提供されるセットアップ資料に基づいて、自分自身のコンピュータにTensorFlow/Keras/Pythonによる実行環境を構築し、その上で画像分類/領域分割/回帰について、医用画像を利用した基本的な課題を実行します。また、DICOMファイルの読み込みなどの前処理の方法や、構築したモデルの保存/読み込みといった実践的な方法についても触れます。そして、課題に応じた評価方法についても考え方や処理方法を実践的に習得します。なお、本ハンズオンは、コニカミノルタ科学技術振興財団助成事業として、学生/若手研究者の支援を目的として実施します。(注意:参加には、事前のセットアップとコンピュータの持ち込みが必要です)

7月24日水曜日のチュートリアル講演の受講後は、90分のハンズオンセミナーに参加していただきます。セミナーは、学会期間中5回開催します(すべて同一内容です)。いずれかの中でご都合のよい時間に1回受講してください。ここでは、深層学習の習得を目的として、課題に取り組んでいただきます。

- 課題1:画像分類/胸部単純X線画像の方向を認識する
課題2:領域分割/胸部単純X線画像のセグメンテーション
課題3:回帰/胸部単純X線画像から年齢を推定する
課題4:PythonでDICOMファイルを読んでみよう!
(実験対象の画像や課題は、変更の可能性があります)

GPUなしでも操作できる程度の画像と学習枚数を使い、スクリプトの書き方、評価方法などを学んでいただきます。詳細は、「コニカミノルタ科学技術振興財団JAMITハンズオンセミナー」の専用ウェブページをご覧ください。

開催スケジュール：5月1日 募集ページオープン／予約開始

7月1日 セットアップ資料公開

7月10日 募集締め切り

7月23日 当日資料の事前公開

7月24日～26日 大会

受講スケジュール：7月24日水曜日：チュートリアル講演の受講をお願いします。

第1回：7月24日（水）16：25～

第2回：7月25日（木）9：00～

第3回：7月25日（木）16：25～

第4回：7月26日（金）9：00～

第5回：超初級者編 7月26日（金）14：00～

（各回90分。第1回～第4回は同じ内容、第5回は重複受講可能です。）

会場：サブ会場（1階 会議室2）

運営スタッフ：原 武史（岐阜大学）／中田 典生（東京慈恵会医科大学）／小田 昌宏（名古屋大学）

福岡 大輔（岐阜大学）／田中 利恵（金沢大学）／中山 良平（立命館大学）

本セミナーは、コニカミノルタ科学技術振興財団の支援を得て実施しています。また、岐阜大学人工知能推進センターの協力で実施します。

15. シンポジウム・ミニシンポジウム

ミニシンポジウム1：7月25日（木）10：40～11：30 会場：メイン会場

CT・MR イメージングにおける深層学習

世話人／座長：増谷 佳孝（広島市立大学）

講演1：深層学習を用いたCT及びPET/SPECTの画像再構成

工藤 博幸（筑波大学）

講演2：深層学習を用いたCT画像の金属アーチファクト低減処理

大竹 義人（奈良先端科学技術大学院大学）

講演3：深層学習を利用したMRイメージング

伊藤 聡志（宇都宮大学）

講演4：生成型Q空間学習による拡散MRイメージング

増谷 佳孝（広島市立大学）

シンポジウム1：7月25日（木）15：05～16：25 会場：メイン会場

医用画像のビッグデータとAI開発の展望

世話人／座長：村尾 晃平（国立情報学研究所）／中田 典生（東京慈恵会医科大学）

講演1：医療画像ビッグデータクラウド基盤

合田 憲人（国立情報学研究所）

講演2：AMEDプロジェクトにおける画像解析タスク俯瞰、眼科画像の解析

佐藤 真一（国立情報学研究所）

講演3：病理と内視鏡画像における胃がん検知システムの開発

原田 達也／黒瀬 優介（東京大学）

講演4：大腸の画像診断：大腸生検の病理画像解析および大腸の内視鏡画像解析

内田 誠一／備瀬 竜馬（九州大学）

講演5：AMED大規模データベースを用いたCT画像解析と病変検出への応用

森 健策／小田 昌宏（名古屋大学）

講演6：大規模CTデータ解析による骨格解剖知識の抽出

大竹 義人／日朝 祐太（奈良先端科学技術大学院大学）

高尾 正樹／菅野 伸彦（大阪大学）

佐藤 嘉伸（奈良先端科学技術大学院大学）

講演7：超音波画像データベース構築とAI開発の取り組み

椎名 毅（京都大学）／目加田慶人（中京大学）

講演8：OpenAIとTradeAI

中田 典生（東京慈恵会医科大学）

総合討論：臨床診断の立場からの特別発言と総合討論

縄野 繁（国際医療福祉大学）／シンポジウム1演者全員

ミニシンポジウム2：7月26日（金） 10：40～11：30 会場：メイン会場
生命機能イメージングの革新：今後の課題と展望
世話人／座長：清末 優子（理化学研究所）／末次 志郎（奈良先端科学技術大学院大学）
講演1：イントロ：JST CREST 情報計測領域について
清末 優子（理化学研究所）
講演2：クライオ電子顕微鏡法による生体分子の構造解析
光岡 薫（大阪大学）
講演3：高速原子間力顕微鏡による生体分子イメージングと機械学習・データ同化
高田 彰二（京都大学）
講演4：細胞活動の高精度3D計測と画像情報解析の次世代化に向けて
清末 優子（理化学研究所）

シンポジウム2：7月26日（金） 15：35～16：55 会場：メイン会場
多元計算解剖学のこれから - さらなる飛躍を目指して
世話人／座長：森 健策（名古屋大学）／清水 昭伸（東京農工大学）
講演1：多元計算解剖学において生み出されたもの
橋爪 誠（九州大学）
講演2：多元計算解剖学における数理
本谷 秀堅（名古屋工業大学）
講演3：多元計算解剖学における多元モデリング
佐藤 嘉伸（奈良先端科学技術大学院大学）
講演4：多元計算解剖学と人工知能ブーム
藤田 広志（岐阜大学）
講演5：多元計算解剖学のその先にあるもの
森 健策（名古屋大学）
パネル討論：多元計算解剖学の今後の発展に向けて

16. NVIDIA / GDEP アドバンス 共催ランチョンセミナー

7月26日（金） 11：50～12：40 会場：メイン会場
DGX-2によって加速されるメディカル AI 開発のためのデータ構造化プラットフォーム
小林 和馬（国立研究開発法人国立がん研究センター研究所 がん分子修飾制御学分野）
座長：中田 典生（東京慈恵会医科大学）
参加者の皆様にお弁当をご用意いたしますが、数に限りがございます。

17. 懇親会

参加者相互の情報交換のため、懇親会を企画いたしました。ぜひご参加ください。
日時：7月25日（木） 18：30～20：00
会場：奈良国立博物館 B1 レストラン『葉風泰夢（ハーフタイム）』
参加費：無料（大会参加費に含まれます。参加は大会参加者に限ります。）

ご 協 力 団 体

本大会は下記企業及び団体にご協力いただきました。心より感謝申し上げます。

共催セミナー： NVIDIA 合同会社
株式会社 GDEP アドバンス

助 成 ： 公益財団法人 コニカミノルタ科学技術振興財団

企 業 展 示 ： アプライド株式会社
株式会社 HPC テック
株式会社エクセル・クリエイツ
株式会社 GDEP アドバンス

協 賛 金 ： 株式会社メディアーク

広 告 掲 載 ： PSP 株式会社
医歯薬出版株式会社
富士通株式会社
富士フイルムメディカル株式会社
株式会社インナービジョン
株式会社オーム社
株式会社オブティム
株式会社 島津製作所
株式会社メディアーク

第1日目/7月24日(水)

	メイン会場 (レセプションホール1)	ポスター会場 (会議室3・4)	展示会場 (ロビー)	サブ会場 (1階 会議室2)
12:30		12:30 - 16:10 OP1 / OP2 ポスター貼付		12:30 - 13:00 広報委員会
13:10	13:10 - 13:20 開会式		展示	
13:20	第9回 JAMIT チュートリアル講演会 (教育委員会企画) (コニカミノルタ科学技術振興財団、JAMIT ハンズオンセミナー連携企画) TL [Beyond Deep Learning] 13:20-14:20 TL1 「世間の流行に左右されない深層学習所感」 鈴木 賢治 14:30 - 15:20 TL2 「様々な大規模計算環境の得手・不得手～ 何ができて何ができない?～」 平野 靖 15:20 - 16:10 TL3 「医師が取り組んだ深層学習: 臨床からスパコンまで」 花岡 昇平 座長: 中田 典生 / 小田 昌宏			
16:10	コーヒーブレイク			
16:25	16:25 - 18:00 一般演題セッション1 (前半:メイン会場にて口頭発表 後半:ポスターセッション) OP1 「イメージング/画質改善」「画像解析/モデリング」「CAD/臨床応用」(OP1-1 ~ 25) 座長: 湯浅 哲也 / 健山 智子 / 石田 隆行			16:25 - 17:55 ハンズオンセミナー 1 HS1 「Deep Learning」
18:00				

第2日目/7月25日(木)

	メイン会場 (レセプションホール1)	ポスター会場 (会議室3・4)	展示会場 (ロビー)	サブ会場 (1階 会議室2)
9:00	9:00 - 10:30 一般演題セッション2 (前半:メイン会場にて口頭発表 後半:ポスターセッション) OP2 「イメージング/画質改善」「画像解析/モデリング」「CAD/臨床応用」(OP2-1 ~ 24) 座長: 小尾 高史 / 中口 俊哉 / 花岡 昇平		展示	9:00 - 10:30 ハンズオンセミナー 2 HS2 「Deep Learning」
10:30	コーヒーブレイク	10:30 - 12:00 OP1 / OP2 ポスター撤去		
10:40	10:40 - 11:30 ミニシンポジウム1 MS1 「CT・MR イメージングにおける深層学習」 工藤 博幸 / 大竹 義人 / 伊藤 聡志 / 増谷 佳孝 座長: 増谷 佳孝			
11:30	昼食			11:45 - 12:45 幹事会
13:00	13:00 - 14:00 総会	12:30 - 16:10 OP3 / OP4 / OP5 ポスター貼付		
14:00	14:00 - 14:50 特別講演1 SL1 「軟骨伝導の発見から MBT (医学を基礎とするまちづくり)へ」 細井 裕司 座長: 佐藤 嘉伸			
14:50	コーヒーブレイク			
15:05	15:05 - 16:25 シンポジウム1 SY1 「医用画像ビッグデータと AI 開発の展望」 合田 憲人 / 佐藤 真一 / 原田 達也 / 黒瀬 優介 / 内田 誠一 / 備瀬 竜馬 / 森 健策 / 小田 昌宏 / 佐藤 嘉伸 / 大竹 義人 / 椎名 毅 / 目加田慶人 / 中田 典生 / 縄野 繁 座長: 村尾 晃平 / 中田 典生			
16:25	16:25 - 17:55 一般演題セッション3 (前半:メイン会場にて口頭発表 後半:ポスターセッション) OP3 「イメージング/画質改善」「画像解析/モデリング」「CAD/臨床応用」(OP3-1 ~ 24) 座長: 伊藤 聡志 / 上村 幸司 / 内山 良一			16:25 - 17:55 ハンズオンセミナー 3 HS3 「Deep Learning」
18:30	18:30 - 20:00 懇親会 (会場: 奈良国立博物館 B1 レストラン<葉風泰夢 (ハーフタイム)>)			

第3日目/7月26日(金)

	メイン会場 (レセプションホール1)	ポスター会場 (会議室3・4)	展示会場 (ロビー)	サブ会場 (1階 会議室2)
9:00	9:00 - 10:30 一般演題セッション4 (前半:メイン会場にて口頭発表 後半:ポスターセッション) OP4 「イメージング/画質改善」「画像解析/モデリング」「CAD/臨床応用」(OP4-1 ~ 24) 座長: 山谷 泰賀 / 本谷 秀堅 / 畑中 裕司		展示	9:00 - 10:30 ハンズオンセミナー 4 HS4 「Deep Learning」
10:30	コーヒーブレイク			
10:40	10:40 - 11:30 ミニシンポジウム2 MS2 「生命機能イメージングの革新: 今後の課題と展望」 光岡 薫 / 高田 彰二 / 清末 優子 座長: 清末 優子 / 末次 志郎			
11:50	11:50 - 12:40 ランチョンセミナー LS 「DGX-2 によって加速されるメディカル AI 開発のためのデータ構造化プラットフォーム」 小林 和馬 座長: 中田 典生			11:45 - 12:45 編集委員会
13:00	13:00 - 13:50 特別講演2 SL2 「ネオコグニトロンと畳み込みニューラルネットワーク」 福島 邦彦 座長: 尾川 浩一			
13:50	13:50 - 15:20 一般演題セッション5 (前半:メイン会場にて口頭発表 後半:ポスターセッション) OP5 「イメージング/画質改善」「画像解析/モデリング」「CAD/臨床応用」(OP5-1 ~ 24) 座長: 菅 幹生 / 滝沢 穂高 / 野村 行弘			14:00 - 15:30 ハンズオンセミナー 5 超初級者編 HS5 「Deep Learning」
15:20	コーヒーブレイク	15:20 - 17:15 OP3 / OP4 / OP5 ポスター撤去		
15:35	15:35 - 16:55 シンポジウム2 SY2 「多元計算解剖学のこれから - さらなる飛躍を目指して」 橋爪 誠 / 本谷 秀堅 / 佐藤 嘉伸 / 藤田 広志 / 森 健策 座長: 森 健策 / 清水 昭伸			
16:55	16:55 - 17:00 閉会式			

特別講演

7月25日(木) 14:00～14:50

メイン会場 (レセプションホール1)

SL1 「軟骨伝導の発見から MBT (医学を基礎とするまちづくり) へ」

座長：佐藤 嘉伸

(奈良先端科学技術大学院大学 / JAMIT2019 大会長)

SL1

軟骨伝導の発見から MBT (医学を基礎とするまちづくり) へ

細井 裕司 (奈良県立医科大学 理事長・学長)

7月26日(金) 13:00～13:50

メイン会場 (レセプションホール1)

SL2 「ネオコグニトロンと畳み込みニューラルネットワーク」

座長：尾川 浩一 (法政大学 / JAMIT 学会長)

SL2

ネオコグニトロンと畳み込みニューラルネットワーク

福島 邦彦 (ファジィシステム研究所 特別研究員)

第9回 JAMIT チュートリアル講演会

(教育委員会企画)

7月24日(水) 13:20～16:10

メイン会場 (レセプションホール1)

TL 「Beyond Deep Learning」

座長：中田 典生 (東京慈恵会医科大学)

小田 昌宏 (名古屋大学)

TL1

世間の流行に左右されない深層学習所感

鈴木 賢治 (東京工業大学 / イリノイ工科大学 (Illinois Institute of Technology))

TL2

様々な大規模計算環境の得手・不得手 ～何ができて何ができない?～

平野 靖 (山口大学)

TL3

医師が取り組んだ深層学習：臨床からスパコンまで

花岡 昇平 (東京大学)

シンポジウム

7月25日(木) 15:05～16:25

メイン会場 (レセプションホール1)

SY1「医用画像のビッグデータとAI開発の展望」

座長：村尾 晃平 (国立情報学研究所)
中田 典生 (東京慈恵会医科大学)

- SY1-1** 医療画像ビッグデータクラウド基盤
合田 憲人 (国立情報学研究所)
- SY1-2** AMED プロジェクトにおける画像解析タスク俯瞰, 眼科画像の解析
佐藤 真一 (国立情報学研究所)
- SY1-3** 病理と内視鏡画像における胃がん検知システムの開発
原田 達也 (東京大学)
黒瀬 優介 (東京大学)
- SY1-4** 大腸の画像診断：大腸生検の病理画像解析および大腸の内視鏡画像解析
内田 誠一 (九州大学)
備瀬 竜馬 (九州大学)
- SY1-5** AMED 大規模データベースを用いた CT 画像解析と病変検出への応用
森 健策 (名古屋大学)
小田 昌宏 (名古屋大学)
- SY1-6** 大規模CTデータ解析による骨格解剖知識の抽出
大竹 義人 (奈良先端科学技術大学院大学)
日朝 祐太 (奈良先端科学技術大学院大学)
高尾 正樹 (大阪大学)
菅野 伸彦 (大阪大学)
佐藤 嘉伸 (奈良先端科学技術大学院大学)
- SY1-7** 超音波画像データベース構築と AI 開発の取り組み
椎名 毅 (京都大学)
目加田慶人 (中京大学)
- SY1-8** OpenAI と TradeAI
中田 典生 (東京慈恵会医科大学)
- SY1-9** 臨床診断の立場からの特別発言と総合討論
縄野 繁 (国際医療福祉大学)
シンポジウム1 演者全員

7月26日(金) 15:35～16:55

メイン会場 (レセプションホール1)

SY2「多元計算解剖学のこれから - さらなる飛躍を目指して」

座長：森 健策 (名古屋大学)
清水 昭伸 (東京農工大学)

SY2-1 多元計算解剖学において生み出されたもの
橋爪 誠 (九州大学)

SY2-2 多元計算解剖学における数理
本谷 秀堅 (名古屋工業大学)

SY2-3 多元計算解剖学における多元モデリング
佐藤 嘉伸 (奈良先端科学技術大学院大学)

SY2-4 多元計算解剖学と人工知能ブーム
藤田 広志 (岐阜大学)

SY2-5 多元計算解剖学のその先にあるもの
森 健策 (名古屋大学)

SY2-6 パネル討論 多元計算解剖学の今後の発展に向けて

ミニシンポジウム

7月25日(木) 10:40～11:30

メイン会場 (レセプションホール1)

MS1「CT・MR イメージングにおける深層学習」

座長：増谷 佳孝 (広島市立大学)

MS1-1 深層学習を用いた CT 及び PET/SPECT の画像再構成
工藤 博幸 (筑波大学)

MS1-2 深層学習を用いた CT 画像の金属アーチファクト低減処理
大竹 義人 (奈良先端科学技術大学院大学)

MS1-3 深層学習を利用した MR イメージング
伊藤 聡志 (宇都宮大学)

MS1-4 生成型 Q 空間学習による拡散 MR イメージング
増谷 佳孝 (広島市立大学)

MS1-5 質疑応答および全体討論

7月26日(金) 10:40～11:30

メイン会場 (レセプションホール1)

MS2 「生命機能イメージングの革新：今後の課題と展望」

座長：清末 優子 (理化学研究所)

末次 志郎 (奈良先端科学技術大学院大学)

MS2-1 イントロ：JST CREST 情報計測領域について
清末 優子 (理化学研究所)

MS2-2 クライオ電子顕微鏡法による生体分子の構造解析
光岡 薫 (大阪大学)

MS2-3 高速原子間力顕微鏡による生体分子イメージングと機械学習・データ同化
高田 彰二 (京都大学)

MS2-4 細胞活動の高精度 3D 計測と画像情報解析の次世代化に向けて
清末 優子 (理化学研究所)

ランチョンセミナー

7月26日(金) 11:50～12:40

メイン会場 (レセプションホール1)

LS「DGX-2によって加速されるメディカルAI開発のためのデータ構造化プラットフォーム」

座長：中田 典生 (東京慈恵会医科大学)

LS DGX-2によって加速されるメディカルAI開発のためのデータ構造化プラットフォーム
小林 和馬 (国立研究開発法人国立がん研究センター研究所 がん分子修飾制御学分野)

ハンズオンセミナー

7月24日(水) 16:25～17:55

サブ会場 (1階 会議室2)

HS1 「Deep Learning」

7月25日(木) 9:00～10:30

サブ会場 (1階 会議室2)

HS2 「Deep Learning」

7月25日(木) 16:25～17:55

サブ会場 (1階 会議室2)

HS3 「Deep Learning」

7月26日(金) 9:00～10:30

サブ会場 (1階 会議室 2)

HS4 「Deep Learning」

7月26日(金) 14:00～15:30

サブ会場 (1階 会議室 2)

HS5 「Deep Learning」 超初級者編

第1日 7月24日(水)

メイン会場(レセプションホール1)

13:00 ~ 13:20

開会式

チュートリアル講演会

13:20 ~ 16:10

TL1 「Beyond Deep Learning」

座長: 中田 典生 (東京慈恵会医科大学)

小田 昌宏 (名古屋大学)

TL1

世間の流行に左右されない深層学習所感

鈴木 賢治 (東京工業大学/イリノイ工科大学 (Illinois Institute of Technology))

TL2

様々な大規模計算環境の得手・不得手 ~何ができて何ができない?~

平野 靖 (山口大学)

TL3

医師が取り組んだ深層学習: 臨床からスパコンまで

花岡 昇平 (東京大学)

第1日 7月24日(水)

前半(口演): メイン会場(レセプションホール1)

後半: ポスター会場(会議室3・4)

一般演題セッション1

16:25 ~ 18:00

OP1

「イメージング/画質改善」

座長: 湯浅 哲也 (山形大学)

OP1-01

制約付きアンサンブル学習を用いた事後平均解の近似による MR 画像再構成

久保田菜々子 (早稲田大学大学院 先進理工学研究科 電気・情報生命専攻)

OP1-02

X 線 CT 画像上の雑音分散に対する検出器モデルの影響

田之上和矢 (名古屋大学大学院医学系研究科)

OP1-03

スパース化空間の類似性を利用した単一画像超解像

竹間 康浩 (宇都宮大学 大学院工学研究科 情報システム科学専攻)

OP1-04

微小金属のアーチファクト補正を目的とした X 線トモシンセシス装置の検討

山川 恵介 (株式会社日立製作所 研究開発グループ)

- OP1-05 敵対的生成ネットワークを利用した MR 圧縮センシング再構成の基礎検討
大内 翔平 (宇都宮大学 大学院 工学研究科 情報システム科学専攻)
- OP1-06 Simulation study of a novel brain PET scanner using 100 ps TOF-DOI sub-millimeter resolution detectors
李 英英 (浙江大学)
- OP1-07 サイクル損失を用いた 3 次元胸部 CT 像の超解像
河合 良亮 (東京農工大学大学院工学研究院)

「画像解析 / モデリング」

座長：健山 智子 (広島工業大学)

- OP1-08 CycleGAN を用いた胸部 CT 画像のドメイン変換とその識別システムへの応用
三宅 将司 (山口大学)
- OP1-09 楕円フーリエ記述子を用いた乳房 X 線像における石灰化クラスタの解析とデータ拡張への応用
志村 一男 (駒澤大学医療健康科学部)
- OP1-10 演題取り下げ
- OP1-11 単眼腹腔鏡映像からの奥行き推定を利用した術具セグメンテーション
鈴木 拓矢 (中京大学 大学院工学研究科)
- OP1-12 深層学習を用いた骨密度測定時の X 線画像における大腿骨セグメンテーション
押川 翔太 (株式会社島津製作所 医用機器事業部 技術部)
- OP1-13 金属表面の画像照合に基づく手術器具の個品管理システム
牧野 賢吾 (日本電気株式会社 データサイエンス研究所)
- OP1-14 舌診断支援システムの自動化に向けた舌検出と領域抽出の検討
唐 啓超 (千葉大学大学院融合理工学府)
- OP1-15 少量のラベルデータを用いた学習によるイレウス症例 CT 像における拡張腸管の自動抽出
小田 紘久 (名古屋大学情報学研究所)
- OP1-16 高解像度連続切片標本画像による股関節周辺領域における神経筋骨格構造のモデル化のための線維トラクトグラフィの応用
時末 尚悟 (奈良先端科学技術大学院大学)

「CAD/ 臨床応用」

座長：石田 隆行 (大阪大学)

- OP1-17 画像認識技術によるうつ病診断の定量化
牧 優太 (神奈川工科大学)
- OP1-18 肝細胞癌に対する選択的 TACE 施行時の Angio-CT を用いた栄養血管同定ナビゲーションソフト (Embolization plan) の初期使用成績と注入造影剤濃度の影響について
葛和 剛 (奈良県立医科大学連携大学院 先端画像下治療開発応用学講座)
- OP1-19 敵対的生成ネットワークを用いた硬性白斑画像の生成と検証
藤田 真穂 (滋賀県立大学大学院工学研究科電子システム工学専攻)

- OP1-20 液状細胞診画像と患者情報の併用による肺癌組織型自動分類の基礎的検討
山田あゆみ (藤田医科大学 医療科学部)
- OP1-21 ResSENet を用いたオートエンコーダによる認知症の疾患鑑別
藤林 大毅 (株式会社 Splink)
- OP1-22 ドメイン敵対的学習を用いる病理画像からの悪性リンパ腫候補領域の抽出と病型識別
古賀 諒一 (名古屋工業大学)
- OP1-23 造影 CT 画像における 2 段階閾値処理及びテクスチャ解析による外傷出血自動検出の検討
木村 拓貴 (千葉大学 大学院融合理工学府)
- OP1-24 深層学習における学習データセット規模拡大に応じた分類精度向上に関する実験的検討
～超拡大大腸内視鏡画像における腫瘍性病変分類に向けた特徴量抽出～
伊東 隼人 (名古屋大学大学院 情報学研究科)
- OP1-25 CNN を用いた人工股関節全置換術術後 CT 画像からの自動インプラント姿勢推定
阪本 充輝 (奈良先端科学技術大学院大学先端科学技術研究科)

第 1 日 7 月 24 日 (水)

サブ会場 (1 階 会議室 2)

ハンズオンセミナー 1

16:25 ~ 17:55

HS1 「Deep Learning」

一般演題セッション2

9:00~10:30 OP2

「イメージング/画質改善」

座長:小尾 高史(東京工業大学)

- OP2-01 MR圧縮センシングにおけるADMM-Netを利用した深層学習再構成の検討
植松 駿(宇都宮大学 大学院地域創生科学研究科 工農総合科学専攻)
- OP2-02 Electron-Tracking Compton Cameraを用いた異なるエネルギー帯でのリストモードMLEM画像の画質評価
稲垣 将史(法政大学大学院 理工学研究科)
- OP2-03 コンプトン検出器を組み合わせた部分リングPETジオメトリの提案
田島 英朗(量子科学技術研究開発機構 放射線医学総合研究所)
- OP2-04 被写体スキャン方式によるX線位相イメージング法の開発
堀場 日明(株式会社島津製作所 基盤技術研究所)
- OP2-05 学習データセットを必要としない畳み込みニューラルネットワークを用いたDynamic PET画像のノイズ除去手法
橋本二三生(浜松ホトニクス株式会社 中央研究所)
- OP2-06 畳み込みニューラルネットワークを用いた低線量CT画像再構成法の多時相CTイメージングへの拡張
森 和希(筑波大学システム情報工学研究科 コンピュータサイエンス専攻)
- OP2-07 FDTDによるShear wave elastographyの不安定要因の検証
伊藤 大貴(千葉大学 大学院 融合理工学府)

「画像解析/モデリング」

座長:中口 俊哉(千葉大学)

- OP2-08 表現学習とSVMによる胃壁マイクロCT像の半教師ありセグメンテーション手法
御手洗 翠(名古屋大学大学院情報学研究科)
- OP2-09 MR画像と病理画像の統合による膀胱腫瘍の多重解像度モデルの構築
下村 智茂(名古屋工業大学生)
- OP2-10 機械学習を用いた人工膝関節画像からの機種同定 ~マハラノビス距離による識別効果とCNNの適用~
岸野万由子(埼玉工業大学 工学部 情報システム学科)
- OP2-11 所見テキスト解析を用いるH&E染色病理画像からの免疫染色群推定
黄 果葡(名古屋工業大学)

- OP2-12 深層学習を用いた術野映像内肺領域抽出
今西 勁峰 (イーグロース株式会社)
- OP2-13 高難易度画素用の損失関数を用いたセマンティックセグメンテーション
松月 大輔 (名城大学)
- OP2-14 Polyp size classification in colorectal cancer using a Siamese network
ヴィラードベンジャミン (名古屋大学大学院情報学研究科)
- OP2-15 病変検出支援アルゴリズムにおける局所画像特徴量の汎用的な自動生成 - 健常データのみでの学習による特徴量生成の検討 -
牛房 和之 (近畿大学大学院 生物理工学研究科)
- OP2-16 X 線単純投影と流体構造連成解析を用いた狭窄柔軟管内流れにおける造影剤濃度勾配の評価
金子凌太郎 (東京大学工学部)

「CAD/ 臨床応用」

座長：花岡 昇平 (東京大学)

- OP2-17 Coxnet と NMF を用いた非小細胞肺癌の組織学的分類
山田 真大 (九州大学大学院 医学系学府 保健学専攻)
- OP2-18 CNN を用いた CAD 開発における段階的学習法の提案
安倍 和弥 (神奈川工科大学)
- OP2-19 Coxnet によって選択されたレディオミクスシグネチャによる SVM を用いた頭頸部癌患者の 5 年生存確率の予測
Le CuongQuoc (九州大学大学院 医学系学府 保健学専攻)
- OP2-20 Kinect を用いた効率的な 3 次元顔面腫れ顔の形態変化の観測と可視化
健山 智子 (広島工業大学 情報学部 知的情報可視化研究室)
- OP2-21 GAN による CT 肺結節画像の生成
濱口 拓真 (山口大学大学院創成科学研究科)
- OP2-22 AutoEncoder の正常症例訓練モデルによる FDG-PET 画像中の悪性腫瘍検出手法に関する研究
前田 健宏 (岐阜大学大学院自然科学技術研究科知能理工学専攻)
- OP2-23 低線量 CT 画像を用いた肺結節の経時変化による良悪性鑑別
東 勇太 (徳島大学大学院先端技術科学教育部)
- OP2-24 造影 MR 画像における部分最小二乗法による肝臓形状解析及びテクスチャ解析を用いた肝線維化のステージ分類
スーフィーマーゼン (奈良先端科学技術大学院大学)

第2日 7月25日(木)

メイン会場(レセプションホール1)

ミニシンポジウム1

10:40 ~ 11:30

MS1 「CT・MR イメージングにおける深層学習」

座長: 増谷 佳孝 (広島市立大学)

- MS1-1 深層学習を用いた CT 及び PET/SPECT の画像再構成
工藤 博幸 (筑波大学)
- MS1-2 深層学習を用いた CT 画像の金属アーチファクト低減処理
大竹 義人 (奈良先端科学技術大学院大学)
- MS1-3 深層学習を利用した MR イメージング
伊藤 聡志 (宇都宮大学)
- MS1-4 生成型 Q 空間学習による拡散 MR イメージング
増谷 佳孝 (広島市立大学)
- MS1-5 質疑応答および全体討論

第2日 7月25日(木)

メイン会場(レセプションホール1)

特別講演1

14:00 ~ 14:50

SL1 「軟骨伝導の発見から MBT (医学を基礎とするまちづくり) へ」

座長: 佐藤 嘉伸

(奈良先端科学技術大学院大学 / JAMIT2019 大会長)

- SL1 軟骨伝導の発見から MBT (医学を基礎とするまちづくり) へ
細井 裕司 (奈良県立医科大学 理事長・学長)

シンポジウム1

15:05 ~ 16:25

SY1 「医用画像のビッグデータと AI 開発の展望」

座長: 村尾 晃平 (国立情報学研究所)

中田 典生 (東京慈恵会医科大学)

- SY1-1 医療画像ビッグデータクラウド基盤
合田 憲人 (国立情報学研究所)
- SY1-2 AMED プロジェクトにおける画像解析タスク俯瞰, 眼科画像の解析
佐藤 真一 (国立情報学研究所)
- SY1-3 病理と内視鏡画像における胃がん検知システムの開発
原田 達也 (東京大学)
黒瀬 優介 (東京大学)

- SY1-4** 大腸の画像診断：大腸生検の病理画像解析および大腸の内視鏡画像解析
内田 誠一（九州大学）
備瀬 竜馬（九州大学）
- SY1-5** AMED 大規模データベースを用いた CT 画像解析と病変検出への応用
森 健策（名古屋大学）
小田 昌宏（名古屋大学）
- SY1-6** 大規模CTデータ解析による骨格解剖知識の抽出
大竹 義人（奈良先端科学技術大学院大学）
日朝 祐太（奈良先端科学技術大学院大学）
高尾 正樹（大阪大学）
菅野 伸彦（大阪大学）
佐藤 嘉伸（奈良先端科学技術大学院大学）
- SY1-7** 超音波画像データベース構築と AI 開発の取り組み
椎名 毅（京都大学）
目加田慶人（中京大学）
- SY1-8** OpenAI と TradeAI
中田 典生（東京慈恵会医科大学）
- SY1-9** 臨床診断の立場からの特別発言と総合討論
縄野 繁（国際医療福祉大学）
シンポジウム演者全員

第2日 7月25日（木）

前半（口演）：メイン会場（レセプションホール1）

後半：ポスター会場（会議室3・4）

一般演題セッション3

16:25～17:55 OP3

「イメージング / 画質改善」

座長：伊藤 聡志（宇都宮大学）

- OP3-01** 少数方向トモシンセシスにおける正則化項を用いた画像再構成
堀 拳輔（杏林大学大学院保健学研究科）
- OP3-02** 超音波造影剤の動態情報を利用した模擬リンパ管の可視化
齋藤 勝也（千葉大学大学院 融合理工学府）
- OP3-03** EM-TV アルゴリズムを用いた少数投影での骨 SPECT 画像再構成の検討
金澤 道和（弘前大学大学院理工学研究科）
- OP3-04** 頭部専用 PET における放射能・減弱補正係数同時推定法の深層学習を用いた精度向上手法の検討
呉 博文（東京工業大学）

- OP3-05 睥癌腫瘍病理顕微鏡画像の染色変換
足立 秀雄 (名古屋工業大学)
- OP3-06 MR エラストグラフィによる内包ファントムの粘弾性分布の評価
菅 幹生 (千葉大学)
- OP3-07 Generative Adversarial Frameworks を用いた腹部 CT 像における非造影像からの造影像の推定
小田 昌宏 (名古屋大学大学院情報学研究科)

「画像解析 / モデリング」

座長：上村 幸司 (国立循環器病研究センター)

- OP3-08 マルチチャンネル化処理と CNN を用いた嚙下時 X 線透視動画における頸椎椎間板の抽出
藤中 彩乃 (筑波大学大学院)
- OP3-09 CT におけるアトラス誘導による肝抽出に関する比較研究
王 進科 (大阪大学大学院医学系研究科放射線統合医学)
- OP3-10 屈折コントラスト X 線 CT を用いた乳頭組織の 3 次元可視化および解析
砂口 尚輝 (名古屋大学)
- OP3-11 深層学習による超音波画像からの肝腫瘍検出に関する初期的検討
堤 一晴 (中京大学 工学部)
- OP3-12 腹腔鏡動画画像からの Fully Convolutional Network による血管領域抽出
盛満慎太郎 (名古屋大学大学院情報学研究科)
- OP3-13 非接触型微小循環観察環境の構築と敗血症モデルラットの血行動態解析
川崎 真未 (千葉大学大学院融合理工学府基幹工学専攻医工学コース)
- OP3-14 手術の多視点動画撮影および画像認識による自動視点切替表示
梶田 大樹 (慶應義塾大学医学部 形成外科)
- OP3-15 覚醒下脳腫瘍摘出術における術中情報を用いた脳機能マッピング工程同定手法の提案
佐藤 生馬 (公立はこだて未来大学大学院 システム情報科学研究科)

「CAD/ 臨床応用」

座長：内山 良一 (熊本大学)

- OP3-16 GAN を用いた病理組織画像における異常組織の自動同定法
林 大誠 (立命館大学理工学部)
- OP3-17 3 次元 CT 画像を用いたじん肺の重症度診断支援システム
森 奈々 (徳島大学大学院 先端技術科学教育部)
- OP3-18 Generative adversarial network を用いた肺結節の 3 次元 CT 画像の生成
西尾 瑞穂 (京都大学附属病院 先制医療・生活習慣病研究センター)
- OP3-19 眼底画像における OCT 検査結果を用いた CNN による網膜神経線維層欠損解析
渡邊 颯友 (岐阜大学大学院自然科学技術研究科知能理工学専攻)
- OP3-20 小児腸閉塞患者の CT 像における CycleGAN を用いた電子洗浄手法の検討
西尾 光平 (名古屋大学大学院情報学研究科)

- OP3-21 低線量 CT 画像に基づいた骨ミネラル量の推定法
山田 凌大 (岐阜大学大学院自然科学技術研究科知能理工学専攻)
- OP3-22 胸部 CT 像中の肺結節の良悪性鑑別における自動抽出された画像特徴の可視化
平島 翔 (山口大学大学院創成科学研究科)
- OP3-23 CT 画像を用いた脊柱海綿骨内の骨密度定量化
李 新 (大阪電気通信大学大学院)
- OP3-24 二段階分類による胸部 X 線画像を用いた異常部位検出システムの検討
堂園 貴弘 (千葉大学 大学院 融合理工学府 基幹工学専攻 医工学コース)

第 2 日 7 月 25 日 (木)

サブ会場 (1 階 会議室 2)

ハンズオンセミナー 2

9:00 ~ 10:30 HS2 「Deep Learning」 (1 と同一内容)

ハンズオンセミナー 3

16:25 ~ 17:55 HS3 「Deep Learning」 (1 と同一内容)

一般演題セッション4

9:00~10:30 OP4

「イメージング/画質改善」

座長:山谷 泰賀

(量子科学技術研究開発機構 放射線医学総合研究所)

- OP4-01 ブロックマッチング5Dフィルターを用いたダイナミックPETスキャンのための画像ノイズ除去
大手 希望(浜松ホトニクス株式会社 中央研究所)
- OP4-02 μ CTを用いた改良版Cycle-GANによる臨床用CT像の超解像処理
鄭 通(名古屋大学大学院情報学研究科)
- OP4-03 視覚情報提示による頭部PET体動抑制手法の開発
鈴木 海斗(千葉大学 大学院融合理工学府)
- OP4-04 静止型SPECTシステムを用いた心筋画像再構成
藤代 鷹平(法政大学 理工学研究科)
- OP4-05 マルチCNNによるMRI画像におけるノイズ低減
金子 幸生(株式会社日立製作所 研究開発グループ)
- OP4-06 全身撮影が可能な立位CTの開発:ファントムスタディ、人体に対する重力の影響
横山 陽一(慶應義塾大学医学部放射線科学教室(診断))
- OP4-07 GANを用いた人工股関節全置換術後CT画像の金属アーチファクト低減
阪本 充輝(奈良先端科学技術大学院大学先端科学技術研究科)

「画像解析/モデリング」

座長:本谷 秀堅(名古屋工業大学)

- OP4-08 複数の皮膚毛細血管に対する血流速度推定の自動化
塚本 唯斗(千葉大学大学院融合理工学府)
- OP4-09 TMS検査のための脳MRI画像からの誘導電流強度の回帰とその推定誤差分散推定
牧 豊大(名古屋工業大学)
- OP4-10 開腹手術映像における遮蔽物除去システムのVR化
北坂 孝幸(愛知工業大学情報科学部)
- OP4-11 手術器具検出を用いた整形外科手術の工程認識における最適なData Augmentationの検討
西尾 祥一(兵庫県立大学)
- OP4-12 敵対的生成ネットワークによるMRI脳画像の頭蓋骨除去の提案
藤山 眞悟(法政大学理工学研究科応用情報工学専攻)

- OP4-13 深層学習を用いた腹腔鏡手術動画像の出血領域自動セグメンテーション
山本 翔太 (名古屋大学大学院情報学研究科)
- OP4-14 血管仮想操作のための脳血管描画方法の検討
田中 康太 (近畿大学大学院生物理工学研究科)
- OP4-15 転移学習を用いた腹部 thick-slice CT 像における多臓器領域の自動抽出の初期検討
申 忱 (名古屋大学大学院情報学研究科)
- OP4-16 歯科的個人識別のための Relation Networks for Object Detection を用いた歯科用 Cone-beam CT
における歯牙の検出
杳名 将太 (岐阜大学大学院自然科学技術研究科知能理工学専攻知能情報学領域)

「CAD/ 臨床応用」

座長：畑中 裕司 (滋賀県立大学)

- OP4-17 時間-周波数解析と CNN を用いた呼吸音の自動分類手法の開発
南 弘毅 (九州工業大学)
- OP4-18 HE 染色標本画像と診断テキストデータを併用する免疫染色パターン推定
橋本 典明 (名古屋工業大学)
- OP4-19 舌の表面特徴に基づく機械学習を用いた舌苔分布推定手法の検討
吉村裕一郎 (千葉大学フロンティア医工学センター)
- OP4-20 肺がん体幹部定位放射線治療における 3次元計画 CT 画像上の肉眼的腫瘍体積の Dense V-net
自動抽出法
中野 里彩 (九州大学大学院医学系学府保健学専攻)
- OP4-21 半教師あり学習を用いた根拠提示可能なメラノーマ識別
村林 誠也 (法政大学大学院理工学研究科)
- OP4-22 転移性肝がん検出のための Conditional GAN による学習画像生成
池田 裕亮 (中京大学 大学院工学研究科)
- OP4-23 Deep CNN における分類器のアテンションメカニズムを利用した CT 画像からの乳腺領域の自動
抽出法
山岸 誠也 (岐阜大学大学院自然科学技術研究科知能理工学専攻)
- OP4-24 Automated approach for estimation of sizes of lung cancer on planning CT images using deep
learning with non-negative matrix factorization
MaZhuangfei (Department of Health Sciences, Graduate School of Medical Sciences,
Kyushu University, Fukuoka, Japan)

ミニシンポジウム2

10:40 ~ 11:30

MS2「生命機能イメージングの革新：今後の課題と展望」

座長：清末 優子(理化学研究所)

末次 志郎(奈良先端科学技術大学院大学)

MS2-1 イントロ：JST CREST 情報計測領域について
清末 優子(理化学研究所)

MS2-2 クライオ電子顕微鏡法による生体分子の構造解析
光岡 薫(大阪大学)

MS2-3 高速原子間力顕微鏡による生体分子イメージングと機械学習・データ同化
高田 彰二(京都大学)

MS2-4 細胞活動の高精度3D計測と画像情報解析の次世代化に向けて
清末 優子(理化学研究所)

ランチョンセミナー

11:50 ~ 12:40

LS「DGX-2によって加速されるメディカルAI開発のためのデータ構造化プラットフォーム」

座長：中田 典生(東京慈恵会医科大学)

LS DGX-2によって加速されるメディカルAI開発のためのデータ構造化プラットフォーム
小林 和馬(国立研究開発法人国立がん研究センター研究所 がん分子修飾制御学分野)

特別講演2

13:00 ~ 13:50

SL2「ネオコグニトロンと畳み込みニューラルネットワーク」

座長：尾川 浩一(法政大学/JAMIT 学会長)

SL2 ネオコグニトロンと畳み込みニューラルネットワーク
福島 邦彦(ファジィシステム研究所 特別研究員)

一般演題セッション5

13:50 ~ 15:20

OP5

「イメージング / 画質改善」

座長:菅 幹生(千葉大学)

- OP5-01 非ランダム間引き収集によるMR圧縮センシングの深層学習再構成
佐藤 佑紀(宇都宮大学 大学院地域創生科学研究科 工農総合科学専攻)
- OP5-02 CT画像再構成におけるメタルアーティファクト除去の新手法
千北 一期(筑波大学大学院 システム情報工学研究科)
- OP5-03 2D U-Netの畳み込みネットワークを用いた隣接スライスからのCT画像再構成
武 淑ケイ(京都大学情報学研究科)
- OP5-04 TV正則化と辞書学習を用いたOS-EM法におけるPET画像再構成
奥村 直裕(電気通信大学情報理工学研究科)
- OP5-05 拡散尖度撮像法のパラメタ推定のための生成型Q空間学習における最適雑音量の自動決定に向けて
内濱 良介(広島市立大学)
- OP5-06 カラー腹腔鏡画像診断のためのコントラスト強調とSRCNN超解像処理の最適条件に関する考察
河畑 則文(東京理科大学理工学部)

「画像解析 / モデリング」

座長:滝沢 穂高(筑波大学)

- OP5-07 動作計測による顔の粘弾性シミュレーション
黒田 嘉宏(大阪大学 大学院基礎工学研究科)
- OP5-08 対称性解析に基づく3次元データから顔の対称面検出
細木 大祐(九州工業大学)
- OP5-09 放射光CTを用いた肺3次元マイクロ血管解析
島谷 峻平(徳島大学大学院先端技術科学教育部システム創生工学専攻)
- OP5-10 CT画像と顎運動情報を用いたVR咬合器の開発
伊藤 崇弘(鶴見大学歯学部クラウンブリッジ補綴学講座)
- OP5-11 グラフ畳み込みニューラルネットワークを用いた腹部動脈血管名自動命名の初期検討
日比 裕太(名古屋大学大学院情報学研究科)
- OP5-12 Btrfly型CAEを用いた骨シンチグラムにおける骨格認識処理の改良
星野 ゆり(東京農工大学 大学院 工学研究院)

- OP5-13 Mask R-CNN を用いた小児胸部 X 線画像における肺領域の自動抽出
魚住 春日 (藤田医科大学大学院 保健学研究科)
- OP5-14 深層学習を用いた非造影 CT 画像からの複数臓器領域の抽出に関する検討
林 雄一郎 (名古屋大学大学院情報学研究科)
- OP5-15 顎口腔領域の CT 画像における金属アーチファクト低減を用いた筋骨格セグメンテーション
- 金属アーチファクトのシミュレーションによる精度検証 -
森谷 友香 (奈良先端科学技術大学院大学 先端科学技術研究科)

「CAD/ 臨床応用」

座長：野村 行弘 (東京大学)

- OP5-16 Faster R-CNN による肝臓がん候補領域の抽出法
古月 夢奇 (九州工業大学)
- OP5-17 マクロ病理マルチスペクトル画像からの再構成反射率を用いた皮膚組織の二元悪性腫瘍分類
アルポヤニエレニ (東京工業大学 工学院 情報通信系)
- OP5-18 FDG PET-CT の腫瘍領域教師データを半自動的に作成するアルゴリズムの提案と性能評価
平田 健司 (北海道大学大学院医学研究院核医学教室)
- OP5-19 乳腺領域の自動抽出を用いた深層ニューラルネットワークによる乳房超音波画像における腫瘍検出
楊 凱文 (産業技術総合研究所)
- OP5-20 レディオミクスによる肺がんの再発リスクの予測 - レディオミクス特徴量の比例ハザード性の検証 -
吉岡 拓弥 (熊本大学大学院保健学教育部)
- OP5-21 深層学習を用いた胃 X 線検査画像における腫瘍領域自動検出の試み
市川 梨沙 (法政大学理工学部)
- OP5-22 疾患股関節の CEA の自動計測と大規模データベース解析への有用性の検討
田中 雄基 (奈良先端科学技術大学院大学情報科学領域)
- OP5-23 3D fully convolutional network を用いた腎腫瘍の定量評価における初期検討
王 成龍 (名古屋大学情報科学研究科)
- OP5-24 網膜動脈硬化症分類のための静脈口径計測
畑中 裕司 (滋賀県立大学工学部電子システム工学科)

第3日 7月26日(金)

メイン会場(レセプションホール1)

シンポジウム2

15:35 ~ 16:55

SY2「多元計算解剖学のこれから - さらなる飛躍を目指して」

座長: 森 健策 (名古屋大学)

清水 昭伸 (東京農工大学)

SY2-1 多元計算解剖学において生み出されたもの
橋爪 誠 (九州大学)

SY2-2 多元計算解剖学における数理
本谷 秀堅 (名古屋工業大学)

SY2-3 多元計算解剖学における多元モデリング
佐藤 嘉伸 (奈良先端科学技術大学院大学)

SY2-4 多元計算解剖学と人工知能ブーム
藤田 広志 (岐阜大学)

SY2-5 多元計算解剖学のその先にあるもの
森 健策 (名古屋大学)

SY2-6 パネル討論 多元計算解剖学の今後の発展に向けて

16:55 ~ 17:00

閉会式

第3日 7月26日(金)

サブ会場(1階 会議室2)

ハンズオンセミナー4

9:00 ~ 10:30

HS4「Deep Learning」(1と同一内容)

ハンズオンセミナー5: 超初級者編

14:00 ~ 15:30

HS5「Deep Learning」

(第1回~第4回は同じ内容, 第5回は重複受講可能です.)

第 1 日 7 月 24 日 (水)

メイン会場 (レセプションホール 1)

13:10 ~ 13:20

開会式

チュートリアル講演会

13:20 ~ 16:10

TL1 「Beyond Deep Learning」

座長：中田 典生 (東京慈恵会医科大学)

(概要) 深層学習を利用した論文が数多く報告されている。今後研究を進めるためには、最新の深層学習の動向を把握するだけでなく、過去との差異を明確にし、データ収集や実行環境の効率化などの観点が必要である。今回の JAMIT チュートリアルは、大会期間中に会場で開催される「コニカミノルタ科学技術振興財団 JAMIT ハンズオンセミナー」と一部連携して、医用画像における深層学習の実際について集中的に講演を企画した。講演 1 では、人工ニューラルネットワーク利用した画像処理の過去から現在、そして、将来への展望を、国際的な観点から幅広く講演いただく。講演 2 では、スパコンや大容量ストレージが必須となる研究を実行するための環境としてのクラウドサービスの実際とその見積について、講演いただく。講演 3 では、正解データの作成、プログラム構築、その評価、論文化と、とすれば一人ですべてをワンオペのように解決できる深層学習の研究状況において、研究者が共同研究を行う新たな環境について講演いただく。

TL1 世間の流行に左右されない深層学習所感

○鈴木 賢治

東京工業大学 / イリノイ工科大学 (Illinois Institute of Technology)

深層学習が革新的な技術として世界的な話題となり、学会、産業界、そして世間を騒がしている。革新的な技術分野に加わることは大変良いことである。しかしながら、世間全体がブームに踊らされている感じがあることは否めない。本講演では、24 年間深層学習の研究開発を続けてきた講演者の深層学習所感について述べる。深層学習は、従来の機械学習と本質的に何が違うのか？学習には大量の症例が本当に必要か？層は深ければ深いほど良いのか？大規模計算、大規模メモリは必須か？などの疑問について、講演者独自の深層学習モデル (MTANN) の研究開発、AI 支援診断や仮想画像化への応用、実用化を交えながら解説する。

TL2 様々な大規模計算環境の得手・不得手 ～何ができて何ができない？～

○平野 靖

山口大学

スパコン、PC クラスタ、クラウドコンピューティングなど、様々な大規模計算環境があり、さらに演算装置には CPU や GPU などいくつかの種類がある。この講演では、それぞれの計算環境・演算装置を紹介し、どのような処理をどのような計算環境で行えばよいかを解説する。また、医用画像処理の分野ではストレージ環境も重要であるため、有償のストレージ環境の概要や独自のストレージ環境を構築する際の概要などについても紹介する。

TL3 医師が取り組んだ深層学習：臨床からスパコンまで

○花岡 昇平

東京大学

講演者は放射線科診断専門医であり、Keras や Tensorflow を扱う深層学習の研究者でもある。その立場から、(1) 今の医用画像処理において深層学習が与えたショック、(2) 臨床医が今考えていること、(3) 医用画像工学者の「中抜き」の危険性、そして (4) これからの工学者と医学者の役割分担と競争、について私見を述べさせていただければと考えている。(1) では深層学習が工学者の職人芸を奪った、いわば「産業革命」となったのではないかと、という観点から歴史をおさらいする。(2) では幾人かの深層学習を使いこなして業績を上げつつある放射線科医を紹介し、また彼らにとって律速段階がなくなっているかを提示したい。特にデータ収集や正解入力の実際について例示するつもりである。(3) は私がいま焦っているところでもあるが、これまでパタレコからの新アルゴリズムを医用画像というニッチに適用してご飯の種にしてきた医用画像工学者が、データと正解ラベルさえあれば研究が成り立つてしまうような時代に、どうやって生き残れるのかを論じたい。(4) は、医師が supercomputer で python を扱うような時代に、工学者と医学者がどのような協働関係を作っていけるかを模索して結びとしたい。

前半(口演):メイン会場(レセプションホール1)

後半:ポスター会場(会議室3・4)

一般演題セッション1

16:25 ~ 18:00 OP1

「イメージング/画質改善」

座長:湯浅 哲也(山形大学)

OP1-01 制約付きアンサンブル学習を用いた事後平均解の近似によるMR画像再構成

○久保田菜々子¹, 原田 賢², 藤本 晃司³, 岡田 知久³, 井上 真郷¹

¹早稲田大学大学院 先進理工学研究科 電気・情報生命専攻, ²早稲田大学 理工学術院総合研究所, ³京都大学大学院 医学研究科 脳機能総合研究センター

MR画像再構成においては、複数の画像事前分布を組み合わせることで精度が向上することが知られているが、最適な重みの組み合わせを交差検証法により求めることは、組み合わせ数が指数的に増加するため大変であった。以前の我々の研究では制約付きアンサンブル学習を用いることで、複数の画像事前分布の組み合わせを線形オーダーの計算量で実現した。また、推定解に事後平均の近似解という意味づけを行うことで、本手法による再構成の精度向上の理論的裏付けを行った。本研究ではさらに画像事前分布の種類を増やした際に本手法が有用であることを報告する。

OP1-02 X線CT画像上の雑音分散に対する検出器モデルの影響

○田之上和矢, 池田 充, 梅田 祐司, 藤井 啓輔, 川浦 稚代, 今井 國治

名古屋大学大学院医学系研究科

雑音を量子雑音に限定した場合におけるX線CT画像上の関心領域内の雑音分散の(アンサンブル領域における)期待値について、X線検出器のモデル(quantum counterとenergy integrating detector)の差が与える影響について検討した。両検出器モデルの出力が類似した結果を与える条件下で、CT画像上の関心領域内の雑音分散の期待値について、解析的に計算した結果と仮想的な撮影系を使用したシミュレーション画像から推定した値について検討した。両モデルにおいて、解析的に計算した期待値はシミュレーション画像から推定した値とよく一致した。また、両モデル間で、雑音分散の値の差は少ない結果となった。今回の検討結果からは、両モデルのCT画像上の関心領域内の雑音分散に与える影響は少なく、同雑音分散に関する検討において、簡易なquantum counter modelでの検討の有効性が示唆された。

OP1-03 スパース化空間の類似性を利用した単一画像超解像

○竹間 康浩, 大内 翔平, 伊藤 聡志

宇都宮大学 大学院工学研究科 情報システム科学専攻

MR画像など画素数が少ない画像を観察する場合は、画像を補間拡大することが多い。このとき、単なる補間ではなく、超解像の効果があれば生体の構造をより認識しやすくなり、画像診断の精度を高めることが期待できる。eFREBAS変換によりスパース展開された像は全て同サイズであり、かつ、周波数帯域別に分離した像は互いに相似性を持っている。そこで、eFREBAS空間における展開像の相似性を利用し、eFREBAS空間にて信号を外挿する画像補間法について検討を行った。学習型超解像や深層学習を利用する方法と比較した結果、比較した深層学習の方法と同等の近い補間誤差と鮮鋭さを有する補間像が得られることが示された。

OP1-04 微小金属のアーチファクト補正を目的とした X 線トモシンセシス装置の検討

○山川 恵介¹, 高橋 啓子², 中村 正²

¹株式会社日立製作所 研究開発グループ, ²日立製作所 ヘルスケアビジネスユニット

近年、乳房や整形で用いられる X 線トモシンセシスにおいて、代表的な FBP 画像では投影データの角度欠損により、金属と軟部組織間等の吸収値差が大きい条件で金属アーチファクトが増加する。これを低減するため、断層画像撮影では画像の金属位置に基づく投影データの補間法が用いられるが、トモシンセシスでは位置毎のアーチファクトのばらつきが大きく画像上の金属抽出が困難であった。報告者は JAMIT2018 にて、全ての投影角度の投影データを仮想 3 次元データとし、3 次元領域拡張法を用いた投影データ金属抽出法を報告したが、ピン等の微小金属になるほど角度方向の領域拡張の精度が低下する課題があった。そこで微小金属の抽出精度向上を目的として、投影角度間の金属の相関情報を用いる方法を提案する。整形用固定具を模擬したファントム実験において、周辺領域の画質を維持し高いアーチファクト低減効果が得られたので報告する。

OP1-05 敵対的生成ネットワークを利用した MR 圧縮センシング再構成の基礎検討

○大内 翔平, 伊藤 聡志

宇都宮大学 大学院 工学研究科 情報システム科学専攻

MRI の撮像時間の短縮を目的として、圧縮センシングが応用されている。圧縮センシングによれば、収集する信号量の削減が可能であり、撮像時間が短縮される。しかし、画像再構成では L1-L2 ノルム最小化問題を反復的に解くため時間を要し、再構成像には人工的な様相が生じる場合がある。

近年では、CNN を利用した MR 画像の再構成法が提案されており、再構成像の品質と再構成時間の面で従前の反復的な手法よりも優れることから、大きな注目を集めている。

本研究では、2 つのネットワークを敵対的に学習させることで解の推定を目指す、敵対的生成ネットワーク (Generative Adversarial Network: GAN) を使用した再構成法について検討を行った。また、既存の反復的解法と比較を行った。再構成シミュレーションによって得られた結果を報告する。

OP1-06 Simulation study of a novel brain PET scanner using 100 ps TOF-DOI sub-millimeter resolution detectors

○李 英英¹, 渡辺 光男², 磯部 卓志², 大手 希望², 森谷 隆広², 得居 葵², 大村 知秀², 劉 華鋒¹

¹浙江大学, ²浜松ホトニクス株式会社 中央研究所

A novel brain PET scanner using 100 ps TOF-DOI sub-millimeter resolution detectors has been proposed and simulation study was performed using the GATE (Geant4 application for tomographic emission) to estimate physical properties and the image quality of the scanner. The detector consists of four layers of independent scintillation detector having an outstanding TOF capability and true first interaction point (FIP) detection ability. The spatial resolution, sensitivity, and scatter fraction were estimated according to NEMA standards. To evaluate the image quality of the scanner implemented not only excellent spatial and timing resolution but also DOI detection with FIP information added, 3D Hoffman, Hot-Derenzo, and NEMA image quality phantom were simulated and analyzed reconstructed images. Our proposed PET scanner will have potential to open a new field of brain study.

OP1-07 サイクル損失を用いた 3 次元胸部 CT 像の超解像

○河合 良亮¹, 斉藤 篤¹, 木戸 尚治², 稲井 邦博³, 木村 浩彦³, 清水 昭伸¹

¹東京農工大学大学院工学研究院, ²大阪大学大学院医学系研究科, ³福井大学医学部

教師あり学習に基づく超解像では、低解像度 (Low Resolution ; LR) 画像とそれに対応する高解像度 (High-Resolution ; HR) 画像の組を用いる方法が一般的である。しかし、この画像の組を得るためには生前に臨床用 CT、死後に作成した摘出標本に MicroCT を適用する必要がある、大量に用意するのが困難である。本稿では、対応付けの無い LR 画像と HR 画像から、サイクル損失を用いて超解像を実現する方法について報告する。具体的には、ResNet を超解像のための生成器、CNN を偽物と本物の高解像度画像を識別する識別器とし、GAN の枠組みを利用して最適化するが、提案法では新しく定義するサイクル損失 (低解像度画像の再構成損失) を含む損失の最小化により ResNet を訓練した。この方法を実際の胸部 CT 像に適用して 8 倍の超解像を行い、PSNR などを用いて結果を評価した。本稿では、対応付けのある画像組を用いた超解像の結果との比較も行いながら、提案法の有効性と限界について議論する。

「画像解析 / モデリング」

座長：健山 智子（広島工業大学）

OP1-08 CycleGAN を用いた胸部 CT 画像のドメイン変換とその識別システムへの応用

○三宅 将司, 間普 真吾, 木戸 尚治, 呉本 亮, 平野 靖
山口大学

機械学習を用いた CAD システムの研究が活発に行われているが、ある医療機関で良い性能を示した CAD システムを他の医療機関に転用する場合、医療機関によって画像の撮影条件が異なるため、CAD の診断精度が変動する可能性がある。その場合、CAD の再学習には医療機関ごとに大量の訓練データを作成する必要がある。これでは、様々な医療機関で広く使いやすいシステムとは言えず、本問題の解決が必要である。本研究では、びまん性肺疾患の陰影分類を例に、CycleGAN を用いて上記の問題を解決する手法を提案する。具体的には、医療機関 A で撮影された胸部 CT 画像の条件を標準と定義し、医療機関 B で撮影された CT 画像を CycleGAN によって A の条件に変換する方式（標準化）を研究する。標準化後の画像に適用する陰影識別器として Residual Network(ResNet)を用い、まず医療機関 A の画像データで学習する。その後、標準化の有無によって医療機関 B の画像の診断精度に差があるかを検証する。同様に、B を標準とした場合も検証する。

OP1-09 楕円フーリエ記述子を用いた乳房 X 線像における石灰化クラスタの解析とデータ拡張への応用

○志村 一男¹, 安中 奨¹, 近藤 啓介¹, 縄野 繁²
¹駒澤大学医療健康科学部, ²国際医療福祉大学三田病院

医療分野において、深層学習の性能向上のキーとなる教師データの確保は容易ではなく、データ拡張技術が注目されている。今回、輪郭情報の定量的評価法のひとつである楕円フーリエ記述子を用い、石灰化クラスタの輪郭を解析し、データ拡張に応用する手法を検討した。楕円フーリエ記述子とは輪郭等の閉曲線を周波数解析する手法であり、円弧度やアスペクト比といった既存の特徴量と比較し、より詳細な形状の特徴を表現可能である。

データベースから得た石灰化クラスタ形状を楕円フーリエ記述子に変換し、得られた特徴量空間から新たな石灰化クラスタ分布の輪郭形状を生成する。別途、抽出した石灰化陰影を生成された石灰化クラスタ分布に応じ配置し、別の乳房 X 線画像に埋め込むことにより新たな教師画像を生成する。

以上の方法を乳房 X 線画像の公開データベースである CBIS-DDSM を用いて検証した結果について報告する予定である。

OP1-10 演題取り下げ

OP1-11 単眼腹腔鏡映像からの奥行き推定を利用した術具セグメンテーション

○鈴木 拓矢¹, 道満 恵介¹, 目加田慶人¹, 三澤 一成², 森 健策³
¹中京大学 大学院工学研究科, ²愛知県がんセンター, ³名古屋大学 大学院情報学研究所

腹腔鏡下手術の手術支援システムでは手術の安全性向上のために、腹腔鏡映像に映る術具領域の正確な抽出が必要である。近年では FCN を用いた術具領域抽出手法が効果を挙げている。色情報に加えて奥行き情報を学習することで、抽出精度が向上すると報告されている。本研究では、深層学習による単眼腹腔鏡映像からの奥行き推定と、推定した奥行きと色情報を学習することで、術具領域抽出の精度向上を目指す。MICCAI2017 のロボット器具データセットを対象に実験した。4分割交差検証の実験結果は平均 IOU が 89%、平均 Dice 係数が 94% となった。推定した奥行き情報を学習に追加することで、誤抽出の低減と輪郭の抽出精度が向上した。

OP1-12 深層学習を用いた骨密度測定時の X 線画像における大腿骨セグメンテーション

○押川 翔太¹, 胡 尔重¹, 中矢 知宏¹, 高橋 渉²
¹株式会社島津製作所 医用機器事業部 技術部, ²株式会社島津製作所 基盤技術研究所 AI ソリューションユニット

骨粗鬆症の診断では DXA (dual-energy X-ray absorptiometry) 法を用いた骨密度の測定が重要視されている。DXA 法による骨密度測定では、骨部の正確なセグメンテーションが再現性の高い骨密度の測定に重要である。そこで本研究では、骨密度測定時の大腿骨 X 線画像の骨部を、深層学習を用いて高精度にセグメンテーションする手法を提案する。骨密度測定時の臨床 X 線画像を用いて学習を行い、学習に使用していない評価用データ 100 枚を用いて性能評価を行った。結果として骨密度測定に重要な大腿骨頸部を中心とした領域において平均 IoU (Intersection over Union) 96.5% となり、高精度にセグメンテーション可能であることを確認した。

OP1-13 金属表面の画像照合に基づく手術器具の個品管理システム

○牧野 賢吾, 高橋 徹, 工藤 佑太, 石山 壘

日本電気株式会社 データサイエンス研究所

本稿では、画像照合による手術器具の個品管理システムを提案する。資産管理や作業履歴の管理のために、手術器具の個品管理が必要である。一般に、マーキングやタグによる個体識別が使われているが、器具によっては付与が不可能であり、タグの脱落や付与のコストの問題もある。

本稿では、物体表面の微細なランダム凹凸パターンをマクロ撮影によって画像化し、画像照合で個体識別を行う物体指紋認証技術の適用を提案する。

器具そのものの物体表面を撮影するだけでよいと、タグ付与が困難で管理できなかった器具についても、写真を撮るだけで容易に個品管理を実現できる。

実験では、メス、ピンセット、ハサミの3種類の金属製手術器具を各5個体用いて、ある特定部位の画像を撮影し、画像照合によって照合精度100%で個体識別が可能であることを確認した。

また、読取の手間を無くすため、物体認識技術とロボットアームを活用した自動撮影システムを試作した。

OP1-14 舌診断支援システムの自動化に向けた舌検出と領域抽出の検討

○唐 啓超¹, ヤンテイショウ¹, 吉村裕一郎², 長谷川 豊¹, 森 康久仁³, 須鎗 弘樹³, 並木 隆雄⁴, 中口 俊哉²

¹千葉大学大学院融合理工学府, ²千葉大学フロンティア医工学センター, ³千葉大学大学院工学研究院, ⁴千葉大学大学院医学研究院和漢診療学

我々はこれまで舌撮影装置 TIAS を開発し、舌色診断支援システムを構築してきた。

この舌色診断支援システムのクリニックや家庭への普及に向けて使用手順の自動化が求められている。そこで本研究ではシステム自動化に向けた舌検出と領域抽出の手法を検討した。舌検出について、先行研究の結果では感度と精度は0.9以上に達したが特異度は0.4未満と誤検出が多発していた。そこで MobileNets 深層学習モデルを用いた舌検出手法を提案した。TIASで撮影した舌画像798枚を用いてモデルを学習させたところ、舌検出特異度と精度の大幅な向上を確認した。舌の領域抽出について、SLIC と GrabCut を用いた先行研究の結果では平均 IoU 値が0.75未満と精度に課題があった。そこで本研究では Pix2Pix 深層学習モデルと領域拡張法を組み合わせた舌領域抽出法を提案した。関連手法との比較評価実験の結果、提案手法の優位性を確認した。

OP1-15 少量のラベルデータを用いた学習によるイレウス症例 CT 像における拡張腸管の自動抽出

○小田 紘久¹, 西尾 光平¹, 北坂 孝幸¹, 天野 日出², 千馬 耕亮², 内田 広夫², 鈴木耕次郎³, 伊東 隼人¹, 小田 昌宏¹, 森 健策^{1,4,5}

¹名古屋大学情報学研究所, ²名古屋大学医学系研究科, ³愛知医科大学放射線医学講座, ⁴名古屋大学情報基盤センター, ⁵国立情報学研究所医療ビッグデータ研究センター

本研究では、Fully convolutional network を用いたイレウス患者の CT 像における腸管領域の抽出において、手塗りされた教師データが少量であっても精度よく抽出を行う手法を提案する。イレウス症例においては、小腸が直径30ミリ程度まで拡張することが多い。一般に Fully convolutional networks の学習を行う場合には大量の学習データが必要であるが、小腸は複雑に入り組んでいるほか非常に長く、手動でのラベル作成は容易でない。提案する腸抽出手法のネットワークを学習するための教師データとして、症例ごと数枚のスライスを手塗りするほか、手塗りの行われていないスライスの一部ではフィルタベースの手法により抽出したラベルを一部修正して併用する。ネットワークは U-net をベースとして入出力サイズ等の変更を施したものを扱い、Keras にて実装する。学習したネットワークを用いて、イレウス患者の腹部 CT 像全体において腸領域を抽出する。

OP1-16 高解像度連続切片標本画像による股関節周辺領域における神経筋骨格構造のモデル化のための線維トラクトグラフィの応用

○時末 尚悟¹, 大竹 義人¹, Mazen Soufi¹, 福田 紀生¹, 高尾 正樹², 菅野 伸彦², BeomSun Chun³, JinSeo Park⁴, 佐藤 嘉伸¹

¹奈良先端科学技術大学院大学, ²大阪大学, ³Ajou University, ⁴Dongguk University

整形外科での診断精度向上などの観点から、正確な筋骨格モデルの構築が求められている。しかし、現状のモダリティでの腱・靭帯領域の撮像や解剖での骨格筋の内部構造把握は困難とされており、骨格筋の起始から停止に至る正確な3次元構造のモデル化はなされていない。そこで本研究では、遺体から得られる股関節周辺領域の高解像度の標本画像を用いることで、骨格筋の起始から停止までの正確な3次元構造のモデル化を目指す。先行研究では大臀筋を対象にその周辺の腱・靭帯組織をマニュアルトレースにより抽出し筋腱線維の構造解析を行った。本研究では解析領域を拡大するために CNN を用いて、データセット全体から腱・靭帯組織を自動抽出し、マニュアルトレースとの線維構造の比較・検討を行う。また、解析した腱・靭帯線維をクラスタリングすることで周辺の骨や骨格筋とのコネクティビティを検証し、解剖学的知見からモデルの整合性の向上を行う。

OP1-17 画像認識技術によるうつ病診断の定量化

○牧 優太¹, 和田 昇太¹, 安倍 和弥¹, 武尾 英哉¹, 永井 優一²

¹ 神奈川工科大学, ² 国立がん研究センター東病院

近年の精神病の診断は主に DSM-5 や ICD-10 などの国際疾病分類を用いており、これらによってうつ病は当て嵌まる症状の数による診断が行われている。この診断方法は医師の主観や患者のその日の体調によって診断結果が左右されてしまうため、科学的、客観的な評価による診断ができていないという問題がある。そのため、うつ病の客観的な評価を行うために、うつ病であるかどうか画像工学技術を利用して、うつ病の定量化(重症度の算出)とうつ病であるかどうかの判定を行うシステムの開発を行った。

定量化には主に視線方向と顔表情に着目した。うつ病患者及び健常者の動画像から、視線方向と顔表情を CNN を用いて検出し、各々の時系列データを得る。そして、それらのデータを機械学習によって定量化し、算出された重症度の評価を行った。その結果、得られた重症度にはうつ病との関連性が見られた。

OP1-18 肝細胞癌に対する選択的 TACE 施行時の Angio-CT を用いた栄養血管同定ナビゲーションソフト (Embolization plan) の初期使用成績と注入造影剤濃度の影響について

○葛和 剛¹, 前原 健吾^{1,2}, 新家 睦巳², 秋山 敬純², 小西 佳之², 穴井 洋³, 小屋敷 誠⁴, 広瀬 聖史⁴, 前田 達郎⁴

¹ 奈良県立医科大学連携大学院 先端画像下治療開発応用学講座, ² 市立奈良病院 医療技術部放射線室, ³ 市立奈良病院放射線科・IVR 研究センター, ⁴ キヤノンメディカルシステムズ

【背景】肝細胞癌の選択的 TACE に対し、Angio-CT(ACT)を使用した automated feeder detection system (AFD) の開発 (Embolization plan; EP), 造影剤濃度に着目して初期臨床評価を行った。

【方法】対象は肝細胞癌 29 患者 33 結節 (腫瘍径; 平均 11.4(5.0-23.0) mm)。総肝もしくは固有肝動脈より秒間 1.0-2.0ml で造影剤 185(L:8 結節) もしくは 295mg I/ml(H:25) で注入し CT hepatic angiography(CTHA) を施行。DSA をゴールドスタンダードとして EP による栄養血管同定評価を行い、完全一致: Excellent(E), ほぼ一致: good(G), 臨床上許容可能: fair(F), 許容不可能: poor(P) とした。

【結果】E:2 (L0,H2) 結節, G:19 (4,15) 結節, F:7 (1,6) 結節, P:5 (3,2) 結節で、F 以上は 28 (5,23) 結節 84.8(62.5, 92)% であった。

【結語】ACT を用いた EP による栄養血管同定は臨床的有用性が示唆された。更なる精度向上には造影剤の注入条件のみならず、EP ソフトウェアなど他条件の検討を要する。

OP1-19 敵対的生成ネットワークを用いた硬性白斑画像の生成と検証

○藤田 真穂¹, 畑中 裕司², 砂山 渡², 村松千左子³, 藤田 広志³

¹ 滋賀県立大学大学院工学研究科電子システム工学専攻, ² 滋賀県立大学電子システム工学科, ³ 岐阜大学工学部電気電子・情報工学科

糖尿病網膜症は中途失明の原因となる病であるが、早期発見と治療によって失明を防ぐことができる病でもある。近年は眼底画像からの初期病変の検出に、畳み込みニューラルネットワーク (CNN:Convolutional Neural Network) が成果を挙げている。一方で CNN を用いる際には、病変データと非病変データとの不均衡が課題となる。現在は敵対的生成ネットワーク (GAN:Generative Adversarial Nets) を用いて病変データ数を増加させ、上記の問題の解決を図る研究が行われている。これらを踏まえて本研究では、初期病変の一つである硬性白斑の画像を生成した。白斑には硬性白斑と軟性白斑があるが、硬性白斑は糖尿病網膜症の初期段階にあらわれる境界が明瞭な白斑である。また生成データと実データ間との分布の差異について、複数数の指標を用いて検証を行った。当日は生成したデータに関する検証結果と、生成したデータが CNN に与える影響について報告する予定である。

OP1-20 液状細胞診画像と患者情報の併用による肺癌組織型自動分類の基礎的検証

○山田あゆみ¹, 寺本 篤司¹, 桐山 諭和³, 塚本 徹哉³, 今泉 和良³, 星 雅人¹, 齋藤 邦明^{1,2}, 藤田 広志⁴

¹ 藤田医科大学 医療科学部, ² 藤田医科大学大学院 保健学研究科, ³ 藤田医科大学 医学部, ⁴ 岐阜大学 工学部 電気電子・情報工学科

病理診断において、肺癌の組織型やサブタイプを正確に把握することは、治療方針を決定するために重要である。本研究では、液状細胞診 (LBC) 画像と患者臨床情報を用いた肺癌組織型分類手法を開発し、基礎評価を行った。はじめに、深層畳み込みニューラルネットワークを用いて、液状細胞診画像から肺癌組織型に関する画像特徴量を抽出した。次に、電子カルテより患者臨床情報 (喫煙情報、腫瘍マーカー値等) を収集し、主成分分析により次元圧縮を行った。得られた画像特徴量とその画像に対応する患者臨床情報の主成分を識別器に入力し、3 種類の肺癌組織型の分類結果を得た。149 症例の臨床データを用いて、3-fold 交差検証にて評価を行ったところ、細胞診画像単体での分類精度は、82.9% であった。画像特徴に喫煙情報・腫瘍マーカー値を加えて、SVM で識別を行ったところ、それぞれ総合識別率は向上した。これらの結果から、提案手法の有用性が示唆された。

OP1-21 ResSENet を用いたオートエンコーダによる認知症の疾患鑑別

○藤林 大毅

株式会社 Splink

深層学習の活用で医療画像解析におけるニューラルネットワークモデルの有効性が近年多数報告されている。本研究報告では3次元 T1 強調 MRI 画像によるアルツハイマー病の疾患鑑別において、全脳の域的なコンテキストの特徴化を考慮したモデル構築を行い、本課題においても深層学習が高い精度を実現することを報告する。提案するモデルは画像の Encoding / Decoding を行う U-net における Encoder ネットワークの畳み込み部分に Squeeze-and-Excitation ブロックを用いた ResNet を用いるものである。学習には北米の ADNI データセットから脳画像の特性を利用したデータ増強処理を行いこれを用いた、学習後のモデル評価は external validation としてオーストラリアの AIBL データベースを用い、従来手法より高い精度が確認された。

OP1-22 ドメイン敵対的学習を用いる病理画像からの悪性リンパ腫候補領域の抽出と病型識別

○古賀 諒一¹, 橋本 典明¹, 横田 達也¹, 中黒 匡人², 高野 桂², 中村 栄男², 竹内 一郎¹, 本谷 秀堅¹

¹名古屋工業大学, ²名古屋大学医学部附属病院

本研究では、悪性リンパ腫の薄切切片の HE 染色病理顕微鏡画像より、病名を推定する手法を提案する。悪性リンパ腫には70種類以上の病型があり、その病型に依存して治療法や治療後の経過が異なるうえに、その病型を病理画像より診断することは専門の病理医であっても容易ではない。この病型識別を支援するシステムを構築するために、切片全体を含む病理画像中より悪性腫瘍領域の部位を選択的に取り出し、そのうえで病型を推定する手法を提案する。この際、施設や染色を行った技師ごとに異なる HE 染色の色味の違いを積極的に無視するために、ドメイン敵対的学習を採用する。これにより、切片全体の病理画像から悪性腫瘍領域の抽出ができるようになり、病理画像における腫瘍領域の可視化が可能となった。また、選択的に取り出された悪性腫瘍を含むバッチのみを用いて病型を推定することで、病型推定の精度向上が確認できた。

OP1-23 造影 CT 画像における 2 段階閾値処理及びテクスチャ解析による外傷出血自動検出の検討

○木村 拓貴¹, 吉村裕一郎², 田中久美子³, 中田 孝明³, 中口 俊哉²

¹千葉大学 大学院融合理工学府, ²千葉大学 フロンティア医工学センター, ³千葉大学大学院医学研究院 救急集中治療医学

現在の外傷治療では救急医による造影 CT 画像を用いた読影診断が行われているが、1000 枚以上の CT 画像を迅速かつ正確に読影する必要があることから医師の負担は大きい。本研究では、医師の負担軽減を目的に外傷出血の自動検出を検討する。外傷出血候補領域の抽出においては、各組織の CT 値分布を参考に、骨領域の除去及び抽出範囲を限定した 2 段階の閾値処理によって出血領域の候補を抽出する。抽出した候補領域のテクスチャ特徴量からランダムフォレスト学習器を用いて候補領域を分類することで誤検出領域の低減を行った。実験として外傷 29 例の全身 CT 像を用意し、計 153 箇所の外傷出血の検出を試みた。読影医によって抽出された正解領域との重心間距離が 7.5mm 以下を正解として評価したところ、感度 96% の出血領域の検出に成功し、候補領域分類を行うことで偽陽性を約 70% 低減した。

OP1-24 深層学習における学習データセット規模拡大に応じた分類精度向上に関する実験的検討 ～超拡大大腸内視鏡画像における腫瘍性病変分類に向けた特徴量抽出～

○伊東 隼人¹, 森 悠一², 三澤 将史², 小田 昌宏¹, 工藤 進英², 森 健策^{1,3,4}

¹名古屋大学大学院 情報学研究科, ²昭和大学横浜市北部病院 消化器センター, ³名古屋大学 情報基盤センター,

⁴国立情報学研究所 医療ビッグデータ研究センター

超拡大大腸内視鏡による超倍率の拡大観察はリアルタイムなポリープの組織学的分類を実現しうる。この新しいモダリティによる高精度な実時間診断の達成に向け、内視鏡医には高度な知識と十分な知識が要求される。超拡大大腸内視鏡の普及と人材確保に向け、非熟練医の教育・サポートを対象とした CAD システムが求められている。CAD システムにおいては高精度な画像分類器がその中核をなす。特に機械学習に基づく分類器の構成においては大規模な学習データセットが不可欠である。中でも深層学習はデータセットから分類に適したパターン表現を自動的に学習して特徴量抽出を行い、それらの分類を行う。したがって、深層学習においては良質なデータセットの構築は非常に重要となる。本研究では大規模データセットを構築し、深層学習に基づく分類器構築における症例数・画像数・分類精度の関係を実験的に調査する。

OP1-25 CNN を用いた人工股関節全置換術後 CT 画像からの自動インプラント姿勢推定

○阪本 充輝¹, 槇野 大樹¹, 大竹 義人¹, 日朝 祐太¹, 高尾 正樹², 菅野 伸彦², 佐藤 嘉伸¹

¹奈良先端科学技術大学院大学先端科学技術研究科, ²大阪大学大学院医学研究科

人工股関節全置換術において、カップ位置・角度といった置換されたインプラント姿勢は術後評価において重要な役割を果たす。従来、術後 CT 画像からの解析が行われているが、金属アーチファクトによる画像の乱れが原因となり自動解析は容易ではなく、半自動での解析が行われてきた。しかし、大規模データセットでの解析には高速かつ自動で解析を行い、インプラント姿勢を推定する手法が求められる。そこで本研究では、CNN (Convolutional Neural Network) を用いて、術後 CT 画像からのインプラントのセグメンテーション・ランドマーク検出により自動でインプラント姿勢を推定する手法を提案する。

一般演題セッション2

9:00~10:30 OP2

「イメージング/画質改善」

座長:小尾 高史(東京工業大学)

OP2-01 MR圧縮センシングにおけるADMM-Netを利用した深層学習再構成の検討

○植松 駿, 伊藤 聡志

宇都宮大学 大学院地域創生科学研究科 工農総合科学専攻

圧縮センシングをMRIの撮像時間に応用することにより、撮像時間を短縮することができるが、画像再構成に多くの時間を要する問題がある。再構成時間の短縮と高画質化のいずれにも効果的として深層学習を利用した再構成法が注目されている。

深層学習再構成として、L1-L2ノルム最小化問題を解く一解法であるADMMをCNNで実現したADMM-Netが提案されている。本研究では、ADMM-NetにおいてCNNのレイヤー数、学習する画像数、学習画像とテスト画像の関係などについて検討を行った。また、従来法である反復的解法と再構成時間および画質を比較し、ADMM-Netの優位性を確認した。

OP2-02 Electron-Tracking Compton Cameraを用いた異なるエネルギー帯でのリストモードMLEM画像の画質評価

○稲垣 将史¹, 尾川 浩一¹, 谷森 達²

¹法政大学大学院 理工学研究科, ²京都大学大学院 理学研究科

ETCCは機械的なコリメータを使用せず、ガンマ線を観測することが可能であり、空間的に自由な位置にカメラを設置して計測し3次元画像を再構成することが可能である。このため、放射線治療装置と組み合わせて治療を行いながら、リアルタイムで治療部位などを観測可能である。本研究では異なるエネルギーの光子を使用したときに、得られる光子と画質の関係を検討する。光子の発生および被検体内での光子輸送計算にはgeantコードを用い、発生光子エネルギーは300keV, 511keV, 4438keVと変化させ、実験系とほぼ同等のジオメトリでデータ収集を行うものとした。ファントムとしては解像度等を評価できる数値ファントムを用い、リストモードML-EM法を適用し、画像再構成を行った。高エネルギーでの再構成結果の方が低エネルギーでの再構成結果に比べて高画質の結果となり、単純なファントムであれば低エネルギーでも再構成可能であることが確認できた。

OP2-03 コンプトン検出器を組み合わせた部分リングPETジオメトリの提案

○田島 英朗, 山谷 泰賀

量子科学技術研究開発機構 放射線医学総合研究所

リングの一部を開放化した部分リングPETは、リングの体軸方向のみならず開放部からも患者にアクセスでき、また、MRIコイル一体型の頭部用PETインサートとして開放部を下にすれば、患者の頭部に被せるようにセットアップができるなど利便性が向上する。一方で、測定可能な投影データには欠損が生じ、画像に強いアーチファクトが生じてしまうという問題がある。本研究では、開放部と対向する部分の検出器をコンプトン検出器とすることで、欠損方向の情報をコンプトンイメージングの原理を用いて補い、投影データの欠損によるアーチファクトを低減可能な新しい部分リングPETジオメトリを提案する。計算機シミュレーションとして、システムマトリクスを用いた順投影によって投影データを作成し、MLEM法によって画像再構成を行った。その結果、通常の部分リングPETで生じてしまうアーチファクトが、コンプトン検出器を組み合わせることによって低減できることが示された。

OP2-04 被写体スキャン方式による X 線位相イメージング法の開発○堀場 日明¹, 佐野 哲¹, 和田 幸久¹, 徳田 敏¹, 池田 凡子², 衛藤翔太郎², 中川 貴之², 田邊 晃一¹, 北村 圭司¹¹株式会社島津製作所 基盤技術研究所, ²東京大学大学院 農学生命科学研究科 獣医外科学研究室

Talbot 干渉計をはじめとする X 線位相イメージング法は, 従来の X 線の吸収像では検出が困難であった軟組織でも視認性良く描出できることから, リウマチや乳がんなどを早期発見するための有用な手法として医療への応用が期待されている. しかしながら Talbot 干渉計の医療応用にあたっては, 被写体の視野範囲が回折格子のサイズによって制限されるという課題がある. そこで, 我々は視野サイズを拡大するため, Talbot 干渉計をベースとして被写体をスキャン撮影する光学系を開発した. 本光学系は格子なしの吸収像と位相イメージング画像を同時に取得することが可能であり, さらに格子方向に対して被写体を回転させて撮影することで位相像を取得する方法も開発した. この光学系を用いて動物の乳がん検体を撮影し, 従来の吸収法では得られなかった腫瘍のコントラストが描出できることを確認した.

OP2-05 学習データセットを必要としない畳み込みニューラルネットワークを用いた Dynamic PET 画像のノイズ除去手法○橋本二三生¹, 大手 希望¹, 寺本 篤司²¹浜松ホトニクス株式会社 中央研究所, ²藤田医科大学 医療科学部

深層学習を医用画像処理に応用する場合, 多数の教師ラベル付き臨床データセットを用意する必要がある. しかし, 症例数の不足や倫理的な制約等により, 大規模で高品質な臨床データセットを構築することは容易ではない. 本研究では, 学習データセットを必要としない畳み込みニューラルネットワーク (CNN) を用いることで, 多数の教師ラベル付き臨床データセットを用意することなく Dynamic PET 画像のノイズを除去する手法を提案する. 本手法は, 当該の計測 PET データのみを CNN の学習に利用する. まず, 教師ラベルとして Dynamic PET 画像を, 入力画像として計測データすべてを用いて再構成した Static PET 画像を用意する. これら一対のデータペアを Encoder-decoder 型の CNN を用いて逐次学習させることにより, 大幅にノイズが除去された Dynamic PET 画像を取得する. 本手法を用いることで, 従来使用されていたノイズ除去手法と比較し, 大幅なノイズ除去性能の向上がみられ, 本手法の有効性が示された.

OP2-06 畳み込みニューラルネットワークを用いた低線量 CT 画像再構成法の多時相 CT イメージングへの拡張○森 和希¹, 千北 一期¹, 工藤 博幸²¹筑波大学システム情報工学研究科コンピュータサイエンス専攻, ²筑波大学 システム情報系

近年, 低線量 CT を目的とした深層学習画像再構成法の研究が精力的に行われている. これらの研究では, フィルタ補正逆投影 (FBP) 法で再構成した劣化画像をコンボリューション層とデコンボリューション層からなる畳み込みニューラルネットワーク (CNN) に入力して雑音を低減した高画質の画像を得る画像再構成法を提案している. 本研究では, この画像再構成法を腹部 CT 撮影 (4 時相) に代表される多時相 CT イメージングに拡張した新手法を提案する. 提案手法では, M 時相の画像のうち M-N 枚を通常線量で撮影しそれ以外の N 枚を低線量で撮影することで低被曝での CT 撮影を実現する. そして, M 時相全ての画像を入力とし低線量で撮影した N 枚の画像を出力とする CNN を用いて, 雑音を除去した高画質の再構成画像を得る. M 時相全ての画像を CNN の入力とすることにより, CNN は通常線量画像を先験情報として低線量画像の画質を改善するように動作して, 1 入力 1 出力の CNN で各時相の画像を独立に処理する単純な手法と比較して, より上手く雑音除去することが可能となるのがキーである. CNN の学習は, 位置合わせした多数患者の CT 画像から CT イメージング過程をシミュレーションしたデータセットを用いて行う. 腹部 CT 実画像データセットを用いたシミュレーション実験により提案手法の有効性を評価した. 具体的には, 4 時相のうち何枚のどの時相を低線量で撮影するかの組み合わせを変化させた幾つかの典型的な撮影プロトコルについて, 深層学習を用いた手法の有効性を示す. 提案手法は, MRI など他のマルチチャンネルイメージングにおいても有効と考えられる.

OP2-07 FDTD による Shear wave elastography の不安定要因の検証○伊藤 大貴¹, 大栗 拓真¹, 山田 敦子¹, 吉田 憲司², 山口 匡²¹千葉大学 大学院 融合理工学府, ²千葉大学 フロンティア医工学センター

超音波で生体組織の硬さを評価する手法として, 音響放射力によって組織内に発生するせん断波の伝播速度 (shear wave velocity; SWV) を利用する方法である Shear wave elastography (SWE) が臨床で実用化されている. しかし, メーカー間で SWV の評価結果に差を有することや, 計測部位によっては評価結果が不安定になることが示されている. 前者の主な要因は, 音響放射力の空間的および時間的特性がメーカーによって異なることや, せん断波の波形を判定するための処理および解析に使用されるアルゴリズムの違いによると考えられるが, 生体内の組織構造や物性による不安定性も含めた検証が必要である.

本研究では, SWE の標準化のアプローチのために, 有限差分時間領域法 (Finite-Difference Time-Domain method; FDTD) を用いて, 実際の診断装置から送信される音響放射力の分布を模擬した送信条件下において, 任意の生体組織性状におけるせん断波の伝播シミュレートし, 送信条件や各種の信号処理が SWV の評価に与える影響について検証する.

「画像解析 / モデリング」

座長：中口 俊哉（千葉大学）

OP2-08 表現学習と SVM による胃壁マイクロ CT 像の半教師ありセグメンテーション手法

○御手洗 翠¹, 小田 紘久¹, 杉野 貴明¹, 守谷 享泰¹, 伊東 隼人¹, 小田 昌宏¹, 小宮山琢真², 森 雅樹³, 高島 博嗣⁴, 名取 博⁵, 森 健策^{1,6,7}

¹名古屋大学大学院情報学研究科, ²名古屋大学大学院医学系研究科, ³札幌厚生病院, ⁴札幌南三条病院, ⁵恵和会西岡病院, ⁶名古屋大学情報基盤センター, ⁷国立情報学研究所医療ビッグデータ研究センター

本稿では, Spherical K-means (SpK) による表現学習と SVM を用いた胃壁 μ CT 像の解剖学的構造に基づいた半教師あり抽出手法について報告する. μ CT 画像は μ m オーダーで標本を 3 次元で観察可能であり, 胃壁 μ CT 像から腫瘍及び層構造を抽出することで腫瘍の立体的構造把握が可能である. しかし, 豊富なラベルデータを作成するのは容易ではないため, 教師ありの抽出手法を用いるのは難しい. また, 胃壁 μ CT 像はコントラストが低いことから, 教師なしの抽出手法で精度良く抽出することは困難である. そこで本手法では, 対象画像とごく少量のラベルデータを利用する半教師ありの抽出手法により問題の解決, 抽出精度の向上を図った. 本手法は (1): SpK による表現学習, (2): 特徴抽出, (3): SVM を用いたラベルの割り当ての 3 段階から成る. 本手法を胃壁 μ CT 像に適用した結果, 良好な結果が得られた.

OP2-09 MR 画像と病理画像の統合による膀胱腫瘍の多重解像度モデルの構築

○下村 智茂¹, クグレマウリシオ¹, 岩本 千佳², 大内田研宇², 橋爪 誠², 横田 達也¹, 本谷 秀堅¹

¹名古屋工業大学, ²九州大学

本研究では膀胱腫瘍の多重解像度モデルを構築する. 多重解像度モデルは膀胱腫瘍の MRI 画像のボクセルと, 対応した Hematoxylin-Eosin 染色顕微鏡病理画像のパッチとの同時確率分布を表現するモデルである. このモデルにより MRI 画像中の各位置において観察されるであろう病理画像のパターンを予測し, これら MRI 画像と病理画像との関係を明らかにすることが本研究の目的である. この多重解像度モデルは, MRI 画像の各ボクセルから確率分布に従い対応する顕微鏡病理画像のパッチ群を予測する生成モデルでもある. この生成モデルを Neural Network を用いて構築し, MRI 画像と顕微鏡病理画像とを位置合わせすることで作成したデータセットを用いて学習した. この生成モデルを用いて MRI 画像の各ボクセルから対応する顕微鏡病理画像のパッチ群を推定することで同時確率分布を近似したので, その結果を報告する.

OP2-10 機械学習を用いた人工膝関節画像からの機種同定 ~マハラノビス距離による識別効果と CNN の適用~

○岸野万由子¹, 山崎 隆治¹, 富田 哲也², 佐藤 嘉伸³, 菅本 一臣²

¹埼玉工業大学 工学部 情報システム学科, ²大阪大学大学院 医学系研究科 運動器バイオマテリアル学, ³奈良先端科学技術大学院大学 情報科学研究科

術後人工膝関節の 3 次元的な運動情報を正確かつ定量的に把握するために, 我々はこれまで, 1 方向 X 線透視画像と人工膝関節 CAD (Computer Aided Design) モデルを用いた 2D/3D レジストレーション手法を開発してきた. 現在, その 3 次元運動計測の全自動化に向けていくつかの要素技術の開発を行っており, その一つとして, X 線画像から人工膝関節の種類 (タイプ) を識別, 同定することは重要である. そこで本研究では, 多種類の人工膝関節のシルエット画像 (シミュレーション画像) を用いて機械学習による識別性能の基礎的な検討を行った. 具体的には, ①マハラノビス距離による識別効果と, ②畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) による識別性能について検証を行った. 結果として, マハラノビス距離による識別では, 誤識別が減少, 識別性能が向上することが分かった. また, CNN による識別では, 少ない特徴量の場合においても識別率が 100% と興味深い結果が得られ, ヒトの感覚とは異なる最適な特徴量が存在, 選択されることが示唆された.

OP2-11 所見テキスト解析を用いる H&E 染色病理画像からの免疫染色群推定

○黄 果葡¹, 橋本 典明¹, 横田 達也¹, 中黒 匡人², 高野 桂², 中村 栄男², 竹内 一郎¹, 本谷 秀堅¹

¹名古屋工業大学, ²名古屋大学医学部附属病院

悪性リンパ腫は形態や性質によって 70 種類以上のタイプに分類され, タイプごとに大きく治療方針が異なる. このため悪性リンパ腫のタイプの病理画像に基づき正確に同定することが治療には不可欠であり, タイプの同定には多数の免疫染色を施した病理画像を観察しなければならない. タイプの同定に必要な免疫染色は症例ごとに異なり, 病理医はまず HE 染色画像を観察し, その結果に基づきタイプの同定に必要な免疫染色群を推定する. 本研究では, 悪性リンパ腫の診断に使用した免疫染色の結果を示す所見テキストデータと HE 画像を併用することにより, 免疫染色推定器を構築する. 所見データを解析すると, 同一タイプの悪性リンパ腫であっても, 施した免疫染色群が互いに異なる症例がある. このことに注目することにより, HE 染色画像からの免疫染色群の推定がどの程度容易であるかを症例毎に定量評価する試みについても紹介する.

OP2-12 深層学習を用いた術野映像内肺領域抽出

○今西 勁峰¹, 武 淑瓊², 中尾 恵², 松田 哲也²

¹ イーグロース株式会社, ² 京都大学大学院 情報学研究所

外科手術の安全性向上において、血管および腫瘍の三次元構造を把握することは不可欠であるため、術中における臓器の変形推定に関する研究が進められており、カメラ画像内における二次元臓器領域が抽出できれば、臓器の三次元変形推定が可能であることが従来の研究によって示されている。しかし、呼吸性移動を伴う時系列な変化が大きい臓器に対するカメラ画像内領域を精度よく自動抽出する手法が確立できていない。本研究では、深層学習を用いて、肺手術の術中カメラ画像に対し、肺領域を自動抽出可能なモデルを構築した。実際の肺がん切除術の術中カメラ画像を用いて本モデルを訓練し、検証用症例の画像を用いて有効性を検証した結果、初期画像に対する肺領域の自動抽出精度、および時系列的な領域変化を伴う連続画像に対しての自動抽出精度がともに良好であったので報告する。

OP2-13 高難易度画素用の損失関数を用いたセマンティックセグメンテーション

○松月 大輔, 堀田 一弘

名城大学

セマンティックセグメンテーションは画像を1画素ずつ識別、ラベル付けを行う。当然、画像の画素毎に識別の難易度の高い箇所もあれば、簡単な箇所もある。通常、セマンティックセグメンテーションのラベル付けは、出力層で出力したいチャンネル数まで次元削減した後にsoftmax関数を適用し、チャンネル毎に確率に変換する。その際、チャンネル毎の確率値が均等に与えられるような箇所は、一般的に識別が難しい箇所であることが多い。そこで我々は、チャンネル毎の確率値に基づき、識別の難しい箇所を強く学習するような学習法を提案する。評価実験では、「細胞膜」、「細胞核」、「細胞質」を含むデータセットを用い、従来の学習方法と我々の提案する学習方法の精度比較を行った。その結果、Intersection over Unionを用いた精度評価において提案手法が従来法を上回ることを確認した。

OP2-14 Polyp size classification in colorectal cancer using a Siamese network

○ヴィラードベンジャミン¹, 伊東 隼人¹, 小田 昌宏¹, 森 悠一², 一政 克朗², 三澤 将史², 工藤 進英², 森 健策^{1,3,4}

¹ 名古屋大学大学院情報学研究所, ² 昭和大学横浜市北部病院消化器センター, ³ 名古屋大学情報基盤センター, ⁴ 国立情報学研究所医療ビッグデータ研究センター

Colorectal cancer is one of the leading cause of cancer related deaths with increasing prevalence. One key factor in the likelihood of adenomatous cell differentiation is polyp diameter. Much research has shown polyp size to be a major characteristic contributor to the risk of colorectal cancer. There exist a significant cut-off value of 10 mm which clinicians use regarding their treatment diagnosis and patient surveillance. However, polyp measurement is highly variable and there exist a high variance between clinician measurement surrounding this threshold value. We propose a novel method to classify polyp size into above or below 10 mm classes based on a Siamese network. In a first step, a Siamese networks is trained to build a high dimensional embedding of features extracted for each polyp size. In as second step, we train an feed-forward neural network that classifies the polyp size based on the distance between the feature embedding of the input image, and the whole embedding space learned by the Siamese network. This method allows for better binary classification of the sub- and sup- 10 mm polyp size classes. Furthermore, our method can be used in a real time classification system as the classification relies only on computing the distances between feature embeddings. Our data consist of around 33,000 images from 129 movies classified into various polyp sizes ranging from 1-15 mm. We trained our model on 23,000 images, and tested on 10,000 images equally split into each binary category. We obtained 89.2% in feature classification.

OP2-15 病変検出支援アルゴリズムにおける局所画像特徴量の汎用的な自動生成 - 健常データのみでの学習による特徴量生成の検討 -

○牛房 和之¹, 根本 充貴², 木村 裕一¹, 永岡 隆¹, 山田 誉大¹, 林 直人³

¹ 近畿大学大学院 生物理工学研究所, ² 近畿大学 生物理工学部, ³ 東京大学 医学部附属病院 22 世紀医療センター

様々な病変検出支援 (CADe) アルゴリズムにおいて適用が可能な、局所画像特徴量の汎用的自動生成法について検討する。特に、不十分量の病変データで CADe アルゴリズムの研究が行われることが少なくないことから、健常部の局所画像パッチデータのみで学習が可能な手法を検討する。教師無し学習法である深層畳み込みオートエンコーダと主成分分析を用いて画像パッチから得た特徴量の比較、およびそれらを併用した際の識別性能を検証する。特徴量は、局所画像パッチのアピアランスベクトルから得られる潜在変数と、潜在変数から再現した画像パッチと本画像との誤差とする。胸部 CT から自動検出した肺結節候補データセットおよび頭部 MRA から自動抽出した脳動脈瘤候補データセットを用いて自動生成された画像特徴量について実験的に検証したので、その結果を報告する。

OP2-16 X線単純投影と流体構造連成解析を用いた狭窄柔軟管内流れにおける造影剤濃度勾配の評価

○金子凌太郎, 高本 聡, 波田野明日可, 泉 聡志
東京大学工学部

冠動脈の狭窄は心筋梗塞などの重大な病気を引き起こす原因となっている。狭窄の機能的重症度を低侵襲かつ簡易に診断する方法として造影剤濃度勾配を指標とするTAG (Transluminal Attenuation Gradient) が挙げられるが、精度の向上が求められている。狭窄後に生じる再循環領域における造影剤の拡散は、TAGに大きく影響すると考えられる。そこで本研究では造影剤拡散動態を明らかにするため、狭窄血管を模擬したシリコンゴム製の柔軟管に流した造影剤をX線単純投影により撮影した。流体は水及び血液を用いた定常流及び拍動流の条件で流した。また実験を模した流体構造連成解析を行い比較を行った。

定常流で流体に水を用いた実験では、狭窄後の造影剤は管断面全体に広がり一様に拡散する様子が観察された。一方、血液を用いた実験では、造影剤濃度の高い領域が管壁を伝いらせん状に回転しながら流れていた。血液を想定した解析では狭窄率が高い場合に噴流が軸中央を外れ管壁を伝う様子が観測され傾向は一致したが、拡散に伴う濃度勾配の定量的な一致には課題が残った。

「CAD/ 臨床応用」

座長：花岡 昇平（東京大学）

OP2-17 Coxnet と NMF を用いた非小細胞肺癌の組織学的分類

○山田 真大¹, 有村 秀孝², 二宮 健太¹

¹九州大学大学院 医学系学府 保健学専攻, ²九州大学大学院 医学研究院 保健学部門

Histological classification of non-small cell lung cancer (NSCLC) affects the decision making of treatment policies. However, histological subtypes, i.e. adenocarcinoma (ADN) and squamous cell carcinoma (SCC), identified from a single biopsy occasionally differ from actual subtypes decided by surgical resections for NSCLC. We aim to explore classification approaches of histological subtypes of NSCLC using three support vector machines (SVMs) with radiomic signatures determined by Coxnet and non-negative matrix factorization (NMF). Classification models of Gaussian, linear and polynomial SVMs constructed with radiomic signatures achieved the areas under the curves (AUCs) of 0.7021, 0.6803, 0.7131 using Coxnet, and 0.7128, 0.6660, 0.7143 using NMF, respectively. The polynomial SVM with the radiomic signature determined by NMF could more correctly classify histological subtypes of NSCLC into ADN and SCC.

OP2-18 CNN を用いた CAD 開発における段階的学習法の提案

○安倍 和弥¹, 武尾 英哉¹, 永井 優一², 縄野 繁³

¹神奈川工科大学, ²国立がん研究センター東病院, ³国際医療福祉大学三田病院

近年、CADの研究分野にもCNNが積極的に用いられるようになった。一般的に、機械学習には様々なバリエーションを有する症例画像を網羅的に与えて学習することで、汎用的で高性能な判別器を設計する。しかし、CNNの学習データを構成する中で、データを一律に与えるのではなく、複数のサブセットに分け、その比率を調整することで効果的な学習ができることが実験的にわかった。CNNが持つ学習データの補間的な特性を検証するとともに、その理由を分析し報告する。

本研究では、乳がん腫瘍の学習データを腫瘍の大きさと濃淡をもとに個々のサブセットを作成し、学習したCNNを評価用として複数用意したデータセットを用いて最適比率を検討し、実際の未知データで性能評価を行う。そして、評価データで検出ミスが多かったサブセットの比率を上げて再学習を行う。これをAUCの上昇が見られる間複数回繰り返し、性能の高いCNNを設計した。このCNNを未知データへ適用した結果、単純に網羅的に学習データを与えたCNNと比べてAUCが高いことが確認でき、本学習法の有効性が確認できた。

また、本学習法を肝腫瘍にも適用したところ、同様の結果が得られ、この学習法の汎化性も確認できた。

OP2-19 Coxnetによって選択されたレディオミクスシグネチャによるSVMを用いた頭頸部癌患者の5年生存確率の予測

○Le CuongQuoc¹, 有村 秀孝², 山田 真大¹, 亀澤 秀美³

¹九州大学大学院 医学系学府 保健学専攻, ²九州大学大学院 医学研究院 保健学部門, ³帝京大学 医療技術学部 診療放射線学科

Five-year survival probability may affect the choices of treatment policies for head-and-neck (H&N) cancer patients. The aim of this study was to investigate an automated approach to predict of 5-year survival probabilities of H&N cancer patients using a support vector machine (SVM). Engineered features representing tumor heterogeneity of cancer patients were extracted from gray-level histogram and texture matrices within cancer regions. The signatures, i.e., sets of significant features, were constructed using a Coxnet algorithm. The signatures were fed into the SVM with a polynomial kernel to estimate the 5-year survival probabilities. The polynomial SVM learning with radiomic signatures archived an area under the curve of 0.665 for stratification of patients based on 5-year survival. The polynomial SVM could be feasible to estimate the 5-year survival probabilities of H&N cancer patients.

OP2-20 Kinect を用いた効率的な 3 次元顔面腫れ顔の形態変化の観測と可視化

○健山 智子¹, 大野 瑛史¹, 松本 慎平², 澤本 尚哉³

¹ 広島工業大学 情報学部 知的情報可視化研究室, ² 広島工業大学 情報学部, ³ 東京大学医学系研究科 公共健康医学専攻

顔面浮腫の診断は、医師の目視による主観的観測が一般的であり、客観的な評価手法の確立が切望されている。本研究では、顔面浮腫の形態変化の数値化より、浮腫具合を評価する計算機診断支援 (CAD) の確立を目指す。顔面浮腫の形態観測として、高精度レーザスキャナを用いた顔形状の 3 次元形状情報の取得などが挙げられるが、使用する機材が高価、キャリブレーションのための計算コストが高いことなどの問題点がある。そのことから、安易な撮像方法で顔形状情報を取得するデバイスの導入として、我々は、汎用性のある RGB-D センサとして、Kinect を導入し、顔面浮腫の形態変化の観測が可能であるかを検証する。検証では、正常 10 名に擬似腫れ顔として頬を膨らまし、その差分についての可視化を解析することで検証をおこなう。その可視化について、臨床医から評価を行い、顔面浮腫の形態変化の診断支援に有効であるかについて議論する。

OP2-21 GAN による CT 肺結節画像の生成

○濱口 拓真¹, 木戸 尚治², 平野 靖¹, 岩野 信吾³

¹ 山口大学大学院創成科学研究科, ² 大阪大学大学院医学系研究科, ³ 名古屋大学大学院医学系研究科

近年、CT 画像中の肺結節の解析を Convolutional Neural Network (CNN) を用いて行う手法が数多く提案されており、高い性能を示すことが報告されている。一方で、このような解析に用いる学習画像を大量に用意できないことが原因で汎化性能を向上させることができない場合が多いという問題がある。この問題を解決するため、一般的には画像に対して回転や鏡映などを行って学習画像数を増加させる手法 (水増し) がとられているが、根本的な解決にはなっていない。そこで本研究では、2 次元画像に対して Deep Convolutional Generative Adversarial Networks (DCGAN) を用いた画像水増し手法を開発することを目的とした。

具体的には、DCGAN によって肺結節画像を生成するモデルを作成し、このモデルを用いて学習画像の生成を行った。比較対象として、水増しを行わなかった場合、および平行移動や回転・鏡映によって水増しを行った場合 (従来法) のそれぞれで CNN の学習を行い、それらの良悪性鑑別精度を比較した。

5 分割交差検証を行った結果、提案法、水増しを行わなかった場合、および従来法の良悪性鑑別の精度は、それぞれ $75.81 \pm 6.36\%$ 、 $76.38 \pm 4.32\%$ および $76.57 \pm 4.40\%$ であった。

結果として本手法の優位性は得られなかったが、本手法では従来法と比較して大量の画像を生成できる可能性が示唆された。

OP2-22 AutoEncoder の正常症例訓練モデルによる FDG-PET 画像中の悪性腫瘍検出手法に関する研究

○前田 健宏¹, 原 武史¹, 周 向栄¹, 片渕 哲朗², 藤田 広志¹

¹ 岐阜大学大学院自然科学技術研究科知能理工学専攻, ² 岐阜医療科学大学保健科学部

本研究の目的は、医師の負担軽減や見落としを防ぐために、体幹部 FDG-PET 画像における悪性腫瘍の自動検出手法の開発を目的とする。ここでは、異常症例より収集が容易な正常症例を利用して、異常検知の観点から検出を行う。PET スライス画像を 12×12 画素のパッチ画像へ分割する。正常症例のみで訓練した AutoEncoder モデルによるパッチ画像の特徴量抽出を行う。再構成誤差を特徴量として加え、外れた傾向を持つパッチ画像を抽出する。抽出されたパッチ画像群を k-means 法により 2 クラスへ分割し、PCA による第一、第二主成分をそれぞれ軸とする 2 次元空間上にプロットする。クラス重心との距離を基にパッチ画像にスコア付けをし、スコアの集積する部位を腫瘍領域とする。腫瘍を含む 33 症例を対象に検出精度を求める。検出率 95.1%、1 症例あたりの偽陽性領域数は 53 領域となり、正常症例のみで訓練した AutoEncoder モデルは腫瘍検出に有用である可能性を示唆した。

OP2-23 低線量 CT 画像を用いた肺結節の経時変化による良悪性鑑別

○東 勇太¹, 鈴木 秀宣², 河田 佳樹², 仁木 登², 楠本 昌彦³, 土田 敬明⁴, 中野 恭幸⁵, 金子 昌弘⁶, 江口 研二⁷

¹ 徳島大学大学院先端技術科学教育部, ² 徳島大学大学院理工学研究所, ³ 国立がん研究センター東病院, ⁴ 国立がん研究センター中央病院, ⁵ 滋賀医科大学, ⁶ 東京都予防医学協会, ⁷ 帝京大学医学部

日本における死因別死亡率はがんが第一位であり、現在もがんによる死亡率は上昇しつづけている。その中でも部分別に見たとき肺がんは、がん死亡者数第一位を占め、こちらも増加傾向にある。肺がんの治療には、早期発見が必須であり、その方法のひとつとして、胸部 3 次元 CT 画像を用いた肺がん CT スクリーニングが施行されているが、これには被爆の影響が大きいため低線量 CT 肺がん検診が取り入れられている。また、NLST や NELSON trial により低線量 CT 検診は肺がん死亡率の減少に効果があることが示されたことにより、低線量 CT 肺がんによる検診の有用性が示されたほか、これからどのように病状が進行していくかを示す特徴が存在している可能性があることがわかった。本研究では、肺結節の経時変化から病状の悪化に伴いどのような特徴量に変化しているのかを明らかにし肺結節の良悪性鑑別を行う。

OP2-24 造影 MR 画像における部分最小二乗法による肝臓形状解析及びテクスチャ解析を用いた肝線維化のステージ分類

○スーフィーマーゼン¹, 大竹 義人¹, 堀 雅敏², 今井 康陽³, 澤井 良之³, 太田 崇詞², 富山 憲幸², 佐藤 嘉伸¹

¹ 奈良先端科学技術大学院大学, ² 大阪大学, ³ 市立池田病院

We aimed at the staging of liver fibrosis by using image features derived from partial least squares regression (PLSR)-based statistical shape and texture analyses applied to contrast-enhanced MR images. MR images of 51 patients were used. Fifty-four texture features were derived from the image histogram and 4 texture analysis matrices. A statistical shape model was constructed by using PLSR. The fibrosis stage was estimated by using a support vector machine (SVM) based on texture features and PLSR scores. The accuracy (in terms of the AUC) at the classifications F0/1 vs. F2-4 (early), F0-2 vs. F3-4 and F0-3 vs. F4 (cirrhosis) were 0.93 ± 0.03 , 0.77 ± 0.05 and 0.84 ± 0.05 , respectively, thus showing the feasibility of the proposed approach for staging of liver fibrosis.

第2日 7月25日(木)

メイン会場 (レセプションホール1)

ミニシンポジウム 1

10:40 ~ 11:30

MS1 「CT・MR イメージングにおける深層学習」

座長：増谷 佳孝 (広島市立大学)

深層学習による医用イメージング技術, 特に CT や MRI の画像再構成を中心に最新の研究成果を紹介する.

MS1-1 深層学習を用いた CT 及び PET/SPECT の画像再構成

○工藤 博幸
筑波大学

CT や PET/SPECT の画像再構成は, 歴史的に解析的手法 (第1世代)・逐次近似法 (第2世代) という順序で研究や実用が進んできた. 深層学習を用いた画像再構成法は, これらに続く第3世代と呼ばれる. 本発表では, 深層学習を用いた CT 及び PET/SPECT の画像再構成に関する発表者らの研究事例を紹介し, これらに基づき私見も含むが期待できる点・問題点・今後の展望などに言及したい.

MS1-2 深層学習を用いた CT 画像の金属アーチファクト低減処理

○大竹 義人
奈良先端科学技術大学院大学

我々は, 人工股関節手術における術前計画, 術中支援, 術後の予後予測を目的として, CT・MRI・X線画像から患者個別の筋骨格モデルを構築することを目指している. 本発表では, 術後 CT 画像の解析に着目し, 人工股関節部品の CAD モデルを学習データとした深層学習モデルによる金属アーチファクト低減処理, およびアーチファクト低減後画像からの股関節周辺筋骨格のセグメンテーションについて報告する.

MS1-3 深層学習を利用した MR イメージング

○伊藤 聡志
宇都宮大学

MRI の画像処理に深層学習を利用する方法が注目されている. 圧縮センシングの再構成に利用すると方法によってはスパース化関数を用いずとも良質な画像を再構成することが可能となる. 人工的な画像になりにくく, かつ反復的計算を必要としないので, 短時間で再構成を行うことができるのも魅力である. 雑音処理に利用すると, 従来の非線形フィルタでは困難であった生体内の構造を十分に反映した良質な雑音除去フィルタを構成できる. 超解像に応用すると従来の学習型解像度を超える高解像度の画像を生成する. 本講演では深層学習を利用したいくつかの事例を紹介する.

MS1-4 生成型 Q 空間学習による拡散 MR イメージング

○増谷 佳孝
広島市立大学

拡散 MRI とは、単一あるいは異なる複数の撮像設定による拡散強調イメージングの手法およびデータの総称である。様々な信号値モデルのパラメタにより脳白質神経などの生体構造の定量化が可能となるが、そのパラメタ推定はこれまでのフィッティングに加え、近年では機械学習によるアプローチによって行われる。本発表では、特に学習を合成データのみで行う生成型 Q 空間学習に注目し、DTI、DKI や NODDI などのモデルに対し深層学習を適用した結果を紹介するとともに、その利点や注目すべき特性を議論する。

MS1-5 質疑応答および全体討論

特別講演 1

14:00 ~ 14:50

SL1 「軟骨伝導の発見から MBT (医学を基礎とするまちづくり) へ」

座長：佐藤 嘉伸

(奈良先端科学技術大学院大学 / JAMIT2019 大会長)

SL1 軟骨伝導の発見から MBT (医学を基礎とするまちづくり) へ

○細井 裕司
奈良県立医科大学 理事長・学長

【MBE, MBT とは】対象が医療産業だけではなく、すべての産業に医学の光を当て、医学による産業の創生・再生を図る MBE をまちづくりの中で実現するのが MBT である。現在、奈良医大を中心に 104 の企業・団体がコンソーシアムを形成し、この理念の実現を目指している。

【MBE, MBT の発想】MBE は、CT や MRI のように工学が医学を助ける ME(医用工学)の逆の発想で、医学的知見を工学や産業の発展に生かすものである。2004 年に私が「軟骨伝導聴覚現象」を発見したことが発想の原点となったので、MBT と合わせて軟骨伝導を紹介する。

シンポジウム 1

15:05 ~ 16:25

SY1 「医用画像のビッグデータと AI 開発の展望」

座長：村尾 晃平 (国立情報学研究所)

中田 典生 (東京慈恵会医科大学)

国立研究開発法人日本医療研究開発機構 (AMED) により「臨床研究等 ICT 基盤構築・人工知能実装研究事業」が開始されており、順次採択された医学系の学会と国立情報学研究所 (NII) を中心とする国内の画像解析のエキスパートの研究室が連携して医用画像の収集・解析に取り組んでいる。現在参画している医学系の学会は、日本消化器内視鏡学会、日本病理学会、日本医学放射線学会、日本眼科学会、日本超音波医学会、日本皮膚科学会であり、画像解析に参加している組織は、NII のほか、東京大学、名古屋大学、九州大学、奈良先端科学技術大学院大学、中京大学である。

本シンポジウムでは、データの収集・解析の基盤の仕組みについて NII から紹介し、様々な具体的な解析タスクについて各組織から事例を紹介する。一方、海外でのデータ収集の状況についても俯瞰し、我が国における今後の研究から社会実現までについて展望を議論する。

SY1-1 医療画像ビッグデータクラウド基盤

○合田 憲人
国立情報学研究所

医療の質・安全性の向上、高度化、効率化、均てん化のため、ICT を活用して医療画像に代表される医療ビッグデータを収集・利活用するための仕組みが求められている。国立情報学研究所では、全国規模で収集される大量の医療画像データの受入・解析が可能な医療画像ビッグデータクラウド基盤を整備・運用している。本クラウド基盤には、現在、医学系 6 学会が全国の病院から収集した医療画像が匿名加工された上で収集され、AI を用いた画像解析研究に活用されている。本講演では、医療画像ビッグデータクラウド基盤の概要および活用状況について紹介する。

SY1-2 AMED プロジェクトにおける画像解析タスク俯瞰，眼科画像の解析

○佐藤 真一

国立情報学研究所

国立研究開発法人日本医療研究開発機構（AMED）の支援のもと「臨床研究等 ICT 基盤構築・人工知能実装研究事業」が 2017 年より開始されており，先の講演で紹介したクラウド基盤の中で各医学系学会から提起されたタスクに取り組んでいる。これらのタスクについて全体を俯瞰し，その中から眼科画像を用いた解析として，緑内障の検出，緑内障を含めた複数疾患の識別を例に取組みを紹介する。

SY1-3 病理と内視鏡画像における胃がん検知システムの開発

○原田 達也，黒瀬 優介

東京大学

国立研究開発法人日本医療研究開発機構（AMED）の支援のもと「臨床研究等 ICT 基盤構築・人工知能実装研究事業」が 2017 年より開始されており，我々は医学系の学会と連携して画像診断支援アルゴリズムの開発に取り組んでいる。本発表では，日本病理学会から提供された Whole slide image (WSI) と日本消化器内視鏡学会から提供された内視鏡画像それぞれに対して開発した胃がん検知アルゴリズムについて報告する。

SY1-4 大腸の画像診断：大腸生検の病理画像解析および大腸の内視鏡画像解析

○内田 誠一，備瀬 竜馬

九州大学

本発表では，内視鏡学会及び病理学会との取り組みについて報告する。内視鏡で撮影した大腸画像において，部位や炎症のクラス分類を行うことは臨床応用上重要である。本発表では，このような課題を実現するための機械学習に必須の学習データ収集を簡易にするクラスタリング手法について報告する。また，病理画像解析としては，大腸の病理画像における「正常」「良性腫瘍」「悪性腫瘍」の 3 領域分割課題に関して報告する。

SY1-5 AMED 大規模データベースを用いた CT 画像解析と病変検出への応用

○森 健策，小田 昌宏

名古屋大学

本講演では，AMED 大規模データベースを用いた CT 画像解析と病変検出への応用について紹介する。AMED 研究プロジェクト「医療ビッグデータ利活用を促進するクラウド基盤・AI 画像解析に関する研究」では，全国の臨床関係学会から医用画像データを収集し，得られた画像データベースを用いて，機械学習等を用いた画像診断アルゴリズムの開発を進めている。本講演では，その中でも放射線領域のデータベースに注目し，クモ膜下出血などの病変の自動検出，異なる機関から収集されたダイバシティの高い画像を用いた解剖学構造自動認識などについて，事例を挙げながら紹介したい。

SY1-6 大規模 CT データ解析による骨格解剖知識の抽出

○大竹 義人¹，日朝 祐太¹，高尾 正樹²，菅野 伸彦²，佐藤 嘉伸¹

¹奈良先端科学技術大学院大学，²大阪大学大学院医学系研究科

我々は，本プロジェクトで日本医学放射線学会が収集している大規模 CT 画像データベースから，整形外科手術の術前計画・術後評価に有用な骨格解剖に関する新たな知識の抽出を目指している。本発表では，股関節手術支援のため，未整理の CT 画像データベースから深層学習を用いて骨盤を含む画像を抽出し，骨盤上の解剖学的特徴点の抽出を行う事で，男女差や加齢に伴う骨盤傾斜角の変化を解析した結果について報告する。

SY1-7 超音波画像データベース構築と AI 開発の取り組み

○椎名 毅¹，目加田慶人²

¹京都大学，²中京大学

日本超音波医学会では，AMED の事業として昨年度から肝腫瘍と乳腺腫瘍を対象に超音波画像データベース構築を開始し，同時にそれらを利用した AI 診断支援システムの開発に取り組んでいる。超音波検査はプローブの操作と読影が同時に要求される検査であり，瞬時の画像認識による診断支援ツールが期待されている。講演では，超音波画像特有の問題の難しさと肝腫瘍の AI 診断システムの開発状況について述べる。

SY1-8 OpenAI と TradeAI

○中田 典生

東京慈恵会医科大学

画像診断 AI の活用は世界的に急速に加速が進んでいる。しかし欧州諸国では、AI 技術はあるが医用画像データが少なく、日本は医用画像があっても、AI 開発が遅れた国もある。画像データを鉱山資源に例えると、日本は膨大な埋蔵資源があるのに、例えば「鉄鉱石を鉄に加工して売る技術」が乏しい後進国の状態である。日本は、「鉄鉱石を鉄に加工する殖産興業と貿易促進」を進めて OpenAI と TradeAI へと変化する必要がある。

SY1-9 臨床診断の立場からの特別発言と総合討論

○縄野 繁

国際医療福祉大学

第 2 日 7 月 25 日 (木)

前半 (口演) : メイン会場 (レセプションホール 1)

後半 : ポスター会場 (会議室 3・4)

一般演題セッション 3

16 : 25 ~ 17 : 55

OP3

「イメージング / 画質改善」

座長 : 伊藤 聡志 (宇都宮大学)

OP3-01 少数方向トモシンセシスにおける正則化項を用いた画像再構成

○堀 拳輔¹, 齊藤 典生², 王 波², 橋本 雄幸¹

¹杏林大学大学院保健学研究科, ²つくばテクノロジー株式会社

トモシンセシスは、制限された角度から得られた投影像を用い、断層像を再構成する技術である。臨床機では、X 線管を機械的に動作させ、60 投影 / 30° の収集を 10 秒程度で行う。一方、現在開発中の装置は 4 投影 / 20° しか収集しないため、1 秒以内の検査が可能であるが、ストリークアーチファクトが出現する。近年、CT や MRI の画像再構成では正則化項を組み込むことにより、スパースな情報からの再構成を可能にしている。本検討では、4 方向トモシンセシスの画像再構成に正則化項を組み込むことでアーチファクトの軽減を試みた。実験は、数値シミュレーションおよび実測データを用い、従来用いてきた Maximum likelihood expectation maximization (ML-EM) 法と、それに正則化を組み込んだ手法との比較検討を行った。ML-EM 法では顕著なストリークアーチファクトが出現したが、Total Variation 正則化を組み込むことで、大幅にアーチファクトを軽減することができ、RMSE も向上した。

OP3-02 超音波造影剤の動態情報を利用した模擬リンパ管の可視化

○齋藤 勝也¹, 吉田 憲司², 大村 眞朗¹, 田村 和輝³, 山口 匡²

¹千葉大学大学院 融合理工学府, ²千葉大学 フロンティア工学センター, ³浜松医科大学 光先端医学教育研究センター

超音波画像診断において検出が困難とされているリンパ管を対象として、従来の生体組織の形態情報に超音波造影剤の動的情報を加えた描出法を提案する。本手法では、造影剤が皮下注射を介してリンパ管内に吸収され、ほぼ静止している状態を想定しており、超音波照射に伴う音響放射力により生じる造影剤の動態をドブラ法により定量する。実験では、皮膚組織の散乱・減衰特性を模擬した散乱体を含む寒天ゲルファントム内に円筒形チャンバを形成することでリンパ管を模擬した。チャンバ内に超音波造影剤 (Sonazoid) の懸濁液を充填し、その上部に設置した単一凹面振動子を方位方向に走査させながら超音波の送受信を行うことで、模擬リンパ管断面の可視化を試みた。提案法を用いることで、形態 (エコー強度) 情報のみでは弁別が困難である場合においても、位相 (動態) 情報を用いることで模擬リンパ管を高コントラストに描出可能であることを確認した。

OP3-03 EM-TV アルゴリズムを用いた少数投影での骨 SPECT 画像再構成の検討

○金澤 道和¹, 笹谷 典太², 細川 翔太³, 渡部 浩司⁴, 湯浅 哲也², 高橋 康幸³, 銭谷 勉¹

¹ 弘前大学大学院理工学研究科, ² 山形大学大学院理工学研究科, ³ 弘前大学大学院保健学研究科, ⁴ 東北大学サイクロトロン・ラジオアイソトープセンター

悪性腫瘍の骨転移などの骨に関する画像診断において, SPECT 装置を用いる骨 SPECT 検査は, 2次元骨シンチグラフィでは解剖学的な位置関係の把握が困難な胸部や骨盤などの部位について有用となる。しかし, 患者への負担などの様々な要因により撮像時間の短縮が望まれている。そこで本研究では, 統計的逐次近似再構成法である ML-EM 法と圧縮センシングを組み合わせた EM-TV アルゴリズムでの画像再構成法を骨 SPECT へ応用し, 少数投影での骨 SPECT 画像再構成を検討した。EM-TV アルゴリズムによる画像再構成は, 観測データにおける統計的な尤度に関する更新と画像のトータルバリエーション(TV)に基づく正則化を交互に行うことにより実現する。少数投影の骨 SPECT 投影データについて EM-TV アルゴリズムでの画像再構成を行い, 従来法として ML-EM 法との比較を行ったところ, アーチファクトおよび定量性を大きく改善することができた。これより, EM-TV アルゴリズムを用いた骨 SPECT における少数投影での画像再構成の可能性が示唆された。

OP3-04 頭部専用 PET における放射能・減弱補正係数同時推定法の深層学習を用いた精度向上手法の検討

○呉 博文¹, 田島 英朗², 山谷 泰賀², 小尾 高史¹

¹ 東京工業大学, ² 量子科学技術研究開発機構 放射線医学総合研究所

高齢化社会の進展により, 認知症患者の増加が大きな問題となっているが, 陽電子放出型断層撮像装置 (PET) はアルツハイマー型認知症の原因物質である特定のタンパク質の蓄積状況を画像として測定することが可能であることから, 認知症の早期発見を目的とした検診での利用への期待が高まっている。しかし, 現在開発を進めている頭部専用 PET は, コンパクトな筐体を目指した PET 専用機であり, 吸収補正を行うための機構がないため, 良好な画質の PET 画像を得るためには, 別途撮影した CT や MRI などを位置合わせして補正用のデータを生成する必要がある。これに対して, 本研究では, 頭部専用 PET の測定のみから診断に十分な画質を得るために, PET 画像再構成に必要な吸収補正画像を同時推定する手法と深層学習を利用した画像補正手法を組み合わせた再構成手法を提案し, 計算機シミュレーションにより, その有効性を示した。

OP3-05 膵臓腫瘍病理顕微鏡画像の染色変換

○足立 秀雄¹, クグレマウリシオ¹, 岩本 千佳², 大内田研宙², 橋爪 誠², 横田 達也¹, 本谷 秀堅¹

¹ 名古屋工業大学, ² 九州大学

本研究の目的は膵臓癌病理画像の3次元多チャンネル画像を生成することである。本発表では病理画像の染色変換について報告する。空間的に連続する病理切片の顕微鏡画像より3次元画像を再構成する。すべての切片を HE など単一の染色で染めれば, その染色の3次元病理画像を得ることができる。この3次元病理画像は生体のミクロな3次元解剖構造を観察する上で有用である。ただし, 観察できる構造は病理切片を染める染色液に依存して変化するが, 単一の切片は単一の染色でしか染めることが出来ない。このため, 同一の生体標本を異なる染色で染めたときに得られるであろう複数の3次元病理画像を同時に観察することは, 実現できれば解剖構造の理解にとって有用であるにも関わらず容易ではない。そこで, (1) 連続する切片を異なる染色で染めることにより様々な染色病理画像を獲得し, (2) それら病理画像を用い染色変換を行う Neural Network を構築する手法を提案する。

OP3-06 MR エラストグラフィによる内包ファントムの粘弾性分布の評価

○菅 幹生^{1,2}, 石井 孝樹¹, 岸本 理和², 小島 隆行²

¹ 千葉大学, ² 量子科学技術研究開発機構 放射線医学総合研究所

Magnetic resonance imaging (MRI) を利用して, 生体内の粘弾性率を非侵襲的に評価する手法として magnetic resonance elastography (MRE) がある。MRE は外部加振装置により撮像対象内部に発生させた弾性波を MRI で画像化し, 弾性波画像から逆問題を解くことで粘弾性率を推定する。本研究では生体組織の粘弾性率と周波数特性を模擬した内包ファントムを使用し, MR エラストグラフィによる内包領域の検出可能な撮像条件を検討することを目的とした。硬さの異なる内包領域を有するファントムを用いた実験結果より, 小領域の検出には小領域内に半波長以上の弾性波が伝播し, 弾性波の波長が 4 pixel 以上となる条件を満たす必要があると考えられた。

OP3-07 Generative Adversarial Frameworks を用いた腹部 CT 像における非造影像からの造影像の推定

○小田 昌宏¹, 隈丸加奈子², 青木 茂樹², 森 健策^{1,3}

¹ 名古屋大学大学院情報学研究科, ² 順天堂大学医学部放射線医学講座, ³ 国立情報学研究所医療ビッグデータ研究センター

本稿では, 深層学習を用いて腹部領域の非造影 CT 像から造影 CT 像を推定する方法について述べる。診断及び治療時における血管を含む解剖構造や異常の確認を目的として, 血管造影下での CT 像撮影が広く行われている。しかし造影剤の影響で呼吸困難や心停止といった重大な合併症を引き起こす場合が存在し, 患者によって造影剤が使用できないことがある。本稿では深層学習による画像処理を用いて, 腹部 CT 像の非造影像から造影像を推定する方法を提案する。Fully convolutional network (FCN) を用いた学習データの直接的学習, generative adversarial framework における FCN の間接的学習等を用い, 非造影から造影像への変換ネットワーク構築を行う。腹部 CT 像における推定実験を行ったところ, 血管等が強調された造影 CT 像に近い画像を推定可能であった。

OP3-08 マルチチャンネル化処理と CNN を用いた嚥下時 X 線透視動画における頸椎椎間板の抽出

○藤中 彩乃¹, 目片幸二郎², 滝沢 穂高³, 工藤 博幸³

¹筑波大学大学院, ²神戸赤十字病院, ³筑波大学システム情報系

嚥下時の頸部動態解析において、頸椎椎間板の同定は嚥下障害の原因疾患の病態理解のために重要である。本報告では、嚥下時 X 線透視動画 (Videofluorography, VF) から CNN を用いて椎間板を自動抽出する手法を提案する。X 線透視動画の各フレームは濃淡画像である。その濃淡画像に濃度正規化、トップハット変換、ソーベルフィルタ、Local Binary Pattern 処理をそれぞれ適用して 4 つの中間画像を生成する。それらの中間画像から 3 つの画像を選択し、RGB の各チャンネルに保存した 1 つのカラー画像を生成する。このカラー画像にパッチベースの CNN を適用し、椎間板候補領域を抽出する。小領域削除などの後処理を適用し、椎間板領域を抽出する。中間画像の組み合わせの中から最適なものを選択する。実際の X 線透視動画に本手法を適用した結果を示す。

OP3-09 CT におけるアトラス誘導による肝抽出に関する比較研究

○王 進科^{1,2}, 程 遠志³, 田村 進一⁴, 富山 憲幸¹

¹大阪大学大学院医学系研究科放射線統合医学, ²ハルビン理工大学ソフトウェア工学部, ³ハルビン工業大学コンピュータ科学技術学部, ⁴株式会社 NBL 研究所

Atlas-guided approaches have shown good prospects on automatic medical image segmentation, in which probabilistic atlas (PA) and multi-atlas segmentation (MAS) have become the most popular models. This paper provides a comparative study between PA and MAS on liver segmentation in CT. For PA, a single atlas is built for spatial correspondence purpose, via co-registrations of all the training images, and segmentation is implemented by registering the resulting atlas to the target image. For MAS, no atlas building process is needed. Each pairwise registration between the target image and the training atlas is performed, followed by propagating all the atlas labels to the target coordinate, the segmentation result is then achieved. In the experiments, a set of 30 abdominal CT images from cooperative hospital was used, and comparative results showed distinct superiorities of the two atlas-guided models on liver segmentation.

OP3-10 屈折コントラスト X 線 CT を用いた乳頭組織の 3 次元可視化および解析

○砂口 尚輝¹, 島雄 大介², 市原 周³, 西村理恵子³, 渡邊 彩¹, 丹羽輝久子¹, 黄 卓然¹, 湯浅 哲也⁴, 安藤 正海⁵

¹名古屋大学, ²北海道科学大学, ³名古屋医療センター, ⁴山形大学, ⁵総合科学研究機構

非浸潤性乳管癌 (DCIS) は癌細胞が乳管内に留まって増殖し、乳管に沿って進展する特徴を持つ。DCIS が乳管から周囲の結合組織へ浸潤すると、浸潤性乳癌となり、リンパ管や血管に進入する可能性が出てくる。浸潤のない、純粋な DCIS は、癌細胞が乳管内に存在するため、手術により DCIS を完全に除去し、DCIS を残さなければ完治する。DCIS の標準的な治療としては、一般的には乳房全摘出か温存術が行われる。乳房全摘を行うとしても、術前に乳頭部の DCIS の有無が分かれば外観を維持した乳頭温存術が可能になるが、現在の臨床画像 (マンモグラフィ、超音波、MRI) では、乳頭内の DCIS の有無を術前に判定することは困難である。乳管は、いくつかの葉 (セグメント) に分かれているが、これらを集約する主乳管が集合する乳頭の詳細な解剖学的構造は、主乳管同士の吻合の有無など不明な点が多い。

本研究では、染色なしで組織標本と同等のコントラストと約 10 μ m の空間分解能により生体組織の 3 次元構造を可視化できる X 線暗視野法による屈折コントラスト CT を用いて、乳頭内の乳管構造を詳細に解析する。具体的には、53 症例の乳頭から乳管数、乳管面積、乳管断面形状などを調査する。また、本研究で乳頭内の乳管同士が吻合する様子が多数確認されており、詳細について報告する。

OP3-11 深層学習による超音波画像からの肝腫瘍検出に関する初期的検討

○堤 一晴¹, 中島 崇博¹, 道満 恵介¹, 目加田慶人¹, 西田直生志², 工藤 正俊²

¹中京大学 工学部, ²近畿大学 医学部

本研究では、腹部超音波画像を対象として深層学習による肝腫瘍検出の初期的検討結果について報告する。腹部超音波における検査水準は実施者の経験に影響され、その均てん化にはコンピュータ支援診断が期待されている。本報告では、肝細胞がん領域とそれ以外の領域を分類する畳み込みニューラルネットワークによる肝腫瘍領域検出について述べる。学習データとして、肝細胞がん領域 61 例にデータ増強を施したものと非腫瘍領域をそれぞれ用いて CNN の学習をし、学習に利用しなかったデータによる評価をおこなった。実験の結果、腫瘍の領域を正しく検出できているが、腫瘍以外の領域を過検出する傾向が見られた。今後、学習データを追加することで検出精度の改善を試みる。

OP3-12 腹腔鏡動画からの Fully Convolutional Network による血管領域抽出

○盛満慎太郎¹, 小澤 卓也¹, 北坂 孝幸², 林 雄一郎¹, 小田 昌宏¹, 伊藤 雅昭³, 竹下 修由³, 三澤 一成⁴, 森 健策^{1,5,6}

¹名古屋大学大学院情報学研究科, ²愛知工業大学情報科学部, ³国立がん研究センター東病院, ⁴愛知県がんセンター, ⁵名古屋大学情報基盤センター, ⁶国立情報学研究所医療ビッグデータ研究センター

本稿では内視鏡動画からの血管領域の自動抽出手法について述べる。腹腔鏡手術は難易度の高い手術であるため、腹腔鏡などで撮影した動画の自動解析による手術支援システムの開発が進められている。動画からの術具や臓器の自動認識は、コンピュータに手術工程を理解させ、術者の手技を適切に支援させることにつながる。手術工程の理解において、体内構造を表す血管の抽出は重要である。しかし、血管は手術中の把持や切断などにより形が変化するため、単純な処理で抽出することは困難である。そこで本研究では、深層学習を用いることにより、腹腔鏡動画から血管領域を自動的に認識する手法の初期検討を行った。モデルには2D U-netを用い、動画中の各フレーム画像に対応する血管領域ラベルを手動で作成し、学習を行った。実験の結果から、腹腔鏡手術動画からの血管領域の抽出が可能であることが確認された。

OP3-13 非接触型微小循環観察環境の構築と敗血症モデルラットの血行動態解析

○川崎 真未¹, 中野 和也², 大西 峻², 羽石 秀昭²

¹千葉大学大学院融合理工学府基幹工学専攻医工学コース, ²千葉大学フロンティア医工学センター

敗血症は感染症に起因して発症し、生命に危機を及ぼす臓器障害である。発症初期には100 μ m以下の血管径である微小循環が障害される。よって敗血症に対する薬効の調査では、微小循環の変化を観察することが重要となる。先行研究では、生体の微小循環を観察可能なSidestream Dark-Field (SDF) 撮影法を用い、敗血症モデルラットの血流速度低下を確認した。しかしSDF撮影法は装置を組織に接触させる必要があり、組織圧迫の影響や衛生面で懸念がある。そこで本発表では、非接触型撮影装置を構築し、敗血症モデルラットの微小循環の観察及び血流速度解析を行った。非接触型撮影装置による取得動画から敗血症モデルラットの血流や血管密度の減少が確認された。また血流速度を算出した結果、健常ラットの血流速度は減少しなかったのに対して敗血症モデルラットの血流速度は減少傾向が確認された。これらの結果から、非接触型撮影装置により微小循環の変化を取得可能であることが示唆された。

OP3-14 手術の多視点動画撮影および画像認識による自動視点切替表示

○梶田 大樹¹, 大石 圭², 高詰 佳史³, 斎藤 英雄², 杉本 麻樹²

¹慶應義塾大学医学部 形成外科, ²慶應義塾大学大学院 理工学研究科, ³慶應義塾大学医学部 解剖学教室

手術の動画撮影の有用性は以前から認識されており、多くの手術室には天井式の術野カメラが設置されている。しかし、従来は外科医の頭部や体によって術野が隠れてしまう問題があった。

そこで我々は、无影灯の光源に対応して複数のカメラを設置し、術野が明るい限りは少なくとも1台のカメラからは、術野の映像が記録可能な「マルチカメラ搭載型无影灯」を試作した。

ただし、同時に多数の映像を見るのは大変であるので、術野が良好に映っている映像を画像認識によって識別し、自動的に映像を切り替える手法を作成した。術野は、人体の色やテクスチャの情報からセグメンテーションを行う機械学習の手法によって認識し、この領域が大きい映像を選択して表示させた。これにより、カメラが自動で切り替わりながら、常に術野を視認できる術野映像の表示が可能となった。

本技術によって、あらゆる場面における術野映像の活用が促進されることが期待される。

OP3-15 覚醒下脳腫瘍摘出術における術中情報を用いた脳機能マッピング工程同定手法の提案

○佐藤 生馬¹, 南部 優太¹, 藤野 雄一¹, 堀瀬 友貴², 楠田 佳緒², 田村 学², 村垣 善浩², 正宗 賢²

¹公立はこだて未来大学大学院 システム情報科学研究科, ²東京女子医科大学 先端生命医学研究所

脳腫瘍摘出手術において、熟練医は最大限の腫瘍摘出と最小限の術後合併症リスクを実現するため、患者の脳構造や機能を把握し、独自の判断プロセスにより腫瘍を切除する。この判断プロセスは、熟練医が培った知識や経験にもとづく暗黙知とされており、医療の質の向上や若手医師教育のために可視化が望まれている。本研究では、覚醒下脳腫瘍摘出術において患者毎に異なる腫瘍付近の脳機能を把握する脳機能マッピング時の暗黙知の可視化に向け、術中情報を用いた脳機能マッピング工程同定手法を提案する。本提案手法では、術中MRIやナビゲーションシステムからの位置情報および顕微鏡などからの動画より特徴量を抽出し、これらの特徴量を用いて2階層からなる階層型隠れマルコフモデルより、手術の流れと脳機能マッピング時の工程を可視化する。そして、過去の臨床データを用いて、本手法により手術工程を同定し、その精度を評価したので報告する。

OP3-16 GAN を用いた病理組織画像における異常組織の自動同定法

○林 大誠¹, 中山 良平¹, 檜作 彰良¹, 黒住 眞史², 真鍋 俊明²

¹立命館大学理工学部, ²滋賀県立総合病院研究所

本研究の目的は、異常組織の病理組織型を推定する診断システム開発の前段階として、アノテーションが不必要な腫瘍を含まない病理組織像のみを、人工知能の一つである GAN (Generative Adversarial Nets) に学習させることで、病理組織像から異常組織を自動同定するアルゴリズムを開発することである。実験試料は、HE 染色された腫瘍を含む病理組織像、腫瘍を含まない病理組織像を 20 倍率でデジタル化した画像を用いた。GAN の学習では、学習用の腫瘍を含まない病理組織像から抽出した関心領域を GAN に入力することにより、正常組織構造をネットワークに学習させた。そして、学習済みネットワークを用いて、正常組織構造とは異なる構造を有すると評価された関心領域を異常組織として同定した。学習した GAN を評価用画像データの関心領域に適用した結果、正答率 91.6% が得られ、提案手法の有効性が示唆された。

OP3-17 3 次元 CT 画像を用いたじん肺の重症度診断支援システム

○森 奈々¹, 日野 公貴¹, 松廣 幹雄², 鈴木 秀宣², 河田 佳樹², 仁木 登², 加藤 勝也³, 岸本 卓巳⁴, 芦澤 和人⁵

¹徳島大学大学院 先端技術科学教育部, ²徳島大学大学院 社会産業理工学研究部, ³川崎医科大学, ⁴岡山ろうさい病院, ⁵長崎大学

じん肺は、粉じんを肺に吸入することによって生じる職業性呼吸器疾患である。日本では毎年 24 万人前後の粉じん作業従事労働者がじん肺健康診断を受診している。近年では歯科技工じん肺など新たな症例が発生しており、粉じん労働者数は増加傾向となっている。

じん肺健康診断では胸部単純 X 線写真を用いて診断され、第 0 型、第 1 型、第 2 型、第 3 型、第 4 型に分類される。ここで、第 1 型以上の患者は労災認定となるが第 0 型の患者は労災認定の対象とならないため正確に診断しなければならない。また、CT 画像は胸部単純 X 線写真に比べて第 1 型の微小な病変を検出することができるため、胸部 CT 検査による診断法が検討されている。

本報告では、3 次元じん肺 CT 画像からマニュアル処理によって粒状影を抽出し、じん肺 CT 画像データベースを作成する。このデータベースを用いて X 線写真の診断結果と粒状影の個数・大きさを重症度別に解析・比較・評価・診断支援システムの開発を行う。

OP3-18 Generative adversarial network を用いた肺結節の 3 次元 CT 画像の生成

○西尾 瑞穂^{1,2}, 野口峻二郎³, 尾上 宏治², 子安 翔², 八上 全弘^{1,2}, 村松千左子⁴, 藤田 広志⁴, 富樫かおり²

¹京都大学附属病院 先制医療・生活習慣病研究センター, ²京都大学大学院医学研究科 放射線医学講座 (画像診断学・核医学), ³大阪赤十字病院 放射線診断科, ⁴岐阜大学工学部電気電子・情報工学科

目的

GAN による肺結節の 3 次元 CT 画像の生成を行い、放射線科医による評価を行った。

方法

LUNA16 のデータセットの 888 セットの 3 次元 CT 画像、1415 個の肺結節を用いた。肺結節に対し 40x40x40 voxels の VOI をセットして、CT 画像を切り出し、その CT 値を 1000 で除算して正規化を行った。改変した 3 次元 Resnet を generator、改変した 3 次元 VGG を discriminator とし、GAN を構成した。トレーニングには 1281 個、テストには 134 個の肺結節を利用し、L1 loss と GAN loss を混合したものを最適化のためのロスとした。学習時には random erasing をベースにした data augmentation を行った。テスト用の 134 個の肺結節につき、ランダムに真の肺結節と生成された肺結節を提示し、二名の放射線科医が評価した。放射線科医には真の肺結節である確信度を入力させ、それを用いて ROC 解析による Area under the curve (AUC) を計算した。

結果

放射線科医の AUC は 0.717 と 0.814 であった。正診率は 71.6% と 81.3%、感度は 71.0% と 78.3%、特異度は 72.3% と 84.6% であった。

考察

GAN によって、放射線科医による真偽の判断が難しい肺結節の 3 次元 CT 画像の肺結節を生成できる可能性が示された。

OP3-19 眼底画像における OCT 検査結果を用いた CNN による網膜神経線維層欠損解析

○渡邊 颯友¹, 村松千左子^{2,3}, 周 向榮^{2,3}, 畑中 裕司⁴, 原 武史^{2,3}, 藤田 広志^{2,3}

¹ 岐阜大学大学院自然科学技術研究科知能理工学専攻, ² 岐阜大学工学部電気電子情報工学科, ³ 岐阜大学大学院医学系研究科知能イメージ情報分野, ⁴ 滋賀県立大学工学部電子システム工学科

緑内障は日本における中途失明原因の第1位とされており, 40歳以上の20人に1人が緑内障と推定されている。しかし, 早期の緑内障は自覚症状が非常に少ないため, 早期発見のためには定期検査が必要である。定期検査の中でも特に眼底検査では, 緑内障診断の指標の一つとして網膜神経線維層欠損(NFLD)の有無を調べる。また, OCT検査は精密検査であり, 網膜神経線維層の厚みを定量する。しかし, 定期検査においては一般的にOCT検査ではなく眼底検査が行われる。そこで, 我々は同時期に得られた眼底画像とOCT検査結果をそれぞれ学習データ, 教師データとして全畳み込みニューラルネットワークの学習を行い, 眼底画像単体からNFLDを検出するコンピュータ支援診断システムを構築した。評価方法は, 視神経乳頭中心部から眼底画像を8方向に分割し, 各領域のNFLDの一致率を調べた。結果として, 眼底画像単体からOCT検査結果を用いてNFLDを解析することに成功した。

OP3-20 小児腸閉塞患者のCT像におけるCycleGANを用いた電子洗浄手法の検討

○西尾 光平¹, 小田 紘久¹, 千馬 耕亮², 北坂 孝幸³, 伊東 隼人¹, 小田 昌宏¹, 檜 顕成², 内田 広夫², 森 健策^{1,4,5}

¹ 名古屋大学大学院情報学研究科, ² 名古屋大学大学院医学系研究科, ³ 愛知工業大学情報科学部, ⁴ 名古屋大学情報基盤センター, ⁵ 国立情報学研究所 医療ビッグデータ研究センター

本研究では, 血管造影された小児腸閉塞患者のCT像におけるCycleGANを用いた電子洗浄手法の検討について報告する。これまでの腸管閉塞部位検出手法は, 腹水等と濃度値の差が小さい残渣が含まれていることから精度が低下する問題があった。そこで, 電子的に腸管内を洗浄し, 残渣が含まれていないCT像を生成することで腸管閉塞部位検出精度向上を目指す。しかし, 多くの電子洗浄手法は残渣が造影されたCT像に対する手法であり, 小児腸閉塞患者のCT像に適用することが困難である。そこで, 本研究ではCycleGANを用いた電子洗浄手法について検討する。残渣の多い小児腸閉塞患者のCT像と残渣の少ない大腸CT検査画像を学習データとして, CycleGANによる双方向それぞれの画像生成モデルを学習する。その後, 残渣の多い画像から残渣の少ない画像への生成モデルを小児腸閉塞患者のCT像に適用する。実験の結果, 小児腸閉塞患者のCT像から残渣の少ない良好なCT像を得ることができた。

OP3-21 低線量CT画像に基づいた骨ミネラル量の推定法

○山田 凌大¹, 石原 匡彦², 原 武史¹, 周 向榮¹, 片渕 哲朗³, 藤田 広志¹

¹ 岐阜大学大学院自然科学技術研究科知能理工学専攻, ² 岐阜大学医学部附属病院放射線部, ³ 岐阜医療科学大学保健科学部

核医学画像の定量解析の中で, 骨に集積する放射性薬剤のSUVの計算では, 全身の骨ミネラル量の測定が重要である。本研究は, 低線量CT画像を用いた骨ミネラル量の推定法の開発を目的とした。等方化したCT画像に閾値処理や空間フィルタを利用し, 骨格抽出を行う。骨格のMIP画像を基に骨面積を定める。骨面積に骨密度を乗じた値を骨ミネラル量の推定値とする。日本人健康者2411人に対し行われた体組成計測におけるDXAの測定データにより, 全身の骨ミネラル量の回帰式が定められている。この回帰式から算出される症例の全身の骨ミネラル量と, 123症例のCT画像に基づき推定した胸部骨ミネラル量の相関係数は0.88であった。また, 骨格を解剖学的構造に基づき, 大腿骨, 骨盤(寛骨, 仙骨・尾骨), 脊柱, 頭蓋骨, 腕部骨に自動分類し, 部位ごとの骨ミネラル量の推定も可能である。以上より, CT画像に基づく骨ミネラル量の定量解析の有用性が示唆された。

OP3-22 胸部CT像中の肺結節の良悪性鑑別における自動抽出された画像特徴の可視化

○平島 翔¹, 平野 靖¹, 木戸 尚治¹, 岩野 信吾², 本田 健³, 関 順彦³

¹ 山口大学大学院創成科学研究科, ² 名古屋大学大学院医学系研究科, ³ 帝京大学医学部附属病院

肺結節はCT像上に高CT値の陰影として写し出され, 医師は肺結節やその周辺の画像所見を基に肺結節の良悪性を判断する。また, 近年ではDeep Learningを用いたCADx(Computer-Aided Diagnosis)システムの研究が行われており, 従来の手法に比べて高い性能を示すことが報告されている。しかし, Deep Learningの判断過程は解釈が難しい。

本研究ではDeep Learningで構築されたCADxシステムの判断結果の根拠を明示的にするために, Deep Learningが抽出した画像特徴の可視化を目的とする。具体的には, 肺結節周辺の3次元画像を用いてCNN(Convolutional Neural Network)の学習と識別を行い, Guided Grad-CAM(Guided Gradient-weighted Class Activation Mapping)を用いてCNNの抽出した画像特徴を可視化した。

OP3-23 CT 画像を用いた脊柱海綿骨内の骨密度定量化

○李 新¹, 光本 浩士¹, 平野 雅嗣², 山崎 克人³, 田村 進一⁴

¹大阪電気通信大学大学院, ²新居浜工業高等専門学校, ³栄宏会小野病院, ⁴(株)NBL 研究所

近年, 高齢化に伴い, 骨粗鬆症患者が年々増加している. その影響により医師による CT 像の読影が膨大化し多大な時間と労力が必要になり見落としが危惧されている. このため, 骨粗鬆症患者の CT 画像を対象としたコンピュータ支援システムの開発がなされ骨密度の計測が報告されている. 先行研究のシステムにおいて, 骨密度の計測は, 脊柱スライスデータ内の椎体を囲む矩形を求め, その各辺の 1/3 の長さを持つ楕円形の ROI 内の平均 CT 値を骨密度としている. また, Snakes 手法を用い海綿骨を抽出し骨密度を計測する研究もあるが, Snakes 手法には初期値の設定が必要である.

本稿では抽出した脊柱の各スライスに対し, 海綿骨と皮質骨の境界を検出し海綿骨領域のデータ値を用いた CT 値の平均を求める. その結果, 骨密度の脊柱に沿った変化, 椎骨ごとの変化を計測することができた

OP3-24 二段階分類による胸部 X 線画像を用いた異常部位検出システムの検討

○堂園 貴弘¹, 吉村裕一郎², 田中久美子³, エズムトルスン², 中田 孝明³, 織田 成人³, 中口 俊哉²

¹千葉大学 大学院 融合理工学府 基幹工学専攻 医工学コース, ²千葉大学 フロンティア医工学センター, ³千葉大学 大学院医学研究院 救急集中治療医学

集中治療室における移動困難な重症患者の経過観察のため X 線ポータブル撮影が用いられる. しかし, 座位や仰臥位などの様々な体位での撮影となるため, 通常時と臓器状態に差異が生じることで読影困難となり, 読影精度の低下が課題となっている. そこで本研究では胸部 X 線ポータブル画像からの肺疾患の診断能を向上するため深層学習の適用を試みた. 提案システムは, まず無気肺と肺炎を 1 クラスとして, 異常なし, 胸水の 3 クラスで分類後, 無気肺または肺炎と分類された画像を 2 クラス分類する 2 段階分類を行う. 評価実験に千葉大学医学部附属病院で収集されたデータと米国立衛生研究所のオープンデータの 2 種類を用いた. その際, 左右反転と 7 度回転処理を行い, データ数を 14 倍に拡張, 評価方法に 3 分割交差検証法を用いた. 実験の結果, 提案する 2 段階分類手法は 4 クラス同時分類時よりもモデル全体の分類精度が向上し, 有効性が示唆された.

一般演題セッション4

9:00~10:30 OP4

「イメージング/画質改善」

座長:山谷 泰賀

(量子科学技術研究開発機構 放射線医学総合研究所)

OP4-01 ブロックマッチング5Dフィルターを用いたダイナミックPETスキャンのための画像ノイズ除去

○大手 希望¹, 橋本二三生¹, 垣本 晃宏¹, 磯部 卓志¹, 犬伏 知生¹, 得居 葵¹, 吉川 悦次¹, 大村 知秀¹, 尾内 康臣²

¹浜松ホトニクス株式会社 中央研究所, ²浜松医科大学 生体機能イメージング研究室

PETリガンドの取込みの定量には、PET検査において連続的なスキャン計画が必要となる。しかし、連続的なPET(ダイナミックPET)画像は、データ収集が複数の短時間フレームよりなるため、ノイジーになりやすい。この欠点を克服するため、ダイナミックPETスキャンのための新しいエッジ保存型平滑化フィルターによる画像復元法を開発した。既に3D医用画像のノイズ除去のためにブロックマッチング4Dフィルター(BM4D)が提案されている。そこで、ワンショットのBM4Dを、連続的な画像をまとめて処理するBM5Dに拡張した。ピーク信号対雑音比、構造化類似度を指標として、数値シミュレーションにより性能を評価した。加えて、臨床条件での被検者データ1例により画質を評価した。結論として、ダイナミックPET画像のノイズ除去においてBM5Dは、BM4D、ガウシアンフィルターより、定量的・定性的に比較的高い性能を示した。

OP4-02 μ CTを用いた改良版Cycle-GANによる臨床用CT像の超解像処理

○鄭 通¹, 小田 紘久², 守谷 享泰¹, 杉野 貴明¹, 中村 彰太³, 小田 昌弘¹, 森 雅樹⁴, 高島 博嗣⁵, 名取 博⁶, 森 健策^{1,7,8}

¹名古屋大学大学院情報学研究所, ²名古屋大学大学院情報科学研究科, ³名古屋大学大学院医学系研究科, ⁴札幌厚生病院, ⁵札幌南三条病院, ⁶恵和会西岡病院, ⁷国立情報学研究所医療ビッグデータ研究センター, ⁸名古屋大学情報連携統括本部情報戦略室

This paper presents a novel super-resolution method with unpaired training dataset of clinical CT and micro CT volumes. For obtaining very detailed information such as cancer invasion from pre-operative clinical CT volumes of lung cancer patients, super-resolution of clinical CT volumes to μ CT-level is desired. While most super-resolution methods require paired low- and high- resolution images for training, it is infeasible to obtain paired clinical CT and μ CT volumes. We propose a novel training approach based on Cycle-GAN, which does not need paired clinical CT and μ CT volumes. Experimental results demonstrated that our proposed method successfully performed super-resolution of clinical CT into μ CT-level.

OP4-03 視覚情報提示による頭部PET体動抑制手法の開発

○鈴木 海斗¹, 岩男 悠真², 高橋美和子², 山谷 泰賀^{2,3}

¹千葉大学 大学院融合理工学府, ²国立研究開発法人量子科学技術研究開発機構 放射線医学総合研究所, ³千葉大学 フロンティア医工学センター

現在注目されている頭部専用PET装置では、体動による取得画像の劣化を防ぐことが課題の一つとなっている。

従来手法として、バンド等を用いて物理的に被験者を拘束する手法や、画像再構成時に体動を補正する手法があげられる。しかし、被験者への負担増や、既存の装置への組み込みが困難などの理由により多くの課題が残されているのが現状である。そこで、本研究では非拘束かつ撮影システムに依存しない体動抑制法の開発を目的とした検討を行う。具体的には、Kinectを用いて被験者の体動を取得し、体動をリアルタイムに可視化することで被験者自らが体動を抑制できるシステムを開発した。

人間の頭部の体動の特性を分析し、認識が容易な体動の可視化手法についての検討を行うとともに、システムの有効性を複数の被験者を対象としたボランティア試験により検証した。結果として開発システムにより体動の標準偏差が50.1%まで抑制できることを確認した。

OP4-04 静止型 SPECT システムを用いた心筋画像再構成○藤代 鷹平¹, 村田 一心¹, 本村 信篤², 尾川 浩一¹¹法政大学 理工学研究科, ²キヤノンメディカルシステムズ

マルチピンホールコリメータを装着した SPECT システムは、検出器を回転させることなく多方向から検出器へ進入するガンマ線の飛来方向を推定可能であり、静止型 SPECT システムとして使用できる。静止 SPECT システムを用いた心筋画像再構成における問題点は、データ収集角度が一定程度、限定されることと肝臓等の他の臓器による散乱線の影響などである。本研究では、静止型 SPECT におけるこれらの問題を検討するために、モンテカルロ法による光子輸送計算を用い、臨床に近い状態で収集された投影データを作成し、心筋画像の評価を行った。ファントムとしては MCAT ファントムを用い、3 検出器 (11 ピンホール) のジオメトリを想定し、画像再構成には ML-EM 法を用いた。この結果、ピンホール投影データには散乱線が含まれるものの、適正な散乱線除去を実施することで、臨床上使用可能と思われる画像を得ることができた。

OP4-05 マルチ CNN による MRI 画像におけるノイズ低減○金子 幸生¹, 野口 喜実¹, 尾藤 良孝², 荻野 昌宏¹¹株式会社日立製作所 研究開発グループ, ²株式会社日立製作所 ヘルスケアビジネスユニット

MRI (核磁気共鳴撮像装置) は、頭部をはじめ様々な部位の検査に用いられているが、撮像時間が長い点が課題である。近年、撮像時間の短縮に関する研究が進んでおり、画像再構成に対して畳み込みニューラルネットワーク (CNN) を適用する研究が注目されている。本研究では、MRI 撮像の高速化を目指して、少数の計測データから再構成された低画質画像に対するノイズ低減について検討を行った。MRI 装置を用いて通常撮像および撮像時間を 1/2 とした撮像実験を行い、撮像画像データから約 90,000 枚の学習パッチを作成した。学習パッチに含まれる輝度情報の特徴を基にサブセットに分類し、各サブセットに対してネットワークを作成した。撮像時間 1/2 の画像を領域分割し、各領域ごとに最適なネットワークを選択し、画像を出力した。結果、単一 CNN の場合と比べ、本手法では PSNR が約 0.5 dB 向上し、ノイズ低減効果を確認した。

OP4-06 全身撮影が可能な立位 CT の開発：ファントムスタディ、人体に対する重力の影響○横山 陽一¹, 山田 祥岳¹, 名倉 武雄², 中原 健裕¹, 成田 啓一¹, 山田 稔¹, 南島 一也³, 荻原 直道⁴, 陣崎 雅弘¹¹慶應義塾大学医学部放射線科学教室 (診断), ²慶應義塾大学医学部整形外科教室, ³慶應義塾大学病院放射線技術室,⁴慶應義塾大学理工学部機械工学科

[Objective] The purpose of this study was to evaluate the performance of upright CT in a phantom study and the effect of gravity on large vessels and the pelvic floor. [Methods] We compared the physical characteristics in a phantom between upright and supine CT. Asymptomatic volunteers underwent both CT examinations. The area of vena cava and aorta and the changes of pelvic floor were evaluated. [Results] The performance of upright CT was comparable to that of supine CT. In the upright position compared with the supine position, the area of SVC was significantly smaller, the area at the level of the diaphragm was similar, and the area of IVC was significantly larger, while the areas of aortas were not significantly different; the pelvic floor descended in the upright position. [Conclusion] Upright CT was comparable to supine CT in physical characteristics and useful in clarifying the effect of gravity on human body.

OP4-07 GAN を用いた人工股関節全置換術後 CT 画像の金属アーチファクト低減○阪本 充輝¹, 日朝 祐太¹, 大竹 義人¹, 高尾 正樹², 菅野 伸彦², 佐藤 嘉伸¹¹奈良先端科学技術大学院大学先端科学技術研究科, ²大阪大学大学院医学研究科

人工股関節全置換術において、術後 CT 画像の解析は人工股関節設置位置や筋骨格形状の評価に重要な役割を果たす。しかし術後 CT 画像では、金属製のインプラントによって発生するアーチファクトが画像解析の精度を大幅に低下させる要因となる。我々はこれまでに、術前 CT 画像とシミュレーション画像を用いて学習した CNN (Convolutional Neural Network) によるアーチファクト低減を用いて、術後 CT 画像での筋肉セグメンテーション精度を向上させる手法を提案してきた。しかし、学習に用いたシミュレーション画像と実術後 CT 画像には乖離があり、それが実画像でのセグメンテーション誤差の原因であると考えている。そこで本研究では、GAN (Generative Adversarial Network) の一種である pix2pix の拡張によって、シミュレーション画像と術後 CT 画像からの変換結果の分布が近づくような画像変換の学習手法について検討した。

OP4-08 複数の皮膚毛細血管に対する血流速度推定の自動化

○塚本 唯斗¹, 瀧本 麦², 中野 和也³, 大西 峻³, 羽石 秀昭³

¹千葉大学大学院融合理工学府, ²花王株式会社, ³千葉大学フロンティア医工学センター

皮膚毛細血管は、組織の健全性に関わる重要な血管系である。毛細血管のモニタリングにより組織状態の把握が可能となるが、このための定量評価手法は発展途上にある。当研究室では、皮膚毛細血管の定量評価に向け、撮影装置及び血流速度推定手法の開発を進めてきた。しかし、従来手法は血管内の局所的な画素値に着目したオプティカルフローに基づいた手法であるため、体動やノイズの影響を受けやすい問題があった。そこで本研究では、血管内全域の画素値を考慮することで、ノイズや血流動態にロバストな手法構築を行った。被験者3名の前腕部内側の皮膚毛細血管に対して提案手法を適用し、血流速度の推定を行った。提案手法による血流速度推定値の妥当性検証のため、手動追跡及び従来手法で推定した血流速度との比較を行った。その結果、従来手法と比較し推定誤差の低減を確認した。提案手法の有効性が示唆された。

OP4-09 TMS 検査のための脳 MRI 画像からの誘導電流強度の回帰とその推定誤差分散推定

○牧 豊大¹, 酒井 隆志¹, ラークソイルッカ², 宇川 義一³, 村上 丈伸³, 横田 達也¹, 平田 晃正¹, 本谷 秀堅¹

¹名古屋工業大学, ²アールト大学, ³福島県立医科大学

TMS 検査において、脳内に誘発される電流強度を高速に高い精度で推定することは必須である。電流強度を推定するためには VCM (Volume Conductor Modeling) を用いた電磁気学的手法が用いられてきたが、推定に数時間必要で医療の現場では実用的ではない。そこで本研究は、DNN (Deep Neural Network) を用いる高速な電流強度回帰手法を開発した。さらに DNN で推定した電流強度の曖昧性を推定する手法も合わせて提案する。本研究では、頭部 MRI 画像と脳に磁場を与えるコイルの位置と姿勢からそのコイルによって誘発される誘導電流強度を、DNN を用いて回帰する。本研究では、DNN のアーキテクチャとして U-Net を採用する。DNN の推定の誤差を定量化するためにバイズアプローチを用いた手法を用いる。この手法では DNN の信頼度を各ボクセル単位で評価できる。曖昧性の分布から、DNN の推定の信頼度が脳溝とコイルの円の中心で悪くなることが発見できた。しかし医学的に重要なのは皮質であるため、提案法の有効性が確認できた。

OP4-10 開腹手術映像における遮蔽物除去システムの VR 化

○北坂 孝幸¹, 伊藤 幹也¹, 駒形 和哉¹, 三澤 一成², 森 健策³

¹愛知工業大学情報科学部, ²愛知県がんセンター, ³名古屋大学情報連携統括本部

本稿では、開腹手術映像における遮蔽物除去システムの VR 化に関して報告する。

OP4-11 手術器具検出を用いた整形外科手術の工程認識における最適な Data Augmentation の検討

○西尾 祥一¹, ホセインベライアット¹, 八木 直美^{1,2}, 新居 学¹, 平中 崇文³, 小橋 昌司¹

¹兵庫県立大学, ²姫路独協大学, ³高槻病院

整形外科手術は腹腔鏡手術や開腹手術と比較して手術工程及び使用する手術器具が多く、外科手術中に医療器具の受け渡しを行う看護師は大きな負担を強いられている。

私たちの以前の研究では人工関節置換術を対象とした整形外科手術における手術室看護師を支援するためのナビゲーションシステムを提案した。この研究では畳み込みニューラルネットワークを用いて手術画像全体に基づいた画像認識により手術工程の認識を試みたが、実用化に必要なとされる精度には及ばなかった。

本研究では整形外科手術における手術工程の認識精度の改善を実現するために、手術映像から取得したフレーム毎に物体検出 (YOLO) を行い、器具のクラス情報と位置座標を検出する。スマートグラス (眼鏡型のデバイス) を用いて記録した整形外科手術映像は手術間で照明環境や撮影角度が大きく異なっており、それらの影響を低減させるための最適なデータの预处理やデータ拡張法を検討する。

OP4-12 敵対的生成ネットワークによる MRI 脳画像の頭蓋骨除去の提案

○藤山 眞悟¹, 茶山 祐亮¹, 彌富 仁¹, 大石 健一²

¹法政大学理工学研究科応用情報工学専攻, ²ジョンズホプキンス大学医学部放射線科

神経障害の診断のために MRI による撮影が日々行われ、MRI 画像は診断ならび研究に多く用いられている。MRI 画像を用いた研究において、特に自動診断支援、類似症例検索実現のためには MRI 画像から頭蓋骨、皮膚のような非脳組織を取り除く skull-stripping と呼ばれる処理が必要不可欠である。しかし既存の skull-stripping 手法は処理時間、除去精度において問題が存在する。本研究は高速かつ正確な skull-stripping を実現する adversarial generative skull-stripping (AGSS) 法を提案する。AGSS は、deep learning 分野において近年多くの成果を挙げている generative adversarial networks (GANs) を応用し、限られた数の脳抽出データの学習を元に、優れた skull-stripping 画像を生成する。

OP4-13 深層学習を用いた腹腔鏡手術動画像の出血領域自動セグメンテーション

○山本 翔太¹, 小田 紘久¹, 林 雄一郎¹, 北坂 孝幸², 小田 昌宏¹, 伊藤 雅昭³, 竹下 修由³, 森 健策^{1,4,5}

¹名古屋大学大学院情報学研究科, ²愛知工業大学情報科学部, ³国立がん研究センター東病院, ⁴名古屋大学情報基盤センター, ⁵国立情報学研究所医療ビッグデータ研究センター

本稿では、腹腔鏡手術動画像に対して、深層学習を用いた出血領域のセグメンテーションを自動的に行う手法について検討する。出血領域のセグメンテーション結果は、内視鏡手術の安全性を高める研究において利用価値が高い。しかし、手術映像中における出血領域を手動でセグメンテーションするのは困難であるため、効率的にセグメンテーションを行う手法が求められている。本研究では、深層学習を用いた出血領域の自動セグメンテーションを行う。出血領域は画像全体に対して小領域であるため、出血領域を含む局所領域を切り出したデータで学習したモデル（局所モデル）と、広範囲を切り出したデータで学習したモデル（広域モデル）を用意し、広域モデルの推定結果に局所モデルの推定結果を統合することでセグメンテーション結果を得る。実験により、腹腔鏡動画像における微小な出血領域の自動抽出には、局所領域に着目することが有効であるという知見が得られた。

OP4-14 血管仮想操作のための脳血管描画方法の検討

○田中 康太, 篠原 寿広, 中迫 昇

近畿大学大学院生物理工学研究科

現代の日本人の主な死因の1つに脳血管疾患がある。脳血管構造は複雑であるため3次元で可視化する際に死角ができ、手前の血管に隠れる血管は観察しにくい。そこで、著者らは、脳血管をより直感的に観察できるようにすることを目的に、注目する血管を隠す血管を仮想的に操作し、注目する血管を観察できるようにする血管仮想操作を提案している。本稿では、血管仮想操作を実現するための脳血管描画方法を提案する。具体的には、はじめにComputed Tomography Angiography (CTA) 画像から抽出した脳血管をサーフェスレンダリング法で描画する。つぎに、注目血管を隠す血管に対し、同じCTA画像から推定した血管の心線データ、すなわち、血管の心線位置情報、半径情報を用いて、チューブ状の簡易血管描画に切り替え、心線データを操作することによって、血管の仮想操作を実現する。実際のCTA画像から抽出された脳血管および推定した血管の心線データを用いて、本描画手法の有効性の一端を確認した。

OP4-15 転移学習を用いた腹部 thick-slice CT 像における多臓器領域の自動抽出の初期検討

○申 忱¹, ロスホルガー¹, 林 雄一郎¹, 小田 紘久¹, 小田 昌宏¹, 三澤 一成², 森 健策^{1,3}

¹名古屋大学大学院情報学研究科, ²愛知県がんセンター中央病院, ³国立情報学研究所医療ビッグデータ研究センター

本稿では、転移学習を用いた腹部 thick-slice CT 像における多臓器領域の自動抽出に関して検討する。臓器領域の自動抽出は医用画像処理において重要な役割を果たしている。近年、スライス厚が0.5mm程度のthin-slice CT像を用いた臓器領域の自動抽出が多く行われているが、スライス厚が5mm程度のthick-slice CT像も医用現場において多く利用されている。そのため、スライス厚が厚いCT像においても臓器領域の自動抽出ができれば有用である。しかし、CT像の体軸方向の解像度が低い場合、従来の3次元fully convolutional networks (FCNs)を用いたthick-slice CT像における臓器領域の自動抽出手法をそのまま適用することは困難である。本研究では、thin-slice CT像の学習済みモデルを用いて転移学習を行うことにより、thick-slice CT像における腹部多臓器の自動抽出を行う。実験により、thick-slice CT像からも腹部多臓器を抽出することが可能であることを確認した。

OP4-16 歯科的個人識別のための Relation Networks for Object Detection を用いた歯科用 Cone-beam CT における歯牙の検出

○杵名 将太¹, 村松千左子², 林 達郎³, 周 向榮², 西山 航⁴, 有地 淑子⁵, 原 武史², 勝又 明敏⁴, 有地榮一郎⁵, 藤田 広志²

¹岐阜大学大学院自然科学技術研究科知能理工学専攻知能情報学領域, ²岐阜大学工学部電気電子・情報工学科情報コース, ³メディア株式会社, ⁴朝日大学歯学部口腔病態医療学講座放射線学分野, ⁵愛知学院大学歯学部歯科放射線学講座

地震や津波などの大災害時には、多数の身元不明の遺体が生じる。その身元確認のために歯科情報が用いられることがあり、歯科的個人識別と呼ぶ。歯科的個人識別にはデンタルチャートと呼ばれる用紙に遺体の口腔内の所見を記録する必要があるが、一般の歯科医師も記録に協力する際、遺体を対象とした記録の経験に乏しいため、記録ミスや精神的負担が危惧される。そのためX線写真から自動的にデンタルチャートの作成に必要な情報を取得する手法の開発が望まれている。本研究では、歯科用Cone-beam CTを対象とし、情報の取得の前段階として画像上の歯牙領域を検出する。検出ネットワークとしてRelation Networks for Object Detectionを使用する。オブジェクト同士の関係性を学習できるとされ、歯列の順序が歯種を判別する際の大きな要素であるため、本研究に有効であると考えられる。ひとつの症例に対し、CTスライスにおける検出ネットワークからの検出結果を統合することにより検出率の向上を図る。

OP4-17 時間-周波数解析と CNN を用いた呼吸音の自動分類手法の開発

○南 弘毅¹, 陸 慧敏¹, 金 亨燮¹, 間普 真吾², 平野 靖², 木戸 尚治²
¹九州工業大学, ²山口大学

呼吸器疾患の診断方法として、聴診器を用いた呼吸音の聴診が簡便で安全な診断方法として長年用いられてきた。一方、聴診音の診断には定量的な評価基準がないため、医師の診断支援を行うシステムの開発が必要である。そこで本論文では、畳み込みニューラルネットワーク（CNN：Convolutional Neural Network）を用いた呼吸音の自動分類手法の提案を行う。主な手法の流れとしては、呼吸音データに対して短時間フーリエ変換と連続ウェーブレット変換を適用し、スペクトログラム画像およびスカログラム画像を生成する。その後、生成した画像を用いて CNN による正常呼吸音、連続性ラ音、断続性ラ音の識別を行う。提案手法を呼吸音データ 22 症例に適用した結果、Accuracy=79.44[%], AUC=0.942 を得た。

OP4-18 HE 染色標本画像と診断テキストデータを併用する免疫染色パターン推定

○橋本 典明¹, 横田 達也¹, 中黒 巨人², 高野 桂², 中村 栄男², 竹内 一郎^{1,3,4}, 本谷 秀堅¹
¹名古屋工業大学, ²名古屋大学医学部附属病院, ³理化学研究所, ⁴物質・材料研究機構

悪性リンパ腫は血液細胞に由来するがんで、白血球の 1 種であるリンパ球ががん化した病気である。これらの病気は多くのサブタイプに細分され、病理診断ではヘマトキシリン・エオジン (HE) 染色標本を観察したのち複数の免疫染色標本を観察することで最終的な病名の決定が行われる。病理画像解析技術を用いた悪性リンパ腫の診断支援応用として HE 染色標本画像からのサブタイプ分類などが考えられるが、実際の診断においてもサブタイプ分類には複数の免疫染色の施行が必要であることから、HE 染色標本画像からの病名の同定は困難であることが予想される。本研究では、病理診断テキストデータが持つ免疫染色情報を解析し、HE 染色画像と組み合わせることにより、各症例の HE 染色標本画像に対するサブタイプの候補群を推定し、病気を一意に決定するための免疫染色の組み合わせを求める手法を提案する。

OP4-19 舌の表面特徴に基づく機械学習を用いた舌苔分布推定手法の検討

○吉村 裕一郎¹, 太田 雄大², Bochko Vladimir³, Falt Pauli⁴, Hauta-Kasari Markku³, 並木 隆雄⁵, 中口 俊哉¹
¹千葉大学フロンティア医工学センター, ²千葉大学大学院融合理工学府, ³ヴァーサ大学, ⁴東フィンランド大学, ⁵千葉大学医学部和漢診療科

近年コンピュータ支援による定量的な舌診断に関する研究が進められている。舌診は漢方の診断法の一つであり、舌の色彩、形状、湿潤、舌苔の状態等から患者の体調を診断するが、計測の難しさから舌苔を解析する研究は少ない。そこで、本研究では RGB 画像からの機械学習を用いた舌苔推定を試みた。具体的には、舌苔に関する指標である舌苔の物理量と被覆領域を推定した。教師データとしては、先行研究で舌苔計測における有効性が示された、蛍光撮影画像を用いる。回帰型学習器を用いて蛍光量を推定し、蛍光量と物理量との関係式から物理量を推定した。また被覆領域推定においては、分類型学習器を用いて蛍光撮影画像から小領域単位で被覆有無のラベルを作成した。実験では学習器として Random Forest と深層学習を用いて性能を比較評価した。13 名の舌画像から 2725 サンプルを抽出し交差検証を行った結果、通常撮影された RGB 画像からの舌苔推定の有効性が示唆された。

OP4-20 肺がん体幹部定位放射線治療における 3 次元計画 CT 画像上の肉眼的腫瘍体積の Dense V-net 自動抽出法

○中野 里彩¹, 有村 秀孝², Mohammad Haekal³, 大賀 才路⁴
¹九州大学大学院医学系学府保健学専攻, ²九州大学大学院医学研究院保健学部門, ³Department of Physics, Faculty of Mathematics and Natural Sciences, Institut Teknologi Bandung, ⁴九州大学大学院医学研究院臨床放射線科学

Automated segmentation of gross tumor volumes (GTVs) are demanded to reduce intra- and inter-observer variabilities in GTV contours, which affect to treatment dose distributions. Hence, we attempted to develop an automated approach using a dense V-Net deep learning, which can segment small structures.

Datasets of 3D planning CT images and GTV contours for 194 lung cancer cases determined by radiation oncologists were fed into the dense V-Net as input and teacher data, respectively.

The proposed approach achieved an average Dice's similarity coefficient (DSC) of 0.792. The average DSCs for solid and part solid GGO types were 0.807 and 0.782, respectively.

The proposed approach could be useful to delineate the various types of GTVs in treatment planning.

OP4-21 半教師あり学習を用いた根拠提示可能なメラノーマ識別

○村林 誠也, 彌富 仁

法政大学大学院理工学研究科

診断が難しい悪性度の高い皮膚がんであるメラノーマ（悪性黒色腫）の早期発見と高精度な診断実現のため、画像認識による自動診断手法の開発が行われている。近年の深層学習を用いた手法は、複雑な特徴量抽出・設計を伴うことなく専門医に匹敵する高い識別精度を実現しているが、識別根拠を提示できず信頼性の面で改善の余地が残されていた。我々はこれまでメラノーマ自動診断における識別根拠の提示について一連の検討を行い一定の成果を実現したが、臨床現場で利用される指標に基づく可読性の高い教師データは作成を医師に依頼する必要からコストが高く、それに起因する予測器の過学習、精度面での改善の必要性が残されていた。そこで本研究では、診断指標予測の精度向上を目的として、深層学習技術をベースに非ラベルデータの知識移転・共有による改良を検討した。また、システム注目領域の推定により得られた視覚的表示との整合性についても比較、評価した。

OP4-22 転移性肝がん検出のための Conditional GAN による学習画像生成

○池田 裕亮¹, 道満 恵介¹, 目加田慶人¹, 縄野 繁²

¹ 中京大学 大学院工学研究科, ² 国際医療福祉大学三田病院

現在、肝がんの読影は医師の目視で行われている。医師の負担を軽減するために機械学習による読影支援が望まれているが学習のために必要な多様な症例画像を収集することは困難である。そのため、健常症例に病変を埋め込む症例画像生成が行われている。従来研究である DCGAN を用いた人工病変画像生成手法では特徴が異なる病変の画像を混ぜて学習に使用した。そのため異なる特徴が混ざった不自然な病変画像を生成してしまう問題があった。

本研究では辺縁部の病変画像と非辺縁部の病変画像のラベルを付与した学習データを用いた Conditional GAN による画像生成法を提案する。生成した病変画像を CNN で構築した肝がん検出器の学習に用い、学習に使用していない 20 症例を適用した。実験の結果、従来手法より検出精度が向上し本手法の有効性を確認した。

OP4-23 Deep CNN における分類器のアテンションメカニズムを利用した CT 画像からの乳腺領域の自動抽出法

○山岸 誠也¹, 周 向栄¹, 原 武史¹, 加賀 徹郎², 加藤 博基², 松尾 政之², 藤田 広志¹

¹ 岐阜大学大学院自然科学技術研究科知能理工学専攻, ² 岐阜大学医学部附属病院放射線科

本研究の目的は、様々な検査の目的で撮影された体幹部 CT 画像から乳腺領域を抽出し、空間的な分布を把握することである。深層学習で構築した乳腺領域のカテゴリ分類器の Attention Map を利用して、乳腺領域の自動抽出を行う。分類器の学習とテストには、それぞれ 80 症例と 16 症例を利用する。3 次元 CT 画像から切り出した乳房領域において、乳頭方向を回転軸とする断面画像を 1 度ごとに生成する。Attention Map は学習用の 80 症例に基づいて作成される。角度ごとに定められた Attention Map を 2 次元で作成し、Attention Map 上で画素値が 122 以上の領域を乳腺領域の抽出結果とする。Attention Map による抽出結果と手動で作成した乳腺領域の 16 症例から求めた平均 Dice 値は 49.6% であった。Dice 値の低い症例は乳腺領域が散在していることを確認した。Attention Map は乳腺領域の空間的な分布を特定できると考えられるため、乳腺領域の確率アトラスの作成に利用できる可能性がある。

OP4-24 Automated approach for estimation of sizes of lung cancer on planning CT images using deep learning with non-negative matrix factorization

○Ma Zhuangfei¹, Arimura Hidetaka², Nakano Risa¹, Yoshitake Tadamasa², Shioyama Yoshiyuki²

¹ Department of Health Sciences, Graduate School of Medical Sciences, Kyushu University, Fukuoka, Japan, ² Faculty of Medical Sciences, Kyushu University, Fukuoka, Japan

Assessment of the change in tumor volume is a substantial factor in the clinical evaluation of cancer treatment. However, it is tedious and difficult for medical doctors to manually measure lung tumor longest diameters ($\geq 10\text{mm}$) in three-dimensional computed tomography (CT) images, and evaluate tumor responses such as complete response and progressive disease. We have developed an automated approach to estimate lung cancer sizes on planning CT images using a deep learning with non-negative matrix factorization (NMF). The longest, middle and shortest diameters of lung cancer were estimated by the largest, middle and smallest standard deviations in the coefficient matrices in NMF, respectively. The errors of estimated lung cancer sizes in the longest, middle and shortest diameters were 17.53%, 21.14% and 20.58%. The NMF would have a potential for estimating the longest diameters in the lung cancer sizes.

ミニシンポジウム2

10:40 ~ 11:30

MS2 「生命機能イメージングの革新：今後の課題と展望」

座長：清末 優子 (理化学研究所)

末次 志郎 (奈良先端科学技術大学院大学)

近年、生命科学研究における各種イメージング技術が革新的に進歩し、得られるデータの質と量が飛躍的に向上した。これに伴い、生命科学の異なる分野において共通して、データを解析する手段の刷新を迫られている。この課題を解決するために、JST CREST 情報計測領域に参画し、ディープラーニングをはじめとする最近の情報学の手法を導入することで分子や細胞の機能をデータから読み解く技術の開発を目指している3チームの研究を紹介する。生体分子内部の構造をとらえるクライオ電子顕微鏡法、分子の3次元構造の経時変化をとらえる高速原子間力顕微鏡 (高速 AFM)、及び、生体内で活動する細胞の3次元動態を高時空間分解能でとらえる格子光シート顕微鏡まで、幅広いスケールにまたがる生命機能イメージング技術について議論する。

MS2-1 イン트로：JST CREST 情報計測領域について

○清末 優子
理化学研究所

MS2-2 クライオ電子顕微鏡法による生体分子の構造解析

○光岡 薫
大阪大学

最近、クライオ電子顕微鏡法による生体高分子やその複合体の構造解析の分解能が著しく向上し、X線結晶構造解析やNMRと並んで、原子モデルを決定できる構造解析法の1つとして利用が進んでいる。その単粒子クライオ電子顕微鏡法について、実際の解析例を含めて簡単に紹介する。さらに、同様の高分解能構造解析を細胞内にある生体高分子に応用することができるクライオ電子線トモグラフィー法とサブトモグラム平均化についても述べる。

MS2-3 高速原子間力顕微鏡による生体分子イメージングと機械学習・データ同化

○高田 彰二
京都大学

高速原子間力顕微鏡 (高速 AFM) は、わが国で開発され、単一のタンパク質やDNA分子の3次元構造の経時変化を観察できる唯一の計測技術です。中程度の分解能をもつ高速AFM計測から高精度情報を得るために情報科学との融合研究が必要です。我々は、データ同化と分子シミュレーション法によって、高速AFM計測からの生体分子の高精度4次元構造解析法を開発しています。本講演では、機械学習によるAFM画像からの超解像度化、データ同化による高速AFM計測と分子シミュレーションの融合の取り組みを紹介します。

MS2-4 細胞活動の高精度3D計測と画像情報解析の次世代化に向けて

○清末 優子
理化学研究所

我々が運用する「格子光シート顕微鏡」は、2014年に初めて発表された高解像型ライトシート顕微鏡で、三次元的な細胞活動をかつてない時空間分解能で計測することができる。本技術により得られる細胞情報が質的にも量的にも劇的に向上したが、従来の技術のみでは解析が不可能となり、情報科学との高度融合によって画像とデータの解析手法を次世代化する必要が生じた。本講演では格子光シート顕微鏡の実際と、情報科学との融合における我々の取り組みを紹介する。

ランチョンセミナー

11:50 ~ 12:40

LS 「DGX-2 によって加速されるメディカル AI 開発のための データ構造化プラットフォーム」

座長：中田 典生（東京慈恵会医科大学）

LS DGX-2 によって加速されるメディカル AI 開発のためのデータ構造化プラットフォーム

○小林 和馬

国立研究開発法人国立がん研究センター研究所 がん分子修飾制御学分野

人工知能技術を用いた臨床支援システムを確立することは、個別化された医療に寄与するのみならず、高齢化で逼迫する医療の持続可能性からも急務である。国立がんセンター中央病院・研究所におけるプロジェクトでは、臨床データを構造化するためのプラットフォームを構築すると共に、メディカル AI 開発を加速するための NVIDIA DGX-2 を本邦の医療機関として先駆けて導入した。その最新の成果について紹介する。

特別講演 2

13:00 ~ 13:50

SL2 「ネオコグニトロンと畳み込みニューラルネットワーク」

座長：尾川 浩一（法政大学 / JAMIT 学会長）

SL2 ネオコグニトロンと畳み込みニューラルネットワーク

○福島 邦彦

ファジィシステム研究所 特別研究員

高いパターン認識能力を学習によって獲得することができる手法として、深層学習（deep learning）や CNN（convolutional neural network）が最近注目を集めている。福島が 1979 年に発表したネオコグニトロンもそのような階層型多層神経回路の一種で、文字認識をはじめとする視覚パターン認識に高い能力を発揮する。ネオコグニトロンの歴史は古いが、現在に至るまで種々の改良が加えられ発展を続けている。現在広く用いられている deep CNN との相違点に重点を置きながら、最近のネオコグニトロンを紹介する。

ネオコグニトロンの考え方を更に発展させた種々のシステム、例えば、部分的に遮蔽されたパターンを認識する神経回路なども開発されている。top-down 型の信号の流れを導入した選択的注意のモデルでは、複数のパターンに順番に注意を向けながら、パターンを切り出し認識することができる。

前半(口演):メイン会場(レセプションホール1)

後半:ポスター会場(会議室3・4)

一般演題セッション5

13:50 ~ 15:20

OP5

「イメージング/画質改善」

座長:菅 幹生(千葉大学)

OP5-01 非ランダム間引き収集によるMR圧縮センシングの深層学習再構成

○佐藤 佑紀, 伊藤 聡志

宇都宮大学 大学院地域創生科学研究科 工農総合科学専攻

MRIは撮像高速化が課題であり,近年では圧縮センシング(Compressed Sensing:CS)を用いた高速撮像が利用され始めている。CSはサンプリングのランダム性による画質変動,反復処理に伴う計算時間の大きさなどの課題がある。ランダム性による画質変動という課題に対し我々は,CSにおける画質変動を抑制する方法として信号収集を規則的に行う非ランダムサンプリングの検討を行ってきた。

本研究では再構成の高速化と再構成像の高品質化を目的とし,非ランダムサンプリングによるCS再構成に畳み込みニューラルネットワークを利用する方法について検討を行った。その結果,信号間引きによるアーティファクトをほぼ除去したランダム間引きに匹敵する良好な再生像を得ることができた。本研究により深層学習の利用によって圧縮センシングの間引き法に関して新たな可能性が示された。

OP5-02 CT画像再構成におけるメタルアーティファクト除去の新技术

○千北 一期, 工藤 博幸, 森 和希, 金 鎔采

筑波大学大学院 システム情報工学研究科

CT画像再構成における未解決問題としてメタルアーティファクトの除去がある。通常のメタルアーティファクトの除去は,まず予備的な画像再構成を行い吸収率が大きい金属部分を同定して(第1ステップ),金属部位を通過する投影データを補間で埋めて画像再構成を行う(第2ステップ)二段階法が商用CT装置では実用されている。本研究では全く新しい上記の1,2ステップを統合した新技术を提案する。提案手法はKudoらが提案したフォルトトレラント画像再構成法(SPIE, Optics+Photonics, 2016)に基づいている。金属部位を通過する投影データをビームハードニングや過度なPoisson雑音の影響を受けた異常データとして捉え,異常データの除外に有効なL1ノルムを評価関数として画像再構成を行う。通常のCT画像再構成では,評価関数として最小2乗誤差が使用されるが,最小2乗誤差は異常データに敏感で金属部位の影響を受けやすくストリークアーティファクトが強く発生する。そこで,L1ノルム誤差を評価関数に使用して金属通過する異常投影データの場所を同定してデータフィッティングから除外する。更に,除外した投影データの情報をうまく埋める効果(従来手法の補間に相当)を持たせるためのトータルバリエーション(TV)を正則化項として加えた式を最終的な評価関数として画像再構成を行う。このように,単一の最小化問題を解くだけで従来手法の二段階を一つのステップに統合できる点がキーである。評価関数の最小化手法としては,上記の評価関数を数学的に厳密に最小化でき更に収束速度が早いRow-Action型の近接スプリッティングに基づく反復手法を構築して使用した。歯科用CT実画像と腹部CT実画像を用いたシミュレーション実験を行った結果(ビームハードニングとPoisson雑音を考慮して計測過程を正しくシミュレーションしたデータを使用),本手法は従来のメタルアーティファクト除去手法に匹敵する(またはそれ以上の)性能を有することが示され,メタルアーティファクト問題に対する新しい方向性の枠組みであると考えられる。

OP5-03 2D U-Net の畳み込みネットワークを用いた隣接スライスからの CT 画像再構成

○武 淑ケイ¹, 中尾 恵¹, 今西 勁峰², 中村 光宏³, 松田 哲也¹

¹ 京都大学情報学研究所, ² イーグロース株式会社, ³ 京都大学大学院医学研究科

Usually, Computed Tomography (CT) image reconstruction refers to a process of creating tomographic images from X-ray projection at various directions. To reduce the radiation dose, many algorithms were proposed to improve the reconstruction process. Generally, they can be divided into two categories: analytical and iterative approaches. Analytical methods are difficult to achieve high accuracy, whereas iterative algorithms suffer from high computation cost. To solve the problem, we apply 2D U-Net convolutional networks to the CT image reconstruction. In contrast to the conventional methods, the proposed approach realizes the reconstruction from the already created CT slices, not the X-ray projection. Using the U-Net, we can create a new middle slice between two adjacent CT slices. This means that we can decrease the number of CT slices to reduce the radiation. We compared the proposed algorithm with interpolation method. Experiment results show that the U-Net based reconstruction totally outperforms the linear interpolation.

OP5-04 TV 正則化と辞書学習を用いた OS-EM 法における PET 画像再構成

○奥村 直裕, 庄野 逸

電気通信大学情報理工学研究所

陽電子放射撮影 (Positron Emission Tomography: PET) スキャンは、癌の発見などの病理診断で重要な役割を果たす。PET スキャンでは、トレーサと呼ばれる陽電子を放射する放射性物質を患者に注入し、サイノグラムと呼ばれる観測データが得る。PET 画像は、このサイノグラムから元の空間でのトレーサ濃度を再構成することで得られる。鮮明な PET 画像を得るためには、S/N 比をあげる必要があるが、被曝量を増加させないことも重要であり、適切なノイズ除去手段の開発は重要である。本研究ではこの問題に対して、2つのノイズ除去手法を組み合わせた手法を適用した。一つは、サイノグラム表現に対するノイズ除去で、ここでは辞書学習を用いた手法を適用した。もう一つは、実画像表現に対するノイズ除去で、これには正則化アプローチに基づいた手法を適用した。このような2種類のノイズ除去手法を組み合わせたアプローチは、従来手法と比較して有効であることがわかった。

OP5-05 拡散尖度撮像法のパラメタ推定のための生成型 Q 空間学習における最適雑音量の自動決定に向けて

○内濱 良介, 河野智奈美, 佐々木 公, 増谷 佳孝

広島市立大学

我々は、深層ニューラルネットワークの学習に合成データのみを用いる生成型 Q 空間学習による拡散 MRI パラメタ推定の研究を行っている。これまでに学習用の合成データと推定対象のデータの雑音量が同等の場合、最も頑健な推定が可能であることが実験により示唆されているが、実画像の雑音量を測定することは容易ではない。そこで本研究では、拡散尖度撮像法 (DKI) のパラメタ推定を例として、与えられた実画像に対して最適な雑音量の学習データを決定するための方法を検討した。具体的には、学習用の合成データおよび DKI の実画像について、それぞれ様々な雑音量のものを用いて以下の実験を行った。まず、実画像の生体領域と空気領域の領域分割の後、両者の信号値の統計により雑音量の推定を試みた。また、推定結果の統計について最小二乗法との比較を行った。これらの結果より、与えられた実画像に対する最適な学習データ決定の可能性が示唆された。

OP5-06 カラー腹腔鏡画像診断のためのコントラスト強調と SRCNN 超解像処理の最適条件に関する考察

○河畑 則文¹, 中口 俊哉²

¹ 東京理科大学理工学部, ² 千葉大学フロンティア医工学センター

医用画像診断におけるコントラスト処理は、各部位の領域を強調させ、異常が無いかを分類・認識することを目的としている。これらの処理の多くは、コントラスト強調に加えて、超解像処理を用いて画像解像度を上げてから分類・認識することで精度が上がるとされる。一方で、医用画像分野における深層学習の普及により、超解像処理においても精度が上がってきたが、多種多様なパラメタが存在し、それらの調整によっては十分な性能が発揮されるとは限らないことがある。そのため、どのパラメタをどのように調整すればよいかを実験により検証し、実用化する必要がある。そこで、本研究では、カラー腹腔鏡画像のコントラスト強調と超解像処理の関係について、超解像に特化した深層畳み込みニューラルネットワークである SRCNN に基づいた waifu2x-caffe (UpResNet10) で実験を行い、最終的に PSNR を測定し、どの程度、精度よく画像が生成できているのかを検証した。

OP5-07 動作計測による顔の粘弾性シミュレーション

○黒田 嘉宏¹，加藤 弘樹¹，谷川 千尋^{2,3}，吉元 俊輔¹，大城 理¹，高田 健治^{2,4}

¹大阪大学 大学院基礎工学研究科，²大阪大学 国際医工情報センター，³大阪大学 大学院歯学研究所，⁴シンガポール 国立大学

顔の動きは感情を身体的に表出することから、コミュニケーションにおいて重要な役割を担う。生体組織のもつ粘弾的な性質は年齢や傷によって変化し、動きに大きく影響する。しかし、従来は顔の動きの表現に着目した医療支援システムは少ない。本研究では、加齢や手術による顔の運動様態の変化を表現することを目的として、顔の粘弾性特性の計測を行うとともに粘弾性モデルに基づく顔の変形シミュレーションを再現するシステムを構築した。実際に計測した運動を元に、顔の運動する様子を計算して表現することを可能とする。発表では、本研究における粘弾性モデルおよびシミュレーション結果について報告する。

OP5-08 対称性解析に基づく 3 次元データから顔の対称面検出

○細木 大祐¹，陸 慧敏¹，金 亨燮¹，木村菜美子²，大河内孝子²，野添 悦郎²，中村 典史²

¹九州工業大学，²鹿児島大学

口唇裂とは、胎児の顔面が癒合する過程において唇が完全に形成されない場合に生じる先天異常で、日本においては約 500 人に 1 人の割合で発生する。左右対称な外鼻を形成することを目的として治療が行われているが、医師の主観に依存した判断基準に基づいているため、手術部位の対称度合を定量的に判断する必要がある。本論文では、手術部位の対称性を解析するための顔の対称基準となる基準面を検出する手法を提案する。提案法では被験者の顔を撮影した 3 次元点群データに対し、顔器官を点として検出したのち、口唇裂による形状変化の影響が顕著とされる上唇から鼻尖点までの領域を除外した鏡像反転点群との位置合わせを行う。次に、元の点群内の 1 点と鏡像反転像内の対応点の間を垂直 2 等分する平面を求めることにより対称基準面を設定する。提案法を実 3 次元点群データに適用した結果、良好な精度で対象基準面を検出することができた。

OP5-09 放射光 CT を用いた肺 3 次元マイクロ血管解析

○鳥谷 峻平¹，齊藤くるみ¹，泓田 彰汰¹，河田 佳樹²，仁木 登²，梅谷 啓二³，阪井 宏彰⁴，中野 恭幸⁵，岡本 俊宏⁶，伊藤 春海⁷

¹徳島大学大学院先端技術科学教育部システム創生工学専攻，²徳島大学大学院社会産業理工学研究部，³(財)高輝度光科学研究センター，⁴兵庫県立尼崎総合医療センター，⁵滋賀医科大学，⁶Cleveland Clinic Heart and Vascular Institute，⁷福井大学 高エネルギー医学研究センター

次世代の画像診断に向けてマイクロ形態を観察して疾患の極初期段階を診断することは極めて重要な課題である。特に、肺の正常形態、極早期の疾患病態のマイクロレベルでの画像化とその定量的解析の実現は、未知分野である肺マイクロ形態の画像診断学を拓き、次世代の胸部画像診断への貢献が期待できる。従来、末梢肺野構造をより正確に理解するために、肺小葉の解剖とそれに基づいた病態解析が行われてきた。しかし、一断面の画像で解析を行っているため立体構造の把握が困難であるとされている。本研究では、高輝度放射光 CT で撮影しその画像から気管支系、血管系の微細構造を 3 次元的に可視化し解析をする。

OP5-10 CT 画像と顎運動情報を用いた VR 咬合器の開発

○伊藤 崇弘，重本 修伺，伊藤 光彦，木原 琢也，井川 知子，重田 優子，小川 匠

鶴見大学歯学部クラウンブリッジ補綴学講座

歯科臨床においては、咬合および咀嚼機能を正しく検査、診断することは非常に重要である。

これらは顎口腔系の一部の形態と機能を単純化して再現する咬合器を用いて評価されることが一般的である。しかし咬合器は患者の形態や、顎運動を直線近似的に表現するもので、全ての患者情報を再現するものではない。そこで我々は、患者個々の形態と機能をより正確に再現できる VR 咬合器 (Virtual Reality Articulator) の開発を進めている。VR 咬合器は CT 画像から得られる形態情報と、顎運動測定により得られる機能情報を同一座標系にて統合することで、従来は観察する手段のなかった患者の実際の顎口腔系の形態と機能を仮想空間上で可視化することができる。

今回、VR 咬合器を用いて顎変形性関節症症例の術前術中の顎位の妥当性や機能評価に応用した結果、高い有用性が認められたので報告する。

OP5-11 グラフ畳み込みニューラルネットワークを用いた腹部動脈血管名自動命名の初期検討

○日比 裕太¹, 林 雄一郎¹, 北坂 孝幸², 伊東 隼人¹, 小田 昌宏¹, 三澤 一成³, 森 健策^{1,4,5}

¹名古屋大学大学院情報学研究科, ²愛知工業大学情報科学部, ³愛知県がんセンター, ⁴名古屋大学情報基盤センター, ⁵国立情報学研究所 医療ビッグデータ研究センター

本稿では、3次元腹部CT像から抽出された腹部動脈領域に対してグラフ畳み込みニューラルネットワークを用いた血管名自動命名についての検討を行ったので報告する。血管は構造が複雑で個人差が大きいこと、その構造の把握は困難である。血管名を自動命名することにより医師が外科手術の際に患者の血管構造を把握する助けとなり、医師の負担を軽減することができる。そのため、これまで腹部動脈領域に対して機械学習を用いた血管名自動命名を行う手法がいくつか提案されてきた。また、近年ではグラフ構造に対する機械学習が盛んに行われており、その有用性が示されている。そこで本稿では、血管構造をグラフ構造と捉え、血管が持つ太さや長さ、腹部臓器との位置関係などを特徴量としてグラフ畳み込みニューラルネットワークを用いた機械学習による血管名自動命名について検討した。実験の結果、平均85.3%の精度で命名することができた。

OP5-12 Btrfly型CAEを用いた骨シンチグラムにおける骨格認識処理の改良

○星野 ゆり¹, 斉藤 篤¹, 大崎 洋充², 吉田 敦史³, 東山 滋明³, 河邊 譲治³, 清水 昭伸¹

¹東京農工大学 大学院 工学研究院, ²群馬県立県民健康科学大学 大学院 診療放射線学研究所, ³大阪市立大学 医学部附属病院核医学科

骨シンチグラム上の骨格認識処理は、骨のSN比が低いこと、高濃度の異常集積により濃度値が正常と大きく異なる場合が多くあること、骨の大きさや形状の個人差が大きいなどの問題により、しばしば処理に失敗する。本報告では、Btrfly型のConvolutional AutoEncoder (CAE)を用いた骨格認識処理の改良について報告する。提案手法では、従来の手法により認識された前後面の骨格ラベルと確率マップの画像を入力とし、正解ラベルを教師ラベルとしてBtrfly型のCAEの学習を行う。この学習済みネットワークに未知症例に対する従来の骨格認識ラベル（前後面）を入力することで、ラベルに含まれる誤りを訂正する。本稿では、提案手法を実際の246症例に対する従来手法による骨格認識ラベルに適用し、性能を評価した結果について報告する。評価値には正解ラベルと改良された認識結果の間のDice scoreに加え、正解ラベルと認識結果の連結成分数や穴の数の差を用いることで、提案手法の有効性や限界について議論する。

OP5-13 Mask R-CNNを用いた小児胸部X線画像における肺領域の自動抽出

○魚住 春日¹, 松原 尚輝¹, 寺本 篤司¹, 大森あゆみ², 本元 強², 河野 達夫³, 斎藤 邦明¹, 藤田 広志⁴

¹藤田医科大学大学院 保健学研究科, ²茨城県立こども病院, ³東京都立小児総合医療センター 診療放射線科, ⁴岐阜大学 工学部 電気電子・情報工学科 情報コース

[目的]

診断に高い専門性が必要な小児医療では、小児科医が少ないため、医師にかかる大きな負担や見逃し、誤診が課題となっている。本研究では小児に好発する肺炎などの胸部疾患の診断を支援することを目的に、解析領域である肺野の抽出を行なった結果について報告する。肺野の抽出には人工知能の一種で、物体検出と領域抽出を同時に高い精度で行うことができるMask RCNNを用いて行う。

[方法]

NIHが公開した‘ChestX-ray8’から小児と成人の胸部X線画像を選択し、肺野領域をラベル付けすることで1000枚の学習データを作成した。Mask RCNNに1000ペアの胸部X線画像とラベル画像の学習データを用いて学習を行なった。

[結果]

学習に用いていない0～15歳の正常8枚、肺炎と診断された17枚の胸部X線画像を用いて、画像の類似度を表すJaccard index, Dice indexで評価した結果、共に90%以上となった。

OP5-14 深層学習を用いた非造影CT画像からの複数臓器領域の抽出に関する検討

○林 雄一郎¹, 申 忱¹, Roth Holger¹, 小田 昌宏¹, 三澤 一成², 森 健策^{1,3}

¹名古屋大学大学院情報学研究科, ²愛知県がんセンター中央病院消化器外科, ³国立情報学研究所医療ビッグデータ研究センター

本稿では深層学習を用いた非造影CT画像からの複数臓器領域の抽出について述べる。医用画像解析において医用画像から人体の解剖学的構造を自動認識することは重要な処理である。我々はこれまで深層学習を用いて造影CT画像から複数の臓器領域を自動抽出する研究を行ってきた。医療現場では、非造影のCT画像も数多く使用されているため、非造影のCT画像からも複数臓器領域を自動抽出することができれば非常に有用である。本研究では、従来研究と同様に3D U-netを用いて非造影CT画像から複数臓器領域を自動抽出する。学習の際に、従来研究において造影CT画像を用いて学習したモデルを初期値とし、非造影CT画像を用いてファインチューニングを行う。実験の結果、ファインチューニングした3D U-netにより非造影CT画像から複数臓器領域を抽出できることを確認した。

OP5-15 顎口腔領域の CT 画像における金属アーチファクト低減を用いた筋骨格セグメンテーション - 金属アーチファクトのシミュレーションによる精度検証 -

○森谷 友香¹, Abdolali Fatemeh², 阪本 充輝¹, 大竹 義人¹, 重田 優子³, 井川 知子³, 三島 章³, 小川 匠³, 佐藤 嘉伸¹

¹ 奈良先端科学技術大学院大学 先端科学技術研究科, ² Department of Radiology and Diagnostic Imaging at University of Alberta, ³ 鶴見大学歯学部

顎口腔機能異常の一つである顎変形症は、複合的な理由により生じる疾患であることや、手術により急な位置変化を生じた顎骨には術前の状態に戻ろうとする性質があることから正確な診断および手術計画において課題がある。このため、筋骨格構造の自動セグメンテーションによる診断や手術計画の支援が求められている。しかし、CT の撮影範囲内に金属製の歯科充填物等が存在する場合、画像上には金属アーチファクトが生じ、筋骨格構造の認識が困難である。我々は、金属アーチファクトのある CT 画像において、筋骨格セグメンテーションの精度を向上させる研究を進めてきた。しかし、これまではアーチファクト低減後の画像から作成した正解データを用いて精度評価を行っており、真に正確な評価ができていないことが問題であった。そこで本研究では、金属アーチファクトをシミュレーションして得られた CT 画像によって精度検証実験を行ったため、その結果を報告する。

「CAD/ 臨床応用」

座長：野村 行弘（東京大学）

OP5-16 Faster R-CNN による肝臓がん候補領域の抽出法

○古月 夢奇¹, 陸 慧敏¹, 金 亨燮¹, 平野 靖², 木戸 尚治², 田辺 昌寛²

¹ 九州工業大学, ² 山口大学

近年、肝臓がんは男女計で世界第 4 位の死亡者数となっている。肝臓がんの治療には、主に手術によるがんとその周囲の肝臓組織の切除がある。そのため、手術を行うには、事前にかんの個数やその大きさの情報を知る必要がある。その際に利用されるのが X 線 CT をはじめとする画像診断である。これらの診断では、得られた CT 像から肝臓の領域やがんの領域を抽出（セグメンテーション）することにより、最終的に 3 次元でその形状を復元することができる。本論文では、ダイナミック CT におけるがん領域を効率的に抽出するための画像解析法を構築するための前段階として、画像上に大まかながんの関心領域としての矩形領域を初期領域として求める手法を提案する。手法としては入力画像に前処理を施した後、Faster R-CNN を使い、がん領域を含む関心領域を矩形で抽出する。本手法をダイナミック CT の動脈相 11 症例に適用した結果、Recall : 71.72[%], AP : 64.60[%] という結果が得られた。

OP5-17 マクロ病理マルチスペクトル画像からの再構成反射率を用いた皮膚組織の二元悪性腫瘍分類

○アルボヤニエレニ¹, 鈴木 裕之², 市村 孝也³, 佐々木 惇³, 柳澤 宏人³, 土田 哲也³, 石川 正弘⁴, 小林 直樹⁴, 小尾 高史²

¹ 東京工業大学 工学院 情報通信系, ² 東京工業大学 科学技術創成研究院 未来産業技術研究所, ³ 埼玉医科大学 医学部, ⁴ 埼玉医科大学 保健医療学部

This study investigates whether reconstructed spectral reflectance from macropathology multi-spectral images (macroMSI) can assist binary classification of tissue malignancy to identify excised tissue margin during skin cancer diagnosis.

We captured high resolution 7-channel macroMSI of 10 samples before and after formalin fixing and a pathologist labelled 115 regions of interest. We reconstructed spectral reflectance by adaptive Wiener Estimation. Subsets of reconstructed spectra were input to k-Nearest Neighbors (kNN) and Support Vector Machine (SVM) classifiers and evaluated by average area under curve of stratified 5-fold cross validation.

Results revealed that inclusion of unfixed spectra improved classification results. SVM outperformed kNN classifier.

OP5-18 FDG PET-CT の腫瘍領域教師データを半自動的に作成するアルゴリズムの提案と性能評価

○平田 健司¹, 古家 翔¹, 真鍋 治¹, 孫田 恵一¹, 小林健太郎¹, 渡邊 史郎¹, 豊永 拓哉², 玉木 長良³, 志賀 哲¹

¹ 北海道大学大学院医学研究院核医学教室, ² イェール大学 PET センター, ³ 京都府立医科大学放射線医学教室

FDG PET-CT での悪性病変のセグメンテーションは深層学習に期待される課題であるが、放射線科医に定義された膨大な教師データを必要とする。PET では閾値処理により教師データ作成が比較的容易ではあるが、腫瘍集積と生理的集積が隣接するとき手作業を要する。この作業を効率化し再現性を高めるアルゴリズムを考案し、実装および操作者間の再現性を確認したので報告する。このアルゴリズムでは、最初に $SUV \geq 2.5$ を満たすボクセルを自動で抽出し、操作者は確実に腫瘍内であるボクセルを指定する。非腫瘍部分が結合している場合には、確実に腫瘍外であるボクセルを追加で指定する。次に 2 点を分離できる最小閾値を探索し、これで解決できない場合は最急降下法および最近傍法を用いる。頭頸部癌と婦人科癌の計 23 例に対して 2 人の核医学医師が本法で教師データを作成したところ、Dice similarity coefficient が 0.98 ± 0.03 と高い一致率が得られた。今後の教師データの作成に有用であると考えられた。

OP5-19 乳腺領域の自動抽出を用いた深層ニューラルネットワークによる乳房超音波画像における腫瘍検出

○楊 凱文, 叶 嘉星, 鈴木 藍雅, 坂無 英徳
産業技術総合研究所

乳房超音波検査における腫瘍の発見率向上のために、機械学習技術を用いた診断支援システムの実現が期待されている。従来の手法では、画像中のノイズと乳腺以外の脂肪や筋肉の影響で、腫瘍の過検出することが多い。そこで本稿では、乳腺領域の自動抽出と腫瘍候補領域の検出を組み合わせ、深層ニューラルネットワークによる腫瘍検出手法を提案する。提案手法では、画素単位の領域分割を行う深層学習モデルである U-Net を用いて、乳房超音波画像から腫瘍が発生しうる乳腺領域の抽出を行う。また、畳み込みニューラルネットワークにより画像中の腫瘍像を検出するモデルを作成する。U-Net による乳腺領域の抽出結果と腫瘍検出モデルの出力を統合し、乳腺以外の腫瘍候補を抑制することで過検出を低減する。実験では、実際の乳房超音波検査にて取得されたデータセットを用いて、従来手法と比べ検出精度が向上し、過検出が削減されることを確認した。

OP5-20 レディオミクスによる肺がんの再発リスクの予測 - レディオミクス特徴量の比例ハザード性の検証 -

○吉岡 拓弥¹, 内山 良一²

¹熊本大学大学院保健学教育部, ²熊本大学大学院生命科学部

医療は存在診断、鑑別診断、治療の順に行われる。コンピュータ支援診断 (CAD) は存在診断や鑑別診断の支援に用いられてきた。よって、CAD は、医療の前半を支援するシステムと考えることができる。一方、Radiomics は医療の後半を支援するシステムであり、再発リスクなどの予後予測に関する研究が行われている。Radiomics による再発リスクの予測では、コックス回帰モデルが用いられることが多い。しかし、病変から取得した高次元画像特徴量は、コックス回帰モデル構築の仮定となる比例ハザード性を満たしている可能性が低く、推定精度の信頼性に問題がある。そこで本研究では、肺がんの再発リスクの予測を例に、肺がんから得た Radiomics 特徴量の比例ハザード性を検討し、コックス回帰モデルと比例ハザード性を仮定しない生存時間分析のモデルの予測性能を比較する。

OP5-21 深層学習を用いた胃 X 線検査画像における腫瘍領域自動検出の試み

○市川 梨沙¹, 野村 敬清², 彌富 仁¹, 橋本 順²

¹法政大学理工学部, ²東海大学医学部専門診療学系画像診断学

がんのスクリーニングにおいて、X 線検査は CT や MRI、内視鏡検査などの専門的検査方法と比べて容易なため、集団検診で広く利用され検診者母数が極めて大きい。一方で X 線検査における病気の検出感度は専門的検査に比べて低いという問題がある。機械学習を用いた自動診断支援に関する研究も主に後者の専門的検査結果を対象としたものがほとんどであり、特に検診者母数の多い胃 X 線検査に対する近年の成果は極めて数少ない。そこで本研究では X 線検査を診断する医師への診断支援を目的として胃 X 線画像を元に、腫瘍領域の自動検出システムを試作した。システムは物体検出と識別を同時に行えるアルゴリズムである Single Shot Multibox Detector (SSD) を用い検証を行った。

OP5-22 疾患股関節の CEA の自動計測と大規模データベース解析への有用性の検討

○田中 雄基¹, 日朝 祐太¹, 大竹 義人¹, 高尾 正樹², 上村 圭亮², 菅野 伸彦², 佐藤 嘉伸¹

¹奈良先端科学技術大学院大学情報科学領域, ²大阪大学大学院医学系研究科

大規模医用画像データベースに対する病態解析の必要性が高まっている。そこで我々は股関節変形症に着目し、大規模医用画像データベースに対する股関節変形症の分類である一次性と二次性の自動分類を目標とする。本研究ではそのための第一歩として三次元 CT 画像から CNN を用いて解剖学的特徴点を特定し、臨床で用いられている CEA (Center Edge Angle) を自動で計測する。また診療科を問わず網羅的に収集された約一万症例の CT データベースから股関節変形症の有病率の測定に利用できるかを検討する。

OP5-23 3D fully convolutional network を用いた腎腫瘍の定量評価における初期検討

○王 成龍¹, 小田 昌宏², 林 雄一郎², 佐々 直人³, 山本 徳則³, 森 健策^{2,4}

¹名古屋大学情報科学研究科, ²名古屋大学情報学研究科, ³名古屋大学医学系研究科, ⁴国立情報学研究所医療ビッグデータ研究センター

Partial nephrectomy is a common treatment for kidney tumors. Due to the wide variety of tumor's anatomical structures, relations between tumor's morphology and surgical outcomes have gained a lot of research interests. Quantitative evaluation of kidney tumor can help physicians to have a better understand of tumor status. Manual segmentation of kidney and tumor is a time-consuming and expensive task. In this work, we used a 3D fully convolutional network to automatically segment kidneys and tumors, and then use traditional statistical analysis methods to quantitatively evaluate the kidney tumor. By using deep-learning based method, kidneys and tumors can be precisely extracted from 3D CT scans. The quantitative analysis can be used for further surgical planning, such as renal clamping strategy. Our segmentation accuracies of kidney and tumor are 93.4% and 42.3%.

OP5-24 網膜動脈硬化症分類のための静脈口径計測

○畑中 裕司¹, 立木 宏和², 川崎 良³, 齋藤 公子⁴, 村松千左子⁵, 藤田 広志⁶

¹ 滋賀県立大学工学部電子システム工学科, ² 滋賀県立大学大学院工学研究科電子システム工学専攻, ³ 大阪大学大学院医学系研究科視覚情報制御学, ⁴ 篠田総合病院眼科, ⁵ 滋賀大学データサイエンス学部, ⁶ 岐阜大学工学部電気電子・情報工学科

網膜動脈硬化症の代表的な所見である網膜動静脈血管狭窄の診断を支援するために、網膜動脈と網膜静脈のなす交差点（AV交差）近くの静脈径の測定処理の開発を目的とする。これまでに提案されてきた手法では、交差点付近で蛇行する静脈の誤検出が多い問題があり、蛇行する静脈径の計測に失敗していた。本研究では、血管骨格をスプライン補間とP型フーリエ記述子を用いて平滑化した。最後に、血管のセグメンテーション処理で得たエッジを使用することによって静脈直径を測定した。提案した方法を95枚の眼底画像に適用したとき、手動計測した静脈径との平均誤差と標準偏差は 1.39 ± 1.11 画素であった。

第3日 7月26日（金）

メイン会場（レセプションホール1）

シンポジウム2

15:35 ~ 16:55

SY2「多元計算解剖学のこれから - さらなる飛躍を目指して」

座長：森 健策（名古屋大学）

清水 昭伸（東京農工大学）

本シンポジウムでは、文科省科研費新学術領域「多元計算解剖学」において行われてきた研究を振り返るとともに、今後の発展について議論する。多元計算解剖学は、(1) 細胞レベルから臓器レベルまでの空間軸、(2) 胎児から死亡時までの時間軸、(3) 撮像モダリティ、生理、代謝などの機能軸、(4) 正常から疾患までの病理軸といった種々の軸にまたがる医用画像情報に基づき、「生きた人体の総理解」のための数理解析基盤を確立し、早期発見や治療困難な疾患に対する高度に知能化された診断治療法実現のための数理的諸手法を開拓する研究領域として設定された。本シンポジウムでは、多元計算解剖学における研究を振り返り、今後の発展に向けてどのように研究を展開するのか議論する。

SY2-1 多元計算解剖学において生み出されたもの

○橋爪 誠

九州大学

本プロジェクトは2014年文部科学省「新学術領域」として採択されたものです。多種多様な医用画像を動的な生体解剖として総合的に理解できるように数理的理論体系を確立し、革新的診断・治療の創出と健康増進に寄与することを目的としています。時間軸、空間軸、機能軸、病理軸の4つの軸上にある各個人の生体情報と医用画像の統合を目指した多元計算解剖モデルを確立し、若手の育成や世界への普及に貢献できましたので報告します。

SY2-2 多元計算解剖学における数理

○本谷 秀堅

名古屋工業大学

多元計算解剖学の目標のひとつは、(1) 細胞レベルから臓器レベルまでの空間軸、(2) 胎児から死亡時までの時間軸、(3) 撮像モダリティ、生理、代謝などの機能軸、(4) 正常から疾患までの病理軸の各軸をまたがる医用画像群を統合し、人体モデルを構築する方法論を確立することであった。ここでは、撮像からデータの統合とモデル化に至る一連の手続きにおける、問題点の数理的側面と我々の取り組みならびに今後の課題を述べる。

SY2-3 多元計算解剖学における多元モデリング

○佐藤 嘉伸

奈良先端科学技術大学院大学

多元計算解剖学では、医用画像を中心として、ミクロからマクロまで多重スケールで得られる、様々なモダリティの解剖・機能（生理）・病理等の時空間データ、言わば、多元データを統合しモデリングすることにより、人体の総理解を目指す。本発表では、このような、人体多元データの統合・モデリングを行う研究開発の枠組み、および、脳、胸部、腹部、筋骨格、ヒトの一生涯のそれぞれにおいて多元データから構築された多元モデルの具体例の紹介を通して、多元モデリングの達成点と波及効果について述べる。

SY2-4 多元計算解剖学と人工知能ブーム

○藤田 広志
岐阜大学

本プロジェクトは2014年6月に開始したが、2年程遅れて人工知能（AI）ブームが医用画像領域にも到来している。AIブームを牽引するディープラーニングにより、これまでの画像認識の手法が置き換わることも多々ある。しかし、ディープラーニングのブラックボックス性の問題や、医用画像のもつ特殊性もあり、多元計算解剖学の枠組みの重要性が否定されるものでは決していない。むしろ、多元計算解剖学にAI（特にディープラーニング技術）が取り込まれることにより、より完成度の高いものになると言えよう。

SY2-5 多元計算解剖学のその先にあるもの

○森 健策
名古屋大学

本講演では、2019年度をもって研究活動を終了した科研費新学術領域研究「多元計算解剖学」を振り返り、この新学術領域が築き上げた基盤的研究、応用的研究、そして、研究者間の人的ネットワークを振り返りながら、多元計算解剖学のその先にあるものについて論じたい。多元計算解剖学では、空間軸、病理軸、機能軸、時間軸の4つの側面から多角的に人体の構造情報を捉え、そのモデルを確立することで新しい医用画像解析手法の確立とその臨床的応用を目指してきた。今後は、これらにより深いレベルでの探求や、異分野領域の融合も、その発展の視野に入ってくる。また、研究コミュニティの維持と発展も重要である。これらの点を踏まえて、本講演では多元計算解剖学のその先にあるものについて議論したい。

SY2-6 パネル討論 多元計算解剖学の今後の発展に向けて

16:55 ~ 17:00

閉会式

以降の予稿は、著者から提出された原稿を査読なしで、そのまま掲載しています。

著者らが自らの内容を MEDICAL IMAGING TECHNOLOGY (MIT) 誌へ投稿する場合、その原稿にこの PDF に類似した内容が含まれていても、二重投稿とは判断しません。

発行日：2019年7月23日

発行者：佐藤嘉伸

製作所：トーヨー企画株式会社

制約付きアンサンブル学習を用いた事後平均解の近似による MR 画像再構成

久保田 菜々子*¹ 原田 賢*² 藤本 晃司*³

岡田 知久*³ 井上 真郷*¹

要旨

MR 画像再構成においては、複数の画像事前分布を組み合わせることで精度が向上することが知られているが、最適な重みの組み合わせを交差検証法により求めることは、組み合わせ数が指数的に増加するため大変であった。以前の我々の研究では制約付きアンサンブル学習を用いることで、複数の画像事前分布の組み合わせを線形オーダーの計算量で実現した。また推定解に事後平均の近似解という意味づけを行うことで、本手法による再構成の精度向上の理論的裏付けを行った。本研究では理論的根拠を洗練させると共に、更に画像事前分布の数を増やした際にも本手法が有用であることを報告する。

キーワード：アンサンブル学習，MR 画像再構成，圧縮センシング，事後平均推定

1. はじめに

Magnetic resonance imaging (MRI) はコイルにより発生させた磁場を用いて患者の体内を撮像する手法である。健康被害がないことが利点であるが、データの収集に時間がかかることが患者の負担となることや、モーションアーチファクトなどが問題となっているため、撮像時間を短縮することが必要となる。

MRI では複数のコイルを用いて信号を受信することが一般的であるが、異なるコイルで観測される信号にはある程度の空間的相関が存在するため、(周波数空間で) 間引き収集された

信号から観測対象の信号の実空間分布 (=MR 画像) を復元するというのが一般的に行われている。撮像時間を短縮して測定されたデータから診断に十分高精度な画像を再構成するには工夫が必要であり、そのような手法は広く研究されている。MRI による観測は Fourier 変換であり、ランダム行列を用いた観測からの信号復元理論 (圧縮センシング) の良い対象となる。

MRI の撮像・再構成手法には観測データの間引き方やデータの補間方法により GRAPPA[1], SENSE[2,3,4], SAKE[5] など様々な手法 [6,7,8,9,10] が考案されており、その中の一つである CS-SENSE 法[11,12]では、画像事前分布と呼ばれる事前知識を利用し圧縮センシングという理論を用いて複数コイルで観測された間引かれたデータから画像を推定する。画像事前分布は複数組み合わせることで MR 画像が持つ複数の特徴を考慮することができるため精度が向上することが知られている[13,14]。しかし、複数種類の画像事前分布を組み合わせる場合、それぞれの画像事前分布の重要度を表す重み係数を決定する必要があるが、これを交差検証法で決める場合、事前分布の種類数の増

*1 早稲田大学大学院先進理工学研究科
電気・情報生命専攻

〔〒169-8555 新宿区大久保 3-4-1〕

e-mail: nanako329@fuji.waseda.jp

*2 早稲田大学理工学術院総合研究所

*3 京都大学大学院医学研究科放射線医学講座

投稿受付：2019 年 5 月 19 日

加に伴い計算量が指数的に増加するという欠点がある。

そこで我々の研究[15]では、アンサンブル学習を用いることでこの問題を解決した。更にアンサンブル学習に制約をつけることで、アンサンブル学習による精度向上に事後平均 (PM) 解の近似という理論的な意味づけを行った。

本研究では我々の提案手法に関し、理論的根拠をより整理すると共に、画像事前分布の数を大幅に増やした際にも計算量のオーダーを変化させることなく、更なる精度向上が可能であることを示す。

2. 問題設定・既存手法

本節でははじめに MR 画像再構成に関する問題設定と既存手法である CS-SENSE 法に関して述べる。なお、本論文では 2 次元の観測データについて述べるが、3 次元 MR 画像等への拡張も容易である。

1) 複数コイル MRI

2 次元の真の断面画像をベクトル化したものを $\mathbf{x} = [x_1, x_2, \dots, x_N]^T \in \mathbb{C}^N$ (説明の都合で複素ベクトルとするが、虚数成分は 0 である)、画素数を N とし、これを $c \in \{1, \dots, C\}$ 番目の MRI コイルにより観測した 2 次元 k-space(周波数空間)データをベクトル化したものを $\mathbf{y}_c \equiv [y_{c,1}, y_{c,2}, \dots, y_{c,M}]^T \in \mathbb{C}^M$ 、これを C 個のコイル全部について纏めたものを $\mathbf{y} \in \mathbb{C}^{CM}$ とする。 $M = N$ の場合全観測、 $M < N$ の場合部分観測と呼ぶ。2 次元離散 Fourier 変換行列を $\mathbf{F} \in \mathbb{C}^{N \times N}$ (本研究ではユニタリ行列で定義する)、部分観測にも対応できる離散 Fourier 変換行列を $\mathbf{F}_u \in \mathbb{C}^{M \times N}$ 、加法的 Gauss 観測ノイズを $\boldsymbol{\epsilon}_c \in \mathbb{C}^M$ として、次式でモデル化する。

$$\mathbf{y}_c = \mathbf{F}_u \mathbf{S}_c \mathbf{x} + \boldsymbol{\epsilon}_c \quad (1)$$

各々のコイルが持つ信号受信感度 (強度および相対的な位相) の空間分布を感度マップと呼び、感度マップ $\mathbf{S}_c \equiv \text{diag}(\mathbf{s}_c)$ (但し $\mathbf{s}_c \in \mathbb{C}^N$) は対角行列で、次式を満たすように調整されているものとする。

$$\sum_{c=1}^C \mathbf{S}_c^* \mathbf{S}_c \equiv \mathbf{I} \quad (2)$$

但し、 \mathbf{I} は単位行列、*付きの行列は随伴行列を表す。

複数コイルで間引き観測されたデータから MR 画像を再構成する手法は複数提案されている。また、未観測部分を単に 0 が観測されたものとして算出した

$$[\hat{\mathbf{x}}]_i \equiv \sqrt{\sum_{c=1}^C |[\mathbf{F}_u^* \mathbf{y}_c]_i|^2} \quad (3)$$

を zerofill 画像と呼び、ベンチマークとする。このとき i は要素番号を表す。また、全観測かつ観測ノイズが無い場合は $\hat{\mathbf{x}} = \mathbf{x}$ となり、元画像を正確に算出できる。ただし本研究では観測ノイズが含まれた実際の全観測データから式(3)で求めた画像を正解画像として扱う。

2) CS-SENSE 法

Compressed sensing SENSE (CS-SENSE 法) は複数コイルでの MR 画像再構成手法の一つである。zerofill 画像では感度マップの推定を回避して元画像を推定したが、この手法は感度マップを高い空間解像度で正確に求めようとすると、通常の MRI 撮像と同程度の長い時間を要するが、この感度マップの空間分布は滑らかであるという仮定を置くことが可能であるため、MRI 撮像に用いられた観測データ \mathbf{y}_c とローパスフィルタ \mathbf{Q} を用いて次式で陽に点推定する[2,3,4].

$$[\mathbf{s}_c]_i \equiv \frac{[\mathbf{F}_u^* \mathbf{Q} \mathbf{y}_c]_i}{\left[\sqrt{\sum_{c=1}^C |[\mathbf{F}_u^* \mathbf{Q} \mathbf{y}_c]_i|^2} \right]_i} \quad (4)$$

更にこの感度マップを用いて次式を解き、

$$\hat{\mathbf{x}} \equiv \underset{\mathbf{x} \in \mathbb{C}^N}{\text{argmin}} \left\{ \frac{1}{2\sigma^2} \sum_{c=1}^C \|\mathbf{y}_c - \mathbf{F}_u \mathbf{S}_c \mathbf{x}\|_2^2 + \sum_{k=1}^K f_k(\mathbf{x}) \right\} \quad (5)$$

得られた複素画像 $\hat{\mathbf{x}} \in \mathbb{C}^N$ の各要素の絶対値をとることで推定画像 $\hat{\mathbf{x}} \in \mathbb{R}^N$ を求める。

$$[\hat{\mathbf{x}}]_i \equiv |[\hat{\mathbf{x}}]_i| \quad (6)$$

正則化項が複数ある場合の最適化は、FCSA[16]などのアルゴリズムにより可能である。

$f_k(\mathbf{x})$ は複素画像に対する $k \in \{1, \dots, K\}$ 番目の正則化項である。正則化項には、TV-norm の複素画像版である BV-norm[17]

$$\|\mathbf{x}\|_{\text{BV}} \equiv \sum_p \sum_q \sqrt{|x_{p,q} - x_{p+1,q}|^2 + |x_{p,q} - x_{p,q+1}|^2} \quad (7)$$

(p, q は 2 次元画像の縦横の要素番号を表す)

や、複素画像の wavelet 係数に対し L1 ノルムをとるものなどがある。

$$\|\mathbf{x}\|_{\text{wavelet}} \equiv \|\Phi\mathbf{x}\|_1 \quad (8)$$

$\Phi \in \mathbb{R}^{N \times N}$ は各種の wavelet 変換行列を表す。また、通常、観測誤差の係数 $1/(2\sigma^2)$ に対する相対的な重み係数が掛けられ、その正則化項をどの程度重んじるのかを指定する。

正則化項に含まれる重み係数は一般に未知であるため推定する必要があるが、正則化項の種類が多い場合、交差検証法等でこれを推定することは計算量が指数的に増加するため一般に困難である。

CS-SENSE 法は確率モデルによる解釈をする最大事後確率推定 (MAP) 解の推定していることと同義である。

3. 提案手法

本節では、初めに確率モデルを示し、その後本手法が事後平均推定 (PM) 解を推定していることと同義であることを示す。

1) 提案モデルの概要

前節で述べたように、画像事前分布の種類が増えた際の、正則化項の重み係数の決定は困難である。そこでアンサンブル学習によりその問題を解決する。係数を変化させたものや、性質の異なる画像事前分布を複数用意し、それぞれ単独の画像事前分布として再構成を行う。その後、各画像事前分布で再構成した画像の線形和により画像の推定を行う。

この解は PM 解となるため、既存手法である MAP 解よりも二乗誤差を最小化する手法であることを理論的に示すことができる。

2) 確率モデル

同時確率を次式で定義する。

$$p(\mathbf{x}, \mathbf{y}, k; \mathbf{w}) \equiv p(k; \mathbf{w})p(\mathbf{x}|k)p(\mathbf{y}|\mathbf{x}, k) \quad (9)$$

$p(k; \mathbf{w})$ は K 個の事前分布に対するカテゴリカル分布であり、次式で定義する。

$$p(k; \mathbf{w}) \equiv w_k \quad (10)$$

$\mathbf{w} \equiv [w_1, \dots, w_K]^T$, $\mathbf{w} \geq \mathbf{0}$, $\sum_{k=1}^K w_k \equiv 1$ である。 k 番目の画像事前分布 $p(\mathbf{x}|k)$ を正則化項 $f_k(\mathbf{x})$ を用いて次式で定義する。

$$p(\mathbf{x}|k) \equiv \frac{1}{Z_k} \exp\{-f_k(\mathbf{x})\} \quad (11)$$

Z_k は正規化定数、 $f_k(\mathbf{x})$ は重み係数付き正則化項である。ここでは、アンサンブル学習の用語に倣って、個々の事前分布 $p(\mathbf{x}|k)$ を弱事前分布と呼ぶ。事前分布全体としては弱事前分布を組み合わせるものになる。

$$p(\mathbf{x}) = \sum_{k=1}^K \frac{w_k}{Z_k} \exp\{-f_k(\mathbf{x})\}$$

更に、式(5)では、重み係数が異なるだけの同種類の正則化項は、一つに纏められてしまうが (例: $f_1(\mathbf{x}) \equiv 2\|\mathbf{x}\|_{\text{BV}}$, $f_2(\mathbf{x}) \equiv 3\|\mathbf{x}\|_{\text{BV}}$ の場合、 $5\|\mathbf{x}\|_{\text{BV}}$ を一つ指定したものと同じ)、この事前分布は同様に纏めることができないため、事前分布の表現力が増すと考えられる。

観測モデル $p(\mathbf{y}|\mathbf{x}, k)$ を、加法的白色 Gauss ノイズを想定し、次式で定義する。

$$p(\mathbf{y}|\mathbf{x}, k) \equiv$$

$$\frac{1}{(2\pi\sigma^2)^{NC}} \exp\left\{-\frac{1}{2\sigma^2} \sum_{c=1}^C \|\mathbf{y}_c - \mathbf{F}_u \mathbf{S}_c \mathbf{x}\|_2^2\right\} \quad (12)$$

3) 推定量

画像 \mathbf{x} の PM 解を求めることとする。

$$\tilde{\mathbf{x}} \equiv \langle \mathbf{x} \rangle_{p(\mathbf{x}|\mathbf{y})} = \sum_{k=1}^K p(k|\mathbf{y}) \langle \mathbf{x} \rangle_{p(\mathbf{x}|\mathbf{y}, k)} = \mathbf{X} \boldsymbol{\omega} \quad (13)$$

但し、 $\mathbf{X} \equiv [\langle \mathbf{x} \rangle_{p(\mathbf{x}|\mathbf{y}, 1)}, \dots, \langle \mathbf{x} \rangle_{p(\mathbf{x}|\mathbf{y}, K)}] \in \mathbb{C}^{N \times K}$, $\boldsymbol{\omega} \equiv [\omega_1, \dots, \omega_K]^T$, $\omega_k \equiv p(k|\mathbf{y})$ である。この式は、弱事前分布毎に求めた PM 解

$$\langle \mathbf{x} \rangle_{p(\mathbf{x}|\mathbf{y}, k)}$$

$$= \frac{\int \mathbf{x} \exp\left\{-\frac{1}{2\sigma^2} \sum_{c=1}^C \|\mathbf{y}_c - \mathbf{F}_u \mathbf{S}_c \mathbf{x}\|_2^2 - f_k(\mathbf{x})\right\} d\mathbf{x}}{\int \exp\left\{-\frac{1}{2\sigma^2} \sum_{c=1}^C \|\mathbf{y}_c - \mathbf{F}_u \mathbf{S}_c \mathbf{x}\|_2^2 - f_k(\mathbf{x})\right\} d\mathbf{x}}$$

の線形結合で全体の PM 解が求まることを示す。また、正規化定数 Z_k を求める必要がないことが分かる。

PM 解は一般に真の解との平均二乗誤差を最小にするため、この意味において Bayes 最適である。

しかしながら、 $\boldsymbol{\omega}$ を正確に算出することは一般に困難であるため、本手法では、評価指標である二乗誤差を最小化するものを、正解画像を用いて逆算することとする。予め用意した全観

測データ L 個の独立同分布標本 $\{\mathbf{y}^{(l)}, \mathbf{x}^{(l)}\}_{l=1}^L$ を用いることとし、標本番号を $l \in \{1, \dots, L\}$ とすると、同時分布は次式に拡張される。なお、 $\mathbf{x}^L, \mathbf{y}^L$ は $\{\mathbf{x}^{(l)}, \mathbf{y}^{(l)}\}_{l=1}^L$ を表す。

$$p(\mathbf{x}^L, \mathbf{y}^L, k; \mathbf{w}) \equiv p(k; \mathbf{w}) \prod_{l=1}^L p(\mathbf{x}^{(l)}|k) p(\mathbf{y}^{(l)}|\mathbf{x}^{(l)}, k) \quad (14)$$

これを用いて、 $\boldsymbol{\omega}$ を次式で近似推定する。

$$\hat{\boldsymbol{\omega}} \equiv \underset{\boldsymbol{\omega} \geq \mathbf{0}}{\operatorname{argmin}} \sum_{l=1}^L \|\mathbf{X}^{(l)} \boldsymbol{\omega} - \mathbf{x}^{(l)}\|_2^2 \text{ s.t. } \sum_{k=1}^K \omega_k = 1 \quad (15)$$

$\boldsymbol{\omega}$ は事後確率値の集まりであるので、当然に $\boldsymbol{\omega} \geq \mathbf{0}$ 、 $\sum_{k=1}^K \omega_k = 1$ という制約が付く。特に $\boldsymbol{\omega} \geq \mathbf{0}$ により、結果的に $\hat{\boldsymbol{\omega}}$ は疎ベクトルになり、多くの弱事前分布が不要になると予想される。尚、ハイパーパラメータ \mathbf{w} は、 $\hat{\boldsymbol{\omega}}$ の推定に暗に含まれるため、陽に決める必要がなくなる。

以上より求めた $\hat{\boldsymbol{\omega}}$ を用いて、新しい部分観測データ \mathbf{y} から、推定画像 $\hat{\mathbf{x}}$ を次式で求めるものとする。

$$\hat{\mathbf{x}} \equiv \mathbf{X} \hat{\boldsymbol{\omega}}, \quad [\hat{\mathbf{x}}]_i \equiv [[\hat{\mathbf{x}}]_i] \quad (16)$$

4. 実験

今回の実験で用いたデータや実験設定、実験の方法、比較する手法に関して述べる。

1) 実験設定

$N = 256 \times 256$ サイズの $C = 32$ チャネル複数コイルデータを用いた。k-space 上の部分観測位置は、低周波数成分の半径 24 ピクセル相当の領域は必ず観測することとし、残りは平均が低周波数領域の中心、標準偏差が縦横 50 ピクセル相当の二次元正規乱数に従って、観測率が 20% になるまでランダムに行った ($M = 0.2N$)。実際に使用したサンプリングマスクを図 1 に、zerofill 画像 $\hat{\mathbf{x}}$ の例と正解画像 \mathbf{x} の例を図 2, 3 に示す。

Intel Core i7-6700K 64GB のマシンを用いた。

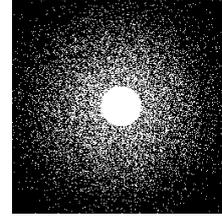


図 1 観測マスク

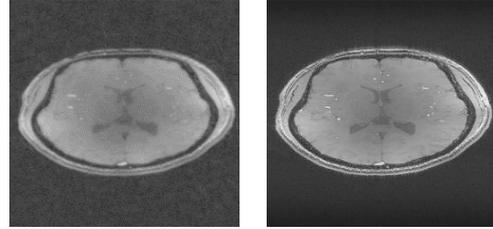


図 2 zerofill 画像

図 3 正解画像

2) 弱事前分布

K 個の弱事前分布 $p(\mathbf{x}|k)$ については、BV-prior, DCT-prior, 各種 wavelet-prior (Doubechies (長さ 4, 6, 8, 深さ 3, 4, 5), Haar (深さ 3, 4, 5), CDF9/7 (深さ 3, 4, 5)) の全 17 種類に、それぞれ重み係数を 50 通り設定した、 $K = 850$ 個を用意した。具体的には、 $f_k(\mathbf{x}) \equiv \lambda_k \|\mathbf{x}\|_{\text{BV}}$, $f_k(\mathbf{x}) \equiv \lambda_k \|\mathbf{x}\|_{\text{wavelet}}$ などの形をとる。DCT-prior についても、wavelet-prior と同様に、複素画像に対する DCT 係数に対し L1 ノルムを計算した。以降、wavelet に関しては Doubechies(長さ, 深さ), Haar(深さ), CDF9/7(深さ)と記載する。

3) 他の設定

ローパスフィルタ \mathbf{Q} には、必ず測定することとした低周波数成分の半径 24 ピクセル相当の領域をそのまま採用するだけのものを用いた。

観測ノイズの分散パラメータ σ^2 は 1 とし、違いは画像事前分布のハイパーパラメータに含めた。

弱事前分布毎の PM 解 $\langle \mathbf{x} \rangle_{p(\mathbf{x}|\mathbf{y}, k)}$ については、実際に算出することは困難であったため、弱事前分布毎の MAP 解 (正確にはこれを絶対値をとって実画像に変換したもの、以下も同じ、既存手法と一致する) で代用した。

$$\hat{\mathbf{x}}_k \equiv \underset{\mathbf{x} \in \mathbb{C}^N}{\operatorname{argmin}} \left\{ \frac{1}{2\sigma^2} \sum_{c=1}^C \|\mathbf{y}_c - \mathbf{F}_u \mathbf{S}_c \mathbf{x}\|_2^2 + f_k(\mathbf{x}) \right\}$$

$$[\hat{\mathbf{x}}_k]_i \equiv [[\hat{\mathbf{x}}_k]_i] \quad (17)$$

最適化には FISTA[18] や、FGP[19]を複素画像に拡張したものを用いた。また、この MAP 解についても正規化定数 Z_k を求める必要はない。

$\hat{\omega}$ の算出については、式(15)の制約を $\omega_k \geq 0$ のみに緩めた。これは、ここで使われる弱事前分布はノルムベースであり、ノルムの劣加法性により縮小推定されるところを、結果的に $\sum_{k=1}^K \hat{\omega}_k > 1$ となることで相殺して、推定精度を上げられると考えたためである。さらに、 $\hat{\omega}$ の算出では学習データの関心領域外を 0 とした。関心領域とは図 4 のような画像中で被写体が写っている場所を指す。医師の診断に必要なのは関心領域のみであり、関心領域外のノイズの再現性は重要でないと考えるためである[20]。

$\hat{\omega}$ の算出の際に、行列 $\mathbf{X}^{(l)}$ のサイズは $N \times K$ と非常に大きい。しかし、式(15)の目的関数を変形すると、定数和を除いて次式であり、

$$\omega^\top \left(\sum_{l=1}^L \mathbf{X}^{(l)*} \mathbf{X}^{(l)} \right) \omega - 2\omega^\top \Re \left(\sum_{l=1}^L \mathbf{X}^{(l)*} \mathbf{x}^{(l)} \right)$$

$K \times K$ の相関行列、長さ K のベクトルを事前に計算しておくことで省メモリ省コストの推定を行える。

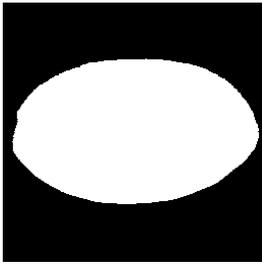


図 4 関心領域の例

5) 評価

同一の MR 装置で観測された多スライスの水平断の観測データ 4 人分各 10 スライスを用い、3 人分のデータ (つまり $L = 30$) で PM 近似解に関しては $\hat{\omega}$ を、MAP 解に関しては全 17 種類の弱事前分布毎の最適な重み係数 λ_k と縮小推定の補正のための定数を学習し、一人分でテストを行う人物間での 4-fold cross validation 法により評価した。縮小推定の補正とは、既存手法は縮小推定されることで指標が悪化するが、これ

は本質的ではないため、学習データに対し評価指標が最もよい定数を掛けることで縮小推定の影響を緩和させた値で評価するためのものである。

評価指標には関心領域の相対 RMSE および mSSIM[21]を用いた。相対 RMSE は、推定画像を $\hat{\mathbf{x}}$ 、正解画像を \mathbf{x} としたとき次式で定義した。

$$\frac{\|\hat{\mathbf{x}} - \mathbf{x}\|_2}{\|\mathbf{x}\|_2} \quad (18)$$

mSSIM は二乗誤差よりもヒトの視覚に近い類似度を与えるとされる指標である。また、評価の際、非関心領域の画素値を推定画像、正解画像、共に強制的に 0 とし、医師の診断に近い評価を行った[20]。

上記評価指標を用いて提案手法の PM 近似解と、zerofill 画像、弱事前分布毎の MAP 解 (既存手法) を比較した。

5. 結果・考察

MAP 解の画像 1 枚当たりの再構成時間は 15 秒程度、 $\hat{\omega}$ の計算時間は 15 秒程度であった。

テストデータに対する評価指標の結果を表 1 に示す。mSSIM は分かり易くするため、1 から引いた値で比較する。いずれの指標も値が小さくゼロに近い方が正解画像に近い。相対 RMSE を比較すると、提案手法がいずれの既存手法よりも推定画像の精度が良かった。提案手法は二乗誤差を最小にするよう設計したため、期待通りである。弱事前分布毎の MAP 解で最も良かったのは BV-prior であり、wavelet-prior の中で最も良かった CDF9/7(5)が続いた。DCT-prior は最も精度が悪かった。

mSSIM を比較すると、こちらも提案手法が一番良い結果となった。これは直接意図した結果ではないが、好ましい特徴である。弱事前分布毎の MAP 解についても、二乗誤差と同様の順位であった。

表 1 評価指標の結果.

手法	相対 RMSE ($\times 10^{-2}$)	1 - mSSIM ($\times 10^{-3}$)
zerofill	22.10	17.81
Doubechies(4,3)	7.349	2.808
Doubechies(4,4)	7.347	2.807
Doubechies(4,5)	7.347	2.806
Doubechies(6,3)	7.304	2.770
Doubechies(6,4)	7.304	2.768
Doubechies(6,5)	7.304	2.767
Doubechies(8,3)	7.313	2.760
Doubechies(8,4)	7.313	2.758
Doubechies(8,5)	7.313	2.758
Haar(3)	7.589	2.908
Haar(4)	7.583	2.904
Haar(5)	7.582	2.902
CDF9/7(3)	7.231	2.734
CDF9/7(4)	7.231	2.732
CDF9/7(5)	7.231	2.731
BV	6.780	2.616
DCT	8.655	3.520
提案手法	6.568	2.176

学習した $\hat{\omega}$ の例を図 5 に示す. 横軸は弱事前分布の重み係数 λ_k の対数を取ったもの, 縦軸は学習により算出した $\hat{\omega}_k$ である. 全体の大きな傾向を見ると, $\hat{\omega}_k$ が非ゼロで生き残った弱事前分布の割合は約 13%で, 期待通り疎な解が得られた. また, 弱事前分布の種類毎に, 最良の MAP 解が存在する重み係数 10^{-4} 付近に大きなピークが得られた. 加えて, 図 6 のような粗いボケた画像である 10^0 付近にもピークが得られた. 10^{-4} 付近の最も大きなピークは既存手法の精度が最も良かった BV-prior であり, BV-prior は 10^0 付近にピークがなかった. 反対に最も精度が悪かった DCT-prior は 10^{-4} 付近にピークがなく, 10^0 付近のみであった. この原因に関しては引き続き考察を行う.

$\sum_{k=1}^K \hat{\omega}_k$ の値は約 1.15 であり, 期待通りに弱事前分布による縮小推定を補ったものと考えられる.

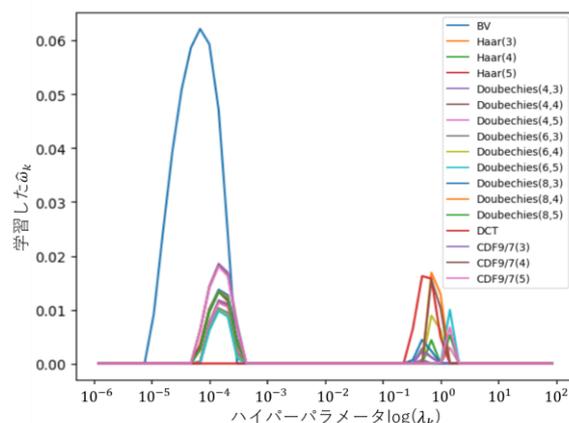
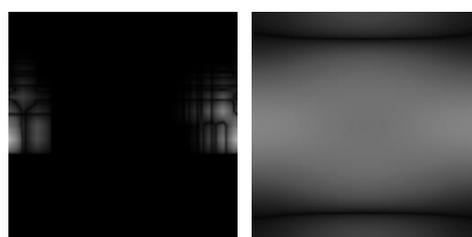


図 5 学習した $\hat{\omega}$ の例

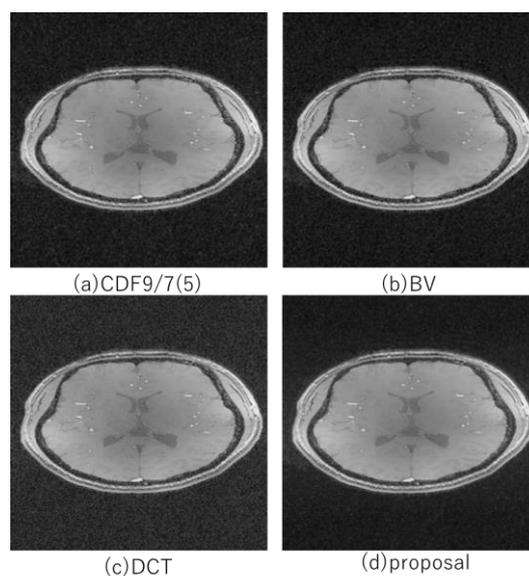


(a) Doube(6,4)

(b) DCT

図 6 ボケた画像の例

推定画像の例を図 7, 正解画像との差分画像を図 8 に示す. 図 8 をみると, 提案手法が既存手法に比べ平均的に良い推定が行われている.



(a) CDF9/7(5)

(b) BV

(c) DCT

(d) proposal

図 7 推定画像

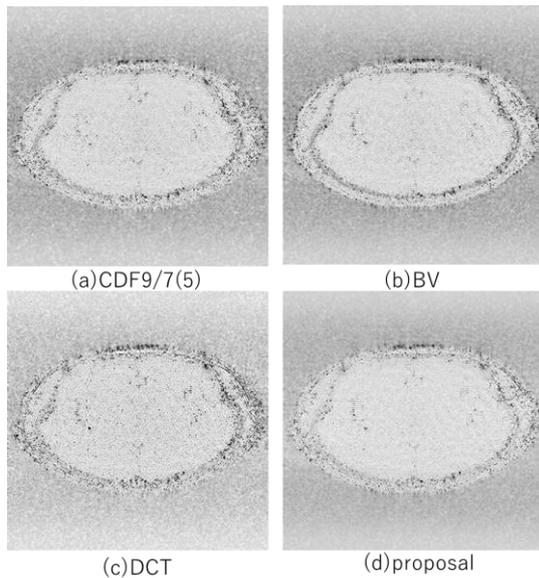


図 8 差分画像

以上の結果から、提案手法は多数の弱画像事前分布を組み合わせることで、既存手法より精度の高い推定が可能であると考えられる。

6. まとめ

アンサンブル学習により、画像事前分布の種類を増加させた際に計算量のオーダーを変化させることなく精度の向上が可能であることを示した。今回のように 17 種類もの画像事前分布を組み合わせた再構成を従来のように交差検証法でパラメータチューニングを行うことは、計算量的に不可能である。しかしアンサンブル学習を用いることで、短時間で多数の画像事前分布を組み合わせた高精度の再構成が可能となった。さらに従来手法では重み係数が異なるだけの画像事前分布は組み合わせることに意味がなかったが、提案手法により組み合わせることが可能となり、画像事前分布としての表現力が向上した。

利益相反の有無

なし

文 献

[1] Griswold MA, Jakob PM, Nittka M et al: Generalized autocalibrating partially parallel

acquisitions (GRAPPA). *Magnetic resonance in medicine* **47(6)**: 1202-1210, 2002

- [2] Pruessmann KP, Weiger M, Scheidegger MB et al: Sense: sensitivity encoding for fast MRI. *Magnetic resonance in medicine* **42(5)**: 952-962, 1999
- [3] Pruessmann KP, Weiger M, Börner P et al: Advances in sensitivity encoding with arbitrary k-space trajectories. *Magnetic resonance in medicine* **46(4)**: 638-651, 2001
- [4] Ying L, Sheng J: Joint image reconstruction and sensitivity estimation in SENSE (JSSENSE). *Magnetic resonance in medicine* **57(6)**: 1196-1202, 2007
- [5] Shin PJ, Larson PE, Ohliger MA et al: Calibrationless parallel imaging reconstruction based on structured low-rank matrix completion. *Magnetic resonance in medicine* **72(4)**: 959-970, 2014
- [6] Lustig M, Donoho D, Pauly JM: Sparse MRI: The application of compressed sensing for rapid MR imaging. *Magnetic resonance in medicine* **58(6)**: 1182-1195, 2007
- [7] Lustig M, Pauly JM: SPIRiT: Iterative self-consistent parallel imaging reconstruction from arbitrary k-space. *Magnetic resonance in medicine* **64(2)**: 457-471, 2010
- [8] She H, Chen RR, Liang D et al: Sparse BLIP: BLind Iterative Parallel imaging reconstruction using compressed sensing. *Magnetic resonance in medicine* **71(2)**: 645-660, 2014
- [9] 笠原勇布,井上真郷, 富樫かおり: アンサンブル学習を用いた MR 画像再構成 信学技報 **116(300) IBISML2016-58**: 87-91, 2016
- [10] 原田賢, 井上真郷, 富樫かおり: CS-SENSE 法における感度マップの不確実性を考慮した事後平均推定近似解 信学技報 **117(211) IBISML2017-21**: 75-82, 2017
- [11] Jiang M, Jin J, Liu F et al: Sparsity-constrained SENSE reconstruction: An efficient implementation using a fast composite splitting algorithm. *Magnetic resonance*

- imaging **31(7)**: 1218-1227, 2013
- [12] Liang D, Liu B, Wang J et al: Accelerating SENSE using compressed sensing. *Magnetic resonance imaging* **62(6)**: 1574-1584, 2009
- [13] Liang D, Wang H, Chang Y et al: Sensitivity encoding reconstruction with nonlocal total variation regularization. *Magnetic resonance in medicine* **65(5)**: 1384-1392, 2011
- [14] Zhou J, J. Li, J.C. Gombanero : Combining SENSE and compressed sensing MRI With a fast iterative contourlet thresholding algorithm. **2015 12th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD)**: 1123-1127, 2015
- [15] 久保田菜々子, 原田賢, 藤本晃司 他: MR 画像再構成における複数の画像事前分布を組み合わせた事後平均近似解 信学技報 **118(284) IBISML2018-47**: 23-28, 2018
- [16] Huang J, Zhang S, Metaxas D: Efficient MR image reconstruction for compressed MR imaging. *Medical Image Analysis* **15(5)**: 670-679, 2011
- [17] B. Liu, L. Ying, M. Steckner et al: REGULARIZED SENSE RECONSTRUCTION USING ITERATIVELY REFINED TOTAL VARIATION METHOD. *IEEE International Symposium on Biomedical Imaging: From Nano to Macro*: 121-124, 2007
- [18] Beck A, Teboulle M: A Fast Iterative Shrinkage-Thresholding Algorithm for Linear Inverse Problems. *SIAM journal on imaging sciences* **2(1)**: 183-202, 2009
- [19] A. Beck, M. Teboulle: Fast Gradient-Based Algorithms for Constrained Total Variation Image Denoising and Deblurring problems. *IEEE Transactions on Image Processing* **18(11)**: 2419-2434, 2009
- [20] T. Akasaka, K. Fujimoto, T. Yamamoto et al: Optimization of Regularization Parameters in Compressed Sensing of Magnetic Resonance Angiography: Can Statistical Image Metrics Mimic Radiologists' Perception? *PLoS ONE* **13(5)**: e0197140, 2018
- [21] Z. Wang, A. C. Bovik, H. R. Sheikh et al: Image quality assessment: From error measurement to structural similarity. *IEEE Transactions on Image Processing* **13(4)**: 600-612, 2004

MR image reconstruction by approximation of posterior mean solution using constrained ensemble learning

Nanako KUBOTA^{*1}, Ken HARADA^{*2}, Koji FUJIMOTO^{*3}, Tomohiro OKADA^{*3}, Masato INOUE^{*1}

*1 Waseda University

*2 Waseda Research Institute for Science and Engineering

*3 Kyoto University

In MR image reconstruction, its accuracy is expected to be improved by combining multiple image prior distributions. However, finding the optimal combination of prior weights by cross-validation method is usually intractable in terms of the exponential calculation cost. In our previous study, we introduced a constrained ensemble learning method to realize using such multiple priors with the linear order computational cost. Moreover, we made theoretical justification of the proposed method, which approximates the posterior mean estimate. In this research, we refine the theoretical justification and validate the method with more image priors.

Key words: ensemble learning, MR image reconstruction, compressed sensing, posterior mean estimate

X線 CT 画像上の雑音分散に対する 検出器モデルの影響

田之上 和矢*¹ 池田 充*¹ 梅田 祐司*¹

藤井 啓輔*¹ 川浦 稚代*¹ 今井 國治*¹

要旨

雑音を量子雑音に限定した場合における X 線 CT 画像上の関心領域内の（「空間平均」の意味での）雑音分散の（「集団平均」の意味での）期待値について、X 線検出器のモデル（quantum counter と energy integrating detector）の差が与える影響について検討した。両検出器モデルの出力が類似した結果を与える条件下で、CT 画像上の関心領域内の雑音分散の期待値について、解析的に計算した結果と仮想的な撮影系を使用したシミュレーション画像から推定した値について検討した。両モデルにおいて、解析的に計算した期待値はシミュレーション画像から推定した値とよく一致した。また、両モデル間で、雑音分散の値の差は少ない結果となった。今回の検討結果からは、両モデルの CT 画像上の関心領域内の雑音分散に与える影響は少なく、同雑音分散に関する検討において簡易な quantum counter モデルでの検討の高い頑健性が示唆された。

キーワード：CT, 画質評価, 被ばく線量

1. はじめに

現在、X 線 CT（Computed Tomography）検査は臨床の場において医学診断に大きな貢献をしているが、使用される機会が非常に増加し被ばく線量が大きな問題となっている。同画像の画質評価に関する検討もこれまで数多くなされているが、均一な CT 値を有することが期待される画像領域における CT 値の変動の分散である X 線 CT 画像上の雑音分散は、最も基本的な指標であるとともに最も多用されているものの一つである。我々はこれまでに、雑音を量子雑音に限定した場合における X 線 CT 画像上の関心領域内の（確率過程論での「空間平均」の意味での）雑音分散の [確率過程論での「集団（集合）平均」の意味での] 期待値について、

文献[1, 2]と同様な方法を使用して解析的に計算することについての検討を行い、同方法の精度がよいことを確認してきた[3]。しかし、これまでの検討において対象とした仮想的な X 線 CT 撮影系の X 線検出器のモデルは、すべて quantum counter としていた。この場合、被写体透過後の X 線検出器で検出される X 線光子数のゆらぎはポアソン分布に従うことになる。一方で、現在臨床の場で使用されている X 線 CT における X 線検出器により近いモデルは energy integrating detector として知られているものである。energy integrating detector モデルでは、X 線検出器の出力の X 線量のゆらぎはポアソン分布とは異なるものとなることもよく知られている。今回、雑音を量子雑音に限定した場合における X 線 CT 画像上の関心領域内の（「空間平均」の意味での）雑音分散の（「集団平均」の意味での）期待値について、仮想的な X 線 CT 撮影系の X 線検出器にこれらの2種類の検出器のモデルを適応した場合に生じる差について検討したので報告する。今回は、両検出器モデ

*1 名古屋大学大学院医学系研究科

[〒461-8673 名古屋市東区大幸南一丁目1番20号]

e-mail: tanoue.kazuya@e.mbox.nagoya-u.ac.jp

ルの出力が類似した結果を与える条件下で、解析的に計算した値と仮想的な撮影系を使用したシミュレーション画像から推定した値についての検討を実施した。

2. 方法

2.1. 仮想的な X 線 CT 撮影系

今回使用した仮想的な X 線 CT 撮影装置は、ファンビーム投影方式とし、各ビームの X 線雑音に関する性状は常に同一であるものとし、かつ、ビーム間で相関はないものとした。X 線入射光子数は空気を通過した際に 1 検出器あたり 10^6 個とし、管電圧 120 kV、ファン角 27.3° 、検出器数 720 個、FOV (field of view) は 19.2 cm、X 線焦点-回転中心間距離を 60 cm、再構成画像の画素数を 512×512 pixels とした。

2.2. X 線検出器モデル

quantum counter モデルを使用した際の X 線検出器の出力は X 線検出器に到達した光子数とした。

energy integrating detector モデルを使用した際の X 線検出器の出力は、以下のようにモデル化した[4]。エネルギーが E の X 線光子が検出器に到達した際、同光子数に係数 $g(E) = GE$ を掛けたものを X 線検出器の出力をとし、エネルギー・ビンごとにこのようにして計算した値の和を最終的な出力とした。ここで、 G は変換係数と呼ばれる定数である。今回の検討では、X 線のエネルギー・ビンを 10 keV として区分化して実施した。また、変換係数 G の値は、X 線光子のゆらぎがない場合において、quantum counter モデルの出力と energy integrating detector モデルの出力が検討した範囲内で最も類似したものとなる値とした。

2.3. X 線光子のゆらぎ

X 線検出器に到達した X 線光子数のゆらぎがポアソン分布に従うことはよく知られているが、X 線検出器が quantum counter モデルの場合、同検出器の出力のゆらぎは (そのまま) ポアソン分布に従うことになる。一方、X 線検出器が

energy integrating detector モデルの場合は、同検出器の出力のゆらぎは、単純なポアソン分布ではなく複合ポアソン分布 (compound Poisson distribution) に従うことが知られている[4]。

2.4. 解析対象画像

今回、水で満たされた直径 15.3 cm の円柱に相当する数値ファントムを被写体とし、上記の仮想的な X 線 CT 撮影装置で撮影した際の再構成画像を解析対象画像とした (図 1 参照)。

2.5. 関心領域の設定

今回の検討では、既述の解析対象画像内に、同再構成画像の中心から等距離 (100 pixels) の 4 箇所的位置を中心とする、 11×11 pixels の正方形の関心領域を設定した (図 1 参照)。そして、これらの関心領域内における (「空間平均」の意味での) 雑音分散の値について検討した。

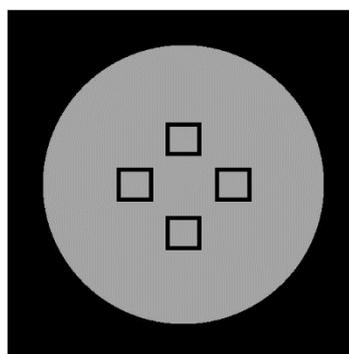


図 1 解析対象画像と設定した関心領域の位置

2.6. 雑音分散の値の検討方法

X 線 CT 画像上の関心領域内の (「空間平均」の意味での) 雑音分散 (不偏分散に相当するものとする) の値の (「集団平均」の意味での) 期待値は、関心領域内の確率変数としての CT 値を X_i ($i = 1, \dots, N$), $E(X_i)$ を X_i の (「集団平均」の意味での) 期待値, $\text{Var}(X_i)$ を X_i の (「集団平均」の意味での) 分散, $\text{Cov}(X_i, X_j)$ を X_i と X_j の (「集団平均」の意味での) 共分散, とそれぞれ表記した際に、式(1)のように与えられる。雑音を量子雑音に限定した場合の関心領域における (「空間平均」の意味での) 雑音分散の値の (「集団平均」の意味での) 期待値と各画素における

(「集団平均」の意味での) 雑音分散について、X線検出器に到達したX線光子数のゆらぎが単純なポアソン分布に従うものとして、既述の数値ファントムに対して同値の(「集団平均」の意味での)期待値を与える式(1)から文献[1, 2]と同様な方法を使用して計算した。一方、既述のX線CT画像上の関心領域内の(「空間平均」の意味での)雑音分散の値の(「集団平均」の意味での)期待値と各画素における(「集団平均」の意味での)雑音分散を、既述の数値ファントムを2種類のX線検出器モデルを使用して仮想的なX線CT撮影系で撮影した300枚のシミュレーション画像を使用して、bootstrap標本数を2000とするbootstrap法によって推定した。

$$\begin{aligned} & \frac{1}{N} \sum_{i=1}^N \text{Var}(X_i) - \frac{2}{(N-1)N} \sum_{i<j}^N \text{Cov}(X_i, X_j) \\ & + \frac{1}{N} \sum_{i=1}^N E^2(X_i) - \frac{2}{(N-1)N} \sum_{i<j}^N E(X_i)E(X_j) \end{aligned} \quad (1)$$

3. 結果

3.1. CT画像上の各画素における「集団平均」の意味での雑音分散に関する検討結果

X線CT画像上の各画素における(「集団平均」の意味での)雑音分散について、X線検出器に到達したX線光子数のゆらぎが単純なポアソン分布に従うものとして解析的に計算した値に対する、2種類の各検出器モデルを使用した仮想的なX線CT撮影系によって作成したX線画像から推定した値との散布図を図2・図3に示す。また、図中の線形回帰式は、X線光子数のゆらぎが単純なポアソン分布に従うものとして解析的に計算した値を独立変数とし、各検出器モデルを使用した仮想的なX線CT撮影系によって作成したX線画像から推定した値を従属変数としたものである。各検出器モデルにおいて、両者の間には強い正の線形相関が認められ、また、回帰式の傾きは1に近い値となった。

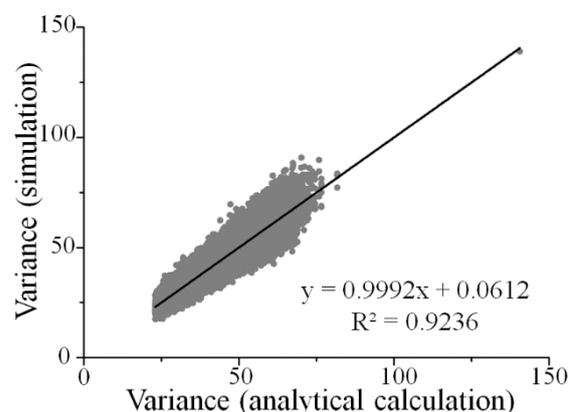


図2 CT画像上の各画素における雑音分散: 解析的に計算した値 versus シミュレーション (quantum counter モデル) からの推定値

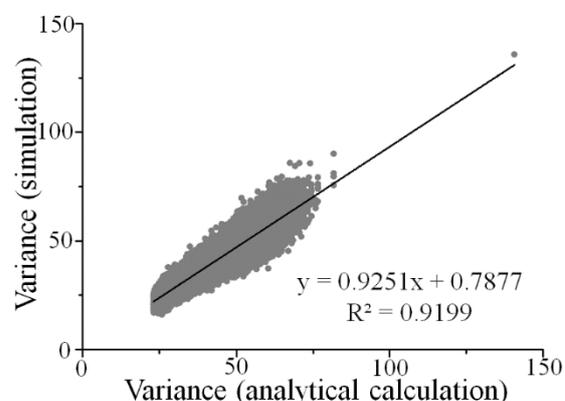


図3 CT画像上の各画素における雑音分散: 解析的に計算した値 versus シミュレーション (energy integrating detector モデル) からの推定値

3.2. 関心領域における「空間平均」の意味での雑音分散に関する検討

既述の関心領域における(「空間平均」の意味での)雑音分散について、これらの4か所の関心領域における結果は、2種類のX線検出器モデルについて、いずれも同様なものとなった。以下、上部に設定した関心領域に関する結果のみを示す。X線CT画像上の関心領域内の(「空間平均」の意味での)雑音分散の値の(「集団平均」の意味での)期待値について、解析的に計算した値と2種類のX線検出器モデルを使用してシミュレーションによって作成したX線CT画像からbootstrap法によって推定した値の

平均値を表 1 に示す。また、図 4 に、X 線 CT 画像上の関心領域内の（「空間平均」の意味での）雑音分散の値の（「集団平均」の意味での）期待値について、シミュレーション画像からの個々の推定値のヒストグラムを X 線検出器モデル別に示す。

表 2 上部に設定した関心領域内の雑音分散

	Variance
解析的に計算した期待値	57.31
quantum counter モデルによる推定値	57.43
energy integrating detector モデルによる推定値	54.56

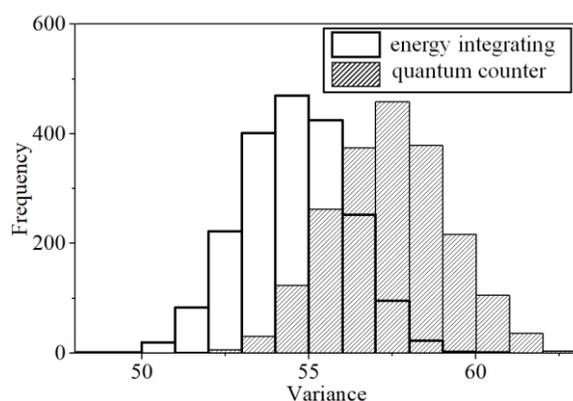


図 4 X 線 CT 画像上の関心領域内の雑音分散の値の推定値のヒストグラム

4. まとめ

今回の検討結果からは、雑音を量子雑音に限定した場合の関心領域における（「空間平均」の意味での）雑音分散の値の（「集団平均」の意味での）期待値について、X 線検出器に到達した X 線光子数のゆらぎが単純なポアソン分布に従うものとして解析的に計算した値は、quantum counter モデルのみならず、energy integrating detector モデルを使用したシミュレーション画像から推定した値ともよく一致した。また、各画素における（「集団平均」の意味での）雑音分散についても、同様に解析的に計算した値は、両モデルを使用したシミュレーション画像から推定した値とよく一致した。以上の

ことから、現在臨床の場で使用されている X 線 CT の検出器により近いモデルである energy integrating detector モデルを使用したシミュレーションによっても、X 線検出器に到達した X 線光子数のゆらぎが単純なポアソン分布に従うものとして解析的に計算する方法の精度が高いことが確認された。さらに、今回検討した 2 種類の X 線検出器モデル間で、雑音を量子雑音に限定した場合における（「空間平均」の意味での）雑音分散の値の差は少ない結果となった。今回の検討結果からは、今回検討した 2 種類の X 線検出器モデル間で CT 画像上の関心領域内の（「空間平均」の意味での）雑音分散に与える影響は少なく、同雑音分散に関する検討において簡易な quantum counter モデルは高い頑健性を有することが示唆される結果となった。

謝辞

本研究は、JSPS 科研費 18K07748 [基盤研究(C)] の助成を受けた。

利益相反の有無

なし

文 献

- [1] Gore J C, Tofts P S: Statistical limitations in computed tomography. *Phys Med Biol* **23** (6): 1176-1182, 1978
- [2] Wunderlich A, Noo F: Image covariance and lesion detectability in direct fan-beam x-ray computed tomography. *Phys Med Biol* **53** (10): 2471-2493, 2008
- [3] 梅田祐司, 池田充, 西尾俊貴 他: X 線 CT 画像上の雑音分散に関する検討. 平成 28 年度日本生体医工学会東海支部学術大会 (予稿集): A3-5, 2016
- [4] Whiting BR, Massoumzadeh P, Earl OA, et al. Properties of preprocessed sinogram data in x-ray computed tomography. *Med Phys* **33** (9): 3290-3303, 2006

Effects of detector models on noise variance in X-ray computed tomography images

Kazuya Tanoue^{*1}, Mitsuru Ikeda^{*1}, Yuuji Umeda^{*1}

Chiyo Yamauchi-Kawaura^{*1}, Keisuke Fujii^{*1}, Kuniharu Imai^{*1}

^{*1} Department of Radiological and Medical Laboratory Sciences, Nagoya University Graduate School of Medicine

We have studied the effects of two detector models, quantum counter and energy integrating detector models, on the ensemble expectation of spatial noise variance in X-ray computed tomography (CT) images, under the assumption that noise is confined to the statistical fluctuations of X-ray photons. In this study, we compared the estimated values of spatial noise variance from the simulation studies of using the two detector models and its analytically-calculated values, when the two detector models output similar values. For the two detector models, the analytically-calculated ensemble expectations of spatial noise variance were well agreed with their estimated values from the simulation studies of using a virtual X-ray CT system. Further, the difference of spatial noise variance was small between the two detector models. The results of this study show that the effects of the two detector models effects were small on spatial noise variance in X-ray computed tomography images, and that the quantum counter model was suggested to have high robustness in the studies of noise variance.

Key words: Computed tomography, Image quality evaluation, Radiation exposure dose

スパース化空間の類似性を利用した単一画像超解像

竹間 康浩^{*1)}, 大内 翔平^{*1)}, 伊藤 聡志^{*1)}

要旨

MR 画像など画素数が少ない画像を観察する場合は、画像を補間拡大することが多い。このとき、単なる補間ではなく、超解像の効果があれば生体の構造をより認識しやすくなり、画像診断の精度を高めることが期待できる。eFREBAS 変換によりスパース展開された像は全て同サイズであり、かつ、周波数帯域別に分離した像は互いに類似性を持っている。そこで、eFREBAS 空間像の類似性を利用し、eFREBAS 空間にて信号を外挿する画像補間法について検討を行った。結果、学習を必要としない提案法による補間像は、深層学習を利用した超解像法と同等の補間誤差と鮮鋭さを有することが示された。

キーワード: 超解像, 補間, 多重解像度解析, eFREBAS 変換

1 はじめに

低解像度画像から高解像度画像を生成する超解像は、光学的な撮像処理により解像度の限界を超える意味から近年のデジタル信号処理による‘ぼけ’を伴わない画像拡大処理までさまざまな意味がある。ハードウェアの性能限界を超える解像度が得られる超解像への期待は大きく、高解像度ディスプレイが普及している現代ではその応用範囲も広い。超解像を医用画像に応用することができれば、画像の細部構造の観察がより容易になり、画像診断の精度向上につながるため、その意義は大きいものがある。

超解像には使用する画像の数より大別すると、観測された 1 枚の画像から超解像画像を生成する単一画像超解像と複数の低解像度画像を合成して高解像度画像を生成する再構成型超解像がある。単一画像超解像では、情報量が増えるわけではないので、一般的に画像のぼけを抑えつつ補間拡大する手法となる。

一方、再構成型超解像は、複数の異なる画像を利用する方法が多く、周波数空間の補間により高解

像度画像を生成することも可能である [1, 2]。しかしながら、高解像度画像の全画素数を未知数とする問題を解くので画像生成に多くの時間を要する問題がある。

2010 年に Yang らは新たな超解像として学習型超解像 (Sparse coding Super Resolution: ScSR) を提案した。ScSR は、まず、スパースコーディングにより得られた基底に関して低解像度パッチと高解像度パッチとの対応関係を学習する。そして、入力された低解像度画像をパッチに分解し、それぞれのパッチに対し高解像度パッチを割り当てて高解像度画像を推定する方法である [3]。学習型超解像は 1 枚の入力画像に対し、高解像度画像を推定するので単一画像超解像と考えることもできるが、学習されたパッチの対応関係には単一画像を超える情報量が含まれているので、補間を超えた解像度の画像を生成できる可能性がある。一般に補間処理により画像を拡大すると輝度値が大きく変化するエッジは補間に伴いぼやける傾向がある。それに対し、学習型超解像ではパッチの対応関係を用いて補間画像を生成するので、エッジ部に鮮鋭さが保たれる。また、近年ではニューラルネットワークを使用して超解像を行う方法が注目されている。Dong らは、3 層の畳み込みニューラルネットワーク (Super-Resolution Convolutional Neural Network : SRCNN)[4] を使用して自然画像の超解像を試み、Yang らの方法を

*1 宇都宮大学 大学院工学研究科

情報システム科学専攻

[〒 321-8585 栃木県宇都宮市陽東 7-1-2]

e-mail:itohst@is.utsunomiya-u.ac.jp

超える信号対雑音比を持つ画像の生成に成功している。Dong らの研究を契機としてさらに多くの層からなるネットワークを使用した超解像法が提案されるようになった。Dong らは、ネットワークの層を増やし、最終層のデコンボリューションにより画像拡大を行うとともに高速化を図る方法 [5] を、Shi らは、デコンボリューションで生じることのある格子状のアーティファクトを低減する方法 [6] を、Zhang らは、画像の劣化プロセスを考慮した方法 [7] を提案している。深層学習により超解像は様々な方法が提案され、その性能は年々改善されたものとなっている。学習型超解像やニューラルネットワークを使用した方法は、従来の補間法では得られない鮮鋭な画像が得られるが、一方で学習に大量の画像と膨大な時間を必要とする問題がある。

本研究では、医用画像でも比較的画素数が少なく補間拡大処理がしばしば行われる磁気共鳴画像 (MR 画像) を対象とし、学習を必要としない単一画像超解像を提案する。MR 画像では、従来より sinc 関数を利用した補間処理が利用されている [8]。本研究では画像に対し一種の多重解像度解析を適用し、画像に由来する特徴成分の類似性を利用し、多重解像度空間で信号を外挿することによる超解像効果を含んだ画像補間法を提案する。単一画像超解像であるが、学習を必要としないため直ちに画像補間を行うことができる利点がある。これまで、 128×128 画素の MR 画像を 2 倍に拡大する処理について基本的な検討を行ってきたが [11]、本研究では、 128×128 画素と 256×256 画素の画像を 2 倍に拡大する場合について詳細に検討し、そして、提案法による補間画像を従来法および学習型超解像と比較することにより提案法を有効性を検証することを目的とする。

2 スパース表現を利用した画像補間

2.1 eFREBAS 変換

eFREBAS 変換はアルゴリズムの異なる 2 通りのフレネル変換が実質的に異なる標本化間隔を持つ性質を利用し、入力画像を任意のサイズにスケールした画像群 (サブ画像と称する) に展開する方法である。入力画像と同サイズの画素数からなり、スケール係数は任意の実数を取ることができる。ここで、簡単化のため、次元信号を扱

うものとする。変数 Δx を入力画像の画素サイズ、 N をデータ数、 m をフレネル変換された信号の折り返しの次数を表す整数、 D を画像のスケール係数とすると、eFREBAS 展開像 I_{scale} は以下の式により表現することができる [9, 10]。eFREBAS 変換では展開スケール D として任意の実数を選択できる。

$$I_{scale}(x) = \frac{1}{DN\Delta x} \sum_{s=-\infty}^{\infty} \sum_{m=-\infty}^{\infty} I(m, x) \text{comb}\left(\frac{x}{D\Delta x}\right) * \delta(x - sDN\Delta x) \quad (1)$$

$$I(m, x) = \left\{ I(x - mDN\Delta x) * \text{sinc}\left(\frac{2\pi x}{D\Delta x}\right) e^{-j\left(\frac{2m\pi x}{D\Delta x}\right)} \right\} \quad (2)$$

式 (1) の $\text{comb}(\cdot)$ はくし形関数、式 (2) の $\text{sinc}(\cdot)$ は sinc 関数を意味する。画像 $I(x - mDN\Delta x)$ が異なる帯域幅を有するバンドパスフィルタ関数 $\text{sinc}\{2\pi x/(D\Delta x)\}e^{-j2\pi mx/(D\Delta x)}$ によって畳み込まれた形となっている。eFREBAS 変換により展開された像 (サブ画像と称する) の位置と周波数空間の領域には対応関係があり、サブ画像群は一種のフィルタバンクを構成する。

2.2 画像補間アルゴリズム

入力画像を I 、フーリエ変換とその逆変換を F 、 F^{-1} 、スケール係数 D による eFREBAS 変換とその逆変換を Ψ_D 、 Ψ_D^{-1} 、拡大倍率を r とする補間拡大処理を L_r とする。まず、画像 I に対しスケール係数を D と $D+2$ とした eFREBAS 変換 $\Psi_D I$ と $\Psi_{D+2} I$ をそれぞれ求める。次に、 $\Psi_{D+2} I$ を $(D+2)/D$ 倍に補間拡大し、 $L_{(D+2)/D} \Psi_{D+2} I$ を得る。式 (3) により、 $\Psi_{D+2} I$ の最も外側の帯域像を切り出し、 $\Psi_D I$ の外側に外挿する処理 R_p を行う。 $(D+2)/D$ 倍に拡大された eFREBAS 変換像をスケール係数 $D+2$ で逆変換すると補間拡大された像 I_L を得る [11]。

$$I_L = \Psi_{D+2}^{-1} [\Psi_D I + R_p L_{(D+2)/D} \Psi_{D+2} I] \quad (3)$$

図 1 を使用して $D=3$ とした場合で式 (3) のアルゴリズムを説明する。(a) に示す入力画像 I をスケール係数 $D=3$ で eFREBAS 変換した像が (d) であり、 $D \times D$ の数のサブ画像に分離される。

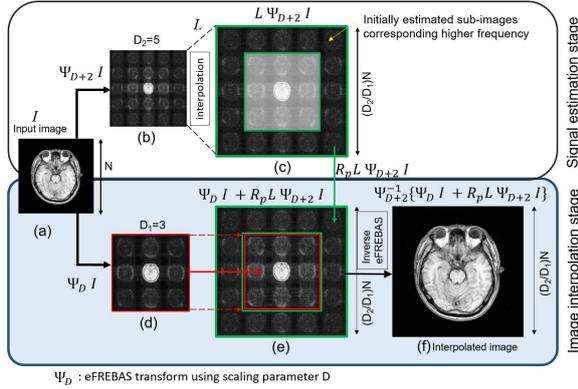


図 1: eFREBAS 変換を利用した画像の補間拡大アルゴリズム

Algorithm 1 Image interpolation by CSA

- 1: **Input** $\rho = 1/L, \alpha, \beta, J_0 = I_L$
- 2: **for** $i = 1$ to number of iteration **do**
- 3: $I_g = J^k - \rho F^{-1}(v - EFR^k)$
- 4: $I_1 = \text{prox}_\rho(2\alpha \|I\|_{BM3D})(I_g)$
- 5: $I_2 = \text{prox}_\rho(2\beta \|\Psi I_L\|_1)(I_g)$
- 6: $I^k = (I_1 + I_2)/2$
- 7: $J^{k+1} = I^k$
- 8: **end for**

図 (d) の外側のサブ画像を推定できれば、超解像効果を持った画像拡大が可能となる。サブ画像を展開像の両端に外挿すると、結果として展開像は $(D+2) \times (D+2)$ のサブ画像から構成されるから、スケーリング係数は $D+2$ となる。本研究では、入力画像を $D+2$ で eFREBAS 展開した像 (b) の最外郭のサブ画像は、(e) の最外郭に入るべきサブ画像の分布に類似している特徴を利用する。すなわち、サブ画像のサイズを揃えるために (b) の画像を $(D+2)/D$ 倍に拡大し、 $L_{(D+2)/D} \Psi_{D+2} I$ を作成する。次に、緑色の枠で囲んだ最も外側のサブバンド像を抽出する操作 R_p により $R_p L_{(D+2)/D} \Psi_{D+2} I$ を (e) の eFREBAS 信号の外側に外挿する。そして、(e) の信号をスケーリング係数 $D+2$ で逆 eFREBAS 変換 (Ψ_{D+2}^{-1}) すれば、補間拡大された像を得ることができる。以後、2 種類のスケーリング係数 $D_1 = D$ と $D_2 = D+2$ を使用した提案法を eFREB-SR(D_1, D_2) と表すことにする。

補間外挿した eFREBAS 信号は、誤差を含むため、スパース性を利用した誤差の軽減を式 (4) により行う。スパース性を与える Ψ の基底は、アーティファクト除去の観点から式 (3) で使用したものと異なる

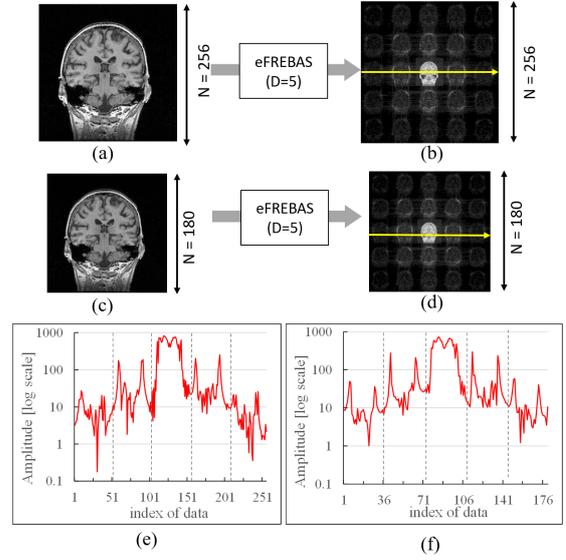


図 2: サイズの異なる入力画像に対する eFREBAS 展開像の相似性: (a) 256×256 画素の画像, (b) 画像 (a) の eFREBAS 展開像 ($D=5$), (c) 180×180 画素の画像, (d) 画像 (c) の eFREBAS 展開像 ($D=5$), (e), (f) それぞれ (b) と (d) の黄線上の信号強度分布

関数がよく、本研究では、スケーリング係数の異なる eFREBAS 変換を使用した。式 (3) により得られた像を下記の制約付き最小化問題を適用する。

$$\operatorname{argmin} \left\{ \frac{1}{2} \|v - EFL\|_2^2 + \alpha \|\Psi I_L\|_1 + \beta \|I_L\|_{BM3D} \right\} \quad (4)$$

ここで、 v は MR 信号、 Ψ はスパース化関数、 $\|\cdot\|_{BM3D}$ は Block Matching and 3 Dimensional Collaborative filter (BM3D)[12] によるノルム、 E は、フーリエ変換空間の信号のうち原点を中心として元画像と同じデータ数だけ抽出する処理を意味する。式 (4) は、異なるノルムを含んだ最小化問題となっている。この複合ノルム最小化問題を解く方法として本研究では、CSA(Composit Split Algorithm)[13] を用いた。CSA のアルゴリズムを **Algorithm 1** に示す。L は、リプシッツ係数、 α と β は、L1 ノルムと BM3D ノルムに対する重みである。

3 補間拡大実験

eFREBAS 変換によりスパース化された空間の類似性をみるために、異なる画像サイズの eFREBAS 展開像を比較した。画素サイズが 256×256 と

180×180 の同種の MR 画像をそれぞれを $D=5$ で eFREBAS 展開した像を図 2(b),(d) に示す. なお, 180点は256点のおよそ5/7に相当する. eFREBAS 展開図の黄線上の強度分布を図示したものが (e) と (f) である. 元画像のサイズは異なるが, eFREBAS 展開したサブ画像は, 高信号が現れる位置等で相似性があることがわかる. これは, 式 (2) にあるようにバンドパスフィルタ関数で入力画像を畳み込み積分した結果が eFREBAS 展開のサブ画像になることからわかる. 入力画像のサイズが異なっても, 展開像の輪郭を周波数成分別に分離するサブ画像の分布は相似的な分布になる性質がある. 本研究では, 図 2(b) の最も外側のサブ画像が未知であるという問題設定において, 画像サイズが小さいが同じ展開スケールの eFREBAS 展開像 (d) の最外郭のサブ画像を利用し, 拡大画像を生成するものである.

提案手法を使用し, 画像中央からの距離に応じて振幅振動の周波数が大きくなるガボールレンズに似たチャート画像の補間拡大を行った. 図 3(a) に示す 256×256 画素の画像を用意し, そのフーリエ変換信号のうち, 中央 128×128 点の信号から構成される帯域制限像 (b) を入力の低解像度画像とする画像の補間拡大を行った. 画像 (b) アルゴリズム 1 に従い eFREBAS 変換の $D = 3$ で展開した像の外側に, $D = 5$ で展開し補間拡大した eFREB-SR(3,5) 像を作成した. α と β は, スパース化空間と BM3D 処理のしきい値処理にかかわる値である. 入力画像の最大輝度値を 1.0 とするとき, しきい値の終値は $1.96 \times 10^{-3} (= 0.5 \times 1/255)$ とした. 式 (4) の Ψ には, 画像拡大に使用した基底と異なる eFREBAS 変換の $D = 4$ と 7 の基底を交互に使用した. 展開スケール $D = 3$ と 5 を使用した場合に 128×128 画素の拡大像は, $214 (\approx 128 \times 5/3)$ 画素となるが, 拡大率を 2 倍とするために補間像のフーリエ変換空間においてゼロフィル外挿を行い, 256×256 画素の画像とした. 比較のために, MR 信号の外側にゼロデータを外挿し, 逆フーリエ変換することにより得られる sinc 関数補間, ニューラルネットワークを使用した超解像法として SRCNN(Super-Resolution Convolutional Neural Network) [4] を, 深層学習を使用した方法として MS-D-Net(The mixed-scale dense convolutional network)[7] を使用した補間を実施した. このチャート図は人工的な画像なので

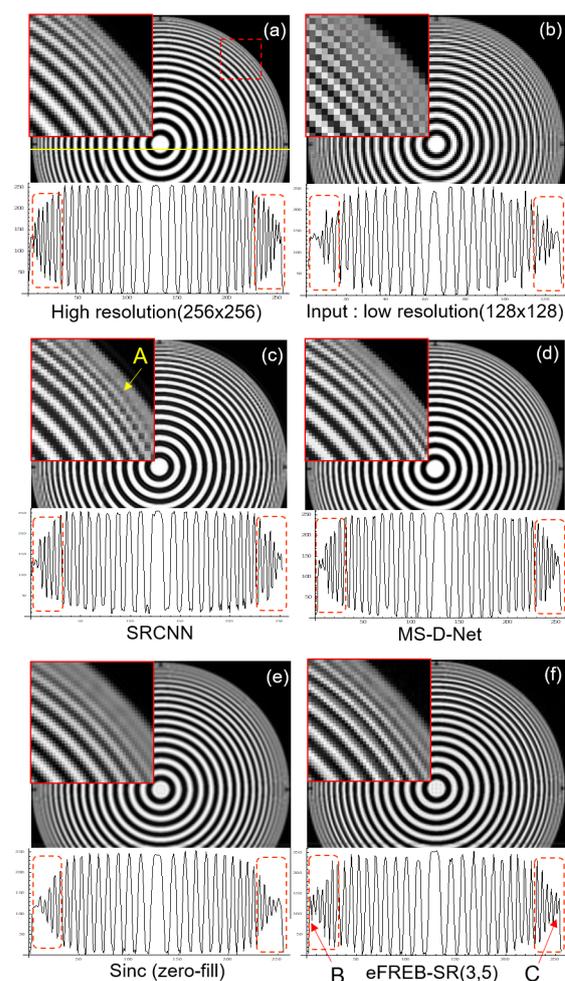


図 3: 評価画像の補間拡大結果: (a) 目標とする高分解能画像 (256×256 画素), (b) 入力画像として使用した (a) の低解像度画像 (128×128), (c) SRCNN, (d) SRMD, (e) sinc 関数補間 (zerofill), (f) eFREBAS-SR (3,5), (a) の赤枠の拡大図と (a) 図の黄線上の振幅分布を示す.

SRCNN と MS-D-Net では MR 画像ではなく, 自然画像で学習したモデルを使用して拡大を行った. 結果を図 3 に示す. 細部の構造を見やすくするために, 各画像において図 (a) の赤枠部に対応する拡大図を左上に示す. また, 図 (a) の黄線部上の振幅分布を下に示す. 拡大図の矢印 A の部分を見ると SRCNN は, 入力画像 (b) では認識できない細かい縞模様を復元できているが, 入力画像のジャギーをそのまま拡大した形となっており縞模様の輝度値変化が滑らかでない. sinc 関数補間は滑らかな補間像が得られているが, 縞模様は解像度は入力画像の (b) と同程度である. (d) の MS-D-Net

表1 各画像補間法の PSNR と SSIM

method	128 → 256		256 → 512	
	PSNR	SSIM	PSNR	SSIM
Sinc	28.08	0.9535	31.73	0.9488
Bicubic	26.56	0.9379	30.38	0.9365
ScSR	28.38	0.9573	31.77	0.9500
SRCNN	28.48	0.9549	31.81	0.9516
MS-D-Net	29.32	0.9621	32.38	0.9523
eF-SR(1,3)	29.21	0.9614	32.26	0.9527
eF-SR(3,5)	28.63	0.9556	31.83	0.9500

eF-SR(1,3) と eF-SR(3,5) は、それぞれ eFREB-SR(1,3) と eFREB-SR(3,5) を示す。

は (c) のようなジャギーは殆どみられず、細かい振動が復元されている。(f) の提案法による像は sinc 関数補間に似て滑らかに補間処理が行われ、かつ sinc 関数補間よりも解像度の高い画像が得られた。振幅分布の比較では、赤い破線枠の中で SRCNN と MS-D-Net は sinc 関数補間に比べて高い振動成分の復元精度が高く、(b) を超える振動成分が復元されている。(f) の eFREB-SR では、赤枠内 B と C の画像端で振動成分の振幅が (d) や (e) の画像より大きく、さらに良好な復元が行われていることがわかる。

次に MR 像を対象とした画像拡大実験を行った。学習と評価に使用した画像はすべて文書により同意を得たボランティア像である。ScSR と SRCNN ではキャノンメディカル製 1.5T MRI を使用して撮像された 100 枚の画像を学習に使用した。評価には学習に使用していない 10 枚の画像を使用した。比較法として図 3 で使用した方法に ScSR[3] を加えて画像補間を行った。実験は 256×256 画素と 512×512 画素の高解像度画像からそれぞれ 128×128 画素と 256×256 画素の低解像度画像を作成し、低解像度画像を 2 倍に拡大する処理を行った。評価方法は、高解像度画像と補間拡大像の平方平均二乗誤差を画素値の最大値との比を取る PSNR (peak signal-to-noise ratio)、および画像が持つ構造的な特徴の保存性を評価する SSIM (structural similarity index)[14] を使用した。

$$\text{PSNR} = 20 \log_{10} \frac{\max[I_L]}{\text{RMSE}} \quad (5)$$

PSNR と SSIM の評価結果を表 1 に示す。ScSR と SRCNN は、いずれも Bicubic や sinc 関数補間よ

り高い PSNR と SSIM 値を示した。MS-D-Net は、比較した補間法の中で平均的に最も高い PSNR であり、補間に伴う誤差が少ないことがわかる。提案法では、eFREB-SR(1,3) が eFREB-SR(3,5) とともに高い PSNR 値であったが、eFREB-SR(1,3) の方がやや高い PSNR と SSIM 値を示し、MS-D-Net に近い値が得られた。

4 まとめ

画像のスパース表現として eFREBAS 変換を利用し、スパース化された空間における分布の相似性を利用した画像拡大法について検討を行った。分解能評価用に使用した実験と MR 画像を使用した実験とから提案法は sinc 関数補間よりも鮮鋭であり、ディープラーニングを使用する MS-D-Net に比肩する高い PSNR と分解能を有する画像が得られることが示された。今後は、拡大率の変更やさらなる高分解能化について検討を行う予定である。

謝辞

本研究の一部は、科学研究費助成金 (16K06379, 19K04423) により実施された。また、MR 画像を提供いただいたキャノンメディカルシステムズに感謝の意を表します。

利益相反の有無
なし。

文献

- [1] Tsai R, Huang T: Multiframe Image Restoration and Registration. *Adv Comput Vis Image Process*, **1**: 317–339, 1984
- [2] Stark H, Oskoui P: High-resolution Image Recovery from Image Plane Arrays, using Convex Projections. *J Opt Soc Am A, Opt Image Sci*, **6**: 1715–1726, 1989
- [3] Yang J, Wright J, Huang T et al.: Image Super-resolution via Sparse Representation. *IEEE Trans Image Process*, **19**: 2861–2873, 2010
- [4] Dong C, Loy CC, He K et al. : Image Super-resolution using Deep Convolutional Networks. *IEEE Trans on PAMI*, **38**: 295–307, 2015
- [5] Dong C, Loy CC, Tang X : Accelerating the Super-Resolution Convolutional Neural Network. *European Conference on Computer Vision (ECCV)*: 391–407, 2016

- [6] Shi W, Caballero J, Hszar F et al. : Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR): 1874–1883, 2016
- [7] K Zhang, W Zuo, L Zhang : Learning a Single Convolutional Super-resolution Network for Multiple Degradations. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR): 3262–3271, 2018
- [8] 高橋哲彦, 瀧澤将宏: MRI 画像再構成のオーバービュー. *Medical Imaging Technology* **31**: 26–31, 2013
- [9] Ito S, Yamada Y: Multiresolution Image analysis using dual Fresnel transform Pairs and Application to Medical Image Denoising. *IEEE ICIP2003 Map8.7*, Barcelona, Spain, 2003
- [10] 伊藤聡志, 山田芳文: 拡張 FREBAS 変換を利用した雑音画像の多段階鮮鋭化. *信学論 J93-D*: 999–1008, 2010
- [11] 竹間康浩, 柴田光貴, 伊藤聡志: スパースコーディングを利用した単一画像超解像に関する検討. 第 37 回日本医用画像工学会大会, OP7-3: 262–268, 2018
- [12] Davov K, Foi A, Katkovnik V et al.: Efficient MR image reconstruction for compressed MR imaging. *Medical Image Analysis* **15**: 2080–2095, 2007
- [13] Huan J, Zhang S, Metaxas D: Image denoising by sparse 3D transform-domain collaborative filtering. *IEEE Trans Image Proc* **16**: 2080–2095, 2007
- [14] Wang Z, Bovik AC, Sheikh HR et al. : Image Quality Assessment :From Error Visibility to Structural Similarity. *IEEE Trans. Image Process* **13**: 600–612, 2004

Single-image Super Resolution using the Similarity of Sparsified Space

Yasuhiro CHIKUMA*1, Shohei OUCHI, Satoshi ITO*1

*1 Graduate School of Engineering, Utsunomiya University

Higher spatial resolution is required in many image processing applications, therefore, super-resolution has attracted attentions in recent years. If super-resolution can be applied to the sectional image of a living tissue, it will improve the accuracy of image diagnosis. In this study, a new image magnification method is proposed and demonstrated, in which the eFREBAS transform is used as sparse coding. Obtained images were compared with learning based super-resolution method (ScSR) in terms of PSNR and SSIM. Experiments showed that obtained images in proposed method showed comparative PSNRs and SSIMs to Deep Learning based method for MR images. In addition, interpolated images have higher resolution and have much more details of the subject than that of Dictionary based method. These studies indicate that proposed method is effective for image magnification of medical images.

微小金属のアーチファクト補正を目的とした

X線トモシンセシス装置の検討

山川 恵介*¹ 高橋 啓子*² 中村 正*²

要旨

近年、乳房や整形で用いられる X 線トモシンセシスにおいて、代表的なフィルタ補正逆投影法 (Filtered Back Projection method : 以下、FBP 法) [1]では投影データの角度欠損により、金属と軟部組織間等の吸収値差が大きい条件で金属アーチファクトが増加する。これを低減するため、断層画像撮影では画像の金属位置に基づく投影データの補間法が用いられるが、トモシンセシスでは位置毎のアーチファクトのばらつきが大きく画像上の金属抽出が困難であった。報告者は JAMIT2018 にて、全ての投影角度の投影データを仮想 3 次元データとし、3 次元領域拡張法を用いた投影データ金属抽出法を提案したが、ピン等の小さな金属になるほど角度方向の領域拡張の精度が低下する課題があった。そこで小さい金属の抽出精度向上を目的として、投影角度間の金属の相関情報を用いる方法を提案する。整形用固定具を模擬したファントム実験において、周辺領域の画質を維持し高いアーチファクト低減効果が得られたので報告する。

キーワード：トモシンセシス、金属アーチファクト補正

1. はじめに

近年、乳房や整形外科領域において、X 線デジタルトモシンセシス (以下、トモ) 装置が用いられている。DT 装置は、X 線診断装置の検出器を固定または移動させながら、被写体を一部の投影角度から撮影し、X 線投影データから被写体の X 線吸収係数を示す断層像 (以下、トモ画像) を得る装置である。DT 装置は近年 CT で用いられる FBP 法の応用により、各種診断で臨床応用されている[2]。

トモ装置は、180 度以上の方向から撮影する X 線 CT と比較して、20 度や 40 度の一部

の投影角度で収集される為、角度欠損によりアーチファクトが発生する課題がある。FBP 法によるトモ画像では、特に金属と骨梁間等の吸収値差が大きい条件で金属アーチファクトが増加する。これを低減する為、X 線 CT では画像の金属位置に基づく投影データの補間法[3]が用いられるが、トモ装置では位置毎の金属アーチファクトのばらつきが大きく画像上の金属抽出が困難で、境界部の金属アーチファクト低減が不十分な場合がある。これまで 3 次元領域拡張法を用いた投影データ金属抽出法を提案している[4]が、ピン等の小さな金属になるほど角度方向の領域拡張の精度が低下する課題があった。そこで小さい金属の抽出精度向上を目的として、投影角度間の金属の相関情報を用いる方法を提案する。整形用固定具を模擬したファントム実験において、周辺領域の画質を維持し高いアーチファクト低減効果が得られたので報告する。

*1 日立製作所 研究開発グループ

〒185-8601 国分寺市東恋ヶ窪 1-280

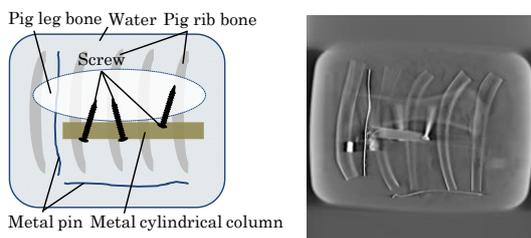
e-mail: keisuke.yamakawa.fd@hitachi.com

*2 日立製作所 ヘルスケアビジネスユニット

2. 方法

従来法[4]では、全ての投影角度 θ の投影データ (x, y) から成る仮想3次元データ (x, y, θ) 上で、操作者が金属の一部を代表開始点として選択し、領域拡張法により金属を抽出する。次に抽出後の金属に対して、周辺情報との差が小さくなるよう投影データの値を抑制する。金属抑制後の投影データにFBP再構成を実施後、別途作成した金属画像の位置に基づき、トモ画像上の抑制された金属の値を復元する。これによりFBP再構成時、金属と周辺情報の差が小さくなる為、金属アーチファクトを低減できる。一方、ピン等の小さな金属になるほど隣接する投影角度間の金属が不連続となることで、角度方向の領域拡張の精度が低下する課題があった。そこで抽出精度を向上するため、投影角度方向に不連続な金属を擬似的な連続体に変換する。従来法に加えて、零平均正規化相互相関[5]を用いたパターンマッチングにより連続体に変換する角度マッチング処理法を提案した。

X線透視診断装置EXAVISTA（日立製）のトモ機能を用い、X線の照射条件は管電圧70kV、管電流160mA、撮影時間14msec/投影、投影角度40度、投影数75とした。画像評価の為、図1に示すように整形外科用の人工股関節の装着に必要なスクリューとピンを想定し、豚の骨に固定したファントムを用いた。



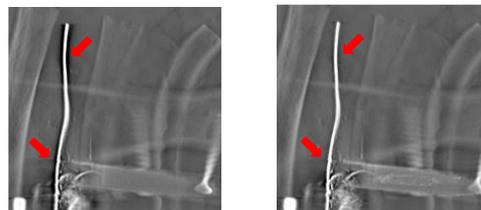
(a) ファントム概観 (b) トモ画像

図1 ファントム実験

3. 結果

従来の金属抽出法、提案法において、ピン周辺を拡大したトモ画像を図2に示す。図2(a)の従来法では、X線源の回転方向に相当する横方向への負値の金属アーチファクト成

分（矢印2箇所）が大きいが、図2(b)の提案法により低減でき、金属アーチファクトに埋もれた組織情報を確認できた。



(a) 従来法 (b) 提案法

図2 ファントムにおける従来法、提案法の比較

4. まとめ

本報告では従来の領域拡張ベースの金属抽出法に加えて、相関係数を用いたパターンマッチングにより連続体に変換する角度マッチング処理法を提案した。本方法により挿入する金属の大小によらず、高精度な金属アーチファクト低減効果を期待できる。

利益相反の有無

山川恵介、高橋啓子、中村正は㈱日立製作所の社員である。

販売名：汎用X線透視診断装置 EXAVISTA
医療機器認証番号：220ABBZX00236000

文献

- [1] Feldkamp, L. A., et al: Practical cone-beam algorithm. J. Opt. Soc. Am, A1, pp612-619, 1984
- [2] H. Machida, et al: Whole-Body Clinical Applications of Digital Tomosynthesis. Radiographics, 36(3), pp735-750, 2016
- [3] W. A. Kalender, et al: Reduction of CT Artifacts Caused by Metallic Implants. Radiology, pp576-577, 1987
- [4] 山川恵介他：X線トモシンセシス装置における金属アーチファクト補正技術の検討. 第37回日本医用画像工学会大会予稿集：225-226, 2018
- [5] 橋本学：テンプレートマッチングの魅力. 第19回画像センシングシンポジウムチュートリアル講演会, 2013

Evaluation of Artifact Correction for Small Metal in X-ray

Tomosynthesis

Keisuke YAMAKAWA^{*1}, Keiko TAKAHASHI^{*2}, Tadashi NAKAMURA^{*2}

*1 Hitachi, Ltd. Research & Development Group

*2 Hitachi, Ltd. Healthcare Business Unit

The X-ray digital tomosynthesis (DT) image reconstructed by limited projection angles causes severe metal artifacts compared with CT acquired at over 180 degrees. The region growing (RG) was applied to detect metal in the projection data. The conventional method which we proposed in 2018 needs accurate metal extraction based on 3D region growing. The method cannot extract small metals such as pins, because of discontinuity of the metal in 3D projection data. A novel method is proposed to separate the metal from projection data by combining pattern matching between neighboring projection angle. The proposed method was compared with the conventional method based on 3D region growing. In the phantom, the proposed method reduced the metal artifact close to metals.

Key words: Tomosynthesis, Metal Artifact Correction

敵対的生成ネットワークを利用した MR 圧縮センシング

再構成の基礎検討

大内 翔平*¹, 伊藤 聡志*¹

要旨

MRI の撮像高速化を目的として圧縮センシングが応用されているが、画像再構成には L1-L2 ノルム最小化問題を解くための反復処理が必要であり、極めて多くの時間を要する。また、再構成像に人工的な様相が生じる場合がある。

近年では CNN を利用した圧縮センシング再構成が提案されており、再構成像の品質および、再構成時間の面で従前の反復処理を伴う解法よりも優れることから、大きな注目を集めている。本研究では、2 つの CNN を敵対的に学習させる生成モデルである、敵対的生成ネットワーク(Generative Adversarial Network : GAN)を圧縮センシング再構成に適用し、既存の反復的再構成法と比較した画質評価を行った。

キーワード：GAN, 圧縮センシング, 再構成, CNN

1. はじめに

MRI(Magnetic Resonance Imaging)では、X 線 CT と比較して患者への負担を最小限に留めながら、高品質な画像を得ることが可能である。しかし、撮像には極めて多くの時間を要する問題がある。これは信号収集に時間を要することに起因しており、撮像時間を高速化するための数々の手法が提案されている。なかでも、圧縮センシング(Compressed Sensing : CS)[1][2]を MRI の画像再構成に応用する手法[3]は、大きな注目を集めている。CS によれば、サンプリング定理を満足しない少数信号からの画像再構成が可能のため撮像時間が短縮化される。しかし、再構成では L1-L2 ノルム最小化問題を反復的に解くことから、再構成処理に極めて多くの時間を要する。

一方で、近年では CNN(Convolutional Neural

Network)を利用した CS 再構成の研究が進められている[4]。CNN による再構成法は、学習に時間を要することが課題であるが、一度学習を行えば、反復処理を伴わない高速な再構成が可能であり、これまでに種々の方式が提案されている[5][6][7][8]。また、CNN による再構成法は、再構成像の品質と再構成時間の面で、従来の反復的再構成法よりも優れた性能を示すことが報告されており、大きな注目を集めている[9][10]。

加えて、近年の一般的な画像処理問題では、敵対的生成ネットワーク(Generative Adversarial Network : GAN)を利用した研究が盛んである[11]。GAN は元来、ランダムノイズを元に画像を生成する、生成モデルの一種であるが、拘束条件を与えることで生成データの制御を可能とした conditional GAN[12]も存在する。conditional GAN の登場により、画像間の変換処理にも GAN が応用[13]され始め、従来の CNN よりも優れた性能を発揮することから GAN の利用が急速に拡大し

*1 宇都宮大学大学院 工学研究科
情報システム科学専攻
〒321-8585 栃木県宇都宮市陽東 7-1-2
e-mail: mt186504@cc.utsunomiya-u.ac.jp

ている。

そこで、本研究では再構成像の品質を改善することを目的として conditional GAN をベースとした、CS 再構成の基礎検討を行った。既存の反復的再構成法および他の CNN による再構成法との比較検討を通して、本手法の有効性を検討することを目的とする。

2. 敵対的生成ネットワーク(GAN)

敵対的生成ネットワーク(GAN)は、Goodfellow ら[11]が提案した、ニューラルネットワーク(NN)を用いた生成モデルであり、generator (生成器) と discriminator (識別器) の2つの NN から構成される。generator は、与えられた教師データに類似したデータを生成できるように学習を行う。一方の discriminator には、generator が生成したデータと教師データが共に与えられ、それらを正しく識別できるように学習を行う。2つの NN を敵対的に学習させることで、最終的には discriminator が教師データと誤認識するような精度のデータを generator で生成することを目指す。

NN による画像処理問題では、CNN を用いることが一般的である。GAN においても、画像処理問題に応用するために、ネットワークに CNN を利用する DCGAN(Deep Convolutional GAN)が Radford ら[14]によって提案された。

また、GAN の NN にテキストや画像などの情報を拘束条件として与えることで、特定の入力データに対して所望の処理を施した出力が得られる GAN(conditional GAN)が Mirza ら[12]によ

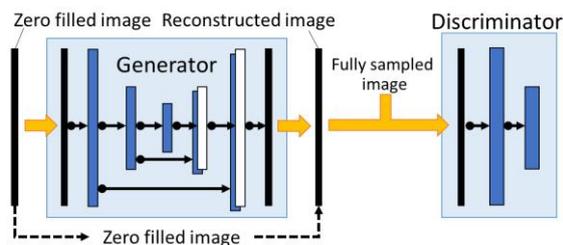


図 1 GAN による再構成ネットワークの概要図

て提案されている。

3. 圧縮センシング再構成への応用

本研究では、Yang ら[15]が提案した手法をベースに、conditional GAN による CS 再構成を行う。本手法の概要を図1に示す。generator は U-Net[16] をベースとした全 16 層の CNN である。前半 8 層が畳み込み、後半 8 層が逆畳み込みであり、各層が Batch Normalization と leaky ReLU を持つ構成である。一方の discriminator は、全 11 層の CNN であり、各層が畳み込み・Batch Normalization・leaky ReLU を持つ構成である。各 CNN の出力層の活性化関数には、generator に hyperbolic tangent 関数を、discriminator に sigmoid 関数を使用している。本手法では、generator にエイリアシングアーチファクトが重畳されたゼロフィル再構成像を与え、アーチファクトを除去した再構成像を生成する。discriminator が、この再構成像を教師データとして与えたフルデータ像と誤認識するまで学習を行う。conditional GAN をベースとした本手法の損失関数は以下で与えられる。 θ_D, θ_G は CNN のパラメータを、 x_t はフルデータ像を、 x_u はゼロフィル再構成像を示している。また、 $D(x)$ は discriminator が、 x を教師データと識別する確率を示している。したがって、generator は式(1)を最小化することを目指し、discriminator は式(1)を最大化することを目指す。

$$\begin{aligned} \min_{\theta_G} \max_{\theta_D} \mathcal{L}_{GAN}(\theta_D, \theta_G) \\ = \mathbb{E}_{x_t \sim p_{train}(x_t)} [\log D_{\theta_D}(x_t)] \\ + \mathbb{E}_{x_u \sim p_G(x_u)} [-\log(D_{\theta_D}(G_{\theta_G}(x_u)))] \end{aligned} \quad (1)$$

本手法の generator では式(1)の右辺第2項に加え、フルデータ像と generator による再構成像の画像空間・信号空間での平均二乗誤差と perceptual loss[17]の計4要素の和を損失関数として用いる。perceptual loss の導出には、ImageNet で学習を行った VGG16[18]を使用した。

4. 画像再構成シミュレーション

4.1 学習・検証および再構成用画像

本研究では GAN の学習・検証および再構成のテストに IXI dataset[19]に含まれる頭部のプロトン密度強調像を使用した。使用した画像はいずれも Philips 製の 1.5T の MRI を用いて撮像されており、画像サイズが 256×256 の位相情報を持たない絶対値画像である。また、学習と検証には 100 名分の計 12,955 枚の画像（学習用に 70%、検証用に 30% を使用）を、再構成には 1 名分の計 40 枚の画像を使用した。

学習時のデータセットは、入力データをゼロフィル再構成像、教師データをフルデータ像とする。ゼロフィル再構成像は、フルデータ像の k 空間に対して図 2 に示す 2 次元ランダム収集および 1 次元ランダム収集を適用し、信号の非収集点にゼロデータを挿入して作成した。いずれの信号収集点分布も、信号量は 40% である。

4.2 既存手法との比較

本研究では、GAN による再構成法との比較として、既存の反復的再構成法である、反復的ソフトしきい値法 (ISTA)[3] による再構成を行った。再構成像の画質評価には PSNR (Peak Signal-to-Noise Ratio) と SSIM (Structural SIMilarity index)[20] を使用した。

また、本研究では表 1 に示す環境の計算機を使用しており、GAN の学習・再構成には GPU を使用した。GAN の学習には、約 8 時間を要した。

表 1 計算機環境

CPU	Intel Core i7-7700 (3.6GHz)
RAM	32GB (DDR4-2400)
GPU	NVIDIA GeForce GTX1080Ti
Software	Python 3.5 Tensorflow 1.10.0 CUDA Toolkit 9.0 / cuDNN 7.0.5

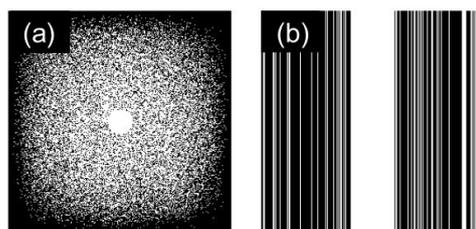


図 2 信号収集点分布: (a) 2次元ランダム収集, (b) 1次元ランダム収集

4.3 画像再構成

2次元ランダム収集を適用した際の再構成結果を図3に、1次元ランダム収集を適用した際の再構成結果を図4に示す。また、再構成像の PSNR, SSIM を表2に示す。

2次元ランダム収集を適用した場合、ISTA では被写体構造を概ね復元できたが、平滑化が目立っていた。GAN による再構成では、アーチファクトの残留および、被写体構造の損失が見られたが、ISTA よりも再構成像が鮮鋭であった。

1次元ランダム収集を適用した場合、ISTA では平滑化処理の影響が強く、脳溝が潰れている箇所も見られた。GAN による再構成では、アーチファクトの残留が僅かに見られるものの、被写体構造は良好に描出できていた。

表2より、1次元ランダム収集では GAN による再構成像の PSNR, SSIM が ISTA を上回る結果となった。

5. 考察

図3および図4の再構成結果より、反復的再構成法である ISTA では、平滑化が目立っていた。反復的再構成法では、再構成処理の際に Total Variation を行うが、この影響が強く現れたことに起因する。

GAN では、2次元ランダム収集を適用した場合、被写体構造の保存性が 1次元ランダム収集を適用した場合より劣っていた。これは、CNN に入力したゼロフィル再構成像の被写体構造の消失度合いに依存することが原因である。ゼロフィ

ル再構成像に生じるアーチファクトは、2次元ランダム収集ではインコヒーレントであるが、1次元ランダム収集ではコヒーレントである。生じるアーチファクトの性質の違いにより、ゼロフィル再構成像における被写体構造の保持に関しては、1次元ランダム収集を適用した方が良好であり、CNNでの再構成処理が2次元ランダム収集よりも容易であったと考えられる。

6. まとめ

本研究では、敵対的生成ネットワーク(GAN)を用いた Image Domain Learning による圧縮センシング再構成について、基礎検討を行った。シミュレーションの結果、再構成に成功し、GANによる再構成法の有効性を確認できた。今後は画質の改善に向けた CNN の調整や学習枚数の増加、様々な信号量での学習等を行う予定である。

謝辞

本研究の一部は、科学研究費助成(16K06379, 19K04423)により実施された。また、本研究を遂行する際に利用した IXI Dataset を提供する Information eXtraction from Images プロジェクトに感謝の意を表す。

利益相反の有無

なし

文献

- [1] Donoho DL: Compressed sensing. IEEE Transactions on Information Theory, **52** : 1289-1306, 2006
- [2] Candès EJ, Wakin MB: An Introduction To Compressive Sampling. IEEE Signal Processing Magazine, **25** : 21-30, 2008
- [3] Lustig M, Donoho DL, Pauly JM: Sparse MRI: The application of compressed sensing for rapid MR imaging. Magnetic Resonance in Medicine, **58** : 1182-1195, 2007
- [4] Wang S, Su Z, Ying L et al: Accelerating magnetic resonance imaging via deep learning. IEEE 13th International Symposium on Biomedical Imaging, Prague, Czech Republic, 2016, pp.514-517
- [5] Han Y, Ye JC : k-Space Deep Learning for Accelerated MRI, arXiv:1805.03779v1
- [6] Lee D, Yoo J, Tak S et al: Deep Residual Learning for Accelerated MRI Using Magnitude and Phase Networks. IEEE Transactions on Biomedical Engineering, **65** : 1985-1995, 2018
- [7] Zhu B, Liu JZ, Cauley SF et al: Image reconstruction by domain-transform manifold learning. Nature, **555** : 487-492, 2018
- [8] Akçakaya M, Moeller S, Weingärtner S et al: Scan-specific Robust Artificial-neural-networks for k-space Interpolation (RAKI) reconstruction: Database-free Deep Learning Reconstruction for Fast Imaging. Magnetic Resonance in Medicine, **81** : 439-453, 2019
- [9] Han Y, Yoo J, Kim HK et al: Deep Learning with Domain Adaptation for Accelerated Projection-Reconstruction MR. Magnetic Resonance in Medicine, **80** : 1189-1205, 2018
- [10] Schlemper J, Caballero J, Hajnal JV et al: A Deep Cascade of Convolutional Neural Networks for Dynamic MR Image Reconstruction. IEEE transactions on Medical Imaging, **37** : 491-503, 2018
- [11] Goodfellow IJ, Pouget-Abadie J, Mirza M et al: Generative Adversarial Nets. the 27th International Conference on Neural Information Processing Systems, Montreal, Canada, 2016, pp.2672-2680
- [12] Mirza M, Osindero S: Conditional Generative Adversarial Nets, arXiv:1411.1784v1
- [13] Isola P, Zhu JY, Zhou T et al: Image-to-Image Translation with Convolutional Adversarial Networks. the 2017 IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, USA, 2017
- [14] Radford A, Metz L, Chintala S: Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks, the 4th International Conference on Learning Representation, San Juan, Puerto Rico, 2016
- [15] Yang G, Yu S, Dong H: DAGAN: Deep De-Aliasing Generative Adversarial Networks for Fast Compressed Sensing MRI Reconstruction, IEEE Transactions on Medical Imaging, **37** : 1310-1321, 2018
- [16] Ronneberger O, Fischer P, Brox T: U-Net: Convolutional Networks for Biomedical Image Segmentation. Medical Image Computing and Computer-Assisted Intervention, Munich, Germany, 2015, pp.234-241

[17] Johnson J, Alahi A, Fei-Fei L: Perceptual Losses for Real-Time Style Transfer and Super-Resolution, European Conference on Computer Vision 2018, Amsterdam, The Netherlands, 2018

[18] Simonyan K, Zisserman A: Very deep convolutional networks for large-scale image recognition, the 3th International Conference for Learning Representations, San Diego, USA, 2015

[19] IXI dataset. <https://brain-development.org/ixi-dataset/>

[20] Wang Z, Bovik AC, Sheikh HR et al : Image Quality Assessment: From Error Visibility to Structural Similarity. IEEE Transactions on Image Processing, **13**: 600-612, 2004

表 2 再構成像の PSNR, SSIM

Pattern	ISTA		GAN	
	PSNR[dB]	SSIM	PSNR[dB]	SSIM
2D random	33.04	0.9547	30.49	0.9561
1D random	27.83	0.8972	30.19	0.9530

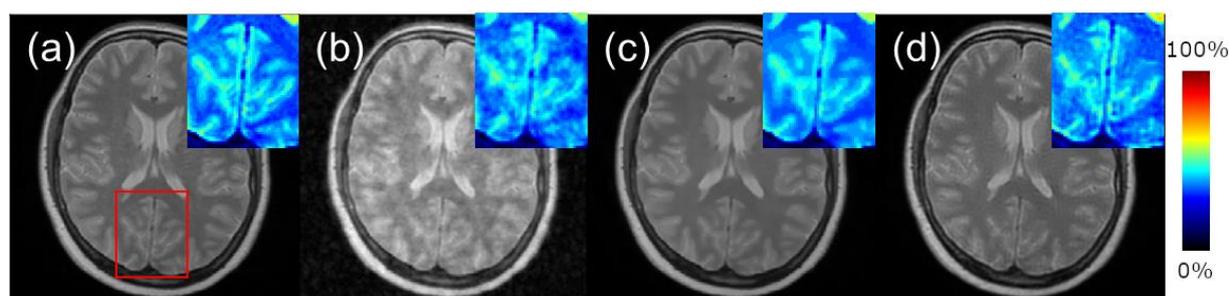


図 3 2次元ランダム収集適用時の再構成結果 : (a)フルデータ像, (b)ゼロフィル再構成像, (c)ISTAによる再構成像, (d)GANによる再構成像, 注目箇所の拡大図を(a)-(d)の右上に示す

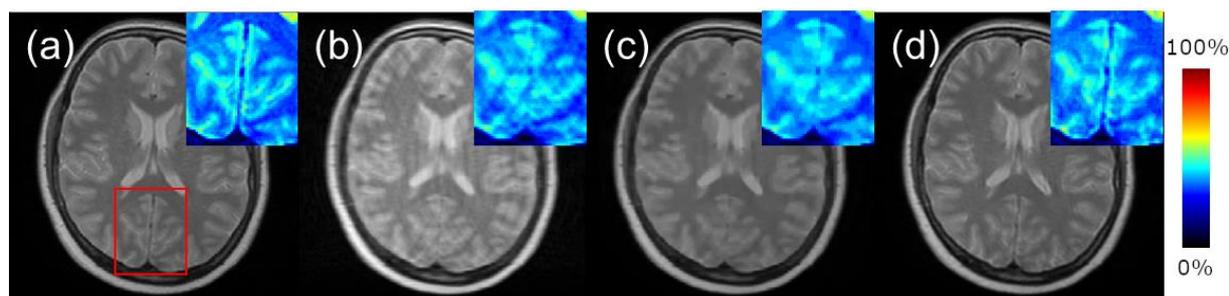


図 4 1次元ランダム収集適用時の再構成結果 : (a)フルデータ像, (b)ゼロフィル再構成像, (c)ISTAによる再構成像, (d)GANによる再構成像, 注目箇所の拡大図を(a)-(d)の右上に示す

MR Compressed Sensing Reconstruction using Generative Adversarial Network

Shohei OUCHI^{*1}, Satoshi ITO^{*1}

^{*1} Graduate School of Engineering, Utsunomiya University

Compressed Sensing (CS) has been applied to reduce the scan time of MR acquisition. CS image reconstruction requires an iterative process to solve the L1-L2 minimization problem, so it is more computationally intensive than traditional inverse Fourier reconstruction. In addition, the obtained image tends to have artificial appearances.

Recently, CNN-CS (Convolutional Neural Network based CS reconstruction) has been proposed. CNN-CS outperforms traditional CS methods in terms of image quality and reconstruction time.

In this study, we examined CNN-CS using Generative Adversarial Network (GAN) that trains two adversarial CNNs. Reconstruction experiments showed that proposed method outperforms traditional CS methods.

Simulation Study of a Novel Brain PET Scanner Using 100-ps TOF-DOI Sub-millimeter Resolution Detectors

Yingying LI^{*1}, Mitsuo WATANABE^{*2}, Takashi ISOBE^{*2}, Kibo OTE^{*2},
Takahiro MORIYA^{*2}, Aoi TOKUI^{*2}, Tomohide OMURA^{*2}, Huafeng LIU^{*1}

Abstract

A novel brain PET scanner using 100-ps TOF-DOI sub-millimeter resolution detectors is proposed, and a simulation study is performed using the Geant4 application for tomographic emission to estimate the physical properties and the image quality of the scanner. The detector consists of four layers of independent scintillation detectors with an outstanding TOF capability of 100 ps and true first interaction point (FIP) detection ability. The spatial resolution was measured according to NEMA standards. To evaluate the image quality of the scanner, we implemented not only excellent spatial and timing resolution, but also DOI detection with the addition of FIP information. Hot-Derenzo, and NEMA image quality phantom were simulated and analyzed reconstructed images in terms of image quality. Our proposed PET scanner has the potential to open a new field of brain study.

Keywords : brain PET, time-of-flight, depth-of-interaction, first interaction point detection

1. Introduction

Positron emission tomography (PET) is an essential in vivo molecular imaging tool that plays a key role in both research and clinical studies. PET scanners are currently popular in clinical studies, and many efforts have been made to further improve the performance by using various strategies. An ideal PET scanner is expected to have both a high-resolution—less than 0.5 mm full width at half maximum (FWHM) and very close to the limiting spatial resolution—and as high a sensitivity as possible to achieve excellent image quality.

We developed a brain PET scanner, using independent four-layer depth-of-interaction (DOI) detectors [1]. The spatial resolution was approximately 0.9 mm over the whole field of view (FOV). The imaging performance was demonstrated in a study of the human brain and in preclinical studies, and excellent images were obtained. However, there remains room for improvement and for realizing an ideal PET scanner. To further improve the excellent image quality, we propose a novel brain PET scanner using 100-ps time-of-flight depth-of-interaction (TOF-DOI) sub-millimeter resolution detectors with multilayer independent readout structures. This paper describes the proposed concept and the performance evaluation results of the simulation studies.

*1 College of Optical Science and Engineering, Zhejiang University

[866 Yuhangtang Rd, Hangzhou 310058, P.R. China]

E-mail: liyingying@hpk.co.jp

*2 Central Research Laboratory, Hamamatsu Photonics K. K., Japan

2. Materials and Methods

2.1. Brain PET scanner design

A brain PET scanner using 100-ps TOF-DOI sub-millimeter resolution detectors is proposed. The TOF-DOI detector consists of four layers of a LYSO scintillator array coupled with a multi-pixel photon counter (MPPC) array, where the scintillator array has 1.0-mm² crystal segments of 50×50 and the MPPC array has 3.0-mm² chips of 16×16. The scintillator thicknesses of the four layers are designed to be 2.5, 3.0, 4.0, and 6.0 mm, respectively, toward the bottom, to achieve not only a higher DOI resolution, but also a coincidence timing resolution (CTR) capability of less than 100 ps because the photon transfer time spread in the scintillator decreases. The four-layer structure with independent readout also allows us to detect the first interaction point (FIP) by analyzing Compton scatterings across and between the layers. The brain PET scanner has 96 TOF-DOI detectors arranged in a shape with a 400-mm-diameter detector ring and a 206-mm axial FOV. The major characteristics of the brain PET scanner are listed in Table 1.

Table 1 Major characteristics of a brain PET

Detector	
Detector material	LYSO:Ce
Crystal size (mm)	1.0×1.0×2.5, 3, 4, and 6 (50×50 array/unit)
Number of layers	4
Number of crystals	960,000
Photodetector	3.0 mm square MPPC(16×16 array/unit)
Number of MPPCs	98,304
Ring geometry	
Number of detector rings	206
Ring diameter (mm)	400
Ring pitch (mm)	1.0
Number of bank	24 (4 detectors axially)
Transaxial FOV (mm)	300
Axial FOV (mm)	206

2.2. Image reconstruction

The reconstruction method for this study is a list-mode dynamic RAMLA (LM-DRAMA) algorithm. Data corrections, including attenuation and scatter correction, were applied. Images were reconstructed using two iterations and 40 subsets. To evaluate the influence of TOF and FIP on image quality, the reconstruction images were compared in four categories, namely TOF and non-TOF for both winner-takes-all (WTA) and FIP. Moreover, to evaluate the benefit of DOI detection, reconstructed images with and without DOI were also compared. The image matrix size is 120×120×81 with a voxel size of 2.5×2.5×2.5 mm³ unless otherwise noted.

2.3. Simulation studies

All phantoms were estimated by means of a Geant4 application for tomographic emission (GATE) simulation toolkit [2]. An energy resolution of 10% FWHM at 511 keV and a coincidence time resolution of 100 ps FWHM were set in the simulation. The energy window and timing window were set to 425-600 keV and 1.5 ns, respectively. As for

data analysis, ASCII-format Hits and Coincidences were collected, as well as delayed data used for random correction. Both the WTA policy as the default mode and true FIP achieved using the Hits and Coincidences data were used for the position of γ -ray detection.

2.3. 1. Reconstructed spatial resolution

Spatial resolution was performed following the NEMA NU2 2018 protocol, but data was reconstructed by LM-DRAMA instead of the FBP method. The image matrix size is $600 \times 600 \times 411$ with a voxel size of $0.5 \times 0.5 \times 0.5$ mm³. An ¹⁸F point source of 1-MBq activity was placed into each 0.25-mm-diameter water sphere, and the spheres were placed into a cylinder phantom filled with low-activity as a hot background. According to NEMA, approximately 200k coincidences were collected at each sphere. The source was placed in six different positions i.e., at radial offsets of 10, 25, 50, 75, 100, and 125 mm from the center of the FOV, where two axial positions, namely the center and three-eighths of the axial FOV from the center of the FOV, were measured. The FWHM values of the point source images were determined by fitting the radial profile using a Gaussian function.

2.3. 2. Contrast recovery and noise

The required activity of ¹⁸F radioactive water in the NEMA body phantom is approximately 50 MBq to simulate a background concentration of 5.3 Bq/ml. The phantom includes six spherical water lesions with an activity concentration eight times that of the background; it was placed in the center of the FOV. A total of 30M coincidences was collected.

The contrast recovery coefficient (CRC) is defined as:

$$Q_{H,j} = \frac{(C_{H,j}/C_{B,j})^{-1}}{(\alpha_H/\alpha_B)^{-1}} \times 100\% \quad (1)$$

where $C_{H,j}$ is the average count in the region of interest (ROI) for each sphere; $C_{B,j}$ the average background ROI count for each sphere; and α_H and α_B the activity concentrations in the hot spheres and background, respectively. Following NEMA, ROIs of the same size as those drawn on the hot spheres were drawn in the background of the phantom on the slices centered on the spheres. Twelve ROIs were drawn in the background of each sphere; thus, sixty ROIs were calculated as the background value. The NEMA body phantom was reconstructed using LM-DRAMA with TOF/non-TOF and WTA/ FIP. The CRC and background variabilities thereof were compared.

2.3. 3. Imaging phantom

A hot-Derenzo phantom was simulated; it was subdivided into six sectors with rod diameters of 1.7, 2.4, 3.5, 4.7, 6.0, and 7.1 mm built into a cylinder phantom with a diameter of 150 mm and height of 37 mm, the source was back-to-back gamma with an energy of 511 keV, and the activity for each rod was 5 kBq. Images were reconstructed using LM-DRAMA with not only TOF/non-TOF and WTA/ FIP, but also DOI/non-DOI.

3. Results

3.1. Reconstructed spatial resolution

The spatial resolutions reconstructed with the LM-DRAMA for TOF of both WTA and FIP are shown in Fig. 1. Our proposed brain PET system with FIP detection achieved an excellent spatial resolution of the sub-millimeter order in the whole FOV, except for the 125-mm radial distance, especially of less than 0.5 mm FWHM within the 50-mm radial distance.

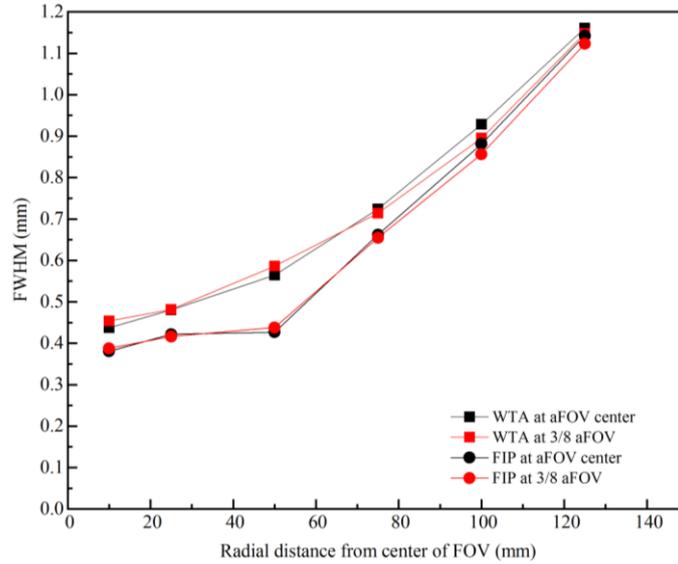


Fig. 1 Spatial resolution of point sources at different radial and axial positions.

3.2. Contrast recovery and noise

The percentage contrast recovery coefficients for each hot sphere and the percentage background variability values are shown in Table 2. Comparison of the TOF with non-TOF values in both WTA and FIP shows that the TOF reconstruction obviously reduced the background variability by more than half. Moreover, the TOF reconstruction led to a better contrast recovery than non-TOF. In addition, the results show that FIP improved the contrast recovery and background uniformity for both TOF and non-TOF.

Table 2 Contrast recovery coefficient and background variability for 8:1 sphere-to-background ratio

Sphere Size (mm)	Contrast (%)				Background variability (%)			
	WTA		FIP		WTA		FIP	
	TOF	non-TOF	TOF	non-TOF	TOF	non-TOF	TOF	non-TOF
10	28.43	28.43	35.26	33.56	10.68	22.99	8.23	17.34
13	30.30	27.98	42.43	38.88	9.81	17.07	7.54	14.09
17	33.29	32.50	40.12	38.86	10.76	18.02	7.16	14.75
22	37.53	34.76	51.79	43.5	8.49	14.95	7.91	16.09
28	48.06	47.12	57.50	56.75	7.68	14.43	7.99	14.56
37	54.69	49.18	53.60	53.43	5.79	14.15	6.31	13.23

3.3. Imaging phantom

The TOF, non-TOF, and non-DOI images of the hot-Derenzo phantom centered at the FOV are shown in Fig. 2. The DOI reconstruction significantly improved the image quality, which is easily observed in the smallest diameter

rods of 1.7 mm, even in the peripheral region. Compared to non-TOF, TOF provided clear edge information, particularly for rods with a radius of 7.1 mm, as indicated by the arrows in the image. From a visual perspective, images with FIP information have a better image quality such that even the rods with a radius of 1.7 mm are more clearly separated compared to the images with WTA.

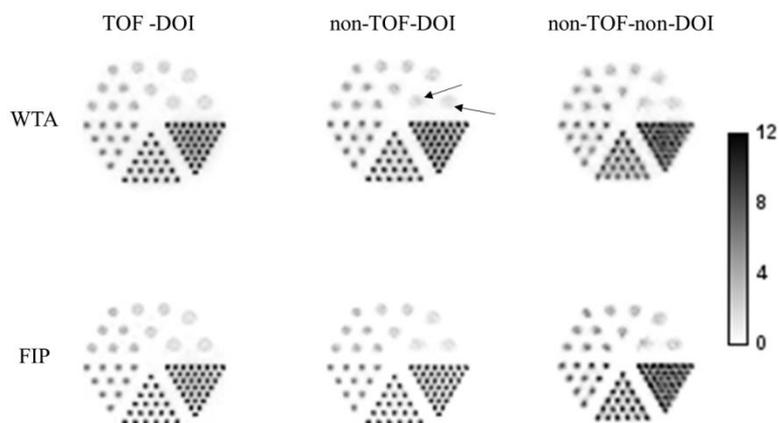


Fig. 2 TOF, non-TOF, non-DOI reconstructed images of the hot-Derenzo phantom centered at FOV. Rod diameters are 1.7, 2.4, 3.5, 4.7, 6.0, and 7.1 mm.

4. Discussion and Conclusion

Simulation studies were performed to evaluate the spatial resolution and image quality of our proposed brain PET scanner. The simulation studies confirm that the described system design achieved an excellent spatial resolution of the sub-millimeter order, especially of less than 0.5 mm FWHM within a 50-mm radial distance. Furthermore, the hot-Derenzo phantom was reconstructed and the results show that the system was able to clearly resolve hot rods with radius of 1.7 mm up to a radial distance of 75 mm. For the NEMA body phantom, the TOF reconstruction with 100 ps homogenized the background by more than half, and led to better contrast recovery than that with non-TOF. Additionally, FIP detection improved the contrast recovery and background uniformity compared to that with WTA. In conclusion, the results demonstrate that our proposed brain PET scanner using 100 ps TOF-DOI sub-millimeter resolution detectors has the potential to realize high imaging performance.

Competing interests

The authors declare no competing interests associated with this manuscript.

References

- [1] Watanabe M, Saito A, Isobe T, et al.: Performance evaluation of a high-resolution brain PET scanner using four-layer MPPC DOI detectors. *Phys Med Biol* **62**: 7148-7166, 2017
- [2] Jan S, Santin G, Strul D, et al.: GATE - Geant4 Application for Tomographic Emission: a simulation toolkit for PET and SPECT. *Phys Med Biol* **49**: 4543-4561, 2004

サイクル損失を用いた 3 次元胸部 CT 像の超解像

河合良亮*¹, 齊藤篤*¹, 木戸尚治*², 稲井邦博*³,

木村浩彦*³, 清水昭伸*¹

要旨

多くの超解像技術では低解像度(Low Resolution ; LR)画像とそれに対応した高解像度(High Resolution ; HR)画像を用いている。しかしこの画像組を大量に用意することは困難である。本稿では、深層学習ベースの超解像処理にサイクル損失を定義し、対応付けのない LR 画像と HR 画像を用いて超解像を実現する方法について報告する。従来の超解像処理では、ResNet を超解像のための生成器、CNN を偽物と本物の HR を識別する識別器とし、GAN の枠組みを利用して最適化するが、提案法では LR の再構成損失をサイクル損失とし、それを含む損失全体の最小化により ResNet を訓練した。この方法を実際の胸部 CT 像に適用して 8 倍の超解像を行い、結果を評価した。本稿では、対応付けのある画像組を用いた超解像との比較も行いながら、提案法の有効性と限界について議論する。

キーワード：超解像，非対応画像組，サイクル損失，GAN，CT 画像

1. はじめに

3 次元 CT 像は胸部の診断や治療において重要な情報源である[1]。正確な画像診断のためには、解像度が高いことが望まれるが、撮影装置の制約により十分な解像度が得られるとは限らない。そこで、低解像度 (Low-Resolution : LR) 画像から高解像度 (High-Resolution : HR) 画像を復元する超解像技術が注目されている。

超解像技術には辞書ベースの手法[2][3]と深層学習ベースの手法[4][5]が存在する。一般に深層学習を用いた手法の性能が高く、例えば、3D-SRGAN[4]は辞書ベースの手法での問題点であるボケを抑制し、精度を向上させている。しかし、多くの手法では、LR 画像とそれに対応する HR 画像の画像組を必要とし、この画像組を得るためには、事前に臨床用 CT、死後に摘出標本のマイクロ CT を撮影する必要がある、容易ではない。

本稿では LR と HR の画像組を用いない超解像処理について述べる。具体的には、従来の 3D-SRGAN[4]の生成器である ResNet の損失関数に、実 LR 画像と生成した LR 画像との差をサイクル損失[5]として組み込む。また、実際の CT 像に適用して性能を評価した結果について報告する。

2. サイクル損失

提案手法では、式(1), (2)の損失関数を反復的に最適化する。

$$\begin{aligned} & \max_{\theta_D} \left[E_{I^{HR} \sim p_{data}(I^{HR})} [\log D_{\theta_D}(I^{HR})] + \right. \\ & \left. E_{I^{Tri} \sim p_{data}(I^{Tri})} \left[\log \left(1 - D_{\theta_D} \left(G_{\theta_{GSR}}(I^{Tri}) \right) \right) \right] \right] \quad (1) \\ & \min_{\theta_{GSR}, \theta_{Gdw}} \left[E_{I^{Tri} \sim p_{data}(I^{Tri})} \left[\log \left(1 - D_{\theta_D} \left(G_{\theta_{GSR}}(I^{Tri}) \right) \right) \right] + \right. \\ & \left. \lambda_A \left\| G_{dw} \left(G_{SR}(I^{Tri}) \right) - I^{Tri} \right\|_1 \right] \quad (2) \end{aligned}$$

式中の $\theta_{D_{HR}}$, $\theta_{G_{SR}}$, $\theta_{G_{dw}}$ はそれぞれ識別器、生成器のパラメータであり、 I^{HR} , I^{Tri} は一辺のサイズが 32voxel の実 HR パッチ画像と実 LR パッチ画像である。ここでパッチ画像とは、一辺のサイズが 32voxel の部分画像であり、GPU のメモリの制約などにより用いた。 $p_{data}(I^{HR})$, $p_{data}(I^{LR})$ は I^{HR} , I^{Tri} の確率分布であり、 D_{θ_D} は実 HR 画像である確率[0,1]である。 $G_{\theta_{GSR}}$ は HR 画

*1 東京農工大学大学院工学研究院
[〒184-8588 東京都小金井市中町 2-24-16]

e-mail: s195357s@st.go.tuat.ac.jp

*2 大阪大学大学院医学系研究科

*3 福井大学医学部

像の生成関数で G_{dw} はLR画像の生成関数、 λ_A は重みである。ここで式(2)の2項目がサイクル損失である。 I^{Tri} を入力とし、変換-逆変換を経た生成LRパッチ画像と I^{Tri} のL1ノルム最小化を目指している。

3. 実験条件及び実験結果

実験には、肺のマイクロCT像（一画素のサイズ： $0.070 \times 0.066 \times 0.070\text{mm}$ ）を使用した。LR画像はこの画像を一様平滑化後（ $8 \times 8 \times 8\text{voxel}$ ）、8画素おきにサンプリングした。また、学習用のHR画像とLR画像は対応関係を持たないように異なる部位から収集した。テストでは同様の手順で作成したLR画像を入力として8倍の超解像を行った。サイクル損失の重み λ_A は5と10を試行した。最適化法はAdam[6]（ $\alpha = 10^{-5}, \beta_1 = 0.9, \beta_2 = 0.999$ ）を用いた。

実験結果を図1、評価値(PSNR)を表1に示す。

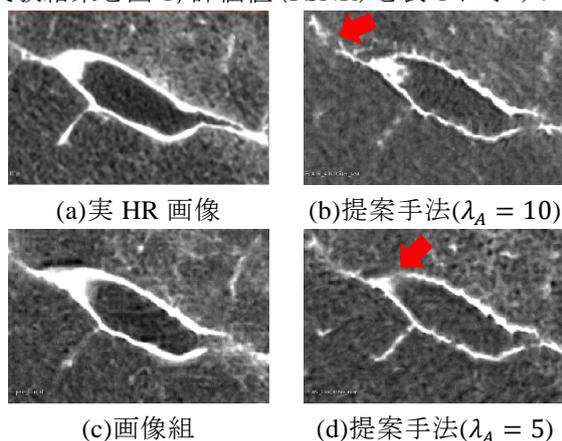


図1 実験結果

表1 評価値

	画像組	提案手法 ($\lambda_A=10$)	提案手法 ($\lambda_A=5$)
PSNR[dB]	24.9	23.7	23.5

図1(b)(c)の矢印が示す通り、従来の超解像に比べて提案手法の超解像はエッジ付近にアーチファクトが発生し、再構成精度が悪いことがわかる。そこで、テスト画像と学習画像の類似性を評価した。具体的には、まず、図1のテスト画像の解剖構造を含む局所領域を解剖構造が約半分になるまで画像上で平行移動させながら、濃度値の標準偏差と平均の変化を測定した。次に、その変化の範囲内に含まれる学習画像の局所領域の割合を求めた。その結果、LR用

の学習画像には8.3%含まれていたが、HR用の学習画像には0.53%の割合でしか含まれておらず、図1のような構造は、HRの学習画像に特に不十分であることが分かった。このことが、超解像の精度が悪い理由の一つであると考えられる。

4. まとめ

本稿では、3DSRGANにサイクル損失を新たに組み込むことで、LRとHRの対応する画像組が不要の超解像処理について述べた。今後は、対応組がある場合と比較して、不自然なアーチファクトが見られる点や、解剖構造の正確な復元ができていない点が課題である。そのため、学習データ数を増やす工夫やLR、HRに同程度の解剖構造を含むような収集方法の改善、解剖構造を多く含むパッチ画像に対して重みをつけて学習をする予定である。

謝辞

日頃から熱心にご討論いただく東京農工大学 清水昭伸研究室の各位に深謝いたします。

利益相反の有無

無

文献

- [1] 中村彰太:胸部外科への臨床応用; MicroCTと肺. 橋爪誠編:多元計算解剖学の基礎と臨床への応用. 誠文堂新光社, 東京, 2018, pp228-232
- [2] 石田純也 他: 肺の3次元CT像からの光学画像合成に関する研究. 東京農工大学, 修士論文, 2017
- [3] H. Chang, D.-Y. Yeung, and Y. Xiong: Super-resolution through neighbor embedding, In CVPR, 01:275-282, 2004.
- [4] Tozawa K, et al. :Super resolution of a lung CT volume using a generative adversarial network”, in CARS., 2018
- [5] Yuan Yuan et al., :Unsupervised Image Super-Resolution using Cycle-in-Cycle Generative Adversarial Network, CVPR workshop, 2018
- [6] D. Kingma and J. Ba, :Adam: A method for stochastic optimization,” In ICML, 2015.

Super-Resolution of a thoracic CT volume using cycle loss

Ryosuke KAWAI^{*1}, Atsushi SAITO^{*1}, Shoji KIDO^{*2}, Kunihiro INAI^{*3}

Hirohiko KIMURA^{*3}, Akinobu SHIMIZU^{*1}

*1 Institute of Engineering, Tokyo University of Agriculture and Technology

*2 Graduate School of Medicine, Osaka University

*3 Faculty of Medical Sciences, University of Fukui

It is difficult to collect a lot of paired images of low resolution (LR) and high resolution (HR) that are commonly used in the most of the existing super resolution techniques. This paper presents a method that employs a cycle loss which does not require paired LR and HR images. Our previously proposed super resolution method used GAN to train ResNet as a generator and CNN as a discriminator. In contrast, the proposed method trains ResNet whose loss function includes the cycle loss that evaluates reconstruction errors of LR image. We applied the proposed method to a thoracic CT volume to achieve eight times super resolution and evaluated the performance. This paper compares the results with those using paired images and discusses the effectiveness and limitations of the proposed method.

Key words: Super-Resolution, unpaired images, Cycle loss, GANs, CT image

Cycle GAN を用いた胸部 CT 画像のドメイン変換と

その識別システムへの応用

三宅 将司*¹ 間普 真吾*¹ 木戸 尚治*²

呉本 堯*¹ 平野 靖*¹

要旨

昨今、デジタル医用画像機器の発達により、膨大な量の医用画像が取得できるようになった。大量の医用画像を用いて機械学習を行い、医療診断のセカンドオピニオンとして利用するコンピュータ支援診断 (Computer-Aided Diagnosis, CAD) の研究も活発に行われている。様々な医療機関で汎用的に使えるコンピュータ支援診断システムを構築することは重要であるが、実際には医療機関によって画像の撮影条件が異なるため、診断の精度が変動する可能性がある。したがって、ある医療機関でよい診断性能を示したシステムが他の医療機関で同じ性能を示すとは限らない。本研究では、ある医療機関で撮影された胸部 CT 画像を用いて学習を行った画像診断システムを、他医療機関でも使えるようにするため、他医療機関で撮影された胸部 CT 画像のドメイン変換、すなわち学習済みの診断システムに適した画像に変換することを目的とする。

キーワード：深層学習、標準化、GAN、胸部 CT、識別

1. はじめに

近年のデジタル医用画像機器の発達によって、膨大な量の医用画像が取得できるようになった。それに伴い、大量の医用画像を用いて機械学習を行い、医療診断のセカンドオピニオンとして利用するコンピュータ支援診断 (Computer-Aided Diagnosis, CAD) の研究も活発に行われている。様々な医療機関で汎用的に使

えるコンピュータ支援診断システムの開発が望まれているが、医療機関によって画像の撮影条件が異なるため診断の精度が変動する可能性がある。

CAD システムの構築には画像処理や画像認識の技術が使われているが、近年、画像認識の研究分野において畳込みニューラルネットワークの研究が急速に発展し、CAD システムの構築にも応用が進んでいる[1]。しかし、ニューラルネットワークの学習には、大量の教師ラベル付き医用画像データが必要となる問題がある。また、医療機関によって医用画像の撮影条件は異なるため、CAD の診断精度が変動する可能性がある。例えば、CT 装置の違いや設定の違いによって画素値が異なる。したがって、CAD がある医療機関でよい診断性能を示したとしても、他の医療機関で同じ性能を示すとは限らない。その場合、CAD の再学習が必要であり、学習の

連絡先:

間普真吾, 山口大学大学院創成科学研究科

〔〒755-8611 宇部市常盤台 2-16-1〕

Tel/Fax0836-85-9519, mabu@yamaguchi-u.ac.jp

*1 山口大学大学院創成科学研究科電気電子情報系専攻

*2 大阪大学大学院医学系研究科人工知能画像診断学共同研究講座

投稿受付：2019年5月15日

ためには医療機関ごとに大量の訓練データを作成する必要がある。ここでは、様々な医療機関で広く使いやすいシステムとは言えず、本問題の解決が必要である。

本研究では、ある医療機関で撮影された胸部 CT 画像を用いて学習を行った画像診断システムを、他医療機関でもそのまま使えるようにするため、Cycle GAN を用いて胸部 CT 画像のドメイン変換を行うことを目的とする。

2. 提案手法

図 1 に提案手法の概要を示す。本研究では、びまん性肺疾患の陰影分類を例に、Cycle GAN[2]を用いて胸部 CT 画像のドメイン変換を行う手法を提案する。具体的には、山口大学医学部附属病院で撮影された胸部 CT 画像(以降、ドメイン A と呼ぶ)の条件を標準と定義し、大阪大学医学部附属病院で撮影された胸部 CT 画像(以降、ドメイン B と呼ぶ)を Cycle GAN によってドメイン A の条件に変換(標準化と呼ぶ)する方式とする。ドメイン変換後の陰影識別器として Residual Network (ResNet)[3]を用い、ResNet はドメイン A の画像データで学習を行う。標準化の有無によってドメイン B の画像の識別精度に差があるかを検証する。同様に、ドメイン B を標準にした場合も検証する。

1) 関心領域画像(ROI 画像)の作成

本研究では、山口大学医学部附属病院で撮影された胸部 CT 画像 503 枚と、大阪大学医学部附属病院で撮影された胸部 CT 画像 636 枚を使用して画像の標準化を行う。それぞれの病院で撮影された胸部 CT 画像の例を図 2 に示す。

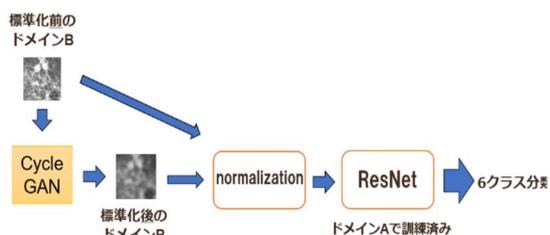


図 1 提案手法の概要

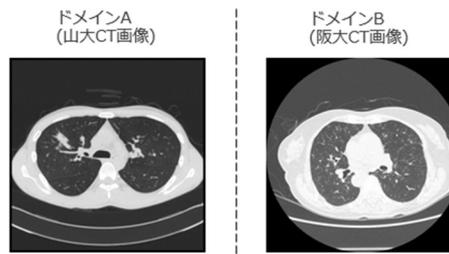


図 2 胸部 CT 画像の例

ドメイン A, B の胸部 CT 画像には 6 つの陰影パターン[浸潤影, 粒状影, 肺気腫, すりガラス陰影, 蜂巣肺, 正常]が含まれている。

ドメイン A, B の胸部 CT 画像を 32×32 [pixel] の関心領域 (Region of Interest, ROI) に分割し、これを Cycle GAN の学習に用いる。各 CT 画像には、各陰影の箇所を示したマスク画像が用意されている。なお、マスク画像は 3 名の放射線科医の指導のもと作成されている。マスク画像の左上からストライドさせつつ 32×32 [pixel] の領域を調査し、領域中に各陰影を示すマスク領域が 5 割以上含まれる場合、対応する胸部 CT 画像から同領域を抽出して ROI 画像とする。

2) Cycle GAN による標準化

Cycle GAN とは、2 つのドメイン間の変換を行う生成モデルの一種である。Cycle GAN の構造を図 3 に示す。Cycle GAN は 2 つの Generator と Discriminator から構成される。ここで、変換に用いるデータ群をそれぞれドメイン A, ドメイン B と呼ぶことにし、ドメイン A からドメイン B に変換する Generator を G, ドメイン B からドメイン A に変換する Generator を F, 本物の A か変換された偽の A かを見分ける Discriminator を D_A , 本物の B か変換された偽の B かを見分ける Discriminator を D_B と定義する。Generator は Discriminator に正しく分類されないようにデータを生成するよう学習し、Discriminator は本物のデータか偽のデータかを正しく分類できるように学習していくことで、

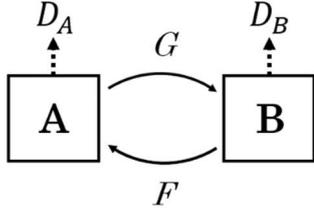


図 3 Cycle GAN の構造(Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks より[1])

ドメイン間の変換を学習していく. G , F , D_A , D_B の学習には, 式(1)から式(3)に示す損失関数を用いる.

$$\begin{aligned}
 L_{GAN}(G, D_B, A, B) &= E_{b \sim p_{data}(b)} [\log D_B(b)] \\
 &\quad + E_{a \sim p_{data}(a)} [\log(1 - D_B(G(a)))] \\
 L_{GAN}(F, D_A, B, A) &= E_{a \sim p_{data}(a)} [\log D_A(a)] \\
 &\quad + E_{b \sim p_{data}(b)} [\log(1 - D_A(G(b)))] \quad (1) \\
 L_{cyc}(G, F) &= E_{a \sim p_{data}(a)} [\|F(G(a)) - a\|] \\
 &\quad + E_{b \sim p_{data}(b)} [\|G(F(b)) - b\|] \quad (2) \\
 L_{identity}(G, F) &= E_{b \sim p_{data}(b)} [\|G(b) - b\|] \\
 &\quad + E_{a \sim p_{data}(a)} [\|F(a) - a\|] \quad (3)
 \end{aligned}$$

式(1)の損失関数を最小化することでドメイン変換の学習を行っていくが, この損失関数だけではどのような入力画像に対しても同じ出力パターンをマッピングするように学習してしまうため, 式(2)と式(3)の損失関数を導入する. 式(2)は Cycle Consistency Loss と呼ばれるもので, Generator が生成したデータを入力として再構成された生成データと, 元のデータが一致するように制約をかけている. これにより, ドメイン間に共通する構造をできるだけ保つように学習するようになる. 式(3)は Identity Mapping Loss と呼ばれるもので, Generator に対象のドメインでないデータを入れた際に何も変換しないように制約をかけている. これにより, 入力と出力間の色の情報を維持することができるようになる.

最終的な損失関数を式(4)に示す.

$$\begin{aligned}
 L(G, F, D_A, D_B) &= L_{GAN}(G, D_B, A, B) \\
 &\quad + L_{GAN}(F, D_A, B, A) \\
 &\quad + \lambda_1 L_{cyc}(G, F) \\
 &\quad + \lambda_2 L_{identity}(G, F) \quad (4)
 \end{aligned}$$

ここで, λ_1 と λ_2 はバイアス項であり, 本実験ではそれぞれ 10, 5 と設定した. G と F は, 式(5)で表される目的関数を満たすように学習を行う.

$$G^*, F^* = \arg \min_{G, F} \max_{D_A, D_B} L(G, F, D_A, D_B) \quad (5)$$

この Cycle GAN にドメイン A とドメイン B の変換を学習させることで標準化を行う. Cycle GAN への入力を作成した ROI 画像である.

3) ResNet による性能評価

Cycle GAN によって標準化された画像を評価するために, ResNet を用いる. ドメイン A を標準とする場合, Cycle GAN による標準化の有効性を確認するために, まず ResNet をドメイン A のデータを用いて学習を行う. そして, Cycle GAN で標準化を行ったドメイン B と標準化を行っていないドメイン B の画像を, ドメイン A で学習した ResNet を用いて 6 クラス分類を行い, Accuracy, Precision, Recall, F 値に差があるかどうかを検証する. また, ResNet に入力するデータの前処理として, z-score normalization または min-max normalization を行う. z-score normalization とは, データの平均を 0, 標準偏差を 1 とする正規化法である. min-max normalization とは, 全データの最小値を 0, 最大値を 1 とする正規化法である.

3. 実験結果

1) 使用データセット

ROI 画像を生成する際にクラスごとのストライド幅を統一してしまうと, ROI 画像の枚数に大きな偏りが生じてしまう. そのため, 本研究では陰影パターンごとにストライド幅を調整することで ROI の枚数を各クラス 3000 枚程度に揃えた. 表 1 に陰影パターンごとに設定したストライド幅と ROI 画像の枚数を示す. 生成した ROI 画像には陰影パターンの教師ラベルを付与した.

2) Cycle GAN による標準化

本研究では, Cycle GAN に入力する画像が 32×32 [pixel] と小さいサイズのため, Generator における ResNet の layer 数を 3 とした. また, 使

表 1 生成したクラスごとの ROI 画像数と, 生成時に設定したストライド幅

	ROI 画像数(枚)		ストライド幅 (pixel)	
	ドメイン A	ドメイン B	ドメイン A	ドメイン B
浸潤影	3071	3447	8	11
粒状影	3023	3311	16	14
肺気腫	3122	3021	24	27
すりガラス 陰影	3460	3273	12	18
蜂巢肺	3236	3434	13	13
正常	3117	3035	29	32

表 2 Cycle GAN の学習に用いた訓練データとテストデータの枚数

	訓練データ		テストデータ	
	ドメイン A	ドメイン B	ドメイン A	ドメイン B
浸潤影	1022	1027	2049	2420
粒状影	1018	1020	2005	2291
肺気腫	1020	962	2102	2059
すりガラス 陰影	989	996	2471	2277
蜂巢肺	1003	1021	2233	2413
正常	1003	1024	2114	2011

用するデータはグレースケールのため, 入力チャンネルは 1 とし, 最適化手法には Adam[4]を用いた.

Cycle GAN の学習に用いたクラス毎の訓練データとテストデータの枚数を表 2 に示す. 表 2 に示した訓練データを用いて Cycle GAN を学習させた. ドメイン変換の学習を行った Cycle GAN による標準化の例を図 4, 5 に示す. 図 4 はドメイン B をドメイン A に標準化(ドメイン B→ドメイン A)した結果の例であり, 図 5 はドメイン A をドメイン B に標準化(ドメイン A→ドメイン B)した結果の例である.

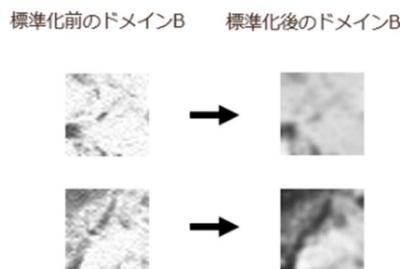


図 4 ドメイン B の標準化の例

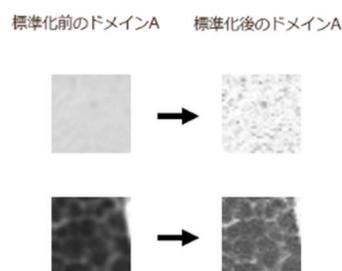


図 5 ドメイン A の標準化の例

3) ResNet の学習結果

使用した ResNet の構造は, 図 6 に示す Residual Block を 5 つ積層し, 4 層目の入力の前に Average Pooling 層を加えたものである.

まず, ドメイン A を用いて ResNet の学習を行った結果を示す. Resnet の学習には, 表 1 で示したドメイン A の粒状影の ROI 画像数に合わせて各クラス 3023 枚の画像を使用した. また, そのうち 9 割を訓練データ, 1 割をバリデ

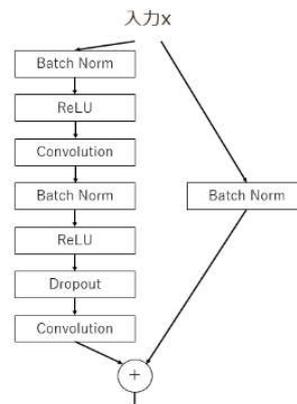


図 6 Residual Block の構成

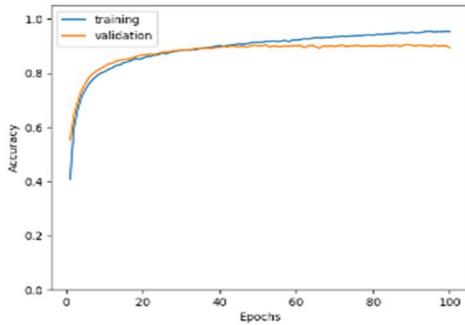


図 7 ドメイン A を用いた ResNet の学習において、min-max normalization を行った時の ResNet の Accuracy の推移

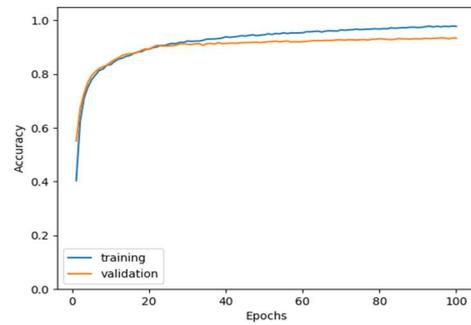


図 9 ドメイン B を用いた ResNet の学習において、min-max normalization を行った時の ResNet の Accuracy の推移

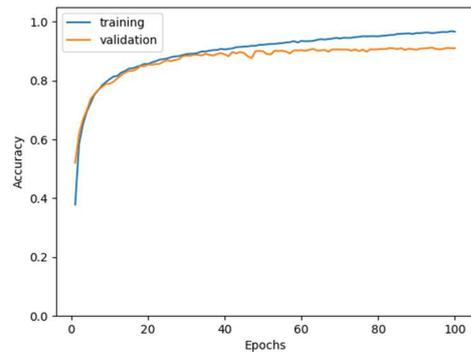


図 8 ドメイン A を用いた ResNet の学習において、z-score normalization を行った時の ResNet の Accuracy の推移

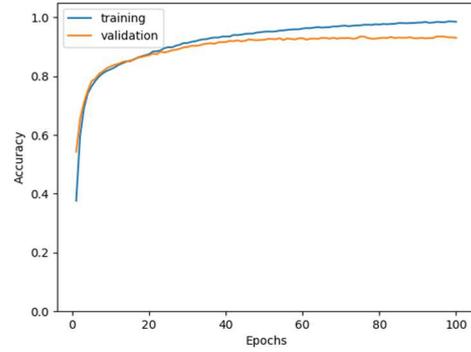


図 10 ドメイン B を用いた ResNet の学習において、z-score normalization を行った時の ResNet の Accuracy の推移

ーションデータとし、epoch は 100 として学習を行った。ResNet に入力するデータの前処理として min-max normalization を行ったときの Accuracy の推移を図 7 に示す。epoch100 時の訓練データに対する accuracy は 0.953，バリデーションデータに対する Accuracy は 0.894 となった。z-score normalization を行ったときの Accuracy の推移を図 8 に示す。epoch100 時の訓練データに対する Accuracy は 0.969，テストデータに対する Accuracy は 0.910 となった。

次に、ドメイン B を用いて ResNet の学習を行った結果を示す。Resnet の学習には、表 1 で示したドメイン B の肺気腫の ROI 画像数に合

わせて各クラス 3021 枚の画像を使用した。また、そのうち 9 割を訓練データ、1 割をバリデーションデータとし、epoch は 100 として学習を行った。ResNet に入力するデータの前処理として min-max normalization を行ったときの Accuracy の推移を図 9 に示す。epoch100 時の訓練データに対する Accuracy は 0.977，バリデーションデータに対する Accuracy は 0.933 となった。z-score normalization を行ったときの Accuracy の推移を図 10 に示す。epoch100 時の訓練データに対する Accuracy は 0.986，テストデータに対する Accuracy は 0.937 となった。

4) ResNet による標準化前後の性能評価
まず、ドメイン A を標準として、ドメイン B

を Cycle GAN で標準化した場合の評価を行った。Cycle GAN で標準化を行っていないドメイン B と標準化を行ったドメイン B の画像を、ドメイン A で学習を行った ResNet の入力とし、識別率に差があるかどうか検証した。評価に使用したデータの枚数は、表 2 に示した Cycle GAN のドメイン B のテストデータに対応している。入力データの前処理で min-max normalization を用いた場合の性能評価値を表 3 に示す。表 3 より、ドメイン B の標準化前と標準化後を比較すると、すべてのクラスにおいて標準化後の F 値が標準化前の値を上回っていることがわかる。また、標準化後の Precision と Recall の値もほとんどが高くなっていることがわかる。標準化前のデータで測定した Accuracy は 0.407、標準化後のデータで測定した Accuracy は 0.696 であった。入力データの前処理で z-score normalization を用いた場合の性能評価値を表 4 に示す。表 4 より、標準化前と標準化後を比較すると、ほとんどのクラスで標準化後の F 値が標準化前の値を上回っているが、肺気腫における F 値が低くなっていることがわかる。このことから、ドメイン A とドメイン B 間で肺気腫の変換規則の獲得が困難であったと考えられる。また、ドメイン B の標準化前のデータで測定した Accuracy は 0.426、標準化後のデータで測定した Accuracy は 0.713 であった。

次に、ドメイン B を標準として、ドメイン A を Cycle GAN で標準化した場合の評価を行った。評価方法はドメイン B を Cycle GAN で標準化した場合と同様である。評価に使用したデータの枚数は、表 2 に示した Cycle GAN のドメイン A のテストデータに対応している。入力データの前処理で min-max normalization を用いた場合の性能評価値を表 5 に示す。表 5 より、ドメイン A の標準化前と標準化後を比較すると、すべてのクラスで標準化後の F 値が標準化前の値を上回っている。また、標準化前のデータで測定した Accuracy は 0.450、標準化後のデータで測定した Accuracy は 0.571 であった。以上より、すべてのクラスにおいて標準化後のデータによる識別性能が、標準前と比較して高く

表 3 ドメイン B に対する標準化における, min-max normalization を用いた ResNet によって測定した性能評価値

	ドメイン B の標準化前			ドメイン B の標準化後		
	precision	recall	F 値	precision	recall	F 値
浸潤影	0.88	0.99	0.93	0.97	0.97	0.97
粒状影	0.01	0.00	0.00	0.51	0.81	0.63
肺気腫	1.00	0.00	0.00	0.56	0.37	0.45
すりガラス陰影	0.13	0.30	0.18	0.89	0.60	0.72
蜂巣肺	0.51	0.99	0.67	0.78	0.83	0.80
正常	0.01	0.00	0.00	0.53	0.53	0.53
Average	0.43	0.41	0.32	0.72	0.70	0.69

表 4 ドメイン B に対する標準化における, z-score normalization を用いた ResNet によって測定した性能評価値

	ドメイン B の標準化前			ドメイン B の標準化後		
	precision	recall	F 値	precision	recall	F 値
浸潤影	0.99	0.84	0.91	0.97	0.97	0.97
粒状影	0.41	0.19	0.26	0.54	0.82	0.66
肺気腫	0.60	0.85	0.71	0.64	0.35	0.45
すりガラス陰影	0.53	0.01	0.02	0.91	0.61	0.72
蜂巣肺	0.21	0.59	0.31	0.79	0.87	0.83
正常	0.12	0.05	0.07	0.52	0.59	0.55
Average	0.49	0.43	0.39	0.74	0.71	0.71

なっているといえる。入力データの前処理で z-score normalization を用いた場合の性能評価値を表 6 に示す。ドメイン A の標準化前と標準化後を比較すると、粒状影、蜂巣肺、正常のクラスでは標準化後の F 値が標準化前より高く、浸潤影、肺気腫、すりガラス陰影のクラスでは標準化前の F 値が標準化後より高くなっている。F 値の平均も標準化前と標準化後であまり変化がない。また、標準化前のデータで測定した Accuracy は 0.673、標準化後のデータで測定した Accuracy は 0.632 であった。以上より、標準化後のデータによる識別性能が、標準化前と比

表 5 ドメイン A に対する標準化における, min-max normalization を用いた ResNet によって測定した性能評価値

	ドメイン B の標準化前			ドメイン B の標準化後		
	precision	recall	F 値	precision	recall	F 値
浸潤影	1.00	0.75	0.85	0.99	0.84	0.91
粒状影	0.01	0.00	0.00	0.35	0.37	0.36
肺気腫	0.25	0.98	0.40	0.39	0.67	0.49
すりガラス陰影	0.73	0.36	0.49	0.75	0.46	0.57
蜂巣肺	0.71	0.60	0.65	0.64	0.86	0.74
正常	0.00	0.00	0.00	0.49	0.23	0.32
Average	0.46	0.45	0.41	0.61	0.57	0.57

表 6 ドメイン A に対する標準化における, z-score normalization を用いた ResNet によって測定した性能評価値

	ドメイン B の標準化前			ドメイン B の標準化後		
	precision	recall	F 値	precision	recall	F 値
浸潤影	0.97	0.99	0.98	0.99	0.88	0.93
粒状影	0.65	0.30	0.41	0.42	0.64	0.51
肺気腫	0.45	0.94	0.61	0.53	0.34	0.42
すりガラス陰影	0.64	0.99	0.77	0.74	0.61	0.67
蜂巣肺	0.88	0.58	0.70	0.76	0.78	0.77
正常	0.96	0.13	0.22	0.53	0.62	0.57
Average	0.76	0.66	0.62	0.67	0.64	0.65

較して高くなっているとはいえない。本ケースでは, min-max normalization による feature scaling と比較して, z-score normalization による feature scaling の効果が大きく Cycle GAN による標準化の効果が現れにくかったといえる。

4. まとめ

本研究では, ある医療機関で撮影された CT 画像を用いて学習を行った画像診断システムを, 他医療機関でも使えるようにするため, Cycle GAN を用いて画像の標準化を行う研究を行った。山口大学医学部附属病院で撮影された胸部 CT 画像をドメイン A, 大阪大学医学部附属病院で撮影された胸部 CT 画像をドメイン B

とし, Cycle GAN を用いてドメイン A をドメイン B に標準化した場合と, ドメイン B をドメイン A に標準化した場合のシミュレーションを行った。ResNet を用いて標準化前と標準化後の識別性能を比較した結果, 標準化前の識別性能が低い場合は Cycle GAN による標準化の有効性が確認できた。しかし, 標準化前である程度の識別性能を示している場合は, 標準化の有効性が確認できなかった。

今後の課題として, 考察で記述したように, 識別性能が Cycle GAN による特徴抽出に依存するため, 識別に有用な特徴を獲得可能な Cycle GAN の構造に改良することが挙げられる。具体的には, Cycle GAN の学習に, ResNet による損失関数の値を考慮させることを予定している。

謝辞

本研究は JSPS 科研費新学術領域研究 多元計算解剖学 SP26108009, JSPS 科研費若手研究 (B)JP16K16116 の助成を受けたものです。

利益相反の有無

なし。

文献

- [1] Arnaud Arindra Adiyoso Setio, Francesco Ciompi, Geert Litjens, et al: Pulmonary Nodule Detection in CT Images: False Positive Reduction Using Multi-View Convolutional Networks, IEEE Transactions on Medical Imaging, 2016
- [2] Zhu, Jun-Yan and Park, Taesung and Isola, et al: Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks. ICCV, 2017
- [3] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun: Deep Residual Learning for Image Recognition. CVPR, 2016
- [4] Diederik P. Kingma, Jimmy Lei Ba: ADAM: A method for stochastic optimization, ICLR, 2015

Domain Transformation of Chest CT Images Using Cycle GAN and Its Application to Classification Systems

Masashi MIYAKE*¹, Shingo MABU*¹, Shoji KIDO*², Takashi KUREMOTO*¹, Yasushi HIRANO*¹

*1 Yamaguchi University

*2 Osaka University

Recently, with the development of digital medical imaging devices, it has become possible to acquire an enormous amount of medical images. Therefore, studies on computer-aided diagnosis (CAD) have been actively conducted, where machine learning is applied to build CAD systems using a large amount of medical images. It is important to construct a CAD system that can be used at various medical institutions, however, there are possibilities that the accuracy of diagnosis may fluctuate when the photography conditions of the images are different depending on the medical institutions. Therefore, a CAD system showing good diagnostic performance in a certain medical institution does not always show the same performance in other medical institutions. Therefore, the aim of this research is to perform image-to-image translation of chest CT images so that medical institutions can use the CAD system which is trained at another medical institution.

Key words: Deep Learning, Standardization, GAN, chest CT, Classification

楕円フーリエ記述子を用いた乳房 X 線画像における 石灰化クラスタの解析とデータ拡張への応用

志村 一男*¹ 安中 奨*² 近藤 啓介*¹ 縄野 繁*³

要旨

CAD (コンピュータ支援診断) システムの性能向上に重要となる教師データの確保は容易ではなく、データ拡張技術が注目されている。

今回、輪郭情報の定量的評価法のひとつである楕円フーリエ記述子を用い、石灰化クラスタの輪郭を解析するとともに、データ拡張に応用する手法を検討した。楕円フーリエ記述子とは輪郭等の閉曲線を周波数分解する手法であり、円形度やアスペクト比といった既存の特徴量と比較し、より詳細な形状の特徴を表現可能な技術である。

画像データから得た石灰化分布の形状を楕円フーリエ記述子に変換し、主成分分析を行なった後、得られた第 1 主成分と面積を特徴量とすることで、B-RADS の 5 つの石灰化分布タイプを分類できる可能性を確認した。

また、各主成分の値を変化させることで、様々な輪郭形状を生成できるため、あらかじめ抽出しておいた石灰化陰影を生成された輪郭形状を持つ石灰化分布に応じ配置し、別の乳房 X 線画像に埋め込むことにより様々な石灰化分布を有する教師画像を人工的に生成できる事が分かった。

以上の方法を乳房 X 線画像の公開データベースである CBIS-DDSM を用いて確認した結果について報告する。

キーワード：楕円フーリエ記述子，データ拡張，乳房 X 線画像

1. はじめに

近年、CR,DR,CT,MR 等の画像診断装置の進歩と共に、日々生成される医療画像は年々増え続けている。コンピュータやネットワークの進歩は、医師の読影環境を大きく変えたが、放射線医の読影負荷は増加し続けている。

そんな中、コンピュータにより医師の診断を支援する CAD (コンピュータ支援診断) システムに関する研究が進められ、いくつかの製品が臨床現場で使われるようになった [1] [2]。し

かし、CAD の認識性能、解析性能はまだまだ不十分であり、本格的な普及には至っていないのが実態である。

CAD の性能向上のために重要となるのは、教師となる大量の症例データである。深層学習の登場により、一般写真画像分野の認識技術は急速に向上し、最近では、人間同等の認識性能を達成している研究結果の報告も散見されるようになった。人物や風景などの一般写真画像データは、インターネット等を通じて大量に収集可能であるということも、深層学習による性能向上に大きく寄与している。

医療分野においては、コンピュータの認識性能は放射線医には遠く及ばない。性能向上のためには、新たな認識技術の研究開発と同様に、質が高くバリエーションに富んだ大量の症例収集が重要となる。しかし、医療分野において

*1 駒澤大学医療健康科学部
[〒305-8573 東京都世田谷区駒沢 1-23-1]
e-mail: shimura@komazawa-u.ac.jp

*2 NTT 東日本関東病院

*3 国際医療福祉大学三田病院

は、個人情報保護や倫理的な配慮が必要であるため、症例データの収集は容易ではない。

最近では、米国の NIH に加え、日本国内でもこうした深層学習を想定したデータベース整備も開始されたが、まだまだ、質、量ともに圧倒的に不足していると言わざるを得ない。

こうした背景の中、症例データを人工的に生成する研究として、CT 画像やマンモグラフィ画像に、別の症例から腫瘍等の病変を抽出し、画像上に埋め込むことにより、新たな症例画像を人工的に埋め込む研究がおこなわれている [3]。

例えば、日本画像工学会では、縄野らにより、肝臓腫瘍を埋め込んだ実症例と見分けがつかない人工 CT 症例画像生成のコンテストが実施され、関連する研究が複数の研究機関で行われた [4]。

また、GAN (Generative Adversarial Network) や VAE (Variational Autoencoder) ように深層学習により、教師データに似た新しいデータを生成する手法が提案され、様々な研究が進められている [10]。これらの取り組みは、医用画像処理分野における症例データ不足を補う手法として CAD システムの開発への有効性が期待できる。

本研究では、こうした過去の取り組みと同じく、人工的な症例を生成する事を目的としている。本研究では、過去の様々な研究と異なり、画像中の形状に着目し、形状を数式で表現することにより、数式を表すパラメータを特徴量として、形状を解析する可能性を示すとともに、パラメータを変更する事により新たな形状を生成し、形状を元に、新たな病変を人工的に生成する検討を行った。

なお、本研究では形状の数式表現手法として Kuhl らによる楕円フーリエ記述子 (Elliptic Fourier descriptors) に着目した [5]。楕円フーリエ記述子はこれまで、動物や植物等の生物の形状の解析や、ボトル等の人工物の形状解析に用いられているが、画像の生成に利用された例はない。

本研究では、マンモグラフィ画像中の石灰

化陰影の分布形状を楕円フーリエ記述子に変換し、楕円フーリエ記述子の周波数成分を主成分分析し、得られた特徴量を用いて、石灰化分布の形状を解析、分類について検討した。

また、主成分を変化させることによる新たな石灰化分布形状を生成し、得られた分布形状に基づく人工石灰化症例画像の生成を検討した。

2. 楕円フーリエ記述子

本研究で用いた形状の数値化手法の一つである楕円フーリエ記述子について以下、説明する。

まず、輪郭を示す曲線上を点が時間 t と共に移動したと考え、図 1 に示すように図形の輪郭を x, y 平面に投影する、このときの x 座標と y 座標は時間 t の関数 $x(t), y(t)$ となり、輪郭上を移動する点が 1 周回って元の位置に戻ってくる時間 T を周期とする周期関数と考えることができる。

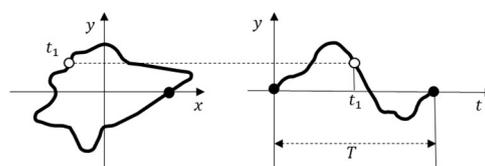


図 1 輪郭上を移動する点と y 座標の関数 $y(t)$

周期関数はフーリエ級数展開が可能であるため、 $x(t), y(t)$ は以下のように周波数の異なる三角関数の線形結合として表現できる。

$$x(t) = \frac{a_0}{2} + \sum_{n=1}^N \left(a_n \cos \frac{2n\pi t}{T} + b_n \sin \frac{2n\pi t}{T} \right) \quad (1)$$

$$y(t) = \frac{c_0}{2} + \sum_{n=1}^N \left(c_n \cos \frac{2n\pi t}{T} + d_n \sin \frac{2n\pi t}{T} \right) \quad (2)$$

このとき、フーリエ級数展開では N が ∞ のとき、輪郭は三角関数の線形結合として正確に表現できる。

しかし、輪郭の形状を大まかに表現するのであれば、 N は有限で構わない。例えば、 $N=1,2,3,4$ とした際に表現される輪郭を図 2 に示すが、 $N=4$ でも元の輪郭を概ね表現できていることが

わかる。なお、本研究では $N=20$ として検討を行った。

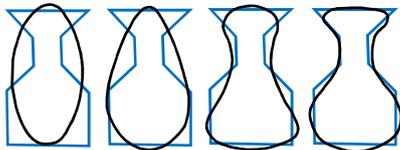
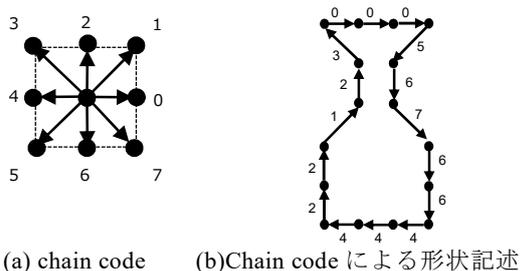


図 2 $N=1\sim 4$ の楕円フーリエ記述子に対応した形状

次に、図形の輪郭から、楕円フーリエ記述子を求める具体的な方法について説明する。まず、輪郭をチェーンコードと呼ばれるコードに変換する。輪郭上の開始点を決め、開始点に隣接する輪郭上の点の方向によって図 3 に示す 8 方向を示すチェーンコードラベルを用いて表す。このように隣接する輪郭上の点を次々にチェーンコードで表現することにより、1 周分の輪郭をチェーンコードで表現することができる。



(a) chain code (b)Chain code による形状記述

図 3 チェーンコードを用いた形状記述

また、得られたチェーンコードから、時間とともに変化する輪郭上の点の x, y 座標の関数を求めることができ、その関数をフーリエ級数に展開し、 N 個までの高調波の各係数を算出することにより、楕円フーリエ記述子を得ることができる。

なお、 $N=1$ の時、輪郭は楕円として表現されるが、この楕円の半長軸を基準に、サイズ、輪郭の向き、計測開始点を標準化している。

こうして得られたフーリエ記述子は高次元の特徴量であり、各輪郭は特徴空間の 1 点に対応する事になる。また、様々な輪郭から得られたフーリエ記述子に対し主成分分析を行い、高次元の情報から低次元の特徴量を得ることに

より、輪郭形状の違いを表す主たる特徴量を求めることができる。

また、主成分の値を変化させることによって、様々な形状に対応したフーリエ記述子を得る事ができる。さらに、楕円フーリエ記述子に対し逆フーリエ変換を行うことにより、様々な形状の輪郭を生成することができるため、本研究では、こうして生成された輪郭形状を利用し新たな石灰化症例を生成する事を試みた。

3. 実験方法

1) 実験方法

(a) 石灰化分布形状の解析

BI-RADS の各石灰化分布タイプを図 4 に示す。Clustered distribution, Linear distribution, Segmental distribution では悪性の可能性が高く、Diffuse distribution や Regional distribution では良性の可能性が高いと言われてている。

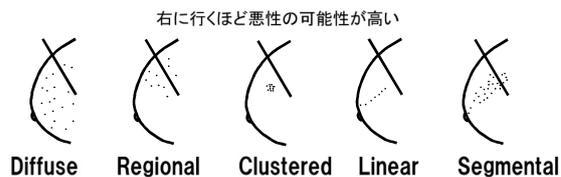


図 4 BI-RADS における石灰化分布タイプ

楕円フーリエ記述子の応用として、石灰化分布のタイプ分類への適用可能性について検討した。

まず、原画像中の各石灰化の位置を中心とする円形領域を描き、その和集合を取ることにより各症例の石灰化分布領域を得る。得られた石灰化分布形状を対象に、楕円フーリエ記述子及び外接四角形の面積を用いて解析を行った。

なお、Segmental distribution に関しては石灰化分布領域が複数領域に分離している症例もあり、その場合は主たる石灰化分布領域のみを対象とした。

また、楕円フーリエ記述子への変換及び関連する解析は、岩田らにより開発された楕円

フーリエ記述子の解析ソフトウェアである SHAPE 及び SHAPE on R を用いて行った [6] [7].

(b)人工石灰化分布画像の生成

前述した分布形状の解析で、得られた主成分を利用して石灰化分布画像を人工的に生成する。

まず、得られた主成分の内、第1第2主成分を変化させ、様々な形状を示す楕円フーリエ変換記述子を得る。その後、楕円フーリエ変換記述子を元に、形状の大きさや、分布の方向及び分布を埋め込む位置を個別に指定し、石灰化分布形状を生成する。

続いて、得られた石灰化分布領域内にランダムに石灰化点を配置する座標を設定し、あらかじめ、抽出しておいた石灰化陰影を、埋め込むことにより新しい石灰化症例画像を生成した。

2) 実験に用いた臨床データ

本研究ではマンモグラフィー画像の公開データベースである米国の CBIS-DDSM (Curated Breast Imaging Subset of DDSM)の画像データ及び付随する臨床データを用いて行った [8]. CBIS-DDSMは1999年に整備された DDSM (The Digital Database for Screening Mammography)をベースとしている [9].

DDSM はスクリーニングマンモグラフィーのデジタルデータベースで、1988年から1999年までにフィルムスクリーンシステムで4方向(左CC,左MLO,右CC,右MLO)撮影された2620画像のマンモ画像および付随する臨床情報からなる。マンモグラフィー画像はマサチューセッツ・ゼネラル・ホスピタル、ウェークフォレスト大学、聖心病院、セントルイスワシントン大学で撮影されたもので、フィルムデジタルイザーを用いて1画素42~50micron, 12~16ビットでデジタル化されている。

また、DDSMデータベースには画像データだけでなく、BI-RADSをベースにした乳腺濃度情報、病変の有無や腫瘍性病変か石灰化病変であ

るかの情報、腫瘍の場合は形や境界の情報、石灰化の場合は石灰化の性状や分布タイプさらには病理検査結果も付加されている。

CBIS-DDSMはDDSMをベースにした753例の石灰化症例と891例の腫瘍症例が含まれているが、DDSMに含まれている不適切なデータの削除や情報の修正に加え、セグメンテーション情報、バウンディングボックス情報の追加、トレーニング用症例とテスト用症例に分離するなど、最近のコンピュータビジョン分野で主流となっているデータベースに準じたフォーマットに整備されている。

なお、本研究ではCBIS-DDSMのトレーニング用石灰化症例から、表1に示すように、石灰化分布タイプ毎に石灰化症例数例を選び実験に用いた。

表1 実験に用いた症例数

Diffuse	Regional	Clustered	Linear	Segmental
2	7	12	6	7

4. 結果

1)石灰化分布の解析

マンモグラフィー画像から得られた Diffuse distribution, Regional distribution, Clustered distribution, Linear distribution, Segmental distribution といった BI-RADS における5つの分布タイプに対応する石灰化分布形状を図5に示す。分布タイプにより、分布の面積や形状が異なることがわかる。

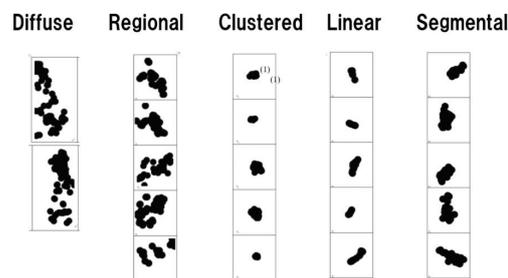


図5 各タイプの石灰化分布の例

次に、各分布の外接四角形の面積の分布を確認した。分布タイプ毎の面積の分布が正規分布に基づくかと仮定し、平均と分散から算出した分

布を図 6 に示す。

図 6 から Diffuse distribution, Regional distribution, Segmental distribution とそれ以外 (Linear distribution, Clustered distribution) はおおむね分離できるが, Linear distribution と Clustered distribution の分布は大きく重複し, 面積だけでは分離できないことがわかる。

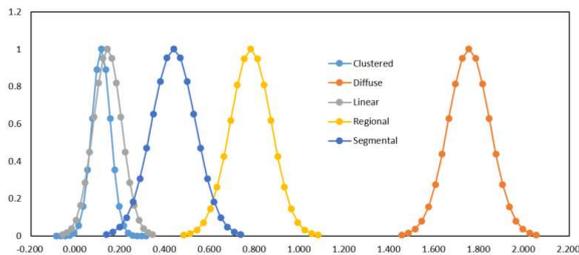


図 6 各タイプの外接四角形の面積

続いて, 面積分布が比較的近く, 分類しにくい Segmental distribution, Linear distribution, Clustered distribution の 3 つのタイプの各石灰化分布を対象に分類手法を検討した。

まず, 前記 3 タイプの輪郭から楕円フーリエ記述子を算出し, 主成分分析を行った。

表 2 に寄与率及び累積寄与率を示すが, 第 1 主成分の寄与率 86.6%, 第 4 主成分までの累積寄与率が 95.2% と比較的低下の主成分で分布形状を概ね表現できることが確認できた。

表 2 各主成分の寄与率及び累積寄与率

	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8
寄与率(%)	86.6	4.01	2.91	1.72	1.38	0.95	0.65	0.49
累積寄与率(%)	86.6	90.6	93.5	95.2	96.6	97.5	98.2	98.7

また, 図 7 に第 1~4 主成分の平均及び平均±標準偏差で表される形状を示す。第 1 主成分は分布形状の縦横比に概ね対応し, 第 2 主成分以降は輪郭形状の比較的細かい凹凸に対応していることがわかる。

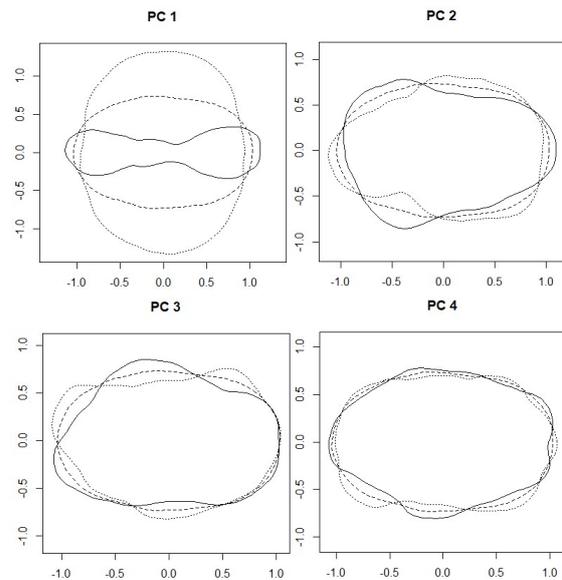


図 7 第 1~4 主成分に対応した輪郭

続いて, 各石灰化分布の特徴量を, 面積を横軸, 第 1 主成分を縦軸に取った座標平面にプロットしたものを図 8 に示す。

Linear distribution および Clustered distribution の石灰化分布は面積指標では大きくオーバーラップするが, 楕円フーリエ記述子から得られた第 1 主成分軸を導入する事により, 分離できることが確認された。

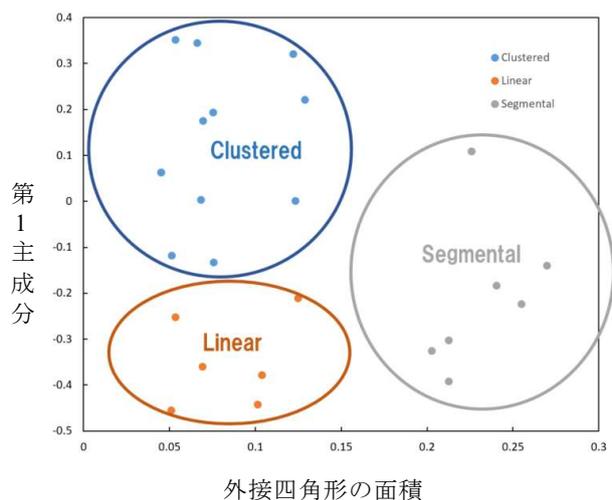


図 8 各タイプの特徴量分布

2) データ拡張への応用

石灰化分布の形状を楕円フーリエ記述子に変換し主成分分析を行い, 得られた第 1, 第 2

主成分からなる特徴量平面に各タイプの分布形状をプロットしたものを図9に示す。

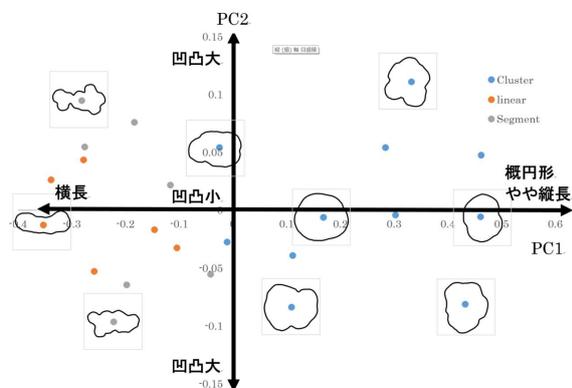


図9 第1, 第2主成分と輪郭形状

第1主成分に関しては値が正の方向に増大するにしたがって概円形でやや縦長の形状となり、負の方向になるにつれ、横長の形状を示すことが分かった。また、第2主成分に関してはその絶対値が小さいと形状の凹凸があまりない滑らかな形状を示し、正負どちらでもその絶対値が大きくなるにつれ、輪郭形状の凹凸が大きくなることが分かった。

次に、このことを利用し、第1, 第2主成分を変化させて得られた分布形状から生成された人工石灰化症例画像を図10に示す。図10に示すように Clustered distribution, Linear distribution, Segmental distribution の分布を呈する人工石灰化症例を生成できることが確認できた。



人工 Clustered 人工 linear 人工 Segmental

図10 生成された人工石灰化症例の一例

5. 考察

今回、我々は石灰化分布の形状に着目し、形状解析技術の一つである楕円フーリエ記述子を適用し石灰化分布の形状特徴を解析し、面積特徴量と組み合わせる事で、BI-RADSの5つの分布タイプに分類できる可能性を示した。

楕円フーリエ記述子は従来の形状特徴量である円形度やアスペクト比といった単一の特徴量と比較して、形状に関するより豊富な情報を表現できていると考えられ、今回用いた第1主成分だけではなく、より高次の主成分を用いることにより、形状のより細かい差異を分類できる可能性がある。

ただし、今回の解析は34例の症例に対して実施したのみであり、より多くの症例画像にて確認する必要がある。

また、楕円フーリエ記述子といった形状を解析する技術を用いて新しい画像を生成するという今回のアプローチはこれまでにない手法である。形状という画像のメタ情報に着目した。新たな形状を生成し、その形状に基づき、画像を生成するアプローチをとっているため、より自然な人工症例画像を生成できる可能性がある。

ただし、今回は、主成分分析に用いたサンプル及び生成サンプルの数は限られているため、今後、より多くの症例を用いた実験により確認していく必要がある。

6. まとめ

楕円フーリエ記述子を応用し石灰化分布の形状特徴を解析し、面積特徴量と組み合わせる事で、BI-RADSの5つの分布タイプに分類できる可能性を示した。

また、楕円フーリエ記述子からえられた第1第2主成分を変化させることで様々な形状の石灰化分布を生成でき、新たに生成された分布形状に基づき石灰化陰影を配置することにより、様々な分布形状を持つ人工石灰化症例を生成できることが分かった。

今後、生成された人工石灰化症例を用いた学習により、性能向上効果を確認するとともに、

楯円フーリエ記述子のさらなる応用を検討していきたい。

利益相反の有無

利益相反なし。

倫理規範の順守

本研究で用いた全ての臨床データは米国の医療機関で収集された公開データベース CBIS-DDSM (Curated Breast Imaging Subset of DDSM)のデータのみである。必要とされる患者同意は本データベースの元となる DDSM (The Digital Database For Screening Mammography)の開発者によって取得されている。

文 献

- [1] Takeo H, Shimura K, Imamura T, et al.: Detection system of clustered micro-calcifications on CR mammogram. *IEICE Trans Inf Syst* **E88-D**: 2591-2601, 2005
- [2] 小畑秀文, 安藤裕, 鴛田栄二, 他: 医療機器評価指標ガイドライン画像診断分野 (コンピュータ診断支援装置) 開発 WG 報告書, 平成 21 年度経済産業省委託事業, 2010
- [3] 安倍和弥, 武尾英哉, 黒木嘉典, 他: 乳がんを対象とした新しい人工石灰化陰影の作成と実症例を全く用いない CAD 開発手法の有効性検証. *Med Imag Tech* **35**: 268-272, 2017
- [4] 北阪孝幸: 第 5 回 JAMIT CAD コンテ
- スト結果報告. *JAMIT News Letter* 16:5-11, 2014
- [5] Kuhl FP, Giardina CR: Elliptic Fourier features of a closed contour. *Computer Graphics and Image Processing* **18**: 236-258, 1982
- [6] Iwata H, Ukai K: SHAPE: A computer program package for quantitative evaluation of biological shapes based on elliptic Fourier descriptors. *Journal of Heredity* **93**: 384-385, 2002
- [7] Iwata H, Niikura S, Matsuura S, Takano Y, et al.: Interaction between genetic effects and soil type in diallel analysis of root shape and size of Japanese radish (*Raphanus sativus* L.). *Breeding Science* **54**: 313-318, 2004
- [8] Lee RS, Gimenez F, Hoogi A, et al.: A curated mammography data set for use in computer-aided detection and diagnosis research. *Scientific Data* **4**: 1-9, 2016
- [9] Heath M, Bowyer K, Kopans D, et al.: The Digital Database for Screening Mammography. *Proceedings of the Fifth International Workshop on Digital Mammography*, 212-218, 2001
- [10] 池田裕亮, 小西孝明, 道満充恵介, 他: 肝臓がん検出器のための 3D-DCGAN を用いた学習用画像生成. 第 37 回医用画像工学会大会予稿集: 232-234, 2018

Analysis of calcification cluster on mammograms and its application for data augmentation using Elliptic Fourier Descriptors (EFD)

Kazuo SHIMURA^{*1}, Sho YASUNAKA^{*2}, Keisuke KONDO^{*1}, Shigeru NAWANO^{*3}

*1 Faculty of Health Sciences, Komazawa University

*2 NTT Medical Center Tokyo

*3 International University of Health and Welfare, Mita Hospital

In the medical field, it is not easy to collect enough teaching data for deep learning. Data augmentation is getting more important to improve the performance.

In this study, we analyzed the shapes of calcification distributions in mammograms using Elliptic Fourier Descriptors (EFD), which is one of the quantitative analyzing methods of the shapes, and we also applied EFD to data augmentation of mammograms with calcifications for CAD research.

Elliptic Fourier descriptors (EFD) is frequency analysis method of closed curves such as contours, and more detailed shaped features can be expressed as compared with conventional features such as circularity and aspect ratio.

The shapes of calcification distributions obtained from the mammograms are converted to EFD data, and a new contour shape of a new calcification distribution is generated from the obtained feature space. According to the generated calcification distribution, a new simulated mammogram is generated by embedding the calcification shadows of the calcification database on another normal mammograms.

We report the results of the verification of the proposed method using CBIS-DDSM, which is a public mammography database.

Key words: Elliptic Fourier Descriptors, Data Augmentation, Mammography

単眼腹腔鏡映像からの奥行き推定を利用した

術具セグメンテーション

鈴木 拓矢^{*1} 道満 恵介^{*1} 目加田 慶人^{*1}

三澤 一成^{*2} 森 健策^{*3}

要旨

腹腔鏡下手術の手術支援システムでは手術の安全性向上のために、腹腔鏡映像に映る術具領域の正確な抽出が必要である。近年ではFCNを用いた術具領域抽出手法が効果を上げている。色情報に加えて奥行き情報をFCNが学習することで、腹腔鏡映像に映る術具領域の抽出精度が向上すると報告されている。本研究では、深層学習による単眼腹腔鏡映像からの奥行き推定と、推定した奥行きと色情報を学習することで、術具領域抽出の精度向上を目指す。MICCAI2017のロボット器具データセットを対象に実験した。1,800枚の画像に対して4分割交差検証をした結果、平均IoUが89%、平均Dice係数が94%となった。推定した奥行き情報を学習に追加することで、誤抽出の低減と輪郭の抽出精度が向上することを確認した。

キーワード：腹腔鏡下手術, Fully Convolutional Network, 奥行き推定, 術具セグメンテーション

1. はじめに

腹腔鏡下手術とは、患者にかかる負担が軽い治療方法である。しかし、医師の視野がモニタに限定されることや、術具の操作が制限されるため、医師にかかる負担は重い。このような限定された環境下では、術具の操作は高難度なため、術具の誤操作による侵襲が発生してしまう。そこで、図1のように、術具の異常動作を自動検出し、医師にフィードバックするシステムがあ

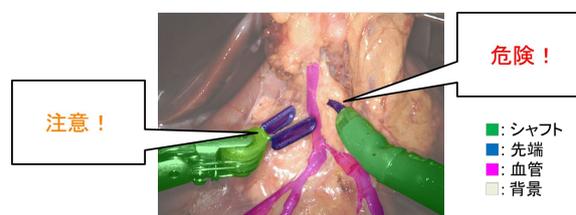


図1 手術支援システムのイメージ

れば、医師は術具の誤操作による侵襲を未然に防ぐことが可能である。異常動作の自動検出には、腹腔鏡映像中の術具・臓器を自動で識別する必要がある。特に、術具によって侵襲が引き起こされるため、術具の位置を正確に求めなければならない。したがって、術具領域はピクセル単位で高精度に抽出する必要がある。近年では、FCNを用いた術具領域の抽出手法が効果を挙げている [1]。従来手法では、腹腔鏡映像の色情報から術具領域を学習し、識別していた。従来手法の術具領域の抽出精度は高いものの、クリップや血液の領域を誤抽出していた。これ

*1 中京大学 大学院工学研究科
〔〒470-0397 豊田市貝津町床立 101〕

e-mail: suzuki.t@md.sist.chukyo-u.ac.jp

e-mail: kdoman@sist.chukyo-u.ac.jp

e-mail: y-mekada@sist.chukyo-u.ac.jp

*2 愛知県がんセンター

e-mail: misawakzn@aichi-cc.jp

*3 名古屋大学 大学院情報学研究科

e-mail: kensaku@is.nagoya-u.ac.jp

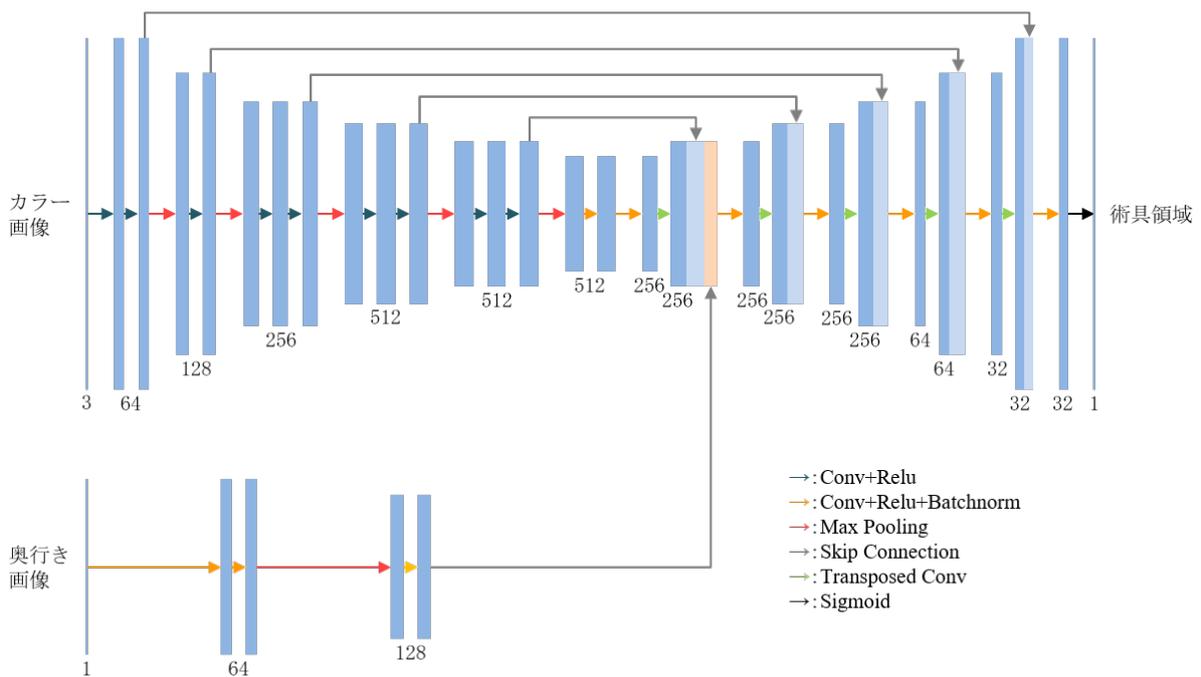


図2 提案するネットワーク構造

らの物体は3次元的な形状が術具と類似していないものの、色が術具と類似していることが誤抽出の原因であった。したがって、術具の領域を正確に求めるには、色だけでなく、3次元的な形状を考慮した術具領域の抽出が望まれる。そこで本研究では、色情報と奥行き情報から術具領域を学習することにより、術具領域の抽出精度の向上を目指す。また、本研究では、最も普及した単眼腹腔鏡を用いた手術映像を対象とする。

2. 提案手法

提案手法は奥行き推定と器具領域の抽出に分けられる。それぞれの詳細を述べる。

1) 奥行き推定の手法

単眼映像からの奥行き推定ではFCRN-DepthPrediction [2]を使用する。FCRN-DepthPredictionは、エンコーダとデコーダをもつネットワーク構造であり、教師あり学習手法である。エンコーダではResNet [3]の構造を使用する。デコーダは、エンコーダの最終層から得られる特徴を逆畳み込みする構造である。FCRN-DepthPredictionの推定精度は、従来の奥

行き推定手法 [4] [5]等の精度よりも高い。

2) 術具領域の抽出手法

術具領域の抽出ではU-Net [6]ベースのネットワークを使用する。提案するネットワークの構造を図2に示す。提案するネットワークは色情報から特徴抽出するエンコーダと、奥行き情報から特徴抽出するエンコーダ、デコーダから構成されている。色情報のエンコーダはVGG16 [7]である。また、色情報のエンコーダはImageNet [8]を用いて事前学習した重みを使用する。デコーダは、エンコーダの各層から抽出された特徴を逆畳み込みする構造である。損失関数には2値交差エントロピー誤差関数を使用し、最適化関数にはAdam [9]を用いる。

3. 実験

実験では、奥行きと術具領域を学習するためのデータセット、奥行き推定の評価、術具領域の推定評価について詳細を述べる。

1) データセット

奥行き推定ではNYU Depth V2 Dataset [10]を用いた。また、術具領域の抽出ではMICCAI 2017 Robotic Instrument Segmentation Dataset [11]

を用いた。NYU Depth V2 Dataset は RGB 画像に対応する奥行きを持つ画像群である。データセットは RGB-D カメラである Kinect を用いて屋内を撮影した画像で構成されている。画像枚数は 1,449 枚、画像の解像度は 640×480 であった。

MICCAI 2017 Robotic Instrument Segmentation Dataset (以降は MICCAI データセットと呼ぶ) は一匹の豚の処置を RGB ステレオカメラで撮影したものである。MICCAI データセットの画像枚数は 1,800 枚あった。また、このデータセットは 8 つの手術シーンで構成されており、1 つの手術シーンは 225 枚あった。これらの画像の解像度は $1,920 \times 1,080$ であった。画像中に映る術具は人の手でラベル付けされた。このデータセットは術具の種類ごとにラベル付けされているが、今回は術具領域と背景領域でラベル付けされた 2 値の画像を教師データとして用いた。

2) 奥行き推定の評価

奥行き推定の評価では、FCRN-DepthPrediction を用いて NYU Depth V2 Dataset を学習したモデルを使用した。このモデルを使用し MICCAI データセットから奥行き推定した結果の例を図 3 に示す。また、モデルの精度は推定値と正解値との二乗平均平方根誤差値を用いて定量的に評価をした。奥行きの正解値は MICCAI データセットから Semi Global Block Matching 法 [12] と重み付き最小二乗フィルタ [13] によって計算して得た。推定結果と正解値との二乗平均平方根誤差値は 4.2 であった。

3) 術具領域の抽出評価

術具領域の推定では MICCAI データセットの画像の色情報と、FCRN-DepthPrediction を用いて画像から推定した奥行き情報を図 1 のネットワークを用いて 4 分割交差検証をした。また、我々は提案手法の結果と従来手法 [1] の結果を Intersection over Union (IoU) と Dice 係数を用いて比較した。実験結果を図 4, 図 5 に示す。従来手法と比較すると提案手法は平均 IoU, 平均 Dice 係数共に約 1% 向上した。色情報だけでなく、奥行き情報を学習に用いることで、すべて

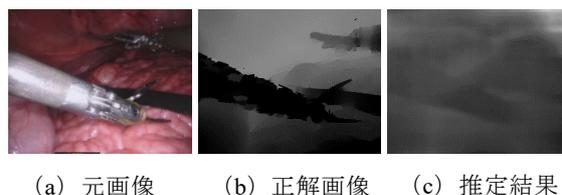


図 3 推定した奥行き画像の例



図 4 IoU の評価結果

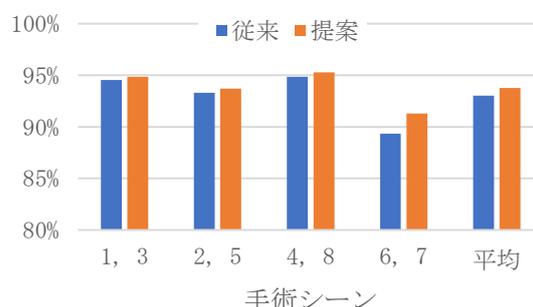


図 5 Dice 係数の評価結果

の画像で提案手法の精度は従来手法の精度よりも上回った。また、提案手法は画像中にクリップや血液が含まれる場合でも誤抽出することなく、術具領域を抽出できた。クリップと血液が含まれる画像から術具を抽出した結果例を図 6 に示す。このことから、提案手法の有効性が確認された。しかし、画像の局所領域の精度が低下した例が確認された。画像の局所領域の精度が低下した例を図 7 に示す。この例の誤抽出した領域には、臓器が映っていた。

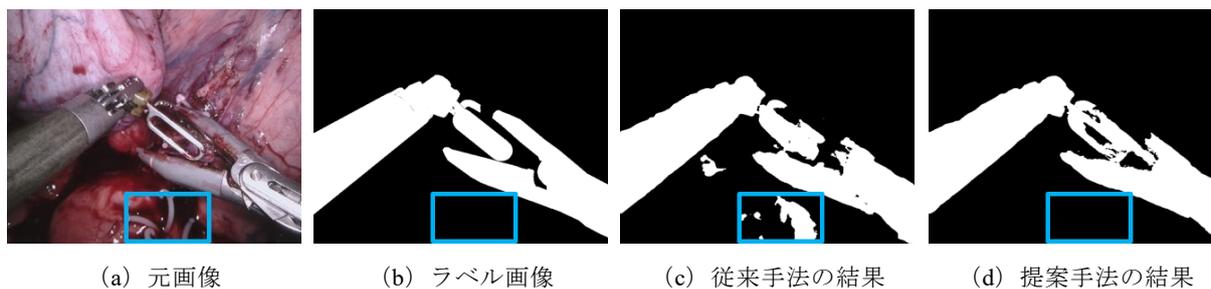


図 6 誤抽出が低減した例

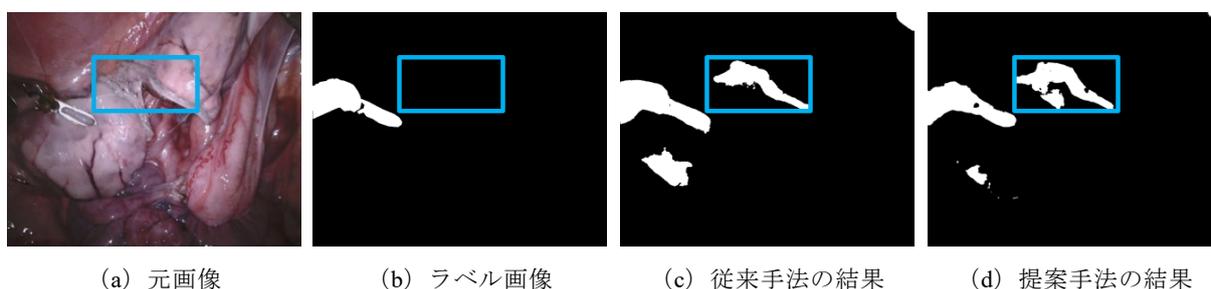


図 7 局所領域の抽出精度が低下した例

4. 考察

提案手法によって得られた、MICCAI データセットにおける、術具領域の抽出結果について考察する。

1) 誤抽出を低減できた例

提案手法は色だけでなく、物体の 3 次元的な形状を学習したことにより、術具と類似しない形状を持つ物体、液体を分類できたと考える。特に、クリップは術具と形状が類似しておらず、形状変化が起きにくい物体である。したがって、形状を考慮した領域抽出をする提案手法により、クリップの誤抽出は低減できたと考えられる。また、血液は血液が一か所に集中した場合、術具と色が類似していた。血液が一か所に集中する場合は、術具のような棒状の形状をもたなかったため、術具と血液を分類できたと考えられる。

2) 画像の局所領域の精度が低下した例

誤抽出した臓器の領域は、色と形状が術具と類似していることが確認できた。このことから単一の画像からの術具領域の抽出は困難なパターンがあると考えられる。したがって、術具領域の抽出では、単一の画像から得られる情報だ

けでなく、映像から連続する複数の画像を用いて、物体の動作を解析し、術具を特定することで精度を向上する必要がある。

5. まとめ

本論文では、腹腔鏡下手術支援に向けた単眼腹腔鏡映像からの術具領域の抽出をした。提案したネットワークが、色情報と推定した奥行きから術具領域を学習することにより、術具の抽出精度が向上した。特に、従来では血液や、クリップを誤抽出していたが、提案手法では誤抽出を低減することが出来た。しかし、提案手法は、色と形状が類似している臓器に対して誤抽出した。今後の課題は、他のネットワークの利用や、単一フレームだけでなく複数のフレームを用いた術具領域の抽出により、抽出精度を向上する必要がある。

謝辞

本研究の一部は、日本学術振興会科研費補助金の援助による。

利益相反の有無

なし

文 献

- [1] Shvets A. A, Rakhlin A, Kalinin A. A, et al.: Automatic Instrument Segmentation in Robot-Assisted Surgery Using Deep Learning. Proc. IEEE International Conference on Machine Learning and Applications (ICMLA), 2018
- [2] Laina I, Rupprecht C, Belagiannis V, et al.: Deeper depth prediction with fully convolutional residual networks. Proc. IEEE International Conference on 3D Vision (3DV), pp. 239-248, 2016
- [3] He K, Zhang X, Ren S, et al.: Deep Residual Learning for Image Recognition. Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770-778, The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, 2016
- [4] Eigen D, Puhrsch C, Fergus R.: Depth map prediction from a single image using a multi-scale deep network. Proc. Advances of Neural Information Processing Systems (NIPS), pp. 2366-2374, 2014
- [5] Roy A, Todorovic S.: Monocular depth estimation using neural regression forest. Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016
- [6] Ronneberger O, Fischer P, Brox T.: U-net: Convolutional networks for biomedical image segmentation. Proc. Medical Image Computing and Computer-Assisted Intervention (MICCAI), pp. 234-241, 2015
- [7] Simonyan K, Zisserman A.: Very deep convolutional networks for large-scale image recognition. Proc. International Conference on Learning Representations (ICLR), 2015
- [8] Deng J, Dong W, Socher R, et al.: ImageNet: A Large-Scale Hierarchical Image Database. In Proceedings of the IEEE Computer Vision and Pattern Recognition (CVPR), 2009
- [9] Kingma D P, Ba J L.: ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION. Proc. International Conference on Learning Representations (ICLR), 2015
- [10] Silberman N, Hoiem D, Kohli P, et al.: Indoor segmentation and support inference from RGBD images. Proc. European Conference on Computer Vision (ECCV), pp. 746-760, 2012
- [11] Allan M, Shvets A, Kurmann T, et al.: 2017 Robotic Instrument Segmentation Challenge. <https://arxiv.org/abs/1902.06426/>, 2017
- [12] Hirschmuller H.: Stereo processing by semiglobal matching and mutual information. Proc. IEEE Transactions on pattern analysis and machine intelligence (TPAMI), pp. 328-341, 2008
- [13] Min D, Choi S, Lu J, et al.: Fast global image smoothing based on weighted least squares. Proc. IEEE Transactions on Image Processing (TIP), pp. 5638-5653, 2014

Surgical Instrument Segmentation using Estimated Depth from Monocular Laparoscopic Images

Takuya SUZUKI^{*1}, Keisuke DOMAN^{*1}, Yoshito MEKADA^{*1}, Kazunari MISAWA^{*2}, Kensaku MORI^{*3}

*1 Graduate School of Engineering, Chukyo University

*2 Aichi Cancer Center

*3 Graduate School of Informatics, Nagoya University

It is necessary to extract surgical instruments from laparoscopic images in order to improve the safety of laparoscopic surgery using a surgery support system. It is reported that the segmentation accuracy can be improved by using color and depth information. In this paper, we propose a U-Net based image segmentation network using the estimated depth information as well as color information for improving the accuracy. We conducted experiments using 4-fold cross validation with 1,800 images in the MICCAI challenge dataset, and confirmed that the proposed method achieved the average IoU of 89% and the average Dice coefficient of 94%. The proposed method reduced the excessive extraction and improved the extraction accuracy by using the estimated depth information as well as color information.

Key words: Laparoscopic Surgery, Fully Convolutional Network, Depth Estimation, Surgical Segmentation

深層学習を用いた骨密度測定時の X 線画像における 大腿骨セグメンテーション

押川 翔太*¹ 胡 尔重*¹ 中矢 知宏*¹ 高橋 涉*²

要旨

骨粗鬆症の診断では DXA（dual-energy X-ray absorptiometry）法を用いた骨密度の測定が重要視されている。DXA 法による骨密度測定では、骨部の正確なセグメンテーションが再現性の高い骨密度の測定に重要である。そこで本研究では、骨密度測定時の大腿骨 X 線画像の骨部を、深層学習を用いて高精度にセグメンテーションする手法を提案する。骨密度測定時の臨床 X 線画像を用いて学習を行い、学習に使用していない評価用データ 100 枚を用いて性能評価を行った。結果として骨密度測定に重要な大腿骨頸部を中心とした領域において平均 IoU(Intersection over Union) 96.5%となり、高精度にセグメンテーション可能であることを確認した。

キーワード：骨密度測定，大腿骨 X 線画像，深層学習，セグメンテーション

1. はじめに

骨粗鬆症の診断に用いられる DXA 法による骨密度の測定では、経過観察における再現性向上のため、骨部の正確なセグメンテーションが重要である。また近年では深層学習によるセマンティック・セグメンテーション(Semantic Segmentation)が注目されており、様々なタスクで高精度なセグメンテーションが可能であることから、医用画像処理への応用が進んでいる。

そこで本研究では、骨密度測定時に取得した大腿骨 X 線画像の骨部を、深層学習を用いて高精度にセグメンテーションする手法を提案する。提案手法の検証では、学習に使用していない大腿骨 X 線画像に対する性能を確認する。

2. 手法

本研究では U-Net[1]をベースとして深層学習モデルの設計を行い、対象とする大腿骨 X 線画像に合わせてパラメータを設定する。大腿骨 X 線画像を入力し、骨領域ラベル画像を出力するように学習を行う。

3. 結果

学習・推論ともに骨密度測定時の大腿骨 X 線画像を使用した。これら臨床画像の骨密度分布はおよそ $0.4\sim 1.2\text{ g/cm}^2$ であり、幅広い骨密度分布を持つデータセットで評価を行った。

*1 株式会社島津製作所 医用機器事業部 技術部

〔〒604-8511 京都市中京区西ノ京桑原町1〕

e-mail: s-oshi@shimadzu.co.jp

*2 株式会社島津製作所 基盤技術研究所 AIソリューションユニット

評価には画像セグメンテーションで一般的に使用されている IoU (Intersection over Union) を採用した。IoU が大きい程、推論結果の骨領域ラベルが正解ラベルと比較してはみ出しや欠けが少なく、抽出精度が高いことを意味する。なお、性能評価は骨密度測定時に重要となる大腿骨頸部を中心とする領域を対象として評価を行った。

学習に使用していない評価用データ 100 枚を学習済みモデルに入力して性能評価を行った結果、平均 IoU (Intersection over Union) 96.5%となった。

4. 考察

図 1 にセグメンテーション結果の例を示す。中央部の正方形の白枠内部が評価対象領域であり、黄色が推論結果と正解ラベルが重なる領域、赤色が推論結果のみの領域、緑色が正解ラベルのみの領域を表す。図 1 から精度良く大腿骨の骨部領域が抽出されていることが確認できる。骨密度の計測部位となる大腿骨頸部においては、大腿骨頸部のエッジが比較的明瞭であるため、正解ラベルとの一致度が高いと考えられる。一方、評価対象外の骨盤の領域では正解ラベルとの不一致が散見された。X 線画像の骨部が不明瞭な領域であることから、このような領域では骨部の判定精度が低下すると考えられる。

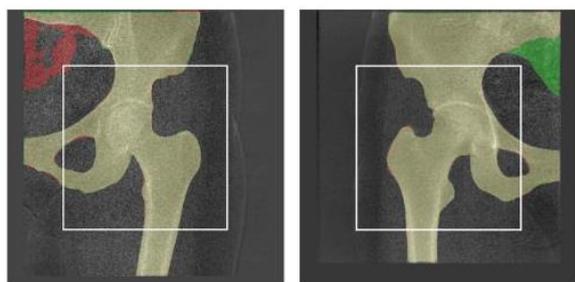


図 1 評価用データのセグメンテーション結果の例。中央部の正方形の白枠内部が評価対象領域。(黄：推論結果と正解ラベルが重なる領域、赤：推論結果のみの領域、緑：正解ラベルのみの領域。)

5. まとめ

本研究では深層学習によるセマンティック・セグメンテーションを用いた大腿骨 X 線画像の骨部領域の抽出を試行した。学習に使用していない 100 枚の評価用データに対して評価を行った結果、骨密度測定に重要な大腿骨頸部を中心とした領域において平均 IoU 96.5%となり、高精度に大腿骨をセグメンテーション可能であることを確認した。

利益相反の有無 なし

文 献

- [1] Ronneberger O, Fischer P, Brox T: U-Net convolutional networks for biomedical image segmentation. Medical Image Computing and Computer-Assisted Intervention (MICCAI), Springer, LNCS, Vol.9351: 234--241, 2015

Femoral segmentation with deep learning in X-ray images for bone mineral density measurement.

Shota OSHIKAWA^{*1}, Erzhong HU^{*1}, Tomohiro NAKAYA^{*1}, Wataru TAKAHASHI^{*2}

^{*1} R&D Department, Medical Systems Division, Shimadzu Corp.

^{*2} AI Solution Unit, Technology Research Laboratory, Shimadzu Corp.

Measurement of bone mineral density (BMD) by dual-energy X-ray absorptiometry (DXA) is commonly used in the diagnosis of osteoporosis. In the DXA method, accurate bone segmentation is important for high reproducibility of BMD measurement. In this study, we propose a method to accurately segment bones in femoral X-ray images using deep learning. We trained the deep learning model by using clinical femoral X-ray images of BMD measurement, and evaluated segmentation accuracy by using 100 data which were not used for training. As a result, mean IoU (Intersection over Union) was 96.5% in the region centered on the femoral neck, and high enough.

Key words: bone mineral density measurement, femoral X-ray images, deep learning, segmentation

金属表面紋様の画像照合による手術器具の個品管理

牧野 賢吾*¹ Jesse de Wit*² 石山 壘*¹ 高橋 徹*¹ 工藤 佑太*¹

要旨

本稿では、画像照合による手術器具の個品管理システムを提案する。資産や作業履歴の管理のために、一般的にマーキングやタグによる個体識別が行われる。しかしながら、器具によってはマーキングやタグの付与が不可能であり、個体識別が困難な場合がある。さらに、さらにマーキングやタグ付与にコストがかかる問題がある。そこで、本稿では、物体表面の微細なランダム凹凸パターンをマクロ撮影によって画像化し、それら画像を照合することで個体識別を行う物体指紋認証技術の適用を提案する。提案手法は、器具の表面を撮影するだけでよく、マーキングやタグの付与が困難な器具に対しても、個品管理を低コストかつ容易に実現できる。実験では、メス、ピンセット、ハサミの3種類の金属製手術器具各5個体に対し、特定部位をマクロ撮影した画像を照合することにより、誤りなく個体識別できることを確認した。さらに、ロボットアームを活用し、手術器具を置く操作のみで個品管理可能な自動撮影システムを試作した。

キーワード：画像照合，個体識別，手術器具，トレーサビリティ

1. はじめに

近年、病院内での資産管理や作業履歴の管理のために、手術器具の個品管理の必要性が高まっている。個品管理の実現により、使用回数を集計し、頻度の少ない器具の過剰在庫の防止や交換時期の予測など、効率化も可能となる。個品管理のためには、器具1つ1つにUDI(Unique Device ID)を割り当て、付与する必要がある。これまで、RFID タグを器具に取り付ける方法[1]や、バーコードやQRコードを直接マーキングする方法[2]が用いられている。しかし、タグの脱落のリスクや、付与に特別な加工を要し、在庫器具への適用にはコストが膨大にかかるといった課題がある。

これら課題に対し、本稿では、タグやマーキングに代わり、手術器具そのものを撮影して得られた画像を照合する個体識別手法を提案する。具体的には、物体表面に存在する個体ごとに異なる微細な表面凹凸を撮影し、その表面凹凸のパターンを照合して個体識別を行う手法

(物体指紋認証技術)[3]を活用する。メス、ピンセット、ハサミの3種類の金属製手術器具(鋼製器具)各5個体に対し、特定部位をマクロ撮影した画像を照合することにより、誤りなく個体識別できることを確認した。さらに、ロボットアームを活用した自動撮影システムを試作し、鋼製器具を置くだけの操作のみで個品管理を実現できること示す。

2. 提案手法

微細な表面凹凸パターンを可視化させるために、文献[4]の撮影法を用い、マクロ撮影する。物体表面へ適切な角度で投光することで、微細な表面凹凸が反射光の強度に対応付けられ、明瞭な物体指紋画像(以降、指紋画像と呼ぶ)が得られる。個体識別を行うためには、まず、器具の個体毎に指紋画像を撮影し、UDIと紐づけてデータベースに登録しておく。次に、器具のUDIを得る際には、再度、同一箇所を撮影し、データベース中の画像と照合する。一致した画像に紐づけられたUDIを参照することで器具の個体識別を実現する。登録画像と照合画像間には並進・回転・スケールの変動が生じるので、文献[5]の手法を用い、変動に対して頑健かつ高速な画像照合を実現する。

*1 NEC データサイエンス研究所
e-mail: k-makino@mb.jp.nec.com

*2 Delft University of Technology
Biomedical Engineering

3. 実験

画像照合による個体識別精度を検証するため、メス、ピンセット、ハサミのそれぞれについて物体指紋を撮影する箇所を決め、1 個体について 2 回ずつ撮影を行った。撮影には図 1(a)に示すカメラ、レンズ、照明を一体化した撮影装置を用いた。図 1(b)に各鋼製器具の外観と撮影箇所を、図 1(c)(d)に撮影した指紋画像の例を示す。各種類 5 個体分撮影し、1 枚目の指紋画像を登録画像、2 枚目の指紋画像を照合画像とした。実利用時を想定し、撮影位置・姿勢が変化するように、1 枚目の撮影を終えた後、鋼製器具を置きなおしてから 2 枚目の撮影を行った。

照合の結果、同一個体間のスコアはすべて 0.5 以上、異なる個体間のスコアは 0.05 未満であり、閾値判定により照合精度は 100% となった。

4. 自動撮影システム

指紋画像の撮影はマクロ撮影であるため、物体指紋が視野に映るよう位置を微調整し、焦点が合うよう高さを微調整する必要がある。この調整作業は繊細で作業負荷が高いため、この作業を自動化する、ロボットアームを活用した撮影システムを試作した(図 2)。試作撮影システムは、アームの先に図 1(a)の撮影装置を取り付けており、置かれた鋼製器具の指紋画像を自動的に撮影できる。文献[6]と同様、別途設置した広角カメラの画像を用いて、器具の位置・種類を認識し、器具の指紋箇所の位置に撮影装置を動かす。本システムにより、利用者は鋼製器具を置くだけで、個体識別を行うことができる。

5. まとめ

本稿では、タグ付けやマーキングが不要な、画像照合による鋼製器具の個体識別手法を提案した。実験では、メス、ピンセット、ハサミの 3 種類の鋼製器具を各 5 個体用いた照合実験において、照合精度 100% で個体識別が可能であることを確認した。また、器具を置くだけで個体識別が行える自動撮影システムを試作した。本システムにより、撮影作業コストを低減し、容易に器具の個品管理を実現できる。自動撮影による照合精度評価、器具の種類・数量を増やしての検証が今後の課題である。

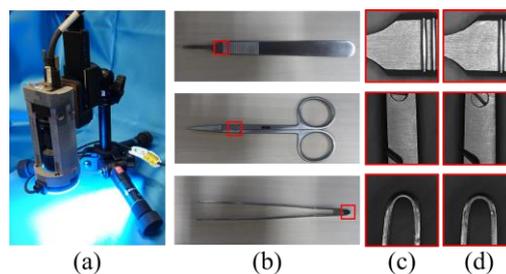


図 1 : (a)指紋画像を撮影するための撮影装置, (b)鋼製器具の外観と撮影箇所(赤枠), (c)撮影される指紋画像の例, (d)別の個体の指紋画像の例

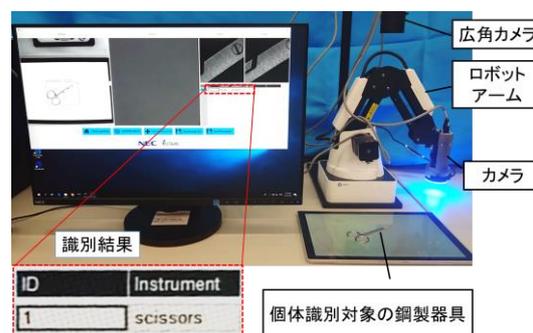


図 2 : 試作した自動撮影システム

利益相反の有無

なし

文献

- [1] S.L. Ting, et al.: Development of an RFID-based Surgery Management System. J. Healthcare Engineering **3-3**: 347-372, 2012
- [2] 佐藤一史 他: 総合滅菌リアルタイムトレーサビリティシステムの導入と運用. 医療機器学 **86**,(3): 347-352, 2016
- [3] 石山 壘: 「物体指紋」を用いた個体識別と認証. VIEW 2018: OS1, 2018.
- [4] T. Takahashi, R. Ishiyama: FIBAR: Fingerprint imaging by binary angular reflection for individual identification of metal parts. EST-2014: 46-51, 2014
- [5] 牧野賢吾 他: Fourier-Mellin 特徴の相関による画像照合の高速化と特徴量削減. MIRU2018: OS3-L1, 2018.
- [6] K. Makino, et al.: Automated Scanning and Individual Identification System for Parts without Marking or Tagging. ACM ICMR2018: 509-512, 2018

Medical Instruments Identification based on Image Matching of Metal Surface

Kengo MAKINO*¹, Jesse de Wit*², Rui ISHIYAMA*¹, Toru TAKAHASHI*¹, Yuta KUDO*¹

*¹ Data Science Research Labs. , NEC Corporation

*² Biomedical Engineering, Delft University of Technology

This paper proposes an individual identification system for medical instruments based on image matching. In general, individual identification using marking or tagging is used to manage assets or work history. However, marking or tagging cannot be applied with special instruments. In addition, they require additional cost. In this paper, we propose “Fingerprint of Things” identification technology for individual identification of medical instruments. The method visualizes micro-scale bumps of the surfaces of medical instruments as unique patterns. Then, it identifies individual instruments by matching them. Because the method only requires image capturing of the instruments, individual management can be easily achieved at low cost, even with special instruments. In our experiments, our method successfully identified five individual medical instruments correctly among three types of metal medical instruments (knives, tweezers, and scissors). In addition, we demonstrated that the individual identification system enables us to capture the unique patterns of the medical instruments automatically using a robot arm.

Key words: Image Matching, Individual Identification, Medical Instruments, Traceability

舌診断支援システムの自動化に向けた 舌検出と領域抽出の検討

唐 啓超^{*1} ヤン テイショウ^{*1} 吉村 裕一郎^{*2}

森 康久仁^{*3} 須鎗 弘樹^{*3} 並木 隆雄^{*4} 中口 俊哉^{*2}

要旨

我々はこれまで舌撮影装置 TIAS を開発し、舌色診断支援システムを構築してきた。この舌色診断支援システムのクリニックや家庭への普及に向けて使用手順の自動化が求められている。そこで本研究ではシステム自動化に向けた舌検出と領域抽出の手法を検討した。舌検出について、先行研究の結果では感度と精度は 0.9 以上に達したが特異度は 0.4 未満と誤検出が多発していた。そこで MobileNets 深層学習モデルを用いた舌検出手法を提案した。TIAS で撮影した舌画像 798 枚を用いてモデルを学習させたところ、舌検出特異度と精度の大幅な向上を確認した。舌の領域抽出について、SLIC と GrabCut を用いた先行研究の結果では平均 IoU 値が 0.75 未満と精度に課題があった。そこで本研究では Pix2Pix 深層学習モデルと領域拡張法を組み合わせた舌領域抽出法を提案した。関連手法との比較評価実験の結果、提案手法の優位性を確認した。

キーワード：舌診、舌検出、領域抽出、深層学習

1. 背景

「舌診」とは東洋医学の診察法の一つであり、舌の色彩、形状、湿潤、舌苔の状態等の所見から患者の体調を診断する。しかし、診断結果は医師の主観や経験に大きく依存するため、定性的である。この問題を解決するため、我々は図 1 に示すような舌撮影装置 TIAS を開発し、舌色診断支援システムを構築した^{[1][2]}。TIAS のクリニックや家庭への普及に向けて使用手順の自動化が求められている。自動化にはカメラのプレビュー動画像から挺舌の状態を検出するためリアルタイム処理が必要である。さらに、撮影後の静止画像 1 枚に対して領域抽出の必要がある。

舌検出について、先行研究として、Haar-Like 特徴量に基づく機械学習を用いた舌検出手法がある。その結果では感度と精度は 0.9 以上に達したが、特異度は 0.4 未満と誤検出が多発していた^[3]。そこで本研究では、MobileNets 深層学習モデルを用いた舌検出手

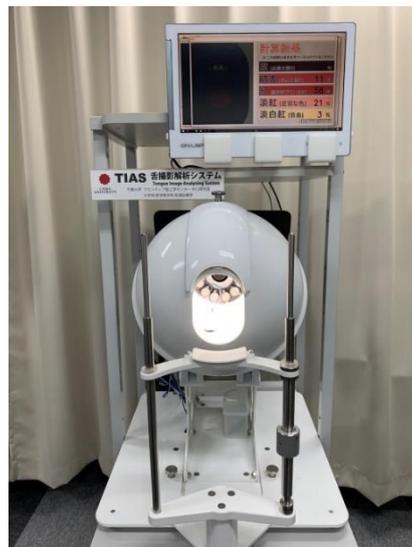


図 1 舌撮影装置 TIAS と舌色診断支援システム

*1 千葉大学大学院融合理工学府

〔〒263-8522 千葉市稲毛区弥生町 1-33〕

*2 千葉大学フロンティア医工学センター

*3 千葉大学大学院工学研究院

*4 千葉大学大学院医学研究院和漢診療学

法を提案した。

舌の領域抽出について、SLIC と GrabCut を用いた先行研究の結果では平均 IoU 値が 0.75 未満と精度に課題があった^[3]。そこで本研究では Pix2Pix 深層学習モデルと領域拡張法を組み合わせた舌領域抽出法を提案した。

2. 提案手法

TIAS のクリニックや家庭への普及に向けて使用手順の自動化が求められている。TIAS 撮影の手順と自動化に必要な措置を図 2 に示す。カメラのプレビュー動画から挺舌の状態を検出するためリアルタイム処理が求められる。一方、撮影後の静止画像 1 枚に対して領域抽出の必要がある。そこで本研究ではシステム自動化に向けた舌検出と領域抽出の手法を検討した。

2.1. 舌検出手法

深層学習(Deep Learning)とは、多層のニューラルネットワークによる機械学習手法で、特徴量抽出を自動化できるという利点がある。近年、画像を対象とした場合、非深層学習の手法より高い性能が示唆されている。

深層学習モデルの一種として MobileNets^[4] は Depthwise Separable Convolution を用いることで、計算速度が一般的な深層学習モデルより速い、リアルタイムでの物体検出が可能となる。また 2 つハイパーパラメータ Width Multiplier と Resolution Multiplier を導入することで、処理時間と精度を調節することができる。スマートフォンやノートパソコンなどの性能に制限があるデバイスにおいても認識や分類モデルへの応用が可能となる。本研究ではリアルタイムの舌検出処理に MobileNets モデルを導入する。図 3 に本研究での提案手法による舌検出の例を示す。

TIAS で撮影した RGB 舌画像 798 枚を用いて MobileNets モデルを学習する。ネットワークに入力する学習画像の解像度は 300×300 で、バッチサイズは 24 である。データ数 798 枚の内 718 枚を訓練データ、80 枚を検証データとして 2000epoch を実行し、loss 値が最も

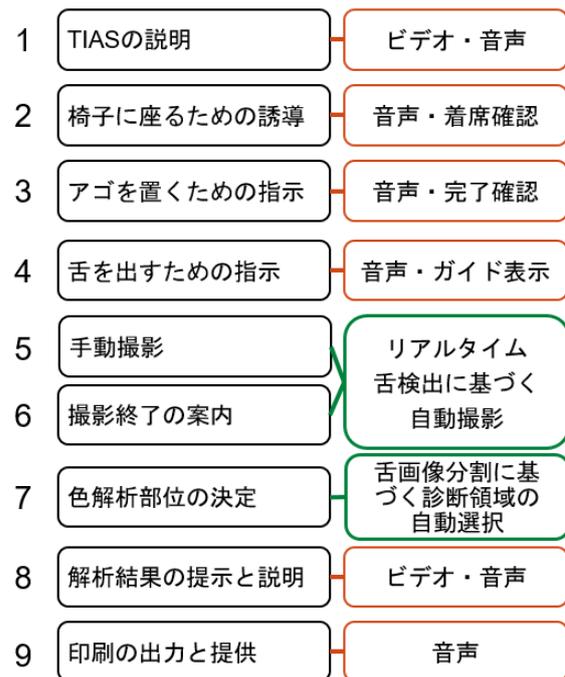


図 2 TIAS 撮影の手順と自動化に必要な措置

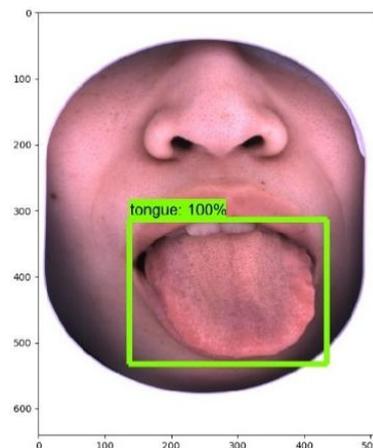


図 3 舌検出の例
緑色矩形領域：舌検出ボックス

小さいモデルを出力する。

舌検出における提案手法の有効性を評価するために TIAS で撮影した 200 枚の舌画像と 33 枚の非舌画像に従来手法と提案手法をそれぞれ適用し、比較評価実験を行った。

2.2. 舌領域抽出手法

Pix2Pix^[5]モデルは GAN を利用した画像生成アルゴリズムの一種で、一対の画像から画像間の関係を学習することで、一方の画像入力から他方の画像を生成することができる。

長谷川らは Pix2Pix モデルで二値化舌画像を生成する手法を提案した⁶⁾。舌画像とそれに対応した二値化舌画像のペアを学習データとして Pix2Pix で学習させ、任意の舌画像を入力した際に対応した二値化舌画像を生成することができる。

本研究では学習データとして TIAS で撮影した 14 人分の被験者の舌画像を用意し、各被験者につき 10~40 枚の舌画像、合計で 424 枚の舌画像を用いた。これらの舌画像と対応した二値化舌画像には、手作業で作成した二値化画像である。図 4 は作成した学習データのペアの一例である。

しかし、Pix2Pix による生成結果では学習データが不十分なため二値化舌画像の出力結果は細かいノイズが発生することが多い。長谷川らは複数枚の出力画像群をピクセルごとに論理積を計算することでノイズ除去を行っているが、1 枚の二値化舌画像の生成に 10 分程度要している。自動化処理を実現するためには、舌領域抽出の処理時間を短縮することは必要不可欠である。この問題を解決するために、領域拡張法⁷⁾を用いて短時間で小領域を除去することを提案する。図 5 に本研究での提案手法によるノイズ除去の例を示す。舌外部の過抽出ノイズを除去する処理と舌内部の欠損を埋める処理をそれぞれ領域拡張により実施した。

しかしながら、テストデータには学習データとは撮影条件が異なる画像がふくまれており、そのような画像に対しては、精度の良い二値化舌画像を生成できない可能性が高い。そこで、本研究では元の 424 枚の舌画像に対して、左右反転と色変換を行うことで、この問題に対応するためのデータ拡張を試みた。舌画像に対して -0.20 から +0.20 までのランダムな輝度調整と 1.0 から 2.0 までのランダムな飽和度調整と 1.0 から 2.0 までのランダムなゲイン調整、異なる順番の組み合わせからランダムに一つを選ぶ、画像入力の 1 イテレーションごとに色変換を行う。さらに、舌検出された検出ボックスをもとに舌画像と二値

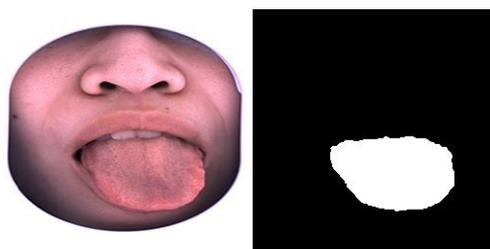


図 4 学習データのペアの例
左側：TIAS で撮影された舌画像(画像を 256×256 にリサイズした)、右側：それに対応した二値化舌画像

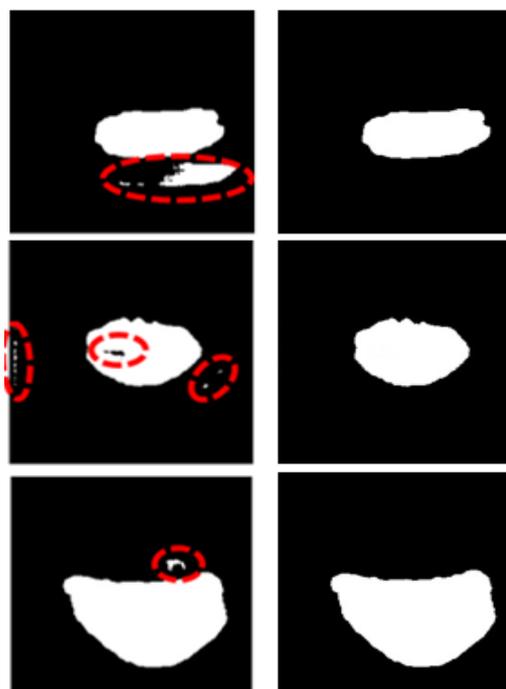


図 5 ノイズ除去の例
左側：ノイズ除去前、右側：ノイズ除去後

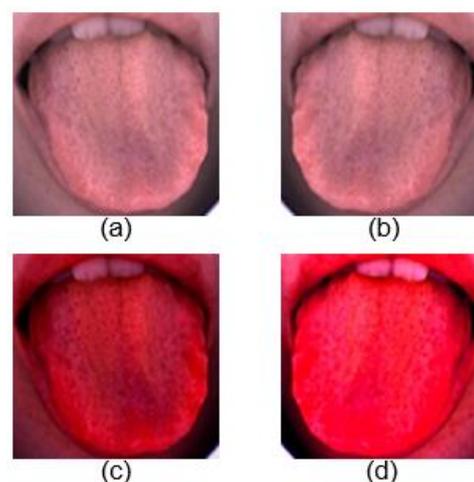


図 6 訓練画像のペアの例
(a)オリジナル舌画像、(b)左右反転した画像、(c)色変換した画像、(d)左右反転と色変換した画像

化舌画像のラベルをトリミングすることで、背景情報による学習精度の低下を防ぐことを試みた。図 6 に示すような画像のペアは今回本研究の学習データとして使用する。

入力画像の解像度は 256×256 で、バッチサイズは 1 である。データ数 424 ペアの内 382 枚を訓練データ、42 枚を検証データとして 50epoch を実行し、loss 値が最も小さいモデルを出力する。

舌領域抽出における提案手法の優位性を示唆するために異なるカメラ条件下で TIAS 撮影した 165 人分の被験者の舌画像用意し、各被験者につき 1~2 枚の舌画像、合計で 170 枚のテスト舌画像に関連手法と提案手法をそれぞれ適用し、比較評価実験を行った。

3. 実験

3.1. 舌検出比較評価実験

TIAS で撮影した 200 枚の舌画像と 33 枚の非舌画像に従来手法の Haar-Like 特徴量を用いた舌検出と提案手法の MobileNets 深層学習モデルを用いた舌検出をそれぞれ適用し、比較評価実験を行った。本研究では評価指標に

Andrew G. Howard ら^[4]の評価実験で使用された IoU 係数を用いた。

今回舌検出成功の判定基準を検出ボックスの IoU 値が 0.7 以上と設定した閾値をもとに 233 枚の画像から舌検出の成否を判定し、感度、特異度、精度の評価を行った。

表 1 に従来手法と提案手法の検出評価結果を示す。Haar-Like 特徴量を用いた舌検出の結果は感度と精度は 0.9 以上に達したが特異度は 0.4 未満と誤検出が多発していた。MobileNets 深層学習モデルを用いた舌検出の結果のそれぞれ評価指標の平均が 1 となったため検出特異度と精度の大幅な向上が確認された。

3.2. 舌領域抽出比較評価実験

学習データと異なるカメラ条件下で TIAS 撮影した 165 人分の被験者の 170 枚テスト舌画像に関連手法と提案手法をそれぞれ適用し、比較評価実験を行った。

テスト舌画像の各手法で生成した二値化舌画像と舌領域抽出画像の結果を図 7 に示す。1 枚の二値化舌画像の生成に要した時間は約 2 秒である。

表 1 舌検出の評価結果

	Haar-Like特徴量	MobileNets
平均感度	93.5%	100%
平均特異度	36.1%	100%
平均精度	91.3%	100%



図 7 テスト舌画像の各手法で出力結果の例

(a)オリジナル舌画像, (b)舌抽出画像(ラベル), (c)Pix2Pix 手法結果, (d)Pix2Pix+Seeded Region Growing 手法結果, (e)Data augmentation+Pix2Pix+Seeded Region Growing 手法結果, (f) Data augmentation+Crop+Pix2Pix+Seeded Region Growing 手法結果

表 2 舌領域抽出の評価結果

Pre-processing	Main method	Post-processing	mIoU
Haar-Like + SLIC	GrabCut	-	73.1%
MobileNets + SLIC	GrabCut	-	81.9%
-	Pix2Pix	-	85.9%
-	Pix2Pix	Seeded Region Growing	87.3%
Data augmentation	Pix2Pix	Seeded Region Growing	90.0%
Data augmentation + Crop	Pix2Pix	Seeded Region Growing	94.7%

実際、提案手法の出力されたモデルのイテレーション数は 43000 である。すなわちイテレーション数と同じに合計 43000 枚舌画像がデータ拡張後の入力画像として生成された。

表 2 に関連手法と提案手法の領域分割評価結果を示す。従来手法の Haar-Like 舌検出に基づく SLIC と GrabCut を用いた舌領域抽出の結果が平均 IoU 値は 0.75 未満である。舌検出手法を MobileNets に変更後、舌検出精度が向上したため、GrabCut 領域抽出結果の平均 IoU 値が 0.819 に向上することが示された。

一方、先行研究の Pix2Pix 深層学習モデルを用いた舌領域抽出の結果が平均 IoU 値は 0.859 である。領域拡張法を後処理として Pix2Pix モデルと組み合わせた後、小領域ノイズを除去することで、領域抽出結果の平均 IoU 値が 0.873 に向上するという改善が確認された。

さらに、データ拡張と舌領域トリミングの前処理手法を提案手法へ導入後、舌領域抽出結果の平均 IoU 値が 0.947 となったため提案手法の優位性が確認された。

4. まとめ

本研究は舌診断支援システムの自動化に向けた舌検出と領域抽出の検討を行った。MobileNets 深層学習モデルを用いた舌検出手法を提案し、従来手法との比較評価実験により舌検出特異度と精度の大幅な向上を確認した。Pix2Pix 深層学習モデルと領域拡張法を組

み合わせて、データ拡張と舌領域トリミングを前処理として追加した舌領域抽出手法を提案した。関連手法との比較評価実験により提案手法の優位性を確認した。

利益相反の有無

なし

文献

- [1] Yamamoto S, Ishikawa Y, Nakaguchi T, et al.: Temporal Changes in Tongue Color as Criterion for Tongue Diagnosis in Kampo Medicine. *Forsch Komplementmed* 2012: 80-85, 2012
- [2] Nakaguchi T, Takeda K, Ishikawa Y, et al.: Proposal for a new non-contact method for measuring tongue moisture to assist in tongue diagnosis, and development of the Tongue Image Analyzing System, which can separately record the gloss components of the tongue. *BioMed Research International* 2015: Article ID 249609, 10 pages, 2015
- [3] 平野諒司, 中口俊哉, 貝沼茂三郎: 大規模画像処理による挺舌中の経時色変化と医学所見との関連解析. *電子情報通信学会技術報告*: vol.115, no.216, IMQ2015-14, 9-14, 2015
- [4] Andrew G. Howard, Menglong Zhu, Bo Chen, et al.: MobileNets: Efficient Convolutional Neural Networks for

- Mobile Vision Applications. arXiv preprint arXiv: 1704.04861, 2017
- [5] Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, et al.: Image-to-image translation with conditional adversarial networks. Proceedings of the IEEE conference on computer vision and pattern recognition, 2017, pp1125-1134
- [6] Hasegawa Y, Tsunashima K, Mori Y, et al.: Generation of binarized tongue image using pix2pix for shape unification. Forum on Information Technology, Fukuoka, 2018, pp343-346
- [7] Adams R, Bischof L: Seeded region growing. IEEE Transactions on pattern analysis and machine intelligence 16.6: 641-647, 1994

Examination of tongue detection and region extraction for automation of tongue diagnosis support system

Qichao TANG^{*1}, Tingxiao YANG^{*1}, Yuichiro YOSHIMURA^{*2}, Yutaka HASEGAWA^{*1}
Yasukuni MORI^{*3}, Hiroki SUYARI^{*3}, Takao NAMIKI^{*4}, Toshiya NAKAGUCHI^{*2}

*1 Graduate School of Science and Engineering, Chiba University

*2 Center for Frontier Medical Engineering, Chiba University

*3 Graduate School of Engineering, Chiba University

*4 Dept. of Japanese-Oriental (Kampo) Medicine,
Graduate School of Medicine, Chiba University

We have developed “Tongue Image Analyzing System (TIAS)” and constructed tongue color diagnosis support system. In order to extend TIAS to clinics and personal homes, the operation of TIAS needs to be automated. In this study, we explored tongue detection and region segmentation extraction methods for system automation. Regarding tongue detection, according to the results of previous researches, sensitivity and accuracy can reach 0.9 or more, however specificity is less than 0.4, and error detection occurred frequently. Therefore, we proposed a tongue detection method using MobileNets deep learning model. The model was trained using 798 tongue images taken with TIAS, and significant improvements in tongue detection specificity and accuracy were confirmed. Regarding region segmentation extraction of tongue, the results of previous researches using SLIC and GrabCut had a problem in accuracy with average IoU value less than 0.75. In this study, we proposed a tongue region segmentation extraction method combining Pix2Pix deep learning model and seeded region growing method. Through a comparative evaluation experiment of related methods, the superiority of proposed method in accuracy was confirmed.

Key words: Tongue diagnosis, Tongue detection, Region segmentation extraction, Deep Learning

少量のラベルデータを用いた学習による イレウス症例CT像における拡張腸管の自動抽出

小田 紘久^{*1}, 西尾 光平^{*1}, 北坂 孝幸^{*2}, 天野 日出^{*3,4},
千馬 耕亮^{*4}, 内田 広夫^{*4}, 鈴木 耕次郎^{*5},
伊東 隼人^{*1}, 小田 昌宏^{*1}, 森 健策^{*1,6,7}

要旨

本稿では, Fully convolutional network (FCN) を用いたイレウス患者の CT 像における腸管領域の抽出において, 手塗りされた教師データが少量であっても精度よく抽出を行う手法を提案する. 腸閉塞をはじめとするイレウス症例の緊急診断支援のため, 腸管を抽出してその走行を提示するシステムの開発が必要である. 一般に FCN の学習を行う場合には大量の学習データが必要であるが, 小腸は複雑に入り組んでいるほか非常に長く, 手動でのラベル作成は容易でない. 本稿では症例ごと 7 枚の Axial スライスのみでラベルが作成された教師データを効率的に使用するためのデータ拡張として, 回転・非剛体変形などの一般的な画像処理のほか, 事前に教師データごとにラベルを他のスライスへ伝播する処理を行うことで, ラベルが手作業で作成されていないスライスも学習に使用可能とする. ネットワークは 3D U-net をもとに入出力サイズを変更を施した Suppressed 3D U-net を用いた. 実験は他のスライスへの伝播処理の有効性を評価するため, 伝播処理あり・なしの比較を行った. 伝播あり・なしの抽出精度を表す Dice 係数はそれぞれ 0.744, 0.782 であり, 伝播処理を行わないほうが高い抽出精度が得られることが知られた.

キーワード: Suppressed 3D U-net, スパースアノテーション, 腸管抽出, 簡易手動抽出

1. はじめに

腸閉塞を含めたイレウス患者の緊急診断においては, 医師が CT 像において腸管をたどり, 閉塞点を探す作業が求められる. とりわけ小腸は腹部において複雑な走行を示すほか全長も長い. 閉塞点を探す作業は多大な労力と慣れを要する. そのため, 自動で腸管の閉塞点を探す手法が求められている.

西尾らは, ヘッセ行列に基づく面状構造強調フィルタを用いて腸管の壁を抽出し, そのフィルタ出力の小さな領域をたどるよう Fast marching algorithm を使用した [1]. この手法では, 腸管の壁の一部が不明瞭である場合にフィルタ出力

も低下し, 抽出に漏れが生じた.

近年, Fully convolutional network (FCN) を含めた深層学習手法による各種臓器・組織の抽出が広く行われている. FCN の学習には画像および, 抽出対象物のラベルが必要となるが, 複雑に入り組んだ腸管を抽出する作業は多大な労力を要するため現実的でない. そこで我々は, 学習用 CT 像における手作業でのラベル付け対象を少数の Axial スライスのみで絞り, それらのラベルのみを用いて学習した場合に正確な抽出が行われることを目指す. とりわけ本稿では, 本来の学習に先立つデータ拡張として, 学習用 CT 像においてラベルを近隣のスライスへ伝播しておき, 多数のスライスを利用することの有効性について調査する.

2. 腸管抽出手法

1) 概要

本手法は CT 像から腸管領域を抽出するものである. ネットワークの学習に用いられる CT 像はそれぞれ n 枚の Axial スライスをもつとす

*1 名古屋大学大学院情報学研究科
〔〒 464-8601 名古屋市千種区不老町〕

email: hoda@mori.m.is.nagoya-u.ac.jp

*2 愛知工業大学情報科学部

*3 東京大学大学院医学系研究科

*4 名古屋大学大学院医学系研究科

*5 愛知医科大学放射線医学講座

*6 名古屋大学情報基盤センター

*7 国立情報学研究所医療ビッグデータ研究センター

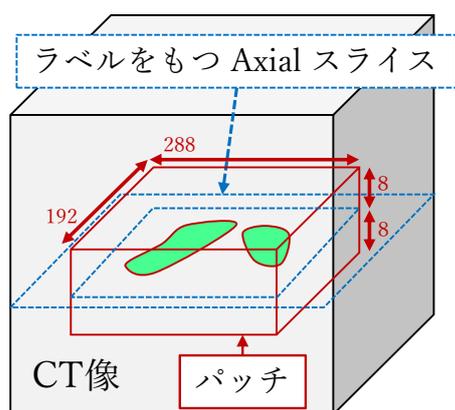


図1 パッチの切り出し方.

ると、8番目から $(n-9)$ 番目までのAxialスライスのうち1枚以上において、腸管のラベルが与えられている必要がある。

2) ネットワーク構成および誤差関数

3D U-net [2] を改変し、入力・出力サイズを $288 \times 192 \times 16$ 画素としたもの (Suppressed 3D U-net) を使用する。Z軸方向は入力サイズが16画素であるため、ネットワーク中でのZ軸方向に対する情報の過度な損失を防ぐよう、13個の畳み込み層のうち7個はXY平面上のみの処理としている。

図1に示すように、ラベルをもつAxialスライス付近をパッチとして切り出すが、その際に16枚あるパッチ内のXY平面のうち中央付近にあたる8枚目に、ラベルをもつAxialスライスが来るようにする。誤差関数はBinary cross-entropyを使用し、その算出に用いるのも8枚目のXY平面のみとする。

3) データ拡張

並進・回転等 CT像に並進・回転ならびに非剛体変形をランダムに行った上でパッチを切り出す。またパッチごと0.95~1.05の係数をランダムに生成し、パッチ内の全画素のCT値[H.U.]に対して係数値を乗算する。

他スライスへの伝播 杉野ら [3] の手法を参考に、学習データそれぞれにおいて事前にラベルを伝播しておくことで、多くのスライスを学習に使用可能とする。

4) 推論

学習されたネットワークはパッチと同サイズの入力を受け、腸管内確率(0~1の実数で、腸管内において高い値、それ以外で低い値)を出力するが、このうち8枚目のXY平面のみが信頼できるものである。CT像の各Axialスライスについて、その周辺を含め16枚のAxialスライスで構成されるパッチを学習時と同様に切り出し、ネットワークで腸管内確率とする。CT像全体において確率を得たうえで、確率が0.5以上の領域を腸管抽出結果とする。

3. 実験および考察

7例の大人のイレウス症例A~Gを{A, B, C}, {D, E}, {F, G}と分け、3分割交差検定を行った。各症例では、腸管の映るAxialスライスのうち7枚を、およそ等間隔となるよう手でラベルを作成し、小児外科医1名によるチェック・修正を受けた。プログラムはKerasにより実装し、学習・テストにはQuadro P6000 (NVIDIA) GPUを1基使用して、10,000イテレーションの学習を行った。事前に抽出結果を他のスライスへ伝播する処理を行った実験を「伝播あり」、単に各症例7枚のラベルを用いて学習を行った実験を「伝播なし」と記す。

表1は交差検定における抽出精度を表し、Dice係数ならびに接続数で評価している。接続数とは、手塗りされた複数のラベルにまたがる自動抽出結果の数を表し、腸管の追跡処理への応用においてはこのような箇所が少ない方がよい。Dice係数・接続数ともに、平均では伝播なしの方が高い精度であった。

図2に結果例を示す。伝播あり(図2(b))の結果では伝播なしの場合(図2(c))に比べ、辺縁まで十分に抽出されていない箇所や、離れたラベルが接続している箇所がみられた。また伝播なしでは全体に辺縁まで1.0に近い値がネットワークより出力されているのに対し、伝播ありの場合は腸管内外でなめらかに出力値が変化している箇所が多い傾向にあった。伝播ありの場合では、伝播の結果が正しいか否かを評価することなくランダムに学習に使用しているため、誤ったラベルでの学習が結果に悪影響を与えた可能性がある。明らかに誤ったラベルは使用し

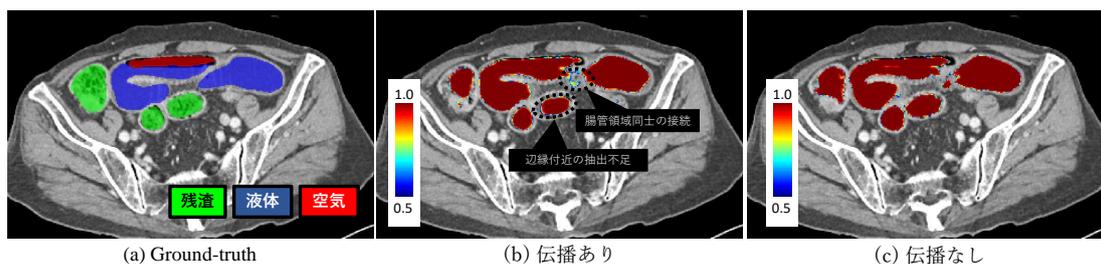


図 2 ネットワーク出力例. (a) Ground-truth. 残渣・液体・空気が色分けされているが、本手法ではこれらを単一クラスとして扱っている. (b) 「伝播あり」の出力. (c) 「伝播なし」の出力.

表 1 各症例の抽出精度. 伝播あり・なしを比較.

症例	Dice 係数		接続数/スライス	
	あり	なし	あり	なし
A	0.675	0.734	0.143	0.000
B	0.732	0.800	1.429	0.714
C	0.805	0.838	0.571	0.571
D	0.861	0.857	0.000	0.143
E	0.871	0.870	0.857	0.714
F	0.400	0.553	0.167	0.333
G	0.865	0.818	0.571	0.000
平均	0.744	0.782	0.534	0.354

コンピュータ外科学会大会, **20(4)**: 348–349, 2018

- [2] Cicek O, Abdulkadir A, Lienkamp S, et al.: 3D U-Net: Learning dense volumetric segmentation from sparse annotation, MICCAI 2018 LNCS 0091: 424–432, 2016
- [3] Sugino T, Roth H, Oda M, et al.: Automatic segmentation of eyeball structures from micro-CT images based on sparse annotation, SPIE Medical Imaging 2018, **10578**, 2018

ない, 手作業で得たスライスと伝播処理で得たスライスの学習バッチ中の制約をつけるなどの改善が考えられる.

4. まとめ

本稿では FCN による CT 像からの腸管自動抽出手法を提案し, そのデータ拡張として, スライスの伝播処理により学習データ中における多くのスライスを使用可能となった反面, 伝播処理の正確性を問わずにランダムにスライスを選定して学習に使用したために精度の低下を引き起こした. 今後, 手動作成されたラベルと伝播結果の, 学習におけるバランスについて改善を図る予定である.

謝辞 本研究の一部は, 堀科学芸術振興財団, MEXT/JSPS 科研費 (17H00867, 17K20099, 26108006, 26560255), JSPS 二国間交流事業ならびに AMED (191k1010036h0001) によった.

利益相反 なし

文 献

- [1] 西尾光平, 小田紘久, 千馬耕亮 他: イレウス診断支援システムにおける閉塞部位の誤検出修正及び改善ツールの構築. 第 27 回日本

Automated Segmentation of Dilated Intestines in Ileus Patients' CT Volumes Using Little Amount of Labeled Training Data

Hirohisa Oda^{*1}, Kohei Nishio^{*1},
Takayuki Kitasaka^{*2}, Hizuru Amano^{*3,4},
Kosuke Chiba^{*4}, Hiroo Uchida^{*4}, Kojiro Suzuki^{*5},
Hayato Itoh^{*1}, Masahiro Oda^{*1}, Kensaku Mori^{*1,6,7}

^{*1} Graduate School of Informatics, Nagoya University

^{*2} School of Information Science, Aichi Institute of Technology

^{*3} Graduate School of Medicine, The University of Tokyo

^{*4} Nagoya University Graduate School of Medicine

^{*5} Department of Radiology, Aichi Medical University Hospital

^{*6} Information Technology Center, Nagoya University

^{*7} Research Center for Medical Bigdata, National Institute of Informatics

In this paper, we propose an intestine segmentation method from CT volumes of ileus patients, which works well with a small number of manually-traced labels on training of fully convolutional network (FCN) for segmentation. Generally, training FCNs requires much amount of training dataset. However, manual tracing of the intestines is very difficult because the intestines are long and have winding shape. We investigate efficacy of data augmentation, that consists of not only general image processing like rotation or non-rigid registration but also propagation of manually-traced labels to other axial slices. By this approach, use of axial slices have no manually-traced labels for training becomes possible. Our FCN network for segmentation named “suppressed 3D U-net” is a modified version of the 3D U-net, whose input and output size are adjusted for our work. To investigate the efficacy of the propagation, performances of w/ and w/o propagation are compared in the experiments. Dice coefficients of w/ and w/o propagation were 0.744 and 0.782, respectively. We found that propagation process decreases the segmentation accuracy, which uses axial slices including incorrect labels for training.

Keywords: Suppressed 3D U-net, Sparse annotation, Intestine segmentation, Easy manual annotation

高解像度連続切片標本画像による股関節周辺領域における 神経筋骨格構造のモデル化のための 線維トラクトグラフィーの応用

時末 尚悟^{*1} 大竹 義人^{*1} Mazen Soufi^{*1}

福田 紀生^{*1} 高尾 正樹^{*2} 菅野 伸彦^{*2}

Beom Sun Chun^{*3} Jin Seo Park^{*4} 佐藤 嘉伸^{*1}

要旨

整形外科での診断精度向上などの観点から、正確な筋骨格モデルの構築が求められている。しかし、現状のモダリティでの腱・靭帯領域の撮像や解剖での骨格筋の内部構造把握は困難とされており、骨格筋の起始から停止に至る正確な3次元構造のモデル化はなされていない。そこで本研究では、遺体から得られる高解像度の標本画像を用いることで、骨格筋の起始から停止までの正確な3次元構造のモデル化を目指す。先行研究では大臀筋を対象にその周辺の腱・靭帯組織をマニュアルトレースにより抽出し筋腱線維の構造解析を行った。本研究ではCNNを用いて、データセット全体から腱・靭帯組織を自動抽出し、そのラベルを用いて線維構造解析を行い、マニュアルトレースとの比較・検討を行う。また、解析した腱・靭帯線維をクラスタリングすることで解剖学的な整合性に基づいた領域分類を行い、周辺の骨や骨格筋とのコネクティビティの検証を行う。

キーワード：筋骨格モデル，トラクトグラフィー，筋腱線維解析

1. はじめに

整形外科での診断精度向上，スポーツ医学での運動解析などを目指して様々な筋骨格モデ

ルが構築されており，OpenSim[1]やAnybody[2]などのシミュレーションシステムが開発されている。しかしながら，既存の骨格筋を線形アクチュエータで近似したモデル[3]では，シミュレーションで不自然な挙動を示すことが問題とされている[4]。

そこで我々のグループでは，骨格筋内部の筋線維走向を解析するため，高解像度の標本画像を用いて，画素勾配から線維の走向を構造テンソルとして取得し，fiber-tracking アルゴリズムを用いることで筋腱線維の走向モデルを構築した[5]。本稿では，先行研究に加え，筋骨格モ

*1 奈良先端科学技術大学院大学 先端科学技術研究科 情報科学領域

〔〒630-0192 奈良県生駒市高山 8916-5〕

e-mail: {otake, yoshi}@is.naist.jp

*2 大阪大学大学院 医学研究科

*3 Ajou University School of Medicine

*4 Dongguk University college of Medicine

投稿受付：2019年5月22日

デルの構築で重要視されている[6]骨格筋と骨の付着部である腱および靭帯の線維構造を解剖学的構造に基づいて分類することで筋骨格シミュレーションに向けた下肢3次元筋骨格標本モデルの構築を目指す。実験では、CNNを用いて自動抽出された腱および靭帯線維領域から得られる線維構造をマニュアルトレースにより作成した正解ラベルから得られる線維構造と比較し、その抽出結果の妥当性を評価する。また、それらの線維構造を周辺の骨・靭帯ラベルに基づいて分類することで、より忠実な線維構造の解析を行う。

2. 手法

2.1. 線維走向推定

先行研究[5]と同様の手法で線維走向を解析する。実験に用いたデータセットの詳細を表1に示す。計算速度向上のため、グレースケールへ変換し画素勾配から構造テンソルを取得する。得られた構造テンソルにトラクトグラフィを適用し線維構造を取得する。

2.2. 腱・靭帯領域の自動抽出

表1に示す通り、実験に用いた高解像度の連続画像から全ての腱・靭帯組織を手動で抽出するには莫大な時間が必要となる。そこで、CNNを用いて腱・靭帯組織の自動抽出を行う。用いたネットワークはU-Net[6]で、データセットから100枚間隔で抽出した25枚の画像にマニュアルでアノテーションし、その画像からランダムに512×512のパッチを3000枚取り出したものを訓練データとして用いる。予測ラベルは5*5*21のClosing Filterでノイズを軽減する。

2.3. 筋腱線維の解剖学的構造に基づく分類

解析した筋腱線維をより解剖学的構造に忠実に再現するため、以下の手順で分類する。

1. 周辺の骨および腱・靭帯に付着していない無効な線維の除去
2. 骨格筋の付着部による有効な線維の分類
3. 不確実な線維の抽出

2.4. 予測ラベルの評価

正解ラベルと予測ラベルの評価を次式で示

表1 データセットの詳細

領域	股関節
Image Size (voxel)	1943*3520*2501
Voxel Size (mm ³ /voxel)	0.1*0.1*0.1
Color	24bit RGB

すDice係数およびASDで行う。

$$DC(A, B) = \frac{2|A \cap B|}{|A| + |B|} \quad (2)$$

$$ASD(A, B) = \frac{1}{|A| + |B|} \left(\sum_{x \in A} \min_{y \in B} d(x, y) + \sum_{y \in B} \min_{x \in A} d(y, x) \right) \quad (3)$$

また、予測ラベルによる線維構造の評価を行うため、fiber distance[7]を用いる。fiber distanceは次式(1)で表される。

$$d_{ij} = \frac{1}{n} \sum_{k=1}^n d_k \quad (1)$$

ここで、 d_k は線維*i*上の点*k*と線維*j*上の最近傍点との距離であり、線維*i*上の全ての点でその総和を取り、点数*n*で割ることで得られる。評価には予測ラベルに基づく筋腱線維の全ての線維について正解ラベルに基づく筋腱線維とのfiber distanceを求める。

3. 実験

3.1. 大臀筋の筋腱線維解析

実験は股関節周辺領域の骨格筋を対象に行う。本稿では大臀筋を対象に停止部である大腿骨への腱および腸脛靭帯の線維走向をマニュアルトレースにより作成したラベルおよび2.2の手法で自動抽出されたラベルをもとに解析し、その結果を比較・検討する。

3.2. 大臀筋の線維走向分類

大臀筋は浅層および深層の2層構造をもち、浅層の停止部は腸脛靭帯、深層の停止部は大腿骨とされている[8]。この解剖学的知見をもとに3.1で解析した線維構造の分類を行う。手法は

2.3 にしたがって、実験は以下のように進めた。なお、線維は全て 100 点の点群として扱い、サーフェスモデルは全て頂点数 8000 に補間を行う。

1. 仙骨・寛骨・起始部の周辺靭帯・腸脛靭帯を合わせたサーフェスモデルを作成し、解析した筋腱線維の端点との最短距離が 15mm 以上の線維をいずれにも付着していない無効な線維として除去する。
2. 線維の端点を k-means 法で起始側と停止側に分類し、停止側の全ての端点と大腿骨のサーフェスモデルとの最短距離を求め、全体の線維数の 1/4 番目の線維の最短距離を閾値として、その閾値以下の線維を深層と定義する。
3. 2. で定義されなかった線維の停止側の端点と腸脛靭帯のサーフェスモデルとの最短距離が 3mm 以上のものを不確実な線維として抽出し、残りの線維を浅層と定義する。

4. 結果

4.1. 大臀筋筋腱構造の比較

図 1 に大臀筋の筋腱線維構造の解析を示す。左側にマニュアルトレースにより作成したラベルを用いて解析した結果、右側に 2.2 の手法により予測したラベルを用いて解析した結果を示している。それぞれ大臀筋周辺の骨ラベルのサーフェスモデルと合わせて Back および Left からのビューを表示しており、線維上の点におけるベクトル方向に応じて RGB 値を割り当てることで線維の走向を色づけしている。

4.2. 大臀筋の筋腱線維の分類

図 2 に大臀筋の予測ラベルに基づく筋腱線維の分類結果を示す。(a)は 3.2 の手順 1 の結果であり、有効な線維を緑、無効な線維を赤で色付けしている。(b)は手順 2 および 3 の結果で、浅層をシアン、深層を朱、不確実な線維を黄で色付けしている。

4.3. 予想ラベルの評価

予測ラベルの Dice 係数は 0.80, ASD は 0.50(mm)であった。

また、予測ラベルと正解ラベルによる線維の

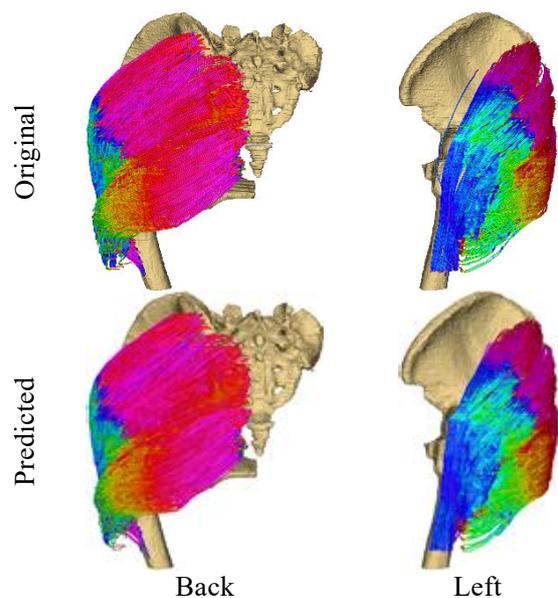


図 1 筋腱線維の解析結果。正解ラベルに基づく(上)、予測ラベルに基づく(下)

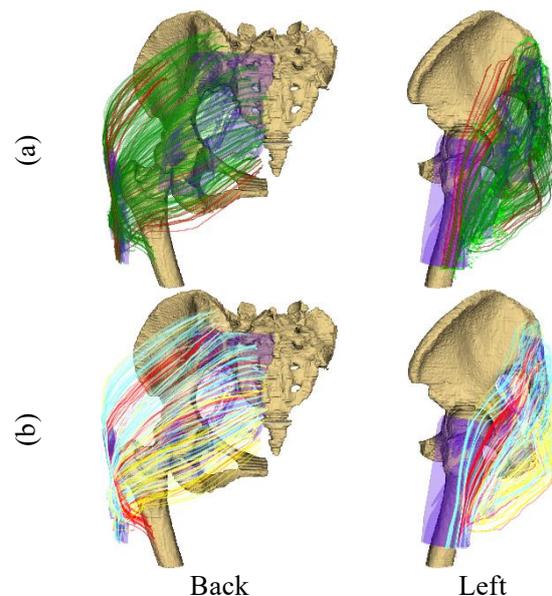


図 2 予測ラベルに基づく線維構造の分類結果。(a)無効な線維の抽出。(b)線維構造の分類。

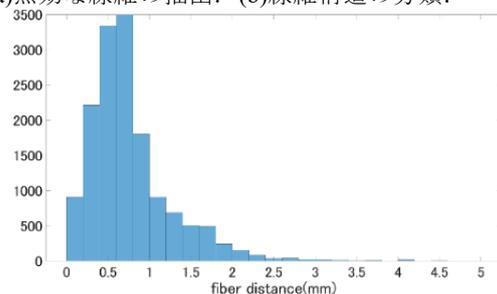


図 3 予測ラベルと正解ラベルに基づく線維間の fiber distance

fiber distance の結果を図 3 に示す。横軸に fiber distance(mm), 縦軸に線維数を示している。fiber distance が 1mm 未満の線維数は全体の約 78% であった。

5. 考察とまとめ

3次元筋骨格標本モデル構築に向けて, CNN を用いて腱・靭帯を自動抽出し, 筋腱線維の評価を行った。得られた筋腱線維を解剖学的知見に基づき, 分類することで, 図 2 のような結果を得た。図 2(a)において, 起始および停止と接続していない線維はラベルの境界部に多く見られることが分かる。また図 2(b)で観察される不確実な線維の多くは浅層および深層の境界にあり, テンソル場が両方の領域の影響を受けていることが原因であると考えられる。

また, 図 1 に示す通り, 正解ラベルと予測ラベルで顕著な差は見られず, 図 3 から fiber distance もほとんどが 2mm 以内に収まっていることが分かる。今後, 誤差が 2mm 以上の線維を抽出し, 原因を追究する。

謝辞

本研究の一部は, KAKENHI 19H01176 および KAKENHI 26108004 の支援による。

利益相反の有無

なし

文 献

- [1] Scott D, Frank A, Allison A, et al.: OpenSim: Open-source Software to Create and Analyze Dynamic Simulations of Movement. IEEE Trans Bio Eng, 54-11, 1940-1950, 2007.
- [2] Michael D, John R, Søren C, et al.: Analysis of musculoskeletal systems in the AnyBody Modeling System, Simulation Modelling Practice and Theory, 14-8: 1100-1111, 2006
- [3] Apoorva R, Christopher D, Matthew D, et al.: Full-body musculoskeletal model for muscle-driven simulation of human gait.,

IEEE Trans Bio Eng, 63-10: 2068-2079, 2016.

- [4] Enrico P, Morten L, Anantharaman G, et al.: Refining muscle geometry and wrapping in the TLEM 2 model for improved hip contact force prediction, PLoS One, 13-9: 2018.
- [5] 時末尚悟, 大竹義人, Soufi M, et al.: 高精細連続切片画像を用いた線維トラクトグラフィーによる筋腱モデリング, In proceedings of 医用画像研究会(MI), Okinawa, 2019
- [6] Ronneberger, O, Fischer, P, Brox, T: U-Net: Convolutional networks for biomedical image segmentation., MICCAI, Springer, LNCS, 9351: 234-241, 2015.
- [7] Lauren O, Carl-Fredrik W: Automatic Tractography Segmentation Using a High-Dimensional White Matter Atlas, IEEE Trans Med Imag, 26-11, 1562-1575, 2007
- [8] Keith L. Moore, Arthur F. Dalley.: 臨床のための解剖学, 佐藤 達夫(監訳), 坂井建雄(監訳), メディカル・サイエンス・インターナショナル, 東京, 2008

An application of fiber tractography for modeling neuromusculoskeletal structures around the hip joint in high-resolution cryosectioned images

Shogo TOKISUE^{*1}, Yoshito OTAKE^{*1}, Mazen Soufi^{*1}, Norio FUKUDA ^{*1}, Masaki TAKAO ^{*2},
Nobuhiko SUGANO^{*2}, Beom Sun CHUN^{*3}, Jin Seo PARK^{*4}, Yoshinobu SATO^{*1}

*1 Graduate School of Information Science, Nara Institute of Science and Technology

*2 Graduate School of Medicine, Osaka University

*3 Ajou University School of Medicine

*4 Dongguk University college of Medicine

High-fidelity musculoskeletal models are necessary for improving the quality of musculoskeletal simulations and the orthopedic surgery planning. However, it is difficult to represent the internal muscle structure in detail by using the current models, that is because the models for the structure from the origin to the insertion has not been accurately developed yet. In our research, we aim to reconstruct the high-fidelity 3D musculoskeletal model containing the origin to the insertion points by using high-resolution cryosectioned specimen images. In our previous study, we analyzed the musculotendinous structure of the gluteus maximus using the label of the manually-extracted ligaments and tendons. In this research, we expand our model by automatically extracting the ligaments and tendons from the whole dataset by using a CNN, and analyze the musculotendinous structures based on fiber tractography. In addition, we classify the analyzed fibers based on the surrounding bone structures, and verify the connectivity between the bones and the muscles, thus obtaining improved models for the target structures.

Key words: musculoskeletal model, tractography, musculotendinous fiber analysis

画像認識技術によるうつ病診断の定量化

牧 優太*¹ 和田 昇太*¹ 安倍 和弥*¹ 武尾 英哉*¹ 永井 優一*²

要旨

近年、うつ病等の精神病の診断は主に医師による問診によって行われており、病名は、DSM-5 や ICD-10 などの診断基準にいくつ症状が当てはまっているかによって付けられている。しかしこの診断方法は、科学的、客観的な評価による診断ができていないという問題がある。そのため、うつ病の客観的な診断を行うために、うつ病であるかどうか画像工学技術を利用して、うつ病診断の定量化(重症度の算出)とうつ病であるかどうかの判定を行うシステムの開発を行った。

定量化には主に視線方向と顔表情に着目した。まずうつ病患者及び健常者の動画像から、視線方向と顔表情を CNN で検出し、各々の時系列データを得た。次にそれらのデータを SVM や NN(ニューラルネットワーク)によって定量化し、その重症度に閾値判別を行った。その結果、どちらも平均して約 77%の識別精度が得られた。また、両モデルの出力値にアンサンブル学習を行い、同様に重症度の閾値判別をしたところ、平均して約 83%の識別精度となり、有意な判別性能を得ていると考えられる。

キーワード：うつ病、定量化、視線方向、顔表情、アンサンブル学習

1. はじめに

WHO のうつ病に関するファクトシートによると、3 億人を超える全年齢層の人々がうつ病に罹患しているとされている。一方、日本国内では、2013 年にうつ病を含む精神疾患が、がん、脳卒中、心筋梗塞、糖尿病の 4 大疾病に新たに加えられ、「5 大疾病」となるなど対策が必要である病とされている[1]。

このうつ病等精神病の診断であるが、主として医師による問診によって行われており、DSM-5(精神障害の診断と統計マニュアル第 5 版) や ICD-10(国際疾病分類第 10 版)などの診断基準にいくつ症状が当て嵌まっているかによって、診断をつけている[2]。しかしながら、うつ病の診断は他の病気の診断、例えば悪性腫瘍の診断で用いられる画像や、糖尿病を診断す

ン A1c) などといった客観的な指標[3]を用いた診断は行えていないという問題がある。

以上を踏まえ、本論文ではうつ病の客観的な診断を行うために、うつ病であるかどうか画像工学技術を利用して、うつ病の重症度の算出とうつ病の判別を行うシステムの開発を目的としている。

なお、一般的なうつ病の重症度の意味は、社会生活に対しうつ病がどのくらい障害をあたえているかを指し、その度合いを QIDS(簡易抑うつ症状尺度)や HAM-D (ハミルトンうつ病評価尺)を基に、軽度や中等度、重度等に分類している[4]。しかしながら、本論文においてうつ病の重症度は、うつ病の度合いを指す値として用いており、うつ病患者である確率を正規化したものと定義している。また、本論文は躁うつ病、気分変調性障害、大うつ病勢障害等に細分化される前の「抑うつ症候群」を「うつ病」と定義している[5]。

このうつ病の診断や定量化等の取り組みは日本のみならず海外でも研究が行われており、例えば Alhanai ら[6]は日常会話(Text と音声)を利用した、宗ら[7]は音声と属性を利用した診断

*1 神奈川工科大学大学院 工学研究科 電気電子工学専攻

〒243-0292 厚木市下荻野 1030)

e-mail: maki2019@ele.kanagawa-it.ac.jp

*2 国立がん研究センター東病院

際に用いられる血糖値、HbA1c (ヘモグロビ

を行う研究をしている。また、構造 MRI 画像を用いて Mwangni ら[8]はうつ病の重症度の推定を、Costafreda ら[9]はうつ病の診断を予想の研究を行っている。一般画像では、Reece ら[10]が Instagram に投稿された画像からうつ病の診断をする研究を行っている。

本研究は、静止画像のみを用いるのではなく、時間という情報も利用したうつ病の定量化と判別を行おうとしているのが、今までの研究と異なる点である。

本論文では、第 2 章で収集した動画と指標、使用するデータについてを、第 3 章ではそのデータを用いた定量化と判別の手法を説明する。第 4 章では第 3 章の手法による結果を、第 5 章は第 4 章の結果からの考察をまとめている。

2. 使用したデータ

2.1 使用動画

本研究に使用する動画は、動画投稿サイト (youtube : <https://www.youtube.com/?gl=JP&hl=ja>) に投稿されていた動画より、動画内で自身がうつ病だと明言しているうつ病患者の動画を、同様にうつ病および精神疾患を患っていない健常者の動画を対象としている。また、条件として投稿者がカメラの正面に位置し、カメラに向かって話しかけている動画のみとしている。上記の条件を満たしていた動画の中で、うつ病患者 15 名と健常者 15 名の計 30 名の動画を選定した。

2.2 データ解析

web や文献からうつ病の身体症状を調査したところ、「視線が下がる」、「表情が少ない(硬い)」[5]など、視線や表情等に特徴があることがわかった。そのため、集めた動画の視線方向と顔表情に着目しそれぞれの時系列変化を秒単位で調べた。視線方向と顔表情の解析にあたって、視線方向は図 1 に示す視線方向モデルのように、上下左右と斜め方向の計 9 方向に定義しており、顔表情は P.エクマンら[11]が定義した基本 6 表情と無表情の計 7 表情として定義している。また、再生時間中に視線方向または顔表情が確認

できなかった部分、つまり欠損値は前もしくは後の非欠損値で補間を行い、欠損値をなくしている。

図 2, 図 3 に解析の際に得た、健常者とうつ病患者の視線方向と顔表情の時系列変化の例をそれぞれ示す。図 2, 図 3 を見てわかる通り、うつ病患者は健常者とは相対的に「視線の動きが少ない(正面を見る)傾向にある」、「表情の表出頻度が少ない(無表情である)傾向にある」ことが実際に確認できた。よって、上記の差異が全てのうつ病患者に存在すると仮定し、これを指標とすればうつ病の重症度算出が可能なのではないかと考えた。後述する第 4 章の実験では、この解析時に得た秒単位の視線方向または顔表情の変化をプロットしたデータを使用した。

3. 手法

定量化にあたって、重症度算出モデルの全体図を図 4 に示す。図 4 より、視線方向データと SVM, 顔表情データと LRN(層再帰型ニューラルネットワーク)の組み合わせと、定量化データと NN(ニューラルネットワーク), SVM, アンサンブル学習のそれぞれの組み合わせで定量化かつ重症度を得ている。この三つのプロセスを以下に示す。

- 1) 視線方向データを利用した定量化
- 2) 顔表情データを利用した定量化
- 3) 二つの手法の統合

これらの詳細を本章 3.1, 3.2, 3.3 にて述べる。

3.1 視線方向データを利用した定量化

視線方向データからデータセットを作成、そのデータセットを 2-class SVM に入力し、出力されたスコア (うつ病患者である確率)に正規化を行い、得られた重症度とそれを閾値判別したときの判別精度を確認する。

学習に用いるデータセットは、視線方向データから特徴量を抽出したものである。2 章 2.2 で得た視線方向データから全視線方向と正面方向以外の各場合における要約統計量(分散)や平

均情報量，正面方向を見る確率，左方向から正面方向を見る確率，下方方向から正面方向を見る確率，縦軸が視線方向，x軸が頻度(動画再生時間内の回数)のグラフの線形近似曲線の傾き，x軸を動画の再生時間と変えたグラフの線形近

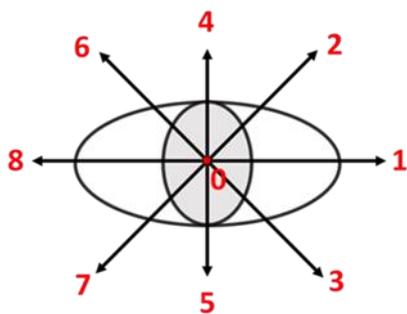
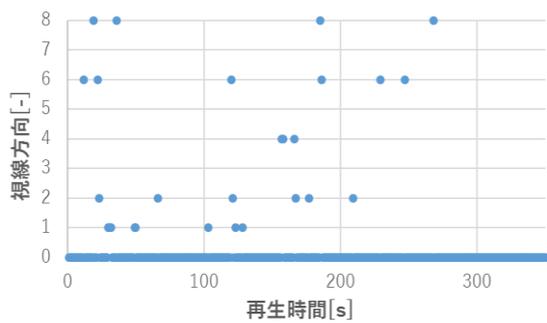
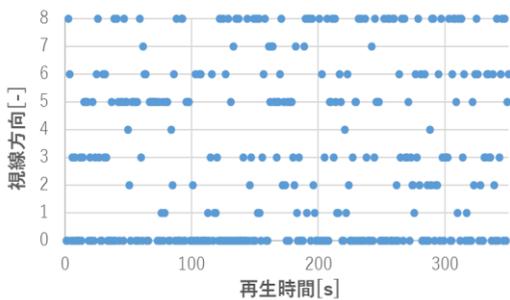


図 1 視線方向モデル

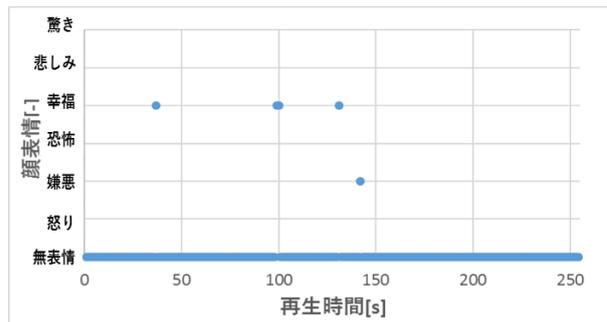


(a) うつ病患者の視線の動きサンプル

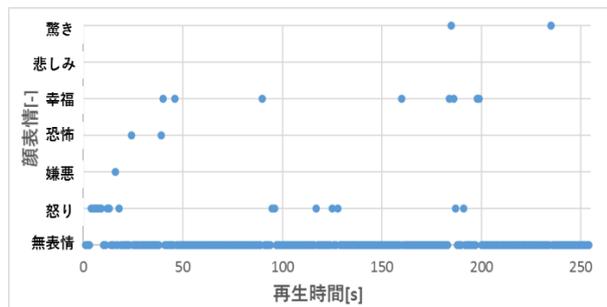


(b) 健常者の視線の動きサンプル

図 2 視線方向の時系列変化



(a) うつ病患者の表情変化サンプル



(b) 健常者の表情変化サンプル

図 3 顔表情の時系列変化

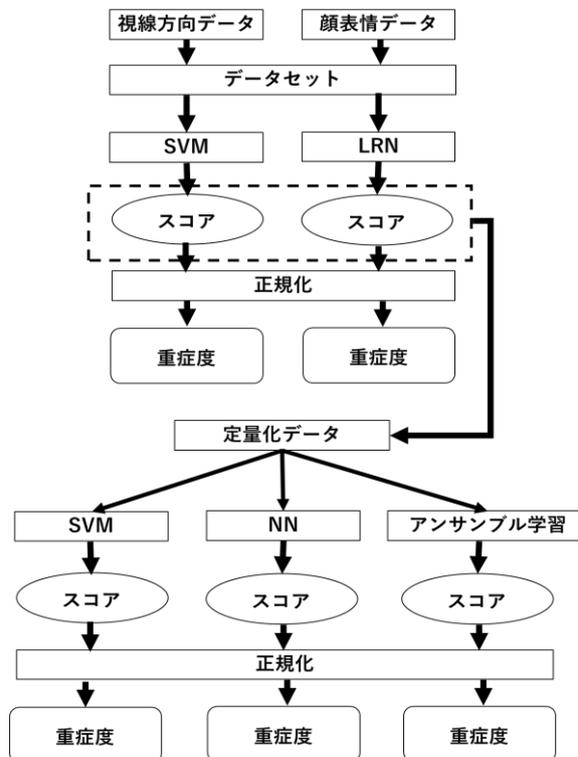


図 4 重症度算出モデルの全体図

似曲線の傾き, そのグラフに高速フーリエ変換(FFT)を行い, 習得したパワースペクトルの第一周波数成分, 前から 1/4 部分までの成分の平均, 1/4 から 2/4 部分までの成分の平均と, 計 12 個を特徴量としている.

SVM の学習には rbf カーネルと, Leave-one-out 交差検証を使用している. また, 初期乱数による影響を考慮して, 5 回同じ条件で実験を行い, 各実験で得られたスコアの平均を正規化する.

3.2 顔表情データを利用した定量化

図 5 にこの 3.2 の手法の定量化の簡略図を示す. 図 5 に示すように, 顔表情データからデータセット(時系列順の表情データ)を作成, そのデータセットを LRN(層再帰型ニューラルネットワーク)に入力し, 出力されたスコアに正規化を行い, 重症度を得る. そして得られた重症度を閾値判別したときの判別精度を確認する.

LRN とは単純再帰型ニューラルネットワークを一般化したニューラルネットワークであり, 図 5 にこの LRN が 2 層であるときのネットワークを示す[12].

本実験に使用する LRN は, 図 6 と同じ 2 層構成としており, 隠れ層のノード数を 10, 遅延は 10 とし, 伝達関数は隠れ層に softmax を, 出力層に purelin(線形伝達関数)を用いている.

学習に用いるデータセットは, 2 章 2.2 で得た顔表情データに水増しを行い, サンプルを増やしている. 水増しにはあるクラスの 1 人の対象者のデータから, 0 秒から 180 秒までを区切り 1 つのデータに, 次に 1 秒から 181 秒までを区切り別の 1 つのデータに, と始点と終点をずらして別のデータとして扱う方法を用いている. 本実験では顔表情データは 0 秒から 254 秒までと一律にそろえているため, 前述通り始点を 0 秒, 終点を 180 秒とすると, 1 人あたり 74 のデータが作成されている.

学習は 5 分割交差検証で, この方法によって分けられた学習データを更に 7:1:2 の割合で train データと validation データ, test デー

タに分け, 学習させている. 学習回数は 1000 Epoch としているが, 6 回の反復の間に検証誤差が減少しなくなったときに学習を終了するようにし, 学習関数はベイズ正則化に設定している. 3.1 と同様に初期乱数を考慮して, 同じ条件で 3 回実験を行い, 各実験で得られた 1 人あたり 74 個のデータのスコアの平均を正規化する.

3.3 二つの手法の統合

3.1 と 3.2 で得られた出力値を特徴量として扱い, 以降定量化データと呼ぶ. この定量化データで NN(ニューラルネットワーク), SVM, softvoting 型アンサンブル学習(以降 softvoting 型), 逐次選択型アンサンブル学習(以降逐次選択型)に学習を行い, 得られたスコアを正規化して, 各場合における重症度と閾値判別による判別精度を確認する.

図 7 にアンサンブル学習(softvoting 型)の全体図を示す. この構成は逐次選択型も同様である.

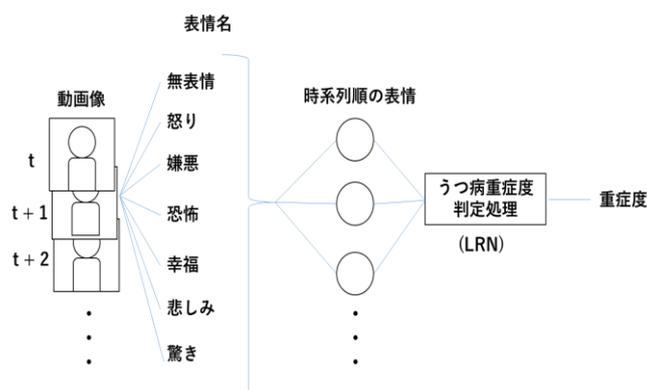


図 5 顔表情データ定量化の簡略図

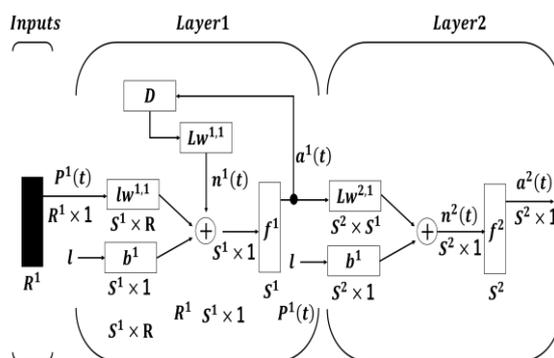


図 6 2層 LRN

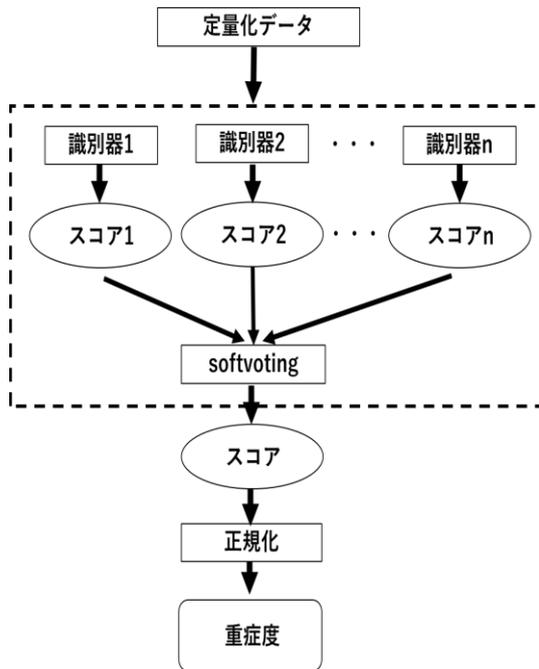


図 7 アンサンブル学習(softvoting 型)

図 7 より、アンサンブル学習に用いる識別器は、NN, SVM, 単純ベイズ, 判別分析, k 近傍分析, アンサンブル学習の計 60 個の識別器で構成している。表 1 にこれら識別器の個数と内容をまとめたものを示す。これらの識別器をひとつひとつ MATLAB R2018-a の関数を用いて簡単に説明する。NN は feedforwardnet、fitnet、patternnet、cascadeforwardnet, layrecnet を隠れ層は 1 層で 10 ノード, SVM は 2-class SVM と 1-class SVM の 2 種類を, それぞれ linear(線形カーネル), gaussian(ガウシアンカーネル), polynomial(多項式カーネル)の 3 種類に分けて, 計 6 種類としている。なお, 1-class SVM の異常値はうつ病のデータとしている。バイナリ分類木は分割予測子の選択に使用するアルゴリズム毎に分け, allsplits(標準 CART) と curvature(曲率検定), interaction-curvature(交互作用検定)の計 3 種類としている。判別分析分類器は, 線形と 2 次の 2 種類を判別タイプごとに計 6 種類としている。単純ベイズ分類器は, カーネル平滑化のタイプは'normal'(ガウス), 'box'(ボックス(一様)), 'epanechnikov'

(Epanechnikov), 'triangle'(三角形)の計 4 種類としている。k 最近傍分類器は, 最近傍探索法の'kdtree'(kd 木を作成および使用して最近傍を探索)と'exhaustive'(網羅的探索アルゴリズム)の 2 種類を, 検出する最近傍の数を 5, 10, 15 とした 3 種類の計 6 種類としている。アンサンブル学習器は弱学習器の決定木, k 最近傍分類器, 判別分析分類器の 3 種類を, 適用できるアンサンブル集約法(AdaBoost, LogitBoost 等)毎に組み合わせて, 計 24 種類となっている。決定木のアンサンブルをバギングするモデルを, 弱学習器の個数ごとに 5 種類作成している。

Softvoting 型は定量化データで学習等を行ったときの, 全 60 個の識別器のスコアの平均を最終的なスコアとしている。一方, 逐次選択型は同じ構成でも識別器の中で最も良い判別性能であった識別器を抽出し, 他の識別器と組み合わせて, その判別性能が良くなれば, この一連の流れを続け, この過程で判別性能が変わらないもしくは悪化すれば, 流れを打ち切り, その組み合わせ前のスコアを最終的なスコアとしている。

この Softvoting 型と逐次選択型のアンサンブル学習に関して, 学習は 5 分割交差検証で行う。当然のことながら初期乱数による影響を考慮し, 同条件で 5 回実験を行い, 回毎の最終的なスコアの平均を正規化する。SVM と NN の学習では, SVM は 3.1 のデータセットを定量化データに変更した以外同じ条件で学習を行う。NN は 3.2 のデータセットを定量化データに, LRN を Cascade-forward

表 1 識別器の内容と個数

モデル	内容	数
判別分析	線形および 2 次判別分析	6
分類木	アルゴリズム別	3
単純ベイズ	カーネル平滑化法別	5
k 最近傍	最近傍探索法・最近傍数別	6
SVM	バイナリと 1 クラス	6
NN	学習モデル別	5
アンサンブル	弱識別器・アンサンブル集約法別	29
合計	-	60

neural network に、実験回数を 15 回に変更して、学習を行った。

4. 結果

4.1 視線方向データによる定量化の評価

表 2 に第 3 章 3.1 の手法によって得られた重症度をまとめたものを示す。本図では閾値を超えうつ病であると判別されたものを赤く塗りつぶしている。表 2 より、うつ病患者の平均重症度は 71.2%，健常者の平均重症度は 28.8% となり 42.4% の差がみられた。また、閾値以上をうつ病だと判別する場合、閾値を 54% とすると、うつ病患者側のマージンは 3.7，健常者側のマージンは 2.8，そして判別精度，感度，特異度はどれも 80% という結果となった。

4.2 顔表情データによる定量化の評価

表 3 に第 3 章 3.2 の手法によって得られた重症度をまとめたものを示す。表 3 より、うつ病患者の平均重症度は 58.2%，健常者の平均重症度は 46.2% となり 12.0% の差がみられた。また、閾値以上をうつ病だと判別する場合、閾値を 60% とすると、うつ病患者側のマージンは 1.3，健常者側のマージンは 2.6，そして判別精度，感度，特異度は順に 77%，86%，66% という結果となった。

4.3 二つの手法統合の評価

表 4 に各場合のスコアを正規化した時の、うつ病患者と健常者の平均重症度とその差を示す。表 4 より、平均重症度の差は逐次選択型が最も大きい値をとっている。

表 5 に各場合の閾値とその閾値に対するマージンを示す。表 5 より、全体的に 4.1，4.2 のときのマージンよりは大きい値となっていることがわかる。

表 6 に各場合の重症度を表 3 の閾値で判別したときの、判別精度，感度，特異度を示す。表 6 より、全体の判別精度は逐次選択型が 83% と最も高く，次点の SVM は約 80% であった。この 2 つであるが，感度，特異度ともに 80% を越えており，バランスが良いといえる。一方 NN は感度だけみると逐次選択型と等しい約 86%

を記録しているが，特異度は約 70% を下回っているため，判別精度は約 77% となっている。

表 2 手法 3.1 による重症度

健常者	うつ病患者
51.2	60.5
17.1	37.9
62.1	11.6
19.8	22.3
41.7	57.7
54.2	63.3
66.6	90.6
46	99.3
6.7	98.8
14.4	91.2
28.3	62.2
10.2	91.3
3	96.3
7.4	87.2
3.9	97.3

表 3 手法 3.2 による重症度

健常者	うつ病患者
38.6	63.4
20.8	47.7
57.4	61.3
33.5	64.7
28.3	24.3
37.7	68.7
53.1	68.7
79.2	80.6
42.9	54.3
55.2	70.6
43.3	63.4
42.5	3.8
68.1	79
52	69.3
40.8	52.8

表 4 各場合の平均重症度とその差

モデル	対象	平均重症度[%]	平均重症度の差[-]
SVM	うつ病	58.6	17.2
	健常者	41.4	
NN	うつ病	83.3	9.5
	健常者	73.8	
softvoting	うつ病	58.5	21.2
	健常者	37.3	
逐次選択型	うつ病	63.6	30.3
	健常者	33.3	

表 5 各場合の閾値とマージン

モデル	閾値[%]	マージン[-]
SVM	50	2.4
		5.6
NN	53	4.1
		3.9
softvoting	53	4.1
		3.9
逐次選択型	45	3.9
		4.7

表 6 各場合の判別精度，感度，特異度

モデル	判別精度[%]	感度[%]	特異度[%]
SVM	80	80	80
NN	77	86	66
softvoting	77	73	80
逐次選択型	83	86	80

それとは逆に softvoting は感度が約 73%と低い
ため、判別精度は約 77%という結果となった。
また、同じアンサンブル学習でも、softvoting
するよりも識別器を選択して組み合わせる
方が、判別精度は良くなるという結果とな
った。しかしながら、この中で最も高い判
別精度を出した逐次選択型であるが、5
回の学習中全て、単体で最も高い精度を
もつ識別器に他の識別器を組み合わせ
ても、その判別精度は変わらない、もし
くは下がってしまうという結果となっ
てしまった。そのため、逐次選択型は組
み合わせが行われず、事実上識別器単
体の判別精度になってしまった。

5. 考察

4 章 4.3 節の結果より、逐次選択型が最も判別精度が良く、同じモデルである softvoting と逐次選択型との間に性能の差が現れたという結果となった。Softvoting の判別精度が低いのは、判別精度の低いモデルのスコアもとってしまうからだと考えられる。

実験では逐次選択型は全て組み合わせられず識別器は単体のみとなっていたが、識別器の組み合わせが識別器単体の性能を上回ることがあるのか、更に 15 回学習してみて、確認した。

表 7 は、15 回逐次選択型の学習を行ったときの、識別器単体とそれ以外の識別器を組み合わせたときの判別精度を比較したものを示す。表 7 より、単体の判別器の方が最大精度・平均精度がともに高く、また標準偏差の値も大きい。そのため、高い判別精度の値をとりうるのは識別器単体の方であるとわかる。よって、識別器の組み合わせが識別器単体の性能を上回るとは少なく、識別器単体の方が良い判別性能を期待できると考えられる。

逐次選択型が全て組み合わせられず識別器単体の方が良い判別性能なのは、使用するデータは同じであるため、再び学習したとしても識別器のスコアは大きく変わらないからである。そのため、新しく選択された識別器は前に取り出した最高精度の識別器と比べて等しいかあるいは低いままである。よって、組み合わせても判別精度が変わらないもしくは下がってしまうからだと考えられる。

表 7 各場合の判別精度，感度，特異度

	平均精度[%]	最大精度[%]	最小精度[%]	標準偏差[%]
単体	82.3	85.8	79.2	2.2
組み合わせ(2個)	81.6	82.5	79.2	1.5

表 8 誤判別が多かった対象者

	平均[-]	標準偏差[-]	全体平均[-]
うつ病患者1	-0.76	0.16	0.96
うつ病患者2	-0.05	0.17	
健常者1	1.11	0.04	0.24
健常者2	1.52	0.01	

倫理規範の順守

なし

4章 4.1 から 4.3 までの重症度において、閾値判別によって判別できていなかった共通の被験者が存在したため、なぜ判別できなかったのかを考える。表 8 にその対象者らの前述の逐次選択型実験時のスコアを示す。

表 8 より、うつ病患者 1 とうつ病患者 2 の平均スコアは負の値をとっており、うつ病患者全体の平均スコアと比べてとても小さい。反対に健常者 1 と健常者 2 の平均スコアは健常者全体の平均スコアと比べてとても小さい。従って、判別精度という点で上記の被験者らがうまく判別されるように閾値を設定することができないからだと考えられる。また、データの基である被験者らの動画を確認したところ、視線方向および顔表情が 2 章 2.2 で仮定した傾向がみられないことがわかった。よって、仮定した傾向と被験者らが合わなかったため、うまく判別することができていなかったと考えられる。

6. まとめ

うつ病診断の客観的な評価を行うために、うつ病診断の定量化(重症度の算出)とうつ病であるかどうかの判定を行うシステムの開発を行った。うつ病患者の視線方向と顔表情の特徴に着目し、データをとって様々な手法を用い定量化と判別を行った。最終的には 83%の精度を得ることができる判別方法が確認でき、有意な判別性能を得ることができた。しかし、本研究で使用したデータは総数や信頼性が十分とは言えないため、病院等と連携し、医師の所見や鑑別済みのうつ病患者のデータ等を得ることが必要である。今後は、前述の信頼性の高いデータの確保とシステムの全自動化や実装を進めていく。また、一括りで定義したうつ病を細かく、かつ他の精神障害も判別できるようになることも必要だと考えられる。

利益相反の有無

利益相反 なし

文 献

- [1] 片桐健志：うつ病とはどのような病気でしょうか 早くうつ病と気付くにはどうすればよいのでしょうか. 杏林医学会誌 49 巻 1 号, pp.91, 2018
- [2] 大坪天平：うつ病を診る上で注意すべきこと 女性心身医 20 巻 3 号, pp.272,
- [3] 二村隆史：うつ病治療薬開発の難しさ. ファルマシア Vol. 53 No. 7, pp.696, 2017
- [4] 坪井貴嗣：うつについて改めて知ってみませんか?: うつ病の治療について 杏林医学会誌 49 巻 1 号, pp.87, 2018
- [5] 船津浩二, 白川治：めまいとうつ—診療のポイント— Equilibrium Research 73 巻 4 号 pp. 246-249, 2014
- [6] Tuka A, Mohammad G, James G: Detecting Depression with Audio/Text Sequence Modeling of Interviews : Interspeech 2018
- [7] 宗 未来, 竹林由武, 関沢洋一 他: “声”だけで、うつ病はどこまで診断可能か? ~音声感情認識技術にアンサンブル型機械学習モデルを応用したうつ病スクリーニング機能に関する精度の検証 RIETI Discussion Paper Series 16-J-054. 2016
- [8] Benson M, Keith M, J. Douglas S : Prediction of illness severity in patients with major depression using structural MR brain scans Journal of Magnetic Resonance Imaging 35(1):64-71 2011
- [9] Sergi G. C, Carlton C, John A, et al. : Prognostic and Diagnostic Potential of the Structural Neuroanatomy of Depression. PLoS One. 2009 ; 4(7): e6353. 2009
- [10] Andrew G R, Christopher M D : Instagram photos reveal predictive markers of depression EPJ Data Science 2017
- [11] Ekman P, Friesen W. V, 工藤力(訳) : 表情分析入門. 誠信書房, 1987 pp 31-

161

[12] Design Layer-Recurrent Neural Networks
<https://jp.mathworks.com/help/deeplearning/ug/design-layer-recurrent-neural->

[networks.html?lang=en](#) (2019年4月27日現在)

Quantification of the diagnosis of depression through using image recognition technology

Yuta MAKI*¹, Syota WADA*¹, Kazuya ABE*¹, Hideya TAKEO*¹, Yuuichi NAGAI*²

*1 Kanagawa Institute of Technology

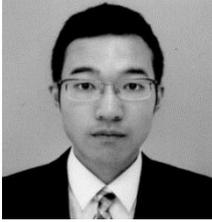
*2 National Cancer Center Hospital East

In recent years, mental disorders such as depression have been diagnosed mainly by physician-patient interviews, and the disorder named according to how symptoms apply to diagnostic criteria in DSM-5 and ICD-10. However, this diagnostic method has the drawback of not being a scientific or objective evaluation. To address this and perform objective evaluation, using image engineering technology for depression determination, we developed a system that quantifies depression diagnosis (i.e. calculates its severity) to judge whether or not depression is present.

For quantification, we focused mainly on eye direction and facial expression. First, we used a CNN to detect the eye directions and facial expressions of subjects with depression and healthy subjects in video images in order to obtain time-series data for each. Next, we quantified this data using SVM and NN and then performed threshold discrimination to obtain severity. As a result, we obtained on average approximately 77% discrimination accuracy. We also applied ensemble learning to the output values of both models, obtaining on average approximately 83% discrimination accuracy when similar threshold discrimination of severity was performed. This result are thought of significant discrimination performance.

Key words: depression, quantification, eye direction, facial expression, ensemble learning

著者紹介



牧 優太 (まき ゆうた)
2019年神奈川工科大学工学部電気電子情報工学科卒。現在同大学院工学研究科電気電子工学専攻在学中。画像工学の研究に従事。本学会学生会員。



和田 昇太 (わだ しょうた)
2019年神奈川工科大学工学部電気電子情報工学科卒。現在同大学院工学研究科電気電子工学専攻在学中。画像工学の研究に従事。本学会学生会員。



安倍 和弥 (あべ かずや)
2010年神奈川工科大学工学部電気電子工学科卒。2012年同大学院博士前期課程修了。2015年同大博士後期課程修了。2015年同大日本人客員研究員。現在同大バイオメディカル研究センターのポスト・ドクター。博士(工学)。医用画像・細胞培養画像などの画像工学の研究に従事。第6回および第8回 JAMIT-CAD コンテスト優勝。本学会、映像情報メディア学会各会員。



武尾 英哉 (たけお ひでや)
1984年神奈川工科大学部卒。1986年同大学院修士課程了。同年富士フィルム株式会社に入社。医用画像処理システムに関する研究・開発に従事。2005年東京農工大大学院博士後期課程了。博士(工学)。2006年神奈川工科大学助教授。現在同大教授。医用・フォト・シネマ映像などの画像工学の研究に従事。2004年度本学会論文賞。第6回および第8回 JAMIT-CAD コンテスト優勝。本学会、映像情報メディア学会、画像電子学会、電子情報通信学会、医用画像情報学会各会員。



永井 優一 (ながい ゆういち)
1991年中央医療技術専門学校夜間部卒。1991年より国立療養所松戸病院放射線科。1992年より国立がんセンター東病院放射線部。2006年より国立がんセンター中央病院(現独立行政法人国立がん研究センター中央病院)放射線診断部消化器官撮影主任。2015年より東埼玉病院放射線科副診療放射線技師長。中央医療技術専門学校非常勤講師(画像工学)。全国国立病院療養所放射線技師会常任理事。2017年より国立がん研究センター東病院放射線部放射線診断技術室副放射線診断技術室長。現在に至る。診療放射線技師。医用画像解析の研究に従事。日本放射線技術学会会員。

肝細胞癌に対する選択的 TACE 施行時の Angio-CT を用いた栄養血管同定ナビゲーションソフト (Embolization plan®) の初期使用成績と注入造影剤濃度の影響について

葛和 剛^{*1,2} 穴井 洋^{*1,3} 前原 健吾^{*1,2} 新家 睦巳^{*2}

秋山 敬純^{*2} 小西 佳之^{*2} 小屋敷 誠^{*4}

要旨

【背景】肝細胞癌(HCC)の選択的肝動脈化学塞栓術 (sTACE) における, Angio-CT を用いた automated feeder detection である Embolization Plan®の評価, 特に造影剤濃度に着目して初期臨床評価を行った. 【対象と方法】sTACE を施行した HCC36 患者 41 結節. CT hepatic angiography(CTHA)は造影剤濃度 185mg/ml (L 群:8 結節)又は 278 (H 群:33)で、秒間 1.0-2.0ml で注入し施行した. そのデータを用いた EP による栄養血管を同定した. 選択的 DSA, CTHA と比較し, 完全一致:Excellent(E), ほぼ一致:good(G), 臨床許容可能:fair(F), 許容不可能:poor(P)の 4 群で評価し, F 以上の判定を臨床的有効とした. 【結果】E;4(L0,H4)結節,G;24(4,20),F;8(1,7),P;5(3,2)であった. 結果は 36 (5,31)結節, 87.8(62.5,93.9)%で, L 群と比較し H 群の方が臨床的有効割合は有意に高かった($p<0.05$). 【結語】HCC に対する sTACE における EP による栄養血管同定の有用性が示唆された.

キーワード : HCC, automated feeder detection(AFD), Angio-CT(ACT)

1. はじめに

肝細胞癌(Hepatocellular Carcinoma; HCC)に対する選択的肝動脈化学塞栓術 (Transcatheter arterial chemoembolization; TACE) は手術や局所穿刺治療が困難な症例において局所制御が期待できる治療方法であるが,慢性肝障害をもつ患者における栄養血管の同定は難しいことが

ある.近年 Cone Beam Computed Tomography (CBCT) 搭載血管造影装置によるボリュームデータを活用した automated feeder detection system (AFD) による栄養血管同定技術が開発され臨床応用が始まっている.本邦では CBCT 以前より Angio-CT (ACT) が汎用され普及しており,今回我々は ACT のボリュームデータを使用した AFD として開発されたキヤノンメディカルシステムズ株式会社製 Embolization plan; EP の臨床使用を評価し,特に使用した造影剤濃度による影響について検討した.

2. 対象と方法

2018年2月15日より2019年3月30日までに選択的 TACE を施行した肝細胞癌患者 36 人 41 結節 (平均年齢 76.3±9.90 歳) を対象とした.対象患者は男性 25 人 (平均年齢 75.5±9.10

*1 奈良県立医科大学大学院
先端画像下治療開発応用学講座
〒634-8522
奈良県橿原市四条町 840 番地
e-mail: sakishu31220@gmail.com

*2 市立奈良病院 医療技術部放射線室

*3 市立奈良病院 放射線科・IVR 研究センター

*4 キヤノンメディカルシステムズ株式会社

歳),女性 11 人(平均年齢 79.1±10.92 歳),対象の平均腫瘍径は 12.3±4.91 (5.0–31.0) mm であった.注入造影剤濃度別の患者背景を表 1 に示す.使用機器は血管撮影装置として INFX-8000C,CT 装置として Aquilion PRIME (いずれもキヤノンメディカルシステムズ株式会社,栃木)を使用.造影剤は iopamidol 370mgI/ml を生理食塩水で希釈して使用し,注入造影剤濃度を 185mgI/ml (L 群)と 278mgI/ml (H 群)に設定した.EP の臨床使用は L 群で 8 例,H 群で 33 例施行した.CT hepatic angiography (CTHA) の方法としてカテーテル先端を主に総肝動脈 (CHA) もしくは固有肝動脈 (PHA) に留置し,注入開始 10 秒後より 1 相目スキャンを開始,30 秒後に 2 相目をスキャンし,造影剤注入速度を 1.0-2.0ml/sec とし,スキャン開始より 1 相目スキャン終了までを注入時間(平均 14 秒)として造影剤を注入した.CTHA 撮影時のプロトコールは,管電圧:120kV,管電流:Volume-EC SET SD11 (5mm),回転速度:0.5sec,収集スライス厚:0.5mm×80,ヘリカルピッチ:HP65(pitch-f:0.813),S-FOV:320mm(M)とした.画像再構成に用いた再構成関数は FC11,逐次近似応用再構成法 AIDR3D:Enhanced-Strong,再構成スライス厚:0.5mm,再構成間隔:0.25mm で拡大再構成(220mm~250mm)した.

CTHA1 相目の撮像データを主に用いて作成した EP により解析した.CTHA2 相目のデータは腫瘍のより正確な範囲の確認に使用した.腫

瘍は原則としてマージンを 0mm と設定し,検索開始ポイントを CHA もしくは PHA のカテーテル先端からとして栄養血管を表示させた.このとき栄養血管を検索できなかった場合,マージンを 1mm ずつ大きくし,栄養血管が検索可能な大きさまでマージンを大きくした.検索結果を実際の選択的 DSA (digital subtraction angiography) 像と比較を行い,完全一致したものを Excellent (E),ほぼ一致したものを good(G),臨床上許容可能な範囲を fair(F),許容不可能なものを poor (P)とした.F 以上の判定を EP による栄養血管同定の臨床的有効とし,臨床的有効割合を評価した.また注入造影剤濃度の違いによる臨床的有効割合を比較検討した.なお,マイクロソフト社製 Excel2016 版を用いて統計学的解析を行い,P<0.05 を有意差ありと判定した.

なお本研究は市立奈良病院倫理委員会で承認されている.

3. 結果

HCC33 例 41 結節全てにおいて EP による栄養血管同定を施行した.なお,注入造影剤濃度 L 群と H 群の患者背景に有意差は認めなかった.

栄養血管同定の結果は E;4 結節,G;24 結節,F;8 結節,P;5 結節で,臨床的有効割合は 41 結節中 36 結節(87.8%)であった.注入造影剤濃度 L 群では E;0 結節,G;4 結節,F;1 結節,P;3 結節,注入造影剤濃度 H 群では E;4 結節,G;20 結節,F;7 結節,P;2 結節で,臨床的有効割合は L 群

表 1 造影剤濃度別の対象患者の背景

	造影剤濃度 185mgI/ml	造影剤濃度 278mgI/ml	
患者数	8	28	
年齢(歳)	78.6±7.57	75.7±10.16	P=0.46
性別(男/女)	5/3	20/8	
腫瘍個数	8	33	
背景肝(HBV, HCV/other)	4/4	19/9	P=0.651
肝機能(Child-Pugh 分類 A/B, C)	5/3	18/10	P=0.996
腫瘍径	12.88±4.15mm (8.0–18.0)	12.1±5.12mm (5.0–31.0)	P=0.694
腫瘍局在(右葉/左葉)	6/2	25/8	P=0.999

HBV:B 型肝炎ウイルス、HCV:C 型肝炎ウイルス、CHA:総肝動脈、PHA:固有肝動脈

表 2 Embolization Plan による評価結果

	total N=41	造影剤濃度 185mgI/ml N=8	造影剤濃度 278mgI/ml N=33
Excellent	4	0	4
Good	24	4	20
Fair	8	1	7
Poor	5	3	2

で 8 結節中 5 結節 (62.5%) で, H 群で 33 結節中 31 結節 (93.9%) であった (表 2) . 注入造影剤濃度の違いによる検討では L 群と比較して H 群で統計学的有意差をもって臨床的有効割合の評価が高かった (p=0.015) .

4. 考察

選択的 TACE は手術や穿刺治療が困難な HCC に対して有用性が報告され, 本邦を中心に広く普及している. しかしながら併存する肝疾患や繰り返す治療などで血管解剖や血行動態は時に複雑で栄養血管の同定が困難なことがある. 近年, 血管造影時の CBCT 撮影による 3 次元デ

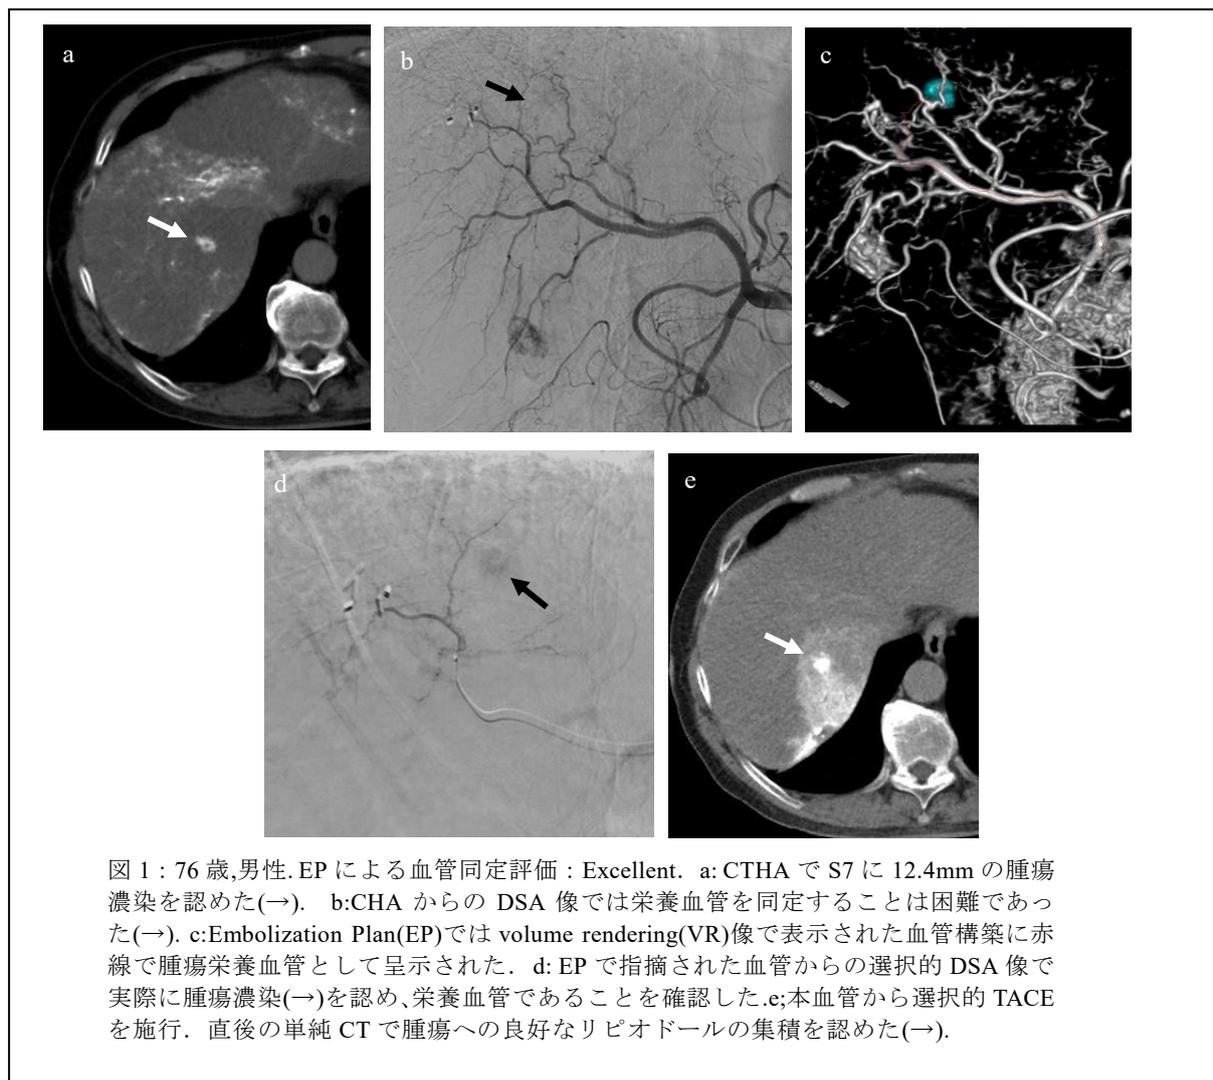


図 1 : 76 歳, 男性. EP による血管同定評価 : Excellent. a: CTHA で S7 に 12.4mm の腫瘍濃染を認めた(→). b: CHA からの DSA 像では栄養血管を同定することは困難であった(→). c: Embolization Plan(EP)では volume rendering(VR)像で表示された血管構築に赤線で腫瘍栄養血管として呈示された. d: EP で指摘された血管からの選択的 DSA 像で実際に腫瘍濃染(→)を認め, 栄養血管であることを確認した. e: 本血管から選択的 TACE を施行. 直後の単純 CT で腫瘍への良好なリピオドールの集積を認めた(→).

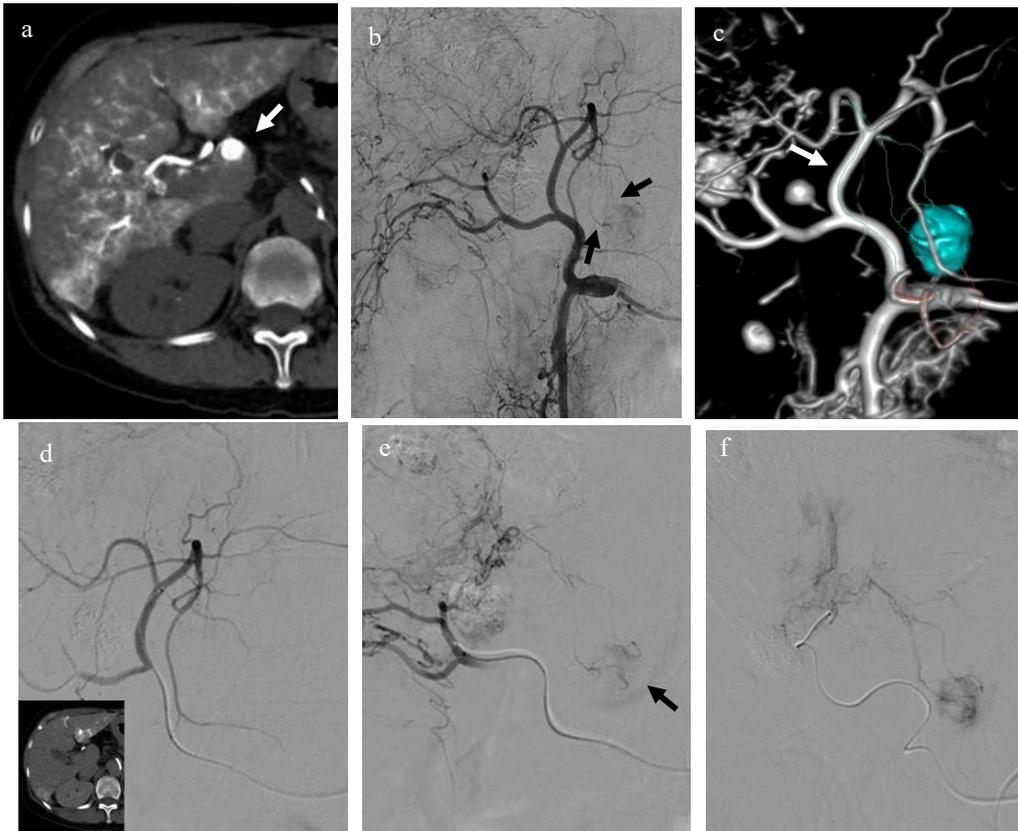


図2 61歳, 女性. EPによる血管同定評価: Poor. a:CHAからのCTHAでS1に10.0mmの腫瘍濃染を認めた(→). b:CHAからのDSA像で腫瘍を認めるが,このDSA像のみで栄養血管を同定することは困難であった(→). c:EPではVR像で緑線が左肝動脈から腫瘍栄養血管として呈示された.d:左肝動脈からの選択的DSAでは腫瘍濃染を認めなかった. e,f:右肝動脈からの選択的DSAで腫瘍濃染を認めた(→).

ータを利用し,栄養血管の同定を行う自動栄養血管同定システム(AFD)の報告が散見される.本邦ではコーンビーム型血管造影装置の普及より早くからCTと一体となったACTシステムが開発,普及している.ACTは通常のCTと同様の撮影であり,また画像収集時間が非常に短く時間分解能に優れている.今回キヤノンメディカルシステムズ株式会社製ACTを用いたボリュームデータを利用したAFDソフトウェア,Embolization plan®を臨床的に試用し,評価するとともに,AFDにおける注入造影剤濃度の影響を評価した.

従来のCBCTを用いたAFDによる腫瘍栄養血管の同定率は,MiyayamaらやIwazawaらによると完全一致率が87.7-88%と高い結果を報告している1,2)が,今回の我々が検討したACTのボリュームデータを活用したAFDでも,実臨床

に耐えうる結果評価としたFair判定以上の割合(臨床的有効割合)は87.8%であり,ほぼ同程度といえる.しかしながらFairの症例では得られた結果を実際の3D血管表示や3方向断面像,またDSAなどを参考に調整が必要となる,いわゆるマニュアル操作と同じ過程を要することも多い.その原因の一つとして栄養血管の途中経路で異なる血管よりスキップして表示される点が挙げられる.CTでのデータマトリックスが512*512と大きいため近接する血管分枝との区別が解析上困難となったのではないかと考える.またこのソフトウェアでは連続して造影された血管のCT値を追従し栄養血管を表示しているが,近接する血管の間の肝実質がまだらに濃染され血管と誤認識している可能性も考えられる.

一方,今回の検討では造影剤濃度H群で造影

剤濃度L群と比較して高い臨床的有効割合が得られた。肝実質と血管や、肝実質と腫瘍の造影コントラストがより際立つことで、より正確に栄養血管のみならず血管全体の同定抽出が容易となるためと考えるが、前述したように全体として高いCT値を呈することで、周辺マトリクス全体へ影響を及ぼし同定血管のスキップといった現象を惹起させる可能性もあると考える。

ACTのデータを用いたAFDは512x512のマトリクスサイズであるが、今後は高精細データの収集がさらなる性能向上のポイントになると考える。またCBCTのデータを用いたAFDでは複数の腫瘍の栄養血管を同時に同定可能であり、システムの完成度は先行している。しかしACTのデータを用いたAFDの利点もある。ACTにおけるデータ収集においては1断面での撮影時間は最速で0.35秒以下とCBCTと比較し時間分解能で凌駕するため、心拍などの動きによる影響は少ないと考える。加えて造影タイミングを1相ではなく、多相でも容易に評価が可能であり、発展性が期待される。また今回は検討していないがCTの方がCBCTより放射線被ばくは低く、低侵襲であると考えられる。

今回の検討では、注入造影剤の濃度による臨床的有効割合を検討したが、具体的な腫瘍、血管および周辺肝実質のCT値や差がEPにおいて至適なのかを検討できておらず、今後課題である。また、今回は初期型EPでの評価であり1回の解析では1個の腫瘍の栄養血管しか同定できず、今後はより実臨床での使用を踏まえて一度に複数の腫瘍の解析が行えるようにする必要がある。

ACTを用いたAFDシステムは、HCCにおける選択的TACEにおいて十分臨床に対応し、有用になると考えるが、より精度の高いシステムの開発は不可欠であり、加えて使用する造影剤濃度を中心とする造影プロトコルの確立が必要であり、空間分解能の向上といった因子の改善、そして解析アルゴリズムの改善が必要であると考えられる。

利益相反の有無

利益相反なし。

文 献

- [1] Miyayama S, Yamashiro M, Hashimoto M, et al. Identification of small hepatocellular carcinoma and tumor-feeding branches with cone-beam CT guidance technology during transcatheter arterial chemoembolization. *J Vasc Interv Radiol.* 24(4):501-8; 2013.
- [2] Iwazawa J, Ohue S, Hashimoto N, et al. Clinical utility and limitations of tumor-feeder detection software for liver cancer embolization. *Eur J Radiol* 82(10):1665-71; 2013

An initial experience of automated feeder detection system (Embolization plan®) using Angio-CT data in the selective embolization of hepatocellular carcinoma, especially on the influence of concentration of contrast material

Takeshi KUZUWA^{*1,2}, Hiroshi ANAI^{*3}, Kengo MAEHARA^{*1,2}, Mutsumi SHINYA^{*2}
Takazumi AKIYAMA^{*2}, Yoshiyuki KONISHI^{*2}, Makoto KOYASHIKI^{*4}

*1 Laboratory of Advanced Technology for Interventional Radiology,
Nara Medical University Affiliated Graduate School Program

*2 Radiation department of the medical engineering department, Nara City Hospital

*3 Department of Radiology & IVR Research Center, Nara City Hospital

*4 Canon Medical Systems Corporation

【Purpose】 To evaluate the utility of the automated tumor feeder detection system(AFD) by angio-CT (ACT) during selective transcatheter arterial chemoembolization (sTACE) for hepatocellular carcinoma (HCC), especially the effect of the concentration of the contrast media.

【Materials and Methods】 Thirty six patient with HCC were treated with sTACE. CT hepatic arteriography (CTHA) with contrast material (L; 185mgI/ml or H; 278mgI/ml) was performed. The feeder arteries were identified by Embolization plan® (Canon, Tochigi) of AFD by CTHA and compared with the actual feeder arteries in selective DSA. We divided the results into the following 4 categories; Excellent(E), good(G), fair(F), poor(P). The clinical utility was defined when the results showed F or higher.

【Result】 Forty one nodules were evaluated. The results showed 4(L0, H4) nodules in E, 24(4,20) nodules in G, 8(1,7) nodules in F, 5(3,2) nodules in P, respectively. The overall clinical utility was obtained in 87.8% (36/41). The clinical utility of L and H were obtained in 62.5% (5/8) and 93.9% (31/33), respectively.

【Conclusion】 It was suggested that AFD by Embolization Plan® using ACT was useful during sTACE for HCC. However, the further innovation of this software is still needed.

Key words: HCC, automated feeder detection (AFD), Angio-CT(ACT)

敵対的生成ネットワークを用いた

硬性白斑画像の生成と検証

藤田 真穂*¹ 畑中 裕司*² 砂山 渡*²

村松 千左子*³ 藤田 広志*⁴

要旨

糖尿病網膜症は中途失明の原因となる病であるが、早期発見と治療によって失明を防ぐことができる病でもある。近年は眼底画像からの初期病変の検出に、畳み込みニューラルネットワーク (CNN:Convolutional Neural Network) が成果を挙げている。一方で CNN を用いる際には、病変データ数と非病変データ数との不均衡が課題となる。現在は敵対的生成ネットワーク (GAN:Generative Adversarial Nets) を用いて病変データ数を増加させ、上記の課題の解決を図る研究が行われている。これらを踏まえて本研究では、糖尿病網膜症の初期病変の一つである硬性白斑の画像を生成した。白斑には硬性白斑と軟性白斑があるが、硬性白斑は糖尿病網膜症の初期段階にあらわれる境界が明瞭な白斑である。また生成データと実データ間との分布の差異について、複数の指標を用いて検証を行った。さらに生成データを用いて病変データ数と非病変データ数との不均衡を改善することが、CNNを用いた硬性白斑の検出精度の向上に貢献するかを検証した。

キーワード: 糖尿病網膜症, 畳み込みニューラルネットワーク, 敵対的生成ネットワーク, 不均衡データ, 硬性白斑検出

1. はじめに

糖尿病網膜症は中途失明の原因となる病であるが、早期発見と治療によって失明を防ぐことができる病でもある。眼底画像からの糖尿病網膜症の初期症状の検出と治療は、失明のリスクの低減に貢献する [1]。

近年は機械学習の一種である畳み込みニューラルネットワーク (CNN:Convolutional Neural Network) が、眼底画像からの糖尿病網膜症の初

期症状の検出に成果を挙げている [2]。しかし機械学習で病変の検出を行うにあたって、得られる病変データ数と非病変データ数とが不均衡であることが大きな障害となっている。これは不均衡なデータの場合、一般的に少数派に所属する病変データの検出率が低くなる傾向にあるためである。

不均衡データを扱うための対応策の一つとして、オーバーサンプリングと呼ばれる手法がある。オーバーサンプリングにおいては、少数派のデータを用いてデータオーギュメンテーションを行うことで多数派とデータ数の均衡をとる。現在は新たなデータオーギュメンテーションの手法として、敵対的生成ネットワーク (GAN:Generative Adversarial Nets) [3] が注目されている。

GAN は眼底画像の生成にも成功している [4] [5]。先行研究においては、一枚の眼底画像全体を生成している。本研究においては GAN に

*1 滋賀県立大学大学院工学研究科電子システム工学専攻

[〒522-0033 滋賀県彦根市八坂町 2500]

e-mail: oi23mfujita@ec.usp.ac.jp

*2 滋賀県立大学工学部電子システム工学科

*3 滋賀大学データサイエンス学部

*4 岐阜大学工学部電気電子・情報工学科

よる生成画像を用いて、眼底画像から病変部分の検出を行う CNN の性能の向上を目指す。そのため、本研究では GAN を用いて CNN に入力する病変画像の生成を行った。対象とした病変は、糖尿病網膜症の初期病変の一つである硬性白斑である。硬性白斑は糖尿病網膜症の初期段階にあらわれる、境界が明瞭な白斑である。

本研究では生成データと実データ間の分布の差異について、複数の指標を用いて検証を行った。また生成データを用いてデータ数における不均衡を改善することが、硬性白斑を検出する CNN の精度向上に貢献するかについても検証を行った。

2. 実験方法

1) データベース, 前処理と学習データの作成

本研究では硬性白斑の所見を含む眼底画像のデータベースとして、Indian Diabetic Retinopathy Image Dataset (IDRiD) [6]を用いた。IDRiD は 81 枚の眼底画像と、画像ごとに糖尿病網膜症の初期病変である血管瘤、硬性白斑、軟性白斑と出血それぞれを画素単位でラベル付けした画像データを提供している。眼底画像の解像度は 2,848×4,288 画素であり、jpg 形式で提供されている。

本研究では、前処理として 81 枚の眼底画像に対して画像ごとに明るさの正規化を行った。その後、前処理後の画像を用いて 32×32 画素の画像を学習データとして切り出した。作成した画像は硬性白斑と非硬性白斑ともに、30,000 枚である。また検証データとして、硬性白斑と非硬性白斑をそれぞれ 6,000 枚ずつ作成した。同様に評価データも 6,000 枚ずつ作成した。

2) GAN の構造と学習方法

硬性白斑における自動検出の研究として、RGB の 3 チャンネルを用いたもの [2] と Green の 1 チャンネルのみを用いる手法 [7] がある。そこで本研究では GAN を用いて、RGB と Green チャンネルそれぞれの硬性白斑を生成した。構築した GAN の構造を図 1 に示す。Convolution1 はストライド 1, パディング 1, 3×3 フィルタを適用する畳み込み層である。また Convolution2 は

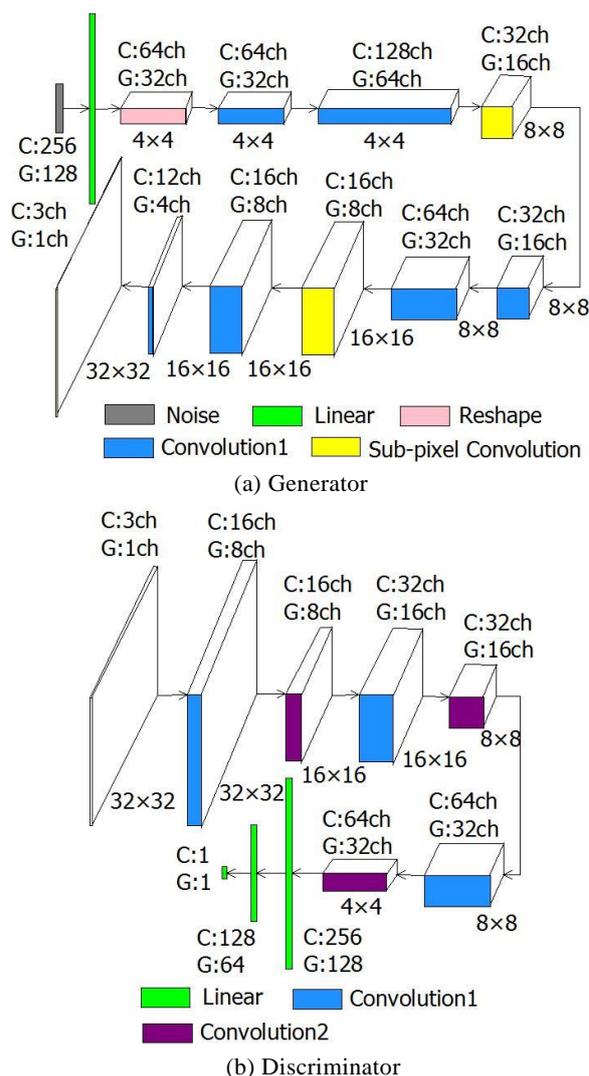


図 1 GAN の構造. C は RGB の 3 チャンネルを, G は Green チャンネルのみを用いた際の構造である.

ストライド 2, パディング 1, 4×4 フィルタを適用する畳み込み層である。活性化関数は Generator と Discriminator の出力層を除いた全層に Leaky Relu を用いた。Generator の出力層の活性化関数には、Sigmoid を用いた。

図 1 に示した GAN の学習には、作成した硬性白斑データのうち 3,000 枚を用いた。また損失関数として、WGAN-GP [8] における損失関数を用いた。最適化手法および更新方法も、[8] と同様のものを用いた。

3) 実データ分布と生成データ分布との比較

学習させた GAN を用いて生成した 27,000 枚の画像データと、GAN の学習に用いた画像デー

タを合わせたものを以後、生成データと呼称する。また学習データとして作成した硬性白斑 30,000 枚を、実データと呼称する。実データと生成データにおいて、それぞれ t-SNE [9] を用いて分布図を描いた。また画像ごとに画素内の最大画素値、最小画素値とその差分を求め、各分布の差異を求めた。

さらに画像ごとに画素値が [(画像内の最大画素値-5), 画像内の最大画素値] の値をとる位置を記録し、それらの分布を求めた。

4) CNN の構造と学習方法

生成データが CNN に与える影響を検証するため、[2] を参考として硬性白斑と非硬性白斑の識別を行う CNN を構築した。構築した CNN の構造を、図 2 に示す。Convolution1 はストライド 1, パディング 1, 3×3 フィルタを適用する畳み込み層である。活性化関数は出力層を除いた全層に Leaky Relu を、出力層には Softmax を用いた。最適化手法には学習率を 0.01 とした Stochastic Gradient Descent を適用し、学習回数は 60epoch とした。損失関数にはクロスエントロピーを用いた。

CNN を学習するための硬性白斑データとして表 1 に示す 5 種類を用意し、GAN による生成データが CNN に与える影響を調べた。従来のデータオーギュメンテーション手法である回転、複製を用いて、3,000 枚の硬性白斑データから 27,000 枚のデータを作成した。また多数派のデータを削減することで、少数派との均衡をとるアンダーサンプリングも比較として用意した。また非硬性白斑の学習データはアンダーサンプリングを除いて、眼底画像から切り出して作成した実データ 30,000 枚である。各手法に

表 1 各学習データの硬性白斑データの内訳。

データの種類	実データ	各手法によるデータ
実データ	30,000	0
生成データ	3,000	27,000
回転データ	3,000	27,000
複製データ	3,000	27,000
アンダーサンプリング	3,000	0

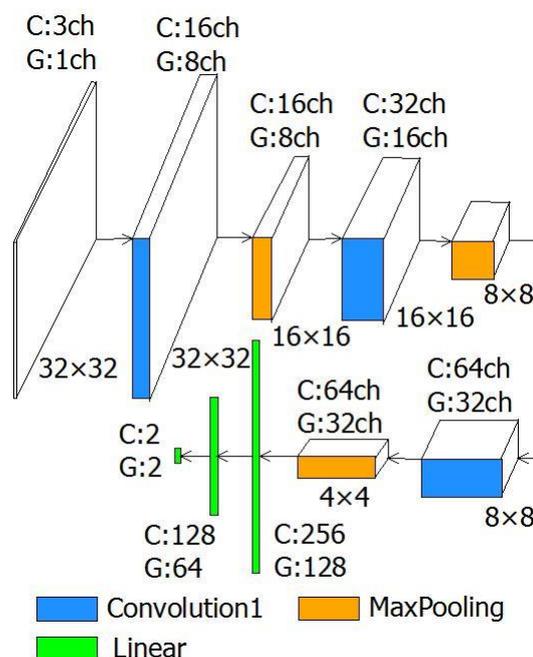


図 2 CNN の構造。C は RGB の 3 チャンネルを、G は Green チャンネルのみを用いた際の構造である。

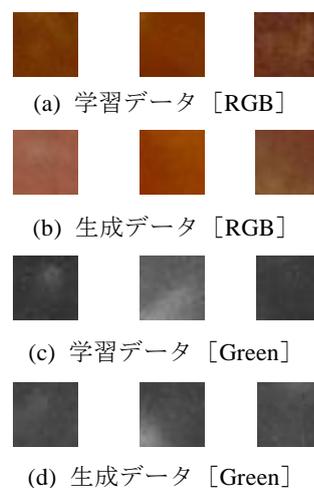


図 3 GAN の学習データと生成データ。

より得た硬性白斑データを学習データに加えて、データ数の不均衡を改善したことによる CNN の性能の変化を調べた。

3. 実験結果と考察

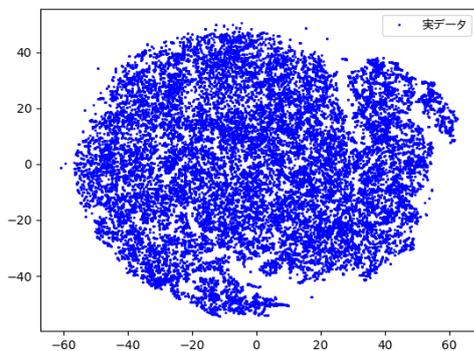
1) 生成データ

GAN の学習に用いたデータの一部を、図 3 に示す。また 50,000epoch 学習させたモデルを用いて生成したデータの一部も図 3 に示す。

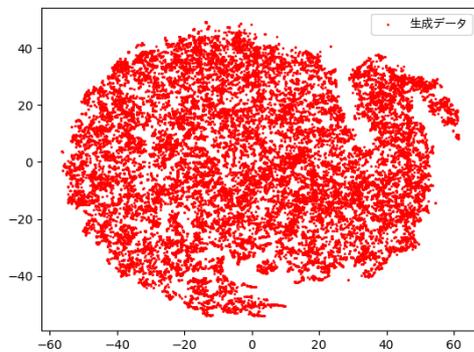
2) 実データ分布と生成データ分布との比較

図4にGreenチャンネルのみを用いた実データと、GANによる生成データにt-SNEを適用して得た分布図を示す。図4よりt-SNEによる分布図では、実データと生成データ間に大きな差異は見受けられない。RGBの3チャンネルを用いた場合も同様に、実データと生成データ間に大きな差異は見られなかった。

図5にGreenチャンネルのみを用いた各データにおいて画像ごとに求めた、画素内の最大画素値と最小画素値の差分の分布図を示す。図5から実データと生成データ間に大きな差異は見受けられない。また最大画素値と最小画素値についても、分布図からは大きな差異は見受けられなかった。硬性白斑は周囲より明るいことから、最大画素値は硬性白斑の色合いを表していると捉える。また最小画素値は、硬性白斑の周辺部の色合いを表していると捉える。最大画素

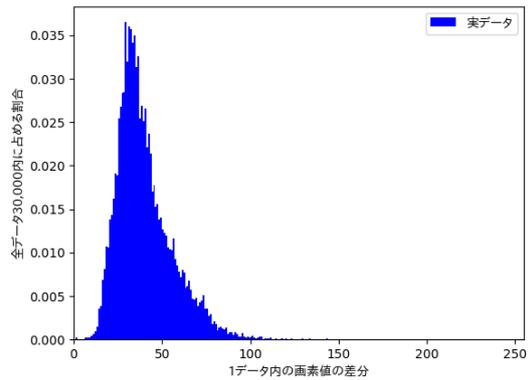


(a) 実データ

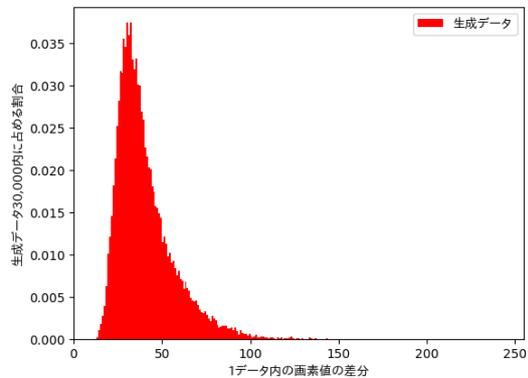


(b) 生成データ

図4 t-SNEによる分布図.



(a) 実データ



(b) 生成データ

図5 画像内における、画素の差分値の分布図.

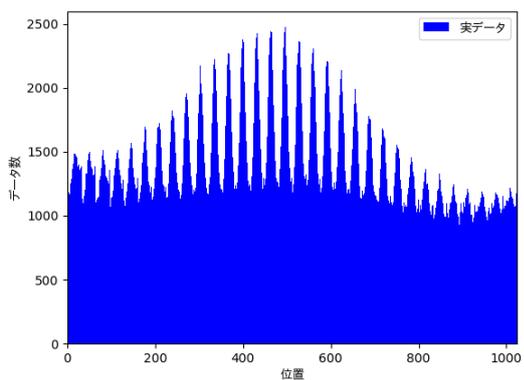
値、最小画素値との差分において実データと生成データ間に大きな差異が見受けられないことから、生成データは硬性白斑とその周辺部分の色合いについては再現できていると考える。またRGBの3チャンネル用いた場合にも、同様の傾向が見られた。

図6にGreenチャンネルのみを用いた各データにおいて画像ごとに求めた、画素値が [(画像内の最大画素値-5), 画像内の最大画素値] の値をとる位置の分布を示す。図6より実データと生成データ間に、差異が見受けられる。硬性白斑部分は、画像内で大きな画素値をとる。このことから生成データは、硬性白斑の現れる位置について実データを再現できていないと考える。原因としてGANの学習に用いたデータが、実データの位置に関する情報を表現するには情報が不足していることが考えられる。また

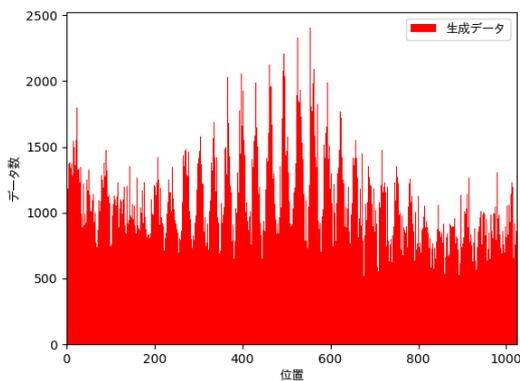
他の原因として、GAN の表現力や学習の不足が考えられる。

3) CNN に与える影響

図 7 に Green チャネルのみを用いた各学習データによって CNN を学習させた際の Sensitivity, Specificity と Average Accuracy の各指標値を示す。図 7 に示した値は、各条件において 10 回ずつ試行を行った際の平均値である。図 7 から実データ、生成データ、回転データ、複製データとアンダーサンプリングの全てにおいて、実データの硬性白斑 3,000 枚と非硬性白斑 30,000 枚による不均衡データを用いた場合よりも Sensitivity と Average Accuracy の値が向上していることがわかる。またこれら 2 つの値はアンダーサンプリングを除いた各データにおいて、データ数の不均衡が改善されるほど、大きくなる傾向にあることがわかる。また RGB の 3 色

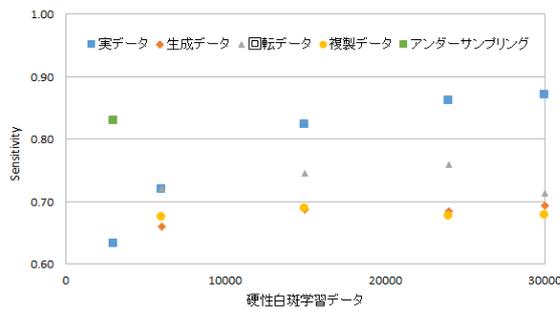


(a) 実データ

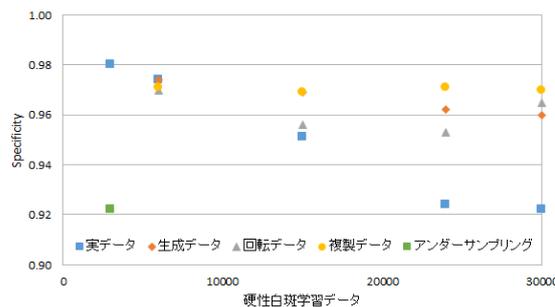


(b) 生成データ

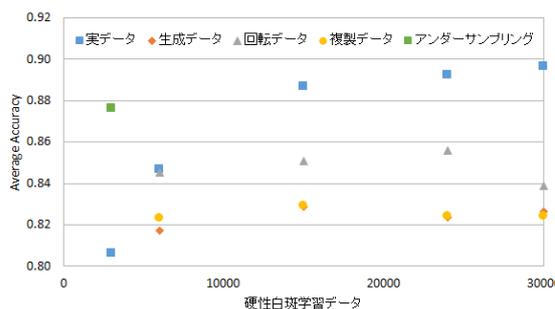
図 6 画像内において、大きな画素値となる位置の分布図。



(a) Sensitivity



(b) Specificity



(c) Average Accuracy

図 7 各指標値と硬性白斑の学習データ数との関係。

チャンネルを用いたデータにおいても、同様の傾向が見られた。

図 7 より GAN による生成データは、不均衡データと比較して Sensitivity と Average Accuracy の値を向上させた。一方で回転や複製、アンダーサンプリングと比較して、Sensitivity と Average Accuracy の伸びは小さなものとなった。これは上述したように、生成データは実データにおける硬性白斑の位置分布を再現できていないためだと考えられる。実データと異なる位置分布について学習したため、傾向の異なる評価データに対する汎化性能が低くなったと推測する。

4. まとめ

本研究においては, GAN を用いて硬性白斑画像の生成を行った. 複数の指標を用いて, 生成データ分布と実データ分布間の差異を求めた. 今後は硬性白斑の位置分布をより忠実に再現できるよう, GAN の構造や学習方法を見直す必要がある. またデータオーギュメンテーションとして GAN を用いた場合, 硬性白斑の検出を行う CNN における Sensitivity と Average Accuracy の向上が見られた. 今後は生成データがより CNN に寄与できるように, 生成データの質を高めていく必要がある.

謝辞

研究遂行にあたり貴重なご助言を賜りました滋賀県立大学工学部の小郷原一智氏に深謝いたします. 本研究の一部は JSPS 科研費 16K01415 および 26108005 の助成を受けたものです.

利益相反の有無

なし

文 献

- [1] Tapp RJ, Mccarty DJ, Shaw JE, et al.: The Prevalence and Factors Associates With Diabetic Retinopathy in the Australian Population. *Diabetes Care* **26**: 1731-1737, 2003
- [2] Tan JH, Fujita H, Sivaprasad S, et al.: Automated Segmentation of Exudates, Haemorrhages, Microaneurysms using Single Convolutional Neural Network. *Information Sciences* **420**: 66-76, 2017
- [3] Goodfellow IJ, Pouget-Abadie J, Mehdi Mirza, et al.: Generative Adversarial Nets. arXiv: 1406.2661v1, 2014
- [4] Zheng R, Liu L, Zhang S, et al.: Detection of exudates in fundus photographs with imbalanced learning using conditional generative adversarial networks. *Biomed Opt Express* **9**: 4863-4878, 2018
- [5] Guibas JT, Viridi TS, Li PS: Synthetic Medical Images from Dual Generative Adversarial Networks. arXiv: 1709.01872v3, 2018
- [6] Porwal P, Pachade S, Kamble R, et al.: Indian Diabetic Retinopathy Image Datasets (IDRiD): A Database for Diabetic Retinopathy Screening Research. data, 2018
- [7] Chudzik P, Majumdar S, Caliva F, et al.: Exudate Segmentation using Fully Convolutional Neural Networks and Inception Modules, *Medical imaging. Image Processing*, 2018
- [8] Gulrajani I, Ahmed F, Arjovsky M, et al.: Improved Training of Wasserstein GANs. arXiv:1704.00028v3, 2017
- [9] Matten L, Hinton G: Visualizing Data using t-SNE. *J Mach Learn Res* **1**: 1-48, 2008

Generating Hard Exudates Image by Using Generative Adversarial Nets and Analyzing Them

Maho FUJITA^{*1}, Yuji HATANAKA^{*2}, Wataru SUNAYAMA^{*2}, Chisako MURAMATSU^{*3}, Hiroshi FUJITA^{*4}

*1 Division of Electronic Systems Engineering, Graduate School of Engineering, the University of Shiga Prefecture

*2 Department of Electronic Systems Engineering, School of Engineering, the University of Shiga Prefecture

*3 Faculty of Data Science, Shiga University

*4 Department of Electrical, Electronic & Computer Engineering, Faculty of Engineering, Gifu University

Early detection and treatment of diabetic retinopathy (DR) contribute to prevent blindness, although this disease is a main factor of blindness. Convolutional neural network (CNN) has been applied for early DR lesion detection with good results. However, it has the challenge that number of normal data is much than abnormal ones. Generative adversarial nets (GAN) has been applied to solve the challenge. Hard exudates is a one of the typical pathological features in early DR and its border is clear. In this study, we augment hard exudates images using GAN. We then investigate difference between generated and real data. This paper discuss about a potentialities that the improvement of imbalanced data based on generated images contributes the performance of the hard exudates detection using CNN.

Key words: Diabetic Retinopathy, Convolutional Neural Network, Generative Adversarial Nets, Imbalanced Data, Hard Exudates detection

液状細胞診画像と患者情報の併用による

肺癌組織型自動分類の基礎的検討

山田 あゆみ^{*1,2} 寺本 篤司^{*1} 桐山 諭和^{*3} 塚本 徹哉^{*3}

今泉 和良^{*3} 星 雅人^{*1} 齋藤 邦明^{*1,2} 藤田 広志^{*4}

要旨

病理診断において、肺癌の組織型を正確に把握することは、治療方針を決定するために重要である。病理医は画像のみでなく、患者の臨床的背景を理解して診断を行なっている。そこで本研究では、液状細胞診(LBC)画像と患者臨床情報を用いた肺癌組織型分類手法を開発し、基礎評価を行った。はじめに、深層畳み込みニューラルネットワークを用いて、LBC画像から肺癌組織型に関する画像特徴量を抽出した。次に、電子カルテより患者臨床情報(喫煙情報等)を収集し、主成分分析により次元圧縮を行った。得られた画像特徴量とその画像に対応する患者臨床情報の主成分を識別器に入力し、3種類の肺癌組織型の分類結果を得た。149症例の臨床データを用いて、3-fold交差検証にて評価を行ったところ、LBC画像単体での分類精度は、82.9%であった。画像特徴に喫煙情報・腫瘍マーカー値を加えて、SVMで識別を行ったところ、それぞれ総合識別率は向上した。これらの結果から、提案手法の有用性が示唆された。

キーワード：肺癌，液状細胞診，組織型分類，電子カルテ

1. はじめに

現在、肺癌は世界的に癌死亡の主な原因のひとつである[1]。近年の化学療法の進歩に伴い、肺癌の組織型を正確に把握することは、治療方針を決定するために非常に重要となっている[2]。肺癌の組織型は、小細胞癌および非小細胞癌に大別され、後者はさらに腺癌と扁平上皮癌に分類される。

肺癌の組織型を把握するために、病理診断が行われる。病理診断とは、病変部から採取された組織や細胞を顕微鏡で観察し形態学的診断を行うものである。

肺癌の病理診断方法として液状化検体細胞診(Liquid-based cytology: LBC)があるが、形態学的に非小細胞癌を識別することは病理専門医でも困難な場合がある。そこで細胞の誤分類を避け病理医の診断を支援するためのツールとして、細胞診画像を用いた肺癌組織型自動分類手法が提案されている[3]。しかし、その分類精度は約70%にとどまっており、さらなる精度向上が課題となっている。

ここで本研究では、医師が診断時に参照する患者臨床データに注目する。病理医は通常、ガラス標本だけでなく、病理診断依頼書や電子カルテを参照し、患者個人の臨床的背景を理解した上で診断を行っている。さらに、肺癌の組織型は喫煙状態や腫瘍マーカーと関連性があることが知られており[4-7]、これらの情報を画像解析に追加することで予測精度の向上が期待できる。

*1 藤田医科大学医療科学部〔〒470-1192 愛知県豊明市杣掛町田楽ヶ窪 1-98〕
e-mail: ayumi926@fujita-hu.ac.jp

*2 藤田医科大学大学院保健学研究科

*3 藤田医科大学医学部

*4 岐阜大学工学部電気電子・情報工学科
〔〒501-1193 岐阜県岐阜市柳戸 1-1〕

投稿受付：2019年5月**日

そこで本研究では、液状細胞診画像と患者臨床情報を用いた肺癌組織型分類手法を開発することを目的とし、基礎評価を行った。

2. 使用データ

藤田医科大学病院にて気管支鏡生検が施行された149症例(腺癌:50症例,扁平上皮癌:51症例,小細胞癌:48症例)の肺癌患者の液状細胞診画像および患者臨床情報を収集した。また、すべての症例において、組織学的病理診断および免疫組織化学的診断による最終診断の情報がある。

なお、本研究は施設内倫理審査委員会により承認を得ている(HM18-352)。

1) 液状細胞診画像

本研究で使用した細胞は、気管支鏡生検時に収集され、Sure Path法[8]を用いてLBC標本を作製した。その後、Papanicolaou法にて染色を行った。40倍の対物レンズを有する顕微鏡(BX51, Olympus)に取り付けられたデジタルスチルカメラ(DP70, Olympus)を使用し、腺癌167枚,扁平上皮癌168枚,小細胞癌168枚の画像をJPEG形式にて収集した。初期マトリクスサイズは、2040 x 1536 pixelであり、すべての画像を768 x 768 pixelに切り出したのち256 x 256 pixelにリサイズした(図1)。

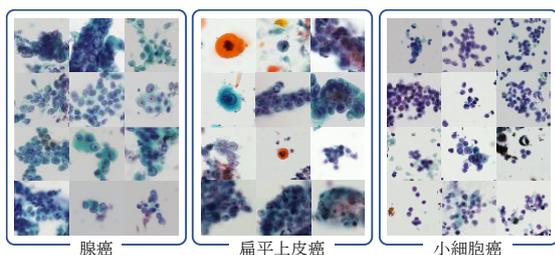


図1 収集した液状細胞診画像の例。

その後、交差検証を行うため、データをランダムに3分割した。また、過学習を防ぐためにデータ増量として、フィルタ処理(鮮鋭化,平滑化),反転,回転(90度),およびcolor offset補正を行い、各セットを5000枚ずつに統一した。

2) 患者臨床情報

電子カルテより、液状細胞診画像に対応する患者の患者臨床データ(年齢,性別,喫煙歴,血液検査結果等)を収集した。血液検査および腫瘍マーカーは、細胞診での細胞採取日と最も近い検査日のデータを収集した。収集項目を表1に示す。

表1 患者臨床データの収集項目。

収集情報	収集項目
患者基本情報	年齢,年代,性別,喫煙状況,ブリンクマン係数,喫煙開始年齢,喫煙年数,喫煙量(本/日),飲酒状況
血液検査	WBC,RBC,Hb,Hct,PLT,MCV,MCH,MCHC,好中球絶対数,白血球像,PT,PT比,PT(INR),PT秒,APTT,フィブリノーゲン,HBs抗原,HBs抗体,HCV抗体,HBc抗体,TP抗体,検体性状(乳び,溶血),TP,Alb,CRP,T-Bil,AST,ALT,LD(LDH),ALP,AMY,TG,T-C,BUN,UA,CRE,eGFRcreat,Na,K,Cl,Ca
腫瘍マーカー	NSE, ProGRP, IL-2R, CYFRA, CEA, SCC, SLX, KL-6, CA19-9

3. 方法

はじめに、深層畳み込みニューラルネットワーク(Deep convolutional neural network: DCNN)を用いて、細胞診画像から肺癌組織型に関する画像特徴量を抽出する。その後、得られた画像特徴量とその画像に対応する患者情報を統合して識別器に入力し、肺癌の組織型分類を行う。

1) 画像特徴量抽出

優れた画像認識性能を有することが知られているDCNNを用いて、液状細胞診画像から各組織型の確信度を得る。

DCNNモデルとして、ImageNetのデータセットで事前学習したVGG-16[9]を使用した。使用したDCNNの構造を図2に示す。

VGG-16は、Visual Geometry GroupのSimonyanらにより提案されたネットワークであり、16層の畳み込み層およびプーリング

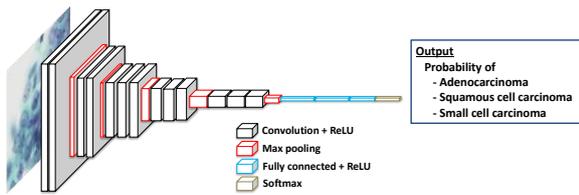


図 2 画像特徴量抽出のための DCNN の構造.

層と、3層の全結合層からなる。3層の全結合層のそれぞれのノード数を1024 - 256 - 3とし、最終層の活性化関数にsoftmax関数を使用し、出力として3種類の組織型(腺癌, 扁平上皮癌, 小細胞癌)の確信度を得られるようにした。

次に、事前学習した DCNN を用いて fine-tuning を行った。256 x 256pixel の液状細胞診画像を入力画像とし、全結合層の部分の重みを再学習した。その時の学習は SGD (Stochastic gradient descent: 確率的勾配降下法)にて最適化を行い、学習率は 10^{-5} 、学習回数は100回とした。学習のフレームワークには Keras + Tensorflow を使用し、演算には、NVIDIA 社製の GEFORCE GTX 1080(メモリ: 8GB)を使用した。

最後に、対象の液状細胞診画像を入力した際に DCNN から得られる3つの組織型の確信度を画像特徴量とした。

2) 患者臨床データの前処理

2. 2)にて収集した患者臨床データに対し、前処理として欠落データの平均値補間を行った。連続変数に対して、平均を0、分散を1とする正規化処理を行い、カテゴリ変数に対してダミー変数化を行った。

3) 主成分分析による次元削減

患者臨床データを特徴量として扱うとき、画像特徴量と比較して特徴数が多いことが問題となる。そこで、主成分分析(principal component analysis: PCA)により次元削減を行う。PCAとは、多くの変数により記述された量的データの変数間の相関を排除し、できるだけ少ない情報の損失で、少数の変数に縮約する解析手法である[10]。本手法では、第6

主成分までを取り出し識別器へ入力した。

4) 機械学習による識別処理

3. 1)で得られた画像特徴量および、その画像に対応する患者臨床情報を識別器に入力し、腺癌, 扁平上皮癌, 小細胞癌の3つの組織型に分類する。識別器として、サポートベクターマシン(Support vector machine: SVM)を使用し、識別性能を評価した。識別処理には、Python用のオープンソース機械学習ライブラリである scikit-learn を使用した。

4. 結果

1) 細胞診画像のみを用いた識別結果

はじめに、液状細胞診画像のみを用いて VGG-16 により分類を行った結果を示す。分類結果の混同行列を表2に示す。表2より、液状細胞診画像単体での組織型分類の総合識別率は82.9%であった。

表 2 VGG-16 による画像単体の分類結果.

		Predicted			
		Adeno	SCC	Small	
Actual	Adeno	140	24	3	83.8%
	SCC	30	126	12	75.0%
	Small	7	10	151	89.9%

2) 患者情報の併用による識別結果

次に、画像特徴量と次元削減を行った患者臨床データを入力とした際の分類結果を表3に示す。液状細胞診画像特徴量に、年齢や喫煙状況などを含む患者基本情報を併用したとき、総合識別率が最も向上した。このときの分類結果の混同行列を表4に示す。

表 3 画像特徴量に患者臨床データを併用したときの分類結果.

入力特徴	総合識別率	画像単体との差
画像のみ	82.9%	-
画像+患者基本情報	86.3%	3.4%
画像+血液検査	84.5%	1.6%
画像+腫瘍マーカー	83.1%	0.2%

表 4 画像特徴量に喫煙データを次元削減した情報を併用した場合の分類の混同行列.

		Predicted			
		Adeno	SCC	Small	
Actual	Adeno	151	15	1	90.4%
	SCC	27	131	10	78.0%
	Small	7	9	152	90.5%

5. 考察

本手法の有効性を評価するために、画像単体および画像特徴量と患者臨床情報を併用した際の分類精度を比較評価した。

149 症例の臨床データに対して本手法を適用したところ、画像単体と比較して、患者基本情報(年齢、性別、喫煙情報等を含む)を併用したとき、総合識別率が 3.4% 向上した。また、このとき、組織型別にみると腺癌で 6.6% と最も識別率が向上した。

結果より、画像単体での分類より、患者臨床データを考慮した提案手法の方が、識別精度が改善することが確認され、基礎検討としては良好な結果が得られた。

6. まとめ

本報告では、細胞診画像および患者臨床データを併用した、肺癌組織型の自動分類手法を提案した。

今後の課題として、さらなる症例の追加による有効性の評価や、分類精度の低い扁平上皮癌の精度向上の検討を行う必要がある。

利益相反の有無

なし

文献

- [1] American Cancer Society, Cancer Facts and Figure, 2018.
- [2] The Japan Lung Cancer Society 編: Guidelines for Diagnosis and Treatment of the Lung Cancer 2018, 金原出版株式会社, 東京, 2018, pp6
- [3] Teramoto A, Tsukamoto T, Kiriyama Y, et al.: Automated Classification of Lung Cancer Types from Cytological Images

Using Deep Convolutional Neural Network. BioMed Research International, Vol. 2017, Article ID 4067832, 1-6, 2017

- [4] Wakai K, Inoue M, Mizuno T, et al.: Tobacco Smoking and Lung Cancer Risk: An Evaluation Based on a Systematic Review of Epidemiological Evidence Among the Japanese Population, Jpn J Clin Oncol. 36(5), pp309-324, 2006
- [5] Salgia R, Harpole D, Herndon JE 2nd, et al.: Role of serum tumor markers CA 125 and CEA in non-small cell lung cancer, Anticancer Res., 21(2B), pp1241-1246, 2001
- [6] Rastel D, Ramaioli A, Cornillie F, et al.: CYFRA 21-1, a sensitive and specific new tumour marker for squamous cell lung cancer. Report of the first European multicentre evaluation. CYFRA 21-1 Multicentre Study Group, Eur J Cancer., 30A(5), pp601-606, 1994
- [7] Stieber P, Dienemann H, Schalhorn A, et al.: Pro-gastrin-releasing peptide (ProGRP) --a useful marker in small cell lung carcinomas. Anticancer Res., 19 (4A), pp2673-2678, 1999
- [8] 日本ベクトン・ディッキンソン株式会社: BD シュアパス™ 液状処理細胞診システムおよび関連製品. <https://www.bdj.co.jp/cytology/products/surepath.html> (2019年5月1日閲覧)
- [9] Simonyan K, Zisserman A: Very deep convolutional networks for large-scale image recognition. A conference paper at International Conference on Learning Representations (ICLR), San Diego, 2015, pp. 1-14
- [10] 金明哲著, “R によるデータサイエンス” 第1版第5刷, 森北出版株式会社, 東京, 2010, pp66-77

Pilot Study on Automated Classification of Lung Cancer Types from LBC Image and Electronic Medical Record

Ayumi YAMADA^{*1,2}, Atsushi TERAMOTO^{*1}, Yuka KIRIYAMA^{*3}, Tetsuya TSUKAMOTO^{*3},
Kazuyoshi IMAIZUMI^{*3}, Masato HOSHI^{*1}, Kuniaki SAITO^{*1,2}, Hiroshi FUJITA^{*4}

*1 School of Medical Sciences, Fujita Health University

*2 Graduate School of Health Sciences, Fujita Health University

*3 School of Medicine, Fujita Health University

*4 Department of Electrical, Electronic and Computer Engineering, Faculty of Engineering, Gifu University

In recent years, as chemotherapy has advanced, it is important to accurately diagnosis the histological type (adenocarcinoma, squamous cell carcinoma and small cell carcinoma). Pathologists diagnose not only images but also the patient's clinical background. In this study, we aimed to develop automated classification scheme of lung cancer type by combining liquid-based cytological (LBC) images and electronic medical record. First, image features were extracted from LBC images using deep convolutional neural network (DCNN). Subsequently, patient clinical data (smoking status etc.) were collected, and dimension compression was performed by principal component analysis (PCA). Image features and patient clinical data corresponding to cytological images were given to the classifier. Finally, classification result of 3 histological categories was obtained. In the experiments, the proposed method was applied to 149 cases (Adenocarcinoma; 50, Squamous cell carcinoma; 51, Small cell carcinoma; 48) and evaluated via 3-fold cross-validation. As a result of experiments, the classification accuracy of the cytological image alone using DCNN was 82.9%. When the image feature and smoking information or tumor markers were given to the support vector machine (SVM), the classification accuracy was improved. These results indicate that the proposed method may be useful for histological classification of lung cancer.

Key words: Lung cancer, Liquid-based cytology, Histological type classification, Electronic medical record

ResSENetを用いたオートエンコーダによる 認知症の疾患鑑別

藤林 大毅*1

要旨

内閣府の調べによると認知症高齢者は年々増え続けると言われており、認知症の中でも割合の多いアルツハイマー病の精度の高い診断補助技術の開発が求められている。現在アルツハイマー病の診断補助に用いられているものは、統計学的手法を用いて脳の萎縮、特に海馬傍回の萎縮度を算出するソフトウェアが主流である。しかし海馬傍回の萎縮以外にもアルツハイマー病の徴候は現れるため、その精度は限られたものとなっていた。我々は恣意的に部位の抽出を行わず、脳の全領域を対象とした深層学習を行う鑑別手法を提案する。欧米のADNIデータベースを用いて学習を行い、検証には豪州のAIBLデータベースを用いたところ、我々の手法は従来手法よりも高い90.9%の鑑別精度であった。

キーワード：3次元T1強調MRI、アルツハイマー病、深層学習、鑑別精度、全脳領域

1. はじめに

アルツハイマー病（AD）は進行性の脳疾患で、記憶や思考能力に障害を引き起こす。認知症の原因としては、ADが最もその割合が多く、全体の約70%を占める。ADの症状の特徴は記憶、言語障害などが進行し、最終的には日常の単純作業を行う能力も失われるといったものである。2012年時点で認知症高齢者数は462万人と、65歳以上の高齢者の約7人に1人であったが、2025年には認知症高齢者数は675万人に上り、高齢者の約5人に1人はなるとの推計データもある。今後患者が増える上で、医師の負担も増える事が想定され、認知症の中で特にAD鑑別の高精度な診断補助技術は非常に重要なものとなる。

ADの診断では持病を含めた病歴、症状お

よび磁気共鳴画像法（MRI）などの所見を踏まえた問診に基づき、医師が最終的に確定診断を行うのが一般的である。しかし、ADにおけるMRI画像の読影は脳梗塞等の読影と異なり、確実な病変が見えないことから、医師がこれを行えるケースが少ないという現場の問題がある。ADのMRI画像における所見として代表的なものとしては、特定の部位、特に海馬傍回の萎縮が特徴であると言われている。国内では海馬傍回の灰白質領域の萎縮度を評価する、VSRADと呼ばれるツールが存在し、現在多くの医療現場で使用されている。VSRADはVBMをベースとしたツールで、海馬付近の領域を着目領域（ROI）として設定した上で、母集団データに対する個々の患者の脳の萎縮度合をZスコアとして統計的に評価している。その他近年では、海馬以外の複数の着目領域を設定したBrain Anatomical Analysis using Diffeomorphic Deformation (BAAD) というツールが提案されている。BAADでは脳の300以上のROIに対して、個々の脳の容積を特徴化し、SVMという機械学習

*1 株式会社Splink

〔〒107-0052 東京都港区赤坂2丁目9-3〕

e-mail: fujibayashi@splinkns.com

手法を用いた疾患を良く分離する超平面からの距離を Alzheimer's Dementia Score (ADS) と定義している。BAADではこのスコアによる疾患鑑別を行った所、同じデータセットを用いた精度比較において、VSRADを上回るという報告がされている[1]。疾患鑑別の精度を向上させるには、BAADのように海馬領域以外の全脳領域に対してADの微細な特徴を捉えていく事が重要であると考えられる。

そこで、我々は3次元T1強調画像を入力とした、着目領域を恣意的に設定しないアルゴリズムを提案する。本アルゴリズムはU-net構造のAuto-EncoderにおけるEncodingの過程でReSENetを用いる深層学習モデルである。

2. 関連研究

深層学習以前の機械学習手法を用いたADの鑑別に関する関連研究は[2]に詳しい。深層学習を用いた研究は2013年以降に始まり、現在ではその研究内容も多岐に渡っている[3]。深層学習モデルにおいては全脳を入力対象とした研究が多いが、一方で海馬を中心にROIを定めている研究も存在しており、その性能の比較は[4]に詳しい。ROIベースと全脳の入力とは、複雑なネットワークの学習を如何に限られたデータ量でコントロールするかによって、その性能の優劣が分かれるようである。以下、深層学習を適用した幾つかの研究について概略を述べ、本課題への深層学習の活用状況を紹介する。

・ Payanらは、2次元スライス画像に対して、全脳の3次元MRIデータを入力とする事で鑑別精度が向上する事を報告した。一般画像認識の学習済みモデルを再学習する転移学習が主流であった深層学習の利用において、MRIデータを直接入力する事を検討した初期の成果である[5]。

・ Mingxiaらは固定的なROIの設定を避け、データから鑑別に有意な特徴領域を発見するLDMILフレームワークという手法を提案した。海馬及び海馬傍回に加えて、特に紡錘状回も有意に鑑別に寄与する部位であると報告されている[6]。

・ Liらは海馬領域に着目し、NC / 非進行性のMCI (sMCI) / 進行性のMCI (pMCI) / ADという順序をラベルとして付与したときの、各状態間のどちらの可能性が大きいかをOrdinal Networkと呼ぶ畳み込みニューラルネットワーク (CNN) の出力として構築し、高い鑑別精度が得られると報告している。ただし、著者らは全脳の情報を用いる事でさらに高い精度が期待できるとも述べている[7][8]。

これらの技術は近年盛んであるAI技術の医療診断への利用という議論を踏まえて、将来的には臨床現場でも用いられるツール化が進むと思われる。しかし、臨床の現場でADの疾患鑑別として現在実際に利用されているツールで深層学習が用いられている物は、まだ殆ど提供されていない。国内では主にVSRADがこれまで利用されてきたが、近年では椎野らによって開発されたBAADと呼ばれるツールの提供も進められている[9]。

・ VSRAD

VSRADは50歳以上の標準的な海馬領域のROIを保有し、VBMを用いた海馬傍回の灰白質部位の萎縮度合を評価し、54歳～86歳の男女80名の健常者と比較してどの程度萎縮が進行しているかを評価し、鑑別を行う。

・ BAAD

BAADはVSRADと同じくVBMを用いた評価ツールであるが、VSRADが海馬傍回の特定領域のみを評価するのに対し、脳の全体領域内で300以上のROIを評価する事を特徴と

したツールである。ADの患者に有意差の見られるROIのみを機械学習させる事で、複数のROIを対象としたAD罹患のスコア(ADS)を算出して鑑別を行うソフトウェアである。VSRADと鑑別精度の比較を行なった結果、VSRADはAccuracy84.8%に対して、BAADは86.1%とVSより高い鑑別精度が出せる事が報告されている[1].

本稿では後章において、これら既存ツールと同じ条件における、提案手法の精度比較実験の結果を示す。

3. 提案手法

本章では提案手法のニューラルネットワークモデルの詳細を述べる。

3.1 ResNet

提案手法は3次元画像データに対応させたResNetをベースとしている。ResNetはCNNの一種であるが、一般的なCNNに比べて畳み込みを行う過程での特徴量の逸失を防ぐ特徴を持っており、画像識別問題に関しては従来のCNNより識別精度が高い事が多く報告されている。

ResNetは、畳み込み層に加えて入出力を繋ぐSkip Connectionの機構を加える事によって、中間層の学習結果と、入力値から出力層までの残差とを合わせた学習を可能とする。これにより深い畳み込み層から構築されるモデルにおいても学習データが持つ特徴の逸失を抑える事を可能とし、直接的な構成のCNNより画像データを用いた分類問題において、高い識別精度が得られる事が多く報告されている[10].

一般に機械学習にはモデルの次元数に対して学習データが少ない場合、訓練データに対する過学習を起し、汎化性能が低下する問題が存在する。ResNetにおいても不十分な数量での深層学習においては、この問題は発生する為、個々の画像の特徴を過学習せずにADの特徴のみを効率良く抽出する機構がさらに必要となる。このため提案する構成はResNetに加えてU-netを組み合わせたモデルを採用する(図1)。

3.2 U-net

U-netはEncoding(左側)とDecoding(右側)から構成されるネットワークである。Encodingの過程では学習データが共通して持つ重要な特徴の抽出が行われ、Decoding部では最下層の共通特徴とEncodingの各層のSkip Connectionによって伝搬される元画像の情報が掛け合わされる形でデータの復号が行われる[11].

我々の提案モデルはU-netのEncoding部にResNetを用いており、学習に際しては、ResNet部の出力である推定ラベルと正解ラベルの残差、並びにDecoding部の出力画像と入力画像の残差の二つを同時に小さくするように行われる。この時、U-Netの出力教師画像は入力と同じMRI画像である(Auto Encoding)。この復号の過程で最適化された最下層の共通特徴を抽出して、これを識別に用いる。つまり、提案モデルは個々の画像の特徴を捉える役割をU-netのDecoding部に流し、ResNetを通るEncoding部にADの分類に重要な共通特徴の抽出が行われる事を意図した構成となっている。

さらに提案手法はSqueeze-and-Excitation(SE)をEncoding部のResNetの畳み込み部分に加えるReSENetと呼ばれる構成とした。SEを加えることにより、畳み込み時に画像の大域的な情報をチャンネルの値にも取り入れ、少ない畳み込みの中でも学習を効率的に進められる効果が得られる事が知られている。ReSENetの部分的なネットワークアーキテクチャを図2に示す。

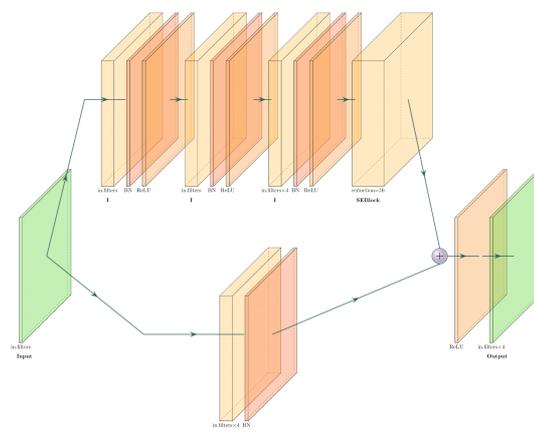


図2：ResSENetのネットワークアーキテクチャ

3.3 Squeeze-and-Excitation

Squeeze-and-Excitation(SE)は大域的な情報をチャンネルに圧縮し、入力画像に応じたチャンネル情報を掛け合わせるものである[12].

Squeeze-and-Excitationは畳み込み時に計算された特徴量を各チャンネルに均等に出力するのではなく、入力画像の特徴量に応じてチャンネルに出力する特徴量を制御する。これにより少ない層の数でも分類に必要な特徴の変換を可能とする。

以上提案手法をまとめると、構成としてはU-NetのEncodingにReSENetを用いたものであり、学習に際してはAuto Encodingとラベル誤差の差異の両方を最小化するものである。評価時にはU-net再下部のEncoding終了時点で抽出される特徴を再度畳み込んだ上で出力層でsoftmax関数を用いて二値分類を行うものである。

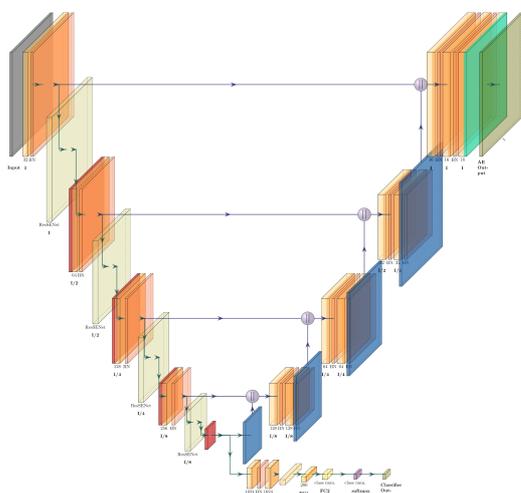


図1：提案手法であるU-Netのネットワークアーキテクチャ

4. 実験

提案手法では、データに二種類の前処理を行う。一つ目は特徴量間でスケールを揃えるために脳画像の正規化を施す。二つ目は学習時にデータの拡充を行うために画像の移動と歪みを施すデータ増強（Data Augmentation）である。提案モデルの学習にはアルツハイマー病の発症予測や治療薬の効果判定法の確立を目的とした北米臨床研究のADNIデータセットを用いる。学習済みのモデルの検証には外部データとして、AD発症の原因を特定する事を目的に1,100人を超える人々を4~5年間縦断的に追った研究データである豪州のAIBLデータを用いる。従来手法と同じ条件での鑑別精度の比較を行うため、従来手法の実験と同様にAD=332例、NC=406例のADNIデータセットを学習に用い、AD=71例、NC=447例のAIBLデータセットをモデル評価用のテストデータとして使用した。

5. 結果

VSRADとBAAD、及び提案手法のAccuracy, Specificity, Sencitivity, Diagnostic odds ratioの結果を表1に示す。また真陽性を縦軸、偽陽性を横軸に設定した提案手法のROC曲線を図3に示す。提案手法のAUCは96%、精度は90.9%、検査後のオッズは62.3であり、従来手法より高い鑑別精度が達成されるとともにSpecificity, Diagnostic odds ratioについても従来手法より高い結果となった。

表1. 提案手法の有用性検証と既存手法の比較
ADNIデータセットで学習した後にAIBLデータでモデルを評価した。

	Accuracy	Sensitivity	Specificity	Diagnostic odds ratio
VSRAD	84.8%	68.1%	84.5%	14.9
BAAD	86.1%	88.9%	85.7%	47.9
提案手法	90.9%	84.5%	91.9%	62.3

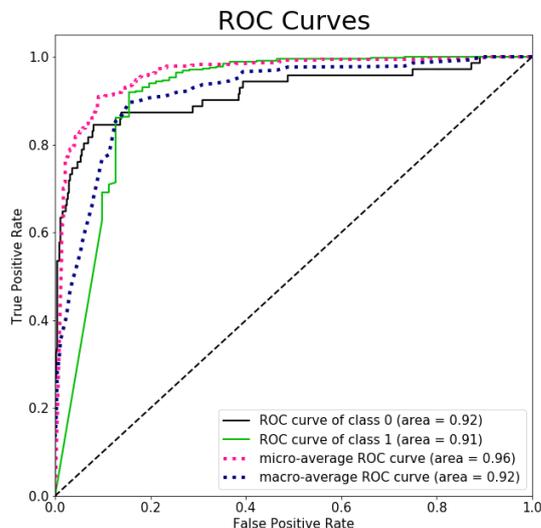


図3：ADNIデータを学習に用い、AIBLで検証した提案手法の結果

6. 結論

本研究ではADの疾患鑑別の高精度化を目的に、ROIの設定を恣意的に行わない深層学習による手法を提案した。我々の提案したReSENetを用いたU-Net構成のネットワークについて従来手法との比較実験を行い、精度 90.9%、特異度 91.9%、検査後オッズ 62.3とより高い結果が得られる結果となった。ADの進行と海馬領域の萎縮の関係はこれまでに良く知られた関係であったが、ADの鑑別には全脳の情報を用いる事で、さらにその精度を向上させ得る事を支持する結果となった。今後はGrad CAM等の技術[13]を用いて提案モデルが判定時に脳内のどのような領域を重要視しているか可視化し、判定根拠をより明確にすると共に、ADの進行について海馬萎縮以外の要因を明らかにする事が課題である。

利益相反の有無

なし

文献

- [1] 椎野 顯彦, 岩本 祐太郎, 韓 先花, 陳 延偉, アルツハイマー病の画像診断—voxel-based morphometryと人工知能によるアルツハイマー病スコアの有用性, 脳循環代謝 (日本脳循環代謝学会機関誌), 2016-2017, 28 巻, 2 号, p. 303-308,, 抄録
- [2] Arbabshirani, Mohammad R., et al. "Single subject prediction of brain disorders in neuroimaging: promises and pitfalls." *Neuroimage* 145 (2017): 137-165.
- [3] Litjens, Geert, et al. "A survey on deep learning in medical image analysis." *Medical image analysis* 42 (2017): 60-88.
- [4] Wen, Junhao et al. "Convolutional Neural Networks for Classification of Alzheimer's Disease: Overview and Reproducible Evaluation." *CoRR* abs/1904.07773 (2019)
- [5] Payan, A. & Montana, G. (2015), Predicting Alzheimer's Disease - A Neuroimaging Study with 3D Convolutional Neural Networks., in Maria De Marsico; Mário A. T. Figueiredo & Ana L. N. Fred, ed., 'ICPRAM (2)', SciTePress, , pp. 355-362 .
- [6] Liu, Mingxia, et al. "Landmark-based deep multi-instance learning for brain disease diagnosis." *Medical image analysis* 43 (2018): 157-168.
- [7] Li, Hongming et al. "Deep Ordinal Ranking for Multi-Category Diagnosis of Alzheimer's Disease using Hippocampal MRI data." *CoRR* abs/1709.01599 (2017): n. pag.
- [8] Li, Hongming, et al. "A deep learning model for early prediction of Alzheimer's disease dementia based on hippocampal MRI." *Alzheimer's & Dementia: The Journal of the Alzheimer's Association* , Volume 14 , Issue 7 , P1407 -

P1409 (2019).

[9] 脳ドックのガイドライン2019, 2019年3月20日 改訂・第5版, 脳ドックのガイドライン2019改訂委員会編

[10] He, Kaiming, et al. "Deep residual learning for image recognition." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.

[11] Ronneberger, Olaf, Philipp Fischer, and Thomas Brox. "U-net: Convolutional networks for biomedical image

segmentation." International Conference on Medical image computing and computer-assisted intervention. Springer, Cham, 2015.

[12] Hu, Jie, Li Shen, and Gang Sun. "Squeeze-and-excitation networks." Proceedings of the IEEE conference on computer vision and pattern recognition. 2018.

[13] Selvaraju, Ramprasaath R., et al. "Grad-cam: Visual explanations from deep networks via gradient-based localization." Proceedings of the IEEE International Conference on Computer Vision. 2017.

ResSENet-based AutoEncoder for Alzheimer's Disease Detection

Daiki FUJIBAYASHI*1

*1 Splink, Ltd.

The importance of diagnostic support tools for dementia will increase since it is predicted that the number of elderly patients with dementia increase in the future. Alzheimer disease (AD), which is the most common cause of dementia, is mainly characterized by hippocampal atrophy. For diagnosis of AD, statistical methods to calculate hippocampal atrophy by setting a region of interests (ROI), within 3DT1-MRI images is widely used. On the other hand, it has been reported that setting multiple ROIs can improve the accuracy of AD classification. In this paper, we propose a classification method which utilize the whole area of the brain instead of setting arbitral regions to be analyzed . We trained the classifier based on the proposed method using the ADNI datasets and verified its performance using the AIBL datasets. We obtained 90.9% accuracy for AD / NC classification.

Key words: T1-MRI, Alzheimer's disease, Deep learning, Classification accuracy

著者紹介



藤林 大毅 (ふじばやし だいき)

2015年同志社大・理工学部・インテリジェント情報工学科卒, 2017年奈良先端科学技術大学院大学博士課程前期・情報科学・情報科学専攻了。現在, 株式会社Splink機械学習エンジニア。MRIを中心とした画像処理の研究開発に従事。

ドメイン敵対的学習を用いる病理画像からの

悪性リンパ腫候補領域の抽出と病型識別

古賀 諒一*¹ 橋本 典明*¹ 横田 達也*¹ 中黒 匡人*²高野 桂*² 中村 栄男*² 竹内 一郎*¹ 本谷 秀堅*¹

要旨

本研究では、悪性リンパ腫の薄切切片の HE 染色病理顕微鏡画像より、その病型を推定する手法を提案する。悪性リンパ腫には 70 種類以上の病型があり、その病型に依って治療法や治療後の経過が異なるうえに、その病型を病理画像より診断することは専門の病理医であっても容易ではない。この病型識別を支援するシステムを構築するために、切片全体を含む病理画像中より悪性腫瘍領域の部位を自動的に選択し、そのうえで病型を推定する手法を提案する。この際、施設や染色を行った技師ごとに異なる HE 染色の色味の違いを積極的に無視するために、ドメイン敵対的学習を導入する。これにより、切片全体の病理画像から悪性腫瘍領域の抽出ができるようになり、病理画像における腫瘍領域の可視化が可能となった。また、自動的に取り出された悪性腫瘍を含むパッチのみを用いて病型を推定することで、病型推定の精度向上が確認できたので報告する。

キーワード：ニューラルネットワーク、ドメイン敵対的学習

1. はじめに

悪性リンパ腫は 70 種類以上の病型に分類されているうえ、どの病型であるかを判断することが困難な病気である。本研究では、HE 染色が行われた悪性リンパ腫の病理標本を顕微鏡で撮影して獲得できる、図 1 に示すような病理顕微鏡画像を用いる。しかし、これらの病理標本はその全体ががんに侵されているわけではなく、病型の同定に利用できるのは標本中の一部分のみで、腫瘍領域を注視することが必要である。病理画像は図 1 のように、そのサイズが非常に大きいため、一括に処理を行うことが非現実的であり、そのため、一定の大きさのパッチに切り出して処理を行う。この場合、切り出したパッチの中に腫瘍領域が存在しない非病気

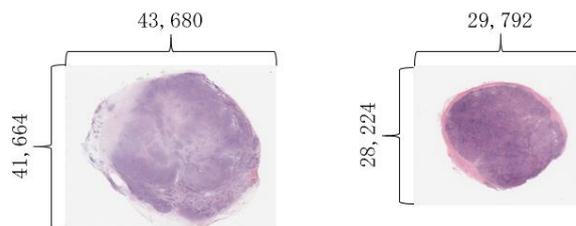


図 1 HE 染色病理顕微鏡画像の例。施設ごとに染色の色合いや強さが異なる。

パッチが混在するという問題点が生じる。また、これらの病理標本は症例間で HE 染色の色味が異なるという問題点もある。本研究の目的は、上に述べた 2 つの問題点に対処した悪性リンパ腫病型識別システムを構築することである。

2. 提案法

本研究では、上に述べた病型識別システムを構築するために、腫瘍領域の判定を行う病気パッチ検出器と、入力パッチの病型を識別する病型識別器が必要となる。

本研究では、病気パッチ検出器の学習に必要なパッチごとの病気か非病気かを示す正解情報が存在しないため、すべてのパッチを病

*1 名古屋工業大学

[〒466-8555 名古屋市昭和区御器所町]

e-mail: koga@iu.nitech.ac.jp

*2 名古屋大学医学部付属病院

[〒466-8560 名古屋市昭和区鶴舞町 65]

病気パッチと仮定した区別なし識別器が出力する事後確率値を病気パッチ検出器のラベルデータ[1]として利用する。その後、病気パッチと判断されたパッチのみを用いて、病型識別器の学習を行う。ここで、これらの識別器はすべて、症例間の染色の違いを無視するために、ドメイン敵対的学習を用いて学習を行う。ドメイン敵対的学習を用いたニューラルネットワークはDANN[2]と呼ばれており、図2のような構造を持つ。本研究では、症例それぞれを1つのドメインと定義して、ドメインが識別できなくなるように学習を行う。これにより、本研究における2つの問題点に対処した病型識別システムの構築が可能となる。

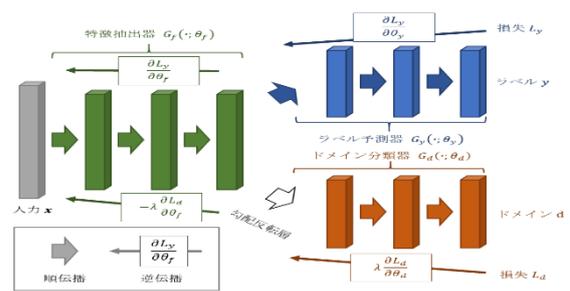


図2 DANNの構造。

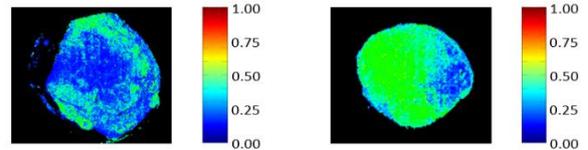


図3 識別器が出力した事後確率。

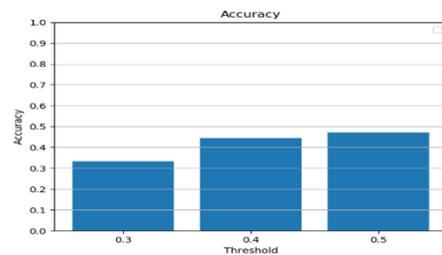


図4 腫瘍候補領域選択の閾値と病型識別率。

3. 実験

3.1. 病気パッチ検出器を用いた腫瘍候補領域の抽出

病気パッチ検出器の学習には5つの病型、合計208症例からなる悪性リンパ腫のHE染色画像を大きさ 224×224 として切り出したパッチ20万枚を用いた。

病気パッチ検出器によって出力された、0から1の連続値で表される病気らしさの値を画素値として書き込むことで、図3のような病気らしさの分布を示す画像を生成した。このような画像から、ある閾値以上の病気らしさを持つパッチを病気パッチとして抽出する。

3.2. 病気パッチのみを用いた病型識別

抽出した病気パッチのみを用いて病型識別器の学習を行った。予測時に出力されるパッチごとの識別結果で投票を行い、最も得票率の高かった病型を標本画像に対する識別結果として出力する。病気パッチ抽出時の閾値ごとの正解率を図4に示す。図4から、病気パッチとして抽出する閾値を大きくするに従い、病型識別率が向上する傾向にあることがわかった。専門の病理医でさえ、高い確度でHE画像のみから病型を推定することは容易ではなく、図4の結果は腫瘍領域の自動選択が適切に機能していることと矛盾がないことが確認できた。

4. まとめ

本研究では、悪性リンパ腫診断支援システムに必要な識別器を構築した。病気パッチ検出器を用いることで、腫瘍候補領域の自動抽出が可能となった。また、病気パッチのみで病型識別を行うと、その識別率は病気パッチとして取り出す閾値を大きくするに伴い向上した。

利益相反の有無

なし

文献

- [1] Le Hou, Dimitris Samaras, Tahsin M. Kurc, et al.: Patch-based Convolutional Neural Network for Whole Slide Tissue Image Classification. CVPR, pp.2424-2433, 2016.
- [2] Yaroslav Ganin, Evgeniya Ustinova, Hana Ajakan, et al.: Domain-Adversarial Training of Neural Networks. Journal of Machine Learning Research, vol.17, pp.1-35, 2016.

Extraction and Subtype Identification of Malignant Lymphoma Candidate Regions from Pathological Images Using Domain Adversarial Training

Ryoichi KOGA^{*1}, Noriaki HASHIMOTO^{*1}, Tatsuya YOKOTA^{*1}, Masato NAKAGURO^{*2},
Kei TAKANO^{*2}, Sigeo NAKAMURA^{*2}, Ichiro TAKEUCHI^{*1}, Hidekata HONTANI^{*1}

*1 Nagoya Institute of Technology

*2 Nagoya University Hospital

In this study, we propose a method to estimate the subtype of malignant lymphoma from hematoxylin and eosin (H&E) stained pathological microscopy images of sliced sections. There are more than 70 subtypes of malignant lymphoma, and depending on the subtype, the treatment method and the progress after treatment differ, and it is so difficult for a specialized pathologist to identify the subtype from pathological images. In order to construct a system to support this subtype identification, we propose a method to automatically extract the malignant tumor area from the whole slide image and then estimate the subtype. In this case, in order to actively ignore differences in the color of H&E stains that differ depending on the facility and the pathologist performing the stain, we adopt domain adversarial training. This enables us to extract the malignant tumor area from the whole slide image, and to visualize the tumor area. Further, by estimating the subtype, the accuracy improvement of estimation could be confirmed.

Key words: Neural Network, Domain Adversarial Training

造影 CT 画像における 2 段階閾値処理及び テクスチャ解析による外傷出血自動検出の検討

木村 拓貴^{*1} 田中 久美子^{*3} 吉村 裕一郎^{*2}

中田 孝明^{*3} 織田 成人^{*3} 中口 俊哉^{*2}

要旨

現在の外傷治療では救急医による造影 CT 画像を用いた読影診断が行われているが、1000 枚以上の CT 画像を迅速かつ正確に読影する必要があることから医師の負担は大きい。本研究では、医師の負担軽減を目的に外傷出血の自動検出を検討する。外傷出血候補領域の抽出においては、各組織の CT 値分布を参考に、骨領域の除去及び抽出範囲を限定した 2 段階の閾値処理によって出血領域の候補を抽出する。抽出した候補領域のテクスチャ特徴量からランダムフォレスト学習器を用いて候補領域を分類することで誤検出領域の低減を行った。実験として外傷 29 例の全身 CT 像を用意し、計 153 箇所の外傷出血の検出を試みた。読影医によって抽出された正解領域との重心間距離が 7.5mm 以下を正解として評価したところ、感度 96% の出血領域の検出に成功し、候補領域分類を行うことで偽陽性を約 70% 低減した。

キーワード：造影 CT 画像，外傷出血，機械学習，Random Forest 法，テクスチャ解析

1. 目的

外傷とは、何らかの要因による体外から加わる力によって生じる損傷であり、出血の程度によっては出血死を引き起こす危険性がある。外傷による死亡は、10 万人当たりおよそ 30 人程度の割合で発生しているが[1]、全国の救命救急センターに外傷治療の実態調査を行ったところ、実際に死亡した外傷患者のうち、修正予測外死亡数(防ぎえた可能性の高い外傷死亡)は 40% に迫る数値であった[2]。こうした外傷死亡を回避するために外傷出血の診断は外傷治療

において重要である。現在の外傷治療では救急医による造影 CT 画像を用いた読影診断によって治療方針の決定を行っているが、この診断方法の問題点として、出血の見落としや膨大な CT 画像の診断に時間を要すること、救急医は外傷患者の処置を行わなければならない読影に専念できる医師が少ないことなどが挙げられる。以上の点を改善するため、本研究では医師の負担軽減を目的に外傷出血の自動検出手法について検討する。

2. 提案手法

2.1. 前処理

研究の対象とする CT 画像は読影に用いられている静脈時相の造影 CT 画像であり、等方化して取り扱う。本研究の提案手法では、前処理として入力画像の分割、骨領域の除去を行う。

図 1 に示す CT 値分布から分かるように、身体的位置によって出血領域の CT 値の分布が異なるため、すべての位置に対応できる一つの閾

*1 千葉大学大学院融合理工学府
〔〒263-8522 千葉市稲毛区弥生町 1-33〕
e-mail: afya2170@chiba-u.jp

*2 千葉大学フロンティア医工学センター

*3 千葉大学大学院医学研究院 救急集中治療医学

値を設定する事は困難である。そのため、それぞれの位置に対応した閾値を設定する事を目的に入力画像を図2に示すように肩より上、骨盤より上、下半身に分割を行った。

骨付近の出血は候補領域抽出を行う際に出血領域と骨領域の境界が曖昧になり、検出が困難になるという問題点がある。そのため、閾値処理による骨領域除去を実装した。閾値処理によって抽出される領域の中で骨領域は体積が十分に大きいという仮定のもと、一定ボクセル以上の領域を骨領域として抽出を行い、骨内部組織の穴埋め後、入力画像内から対象となる領域を除去する事で骨領域除去を行う。アルゴリズムは以下の通りである。

- (1) 図3を参考にCT値380HUを閾値と設定し、閾値以上のボクセルを骨領域として抽出
- (2) 候補領域の中からボクセル数が90000(約20cm³)以上の領域のみを抽出(図4)
- (3) Closing, スライスごとの外輪郭抽出による領域内部の穴埋め
- (4) 入力画像内から抽出した対象となる領域部分を除去

2.2. 候補領域抽出手法

図1を参考にした上で、経験的に閾値の決定を行い、出血候補領域の抽出を行った。アルゴリズムは以下の通りである。

- (1) ガウシアンフィルタ $\sigma=2.0$ を用いて平滑化を行い、ノイズの低減を行う。
- (2) 頭部:85HU, 胴体:160HU, 下半身:80HUに閾値を設定し、閾値以上のCT値のボクセルを候補領域として抽出。

候補領域を抽出した際、出血領域に加え、ベッドや太い血管など明らかに出血領域ではない領域などの誤検出領域が同時に抽出されている。このような領域を除去する事を目的に以下に示す条件を設定し、条件に合う領域のみを候補領域として抽出した。

- (1) ボクセル数が30(約6mm³)以上90000(約20cm³)以下。
- (2) 候補領域の平均CT値が一定範囲内
 頭部 : 100~175HU
 胴体 : 150~250HU
 下半身 : 90~160HU

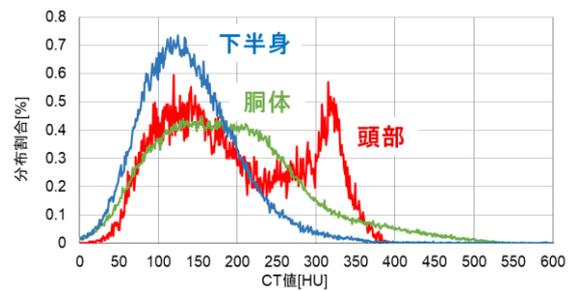


図1 身体的位置における出血領域のCT値分布

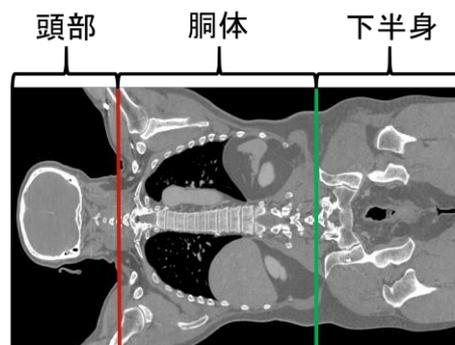


図2 入力画像の分割

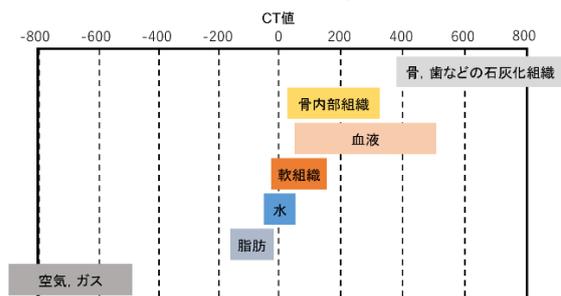


図3 造影CT画像におけるCT値分布

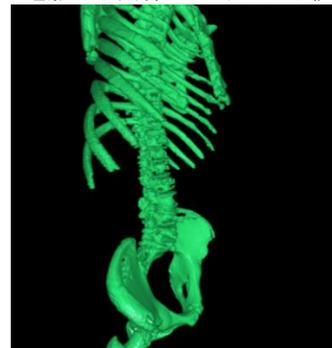
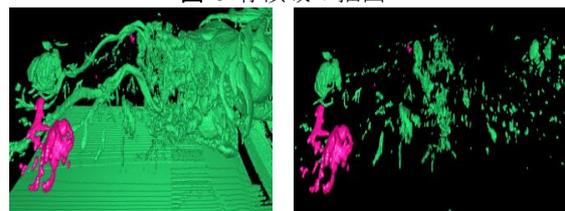


図4 骨領域の抽出



(a)候補領域抽出 (b)誤検出判別結果

図5 抽出結果(赤色の領域が出血領域)

図5に抽出結果を示す。図5(a)に存在しているベッドや太い血管、ノイズと思われる小さな領域を図5(b)では除去できている事が確認できる。また、出血領域で検出される領域とそれ以外の軟組織で検出される誤検出領域では、図3から分かるように出血領域の方がCT値の高い領域が多く含まれており、平均CT値に差が生じるという仮定のもと、平均CT値が一定範囲外の領域を誤検出領域として除去する条件(2)を設定した。

ここまで閾値処理による候補領域抽出を行ってきたが、図1が示すように出血領域が取りうるCT値の範囲は広いため、すべての出血領域を検出できる一つの閾値を決定する事は困難である。そこで、本研究では2つの閾値を用いた2段階閾値処理による抽出手法を実装した。図6に2段階閾値処理の流れを示す。高いCT値の出血領域を検出する閾値と低いCT値の出血領域を検出する閾値の2つの閾値を設定して、それぞれ検出処理を行い、最終的に結果を足し合わせた。誤検出除去の条件(2)である平均CT値の範囲を調整する事で、低閾値での検出で高いCT値の出血領域を抽出しないように抽出範囲を限定する事が可能である。閾値及び平均CT値の範囲は経験的に調整し、最も検出率が高くなる値を探索して、以下のように設定した。

- 頭部： 低閾値:85HU
平均CT値:100~170HU
高閾値:150HU
平均CT値:180~265HU
- 胴体： 低閾値:75HU
平均CT値:90~120HU
高閾値:165HU
平均CT値:200~350HU
- 下半身： 低閾値:80HU
平均CT値:90~140HU
高閾値:140
平均CT値:150~280HU

2.3. 候補領域分類

液体である出血領域の形状は複雑であり、領域ごとに全く異なるため、形状による候補領域の分類は困難である。そこで、出血領域の形状に依存しない特徴として、テクスチャ特徴量を

用いた候補領域の分類を行った。本研究では、表1に示す手法により算出される計23種のテクスチャ特徴量[3][4]を正解領域と誤検出領域でそれぞれ算出し、Random Forestで学習を行い、分類器を作成した[4]。訓練データとして表2のデータセットを用意した。作成した分類器を用いて各候補領域が誤検出かどうかを推定する事で誤検出低減を行った。

3. 評価

3.1. 候補領域の抽出

29症例 157箇所の外傷症例に対して抽出処理を行い、正解領域と候補領域との重心間の距離

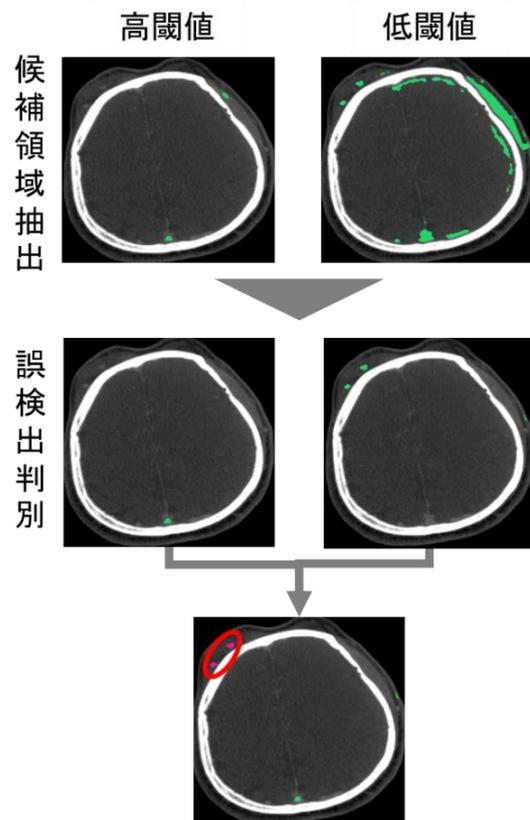


図6 2段階閾値処理

表1 算出したテクスチャ特徴量

● ヒストグラム統計量 平均, 分散, 歪度, 尖度等
● 同時生起行列
● 差分統計量

表2 訓練データ

正解領域	誤検出領域
354箇所	354箇所

が 7.5mm 以内の領域を真陽性として評価を行った。通常の閾値処理では、138 箇所出血領域を抽出したのに対し、2 段階閾値処理による抽出では、151 箇所出血領域の抽出に成功し、感度は 96%まで向上した(表 3)。

3.2. 候補領域分類

候補領域の分類の前後でそれぞれの誤検出の数を比較した。1 症例あたり 1596 箇所の FP が生じていたが、候補領域の分類によって一症例あたりの平均 FP 数が 490 箇所となった。感度を維持した上で、約 70%の誤検出領域の低減に成功した(表 4)。

4. 結論

本研究では、造影 CT 画像からの外傷出血検出手法を提案した。候補領域の抽出においては 2 段階閾値処理を実装する事で、感度が向上し通常の閾値処理よりも性能の良い抽出手法である事を確認した。また、テクスチャ特徴量を用いた候補領域分類を行うことにより、誤検出の低減効果を確認した。

利益相反の有無

なし

生体に関わる研究の倫理規範順守

本研究は千葉大学大学院医学研究院生命倫理審査 2972 号の承認を得た。

表 3 2 段階閾値処理の結果

	感度[%]	平均FP数
通常の閾値処理	88	998
2段階閾値処理	96	1596

表 4 候補領域分類結果

	感度[%]	平均FP数
分類前	96	1596
分類後	96	490

文 献

- [1] 厚生労働省 死因順位別に見た年齢階級・性別死亡数・死亡率・構成割合 2007 年 <https://www.mhlw.go.jp/toukei/saikin/hw/jinkou/suii07/deth8.html>
- [2] 平成 13 年度厚生科学特別研究「救命救急センターにおける重傷外傷患者への対応の充実に向けた研究」研究班の結果報告 2001 年
- [3] 藤田広志, 石田隆行, 桂川茂彦ら, “実践 医用画像解析ハンドブック” オーム社, 2012 年
- [4] Bowen Song et al., “Volumetric texture features from higher-order images for diagnosis of colon lesions via CT colonography,” International Journal of Computer Assisted Radiology and Surgery, Vol.9, No. 6, pp. 1021-1031, 2014.
- [5] Random Forests [Online]. Available : https://www.stat.berkeley.edu/users/breiman/RandomForests/cc_home.htm

Automatic detection of extravasation by two-step thresholding and texture analysis in contrast-enhanced CT image

Hiroki KIMURA^{*1}, Kumiko TANAKA^{*3}, Yuichiro YOSHIMURA^{*2}
Takaaki NAKADA^{*3}, shigeto Oda^{*3}, Toshiya NAKAGUCHI^{*2}

*1 Graduate of Science and Engineering, Chiba University

*2 Center for Frontier Medical Engineering, Chiba University

*3 Department of Emergency and Critical Care Medicine

In the current trauma treatment, an emergency doctor diagnoses an image using contrast-enhanced CT images, but the burden on the doctor is large because it is necessary to read more than 1000 CT images quickly and accurately. In this study, we consider automatic detection of extravasation for the purpose of reducing the burden on doctors. In the extraction of extravasation candidate regions, the regions are extracted by bone region removal and two-step threshold processing with limited extraction range with reference to the CT value distribution of each tissue. The false detection region was reduced by classifying the candidate area using the random forest learner from the texture feature quantity of the candidate area. We prepared whole-body CT images of 29 cases and tried to detect a total of 153 points of extravasation. When the region which the distance between the candidate region and the extracted correct region by doctor is less than or equal to 7.5mm is the correct answer, It successfully detected a extravasation with a sensitivity of 96%, and candidate region classification reduced false positives by about 70%.

Key words: contrast-enhanced CT images, extravasation, machine learning, Random Forest method, texture analysis

深層学習における学習データセット規模拡大に応じた 分類精度向上に関する実験的検討 -超拡大大腸内視鏡画像における腫瘍性病変分類に向けた 特徴量抽出-

伊東 隼人^{*1}, 森 悠一^{*2}, 三澤 将史^{*2}, 小田 昌宏^{*1},
工藤 進英^{*2}, 森 健策^{*1,3,4}

要旨

超拡大大腸内視鏡による超倍率の拡大観察はリアルタイムなポリープの組織学的分類を実現しうる。この新しいモダリティによる高精度な実時間診断は内視鏡医に高度な知識と十分な経験があって初めて実現しうる。超拡大大腸内視鏡の普及に向けた非熟練医の教育・サポートを対象とするCADシステムが求められている。CADシステムにおいては高精度な画像分類器がその中核をなす。特に機械学習に基づく分類器の構成においては大規模な学習データセットが不可欠である。中でも深層学習はデータセットから分類に適したパターン表現を自動的に学習して特徴量抽出を行い、それらの分類を行う。したがって、深層学習においては良質なデータセットの構築が非常に重要である。本研究では大規模データセットを構築し、深層学習に基づく分類器構築における症例数・画像数・分類精度の関係を実験的に調査する。

キーワード: 内視鏡検査, 超拡大内視鏡, 病理類型分類, 深層学習, テクスチャ解析, 汎化性能

1. はじめに

医用画像工学の領域においても診断支援・画像処理・画像再構成をはじめ多くの応用研究に対し、Convolutional Neural Network (CNN) [1-6] ベースの深層学習手法が大規模データを対象とする最適化手法として利用されている。一方で機械学習のための医用画像収集ならびにアノテーションに関しては医師に多大な負担をかけるとともに、構築した医用データセットの利用に関しては患者の人権問題をも含む。一般画像とは異なり、大規模データセット構築・利用は困難である上に、データドリブンな深層学習を利用するに際してはどの程度の大規模データをどのように収集するかが肝要となる。本稿では図1に示す超拡大大腸内視鏡画像の腫瘍・非腫瘍分類を対象とする。この2カテゴリへのパターン分類というパターン認識問題で最も基本的な問題に対し、収集した約3500症例分のアノテーション済み画像を用いて症例数・画像数・分類

精度の関係を調査する。さらに学習済みモデルの汎化性能を評価することで、深層学習に向けた大規模データセット構築の指針を模索する。

2. 関連研究

大腸ポリープ表面を内視鏡で拡大観察に基づき、組織学的なポリープの分類を行う診断方法 [7] が研究されている。この診断方法は細胞核の分布パターン (ピットパターン) や血管の形状といったポリープ表面のテクスチャに基づく診断方法である。この診断方法は生検を介さない実時間病理診断を実現しうるが、高度な知識と十分な経験が要される。特に520倍の超拡大観察可能な超拡大内視鏡 (Olympus, Tokyo) は新しいモダリティであるために熟練医の数が非常に少ない。そのため、非熟練医の教育・補助を目的としたコンピュータ支援診断 (CAD) システムが望まれており、拡大内視鏡画像の病理パターン分類手法 [8-18] が検討されている。

玉木らは75倍拡大観察下でのポリープ表面の狭帯域画像より、局所領域における勾配の方向統計に基づく微量表現 [9]、局所領域の方向・形状を考慮した多重解像度解析 [10]、そして深層学習 [11] といった複数アプローチでポリープ表面のテクスチャを表す特徴量を抽出し、病理学的

^{*1} 名古屋大学大学院情報学研究科知能システム専攻 [〒464-0822 名古屋市千種区不老町]
e-mail: hitoh@mori.m.is.nagoya-u.ac.jp

^{*2} 昭和大学横浜市北部病院消化器センター

^{*3} 名古屋大学情報基盤センター

^{*4} 国立情報学研究所医療ビッグデータ研究センター

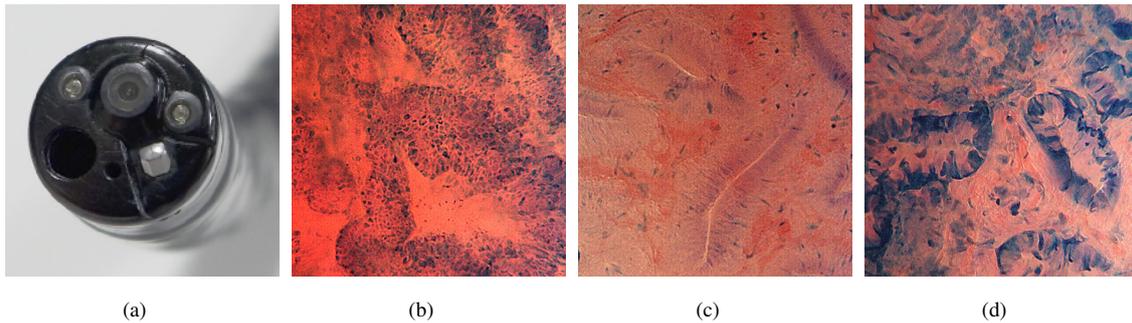


図1 超拡大内視鏡ならびに520倍拡大観察におけるポリープ表面の画像例。(a) CF-H290HCI (Olympus, Tokyo). 内視鏡先端のレンズ部分をポリープ表面に接着し、倍率を上げることで超拡大観察を実行する。(b)-(d)はそれぞれ非腫瘍、腺腫、そして浸潤癌の典型例を示す。(c)および(d)が腫瘍性病変のテクスチャパターンに該当する。

な分類を試みた。いずれの場合も線形サポートベクターマシン (SVM) [19] を分類器として用いている。深層学習ベースのアプローチ [11] では AlexNet [2], CaffeNet [3] そして GoogLeNet [4] という3つのネットワーク構造を利用し、それぞれの学習モデルの各層より特徴抽出を行った。抽出した特徴量を SVM で学習・分類することにより、分類精度の高い特徴量抽出を行う層を調査した。AlexNet と CaffeNet は全8層の中に5層の畳み込み層を持つが、最も分類精度の高い特徴量を抽出しているのは2また3層目であった。GoogLeNet は最後の全結合層を除くと21層であるが、最も分類精度の高い特徴量を抽出するのは最初の2つの Inception module の後にある pooling 層であった。深層学習の1-3層目の浅い畳み込み層ではエッジ・コーナー・プロップといった低レベル特徴量を抽出すると言われているが、テクスチャの分類にはこのような低レベル特徴量の抽出が有用である。

森らは520倍観察が可能な超拡大内視鏡を用いた実時間病理診断を目標にCADシステムの構築 [12-14] を検討した。細胞核の形状特徴量 [12] や形状特徴の局所的なバイナリパターンを追加した特徴量 [13] の検討報告があるものの、倍率が上がったとしても観察されるパターンはポリープ表面のテクスチャであることからマルチスケールのテクスチャ特徴量を採用するに至った [14]。分類には SVM を採用し、特徴空間における識別境界からクエリまでの距離に基づいたカテゴリに属する尤度 [20] を推定している。

伊東らは約400-1000症例程度の超拡大内視鏡画像2万枚を用いて、深層学習による特徴抽出の初期検討 [15, 16] を行った。しかしこの規模のデータセットは深層学習ベースの大規模学習には不十分であり、データセット拡充の必要性を主張した。伊東らはマルチスケールのテクスチャ特徴量と深層学習モデルの浅い層より得られる特徴量に対する特徴選択法 [17, 18] も検討している。

野里らは病理組織画像から高次相関局所特徴量 [21] を抽出し、正常な細胞とがん細胞それぞれを表す特徴ベクトル集合が張る2つのカテゴリ部分空間を直交化させることで特徴選択を行っている [22]。一方、伊東らは超拡大内視鏡画像からマルチスケールの Haralick 特徴量 [23] を抽出し、2カテゴリの線形部分空間同士のグラスマン距離を最大化することで特徴選択を行っている [17, 18]。このグラスマン距離最大化では期待値の意味で2カテゴリの線形部分空間が直交する最小次元の特徴空間を求めている。野里らの特徴選択では一方のカテゴリの線形部分空間の補空間にもう一方の特徴量を射影することで直交化を行うが、伊東らの特徴選択は直交化において学習データに共通でありかつ分類に寄与しない成分を除去する。したがって、学習データが単一の施設により得られたものであったとしても、特徴選択により高い汎化性能が得られる。

表1 ResNetの構成. 各 residual unit は文献 [6] の building block の構成に準拠. カーネルサイズの削減時には Residual unit 内にて線形写像を用いてサイズ調整を行った. Weight decay は 0.00001 とした. パラメータ数は総計 1,228,034 個. 最終層は出力数 2 の softmax 関数とした.

Layer name	Architecture
conv1	3 × 3, 64, stride 2 × 2
conv2_x	max pooling, stride 2 × 2
	$\begin{bmatrix} 3 \times 3, & 64 \\ 3 \times 3, & 64 \end{bmatrix} \times 1$
conv3_x	$\begin{bmatrix} 3 \times 3, & 128 \\ 3 \times 3, & 128 \end{bmatrix} \times 1$
	$\begin{bmatrix} 3 \times 3, & 256 \\ 3 \times 3, & 256 \end{bmatrix} \times 1$
global average pooling, 256-dimensional fc layer	

3. 手法

深層学習手法として CNN [1, 2, 5] ならびに Residual Neural Network (ResNet) [6] を利用する. CNN は AlexNet [2] をベースに超拡大大腸内視鏡画像の分類に最適化された 3 層の構成 [15, 16] を利用する. 上記の 3 層 CNN における畳み込み層を residual unit [6] に置き換えたものを ResNet の構成として利用する. 図 2 および表 1 がそれぞれ CNN と ResNet のネットワーク構成を示す. 非深層学習手法としては, マルチスケールでテクスチャ特徴量を抽出し, 線形 SVM ならびに Platt 尤度推定に基づく分類手法 [17, 18] を利用する.

4. 実験

1) データセット構築

実験においては IRB 承認済みの 2 種類のデータセットを利用した. ひとつはある 1 施設の通常診察時に収集された超拡大大腸内視鏡画像集合である. もうひとつは 3 つの他施設における通常診察時に収集された超拡大大腸内視鏡画像集合である. これらを EC 染色画像データセットおよび他施設データセットと呼称する. 画像収集においては染色液でコントラスト強調を行った上で, ポリープそれぞれに対して表面に接着した超拡大内視鏡の位置を少しずつ移動させながら 10 枚から 200 枚ほどの撮影を行った. これらの収集した画像には生検・病理診断を経て

表2 EC 染色画像データセット

	学習	検証	テスト	計
腫瘍 [枚]	26,462	3,213	3,262	32,937
非腫瘍 [枚]	13,180	1,592	1,638	16,937
計 [枚]	39,642	4,805	4,900	49,347
計 [症例数]	2,822	342	349	3,513

表3 他施設データセット. 3 つの病院 A, B, そして C それぞれにおける腫瘍・非腫瘍画像の内訳を示す.

	A	B	C	計
腫瘍 [枚]	2,907	231	827	3,965
非腫瘍 [枚]	443	29	190	662
計 [枚]	3,350	260	1,017	4,627

腫瘍・非腫瘍ラベルのアノテーションを施した. 表 2 および 3 は 2 つのデータセットにおける画像数の内訳を示す. 表 2 の症例数はデータセット全体の症例数のみを把握しているため, 学習・検証・テストデータの症例数は画像数の比と対応するように算出した.

EC 染色画像データセットは症例レベルで重複がないように学習・検証・テストデータの 3 つに分割した. 検証・テストデータの構成においては実臨床における腫瘍・非腫瘍のパターンの分布の分散を反映した構成となるように, 熟練内視鏡医 2 名に選別を依頼した. さらに, 診断に不適切である染色失敗である画像は検証・テストデータからは除去した.

2) 深層学習手法の学習

EC 染色画像データセットを 1/2, 1/4, そして 1/8 の画像数となるように更に分割を行った. 分割に際して症例数も画像数に比例するように, 撮影日時に基づいて行った. これら 3 つの症例数が削減された学習データとすべての症例数を含む元の学習データを用いて CNN の学習を行った. バッチサイズは 1024, エポック数は 300, 学習データは事前に 30 度ずつ回転させて 12 倍にデータ拡張した上で, ミニバッチごとにランダムに左右上下の反転を加えて学習させた. データ拡張を含めると 4 種類の学習データの総画像数は約 143 万, 72 万, 36 万, そして 18 万枚程度となる. 基本学習率は 0.00001 からはじめ, 100, 150, 200 そして 250 エポックにて逐次 1/10 倍の

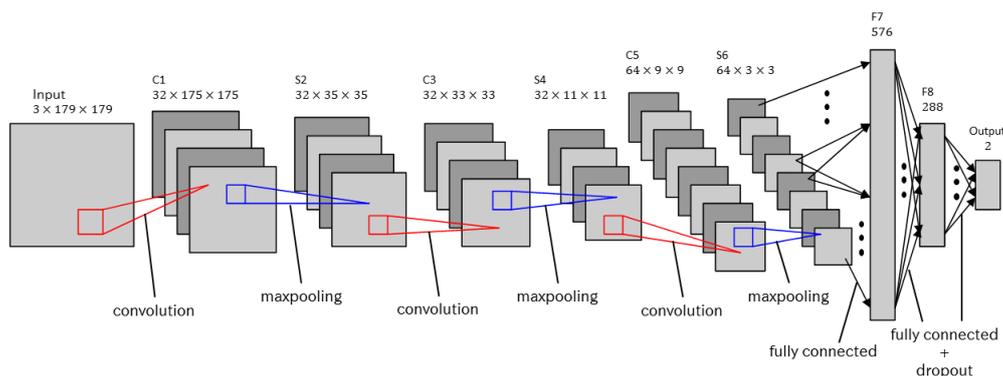


図2 3層CNNの構成. 学習時には畳み込み層それぞれにバッチ正規化 [24] を, 全結合層には dropout [25] を利用した. 活性化関数には Leaky ReLu (負領域の勾配は 0.3) [26] を用いた. パラメータ数は総計 529,794 個. 最終層は出力数 2 の softmax 関数とした.

値に再セットし, He の初期化 [28] と Adam [27] を利用して学習させた. 図 3 は各学習過程における各エポックごとの学習・検証データに対する分類精度 (accuracy) の推移を示す. 図 4 は学習データの症例数に対する学習済み CNN モデルの学習・検証・テストデータにおける分類精度を示す. 分類精度はデータ全体のうち正しいカテゴリに分類できた画像の割合を指す.

ResNet の場合はすべての学習データを用い, CNN の場合と同様に事前・オンラインのデータ拡張を利用した. バッチサイズは 512, エポック数は 250, 基本学習率は 0.00001 からはじめ, 100, 150 そして 250 エポックにて逐次 1/10 倍の値に再セットし, He の初期化と Adam を利用した学習を行った.

どちらの場合も入力 は 179 x 179 pixel の RGB カラー画像とし, 実装には TensorFlow バックエンドの Keras [29] を用いて Nvidia 製 GPU V100 (32GB) を 1 枚利用して計算した.

3) 非深層学習手法の学習

EC 染色画像データセットの学習・検証データセットを合わせて SVM 用の学習データとした. この学習データを 1/2, 1/4, 1/8 の画像数・症例数となるように再分割を行った. 計 4 種類の学習データそれぞれに対して 5 分割交差検定を行い, グリッドサーチによる線形 SVM のハイパーパラメータの最適値を求めた上でそれぞれの学習を行った. SVM の学習には LibSVM [30] を利用した.

4) 学習済みモデルの比較

4 つの学習済み CNN モデル, 1 つの学習済み ResNet モデル, そして 4 つの学習済み SVM モデルを用いて EC 染色画像データセットおよび他施設データセットのテストデータに対する分類を行った. 評価指標として感度・特異度 (sensitivity・specificity) を用いた. 腫瘍ならびに非腫瘍をそれぞれ陽性と陰性とおくととき, 感度と特異度はテストデータを分類した際の腫瘍における真陽性の割合と非腫瘍における真陰性の割合を指す. 図 5 がテストデータに対する各モデルの分類の ROC 曲線を示す.

5. 考察

図 3(a) では学習初期より終了時まで一貫して学習データと訓練データにおける分類精度に乖離が存在する. しかも訓練データにおける分類精度エポックごとの上下も大きい. この結果はパターン全体を表す特徴量の深層学習には, 学習データの症例数が完全に不足していることを示す. 図 3(b) では学習初期の学習データと訓練データにおける分類精度乖離はないが, 20 エポック付近から 2 つのデータ間における分類精度の乖離が始まる. 図 3(c) では図 3(a),(b) よりも分類精度の向上が確認できるものの, やはり 10-20 エポック付近で学習データと検証データにおける分類精度の乖離が始まる. 図 3(d) では学習データと検証データの分類精度の差は僅かであり, 100 エポック付近まではほぼ一致して

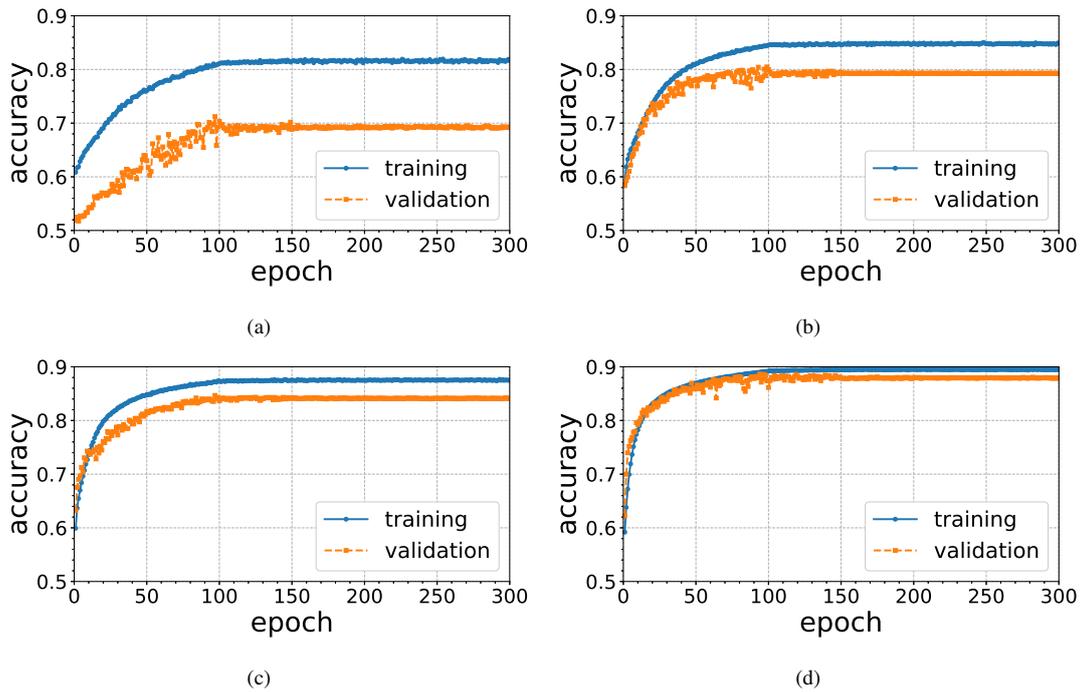


図3 CNNの学習過程における学習・訓練データに対する分類精度. (a)-(d)はそれぞれ1/8, 1/4, 1/2 そしてすべての学習データを用いた場合の学習における分類精度を示す. (a)-(d)における学習に用いたデータに含まれる症例数はそれぞれ353, 706, 1411 そして2822である.

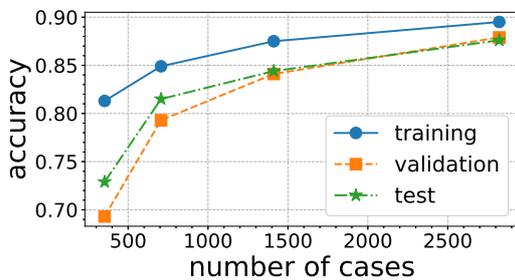


図4 学習データの症例数と学習済みCNNモデルの分類精度.

いる。理想的な学習データで学習を行った場合、学習データと検証データの分類精度を表す曲線は一致するか、検証データの分類精度がやや上となることが想定される。約2800症例程度があれば、完全ではないものの、本問題に関して十分な学習データであると考えられる。

図4の示す学習データにおける症例数と学習済みモデルの分類精度の関係より、約2800症例の2倍から4倍程度の症例数があれば、学習データと検証データの分類精度はほぼ一致すると予想される。学習データ内の症例数が1400程度以上では検証・テストデータにおける分類精

度がほぼ一致していることから、検証・テストデータが合わせて約1400症例程度のパターンの分散をよく表していることも伺える。

図5ではいずれの手法においても、腫瘍カテゴリの画像数が多いためか、感度重視の学習済みモデルとなっている。図5(a)において、学習データにおける症例数が約350-1400程度では感度・特異度はともに非深層学習手法の方が高いものの、学習データの症例数が約2800程度となると深層学習手法の方が高い評価値となる。図5(b)は学習データにおける症例数が約2800程度の場合の学習済みCNN, ResNet そしてSVMにおける他施設データセットの分類結果である。図5(a)とは対照的に、図5(b)の結果は非深層学習手法であるSVMの評価値が最も高く、ResNetの評価値が最も低い。

図5の比較結果は深層学習手法が学習データにおける観測パターンをよく学習していることを示す一方、汎化性能が十分でないことを意味する。統計量を元に定義されたテクスチャ特徴量とSVMの場合、学習データを収集した施設と他施設の両方の分類精度で同程度の精度であ

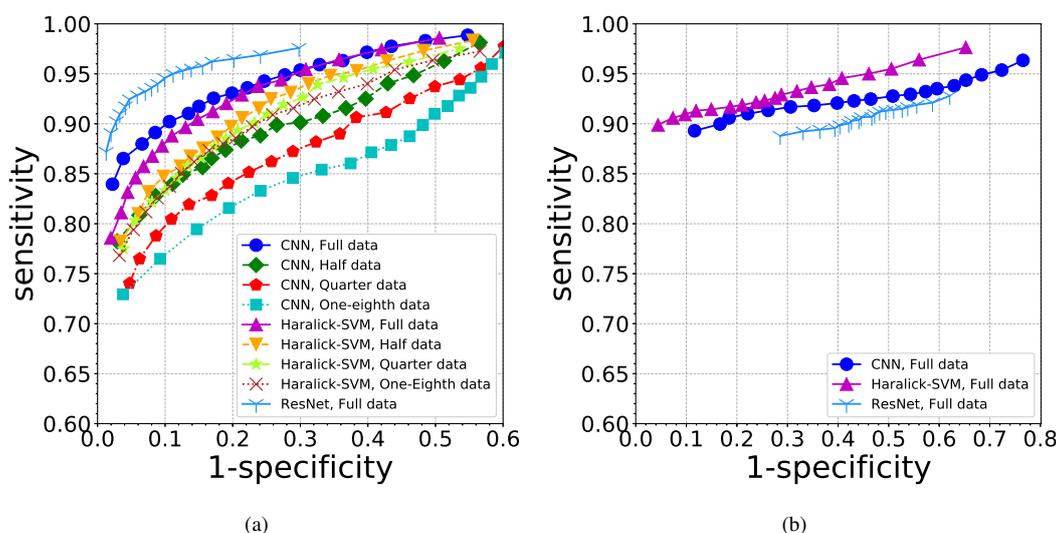


図5 テストデータに対するROC曲線。(a)EC染色画像データセット (b)他施設データセット。どちらの場合も、縦・横軸はそれぞれ感度および1から特異度引いた値を示す。

ることから、データドリブンな特徴量抽出において、学習に用いた施設データに由来する共通のパターンも抽出していると考えられる。特に、ResNetにおいては学習データをよく学習しているため、学習データを収集した施設における観測パターンの中に最適化された学習モデルとなっている。一般的にはCNNよりも高い分類精度を達成することで知られるResNetではあるが、これらの実験結果はResNetの汎化性能の低さを明らかにした。

深層学習手法で抽出される特徴量が施設由来の共通の特徴量を持っていると仮定するとき、この共通の特徴量を除去し、2つのカテゴリの差のみをよく表す特徴量を選択することで汎化性能の向上が期待できる。

6. まとめ

本稿では超拡大内視鏡画像の腫瘍・非腫瘍の2分類に対して、深層学習における学習データの規模と分類精度の関係を調査した。さらにテクスチャ特徴量抽出とSVMによる分類との比較を行い、抽出した特徴量の汎化性能をも調査した。約2800症例からなる約4万枚の学習データにデータ拡張を併用することで、従来のハンドクラフト特徴量と同程度の分類精度となる特徴量抽出が深層学習にて行えることを確認した。一方で、他施設データに対する汎化性能に関し

ては特徴抽出・特徴選択に未だ改善の余地があることを確認した。

謝辞 本研究の一部はJSPS/MEXT 科研費 (No. 26108006, 17H00867), 堀科学芸術振興財団そしてAMED (No. 18hk0102034h0103, 19hs0110006h0003, 19lk1010036h0001) の支援を受けた。利益相反 なし

文献

- [1] Lecun Y, et al.: Gradient-based learning applied to document recognition, Proc. of IEEE, **86**: 2278-2324, 1998.
- [2] Krizhevsky A, et al.: ImageNet Classification with Deep Convolutional Neural Networks, Proc. of NIPS, **1**: 1097-1105, 2012.
- [3] Jia Y, et al.: Caffe: Convolutional architecture for fast feature embedding, arXiv:1408.5093, 2014.
- [4] Szegedy C, et al.: Going Deeper With Convolutions, Proc. CVPR, 2015.
- [5] Simonyan K, Zisserman A: Very Deep Convolutional Networks for Large-Scale Image Recognition, Proc. International Conference on Learning Representations: 2015.
- [6] He K, et al.: Deep Residual Learning for Image Recognition, Proc. CVPR: 770-778, 2016.
- [7] Kudo S-E, et al.: The Diagnosis of

- Colorectal Tumors with Endocytoscopy (Japanese), *Gastroenterological endoscopy*, **55(4)**: 1510-1517, 2013.
- [8] Kominami Y, et al.: Computer-aided diagnosis of colorectal polyp histology by using a real-time image recognition system and narrow-band imaging magnifying colonoscopy, *Gastrointestinal Endoscopy*, **83**: 643-649, 2016.
- [9] Tamaki T, et al.: Computer-aided colorectal tumor classification in NBI endoscopy using local features, *Medical Image Analysis*, **17(1)**: 78-100, 2013.
- [10] Wimmer G, et al.: Directional wavelet based features for colonic polyp classification, *Medical Image Analysis*, **31**: 16-36, 2016.
- [11] Tamaki T, et al.: Computer-Aided Colorectal Tumor Classification in NBI Endoscopy using CNN Features, *Proc. Korea-Japan joint workshop on Frontiers of Computer Vision*, 2016.
- [12] Mori Y, et al.: Novel computer-aided diagnostic system for colorectal lesions by using endocytoscopy, *Gastrointestinal Endoscopy*, **81(3)**: 621-629, 2015.
- [13] Mori Y, et al.: Impact of an automated system for endocytoscopic diagnosis of small colorectal lesions: an international web-based study, *Endoscopy*, **48(12)**: 1110-1118, 2016.
- [14] Mori Y, et al.: Real-Time Use of Artificial Intelligence in Identification of Diminutive Polyps During Colonoscopy: A Prospective Study, *Annals of Internal Medicine*, **169(6)**: 357-366, 2018.
- [15] Itoh H, et al.: Classification of neoplasia and non-neoplasia for colon endocytoscopic images by convolutional neural network, *IEICE Technical Report*, **117(220)**: 17-21, 2017.
- [16] Itoh H, et al.: Cascade classification of endocytoscopic images of colorectal lesions for automated pathological diagnosis, *Proc. SPIE Medical Imaging*, **10575**, 2018.
- [17] Itoh H, et al.: Feature-selection method based on Grassmann distance for the classification of neoplastic polyps on endocytoscopic images, *IEICE Technical Report*, **117(518)**: 51-56, 2018.
- [18] Itoh H, et al.: Discriminative Feature Selection by Optimal Manifold Search for Neoplastic Image Recognition, *Proc. ECCV workshops*, **4**: 534-549, 2018
- [19] Vapnik VN: *Statistical Learning Theory*, Wiley, 1998.
- [20] Platt JC: Probabilistic Outputs for Support Vector Machines and Comparisons to Regularized Likelihood Methods, *Advances in large margin classifier*: 61-74, 1999.
- [21] Kobayashi T and Otsu N: Image Feature Extraction Using Gradient Local Auto-Correlations, *Proc. ECCV*: 346-358, 2008.
- [22] Nosato H, et al.: Histopathological Diagnostic Support Technology using Higher-order Local Autocorrelation Features (Japanese), *IPSJ SIG Technical Report*, **2010-MPS-81(32)**: 161-164, 2009.
- [23] Haralick, RM, et al.: Textural Features for Image Classification, *IEEE Transactions on Systems, Man, and Cybernetics*, **SMC-3(6)**: 610-621, 1973.
- [24] Ioffe S and Szegedy C: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, *Proc. International Conference on Machine Learning*, **37**: 448-456, 2015.
- [25] Srivastava N, et al.: Dropout: A Simple Way to Prevent Neural Networks from Overfitting, *Journal of Machine Learning Research*, **15**: 1929-1958, 2014.
- [26] Maas AL, et al.: Rectifier Nonlinearities Improve Neural Network Acoustic Models, *Proc. International Conference on Machine Learning*, 2013.
- [27] Kingma DP and Ba J: Adam: A Method for Stochastic Optimization, *Proc. International Conference on Learning Representations*, 2015.
- [28] He K, et al.: Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification, *Proc. ICCV*: 1026-1034, 2015.
- [29] Chollet F, et al.: Keras, <https://keras.io>, 2105.
- [30] Chang C-C and Lin C-J: LIBSVM: A library for support vector machines, *ACM Transactions on Intelligent Systems and Technology*, **2(3)**: 27:1-27:27, 2011.

Experimental Evaluation of Relation between Dataset Size and Classification Accuracy in Deep Learning -Feature Extraction from Endocytoscopic Colorectal Images for Neoplasia Classification-

Hayato Itoh^{*1}, Masashi Misawa^{*2}, Yuichi Mori^{*2}, Masahiro Oda^{*1},
Shin-Ei Kudo^{*2}, Kensaku Mori^{*1,3,4}

^{*1} Graduate School of Informatics, Nagoya University

^{*2} Digestive Disease Center, Showa University Northern Yokohama Hospital

^{*3} Information Technology Center, Nagoya University

^{*4} Research Center for Medical Bigdata, National Institute of Informatics

A new modality, endocytoscope, can establish real-time pathological diagnosis of colorectal polyps. However, high-level knowledge and sufficient experiences are required of endoscopists for accurate endocytoscopic diagnosis. For the achievement of the real-time cost-effective endocytoscopic diagnosis, computer-aided diagnosis (CAD) system, which helps and educates trainee and non-expert endoscopists, has potential demands. Accurate image-pattern classifier has a core role in the CAD system. In the machine-learning approach for the construction of high-performance classifier, designing of large-scale training dataset has an essential role. In especially, this data design is critical role in deep learning, since the deep learning is a data-driven representation learning for feature extraction and classification of it. We explore the relation among the number of cases, the number of images, and classification accuracy in deep learning approach for recognition of colorectal neoplastic polyps.

Keywords: Colonoscopy, endocytoscope, pathological pattern classificatoin, deep learning

CNN を用いた人工股関節全置換術術後 CT 画像からの 自動インプラント姿勢推定

阪本 充輝*¹ 槇野 大樹*¹ 大竹 義人*¹ 日朝 祐太*¹

高尾 正樹*² 菅野 伸彦*² 佐藤 嘉伸*¹

要旨

人工股関節全置換術において、カップ位置・角度といった置換されたインプラント姿勢の計測は術後評価において重要な役割を果たす。従来、術後 CT 画像からの計測が行われているが、金属アーチファクトによる画像の乱れが原因となり自動計測は容易ではなく、半自動での計測が行われてきた。しかし、我々が目的としている大規模データセットでの人工股関節全置換術術後 CT 画像の解析には、高速かつ自動でインプラント姿勢を推定する手法が求められる。そこで本研究では、CNN (Convolutional Neural Network) を用いて術後 CT 画像から置換されたカップの角度を自動で推定する手法を提案する。

キーワード：姿勢推定, Convolutional Neural Network, 術後 CT 画像

1. はじめに

人工股関節全置換術 (THA) において、不適切なカップ位置・角度はインピンジメントや脱臼などの術後合併症を引き起こす要因となるため[1]、置換されたインプラント姿勢の計測は術後評価において重要な役割を果たす。従来、術後 CT 画像からの解析が行われているが、金属アーチファクトによる画像の乱れが原因となり自動解析は容易ではなく、半自動での解析が行われてきた。しかし、大規模データセットでの解析には高速かつ自動でインプラント姿勢を推定する手法が求められる。Tompson ら[2] は CNN (Convolutional Neural Network) を用いて関節位置を推定し、を人体の姿勢を推定する

手法を提案している。本研究では CNN により、設置されたカップの角度 (anteversion, inclination) (図 1) を手動で推定する手法を提案する。

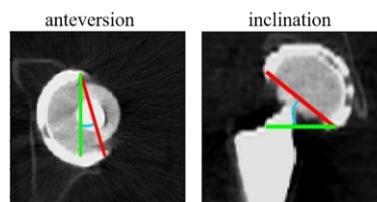


図 1 カップ角度の定義

2. データセット

本研究では、大阪大学医学部附属病院で撮影された 34 症例の THA 術後 CT 画像を用いる。CT 画像の Field of view は 360×360 [mm²]、マトリックスサイズは 512×512 、スライス間隔は 1.0 [mm] である。

また、Murray ら[3]の定義に従い、それら 34 症例のデータにおいて手動で計測したカップの角度データを使用した。手動計測では、coronal 平面においてカップ径が最大となるスライスで inclination を測定し、同様の方法で

*1 奈良先端科学技術大学院大学先端科学技術研究科情報科学領域

[〒630-0192 奈良県生駒市高山町 8916-5]

e-mail: sakamoto.mitsuki.si2@is.naist.jp

*2 大阪大学大学院 医学研究科

投稿受付：2019 年 5 月 22 日

axial 平面から anteversion を測定した。

3. 手法

図 2 に本手法のフローを示す。まず、THA 術後 CT 画像を入力として U-Net[4]によりカップの辺縁を示すヒートマップを推定する。その後、ヒートマップの最大値の 80%を閾値として二値化した結果を用いて主成分分析を行い、その第 3 主成分をカップの法線ベクトルとすることで、カップの角度を推定する。

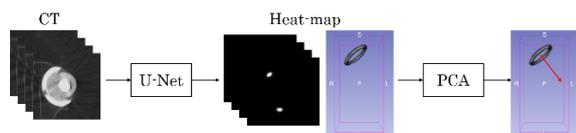


図 2 提案手法のフロー

4. 実験

4.1 実験概要

CT 画像から閾値(2000HU)により抽出したインプラントと CAD モデルを位置合わせすることで学習データを作成した。

U-Net の学習には閾値により抽出したマトリックスサイズ 128×128 、スライス間隔 1.0 [mm]の画像を 34 症例使用した。画像データセットは 2-fold に分割し、交差検証により U-Net の学習を行った。

4.2 実験結果

手動計測と提案手法により計測したカップ角度の差を示した box plot と誤差が最も大きかった症例、最も小さかった症例、中央値を示した症例を anteversion と inclination それぞれについて図 3 に示す。

表 1 手動と提案法でのカップ角度の計測の差

anteversion[deg] (median)	Inclination[deg] (median)
1.57	1.76

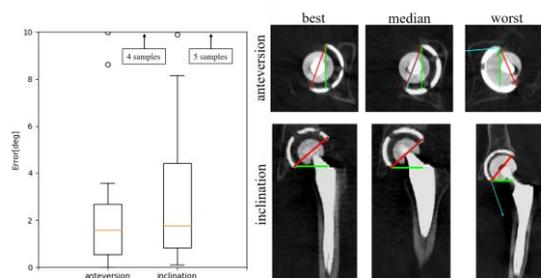


図 3 手動計測と提案手法でのカップ角度の差。
赤線：手動、青線：提案手法による法線ベクトル。

5. 考察

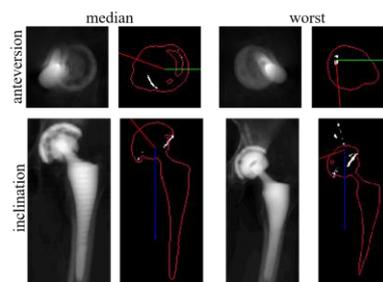


図 4 U-Net でのヒートマップ推定例。

左：DRR 画像，右：閾値処理後のヒートマップ

anteversion, inclination についてそれぞれ手動と手法によるカップ角度の計測誤差が中央値を示した症例と最も大きかった症例での U-Net からのヒートマップの推定結果を図 4 に示す。anteversion について最も誤差が大きい場合はカップの辺縁を正常に認識できないケースであった。U-Net からのヒートマップの予測値が低く閾値処理の際に多くの点が失われたことが原因と考えられる。inclination ではボルトを誤認識したケースで最も誤差が大きかった。カップ辺縁から離れた位置にヒートマップが推定されることで誤った角度が推定された。

6. まとめ

本研究では U-Net によりヒートマップを推定し、主成分分析を用いることでカップの姿勢を推定し、手動計測との結果と比較を行った。ヒートマップの推定が正常に行われないケースが見られたためセグメンテーションと姿勢推

定を同時に行うマルチタスクによる手法や 3D U-Net[5]による推定を行う予定である。

また、今後は提案法を大規模データセットへ適応し、解析を進めていく予定である。

謝辞

本研究の一部は、KAKENHI 19H01176 および KAKENHI 26108004 の支援による。

利益相反の有無

なし

文 献

- [1] Yamada K, Endo H, Tetsunaga T, et al.: Accuracy of cup positioning with the computed tomography-based two-dimensional to three-dimensional matched navigation system: a prospective, randomized controlled study. *J Arthroplasty* 33(1):136–143, 2018
- [2] Tompson J, Jain A, LeCun Y, et al. : Joint training of a convolutional network and a graphical model for human pose estimation. In *Advances in neural information processing systems* (pp. 1799-1807), 2014.
- [3] Murray D. W. The definition and measurement of acetabular orientation. *The Journal of bone and joint surgery. British volume*, 75(2), 228-232. 1993
- [4] Ronneberger O, Fischer P, Brox T, U-net: Convolutional networks for biomedical image segmentation. *MICCAI* 234-241, 2015 Springer, Cham
- [5] Çiçek Ö, Abdulkadir A, Lienkamp S. S., Brox, T., & Ronneberger, O.et al.: 3D U-Net: learning dense volumetric segmentation from sparse annotation. *MICCAI* 424-432, 2016 Springer, Cham. 2016

Automatic implant orientation estimation from CT images after total hip arthroplasty using CNN

Mitsuki SAKAMOTO*¹, Hiroki MAKINO*¹, Yoshito OTAKE*¹, Yuta HIASA*¹
Masaki TAKAO*², Nobuhiko SUGANO*², Yoshinobu SATO*¹

*1 Graduate School of Information Science, Nara Institute of Science and Technology

*2 Graduate School of Medicine, Osaka University

In total hip arthroplasty, the implant orientation properties, such as cup position and angle, play an important role in the evaluation of surgical outcome. Conventionally, estimation has been performed based on postoperative CT images. As metal artifacts caused by the implant degrade the image quality, the automatic estimation is not easy, thus a semi-automatic estimation is usually performed. However, for analysis on a large-scale data set, a fast and automated method to analyze the implant orientation is required. In this study, we propose an automated method to estimate implant orientation such as cup angle from postoperative CT image using Convolutional Neural Network (CNN).

Key words: Convolutional Neural Network, Postoperative CT image, orientation estimation

MR 圧縮センシングにおける ADMM-Net を利用した 深層学習再構成の検討

植松 駿^{*1}, 伊藤 聡志^{*1}

要旨

本研究では, ADMM-Net を利用した MR 圧縮センシングの深層学習再構成について検討を行った. 臨床で多く使用されるカルテシアン座標系を使用し, 必要なステージ数, および学習用 MR 画像とテスト用モデルが同一種の場合と別種の場合の画質評価を行った. 結果, 15 ステージで良好な結果が得られ, また, 同種の画像を学習させるとより高画質の再構成像が得られた. 反復再構成との比較では, ADMM-Net において極めて短い再構成時間で高い PSNR と SSIM の値を得ることができた. ADMM-Net は圧縮センシングの再構成手法として優れた性能を有していることが示された.

キーワード: 圧縮センシング, 交互方向乗数法(ADMM), 深層学習

1. はじめに

核磁気共鳴現象を利用した生体映像法 (Magnetic Resonance Imaging : MRI) による診断画像を医療現場で使用する場合は, 画質は高い方が良いが, そのためには一般的に長時間の撮像が求められるトレードオフの関係がある. 圧縮センシング (Compressed Sensing : CS) [1] を MRI に応用した圧縮センシング MRI (CS-MRI) [2] は, サンプリング定理を満たさない少数の信号から良質な MR 画像を再構成できる方法であり, 信号収集量を減らすことができるため効果的に撮像時間の短縮が可能となる.

一般的に, CS-MRI は MR 信号の推定誤差に L2 ノルムを与え, その条件のもとで L1 ノルム最小化問題を解く [2][3]. CS-MRI において, データの正則化を事前に行うことは画質を改善するための重要な手法であり, さらに圧縮センシングの

理論において, 信号にスパース性を与えることもまた, 再構成像上のアーティファクトを除去するために重要な要素である [3].

CS-MRI の最小化問題を解く方法として, 収束保証を伴う変数分割アルゴリズムである交互方向乗数法 (Alternating Direction Method of Multipliers : ADMM) が提案された [4][5]. L1 ノルム最小化問題の解法として一般的に知られる反復的ソフト閾値法に比べて良質な画像を再生できると報告されている. しかしながら, 再構成の性能と時間に影響を与える最適パラメータを決めるのは必ずしも容易ではない.

一般的に CS-MRI においてスパース化関数や正則化の方法は経験的に選択されることが多いが, MR 画像再構成の精度および再構成時間を考慮すると, 必ずしも最適な選択とは言えない. 最適なスパース化関数や正則化の方法も撮像対象に依存することも想定される.

近年, CS-MRI の再構成に深層学習を利用して行う研究が注目されている. 深層学習を用いた MR 画像の再構成は, 従来の反復的解法よりも高

*1 宇都宮大学 大学院地域創生科学研究科
工農総合科学専攻
情報電気電子システム工学プログラム
〒321-8585 栃木県宇都宮市陽東 7-1-2
e-mail: mc196809@cc.utsunomiya-u.ac.jp

速、かつ高画質である報告が行われており [6][7][8], 圧縮センシングの画像再構成への応用に期待が高まっている。

間引きを行った MR 信号から良質な画像を再構成するための、高速かつ高い精度を有する方法に, ADMM の反復手順を参考にした深層学習再構成である ADMM-Net が提案されている[6]. ADMM-Net は間引いた MR 信号空間を入力とし, 再構成された MR 画像を出力とする CNN で構成されている. ADMM-Net は, 反復再構成をモデルとしているが, 各反復ステップにおける重みやスパース化関数の係数を学習により調整できる柔軟な構造となっている. そのため, 反復再構成に比べて高精度の再構成が期待される. ADMM-Net においてラジアルスキャンの CS-MRI について検討が行われているが, 臨床で最も多く使用されるカルテシアンスキャンについての検討は行われていない. そこで, 本研究では, カルテシアンスキャンによる 2 次元撮像の CS-MRI に ADMM-Net を応用し, ステージ数や再構成像の品質について検討を行った. また, MRI のプロトン密度, T_2 の特徴量に対し学習画像と同種の場合と別種の場合とでの再構成性能を比較し, 学習画像とテスト画像の関係について検討を行った.

2. ADMM-Net

2.1. 交互方向乗数法 (ADMM)

圧縮センシングとは, 信号がスパース性を満たすとき, サンプリング定理を満たさない少数の信号から元の信号を再構成する技術である. この手法を MRI に応用することにより, MR 信号空間の信号の格納を間引くことが可能となり, 撮像時間の短縮化が図れる. x を推定した再構成像, y を MR 信号空間の間引き信号とする. 間引きを行う関数を U , フーリエ変換を F , スパース

性を促す関数を Ψ とするとき, 再構成像は式(1)の最適化問題を解くことで推定される. ここで, λ は正則化パラメータである.

交互方向乗数法(ADMM)は, 二つの関数を含む最適化問題に対して, 新たな変数と制約条件を

$$\operatorname{argmin}_x \left\{ \frac{1}{2} \|UFx - y\|_2^2 + \lambda \|\Psi x\|_1 \right\} \quad (1)$$

加え, 拡張ラグランジュ法を利用する方法である[9]. 式(1)において, ADMM では変数 $z = \{z_1, z_2, \dots, z_L\}$ と制約条件を加えた以下の最適化問題を求める.

$$\operatorname{argmin}_{x,z} \left\{ \frac{1}{2} \|UFx - y\|_2^2 + \sum_{l=1}^L \lambda_l \|z_l\|_1 \right\} \quad (2)$$

$$s. t. \quad z_l = \Psi_l x, \quad \forall l \in \{1, 2, \dots, L\}$$

式(2)に拡張ラグランジュ法を適用する(式(3)).

$$L_{aug}(x, z, h) = \frac{1}{2} \|UFx - y\|_2^2 + \sum_{l=1}^L \{ \lambda_l \|z_l\|_1 + (h_l)^T (\Psi_l x - z_l) + \frac{\mu_l}{2} \|\Psi_l x - z_l\|_2^2 \} \quad (3)$$

ここで, μ_l を罰金項の係数とすると, 新たに導入した変数 z と元の変数 x , およびラグランジュ未定乗数 h を以下のように更新する.

$$\begin{cases} x^{(n)} = \operatorname{argmin}_x L_{aug}(x^{(n-1)}, z^{(n-1)}, h^{(n-1)}) \\ z^{(n)} = \operatorname{argmin}_z L_{aug}(x^{(n)}, z^{(n-1)}, h^{(n-1)}) \\ h^{(n)} = h^{(n-1)} + \mu_l (\Psi_l x^{(n)} - z_l^{(n)}) \end{cases} \quad (4)$$

ここで, n は n 回目の反復を示す. このように変数を分割して最適化を行う方法が ADMM である.

2.2. ADMM-Net の構造

本研究で使用する ADMM-Net[6] は上記に示した ADMM から構成される. ADMM の式(4)から式(5)が導かれる. ここで, η_l は更新係数, $\beta_l = h_l / \mu_l$ としており, $Z^{(n)}$ ではソフト閾値関数 $S_\alpha(\cdot)$ が用いられる.

$$\begin{cases} X^{(n)}: x^{(n)} = F^T \left(U^T U + \sum_{l=1}^L \rho_l F \Psi_l^T \Psi_l F^T \right)^{-1} \\ \quad \left\{ U^T y + \sum_{l=1}^L \rho_l F \Psi_l^T (z_l^{(n-1)} - \beta_l^{(n-1)}) \right\} \quad (5) \\ Z^{(n)}: z_l^{(n)} = S_{\lambda_l / \rho_l} (\Psi_l x^{(n)} + \beta_l^{(n-1)}) \\ M^{(n)}: \beta_l^{(n)} = \beta_l^{(n-1)} + \eta_l (\Psi_l x^{(n)} - z_l^{(n)}) \end{cases}$$

ADMM-Net の構造を図 1 に示す. この図は, ADMM による式(5)の異なる処理に対応する層と, 処理間に対応する矢印で表される. また, ADMM の n 回目の反復は n 番目のステージに対応し, n 番目のステージには, 再構成層($X^{(n)}$), 畳込み層($C^{(n)}$), 非線形変換層($Z^{(n)}$), 乗数更新層($M^{(n)}$)からなる 4 種類の層により構成される. 図 1 の ADMM-Net の全体の流れは, 間引いた MR 信号空間を入力すると, 上記の 4 種類の層からなるステージを N 回繰り返す, 最終的に再構成層($X^{(n+1)}$)により再構成された MR 画像を出力する. 本研究では, 畳込み処理で用いられるフィルタには 3×3 の離散コサイン変換を基本としたもの, パラメータの更新手法は Adam[10]として検証を行う.

3. 画像再構成実験

3.1. 再構成実験に使用した MR 画像

本研究では, 一般に公開と使用が許可されている IXI Dataset [11]に含まれる 256×256 画素の頭部 MR 画像を再構成実験に使用した. IXI Dataset には, Information eXtraction from Images プロジェクトの一環として, ロンドンの 3 つの医療機関から集められた健全な被験者 600 人分の MR 画像が含まれている. 学習に使用する画像は, IXI Dataset のプロトン密度強調像(以下, PDWI), T_2 強調像(以下, T_2 WI)からそれぞれ 200 枚を選別し, テスト画像は学習用画像と重複の無い 25 枚をそれぞれ選別した.

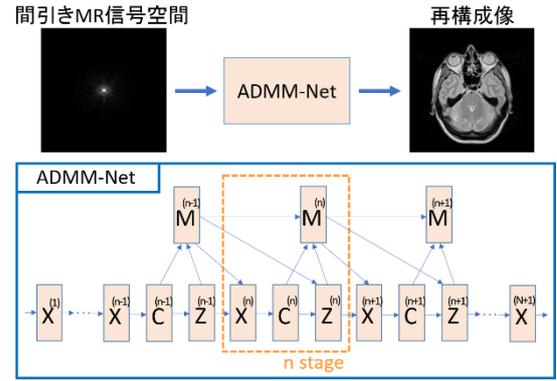


図 1 ADMM-Net の構造

3.2. 学習用データセット

本研究では, IXI Dataset の MR 画像をフーリエ変換することで数値的に合成した MR 信号空間から, カルテシアン座標系を用いて間引き処理を行っている. 図 2 の信号収集パターンは, 中心部に近い領域を重点的に収集した位相エンコード方向ランダム間引き法を適用している. なお, 収集する信号量は 30%である. 学習用画像に対して, 図 2 の信号収集パターンを用いた間引き MR 信号空間と, 全信号による MR 画像との学習データ対を作成し, 学習を行った.

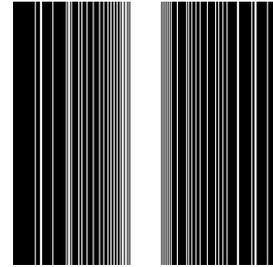


図 2 信号収集パターン

3.3. 画像再構成

本研究で使用した計算機環境を表 1 に示す. テスト用 MR 画像に対し, ADMM-Net と従来法として ADMM を利用した反復的解法である C-SALSA-B[12]を使用し, 再構成性能の比較を行った. ここで, C-SALSA-B のスパース化関数にはウェーブレット変換(Daubechies, $N=3$)を適用している. 再構成実験において, 学習するモデルによ

る再構成性能の依存度を調べるために、以下の2通りの学習モデルを使用した。

1. 200枚のPDWIを学習(モデルP)
2. 200枚の T_2 WIを学習(モデル T_2)

テスト用MR画像であるPDWI, T_2 WIそれぞれにおいて、学習モデルを変更した場合におけるADMM-Netと、C-SALSA-Bにおける性能評価を行った。ここで、学習にはCPUとGPU、テストにはCPUのみを用いた。学習時間は両モデルとも約16日であった。また、評価方法にはピーク信号対雑音比(Peak Signal-to-Noise Ratio : PSNR), および両画像間で対応する局所領域内の輝度値やコントラスト、構造の相似性を評価するSSIM(Structural SIMilarity index)[13]を使用した。

表1 計算機環境

CPU	Intel Core i7-8700 (3.2GHz)
GPU	NVIDIA GeForce GTX1070Ti
RAM	32GB (DDR4-2400)
Software	MATLAB R2017b CUDA Toolkit 9.0 / cuDNN 7.0.5

ADMM-Netにおけるステージ数によるPSNRとSSIMを比較した。それぞれの平均値を図3に示す。なお、モデルPで使用した200枚のPDWIから選別した25枚で学習を行っており、テスト画像は学習画像と重複の無い25枚としている。図3より、ADMM-Netはステージが増加するほど良好な結果を示した。本研究では、十分なステージ数として15を選び、学習画像とテスト画像の関係について検討を行った。

テスト画像をPDWIとして、学習モデルを変更した場合のADMM-Net, およびC-SALSA-Bにより得られた再構成像を定量的, および定性的に比較した。このときのPSNRとSSIMの平均値を表2に示す。ここで、ADMM-Netにおける画像再構成において、モデルP, モデル T_2 により得ら

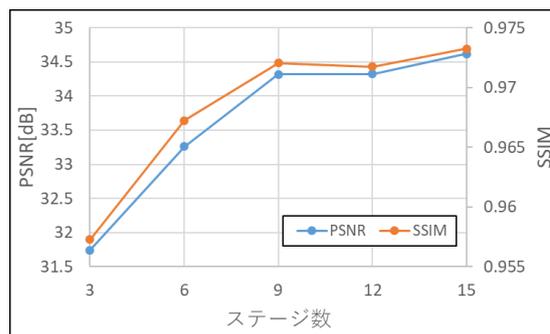


図3 ステージ数ごとのPSNRとSSIM

表2 PDWI再構成像の評価値

再構成法	PSNR[dB]	SSIM
DL_P→P	35.16	0.9757
DL_ T_2 →P	35.12	0.9756
C-SALSA-B	30.93	0.9507

れたPDWI再構成像をそれぞれDL_P→P, DL_ T_2 →Pと称する。表2より、DL_P→PはDL_ T_2 →Pに比べて、PSNR, SSIMの面で高い値を記録していた。また、ADMM-NetはC-SALSA-Bに比べて、どちらの学習モデルの場合でも評価値が高い結果となった。図4にPDWI再構成像の例を示す。なお、拡大画像はコントラストをわかりやすくするための調整を行っている。図4における再構成像の拡大画像より、C-SALSA-Bによる再構成像にはアーティファクトが残留していた。ADMM-Netによる再構成では平滑化の程度が大きい再構成像となったが、C-SALSA-Bよりも目標画像の特徴を有していることが確認できる。ADMM-Netによる再構成像2種の比較において、同種の画像を学習したDL_P→Pが、赤矢印で示す画像中央の黒い部分のコントラストの表現が他の方法に比べて良好である。

次に、テスト画像を T_2 WIとして、学習モデルを変更した場合のADMM-Net, およびC-SALSA-Bにより得られた再構成像を比較した。このときのPSNRとSSIMの平均値を表3に示す。ここで、ADMM-Netにおける画像再構成にお

いて、モデルP、モデル T_2 により得られた T_2 WI再構成像をそれぞれ $DL_P \rightarrow T_2$, $DL_T_2 \rightarrow T_2$ と称する。表 3 より、 $DL_T_2 \rightarrow T_2$ は $DL_P \rightarrow T_2$ に比べて、PSNR, SSIM の面で高い値を記録していた。また、ADMM-Net は C-SALSA-B に比べて、いずれの学習モデルの場合においても高い PSNR と SSIM が得られた。図 5 に T_2 WI 再構成像の例を示す。なお、拡大画像はコントラストをわかりやすくするための調整を行っている。図 5 における再構成像の拡大画像より、テスト画像を PDWI とした場合と同様に C-SALSA-B から得られる再構成像にはアーティファクトが残留した。ADMM-Net による同種と別種の再構成像を比較すると、同種の画像を学習した $DL_T_2 \rightarrow T_2$ において、赤枠部で示す画像中央左上の黒い線が明瞭に描出された。

再構成に要する時間を比較すると、ADMM-Net の再構成時間の平均は約 0.74 秒、C-SALSA-B では約 19.92 秒であり、ADMM-Net の再構成に要する時間は C-SALSA-B の約 1/25 倍と極めて短時間で行うことができた。以上より、ADMM-Net は C-SALSA-B に比べて短い再構成時間で、かつ高い精度の画像を再生できる可能性が示された。また、ADMM-Net において、テスト画像と同種の画像を学習させることがより効果的であることが示唆された。

4. 考察

ADMM-Net において、テスト画像と同種の画像を学習させることがより効果的であったが、それぞれ別種の場合における再構成像の評価値を比較してみると、テスト画像が PDWI の場合では大きな差はなく、 T_2 WI とした場合の方が差が大きかった。このことから、学習画像とテスト画像の関係において、 T_2 WI の方が効果的であると考えられる。また、本研究で使用した IXI Dataset の

表 3 T_2 WI 再構成像の評価値

再構成法	PSNR[dB]	SSIM
$DL_P \rightarrow T_2$	33.40	0.9751
$DL_T_2 \rightarrow T_2$	33.64	0.9759
C-SALSA-B	30.06	0.9566

MR 画像において、モデル P とモデル T_2 で用いられる学習画像は、それぞれランダムに 200 枚選んでいる。しかし、IXI Dataset に含まれる PDWI と T_2 WI には同じ被験者での撮像面のみが異なる MR 画像があり、この撮像面が一致している画像をそれぞれ 200 枚選別して学習を行い、本研究で検証したランダム選択の場合との再構成性能と比較、検討していく必要があると考える。

本研究で、反復的解法として使用した C-SALSA-B は 100 回の反復を行っている。ADMM-Net は 15 ステージとしており、これは反復的解法における 15 回の反復に相当する。そのため、ADMM-Net の方が再構成時間を短縮できたと考える。ADMM-Net の方が反復的解法よりも高い評価結果が得られた点に関して、反復的解法は反復ステップで使用する重み係数の値を経験的に与え、かつ固定して使用している。それに対し、ADMM-Net で用いられる重み係数は、学習によってステージごとに誤差を軽減する方向に更新される。これより、少ないステージ数でもステージごとに適した重み係数を使用しているのが高い精度で画像再構成を行うことができると考える。

5. まとめ

本研究では、ADMM-Net を利用した MR 画像の深層学習再構成について検討を行った。従来法である反復的解法と比較した結果、高い PSNR と SSIM を示したことから、医用画像で重要となるコントラストや構造的な特徴の復元性能が高

く、また学習には時間を要するものの再構成処理は高速であることが示された。また、テスト画像と同種の画像を学習させることが有効であることが示唆された。今後は、新たな学習モデルの組み合わせに関する検証や ADMM-Net のステップ数をさらに増加させた場合における検証を通じて、再構成性能の改善を図る予定である。

謝 辞

本研究の一部は、科学研究費助成金(16K06379, 19K04423)により実施された。また、本研究を遂行する際に利用した IXI Dataset を提供する Information eXtraction from Images プロジェクトに感謝の意を表します。

利益相反の有無

なし

文 献

- [1] D.L.Donoho, "Compressed sensing," IEEE Transactions on Information Theory, vol.52, no.4, pp.1289-1306, 2006
- [2] M.Lustig, D.L.Donoho, J.M.Santos, J.M.Pauly, "Compressed Sensing MRI," IEEE Signal Processing Magazine, vol.25, no.2, pp.72-82, 2008
- [3] M.Lustig, D.Donoho, J.M.Pauly, "Sparse MRI: The application of compressed sensing for rapid MR imaging," Magnetic Resonance in Medicine, vol.58, no.6, pp.1182-1195, 2007
- [4] S.Boyd, N.Parikh, E.Chu, B.Peleato, J.Eckstein, "Distributed Optimization and Statistical Learning via the Alternating Direction Method of Multipliers," Foundation and Trends in Machine Learning, vol.3, no.1, pp.1-122, 2010
- [5] Y.Wang, W.Yin, J.Zeng, "Global Convergence of ADMM in Nonconvex Nonsmooth Optimization," arXiv:1511.06324, 2015
- [6] Y.Yang, J.Sun, H.Li, Z.Xu, "Deep Admm-Net for Compressive Sensing MRI," Advances in Neural Information Processing Systems, pp.10-18, 2016.
- [7] Y.Yang, J.Sun, H.Li, Z.Xu, "ADMM-Net: A Deep Learning Approach for Compressive Sensing MRI," arXiv:1705.06869, 2017
- [8] J.Zhang, B.Ghanem, "ISTA-Net: Interpretable Optimization-Inspired Deep Network for Image Compressive Sensing," arXiv:1706.07929, 2018
- [9] 大関真之, "「今日からできるスパースモデリング」," <http://www-adsys.sys.i.kyoto-u.ac.jp/mohzeki/Presentation/lecturenote20150902.pdf>
- [10] D.P.Kingma, J.Ba, "Adam: A Method for Stochastic Optimization," International Conference on Learning Representations, San Diego, 2015
- [11] IXI Dataset," <https://brain-development.org/ixi-dataset/>
- [12] Y.Liu, J.F.Cai, Z.Zhan et al., "Balanced Sparse Model for Tight Frames in Compressed Sensing Magnetic Resonance Imaging," PLOS ONE, vol.10, no.4, pp.1-19, 2015
- [13] Z.Wang, A.C.Bovik, H.R.Sheikh, E.P.Simoncelli, "Image quality assessment: from error visibility to structural similarity," IEEE Transactions on Image Processing, vol.13, no.4, pp.600-612, 2004

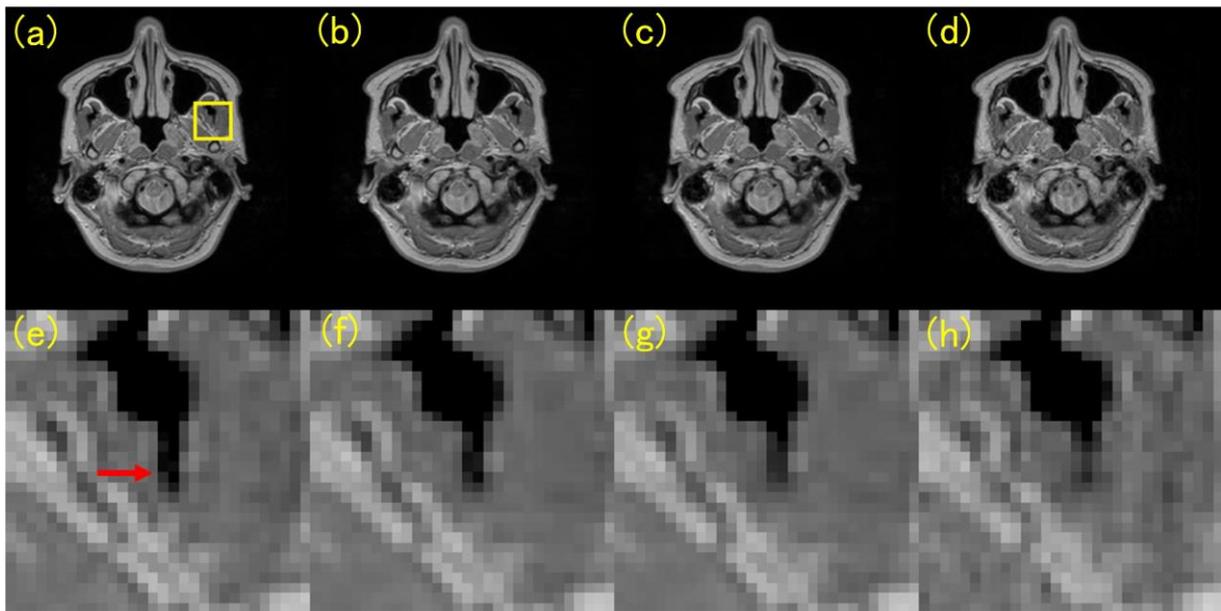


図4 PDWI 再構成像比較 : (a)目標画像, (b)DL_P→P, (c)DL_T₂→P, (d)C-SALSA-B,
(e)~(h) それぞれ(a)~(d)の拡大画像

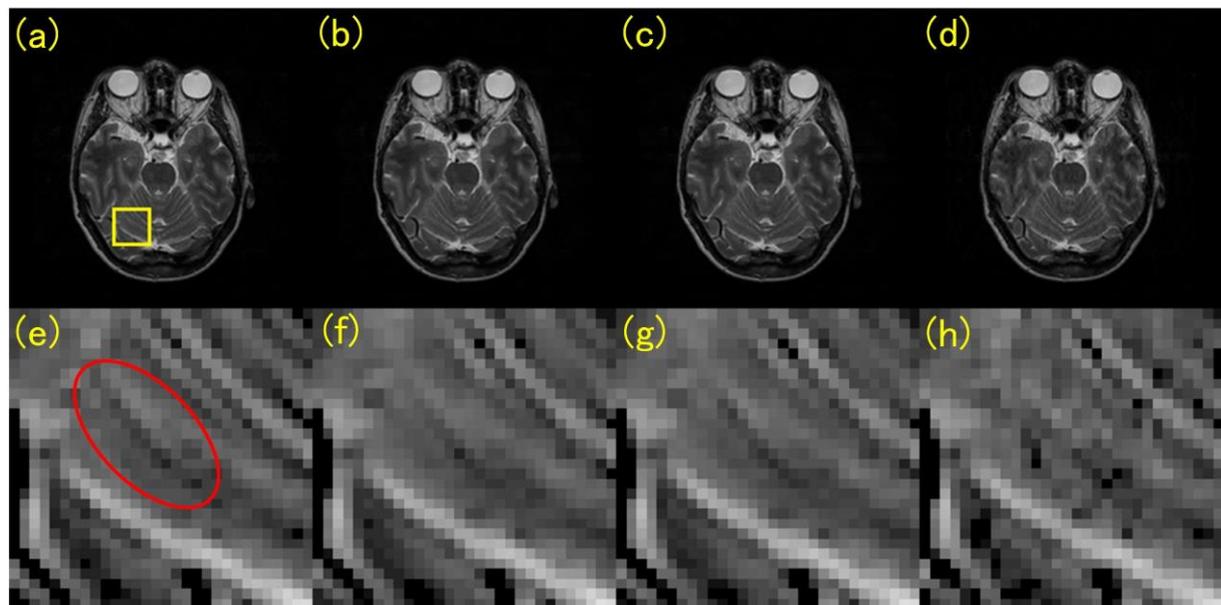


図5 T₂WI 再構成像比較 : (a)目標画像, (b)DL_P→T₂, (c)DL_T₂→T₂, (d)C-SALSA-B,
(e)~(h) それぞれ(a)~(d)の拡大画像

Study on Deep Learning Reconstruction using ADMM-Net in MR Compressed Sensing

Shun UEMATSU*¹, Satoshi ITO*¹

*¹ Graduate School of Regional Development and Creativity, Utsunomiya University

Study on MR image reconstruction using ADMM-Net as convolutional neural network(CNN) was executed. Learning of network was performed using MR PDWI (Proton Density Weighted Images) and T2WI(T2 Weighted Images) independently. Image reconstruction tests were performed for the two situations; one is that test image and training image are the same type and the other is different. Furthermore, CNN based ADMM-Net was compared to iterative reconstruction based on ADMM in the sense of accuracy of reconstructed images and reconstruction time. Simulation studies showed that learning is effective when the type of test image and learning is the same, and ADMM-Net provides higher PSNR and SSIM images in a short time compared to conventional ADMM iterative reconstruction. These results indicate that deep learning reconstruction using ADMM-Net is superior to ADMM iterative reconstruction, and the accuracy of reconstruction depends on the coincidence of image type used in learning and testing.

Key words: Compressed Sensing, ADMM, Deep Learning

Electron-Tracking Compton Camera を用いた異なるエネルギー帯でのリストモード MLEM 画像の画質評価

稲垣 将史*¹ 尾川 浩一*¹ 谷森 達*²

要旨

Electron-tracking Compton camera (ETCC)は機械的なコリメータを使用せず、ガンマ線を観測することが可能であり、空間的に自由な位置にカメラを設置して計測し 3 次元画像を再構成することが可能である。このため、放射線治療装置と組み合わせて治療を行いながら、リアルタイムで治療部位などを観測可能である。本研究では異なるエネルギーの光子を使用したときに、得られる再構成画像の画質を比較する。光子の発生および被検体内での光子輸送計算には Geant コードを用い、発生光子エネルギーは 300 keV, 511 keV, 4438 keV とし、実験系とほぼ同等のジオメトリでデータ収集を行うものとした。ファントムとしては定量性を評価できる数値ファントムを用い、リストモード ML-EM 法を適用し画像再構成を行った。この結果、高エネルギーでの再構成結果の方が低エネルギーでの再構成結果に比べて高画質の結果となり、単純な放射能分布であれば低エネルギーでも再構成可能であることが確認できた。

キーワード：電子飛跡追跡型コンプトンカメラ、モンテカルロシミュレーション、画像再構成、リストモード ML-EM 法

1. はじめに

ETCC では機械的なコリメータを使用せず、ガンマ線を観測することが可能であり、装置自体も小型であるため、空間的に自由な位置にカメラを設置して 3 次元画像を再構成することが可能である。このため、放射線治療装置と組み合わせて治療を行いながら、リアルタイムで治療部位などを観測することが可能である。一方で、どのようなエネルギー帯のガンマ線を利用し画像再構成を行えば所望の画質を得ることができるかは詳しく分かっていない。本研究では異なるエネルギー帯のガンマ線を使用したときに得られる画質を評価する。

2. 方法

ETCC(図 1)では検出器 1 で得た電子の進行方向とエネルギー、コンプトン散乱が発生した座標と検出器 2 で得た光子の検出座標とそのエネルギーを使用することで、検出器に入射する光子の進行方向を算出する[1]。図 1 では ETCC を 2 台設置したシステムのジオメトリを示す。本研究ではガンマ線のエネルギーとして ⁶⁷Ga から発するガンマ線の 300keV, PET で用いる消滅ガンマ線の 511keV, 陽子線治療時にカーボンから発生するガンマ線の 4438keV を想定したシミュレーションを行い、結果を比較した。検出器 1 は 20×20×20 cm³, 3 気圧の CF₄ ガス検出器であり、検出器 2 はピクセルサイズ 0.1×0.1 cm², 200×200 ピクセルの NaI シンチレーション検出器である。ファントムはボクセルサイズ 0.1×0.1×0.1 cm³, 128×128×128 ボクセルから構成され、原点を中心とした半径 1.5cm の球(水媒質)の中に(0.5, 0, 0)を中心とした半径 0.5cm の球が存在するものを使用した。外側の球からは 300,000 個/ボクセル、内側の球から 1,500,000

*1 法政大学大学院 理工学研究科
〔〒184-8584 小金井市梶野町 3-7-2〕
e-mail: masafumi.inagaki.9d@stu.hosei.ac.jp

*2 京都大学大学院 理学研究科

個/ボクセルの光子を発生させた。検出器のエネルギー分解能は 10.2 % @300 keV, 7.8% @511 keV, 2.7 % @4438 keV とし, ガス検出器内で 10 keV 以上電離したときに電子を測定可能とした。

光子輸送シミュレーションには Geant コードを使用し, 実験系とほぼ同様のジオメトリで測定を行った。画像再構成には以下の式(1)で表されるリストモード ML-EM アルゴリズムを使用した[2][3]。

$$\lambda_j^{k+1} = \frac{\lambda_j^k}{\sum_{i=0}^N c_{ij}} \sum_{i=1}^M \frac{c_{ij}}{\sum_{j'=1}^M c_{ij'} \lambda_{j'}^k} \quad (1)$$

ここで λ_j^k は反復回数k回のピクセルjの画素値, c_{ij} はピクセルjから放出された光子が検出器iで検出される確率であり, Nは検出器数, Mはピクセル数である。

吸収補正は行なっていない。評価方法としては再構成画像と原画像の中央のラインプロファイルでの比較と, 半径 0.3cm の球領域 (112 ボクセル) の ROI 内の値で評価を行った。図2に比較する領域を示す。

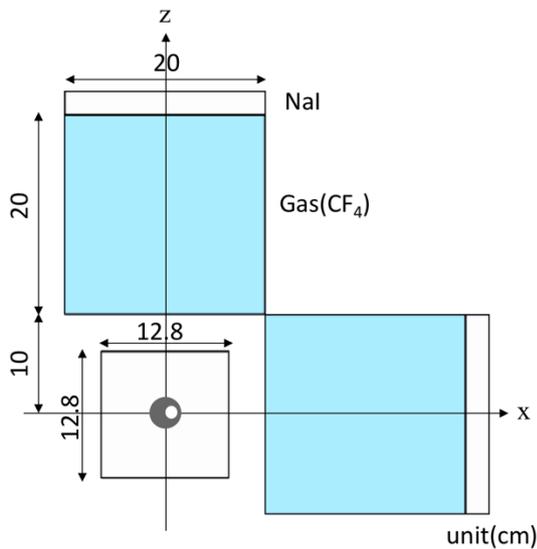


図1 データ収集ジオメトリ

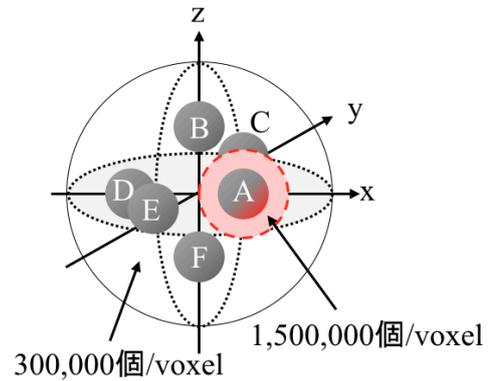


図2 半定量評価で使用する ROI 領域

3. 結果

図3はリストモード ML-EM 法を用いて再構成した x-y 平面の再構成画像である。(a)は光子の発生比率を示した原画像であり, (b)は 300 keV, (c)は 511 keV, (d)は 4438 keV の光子を使用したときの再構成画像である。また, 図4は再構成画像の中央部分のラインプロファイルを比較した図である。さらに, 表1に ROI 内の値を示す。

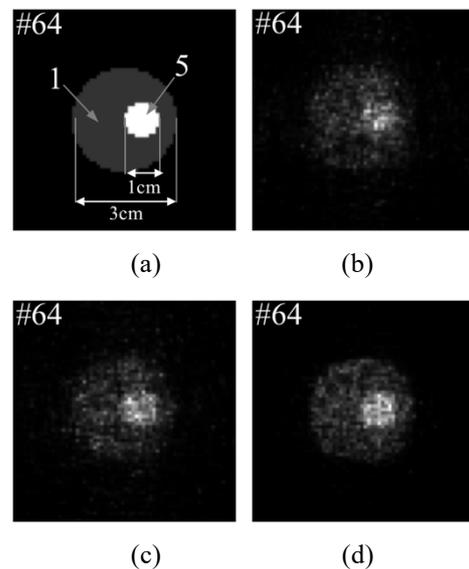


図3 再構成画像

(a)原画像, (b)300 keV, (c)511 keV, (d)4438 keV

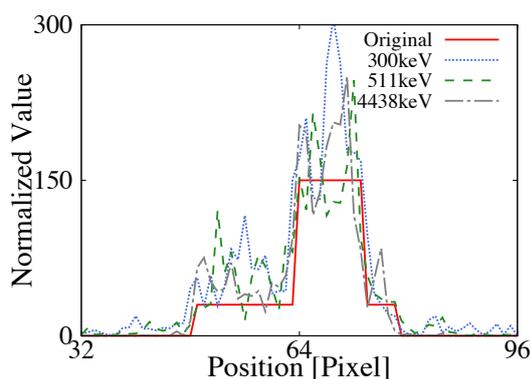


図4 ラインプロファイル画像

表1 B~F の各領域内の平均値を A 領域内の平均値で割った値

	B/A	C/A	D/A	E/A	F/A
300 keV	4.6	3.8	3.1	3.3	3.0
511 keV	4.5	3.8	3.1	3.2	3.5
4438 keV	4.6	4.0	3.7	4.4	4.6
True	5.0	5.0	5.0	5.0	5.0

4. 考察

図3より(b)では外側の球の形は確認することができるが、内側の球が少し崩れた結果になった。(c), (d)では内側の球の形を確認することができた。また、図4のラインプロファイルでも300 keVのときには原画像の値から離れている値が多く、値が安定していないが、511 keV, 4438 keVでは比較的値が安定していた。表1の結果よりROI値の比較をするとエネルギーを大きくすればするほど理論値に近づく結果となった。コンプトン散乱後の電子を検出する際にエネルギーが低い光子を使用したときの方が10keV以上電離するまでに多重散乱が生じるため、光子の進行方向に推定に誤りが生じてしまうことが再構成画像の劣化原因だと考えられる。

5. まとめ

本研究では異なるエネルギーの光子を使用してシミュレーションを行い、画像再構成を行った。単純なファントムであれば低エネルギーの光子を使用しても再構成が可能であるが、高エネルギーの光子を使用した場合の方がより高精度な結果を得ることができることが確認できた。

利益相反の有無

なし

文献

- [1] Tanimori T, Hattori K, Kabuki S, et al.: Advanced Compton camera with the ability in electron tracking based on micro pixel gas detector for medical imaging. IEEE Nucl Sci Sympo Conf Rec, 3380-3874, 2006
- [2] Reader A, Manavaki R, Zhao S, et al.: Accelerated list-mode EM algorithm. IEEE Trans Nucl Sci **49**: 42-49, 2002.
- [3] Kim Y, Lee T, Lee W, et al.: Double-layered CZT Compton imager. IEEE Trans Nucl Sci **64**: 1769-1773, 2017
- [4] Koide A, Kataoka J, Masuda T, et al.: Precision imaging of 4.4MeV gamma rays using a 3-D position sensitive Compton camera. Sci Rep **8**: 2018

Quality of list-mode ML-EM images of different energies acquired with an electron-tracking Compton camera(ETCC)

Masafumi INAGAKI*¹, Koichi OGAWA*¹, Toru TANIMORI*²

*1 Graduate School of Engineering, Hosei University

*2 Graduate School of Science, Kyoto University

An electron-tracking Compton camera(ETCC) is a new modality to acquire gamma rays with two detectors: one is used for detecting the direction of a recoiled electron that is generated at the Compton scattering, and the other is used for detecting the scattered photon. Thus, it is not necessary to use a mechanical collimator that is commonly used in a conventional gamma camera. In addition, we can locate ETCCs at an arbitral position, and so we can use this modality at a clinical situation in a heavy ion radiation therapy. In this study, we evaluated the quality of images acquired with two ETCCs as regard with gamma rays of different energies (300, 511, and 4438 keV). Image reconstruction was performed with a list-mode ML-EM algorithm and the Geant code was used for the transportation of photons and electrons in a simple numerical phantom and ETCCs. We assumed the geometry in reference to the actual ETCC detector developed by Tanimori et al. Simulation results showed that the quality of images was improved when we used high energy gamma rays.

Key words: electron-tracking Compton camera, Monte Carlo simulation, image reconstruction, list-mode ML-EM

コンプトン検出器を組み合わせた 部分リング PET ジオメトリの提案

田島 英朗*¹ 山谷 泰賀*¹

要旨

リングの一部を開放化した部分リング PET は、リングの体軸方向のみならず開放部からも患者にアクセスでき、また、MRI コイル一体型の頭部用 PET インサートとして開放部を下にすれば、患者の頭部に被せるようにセットアップができるなど利便性が向上する。一方で、測定可能な投影データには欠損が生じ、画像に強いアーチファクトが生じてしまうという問題がある。本研究では、開放部と対向する部分の検出器をコンプトン検出器とすることで、欠損方向の情報をコンプトンイメージングの原理を用いて補い、投影データの欠損によるアーチファクトを低減可能な新しい部分リング PET ジオメトリを提案する。計算機シミュレーションとして、システムマトリクスを用いた順投影によって投影データを作成し、MLEM 法によって画像再構成を行った。その結果、通常の部分リング PET で生じてしまうアーチファクトが、コンプトン検出器を組み合わせることによって低減できることが示された。

キーワード：PET、コンプトンイメージング、画像再構成、PET-MRI、ジオメトリ

1. はじめに

PET (Positron Emission Tomography) 装置は一般的に、円筒状に隙間なく検出器を配置することで、原理上完全な画像再構成を行えるように構成されている。一方で、リングの一部を開放化し、部分リング PET とすることで、リングの体軸方向のみならず、開放部分からも患者にアクセスすることができるようになる。また、MRI のボア内で使用する MRI コイル一体型 PET インサート [1,2] を部分リング化すれば、上から被せるようにセットアップすることができ、より利便性が高まることが期待される。しかしながら、測定可能な投影データには欠損が生じ、完全再構成の条件が満たされなくなってしまうため、画像に強いアーチファクトが生じてしまう。部分リング PET のアーチファクトを低減

する方法としては、これまでに Time-of-Flight 情報を用いた方法が検討されているが、非常に高い時間分解能が必要である [3]。一方我々は、散乱検出器と吸収検出器によって構成されるコンプトン検出器を使い、エネルギー情報によってガンマ線を放出した放射性物質の位置を

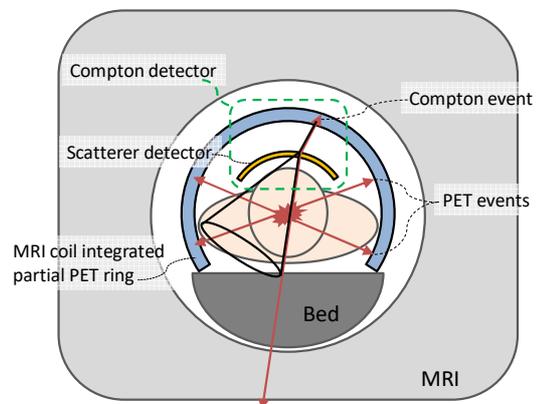


図 1 MRI の PET インサートとして応用した提案ジオメトリの概念図

*1 量子科学技術研究開発機構
放射線医学総合研究所

円錐表面上に限定することが可能なコンプトンイメージングの手法に着目した [4,5] . 本研究では, 開放部と対向する部分をコンプトン検出器とすることで, 欠損方向の情報をコンプトンイメージングの原理を用いて補い, アーチファクトの低減が可能な新しい部分リング PET ジオメトリを提案する.

2. 方法

提案ジオメトリを MRI コイル一体型 PET インサートとして構成した場合, 図 1 に示すように下側を開放部とすることで, 患者の頭に被せるようにセットアップが可能となる. 頭部に集積した PET 薬剤から放出される消滅放射線対は, 横方向では同時計数により測定できるが, 上下方向に放出された場合, 下側の開放空間のため, 同時計数はできず縦方向の投影データが欠損する. そこで, 散乱検出器を上側に配置し, 部分リング PET の検出器の上側をコンプトン検出器の吸収検出器とすることで, 消滅放射線対の片方が検出できるようになり, 縦方向の投影データの情報が取得できるようになり, 横方向の分解能を得ることができるようになる.

1) 計算機シミュレーション

提案ジオメトリの有効性を検証するために, 初期検討として計算機による 2 次元でのイメージングシミュレーションを行った. 図 2 に検出器配置と想定した数値ファントムを示す. 部分リング PET の検出器は, ピクセルサイズ 3mm, 厚さ 20mm とし, 散乱検出器はピクセルサイズ 2mm, 厚さ 5mm とした. ノイズフリーの測定データとして, システムマトリクスを用いた順投影によって投影データを作成した. その際, 検出器素子の大きさの影響を考慮するために, 素子内をサブサンプリングして計算し平均化した. また, コンプトンイベントの順投影では, 散乱検出器のエネルギーウィンドウを 50 keV から 150 keV とし 1 keV ごとにサンプリングし, クライン-仁科の公式より求めた散乱角を半頂角とし, 散乱検出器を頂点とした円錐表面上, エネルギー分解能から換算した分散を持つガ

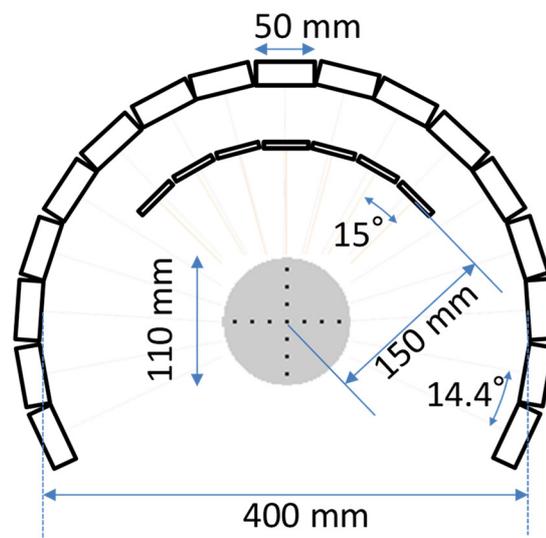


図 2 計算機シミュレーションで模擬した検出器配置と数値ファントム

ウス関数による広がりを持つと想定した応答関数を実装し, 画素値に対する重みとして積算した. 散乱検出器のエネルギー分解能はエネルギーウィンドウ内全体で均一とし, 5%と2%の2種類で検証した.

数値ファントムは直径 110mm のバックグラウンドの円の中にホットスポットがある構造とした. ピクセルサイズは 1.5mm×1.5mm とし, ホットスポットの大きさは 2×2 ピクセル, バックグラウンドに対して, 5 倍の集積があるものとした. なお, 数値ファントム内での減弱や散乱の影響は無視した.

2) 画像再構成

画像再構成は PET の投影データと, コンプトンの投影データを合わせて 1 つのデータセットとして MLEM (Maximum Likelihood Expectation Maximization) 法 [6] を適用することで行った. 本検討では, 画像サイズもシステムマトリクスのモデルも投影データ作成と同じものを用いた. なお, 検出器応答関数の空間的な広がり以外の影響は計算機シミュレーションで考慮していないため, 感度補正, 偶発同時計数補正, 減弱補正, 散乱補正等の補正法は適用していない.

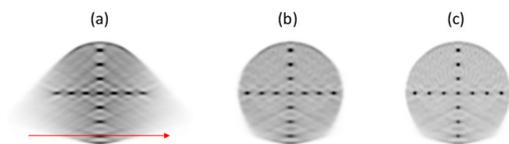


図3 部分リング PET のみ(a), 及び提案ジオメトリでエネルギー分解能を 5% (b)と 2% (c) として得られた再構成画像

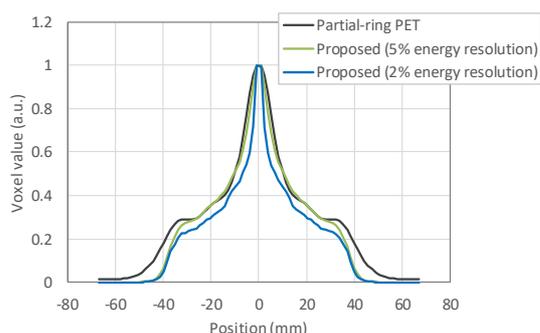


図4 図3中の赤矢印で示す箇所のプロファイル

3. 結果

図3にシミュレーションで得られた投影データを画像再構成した結果を示す. 部分リングPETのみでは画像の左右で斜め下方向への強いアーチファクトが発生していたのに対し, コンプトン検出器を組み合わせることでアーチファクトが低減されている. また, エネルギー分解能を5%から2%へさらに高めることで, 横方向への広がりを抑え, 空間分解能が改善されていることが分かる (図4).

4. まとめ

部分 PET リングにコンプトン検出器を組み合わせることで, 開放部の利便性を享受しつつアーチファクトの少ない画像を得ることが可能な新しいジオメトリの提案を行い, 2次元でのイメージングシミュレーションによって有

効性の検証を行った. その結果, 角度欠損によるアーチファクトを抑制することが可能で, さらにエネルギー分解能が高い散乱検出器が実現されれば, 開放部に近い場所においても空間分解能の劣化も抑制することが可能であることが示唆された.

利益相反の有無

なし.

文献

- [1] Nishikido F, Fujiwara M, Tashima H, et al.: Development of a full-ring “add-on PET” prototype: a head coil with DOI-PET detectors for integrated PET/MRI. Nucl Instr Meth Phys Res A **863**: 55-61, 2017
- [2] Nishikido F, Suga M, Shimizu K, et al.: Second “add-on” PET prototype: a head coil with PET to upgrade existing MRI to PET/MRI. J Nucl Med **57** (supplement 2): 110-110, 2016
- [3] Surti S and Karp J S: Design considerations for a limited-angle, dedicated breast, TOF PET scanner. Phys Med Biol **53**: 2911-2921, 2008
- [4] Phillips GW: Gamma-ray imaging with Compton cameras. Nucl Instr Meth Phys Res B **99**: 674-677, 1995
- [5] Singh M: An electronically collimated gamma camera for single photon emission computed tomography. Part I: Theoretical considerations and design criteria. Med Imag **10**: 421-427, 1983
- [6] Shepp LM, Vardi Y: Maximum likelihood reconstruction for emission tomography. IEEE Trans Med Imag **1**: 113-122, 1982

A proposed partial-ring PET geometry combining with Compton detectors

Hideaki TASHIMA^{*1}, Taiga YAMAYA^{*1}

^{*1} National Institutes for Quantum and Radiological Science and Technology,
National Institute of Radiological Sciences

Partial-ring PET where a part of the ring is open has accessibility to the patient not only from axial direction but also from the open part. In addition, partial-ring MRI-coil integrated brain PET insert will enhance convenience for patient setup by covering the patient head with a downward open part. On the contrary, measurable projection data of the partial-ring PET has limited directions causing strong artifacts in images. In this study, we propose a new partial-ring PET geometry having a Compton detector at opposing side of the open part, which compensate the missing direction information by the principal of the Compton imaging to mitigate the artifact. We conducted a computer simulation, in which we generated projection data by forward projection using a system matrix, and we reconstructed images by the MLEM algorithm. As a result, the artifacts caused in the conventional partial-ring PET could be mitigated by combining the Compton detector.

Key words: PET, Compton imaging, Image reconstruction, PET-MRI, geometry

被写体スキャン方式による X線位相イメージング法の開発

堀場 日明*¹ 佐野 哲*¹ 和田 幸久*¹ 徳田 敏*¹ 池田 凡子*²

衛藤 翔太郎*² 中川 貴之*² 田邊 晃一*¹ 北村 圭司*¹

要旨

Talbot 干渉計をはじめとする X 線位相イメージング法は、従来の X 線の吸収像では検出が困難であった軟組織でも視認性良く描出できることから、リウマチや乳がんなどを早期発見するための有用な手法として医療への応用が期待されている。しかしながら Talbot 干渉計の医療応用にあたっては、被写体の視野範囲が回折格子のサイズによって制限されるという課題がある。そこで、我々は視野サイズを拡大するため、Talbot 干渉計をベースとして被写体をスキャン撮影する光学系を開発した。本光学系は格子なしの吸収像と位相イメージング画像を同時に取得することが可能であり、さらに格子方向に対して被写体を回転させて撮影することで位相像を取得する方法も開発した。この光学系を用いて動物の乳がん検体を撮影し、従来の吸収法では得られなかった腫瘍のコントラストが描出できることを確認した。

キーワード：X 線位相イメージング、スキャン撮影、位相像、乳がん検体

1. はじめに

X 線位相イメージング法は、従来の X 線の吸収像では検出が困難であった軟組織や軽元素の部材でも視認性良く描出できることから、リウマチや乳がんなどの早期発見、また炭素繊維強化樹脂 (CFRP) などの新素材を観察解析するための有用な手法として、医療や非破壊検査への応用が期待されている。従来、X 線位相イメージング法では可干渉性が高くかつ高強度な X 線を照射するため放射光施設を用いることが主流であったが、近年回折格子を使用する

Talbot 干渉計の研究により、医療や産業用の X 線源を使用する実験系での撮影が可能となった[1,2,3,4].

Talbot 干渉計の医療応用にあたっては、被写体の視野範囲が回折格子のサイズによって制限されるという課題がある。そこで、我々は視野サイズを拡大するため、Talbot 干渉計をベースとして被写体をスキャン撮影する光学系を開発した。本光学系はスキャン撮影を行うことで位相イメージング画像の視野サイズを拡大するだけでなく、格子なしの従来の吸収像も同時に撮影することが可能である。さらに格子方向に対して被写体を回転させて撮影し、2 軸方向の解析を行うことで位相像を取得する方法も開発した。本稿では、開発した位相イメージング法の概要と、本手法による動物乳がん検体の撮影結果について報告する。

*1 株式会社島津製作所 基盤技術研究所
〔〒619-0237 相楽郡精華町光台 3-9-4〕
e-mail: a-horiba@shimadzu.co.jp

*2 東京大学大学院 農学生命科学研究科
獣医外科学研究室

2. 被写体スキャン方式の概要

本光学系は、Talbot 干渉計に被写体スキャン機構を加えた構成となっている。以下、光学系概要と画像取得方法について説明する。

1) 光学系概要

本光学系では、管球、回折格子、検出器が縦（Z 軸）方向に配置されている。外観を図 1 に示す。第 1 格子は管球から照射される X 線を可干渉性のある複数の X 線に変え、第 2 格子に照射する。第 2 格子を透過した X 線は、Talbot 効果により第 2 格子と同じ周期パターンを発生させる（自己像）。この自己像と第 3 格子を重ねるように配置することで、モアレが発生する。格子間に被写体を配置すると屈折や散乱によってモアレが変形するので、これを検出することで一般的には解像が難しい小さな自己像の変化を間接的に捉えることができる。

被写体は X 線照射中に X 軸方向に移動させて撮影する（図 2）。これにより、被写体の視野サイズをスキャン方向に拡大することができる。例えば、スキャン撮影を行わない光学系では格子サイズの制約を受け視野は～5cm 幅程度となるが、本光学系では最大 20cm 幅までの撮影が可能である。

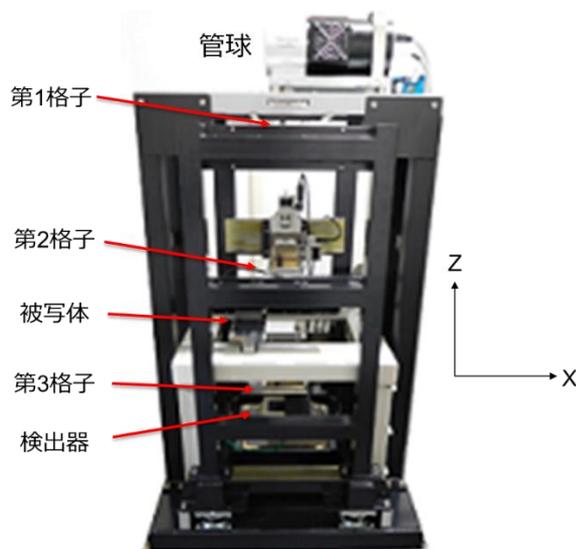


図 1 被写体スキャン方式による X 線位相イメージング法の光学系外観。

また、各格子には格子あり/なし領域を設けており、格子なしの従来の吸収像も同時に撮影することができる（図 2, 3）。

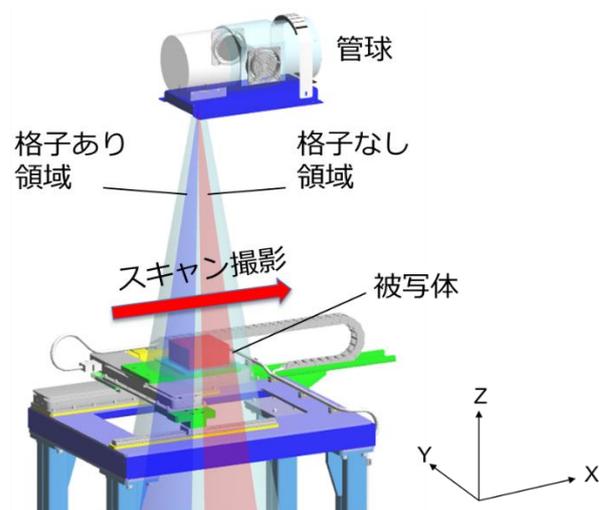


図 2 スキャン方式による格子あり/なし領域の同時撮影（格子、管球保持部省略）。

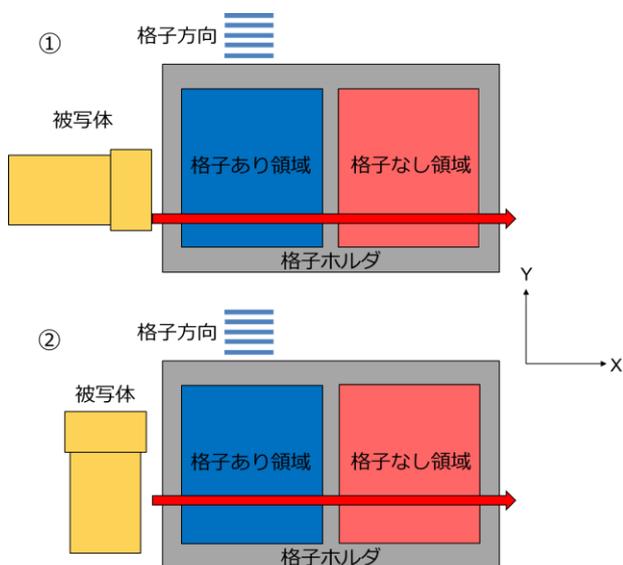


図 3 各格子ホルダ内の配置と被写体スキャン方向。位相像を取得するために被写体を回転させて撮影した。

2) スキャン方式による画像取得方法

本手法では、Talbot 干渉計で主に用いられる縞走査法[1]をベースにし、スキャン撮影に対応した解析方法で画像取得を行っている。

縞走査法では、第2または第3格子を走査して検出器の各画素における強度変化（ステップカーブ）を被写体あり/なしの2種類取得し、それらを解析して吸収像，位相微分像，暗視野像を得るのが一般的である。これを被写体ありの場合で考えると，被写体（固定）に対してモアレ空間を移動させながら撮影しているということになる。

これに対して，スキャン撮影ではモアレ空間（固定）に対して被写体を移動させながら撮影することとなる。いずれも被写体とモアレ空間を相対的に移動させながら撮影を行っており，原理的には同等の画像が得られると考えられる。本手法では，モアレ空間において被写体を一定速度で動かして取得した一連の画像に対して，被写体が静止するように座標変換を行う。これにより，被写体に対してモアレが移動するような画像が得られる。これらの画像から，各画素における強度変化（ステップカーブ）を取得し，縞走査法と同様の解析を行う。

3) 位相像取得方法

本手法は位相像の取得にも対応している。通常，位相像は位相微分像を1軸方向に積分することで取得できるが，1軸のみでは位相微分像のノイズ成分を拾ってストリーク状のアーティファクトが生成されやすい。そこで，2軸方向の位相微分像をフーリエ変換し，周波数領域で所定の演算をしてから逆フーリエ変換する手法を導入した（式1）[5]。

$$\Phi(x, y) = \mathcal{F}^{-1} \left[\frac{\mathcal{F}[\Phi_x + i\Phi_y](k, l)}{2\pi i(k + il)} \right] (x, y) \quad (1)$$

ここで， Φ_x ， Φ_y は被写体(X)方向と(Y)方向の位相微分像， x ， y は実空間上の座標， k ， l は周波数空間上の座標を表す。 $\Phi(x, y)$ が本手法で取得できる位相像となる。2軸方向の成分を合わせて解析することで，アーティファクトを大幅に低減することが可能となる（図4）。この解析を行うため，本手法では図3に示したように格子方向に対して被写体を回転させて2回のスキャン撮影を行う。

なお，格子あり領域に2軸方向の格子を配置

することで，1回のスキャンで位相像取得に必要な画像を得ることも可能である。

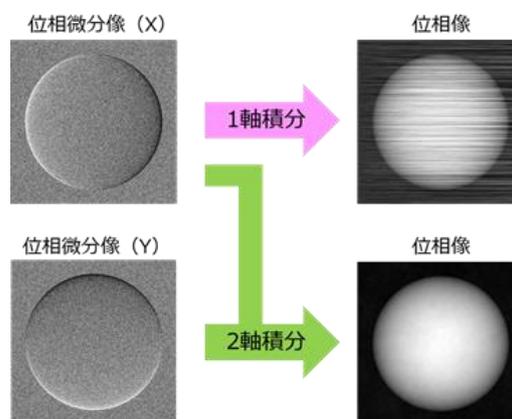


図4 位相像の1軸，2軸積分取得画像の比較（被写体：樹脂球）。

3. 動物乳がん検体の撮影

X線位相イメージングによる乳がん撮影の優位性を検討するため，動物乳がん切除検体の撮影を行った。撮影条件は管電圧40kV（格子なし吸収像のみ30kV），管電流50mA，照射時間8sec，被ばく線量は格子あり/なし領域においてマンモグラフィのガイドラインである3mGy以下とした。また，検体は劣化しないよう切除後生理食塩水に浸漬し，撮影時を除いて冷蔵保存を行った。

撮影結果の一例を図5に示す。この検体は乳腺がん（乳腺混合腫瘍内腺がん）を含むイヌの乳腺組織である。吸収像（格子なし）においては腫瘍にほとんどコントラストがついていないのに対して，位相微分像では腫瘍の境界が描出されていることがわかる。さらに，2軸積分により取得した位相像においてはより明瞭に腫瘍部分を描出することができた。また，石灰化部分は吸収像（格子なし）でも見られるが，暗視野像においてより明瞭に描出されていることがわかる。この石灰化部分は位相像においても視認性良く描出されている。このように，スキャン方式によるX線位相イメージング撮影の優位性を動物乳がん検体において示すことができた。

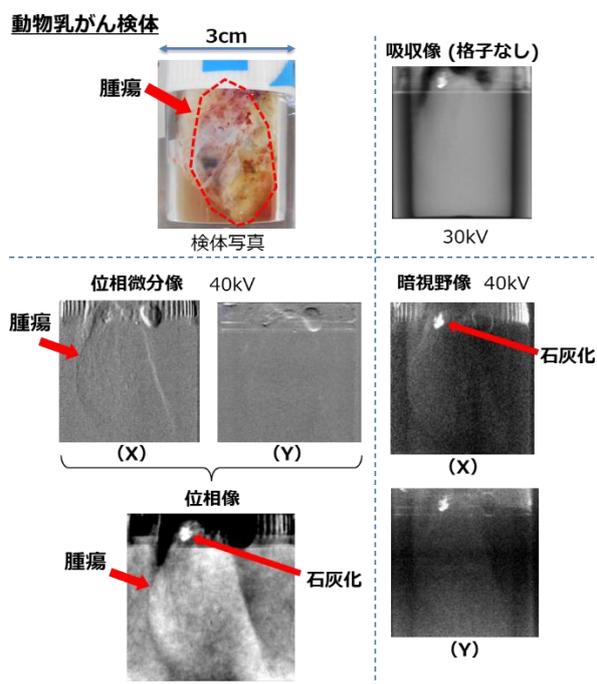


図5 動物乳がん検体の撮影結果. 位相像において腫瘍部分を明瞭に描出することができた. (X), (Y)はそれぞれ図3の被写体方向①, ②に対応する.

4. まとめ

被写体スキャン方式による X 線位相イメージング法を開発した. 被写体の視野サイズ拡大に加え, 格子なし吸収像と 2 軸積分による位相像の取得も可能となった. 本手法で動物乳がん検体を撮影した結果, 位相像において腫瘍と石灰化部分を明瞭に描出することができ, スキャン方式による X 線位相イメージングの優位性が示された. 今後はヒト乳房切除検体の撮影を行い, 同様の検証を進める予定である.

謝辞

研究遂行にあたり多大なるご協力を賜りました昭和大学医学部乳腺外科の明石定子准教授に深く感謝いたします.

利益相反の有無

なし

文献

- [1] Momose A, Kawamoto S, Koyama I, et al.: Demonstration of X-Ray Talbot Interferometry. *Jpn J Appl Phys* **42**: L866-L868, 2003
- [2] Pfeiffer F, Weitkamp T, Bunk O, et al.: Phase retrieval and differential phase-contrast imaging with low-brilliance X-ray sources. *Nat Phys* **2**: 258-261, 2006
- [3] 百生敦: Talbot 効果を利用した X 線位相イメージング. *放射光* **23**: 382-392, 2010
- [4] 土岐貴弘, 白井太郎, 佐野哲他: 産業用 X 線位相イメージング装置の開発. *島津評論* **75**: 73-77, 2018
- [5] Kottler C, David C, Pfeiffer F, et al.: A two-directional approach for grating based differential phase contrast imaging using hard x-rays. *Opt Express* **15**: 1175-1181, 2007

Development of an X-ray phase contrast imaging system using a subject scanning method

Akira HORIBA^{*1}, Satoshi SANO^{*1}, Yukihiisa WADA^{*1}, Satoshi TOKUDA^{*1}, Namiko IKEDA^{*2},
Shotaro ETO^{*2}, Takayuki NAKAGAWA^{*2}, Koichi TANABE^{*1}, Keishi KITAMURA^{*1}

*1 Technology Research Laboratory, Shimadzu Corporation

*2 Laboratory of Veterinary Surgery, Graduate School of Agricultural and Life Sciences, The University of Tokyo

X-ray phase contrast imaging, Talbot interferometer representatively, allows to produce significant contrast of soft tissues that are difficult to detect with conventional X-ray absorption imaging, therefore it is expected to be applied to medical imaging for early detection of lesions such as rheumatism or breast cancer. However, in medical application of Talbot interferometer, there is a problem that the field of view of the subject is limited by the size of the diffraction gratings. In order to expand the field size, we have developed an X-ray phase contrast imaging system using a subject scanning method based on Talbot interferometer. This method also enables to acquire the conventional absorption image without gratings and phase contrast images, i.e., the differential phase contrast image, and the dark-field image simultaneously. In addition, a method of generating the phase image with rotating subject with respect to the grating direction is also developed. Using this system, mammal breast cancer sample images are acquired, and the contrast of the tumors are obtained that are difficult to image by the conventional absorption method.

Key words: X-ray phase contrast imaging, Scanning method, Phase image, Breast cancer sample

学習データセットを必要としない畳み込みニューラルネットワークを用いた Dynamic PET 画像のノイズ除去手法

橋本 二三生*1 大手 希望*1 寺本 篤司*2

要旨

深層学習を医用画像処理に応用する場合、多数の教師ラベル付き臨床データセットを用意する必要がある。しかし、症例数の不足や倫理的な制約等により、大規模で高品質な臨床データセットを構築することは容易ではない。本研究では、学習データセットを必要としない畳み込みニューラルネットワーク (CNN) を用いることで、多数の教師ラベル付き臨床データセットを用意することなく Dynamic PET 画像のノイズを除去する手法を提案する。本手法は、当該の計測 PET データのみを CNN の学習に利用する。まず、教師ラベルとして Dynamic PET 画像を、入力画像として計測データすべてを用いて再構成した Static PET 画像を用意する。これら一対のデータペアを Encoder-decoder 型の CNN を用いて逐次学習させることにより、大幅にノイズが除去された Dynamic PET 画像を取得する。定量評価の結果、本手法を用いることで、従来使用されていたノイズ除去手法と比較し、大幅なノイズ除去性能の向上がみられ、本手法の有効性が示された。

キーワード : Dynamic PET, ノイズ除去, 深層学習, 畳み込みニューラルネットワーク, Deep image prior

1. はじめに

陽電子放射断層撮影 (Positron emission tomography ; PET) 検査は、体内の薬剤動態をダイナミックに計測できる非侵襲的なイメージングモダリティであり、がんのスクリーニングや神経変性疾患の早期発見に有効とされている [1]。ダイナミックな PET データ収集では、時間分解能を高めるほど低カウントに起因する統計ノイズが発生し、Signal-to-noise ratio (SNR) が低下する。そこで、ダイナミック PET 計測における画像の定量性を損なわないように、統計的画像再構成法[2]が導入されているが、

画質改善の効果には限界がある。

畳み込みニューラルネットワーク (Convolutional neural networks ; CNN) に代表される深層学習 (Deep learning) が、近年様々な分野で実用され、医用画像処理においても急速に普及しつつある。一般的に、CNN は大規模な学習データセットを構築し学習を行う必要があるが、臨床現場で学習データセットを収集するためには、倫理的な制約や患者数の確保など、解決すべき課題が多数存在する。例えば、PET 画像のノイズ除去に CNN を応用する場合、高線量または長時間フレームと、低線量または短時間フレームの画像対を用意する必要があり、多大な労力を要する。そのうえ、学習データセットに含まれていない未知の症例や、新規 PET 薬剤に対する処理は定量性が担保できず、堅牢性が高いとはいえない。近年、学習データセットに高品質な正解ラベルを用意する必要のないノイズ除去処理が提案されている[3-5]。特に、

*1 浜松ホトニクス株式会社 中央研究所
〒434-8601 浜松市浜北区平口 5000

e-mail: fumio.hashimoto@crl.hpk.co.jp

*2 藤田医科大学 医療科学部 放射線学科

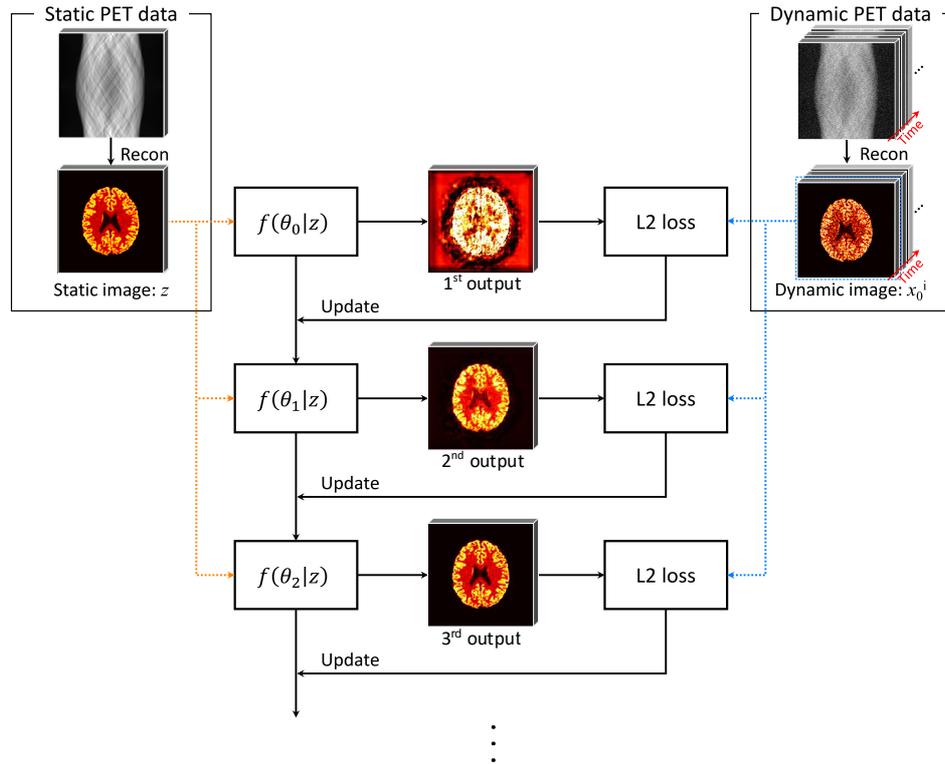


図 1 提案手法の概要.

Deep image prior (DIP) とよばれる手法[3,4]は、ノイズ除去処理対象の画像のみを用意し、CNNを画像フィルタリングのように用いることができる。

そこで本研究では、DIPを応用したDynamic PET画像のノイズ除去手法を提案する。本手法は、高品質な正解ラベルを用意する必要がなく、当該の計測PETデータのみでノイズ除去可能であることが最大の特徴である。

2. 方法

1) 提案手法

提案手法の概要を図1に示す。提案するネットワークは、次式によって学習される。

$$\theta^{i*} = \arg \min_{\theta} \|x_0^i - f(\theta^i|z)\|, x^{i*} = f(\theta^{i*}|z) \quad (1)$$

ここで、 $\|\cdot\|$ はL2ノルム、 f はCNN、 θ はCNNのパラメータを表している。正解ラベル x_0^i ($i=1, 2, \dots, T$)および入力 z はそれぞれ、ノイズ除去処理対象であるDynamic画像、PET計測開始から終了までの全計測データを用いて再構成し

たStatic画像である。本研究では、U-netをベースにしたCNN構造[6]を利用した。

2) 実験

提案手法の画質性能を従来手法と比較するため、 ^{18}F FDGを模擬したシミュレーション実験による評価を行った。シミュレーション詳細については文献[7]を参照されたい。また、定量評価指標として、peak SNR (PSNR) および Structural similarity (SSIM) を使用した。

3. 結果および考察

シミュレーション実験による結果を図2に示す。ここで、図中Frame6, 26はそれぞれPET計測開始から120-160秒、3900-4200秒のフレームに該当する。

図2より、提案手法は他手法と比較し、統計ノイズを抑制しつつコントラストを保存できている。また、本手法を用いることで、他手法と比較しPSNRおよびSSIMが大幅に改善した。これらの結果は、提案手法がDynamic PET画像のノイズ除去に対して有効な手法であること

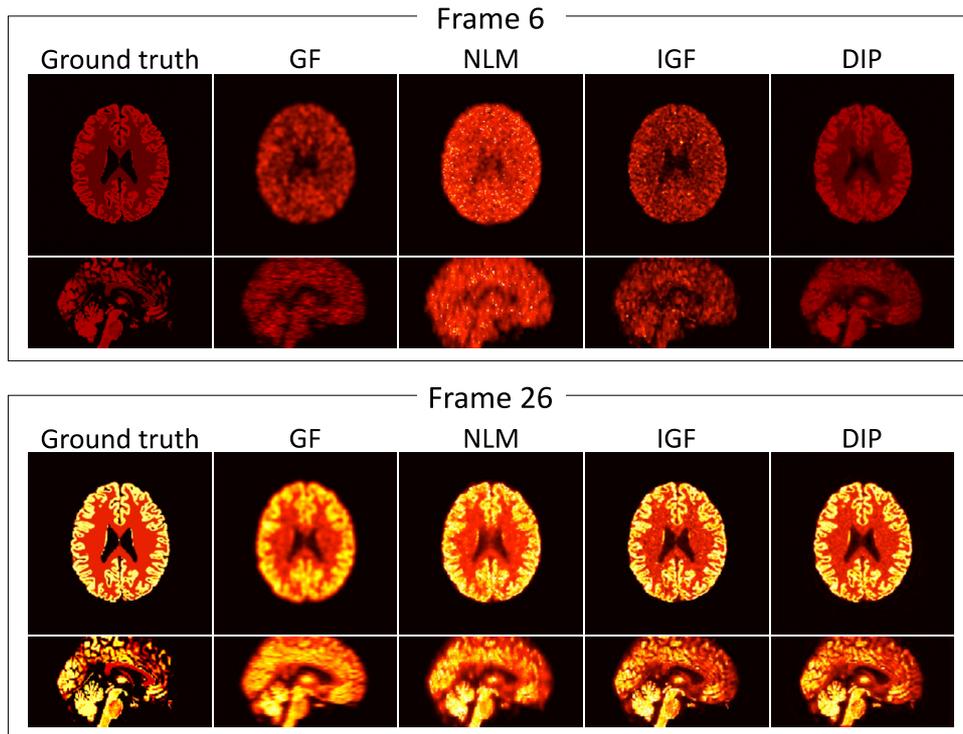


図2 提案手法のシミュレーション処理結果. 左から Ground truth (正解画像), GF (Gaussian filtering), NLM (Non local means filtering), IGF (Image guided filtering), DIP (Deep image prior) の

を示唆している.

4. まとめ

本研究では, DIP を応用した Dynamic PET 画像のノイズ除去手法を提案し, ノイズ抑制効果の向上をシミュレーション実験により評価した. その結果, 提案手法は統計ノイズを抑制しつつコントラストを保存できており, Dynamic PET 画像のノイズ除去に対して有効な手法であることが示唆された.

利益相反の有無

なし.

文献

- [1] Phelps ME: PET: molecular imaging and its biological applications, Springer-Verlag, New York, 2004.
- [2] 小林哲哉: エミッション CT における統計的画像再構成の基礎と展開. Med Imaging Technol **31**: 21-25, 2013.
- [3] Lehtinen J, Munkberg J, Hasselgren J, et al.: Noise2Noise: Learning image restoration without clean data. arXiv: 1803.04189, 2018.
- [4] Gong K, Catana C, Qi J, Li Q: PET image reconstruction using deep image prior. IEEE Trans Med Imaging, 2018. 10.1109/TMI.2018.2888491.
- [5] Ulyanov D, Vedaldi A, Lempitsky V: Deep image prior. Proc IEEE CVPR: 9446–9454, 10.1109/CVPR.2018.00984, 2018.
- [6] Hashimoto F, Kakimoto A, Ota N, et al.: Automated segmentation of 2D low-dose CT images of the psoas-major muscle using deep convolutional neural networks. Radiol Phys Technol, 2019. 10.1007/s12194-019-00512-y.
- [7] Hashimoto F, Ohba H, Ote K, et al: Denoising of Dynamic Sinogram by Image Guided Filtering for Positron Emission Tomography, IEEE trans Radiat Plasma Med Sci **2**: 541-548, 2018.

Noise Reduction Technique for Dynamic PET Images using Convolutional Neural Networks without Training Dataset

Fumio HASHIMOTO*¹, Kibo OTE*¹, Atsushi TERAMOTO*²

*1 Central Research Laboratory, Hamamatsu Photonics K.K.

*2 School of health Sciences, Fujita Health University

Deep neural networks are needed to prepare the large size of training image datasets, however, it is not easy for clinical uses because of difficulty in preparing the large size of high-quality patient datasets. In this study, we proposed dynamic positron emission tomography (PET) image denoising using convolutional neural networks (CNN) without training datasets. The advantage of this study is that training datasets are not necessary, as the original PET data of its own is used to reduce the statistical noise. Static PET data were acquired for input to the network, with the dynamic PET images being handled as training labels, while the denoised dynamic PET images were represented by the network output. The proposed denoising method can improve the denoising performance compared with the other non-deep learning algorithms. These results indicate that the proposed method is a practical algorithm for dynamic PET data.

Key words: Dynamic positron emission tomography, Denoising, Deep learning, Convolutional neural networks, Deep image prior

畳み込みニューラルネットワークを用いた

低線量 CT 画像再構成法の多時相 CT イメージングへの拡張

森 和希^{*1} 工藤 博幸^{*1}

要旨

本論文では,画像再構成法を腹部 CT 撮影 (4 時相) に代表される多時相 CT イメージングに拡張した新手法を提案する.提案手法では,M 時相の画像のうち M-N 枚を通常線量で撮影しそれ以外の N 枚を低線量で撮影することで低被曝での CT 撮影を実現する.そして,M 時相全ての画像を入力とし低線量で撮影した N 枚の画像を出力とする CNN を用いて,雑音を除去した高画質の再構成画像を得る.M 時相全ての画像を CNN の入力とすることにより,CNN は通常線量画像を先験情報として低線量画像の画質を改善するように動作して,1 入力 1 出力の CNN で各時相の画像を独立に処理する単純な手法と比較して,より上手く雑音除去することが可能となることがキーである.腹部 CT 実画像データセットを用いたシミュレーション実験により提案手法の有効性を評価した.

キーワード: 画像再構成, 多時相, 深層学習, 低線量 CT

1. はじめに

CT (Computed Tomography) はエコー検査で検出しにくい深部臓器を見ることができる利点があり,現代の医療に不可欠な装置といえる.しかし,CT による撮像は被ばくによる健康被害が問題とされ,より低線量で撮影を行うことが望ましい.低線量での撮影は光子数のばらつきによりノイズが発生してしまうため,低線量 CT の実現にはノイズ除去技術の向上が不可欠である.

近年,低線量 CT を目的とした深層学習画像再構成法の研究が精力的に行われている.これらの研究では,フィルタ補正逆投影 (FBP) 法で再

構成した劣化画像をコンボリューション層とデコンボリューション層からなる畳み込みニューラルネットワーク (CNN) に入力してノイズを低減した高画質画像を得る画像再構成法を提案している.本研究では,この画像再構成法を腹部 CT 撮影に代表される多時相 CT イメージングに拡張した新手法を提案する.提案手法では,M 時相の画像のうち M-N 枚を通常線量で撮影し,それ以外の N 枚を低線量で撮影することで低被曝での CT 撮影を実現する.そして,M 枚全ての画像を入力し,低線量で撮影した N 時相の画像を出力する CNN を用いて,ノイズを除去した高画質の再構成画像を得る.また,M 時相の画像のうち M-N 枚のみを入力し,それ以外の N 枚の再構成画像を得ることも可能である.

CNN の学習は,74 名の CT 画像から CT イメージング過程をシミュレートしたデータセットを用いて行い,最適なノイズ除去を行う過程

*1 筑波大学システム情報系
[〒305-8573 つくば市天王台 1-1-1]
e-mail: shion06141016@gmail.com

を CNN に学習させた.腹部 CT 実画像データセットを用いたシミュレーション実験により,提案手法の有効性を示す.

2. 方法

2-1 入力と出力

本研究では,複数枚の時相を低線量で撮影,もしくは全く撮影しないという問題設定を考えている.ネットワークへの入力は従来の1入力1出力の手法と異なり,低線量または通常線量で撮影した複数の時相全てを入力する.出力はノイズ除去を行った低線量時相画像または全く撮影しなかった時相の画像である.通常線量画像が先験情報として機能し,従来手法より上手く雑音を除去することを期待している.

2-2 ネットワーク構造

ネットワーク構造は UNet[1]を用いている.UNet は入力データの特徴を抽出するためのエンコーダ部と,特徴マップを拡大するためのデコーダ部から構成される完全畳み込みネットワーク[2]の1つである.

ネットワーク構造を図 1 に示す.エンコーダ部は,まず最初に 3×3 フィルタを用いてストライド 1 及びパディング 1 で畳み込みを行う.その後,CBR 構造を 5 回繰り返す.本稿における CBR 構造とは, 4×4 フィルタを用いたストライド 2,パディング 1 の畳み込み,バッチノーマラ

イゼーション[3],ReLU という手順のことである.

デコーダ部は,まず始めに CBR 構造を 5 回繰り返す.ただし,エンコーダ部で畳み込みを行った部分を逆畳み込みに置き換えている.訓練の際は最初の 2 回にドロップアウトをレート 0.5 で適用した.そして最後に 3×3 フィルタを用いてストライド 1 及びパディング 1 で畳み込みを行う.また,図 1 に示すように,エンコーダ部の第 N 層目($N:1 \sim 5$)をデコーダ部の第 $6-(N-1)$ 層目にスキップ結合している.

2-3 データセット

74 例の腹部 CT 画像(4 時相)を用い,内 58 例を訓練用とし,残りの 16 例を評価用とした.各患者の肝臓が最も大きく見えるスライス 1 枚を用いた.画像サイズは 512×512 であった.用いた時相は早期相,門脈相,遅延相,非造影の 4 種である.

画像は患者の CT 実画像から FBP 法で CT イメージング過程をシミュレートしており,劣化過程はポアソン分布でシミュレートした.また,CNN に入力する際は,画像のコントラストの範囲を 0.165~0.235 に絞った.

2-4 訓練方法

時相をチャンネルとして扱うことで $M-N$ 枚の通常線量画像と N 枚の低線量画像を入力とし,低線量で撮影した N 枚の画像を出力とした.バッチサイズは 4 とした.

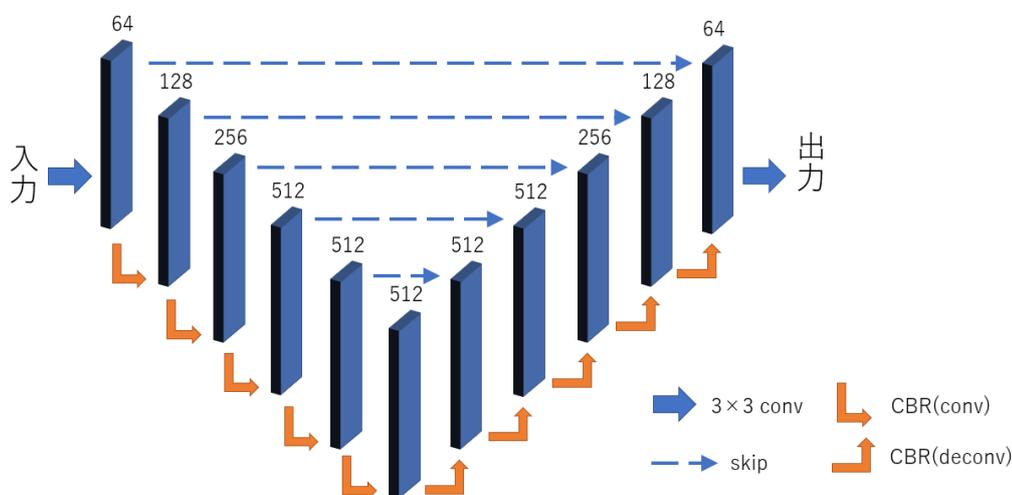


図 1 ネットワーク構造.

各層の数字はチャンネル数.

損失関数には劣化画像と非劣化画像の平均二乗誤差を用い,係数 0.0001 で L2 正則化を適用した.最適化法には Adam[4]を用いて 510epoch 更新した.学習率の初期値は 0.001 で,30epoch ごとに 0.8 倍した.実装には Chainer を用い,GPU(GeForce GTX 1080)を用いて計算した.

2-5 評価方法

劣化画像と非劣化画像のピーク信号対雑音比 (peak signal to noise ratio; PSNR) と構造的類似性 (Structural similarity; SSIM) [5]で評価した.SSIM のウィンドウサイズは 7 とした.

3. 結果

図 2,3 はノイズの強さ (再構成時の光線あたりの光子数) 及び適用手法を変えた際の門脈相における平均 PSNR と SSIM の推移である.光子数 0 は,出力したい時相以外の 3 時相のみを CNN に入力する実装を行った.ノイズが小さい場合(光子数 50000)は提案手法と従来手法の差がほぼ無いが,ある程度ノイズが強くなると提案手法が優位になることがわかる.また,従来手法では光子数 0 で画像を作ることができないため,その場合でも提案手法が優位と言える.本稿では省略するが,他の時相でも類似の結果が得られる.

表 1 は光子が 500 個の場合の,各時相における提案手法の平均 PSNR 及び SSIM とその従来手法との差である.提案手法は非造影画像では SSIM において優位性が見られ,それ以外の時相では PSNR 及び SSIM の両方で優位性が見られた.

図 4 は原画像,ノイズ画像,提案手法の出力,従来手法の出力,ノンローカルミーニフィルタ[6]による門脈相のノイズ除去画像の一例である.従来手法と比べると,図中に赤枠で示した辺りが特に改善されていることがわかる.図 5 は非造影のノイズ除去画像の一例である.門脈相と同様に,従来手法と比べて特に改善されている部分を赤枠で示す.また,光子 0 個の場合と光子 500 個の場合で大きく異なる部分を緑枠で示す.本稿では省略するが,他の時相でも類似の改善が得られる.

表 1 光子 500 個の場合の提案手法の平均 PSNR と SSIM 及び従来手法との差.

	PSNR	PSNR の差	SSIM	SSIM の差
早期相	25.4	1.0	0.82	0.04
門脈相	25.5	1.3	0.82	0.05
遅延相	25.8	1.1	0.82	0.04
非造影	25.7	0.1	0.82	0.02

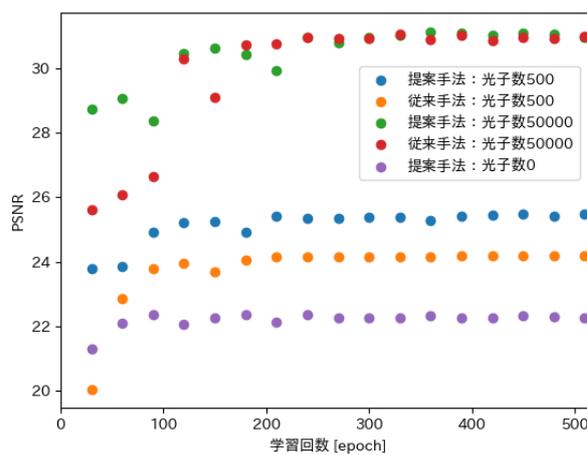


図 2 門脈相の平均 PSNR の推移.

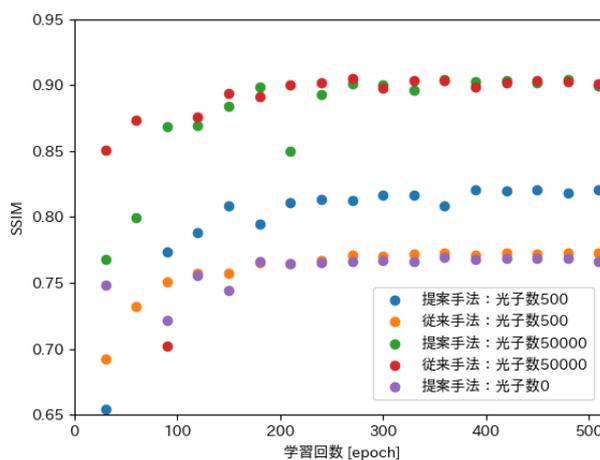


図 3 門脈相の平均 SSIM の推移.

4. 考察

図 2 と図 3 に示すように,ノイズが小さい場合に従来手法と提案手法に大きな差が生じなかった.他の時相から得られる情報を用いるよりも目的の時相から情報を得た方が画質改善に繋がるため,ネットワークが他の時相を無視

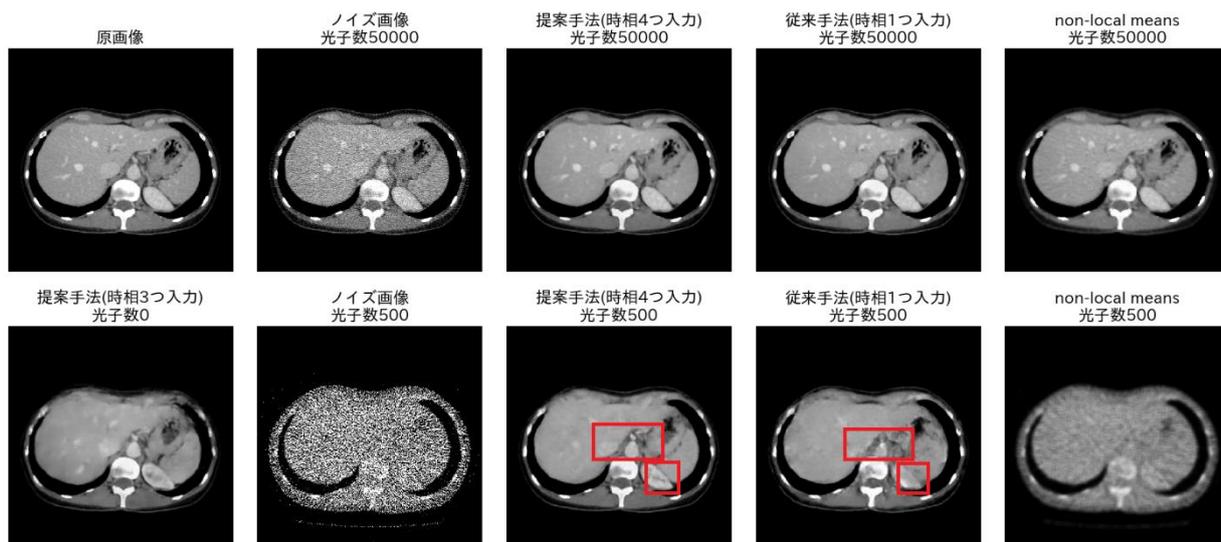


図 4 門脈相の画像.

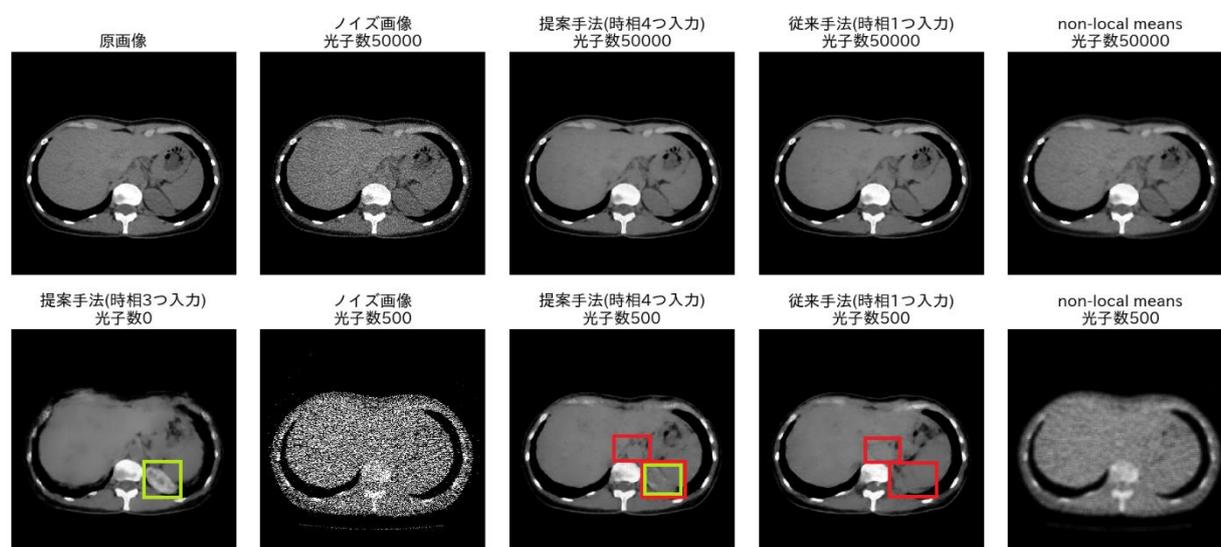


図 5 非造影の画像.

するように学習が行われたためだと考えられる.

表 1 に示すように,数値評価において提案手法が最も有効だったのは門脈相だった.門脈相は最もコントラストが大きいため,ノイズによって失われる情報が相対的に大きく,他の時相から得られる情報が有効に働いたのだと考えられる.反対に,最もコントラストが小さい非造影画像では従来手法との違いが生まれ難かった.ただし,図 5 に示す通り,目視での評価では提

案手法の方が高品質であることがわかった.

図 5 の緑枠で示した箇所のように,目的の時相の情報が皆無(光子数 0)の場合,明るさが原画像から大きく乖離した部分が生じることがある.これは,他の時相の明るさに引きずられていることが原因だと考えられる.図 5 の下段中央のように,目的の時相を入力に加えることで改善されることがわかった.この際,図 5 のように,目的の時相に強いノイズがかかっている問題ないと考えられる.

5. まとめ

本研究では,シミュレーションにより作成した画像を用いて,複数の時相を入力する提案手法と1時相のみを入力する従来手法及びノンローカルミーンフィルタのノイズ除去効果を比較した.さらに,コントラストが高い門脈相において最も効果を発揮することがわかった.

今後,学習させるスライス数を増やすなど訓練データの工夫によって得られる変化の調査や,低線量ではなくスパースビューCTでの調査を行う予定である.

利益相反の有無

無し

文 献

- [1] Ronneberger O, Fischer P, Brox T : U-Net: convolutional networks for biomedical image segmentation. International Conference on MICCAI, 2015
- [2] Long J, Shelhamer E, Darrell T: Fully Convolutional Networks for Semantic segmentation. International Conference on CVPR, 2015
- [3] Ioffe S, Szegedy C: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. International Conference on Machine Learning, 2015
- [4] Kingma D, Ba Jimmy: Adam: A Method for Stochastic Optimization. International Conference on Learning Representations, 2015
- [5] Wang Z et al: Image Quality Assessment: From Error Visibility to Structural Similarity. IEEE TRANSACTIONS ON IMAGE PROCESSING, VOL 13, NO.4, 2004
- [6] Buades A, Coll B, Morel J: A non-local algorithm for image denoising. In Proc IEEE Conf Comp Vis Patt Recogn 2: 60-65, 2005
- [7]

Extension of Low-Dose CT Image Reconstruction Method Using Convolutional Neural Network to Multi-Phase CT Imaging

Kazuki MORI*¹, Hiroyuki KUDO*¹

*1 Graduate School of Information and Systems, University of Tsukuba

In this paper, we propose a new method that extends the image reconstruction method to multi-phase CT imaging represented by abdominal CT imaging (four-time phase). In the proposed method, low-dose CT imaging is implemented by imaging M-N of the M phase images at a normal dose and imaging the other N at a low dose. Then, a high quality reconstructed image from which noises have been removed is obtained using a CNN that has as input an image of all M time phases and outputs N images taken at low dose. By using the images of all M phases as the input of the CNN, the CNN operates to improve the image quality of the low dose image, usually with the dose image as a priori information. The key is that it allows better denoising compared to the simple approach of independently processing each phase image with a 1 input 1 output CNN. The effectiveness of the proposed method was evaluated by simulation experiments using abdominal CT real image data sets.

Key words: Image Reconstruction, Multi-Phase CT, Deep Learning, Low-Dose CT

著者紹介



森 和希 (もり かずき)
2018年広島大学理学部物理科学科卒。
現在、筑波大学院・システム情報・博士前期課程在学中。



工藤 博幸 (くどう ひろゆき)
1985年東北大・工・通信卒。1990年同大学院博士課程了。現在、筑波大・システム情報・教授。1990年電子情報通信学会論文賞、1991年・2001年・2006年・2008年日本医用画像工学会論文賞、2006年・2008年国際雑誌『Inverse Problems』High Lights受賞、2008年国際雑誌『Physics in Medicine and Biology』High Lights受賞、2018年文部科学大臣表彰科学技術賞受賞。工博。CTとPETを中心とした医用イメージング、画像処理の研究に従事。IEEE, SIAM, 各会員。電子情報通信学会フェロー。日本医用画像工学会副会長。

FDTD による Shear wave elastography の不安定要因の検証

伊藤 大貴*¹ 山田 敦子*¹ 大栗 拓真*^{1,3} 吉田 憲司*² 山口 匡*²

要旨

超音波で生体組織の硬さを評価する手法として、音響放射力によって組織内に発生させたせん断波の伝播速度 (shear wave velocity; SWV) を利用する Shear wave elastography (SWE) が臨床で実用化されている。しかし、伝播するせん断波の波形を判定する処理や解析に使用されるアルゴリズムの違いなどの技術的な差異や、生体内の組織構造および物性の複雑性などの要因により、診断装置のメーカー間および設定条件によって SWV の評価結果に差を有することや、計測部位によっては評価結果が不安定になることが示されている。本稿では、SWE の標準化のアプローチのために、弾性 FDTD 法 (Finite-Difference Time-Domain method; FDTD) を用いて、実際の診断装置から送信される音響放射力の分布を模擬した送信条件下において、任意の生体組織性状におけるせん断波の伝播をシミュレートし、各種の信号処理が SWV の評価に与える影響について検証した。結果として、2つの信号処理方法により SWV の算出結果に違いが生じ、その違いは組織構造が複雑になるにつれて顕著になることを確認した。

キーワード：超音波，エラストグラフィ，せん断波，弾性 FDTD，粘弾性

1. はじめに

Shear wave elastography (SWE) は、音響放射力によって組織内に発生させたせん断波の速度 (shear wave velocity; SWV) を利用し、生体組織の硬さを評価する手法である。しかし、診断装置のメーカー間や設定条件によって SWV の評価結果に差を有することや、計測部位によっては評価精度が低下することが示されている [1]。

組織の硬さを表す係数は複数あり、SWE では主に剛性率やヤング率が用いられるが [5]、本稿では、剛性率に着目し組織の硬さの評価を行う。媒質のずり粘性を無視すると、弾性体内を伝播するせん断波速度 c_s は次式で表される。

$$c_s = \sqrt{\frac{G}{\rho}} \quad (1)$$

ここで、 G は剛性率であり、 ρ は密度である [5]。生体組織の密度を 1000 kg/m^3 と仮定すると、式 (1) を用いて、生体組織に振動を与えて発生させたせん断波の速度 c_s から剛性率 G を算出し、生体組織の硬さを評価することができる。しかし、媒質の境界面ではせん断波の反射や屈折が発生するため、生体組織などの不均一な媒質中では伝播するせん断波が複雑になり、SWV の評価結果が不安定なることが示されている [1-3]。そのため、弾性体内の音波伝播の時間変化を計算する弾性 FDTD (Finite-Difference Time-Domain) 法 [4] を用いて、様々な媒質内を伝搬するせん断波を 2 次元 (X-Y) シミュレーションで再現し、その結果を用いて SWV を解析し、そのばらつき要因を検証した。

また、SWV を解析する際には、せん断波の波形 (波頭やピーク) を検出する処理が重要であるが、メーカー毎に処理や解析に使用されるアル

*1 千葉大学大学院融合理工学府基幹工学専攻医工学コース

[〒263-8522 千葉市稲毛区弥生町 1-33]

e-mail; d.ito@chiba-u.jp

*2 千葉大学フロンティア医工学センター

*3 GE Healthcare Japan 株式会社

投稿受付：2019 年 5 月 15 日

ゴリズムが違うことが示されている[1]. 本検討では, せん断波の伝播速度を(i)せん断波形のピークを用いた解析と(ii)相互相関法を用いた解析の2種類の方法で算出し, 信号処理の違いがSWVに差を生じるかについて検討した.

2. せん断波の伝播シミュレーション

2.1. シミュレーション空間の設計

シミュレーション空間内に送信音圧を与えることで, せん断波を励起させた. 与える音場分布は, 臨床装置のプロープからプッシュパルスを送信して発生する音響放射力の音場分布を参考に作成した. 模擬した音場分布を図1に示す. 音場分布の最大音圧を10 MPa, ビーム径を1.25 mm, ビーム長を20 mmと設定した. この音場分布を図2に示すシミュレーション空間の左端に与え, せん断波を生じさせた. 本稿では, Y方向の粒子速度の時間変化から伝播するせん断波を算出する. ここで, Y軸について対称音場分布を与えた場合, 伝播するせん断波もY軸について対称となるため, 計算はシミュレーション空間の全面で行っているが, 以降の評価については上半分(図2内の水色の領域)のみを解析範囲としている.

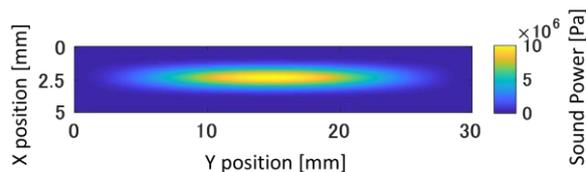


図1 照射超音波(送信音圧)の音場分布

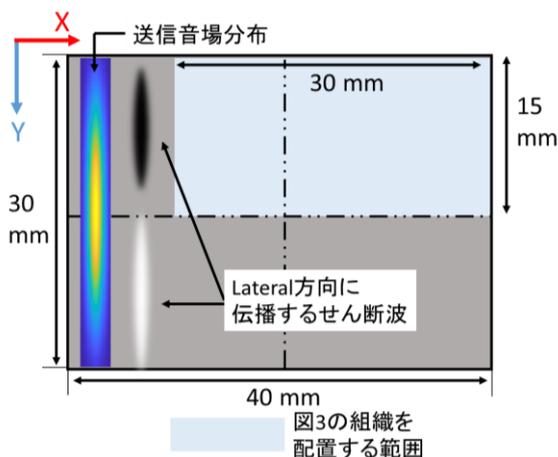


図2 シミュレーション空間の模式図

2.2. シミュレーション条件

グリッドの粗さにより発生する数値分散を防ぐために, せん断波の周波数を数 kHz と仮定し, その波長より十分細くなるようなシミュレーションの条件として, 計算の空間グリッドを100 μm と設定した. それに伴い, クーランの安定条件[4]により時間グリッドを2.375 ns に設定した. また, FDTD シミュレーション空間の端から発生する不要な反射を無くすために, 空間の終端には吸収境界条件として Beneger の PML 吸収境界条件[5]を用いた.

2.3. 生体組織モデル

図2の水色の領域に, 図3に示す複数種の組織モデルを置き, シミュレーションを行った. 図3の(a)は媒質Aのみの均質組織モデル, (b)は媒質Aの均質組織内に半径1.5 mmの円状媒質Bの組織を1つ配置したモデル, (c)は(b)と同じ円状組織Bを複数個, 無作為に配置したモデルである.

周辺組織である媒質Aと円状組織である媒質Bの物性値を表1に示す. 表1の横波音速

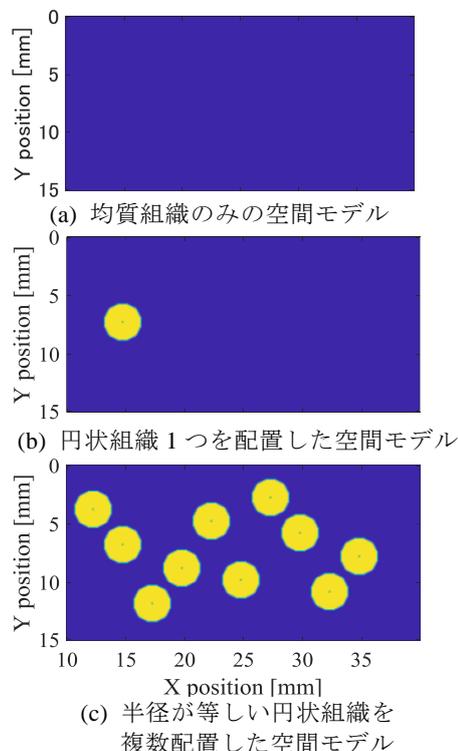


図3 灰色部分に配置する空間モデル

は、表 1 の物性値と式(1)を用いて算出した理論値である。

表 1 各組織のパラメータ

密度		1000	kg/m ³
媒質 A (青色部分)	体積弾性率	2.25	GPa
	剛性率	4	kPa
	横波音速	2	m/s
媒質 B (黄色部分)	体積弾性率	2.25	GPa
	剛性率	16	kPa
	横波音速	4	m/s

3. 伝播するせん断波の様子

図 3 のそれぞれの空間分布に対して送信音圧を与え、発生したせん断波の振幅を一定時間毎に検出し、各位置におけるせん断波の振幅を等高線で結んで表示した結果を図 4 に示す。図中の最左の線(緑色)は加振から 5 ms 後の波形の振幅を示し、それ以降 1 ms 間隔で振幅を等高線で示している。図 4(b) において、円状組織を見ると、円状組織内の速度だけではなく、円状組織周辺の媒質 A の組織の速度が速くなって

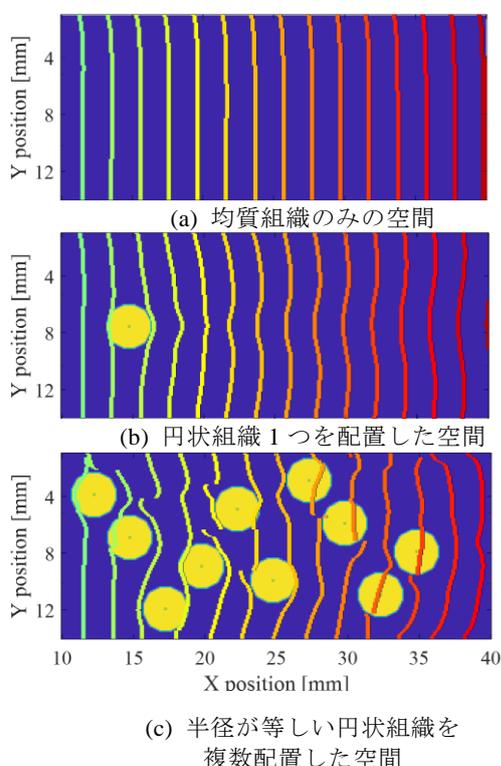


図 4 伝播するせん断波の振幅の等高線表示

いる様子がわかる。同様の傾向は図 4(c)でも確認されるが、剛性率の高い円状組織を複数配置することで等高線の不連続性が強く生じている。このことから、組織構造が複雑であるほどに、せん断波の伝播が複雑となり、SWV の評価も不安定になることがわかる。

4. SWV の解析法

図 3 のそれぞれのモデルについてせん断波の時間変化を算出し、SWV を評価した。SWV の算出には、(i)せん断波形のピークを用いた解析と、(ii)相互相関法を用いた解析の 2 つの信号処理法を適用した。FDTD シミュレーションにおけるせん断波のサンプリング周波数は約 2 MHz であり、SWV はシミュレーション条件から 5 m/s 以下となるため、せん断波が 1 フレームで伝播する距離は 2.5 μm 以下である。これは空間グリッドより十分に小さいため、シミュレーションの時間分解能は担保されている。

(i) せん断波のピークを用いた解析

せん断波形のピーク値を用いて、せん断波の伝播速度を算出した。解析領域内の 1 つの空間グリッドの両端の X 方向の座標 x_1 , x_2 にせん断波のピーク値が通過する時間をそれぞれ t_1 , $t_1 + t_s$ とする。これらのパラメータから、式(2)を用いて 1 つの空間グリッド内の SWV を算出する(図 5)。

$$SWV = \frac{x_2 - x_1}{(t_1 + t_s) - t_1} = \frac{\Delta x}{t_s} \quad (2)$$

ここで、 Δx はシミュレーションの空間グリッドである。この処理を解析領域内の空間グリッド毎に行い、せん断波速度分布を推定した。

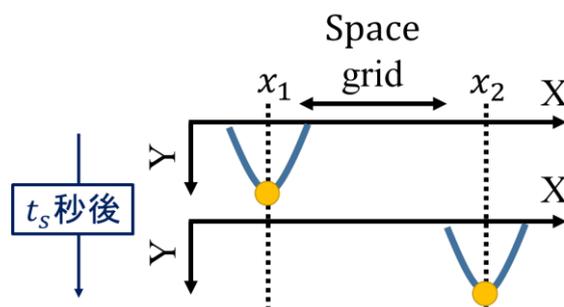


図 5 せん断波のピーク値を用いた SWV 評価方法

(ii) 相互相関法を用いた解析

相互相関法を用いて SWV を解析した。X 方向に連続する 2 点 x_1 および $x_1 + \Delta x$ における Depth 方向の粒子速度をそれぞれ $v_1(t)$, $v_2(t)$ とすると、せん断波がこの 2 点間を伝播する時間 τ は式(3)の相互相関関数 $R(\tau)$ を用いて求めることができる (図 6)。

$$R(\tau) = \int v_1(t)v_2(t + \tau) dt \quad (3)$$

この相互相関関数 $R(\tau)$ が最大となる時間差 τ が伝播時間となるため、2 点間を伝播するせん断波の SWV は次式により算出される[2]。

$$SWV = \frac{\Delta x}{\tau} \quad (4)$$

相互相関法についても、解析法(i)と同様に解析領域全体に対し行うことでせん断波速度分布を推定した。

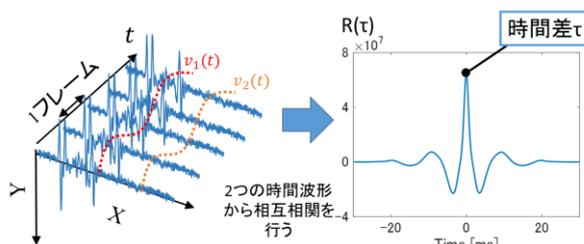


図 6 相互相関法を用いた SWV 評価方法

5. SWV の解析結果

図 3 のそれぞれの空間分布に対して、せん断波速度を算出し、その結果から SWV の 2 次元分布を作成した。図 7 は解析法(i)によりせん断波形のピーク追跡から解析した結果を、図 8 は解析法(ii)により相互相関法による追跡から解析した結果を示す。どちらの解析法においても、図 7(b)および図 8(b)に示す通り円状組織が 1 つ配置されている空間において、媒質 B の付近で SWV が速くなっていることが確認できる。また、媒質 B とせん断波の波面が交わる付近 (図中の黒枠部分) では、媒質の特性が異なることで発生する反射波により、SWV が遅くなった。この傾向は、多数の円状組織が混在しているモデルにおいてより顕著となっており、図 7(c)および図 8(c)のように組織構造が複雑な場合においては、せん断波音速の評価精度が低下し、空間分布として不安定となっていることが確認でき

る。

せん断波速度分布全体を見ると、2 つの異なる信号処理法(i)と(ii)の結果において明確な違いが確認できる。図 7(a)および図 8(a)に示した媒質 A (横波音速の理論値 2 m/s) のみの均質媒質空間において、空間内の SWV の平均値は(i)せん断波形のピークを用いた解析において 2.024 m/s (設定値からの誤差: +1.1 %), (ii)相互相関法を用いた解析において 2.080 m/s (誤差: +3.9 %) である、どちらも理論値との誤差が小さい結果となった。一方で、(ii)の誤差がやや大きいのは、媒質空間の両端付近において窓幅の影響などによる SWV 評価値の段階的変化が生じているためである。

媒質空間中に円状組織が 1 つ配置されているケースである図 7(b)および図 8(b)においては、2 つの信号処理法で大きな差異が生じている。媒質 B (横波音速の理論値が 4 m/s) の領域に着目すると、SWV の平均値は(i)せん断波形のピーク値を用いた解析では 4.116 m/s (誤差: +2.9 %) となり誤差は小さいが、円形組織内の SWV 値の分布としては極端に遅い領域が混在するばらつきが大きい状態となっている。また、(ii)相互相関法を用いた解析においては、円形組織内の SWV の平均値は 2.993 m/s (誤差: -25.8 %) となり、理論値とは大きな乖離を有している。せん断波の伝播状況を動画上で確認したところ、異なる媒質の境界から強い反射が生じることにより、せん断波が干渉を受けて波形の乱れと信号レベルの低下が生じ、今回の SWV 算出法においては評価結果に影響を与えることを確認した。この傾向は、円状組織が多数配置された場合 (図 7(c)および図 8(c)) において、より顕著となっている。

6. まとめ

実際の超音波診断装置の送信音場を模擬した弾性 FDTD 法を用いて、剛性率の異なる 2 種の組織が混在した媒質におけるせん断波の伝播を計算機シミュレーションで再現し、組織構造と信号処理が SWV に与える影響を確認した。微小組織の混在でも SWV は影響を受け、組織

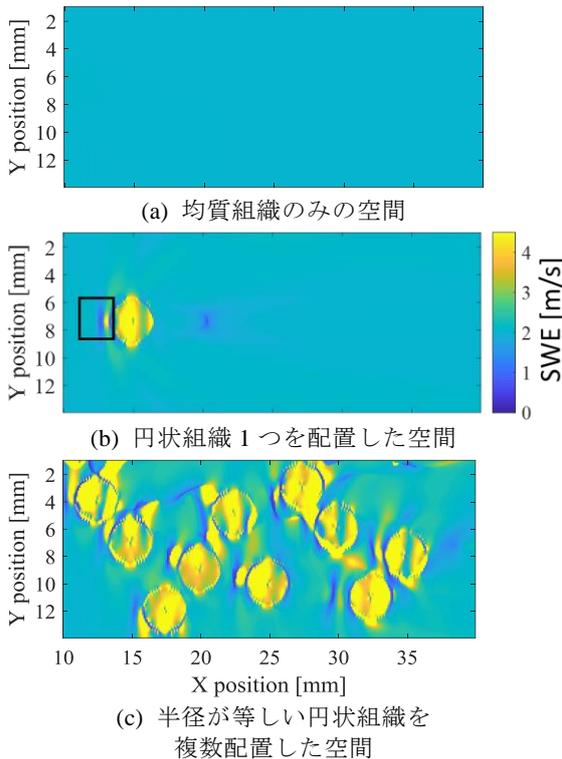


図 7 せん断波のピークを用いた解析におけるせん断波速度分布

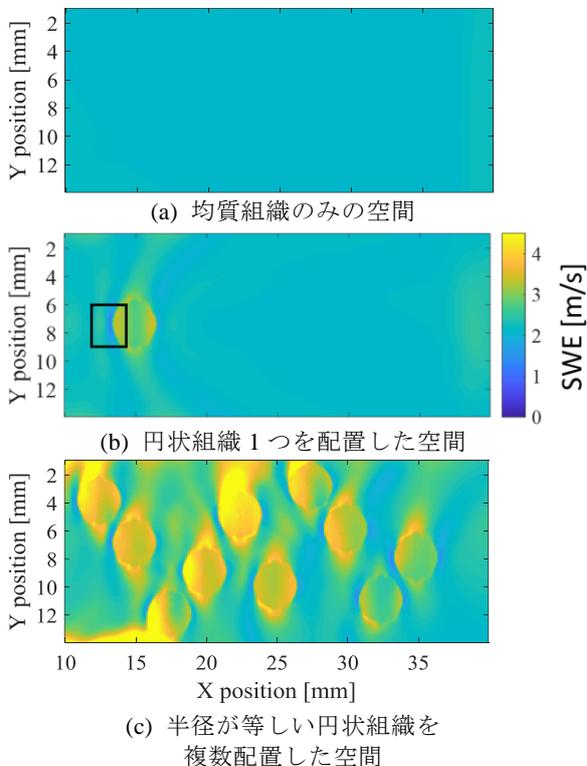


図 8 相互相関法を用いた解析におけるせん断波速度分布

構造の複雑性により影響の程度が変わること、また、その影響はせん断波の毎時の波形を検出する信号処理法によって大きく異なることが確認された。今回の検討では、せん断波は媒質空間上を X 方向に伝播するものであると仮定し、同一箇所の Y 方向変位を用いて SWV を評価しているが、実際には円弧上に伝播しているため、その乖離によって SWV 分布に特異な結果が表れていることも否めない。しかし、せん断波の伝播方向や変位方向をどのように扱うかは臨床用装置でも多様であるため、今後はそれらを考慮した追検討を行い、各種の処理条件によって SWV の評価値にどの程度のばらつきが生じるかについて明確にし、SWV の標準化指標策定に役立てる。

謝辞

本研究の一部は、JSPS Core to Core Program, JSPS KAKENHI Grant Number 15H03030, 17H05280, 19H04482, 千葉大学グローバルプロミネント研究基幹の支援を受けた。

利益相反の有無

開示すべき利益相反状態はない。

文献

- [1] Mark L. Palmeri, et al.: Guidelines for Finite-Element Modeling of Acoustic Radiation Force-Induced Shear Wave Propagation in Tissue-Mimicking Media, IEEE T. Ultrason., 64(1), 78-92, 2017
- [2] 山川誠：せん断波伝播による超音波エラストグラフィの原理, Med. Img. Tech. 32(2), 75-80, 2014
- [3] 山越芳樹：せん断波伝播による組織弾性計測, J. Med. Ultrason., 42(5), 589-597, 2015
- [4] 佐藤雅弘：FDTD 法による弾性振動・波動の解析入門, 森川出版, 2003
- [5] 宇野亨：FDTD 法による電磁界およびアンテナ解析, コロナ社, 1998
- [6] 荒木力：エラストグラフィの徹底解説, 秀潤社, 2011

Verification of instability factors of shear wave elastography by FDTD

Daiki ITO^{*1}, Atsuko YAMADA^{*1}, Takuma OGURI^{*1,3}, Kenji YOSHIDA^{*2}, Tadashi YAMAGUCHI^{*2}

*1 Graduate School of Science and Technology, Chiba University

*2 Center for Frontier Medical Engineering, Chiba University

*3 GE Healthcare Japan Co.,Ltd.

Shear wave elastography (SWE), which utilizes the shear wave velocity (SWV) generated in tissue by acoustic radiation force, has been used in clinical practice as a method for evaluating the stiffness of tissues by ultrasound. However, SWV calculation dramatically depends on the diagnosis equipments because of the difference of the algorithms of pre and post signal processing, and the calculated SWV is also unstable in some observation targets due to the physical properties and the structure of the tissue. In this report, the relationship between the methods of signal processing and the calculated SWV was investigated by means of simulated shear wave propagation in tissue with the elastic Finite-Difference Time-Domain (FDTD) method. Propagation of shear wave in biological tissue was simulated under the transmission condition which mimicked the acoustic radiation force distribution of actual diagnosis equipment. The results show that the calculated SWV differs between the two signal processing, and this difference becomes remarkable as tissue structure becomes complicated.

Key words: ultrasound, elastography, shear wave, elastic FDTD, viscoelasticity

著者紹介



伊藤 大貴 (いとう だいき)

2019年千葉大・工学部・メディカルシステム工学科卒。現在、千葉大学院・融合理工学府・基幹工学専攻・医工学コース在籍中。日本医用画像工学会会員、日本音響学会会員



山田 敦子 (やまだ あつこ)

2018年千葉大・工学部・メディカルシステム工学科卒。現在、千葉大学院・融合理工学府・基幹工学専攻・医工学コース在籍中。日本音響学会会員



大栗 拓真 (おおぐり たくま)

2015年千葉大院・工学研究科・メディカルシステムコース修了。現在、GE Healthcare Japan 超音波製品開発部、千葉大学院・融合理工学府・基幹工学専攻・医工学コース在籍中。汎用超音波診断装置の開発に従事。日本超音波医学会会員。



吉田 憲司 (よしだ けんじ)

2009年同志社大学大学院生命医科学研究科・生命医科学専攻修了。博士(工学)。現在、千葉大・フロンティア医工学センター・助教。医用超音波、特に造影超音波の研究に従事。IEEE、日本音響学会、日本超音波医学会、応用物理学会、各会員。



山口 匡 (やまぐち ただし)

2001年千葉大・自然科学研究科・情報科学専攻修了。博士(工学)。現在、千葉大学フロンティア医工学センター・教授。医用超音波、特に組織性状診断と音響特性評価の研究に従事。IEEE・Senior member、IEICE・Senior member、超音波医学会・理事、音響学会・超音波/アコースティックイメージング委員など。

表現学習と SVM による胃壁マイクロ CT 像の

半教師ありセグメンテーション手法

御手洗 翠^{*1} 小田 紘久^{*1} 杉野 貴明^{*1} 守谷 享泰^{*1}

伊東 隼人^{*1} 小田 昌宏^{*1} 小宮山 琢真^{*2} 森 雅樹^{*3}

高畠 博嗣^{*4} 名取 博^{*5} 森 健策^{*1,6,7}

要旨

本稿では, Spherical K-means (SpK) による表現学習と SVM を用いた胃壁 μ CT 像から粘膜層, 粘膜下層, 筋層及び腫瘍を半教師ありで抽出する手法について報告する. μ CT 画像は μ m オーダーで標本を 3 次元的に観察可能であり, 胃壁 μ CT 像から腫瘍及び層構造を抽出することで腫瘍の立体的構造把握が可能となる. しかし, 豊富なラベルデータを作成するのは容易ではないため, 教師ありの抽出手法を用いるのは難しい. また, 胃壁 μ CT 像はコントラストが低いことから, 教師なしの抽出手法で精度良く抽出することは困難である. そこで本手法では, 対象画像とごく少量のラベルデータを利用する半教師ありの抽出手法により問題の解決, 抽出精度の向上を図った. 本手法は(1) SpK による表現学習, (2) 特徴抽出, (3) SVM を用いたラベルの割り当ての 3 段階から成る. 本手法を胃壁 μ CT 像に適用した結果, 粘膜層, 粘膜下層, 筋層及び腫瘍の抽出の F 値の平均がそれぞれ 59.6%, 41.9%, 70%, 32.3%であった.

キーワード: マイクロ CT, セグメンテーション, 胃壁, 半教師あり学習

1. はじめに

胃癌診断において, 胃壁の顕微鏡画像を用いた診断はその後の治療方針の決定に重要である. 顕微鏡画像では, μ m オーダーで胃壁の微細構造を 2 次元的に確認できる. しかし, 圧挫

などの人工的な変化が加わることがあるので, その診断, 解釈は慎重でなければならない[1]. 胃壁の μ CT 像では, 胃壁の微細構造を非破壊的に 3 次元で確認できるため, 腫瘍の立体的構造把握が可能であると考えられる. しかし, 胃壁のマイクロ CT 像を読影できる医師が少ないため, ラベルデータの作成が容易ではことから, 教師あり学習を用いることが難しい. また, 粘膜層, 粘膜下層, 筋層及び腫瘍の濃度値の差が小さい, パラフィン領域と胃壁領域のコントラストが低いなどの点から教師なし抽出手法を用いて精度良く各組織を抽出することは困難である. そこで, 本研究では Spherical K-means (SpK) による表現学習を用いた教師なし抽出手法[2]とごく少量のラベルデータを利用し, 粘膜層, 粘膜下層, 筋層及び腫瘍を精度良く抽出する半教師あり抽出手法を提案する.

*1 名古屋大学大学院情報学研究科
〔〒464-8601 名古屋市千種区不老町〕
e-mail: mmitarai@mori.m.is.nagoya-u.ac.jp

*2 名古屋大学大学院医学系研究科

*3 札幌厚生病院

*4 札幌南三条病院

*5 恵和会西岡病院

*6 名古屋大学情報基盤センター

*7 国立情報学研究所医療ビッグデータ研究センター

2. 手法

本手法は、入力された胃壁マイクロ CT 像と 1 スライスのアノテーションしたラベルから、胃壁の各組織を抽出する。前処理として異なるスライスの情報を用いたノイズ除去を行う。前処理後の画像からパッチを切り出し、SpK を実行することで、各クラスの重心を算出する。各クラスの重心は特徴抽出フィルタとして利用する[2]。入力画像のクラス番号のラベルが存在する領域からパッチを切り出し、SpK で得られた重心をフィルタとして適用し、特徴抽出を行う。得られた特徴量とパッチを切り出した位置のラベルを SVM の訓練データとして入力する。入力画像の全領域から切り出したパッチにフィルタを適用し、特徴量を抽出する。訓練された SVM に全てのパッチから得られた特徴量をテストデータとして入力し、分類結果をラベルとしてパッチの切り出した位置に割り当てる。

3. 実験と結果

1 人の胃癌患者から抽出した胃壁を固定した 3 つのパラフィンブロックのマイクロ CT 像に本手法を適用した。SpK に用いたパッチサイズ $5 \times 5 \times 5$ voxels, 特徴抽出のパッチサイズ $41 \times 41 \times 13$ voxels, SVM の訓練に用いたパッチ数 1500 で実験を行った。粘膜層, 粘膜下層, 筋層及び腫瘍の抽出結果について F 値で評価を行った。評価値を表 1 に、抽出結果の例を図 1 に示す。

4. 考察

提案する手法ではマイクロ CT 像から濃度値の差異が少ない胃壁の層構造を抽出することが可能であった。しかし、Case2 (表 1) のように癌によって層構造が乱れている胃壁については各組織抽出の精度が低い結果となった。これは粘膜下層が細くなり、濃度値の差が無い粘膜層と筋層が接することで、それぞれの領域から抽出される特徴量が非常に類似し、識別が困難になるためであると考えられる。また、ノイズの影響により組織の境界が曖昧になっている症例に関しても精度が低くなった。

5. むすび

本稿では、SpK による表現学習と SVM を用

いて胃壁マイクロ CT 像から各組織を抽出する手法を提案した。今後は層が乱れている胃壁の抽出精度向上のため、胃壁の層構造をルールとして利用することを検討する。また、ノイズの影響により境界が曖昧になっている症例への対応として境界を強調する処理を追加することで精度の向上を目指す。

謝辞

本研究の一部は堀科学芸術振興財団, JSPS/MEXT 科研費 (26108006, 17K20099, 17H00867), AMED (191k1010036h0001), ならびに JSPS 二国間交流事業によった。

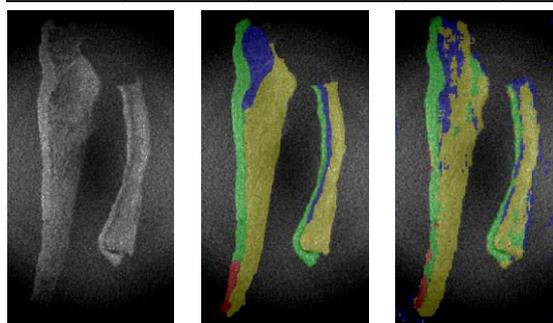
利益相反の有無 なし

文 献

- [1] 日本胃癌学会(編):胃癌治療ガイドライン医師用. 改訂第 3 版, 2010
- [2] Moriya T, Roth HR, Nakamura S, et al.: Unsupervised pathology image segmentation using representation learning with spherical k-means. SPIE Medical Imaging 2018 Digital Pathology **10581**: 1058111, 2018

表 1 提案手法による各組織の F 値

	粘膜層 [%]	粘膜下層 [%]	筋層 [%]	腫瘍 [%]
Case1	69.1	49.7	77.3	40.4
Case2	39.9	21.9	65.0	24.2
Case3	69.8	54.1	67.8	-
平均	59.6	41.9	70.0	32.3



(a) (b) (c)

図 1 胃壁マイクロ CT 像の例。粘膜層は緑色, 粘膜下層が青色, 筋層が黄色, 腫瘍が赤色のラベルである。(a) 入力画像。(b) 正解ラベル。(c) 提案手法による抽出結果。

Semi-supervised Segmentation of Stomach Wall on Micro-CT Volumes using Representation Learning and SVM

Midori MITARAI ^{*1}, Hirohisa ODA ^{*1}, Takaaki SUGINO ^{*1}, Takayasu MORIYA ^{*1},
Hayato ITOH ^{*1}, Masahiro ODA ^{*1}, Takuma KOMIYAMA ^{*2}, Masaki MORI ^{*3},
Hirotugu TAKABATAKE ^{*4}, Hiroshi NATORI ^{*5} and Kensaku MORI ^{*1,6,7}

*1 Graduate School of Informatics, Nagoya University

*2 Nagoya University Graduate School of Medicine

*3 Sapporo-Kosei General Hospital

*4 Sapporo Minami-sanjo Hospital

*5 Keiwakai Nishioka Hospital

*6 Nagoya University Information Technology Center

*7 Research Center for Medical Bigdata, National Institute of Informatics

In this paper, we report a semi-supervised segmentation method of the mucosa layer, submucosa, muscle layer and tumor from stomach wall μ CT volumes using representation learning by Spherical K-means (SpK) and SVM. μ CT scanner enables the 3D visualization in μ m order, and the three-dimensional structure of the tumor can be grasped by segmenting the tumor and layer structure from the stomach wall μ CT volume. However, application of supervised methods for segmenting them is not suitable. Because creating enough labeled data for training is difficult. In addition, it is difficult to segment the mucosa layer, submucosa, muscle layer and tumor with high accuracy by using unsupervised segmentation method because contrast of intensities between tumor and layer structure's is low. Therefore, in this method, we try to solve the problems and improve the segmentation accuracy by employing a semi-supervised segmentation method using a very small amount of label data. This method consists of three steps including (1) representation learning, (2) feature extraction and (3) label assignment. As a result of applying the proposed method to stomach walls in μ CT volumes, the averages of F-values of mucosa layer, submucosa, muscle layer and tumor segmentation results were 59.6%, 41.9%, 70%, and 32.3%, respectively.

Key words: Micro CT, Segmentation, Stomach wall, Semi-supervised learning

MR 画像と病理画像の統合による 膵癌腫瘍の多重解像度モデルの構築

下村 智茂^{*1} マウリシオ クグレ^{*1} 横田 達也^{*1}

岩本 千佳^{*2} 大内田 研宙^{*2} 橋爪 誠^{*2} 本谷 秀堅^{*1}

要旨

本研究では膵癌腫瘍の多重解像度モデルを構築する。膵癌は5年生存率が最悪であり、その機序の解明の為に基礎研究が盛んに成されている。本研究で構築する多重解像度モデルは膵癌腫瘍のMRI画像と対応する顕微鏡病理画像との同時確率分布を表現するモデルである。この為に、低分解能だが非侵襲なMRI画像と、高分解能だが侵襲的にしか取得できない病理画像とを統合する。これによるMRI画像と病理画像との関係解明が本研究の目的である。本研究ではMRI画像と病理画像との位置合わせにより作成されたデータセットを用いる。Generative Adversarial NetworkによりMRI画像の画素とHE染色病理画像の同時確率分布を推定し、MRI画像の1ボクセルから病理画像のパッチ群を推定するシステムを構築したので、その結果を報告する。

キーワード：病理画像、膵癌、KPCマウス、生成モデル、Generative Adversarial Networks

1. はじめに

膵癌は5年生存率が癌の中で最低で基礎研究が盛んに成されており、我々は膵癌の成長や転移などのマクロな機能と細胞レベルのミクロな解剖構造との関係を表す膵癌の多重解像度・経時変化モデルを構築している。このモデルは膵臓の経時MRI画像と摘出した膵臓の顕微鏡病理画像より構築する。MRI画像は非侵襲で膵癌腫瘍の経時変化や体内における腫瘍外形を観察可能となる。ただし空間分解能は $0.1536 \times 0.1536 \times 0.5 \text{mm/voxel}$ で腫瘍内部の構造の観察はできない。一方、顕微鏡病理画像は侵襲的で膵臓を摘出後、薄切し顕微鏡を用いた撮影により取得する。外形の観察は難しいが空分

本研究の目的はMRI画像の各位置と対応する病理画像との同時分布を表す多重解像度モデルの構築である。これはMRI画像からの対応病理画像パターンの予測に有用であり、各ボクセルから病理画像を一意に推定する代わりに、観察される病理画像分布を予測する。図1に示すMRI画像の腫瘍領域と対応付けした病理画像を用いてモデルを構築する。このモデルはボクセルを指定すると確率分布に従い病理画像パッチ群を取得可能である為、MRI画像からの病理画像群の生成モデルでもある。

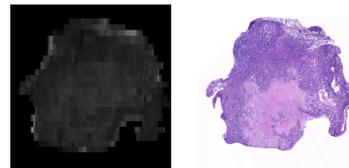


図1 MRI画像(左)と対応付けをした病理画像(右)

*1 名古屋工業大学

*2 九州大学

解能は $1.47 \times 1.47 \times 4 \mu\text{m/voxel}$ と高く各種染色より部位毎に異なるミクロ構造を観察できる。

2. Conditional α -GAN による膵癌腫瘍の多重解像度モデルの構築

本研究では多重解像度モデル構築の為に α -GAN[1]を利用する. 隠れ変数を利用した生成モデルには Variational Auto Encoder(VAE)[2]や Generative Adversarial Network(GAN)[3]があるが, VAE はボケた画像が生成されやすく GAN は mode collapse が生じる. α -GAN では VAE と GAN を組み合わせこれらの欠点に対処する.

α -GAN は真だが未知の分布 $p^*(\mathbf{x})$ に従う観測データ \mathbf{x} を隠れ変数 $\mathbf{z} \sim p(\mathbf{z})$ に写像する $q_{\eta}(\mathbf{z}|\mathbf{x})$ を表す Encoder と隠れ変数よりデータを生成する Generator \mathcal{G}_{θ} , データが $p^*(\mathbf{x})$ に従うか Generator より生成されたかを識別する Discriminator \mathcal{D}_{ϕ} , 隠れ変数が Encoder か $p(\mathbf{z})$ より生成されたかを識別する Code Discriminator \mathcal{C}_{ω} の 4 つのネットワークから成る. また, それぞれパラメータ $\eta, \theta, \phi, \omega$ を持つ. 本研究では条件変数 \mathbf{y} を導入した Conditional α -GAN を利用し, 誤差関数を次のように定義する.

$$\mathcal{L}(\theta, \eta) = \mathbb{E}_{q_{\eta}(\mathbf{z}|\mathbf{x}, \mathbf{y})} \left[-\lambda \|\mathbf{x} - \mathcal{G}_{\theta}(\mathbf{z}|\mathbf{y})\|_1 + \log \frac{\mathcal{D}_{\phi}(\mathcal{G}_{\theta}(\mathbf{z}|\mathbf{y}))}{1 - \mathcal{D}_{\phi}(\mathcal{G}_{\theta}(\mathbf{z}|\mathbf{y}))} + \log \frac{\mathcal{C}_{\omega}(\mathbf{z}|\mathbf{y})}{1 - \mathcal{C}_{\omega}(\mathbf{z}|\mathbf{y})} \right] \quad (1)$$

本研究では膵癌の MRI 画像の各位置から病理画像を推定する生成モデルを作成する. MRI 画像の 1voxel に対し病理画像の 104×104pixel の領域が対応しており, 膵癌腫瘍は中心に近づくにつれて構造が変化する為, 輝度値と各スライスでの腫瘍外縁部からの距離をボクセルから得られる情報として使用する.

3. 実験結果

学習データは約 200 万個のサンプルからなり, この内 8 割を訓練に 2 割をテストに使用した. 訓練時は病理画像に回転, 反転, 32x32pixel のクロップをランダムに行い学習係数 0.0008 の Adam を用いて 10 エポック学習を行った. 隠れ変数は 64 次元で標準正規分布に従うとした.

図 2 に無作為に選択した目標画像と学習したモデルによる復元結果を示す. 擬似画像はボケてはいるが大凡の構造は復元できている. 次に同じボクセル条件の下で画像を並べ分布を視

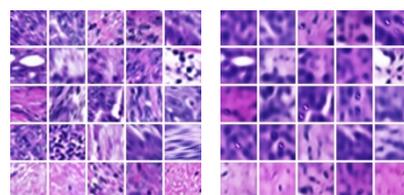


図2 目標病理画像群 (左) とその復元結果 (右)

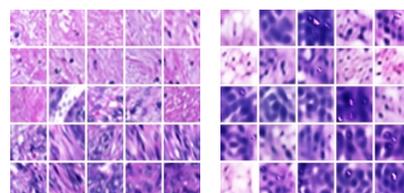


図3 目標病理画像分布 (左) と擬似病理画像分布 (右)

覚的に比較し, 結果を図 3 に示す. どちらの分布でも薄桃色と紫色の病理画像が同量ずつ含まれ, MRI 画像と病理画像の分布は完全ではないが捉えられている. 擬似生成モデルは大まかな特徴を獲得できている為, MRI 画像と病理画像の同時確率分布の記述が可能となった.

4. まとめ

本研究は MRI 画像と病理画像の同時分布を表現する多重解像度モデルの構築を目的とした. この為に MRI 画像のボクセルから病理画像パッチを推定する生成モデルを作成し視覚的な同時分布の確認により評価を行った. 今後は精度向上や定量評価方法の検討が課題となる.

謝辞

本研究は JSPS 科研費 26108003 の助成を受けたものです.

利益相反の有無

なし

文献

[1] M. Rosca, B. Lakshminarayanan, D. Warde-Farley, et al: Variational Approaches for Auto- Encoding Generative Adversarial Networks, arXiv e-prints, p.arXiv:1706.04987, June 2017.

[2] D.P. Kingma and M. Welling: Auto-Encoding Variational Bayes, arXiv e-prints, p.arXiv:1312.6114, Dec. 2013.

[3] I.J. Goodfellow, J. Pouget-Abadie, M. Mirza, et al: Generative Adversarial Networks, arXiv e-prints, p.arXiv:1406.2661, June 2014.

Construction of a Multiscale Model of Pancreatic Tumors by Integration of MR and Pathological Images

Tomoshige SHIMOMURA^{*1}, Mauricio KUGLER^{*1}, Tatsuya YOKOTA^{*1}, Chika IWAMOTO^{*2},
Kenoki OHUCHIDA^{*2}, Makoto HASHIZUME^{*2}, and Hidekata HONTANI^{*1}

*1 Nagoya Institute of Technology

*2 Kyushu University

In this paper, we construct a multiscale model of pancreatic tumors. Pancreatic tumors are the worst five-year survival rate and have been researched to clarify its mechanism. Our multiscale model is a model that represents the joint distribution between MRI images of pancreatic tumors and the corresponding microscopic pathology images. For constructing the model, we integrate low resolution but non-invasive MRI images and pathology images with high resolution but invasively. The purpose of this study is to clarify the relationship between MRI images and pathological images of pancreas tumors by this model. In this study, we use a data set created by alignment of MRI images and pathological images. We construct a system that predicts pathological image patches from 1 voxel of MRI images by estimating the joint distribution of voxel values of MRI images and HE stained pathological images with generative adversarial networks, and report the result.

Key words: Pathology images, Pancreas Tumors, KPC mouse, Generative model, Generative Adversarial Networks

著者紹介



下村 智茂 (しもむら ともしげ)
2017年名古屋工業大学・工学部・情報工学科卒。2017年同大学院博士前期課程・工学研究科・情報工学専攻修了。現在、同大学院博士後期課程・工学研究科・情報工学専攻在籍。2018年電子情報通信学会医用画像処理研究会奨励賞受賞。

機械学習を用いた人工膝関節画像からの機種同定 ～マハラノビス距離による識別効果と CNN の適用～

岸野 万由子*¹ 山崎 隆治*^{1,2} 富田 哲也*³

佐藤 嘉伸*⁴ 菅本 一臣*³

要旨

現在、我々は、1方向 X 線透視画像と人工膝関節 CAD (Computer Aided Design) モデルを用いた 2D/3D レジストレーションに基づく人工膝関節 3 次元運動計測の全自動化に向けていくつかの要素技術の開発を行っている。その一つとして、X 線画像から人工膝関節の種類 (タイプ) を識別、同定することは重要である。そこで本研究では、多種類の人工膝関節のシルエット画像 (シミュレーション画像) を用いて機械学習による識別性能の基礎的な検討を行った。具体的には、マハラノビス距離による識別効果と、畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) による識別性能について検証を行った。結果として、2つの特徴量を用いたマハラノビス距離による識別では、ユークリッド距離による識別に比べ、誤識別が減少、識別性能が向上することが分かった。また、CNN による識別では、さらに識別率が向上し、その効果が確認された。

キーワード：人工膝関節画像、パターン認識、マハラノビス距離、CNN

1. はじめに

術後人工膝関節の 3 次元運動情報を正確かつ定量的に把握することは、最適な人工膝関節の開発や手術手技の評価等を行う上で

非常に重要である。我々はこれまでに、術後人工膝関節の正確な 3 次元運動計測を実現するため、1方向 X 線透視画像と人工膝関節 CAD (Computer Aided Design) モデルを用いた 2D/3D レジストレーション手法を開発してきた[1,2]。現在、その 3 次元運動計測の全自動化に向けていくつかの要素技術の開発を行っており、その一つとして X 線画像から人工膝関節の種類 (タイプ) を識別、同定することは重要である。近年、機械学習・AI (人工知能) 技術を用いて画像中の対象物体を識別・分類する研究が盛んに行われている。そこで本研究では、多種類の人工膝関節のシルエット画像 (シミュレーション画像) を用いて (図 1)、機械学習による識別性能の基礎的な検討を行う。具体的には、学習データのクラス分布を考慮したマハラノビス距離による

*1 埼玉工業大学大学院工学研究科情報システム専攻

[〒369-0293 埼玉県深谷市普濟寺 1690]

e-mail: f9004mxm@sit.ac.jp

*2 埼玉工業大学工学部情報システム学科

e-mail: yamazaki@sit.ac.jp

*3 大阪大学大学院医学系研究科運動器バイオマテリアル学

*4 奈良先端科学技術大学院大学情報科学研究科



Fタイプ Nタイプ Pタイプ Vタイプ
 図1 様々なタイプの人工膝関節シルエット画像（大腿骨コンポーネント）.

識別効果，畳み込みニューラルネットワーク（CNN：Convolutional Neural Network）による識別性能について検証を行ったので報告する．

2. 方法

以下，本研究で使用されるマハラノビス距離，および機械学習法の一つである CNN について述べる．

1) マハラノビス距離

マハラノビス距離とは，学習データのクラス分布を考慮した識別を行う際に有効な距離である．正規分布を用いており広がり大きい分布に対して距離が短くなるので，一般的に用いられるユークリッド距離に比べ，精度の良い結果が得られる．以下にマハラノビス距離の求め方について示す．

マハラノビス距離を求めるには，まず，クラスごとの学習のための入力画像群の分布から平均値と分散・共分散を求める．クラス c に属し， K 次元の $N^{(c)}$ 個の学習用入力画像群を $x_n^{(c)} = (x_{n1}, x_{n2}, \dots, x_{nK})^T, n = 1, \dots, N^{(c)}$ とすると，クラスの平均ベクトル $M^{(c)}$ と分散共分散行列 $S^{(c)}$ は以下の式になる [3].

$$M^{(c)} = (M_1^{(c)}, M_2^{(c)}, \dots, M_K^{(c)})^T \quad (1)$$

ただし， $M_1^{(c)} = \frac{1}{N^{(c)}} \sum_{n=1}^{N^{(c)}} x_{ni}$

$$S^{(c)} = \begin{bmatrix} S_{11}^{(c)} & S_{12}^{(c)} \dots & S_{1K}^{(c)} \\ S_{21}^{(c)} & S_{22}^{(c)} \dots & S_{2K}^{(c)} \\ \vdots & \vdots & \vdots \\ S_{K1}^{(c)} & S_{K2}^{(c)} \dots & S_{KK}^{(c)} \end{bmatrix} \quad (2)$$

ただし，

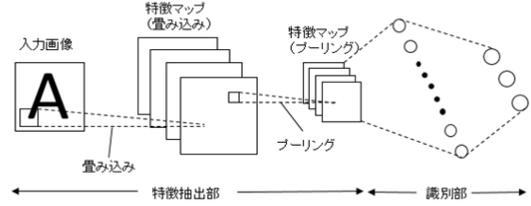


図2 CNN の概要図．

$$S_{ij}^{(c)} = \frac{1}{N^{(c)}} \sum_{n=1}^{N^{(c)}} (x_{ni} - M_i^{(c)})(x_{nj} - M_j^{(c)})$$

式(1)および式(2)より，マハラノビス距離は以下の式になる．

$$d_m^{(c)}(x) = (x - M^{(c)})^T (S^{(c)})^{-1} (x - M^{(c)}) \quad (3)$$

2) CNN

CNN は，通常のニューラルネットワークとは違い，全結合層だけでなく，畳み込み層とプーリング層から構成されるニューラルネットワークである．指定されたフィルタと呼ばれる小領域を畳み込み，特徴量とするため，ニューラルネットワークのように 1 ピクセルに対する特徴量よりも，画像の傾向を知ることができる（図2）．

3. 実験および結果

本実験では，図1に示す4タイプ(F,N,P,V)の人工膝関節のシルエット画像（シミュレーション画像）を生成，使用した．実際の人工膝関節 X 線画像と同様のシルエット画像（姿勢画像）を得るために，X 線撮影空間をコンピュータ内に再現し（図3），人工膝関節 CAD モデルを X 軸および Y 軸回りに $\pm 5^\circ$ および $\pm 10^\circ$ の 2 パターンの範囲について，各範囲で 1° ごとに回転，中心投影描画することにより生成画像を得た．X，Y 軸回りに $\pm 5^\circ$ の範囲で回転させた場合には，各タイプに対して 121 枚の画像を生成，実験には計 484 枚（ 4×121 ）を使用した．また，X，Y 軸回りに $\pm 10^\circ$ の範囲で回転させた場合には，各タイプに対して 441 枚の画像を生成，実験には計 1764 枚（ 4×441 ）を使用した．

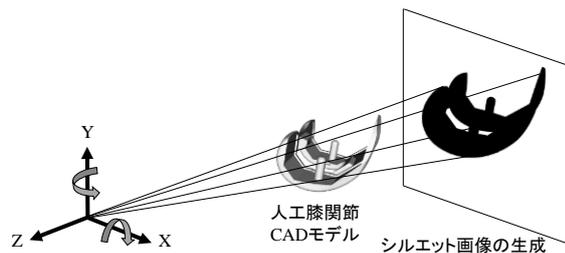


図 3 コンピュータ内に再現した X 線撮影空間と生成画像。

1) マハラノビス距離による識別効果

本実験では、人工膝関節シルエット画像の識別に役立つと予想される特徴量として、“複雑度” および “外接長方形に占めるシルエットの領域比” の 2 つの特徴量を用いた。図 4 および図 5 に $\pm 5^\circ$ 、 $\pm 10^\circ$ の範囲で回転させたときに生成した画像の各タイプにおける特徴量の分布をそれぞれ示す。

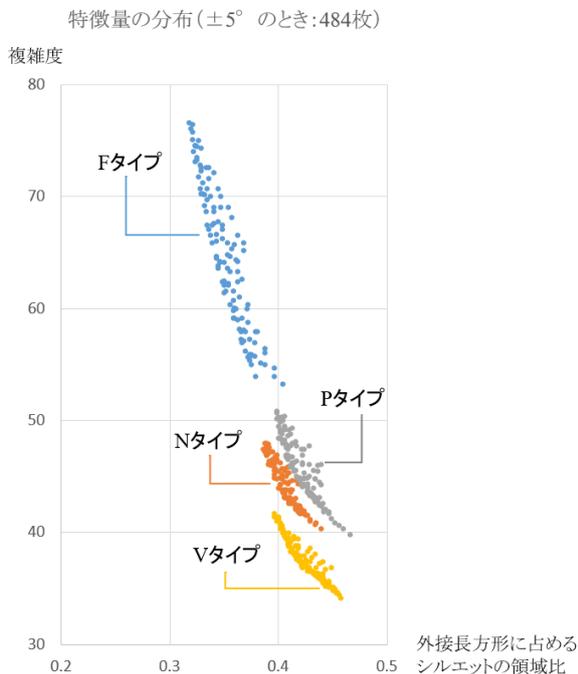


図 4 $\pm 5^\circ$ の範囲で回転させたときに生成した画像の各タイプにおける特徴量の分布。

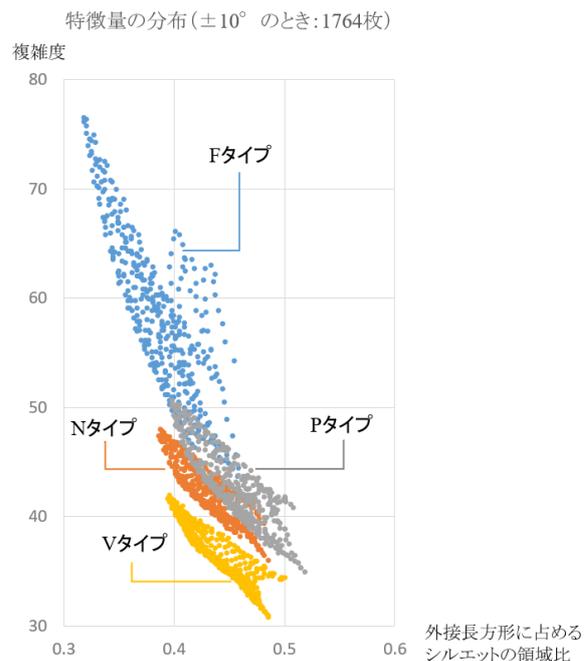


図 5 $\pm 10^\circ$ の範囲で回転させたときに生成した画像の各タイプにおける特徴量の分布。

484 枚 ($\pm 5^\circ$ の範囲で生成) および 1764 枚 ($\pm 10^\circ$ の範囲で生成) の画像に対して、一つ抜き交差検証 (leave-one-out cross validation) を行い、ユークリッド距離およびマハラノビス距離を用いた場合の識別性能、効果を検証した。結果として、マハラノビス距離による識別では、ユークリッド距離に比べて誤識別が減少し ($\pm 5^\circ$ の範囲で回転させたときには N タイプの 7 枚のみ、 $\pm 10^\circ$ の範囲で回転させたときには 4 タイプ合わせて 271 枚が誤識別)、識別性能がそれぞれ 94.4% から 98.6% ($\pm 5^\circ$ の範囲の場合)、71.0% から 84.6% ($\pm 10^\circ$ の範囲の場合) に向上することが分かった (表 1)。

表 1 $\pm 5^\circ$ 、 $\pm 10^\circ$ の回転範囲における生成画像を用いたユークリッドおよびマハラノビス距離による識別性能。

	2つの特徴量 (“複雑度” および “外接長方形に占めるシルエットの領域比”) を用いた識別	各タイプで誤識別された枚数				識別率 (%)
		F	N	P	V	
$\pm 5^\circ$ の回転範囲における生成画像	ユークリッド距離	5	8	6	8	94.4
	マハラノビス距離	0	7	0	0	98.6
$\pm 10^\circ$ の回転範囲における生成画像	ユークリッド距離	73	146	208	84	71.0
	マハラノビス距離	31	96	131	13	84.6

2) CNN による識別性能

前述の実験結果をもとに、本実験では、2つの特徴量に基づくマハラノビス距離を用いて誤識別された画像（ $\pm 5^\circ$ の範囲で回転させたときには7枚、 $\pm 10^\circ$ の範囲で回転させたときには271枚）に対してCNNによる識別が可能かどうか調査した。ネットワークとしては、畳み込み層からプーリング層の階層数を1とした単純なネットワークを構築、使用した（フィルタサイズは 5×5 、フィルタ数は2を適用）。

表2に結果を示す。上段2つが、それぞれ $\pm 5^\circ$ および $\pm 10^\circ$ の回転範囲における生成画像を用いた場合の一つ抜き交差検証の結果を示し、表1のマハラノビス距離を用いて誤識別された全ての画像に対して識別が成功することが分かった。また、下段2つは、参考として、 $\pm 10^\circ$ の回転範囲の生成画像を用いた場合の5-fold cross validationにおける、単純なネットワークおよびAlexNet[4]を使用したときの識別性能を示す。本研究で構築した単純なネットワークでは全ての画像に対して識別が成功したが（100%）、AlexNetを用いた場合、誤識別される画像が存在した。

表 2 $\pm 5^\circ$ 、 $\pm 10^\circ$ の回転範囲における生成画像を用いたCNNによる識別性能。上段2つはleave-one-out cross validation、下段2つは5-fold cross validationによる性能を示す。

CNNによる識別		各タイプで誤識別された枚数				識別率 (%)
		F	N	P	V	
leave-one-out cross validation	単純なネットワーク ($\pm 5^\circ$)	0	0	0	0	100
	単純なネットワーク ($\pm 10^\circ$)	0	0	0	0	100
5-fold cross validation	単純なネットワーク ($\pm 10^\circ$)	0	0	0	0	100
	AlexNet ($\pm 10^\circ$)	0	2	0	0	99.9

利益相反の有無

なし

4. 考察

本研究では、ユークリッド距離を用いた識別に比べ、マハラノビス距離を用いた識別では識別率が向上することが分かった。本実験で用いた各タイプの2つの特徴量の分布は正規分布に近いために、分布を考慮したマハラノビス距離を用いることで、誤識別が減少したと考えられる。また、CNNによる識別において、単純なネットワークを用いた識別では、マハラノビス距離による識別で用いた特徴量と同じ数のフィルタ数を用いたが、その結果、識別率が100%となる興味深い結果が得られた。これにより、ヒトの感覚とは異なる最適な特徴量が存在、選択されることが示唆された。一方でAlexNetを用いた識別では誤識別された画像が数枚存在した。これはネットワークの構成上、畳み込みが多いため画像の解像度が小さくなりすぎて、各タイプの画像の特徴が減ってしまい、識別が難しくなったためであると考えられる。このことから、CNNによる識別において識別率の向上を図るためには、最適なネットワークを構築、選択する必要があると考えられる。

文献

- [1] Yamazaki T, Watanabe T, Nakajima Y, et al.: Improvement of depth position in 2-D/3-D registration of knee implants using single-plane fluoroscopy. IEEE Trans Med Imag **23**: 602-612, 2004
- [2] Yamazaki T, Futai K, Tomita T, et al.: 3D kinematics of mobile-bearing total knee arthroplasty using X-ray fluoroscopy. IJCARS **10**: 487-495 2015
- [3] 奥富正敏, 他: デジタル画像処理 (改定新版). 公益財団法人 画像情報教育振興協会 (CG-ARTS 協会), 2015
- [4] Krizhevsky A, Sutskever I, Hinton GE: ImageNet classification with deep convolutional neural networks. In Proc. Advances in Neural Information Processing Systems **25**:1090-1098, 2012

Identification of type from total knee arthroplasty images using machine learning ~Discrimination effect by Mahalanobis distance and application of CNN~

Mayuko KISHINO*¹, Takaharu YAMAZAKI*^{1,2}, Tetsuya TOMITA*³,
Yoshinobu SATO*⁴, Kazuomi SUGAMOTO*³

*1 Department of Information Systems, Saitama Institute of Technology Graduate School of Engineering

*2 Department of Information Systems, Saitama Institute of Technology

*3 Division of Orthopaedic Biomaterial Science, Osaka University Graduate School of Medicine

*4 Graduate School of Information Science, Nara Institute of Science and Technology

We have developed some elemental techniques for full automation of 3D knee kinematic measurement based-on 2D/3D registration using a single-plane fluoroscopic image and computer assisted design (CAD) model of the knee implant. As one of them, to identify the type of knee implant from X-ray image is important. In this study, we basic examined the discrimination performance by machine learning, using silhouette (simulation) images of many kinds of artificial knee implant. Specifically, we verified about the identification effect by Mahalanobis distance and the discrimination performance by CNN. As a result, it was found that misclassification was reduced and discrimination performance was improved in identification by Mahalanobis distance compared to identification by Euclidean distance using two feature quantities. In addition, for identification by CNN, the identification rate was further improved, and its effect was confirmed.

Key words: Total knee arthroplasty images, Pattern recognition, Mahalanobis distance, CNN

所見テキスト解析を用いる H&E 染色病理画像からの 免疫染色群推定

黄 果葡^{*1} 橋本 典明^{*1} 横田 達也^{*1} 中黒 匡人^{*2}

高野 桂^{*2} 中村 栄男^{*2} 竹内 一郎^{*1} 本谷 秀堅^{*1}

要旨

本研究では、悪性リンパ腫のサブタイプ同定に用いる免疫染色群を HE 染色画像より推定する手法を提案する。サブタイプの同定には多種類の免疫染色を施した病理画像を観察しなければならず、サブタイプ同定に必要な免疫染色群は症例ごとに異なる。病理医はまず HE 染色画像を観察し、その結果に基づきサブタイプの同定に必要な免疫染色群を定めている。本研究では、HE 画像より悪性リンパ腫同定に必要な免疫染色群を推定する機械を構築するために、HE 画像と所見テキストの組を利用する。同一サブタイプの悪性リンパ腫であっても、HE 画像に依存してサブタイプ同定に用いる免疫染色群が異なる症例がある。このことに注目することにより、HE 染色画像からの免疫染色群推定の容易さを症例ごとに定量評価する試みについても紹介する。

キーワード：悪性リンパ腫、免疫染色、CNN、決定木、数量化Ⅲ類

1. はじめに

悪性リンパ腫は血液細胞に由来する癌の一つであり、全身のいずれの場所にも病変が発生する可能性があり、形態や性質によって 70 種類以上のタイプに分類される [1]。悪性リンパ腫の治療はどのタイプに分類されるかによって、大きく治療方針が異なるため、正確な診断には病理顕微鏡検査による腫瘍の観察が必要となる。病理顕微鏡検査では、H&E 染色による観察結果に基づいて、更に 110 ある免疫染色のうち幾つかを選択して染色を行うことで腫瘍の性状評価を行い、病気のタイプの決定を行う。本研究では、HE 染色画像から

の免疫染色群を推定し、サブタイプと免疫染色群の組から症例ごとに「典型度」を評価した。悪性リンパ腫の診断では、サブタイプが同じでも免疫染色群は症例ごとに異なる。なぜなら、診断が容易であるかによって、用いる免疫染色の組が異なり、染色組間の距離が変化するためである。したがって、症例の免疫染色の組と組の間の距離を数量化Ⅲ類により求め、各サブタイプの確率密度関数をカーネル密度推定により求めることで「典型度」を定義し、予測器への入力に用いることで免疫染色群予測の容易さを定量評価した。

2. 決定木による免疫染色の予測対象決定

所見データから得られた患者の病名と免疫染色の結果を用いて決定木の構築を行う。決定木学習アルゴリズムには C4.5[2]を使用した。構築された決定木は H&E 染色病理画像が根ノードとなり、その下に木が複数構築さ

*1 名古屋工業大学

〔〒466-8555 名古屋市昭和区御器所町〕

e-mail: k.ko.212@nitech.jp

e-mail: hontani@nitech.ac.jp

*2 名古屋大学医学部附属病院

れる。木のノードは免疫染色となっており、子ノードへと伸びる枝は当該免疫染色での染色結果を示し、葉ノードは病名となっている。本研究では H&E 染色病理画像から推定できる免疫染色は根ノードにより近い免疫染色であると推定できる。構築された決定木の結果から、6 種類の免疫染色を推定対象とする。

3. 数量化Ⅲ類による症例の典型度評価

数量化Ⅲ類を用いて症例間と免疫染色間の距離評価を行った。結果から、3 種類の腫瘍な病気タイプに分かれる図 1 のような散布図が得られた。

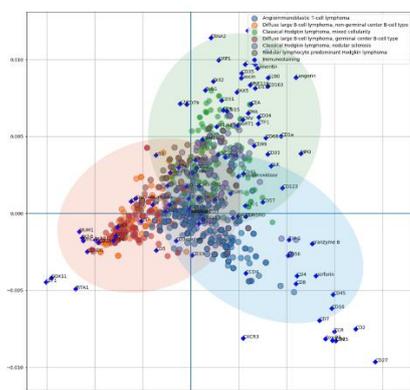


図 1 免疫染色の組により定めた距離に基づく症例の散布図。各点が症例を表し、色が病型を表す。

腫瘍な病気タイプ 3 種類について散布図からカーネル密度推定を行い、病気毎の確率密度関数を計算する。各病気の確率密度関数に症例の座標を代入することで症例の出現しやすさを算出することができる。散布図から、中心部は様々な病気タイプが混在しているため、中心部以外の症例については H&E 染色病理画像からの免疫染色群の予測が容易であると考えられる。本研究では、予測のしやすさを典型度とし、確率密度関数を用いた典型度の定義を行った。各病気のタイプの確率密度関数を f_B , f_T , f_H とすると、B 細胞リンパ腫である症例 \mathbf{x} の典型度は、

$$\frac{f_B(\mathbf{x})}{f_B(\mathbf{x})+f_T(\mathbf{x})+f_H(\mathbf{x})} \quad (1)$$

として定義される。他の病気タイプについても同様の計算を行うことで症例の典型度が定義できる。

4. 畳み込みニューラルネットワークによる免疫染色の推定

悪性リンパ腫の H&E 染色病理画像をパッチに切り出した画像を入力とし、決定木学習によって定めた免疫染色 6 種類を出力とする畳み込みニューラルネットワークを構築する。また、症例の典型度と免疫染色群予測の難易度の関係を表すために実験を行った。

5. 実験

病理画像のパッチを入力とした予測器による学習結果を示す。学習データとして典型度の低いものを使用する学習と、高いものを使用した学習の二種類を行い、精度の比較を行った。テストデータは共通のものを使用している。実験のエポック毎の精度を図 2 に示す。

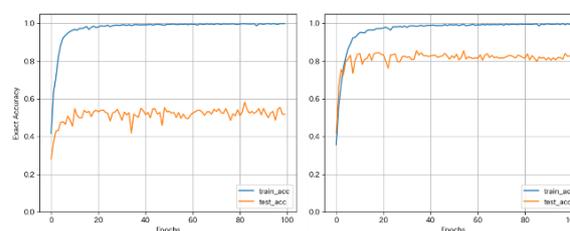


図 2 症例の典型度の違いによる免疫染色群推定の実験結果。左図は典型度の低いデータを用いた学習結果。右図は典型度の高いデータを用いた学習結果を表す。

利益相反の有無

「なし」

文献

- [1] 悪性リンパ腫 基礎知識:[国立がん研究センター がん情報サービス]. <https://ganjoho.jp/public/cancer/ML/index.html>. (2019 年 5 月 5 日閲覧)
- [2] J. Ross Quinlan. C4.5: Programs for machine learning. Morgan Kaufmann Publishers, San Mateo, California, 1993.

Immunostaining group estimation from H&E stained pathology images using findings text analysis

Kaho KO^{*1}, Noriaki HASHIMOTO^{*1}, Tatsuya YOKOTA^{*1}, Masato NAKAGURO^{*2}, Kei KOHNO^{*2},
Shigeo NAKAMURA^{*2}, Ichiro TAKEUCHI^{*1}, Hidekata HONTANI^{*1}

*1 Nagoya Institute of Technology

*2 Nagoya University Hospital

In this study, we propose a method to estimate immunostaining groups used for subtype identification of malignant lymphomas from HE staining images. In order to identify subtypes, it is necessary to observe pathological images subjected to many types of immunostaining, and the immunostaining group required for subtype identification differs from case to case. The pathologist first observes the HE staining image, and based on the result, the immunostaining group necessary for identification of the subtype is defined. In this study, in order to construct a machine to estimate the group of immunostainings necessary for the identification of malignant lymphoma from HE images, we use a set of HE images and findings text. Even in the case of malignant lymphomas of the same subtype, there are cases where the immunostaining groups used for subtype identification differ depending on HE images. By focusing on this, we introduce an attempt to quantitatively evaluate the ease of immunostaining group estimation from HE staining images for each case.

Key words: Malignant lymphoma, Immunostaining, CNN, Decision tree, Quantification III,

深層学習を用いた術野映像内肺領域抽出

今西 勁峰^{*1} 武 淑瓊^{*2} 中尾 恵^{*2} 松田 哲也^{*2}

要旨

外科手術の安全性向上のためには血管および腫瘍の三次元構造の正確な把握が必要不可欠である。近年、術中臓器の変形推定技術が広く研究されており、カメラ画像内における二次元臓器領域が抽出できれば、臓器の三次元変形推定が可能であることが示されている。しかし、手術時において形状が大きく変化する肺などの臓器についてはカメラ画像内の臓器領域を精度よく自動抽出する手法が確立されていない。本研究では、深層学習を用いて、胸腔鏡下肺がん切除術の術中カメラ画像に対し、肺領域を自動抽出可能なモデルを構築した。過去に実施された肺がん切除術の術中カメラ画像を用いて本モデルを訓練し、検証用症例の画像を用いて有効性を検証した結果、初期画像に対する肺領域の自動抽出精度、および時系列的な領域変化を伴う連続画像に対しての自動抽出精度がともに良好であったので報告する。

キーワード：深層学習，手術映像，領域抽出，セグメンテーション，U-Net

1. はじめに

近年、カメラ解像度の向上や手術用ロボットの高性能化により、低侵襲である内視鏡下での外科手術が一層幅広い診療科で実施されている。内視鏡下手術の安全性向上において、関心領域の血管および腫瘍の三次元構造を把握することが不可欠である。しかし、内視鏡の狭い術野を通して臓器の一部を視認しながら手術を進めなければならず、これを支援する研究が進められている[1][2][3]。

これまでに腹腔鏡画像における肝臓の輪郭を視覚的な手がかりとしてバーチャルモデルと手術映像との姿勢合わせを目指した研究[4]が報告されているが、特に肺がんを対象とした呼吸器外科手術等においては、肺内圧の変化に伴って肺実質が大きく虚脱し、その変形量が50%以上と大きいため、腫瘍位置の正

確な同定には変形推定が必要不可欠である。近年、1枚の術中カメラ画像における臓器のシルエットから変形推定が可能であることが実験的に示されているが[5]、臨床利用においてはカメラ画像内の肺領域の認識が必要である。Wuら[6]はグラフカット法とオプティカルフロー法を組み合わせることで時系列的に変化するカメラ画像内の肺領域をトラッキングする手法を開発した。しかし、開始フレームやトラッキングが失敗した際には手動設定が必要で、自動化には課題が残っている。

本研究では、肺手術の術中カメラ画像に対し、深層学習を用いて、術野映像内の肺領域を自動抽出可能なモデルを構築することを目的とする。深層学習では二次元画像に対する領域抽出・分割用モデルが多く提案されており、医用画像に対してはセグメンテーションモデルとしてU-Net[7]が広く用いられている。術中映像に対しては、U-Net構造を応用したモデルを用いてリアルタイムで術具領域を抽出可能な研究[8]も提案されているが、変形量が大きく、表面模様の個人差の大きい臓器領域の抽出については対応できていない。本研究ではU-Netを応用した領域抽出モデルを構

*1 イーグロース株式会社

〔〒604-8006 京都市中京区下丸屋町 403 番地〕

e-mail: k.imanishi@egrowth.co.jp

*2 京都大学大学院 情報学研究科

築し、実際の肺がん切除術の術中カメラ画像を用いて本モデルを訓練した上で、検証用画像に対し良好な精度で肺野領域を抽出することを確認したので報告する。

2. 術野映像内の臓器領域抽出モデル

本研究では、U-Net 構造を用いて、臓器抽出モデルを2個構築した。モデル1はU-Net構造をそのまま採用し、予測対象フレーム画像(256×256×3)を入力とし、予測対象フレームにおける肺野領域を出力とするモデルであり、モデル2は[予測対象フレーム(256×256×3)、参照フレーム+参照フレームにおける肺野領域(256×256×4)]の2入力から、予測対象フレームにおける肺野領域を出力とするモデルである(図1)。つまり、モデル1は初期画像における肺野領域の抽出を目的とするモデルであり、モデル2は連続的なフレームの差異情報を考慮した肺野領域抽出を目的とするモデルである。ただし、初期画像以降の抽出結果については、2モデルの出力をアンサンブル処理した結果を採用する。

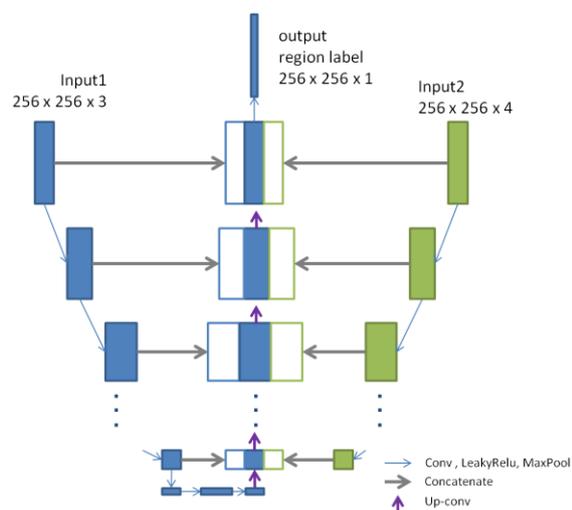


図1 U-Net 構造を持つ映像トラッキング用モデル

3. 学習実施および結果

京都大学医学部附属病院呼吸器外科から胸腔鏡下肺がん切除術を受けた25例の手術動画の提供を受けて、術具が含まれていないシーンを20~50フレーム程度ピックアップし、

フレーム画像を抽出した後、手作業によって各フレームにおける肺野領域の教師データを作成して学習した。また、学習する際はデータ拡張手法として、平行移動、アフィン変換、ズーム、コントラスト変更等の処理を行った。なお、ダイス係数を学習および評価に用いた。2つのモデルを用いて、各症例動画から抽出した教師データに対し、交差検証を実施した結果、ダイス係数は平均0.954、最小0.768、最大0.992であった(表1)。Model2のみを用いた方がアンサンブル処理よりも精度が高かったが、カメラ視点が大きく移動した際や継続的なトラッキングによる誤差の拡大を抑制するため、アンサンブル処理を行ったほうが頑健性は高い傾向にあった。抽出結果例を図2に示す。抽出結果の傾向として、変色の少ない肺に対しては精度良く抽出できているが、変色や癒着の多い肺については抽出精度は低かった。抽出精度が低かった症例については、

表1 各モデルおよびアンサンブル処理による抽出結果(ダイス係数)

	Model1	Model2	Ensemble
Average	0.946	0.969	0.954
Min	0.758	0.897	0.768
Max	0.991	0.993	0.992



図2 抽出結果例。(a)良好な抽出結果例および(b)精度の低かった抽出結果例。右:元画像。左:抽出された肺領域(ハイライト部)

他の症例に類似した変色や癒着部がなかったため、学習パターンが不足し、これらの症例に対する汎化性能が向上しなかったためと考える。

4. まとめ

本研究では、術野映像内の肺領域を自動抽出可能な深層学習モデルを開発した。実際の手術動画から教師データを生成・学習した結果、良好な抽出結果が得られることが分かった。変色や癒着の多い症例に対しての抽出結果は低かったが、今後はさらなる症例画像を追加して学習を行うことで抽出精度を改善可能であると考えられる。

謝辞

本研究は、AMED 産学連携医療イノベーション創出プログラム (ACT-M) 「脱気変形肺に対応した微小結節の術中同定法」の助成による。

利益相反の有無

なし。

文 献

- [1] Lin MW, Chen JS: "Image-guided techniques for localizing pulmonary nodules in thoroscopic surgery", *Journal of Thoracic Disease*, 8(9): S749-S755, 2016
- [2] Nickel F, Kennigott HG et al.: "Computer tomographic analysis of organ motion caused by respiration and intraoperative pneumoperitoneum in a porcine model for navigated minimally invasive esophagectomy". *Surg Endosc* 32(10), pp. 4216-4227, 2018.
- [3] Nakao M, Oda Y, Taura K and Minato K: "Direct Volume Manipulation for Visualizing Intraoperative Liver Resection Process", *Computer Methods and Programs in Biomedicine*, Vol. 113, No. 3, pp. 725-735, 2014.
- [4] Koo B, Ozgur E, Le Roy B, et al.: "Deformable registration of a preoperative 3D liver volume to a laparoscopy image using contour and shading cues", *MICCAI*, 2017
- [5] Nakao M, Akira S, Matsuda T: "A simulation study on deformation estimation of elastic materials using monocular images", *Int. J. Computer Assisted Radiology and Surgery*, 12(1), S257-258, 2017
- [6] Wu S, Nakao M, Matsuda T: "Continuous Lung Region Segmentation from Endoscopic Images for Intra-operative Navigation", *Computers in Biology and Medicine*, Vol. 87, No. 1, pp. 200-210, 2017
- [7] Ronneberger O, Fischer P, Brox T : "U-Net: Convolutional Networks for Biomedical Image Segmentation", *MICCAI*, Vol. 9351, pp234-241, 2015
- [8] Garcia-Peraza-Herrera, L.C., Li W, Fidon L, et al.: "ToolNet: holistically-nested real-time segmentation of robotic surgical tools", *IROS*, pp5717-5722, 2017

Lung region segmentation of intraoperative images using deep learning

Keiho IMANISHI^{*1}, Shuqiong WU^{*2}, Megumi NAKAO^{*2}, Tetsuya MATSUDA^{*2}

*1 e-Growth Co., Ltd.

*2 Graduate School of Informatics, Kyoto University

Accurately understanding the three-dimension (3D) geometry of vascular structures and tumors is essential for improving the safety of surgery. Recently, techniques for online estimation of organ deformation have been widely studied. Although latest studies have shown that estimation of the 3D deformation of organs is possible from 2D organ regions of intraoperative camera images, segmentation of organ regions that are greatly deformed during treatment from camera images with high accuracy is a technical challenge. This study propose a model that can automatically segment the lung region from intraoperative camera images of endoscopic lung cancer resection using deep learning. We trained and verified the accuracy of the model using intraoperative camera images of lung cancer resection. Verification results show that proposed model can accurately segment the lung area from the initial image and continuous intraoperative images.

Key words: Deep learning, Intra-operative image, segmentation, U-Net

高難易度画素用の損失関数を用いた

セマンティックセグメンテーション

松月 大輔^{*1} 堀田 一弘^{*1}

要旨

セマンティックセグメンテーションは画像中の 1 画素ずつを識別し、ラベル付けを行う。当然、画像の画素毎に識別の難易度の高い箇所もあれば、簡単な箇所もある。通常、セマンティックセグメンテーションのラベル付けは、出力層で出力したいチャンネル数まで次元削減した後に softmax 関数を適用し、各クラス確率に変換する。その際、各クラス確率値が均等に与えられるような箇所は、一般的に識別が難しい箇所であることが多い。そこで我々は、各クラス確率の最大値に基づき、識別の難しい箇所を強く学習するような学習法を提案する。評価実験では、「細胞膜」、「細胞核」、「細胞質」を含むデータセットを用い、従来の学習方法と我々の提案する学習方法の精度比較を行った。その結果、Intersection over Union を用いた精度評価において提案手法が従来法を上回ることを確認した。

キーワード：細胞画像、セグメンテーション、画素難易度、Deep learning

1. はじめに

近年、Deep Learning の発展と共に様々な業界において人的労力削減の為に AI による自動化が行われている。医療分野では人間には判断することの難しい CT 画像からの異常検知を行うことにより、医師の診断援助が期待されている。また、細胞分野においては細胞画像から「細胞膜」、「細胞核」などを自動分類するセマンティックセグメンテーションが注目されており、研究者が目で見えてきた大きな負担を軽減することが可能である。そこで本論文では細胞画像のセマンティックセグメンテーションの精度向上を目指す。

セマンティックセグメンテーションは

Convolutional Neural Network(CNN)[1]の登場により、Deep Learning を用いた手法が主流となっており、CNN 構造に基づいた Fully Convolutional Network(FCN)[2]の登場を機にエンコーダー・デコーダー構造を持つアーキテクチャが多く提案されてきた。SegNet[3]では FCN のエンコーダー構造に VGG16[4]を応用しており、車載カメラにおけるセグメンテーションにおいて大きな精度向上を示した。医療画像の分野では、エンコーダー・デコーダー間に Concatenation を含むことにより、デコーダー部分で失われる特徴をエンコーダー部分が補正し、セグメンテーション精度向上を実現した U-net[5]が高い有効性を示している。近年ではエンコーダー・デコーダー構造のうち、エンコーダー部分の特徴抽出を、物体分類の分野で非常に高い精度を示した ResNet[6]や ResNext[7]、DenseNet[8]などの非常に深いネットワークを採用するモデルが多くみられる。PSPnet[9]ではエンコーダー部分に ResNet101 を、FC-DenseNet[10]は DenseNet

*1 名城大学 理工学研究科 電気電子工学専攻 [〒468-8502 愛知県名古屋市天白区塩釜口 1-501]]

e-mail: {140442123@c alumni, kazuhotta@}.meijo-u.ac.jp

を採用しており、深い特徴抽出がセマンティックセグメンテーションにおいても有効性があることを示した。しかし、これらの手法はセグメンテーション精度を大きく向上させたがその反面、内部パラメータの増加により、計算コストが非常に大きくかかってしまう問題点がある。その問題を解決するためには、学習を効率的に行うことが重要である。

セマンティックセグメンテーションは画像を1画素ずつ識別、ラベル付けを行う。当然、画像の画素毎に識別の難易度の高い箇所もあれば、簡単な箇所もある。通常、セマンティックセグメンテーションのラベル付けは、出力層で出力したいチャンネル数まで次元削減した後に softmax 関数を適用し、各クラスの確率に変換する。その際、クラス毎の確率値が均等に与えられるような箇所は、一般的に識別が難しい箇所であることが多い。そこで我々は、確率の最大値に基づき、識別の難しい箇所を強く学習することにより学習を効率的に行う手法を提案する。

本論文の構成は以下の通りである。まず、2節で関連研究について述べる。次に、3節で提案手法を示し、4節で実験結果を示す。最後に結論として、まとめと今後の課題を5節で述べる。

2. 関連研究

学習を効率的に行うことにより精度向上を目指す手法は物体分類問題においては様々な研究が行われている。Curriculum Learning[11]では、識別の簡単な所から学習を実施し、その後難しい箇所を学習することにより、人間の学習に近い形を実現し分類精度向上を示した。また近年では人間の注意構造をモデル化した Attention 機構が注目されている。画像分類コンテストである ILSVRC2017 で優勝した SENet[12]は Residual Attention[13]に channel 毎の注意構造を導入することにより、学習に重要な箇所をより重点的に学習でき、高い分類精度を示した。しかし、これらの Attention 機構は複数回の畳み込み処理や全結合層を含

んでおり、注意構造による重点的な学習は可能であるが、パラメータ数は増加してしまうため、計算コストの増加が問題となる。

セマンティックセグメンテーションの分野では Inception Resnet[14]に階層的に簡単な箇所から学習を行う機構を加え、ステージ毎に損失関数を算出する Deep Layer Cascade[15]や、クラス毎の出現画素数を基にしたクラス難易度によるタスク分類を行った後に学習を行う方法 [16]では、識別の難易度に注目した構造の有効性を示している。しかし、これらの手法は難易度毎に事前に正解画像を用意する必要がある。

3. 提案手法

多くのセマンティックセグメンテーションを行うネットワークは、テスト時において出力層に softmax 関数を使用し、各クラスの確率に変換する。その際、クラス毎の確率値が均等に与えられるような箇所は、一般的に識別が難しい箇所であることが多い。図1は3クラスの細胞画像において、学習時の出力層に softmax 関数を適用後、確率の最大値を画素毎に抽出して可視化した確率マップである。確率マップは青色に近い箇所ほど確率の最大値が1に近く、赤色に近い箇所ほど確率の最大値が0に近づくことを示している。図1では3クラスの細胞画像なので、確率の最大値が50%付近を示している黄色い箇所は識別が難しい箇所であることを示している。図1を見ると、学習回数の少ない Epoch = 5 ~ Epoch = 40 付近では黄色を示す領域が多々見られることが分かる。逆に Epoch = 200 のように学習が進んでいく毎に黄色を示す領域は細かいエッジ情報のみとなっていく、ほとんどの領域は青色領域となり外形やクラスが決定していることを示している。当然、青色領域も正解と異なる箇所も多々存在する。つまり、学習に有効な外形やクラスを特定する情報は、少ない学習回数に集中しており、黄色領域などの難しい箇所が重要となる。そこで我々は確率の最大値に基づき、確率的に難しい箇所

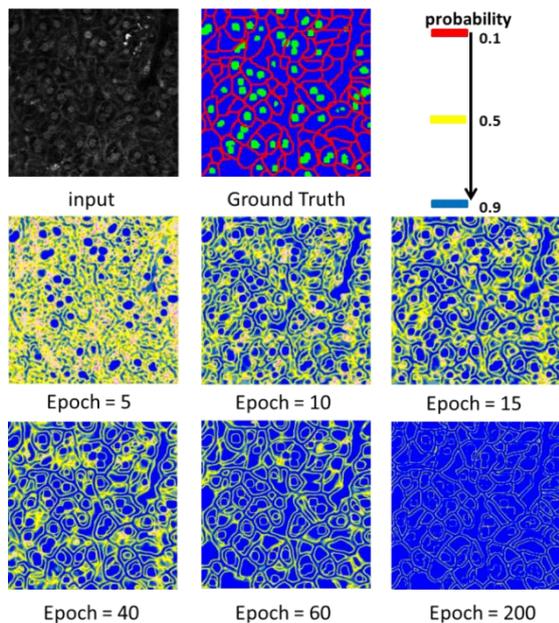


図1 細胞画像の確率マップ

を強く学習することにより、効率的な学習を行う手法を提案する。

我々の提案手法は医療分野のセマンティックセグメンテーションにおいて高精度を示し、計算コストの軽いネットワークであるU-net[5]をベースにしている。図2に我々の提案手法のモデルを示す。我々の提案手法ではエンコーダー・デコーダー共に 3×3 の畳み込み処理後にBatch Renormalization[17]を採用している。Batch Renormalizationでは細胞画像のように少ない学習画像の際にも大きく依存しないように学習を行える。我々の提案手法は主に2つの工程で実装される。

- (1) 通常セマンティックセグメンテーションと同様にSoftmax cross entropy誤差(loss)を算出する。
- (2) 出力層にSoftmax関数を適用後、確率の最大値が閾値 α を超えた箇所のみSoftmax cross entropyで誤差(loss_hard)を算出する。

(2)について詳しく説明すると、出力層にSoftmax関数を適用することによりクラス毎の確率が埋め込まれる。その確率の最大値を画素毎に抽出したマスク画像を作成し、その確率の最大値が閾値 α を超えた画素のみ学習

を行う。閾値 α はマスク画像の画素平均により決定する。

$$\alpha = \frac{1}{y \cdot x} \sum_{\substack{0 \leq i \leq y \\ 0 \leq j \leq x}} f(x, y) \quad (1)$$

ここで x, y はマスク画像の x 軸、 y 軸方向の画素数を示しており、 f はマスク画像を表す。

最終的にネットワークが学習を行う損失関数は(1)(2)の工程にハイパーパラメータ λ をかけた値とした。本実験においては、経験的法则から $\lambda=0.5$ に固定して実験を行う。

$$loss_{All} = loss + \lambda * loss_{hard} \quad (2)$$

4. 評価実験

本節では2種類の細胞画像を用いた評価実験の結果を示す。本実験の評価指標はIntersection over Union(IoU)を採用した。IoUは各クラスに対して画素毎に重なり率を導出するので、セマンティックセグメンテーションにおいて適している。IoUは次のような式で表すことができる。

$$IoU = \frac{TP}{FP+FN+TP} \quad (3)$$

ここでFPはFalse Positive, FNはFalse Negative, TPはTrue Positiveを表す。

4.1節ではマウスの細胞画像のデータセットに対する評価実験について、4.2節ではショウジョウバエの細胞画像のデータセットに対する評価実験の結果を示す。

4.1. マウスの細胞画像データセット

マウスの細胞画像データセットは顕微鏡に「細胞核」、「細胞質」に蛍光マーカーが発現するマウスの肝臓の50枚の蛍光画像である。また画像サイズは最小 161×161 画素、最大 657×657 画素の不均一の画像サイズとなっている。本実験では画像サイズを統一するために全50枚の画像を 256×256 画素にリサイズした。また、50枚のうち35枚を学習画像として選択し、5枚を検証及び10枚をテスト用に分類し、テスト実験は、従来法及び提案手法共に3回評価実験を行い、その平均値により評価を行った。

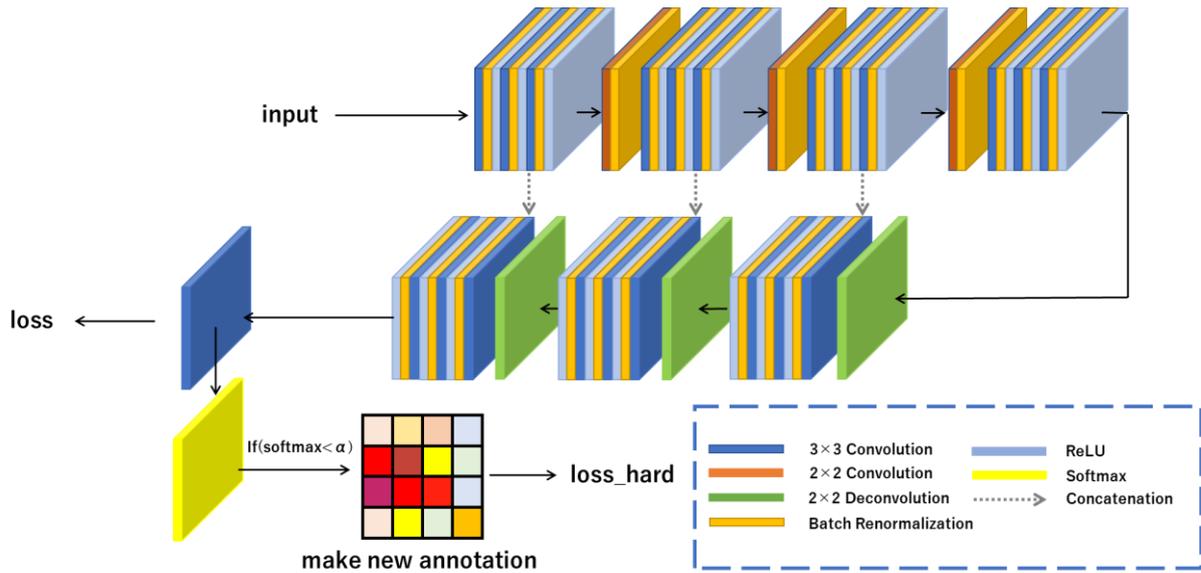


図 2 提案手法モデル図

図 3 に本実験においての検証画像による mean IoU と学習回数 の関係を表すグラフを示す。図 3 を見ると、従来法では学習が収束するのに必要な学習回数が多いことが確認できるが、我々の提案手法では学習回数が 50 回以内という、少ない学習回数で従来法では確認できなかった mean IoU が 60% を超える結果が確認できる。

図 6 にテスト時においての、高難易度画素の学習を行わない従来法のセグメンテーション結果と、我々の提案手法のセグメンテーション結果を示す。また図 6 の白丸部分を拡大した画像を図 4 に示す。図 4 をみると、従来法では捉えることのできなかつた細胞核の検知が可能になったことや、より鮮明に細胞膜を捉えることができるようになってきていることがわかる。また、提案手法と同等の学習回数で一番良い検証結果が得られた従来法によるテスト結果と提案手法を比較してみると、従来法では未検出の細胞膜、細胞核があることに加え、細胞膜がより太く検出されてしまうことがわかる。学習回数を重ねた従来法では、細胞膜の太さを制限できている点から、学習が不十分であるということが確認できる。

最後に表 1 に IoU での評価実験結果を示す。表 1 から、我々の提案手法は IoU において、細胞膜、細胞核、細胞質すべてのクラスで従

来法より 1% 以上精度が向上していることがわかる。また、学習回数が少ない場合の従来法では、細胞膜において提案手法よりわずかに精度が高く検出されている。これは少ない学習回数の従来法では図 4 に示す通り、細胞膜が通常より太く検出されているため、細胞膜の IoU が高くなったからである。

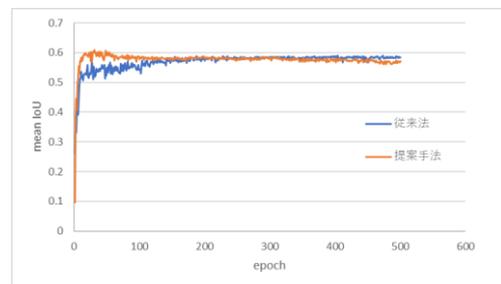


図 3 検証画像の学習回数と mean IoU の関係

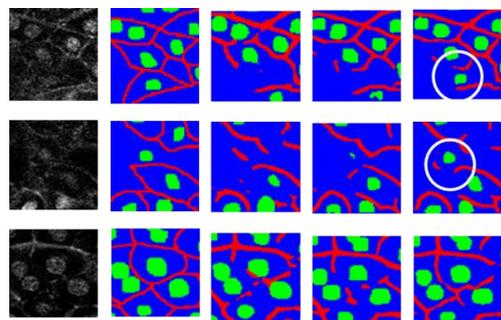


図 4 セグメンテーション結果拡大図(左から、入力画像、正解画像、学習回数 20 回~40 回で検証結果が最もよかった従来法の結果、従来法の結果、提案手法)

表 1 IoU 実験結果

	細胞膜	細胞核	細胞質	Mean IoU
従来法	37.5	66.1	74.0	59.2
提案手法	38.9	68.7	76.9	61.5
従来法 (20~40epoch)	39.2	62.6	72.5	58.1

4.2. ショウジョウバエの細胞データセット

ショウジョウバエの細胞画像データセット [18]では、「細胞膜」、「細胞核」、「細胞質」、「シナプス」を含む全 20 枚のデータセットである。また画像サイズは 917×917 であり、本実験では 512×512 にリサイズ処理を行い、20 枚の画像のうち 12 枚を学習画像として選択し、0 度、180 度、270 度及びそれぞれ左右反転を加えることにより 96 枚とした。そして 3 枚を検証、5 枚をテスト用画像として分類し、また同様に従来法及び提案手法共に 3 回評価実験を行い、その平均値により評価を行った。

図 6 に高難易度画素の学習を行わない従来法のセグメンテーション結果と、我々の提案手法のセグメンテーション結果を示す。また図 6 の白丸部分を拡大した画像を図 5 に示す。図 5 を見ると、従来法ではシナプスを多く誤検出してしまっていたが、我々の提案手法では誤検出を軽減していることがわかる。また、形状を捉えることが難しいような細胞膜においても、画素毎に難しい箇所を重点的に学習する我々の手法では正確に細胞膜の形状を捉えることに成功している。しかし、まだ細胞核に似ている細胞質などの誤検出を抑制する傾向はみられたが、精度が不十分であり、今後の研究課題である。

最後に表 2 に IoU での評価実験結果を示す。表 2 から、細胞膜、細胞核、シナプスそして細胞質すべてのクラスにおいて IoU による精度が向上していることがわかる。特に、我々の提案手法と同等の学習回数である、epoch = 50 付近で従来法と比較してみるとシナプスでは約 15%もの精度向上が確認できる。これは我々の提案手法が、高難易度画素を重点的に学習することにより、シナプスなどの難しいクラスにおいても非常に効率的に学習する

ことができていることを示している。

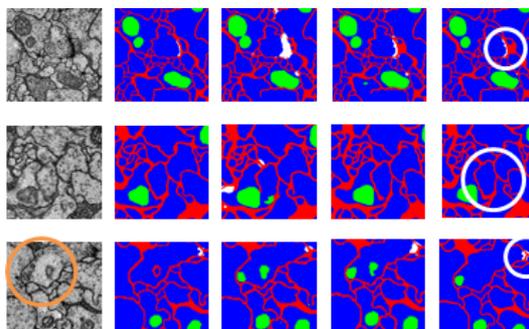


図 5 セグメンテーション結果拡大図(左から、入力画像、正解画像、学習回数 50 回付近で検証結果が最もよかった従来法の結果、従来法の結果、提案手法)

表 2 IoU 実験結果

	細胞膜	細胞核	シナプス	細胞質	Mean IoU
従来法	80.8	79.2	29.0	92.7	70.2
提案手法	80.9	82.8	32.9	93.6	72.6
従来法 (epoch = 50付近)	78.8	72.3	18.0	91.1	65.1

5. おわりに

本論文では、セマンティックセグメンテーションにおける各画素の識別の難しさに注目し、難しい画素を重点的に学習することにより、効率的な学習且つセグメンテーション精度の向上を実現した。

今後の展望として、損失関数を求める際のハイパーパラメータを学習的に決定することと共に、様々なセマンティックセグメンテーションのモデルに我々の提案手法を適用し、更に有効性を確かめていきたい。

利益相反の有無

なし

文 献

- [1] Krizhevsky A. Sutskever I. Hinton G E.: ImageNet Classification with Deep Convolutional Neural Networks. Advances in Neural Information Processing Systems **25**: 1097-1105,

- 2012
- [2] Long J. Shelhamer E. Darrell T.: Fully convolutional networks for semantic segmentation. *Proc. IEEE Transactions on Pattern Analysis and Machine Intelligence* **39**: 3431-3440, 2017
- [3] Badrinarayanan V. Kendall A. Cipolla R.: SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence* **39**: 2481-2495, 2017
- [4] Simonyan K. Zisserman A.: Very Deep Convolutional Networks for Large-Scale Image Recognition. *Computer Vision and Pattern Recognition*, 2014
- [5] Ronneberger O. Fischer P. Brox T.: U-Net: Convolutional Networks for Biomedical Image Segmentation. *Proc. Medical Image Computing and Computer-Assisted Intervention: 2015*, pp234-241.
- [6] He K. Zhang X. Ren S. et al.: Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016.
- [7] Xie S. Girshick R. Dollár P. et al.: Aggregated residual transformations for deep neural networks. *Computer Vision and Pattern Recognition*, 2017
- [8] Huang G. Liu Z. Van D M. et al.: Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017, pp4700-4708.
- [9] Zhao H. Shi J. Qi X. et al.: Pyramid scene parsing network. *IEEE Conf. on Computer Vision and Pattern Recognition*, 2017.
- [10] Jégou S. Drozdal M. Vazquez D.: The one hundred layers tiramisu: Fully convolutional densenets for semantic segmentation. *Computer Vision and Pattern Recognition Workshops*, 2017
- [11] Bengio Y. Louradour J. Collobert R. et al.: Curriculum learning. *Proceedings of the 26th annual international conference on machine learning*. ACM, 2009.
- [12] Hu J. Shen L. Sun G.: Squeeze-and-excitation networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018, pp7132-7141.
- [13] Wang F. Jiang M. Qian C. et al.: Residual attention network for image classification. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* 3156-3164, 2017
- [14] Szegedy C. Ioffe S. Vanhoucke V. et al.: Inception-v4, inception-resnet and the impact of residual connections on learning. *AAAI*, 2017.
- [15] Li X. Liu Z. Luo P. et al.: Not all pixels are equal: Difficulty-aware semantic segmentation via deep layer cascade. *IEEE Conference on Computer Vision and Pattern Recognition*, 2017.
- [16] Matsuzuki D. Hotta K.: Semantic Segmentation by Integrating Classifiers for Different Difficulty Levels. *International Symposium on Visual Computing*, 2018, pp607-615.

[17] Ioffe S.: Batch renormalization: Towards reducing minibatch dependence in batch-normalized mdels. In Advances in neural information processing systems, 2017, pp1945-1953.

[18] Gerhard S. Funke J. Martel J. et al.: Segmented anisotropic ssTEM dataset of neural tissue. Retrieved, 16, 09, 2013

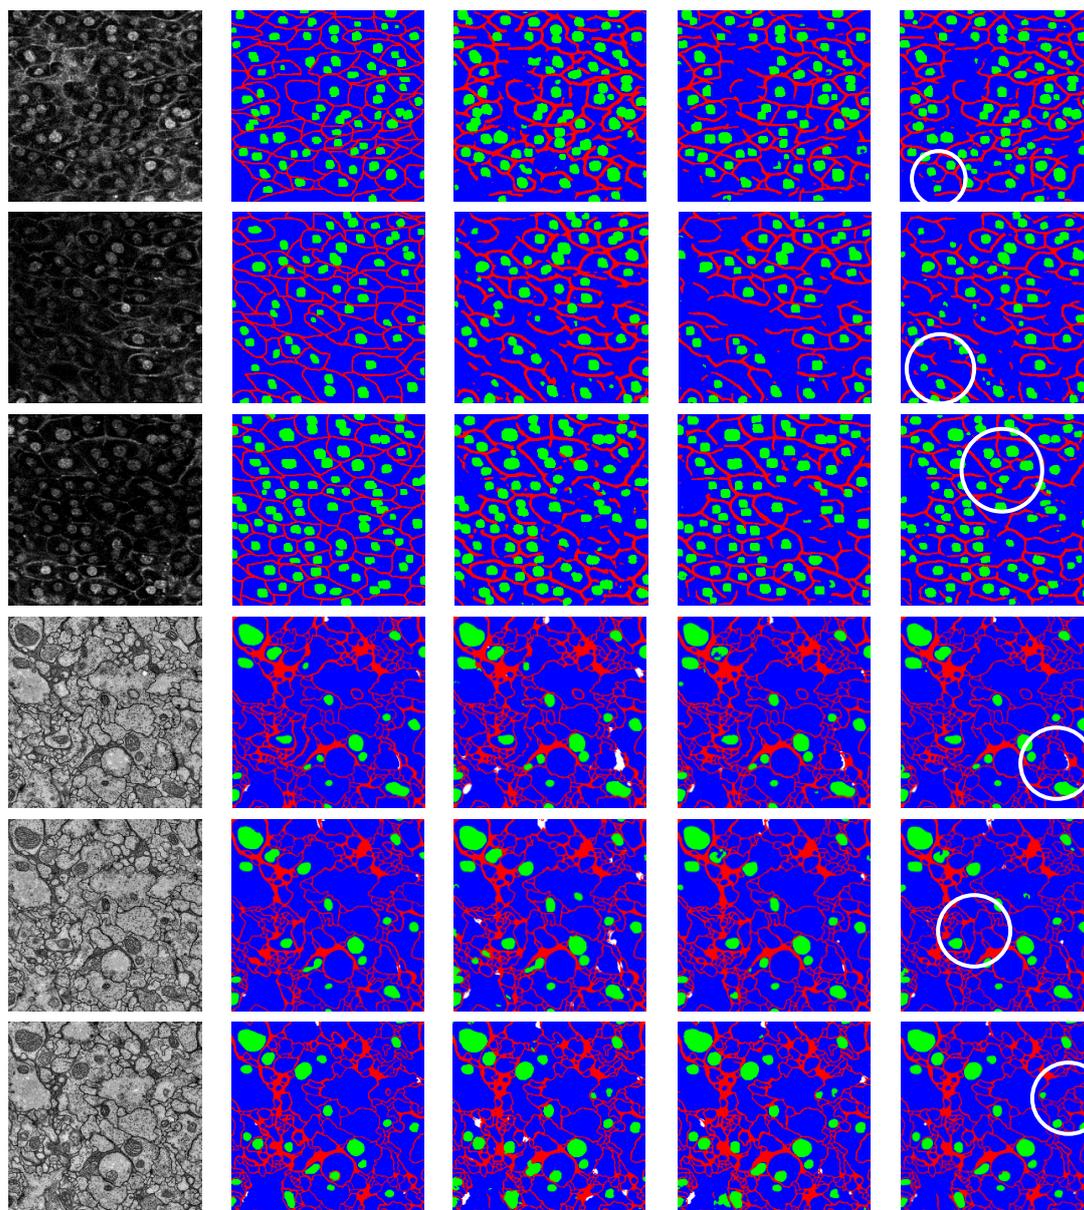


図6 セグメンテーション結果(左から, 入力画像, 正解画像, 少ない学習回数での従来法の結果, 従来法の結果, 提案手法, また上3つがマウスの細胞画像での実験結果, 下3つがショウジョウバエの細胞画像での実験結果)

Sematic Segmentation Using Loss Function for Difficult Pixels

Daisuke MATSUZUKI¹, Kazuhiro HOTTA¹

¹ Meijo University

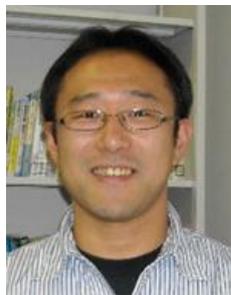
Semantic segmentation recognizes each pixel in an image. In general, an image includes pixels that are easy to recognize and difficult to recognize. At the final layer, we apply softmax function to convert the output of network to probability. At that time, pixels that have small maximum probability are often difficult to recognize. Therefore, we propose a method to learn pixels that are difficult to recognize according to maximum probability of each pixel. In the evaluation experiment, we compared the accuracy of the conventional method with our proposed method on datasets including "cell membrane", "cell nucleus" and "cytoplasm". By the evaluation using Intersection over Union, we confirmed that the proposed method outperformed the conventional method.

Key words: Cell image, Segmentation, Pixel difficulty, Deep Learning

著者紹介



松月 大輔 (まつづき だいすけ)
平成 30 年 3 月名城大学理工学部卒業,
平成 32 年同大学院大学院博士前期課程
修了予定. 現在, 細胞画像及び車載カ
メラ画像のセマンティックセグメンテ
ーションの研究に従事. 現在は, セマン
ティックセグメンテーションの様々な
難易度に注目し, 平成 30 年に
International Symposium on Visual
Computing で研究発表を実施.



堀田 一弘 平成 9 年埼玉大学工学部
卒. 平成 14 年同大学院博士後期課程修
了. 博士(工学). 平成 11 年~平成 14
年日本学術振興会特別研究員(DCI). 平
成 14 年電気通信大学情報通信工学科
助手, 平成 19 年同大学助教, 平成 22
年から名城大学理工学部電気電子工学
科准教授. 平成 30 年から同大学教授.
平成 24 年メリーランド大学 Visiting
Scholar. パターン認識, コンピュータ
ビジョンの研究に従事. 情報処理学会,
映像情報メディア学会, IEEE
Computer Society 各会員.

Template (Common to all types of submissions) ver. 2.0 (Revised 2019.3.28)

Polyp size classification in colorectal cancer using a Siamese network

Benjamin VILLARD*1, Yuichi MORI*2, Masahi MISAWA*2, Shin-ei KUDO*2, Hayato ITOH*1, Masahiro ODA*1, Kensaku MORI*1,3,4

*1Department of Intelligent Systems, Graduate School of Informatics, Nagoya University, Japan.

*2Digestive Disease Center, Showa University Northern Yokohama Hospital, Japan.

*3Information Technology Center, Nagoya University, Japan.

*4Research Center for Medical Big data, National Institute of Informatics, Japan.

Abstract

Colorectal cancer is one of the leading cause of cancer related deaths with increasing prevalence. One key factor in the likelihood of adenomatous cell differentiation is polyp diameter. Much research has shown polyp size to be a major contributor to the risk of colorectal cancer. There exist a significant cut-off value of 10 mm which clinicians use regarding their treatment diagnosis and patient surveillance. However, polyp measurement is highly variable and there exist high variance between clinician measurements surrounding this threshold value. We propose a novel method to classify polyp size into above or below 10 mm classes based on a Siamese network. In a first step, a Siamese networks is trained to build a high dimensional embedding of features extracted for each polyp size. In as second step, we use a k-NN approach that classifies the polyp size based on the distance between the feature embedding of the input image, and the whole embedding space learned by the Siamese network. This method allows for better binary classification of the polyp size classes. Our data consist of around 13,434 images from 115 movies classified into various polyp sizes ranging from 1-14 mm. We trained our model on 10,746 images, and tested on 2,688 images equally split into each binary category. We obtained 70.2 in feature embedding classification and 95.7% on binary classification.

Keywords : Colorectal cancer, Polyp size classification, Siamese Network, Medical Imaging

1. Introduction

Colorectal polyp size is a critical biomarker in colorectal cancer diagnosis and management, with larger polyp size having been associated with a greater likelihood of adenocarcinomatous cell differentiation [1-4]. The majority of colorectal cancer arise from pre-existing adenoma, with small initial polyps gradually growing into adenocarcinoma over several years. There exists many factors that can effect the transition into a malignant stage, such as genetics, growth rate, and most importantly size [2]. Polyp diameter can be assessed by endoscopist or pathologists, with endoscopist using visual estimation of the diameter, and pathologists assessing the size using ruler measurements after removal of the polyps from formalin. It has been shown that endoscopist assessment can be highly variable. Summers et al [1] report that 20% of endoscopist measurements had a 3mm over- or underestimation of polyp size compared to the reference standard. Furthermore, typical endoscopes operate using a wide-angle lens, which can further increase the measurement bias.

There exists two significant thresholds in the clinical decision making process, which occur at 5 mm and 10 mm. Polyps 10mm and above are considered to have the most likely risk of cancer proliferation and a such should be removed. However, due to the human bias, endoscopist tend to either over or under estimate polyp sizes surrounding these particular thresholds. This can be observed in our data, shown in Fig. 1 *left*, where the distribution of polyp size can be seen to be significantly skewed to be under 10 mm (representative of clinical occurrence), with almost no annotations made at the 10mm threshold. There thus is a need for an automatic classification system that can aid clinicians in their estimations.

Polyp classification is an active field of research. Most of the current research focus on polyp detection [5-8]. However, we have found few works that focus on polyp size classification [4,9], most of which achieve the classification using depth estimation. The work in [9] use pre-trained monocular depth estimation neural networks, which they train using an unsupervised approach. However, the pre-trained model was trained on computer vision based features and is therefore not adept at classifying medical imaging features.

In this work we propose a binary classification model based on Siamese networks, first used in [10] to

classify signatures. By training a convolutional neural network (CNN) to learn high dimensional descriptive features for the above or below 10mm polyp classes, new instances can be classified into the appropriate class. In the training step, we train a Siamese network - an identical pair of CNN working in parallel with shared weights, to learn this embedding. Once the networks have been trained, and the weights known, we pass a query image to the trained network, obtaining a high level feature embedding. We then use the k-Nearest Neighbors (k-NN) algorithm to compute the closest class cluster to the feature embedding of the query image. To the best of our knowledge, we present one of the first use of Siamese networks in the field of medical imaging as well as to classify polyp sizes. Furthermore, our method allows to build a high dimensional understanding of polyp features that ultimately can be used not only for binary classification, but to build a high level embedding for each polyp size class. As the query process relies only on the distance computation between the feature embedding, we believe that this methodology could be ultimately used in real time.

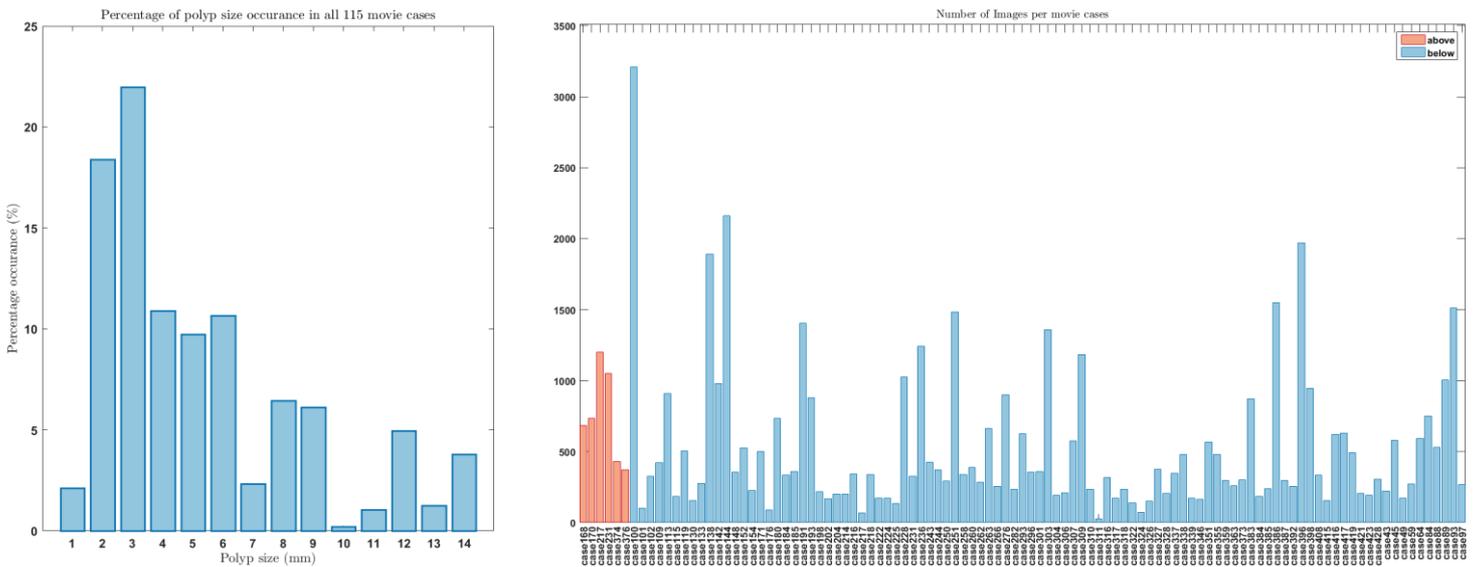


Fig.1 Data information. *Left*: Percentage of polyp size occurrences in all 115 cases. *Right*: Number of polyp images per movie case, for all 115 cases. The orange bars represent the above class, while the blue bars represent the below class.

2. Data and Methodology

Our data consist of 115 colonoscopic movies of different patients, each roughly lasting around 15 minutes. Each movie was annotated by clinical experts. Segments containing polyps were selected and clinicopathologic information, such as the polyp size, as well as imaging conditions, such as white light, chromo or near blue infrared, were recorded. For each segment in all the movie cases, all the movie frames for that segment were extracted and saved as individual images, belonging to the above or below class. Only segments belonging having been acquired under white light conditions were used. The number of frames saved and classified into above or below can be seen in Fig. 2 *right*. In total, our data consisted of 4, 478 and 51, 845 images belonging to the above and below class, respectively. In order to train our network on a balanced dataset, we randomly selected the same amount of images from the below class as the above class. As we had very few cases belonging to the above class (6 cases), representing a total of 8 different polyps, we split our data into training and testing datasets using an 80/20% split, and report our accuracy on the 20% split. In such a manner, our training data consisted of 10,746 pairs of images of class: same above, same below, and different. Our testing data consisted of 2, 688 image pairs corresponding to

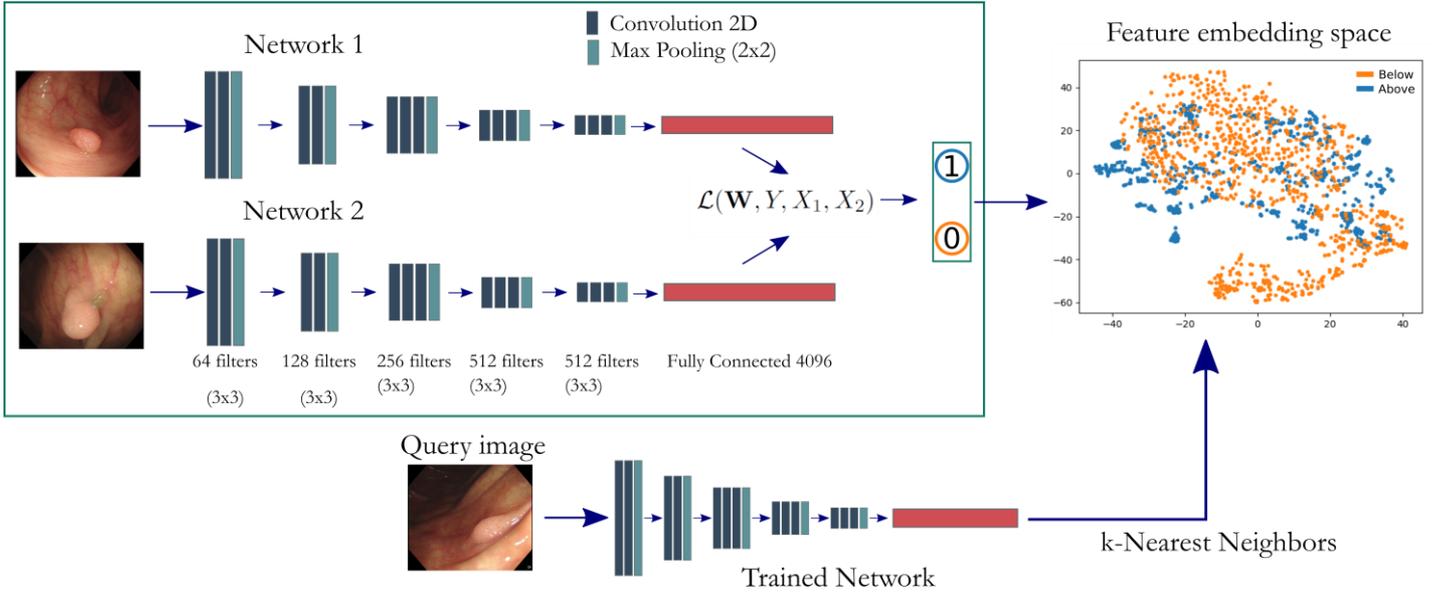


Fig. 2 Overview of our approach. The green box (top left) represents the training stage that builds a high dimensional feature embedding space. Network 1 and 2, based on VGG16, are identical and work in parallel. In the training stage, two images are fed through the networks and the contrastive loss is used such that images belonging to the same category are clustered together in the embedding space, shown in the top left. The network with the trained weights is then used on a new image, to convert it to a 4,096 dimensional embedding and the k-NN algorithm ($k = 100$) is used to compute the closest class cluster.

the same classes.

The framework for our methodology can be seen in Fig.2. The green box (top left) represents the training stage that builds a high dimensional feature embedding space. Network 1 and 2, based on VGG16, are identical and work in parallel. Each image is converted to grayscale and resized to be 200x200 to be the input to the network. Pairs of images are given to the network as input, belonging either to the category same above, same below, or different. Each image goes through a series of convolutions and max pooling operators before being encoded in a 4,096 embedding vector. The contrastive loss function is then used to map the distance between the feature embeddings and is given by:

$$\mathcal{C}(\mathcal{W}, \mathcal{Y}, \mathcal{X}_1, \mathcal{X}_2) = (1 - \mathcal{Y}) \frac{1}{2} (\mathcal{D}_{\mathcal{W}}(\mathcal{X}_1, \mathcal{X}_2))^2 + (\mathcal{Y}) \frac{1}{2} \{\max(0, m - (\mathcal{D}_{\mathcal{W}}(\mathcal{X}_1, \mathcal{X}_2)))\}^2$$

where \mathcal{C} represents the contrastive loss function, \mathcal{W} the network weights, m is an arbitrarily chosen margin, \mathcal{X}_1 and \mathcal{X}_2 the feature embeddings of the image pairs, with $\mathcal{Y} = 1$ if they are similar (same-above or same-below category) and $\mathcal{Y} = 0$ if they are dissimilar (above-below or below-above category). $\mathcal{D}_{\mathcal{W}}$ represents the l_2 norm used in mapping the distance in the feature space, as a function of the weights \mathcal{W} , such that $\mathcal{D}_{\mathcal{W}}(\mathcal{X}_1, \mathcal{X}_2) = \|\mathcal{X}_1 - \mathcal{X}_2\|_2$. Computing the contrastive loss allows to map the distance $\mathcal{D}_{\mathcal{W}}$ between the feature vectors to be small if the embeddings belong to the same class, or high if they belong to different classes. A t-SNE plot showing a 2D representation of the 4,096 feature embedding space can be seen in Fig.1 top right.

3. Results and Conclusions

We validated the discriminative power of the network on the feature embedding space, as well as for the binary classification. With regards to the first evaluation, our methodology was evaluated on 2,688 image pairs corresponding to the categories same-above, same-below, and dissimilar. Our network was able to classify pairs of images as similar or dissimilar with a 70.2% accuracy. As for the binary classification, we evaluated our algorithm on 1,792 images belonging to the above or below category. Using a k-NN, with $k=100$, we obtained a 95.7% accuracy. Fig. 3 shows some example of images having been correctly or incorrectly classified as above or below 10mm.

As mentioned previously, it should be noted that although there is a clear separation between the training and validation data, the testing images also belong to the 115 movie cases which can cause some classification bias. In the future we aim to obtain more cases, in particular belonging to the above category, having multiple polyps per case, as to present a more accurate representation of the methodology accuracy.

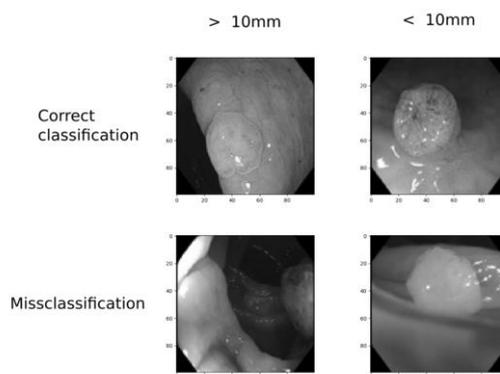


Fig. 2 Example of the binary classification results having been correctly or incorrectly classified as above or below 10mm.

Competing interests

The Authors acknowledge collaboration with the company CYBERNET.

Acknowledgement

The authors would like to acknowledge AMED grant numbers 18hk0102034h0103 (2018), and 18hs0110006h0002 (2018).

References

- [1] Summers RM. Polyp size measurement at ct colonography: What do we know and what do we need to know? *Radiology*, 255:707–720, 2010.
- [2] Hofstad B, Vatn M H, Andersen S N, Huitfeldt HS, Rognum T, Larsen S, Osnes M. Growth of colorectal polyps: redetection and evaluation of unresected polyps for a period of three years. *Gut*, British Society of Gastroenterology, Vol. 39. 1996, pp449-456.
- [3] Klein JL, Okcu M, Preisegger K, Hammer H. Distribution, size and shape of colorectal adenomas as determined by a colonoscopist with a high lesion detection rate: Influence of age, sex and colonoscopy indication. *United European Gastroenterology Journal*, 4(3):438–448, 2016.
- [4] Fabio Martínez, Josué Ruano, Martín Gómez, and Eduardo Romero. Estimating the size of polyps during actual endoscopy procedures using a spatio-temporal characterization. *Computerized Medical Imaging and Graphics*, 43:130–136, 2015.
- [5] Pu Wang P, Glissen B J R Brown Jeremy R. Xiao, Xiao, Tyler M. Berzin, Mengtian Tu, Fei Xiong, Xiao Hu, Peixi Liu, Yan Song, Di Zhang, Xue Yang, Liangping Li, Jiong He, Xin Yi, Jingjia Liu, and Xiaogang Liu. Development and validation of a deep-learning algorithm for the detection of polyps during colonoscopy. *Nature Biomedical Engineering*, Vol.2. 2018, pp741-748.
- [6] Gregor Urban, Priyam Tripathi, Talal Alkayali, Mohit Mittal, Farid Jalali, William Karnes, and Pierre Baldi. Deep learning localizes and identifies polyps in real time with 96% accuracy in screening colonoscopy. *Gastroenterology*, Vol.155(4). 2018, pp1069-1078.
- [7] Misawa Masashi, Kudo Shin-ei, Mori Yuichi, Cho Tomonari, Kataoka Shinichi, Yamauchi Akihiro, Ogawa Yushi, Maeda Yasuharu, Takeda Kenichi, Ichimasa Katsuro, Nakamura Hiroki, Yagawa Yusuke, Toyoshima Naoya, Ogata Noriyuki, Kudo Toyoki, Hisayuki Tomokazu, Hayashi Takemasa, Wakamura Kunihiko, Baba Toshiyuki, Ishida Fumio, Itoh

Hayato, Roth Holger, Oda Masahiro, and Mori Kensaku. Artificial intelligence-assisted polyp detection for colonoscopy: Initial experience. *Gastroenterology*, Vol.154. 2018, pp2027-2029.

[8] R. Zhang, Y. Zheng, T. W. C. Mak, R. Yu, S. H. Wong, J. Y. W. Lau, and C. C. Y. Poon. Automatic detection and classification of colorectal polyps by transferring low-level cnn features from nonmedical domain. *IEEE Journal of Biomedical and Health Informatics*, Vol.21(1) 2017. pp41-47.

[9] Hayato Itoh, Holger R. Roth, Yuichi Mori, Masashi Misawa, Masahiro Oda, Shin-ei Kudo, and Mori Kensaku. Polyp-size classification with rgb-d features for colonoscopy. *Proc. SPIE 10950, Medical Imaging 2019: Computer-Aided Diagnosis*, 1095015, 2019.

[10] Jane Bromley, Isabelle Guyon, Yann LeCun, Eduard S. Sackinger, and Roopak Shah. Signature verification using a "siamese" time delay neural network. In *Proceedings of the 6th International Conference on Neural Information Processing Systems*, NIPS'93, 1993, pp737-744.

病変検出アルゴリズムにおける局所画像特徴量の 汎用的な自動生成

— 健常データのみでの学習による特徴量生成の検討 —

牛房 和之^{*1} 根本 充貴^{*2} 木村 裕一^{*1} 永岡 隆^{*1} 山田誉大^{*1}

林 直人^{*3}

要旨

様々な病変検出支援(CADe)アルゴリズムにおいて適用が可能な, 局所画像特徴量の汎用的自動生成法について検討する. 特に, 不十分量の病変データで深層学習を用いた CADe アルゴリズムの研究が行われることを想定し, 健常部の局所画像パッチデータのみで学習が可能な手法を検討する. 本稿では, 教師無し学習法である深層畳み込みオートエンコーダと主成分分析を用いた特徴量生成手法を提案する. 特徴量は, 局所画像パッチのアピアランスベクトルから得られる潜在変数と, 潜在変数から再現した画像パッチと入力局所画像パッチとの誤差とする. 抽出特徴量の識別における有用性を確認するために, 胸部 CT および頭部 MR アンギオグラフィ上の病変検出実験を行ったので, その結果を報告する.

キーワード: コンピュータ検出支援システム, 特徴量抽出, オートエンコーダ, 主成分分析

1. はじめに

近年, CT や MRI 画像などの医用画像の撮像技術が向上し, それに伴い大量かつ高精細な医用画像が撮像可能になったことで, 放射線診断医の画像読影における負担が増加している. その負担軽減のために, 病変部位候補の識別を行うコンピュータ検出支援 (CADe: computer aided

detection) システムの必要性が高まっている^[1,2].

CADe システムによる病変候補識別では, 画像内の局所の濃淡や形状などを定量化した特徴量という値を用いる. この特徴量が病変候補識別に有用であるかどうかによって CADe の病変検出性能は左右される. 特徴量の生成法には大別して 2 つの方法がある. 1 つは, 医学的知識や工学的知識に基づいて手作業で関数を設計・実装する方法である^[3]. もう 1 つは機械学習を用いた自動生成法である. 特に後者の手法では, 深層学習を用いたものが, 近年パターン認識分野で好成績を収めたことで, 注目を集めており, 研究が各所で盛んに行われている^[4].

また, 深層学習による特徴量の生成では過去の実測データなどの具体的な事象が学習データとして用いられる. その際, 十分な量の学習

*1 近畿大学大学院 生物理工学研究科
〔〒649-6433 和歌山県紀の川市西三谷
930〕

e-mail: k.ushifusa@gmail.com

*2 近畿大学 生物理工学部

*3 東京大学医学部附属病院 22 世紀医療センター

データが確保できないと適切な学習が行われず、抽出される特徴量が識別処理に有用な値とならない。

しかし、とりわけ病変データの収集は容易なことではない上、個人情報保護の問題や収集データの標準化の問題などがある^[4]。よって、CAdE システムの研究開発において常に十分な量の病変学習データが準備できるとは限らない。一方で、病変部位は有病症例データの中で病変の領域はわずかであり、大部分は健常な領域である。すなわち、有病症例データから得られる局所画像パッチデータのほとんどが、健常クラスのデータである。

本稿では、病変データの有無に性能が左右されない特徴量の自動生成法について提案する。提案法では、病変データに比べ収集が容易で、かつ病変領域ラベルデータを作成する必要がない健常データのみを用いる。このことにより、病変データの量に依存しない安定した特徴量自動生成法となることが期待できる。我々はデータドリブな CAdE システムの自動生成、自動最適化に関する研究^[5]を行っており、本研究はその一部である。

2 節では提案法で用いられる手法について、3 節では提案法の有用性を確認するための実験・結果について、4 節では実験結果から考察できることと今後の展望についての説明を行い、5 節にて本稿のまとめを述べる。

2. 手法

2.1. 学習・検出処理モデル

想定する病変検出処理モデルと、検出処理に用いる特徴量抽出器の学習モデルを図 1, 2 に示す。特徴量の学習モデルは、①前処理、②病変候補検出、③健常データセットのみを用いた特徴量抽出器の学習の 3 つの処理で構成される。前処理および病変候補検出は、検出処理モデルで用いられるものと共通とする。

前処理では、画像の等方化や標準化、病変候補画像パッチの抽出領域の限定が行われる。病変候補検出処理は、前処理での抽出領域について、16 voxels 間隔で $32 \times 32 \times 32$ voxels の 3 次

元領域に複数分解切り出しを行う処理とする。

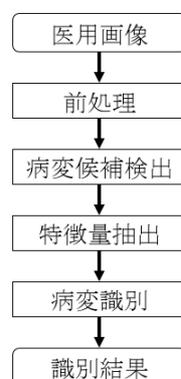


図 1. 病変検出処理モデル

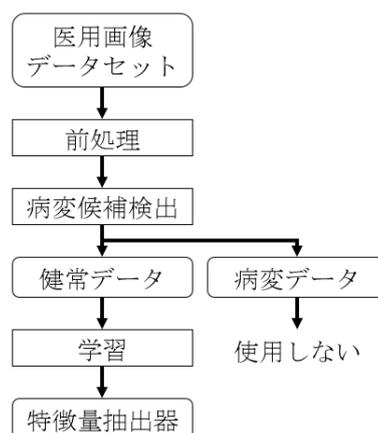


図 2. 特徴量抽出器学習モデル

2.2. 特徴量抽出器およびその学習

提案法では、教師無し学習法である深層畳み込みオートエンコーダ (Deep CAE : Deep Convolution Autoencoder)^[6,7] と主成分分析 (PCA : Principal Component Analysis)^[8] を用いて特徴量の自動生成を行う。以下では、それぞれの処理の詳細について説明する。

2.1.1. Deep CAE

提案法で用いる Deep CAE は、自動検出した $32 \times 32 \times 32$ voxels の 3 次元病変候補画像を 2.5 次元化^[9]した画像 (32×32 voxels の 3 チャネル画像) を入力とする。Deep CAE の構成は、2 層の Convolution 層、1 層の Full Connection 層から

なる (図 3). 潜在変数ベクトルの次元数は, 健常クラス学習画像 (2.5D) の画素値に PCA を適用した際に累積寄与率が 95%となる次元数と同数とする. また, 活性化関数は ReLU とする.

Deep CAE により抽出される特徴量は, 潜在変数ベクトルと, 潜在変数ベクトルから再現した画像パッチと入力画像パッチとの画素値の平均二乗誤差とする.

Deep CAE の学習では, 健常データのみを用いる. 学習のハイパーパラメータは, Mini Batch サイズは 256, Epoch 数は Early stopping によって決定, 損失関数は交差エントロピー誤差とした. これらのパラメータは, 予備実験の結果から手動にて決定した.

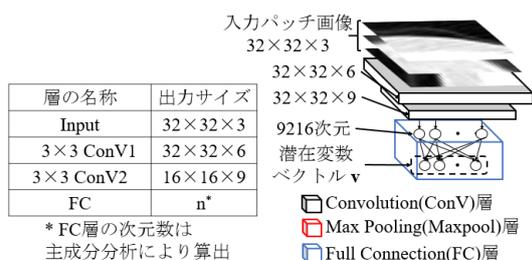


図 3. Deep CAE の構造

2.1.2. PCA

PCA を用いた特徴量抽出法は, 顔画像認識などで以前より用いられていた手法と同様の手法^[7]である.

PCA の学習で, 学習用の 3 次元病変候補 t の 2.5 次元画像の各画素値を要素とするベクトル x_t の集合である X

$$X = \{x_1, x_2, x_3, \dots, x_M\} \quad (1)$$

に対して算出される平均ベクトル μ と共分散行列 S

$$\mu = \frac{1}{M} \sum_{t=1}^M x_t \quad (2)$$

$$S = \frac{1}{M} \sum_{t=1}^M \sum_{u=1}^M (\mu - x_t)(\mu - x_u)^T \quad (3)$$

から, 固有値問題

$$S = \lambda v \quad (4)$$

を解くことで得られる複数の固有ベクトル v_e を得る.

任意病変候補 i の画素値ベクトル x_i から抽出される特徴量は, x_i の主成分ベクトルの要素と, x_i を主成分ベクトルに投影した際の残差とする. 主成分ベクトルの次元数は予備実験の結果から得た累積寄与率 95%の次元数とする.

2.3. 検証法について

提案法の有用性を評価するために, 胸部 CT データセット上の肺結節検出および頭部 MR アンギオグラフィ (MRA) データセット上の脳動脈瘤検出を例題とした検証実験を行う. 病変検出処理の流れは共に図 1 の検出処理モデルに従い, 特徴量抽出器の学習処理の流れは図 2 の学習モデルに従う.

肺結節検出の検証実験における前処理には, Nomura らの肺野領域抽出法および血管領域抽出法^[10]を採用する. 脳動脈瘤検出の検証実験における前処理には, Nomura らの画素値正規化および血管抽出法^[11]を行う. 検出病変候補の識別器としては, Decision stump を弱識別器とした Adaboosted ensemble^[12]を用いる. また, 予備実験の結果から弱識別器数=500 とした.

3. 実験および結果

実験には東京大学医学部附属病院にて撮影された胸部 CT 450 例および頭部 MRA450 例を使用した. いずれの画像も 1 個以上の肺結節/脳動脈瘤を含む. 450 例の画像データは学習用 300 例と検証用 150 例に分割して検証実験を行った.

胸部 CT 上の肺結節検出の処理では, 前処理にて $0.78 \times 0.78 \times 1.25$ [mm³] 解像度の CT を 0.78 mm 等方解像度にスケーリングする. 学習用 300 例からは健常候補 478,525 パッチ, 病変候補 3916 パッチが自動検出され, 検証用 150 例からは健常候補 234,386 パッチ, 病変候補 1,589 パッチが自動検出された. また, 予備検討から Deep CAE, PCA にて算出される潜在変数特徴量の次元数を 99 とした.

頭部 MRA 上の脳動脈検出の処理では、前処理にて $0.47 \times 0.47 \times 0.60$ [mm³] 解像度の MRA を 0.47mm 等方解像度にスケーリングする。学習用 300 例からは健常候補 127,257 パッチ、病変候補 2553 パッチが自動検出され、検証用 150 例からは健常候補 84,591 パッチ、病変候補 1,328 パッチが自動検出された。また、予備検討から Deep CAE, PCA にて算出される潜在変数特徴量の次元数を 122 とした。

実験には、Intel Core i7-7700, 64GB RAM, NVIDIA GeForce 1080Ti を搭載し、Windows10 Pro OS のコンピュータを用いた。各種病変検出処理および特徴量自動生成器は、C/C++および Python (Tensorflow ver.1.3.0) により実装した。

3.1. 胸部 CT 上の肺結節候補識別実験

Deep CAE の学習過程での認識誤差の推移を図 4 に示す。また、loss は学習時の損失誤差、val_loss は検証時の損失誤差である。loss および val_loss がともに減少しており、学習が適切に行われたことが読み取れる。

次に、抽出特徴量を用いた病変識別の FROC 曲線を図 5 示す。肺結節候補の識別感度は 5FPs/症例のとき 84.2%、10FPs/症例のとき 86.6%、15FPs/症例のとき 87.8% となった。また、図 6 に 5FPs/症例時、識別結果が True Positive (TP) となった画像と、True Negative (TN) となった画像、FP となった画像、False Negative (FN) となった画像を示す。

Deep CAE によって抽出された特徴量 (CAE 特徴量) と PCA によって抽出された特徴量 (PCA 特徴量) が識別器学習時に選ばれた回数の割合は CAE 特徴量が 17.8%、PCA 特徴量が 82.2% となった。また、弱識別器の重みを観察すると CAE 特徴量由来の弱識別器に付与された重みは全体の 36.6%、PCA 特徴量由来の弱識別器には 63.4% の重みが付与されていた。各特徴量に付与された弱識別器重みは、PCA による第 1 主成分特徴量に付与されたものが最大 (全体の 37.4%)、次に大きかったのは PCA 残差誤差特徴量 (全体の 31.7%)、その次に大きかったのは PCA 第 3 主成分 (全体の 3.66%) であった。

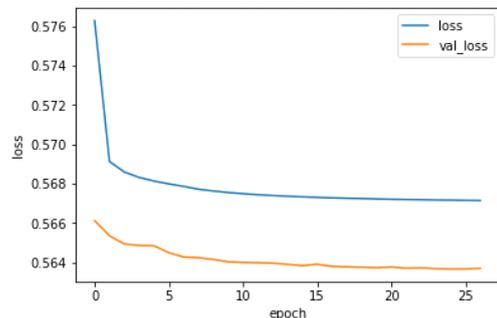


図 4. Deep CAE 学習認識誤差曲線 (肺結節候補識別)

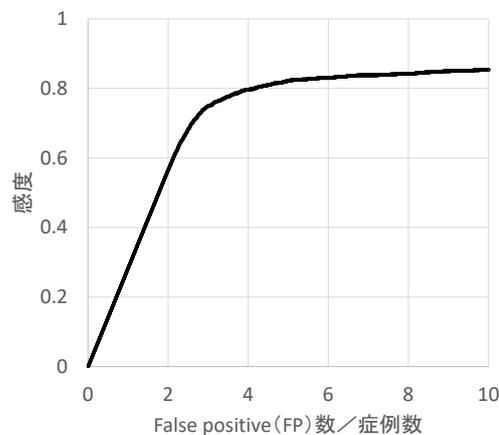


図 5. 肺結節候補識別 FROC 曲線

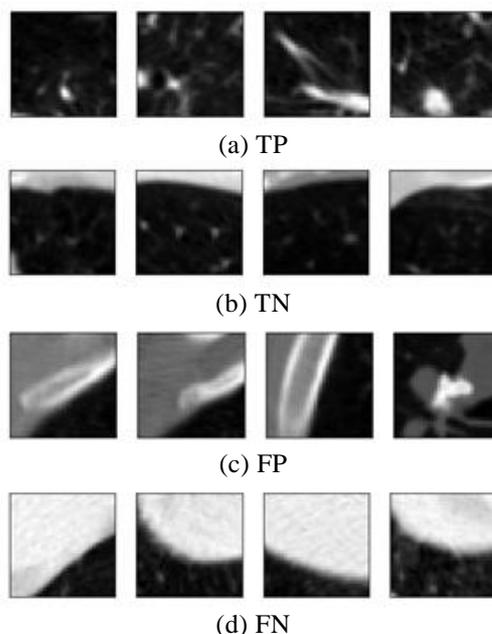


図 6. 肺結節候補識別結果画像例 (5 FPs/症例)

CAE 特徴量の中で弱識別器重みが最大であったのは第 12 目の特徴量であった。

3.2. 頭部 MRA 上の脳動脈瘤候補識別実験

Deep CAE の学習過程での認識誤差の推移を図 7 に示す。loss および val_loss がともに減少しており、学習が適切に行われたことが読み取れる。

次に、抽出特徴量を用いた病変識別の FROC 曲線を図 8 示す。脳動脈瘤候補の識別感度は 5FPs/症例のとき 17.7%，10FPs/症例のとき 28.1%，20FPs/症例のとき 43.3%となった。また、図 9 に 5FPs/症例時、識別結果が True Positive (TP) となった画像と、True Negative (TN) となった画像、FP となった画像、False Negative (FN) となった画像を示す。

Deep CAE によって抽出された特徴量 (CAE 特徴量) と PCA によって抽出された特徴量 (PCA 特徴量) が識別器学習時に選ばれた回数の割合は CAE 特徴量が 36.8%，PCA 特徴量が 63.2%となった。また、弱識別器の重みを観察すると CAE 特徴量由来の弱識別器に付与された重みは全体の 36.6%，PCA 特徴量由来の弱識別器には 63.4%の重みが付与されていた。各特徴量に付与された弱識別器重みは、PCA による第 1 主成分特徴量に付与されたものが最大 (全体の 19.5%)，次に大きかったのは PCA 残差誤差特徴量 (全体の 7.25%)，その次に大きかったのは CAE 特徴量の第 116 番目の特徴量 (全体の 5.20%) であった。

4. 考察

胸部 CT 上の肺結節識別実験および頭部 MRA 上の脳動脈瘤識別実験を行った。実験の結果から、提案法によって Deep CAE 特徴量および PCA 特徴量を健常データのみから学習できたことと、提案法にて得られる特徴量の有用性を確認した。

胸部 CT 上の肺結節候補識別実験については、Deep CAE 特徴量と PCA 特徴量がともに識別器の学習で選択されており、互いの特徴量が相補的な役割を果たしたと考える。特徴量の選択回

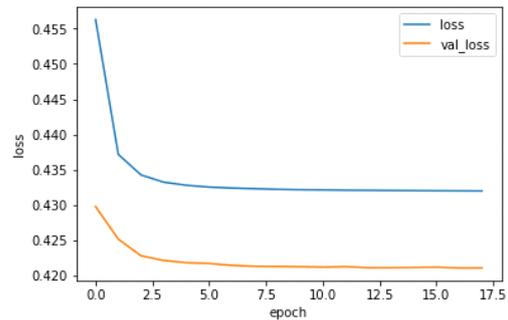


図 7. Deep CAE 学習認識誤差曲線 (脳動脈瘤候補識別)

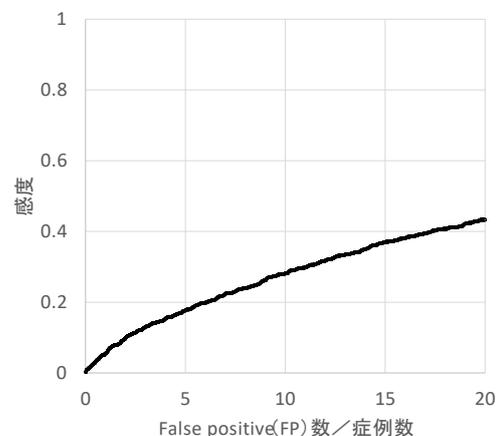


図 8. 脳動脈瘤候補識別 FROC 曲線

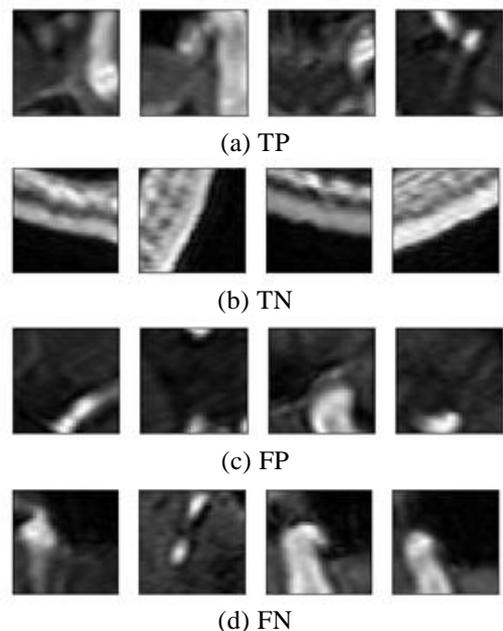


図 9. 脳動脈瘤候補識別結果画像例 (5 FP/症例)

数や弱識別器の重みから、画素値を線形に次元圧縮した PCA 特徴量が識別において主に用いられる特徴量となり、Deep CAE によって抽出できる非線形な特徴量は PCA では表現できない特徴を補完する働きをしたと考えられる。識別結果画像より、TN や TP は肺野内部の低 CT 値領域を多く含んだものが多く、FP や FN は胸壁外を多く含んだ領域が多いことが分かった。このことから、本手法は胸壁外を多く含んだ候補領域からの特徴量抽出が効果的に行われず、これらの FP、FN が多く発生したと考える。

頭部 MRA 上の脳動脈瘤候補識別実験についても、Deep CAE 特徴量と PCA 特徴量がともに識別器の学習で選択されており、互いの特徴量が相補的な役割を果たしたと考える。ただし、脳動脈瘤候補の識別精度は肺結節候補と比べて低かった。肺結節・脳動脈瘤候補の TP 画像を比較確認すると、脳動脈瘤については病変部分が候補画像サイズに対してかなり大きいことが分かる。このことは、脳動脈瘤候補識別に有用な特徴量の抽出を困難にした要因の一つと考える。マルチスケール処理などを採用し、各病変で最適なスケールでの候補領域を解析することを可能にすることで、識別精度の改善が期待できる。また、識別結果画像を確認すると、TN となった領域は血管ではない領域が主であった。一方、TP、FP、FN 画像はいずれも血管領域であった。血管領域以外には脳動脈瘤は発生しないので、候補識別器が血管領域か否かを識別することを主に学習したと考える。このことから、脳血管領域抽出処理の内容は候補識別精度を大きく左右することが分かった。

今後は、入力データをマルチスケールにすることにより、血管の全体を見てから局所を見るという医師の画像診断のプロセスに沿った特徴量生成を検討する。また、健常データセットの潜在変数ベクトル群からの特徴量空間におけるマハラノビス距離など、その他の特徴量生成も検討する。

5. まとめ

健常データのみでの学習による特徴量の自動

生成法について提案した。提案法の有用性の確認のため胸部 CT 上の肺結節検出および頭部 MRA 上の脳動脈瘤の病変候補に対する識別実験を行った。胸部 CT を用いた実験では、感度は 5FPs/症例で 84.2%、10FPs/症例で 86.6%となった。頭部 MRA を用いた実験では感度は 5FPs/症例で 17.7%、10FPs/症例と 28.1%となった。これらの結果から、提案法の有用性が確認された。

謝辞

本研究を行うにあたりご討論頂いている近畿大学生理工学部医工学科・根本研究室の学生諸氏、近畿大学大学院生物理工学部システム生命工学科・木村研究室および永岡研究室の諸氏に感謝します。そして、貴重な臨床データをご提供頂いた、東京大学医学部附属病院放射線科、同 22 世紀医療センターコンピュータ画像診断学/予防医学講座 (CDRPM) の先生方に深く感謝します。

利益相反の有無

なし

文献

- [1] Ronald A Castellino: Computer aided detection (CAD): an overview: *Cancer Imaging* **5-1**: 17-19, 2005
- [2] 尾上守夫: ME 技術の進歩 医用画像処理. *医用電子と生体工学* **20-7**: 532-535, 1982
- [3] Van Ginneken B, Schaefer-Prokop CM, Prokop M: Computer-aided diagnosis: how to move from the laboratory to the clinic. *Radiology* **261-3**: 719-32, 2011
- [4] 大江和彦: これからの医療における AI の活用と課題. *医薬品情報学* **19-3**: N1-N3, 2017
- [5] Nemoto M, Hayashi N, Hanaoka S, et al.: Feasibility Study of a Generalized Framework for Developing Computer-Aided Detection Systems-a New Paradigm. *J Digit Imaging* **30-5**: 629-639, 2017

- [6] 瀧雅人：これならわかる深層学習入門. 講談社，2017，pp136-148
- [7] 瀧雅人：これならわかる深層学習入門. 講談社，2017，pp153-176
- [8] 坂野鋭：パターン認識における主成分分析 顔画像認識を例として：統計数理：Vol. 49：No. 1：23-42：2001
- [9] Holger R. Roth, Le Lu, Ari Seff, Kevin M. Cherry, et.al.: A New 2.5D Representation for Lymph Node Detection using Random Sets of Deep Convolutional Neural Network Observations. Proc MICCAI **2014**: 520-527, 2014
- [10] Yukihiro Nomura, Mitsutaka Nemoto, Yoshitaka Masutani, et.al: Reduction of false positives at vessel bifurcations in computerized detection of lung nodules. Journal of Biomedical Graphics and Computing **4-3**: 36-46, 2014
- [11] Yukihiro Nomura, Yoshitaka Masutani, Soichiro Miki: Performance improvement in computerized detection of cerebral aneurysms by retraining classifier using feedback data collected in routine reading environment. Journal of Biomedical Graphics and Computing **4-4**: 12-21, 2014
- [12] 平井有三：はじめてのパターン認識. 森北出版株式会社，2017，pp137-141

Generalized generation of local image features for computer-aided detection algorithm

— A study of feature generation by learning only normal data —

Kazuyuki USHIFUSA^{*1}, Mitsutaka NEMOTO^{*2}, Yuichi KIMURA^{*1}, Takashi NAGAOKA^{*1}, Takahiro YAMADA^{*1},
Naoto HAYASHI^{*3}

^{*1} Graduate School of Biology-Oriented Science and Technology, Kindai University.

^{*2} Faculty of Biology-Oriented Science and Technology, Kindai University.

^{*3} Department of Computational Diagnostic Radiology and Preventive Medicine, 22nd Century Medical and
Research Center, The University of Tokyo Hospital

We propose a generalized generation of local image features that can be applied various computer-aided detection (CAdE) algorithms. The clinical datasets for developing CAdE algorithms are often small-scale and not easy to apply deep learning for multi-class classification. The proposed feature generation method is based on unsupervised learning with only normal class data that can be collected easier than lesion class data. A deep convolutional autoencoder and a principal component analysis are used in the proposed method. These encoders extracted the latent variable features from an appearance vector of a local image patch. The reconstruction error between an original image patch and an image from the latent variables is also calculated as an image feature. We evaluated the proposed method with the experimental results of lung nodule detection on chest CT and aneurism detection on head MRA.

Key words: computer-aided detection, feature extraction, Autoencoder, principal component analysis

X線単純投影と流体構造連成解析を用いた

狭窄柔軟管内流れにおける造影剤濃度勾配の評価

金子 凌太郎*¹ 高本 聡*¹ 波田野 明日可*¹ 泉 聡志*¹

要旨

冠動脈の狭窄の機能的重症度を低侵襲かつ簡易に診断する方法として造影剤濃度勾配を指標とする TAG (Transluminal Attenuation Gradient) が挙げられるが、精度の向上が求められている。狭窄後に生じる再循環領域における造影剤の拡散は、TAG に大きく影響すると考えられる。そこで本研究では造影剤拡散動態を明らかにするため、狭窄血管を模擬した柔軟管に流した造影剤を X 線単純投影により撮影した。流体は水及び血液を用い定常流及び拍動流の条件で流した。また実験を模した流体構造連成解析を行い比較した。定常流で流体に水を用いた実験では、狭窄後の造影剤は管断面全体に広がり一様に拡散する様子が観察された。一方、定常流で血液を用いた実験では、造影剤濃度の高い領域が管壁を伝いらせん状に回転しながら流れていた。血液を想定した解析では狭窄率が高い場合に噴流が軸中央を外れ管壁を伝う様子が観測され傾向は一致したが、拡散に伴う濃度勾配の定量的な一致には課題が残った。

キーワード：造影剤，狭窄柔軟管，流体構造連成解析，TAG，X 線単純投影

1. 緒言

日本人の死因の多くを占めるものとして、心筋梗塞が挙げられる。この病気は、冠動脈に狭窄病変が起り、心臓壁が壊死することで発生する。心筋梗塞の適切な治療方法を選択するためには、狭窄の機能的重症度を正確に評価する必要がある。現在基本となっている評価方法として、心臓カテーテル検査が挙げられる。これは、血管にカテーテルを挿入し狭窄部前後の圧力を計測してその比 FFR (Fractional Flow Reserve) を取ることで、狭窄の程度を評価する方法である。この方法では、精度の高い評価を期待できる[1]が、侵襲性を伴うという点で問題がある。そこで、低侵襲で簡易な方法として、CT 画像の CT 値の勾配から狭窄率を推定する TAG (Transluminal Attenuation Gradient) や、

CCTA (Coronary Computed Tomography Angiography) で得た形状データをもとに数値解析をすることで狭窄病変のある冠動脈の入り口の圧力と狭窄より下流の圧力の比 FFR を推定することで狭窄による虚血の程度を評価する FFR-CT などの方法が考案されている[2]が、計算負荷や精度の観点では問題がある。そのため、CT 画像から狭窄の機能的重症度を評価する際の計算負荷の軽減および精度の向上が求められている。

解析による狭窄の度合いの評価としては、実測した FFR に対する精度は CCTA のみから評価するより CCTA を数値解析した FFR-CT から評価する方が良いとされている[3]。そこで、FFR-CT からのアプローチとして、Yoon らの論文が挙げられる[4]。この論文によると、侵襲的な方法で実測した FFR に対し、FFR-CT は感度 81%、特異度 94%と良い結果が得られているが、モデリングの手間や人的労力がかかることが問題である [2]。そこで、より計算負荷の小さい方法として TAG が注目されている。TAG につ

*1 東京大学大学院工学系研究科機械工学専攻

[〒113-8656 東京都文京区本郷 7-3-1]

いては、Wong らによると実測した FFR に対し 320 列 CT を用いた TAG は感度 77%、特異度 74%と FFR-CT には劣るが近い値となっている [5]。しかし、この値について流体力学の見地からの説明は不十分であり、狭窄と TAG 値の関係は不明である。

当研究室では、狭窄と TAG 値の関係の考察のため、流体構造連成解析と造影剤動態の解析を行ってきた。流体構造連成解析については、冠動脈を想定した分岐システムモデルにおいて、実験との比較により流量や圧力の計算結果について妥当性を確認した [6]。一方、造影剤動態の解析の妥当性確認も必要であるが、狭窄のある管における造影剤動態を撮影する実験は行われてこなかった。本研究では、柔軟管の狭窄が造影剤動態に与える影響を明らかにするため、狭窄血管を模擬した狭窄のある柔軟管を用いて造影剤動態を撮影する実験を行った。また、現象を明らかにするため、実験を模した流体構造連成解析を行った。

2. 手法

2-1. 実験手法

現象解明およびシミュレーションの妥当性確認のため、血管を模擬した狭窄柔軟管を用いた実験を行った。本研究では、狭窄のある冠動脈を想定し、以下の図 1 のような装置を組んだ。流体がポンプから吐出され、狭窄管を通して容器へ排出される。流路にはシリコンチューブを用い、圧力計 (KEYENCE, AP-12S) および流量計 (KEYENCE, FD-XS8) を図 1 に示す配置で設置した。流量計は校正が必要であり、予め流量計の値と実際の流量の関係調べた。ポンプにはギアポンプ (ツカサ電工, TG-85E-PU-DB4-KA, 24V) を用い、直流可変電源 (テクシオ, PFR-100L50) からポンプに印加する電圧を変化させることで、柔軟管入口の圧力変化を制御した。造影剤はポンプの直後に作った分岐からインジェクタを用いて注入した。

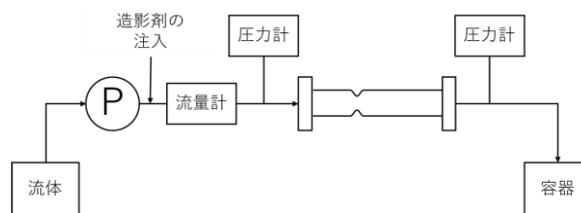


図 1 実験装置の概略図

流体には、水およびブタの血液を用いた。柔軟管には、流体に水を用いた実験では内径 3 mm、外径 5 mm、厚さ 1 mm、長さ 70 mm のシリコンゴム製のゴム管 (ヤング率 0.3 MPa) に、流体入口側から 26 mm の位置に釣り糸を縛って狭窄を作ったものを用いた。また、流体に血液を用いた実験では、内径 3 mm、外径 5 mm、厚さ 1 mm、長さ 60 mm のポリビニルアルコール製の柔軟管 (水で濡れている状態でヤング率 0.1 MPa) に、流体入口側から 24 mm の位置に釣り糸を縛って狭窄を作ったものを用いた。流れの時間変化の条件については、ポンプに印加する電圧を一定にした定常流の条件および 1 Hz、duty 比 50 % で矩形波状に変化させた拍動流の条件とした。

造影剤の撮像には X 線循環器診断システム (キャノンメディカル, Infinix Celeve-i INFX-8000C) を使用した。この装置では、30 fps で透過画像を取得可能であり、また静止物であれば 3 次元再構築が可能である。

2-2. 解析手法

血管を模擬した柔軟管は柔らかいため、流体力によって変形する。一方、管が変形すれば、流体の流れの境界条件が変わるため、影響を受ける。そのため、柔軟管内の流れ場の解析を行うためには、このような流体と構造体の相互作用を考慮した流体構造連成解析が必要である。本研究では、先行研究 [6] にて開発された ALE 有限要素法による一体型流体構造連成解析プログラムを用いた。その支配方程式は、流体領域では連続の式 (1) と Navier-Stokes 方程式 (2)、構造領域では平衡方程式 (3) である。

$$\frac{\partial v_i}{\partial x_i} = 0 \quad (1)$$

$$\rho_f \left\{ \frac{\partial \mathbf{v}}{\partial t} \Big|_x + (v_i - \hat{v}_i) \frac{\partial \mathbf{v}}{\partial x_i} \right\} = \nabla_x \cdot \mathbf{T}_f \quad (2)$$

$$\rho_{0s} \left(\frac{\partial^2 \mathbf{u}}{\partial t^2} \Big|_x \right) = \nabla_x \cdot (\mathbf{S} \cdot \mathbf{F}^T) + \rho_{0s} \mathbf{g} \quad (3)$$

ここで、 x は Euler 座標、 X は Lagrange 座標、 \varkappa は ALE 座標、 v は流速、 \hat{v} は ALE 座標の Euler 座標に対する速度、 u は変位、 ρ_f は流体の密度、 ρ_{0s} は固体の基準配置での密度、 \mathbf{T} は Cauchy 応力テンソル、 \mathbf{S} は第 2Piola-Kirchhoff 応力テンソル、 \mathbf{F} は変形勾配テンソルである。流入口、流出口において単純に自然境界条件を与えると、流速の乱れなどを生じ解析が困難になるため、境界面の流速と圧力は代表流速、代表圧力とそれぞれそのプロファイル関数で表している。

造影剤動態の解析では、Particle-trace 解析を用いた。これは、造影剤動態の解析を高い精度で行うためには、造影剤の移流と拡散の両方を考慮した移流拡散方程式を解くべきであるが、本研究においては、造影剤動態は流体の流れ場に影響を及ぼさず、造影剤の移動は拡散効果に比べ移流効果が支配的であると考えられるためである。

解析モデルには、図 2 のような管を用いた。実験における柔軟管のうち取り付け治具の部分を除いたものを想定し、内径 3 mm、外径 5 mm、長さ 60 mm、ヤング率 0.3 MPa、ポアソン比 0.45、密度 $9.7 \times 10^2 \text{ kg/m}^3$ とした。狭窄部は、先行研究 [6][7]でも使用されている、上流から 17 mm～23 mm の間に \cos カーブで表現されたものとした。流体の物性値は、水を想定したものでは密度 $9.982 \times 10^2 \text{ kg/m}^3$ 、粘性係数 0.001 とし、血液を想定したものでは密度 $1.055 \times 10^3 \text{ kg/m}^3$ 、粘性係数 0.0038 とした。



図 2 解析モデル

3. 結果と考察

3-1. 実験結果

X 線循環器診断システムを用いて実験に用いた柔軟管の 3D 画像を撮影した。シリコンゴム製のゴム管の面積狭窄率は 74%，ポリビニルア

ルコール製の柔軟管の面積狭窄率は 78 %だと分かった。

まず、流体に水を用い上流圧力が 5 kPa の定常流の条件とした実験について、造影剤が流れ始めてから 0.5 秒後の撮影結果を示す。なお、時刻は造影剤濃度が徐々に上がっている途中の時刻を選んだ。

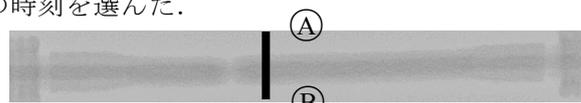


図 3 水の定常流での造影剤濃度勾配

この結果から、狭窄後において造影剤は管全体に均等に広がっていたことが分かった。以下に管軸に垂直な方向の造影剤濃度勾配を示す。これは、撮影結果から上図の AB 線上（幅 5 ピクセル）の明度を取得し、流体の流れていない部分から単位厚さ当たりの柔軟管による明度変化を計算して、流体の流れている部分の明度変化から柔軟管による影響を除いた後、流体部の単位厚さ当たりの明度変化を計算したものである。「位置」とは、管軸を 0 として管軸に垂直な方向に撮影結果の下方向を正とした軸である。また、直線でこの断面における平均値を示している。

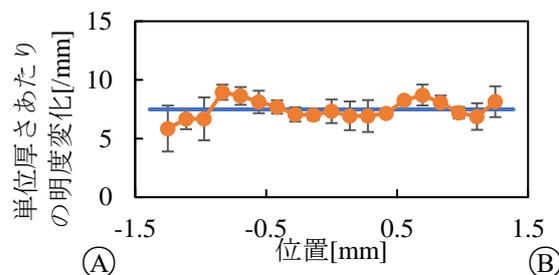


図 4 水の定常流での狭窄後の造影剤濃度勾配

平均値は 7.5 /mm だった。

次に、上流圧力が 0～6 kPa 拍動流の条件での実験について、造影剤が流れ始めてから 1.2 秒後の撮影結果および管軸に垂直な方向の造影剤濃度勾配を示す。

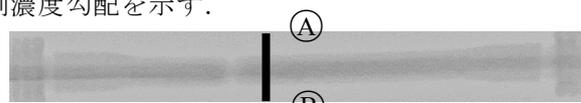


図 5 水の拍動流での造影剤濃度勾配

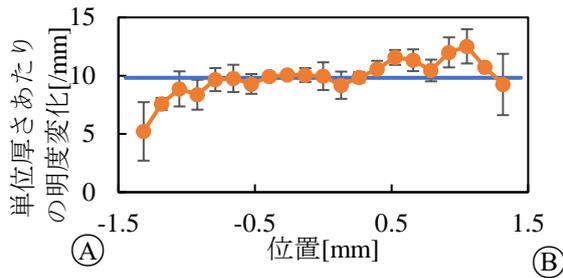


図6 水の拍動流での狭窄後の造影剤濃度勾配

平均値は 9.8/mm だった。拍動流においても、狭窄後において造影剤は管全体に様に広がっていたことが分かった。

次に、流体に血液を用い上流圧力が 20 kPa 定常流の条件とした実験について、造影剤が流れ始めてから 1.5 秒後の撮影結果および管軸に垂直な方向の造影剤濃度勾配を示す。

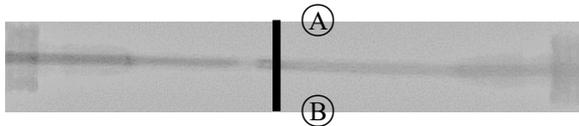


図7 血液の定常流での造影剤濃度勾配

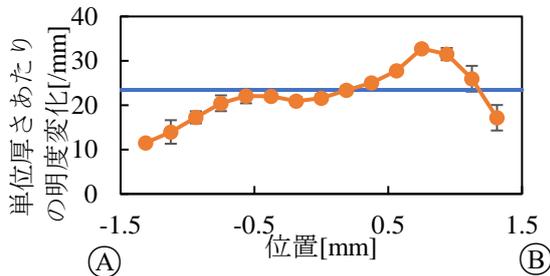


図8 血液の定常流での狭窄後の造影剤濃度勾配

平均値は 23.4/mm だった。血液を用いた実験では、狭窄後の造影剤は管壁付近が濃くなっていることが分かった。明度を測定した地点より後ろでは、造影剤濃度の高い領域がらせん状に回転しながら流れていた。

3-2. 流体構造連成解析

流体が水で定常流を想定した解析を、入口・出口圧力と流量について実験と比較すると、以下の図のようになった。

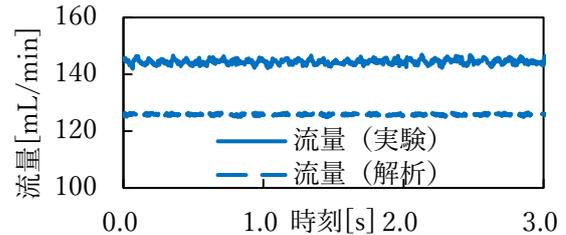
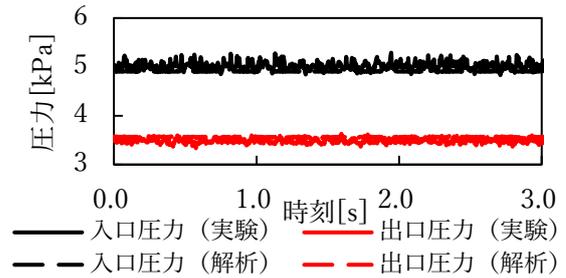


図9 実験と解析の圧力・流量の比較

図9より、圧力については概ね一致しているものの流量は差があり、定量的な一致には課題が残った。解析モデルは実験で用いた柔軟管と狭窄部の形状が異なり、それが影響している可能性がある。

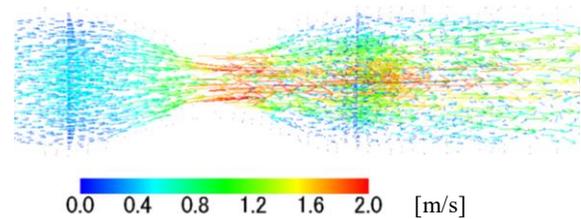


図10 狭窄部付近の流速ベクトル可視化 (水)

図10は狭窄部付近の流速ベクトルを大きさに比例した矢印で可視化したものである。狭窄後は流体が管全体に広がる流れになっていたと考えられる。

一方、流体を血液と想定した 5 kPa 定常流の解析では、解析の狭窄率を 95% とすると圧力損失が実験と一致した。この狭窄率の解析での流速ベクトルは以下の図のようになった。

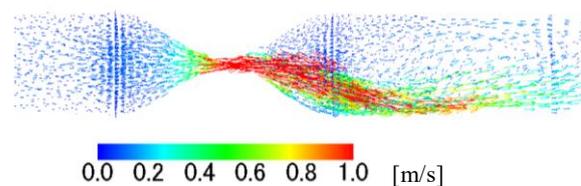


図11 狭窄部付近の流速ベクトル可視化 (血液)

狭窄後に管壁を伝う噴流は、造影剤の濃い領

域に相当している可能性がある。しかし、血球が影響している可能性も考えられるので、原因の特定には更なる実験が必要である。

3-3. 造影剤動態の解析結果

流体を水とし定常流を想定した造影剤動態解析の結果のうち、狭窄部付近を図 12 に示す。



図 12 水の定常流におけるパーティクルの分布

図 10 と図 12 を併せ考えると、狭窄後に造影剤は管全体に広がっているという解析結果であり、実験と一致する傾向が得られた。

4. 結言

狭窄柔軟管に水及び血液を流し造影剤動態を撮影する実験とそれを模した流体構造連成解析及びパーティクルトレース解析を行った。実験では、流体が水るとき狭窄後の造影剤は管全体に拡散したが、血液のときは造影剤濃度の高い領域が管壁を伝ってらせん状に流れるという違いがあった。解析については、血液かつ定常流の条件において狭窄後に噴流が管壁を伝っており定性的には一致したが、定量的な一致には課題が残った。

謝辞

実験においてご協力を賜った東京大学医学部附属病院の月原弘之先生、井野賢司先生、東京大学大学院工学系研究科の藤澤彩乃先生に心より感謝いたします。本研究は JSPS 科研費 15K17932 の助成を受けたものです。

利益相反の有無

なし

文献

[1] P.Tonino, B.D.Bruyne, N.Pijls, et al.: Fractional Flow Reserve versus Angiography for Guiding Percutaneous Coronary Intervention. The NEW

ENGLAND JOURNAL of MEDICINE, Vol.360, No.3: 213-224, 2009

- [2] A. J. Einstein: TAG-Is It It? Improving Coronary Computed Tomography Angiography With the Isotemporal Transluminal Contrast Attenuation Gradient. Journal of the American College of Cardiology, Vol.61, No.12: 1280-1282, 2013
- [3] B.-K. Koo, A. Erglis, J.-H. Doh, et al.: Diagnosis of Ischemia-Causing Coronary Stenoses by Noninvasive Fractional Flow Reserve Computed From Coronary Computed Tomographic Angiograms. Journal of the American College of Cardiology, Vol.58, No.19: 1989-1997, 2011
- [4] Y. E.Yoon, J. -H. Choi, J. -H. Kim, et al.: Noninvasive Diagnosis of Ischemia-Causing Coronary Stenosis Using CT Angiography. CARDIOVASCULAR IMAGING, Vol.5, No.11: 1088-1097, 2012
- [5] D. T. Wong, B. Ko, J. Cameron, et al.: Transluminal Attenuation Gradient in Coronary Computed Tomography Angiography Is a Novel Noninvasive Approach to the Identification of Functionally Significant Coronary Artery Stenosis. Journal of the American College of Cardiology, Vol.61, No.12: 1271-1279, 2013
- [6] 波田野明日可, 住吉谷淳, 鈴木一真 他: 分岐狭窄柔軟ファントム実験と ALE 流体構造連成解析による造影剤動態解明. 日本機械学会論文集, Vol.84, No.863 : 1-12, 2018
- [7] S. A. Ahmed , D. P. Giddens: Pulsatile poststenotic flow studies with laser Doppler anemometry. Journal of biomechanics, Vol.17, No.9: 695-705, 1984

X-ray projection and fluid structure interaction analysis of contrast agent dynamics through an elastic stenosis

Ryotaro KANEKO*1, So TAKAMOTO*1, Asuka HATANO*1, Satochi IZUMI*1

*1 The University of Tokyo

Transluminal attenuation gradient (TAG) is one of noninvasive assessments of the functional significance of a stenosis and its diagnostic performance should be improved for practical use. TAG is the gradient of contrast from the ostium when contrast agent first passes; therefore, diffusion of contrast agent at downstream of a stenosis can affect the diagnostic performance. In this study, the diffusion of the contrast agent in fluid flowing through a flexible tube simulating a stenotic blood vessel was radiographed. Water or blood was used as the fluid, flowing under steady flow or pulsatile flow condition. ALE fluid-structure interaction finite element simulation was also conducted in order to estimate flow distribution. In the experiment using water under steady flow condition, the contrast agent diffused uniformly over the entire tube at downstream of the stenosis. On the other hand, in the experiment using blood under steady flow condition, the contrast agent flowed helically along the tube wall. The simulation with blood showed the jet flowed off the center and along the tube wall when the narrowing rate was high, which agreed the experiment. However, concentration gradients associated with diffusion did not agree quantitatively.

Key words: Contrast agent, Flexible tube, Fluid-structure interaction, Stenotic flow, X-ray projection

著者紹介



金子 凌太朗 (かねこ りょうたろう)
2019年東京大・工学部・機械工学科卒。現在、東京大大学院修士課程・工学系研究科・機械工学専攻・1年。



高本 聡 (たかもと そう)
2012年東京大・工学部・機械情報工学科卒。2017年同大大学院博士課程・工学系研究科・機械工学専攻了。現在、東京大・工学系研究科・機械工学専攻・助教。



波田野 明日可 (はたの あすか)
2007年東京大・工学部・機械工学科卒。2012年同大大学院博士課程・新領域創成科学研究科・人間環境学専攻了。現在、東京大・工学系研究科・機械工学専攻・講師。



泉 聡志 (いずみ さとし)
1994年東京大大学院・工学系研究科・機械情報工学専攻了。現在、東京大・工学系研究科・機械工学専攻・教授。

Classification of histological subtypes of NSCLC using Coxnet and NMF

Masahiro YAMADA^{*1}, Hidetaka ARIMURA^{*2}, Kenta NINOMIYA^{*1}

Abstract

Histological classification of non-small cell lung cancer (NSCLC) affects the decision making of treatment policies. However, histological subtypes, i.e. adenocarcinoma (AC) and squamous cell carcinoma (SCC), identified from a single biopsy occasionally differ from actual subtypes decided by surgical resections for NSCLC. We aim to explore classification approaches of histological subtypes of NSCLC using three support vector machines (SVMs) with radiomic signature sets (sets of significant image features) determined by Coxnet and non-negative matrix factorization (NMF). Classification models of Gaussian, linear and polynomial SVMs constructed with radiomic signatures achieved the areas under the curves (AUCs) of 0.7021, 0.6803, 0.7131 using Coxnet, and 0.7128, 0.6660, 0.7143 using NMF, respectively. The polynomial SVM with the radiomic signature determined by NMF could more correctly classify histological subtypes of NSCLC into AC and SCC.

Keywords: Histological subtypes, Radiomics, Classification, NSCLC, SVM

1. Introduction

The most common histological subtypes of non-small cell lung cancer (NSCLC) are adenocarcinoma (AC), squamous cell carcinoma (SCC) and large cell carcinoma (LCC) [1]. AC accounts for 38.5% of all lung cancer, with SCC accounting for 20% and LCC accounting for 2.9% [2]. Histological classification of lung cancer provides important information about tissue characteristics and anatomical location [3], which is utilized for determination of treatment policies [4].

The recent advancements in the therapy for lung cancer are discovery of targetable mutations for molecular targeted drugs and development of histology-based therapeutic regimen selection [4,5].

In clinical practice, the most common way of classifying histological subtypes is the biopsy, in which specimens are sampled. This method is clinically limited by the invasive procedures as well as prolonged time and cost efficiency [5]. Furthermore, histological subtypes identified from specimens sampled by the single biopsy occasionally differ from those from surgical resection [6].

Radiomics based on medical images, which are routinely acquired in noninvasive, lower cost and fast way, has been proposed [7]. For increasing the classification accuracy in the biopsy or without the biopsy, we aim to develop an automated approach for classifying histological subtypes of NSCLC using support vector machines (SVMs) with radiomic features.

*1 Department of Health Sciences, Faculty of Medical Sciences, Kyushu University [3-1-1 Maidashi, Higashi-ku, Fukuoka, 812-8582, Japan]
e-mail: masahiro19940622@gmail.com

*2 Department of Health Sciences, Graduate School of Medical Sciences, Kyushu University

2. Materials and frameworks

2.1. Clinical cases

Computed tomography (CT) images of 205 lung cancer patients (male: 152, female: 53, age: 43-87 (mean: 69)) were selected from the datasets of NSCLC-Radiomics and NSCLC-Radiogenomics in The Cancer Imaging Archive (TCIA) database [8]. The patients were categorized into two histological subtypes of AC ($n=103$) and SCC ($n=102$), and into four overall stages I ($n=80$, 39.0%), II ($n=45$, 22.0%), III A ($n=43$, 21.0%) and III B ($n=37$, 18.0%). The CT images of NSCLC-Radiomics were acquired with a scanner (SOMATOM Sensation-16, Siemens), with an in-plane pixel size of 0.98×0.98 mm², a slice thickness of 3 mm and 16-bit gray levels. The patients of NSCLC-Radiomics data treated with radiotherapy or chemoradiotherapy. The CT images of NSCLC-Radiogenomics were acquired with several CT machines, with in-plane pixel sizes of 0.6-1.37 mm, slice thicknesses of 0.63-7.00 mm and 16-bit gray levels.

2.2. Overall procedure

Figure 1 shows an overall procedure of our proposed approach.

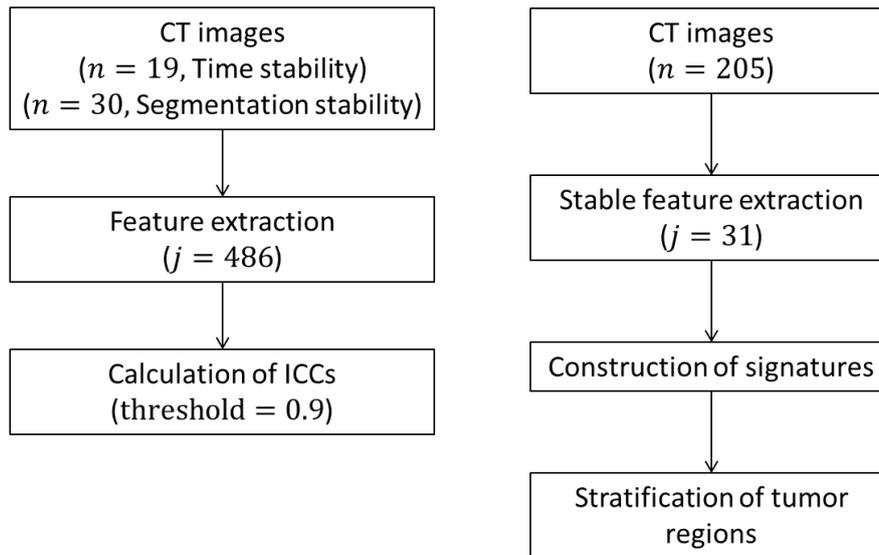


Fig. 1. An overall procedure of our proposed approach. A left flow shows the calculation of ICCs of radiomic features. A right flow shows the stratification of tumor regions into AC and SCC.

In the first step, we calculated intraclass correlation coefficients (ICCs) of radiomic features which were extracted from CT images.

In the second step, high stability features were extracted from CT images ($n = 205$) of NSCLC, and we constructed signatures using Coxnet and NMF (non-negative matrix factorization). Finally, the areas under the curves (AUCs) were evaluated to investigate the most appropriate kernel function in SVMs.

2.3. Feature extraction

In this study, 486 radiomic features which included statistical features, texture features and wavelet features, were calculated. Statistical features describe the image histograms within GTV (gross tumor

volume). Texture features were derived from gray-level co-occurrence matrix (GLCM) [9], gray-level run length matrix (GLRLM) [10], gray-level size zone matrix (GLSZM) and neighborhood gray-tone difference matrix (NGTDM). Wavelet features were extracted on the images which were transformed by coiflet wavelet function at three dimensions. These features were computed in MATLAB 2015b.

2.4. Assessment of stability features

Thirty-one stable radiomic features were selected by calculating ICCs using RIDER dataset and multiple delineation dataset [8,11]. We used 19 patients in RIDER dataset to assess stable features between the test and the retest scans, and 30 patients in RIDER, LIDC-IDRI and QIN-Lung-CT datasets [8] to evaluate the stability of radiomic features against variation in manual delineations which nine oncologists delineated. The ICC is a statistical measure that assesses the degree of agreement (consistency) [12]. In our study, the multiplication of the ICCs of temporal and multisegmentation (mICC) are calculated as

$$\text{mICC} = \overline{\text{ICC}}_{\text{temporal}} \times \overline{\text{ICC}}_{\text{segmentation}} \quad (1)$$

where $\overline{\text{ICC}}_{\text{temporal}}$ and $\overline{\text{ICC}}_{\text{segmentation}}$ indicate the mean ICC (Eq. (2)) computed for the features of temporal stability and multisegmentation stability, respectively. The mean ICCs for each feature across the whole dataset were calculated by

$$\overline{\text{ICC}}_j = \frac{1}{M} \sum_{k=1}^M \text{ICC}_{j,k} \quad (2)$$

where $j (= 1, \dots, M)$ is the feature number, N is the number of radiomic features, $k (= 1, \dots, M)$ is the patient number and M is the number of patients. Following the classification of the ICC [13], features with higher agreement (i.e. $\overline{\text{ICC}} \geq 0.9$) were considered high-stability features, whereas features with lower agreement (i.e. $0 \leq \overline{\text{ICC}} < 0.9$) were considered low-stability features. Consequently, features with $\text{mICC} \geq 0.81$ were considered high-stability features. The ICC was calculated by using the IRR package in R Ver. 3.4.1 [14].

2.5 Feature selection

2.5.1 Coxnet algorithm

Simon et al studied the relationship between predictor variables and survival time, and developed the Coxnet algorithm [15,16]. The Cox proportional hazard model $h_i(t|\mathbf{x}_i)$ for a patient i at a time t can be expressed by

$$h_i(t|\mathbf{x}_i) = h_0(t)e^{\beta^T \mathbf{x}_i} \quad (3)$$

The Lagrangian formulation is constructed as follows

$$\hat{\beta} = \underset{\beta}{\operatorname{argmax}}[kl(\beta) - \lambda P_{\alpha}(\beta)] \quad (4)$$

where

$$l(\beta) = \sum_{i=1}^n d_i \left\{ \beta^T x_i - \ln \left(\sum_{t_j \geq t_i} e^{\beta^T x_j} \right) \right\}$$

$$P_{\alpha}(\beta) = \alpha \|\beta\|_1 + \frac{1-\alpha}{2} \|\beta\|_2^2$$

$$d_i = \begin{cases} 1, & \text{event occurred at } t_i \\ 0, & \text{censored at } t_i \end{cases}$$

and i, j are the patient number, x is the feature vector, β is the coefficient vector, $h_0(t)$ is the baseline hazard function, t_i, t_j are the survival time of a patient i, j ($t_i \leq t_j$), k is the scaling factor, λ is the Lagrangian multiplier and α ($0 \leq \alpha \leq 1$) is a blending parameter.

2.5.2 NMF algorithm

Non-negative matrix factorization (NMF) aims to obtain a linear representation of multivariate data under nonnegativity constrains. These constraints lead to a part-based representation because only additive, without any subtractions, combinations of the original data are allowed [17]. Given a positive matrix X of size $N \times M$ and desired rank K (number of bases), the NMF algorithm iteratively computes an approximation

$$X \sim WH \quad (5)$$

subject to $w_{ik} \geq 0, h_{kj} \geq 0$

where X is the data, W is the basis matrix with elements w_{ik} (i is the feature number, k is the rank number), H is the coefficient matrix with elements h_{kj} (j is the patient number), N is the number of features and M is the number of patients. W and H are nonnegative matrices with respective sizes $N \times K$ and $K \times M$.

3. Results

3.1 Feature selection

In this study, the parameter $\alpha = 1$ (LASSO penalty) was used in Coxnet and performed a 10-folds cross validation method to decide the Lagrangian multiplier λ . An optimal λ was determined at the point of minimum mean cross validation error. Five significant features (LHL_RLN, LHL_SZE, HLH_Strength, LHH_SZE and HHH_Strength) with non-zero coefficients were selected as a radiomic signature.

In NMF, the rank k was decided with considering about RSS (residual sum of squares) curve. The RSS curve had been adopted to determine the optimal rank k from 6. Five significant features (HLL_Busyness, LHL_LRE, LHL_Busyness, HHH_Busyness and HHH_Strength), which were the highest magnitude of basis matrix W , were selected.

3.2 Stratification of tumor regions

SVMs were used for classifying histological subtypes of NSCLC in this study. We used three kernel functions; Gaussian, linear and polynomial. Optimal parameters were decided in each kernel function. Figure 2 shows the ROC curves using a signature of Coxnet (left) and NMF (right).

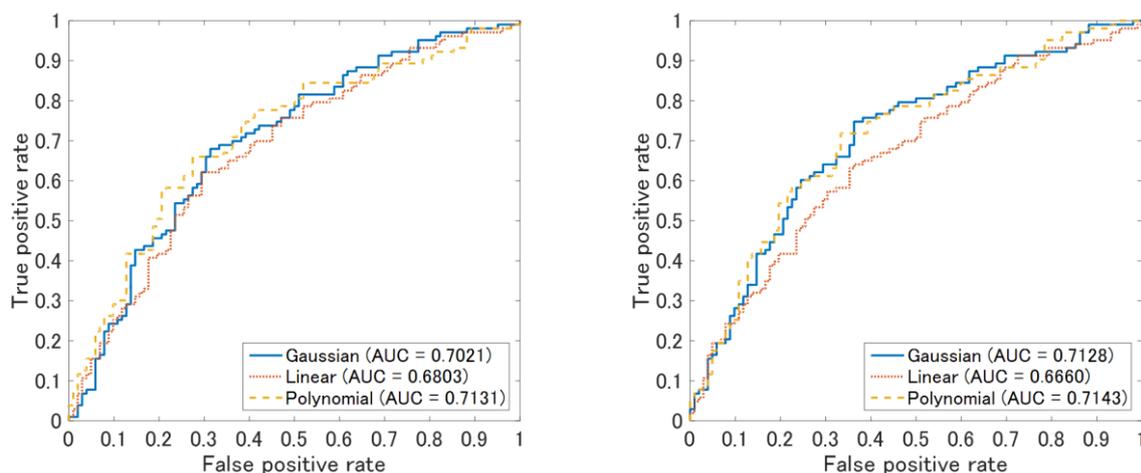


Fig. 2. ROC curves using a signature of Coxnet (left) and NMF (right).

Classification models of Gaussian (G), linear (L) and polynomial (P) SVMs achieved AUCs of 0.7021 (G, sigma : 1.19), 0.6803 (L, slope : 0.5, intercept : 5), 0.7131 (P, slope :0.5, intercept : 380, dimension : 5) using Coxnet, and 0.7128 (G, sigma : 1.26), 0.6660 (L, slope : 1.2, intercept : 335), 0.7143 (P, slope : 0.15, intercept : 140, dimension : 9) using NMF, respectively.

4. Discussion and conclusion

An emerging field radiomic quantifies phenotypic characteristic of tumor tissues using medical images. In this study, we investigated the association of radiomic features and histological subtypes of NSCLC and achieved relatively higher prediction accuracy, especially when using polynomial functions.

According to Matsuda et al, the true diagnosis of histological subtypes of lung cancer cannot be made of a small biopsy fragment, because of the lack of cell differentiation [18]. Our study, which is classification of histological subtype using image features, might be useful for not only increasing the classification accuracy but also patients who do not prefer a biopsy.

The performance of classifiers can be enhanced if we incorporate the clinical information like tumor grade, location, smoking history and obesity [19]. For example, a recent study showed body mass index was inversely associated with SCC, and the association was positive for AC [20].

In conclusion, histological subtypes of NSCLC could be classified into AC and SCC using a polynomial support vector machine with radiomic features.

Acknowledgement

The authors would like to express their appreciation to all of members of the Arimura laboratory who provided precious comments and advices for this study.

Conflict of interests

The authors do not have any conflict of interests to disclose.

References

- [1] Travis WD, "Pathology of lung cancer." *Clin Chest Med*, 32(4):669-92 (2011).
- [2] Charles S, Lynn T, Richard A, "Lung Cancer: Epidemiology, Etiology and Prevention." *Clin Chest Med*, 23(1):1-25 (2002).
- [3] Wu W, Parmar C, Grossmann P et al, "Exploratory Study to Identify Radiomics Classifiers for Lung Cancer Histology." *Front Oncol*, 30;6:71 (2016).
- [4] Manegold C, "Treatment algorithm in 2014 for advanced non-small cell lung cancer: Therapy selection by tumour histology and molecular biology." *Adv Med*, 59(2):308-13 (2014).
- [5] Cufer T, Ovcaricek T, O'Brien ME, "Systemic therapy of advanced non-small cell lung cancer: major-developments of the last 5-years." *Eur J Cancer*, 49(6):1216-25 (2013).
- [6] Cataluna JJ, Perpina MD, Greses JV et al, "Cell Type Accuracy of Bronchial Biopsy Specimens in Primary Lung Cancer." *Chest*, 109(5):1199-203 (1996).
- [7] Aerts HJ, Velazquez ER, Leijenaar RT et al, "Decoding tumour phenotype by noninvasive imaging using a quantitative radiomics approach." *Nat Commun*, 5:4006 (2014).
- [8] The Cancer Imaging Archive, December 2010, <http://www.cancerimagingarchive.net/>
- [9] Haralick RM, Shanmugan K, Dinstein I, "Texture features for image classification." *IEEE Trans Syst Man Cybern*, 3:610-21 (1973).
- [10] Peto R, Peto J, "Asymptotically efficient rank invariant test procedures" *J R Stat Soc Ser A* 135:185-207 (1972).
- [11] Zhao B, James LP, Moskowitz CS et al, "Evaluating variability in tumor measurements from same-day repeat CT scans of patients with non-small cell lung cancer." *Radiology* 252:263-72 (2009).
- [12] Soufi M, Arimura H, Nakamoto T et al, "Exploration of temporal stability and prognostic power of radiomic features based on electronic portal imaging device images" *Physica Medica*, 46:32-44
- [13] Koo Tk, Li MY, "A Guideline of Selecting and Reporting Intraclass Correlation Coefficients for Reliability Research." *J Chiropr Med*, 15(2):155-63 (2016).
- [14] Gamer M, Lemon J, Fellows I, et al, "irr: Various Coefficients of Interrater Reliability and Agreement." , <https://www.r-project.org>
- [15] Simon N, Friedman H, Hastie T et al, "Regularization Paths for Cox's Proportional Hazards Model via Coordinate Descent." *Journal of Statistical Software*, 39(5):1-13 (2011).
- [16] Mazen S, Arimura H, Nagami N, "Identification of optimal mother wavelets in survival prediction of lung cancer patients using wavelet decomposition-based radiomic features." *Medical Physics*, 45(11):5116-28 (2018).
- [17] Zdunek R, Cichocki, "Nonnegative matrix factorization with constrained second-order optimization." *Signal Processing*, 87(8):1904-16 (2007).
- [18] Matsuda M, Horai T, Nakamura S et al, "Bronchial brushing and bronchial biopsy: comparison of diagnostic accuracy and cell typing reliability in lung cancer." *Thorax* 41(6):475-78 (1986).
- [19] Bufill JA "Colorectal cancer: evidence for distinct genetic pathways based on proximal or distal tumor location." *Ann Intern Med*, 15;113(10):779-88 (1990).
- [20] Zein EI M, Parent ME, Nicolau B et al, "Body mass index, lifetime smoking intensity and lung cancer risk." *Int J Cancer*, 1;133(7):1721-31 (2013).

CNN を用いた CAD 開発における段階的学習法の提案

安倍 和弥*¹ 武尾 英哉*¹ 永井 優一*² 縄野 繁*³

要旨

近年, CAD の研究分野にも CNN が積極的に用いられるようになった. 一般的に, 機械学習には様々なバリエーションを有する症例画像を網羅的に与えて学習することで, 汎用的で高性能な判別器を設計する. しかし, CNN の学習データを構成する中で, データを一様に与えるのではなく, 複数のサブセットに分け, その比率を調整することで効果的な学習ができる可能性が確認できた. 本論では, このサブセットを使用して CNN の学習を段階的に繰り返し行う学習法について提案する.

本研究では, 乳がん腫瘍の学習データを腫瘍の大きさと濃淡をもとに個々のサブセットを作成し, 学習した CNN を評価用として複数用意したデータセットを用いて最適比率を検討し, 実際の未知データで性能評価を行う. そして, 評価データで検出ミスの多かったサブセットの比率を上げて再学習を行う. これを AUC の上昇が見られる間複数回繰り返し, 性能の高い CNN を設計した. この CNN を未知データへ適用した結果, 単純に網羅的に学習データを与えた CNN と比べて AUC が高いことが確認でき, 本学習法の有効性が確認できた. また, 本学習法を肝腫瘍にも適用したところ, 同様の結果が得られ, この学習法の汎化性も確認できた.

キーワード: CNN, CAD, 学習法, 乳がん腫瘍, 肝腫瘍

1. はじめに

近年, 医療の現場では CT や MRI など撮影装置の高精細化により生成される医用画像の量が増大している. 撮影される画像の枚数は患者一人あたり数百枚にもおよび, それを読影する医師の負担も急増している. そのため診断の補助を行うコンピュータ画像支援診断 (Computer Aided Diagnosis/Detection: CAD) の開発が非常に重要視されている.

その CAD の研究分野においても人工知能, AI を用いた研究が進められている. その中でも画像認識手法である CNN (Convolutional Neural Network) は積極的に用いられるようになった

[1]. 一般的に, 機械学習には様々なバリエーションを持った症例画像を網羅的に与えて学習を行うことで, 汎用的で高性能な判別器を設計する. これは, 学習に含まれていない画像はうまく検出ができないと考えられるからである. しかし, CNN の学習データを構成する中で, データを一様に与えるのではなく, 複数のサブセットに分け, その比率を調整することで効果的な学習ができる可能性が確認できた. 本論では, このサブセットを使用して CNN の学習を段階的に繰り返し行う学習法について提案する.

CNN を用いた乳がん腫瘍影の検出は Almasni ら[2,3]や Tan ら[4]などが行っている. また, CNN を用いた肝腫瘍 (肝臓がん) の検出は近藤ら[5]が行っている. しかし, これらは学習データについては網羅的に与える手法をとっており, 与える学習データの内容について精査してはいない.

CNN の課題として, 有効ではない画像が含まれると性能が低下する問題がある. これに対しサブセットを作成して段階的に学習を行うこ

*1 神奈川工科大学工学部電気電子情報工学科

[〒243-0292 厚木市下荻野 1030]

e-mail: abex0930@ele.kanagawa-it.ac.jp

*2 国立がん研究センター東病院

*3 国際医療福祉大学三田病院

とにより、無作為に画像を与えた場合に比べて有効な画像群を優先して用いることが可能となり判別精度の向上が期待できる。

本論文のポイントを以下に示す。

- ① 段階的学習法の提案
- ② 提案システムの乳がん腫瘍への適用
- ③ 汎化性確認のため同手法の肝腫瘍への適用

本論文では、2章で段階的学習法の手法について、3章で提案学習法での検出性能の推移を示す。4章にて考察、5章にて本研究のまとめについて述べる。

	サイズ		
	小	大	
濃 ↑ コントラスト ↓ 淡	SD	MD	LD
	SM	MM	LM
	SP	MP	LP

図2 分類表

2. 段階的学習法について

2.1 段階的学習法の流れ

提案する段階的学習法の流れを図1に示す。

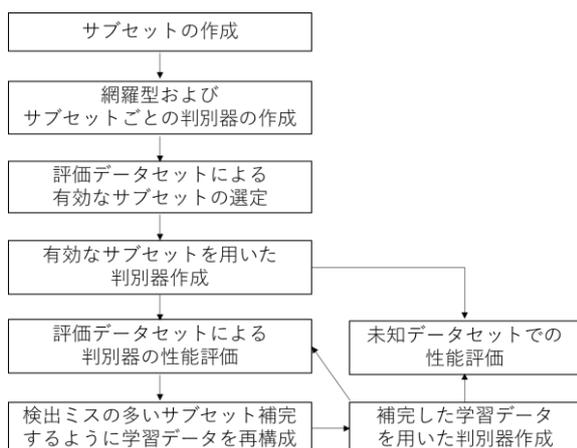


図1 段階的学習法の流れ

2.2 サブセットの作成

乳がん腫瘍、肝腫瘍の症例画像をサイズの大小とコントラストの濃淡を基に9分類に分けサブセットを作成する。分類表を図2に示す。コントラストは腫瘍内部と辺縁での差分とした。

分類表の分類名は、サイズをS・M・L (Small, Middle, Large), コントラストをP・M・D (Pale, Middle, Deep) と分類し頭文字をつなげて表記したものであり、本論では以降この表記で記述を行う。

2.3 乳がん腫瘍 CNN の段階的学習

乳がん腫瘍影判別のCNNはAl-masniらの手法[2]や藤田らの書籍[6]を参考にyolo[7]を用いて作成した。OSはubuntu18.04, cuda9を用いてGPUを利用した学習を行っている。CNNの構成は中間層8層のCNNを用い、転移学習は使用していない。すべての学習においてEpoch数は5000, バッチサイズは64とした。

本論にて使用するyoloでは完全ランダムで画像を選択し学習する。そのため、同様の種類の画像が連続で選択された場合、その種類に特化した判別器になる可能性があり、稀に低性能の判別器が作成される。この問題への対策として、同一の学習データセットにて各3回の学習を行って判別器の作成を行い、判別性能が最高である判別器を使用することとした。

初めに各サブセット単体でのCNNと各サブセットを網羅したCNNを作成する。作成した判別器にて評価データセットを用いて評価を行い、判別性能を求める。評価用データセットには、がん症例100例、非がん症例100例の計200例を用意した。評価にはROCグラフを用いてAUC(ROCグラフの下面積)を算出し、各学習における判別性能を算出する。なお、症例数の関係上、乳がん腫瘍に関してはSP, SM, SDの3つのサブセットは統合し計7つのサブセットにて評価を行った。評価結果でのAUCを表1, 図3に示す。

表1 判別器ごとの AUC(腫瘍)

判別記名	AUC
判別器 S	0.873
判別器 MD	0.550
判別器 MM	0.856
判別器 MP	0.843
判別器 LD	0.811
判別器 LM	0.831
判別器 LP	0.706
判別器 X (網羅)	0.878

		サイズ	
		小	大
コントラスト	濃		
		0.550	0.811
	淡	0.873	0.831
		0.856	0.706

図3 分類表でみる AUC(腫瘍)

サブセット MD において、枚数不足に起因するとみられる極端に低い学習結果が得られたため後の平均 AUC 算出からは除外している。

網羅型である判別器 X 及び MD を除いた判別器の平均 AUC は 0.820 であり、平均より判別性能が高かったのは、サブセット S・MM・MP・LM であった。ただ、サブセット S は複合であるため単独での性能が未知数である。よって、1 段階目の学習は MM・LP・LM の 3 種にて判別器 Y1 の作成を行った。以降は作成する Y 系統の判別器での検出ミスが多いサブセットを加えて、段階的に高性能な判別器作成を行う。追加するサブセットの決定は式(1)にて Score を算出。MM を除き最も有効であるサブセットのみを加えて判別器を組み替える。判別器 Y1 での検出ミス数と Score を図 4 に示す。

$$\text{Score} = (\text{対象サブセットの検出ミス} \times 2) + (\text{周囲 3 サブセットの検出ミス}) \quad (1)$$

		サイズ		
		小		大
コントラスト	濃	4 (19)	4 (16)	1 (12)
		4 (16)	3 (-)	3 (13)
	淡	1 (10)	1 (9)	3 (13)

図4 判別器 Y1 での検出ミス数と Score (カッコ内に Score を記載)

Score より SD を加えて判別器 Y2 を作成する。以降も同様に Score を基に組み換えを行い、AUC が飽和または減少するまでに行い最高性能の判別器を作成する。最終的な評価データセットでの AUC の推移を表 2 に示す。

表2 評価データセットによる段階的学習法の AUC 推移(腫瘍)

判別記名	AUC
判別器 X (網羅)	0.878
判別器 Y1	0.820
判別器 Y2	0.851
判別器 Y3	0.873
判別器 Y4	0.921

表 2 より評価データセットでは判別器 Y4 が最高値となった。また、段階的な判別性能の向上も確認できた。

2.4 肝腫瘍 CNN の段階的学習

汎化性の確認のため、肝腫瘍の CNN も乳がん腫瘍と同様に yolo を用いて作成を行った。サブセットについても乳がん腫瘍と同様にサイズとコントラストを用いて 9 分類し各判別器と網羅型の判別器を作成、式(1)の Score を用いて

段階的に学習を行った。また、肝腫瘍では評価データセットを2種類用意、相互に評価データセットと未知データセットとすることで2通りの判別器にて本学習法の評価を行った。データセットには、がん症例100例、非がん症例100例の計200例を用意した。サブセットごとのAUCを表3に示す。

表3 判別器ごとのAUC(肝腫瘍)

判別記名	評価セット	評価セット
	A AUC	B AUC
判別器SD	0.822	0.824
判別器SM	0.732	0.753
判別器SP	0.846	0.855
判別器MD	0.772	0.769
判別器MM	0.797	0.803
判別器MP	0.834	0.855
判別器LD	0.701	0.699
判別器LM	0.732	0.774
判別器LP	0.846	0.775
判別器X(網羅)	0.825	0.865

セットAでは網羅型である判別器Xを除いた判別器の平均AUCは0.787であり、平均より判別性能が高かったのは、サブセットSD・SP・MM・MP・LPであった。また、セットBでは平均AUCは0.790であり、平均より判別性能が高かったのは、サブセットSD・SP・MM・MPであった。よって、これらより判別器Z1を作成し段階的に学習を行った。評価データセットでのAUCの推移を表4に示す。

表4より評価データセットでは、セットAでは判別器Z2、セットBでは判別器Z4が最高値となった。

表4 評価データセットによる段階的学習法のAUC推移(肝腫瘍)

判別記名	評価セット	評価セット
	A AUC	B AUC
判別器X(網羅)	0.825	0.865
判別器Z1	0.891	0.859
判別器Z2	0.904	0.860
判別器Z3	0.856	0.888
判別器Z4	-	0.907
判別器Z5	-	0.884

3. 未知データでの本学習法による検出性能の推移

3.1 乳がん腫瘍

2.3節にて作成したCNNを未知データセットにて適用し、評価を行った。未知データセットにはがん症例100例と非がん症例100例を用いた。結果を表5に、ROCの推移を図5に示す。

表5 未知データでの判別性能の推移(腫瘍)

判別記名	AUC
判別器X(網羅)	0.840
判別器Y1	0.814
判別器Y2	0.852
判別器Y3	0.858
判別器Y4	0.888

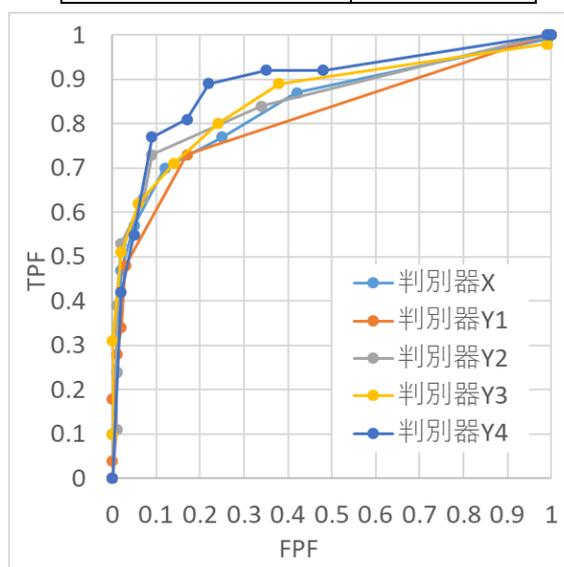


図5 未知データでのROCグラフ(腫瘍)

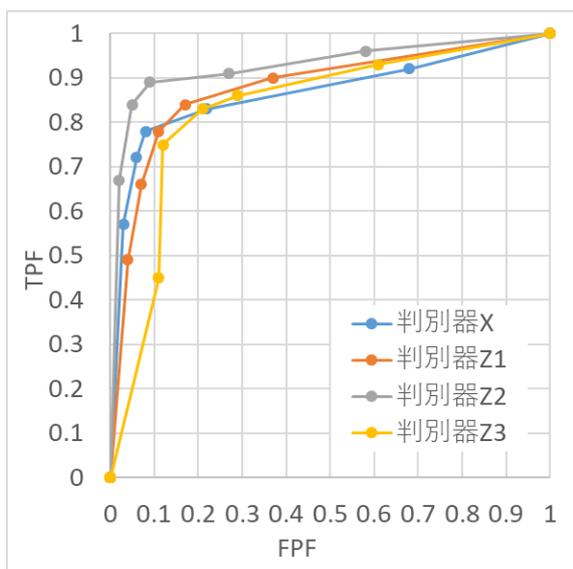
表5、図5より未知データにおいても有意な判別性能の向上が見取れる。網羅型であるXのAUCが0.840に対し、段階型学習法では段階的な性能向上が見られ、最終的に0.888まで増加した。

3.2 肝腫瘍

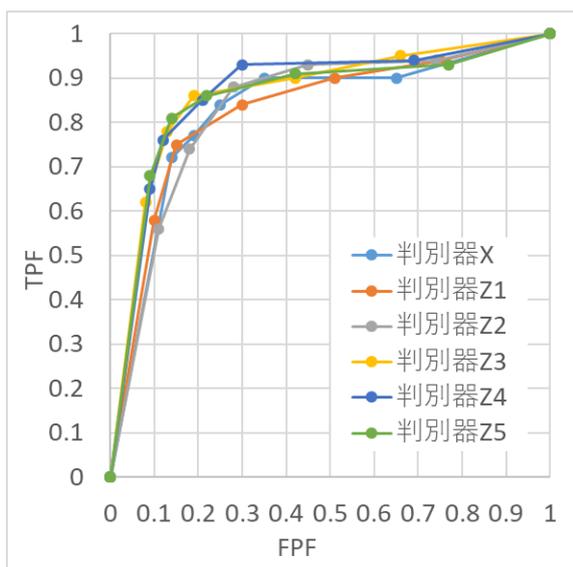
2.4節にて作成したCNNを未知データセットにて適用し、評価を行った。未知データセットにはがん症例100例と非がん症例100例を用いた。結果を表6に、ROCの推移を図6(a)(b)に示す。

表 6 未知データでの判別性能の推移(肝腫瘍)

判別記名	未知セット A AUC	未知セット B AUC
判別器 X(網羅)	0.865	0.825
判別器 Z1	0.877	0.828
判別器 Z2	0.927	0.835
判別器 Z3	0.832	0.865
判別器 Z4	-	0.868
判別器 Z5	-	0.856



(a) 未知セット A の ROC グラフ



(b) 未知セット B の ROC グラフ

図 6 未知データでの ROC グラフ(肝腫瘍)

表 6 及び図 6 より、乳がん腫瘍同様こちらも未知データにおいても有意な判別性能の向上が見取れる。また、未知セット A・B ともに網羅型である X に比べて評価データでの最適値である Z2・Z4 で AUC の最高値を得ており、本学習法の有効性が示唆できた。

4. 考察

2 章の表 2・3 の結果より、サブセットの AUC を基にした学習データセット構築と、Score を用いた弱点補強法が CNN 開発に有効であると確認できた。特に Score を使用しての段階的学習では、従来の網羅型の CNN と同数の学習データでより効率的に学習が行えていることが確認できる。

3 章の評価結果より、段階的学習法を用いることにより、最適化を行った評価データだけでなく最適化を行っていない未知データにおいても性能の向上が確認できた。また、対象により多少ばらつきはあるものの FP 率 10% で 80%~90% の高い TP 率が得られており、医師の正答率が 80%~90% と言われているため同等の性能が得られたといえる。

乳がん腫瘍においてはデータ不足によりサブセット S 系が個別に評価できなかった。また、同様にデータ数不足と思われる要因によりサブセット MD の学習性能が低かった。これらの問題は一層のデータ収集を行うことにより、的確なサブセットを使用しての判別器開発が行えると考えられる。

肝腫瘍においては撮影機器や造影剤によるコントラストのばらつきが大きく同一サブセット内でもばらつきが見られる。今回は門脈相のみを用いたが、位置合わせを行い単純相との差分をコントラストとして用いるなども検討の余地がある。また、嚢胞を検出してしまいうこともあり嚢胞は別途学習を行うことも検討の余地がある。

乳がん腫瘍での MM など有効なサブセットのみで効果的な CNN が作成できる要因として、サブセットによる周囲の補完が考えられる。図 7 に示す通り、同一サブセット内にある大小や

コントラスト差などから、CNNにより周辺を補完する特徴量が作られるため性能の向上が見られた。一方、肝腫瘍でのLD、LMなどは嚢胞の誤検出の要因となりやすく精度が低下したと考えられる。この点からも単純に網羅するよりもサブセットを用いて不要部位を減少させる利点と考えられる。

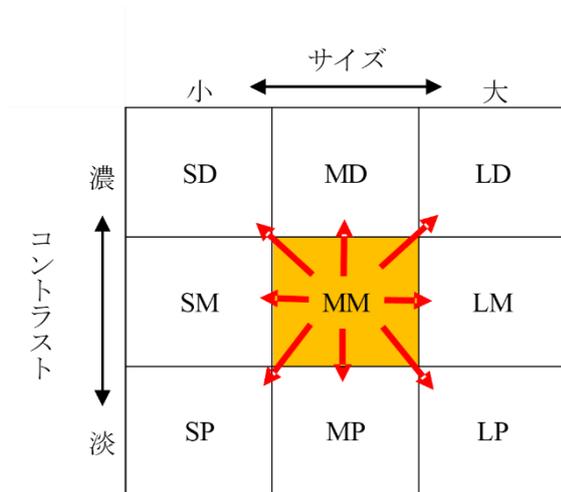


図7 サブセットによる補完

5. まとめ

本論では、CNNを用いたCAD開発においてサブセットを用いて段階的に学習を行い、判別性能の高いCNNの作成手法について提案を行った。サイズの大小、コントラストの濃淡に注目して症例画像を9個のサブセットに分割、中間評価画像を利用して最適な組み合わせを検討し、未知データにて性能向上を評価した。その結果、乳がん腫瘍と肝腫瘍のいずれを対象とした判別器においても段階的に性能向上が見られる結果となり、本手法でのCAD開発の有効性が確認できた。

利益相反の有無

利益相反 なし

倫理規範の順守

本研究にて使用した患者の症例データは、すべての患者の初診時に撮影画像の研究利用も含めた「包括的合意」にサインを受け、また各

病院にて倫理委員会を通したうえで提供を受けたものを使用している。

文献

- [1] Robertson S, Hartman J, Robertson S et al: Digital image analysis in breast pathology-from image processing techniques to artificial intelligence. Translational Research Vol.194, pp.19-35, 2018
- [2] Al-masni M. A., Al-antari M. A., Park J et al: Simultaneous detection and classification of breast masses in digital mammograms via a deep learning YOLO-based CAD system. Computer Methods and Programs in Biomedicine Vol.157, pp.85-94, 2018
- [3] Al-masni M. A., Al-antari M. A., Park J et al: Detection and classification of the breast abnormalities in digital mammograms via regional Convolutional Neural Network. IEEE Conf Proc. No.EMBC. pp.1230-1233, 2017
- [4] Tan Y. J., Sim K. S., Ting F. F: Breast cancer detection using convolutional neural networks for mammogram imaging system. IEEE Conf Proc. No.ICORAS. pp.1-5, 2017
- [5] 近藤正, 上野淳二, 高尾正一郎: 人工知能技術を用いた多層型 GMDH-type ニューラルネットワークによる肝臓癌の医用画像診断. 信学技報 111(396), pp1-6, 2012
- [6] 藤田一弥, 高原歩: 実装ディープラーニング. オーム社, 東京, 2016, pp150-167
- [7] Joseph R, Santosh D, Ross G et al: You Only Look Once: Unified, Real-Time Object Detection. Computer Vision and Pattern Recognition, arXiv:1506.02640, 2015

Proposal for an incremental learning method for CAD development that uses CNN

Kazuya ABE^{*1}, Hideya TAKEO^{*1}, Yuuichi NAGAI^{*2}, Shigeru NAWANO^{*3}

*1 Kanagawa Institute of Technology

*2 National Cancer Center Hospital East

*3 International University of Health and Welfare, Mita Hospital

In recent years, convolutional neural networks (CNN) have found increasingly active application in the field of computer-aided diagnosis (CAD) research. Typically, general-use, high-performance detectors are designed using machine learning, the training of which is conducted by applying comprehensive sets of case images having various variations. In this study, we show that, when configuring CNN training data, dividing the data into multiple subsets and adjusting their ratios, instead of providing the data uniformly, has the potential for effective learning. We propose in this study a learning method by which CNN learning using these subsets is incrementally repeated.

In this study, subsets of breast cancer mass learning data based on mass size and intensity were created. Using multiple data sets prepared for use in the evaluation of a CNN that had been subjected to learning, optimal ratios were considered and, based on this, performance evaluations using actual unknown data were conducted. Next, the ratios of evaluation data subsets having numerous detection errors were raised and relearning conducted. This process was repeated multiple times, as long as increases in the area under curve (AUC) were observed, thus enabling the design of a high-performance CNN. As a result of applying unknown data to this CNN, we found that it exhibited a higher AUC than a CNN to which learning data was simply provided comprehensively, demonstrating the effectiveness of the proposed learning method. Furthermore, applying the proposed learning method to hepatic tumors produced similar results, indicating the general applicability of this method.

Key words: CNN, CAD, learning method, breast cancer mass, hepatic tumor

著者紹介



安倍 和弥 (あべ かずや)

2010年神奈川工科大学工学部電気電子工学科卒，2012年同大学院博士前期課程修了，2015年同大博士後期課程修了．2015年同大日本人客員研究員．現在同大バイオメディカル研究センターのポスト・ドクター．博士（工学）．医用画像・細胞培養画像などの画像工学の研究に従事．第6回および第8回 JAMIT-CAD コンテスト優勝．本学会，映像情報メディア学会各会員．



武尾 英哉 (たけお ひでや)

1984年神奈川大工学部卒，1986年同大学院修士課程了．同年富士フィルム株式会社に入社．医用画像処理システムに関する研究・開発に従事．2005年東京農工大大学院博士後期課程了．博士（工学）．2006年神奈川工科大学工学部助教授．現在同大教授．医用・フォト・シネマ映像などの画像工学の研究に従事．2004年度本学会論文賞．第6回および第8回 JAMIT-CAD コンテスト優勝．本学会，映像情報メディア学会，画像電子学会，電子情報通信学会，医用画像情報学会各会員．



永井 優一 (ながい ゆういち)

1991年中央医療技術専門学校夜間部卒．1991年より国立療養所神戸病院放射線科，1992年より国立がん研究センター東病院放射線部，2006年より国立がんセンター中央病院（現独立行政法人国立がん研究センター中央病院）放射線診断部消化器官撮影主任，2015年より東埼玉病院放射線科副診療放射線技師長，中央医療技術専門学校非常勤講師（画像工学），全国国立病院療養所放射線技師会常任理事，2017年より国立がん研究センター東病院放射線部放射線診断技術室副放射線診断技術室長，現在に至る．診療放射線技師．医用画像解析の研究に従事．日本放射線技術学会会員．



縄野 繁 (なわの しげる)

1981年千葉大学医学部卒，同年千葉大学医学部付属病院放射線科研修医．1982年同助手．1986年国立がんセンター病院放射線診断部医員．1992年7月1日国立がん研究センター東病院放射線部医長．2002年4月1日同部長．2007年4月1日国際医療福祉大学三田病院放射線診断センター教授．日本医用画像工学会，日本医学放射線学会専門医，日本核医学会専門医，日本磁気共鳴医学会，北米放射線学会，CT・MRIの診断，消化管X線診断．

Prediction of five-year survival probabilities of head-and-neck cancer patients using support vector machine based on radiomic signatures selected by Coxnet

LE Cuong Quoc¹, Hidetaka ARIMURA^{*2}, Masahiro YAMADA¹,
Hidemi KAMEZAWA³

Abstract

Five-year survival probability may affect the choices of treatment policies for head-and-neck (H&N) cancer patients. The aim of our study was to investigate an automated approach to predict of 5-year survival probabilities of H&N cancer patients using a support vector machine (SVM). Computed tomography (CT) images of 126 patients with H&N squamous cell carcinoma were selected from The Cancer Imaging Archive database for this study. Engineered features representing tumor heterogeneity of cancer patients were extracted from gray-level histogram and texture matrices within cancer regions. The signatures, i.e., sets of significant features, were constructed using a Coxnet algorithm. The signatures were fed into the SVM with a polynomial kernel to estimate the 5-year survival probabilities. The polynomial SVM learning with radiomic signatures archived an area under the curve of 0.665 for stratification of patients based on 5-year survival. The polynomial SVM could be feasible to estimate the 5-year survival probabilities of H&N cancer patients by continuing this study to improve the approach.

Keywords : Head-and-neck cancer, Five-year survival probabilities, Coxnet, Support vector machine

1. Introduction

More than 90% cancer in head-and-neck (H&N) region are squamous cell carcinomas (SCC) [1]. In H&N cancer patients, five-year survival probability may affect the choice of treatment policies. Hence, prediction of 5-year survival probability plays an essential role during treatment course of H&N cancer. Recently, radiomics has attracted increased attention of researchers and clinicians due to its quantitative advantages. Radiomics could massively and comprehensively analyze and extract mineable data from a large amount of medical images [2]. Machine-learning techniques, e.g. support vector machine (SVM), have been used to imitate complex neural network or brain plasticity. In clinical practice, machine-learning approaches with high accuracy could drive the success of radiomics-based applications. We hypothesized that a radiomic-based SVM approach could be feasible to stratify H&N cancer patients

1 Department of Health Sciences, Graduate School of Medical Sciences, Kyushu University

*2 Department of Health Sciences, Faculty of Medical Sciences, Kyushu University

[3-1-1, Maidashi, Higashi-ku, Fukuoka 812-8582, Japan]

e-mail: arimurah@med.kyushu-u.ac.jp

3 Department of Radiological Technology, Teikyo University

and predict 5-year survival probabilities of them. Our study aimed to investigate and validate an automatic approach of the radiomic-based SVM model for prediction of 5-year survival probabilities of the patients.

2. Materials and methods

1) Clinical cases

Our study employed computed tomography (CT) images of 126 cancer patients with HNSCC [3] (male: 107, female: 19, age: 29-91 (mean: 56.79)) from The Cancer Imaging Archive database [4]. Patients were categorized into five overall stages I (n=3, 2.38%), II (n=2, 1.58%), III (n=15, 11.90%), IVA (n=95, 75.40%), and IVB (n=11, 8.74%). CT images were acquired using several CT scanners, with in-plane pixel sizes of 0.6386-0.9766 mm and slice thicknesses of 2.50-3.75 mm.

2) Overall procedure

Figure 1 describes the overall scheme of the proposed procedure. CT images of each H&N cancer patient were first focused on a cancer region and interpolated to obtain isotropic images. Engineered features representing tumor heterogeneity were extracted from gray-level histogram and texture matrices [5, 6] within cancer regions. Feature extraction was performed and significant features were selected using an algorithm based on a Coxnet [7] model to construct radiomic signatures. The Coxnet algorithm was performed using the glmnet package in R software Ver. 3.4.4. The signatures were fed into a SVM model with a polynomial kernel function for estimation of 5-year survival probabilities.

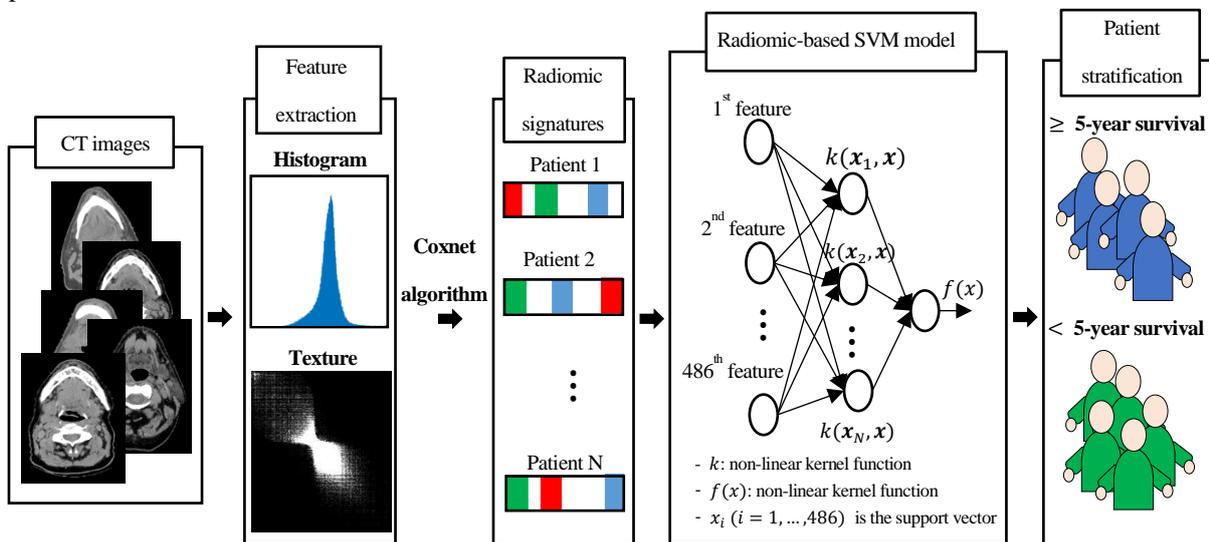


Fig. 1 An overall procedure.

3) Coxnet algorithm

The Cox proportional hazard model $h_i(t|x_i)$ for a patient i at a time t can be expressed by

$$h_i(t|\mathbf{x}_i) = h_0(t)e^{\beta^T \mathbf{x}_i}. \quad (1)$$

The Lagrangian formulation is constructed as follow

$$\hat{\beta} = \operatorname{argmax}_{\beta} [kl(\beta) - \lambda P_{\alpha}(\beta)], \quad (2)$$

where

$$l(\beta) = \sum_{i=1}^n d_i \left\{ \beta^T \mathbf{x}_i - \ln \left(\sum_{t_j \geq t_i} e^{\beta^T \mathbf{x}_i} \right) \right\}, \quad (3)$$

$$P_{\alpha}(\beta) = \alpha \|\beta\|_1 + \frac{1-\alpha}{2} \|\beta\|_2^2, \quad (4)$$

$$d_i = \begin{cases} 1, & \text{event occurred at } t_i \\ 0, & \text{censored at } t_i \end{cases}, \quad (5)$$

and i, j are the patient number, \mathbf{x} is the feature vector, β is coefficient vector, $h_0(t)$ is the baseline hazard function, t_i and t_j ($t_i \leq t_j$) are the survival time of a patient i and j , k is the scaling factor, λ is the Lagrangian multiplier, and α ($0 \leq \alpha \leq 1$) is the blending parameter for adjusting the impact of the LASSO and ridge regression penalty on the overall regularization [7].

4) Feature selection and signatures construction

From CT images, gray-level histogram and texture matrices were calculated and a total of 486 radiomic features were extracted within cancer regions. A Coxnet algorithm with a blending parameter $\alpha = 0.25$ was employed in this study. The cross-validation error of our algorithm was calculated using a 10-fold cross validation, in which the training and validation datasets were selected using random variables. In the m -fold cross validation, the cross-validation error $CE(\lambda)$ can be calculated by [8]

$$CE(\lambda) = -\frac{1}{n} \sum_{m=1}^M \{l(\hat{\beta}_{\lambda}^m) - l^m(\hat{\beta}_{\lambda}^m)\}, \quad (6)$$

where m is the number of folds, $\hat{\beta}_{\lambda}^m$ is a vector of the optimal coefficients based on the datasets in which the m^{th} subset was used for validation, and l^m is the partial likelihood calculated among the patients without the m^{th} subset. Since the training and validation datasets for cross validation was selected using random variables, the Coxnet algorithm produced different optimal models and minimum cross-validation errors. Therefore, we applied the Coxnet algorithm with 100 iterations for feature selection. After 100 iterations, features selected 100 times were assumed to be robust for variations in the training dataset. The possible association between each 100-time-selected feature with survival was evaluated using a Kaplan-Meier analysis, and a p -value from the log-rank test was calculated. In this study, features, which were selected 100 times by the Coxnet algorithm and had p -value < 0.05 , were considered to have stronger associations with patients' prognoses, and they were used for building radiomics signatures.

5) Bulding of a SVM model

A radiomic-based SVM model with a polynomial kernel function was built for estimation of 5-year survival probabilities of H&N cancer patients. Other parameters of the SVM model were optimized using a leave-one-out test based on the actual survival time.

6) Performance validation of the SVM model

The performance of our radiomic-based polynomial SVM model was evaluated using the area under the curve (AUC) of the receiver operator characteristic (ROC) curve.

3. Results and discussion

1) Selection of radiomic features and construction of signatures

Twelve features (Median, Skew, LLL_Median, LLL_Variance.1, HLL_LZLGE, LHL_Mean, LLH_LZE, LLH_LGZE, LLH_LZLGE, LLH_LZHGE, HLH_Skew, and HHH_Skew) were selected 100 times by the Coxnet algorithm and considered as robust features. Figure 2a illustrates the results of our feature selection process (only a portion of 486 features were shown in this figure). Among twelve robust features, there were three features (HLL_LZLGE, LHL_Mean, and Median) having p -value < 0.05 resulting from the Kaplan-Meier analysis and the log-rank test. Figure 2b exhibits the relation p -value < 0.05 in term of $-\log_{10}(p\text{-value}) > -\log_{10}(0.05)$ for a better visualization.

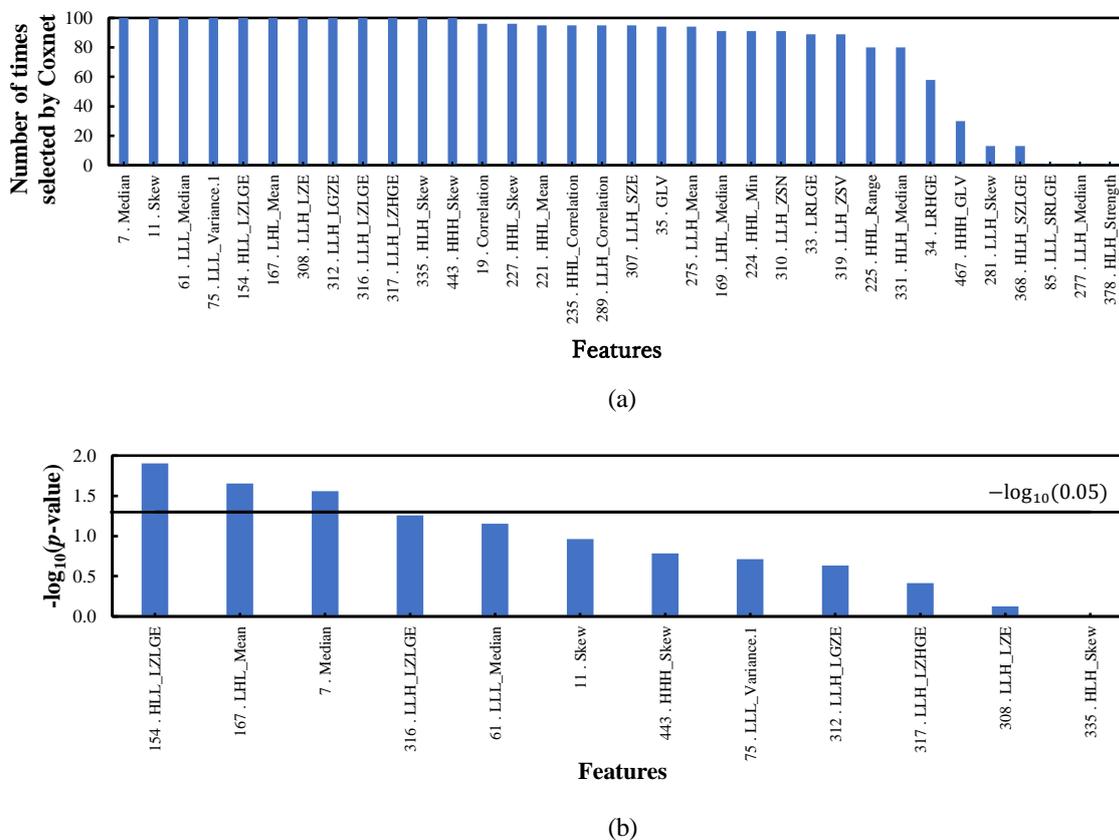


Fig. 2 Bar graphs of (a) number of times selected by Coxnet and (b) $-\log_{10}(p\text{-value})$ for various image features.

2) Estimation of 5-year survival probabilities

Our radiomic-based SVM model with a polynomial kernel function (slope = 0.85, intercept = 260, dim = 9) achieved an AUC of 0.665 (Figure 3). The results of our SVM model could produce the predictions of 5-year survival probabilities for H&N cancer patients.

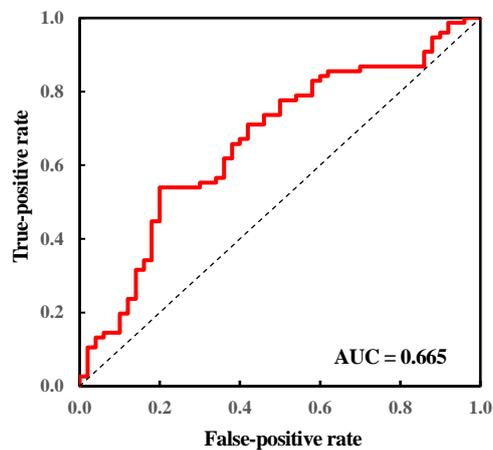


Fig. 3 An ROC curve of SVM model based on radiomics signatures.

3) Discussion

Radiomics provided quantitative measurements of tumor heterogeneity based on distribution of gray levels on medical images, while the SVM had the advantages of classification and its outputs can be used as probability. Therefore, we trained a SVM model with a polynomial kernel function based on radiomic signatures selected by a Coxnet algorithm, which are associated with 5-year survival probabilities of H&N cancer patients. The performance of our model achieved an AUC of 0.665. It could be feasible to employ a radiomic-based polynomial SVM model to predict the 5-year survival probabilities of H&N cancer patients.

Competing interests

The authors do not have any competing interests to disclose.

Acknowledgement

L.C.Q was a recipient of the Japanese government MEXT scholarship (Ministry of Education, Culture, Sport, Science and Technology) during this study. The authors are grateful to all members in Arimura laboratory (<http://web.shs.kyushu-u.ac.jp/~arimura/>), whose comments made enormous contribution to this study.

References

- [1] Sanderson R J, Ironside J A D: Squamous cell carcinomas of the head and neck. *BMJ* **325**: 822-827, 2002.
- [2] Arimura H, Soufi M: A review on radiomics for personalized medicine in cancer treatment. *Med Imag Tech* **36**: 81-89, 2018.
- [3] Grossberg A, Mohamed A, Elhalawani J, et al.: Imaging and Clinical Data Archived for Head and Neck Squamous Cell Carcinoma Patients with Radiotherapy. *Scientific Data* **5**: Article number: 180173, 2018.

- [4] <http://www.cancerimageingarchive.net/>
- [5] Haralick RM, Shanmugam K, Dinstein I: Textural features for image classification. *IEEE Trans Syst Man Cybern* **3**: 610-621, 1973
- [6] Galloway MM: Texture analysis using gray level run lengths. *Comput Graph Image Process* **4**: 172-179, 1975.
- [7] Simon N, Friedman H, Hastie T, et al.: Regularization Paths for Cox's Proportional Hazards Model via Coordinate Descent. *J Stat Softw* **39** (5): 1-13, 2011.
- [8] Hokeun Sun, Wei Lin, Rui Feng, et al.: Network-regularized high-dimensional Cox regression for analysis of genomic data. *Stat Sin* **24** (3): 1433-1459, 2014.

Kinect を用いた効率的な

3次元顔面腫れ顔の形態変化の観測と可視化

健山 智子^{*1} 大野 瑛史^{*1} 松本 慎平^{*2}

要旨

顔面浮腫や顔面陥没骨折などに伴う顔面形態変化の診断・経過観測は、医師の目視による主観的観測が一般的であり、客観的な評価手法の確立が切望されている。本研究では、顔面浮腫の形態変化の数値化より、浮腫具合を評価する計算機診断支援(CAD)の確立を目指す。顔面形態観測として、高精度レーザスキャナを用いて顔の3次元形状情報の取得などが挙げられるが、使用する機材が高価だけでなく、キャリブレーションのための計算コストが高いことなどの問題点がある。そのため、安易な撮像方法で顔形状情報の取得が可能なデバイス導入に、我々は、汎用性のあるRGB-Dセンサ、Kinect V2を導入し、顔面形態変化に対する疾患観測が可能かを検証する。検証では、顔面浮腫を模した正常10名に擬似腫れ顔として頬を膨らまし、その差分についての可視化を解析することで検証をおこなう。その可視化に対し臨床医の評価を反映し、顔面浮腫の形態変化の診断支援に有効であるか議論する。

キーワード：顔面浮腫，3次元顔面形態解析，疑似腫れ顔生成，Kinect V2，ランドマーク選定，

1. はじめに

顔は、個人特徴を表現するだけでなく、豊かな表情変化などから、我々にとって相手とのコミュニケーションを図るための重要な役割を担う。その豊かな表情変化や様々な状況を表現するための美貌、美容に対する関心

は、すべての人において関心が高く、顔全体、もしくは顔における個々の部位の変化によって表現される。ゆえに、この顔の形態変化はコミュニケーション相手へ様々な印象を引き起こすことから、顔形状の変化に伴う疾患は、患者の精神的な苦痛を引き起こす要因となるゆえ、疾患に対する効果的な治療法の提示・経過観測は、臨床現場においても重要である。

顔面形態変化における疾患として、顔全体における変形、また顔の一部の部位の変化が挙げられる[1]。前者には下顎矯正ならびに顔形成手術後の顔面浮腫や顔面陥没骨折、そして後者は顔面神経麻痺に伴う変形疾患がそれぞれ列挙される。本研究では今回、形成外科医指導の下、前者の顔面浮腫の疾患に伴う顔面形態変化の観測ならびに可視化について焦点を当てる。

顔面浮腫の症例は一般的に、通常時の顔の状態と比較すると、頬周辺の膨張と赤みを帯

*1 広島工業大学情報学部知的情報システム学科知的情報可視化研究室

〔〒731-5193 広島県広島市佐伯区三宅2-1-1〕

email: {t.tateyama.es,

md19001 }@cc.it-hiroshima.ac.jp

*2 広島工業大学情報学部知的情報システム学科知的情報可視化研究室

〔〒731-5193 広島県広島市佐伯区三宅2-1-1〕

投稿受付：2003年1月31日

びた症状である。この疾患の発症要因は様々であるが、形成外科の分野では顎矯正手術後に発症する可能性が非常に高く、術後の治療として顔面浮腫の度合いに基づいて投薬治療をおこなう。

顔面浮腫の診断は臨床医による視診・触診による経過観察が一般的であるが、その指標基準は定まっておらず、臨床医の経験に基づく主観評価となるため、顔面浮腫の診断結果が医師ごとに異なる可能性が高い。ゆえに、顔面浮腫の度合いを客観的に評価するための指標整備は急務であり、臨床現場でも多くの形成外科医が取り組んでいる課題である。この課題克服の取り組みとして、CT や MR などの高精細医用画像を用いた顔面内部からの浮腫度合い観測手法[2]が提案されているが、この医用画像撮像装置そのものは膨大な金額と場所が必要となるだけでなく、放射線の問題や撮像時間の長さの影響などから多くの課題が挙げられる。Kau らは、高精細3次元レーザスキャナを2台用いて3次元の顔面撮像を取得し、この3次元顔面撮像からその差分を指標とする顔面浮腫の形態変化の観測を提案した[3, 4]。この手法は、顔面外部からの撮像による顔面形態変化の観測を可能とし、放射線被曝の問題解決につながった。また、先述の装置にかかる膨大な金額と場所についても解決された手法ではあるが、この高精細レーザスキャナも1台あたりのコストもまた非常に高価である。さらに、2台のレーザスキャナから取得された顔情報に対し、データのキャリブレーション処理ならびに処理後の顔面形態観測のためのランドマーク特定を手動で行っているため、その処理手順は非常に複雑である。そして、その評価方法および提示方法として、定量的な手法として確立されていない。そのため、臨床現場からは、より効率的な手法での顔面形態変化の観測が切望されている。さらには、これら取得されたデータならびに臨床現場の知識と経験が導入されたデータベースの整備・客観評価システムの実現が強く切望されている。本研究では、以上の通り、臨床現場における顔面浮腫診断におけるの計算機診断支援システムの開発を

目的としている。

顔面形態変化の観測を可能とするため、先述で提示したような、高精細 3 次元レーザスキャナ、そして、体や顔の 3 次元形状を瞬時に撮像・画像化し、美容皮膚領域で広く利用されている VECTRA series[5]等による計測が挙げられる。他にも、複数の高精細カメラから、多視点方向から撮像、エピポーラ幾何などコンピュータビジョン技術から 3 次元形状の計測手法などが挙げられる[6]。しかし、上記すべての手法では、個々の計測機器そのものの費用や選択する機器による計測スペースの確保と維持の膨大化、さらには、膨大な点群情報が取得されているため、3 次元形状推定だけでなくその点群位置合わせについて複雑な計算処理が膨大となる。そのため、本研究における研究課題(以降、リサーチクエスチョン, RQ)は以下 2 つとする。

[RQ:1] 民生用の3次元形状計測機器を用いて、顔面形態情報の計測が可能であるか

[RQ:2] 取得された顔面浮腫症例の観測・診断のためのランドマークはどの部位となるか

先述の通り、現状における顔面形態変化の観測は、機器やスペースにおいて膨大な費用と処理時間が要求され、限られた施設のみでの観測となっている。多くの施設で顔面形態変化の定量的観測を可能にするため、本研究では、[RQ:1]において、民生用 RGB-D センサとして広く利用されている Kinect V2[7]を用いた 3 次元顔面形態の観測と可視化を提案する。この可視化は、関連研究 Kau らの手法と同様の可視化提示となったことから、臨床への応用についても十分可能であることを示す。

また、多くの 3 次元形態解析では Iteration Closet Points (ICP)[8]が用いられる。しかし、ICP は全点群に対する位置合わせとなるため、頬部位における顔面浮腫の 3 次元形態観測では頬の膨らみを抑制させてしまい、正確な形状の取得が難しくなる。頬の膨らみや顔形状を高精度に計測するためには、頬の膨らみなどを考慮した顔形状の点群位置合わせの手法が重要となる。本研究では、[RQ:2]として、高精細な顔面浮腫の 3 次元形態変化の観測を可能とするランドマ

ークの特定について提案する。

本論文は以下の構成となる。2.では[RQ;1]の課題，本研究における疑似腫れ顔の生成と民生用 RGB-D センサによる顔面形態観測のための Kinect の導入について議論し，3.では顔面形態観測における位置合わせのランドマーク特定，4.では実験として，提案手法の可視化結果を示し，5.で本研究を総括する。

2. 顔面形態変化観測のための診断支援の構成と疑似腫れ顔生成

顔面形態変化を伴う疾患は，顔面陥没や顔面浮腫などの顔全体の変化をはじめ，顔面神経麻痺などの局所部位変化が挙げられるが，今回，関連研究の Kau らの手法に沿って，まずは顔面浮腫による3次元顔面形態変化を観測対象とした診断支援を本研究の対象とする。

1) 研究対象の疑似顔面浮腫の構成

顔面浮腫は，下顎矯正手術や形成手術後などに発症し，通常時の顔の状態と比較すると，頬周辺の膨張と赤みを帯びた症状である。この症例は6ヶ月間腫れ度合いを臨床医の目視による主観評価から投薬を行って治療を行うが，臨床医ごとにその診断が異なる可能性があることが課題である。ゆえに，客観的な観測手法確立が臨床現場より求められているため，本研究では，計算機による顔面形態変化の客観的計測と可視化を目的としている。

多くの顔面浮腫の症例が観測されている一方，これまでその形態変化に対する客観的観測手

表 1. 解析対象の3次元顔形状情報の構成

Subject Numbers	13 volunteer (Male, Health)
Age	20 – 25
撮像方向	Front (based Depth information)
Expression	Normal x (10 / volunteer) Puffy x (10/volunteer)
Device	Kinect V2
Data style	3D point cloud based on Kinect V2 HD Face Lib [3]
Points	1347



(a) 正常顔



(b) 疑似腫れ顔



(c)顔面浮腫観測の対象領域（赤枠）

図 1： 本研究で構築した疑似腫れ顔（本研究で観測・解析の対象となる顔情報）

法は未確立であり，その臨床データの取得は臨床医ごとに異なっていることから，臨床データが極めて少ないことも本研究の課題である。よって，臨床現場での応用可能性についての調査として，本研究では，臨床医の診断経験にもとづき，顔面浮腫の発症・既往歴のない成人男性 13 名を対象として，頬部位を膨らませた疑似腫れ顔の検討を行った。解析対象となる3次元顔形状情報の構成を表 1，そして本研究で構成した顔面浮腫観測としての疑似腫れ顔を図1に示す。正常時における顔形状は通常状態の顔(図1(a))であり，疑似腫れ顔は図1(b)のように頬を膨らませた状態として，図1(c)に示す顔面の赤枠領域を解析・可視化の対象領域とした。この部位を正面方向に対して3次元形状の情報を取得する。

なお，このような疑似腫れ顔と正常例について，臨床医より，概ね検証用のデータとして適応できることの確認をもらい，本研究で検証を進めた。

2) 顔面形態観測のための RGB-D センサ選定

1. で述べたように，これまで顔面浮腫の顔

面形態変化の観測では、VECTRA などの高精度 3 次元スキャナなどから取得されていたがその費用が非常に膨大でクリニックや小規模臨床施設への導入は膨大な費用となる。さらに、取得された 3 次元形態情報もまた、膨大な点群情報であると同時に多視点からの撮像が必要となり、形態変化観測・可視化のため複雑な計算処理が求められる。

本研究では、関連研究の課題を克服するため、民生用 RGB-D センサのひとつ、Kinect V2 を用いて顔形状情報の観測・取得を行った。

Kinect V2 はカラー画像と Time-of-Flight (TOF) 方式で、光の反射時間を利用して、

対象に対する 3 次元形状計測を計測した距離画像を同時に提示する。

本研究では、1) の定義に従った正常顔、疑似腫れ顔について、Kinect V2 と HD Face ライブラリから取得された 3 次元形状点群情報に基づき、顔面形態の 3 次元形態変化に対する観測と可視化を行う。HD Face ライブラリとは、Kinect V2 から取得された顔形状の点群を提示するためのライブラリであり、基準顔としての 3 次元点群情報 (図 2) も用意されている。この基準顔の情報を用いて、取得された顔の 3 次元形状情報を 1347 点の 3 次元点群情報として計測された顔情報を取得できるだけでなく、解剖学的ランドマークも十分に整備されている。このことから、これまで複雑な計算処理が必要であった顔形状解析の簡易化にもつながり、より精度の高い顔面形態解析が可能になる。以上の理由より、本研究でのデバイスとして Kinect V2 を行った。図 3 に、図 1 で提示した正常顔と疑似腫れ顔について、Kinect V2 と HD Face ライブラリを用いて観測した 3 次元顔形状の点分布を示す。このように、解析に十分必要な顔形状の点分布情報取得が容易に行える。



図 2 : Kinect HD Face ライブラリ基準顔形状



(a) 正常顔



(b) 疑似腫れ顔

図 3 : Kinect V2 から観測された 3 次元顔形状の点分布 (図 1(a), (b) の顔形状を提示)

3. 顔面形態変化観測のための正規化とランドマーク特定

1) 顔面形態変化観測のための位置合わせとランドマーク選定

2) で述べた顔の 3 次元形状点群情報は、顔形状の左右方向や前後方向などの向き違いがある。さらに、顔面浮腫に関する顔面形態変化の観測では、口もとの膨らみなどがどのように影響されるかなどについて、これまでの研究でも未着手である。そのため、顔面浮腫形態観測のため 3 次元形状の正規化は、剛体変換を行う際にどのような解剖学的特徴をランドマークとして選定するか、本研究では調査を行う。顔面浮腫の場合、頬部位の膨らみが観測できることから、顔位置の前後のズレ以外にもその頬の膨らみ具合がどのように影響の影響が、疾患の特徴として考えられる。よって、本研究では、顔面形態変化観測のためのランドマーク選定例として、各図内の赤の点を剛体変換のランドマークとして、図 4 に示すように、ランドマーク 5 点 ((a): 額のランドマークなし + 口元ランドマークあり, (b): 額のランドマークあり + 口元のランドマークなし) と 6 点 ((c): 額のランドマークあり + 口

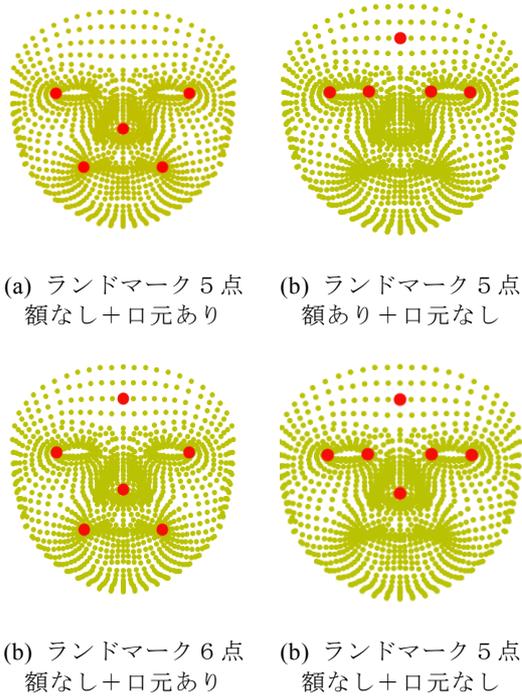


図 4：本研究での選定評価における各ランドマーク（赤点）

元ランドマークあり、(d)：額のランドマークあり+口元のランドマークなし)より、顔面腫れ顔形態変化におけるランドマークの影響を評価した。

各図の赤点がランドマークであり、これは HD Face ライブラリの解剖学ランドマーク番号に従っている。ランドマーク間の位置合わせは下式の剛体変換に従う。

$$\hat{\mathbf{p}} = \mathbf{R}\mathbf{p} + \mathbf{t} \quad (1)$$

ここで、HD Face ライブラリに用意され基準顔の 3 次元形状ベクトル $\hat{\mathbf{p}} = (\hat{x}, \hat{y}, \hat{z})^t$ と Kinect V2 から観測された各症例の 3 次元形状ベクトル $\mathbf{p} = (x, y, z)^t$ である。また、平行移動のベクトルは $\mathbf{t} = (t_x, t_y, t_z)^t$ とし、その基準は鼻頭頂部のランドマークからの移動ベクトルを考慮する。また、回転ベクトル \mathbf{R} は式 (2) に従い、回転パラメータ (それぞれ x, y, z 軸に従った角度を示す) を推定する。

$$\mathbf{R} = \begin{bmatrix} a & b & c \\ d & e & f \\ g & h & i \end{bmatrix} \quad (2)$$

ここで、それぞれ $a = \cos \beta \cos \gamma$, $b =$

$\cos \alpha \sin \gamma + \sin \alpha \sin \beta \cos \gamma$, $c = \sin \alpha \sin \gamma - \cos \alpha \sin \beta \cos \gamma$, $d = -\cos \beta \sin \gamma$, $e = \cos \alpha \sin \gamma - \sin \alpha \sin \beta \cos \gamma$, $f = \sin \alpha \sin \gamma + \cos \alpha \sin \beta \cos \gamma$, $g = \sin \beta$, $h = -\sin \alpha \cos \beta$, $i = \cos \alpha \cos \beta$, である。

2) 位置合わせによる症例間のズレ評価と考察

ランドマーク選定における位置合わせのズレ評価と考察を図 5, 6 の結果から考察する。図 5 に、位置合わせのズレ評価を示す。各結果は、図 4(a)~(b)におけるランドマーク選定に従った結果である。また、各グラフともに、顔のセンターラインに存在する各ランドマーク間 (正常顔：青, 疑似腫れ顔：赤), 選定対象のランドマーク間 (正常顔：緑, 疑似腫れ顔：紫) 各ズレの全体の平均とその差分の分布を提示した。この結果から確認できるように、顔 5 点のランドマークと 6 点のランドマークの比較では、6 点によるランドマーク選定により、正常・疑似腫れ顔ともに症例間の位置ずれが抑制されている。疑似腫れ顔の評価において、6 点の選定でも十分に位置ずれの抑制が確認できることが示唆された。また、額のランドマーク導入は顔前後の位置ずれを抑制するかを評価するため、我々は顔の鼻頭頂を通る顔中央部の直線 (額頭頂から顎底) に存在するランドマークにおけるズレの評価を行った (各グラフともに青：正常, 赤：疑似腫れ顔)。また、この評価における各ランドマークのズレ結果を図 6 にも併せて示す。図 6 の各結果は、それぞれランドマークを図(a), (b), (d)の選択の違いを比較するため、顔中央部直線上における点群のズレ可視化結果である。この評価では、サンプル 10 名の正常顔 (青), 疑似腫れ顔 (赤) をそれぞれ任意でひとつずつ選択し、それぞれ 10 症例ずつプロットした。図 5 の結果からも確認できるように、額部位をランドマークとして導入することで、顔の前後ズレが抑制されていることは数値としても十分に評価でき、さらに図 6 の結果では、顔の額部、そして顔下部 (顎部位) のズレが十分に抑制されていることも同時に確認

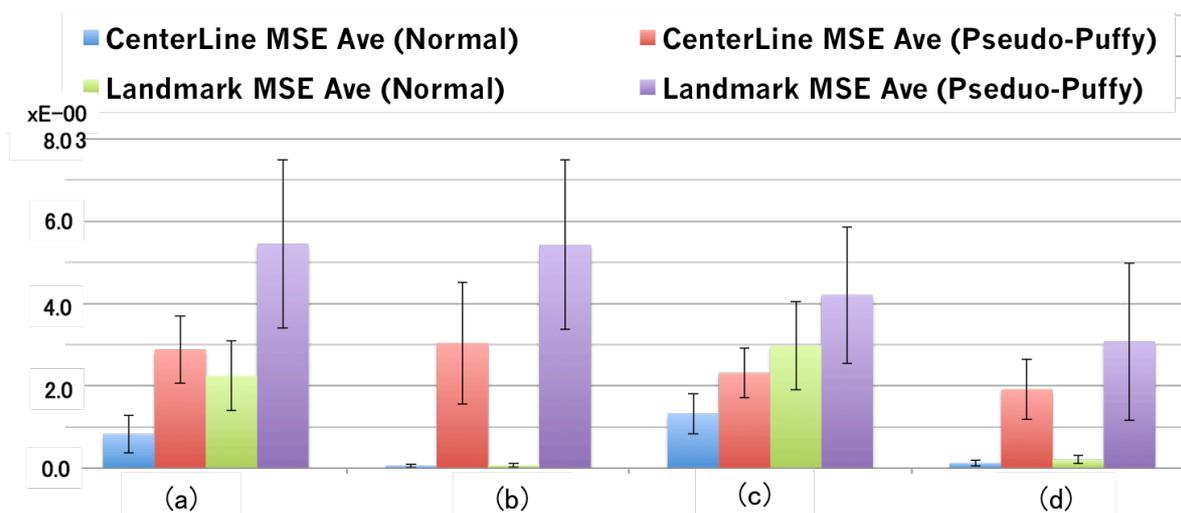
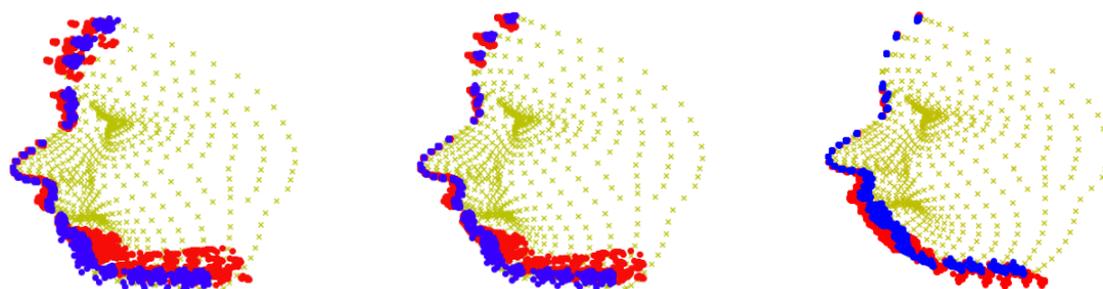


図 5: 図 4(a)~(d)のランドマーク選定におけるズレ評価結果, 各グラフともに, 顔のセンターラインに存在する各ランドマーク間 (正常顔: 青, 疑似腫れ顔: 赤), 選定対象ランドマーク間 (正常顔: 緑, 疑似腫れ顔: 紫) 各ズレの全体の平均とその差分の分布を提示



(a): 図 4(a)のランドマーク選定 (b): 図 4(b)のランドマーク選定 (c): 図 4(d)のランドマーク選定

図 6: ランドマーク選定からの位置合わせの比較 (青: 正常顔, 赤: 疑似腫れ顔, 任意 10 例をプロット)

された. このことから, 額部位のランドマーク導入により, 顔全体の前後ズレが抑制され, 顔面の 3 次元形態変化解析に有効なランドマークである. 額部位も本研究のランドマークとして選定した.

また, ランドマーク 5 点かつ額を考慮しない場合, 図 6 (a) より顔前後のズレが広く存在することを確認した. この抑制として, 目元の導入を検討した. 目元において, 目尻だけでなく目頭を選定することで顔前後のズレ分布が抑制されていることを図 (b, c) より確認され, さらにランドマークとして目頭, 目尻を選定する. なお, 顎底部位のランドマーク

特定として, 本研究での経験上, 顔面腫れ顔の度合いを評価する範囲であることがわかり, 導入しない. 以上を踏まえ, 我々は顔面形態変化の観測のための可視化について, 臨床医と検討を行なった.

4. 顔面浮腫形態観測のための可視化

2. 3 の記述にもとづき, さらに顔面形態変化の観測・可視化について, 検討した. 疑似腫れ顔と正常症例間でその変化の提示が臨床現場でも十分に妥当であるか, について形成外科医と検討を行った. 任意のサンプル i における正常症例と疑似腫れ顔症例の各 3 次元点群分布ベクトルをそれぞれ $\mathbf{p}_f, \mathbf{p}_n$ として,

各点群分布を座標(0, 0, 0)からのユーグリッド距離を考慮し、式(3)より可視化した結果を図7に示す。

$$D_i = |P_f|_i - |P_n|_i \quad (3)$$

図7は、任意のサンプル1例における正常顔と疑似腫れ顔間の差分を点群距離に基づきレインボーカラーで可視化した。可視化は、HDFaceライブラリの基準顔上にその差分をプロットさせて評価した。この結果から、頬部位において、変化が大きく、顔面浮腫では影響を持たない額部などでは変化が低いことが提示された。この結果は、臨床医が顔面浮腫についての評価と同様の結果であるとの評価であった。また、この可視化は、関連研究[3]でKauらが提示した結果とも類似した可視化である。

また、他症例についての可視化を行った。他症例においても図7と同様の可視化が提示され、より詳細に可視化されるよう、サーフェイス情報により可視化を行った結果における任意例が図8である。この可視化から顔面浮腫変化の様子は十分に理解しやすいと評価された。

以上より、1.で定義した各RQにおいて、以下が示唆され、実験結果から提案法の有効性が示された。

[RQ:1] 民生用デバイスにおいて、Kinect選定は有効であり、可視化も十分な評価が得られる

[RQ:2] 腫れ顔に対する顔面形態変化観測のための可視化では、ランドマークとして、口元を含まない6点として、両目の目頭、目尻、額中央部、鼻頭頂を選定

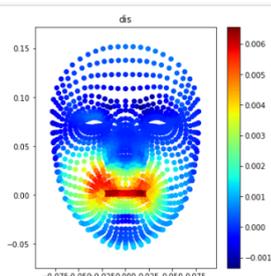


図7:顔面形態変化の可視化結果(症例1)

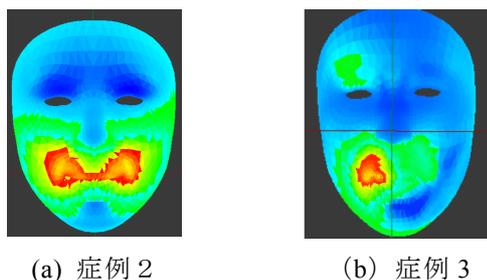


図8:他症例に対する顔面形態変化の可視化

5. おわりに

顔面浮腫による顔面形態変化の観測・可視化支援を背景として、本研究では、形成外科医指導の下、民生用デバイス選定および観測手法の提案、観測の妥当性評価のための疑似腫れ顔生成、さらに客観評価のためのランドマーク選定を行った。民生用デバイスの選定として、本研究ではKinect V2を用いることで、3次元形状の観測およびその天運分布の特定を容易に行えることを提示した。また、解析のためのランドマーク選定では、頬部位の変化に注目するため、額、両目の目尻、目頭、鼻頭頂の6点をランドマークとして選定することの妥当性を検証した。以上を踏まえ、可視化を行った結果、臨床医のこれまでの経験と知識に十分に合った可視化を提示することができ、本研究の有効性を示した。

現在、本研究は疑似腫れ顔を用いて検証をしている。今後、臨床現場での応用を目指し、提案手法を用いて実際の臨床現場で取得された臨床情報を用いた検証が必要である。また、顔面浮腫以外の顔面疾患に対しても、提案法が有効であるか評価し、診断支援を目指す。

謝辞

本研究において、臨床医の立場から御指導賜りました澤本尚哉医師に謝意を示す。本研究は、JSPS 科研費基盤研究C(18K11454)、公益研究財団古川技術振興財団の助成のもと、遂行した。

利益相反の有無

なし

文 献

- [1] 小林正治：顎矯正手術の周術期管理，日本口腔外科学会雑誌，**62**(11)，pp.554-560, 2016.
- [2] Agrawal A, Singh V, K Pradeep, et al“Unilateral swelling of cheek” Natl J Maxillofac Surg. **8**(2): pp.157–161, 2017.
- [3] Kau C.H, Andrew J, Stephen R: A Three-Dimensional Evaluation of Postoperative Swelling following Orthognathic Surgery at 6 Month, Plastic and Reconstructive Surgery. **119**(7): pp.2192-2199, 2007.
- [4] Kovacs L, Zimmermann A, Brockmann G, et. Al.: Three-dimensional quantification of facial symmetry in adolescents using laser surface scanning, European Journal of Orthodontics **36**(2), pp.125–132: 27 July 2011
- [5] CANFIELD: VECTRA series H1~M3, <https://www.canfieldsci.com/imaging-systems/vectra-h1-3d-imaging-system/>, Last Access : 2019/05/15.
- [6] Osawa S, D. Guifang, Chen YW: Reconstruction of 3D Dynamic Expressions from Single Facial Image, Proc.of.ICIP 2013, pp.1386- 1390,2013.
- [7] MicroSoft Corplation, Kinect for Windows, <https://developer.microsoft.com/ja-jp/windows/kinect>, Last accessed : 2019/05/15.
- [8] Szymon.R and Marc.L: Efficient Variants of the ICP Algorithm”, Proc of Third International Conference on 3-D Digital Imaging and Modeling, pp.145–152, 2001.
- [9] Pterneas V: Kinect HD Face, <https://pterneas.com/2015/06/06/kinect-hd-face/>, Last access 2019/05/15
- [10] 大野瑛史, 健山智子：Kinect を用いた腫れ顔の3次元形態変化の解析-顔形状の位置合わせ-, 2018年 IEEE Hiroshima Chap 若手研究会, pp41-43, 広島工業大学, 2018/07/28.

Efficient Observation and Visualization for Morphological Changes of 3D Facial Swell Using Kinect

Tomoko TATEYAMA^{*1}, Akifumi OHNO^{*1}, Shimpei MATSUMOTO^{*2}

*1 Intelligent Visual Analytics Lab, Department of Computer Science, Hiroshima Institute of Technology

*2 Social System Engineering Lab, Department of Computer Science, Hiroshima Institute of Technology.

The post-surgical follow-up observation of facial swelling change is mainly subjective assessment by the plastics doctor, therefore clinical field hopes to establish its numerical assessment of the facial changed. In this study, we focus to develop Computer Aided Diagnosis system for assessment to three-dimensional facial swelling morphological change after orthognathic surgery. Laser-scanner is effective device and used generally for measuring facial shape features, however the device is so expensive that is necessary to adopt general-purpose devices in order to reduced cost. Although Kinect is one of the general-purpose devices that can acquire three-dimensional face shape information, verification that its accuracy is effective for the measurement of facial swelling is not sufficient. In this study, we verify the effectiveness of the evaluation of the morphological change from the face shape obtained using Kinect. First, we propose an alignment method at some points including the forehead part for the face shape of all samples and evaluate whether accurate analysis for facial morphological change is possible.

Key words: Facial Swelling, Morphological Change of 3D Face points, Pseudo-Puffy shape, Kinect V2, Landmark Selection

著者紹介



健山 智子 (たてやま ともこ)
2009年3月琉球大学大学院総合知能工学専攻博士後期課程修了。2009年4月より立命館大学情報理工学部助手、2013年4月より同大学情報理工学部特任助教、2016年4月より広島工業大学情報学部知的情報システム学科助教、現在に至る。博士(工学)。計算解剖学、パターン認識、統計学習による画像処理、医用画像処理、知能情報処理、コンピュータグラフィックの医用画像工学への応用に関する研究に従事。電子情報通信学会、日本医用画像工学学会、IEEE、日本コンピュータ外科学会などの各会員。

大野 瑛史 (おおの あきふみ)
2019年広島工業大学・情報学部卒。現在、同大学情報システム工学専攻。学士。顔面形態変化の観測、可視化、計算機支援診断システム開発の研究に従事。



松本 慎平 (まつもと しんぺい)
2007年3月大阪大学 大学院情報科学研究科 情報数理学専攻博士課程終了。2007年大分工業高等専門学校 制御情報工学科助教、2010年広島工業大学情報学部助教、2013年同大学准教授、現在に至る。博士(情報科学)。数理最適化、社会システム工学、教育工学、データサイエンスに関する研究に従事。日本OR学会、日本経営システム学会、IEEEなどの各会員。

GANによるCT肺結節画像の生成

濱口 拓真^{*1} 木戸 尚治^{*2} 平野 靖^{*1} 岩野 信吾^{*3}

要旨

近年、CT画像中の肺結節の解析をConvolutional Neural Network (CNN)を用いて行う手法が数多く提案されており、高い性能を示すことが報告されている。一方で、このような解析に用いる学習画像を大量に用意できないことが原因で汎化性能を向上させることができない場合が多いという問題がある。この問題を解決するため、一般的には画像に対して回転や鏡映などを行って学習画像数を増加させる手法がとられているが、根本的な解決にはなっていない。そこで本研究では、2次元画像に対してDeep Convolutional Generative Adversarial Networks (DCGAN)を用いた画像 data augmentation 手法を開発することを目的とした。55個の良性結節と120個の悪性結節を含むデータベースを用いて本手法の性能を評価した結果、CNNによる良悪性鑑別の精度は $75.81 \pm 6.36[\%]$ であった。

1. はじめに

肺がんをはじめとした肺に関する疾患に肺結節がある。肺結節はCT画像において類円形の陰影として描出される。医師はこれらの陰影を読影することにより肺結節の良悪性鑑別などを行う。しかし、CT画像が撮影される機会が増加し、また扱うスライス数も増えたことにより読影する医師の負担が増加している。これらの問題を解決するためにコンピュータ支援診断(Computer Aided Diagnosis, CADx)システムの開発が行われている。近年のCADxシステムについては、

CNN(Convolutional Neural Network)を用いた手法が数多く提案されている。CNNを用いた手法では、大量の正解ラベル付きの画像が必要である。しかし、正解ラベル付き画像を作成できるのは、専門知識を持つ医師しかいないため、大量に作成するのは難しい。この問題を解決するために学習データの data augmentation 法が存在するが、元々のデータに対して平行移動や回転、鏡映といった画像処理を行い、データを増やすため、学習データの情報量自体は増加せず、根本的解決に至っていない。そこで、本研究ではDeep Learningの手法の一つであるGAN(Generative Adversarial Network)[1]を用いて肺結節画像を生成することで、新しいdata Augmentation手法を提案することを目的とした。本研究で用いたGANは、DCGAN(Deep Convolutional GAN)[2]である。DCGANは、GANに対して

*1 山口大学大学院創成科学研究科電気電子情報系専攻

[〒755-8611 宇部市常盤台2丁目16-1]

e-mail: b054vg@yamaguchi-u.ac.jp

*2 大阪大学大学院医学系研究科

*3 名古屋大学医学部放射線医学教室

CNN の構造を適応して、画像生成に特化した GAN モデルである。本研究では、DCGAN の入力に対して物体の属するラベルを付与することで、生成画像の種類の制御を目的とした conditional GAN[3]と、Discriminator および Generator の学習回数を制御し、Generator が 10 ステップ先の Discriminator に対して学習を行う Unrolled GAN[4]の 2 つの手法を用いた Unrolled-cDCGAN を用いて実験を行った。本研究では、まず肺結節周辺を切り出した 2 次元画像に対して Unrolled-cDCGAN の学習を行い、肺結節画像を生成するモデルを作成した。そして、GAN を用いて data augmentation した学習データに対して肺結節の良悪性鑑別を行う CNN モデルを作成し、その精度を評価した。また、本研究の比較として学習データに対して data augmentation を行わなかった場合と、従来の data augmentation 手法を用いて data augmentation した場合のそれぞれのデータで良悪性鑑別を行う CNN モデルを作成し、それらの精度を評価した。

2. 提案手法

GAN による CT 肺結節画像生成の概要を図 1 に示す。まず、胸部 CT 画像から階調変換によって階調数を 256 階調へ変換した。そして等方性ボクセル化し、階調変換した画像に対して肺結節を中心として $48 \times 48 \times 48$ [voxel]の大きさで肺結節周辺を切り出した。次に、切り出した画像から axial, coronal, sagittal の 3 断面の中心スライスを切り出した画像を作成した。最後に、作成した画像すべてを用いて GAN の学習を行い、GAN による画像生成を行った。

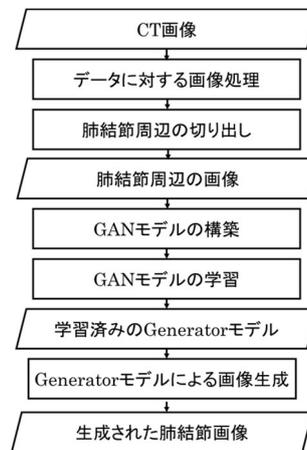


図 1 GAN による CT 肺結節画像生成の概要

次に、CNN による肺結節の良悪性鑑別の概要を図 2 に示す。CNN における肺結節の良悪性鑑別については、5 分割交差検証により精度の評価を行った。まず、良悪性鑑別用の学習データを作成した。次に、学習済みの Generator モデルを使用して data augmentation を行った。最後に、学習データを用いて CNN モデルを学習し、テストデータを用いて良悪性鑑別の精度の評価を行った。

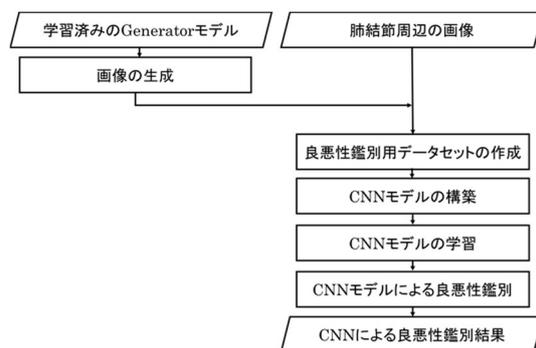


図 2 CNN による肺結節の良悪性鑑別の概要

1) 画像に対する前処理

図3は肺結節画像のCT値のヒストグラム例である。

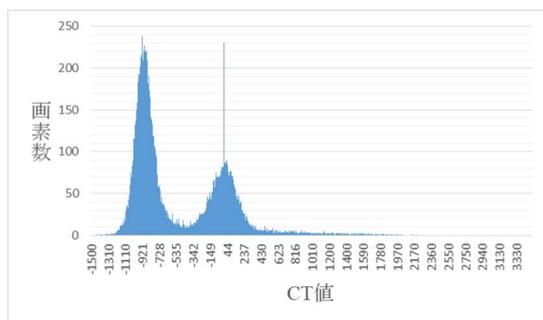


図3 肺結節画像のCT値のヒストグラム例

図3では、-500~430[H.U]が肺結節を表す箇所である。そのため、-1000~200[H.U]を0~255の256階調に階調変換を行った。さらに、データをTensorFlowで扱うためにデータを[0, 255]の画素値から[-1, 1]に正規化を行った。

2)肺結節周辺画像の切り出し

今回用いたCT画像は解像度にばらつきがあり、解像度をそろえるためにスペーシングサイズを 0.625×0.625 [mm]に、またスライス厚を 0.625 [mm]に統一した。この画像から肺結節の中心から $48 \times 48 \times 48$ [voxel]で画像を切り出した。そのあと、axial, coronal および sagittal の各断面の中心スライスを切り出した2次元画像を作成した。

3)学習データの増し

Deep Learningの学習には大量の学習データが必要である。また、使用した肺結節画像のデータは、良性の枚数と悪性の画像数に約2倍の差が存在する。そこで、本研究では、GANの学習および良悪性鑑別用のCNNの学習のために、画像処理によるdata augmentationを行った。具体的には、良性肺結節画像では、正方向および負方向にそれぞれ5[pixel]の平行移動と元画像に対して、 $90 \cdot 180 \cdot 270$ 度の回転および鏡映・反転を組み合わせることで1枚の画像から54枚の画像を作成した。悪性肺結節画像では良性肺結節画像と同様の手法から鏡映・反転を省くことで1枚の画像から27枚の画像を作成した。これにより、良性の画像データ枚数と悪性の画像データ枚数をほぼ同数にした。

4)GANモデルの構築

今回の実験で構築したGANのGeneratorモデルを表1に、Discriminatorモデルを表2にそれぞれ示す。Generatorモデルには各dense層およびdeconvolution層の後にbatch normalization層を追加した。なお、識別モデルの層の種類や数、あるいはフィルターサイズなどは出力画像のサイズが 48×48 [pixel]となり、かつ生成精度が高くなるように実験的に定めた。

表1 Generatorモデル

層種・名称	フィルターサイズ	ストライド	出力マップサイズ	活性化関数
data	-	-	102	-
dense1	-	-	36621	PReLU
reshape1	-	-	$3 \times 3 \times 4096$	-
deconvolution1	4×4	2	$6 \times 6 \times 2048$	PReLU
deconvolution2	4×4	2	$12 \times 12 \times 1024$	PReLU
deconvolution3	4×4	2	$24 \times 24 \times 512$	PReLU
deconvolution4	4×4	2	$48 \times 48 \times 1$	tanh

表 2 Discriminator モデル

層種・名称	フィルターサイズ	ストライド	出力マップサイズ	活性化関数
data	-	-	48 × 48 × 3	-
convolution1	5 × 5	1	48 × 48 × 64	PReLU
maxpooling1	2 × 2	2	24 × 24 × 64	-
convolution2	5 × 5	1	20 × 20 × 128	PReLU
maxpooling2	2 × 2	2	10 × 10 × 128	-
dense1	-	-	1024	PReLU
dense2	-	-	1	sigmoid

5)GAN モデルの学習

Generator の入力は一様分布の乱数 100 個および、生成する肺結節画像の良悪性ラベル 2 個とし、出力は 48×48[pixel]の濃淡画像とした。Discriminator の入力肺結節画像と肺結節の良悪性ラベルの 48×48×3 の画像とし、出力は肺結節画像の本物らしさを表す尤度とした。学習係数は、Generator が 8.0×10^{-4} 、Discriminator が 1.0×10^{-5} とした。また、学習回数は最大 500 回としたが、途中で mode collapse が生じたため、320 回目で得られた Generator モデルを使用して画像生成を行った。

3. 実験

1)対象データ

実験では、名古屋大学医学部附属病院で撮影された肺結節を含む胸部 CT 像 172 症例を用いた。対象とした CT 画像の詳細を以下に示す。

- ・ 画像サイズ:512×512[pixel]
- ・ ピクセルサイズ:0.566~0.781[mm]
- ・ スライス厚:0.301~1.00[mm]
- ・ スライス枚数:306~1086[枚]

肺結節には、医師の診断による良悪性のラベルが与えられている。交差検証を行うために、データセット 1 つにつき良性画像を 33 枚、悪

性画像を 72 枚にした。

2)GAN による data augmentation

学習データに対して GAN による data augmentation を行い、CNN による良悪性鑑別を行った。手法としては、まず学習データとして良性画像を 132 枚と悪性画像を 288 枚用意した。次に、GAN に良性のラベルを入力とした生成画像 7128 枚と悪性のラベルを入力とした生成画像 7776 枚を生成した。

3)比較実験

data augmentation 手法の比較として、画像処理による data augmentation 手法、data augmentation を行わない場合、GAN で生成したデータのみを使用した場合のそれぞれについて CNN による良悪性鑑別を行い、精度を評価した。data augmentation 手法は 2 節で述べた方法を用いて行った。画像処理を用いた data augmentation では、まず学習データとして良性画像を 132 枚と悪性画像を 288 枚用意した。次に、2.3 節で述べた data augmentation 手法と同様の手法で学習データに対してデータの増しを行い良性画像 7128 枚と悪性画像 7776 枚を作成した。GAN で生成した画像のみを使用した場合には、GAN に良性のラベルを入力とした生成画像 7260 枚と悪性のラベルを入力とした生成画像 8064 枚を生成し、実験を行

った。

4)評価方法

GANによる data augmentation 手法の評価方法として既存の肺結節の良悪性鑑別の CNN モデルの 1 つである CNN47[5]を基に肺結節画像の良悪性鑑別を行うモデルを作成した。そして、学習データおよび GAN で生成したデータを用いて CNN の学習を行い、CNN による良悪性鑑別の精度を用いて評価を行った。

肺結節の良悪性鑑別には 5 分割したデータセットの内 1 つをテストデータとし、残り 4 つを学習データとする 5 分割交差検証で行った。CNN による良悪性鑑別では CNN が出力した尤度を閾値 0.5 で分類した。表 3 に CNN47 を基に作成した肺結節の良悪性鑑別モデルを示す。また、CNN の学習係数は 1.0×10^{-4} とし、学習回数は 200 回とした。

表 3 CNN47 を基に作成した肺結節の良悪性鑑別モデル

層種・名称	フィルターサイズ	ストライド	出力マップサイズ	活性化関数
data	-	-	$48 \times 48 \times 1$	-
convolution1	5×5	1	$48 \times 48 \times 40$	ReLU
maxpooling1	2×2	2	$24 \times 24 \times 40$	-
convolution2	5×5	1	$24 \times 24 \times 80$	ReLU
convolution3	5×5	1	$24 \times 24 \times 40$	ReLU
maxpooling2	2×2	2	$12 \times 12 \times 40$	-
dropout1(0.25)	-	-	$12 \times 12 \times 40$	-
convolution4	3×3	1	$12 \times 12 \times 100$	-
maxpooling3	2×2	2	$6 \times 6 \times 100$	ReLU
dropout2(0.25)	-	-	$6 \times 6 \times 100$	-
convolution5	3×3	1	$6 \times 6 \times 200$	-
maxpooling4	2×2	2	$3 \times 3 \times 200$	ReLU
dropout3(0.5)	-	-	$3 \times 3 \times 200$	-
convolution6	3×3	1	$3 \times 3 \times 500$	ReLU
dropout4(0.25)	-	-	$3 \times 3 \times 500$	-
convolution7	3×3	1	$3 \times 3 \times 300$	-
dense1	-	-	500	ReLU
dropout5(0.5)	-	-	500	-
dense2	-	-	200	ReLU
dense3	-	-	2	softmax

4. 結果

1)GANによるCT肺結節画像生成結果

GANによる肺結節画像生成結果における目視での成功例を図3に、失敗例を図4に示す。ここで、図3, 4の(a)(b)は良性のラベルを与えて生成した画像を、(c)(d)は悪性のラベルを与えて生成した画像をそれぞれ示す。

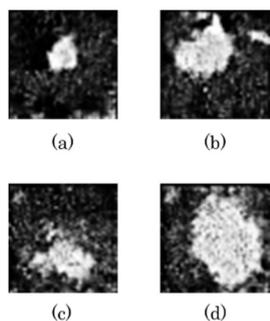


図3 肺結節画像生成結果における成功例

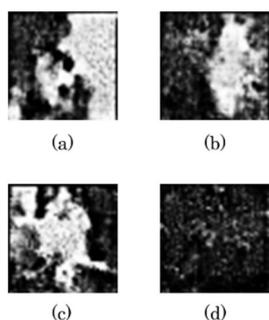


図4 肺結節画像生成結果における失敗例

図3より、良性・悪性ともに類円形の肺結節画像が生成できた。しかし、生成された画像の中には、図4で示した形が不整な肺結節画像が生成される場合もあった。

2)CNNによる肺結節の良悪性鑑別結果

肺結節の良悪性鑑別結果を表4に示す。

表4 肺結節の良悪性鑑別結果

データの種類	識別率(Mean±SD)
data augmentation なし	76.38±4.32
画像処理による data augmentation	76.57±4.40
GANによる data augmentation	75.81±6.36
GANで生成した 画像のみ	58.29±3.78

data augmentationなしに対して、画像処理による data augmentation, GANによる data augmentationのそれぞれで t 検定を行った結果、いずれの組み合わせでも p 値が 0.05 よりも大きい結果となり、有意差は得られなかった。

5. 考察

1)CNNの良悪性鑑別に関する考察

今回の実験では、data augmentationなしと比較して既存の data augmentation手法とGANによる data augmentationのそれぞれが有意差のない結果となった。このような結果となった原因としては次の2つが考えられる。1つ目は、画像処理を用いた data augmentation手法に関して data augmentation枚数が不十分である可能性である。今回の実験では、DCGANの学習時と同じ data augmentation手法を行った。しかし、画像処理を用いた data augmentationでは、平行移動を行う距離や、回転角の種類を増やすことにより、より多くの data augmentationが可能である。そこで、data augmentation枚数を増やすことによって精度が向上する可能性がある。2つ目は、GANを用いた data augmentation手法に関して、生成画像の精度が不十分である可能性がある。今

回の実験では目視で確認したところ、生成された画像の中に形状が不整な肺結節など正しく生成されなかった画像が存在した。そのため、画像生成の精度を向上させることにより CNN の良悪性鑑別の精度が向上する可能性がある。

2)生成された画像に関する考察

今回の実験では、生成された画像の中に正しく生成されなかった画像が存在した。画像生成に失敗した原因としては、以下の2つが考えられる。1つ目は、良性の肺結節症例の中に典型的ではない肺結節画像が含まれていたことである。実験で使用したデータの中には、良性でも形状が複雑な肺結節が多く、典型的な症例が少なかった。そのため、典型的な良性の肺結節画像の学習枚数が不足し、形状が不整な肺結節画像が生成されたと考えられる。したがって、良性の肺結節について典型的な肺結節データのみを GAN の学習に用いることで良性の肺結節の画像生成の精度が改善されることが見込まれる。2つ目は、GAN モデルの改善である。今回の実験では、GAN が生成した画像の中には形状が不整な肺結節画像が生成された場合もあったため、GAN モデルにも改善の余地がある。具体的な改善策としては、DCGAN の中間層におけるフィルターサイズの変更や、出力マップサイズの変更、学習エポック数の変更を行うことにより画像生成の精度の向上が見込まれる。

6. まとめ

今回、GAN を用いた data augmentation 手法により、肺結節の良悪性鑑別の精度において 75.81[%]の精度を得ることができた。しかし、従来の data augmentation 手法と比較して、有意差が得られない結果となった。良悪性鑑別の精度が 75.81[%]であるため、臨床の場にお

いて結果を活用するにはさらなる精度向上が求められる。良悪性鑑別の精度が向上しなかった原因としては、生成した画像の中に生成に失敗した画像が含まれていたことがあげられる。そのため、課題として考察で述べた良性の症例について典型的な症例のみを使用して GAN の学習を行うことや、GAN モデルの改良があげられる。

7. 謝辞

本研究は日本学術振興会科学研究費補助金新学術領域研究(26108009), および基盤研究(B)(17H02110)による支援を受けた。

利益相反の有無

無し。

文献

- [1] Goodfellow I, Pouget-Abadi e, Mehdi Mirza J, Xu B, et al :Generative Adversarial Nets, NIPS2014:2672-2680,2014
- [2] Radford A, Metz L, Chintala S:Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks, ICLR2016, 2016
- [3] Mirza M, Osindero S:Conditional Generative Adversarial Nets, arXiv:1411.1784, 2014
- [4] Metz L, Poole B, Pfau D, Sohl-Dickstein J:Unrolled Generative Adversarial Networks, arXiv:1611.02163, 2016
- [5] Causey JL, Zhang J, Ma S, et al : Highly accurate model for prediction of lung nodule malignancy with CT scans,Scientific Reports, 8, Article number:9286, 2018

Generating CT lung nodule images by use of GAN

Takuma HAMAGUCHI*¹, Shoji KIDO*², Yasushi HIRANO*¹
Shingo IWANO*³

*1 Graduate School of Sciences and Technology for Innovation, Yamaguchi University

*2 Graduate School of Medicine, Osaka University

*3 Nagoya University, Graduate School of Medicine

In recent years, many methods for analyzing lung nodules of medical images by using convolutional neural networks (CNNs) have been proposed. However, there is a problem that large amounts of data cannot be prepared. In order to solve the problem, a method to augment the data by using rotation and reflection is used. However, it is not a fundamental solution. In this study, we proposed a new data augmentation method by using “Generative Adversarial Network(GAN)”. First, we cut out 2D images from 3D CT image with lung nodule on the center. Next, we made a generator model which generates lung nodule images. After that, we trained a CNN model that discriminates benign from malignant nodules. We compared the performance of our method with no data augmentation, augmented data by using translation, rotation and reflection, and using only GAN generated data. As a result, we obtained $75.81 \pm 6.36[\%]$ by use of our method. And we obtained $76.38 \pm 4.32[\%]$ by use of no data augmentation, $76.57 \pm 4.40[\%]$ by use of rotation and reflection, and $58.29 \pm 3.78[\%]$ by use of only GAN generated data. Therefore, the results using our methods were not superior to conventional augmentation methods.

AutoEncoder の正常症例訓練モデルによる

FDG-PET 画像中の悪性腫瘍検出手法

前田 健宏*¹ 原 武史*¹ 周 向栄*¹

片渕 哲朗*² 藤田 広志*¹

要旨

本研究の目的は、医師の負担軽減や見落としを防ぐために、体幹部 FDG-PET 画像における悪性腫瘍の自動検出手法の開発を目的とする。ここでは、異常症例より収集が容易な正常症例を利用して、異常検知の観点から検出を行う。PET スライス画像を 12×12 画素のパッチ画像へ分割する。正常症例のみで訓練した AutoEncoder モデルによるパッチ画像の特徴量抽出を行う。再構成誤差を特徴量として加え、外れた傾向を持つパッチ画像を抽出する。抽出されたパッチ画像群を k-means 法により 2 クラスへ分割し、PCA による第一、第二主成分をそれぞれ軸とする 2 次元空間上にプロットする。クラス重心との距離を基にパッチ画像にスコア付けをし、スコアの集積する部位を腫瘍領域とする。腫瘍を含む 33 症例を対象に検出精度を求める。検出率 95.1%、1 症例あたりの偽陽性領域数は 53 領域となり、正常症例のみで訓練した AutoEncoder モデルは腫瘍検出に有用である可能性を示唆した。

キーワード：FDG PET, 深層学習, コンピュータ支援診断

1. はじめに

日本において、がんによる死亡者数は増加傾向にあり、早期発見と早期治療が重要とされている[1]。PET 検査はがんや炎症の病巣の調査、腫瘍の大きさや場所の特定、治療効果判定などの用途で用いられる。

PET 検査では 1 度の撮影で約 300 枚のスライス画像が生成され、すべての画像を精査するには多大な時間を要する。加えて、検査件数の増加により読影医師の負担増大が問題と

なっている。負担軽減のために、コンピュータ支援診断(CAD)システムの開発が期待されている。

悪性腫瘍の自動検出を深層学習による直接検出により行う場合、多量の教師データが必要となる。部位や種類ごとに多くの教師データを用意することは難しいが、正常症例は比較的収集が容易である。ニューラルネットワークの一種である AutoEncoder は、大量の正常データで訓練したモデルを利用した異常検知に使用されている事例がある[2]。

以上より、AutoEncoder を利用した悪性腫瘍の自動検出手法の開発を目的とする。ここでは、比較的収集が容易である正常症例を訓練に利用した AutoEncoder モデルによる特徴量抽出と、異常検知の考えを基にした自動検出を目指す。

*1 岐阜大学大学院自然科学技術研究科
知能理工学専攻

[〒501-1193 岐阜市柳戸 1-1]

e-mail: tmaeda@fjt.info.gifu-u.ac.jp

*2 岐阜医療科学大学保健科学部

2. 方法

2.1 正常 AutoEncoder モデルの作成

AutoEncoder はニューラルネットワークの一種である。入力画像をより低次元な情報へ符号化し、符号化された情報を入力画像へと復元する構造である。本手法では、PET 画像を Axial, Sagittal, Coronal の 3 断面において、各スライス画像を 12×12 画素のパッチ画像へ等間隔で切り出した画像を入力とする。訓練に用いる画像は正常症例のみとする。

2.2 特徴量抽出と異常検知

正常症例で訓練を行った AutoEncoder モデルを用いて、144 次元の画像を 6 次元へと符号化する。また、AutoEncoder の入出力の差を一つの特徴量として加え、パッチ画像 1 枚から 7 次元の特徴量を算出する。

7 次元特徴量群から、腫瘍が映っていると思われるパッチ画像を抽出する。多変量データのロバストな外れ値検知手法である MSD 法[3]により、外れた傾向の特徴量を持つパッチ画像を抽出する。次に k-means 法を適用し、2 クラスタへ分割する。

腫瘍の検出を行うために、パッチ画像の異常度を示すスコアを算出する。流れを図 1 に示す。MSD 法で抽出されたデータに対して主成分分析を行い、第一、第二主成分をそれぞれ x, y 軸とする平面にプロットする。k-means 法によるクラスタリング結果を基に、各クラスタの重心座標を求める。重心に近いほど高い値となるように設定した式を用いて異常スコアを求める。

求めた異常スコアを利用し、腫瘍領域の決定を行う。元画像上で異常スコアが高いパッチ画像が集中している箇所を腫瘍領域として検出する。最後に、検出した領域内の最大値や平均などから偽陽性の削除を行う。

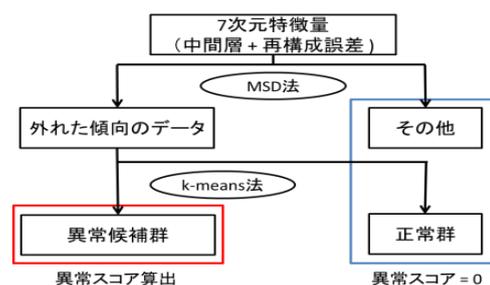


図 1 異常コア算出の流れ

3. 結果

腫瘍領域を含む異常症例 33 症例を対象に自動検出を行い、検出率と偽陽性領域数を求めた。AutoEncoder の訓練には正常症例 35 症例を用いた。

検出結果の例を図 2 に示す。橙色、薄緑色がそれぞれ、正解領域、検出領域である。検出率は 95.1%、偽陽性領域数は 53 となった。内訳を表 1 に示す。

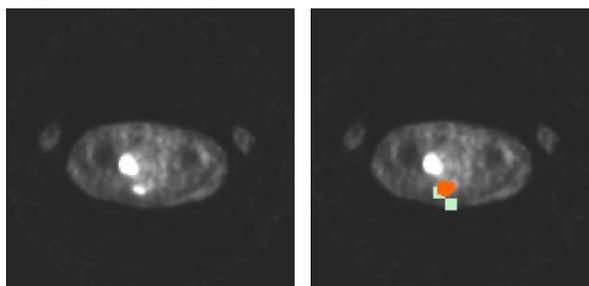


図 2 元画像(左)と検出結果(右)

	肺	肝臓	腹部	合計
腫瘍数[個]	9	7	86	102
検出数[個]	8	6	83	97
検出率[%]	88.9	85.7	96.5	95.1

表 1 検出結果

4. まとめ

本研究では、正常症例のみを訓練データとした AutoEncoder モデルと、異常検知の考えを利用した悪性腫瘍の自動検出を行った。102 個の腫瘍領域に対して、97 個の検出に成功した。偽陽性領域数は 53 領域となった。

以上より、異常症例より比較的収集が容易である正常症例のみで学習した AutoEncoder モデルは、悪性腫瘍の検出に有用である可能性が示唆された。

謝辞

本研究を進めるにあたり、有益なご助言をいただきました研究室の方々に感謝の意を表します。本研究の一部は、文部科学省科研費・新学術領域研究（26108005）および基盤研究C(17K10455, 18K12102)の補助によって行われました

利益相反の有無

なし

文 献

- [1] 日本アイソトープ協会, “第8回全国核医学診療実態調査報告書”, RADIOISOTOPES, Vol.67, No.7, pp.339-387, 2018
- [2] 立花亮介, 松原崇, 上原 邦昭, “深層生成モデルによる非正規化異常度を用いた工業製品の異常検知”, 第32回人工知能学会全国大会論文集, pp.772-775, 2018
- [3] 和田かず美, “多変量外れ値の検出~MSD法とその改良手法について”, 統計研究彙報, Vol.67, pp.89-157, 2010

Malignant tumor detection method in FDG-PET Imaging by normal case training model of AutoEncoder

Takehiro MAEDA*¹, Takeshi HARA*¹, Xiangrong ZHOU*¹

Tetsuro KATAFUCHI*², Hiroshi FUJITA*¹

*1 Department of Intelligence Science and Engineering,
Graduate School of Natural Science and Technology, Gifu University

*2 Faculty of Health Science, Gifu University of Medical Science.

The purpose of this study is to develop a method for automatic detection of malignant tumors in FDG-PET images in order to reduce the burden on doctors and prevent oversight. We use normal cases that are easier to collect than abnormal cases, and detect them from the viewpoint of abnormal detection. The PET slice image is divided into 12×12 pixel patch images. Feature extraction of patch image is performed by AutoEncoder model trained only in normal cases. Reconstruction errors are added as feature, and patch images with a tendency to deviate are extracted. The extracted patch image group is divided into 2 clusters by k-means method, and is plotted on a two-dimensional space with the first and second principal components as axes by PCA. The patch image is scored based on the distance from the cluster centroid, and the region where the score is accumulated is taken as the tumor area. The detection accuracy is calculated for 33 cases including tumor. The detection rate was 95.1%, and the number of false positive areas per case was 53, suggesting that the AutoEncoder model trained in only normal cases may be useful for tumor detection.

Key words: FDG PET, Deep Learning, CAD

低線量 CT 画像による 肺結節の経時変化に基づく良悪性鑑別

東 勇太*¹⁾ 鈴木 秀宣*²⁾ 河田 佳樹*²⁾ 仁木 登*²⁾

楠本 昌彦³⁾ 土田 敬明⁴⁾ 飯沼 元⁴⁾

要旨

日本における死因別死亡率はがんが第一位であり、現在もがんによる死亡率は上昇し続けている。その中でも部分別に見たとき肺がんは、がん死亡者数第一位を占め、こちらも増加傾向にある。早期発見に低線量 CT 肺がん検診が取り入れられている。そこで本研究では、テクスチャー解析を行い肺結節の経時変化から病状の悪化に伴う特徴量の変化を調べ、肺結節の良悪性鑑別を行うことである。

キーワード: CT, CAD, 医用画像処理

■ 背景, 目的

わが国において、死因別死亡率はがんが第一位であり、現在もがんによる死亡率は増加傾向にある。そして、がんの中でも死亡者数が最も多い部位は肺であり、男性の場合他の部位と比べて肺がんによる死亡率は極めて高い。女性においても死亡率は第二位であるが、年々増加している。このようにがんの死亡率が増加傾向にあるのは、早期発見が必要であるためである。そこで低線量 CT 肺がん検診が取り入れられ始めた。今まで、低線量 CT 肺が

ん検診の有用性を示すエビデンスは少なかったが大規模な無作為化比較試験である北米の National Lung Screening Trial (NLST) やオランダ・ベルギーの NELSON trial により肺がん死亡率の減少に効果があることが示された。本研究では、長期期間の検診により、肺結節のテクスチャー解析を行い、経時変化から病状の悪化に伴う特徴量の変化を調べ、良性結節と悪性結節の有意となるパラメータを明らかにし、肺結節の良悪性鑑別を目的とする。

■ CT 画像 撮影条件

本研究では、国立がん研究センターで撮影されたデータセットを用いて実験を行った。詳しい撮影条件を表 1 に示す。CT 画像は低線量の画像であり、また読影医による結節の判定が示されている。これを図 1 に示す。

*1) 徳島大学大学院先端技術科学教育部
システム創生工学専攻

[〒770-8506 徳島県徳島市南常三島 2-1]

e-mail: c501938010@tokushima-u.ac.jp

*2) 徳島大学大学院社会産業理工学研究部

*3) 国立がん研究センター東病院

*4) 国立がん研究センター中央病院

表 1 データセットの撮影条件

撮影条件	
メーカー	TOSHIBA
装置	Aquilion
管電圧[kV]	120
管電流[mA]	30
スライス厚[mm]	1
ピクセルサイズ[mm]	0.625
再構成間隔[mm]	1
再構成関数	FC01
画素サイズ[pixels]	512 × 512

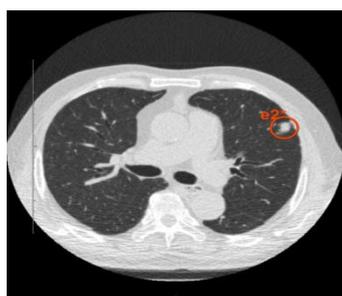


図 1 低線量 CT 画像
(赤丸:読影医による結節の判定)

■ 手法

実験に用いるデータの選別から行う。

データセットに含まれる症例数は 683 症例である。一人が受けた 1 回以上の検診をまとめて 1 症例としているため、検診回数が 1 回の症例や悪性結節を含まない症例などある。そこで長期的な肺結節の経時変化をみるため、検診回数が 1,2 回の症例を除き、その中でも肺がんの疑いとされた e1,e2 判定の結節が存在する症例を実験に用いることとした。このとき、症例数は 683 症例から 222 症例となった。

■ 結果

データセットの分布を図 2、実験に用いるデータセットの分布を図 3 に示す。

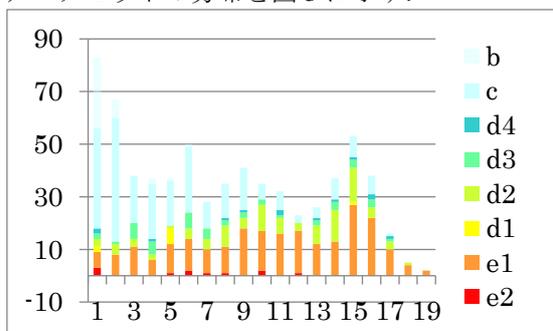


図 2 データセット分布

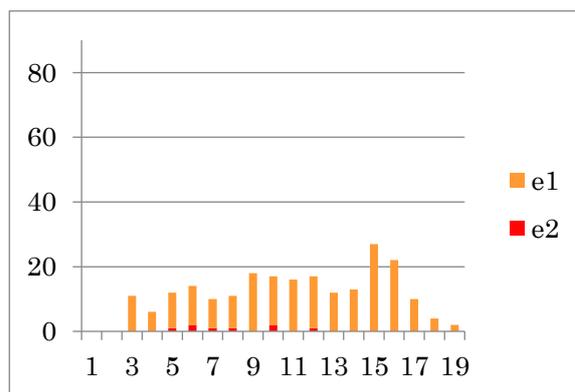


図 3 実験に用いるデータセット分布

■ まとめ

元のデータセットから検診回数,検診結果を条件に実験に使用するデータを選別し,新たにデータセットを作成した.今後はこのデータセットを用いて,肺結節の判定の変化のパターンを分類し,テキスト解析を行い経時変化による特徴量の変化を調べていく.

利益相反の有無

なし

文献

- [1] Uraujh Yousaf-Khan, et al. Final screening round of the NELSON lung cancer screening trial: the effect of a 2.5-year screening Interval ; Thorax 2017;72:48-56. doi:10.1136/thoraxjnl-2016-208655
- [2] McWilliams A, Tammemagi MC, Mayo JR, et al. Probability of cancer in pulmonary nodules detected on first screening CT. N Engl J Med 2013;369:910-9. DOI: 10.1056/NEJMoa1214726
- [3] 「NationalLungScreeningTrial の概要と評価」 祖父江友孝
- [4] 「肺癌取り扱い規約 第 8 版」 編集：日本肺癌学会 (2017)

Differentiation of Benign and Malignant Lung Nodules by Temporal Change Using Low Dose CT Images

Azuma Yuta^{*1)} Hidenobu Suzuki^{*2)} Yoshiki Kawata^{*2)} Noboru Niki^{*2)} Masahiko
Kushumoto^{*3)} Takaaki Tsuthida^{*4)} Gen Iinuma^{*4)}

*1 System Innovation Engineering , Graduate School of
Advanced Technology and Science, The University of Tokushima

*2 The University of Tokushi

*3 National Cancer Hospital East

*4 National Cancer Center Hospital

Cancer is the number one cause of death by death in Japan, and the mortality rate from cancer continues to increase. Among them, lung cancer accounts for the largest number of cancer deaths when viewed partially Low-dose CT lung cancer screening is incorporated in early detection, so in this study, texture analysis is carried out to examine changes in the characteristic amount associated with deterioration of the medical condition from the time-dependent change of lung nodules, lung It is to distinguish between benign and malignant nodules.

Key words: X-ray image, CT, Medical image processing

Staging of liver fibrosis by using texture and partial least squares-based statistical shape analyses in contrast-enhanced MR images

Mazen Soufi¹, Yoshito Otake¹, Masatoshi Hori², Kazuya Moriguchi¹,
Yasuharu Imai³, Yoshiyuki Sawai³, Takashi Ota², Noriyuki Tomiyama²,
Yoshinobu Sato^{1*}

Abstract

We aimed at the staging of liver fibrosis by using image features derived from texture analysis and partial least squares (PLS) regression -based statistical shape modelling applied to contrast-enhanced MR images. MR images of 51 patients were used. Fifty-four texture features were derived from the image histogram and 4 texture-characterizing matrices. A statistical shape model was constructed by using PLS. The fibrosis stage was estimated by using a support vector machine (SVM) based on the texture features and PLS scores. The accuracy (in terms of the AUC) at the classifications F0/1 vs. F2-4 (early), F0-2 vs. F3-4 and F0-3 vs. F4 (cirrhosis) were 0.93 ± 0.03 , 0.77 ± 0.05 and 0.84 ± 0.05 , respectively, thus showing the feasibility of the proposed approach for staging of the liver fibrosis.

Keywords : liver fibrosis, contrast-enhanced MR, statistical shape modeling, partial least squares, texture analysis

1. Introduction

Liver fibrosis is an asymptomatic disease that ultimately progress into cirrhosis, which is linked with prominent morbidity and mortality. The diagnosis of liver fibrosis includes staging the degree of fibrosis with one of five stages (from F0 'no fibrosis' to F4 'cirrhosis') [1]. The early detection of liver fibrosis is especially necessary because it may help in reversing the fibrosis, for example, through antiviral treatments [2].

Biopsy is considered the gold standard in diagnosing liver fibrosis. However, it is invasive and is prone to sampling errors. Other methods include serum/blood markers and elastography imaging techniques, such as magnetic resonance elastography (MRE) [3]. However, these tests might produce false positives due to other complications [4]. Therefore, an additional diagnostic tool for liver fibrosis is needed.

On the other side, image analysis approaches, such as statistical shape modeling [5] and texture analysis [6,

1 Division of Information Science, Nara Institute of Science and Technology

8916-5, Takayama-cho, Ikoma, Nara 630-0192, Japan

*yoshi@is.naist.jp

2 Department of Diagnostic and Interventional Radiology, Osaka University Graduate School of Medicine

D1, 2-2 Yamadaoka, Suita, Osaka, 565-0871, Japan

3 Department of Gastroenterology, Ikeda Municipal Hospital

3-1-18, Jonan, Ikeda, Osaka, 563-8510, Japan

7]; however, up to our knowledge, the fusion of these approaches has not been investigated yet. Deep learning approaches were also developed for the staging of liver fibrosis [8, 9]. Nevertheless, those approaches require large datasets for training the classification models (e.g. hundreds of datasets), which may not be available. Therefore, the purpose of this study was to investigate the feasibility of fusing MR image-based statistical shape modeling and texture analysis approaches for the staging of liver fibrosis.

2. Materials and methods

2.1 Image datasets

Institutional review board approvals for this retrospective study were obtained from Ikeda Municipal Hospital (approval ID: 3253) and Osaka University Hospital (approval ID: 14251). The proposed approach was validated on 51 contrast enhanced fat-suppressed T1-weighted MR images acquired by a 1.5 Tesla scanner (Signa HDxt 1.5T, GE Medical Systems, Milwaukee, WI). The distribution of the fibrosis stages was F0/1 (n=18), F2 (n=15), F3 (n=7) and F4 (n=11).

2.2 Proposed approach

Figure 1 shows the proposed approach for staging of liver fibrosis by using a fusion of partial least squares (PLS) regression-based shape and texture features. The liver shape was segmented from the 3D MR images. A smoothed polygon model was reconstructed from the segmented liver shapes, and an SSM was constructed based on affine and deformable registrations of a template to each polygon model. The shape features (scores) were derived from the registered polygons, and the shape modes summarizing 99.5% of the cumulative variation were selected.

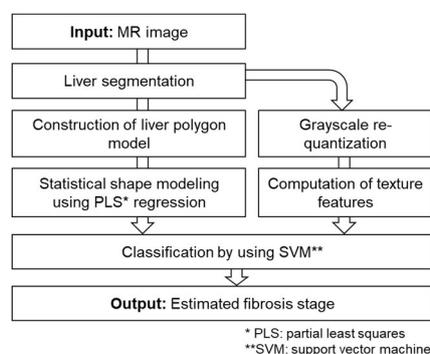


Fig. 1 Proposed approach for staging of liver fibrosis based on fusion of SSM features (PLS scores) with texture features.

The texture features were derived by using the histogram of the segmented liver and 4 types of texture representation matrices, i.e. gray-level co-occurrence matrix (GLCM) [10], graylevel run-length matrix (GLRLM) [11], graylevel size-zone matrix (GLSZM) [12] and neighborhood gray tone difference matrix (NGTDM) [13], yielding 54 features. The matrices were computed on the image after re-quantization to 16 graylevels (4-bit), following Ref. [7]. A feature selection was applied to the derived features, in which only the features of a non-negligible correlation with the fibrosis stage (i.e. Pearson correlation coefficient > 0.3) were selected. The selected features were normalized by using a z-score (difference from the mean divided by the standard deviation). The texture features were combined with the PLS scores, and fed into a support vector machine (SVM) with a linear kernel to predict the fibrosis stage. The prediction

was performed under a binary classification (i.e. F0/1 vs. F2-4, F0-2 vs. F3-4 and F0-3 vs. F4) with a 5-fold cross-validation repeated for 50 iterations.

3. Results and discussions

Figure 2 shows the shape variations obtained by the PLS scores in the direction perpendicular to the discrimination hyperplane. The features represented commonly-known variations with respect to the fibrosis progression, such as enlargement of left lobe and shrinkage in the front side of the right lobe, as well as detailed shape variations, such as enlargement in the back side of the right lobe. These variations agree, to some extent, with those observed in cirrhotic livers by Ozaki et al. [14].

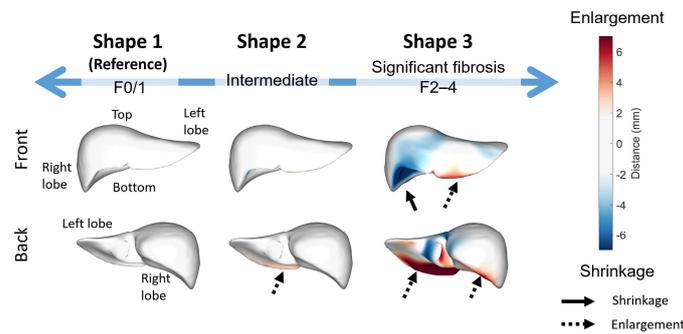


Fig. 2 Shape variations represented by PLS scores. The features represented commonly-known variations, such as enlargement of left lobe, as well as detailed shape variations, such as enlargement in the back side of the right lobe.

Figure 3 shows the Pearson correlation coefficient between the 54 texture features and the fibrosis stage. Eight features yielded non-negligible correlations, i.e. the histogram-based entropy, mean, median and root-mean-square (RMS), the GLSZM-based size zone emphasis (SZE) and zone size non-uniformity (ZSN), and the NGTDM-based busyness and strength features. The maximum correlation value in absolute value corresponded with the SZE ($\rho = -0.49$), which shows a moderate correlation between the texture features and the fibrosis stage.

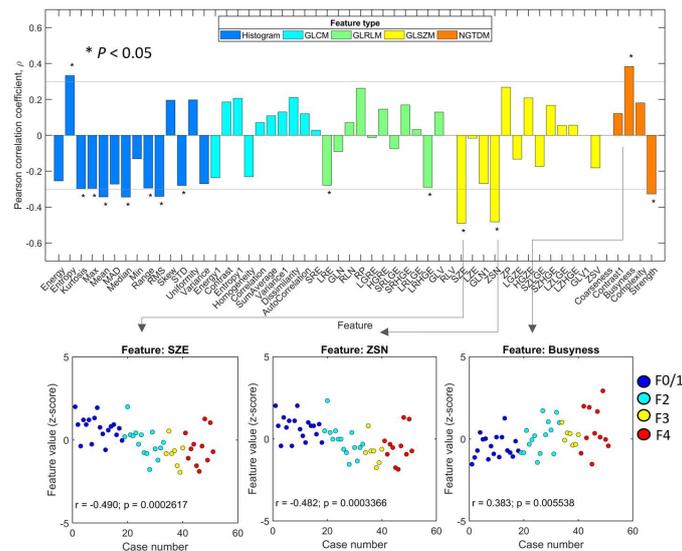


Fig. 3 Pearson correlation coefficient between texture features computed at 16 re-quantization levels and the fibrosis stage. Features with non-negligible correlation ($\rho > 0.3$) were selected for the staging. Lower row shows examples for the features with largest-3 correlation coefficients in absolute value.

Figure 4 shows examples for representative cases of the 4 fibrosis stages with the normalized values of the largest-3 correlation features. The image features characterized the randomness in the graylevel distributions at the liver vasculature and parenchymal sub-regions.

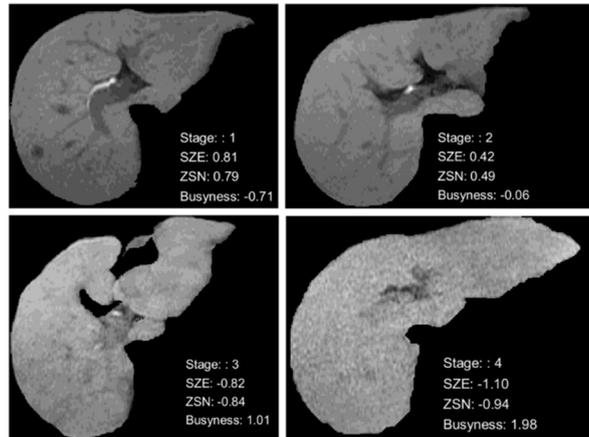


Fig. 4 Examples for representative images with the largest-3 correlation texture features (SZE: small zone emphasis, ZSN: zone size non-uniformity; and busyness).

Figure 5 summarizes the performance of the proposed approach in terms of the AUC and ACC measures. Compared with the approach using only SSM-based PLS scores, the proposed approach yielded AUCs of 0.97 ± 0.02 , 0.78 ± 0.04 and 0.82 ± 0.06 for the classifications F0/1 vs. F2-4, F0-2 vs. F3-4 and F0-3 vs. F4, respectively. The performance has improved in the classifications F0/1 vs. F2-4; however, it slightly degraded in the classification F0-2 vs. F3-4. There was no statistical significance in the improved performance at the classification F0-3 vs. F4.

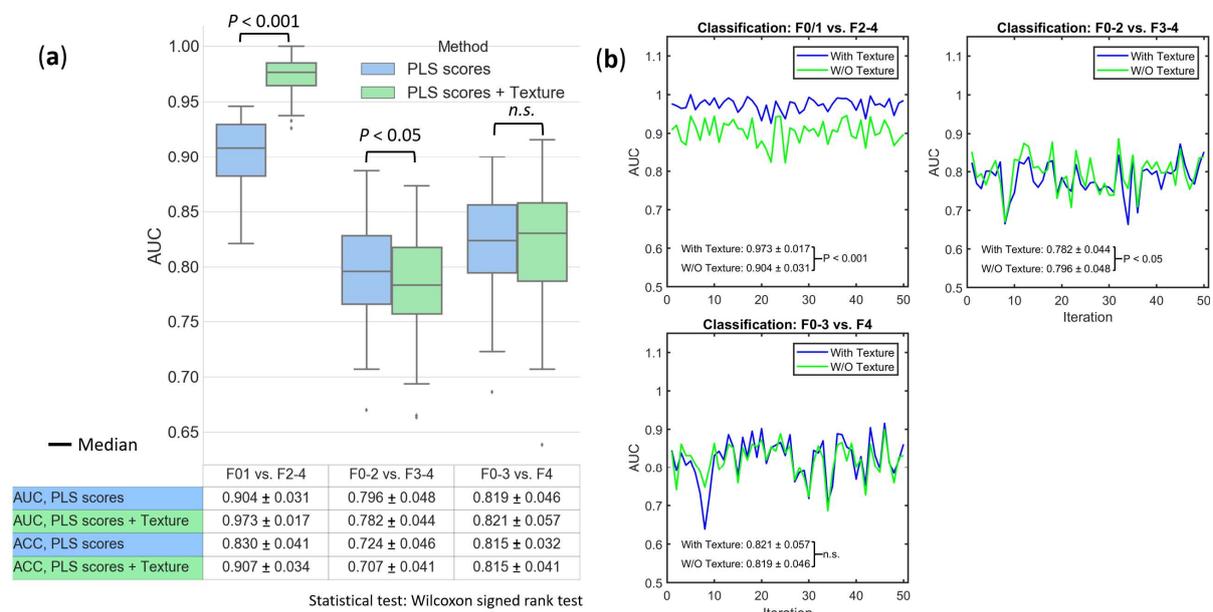


Fig. 5 Comparison of the classification accuracy between the PLS scores-based approach (blue) and fusion with texture features approach (green). (a): box-plot of AUCs with a statistical summary table of the AUC and accuracy (ACC) measures; (b): variations in the AUC with respect to the iteration number.

House et al. have shown the potential of the GLCM-based features in prediction of the liver fibrosis stage [6]. Their approach achieved AUCs of 0.81, 0.81 and 0.87 for the three classifications. Their study was applied to 48 images,

and have shown the potential of the entropy features in the discrimination between non-fibrotic and fibrotic livers. Zhang et al. have also shown the potential of using 15 texture features in prediction of liver fibrosis stage. Their approach was validated on a larger dataset of MR images (n=218), and revealed the predictive value of the mean and entropy features [7]. These results align with our findings in showing the potential of the texture features, particularly the entropy feature, in the fibrosis staging. We additionally showed the potential of GLSZM- and NGTDM-based features, whose application to fibrosis staging has not been investigated before. However, the current study has a limitation of the small dataset employed for the analysis. Currently, a larger dataset (> 250 MR images) is under preparation in order to validate the proposed approach. In addition, the potential of fusing deep learning-based representations with the handcrafted features tested in this study will be investigated.

4. Conclusions

This study has investigated the fusion of PLS-based shape features with texture features for the prediction of liver fibrosis stage. An improvement was obtained at the early detection of the fibrosis (F0/1 vs. F2–4) compared with the classification by using only PLS-based features, thus showing the potential of the proposed approach for the staging of liver fibrosis.

Competing interests

The authors have no competing interests.

Acknowledgement

The authors are grateful for Fukuda Norio, Yuki Suzuki, Steven Lim, Yukio Oshiro and Toshiyuki Okada for their contributions to this study. This research was supported by Japan Society for the Promotion of Science (JSPS) Grants-in-Aid for Scientific Research (KAKENHI) Number 26108004 / 26461789 / 17K10403 and 19K20711.

References

- [1] Ichida F, Tsuji T, Omata M, et al.: New Inuyama classification; new criteria for histological assessment of chronic hepatitis. *Int Hepatol Commun* **6**(2):112–119, 1996
- [2] Liaw YF, Reversal of cirrhosis: an achievable goal of hepatitis B antiviral therapy. *J Hepatol* **59**(4):880–881, 2013
- [3] Wang QB, Zhu H, Liu HL, Zhang B et al.: Performance of magnetic resonance elastography and diffusion-weighted imaging for the staging of hepatic fibrosis: A meta-analysis. *Hepatology* **56**(1):239–247, 2012
- [4] Tang A, Cloutier G, Szeverenyi NM, et al.: Ultrasound elastography and MR elastography for assessing liver fibrosis: part 2, diagnostic performance, confounders, and future directions. *Am J Roentgenol* **205**:33–40, 2015
- [5] Hori M, Okada T, Higashiura K, et al. Quantitative imaging: quantification of liver shape on CT using the statistical shape model to evaluate hepatic fibrosis. *Acad Radiol* **22**(3):303–309, 2015
- [6] House MJ, Bangma SJ, Thomas M, et al.: Texture-based classification of liver fibrosis using MRI. *J Magn Reson Imaging* **41**(2):322–328, 2015
- [7] Zhang X, Gao X, Liu BJ, et al: Effective staging of fibrosis by the selected texture features of liver: Which one is better, CT

or MR imaging?. *Comput Med Imag Graph* **46**:227–236, 2015

- [8] Yasaka K, Akai H, Kunimatsu A, et al.: Liver Fibrosis: Deep Convolutional Neural Network for Staging by Using Gadoteric Acid-enhanced Hepatobiliary Phase MR Images. *Radiology* **287**(1):146–155, 2018
- [9] Choi KJ, Jang JK, Lee SS, et al.: Development and validation of a deep learning system for staging liver fibrosis by using contrast agent-enhanced CT images in the liver. *Radiology*, 289(3), 688-697, 2018
- [10] Haralick RM, Shanmugam K, Dinstein I. Textural features for image classification. *IEEE Trans Syst Man Cybern.* **3**:610–621, 1973
- [11] Galloway MM. Texture analysis using gray level run lengths. *Comput Graph Image Process* **4**:172–179, 1975.
- [12] Thibault G. Texture indexes and gray level size zone matrix. Application to cell nuclei classification. In *Proc. Pattern Recognition and Information Processing*. Minsk, Belarus, 140-145, 2009
- [13] Amadasun M, King R. Textural features corresponding to textural properties. *IEEE Trans Syst Man Cybern.* **19**:1264–1274, 1989
- [14] Ozaki K, Matsui O, Kobayashi S, et al.: Selective atrophy of the middle hepatic venous drainage area in hepatitis C-related cirrhotic liver: Morphometric study by using multidetector CT. *Radiology* **257**(3):705–714, 2010

少数方向トモシンセシスにおける

正則化項を用いた画像再構成

堀 拳輔^{*1} 橋本 雄幸^{1*} 齊藤 典生^{*2} 王 波^{*2}

要旨

トモシンセシスは制限角内の投影から3次元画像を再構成する技術である。現在開発中の4つのX線管を有する装置では1秒以内の短時間撮影が可能で、患者の息止めによる負担がほとんどない。しかし、投影数が4つと少ないため、再構成画像の画質が劣化する。本研究では、正則化項を組み込んだ逐次近似アルゴリズムを4方向トモシンセシス画像再構成へ応用し、その有用性について検討した。ML-EM法とTV正則化を組み込んだ方法で数値ファントムおよび実測データの再構成を行い、RMSEおよびCNRによる比較検討を行った。数値シミュレーションでは、ML-EM法と比較してML-EM+TV再構成の奥行方向に生じるアーチファクトが抑制され、分解能が向上した。実測データではTV正則化を組み込むことでノイズが抑制でき、近似回数を重ねるにつれCNRが向上した。4方向トモシンセシスにおいて、正則化項を組み込んだ再構成アルゴリズムはアーチファクト抑制およびノイズ低減に有用であった。

キーワード：トモシンセシス、逐次近似画像再構成法、正則化

1. はじめに

トモシンセシスは制限された角度から得られる投影を用い、断層像を再構成する技術である [1]。臨床機では、単純X線撮影に用いられるX線管を機械的に動作させることで、制限角 30° 以内で約60投影を10秒かけて撮影するため、患者の息止めによる負担が大きい。さらに、撮影中に息止めができなかった場合、被ばく線量が多いにもかかわらず、単純X線検査と比較して、肺結節検出能が同等になることが報告されている [2]。一方、現在開発中であるトモシンセシス装置は、4つの小型X線管が固定配置されており、それぞれのX線管からほぼ同時に撮

影できる [3]。1秒以内に制限角 20° 程度で4方向の投影を収集できるため、肺がん検診やポータブル撮影等での活躍が期待されている。しかし、収集する角度範囲に対して投影数が極端に少ないため、ストリーク状のアーチファクトが発生してしまう問題があった。

近年、Computed Tomography (CT) や Magnetic Resonance Imaging (MRI)、核医学画像の再構成アルゴリズムに正則化を組み込むことで、スパースな情報からの画像再構成が可能となっている [3, 4, 5]。本研究では開発中のトモシンセシス装置の従来までの画像再構成法である Maximum likelihood expectation maximization (ML-EM) 法に Total variation (TV) 正則化を組み込み、その有効性に関して数値シミュレーションおよび胸部ファントムを撮影した実測データを用いてその有用性を検討した。

*1 杏林大学大学院保健学研究科
〔〒181-8612 三鷹市下連雀 5-4-1〕

e-mail: hori1911n@std.kyorin-u.ac.jp

*2 つくばテクノロジー株式会社
投稿受付：

2. 方法

2-1. 実験方法および使用機器

本実験における数値シミュレーションでは、 $128 \times 128 \times 128$ pixels の 3D Shepp&Logan ファントム (図 1) を対象とし、信号雑音比が 20 dB となるように正規分布にしたがうノイズを付加した。また、実測ではポータブル 3D 表示 X 線装置 [6] および Flat Panel Detector (PaxScan®4336W v4: Varex Imaging) を用いて、CT 値+100 で直径 10 mm および 35 mm の模擬結節を封入した胸部ファントム (N-1 ラングマン: 株式会社京都科学) を表 1 に示す条件で撮影を行った。

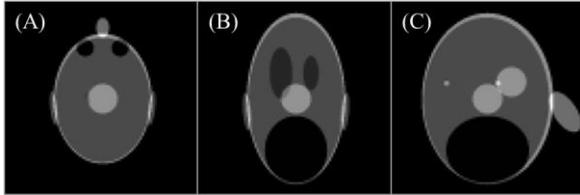


図 1 3D Shepp&Logan ファントム
A: 横断面, B: 冠状断面, C: 矢状断面. 最大画素値は 3.5 であり, 最小画素値は 0 である。

表 1 撮影条件および検出器仕様

管電圧	120 kV
管電流	17.5 mA
撮影時間	100 msec
X 線管-検出器間距離	80 cm
検出器サイズ	42.7×34.4 cm
マトリクスサイズ	3,072×2,476
ピクセルサイズ	139 μm/pixel

臨床機のとモシンセシスは、検出器を固定し、X 線管を体軸方向に動作させて撮影するが、現在開発中のとモシンセシス装置は体軸方向に配置した 4 つの X 線管を固定して撮影する (図 2)。したがって、臨床機の条件での投影は、制限角 20° において 40 投影とし、開発機の条件での投影は、制限角 20° において 4 投影とした。また、X 線は一点からコーン状に放射されることを考慮し、画像再構成を行った。

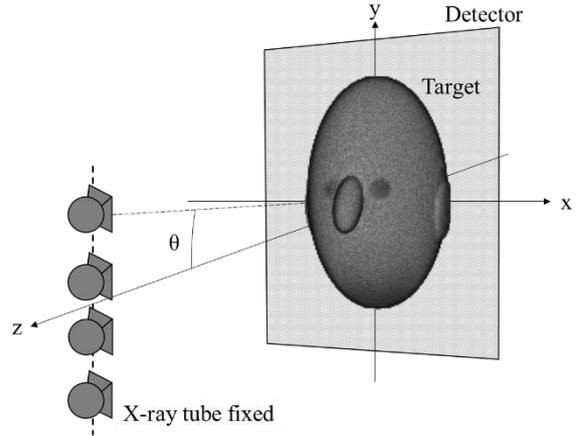


図 2 とモシンセシス撮影系

4 方向撮影時の各 X 線管に対する θ はそれぞれ $-10^\circ, -3^\circ, 3^\circ, 10^\circ$ である。

2-2. 画像再構成法

X 線による投影は式(1)で表される。

$$Y = A \cdot X \quad (1)$$

A は検出確率に関するシステム行列, X は原画像, Y はポアソン性を考慮した投影 (式(2)) を表す。

$$y_j = \text{poisson} \left(\sum_{i=0}^I a_{ij} \cdot x_i \right) \quad (2)$$

ここで, X を求める式(1)の逆問題を式(3)で表される最小化問題に書き換える。

$$X = \arg \min \left(\frac{A \cdot X}{y_j} + \beta \cdot U(X) \right) \quad (3)$$

式(3)の右辺の第一項は ML-EM 法で解くことができ, (4)で表される。

$$x_i^{(k+1)} = \frac{x_i^{(k)}}{\sum_{j=1}^J a_{ij}} \cdot \sum_{j=1}^J \frac{y_j a_{ij}}{\sum_{i=1}^I a_{ij} x_i^{(k)}} \quad (4)$$

ここで, a_{ij} は i が j に検出される確率, x および y はそれぞれ k 回目の再構成像と投影を表す。式(3), (4)より, 本研究で提案する正則化を組み込んだ逐次近似画像再構成法 (ML-EM+TV) は式(5)で表される。

$$x_i^{(k+1)} = \frac{x_i^{(k)}}{\sum_{j=1}^J a_{ij}} \cdot \sum_{j=1}^J \frac{y_j a_{ij}}{\sum_{i=1}^I a_{ij} x_i^{(k)}} - \beta \frac{\partial}{\partial x_i^{(k)}} U(x_i^{(k)}) \quad (5)$$

ここで、 $U(x_i)$ は正則化項であり、式(6)で表される TV ノルムを用いた。

$$U(x_i) = \sum_{i=1}^I \sqrt{\left(\frac{\partial x_i}{\partial x}\right)^2 + \left(\frac{\partial x_i}{\partial y}\right)^2} \quad (6)$$

2-3. 評価指標

数値シミュレーションの検討では、基準画像 a とし、対象画像 b との差を式(4)で示す Root mean square error (RMSE) で評価した。トモシンセシスは投影角度に制限があるため、原画像の形状を正確に描出することはできない。したがって、制限角 20° においてノイズを含まない 40 投影を収集し、ML-EM+TV 法で再構成した画像を基準画像とした。

$$RMSE = \frac{1}{N} \sum_{i=1}^N \sqrt{(a_i - b_i)^2} \quad (4)$$

胸部ファントム実測データでの検討では、式(5)で示す Contrast to noise ratio (CNR) で評価した。それぞれ、 $signal$ は 10 mm 模擬結節部、 $B.G.$ は肺野部とした。

$$CNR = \frac{Mean_{signal} - Mean_{B.G.}}{\sigma_{B.G.}} \quad (5)$$

3. 結果と考察

3-1. 数値シミュレーション

3D Shepp&Logan ファントムを用いて、ML-EM 法および ML-EM+TV 法により画像再構成を行った。制限角 20° において、ノイズを付加せず 40 投影収集する条件で再構成した画像を基準再構成画像とし、図 3 A, D に示す。

基準再構成画像と比較して、ML-EM 法により再構成した画像の冠状断面では、口元部に階段状のアーチファクトが生じた (図 3 B) が、ML-EM+TV 再構成画像では滑らかに描出された (図 3 C)。矢状断面において、ML-EM 再構成画像では奥行き (Z 軸) 方向にストリークアーチファクトが発生していた (図 3 E) が、ML-

EM+TV 法ではアーチファクトが抑制され、分解能が向上していることが確認できた (図 3 F)。これは、ML-EM+TV 法では、正則化項が組み込まれたことにより、角度方向においてスパースになった情報を復元しながら画像再構成できたためと考えられる。

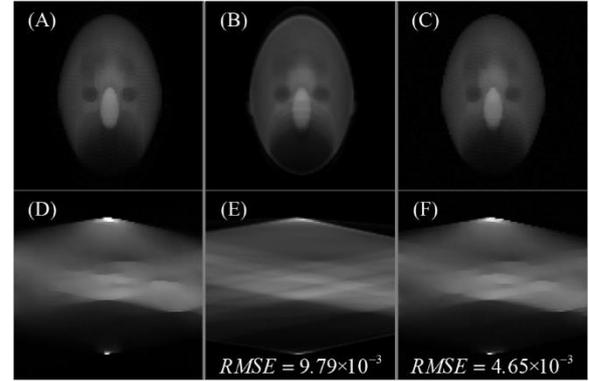


図 3 Shepp&Logan ファントム再構成画像
基準再構成画像 (左: A, D) と ML-EM 再構成画像 (中央: B, E), ML-EM+TV 再構成画像 (右: C, F) を示す。上段 (A, B, C) はそれぞれ $z=30$ での冠状断面画像で、下段 (D, E, F) は $y=64$ での矢状断面画像である。

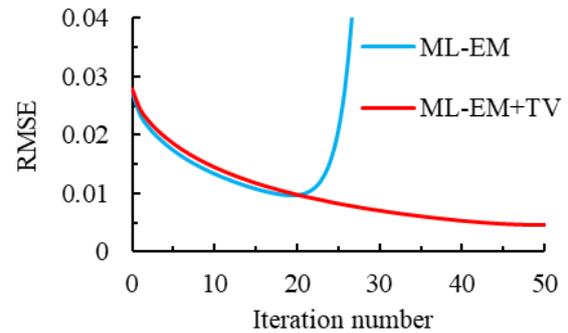


図 4 基準画像と ML-EM および ML-EM+TV 像との RMSE 値
青線は ML-EM 法、赤線は ML-EM+TV 法で再構成した画像と基準画像との RMSE 値を示す。

さらに、基準再構成画像と ML-EM 像および ML-EM+TV 像との RMSE 値を図 4 に示す。ML-EM 法では近似回数 25 程度で再構成値が発散したが、ML-EM+TV 法では値の発散が抑制され、

近似回数を重ねるにつれて RMSE 値が減少した。ML-EM 法では近似回数が約 20 回以上で計算誤差による変動成分が増大してしまったが、ML-EM+TV 法では変動成分を低減しながら近似を重ねたことで発散を抑制できたと考えられる。

3-2. 胸部ファントム実測データ

ポータブル 3D 表示 X 線装置で胸部ファントムを撮影し、取得した投影から再構成した画像を図 5 に示す。

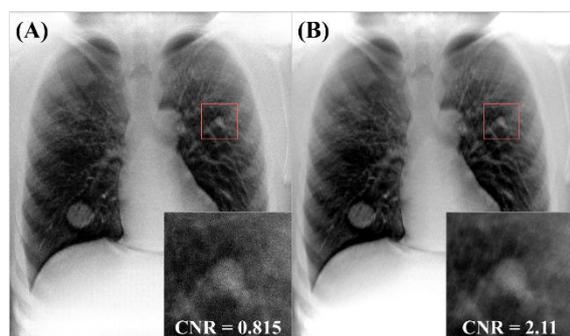


図 5 胸部ファントム再構成画像

A : ML-EM 再構成画像, B : ML-EM+TV 再構成画像. 左下に赤枠で示した 10 mm 模擬結節の拡大画像を示す。

数値ファントムでの結果と同様、実測データでも ML-EM 法により再構成した画像では、近似回数を重ねるごとにノイズが増大したが、ML-EM+TV 再構成では、ノイズが抑制されながらコントラストが向上し、CNR は 2.6 倍に向上した。

4. まとめ

正則化項を組み込んだ画像再構成はアーチファクトを抑制でき、ノイズの低減が可能とな

るため、少数方向トモシンセシスにおいて有用であった。

利益相反の有無

なし。

文 献

- [1] James T Dobbins III, Devon J Godfrey: Digital x-ray tomosynthesis: current state of the art and clinical potential. *Phys. Med. Biol.* **48**: R65, 2003
- [2] Kim S.M., Chung M.J., Lee K.S. et al: Digital tomosynthesis of the thorax: the influence of respiratory motion artifacts on lung nodule detection. *Acta Radiologica* **54**: 634-639, 2013
- [3] 王波, 鈴木良一, 王曉東 他: ポータブル 3D 表示 X 線撮影装置. 特許第 6281119 号, 2018
- [4] 工藤博幸: 低被爆 CT における画像再構成法—統計的画像再構成, 逐次近似画像再構成, 圧縮センシングの基礎—. *Med Imag Tech* **32**: 239-248, 2014
- [5] Lustig M., Donoho D., Pauly J.M.: Sparse MRI: The application of Compressed Sensing for Rapid MR imaging. *Magnetic Resonance in Medicine* **58**: 1182-1195, 2007
- [6] V.Y. Panin, G.L. Zeng, G.T. Gullberg: Total variation regulated EM algorithm [SPECT reconstruction]. *IEEE Trans Nucl Sci* **46**: 2202-2210, 1999

Image Reconstruction with Regularization for Small Number Projection Tomosynthesis

Kensuke HORI*1, Takeyuki HASHIMOTO*1, Norio SAITO*2, Wang BO*2

*1 Kyorin University Graduate School of Health Sciences

*2 Tsukuba Technology Co., Ltd.

Tomosynthesis is the technique of reconstructing 3D image from the projection within limited angles. The device under development with 4 fixed X-ray tubes enables to image in about 1 second and facilitates for patients to hold a breath. However, the image quality of the reconstructed image is degraded because the number of projections is small. In this study, availability of image reconstruction algorithm with regularization for small projection tomosynthesis is examined. Image of digital phantom and measurement chest phantom, reconstructed by ML-EM and ML-EM +TV, is compared using RMSE and CNR. In numerical simulation, the image reconstructed by ML-EM + TV is enables to suppress the artifact and improve the resolution in depth direction. In measurement data, the TV regularization enables to suppress the noise and improve the CNR by increment of iteration. Therefore, image reconstruction with regularization for small projection tomosynthesis is effective in reducing artifacts and noise.

Key words: Tomosynthesis, Iterative image reconstruction, Regularization

著者紹介



堀 拳輔 (ほり けんすけ)

2017年北里大学医療衛生学部卒業。
2019年北里大学大学院医療系研究科修士課程修了。現在、杏林大学大学院保健学研究科博士後期課程に在学中。画像処理、特に医用画像再構成の研究に従事。2018年 AOCMP Best Presentation を受賞。



橋本 雄幸 (はしもと たけゆき)

1994年筑波大学工学研究科博士課程修了。工学博士。1994年横浜創英短期大学情報処理科講師、2012年横浜創英大学こども教育学部教授、2016年杏林大学保健学部診療放射線技術学科教授。ラドン変換の逆問題、画像処理、非破壊検査の応用研究に従事。



齊藤 典生 (さいとう のりお)

1985年山形大学大学院修士課程修了、国立公害研究所でミュー散乱レーザーレーダーの研究、その後、日本電気で高出力・高安定 YAG レーザーの開発に従事。

2012年よりつくばテクノロジーにて研究開発全般を担当。

第6回ものづくり日本大賞 優秀賞受賞。



王 波 (おう は)

1982年中国西安電子科技大学レーダーシステム専攻卒業、

1986年同大学修士修了、助手、講師。1993年筑波大学に留学、CTとMRIの画像処理研究；

1999年(独)通総研(NICT)と(独)産総研(AIST)にて、3D画像処理と非破壊検査技術に関する研究。

2005年つくばテクノロジー(株)を起業、研究開発・経営全般を担当。

第6回ものづくり日本大賞 優秀賞受賞。

超音波造影剤の動態情報を利用した模擬リンパ管の可視化

齋藤 勝也*¹ 吉田 憲司*² 大村 眞朗*¹ 田村 和輝*³ 山口 匡*²

要旨

従来の超音波造影法では可視化が困難であるリンパ管のイメージング手法として、音響放射力により生じる超音波造影剤の動態情報をドプラ法で定量する動的超音波造影法を提案している。本報告では、皮膚組織の散乱・減衰特性を模擬した散乱体含有ファントムを作成し、その内部に形成した直径 0.28 mm の模擬リンパ管を対象に可視化を試みた。模擬リンパ管内に超音波造影剤 (Sonazoid™) 懸濁液を充填した状態で、単一凹面振動子（中心周波数 14.4 MHz）を方位方向に 10 μm ずつ移動させ、各走査線において 2 kHz のパルス繰り返し周波数で超音波を 0.5 秒間送信した。取得される受信信号に提案法を適用することで造影剤の動態情報を反映した二次元像を生成した。その結果、走査線あたり一回の超音波送受信データから生成される従来の B-mode 画像と比して提案法ではコントラスト比が改善することが確認された。

キーワード：音響放射力，超音波造影剤，超音波ドプラ，模擬リンパ管，コントラスト改善

1. はじめに

リンパ管の可視化技術が創出できれば、術中センチネルリンパ節の同定技術やリンパ浮腫診断におけるリンパ機能評価など診断・治療応用の両面において有効である。現状のリンパ管描出法として色素法やラジオアイソトープ法などが実施されているが、近年は非切開でリアルタイム性に優れ、広視野な観察が可能であることからインドシアニングリーン (ICG) を用いた近赤外蛍光造影法が注目されている。しかし、生体組織による光の散乱・吸収のため、10 mm より深部に位置するリンパ管を観察できないという欠点がある[1]。生体に対して良好な侵達度を有する超音波を用いて、この欠点を補う手法を提案する。

リンパ管を含む体表組織の形態学的な特徴を考慮すると、従来のエコー強度情報を用いる

超音波イメージング (B-mode 画像) では明瞭な可視化は困難であると考えられる。そこで、リンパ管描出を補助する手法として、音波照射時に生ずる造影剤の移動をドプラ法で検出する動的超音波造影法を提案してきた。これまでの検討において、造影剤のわずかな移動をドプラ法で定量可能であることを示し、その移動速度が理論計算結果と概ね一致することを確認している[2]。また、受信信号に混在するクラッタ信号が造影剤移動速度の過小評価につながる可能性について検証してきた[3]。

本報告では、実際のリンパ管と直径が同程度である円筒形チャンバを対象に、提案手法を用いてイメージングを試みた。チャンバの視認性について、コントラスト比を指標に従来手法と比較した結果について報告する。

2. 動的超音波造影法

図 1 に提案手法の概念図を示す。皮下注射により生体組織に投与された超音波造影剤がリンパ管内に吸収され、管内においてほぼ静止している状態、もしくは非常に移動速度が遅い状態を想定する。この状況下で超音波を照射すると、音響放射力が作用し、造影剤が振動子から

*1 千葉大学大学院融合理工学府
〔〒263-8522 千葉市稲毛区弥生町 1-33〕
e-mail: skatsuya@chiba-u.jp

*2 千葉大学フロンティア医工学センター

*3 浜松医科大学光先端医学教育研究センター

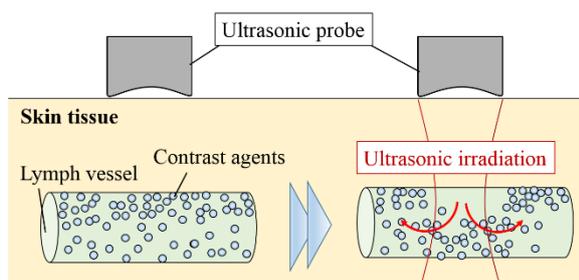


図 1 動的超音波造影法の原理模式図

離れる方向に移動することが実験的に確認されている[4,5]. 本研究では, この能動的に生じさせた造影剤の動態を超音波ドプラ法で検出することで, リンパ管の描出を目指している.

3. 実験方法

1) 計測対象

生体の散乱・減衰特性を模擬するため, 散乱体含有ファントムを作製した. 平均粒径 $10 \mu\text{m}$ のポリアミド粒子 (ORGASOL, アルケマ) を体積濃度 7.2% で混入した寒天ゲル内にリンパ管を模擬した直径 0.28 mm の円筒形チャンバをそれぞれ形成した. チャンバには超音波造影剤 (Sonazoid™) の懸濁液を充填させた. 造影剤の粒子径は $1.24 \pm 0.37 \mu\text{m}$, 数密度は 2.26×10^{12} 個/ m^3 である.

2) データ取得方法

図 2 に実験システムを示す. 中心周波数 14.4 MHz , 焦点距離 19.3 mm の単一凹面振動子をその焦点がチャンバ中心と一致するように鉛直上方に設置する. 超音波の送受信にはパルスレーザ (Model 5800, Olympus) を用いた. パルス繰り返し周波数 (PRF) 2 kHz で超音波を繰り返し送信し, 同振動子によりチャンバからのエ

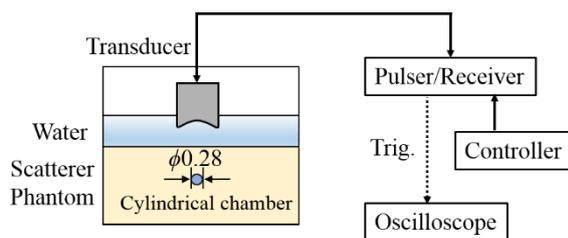


図 2 計測システム

コー信号を受信した. 超音波照射期間は 0.5 秒である. 送信波のパルス長は $0.32 \mu\text{s}$ であり, この値から深度方向の分解能を算出すると 0.26 mm となる. 受信信号はオシロスコープ (HDO6104, LeCroy) を用いて, 量子化ビット数 12 bit , サンプル周波数 250 MHz で記録した. チャンバ中心から方位方向に $10 \mu\text{m}$ ずつ振動子を移動させ, 各走査線において上記と同様の条件で RF エコー信号列を受信した. 超音波ビームの点拡がり関数 (PSF) は $79 \times 208 \mu\text{m}$ (距離方向 \times 方位方向) であり, フォーカス位置における負音圧のピーク値は 3.0 MPa であった. 一般的に, 超音波の非熱的作用の安全性評価の指標として用いられるメカニカルインデックス (Mechanical Index : MI) を概算すると, 0.79 であった. 先行研究では, Sonazoid™ に関して, MI 値が 0.4 を超えると造影剤の崩壊が始まり, 1.0 を超えると造影剤の多くが崩壊することが報告されている[6].

3) 信号処理

励起信号は $1/\text{PRF}$ 秒間隔で繰り返し振動子に印加され, 同一周期でエコー信号も受信される. 繰り返し時間間隔 ($1/\text{PRF}$) で切り出した波形を並び替えると図 3 に示す模式図となる. 深度方向 (t) の信号にヒルベルト変換を施し, 得られた解析信号の繰り返し時間方向 (τ) の変動をドプラ信号と定義した. このドプラ信号にフーリエ変換を適用し算出した周波数スペクトル $S(f)$ より造影剤の移動速度を評価することができる.

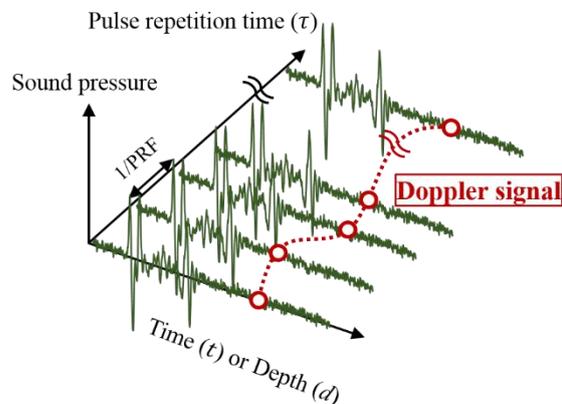


図 3 ドプラ信号の概念図

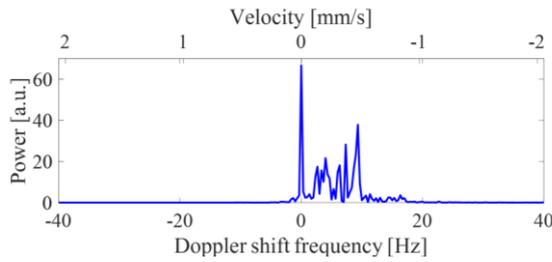


図 4 ドプラ信号のパワースペクトルの一例

チャンバ中心 ($t = t_0$) におけるドプラ信号のパワースペクトル $P(f)$ の一例を図 4 に示す. ここでは, 振動子から遠ざかる方向への移動を正の周波数成分として表示している. 速度の定量化のため, 式(2)よりドプラ信号のパワースペクトルの期待値をドプラシフト周波数 Δf として求め, 式(3)を用いて移動速度に換算した.

$$P(t, f) = S(t, f)S^*(t, f). \quad (1)$$

$$\Delta f(t) = \int_{-f_{th}}^{f_{th}} f \cdot \frac{P(t, f)}{\int_{-PRF/2}^{PRF/2} P(t, f) df} df. \quad (2)$$

$$V_{UCA} = \frac{\Delta f}{2f_0 + \Delta f} c. \quad (3)$$

ここで, f_{th} は積分区間, f_0 は送信波の周波数,

c は水の音速 (1480 m/s) である. 期待値の算出において, パワースペクトルの成分が集中する周波数帯域を選択するために, f_{th} を 80 Hz としして解析した.

チャンバ周囲の散乱体含有ファントムが完全に静止しているという仮定の下, ドプラ信号の周波数スペクトルにおける 0 Hz の信号強度をクラッタ信号 (静止エコー成分) の強度, それ以外の周波数成分の積分値を造影剤由来の信号 (動のエコー成分) の強度と定義した.

$$S_{stational}(t) = S(t, 0). \quad (4)$$

$$S_{dynamic}(t) = \int_{-PRF/2}^{PRF/2} S(t, f) df - S_{stational}(t). \quad (5)$$

4. 結果と考察

図 5 に B-mode 画像および提案法を用いてチャンバを可視化した結果を示す. 同図(a)は各走査線において 1 回の送受信データからエコー強度分布を示した B-mode 画像である (従来法). 同図(b)-(d)は 0.5 秒間に渡るエコー信号列から算出した静止エコー成分の強度 ($S_{stational}$), 動

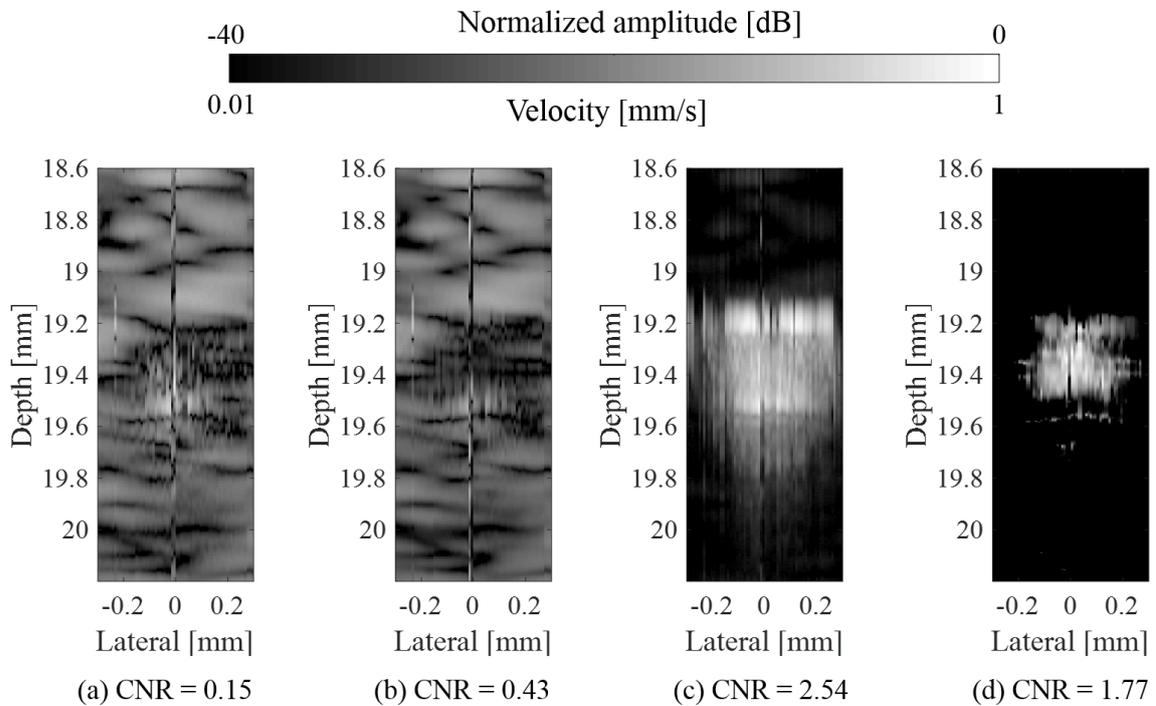


図 5 (a) 従来法 (B-mode 画像), (b) 静止エコー成分の強度, (c) 動のエコー成分の強度, (d) 造影剤移動速度の二次元像. (各画像は最大値で規格化し, 対数圧縮して表示している.)

的エコー成分の強度 ($S_{dynamic}$), 造影剤の移動速度 (V_{UCA}) の二次元分布像である。ただし, 各画像の最大値で規格化し, 対数圧縮後の画像を表示している。各画像のダイナミックレンジは 40 dB である。(速度レンジは 0.01~1 mm/s である。) B-mode 画像ではチャンバの存在箇所が判別できないが, 動的エコー成分や移動速度の二次元像では造影剤の存在部位を高感度に検出することができた。

チャンバの視認性について定量的に議論するため, チャンバと周囲ファントムのコントラスト比を式(6)で評価した。

$$CNR = \frac{|\mu_{UCA} - \mu_{clutter}|}{\sqrt{\sigma_{UCA} + \sigma_{clutter}}} \quad (6)$$

ここで, μ と σ はそれぞれの関心領域 (ROI) 内の評価指標 (エコー強度もしくは移動速度) の平均値および分散である。図 5(b)に示す静止エコー成分の強度マップを基にチャンバ位置を同定した。チャンバ中心と思われる走査線上において, 静止エコー成分および動的エコー成分の強度比が低値となる領域にチャンバが存在すると仮定し, この強度比を基に振動子側のチャンバ壁と反対側のチャンバ壁の位置を決定し, その中間をチャンバ中心と定義した。チャンバ中心に直径 0.28 mm の円を ROI として設定し, 円内をチャンバ域, 円外を周囲ファントム域とした。図 5(a)-(d)に示す画像における CNR はそれぞれ 0.15, 0.43, 2.54, 1.77 と算出された。同図(c),(d)のように造影剤の動態情報を利用することで, 1回の送受信データから作成した従来法 (同図(a)) よりもコントラスト比が 10倍以上改善することが確認できた。また, 同図(c)は同図(d)よりも CNR が高く算出されているが, チャンバが実際のサイズよりも過大に描出されている。この原因として, チャンバとファントムにおける界面からのクラッタエコーの影響を完全に除去できていない可能性が考えられる。

5. まとめ

音響放射力により生じる造影剤のわずかな

移動を定量する動的超音波造影法を用いて, 模擬リンパ管の可視化実験を試みた。B-mode 画像からでは模擬リンパ管の弁別が困難であったが, パルス列送波期間に生じる造影剤の動態情報を画像化することで高コントラストに模擬リンパ管を検出できることを示した。

謝辞

本研究の一部は, 千葉大学テニユアトラック教員の研究推進助成制度, テルモ生命科学芸術財団, JSPS Core-to-Core Program, JSPS 科研費 19H04436, 17K11529 の助成を受けた。

利益相反の有無

開示すべき利益相反状態はない。

文 献

- [1] Alander JT, Kaartinen I et al: A review of indocyanine green fluorescent imaging in surgery. *J Biomed Imaging* **7**: 2012
- [2] 吉田憲司, 齋藤勝也 他: 動的造影超音波法における造影剤移動速度の実測と理論計算の比較. *信学技報*, **118(409)**: 141-146, 2019
- [3] 齋藤勝也, 吉田憲司 他: アクティブ造影超音波法における模擬リンパ管の検出. *信学技報*, **118(452)**: 33-37, 2019
- [4] Dayton PA, Morgan KE et al: A Preliminary Evaluation of the Effects of Primary and Secondary Radiation Forces on Acoustic Contrast Agents. *IEEE Trans Ultrason Ferroelectr Freq Control* **44**: 1264-1277, 1997
- [5] Tortoli P, Guidi F et al: The use of microbubbles in Doppler ultrasound studies. *Med Biol Eng Comput* **47**: 827-838, 2009
- [6] Shi WT, Forsberg F et al: Destruction of contrast microbubbles and the association with inertial cavitation. *Ultrasound in Med Biol* **26**: 1009-1019, 2000

Visualization of a simulated lymph channel by analyzing dynamic translation of ultrasound contrast agents

Katsuya SAITO*¹, Kenji YOSHIDA*², Masaaki OMURA*¹, Kazuki TAMURA*³, Tadashi YAMAGUCHI*²

*1 Graduate School of Science and Engineering, Chiba University

*2 Center for Frontier Medical Engineering, Chiba University

*3 Preeminent Medical Photonics Education & Research Center, Hamamatsu University School of Medicine

This study proposed a method named contrast enhanced active Doppler ultrasonography(CEADUS) for visualizing lymph vessels that were difficult with conventional ultrasound imaging. This method quantifies the translation of ultrasound contrast agents(UCAs) due to the acoustic radiation force by Doppler method. In this report, we attempted to visualize a cylindrical chamber with a 0.28-mm diameter in a tissue-mimicking phantom containing acoustic scatterers. The chamber was filled with a suspension of Sonazoid™ as UCAs. The single element concave transducer with 14.4-MHz center frequency was scanned at the step of 10 μm in the lateral direction. At each scan line, ultrasound was emitted with pulse repetition frequency of 2 kHz for 0.5 s. We obtained two-dimensional images using dynamic information of the UCAs by analyzing successive echo signals at each scanning line. As a result, the contrast ratio in CEADUS images was improved compared with the conventional B mode image generated from one transmitting and receiving of ultrasound.

Key words: Acoustic radiation force, Ultrasound contrast agent, Doppler ultrasound, Simulated lymph vessel, Contrast improvement

著者紹介



齋藤 勝也 (さいとう かつや)
2018年千葉大学・工学部・メディカルシステム工学科卒。現在、千葉大学大学院・融合理工学府・基幹工学専攻・医工学コースに在学。日本医用画像工学会、日本音響学会、各会員。



吉田 憲司 (よしだ けんじ)
2009年同志社大学大学院生命医科学研究科・生命医科学専攻修了。博士(工学)。現在、千葉大・フロンティア医工学センター・助教。医用超音波、特に造影超音波の研究に従事。IEEE、日本音響学会、日本超音波医学会、応用物理学会、各会員。



大村 眞朝 (おおむら まさあき)
2017年千葉大学大学院工学研究科・人工システム科学専攻修了。修士(工学)。現在、千葉大学大学院・融合理工学府・基幹工学専攻・博士後期課程在学。日本医用画像工学会第35回大会・大会奨励賞受賞。医用超音波、特に組織性状診断法の研究に従事。IEEE、日本音響学会、日本超音波医学会、各会員。



田村 和輝 (たむら かずき)
2019年千葉大学大学院工学研究科博士後期課程修了。博士(工学)。現在、浜松医科大学 光先端医学教育センター助教。現在に至る。超音波医用計測の研究に従事。IEEE、日本音響学会、日本超音波医学会、各会員。



山口 匡 (やまぐち ただし)

2001年千葉大・自然科学研究科・情報科学専攻修了。博士(工学)。現在、千葉大学フロンティア医工学センター・教授。医用超音波、特に組織性状診断と音響特性評価の研究に従事。IEEE・Senior member, IEICE・Senior member、超音波医学会・理事、音響学会・超音波/アコースティックイメージング委員など。

EM-TV アルゴリズムを用いた少数投影での 骨 SPECT 画像再構成の検討

金澤 道和^{*1} 笹谷 典太^{*2} 細川 翔太^{*3} 渡部 浩司^{*4}

湯浅 哲也^{*2} 高橋 康幸^{*3} 銭谷 勉^{*1}

要旨

骨シンチグラフィでは胸部や骨盤などの部位において解剖学的位置の把握や定量評価は難しく、骨 SPECT の 3 次元画像が効果的である。しかし、多数の投影が必要なため撮像時間が長く、撮像時間の短縮が望まれる。本研究では、統計的逐次近似画像再構成法である ML-EM 法とトータルバリエーション(TV) 正則化を組み合わせた EM-TV アルゴリズムを骨 SPECT 画像再構成へ応用し、少数投影骨 SPECT の可能性を検討した。EM-TV 画像再構成は、観測データにおける統計的な尤度に関する更新と画像の TV に基づく正則化を交互に行うことで実現し、数値ファントムシミュレーションおよび臨床骨 SPECT 投影データを用いた実験によって評価された。従来法の ML-EM 法と比較した結果、アーチファクトおよび定量精度が大きく改善した。TV の骨 SPECT 画像再構成への応用は本研究が最初であり、少数投影骨 SPECT の可能性が示唆された。

キーワード：骨 SPECT、少数投影、トータルバリエーション、EM-TV アルゴリズム、画像再構成

1. はじめに

骨シンチグラフィは、悪性腫瘍の骨転移や骨髄炎などの診断に利用されている。しかし、プラナー像（2 次元投影画像）であるため、解剖学的な位置の把握や定量的な評価が難しい。一方、骨 SPECT（single photon emission computed tomography）は薬剤の 3 次元分布画像を得ることができるので、解剖学的位置関

係の把握や定量評価が容易となり、骨シンチグラフィに追加して SPECT 撮像が望まれる [1-6]。しかしながら、SPECT は多方向からの投影データを必要とするため、撮像時間が長い。骨 SPECT の短時間撮像が要求されるが [3-6]、解決策の 1 つとして、より少ない方向からの投影データによる画像再構成が挙げられる。

一方近年、信号処理分野において圧縮センシングが注目を集めている [7, 8]。その手法の一つとして、トータルバリエーション(total variation; TV) と呼ばれる L1 ノルム量を最小化することで、スパース性を有する信号においてはナイキスト条件を格段に下回るサンプリングレートでも元信号を再構成できることが知られており [9]、医用画像分野でも MRI（magnetic resonance imaging）において応用、

*1 弘前大学大学院理工学研究科
〔〒036-8561 青森県弘前市文京町 3〕
e-mail: ms19507@eit.hirosaki-u.ac.jp

*2 山形大学大学院理工学研究科

*3 弘前大学大学院保健学研究科

*4 東北大学サイクロトロン・ラジオアイソトープセンター

投稿受付：2019 年 5 月 21 日

実用化されている [10]. この手法を, 統計的逐次近似画像再構成法である ML-EM (maximum likelihood-expectation maximization) 法 [11] と組み合わせることで, 骨 SPECT 画像再構成において投影数の削減が期待できる.

本研究では, ML-EM 法と TV 正則化を組み合わせることで考案された EM-TV (expectation maximization-total variation) アルゴリズム [12, 13] による画像再構成法を骨 SPECT へと応用し, 数値ファントムシミュレーションおよび臨床データによって, 少数投影での骨 SPECT 画像再構成の可能性を検討した. TV を骨 SPECT 画像再構成に応用したのは本研究が最初である.

2. EM-TV アルゴリズムによる画像再構成

図 1 に示されるように, SPECT における投影データと再構成画像の関係は式(1)のように表される.

$$y_i = \sum_{j=1}^J x_{ij} = \sum_{j=1}^J C_{ij} u_j \quad (1)$$

ここで, i は検出器の番号を表す添字, j は画像の画素を表す添字, I は検出器の総数, J は画素の総数, y_i は検出器 i で検出される光子数 (不完全データ), x_{ij} は画素 j から検出器 i に入射する光子数 (完全データ), C_{ij} は画素 j から検出器 i に入射する光子の確率 (検出確率), u_j は画素 j 内の光子数 (放射性核種の濃度に比例) である. ここで,

$$\mathbf{f} = (y_1, y_2, \dots, y_I)^T \quad (2)$$

$$\mathbf{u} = (u_1, u_2, \dots, u_J)^T \quad (3)$$

$$\mathbf{K} = \begin{pmatrix} C_{11} & C_{12} & \dots & C_{1J} \\ C_{21} & \ddots & & C_{2J} \\ \vdots & & \ddots & \vdots \\ C_{I1} & C_{I2} & \dots & C_{IJ} \end{pmatrix} \quad (4)$$

とおくと, 式(1)を式(5)のような線形方程式で表すことができる.

$$\mathbf{K}\mathbf{u} = \mathbf{f} \quad (5)$$

\mathbf{K} は撮像系が決まれば事前に計算できる値で, システムマトリクスや係数行列と呼ばれる. \mathbf{f} は測定により得られる値である. したがって, SPECT の画像再構成は測定値 \mathbf{f} から未知の物理量の推定値 \mathbf{u} を求める線形逆問題に帰着する.

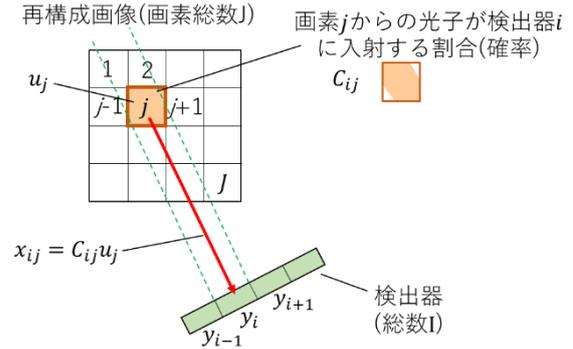


図 1 SPECT における投影データと再構成画像との関係.

また, 未知の物理量の推定値が画素値となる画像 \mathbf{u} の TV ノルムは以下のように定義される.

$$TV(\mathbf{u}) = \int |\nabla \mathbf{u}| \quad (6)$$

EM-TV アルゴリズムは, EM アルゴリズムと TV 正則化を組み合わせることで考案された手法である [12, 13]. SPECT における観測データはポアソン分布に従うため, 以下の式を目的関数とする最小化問題を解くことにより, 再構成画像を得ることができる.

$$\min_{\mathbf{u} \geq 0} \left\{ (\mathbf{K}\mathbf{u} - \mathbf{f}) \log \mathbf{K}\mathbf{u} + \lambda TV(\mathbf{u}) \right\} \quad (7)$$

ここで, 第一項はポアソン分布に関する負号付き対数尤度, 第二項は TV 項である. また, λ は 2 つの項を調整するパラメータである. 式(7)は, 凸制約最適化問題に帰着するため, 最適性条件より

$$\begin{cases} \mathbf{u}_{k+\frac{1}{2}} = \mathbf{u}_k \frac{\mathbf{K}^*}{\mathbf{K}^* \mathbf{1}} \left(\frac{\mathbf{f}}{\mathbf{K}\mathbf{u}_k} \right) & (EM \text{ step}) \\ \mathbf{u}_{k+1} = \mathbf{u}_{k+\frac{1}{2}} - \frac{\lambda}{\mathbf{K}^* \mathbf{1}} \mathbf{u}_k \frac{\partial}{\partial \mathbf{u}} TV(\mathbf{u}) & (TV \text{ step}) \end{cases} \quad (8)$$

という更新式が導かれる. ここで, \mathbf{K}^* は \mathbf{K} の

転置行列である。また、 k はイタレーション回数である。式(8)は、EM step と TV step の2つのステップで構成される。EM step は、ML-EM 法と同様の更新式である。TV step では、Rudin, Osher, Fatemi らによって考案された ROF モデル[9]での TV 正則化を行う。この式(8)に従い、繰り返し計算を行うことにより収束解を求める。

3. 実験

少数投影骨 SPECT に対する EM-TV 画像再構成の効果および可能性を検討するために、数値ファントムシミュレーションおよび臨床骨 SPECT データによる評価実験を行った。臨床データは GE 社製 2-head, SPECT-CT 装置 Infinia Hawkeye4, を用いて得られた。本研究は弘前大学大学院保健学研究科の倫理委員会の承認を受けて行われた(承認番号 2019-007)。

1) 数値ファントムシミュレーション

まずは、EM-TV アルゴリズムの効果を確認するために、数値ファントムに対してコンピュータ上で順投影を行って得た投影データを画像再構成した。

(1) Shepp-Logan ファントム

画像再構成において標準的なテスト画像として用いられる Shepp-Logan ファントム(128×128 画素)を使用し、360度を等間隔で分割した12方向と72方向の投影データ(128 bin)を作成して画像再構成を行った。画像再構成は ML-EM および EM-TV で行い、それぞれの再構成画像で比較を行った。ML-EM での再構成はイタレーション回数を100回とした。EM-TV においては、 $\lambda=0.01$ とし、イタレーション回数を10000回とした。

(2) 3D 骨 SPECT ファントム

図2に示すように、数値ファントムとして骨 SPECT 撮像と同時に撮影された3次元 X 線 CT 画像(128×128×128 画素, 画素サイズ: 4.41806 mm×4.41806 mm×4.41806 mm)を2つのしきい値を用いて、空気、骨、その他(軟部組織)の領域に3値化し、それぞれに0, 255, 127を設定したものを使用して投影

データを作成した。投影数を72, 36, 24, 12, 8と変化させ、ML-EM と EM-TV による画像再構成を行った。ML-EM での再構成はイタレーション回数を20回とした。EM-TV においては、 $\lambda=0.01$ とし、イタレーション回数を1000回とした。再構成画像の画質の評価として、それぞれの画像と数値ファントムとの RMSE(Root Mean Square Error)を計算し、ML-EM と EM-TV との比較を行った。

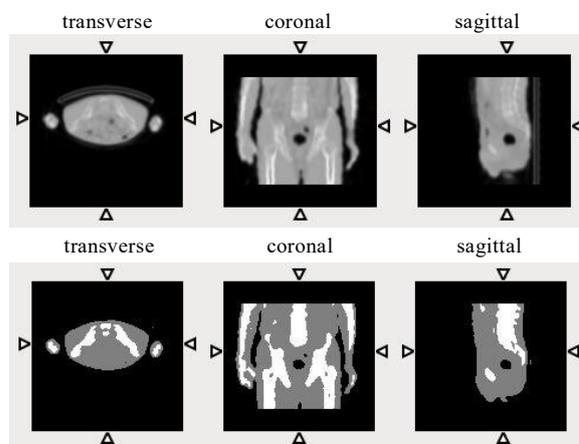


図2 X線CT画像を3値化して得た3D骨SPECT数値ファントム。上: 3次元X線CT画像。下: 3D骨SPECTファントム

2) 臨床骨 SPECT 投影データを用いた画像再構成

臨床用 SPECT-CT 装置で撮像された骨 SPECT 投影データを EM-TV アルゴリズムで画像再構成を行った。骨 SPECT 撮像は、骨スキャン用放射性核種 $^{99m}\text{Tc-MDP}$ を 1045 MBq 投与し、5時間後に撮像、step&shoot で72方向から投影データを1投影あたり15秒の約9分間、LEHR コリメータ、2検出器を用いて収集した。このうち、12方向分の投影データを等間隔に抜き出し少数投影データとした。72方向の投影データに対し ML-EM 法による画像再構成を行い、その再構成画像を目標画像として設定した。また、少数投影データに対して、ML-EM および EM-TV での画像再構成を行った。ML-EM での再構成はイタレーション回数を20回とした。EM-TV において

は、 $\lambda=0.1$ とし、イタレーション回数を 1000 回とした。それぞれの再構成画像上に関心領域 (region of interest: ROI) を設定、ROI 内の平均値に関して目標画像との比較を行った。投影データは 128×128 画素、画素サイズ $4.41806 \text{ mm} \times 4.41806 \text{ mm}$ で、再構成画像は $128 \times 128 \times 128$ 画素、画素サイズ $4.41806 \text{ mm} \times 4.41806 \text{ mm}$ である。

4. 結果

1) 数値ファントム実験

(1) Shepp-Logan ファントム

図 3 に、12 投影および 72 投影でのそれぞれの手法で画像再構成した結果を示す。図 3(b)より、72 投影での ML-EM による再構成画像では原画像に近づいている様子が見られたが、同時に線状のアーチファクトも見られた。図 3(c)より、12 投影での ML-EM による再構成画像では原画像のような形状を判別するのが難しく実用的ではないことがわかる。一方、図 3(d)より、12 投影での EM-TV による再構成画像では原画像により近づいていることが確認できた。

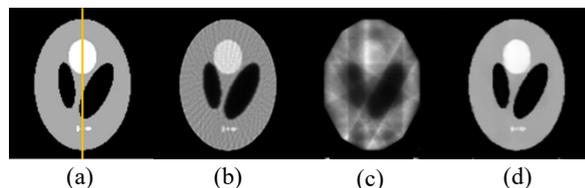


図 3 Shepp-Logan ファントムの再構成画像。(a)原画像。(b)72 投影 ML-EM。(c)12 投影 ML-EM。(d)12 投影 EM-TV。

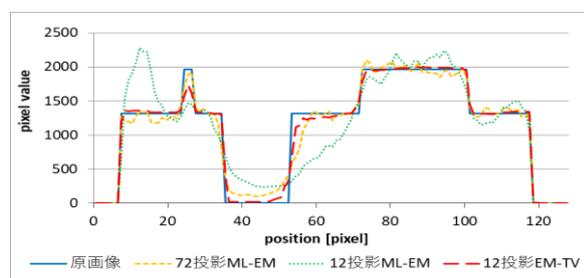


図 4 Shepp-Logan ファントム再構成画像のラインプロフィール。

図 4 に、図 3(a)の黄色線の位置のラインプロ

ファイルを示す。12 投影での EM-TV による再構成画像のプロファイルが原画像のものとはほぼ一致していることが確認できた。

以上から、Shepp-Logan ファントムでは EM-TV による 12 投影での画像再構成が可能であることが確認できた。

(2) 3D 骨 SPECT ファントム

図 5 に、3D 骨 SPECT ファントムの再構成画像のうち 72 投影 ML-EM, 12 投影 ML-EM, 12 投影 EM-TV の画像をそれぞれ示す。また、図 5(a)の黄色線で示した位置のそれぞれのラインプロフィールを図 6 に示す。図 5(c)より、12 投影での ML-EM による再構成画像ではアーチファクトが見られるのに対し、図 5(d)の EM-TV による再構成画像ではアーチファクトが改善されていることがわかる。

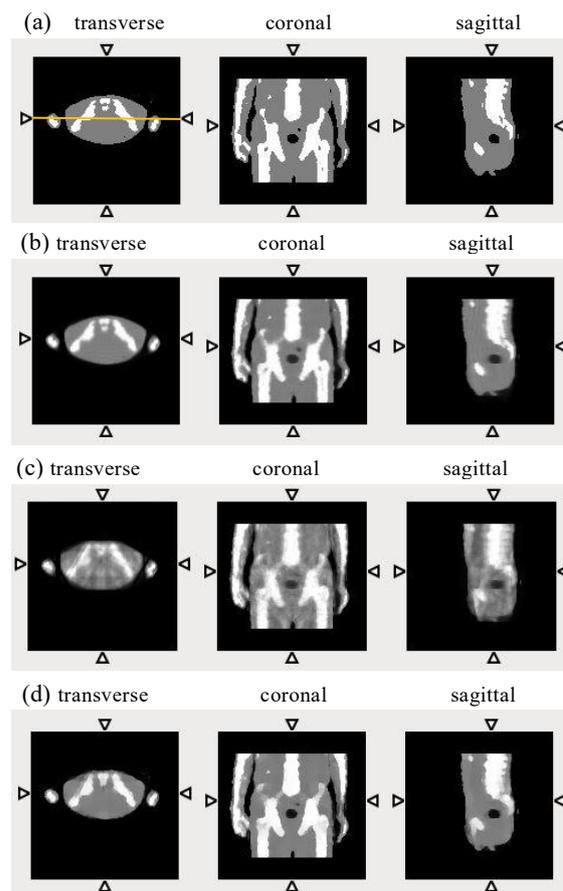


図 5 3D 骨 SPECT ファントム再構成画像。(a)原画像。(b)72 投影 ML-EM。(c)12 投影 ML-EM。(d)12 投影 EM-TV。

図7にそれぞれの再構成画像のRMSEを示す。すべての投影数において、ML-EMよりもEM-TVによる再構成画像のRMSEが小さいことが確認できた。また、72投影でのML-EMによる再構成画像と、12投影でのEM-TVによる再構成画像のRMSEがほぼ等しいことがわかる。このシミュレーション実験の結果から、臨床データを用いた実験での目標画像を72投影のML-EM再構成画像とし、少数投影データを12投影と設定した。

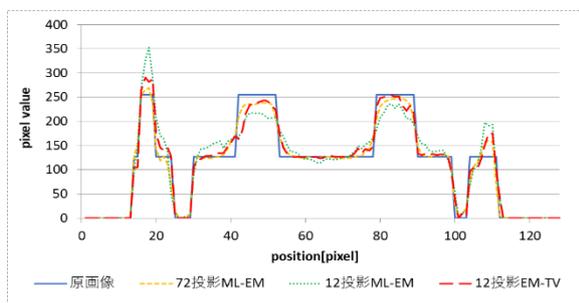


図6 3D骨SPECTファントム再構成画像のラインプロフィール。

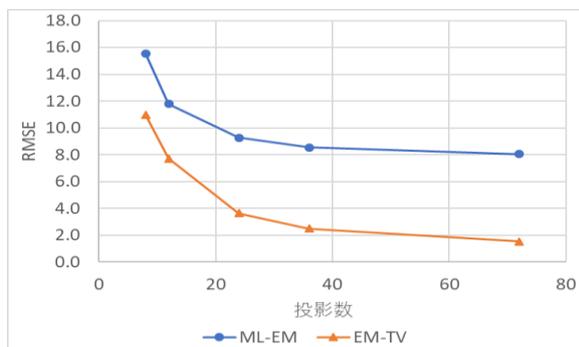


図7 各投影数でのML-EMとEM-TVの再構成画像のRMSEの比較。

2) 臨床骨SPECTデータを用いた画像再構成

図8に、72投影でのML-EMによる再構成画像(目標画像)、12投影でのML-EMによる再構成画像、12投影でのEM-TVによる再構成画像をそれぞれ示す。また、表1にROIを設定し、ROI内の平均値をそれぞれ比較した結果を示す。図8より、12投影でのML-EMによる再構成画像ではアーチファクトが見られるが、EM-TVによる再構成画像では改善さ

れていることが確認できた。さらに、ROIでの評価からML-EMよりもEM-TVによる再構成画像の誤差が少ないことがわかる。これより、少数投影データを用いた際の、EM-TV画像再構成による定量性の改善が確認できた。

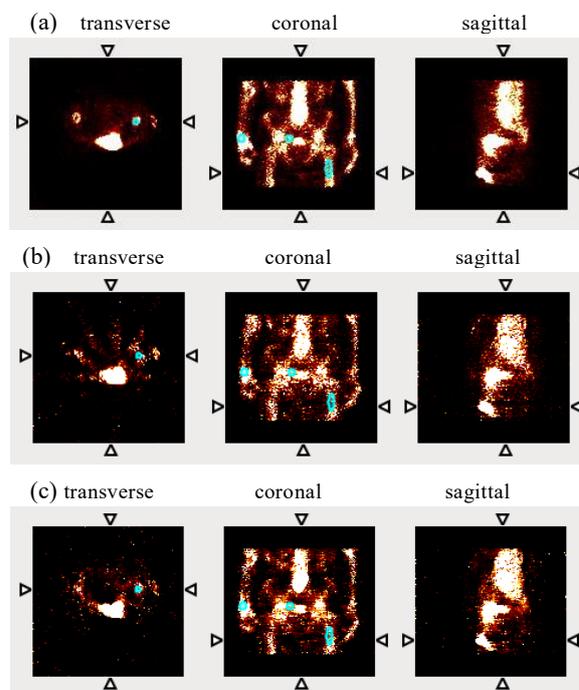


図8 臨床骨SPECTデータの再構成画像。(a)72投影ML-EM。(b)12投影ML-EM。(c)12投影EM-TV。

表1 それぞれの再構成画像でのROI評価

画像再構成法	ROI1(骨盤)		ROI2(大腿骨)		ROI3(手首)	
	平均	誤差(%)	平均	誤差(%)	平均	誤差(%)
ML-EM 72投影	1.69	-	1.26	-	4.91	-
ML-EM 12投影	1.96	15.9	0.90	28.1	4.31	12.4
EM-TV 12投影	1.68	0.6	1.15	8.4	4.74	3.6

5. 考察

2つの数値ファントムを用いたシミュレーション実験において、従来法のML-EM法では12投影でアーチファクトがみられ、画像は大きく崩れたが、EM-TVアルゴリズムによる画像再構成ではエッジを保ったまま平滑化を

行うような効果が見られ、アーチファクトも無く、原画像に近い定量精度の高い画像を得ることができた。また、臨床骨 SPECT 投影データを用いた画像再構成では、ML-EM で見られた顕著なアーチファクトが、EM-TV で劇的に改善した。また、定量評価においても、72 投影の再構成画像に対する定量値の誤差は、12 投影の ML-EM で骨盤、大腿骨、手首のそれぞれで 15.9%, 28.1%, 12.4% とかなり悪かった。それに対して 12 投影の EM-TV で 0.6%, 8.4%, 3.6% と大きく改善され、72 投影の再構成画像に近い値を得ることができた。

しかし、臨床データを用いた EM-TV アルゴリズムによる画像再構成では一部のノイズのカウントが増えてしまった。EM-TV アルゴリズムは、ML-EM 画像再構成と TV による正則化（およびノイズ除去）を繰り返し同時に行う。つまり、ML-EM のイタレーション回数と TV 正則化のイタレーション回数が等しくなる。本実験では、TV 正則化の計算手法として ROF モデルを用いており、その収束速度から正則化に必要なイタレーション回数が多くなってしまっている。そのため、ML-EM のイタレーション回数も増えてしまっているのだが、ML-EM のイタレーション回数が過大に増えてしまうと統計ノイズの影響などから一部のノイズのカウントが増えてしまう。これにより、正則化が間に合わずエッジとして残ってしまうことが原因ではないかと考える。解決案として、TV 正則化の計算手法に Chambolle アルゴリズム [14] の適用を挙げる。TV 正則化の収束速度を向上させることができるので、その結果 ML-EM の過度なイタレーションによる一部のノイズの強調の抑制が期待される。また、統計ノイズの影響を改善する方法としてコリメータ開口補正の実装も方法の 1 つである [15]。

また、臨床データ用いた実験結果では定量精度は大きく改善されたものの、まだ不十分と考えられる。この原因の 1 つとして、吸収や散乱線の影響が挙げられる。今回、吸収補正や散乱線補正を行っていないが、胴体のサ

イズから吸収や散乱線の影響は小さくないと思われる。今後、モンテカルロシミュレーションによって吸収や散乱の影響を評価しつつ、吸収補正や散乱線補正の実装を検討する。また、今回臨床データでの評価は 1 例のみだったが、多数症例での評価も必要である。

さらに今後の課題として、EM-TV アルゴリズムのパラメータ λ について、今回、数値ファントムのシミュレーション実験では $\lambda=0.01$ 、臨床データを用いた実験では $\lambda=0.1$ と経験的に決定し画像再構成を行った。しかし、 λ の値によって再構成画像の精度が大きく変わることを確認しており、より適切な λ の値の決定が重要であると考えられる。今後、 λ の値と再構成画像との関係を調べ、適切な λ の選択方法の考案を課題とする。

最後に、12 投影での骨 SPECT 画像再構成が実現すれば、72 投影で 9 分かかっていた撮像が、15 秒/投影×12 投影=3 分、2 検出器なので 6 投影分のわずか 1.5 分と、極めて短時間の骨 SPECT 検査が可能となる。

6. まとめ

EM-TV アルゴリズムを骨 SPECT へ応用し、それを用いて数値ファントムおよび骨 SPECT 撮像で収集した投影データでの画像再構成を行うことにより、少数投影での骨 SPECT 画像再構成を検討した。結果、従来法と比較し、再構成画像のアーチファクトおよび定量性の改善を確認できた。これにより、骨 SPECT における少数投影での画像再構成の可能性が示唆された。

謝辞

本研究は JSPS 科研費 JP17H04116 の助成を受けたものです。

利益相反の有無

なし。

文献

- [1] Kosuda S, Kaji T, Yokoyama H, et al.: Dose bone SPECT actually have lower

- sensitivity for detecting vertebral metastasis than MRI? *J Nucl Med* **37**: 975-978, 1996
- [2] 小須田茂：骨シンチグラフィと骨 SPECT の適切な使い方. 断層映像研究会雑誌 **28**: 58-64, 2001
- [3] Palmedo H, Marx C, Ebert A, et al.: Whole-body SPECT/CT for bone scintigraphy: diagnostic value and effect on patient management in oncological patients. *Eur J Nucl Med Mol Imaging* **41**: 59-67, 2014
- [4] Van den Wyngaert T, Strobel K, Kampen WU, et al.: The EANM practice guidelines for bone scintigraphy. *Eur J Nucl Med Mol Imaging* **43**: 1723-1738, 2016
- [5] 増田安彦, 川渕安寿, 片淵哲朗, 他：臨床に役立つ基準画像の収集・処理・表示・出力のポイント. 核医学技術 **28**: 13-66, 2008
- [6] 日本核医学技術学会 SPECT 標準化委員会：骨 SPECT 撮像の標準化に関するガイドライン 1.0. 核医学技術 **37**: 517-530, 2017
- [7] 篠原広行, 小島隆行, 橋本雄幸：圧縮センシングによる少数投影からの画像再構成. 断層映像研究会雑誌 **40**: 31-42, 2014
- [8] 工藤博幸：低被曝 CT における画像再構成法—統計的画像再構成, 逐次近似画像再構成, 圧縮センシング—. *Med Imag Tech* **32**: 239-248, 2014
- [9] Rudin L, Osher S, Fatemi E: Nonlinear total variation based noise removal algorithms. *Physica D* **60**: 259-268, 1992
- [10] Block KT, Uecker M, Frahm J: Undersampled radial MRI with multiple coils. Iterative image reconstruction using a total variation constraint. *Magn Reson Med* **57**: 1086-1098, 2007
- [11] Shepp LA, Vardi Y: Maximum likelihood reconstruction for emission tomography. *IEEE Trans Med Imaging* **MI-1**: 113-122, 1982.
- [12] Sawatzky A, Brune C, Wbbeling F, et al.: Accurate EM-TV algorithm in PET with low SNR. In 2008 IEEE Nuclear Science Symposium Conference Record, Dresden, 2008, pp5133-5137
- [13] Sasaya T, Sunaguchi N, Aoki D, et al.: EM-TV reconstruction algorithm for pinhole-type fluorescent X-ray computed tomography. In Proceedings of 2015 10th Asian Control Conference (ASCC), Kota Kinabalu, 2015, Paper ID 1570073831
- [14] Chambolle A: An Algorithm for Total Variation Minimization and Applications. *Journal of Mathematical Imaging and Vision* **20**: 89-97, 2004
- [15] 崎本智則, 銭谷 勉, 石田健二, 他：頭部 SPECT におけるコリメータ開口補正およびモンテカルロ法に基づく散乱線補正を用いた画像再構成法の定量精度評価. *Med Imag Tech* **28**: 135-144, 2010

Bone SPECT reconstruction from a small number of projections using EM-TV algorithm

Michikazu Kanazawa^{*1}, Tenta Sasaya^{*2}, Shota Hosokawa^{*3}, Hiroshi Watabe^{*4},
Tetsuya Yuasa^{*2}, Yasuyuki Takahashi^{*3}, Tsutomu Zeniya^{*1}

*1 Graduate School of Science and Technology, Hirosaki University

*2 Graduate School of Science and Engineering, Yamagata University

*3 Graduate School of Health Sciences, Hirosaki University

*4 Cyclotron and Radioisotope Center, Tohoku University

Bone scintigraphy is difficult to understand anatomical position and evaluate quantitatively in the regions of the thorax and pelvis especially. Three-dimensional image of bone SPECT is effective for this case. However, SPECT imaging time is long because SPECT reconstruction needs many projections. So, shortening of SPECT imaging time is desired. In this study, we applied the expectation maximization-total variation (EM-TV) algorithm combining the maximum likelihood-expectation maximization (ML-EM) method, which is a statistical iterative image reconstruction method, and the total variation (TV) regularization to bone SPECT reconstruction, and evaluated feasibility of the bone SPECT in a small number of projections using the EM-TV reconstruction. Image reconstruction by EM-TV algorithm is realized by alternately updating the statistical likelihood in observation data and the TV of the image. To evaluate we performed computer simulation with numerical phantoms and image reconstruction with EM-TV algorithm on clinical bone SPECT projection data in a small number of projections. As a result, the artifact and the quantitative accuracy could significantly be improved as compared to the ML-EM method as conventional method. These results suggest a possibility of bone SPECT reconstruction from a small number of projections using EM-TV algorithm.

Key words: Bone SPECT, a small number of projections, total variation, EM-TV algorithm, image reconstruction

著者紹介

和文でも英文でも可。

ここに顔写真を
貼り付けてくだ
さい。

山田 太郎 (やまだ たろう)
1990年筑波大・情報学群・情報学類卒。1995
年同大大学院博士課程・システム情報・CS
専攻了。現在、筑波大・システム情報・准
教授。2005年日本医用画像工学会論文賞受
賞。工博。CTとPETを中心とした医用イメ
ージング、画像処理の研究に従事。IEEE,
電子情報通信学会、各会員。

ここに顔写真を
貼り付けてくだ
さい。

鈴木 次郎 (すずき じろう)
1995年筑波大・医学専門学群卒。現在、医
用画像研究所・主任研究員。医博。計算機
支援診断の研究に従事。

頭部専用 PET における放射能・減弱補正係数同時推定法の 深層学習を用いた精度向上手法の検討

呉 博文*¹ 田島 英朗*² 山谷 泰賀*² 小尾 高史*³

要旨

高齢化社会の進展により、認知症患者の増加が大きな問題となっている。PET はアルツハイマー型認知症の原因物質である特定のタンパク質の蓄積状況を画像として測定することが可能であることから、認知症の早期発見を目的とした検診での利用への期待が高まっている。現在、高性能でありながら低コストでコンパクトな筐体を目指した頭部専用 PET 装置の開発を進めているが、減弱補正用のデータを取得する機構を省略しているため、PET 画像の定量性を確保するために別途撮影した CT や MRI など位置合わせして補正用のデータを生成する必要がある。そこで本研究では、頭部専用 PET 装置の測定のみから診断に十分な画質と定量性を得るために、PET 画像再構成に必要な減弱補正画像を同時推定する手法と深層学習を利用した画像補正手法を組み合わせた再構成手法を提案し、計算機シミュレーションによりその有効性を示した。

キーワード：PET, 画像再構成, 深層学習, 減弱補正, U-Net

1. はじめに

現在、日本では高齢化社会の進展により、認知症患者の増加が大きな問題となっている。厚生労働省によると、認知症の患者数は 2012 年時点で約 462 万人、2025 年には約 700 万人まで増加することが予想されている[1]。そのため、認知症対策は喫緊の課題となっており、その早期診断の実現が期待されている。

PET (Positron Emission Tomography) は、認知症の原因となるタンパク質の蓄積を画像化することによって、早期診断を可能とすることが期待されている。今後、脳 PET の需要が高まる

ことが予想されるため、従来の PET/CT 装置と比べて低コストでコンパクトな普及型の頭部専用 PET 装置の開発を進めている [2, 3]。

ここで、PET 装置における画像再構成において、減弱補正は必須のプロセスである。従来の PET/CT では CT 装置によって減弱係数を取得することで、PET 画像の減弱補正を行う。しかしながら、頭部専用 PET 装置では、装置サイズやコストの観点から、別途撮影した CT や MRI 画像を用いることを想定し、CT 装置などの減弱補正用データを取得する機構を省略している。今後よりいっそう広く普及させるためには、頭部専用 PET 装置のみから診断に十分な画質と定量性を確保できることが望ましいため、Time-Of-Flight(TOF)情報を使って、減弱係数と放射能分布を同時に推定する手法の検討を進めている。

一方、近年機械学習を様々な分野に取り入れた研究がなされており、これまでに、MLAA (Maximum Likelihood reconstruction of Attenuation and Activity) [4]という放射能と減弱

*1 東京工業大学工学院情報通信系情報通信コース

*2 量子科学技術研究開発機構 放射線医学総合研究所

*3 東京工業大学 科学技術創成研究院 未来産業技術研究所兼社会情報流通基盤研究センター

係数分布（減弱マップ）の同時推定手法に対して、深層学習ネットワークを組み込み、その精度を向上させる研究がなされている[5].

本稿では、頭部専用 PET において、放射能分布と減弱補正係数 (ACF: Attenuation Correction Factor) の同時推定法である MLACF (Maximum Likelihood reconstruction of activity and Attenuation Correction Factor) [6] と、ACF の精度を向上させるための深層学習を組み合わせ、最終的な再構成画像の精度向上が可能な手法を提案し、計算機シミュレーションによって有効性を検証する.

2. 提案手法

提案手法の流れを図 1 に示す.本手法では、まず頭部専用 PET 装置で得られた TOF-PET データに対して、MLACF による再構成を行う. その後、得られた放射能分布を順投影して作成したサイノグラムと ACF サイノグラムを用いて U-Net[7]の入力を作成し、高精度な ACF サイノグラムの推定を行う. 最後に推定された高精度 ACF サイノグラムを用いた MLEM 法で放射能分布の推定を行う.

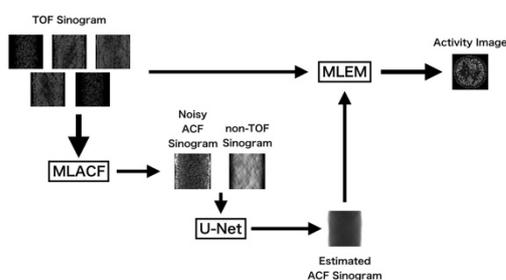


図 1 ワークフロー

2. 1. ネットワークアーキテクチャ

図 2 に本研究で用いる U-Net のアーキテクチャを示す.

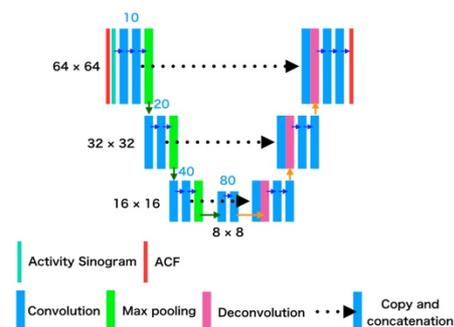


図 2 ネットワークアーキテクチャ

各 Convolution 層でのカーネルサイズは 3×3 , stride は 1 として構成し、各 pooling 層でのカーネルサイズは 2×2 , stride は 2 で構成した. さらに、各 Deconvolution 層においては、カーネルサイズは 3×3 , stride は 2 で構成した.

図 3 に本研究で用いた U-Net の入力と出力を示す.

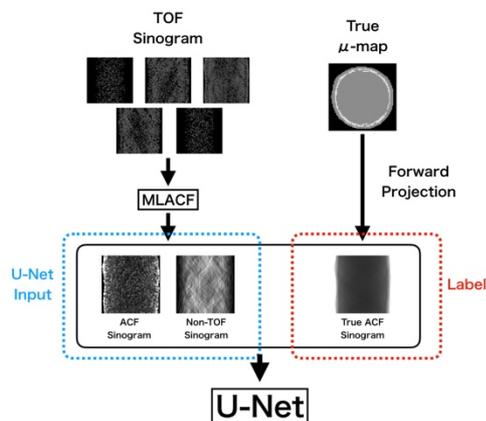


図 3 U-Net の入出力

本研究では MLACF で同時推定した放射能分布から Non-TOF のサイノグラムを作成し、それと出力の ACF サイノグラムを連結させて U-Net の入力とし、ACF サイノグラムの真値をラベルとした.

2. 2. 学習

U-Net を ACF サイノグラムの予測に用いるため、損失関数は出力とラベルの MSE とした. ま

た，最適化手法として Adaptive moment estimation method (Adam)[8]を用い，学習率は 0.001， β_1 を 0.9， β_2 を 0.999 に設定した．加えて，収束を高速化させるため，各重みは Xavier method[9]で初期化し，各レイヤーにおいて Batch Normalization[10]を行なった．さらに，過学習を防ぐため，最初に Deconvolution に入る前の層のノードに対し確率 0.5 で Dropout[11]を行なった．学習におけるバッチサイズは 32，エポック数は 20 とした．

3. 計算機シミュレーション

3. 1. シミュレーションデータ

シミュレーションを行うためのデータは Brainweb[12]において公開されている 20 の脳モデルから作成した．放射能分布は，一般的な脳への蓄積状況を鑑み，灰白質にある程度集中するように作成した．また，一部のスライスにランダムに 5 パターンの放射能の高い部位を加えた．減弱マップについては頭を灰白質/白質部と骨のみで構成されていると仮定し構成した．この減弱マップに対して TOF サイノグラムと ACF サイノグラムを線積分による順投影により計算し，ノイズなしのデータセットを作成した．この時想定した時間分解能は 520ps とし，ガウス関数により TOF のカーネルを設定した．放射能分布に関しては，PET 薬剤として 130MBq の ^{18}F -FDG を 60kg 前後の人間に対して投与することを想定した．PET 感度として 2-5%を想定し，10 分前後の計測時間におけるスライス厚 0.5 mm， $3 \times 3\text{mm}^2$ のピクセル内の線量を仮定したものをを用いた．

v また，ノイズなしの TOF サイノグラムに対してポアソンノイズを加えてノイズありの TOF サイノグラムを作成した．図 4 に TOF サイノグラムの生成のプロセスを示す．この時，角度方向に 64 回のサンプリングで，3mm の解像度を想定した．これにより 64×64 ピクセルの TOF サイノグラムを作成した．

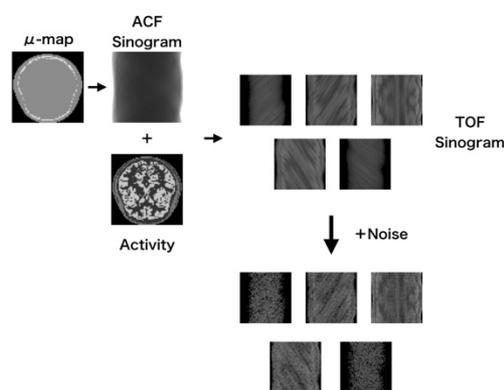


図 4 シミュレーションデータ生成

使用した脳モデルのうち，16 個をトレーニングセット作成のためのデータセットとして使用した．また，残りの 4 個の脳モデルから評価用のデータを生成した．まず，トレーニングセットと同等の放射能濃度で生成した放射能分布と減弱マップを作成し，TOF サイノグラムを生成した後ポアソンノイズを加えた．また，ノイズが増加した際の影響を確認するためにカウントを半分にした放射能分布を用いた TOF サイノグラムも同様に作成した．作成した評価用データのうち，2 個の脳モデルから生成したものを検証用に，残り 2 個の脳モデルから生成したものをテストセット用として使用した．図 5 にトレーニング，検証，テストセットに使用した脳モデルから生成した放射能分布及び減弱マップのスライスの例を示す．図の中には TOF データを作成するための元データがそれぞれ 3 例ずつ示されており，検証及びテストセットの場合にはカウントを下げた場合の例 (Example 3) が含まれている．

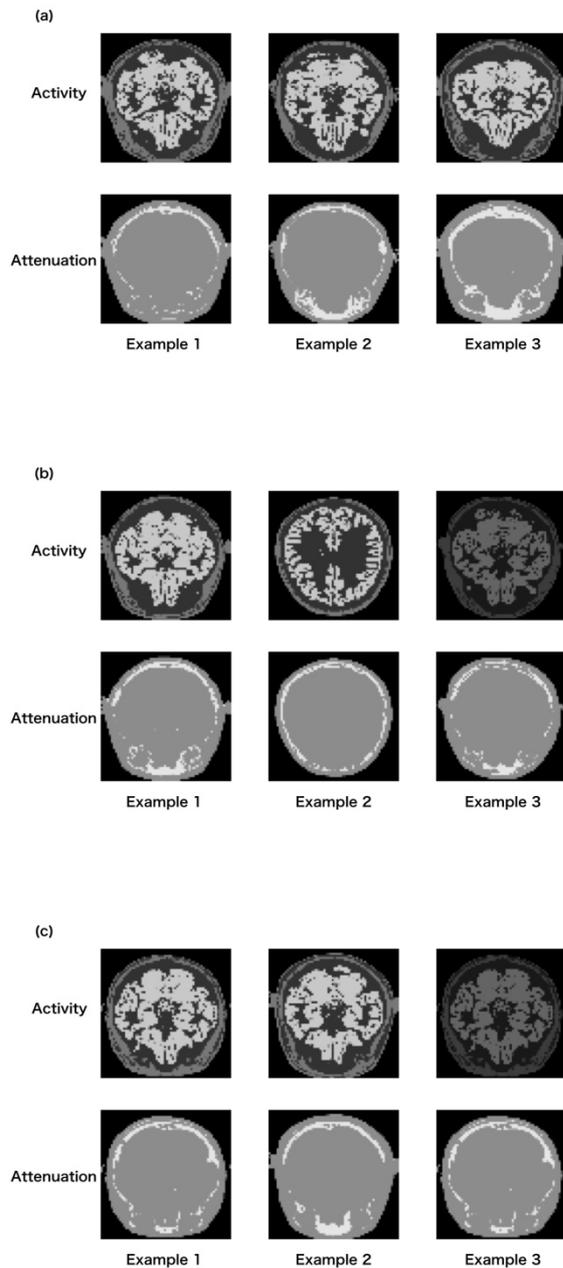


図 5 (a)トレーニングセットの元データ例 (b)検証セットの元データ例 (c)テストセットの元データ例

3. 2. シミュレーション結果

以下に U-Net から出力された ACF とその ACF を用いて再構成された放射能分布について示す。また, MLACF の反復回数は 50 回とし, この結果は全てテストセットにおける結果で

ある。

画像の誤差は, Normalized Root Mean Square Error(NRMSE)を用いて評価した。

$$NRMSE = \sqrt{\frac{1}{N} \sum_i \frac{(a_i^{out} - a_i^{true})^2}{\overline{a^{out}} \overline{a^{true}}}} \quad (1)$$

ここで, N はピクセル数を表し, a_i^{out} は ACF サイノグラムの i 番目のピクセルの推定値, a_i^{true} は ACF サイノグラムの i 番目のピクセルの真値を表す。また, $\overline{a^{out}}$ は ACF サイノグラムの推定値の平均を表しており, $\overline{a^{true}}$ は ACF サイノグラムの真値の平均を表している。

まず, ACF サイノグラムについて MLACF の出力と U-Net の出力画像の比較をそれぞれノイズなし, SN5.5(35 万カウント前後), SN3.9(18 万カウント前後)に分けて図 6 に示した後数値的な比較について述べる。

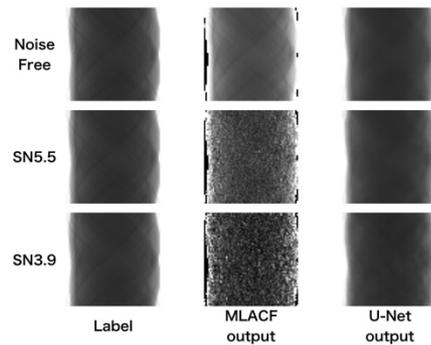


図 6 ACF サイノグラム比較

ここで視覚的に明らかにノイズが少なくなっていることが見て取れる。

NRMSE を比較したものを表 1 に示す。

表 1 ACF の NRMSE の比較

	MLACF	U-Net
データ全体	0.34	0.051
ノイズなし	0.29	0.039
SN5.5	0.31	0.046
SN3.9	0.43	0.067

以上より, 提案手法によりノイズを数%のオーダーまで除去できることが確認できた。

次に、ノイズの除去された ACF の放射能分布の推定に対する影響を確認するため、図 7 に再構成画像による比較をノイズなし、SN5.5、SN3.9 に分けてそれぞれ示す。

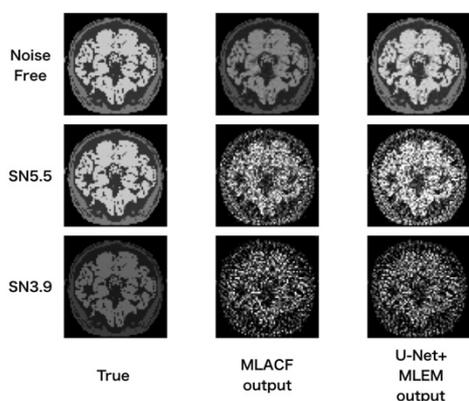


図 7 SN3.9 の再構成結果

ここでは、視覚的には多少の改善は見られるものの、顕著ではない。ここでも NRMSE による評価結果を表 2 に示す。いずれの場合においても改善していることが分かる。

表 2 再構成画像の NRMSE の比較

	MLACF	U-Net + MLEM
ノイズなし	0.53	0.17
SN5.5	0.82	0.69
SN3.9	1.5	1.3

4. まとめ

本研究では、頭部 PET 装置における画像再構成において深層学習を用いた手法による精度向上について検討した。再構成された ACF サイノグラムにおいては従来の MLACF に比べて顕著な改善が確認された。また、放射能分布に関しては、ノイズなし、SN5.5、SN3.9 の 3 つの場合に分けて確認した結果、十数%以上の精度向上が見られ、ノイズなしの場合には特に顕著であった。ノイズありの場合においては低カウントになりノイズが増えるほど効果が減少するものの精度改善が可能であることを示した。したがって、提案手法は頭部専用 PET 装置において有効であり、今後も発展の余地があることが

示唆された。

謝辞

本研究の一部は JSPS 科研費 16K21637 の助成を受けたものです。

利益相反の有無

なし。

文 献

- [1] 厚生労働省：認知症施策推進総合戦略～認知症高齢者等にやさしい地域づくりに向けて～（新オレンジプラン）2017
- [2] 放射線総合医学研究所：世界初、ヘルメット型 PET の開発に成功—高性能・小型の頭部専用装置で認知症早期診断の普及へ—2015
- [3] H. Tashima, E. Yoshida, H. Wakizaka et al: First prototyping of a dedicated PET system with the hemisphere detector arrangement. *Phys. Med. Biol.* 64 065004. March 8, 2019
- [4] A. Rezaei, M. Defrise, G. Bal et al: Simultaneous reconstruction of activity and attenuation in time-of-flight PET. *IEEE Trans. Med. Imag.*, vol. 31, no. 12, Dec. 2012. pp. 2224-2233.
- [5] D. Hwang, K. Y. Kim, S. K. Kang et al: Improving the Accuracy of Simultaneously Reconstructed Activity and Attenuation Maps Using Deep Learning. *J Nucl Med.*, vol. 59, no. 10, October 1, 2018. pp. 1624-1629.
- [6] A. Rezaei, M. Defrise, G. Bal et al: ML-Reconstruction for TOF-PET With Simultaneous Estimation of the Attenuation Factors. *IEEE Trans. Med. Imag.*, vol. 33, no. 7, Jul. 2014. pp. 1563-1572.
- [7] O. Ronneberger, P. Fischer, T. Brox: U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, Springer, LNCS, Vol.9351, 2015. pp. 234-241.
- [8] D. P. Kingma, J. Ba: Adam: A Method for Stochastic Optimization. A conference paper at

- the 3rd International Conference for Learning Representations, San Diego, 2015.
- [9] X. Glorot, Y. Bengio, “Understanding the difficulty of training deep feedforward neural networks”, Proceedings of the 13th International Conference on Artificial Intelligence and Statistics (AISTATS), Chia Laguna Resort, Sardinia, Italy. 2010.
- [10] S. Ioffe, C. Szegedy: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. arxiv.org website <https://arxiv.org/abs/1502.03167>
- [11] N. Srivastava, G. Hinton, A. Krizhevsky , I. Sutskever et al: Dropout: A Simple Way to Prevent Neural Networks from Overfitting. Mach Learn Res. 15, 2014. pp. 1929-1958.
- [12] BrainWeb: Simulated Brain Database, website <http://brainweb.bic.mni.mcgill.ca/brainweb/>
- [13] NIST, X-Ray Mass Attenuation Coefficients, website <https://www.nist.gov/pml/x-ray-mass-attenuation-coefficients>

Accuracy improvement of simultaneous activity and attenuation correction factor estimation for dedicated brain PET using deep learning

Bowen WU^{*1}, Hideaki TASHIMA^{*2}, Taiga YAMAYA^{*2} Takashi OBI^{*1}

*1 Tokyo Institute of Technology

*2 National Institute of Radiological Sciences, QST

As aging of society developed, dementia became a severe problem. We expect a demand for using positron emission tomography (PET) in diagnosis of dementia at early phase will increase because the PET can measure accumulation of protein causing dementia caused by the Alzheimer's disease. To meet the demand for widespread use of PET, we are developing a dedicated brain PET scanner to achieve high performance with a compact and low cost gantry. Attenuation correction data necessary for quantitative imaging are required to be generated by registering a separately acquired CT or MRI image as the scanner does not have an attenuation correction device to make the gantry as compact as possible. In this work, we propose a method to simultaneously estimate attenuation correction factor and activity images by combining with a deep learning network for improving accuracy. We demonstrated the effectiveness of the method by a computer simulation.

Key words: PET, image reconstruction, deep learning, attenuation correction, U-Net

膵癌腫瘍病理顕微鏡画像の染色変換

足立 秀雄*¹ クグレ マウリシオ*¹ 岩本 千佳*² 大内田 研宙*²

橋爪 誠*² 横田 達也*¹ 本谷 秀堅*¹

要旨

本研究の目的は膵臓癌病理画像の3次元多チャンネル画像を生成するために病理画像の染色変換を行うことである。空間的に連続する病理切片の顕微鏡画像より3次元画像を再構成する。この3次元病理画像は生体のミクロな3次元解剖構造を観察する上で有用である。すべての切片をHE染色など単一の染色で染めれば、その染色の3次元病理画像を得ることができる。本研究の目的は、同一標本を異なる染色液で染めたときに得られるであろう多チャンネルの3次元病理画像を構築することである。この3次元画像は、各チャンネルがそれぞれ異なる染色液で染色した病理画像を表現する。病理切片は単一の染色でしか染めることが出来ないため、多チャンネルの3次元病理画像を構築するためには、各病理画像を染色変換しなければならない。本稿ではGANによる染色変換の結果を報告する。

キーワード：染色変換, GAN, pix2pix, 膵臓癌

1. はじめに

膵臓癌の研究は重要であり、現在でも基礎研究が継続して行われている。本研究では人と類似した膵臓癌を発症する実験用マウスの膵癌腫瘍の病理画像群を用いる。マウスの膵臓を連続的に薄切片し、それぞれをHE/MT/CK19/Ki67の4種類の染色により交互に染色した。連続する2枚の薄切片は、腫瘍の異なる断面ではあるものの、共通して観察される解剖構造が多い。これら画像間で対応するランドマークを検出し、非剛体位置合わせを適用することにより3次元病理画像を構築する[1]。

2. GANによる染色変換

本研究の目的は膵臓癌腫瘍の染色変換により多

チャンネル3次元病理画像を構築することである[2]。そのためにHE染色をMT染色とCK19染色に変換する。この染色変換にはGenerative Adversarial Network(GAN)のうち、pix2pix[3]を採用する。Pix2pixは画像の生成器にU-netを用い、識別器には畳み込みネットワークを複数用いる。それぞれの識別器は生成画像を異なるスケールで観察して真偽を判定する。具体的には、3つの識別器を用意し、それぞれの識別器に元画像と、ダウンサンプルの比率の異なる画像を入力する。これにより、大域と局所の双方で実画像と整合する偽画像を生成できるようになる。

最適化する目的関数は次のとおりである。

$$\max_G \min_{D_1, D_2, D_3} \sum_{k=1,2,3} \mathcal{L}_{GAN}(G, D_k) + \lambda \mathcal{L}_{L1} \quad (1)$$

$\mathcal{L}_{GAN}, \mathcal{L}_{L1}(G)$ は次のように与えられる。

*1 名古屋工業大学

*2 九州大学

$$\mathcal{L}_{GAN}(G, D) = \mathbb{E}_{(s,x) \sim p_{data}(s,x)} [\log D(s, x)] + \mathbb{E}_{s \sim p_{data}(s)} [1 - D(s, G(s))]$$

$$\mathcal{L}_{L1}(G) = \mathbb{E}_{(s,x) \sim p_{data}(s,x)} [\|x - G(s)\|_1]$$

本研究ではsがHE染色、xがsと対応するMT染色である。このGANを用いHE染色からMT染色とCK19染色への変換を行った。Pix2pixの学習に必要なペア画像は非剛体位置合わせを行い作成した。

3. 実験

実験の詳細設定について説明する。最適化手法についてはAdamを採用し $\alpha = 0.0002, \beta_1 = 0.5, \beta_2 = 0.999$ とした。式(1)の λ は100とした。また学習にサイズ 1024×512 の684枚の画像を利用し、水平垂直に反転するdata augmentationを行った。

染色変換結果を図1に示す。図1上段が入力したHE染色、中段がターゲット画像、下段が染色変換結果である。また左がMT染色、右がCK19染色への変換結果である。

染色変換後の断面図を示す。図2左上はHE染色193枚とMT染色63枚、右上はHE染色193枚とCK19染色63枚、各256枚を臓器からスライスした順に並べた断面図の一部である。図2下段はHE染色をMT染色、CK19染色にそれぞれ変換した後の断面図である。

4. まとめ

本研究では染色変換法を提案した。今後は一つの染色から同時に複数染色へと変換する手法などを開発する。

5. 利益相反の有無

なし

文献

- [1] Mauricio Kugler, Yushi Goto, Naoki Kawamura, et al.: Accurate 3D Reconstruction of a Whole Pancreatic Cancer Tumor from Pathology Images with Different Stains. Miccai

Workshop, COMPAY

- [2] Masayuki Fujitani, Yoshihiko Mochizuki, Satoshi Iizuka, et al.: Re-staining Pathology Images by FCNN. International Conference on Machine Vision Applications (MVA), 2019
- [3] Isola Phillip, Zhu Jun-Yan, Zhou Tinghu, et al.: Image-to-Image Translation with Conditional Adversarial Networks. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017

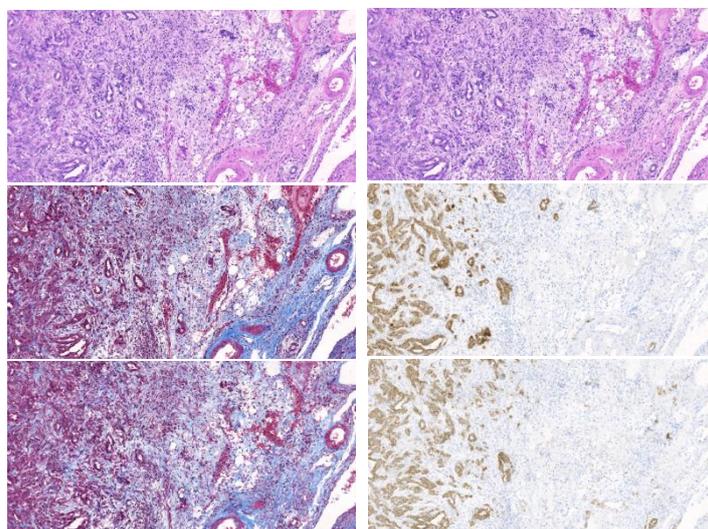


図1 染色変換結果。上段入力画像、中段ターゲット画像、下段染色変換結果。

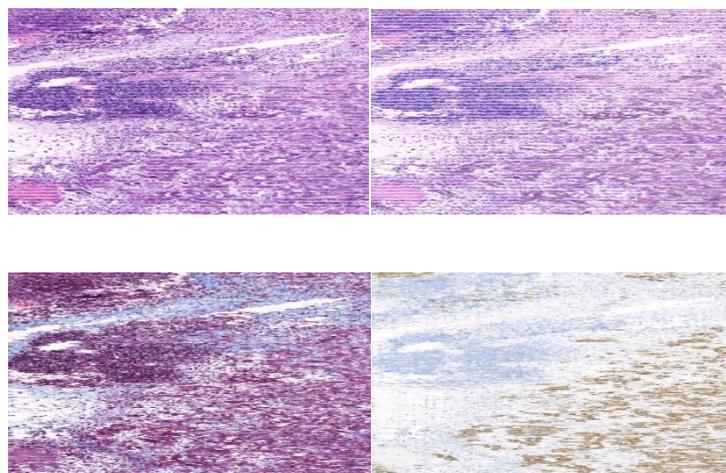


図2 pix2pixによる染色変換前後の断面図。上段が染色変換前、下段が染色変換後。

Staining transformation for Microscopic Pathology Images of Pancreatic Cancer Tumor

Hideo ADACHI^{*1}, Mauricio KUGLER^{*1}, Chika IWAMOTO^{*2}, Ohohda KENOKI^{*2}

Makoto HASHIZUME^{*2}, Tatsuya YOKOTA^{*1}, Hidekata HONTANI^{*1}

^{*1} Nagoya Institute of Technology

^{*2} Kyushu University

Key words: Stain Transfer, GAN, pix2pix, Pancreatic cancer

The purpose of this study is to carry out staining transformation of pathological images to generate three-dimensional multi-channel images of pancreatic cancer pathological images. A three-dimensional image is reconstructed from microscopic images of spatially consecutive pathological sections. This three-dimensional pathological image is useful for observing the microscopic three-dimensional anatomical structure. If all sections are stained with a single stain such as HE staining, a three-dimensional pathological image of the stain can be obtained. The purpose of this study is to construct a multi-channel three-dimensional pathological image that may be obtained when the same specimen is dyed with different stains. Pathological sections can only be stained with a single stain. Therefore, in order to construct a multi-channel three-dimensional pathological image, each pathological image must be transformed. In this paper, we report the result of stain transformation by GAN.

MR エラストグラフィによる内包ファントムの 粘弾性分布の評価

菅 幹生*¹ 石井 孝樹*¹ 岸本 理和*² 小島 隆行*²

要旨

Magnetic resonance imaging (MRI) を利用して、生体内の粘弾性率を非侵襲的に評価する手法として magnetic resonance elastography (MRE) がある。MRE は外部加振装置により撮像対象内部に発生させた弾性波を MRI で画像化し、弾性波画像から逆問題を解くことで粘弾性率を推定する。本研究では生体組織の粘弾性率と周波数特性を模擬した内包ファントムを使用して、MR エラストグラフィにより内包領域が検出可能な撮像条件を検討することを目的とした。硬さの異なる内包領域を有するファントムを用いた実験結果より、内包領域の検出には、内包領域の大きさと波長の関係、波長のピクセル数などを考慮して撮像パラメータを設定する必要があることを明らかにした。

キーワード：MRI, エラストグラフィ, 内包領域, 撮像条件

1. はじめに

疾病と生体組織の弾性率には相関がある。

Magnetic resonance imaging (MRI) を利用して、生体内の粘弾性率を非侵襲的に評価する手法として magnetic resonance elastography (MRE) がある[1]。MRE は外部加振装置により撮像対象内部に発生させた弾性波を MRI で画像化し、弾性波画像から逆問題を解くことで粘弾性率を推定する。本研究では、MRE により得られる粘弾性率分布を腫瘍などの検出に利用することを想定し、生体組織の粘弾性率と周波数特性を模擬した内包ファントムを使用して、MRE により内包領域が検出可能な撮像条件を検討する

ことを目的とした。

2. 方法

外部加振周波数 60 Hz での MRE 測定において背景領域の貯蔵弾性率 (G') が 3.1 kPa, 内包領域の G' が 1.5, 5.3, 9.1 kPa となる 3 種類の円筒型アクリル容器入り内包ファントム (名称をそれぞれ A, B, C とする) を作成した。アクリル容器の内径は 144 mm, 高さは 128 mm, 2 つの内包領域の直径は 20 mm と 30 mm とした。

MRE 測定は 3 T MRI (MAGNETOM Skyra, Siemens) を用いた SE-EPI ベースの MRE パルスシーケンス (WIP) を利用した。撮像パラメータは、TR/TE: 3000/97 ms, Matrix: 128×128, FOV: 384×384 mm, スライス枚数: 15 枚, スライス厚: 3.0 mm とし、積分型粘弾性率分布推定法[4]を用いて算出した。外部加振周波数は 40, 60, 90, 120 Hz とした。得られた貯蔵弾性率分布は図 1 に示す関心領域において式 1 に示すコントラスト対雑音比 (contrast to noise ratio: CNR) を用いて評価した。

*1 千葉大学

[〒263-8522 千葉市稲毛区弥生町 1-33]

e-mail: mikio.suga@faculty.chiba-u.jp

*2 量子科学技術研究開発機構放射線医学総合研究所

$$CNR = \frac{|M_{s1} - M_{s2}|}{\sqrt{SD_{s1}^2 + SD_{s2}^2}} \quad (1)$$

ここに、 M_{s1}, M_{s2} は対象とする2種類のROIの平均値、 SD_{s1}, SD_{s2} は対象とする2種類のROIの標準偏差を表す。

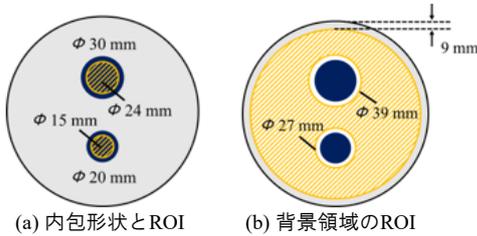


図1 CNR算出用関心領域と内包形状 (coronal 断面)

3. 結果と考察

図2に内包型ファントムの貯蔵弾性率分布、図3に内包直径ごとのCNRを示す。各ファントムや測定周波数におけるCNRより、内包領域が背景領域よりも硬いファントムBとCでは周波数が高いほどCNRも上昇し、検出能が向上した。一方、内包領域が柔らかいファントムAでは120 Hzで検出能が低下した。周波数が高いほど弾性波の波長が短くなり、柔らかい内包領域において1波長を構成するpixel数が不足したことが原因と考えられる。今回の測定条件では硬さの異なる小領域の検出には1波長を構成するpixel数は4以上、そして半波長以上がその小領域に入るように測定周波数を設定する必要があると考えられる。

3. まとめ

生体組織の粘弾性率と周波数特性を模擬した内包ファントムを使用した実験により、内包領域の検出には、内包領域の大きさと波長の関係、波長のピクセル数などを考慮して撮像パラメータを設定する必要があることが示唆された。

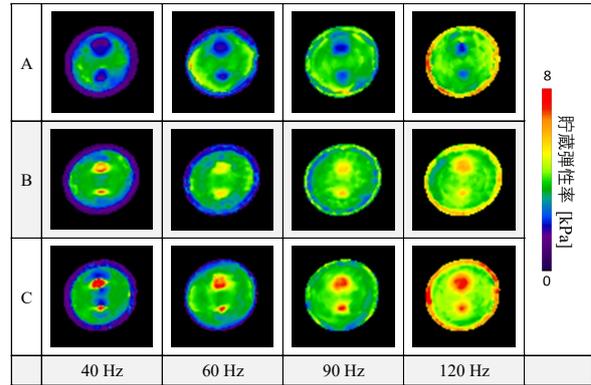
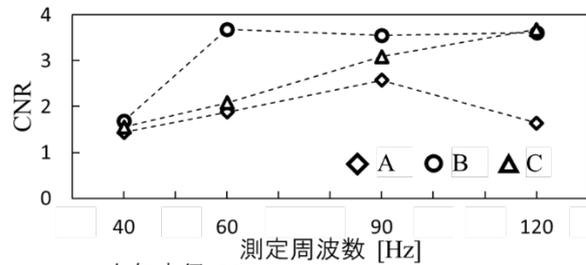
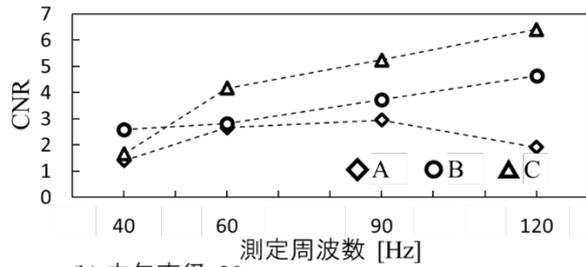


図2 内包型ファントムの貯蔵弾性率分布



(a) 内包直径 20 mm



(b) 内包直径 30 mm

図3 内包型ファントムの CNR

謝辞

本研究の一部は JSPS 科研費 JP17H02115, JP17H05279 の助成を受けたものです。

利益相反の有無

なし

文献

- [1] Muthupillai R, Lomas DJ, Rossman PJ, et al.: Magnetic resonance elastography by direct visualization of propagating acoustic strain waves. *Science* **29**: 1854-1857, 1995

Evaluation of Viscoelasticity Distribution of Embedded Phantom by MR Elastography

Mikio SUGA^{*1,2}, Koki Ishii^{*1}, Riwa Kishimoto^{*2}, Takayuki Obata^{*2}

*1 Chiba University

*2 National Institute of Radiological Sciences, QST

Magnetic resonance elastography (MRE) is a noninvasive method to evaluate viscoelasticity distribution using magnetic resonance imaging (MRI). MRE visualize the shear wave generated inside of object by external driver using MRI, and estimates the viscoelasticity by inversion algorithm from the elastic wave image. In this study, we aimed to investigate the imaging conditions that can detect the embedded region by MRE using tissue mimicking embedded phantoms. The results indicate that it is necessary to select imaging parameters in consideration of the relationship between the size of the embedded area and a shear wavelength, the number of pixels of a shear wavelength.

Key words: MR elastography, viscoelasticity distribution, embedded phantom, shear wavelength

Generative Adversarial Frameworks を用いた

腹部 CT 像における非造影像からの造影像の推定

小田 昌宏*¹ 隈丸 加奈子*² 青木 茂樹*² 森 健策*^{1,3}

要旨

本稿では、深層学習を用いて腹部領域の非造影 CT 像から造影 CT 像を推定する方法について述べる。診断及び治療時における血管を含む解剖構造や異常の確認を目的として、血管造影下での CT 像撮影が広く行われている。しかし造影剤の影響で呼吸困難や心停止といった重大な合併症を引き起こす場合が存在し、患者によって造影剤が使用できないことがある。本稿では深層学習による画像処理を用いて、腹部 CT 像の非造影像から造影像を推定する方法を提案する。Fully convolutional network (FCN) を用いた学習データの直接的学習、Generative adversarial frameworks (pix2pix, CycleGAN) における FCN の間接的学習等を用い、非造影から造影像への変換ネットワーク構築を行う。腹部 CT 像における推定実験を行ったところ、CycleGAN を用いると他の方法より良好で造影 CT 像に近い画像を推定可能であった。

キーワード：CT 像，造影像推定，Generative adversarial framework, pix2pix, CycleGAN

1. はじめに

診断及び治療時の CT 像の撮影において、血管及び血流の豊富な組織の位置と形状の視認性を向上させるため、血管造影剤を患者に投与する場合がある。血管造影 CT 像は血管の状態確認だけでなく、造影効果の経時変化を利用してがんなど異常組織の発見にも用いられる。また、外科手術における臓器構造の把握にも有用である。このように血管造影 CT 像は診断及び治療に広く利用される。

血管造影剤は静脈注射等で患者に投与され

るが、患者によって副作用を生じる場合がある。副作用には痒みなど軽度なものもあるが、呼吸困難や心停止など重大な副作用が発生する場合もあるため [1, 2]、造影剤投与には注意が必要である。

CT 像撮影時の血管造影剤投与を不要とすることを目的とし、本稿では腹部非造影 CT 像から造影 CT 像を推定する方法を提案する。非造影 CT 像から造影 CT 像を推定する画像回帰モデルとして Fully convolutional network の一種である U-net [3] を使用した。U-net を訓練する際に、学習データをネットワークに直接的に与える直接的学習と、Generative adversarial frameworks (pix2pix, CycleGAN) を用いた間接的学習を行い、それぞれの推定結果の比較を行った。

2. 手法

2.1 使用画像

画像回帰モデルの学習には同一患者の腹部の非造影 CT 像と血管造影 CT 像（動脈相）を

*1 名古屋大学大学院情報学研究科
〔〒464-8601 名古屋市千種区不老町〕
e-mail: moda@mori.m.is.nagoya-u.ac.jp

*2 順天堂大学大学院医学研究科

*3 国立情報学研究所医療ビッグデータ
研究センター

投稿受付：2019年5月15日

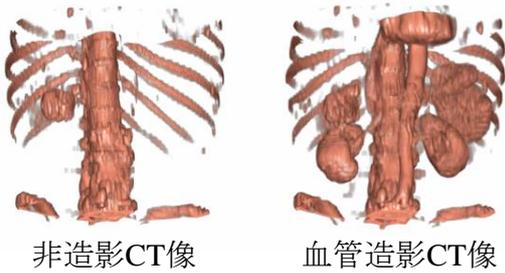


図 1 非造影及び血管造影 CT 像の 3D 像

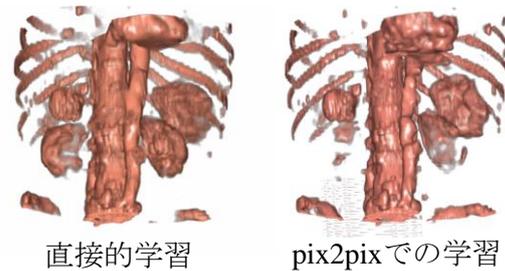


図 2 提案手法で得られた
推定造影 CT 像の 3D 像

基にした画像を用いる。これらは非剛体レジストレーションを適用し位置合わせを行う。それぞれの CT 像から取り出した Axial スライス像を使用し、2D 画像回帰モデルの学習を行う。

2.2 画像回帰モデルの学習

- (1) 直接的学習：U-net に学習用の非造影 CT 像から得た Axial スライス像を入力，造影 CT 像から得た Axial スライス像を教師データとして与え，100 epoch の学習を行う。
- (2) pix2pix での学習：生成モデルとして U-net を使用した pix2pix に学習用画像を与え，100 epoch の学習を行う。
- (3) CycleGAN での学習：生成モデルとして U-net を使用した CycleGAN に学習用画像を与え，400 epoch の学習を行う。

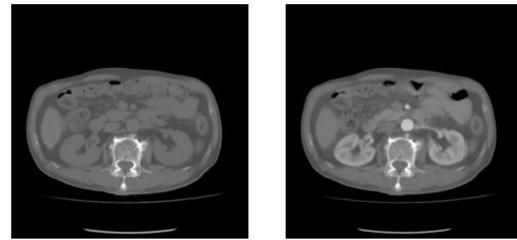


図 3 非造影及び血管造影 CT 像の
Axial スライス像

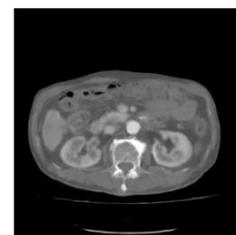
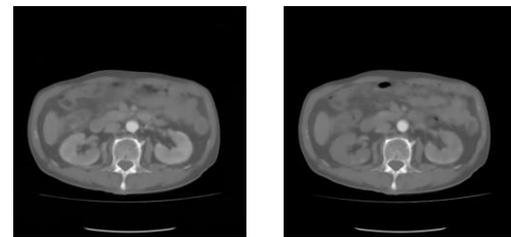


図 4 提案手法で得られた
推定造影 CT 像の Axial スライス像

2.3 造影 CT 像の推定

上記(1), (2), (3)で学習した 3 つの U-net に対し，評価用非造影 CT 像の Axial スライス (2D 画像) を 1 枚ずつ入力する。U-net が出力した推定造影 Axial スライス画像を構成し，推定造影 CT 像 (3D ボリューム) を得る。

3. 実験及び考察

非造影と血管造影 CT 像の組 29 例を用いて実験を行った。2.2 で示した(1)と(2)の学習法では 26 例を学習，3 例を評価に用いた。(3)は 29 例全てを学習に用いた。CT 像の仕様は，画像サイズ 512×512 pixels，スライス枚数 41～96 枚，画素間隔 0.586～0.782 mm，スライス厚 5.0 mm である。非造影及び造影 CT 像の 3D 像及び Axial スライス像の例を図 1, 3 に，非造影 CT 像から

提案手法により生成した推定造影 CT 像の 3D 像及び Axial スライス像の例を図 2, 4 に示す。

図 2 から、直接的学習と CycleGAN での学習を用いた場合に比較的血管造影 CT 像に近い結果が得られた。今回の画像変換で扱った血管の濃度値変化は画像内で比較的小さな変化であり、pix2pix ではこの変化を表現するようネットワークの学習を行うことができなかったと考えられる。

4. むすび

本稿では非造影 CT 像からの造影 CT 像推定手法を提案した。推定は U-net を用い、直接的学習、pix2pix での学習、CycleGAN での学習の 3 通りを行った。学習済み U-net で推定造影 CT 像を生成した結果、CycleGAN を用いた場合に比較的良好的な推定結果が得られていた。今後の課題として、推定結果の定量評価、細かい血管推定精度向上、3D 画像回帰モデルの使用が挙げられる。

謝辞 本研究の一部は、JSPS 科研費 26108006、

17H00867, 17K20099, AMED 研究費「医療ビッグデータ利活用を促進するクラウド基盤・AI 画像解析に関する研究」181k1010028s0401, 191k1010036h0001, JSPS 二国間交流事業、公益財団法人 堀科学芸術振興財団によった。

利益相反の有無 なし

文 献

- [1] Katayama H, Yamaguchi K, Kazuka T, et al: Adverse reactions to ionic and non-ionic contrast media - A report from the Japanese Committee on the Safety of Contrast Media. *Radiology* **175**(3): 621-628, 1990
- [2] Andreucchi M, Solomon R, Tasanarong A: Side effects of radiographic contrast media: pathogenesis, risk factors, and prevention. *BioMed Research International*, 2014
- [3] Ronneberger O, Fischer P, Brox T, et al: U-Net convolutional networks for biomedical image segmentations. *MICCAI* **9351**: 234-241, 2015

Estimation of Contrasted Abdominal CT Volume from Non-contrasted CT Volume using Generative Adversarial Frameworks

Masahiro ODA^{*1}, Kanako KUMAMARU^{*2}, Shigeki AOKI^{*2}, Kensaku MORI^{*1,3}

*1 Graduate School of Informatics, Nagoya University

*2 Graduate School of Medicine, Juntendo University

*3 Research Center for Medical Bigdata, National Institute of Informatics

We propose an estimation method of an abdominal contrasted CT volume from a non-contrasted CT volume. In diagnosis and treatment, contrasted CT volumes are taken to confirm anatomical structure and abnormal regions related to the blood vessels. However, administration of contrast agents causes dyspnea and cardiac arrest in some cases. In this paper, we propose an estimation method of contrasted images from non-contrasted images in abdominal CT volumes. As the estimation method, we employ an image regression model using a fully convolutional network (FCN). We trained the FCN in a direct-training and indirect-trainings using generative adversarial frameworks (pix2pix, CycleGAN). In our experiments using abdominal CT volumes, contrasted CT-like volumes having good-quality were generated when we used the CycleGAN.

Key words: CT volume, Contrasted image estimation, Generative adversarial framework, pix2pix, CycleGAN

マルチチャンネル化と CNN を用いた 嚙下時 X 線透視動画における頸椎椎間板の抽出

藤中 彩乃*¹ 目片 幸二郎*² 滝沢 穂高*³ 工藤 博幸*³

要旨

嚙下時の頸部動態解析において、頸椎椎間板の同定は嚙下障害の原因疾患の病態理解のために重要である。本報告では、嚙下時 X 線透視動画 (Videofluorography, VF) から CNN を用いて椎間板を自動抽出する手法を提案する。X 線透視動画の各フレームは濃淡画像である。その濃淡画像に濃度正規化、トップハット変換、Local Binary Pattern 処理、ソーベルフィルタをそれぞれ適用して 4 つの中間画像を生成する。それらの中間画像から 3 つの画像を選択し、RGB の各チャンネルに保存した 1 つのカラー画像を生成する。このカラー画像にウィンドウベースの CNN を適用し、椎間板領域を抽出する。中間画像の組み合わせの中から最適なものを選択する。実際の X 線透視動画に本手法を適用した結果を示す。

キーワード：嚙下時 X 線透視動画、頸椎椎間板、CNN、マルチチャンネル化、カラー画像

1. はじめに

頸椎構造物の一つである頸椎椎間板を同定する医学的^[1]および工学的^[2,3]な研究が報告されている。本研究では、ウィンドウベースの畳み込みニューラルネットワーク (CNN) を用いて嚙下時 X 線透視動画 (Videofluorography, VF) から椎間板を自動抽出する手法を提案する。

2. 方法

VF の各フレームは 8 ビットの濃淡画像である。この濃淡画像に、濃度正規化、トップハット変換、Local Binary Pattern 処理、ソーベルフィルタをそれぞれ適応し、4 種類の中間画像を生成する。それらの中間画像から、重複を許し

て 3 つを選択し、RGB の各チャンネルに保存することで、一枚のカラー画像を生成する。このカラー画像にウィンドウベースの CNN を適用し、頸椎椎間板の画素を抽出する。

3. 実験

本研究の参加者は、39 名の健常な実験参加者と、19 名の頸椎固定術術前患者の合計 58 名である。参加者から事前に同意を得た後、実験を行う。参加者は任意の時期に実験を取り止めることができる。

4. 結果

健常な実験参加者のフレーム画像を図 1 に、その頸椎椎間板の正解領域を図 2 の赤色領域に示す。表 1 に RGB 各チャンネルに保存した中間画像の一覧、図 3~8 に椎間板ウィンドウの例、図 9~14 に椎間板の抽出結果を示す。表 2 に、23 症例で抽出実験を行った際の抽出精度を示す。

*1 筑波大学大学院システム情報工学研究科コンピュータサイエンス専攻
〔〒305-8573 つくば市天王台 1-1-1〕

*2 神戸赤十字病院

*3 筑波大学システム情報系

表 1 中間画像の一覧.

R チャン ネル	G チャン ネル	B チャン ネル	ウィン ドウ	抽出 結果
正規化	正規化	正規化	図 3	図 9
Top-hat	Top-hat	Top-hat	図 4	図 10
LBP	LBP	LBP	図 5	図 11
Sobel	Sobel	Sobel	図 6	図 12
正規化	Top-hat	Top-hat	図 7	図 13
正規化	Top-hat	LBP	図 8	図 14

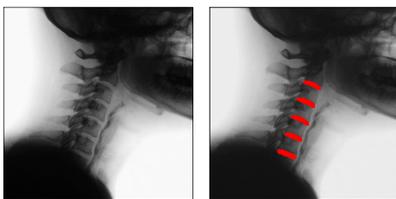


図 1

図 2



図 3

図 4

図 5

図 6

図 7

図 8

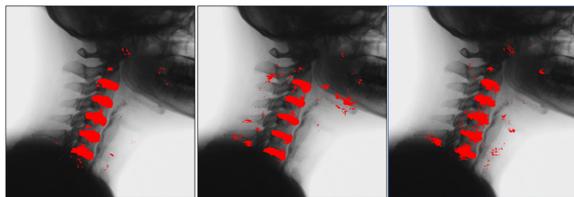


図 9

図 10

図 11

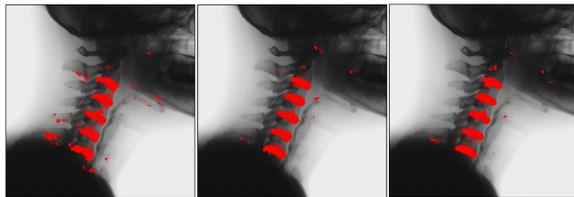


図 12

図 13

図 14

表 2 中間画像の組み合わせと抽出精度.

R チャン ネル	G チャン ネル	B チャン ネル	平均 F 値
正規化	正規化	正規化	0.628
Top-hat	Top-hat	Top-hat	0.592
LBP	LBP	LBP	0.564
Sobel	Sobel	Sobel	0.560
正規化	Top-hat	Top-hat	0.651
正規化	Top-hat	LBP	0.644

5. 考察

表 2 より, 同じ中間画像を組み合わせた場合より, 異なる中間画像を組み合わせた場合の方が, 抽出精度が高くなることが分かった.

6. まとめ

VF にマルチチャンネル化と CNN を適用し, 頸椎椎間板を抽出する手法を提案した. 今後の課題は, 中間画像の種類を増やすことと, 最適な組み合わせを探索する手法を開発することである.

謝辞

研究遂行にあたり貴重なご協力を賜った京都大学大学院医学研究科人間健康科学系専攻リハビリテーション科学コース 松林潤氏, 岡山大学整形外科 瀧川朋亨氏, 神戸赤十字病院整形外科 戸田一潔氏, 神戸赤十字病院整形外科 伊藤康夫氏に深謝いたします.

利益相反の有無

「なし」

文 献

- [1] Hardik S, Hitesh I. S. R, Amandeep K et al.: Dysphagia, dysphonia & dyspnoe caused by ostrich beak-like anterior C1-C2 cervical osteophyte. *Interdisciplinary Neurosurgery* **16**: 132-134, 2019
- [2] Sean J. D, Weiye Z, Martin T et al.: In-vivo T2-relaxation times of asymptomatic cervical intervertebral discs. *Skeletal Radiology* **45-3**: 393-400, 2016
- [3] Ayano F, Yuki S, Kojiro M et al.: Segmentation of intervertebral disks from videofluorographic images using convolutional neural network. *International Forum on Medical Imaging in Asia, Proceedings* **11050**: 110501I, 2019

Segmentation of Intervertebral Disks from Videofluorography by Multi Channelization and CNN

Ayano FUJINAKA^{*1}, Kojiro MEKATA^{*2}, Hotaka TAKIZAWA^{*3}, Hiroyuki KUDO^{*3}

*1 Department of Computer Science, Graduate School of Systems and
Information Engineering, University of Tsukuba

*2 Kobe Red Cross Hospital

*3 Faculty of Engineering, Information and Systems, University of Tsukuba

In order to understand the pathological causes of dysphagia, it is important to analyze the arrangement of cervical structures. In this report, we propose a segmentation method of intervertebral disks (IDs), which are ones of the representative cervical structures, in Videofluorography (VF) based on multi channelization technique and CNN. Each frame of VF is a gray scale image. By applying intensity normalization, morphological top-hat transform, local binary pattern operation, and Sobel filter to the frame image, four intermediate images are obtained. Three images are selected from the four intermediate images, and then one color image is generated by setting the three images to its RGB channel planes. Window-based CNN is applied to the color images to extract ID regions. Several experimental results are shown.

Key words: Videofluorography, Cervical intervertebral disk, CNN, Multi channelization, Color image

A Comparative Study on Atlas-guided Liver Segmentation in CT

Jinke WANG^{*1, 2}, Yuanzhi CHENG³, Shinichi TAMURA⁴,
Noriyuki TOMIYAMA¹

Abstract

This paper provides a comparative study between probabilistic atlas (PA) and multi-atlas (MA) on liver segmentation in CT. Comparative results showed distinct superiorities of the two models.

Keywords : probabilistic atlas, multi-atlas, liver segmentation

1. Introduction

Segmentation is a key prerequisite for image-guided liver surgery, and is helpful for making choice of therapeutic strategy. Among the popular segmentation models, atlas-guided ones, including probabilistic atlas (PA) and multi-atlas (MA) have shown good prospects. Newly atlas-based methods are developed constantly, including single organ segmentation [1], multiple organs segmentation [2], and good surveys [3]. However, comparative studies between PA and MA are rare.

This paper first gives basic working flows of PA and MA. Then, experiments are implemented using 30 CT datasets. Finally, we provide conclusions based on the results.

2. Method

1) Registration algorithm

Registration is the core for atlas-based methods. In this work, registration tool *elstix* [4] is utilized, which could be well combined with popular medical image processing tool *Insight Toolkit* (ITK). The selected algorithm for non-rigid registration is 3D B-Splines.

2) Probabilistic atlas

PA process is divided into 2 parts: atlas construction, and atlas-based registration. For atlas construction, a single average atlas is built for both spatial correspondence and standardization purposes (shown in Fig. 1), via registering

*1 Department of Radiology, Graduate School of Medicine, Osaka University [2-2 Yamadaoka, Suita, Osaka 565-0871, Japan] e-mail: ousinka@hotmail.com

2 Department of Software Engineering, Harbin University of Science and Technology [92, Xidazhi, Nangang, Harbin, 150080, China]

3 School of Computer Science and Technology, Harbin Institute of Technology, [52 Xuefu, Nangang, Harbin, 150001, China]

4 NBL Technovator Co., Ltd [631 Shindachimakino, Sennan, Osaka 590-0522, Japan]

all the training images to one selected training image. For atlas-based registration, the segmentation is first implemented by registering the average intensity atlas to the target image, and then by propagating the average labeled atlas with transformational model, the segmentation result is then obtained.

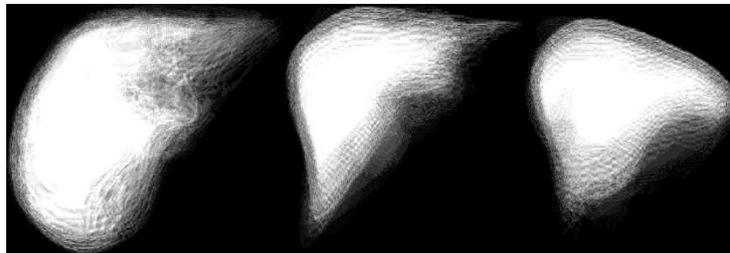


Fig. 1 Average Atlas for labeled image.

2) Multi-atlas

For MA, no atlas building is needed, but only registration process. Pairwise registrations are performed from each training intensity image to the target testing image, resulting in corresponding transformation models. Then, based on these models, all the labeled binary images are propagated to the target coordinate, the segmentation result is achieved with “majority voting”.

3. Experiments

1) Datasets

A total of 30 abdominal datasets with reference segmentations from corporative hospital are used in the experiments (20 for training, 10 for testing), in which, 10 cases have adjacent organs with similar intensities, 5 cases have small tumors (3 inside, 2 border). The experiment is programmed using ITK in Ubuntu, with CPU i7-6770, 4G RAM. The scanning parameters are provided in Table 1.

Table 1 Scanning parameters.

CT scanner	Number	Slice size	Pixel size	Slice number	Slice distance
SIMENS SOMATOM Definition Flash	30	512×512	0.51~0.87	341~475	0.8~3.0

2) Accuracy

Comparative results were shown in Table 2. It showed a slight superiority performance for MA on all four metrics. Fig. 2 was a typical segmentation error on both 2D and 3D views, in which MA showed smaller error on the liver border.

Table 2 Comparative results on four metrics.

Method	VOE (%)	ASD (mm)	RMSD (mm)	MSD (mm)
PA	7.92	1.74	1.92	13.77
MA	7.34	1.59	1.56	11.69

2) Time cost

As shown in Fig. 3, we provided an average computational time for 10 testing images. Though the time-cost for

PA-training is quite high (comparable to that of MA-testing), the time-cost for PA-testing is much more less. The main reason is that, once the atlas construction of PA is completed, only one average atlas image is needed to be registered to the target image. Contrastively, pairwise registrations are always required between all the training images and the target image in MA process.

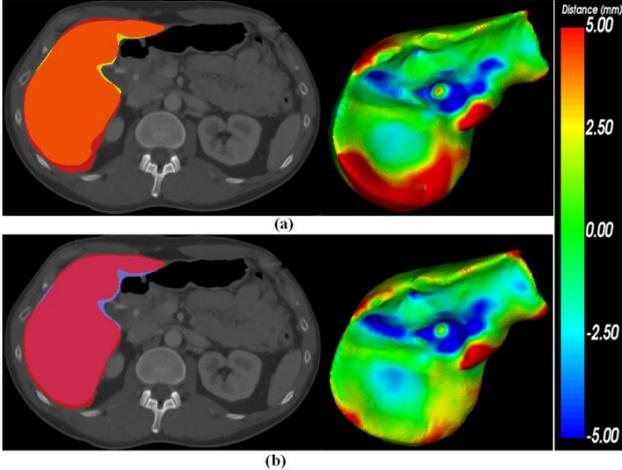


Fig. 2 Errors evaluation (a) PA (b) MA. In 2D view, golden result is labeled with red color, while yellow and blue represent PA and MA results, respectively.

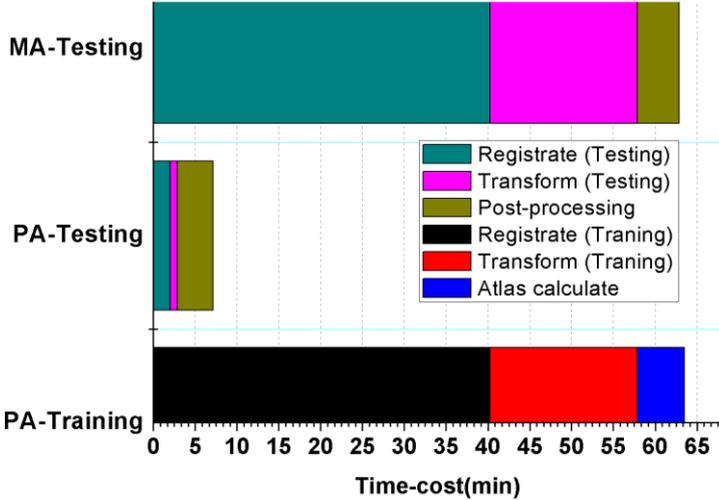


Fig. 3 Time-cost for both PA & MA

4. Conclusions

Generally, MA can obtain higher segmentation accuracy than PA, but in the case of limited datasets, the accuracy of the PA is comparative to that of PA. Once the PA atlas is constructed, the computational cost is very low. Therefore, for atlas-guided liver segmentation, appropriate atlas strategy (PA, MA) should be made according to both time and precision requirements, with specific application scene. In further study, the scales and varieties of the experimental datasets will be extended to provide a more comprehensive and convincing comparison.

Ethics statements

The research was approved by the ethics committee of Harbin University of Science and Technology, with

informed consent obtained from all patients being included in the study.

Competing interests

No conflict of interest was reported by the author(s).

References

- [1] Shi C, Cheng Y, Wang J, et al.: Low-rank and sparse decomposition based shape model and probabilistic atlas for automatic pathological organ segmentation. *Med Image Anal* **38**: 30-49, 2017
- [2] Okada T, Linguraru M, Hori M, et al.: Abdominal multi-organ segmentation from CT images using conditional shape–location and unsupervised intensity priors. *Med Image Anal* **26**: 1-18, 2015
- [3] Iglesias J, Sabuncu M: Multi-atlas segmentation of biomedical images: a survey. *Med Image Anal* **24**: 205-219, 2015
- [4] Klein S, Staring M, Murphy K, et al.: Elastix: a toolbox for intensity-based medical image registration. *IEEE Trans Med Imag* **29**, 196-205, 2010

Biography



Jinke Wang

He received the Ph.D. degree from the Harbin Institute of Technology, Harbin, China, in 2016. He is an associate Professor in the Department of Software, Harbin University of Science and Technology, China. Currently he is doing post-doctoral study in Osaka University.



Yuanzhi Cheng

He received the Ph.D. degree from the Harbin Institute of Technology, Harbin, China, in 2007. He is currently a Professor in the School of Computer Science and Technology, Harbin Institute of Technology.



Shinichi Tamura

He received the Ph.D. degree in electrical engineering from Osaka University, Osaka, Japan, in 1971. He is an Editorial Board Member of the IJCARS, an IEEE Life Fellow, IEICE Fellow, and a Member of IEICE, IPSJ, and JAMIT.



Noriyuki Tomiyama

He received the Ph.D. degree in Medicine from Osaka University, Osaka, Japan, in 1993. He is currently a Professor in the Department of Radiology, Graduate School of Medicine, Osaka University.

X線暗視野法に基づく屈折コントラストX線CTを用いた ヒト乳頭の3次元可視化および解析

砂口 尚輝^{*1}, 島雄 大介^{*2}, 市原 周^{*3}, 西村 理恵子^{*3},

岩越 朱里^{*3}, 渡邊 彩^{*1}, 丹羽 輝久子^{*1}, 黄 卓然^{*1},

湯浅 哲也^{*4}, 安藤 正海^{*5}

要旨

乳房の乳頭部における乳管の組織構造はまだ完全に把握されていない。例えば、最も解析しやすいと考えられる乳頭内の乳管数は、解剖学の教科書で15~20本と書かれているが、2000年以降の報告では平均値で約25本、多い人で50本あるとされている。それ以外の3次元的な乳管構造についても徐々に分かっている。一方で、このような解剖学的な解析は、労力を必要とする3次元病理観察に基づくため、多症例による統計的解析はほとんど行われていない。本研究では、染色された2次元組織像に匹敵するコントラストで描出できるX線暗視野法に基づく屈折コントラストCTを用いて、ヒトの乳房から採取された23症例の乳頭を撮影し、乳頭内乳管の3次元可視化および解析を行う。その結果を先行研究と照らし合わせて、解剖学研究における屈折コントラストCTの有用性を示す。

キーワード：屈折コントラストX線CT, X線暗視野法, 乳頭, 解剖学, 3次元可視化

1. はじめに

乳癌は罹患率、死亡率ともに増加の一途を辿っており、本邦では30歳~64歳女性のがん死

亡原因の第一位となっている(国立がん研究センター「がん情報サービス」がん統計)。乳癌の多くは、乳管(母乳が通る管)で発生する乳管癌である。乳管は、乳頭部の太い乳管(主乳管)から分岐を繰り返して乳房内に広がっており、様々な太さのものから構成されている。乳癌は乳管内面を覆う腺上皮細胞から発生し、増殖を繰り返して進展していく。乳癌の中でも、非浸潤性乳管癌(DCIS)は癌細胞が乳管内に留まって増殖し、乳管に沿って進展する特徴を持つ。DCISが乳管から周囲の結合組織へ浸潤すると、浸潤性乳癌となり、リンパ管や血管に進入し、他の部位に転移する。浸潤のない、純粋なDCISは、癌細胞が乳管内に留まっているため、手術によりそれらを完全に除去することができ

*1 名古屋大学大学院医学系研究科医用技術学専攻

[〒461-8673 名古屋市東区大幸南一丁目1番20号]

e-mail: sunaguchi@met.nagoya-u.ac.jp

*2 北海道科学大学

*3 名古屋医療センター

*4 山形大学

*5 総合科学研究機構

投稿受付：2019年5月14日

ば完治する。一方、DCISは、乳頭部にまで進展する可能性があるため、乳頭温存乳房切除術（Nipple-sparing mastectomy）には再発のリスクが存在する[1]。もし、術前に乳頭内の状態を調べることができれば、患者に対し安全な乳頭温存を提供できるが、現在の乳頭内診断手法である臨床画像（X線造影、超音波、MRI）、乳管内視鏡、乳管洗浄では、乳頭部におけるDCISの有無を正確に判定することは困難である。その大きな要因は、乳頭内の主乳管同士との吻合の有無や3次元空間内における乳管形状など解剖学的な情報が不足しているからと考えられる。現在解剖学の教科書で書かれていることは、乳腺実質でいくつかの葉（セグメント）に分かれた乳管が乳頭部で15-20本の主乳管に集約するという基本構造についてだけである[2]。後述するが、この記述についても異なる結果が報告されている。

乳頭内乳管の3次元解剖構造について解析した研究は2000年代になっていくつか報告されている。この中で使用されている観察手法は従来の2次元平面に基づく病理観察ではなく、複数の組織切片から再構成される3次元病理観察に基づく。2004年Goingらは、1症例に対し100 μm 間隔で得た病理切片像から乳管を抽出し、乳管構造を3次元的に可視化した。その観察から乳頭先端で開口する乳管数や乳輪下で生じる乳管があることを示した[3]。2007年Rusbyらは、2症例に対し50 μm 間隔で得た病理切片像からGoingらと同様に3次元可視化を行っている。彼らは、乳管が乳頭先端に到達する際に共通の開口を持つこと、乳管の断面積は乳頭先端で急激に小さくなること、乳輪付近から生じる乳管があること、乳管は乳輪下で集約し、くびれ状の形態をとることなど多数の結果を示した[4]。このように、3次元病理観察は2次元平面で知ることの難しい多数の解剖学的情報をもたらしてくれる。

一方で、彼らの解剖学的情報は1, 2症例から得られており、十分な統計的な議論が行われていない。この理由として、多症例を用いた3次元病理観察には多大な労力がかかるためと考

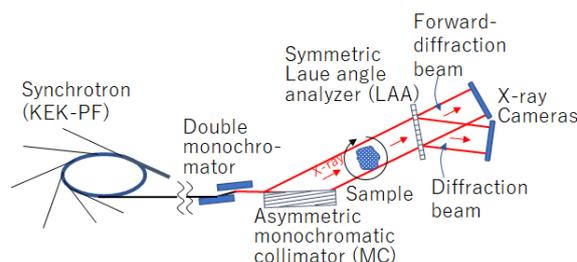


図1 X線暗視野法に基づく屈折コントラストCT撮像システム

えられる。一般的に病理切片は、組織ブロックを3-4ミクロンの厚さで薄くスライスし、ヘマトキシリンエオジン液で染色を施したものである。3次元組織像は、病理切片を光学顕微鏡で画像化し、スライス画像を積み重ねることで作成される。これらの作業は人の手を必要とし、3次元組織像を構築するためには膨大なスライスを必要することから長時間を要する。そのため、3次元的な観察は上述のような研究レベルで形態学的な情報を得るために一部実施されることはあるが、その症例数は2次元組織像と比べると極端に少ない。

新たな3次元組織像の観察手法として、我々は生体内を染色された2次元組織像に匹敵するコントラストで撮像できるX線暗視野法に基づく屈折コントラストCTを利用する[5, 6]。この方式は現在国内外でも実現していない病理診断での利用に向けて研究が進められている[7]。屈折コントラストCTは生体の3次元像を未染色・非破壊で短時間で得ることができるため、多症例研究における撮像法として最も適した方法であると考えられる。

本研究では、屈折コントラストCTを用いてヒトの乳房から摘出した乳頭23症例を撮像し、CTから乳頭内の乳管構造を解析する。その結果が病理観察に基づく先行結果と比較し妥当であるか確認し、解剖学研究における屈折コントラストCTの有用性を示す。最初に、CTから得た乳管数や乳管断面積を先行研究の結果と比較する。次に、Rusbyらの「乳管径は乳頭先端で急激に小さくなる」という主張についてCT画像の乳管断面像から確認する。最後に、Rusbyらの「乳頭内の乳管はくびれを持つ」という主

張について乳管の3次元可視化によって確認する。

2. 撮像手法・試料および解析手法

図1は試料撮影のために使用された屈折コントラストCT撮像システムの概要図である。本撮像手法は入射源として放射光X線を用いる。放射光X線ビームは2結晶モノクロメータにより単色化され、非対称Bragg-caseモノクロメータ結晶(MC)で回折することにより、試料サイズよりも大きい視野を形成する。入射ビームは試料を伝搬する過程でその電子密度分布に従って屈折し、その後方に設置された薄いLaue-case角度アナライザ結晶(LAA)に入射する。ここで、ビームの屈折角度はX線の強度情報に変換され、後方のX線カメラで測定される。また、屈折コントラストCTは、試料を回転させて繰り返し撮影した投影データから再構成される。

撮像装置は茨城県つくば市の高エネルギー加速器研究機構フォトンファクトリーBL14Bビームラインに構築される。X線エネルギーは19.8 keVに設定される。MCとLAAの各結晶の回折面はSi(111)である。X線カメラの視野は、 $36\text{ mm}^H \times 24\text{ mm}^V$ で、ピクセルサイズは $14.8\text{ }\mu\text{m}$ である。撮影された投影数は600枚で、再構成アルゴリズムには屈折X線に基づく逐次的再構成法[8]が採用された。

乳頭試料は乳がんにより全摘出された女性の乳房から切り出したものである。この実験で23症例の乳頭が撮像され、すべて解析に利用された。各試料は10%の緩衝ホルマリン液で固定された後、保存のためにエタノールに置換された。撮像5~6時間前に、試料内部のエタノールを除去するために水に浸された。撮像直前に、円筒のプラスチックチューブに挿入され、乾燥しないように周辺をアガロースゲルで満たされた。撮像の際は、それを直方体の水槽に挿入し投影撮影毎に回転させる。水槽に入れる理由は、円筒チューブ表面で生じる試料に起因しない屈折を低減するためである。本研究は、名古屋大学および名古屋医療センターの生命倫理審

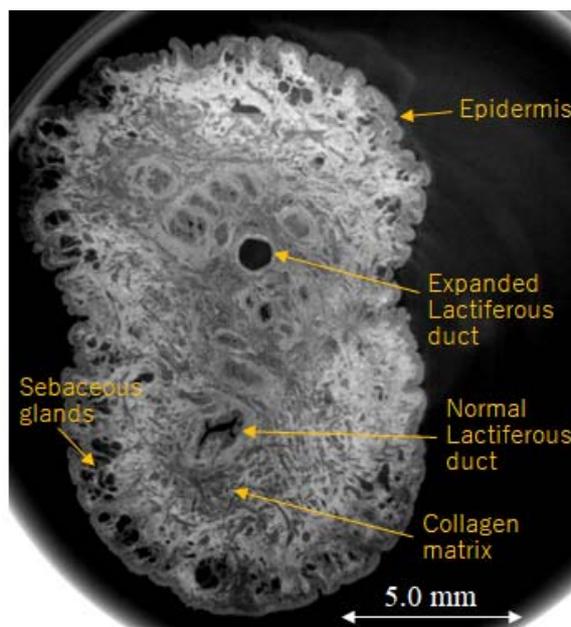


図2 乳頭の屈折コントラストCT像

査で承認を受けている。

1) 乳頭内乳管数および乳管断面積

初めに、乳頭内の乳管構造を得るために、CT画像上の乳頭の付け根方向のスライスから先端のスライスまでの乳管の輪郭を抽出する。抽出作業には、画像処理ソフトImage J[9]のMeasurementsツールが利用される。作業簡略化のために、乳頭の形状が大きく変化しないスライスについては抽出せず、前後の輪郭でスプライン補間する。Measurementsツールで測定する輪郭情報は、重心位置と断面積である。

乳管数は、乳輪下で生じる乳管も含めて乳頭内にあるすべての乳管を数えたものである。

乳管断面積は乳管の深さ方向で大きく変化するため、その経路上の最大断面積と最小断面積で評価する。まず、23症例すべての乳管の最大断面積と最小断面積を求め、平均値と標準偏差で評価する。

2) 乳頭先端から付け根までの乳管断面形状

乳管が先端で細くなることを確認するために、23症例すべての乳管に対し、乳管先端から付け根までの乳管断面積を求める。また、先端から3 mmの深さまでの中で面積勾配(断面積の変化量/微小深さ)が最も大きくなる先端からの深さ D を定義し、形状が大きく変化する深

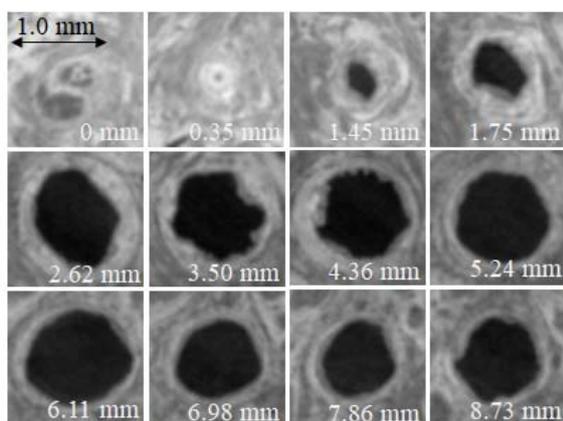


図3 乳頭先端から付け根までの乳管断面形状

さを評価する。

3) 乳管の3次元可視化

乳管の3次元像は、3次元空間に事前に求めた乳管の重心位置をプロットし、点を線でつなぎ合わせることで作成される。3次元可視化に抽出した輪郭をそのまま使用することもできるが、いくつかの太い乳管が他の乳管を隠してしまい、構造の把握が困難になるため行っていない。3次元像のスライス厚は14.8 μmであり、3次元像はボリュームレンダリングによって可視化される。

3. 結果

図2はある症例における乳頭の屈折コントラストCTを表す。CT画像上の画素値は複素屈折率 δ を表し、密度の大きさに比例する。ここで、白は密度が大きいことを表す。図2は、乳管、繊維組織、皮脂腺、上皮組織を鮮明に描出している。また、大小形の異なる乳管は19個存在し、すべて画像から確認できる。

1) 乳頭内乳管数および乳管断面積

CTからカウントされた乳管数は、23症例で633本存在した。1症例あたりの平均値、中央値、標準偏差はそれぞれ27.5本、25本、9.3本であった。四分位範囲および最大値最小値範囲はそれぞれ20.5-31.5、15-51であった。また、乳頭の高さ、大きさ、年齢と乳管数には有意差がないことが分かっている。

最小断面積および最大断面積は、 $0.011 \text{ mm}^2 \pm 0.009 \text{ mm}^2$ および $0.297 \text{ mm}^2 \pm 0.166 \text{ mm}^2$ で

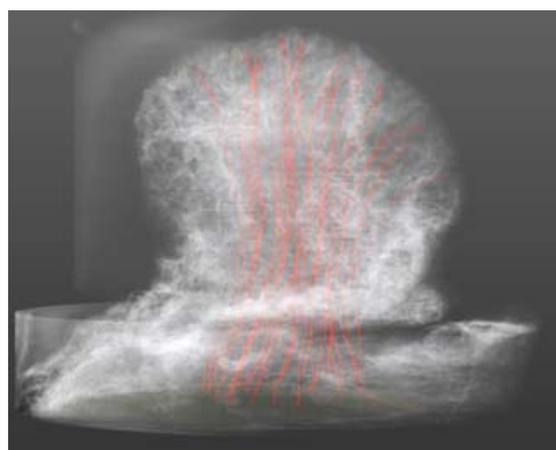


図4 乳頭内乳管のボリュームレンダリング像

あった。

2) 乳頭先端から付け根までの乳管断面形状

図3はある症例における乳管の先端から付け根までの断面の一例である。画像上に記載された距離は表皮からの深さを表す。深さ2.62 mmから8.73 mmまでの形状は円であり、断面積はほとんど変化しない。その後、1.75 mmから表皮に向かって急激に細くなる。表皮では直径50 μmの円形状になり、外に開口している。ほとんどの乳管は、この例のように先端で細くなる傾向がある。全症例全乳管の平均 D は $0.85 \text{ mm} \pm 0.20 \text{ mm}$ である。症例毎に求めた平均 D は $0.4 \text{ mm} \sim 1.3 \text{ mm}$ の範囲にある。また、症例毎に求めた D の標準偏差は $0.2 \text{ mm} \sim 0.9 \text{ mm}$ であり、個人差が大きいことが分かる。

3) 乳管の3次元可視化

図4はある症例の乳頭内乳管をボリュームレンダリングにより可視化したものである。赤色の縦に伸びる管構造は乳管を表す。白いの雲状の構造は、乳頭の乳管位置を把握しやすいように重ねた乳頭実質である。画像上部は乳頭先端を表し、下部が付け根を表す。すべての乳管は乳頭部と乳輪の境界付近でくびれを持つことが分かる。このようなくびれを持つ症例は23症例中14症例(61%)存在する。

4. 議論

1) 乳頭内乳管数および乳管断面積

病理観察に基づく先行研究で得られた乳管

数は, Going らの結果[3]で中央値 27 本(11-48)(症例数 72 件), Taneri らの結果[10]で平均値 17 本(18-30)(症例数 226 件), Rusby らの結果[4]で平均値 24 本(5-50)(症例数 129 件)である. 我々の結果は, Going や Rusby らの結果に近いと言える. ただし, Rusby らは, 乳管数を計測するスライス位置については明確には定義していない. Going らは, 乳輪のベースを基準スライスとしているが, 乳管は乳輪下の末梢に向かって枝分かれするため, 過剰に計測している可能性がある. 我々は, 乳頭の 3 次元像全体を見て計測していることから, 彼らよりも誤差が生じにくいと言える.

Rusby らは, 乳管の最小径と最大径について, 3 症例の平均で 0.06 mm, 0.7 mm と求めている. 一方で, 我々は, 乳管には様々な形状があることを考慮し, 直径ではなく輪郭から求めた断面積を使用している. Rusby らの結果を断面積に換算すると, 最小断面積は 0.003 mm², 最大断面積は 0.38 mm² となる. 彼らの結果は, 我々の結果の標準偏差内に入っており, 彼らの結果と矛盾しない. また, 我々の結果は彼らより症例数が多いため, より精度が高いと言えるかもしれない.

2) 乳頭先端から付け根までの乳管断面形状

Rusby らは, 乳管の断面積が乳頭先端から 1.5 mm 付近で最小になり, 3 mm 付近で 10 倍に大きくなると報告している. 我々は, 面積勾配が大きくなる位置を求めたが, その位置は彼らの結果よりも非常に浅い. この相違は, 結果で示したように, 個人差が大きいことが起因していると考えられる. また, 彼らの被験者はアメリカ人が多いと考えられるが, 我々の被験者はすべて日本人である. そのため, 人種による乳頭構造の違いが存在する可能性もある.

3) 乳管の 3 次元可視化

Going らの 3 次元像は, すべての乳管が先端から付け根までほぼ真っ直ぐ伸びる様子を示している. Rusby らの 3 次元像は乳管が先端で集まるように見える. また, 乳輪下 2 mm で乳管はくびれ状になると主張している. 我々の 23 症例から得た 3 次元像は, 図 4 のように乳頭が

先端で発散するタイプ, Going らと同様にまっすぐ伸びるタイプ, Rusby らと同様に先端で集まるタイプと様々な形状を確認できる. これらタイプと乳頭の大きさには関係がない. また, くびれ状に関しては, 我々の結果では発散するタイプと集まるタイプで確認することができる.

現在の乳頭内診断では乳頭内の乳管癌の有無を調べるために, 対象乳管の X 線造影や内視鏡を行うが, 信頼性は低いと言われている. この理由は, 今回の結果で確認された大きく変化する乳管径や様々なタイプの乳管経路のため, 乳管にカテーテルなどを挿入する際に, 乳管の突き破りや別の乳管への誤挿入が生じているためと推察する. また, 乳頭内の乳管構造に個人差が大きいことも信頼性を下げている要因と考えられる. 本研究で使用した屈折コントラスト CT を乳頭診断に利用することも考えられるが, 光源に特別な放射光 X 線が必要であり容易ではない. すなわち, 乳頭内の癌の進展を精度よく診断する術がない現時点においては, DCIS における乳頭の温存術は依然としてリスクが高いと言える.

5. まとめ

本研究では, 屈折コントラスト CT を用いてヒトの乳房から採取した 23 症例の乳頭を撮像し, 3 次元可視化と解剖学的な解析を行った. この結果を従来の病理観察に基づく解剖学研究と比較し, 屈折コントラスト CT から従来法と同様な解析ができることを示した. また, 従来よりも多数の症例を解析できたことにより, 乳管が先端で発散する新しいタイプを発見することができた. 今後さらに症例数を増やし, 新しい解剖学情報や DCIS の進展経路などを明らかにしたい.

謝辞

本研究の試料を準備していただいた名古屋医療センターのスタッフの方に感謝を申し上げます. また, 撮像システムで使用された LAA 結晶は KEK の PF 結晶加工室を利用して杉山

弘助教および笹谷典太氏によって作成されました。ここで感謝を申し上げます。また、貴重なX線 CCD カメラを貸していただいた KEK の平野馨一准教授および兵藤一行准教授に感謝申し上げます。本研究は JSPS 科研費 16K01369, 16K08654, 22591353, 15H01129, 26286079, 18K13765, 平成 29 年度国立病院機構共同臨床研究 H29-NHO(癌般)-01, H29-NHO(多共)-02 および KEK 放射光実験課題 2016G0625 の支援を受けています。

利益相反の有無

無し。

文 献

- [1] Rusby JE, Smith BL, Gui GP. Nipple-sparing mastectomy. *Br. J. Surg.* **97**: 305–316, 2010
- [2] Human Anatomy Atlas 2019, Visible Body <https://www.visiblebody.com>
- [3] Going J J, Moffat F D: Escaping from Flatland: clinical and biological aspects of human mammary duct anatomy in three dimensions. *J. Pathol* **203**: 538–544, 2004
- [4] Rusby J, Brachtel E, Michaelson J et al: Breast duct anatomy in the human nipple: three-dimensional patterns and clinical implications. *Breast Cancer Res Treat* **106**:171–179, 2007
- [5] Ando M, Maksimenko A, Sugiyama et al: Simple X-ray dark and bright-field imaging using achromatic Laue optics. *Jpn. J. Appl. Phys* **41**,L1016–L1018, 2002
- [6] Sunaguchi N, Yuasa T, Huo Q et al: X-ray refraction-contrast computed tomography images using dark field imaging optics. *Appl. Phys. Lett.* **97**: 153701, 2010
- [7] Ando M, Sunaguchi N, Shimao D et al: Dark-Field Imaging: Recent developments and potential clinical applications. *Phys. Med.* **32**:1801–1812, 2016
- [8] Sunaguchi N, Yuasa T, Gupta R et al: An efficient reconstruction algorithm for differential phase-contrast tomographic images from a limited number of views. *Appl. Phys. Lett.* **107**: 253701, 2015
- [9] Image J, <https://imagej.nih.gov/ij/>
- [10] Taneri F, Kurukahvecioglu O, Akyurek N et al: Microanatomy of Milk Ducts in the Nipple. *Eur. Surg. Res.* **38**:545–549, 2006

Three-dimensional imaging of human nipple using refraction-contrast

X-ray computed tomography

Naoki SUNAGUCHI*¹, Daisuke SHIMAO*², Shu ICHIHARA*³, Rieko NISHIMURA*³, Akari Iwakoshi*³,
Aya Watanabe*¹, Kikuko NIWA*¹, Zhuoran HUANG*¹, Tetsuya YUASA*⁴, Masami ANDO*⁵

*1 Nagoya University

*2 Hokkaido University of Science.

*3 Nagoya Medical Center.

*4 Yamagata University.

*5 CROSS.

For the pathological field, we have developed the refraction-contrast computed tomography using X-ray dark field imaging technique (XDFI-CT) which is a kind of analyzer-based imaging using a Laue-case Si crystal, which allows to visualize the precise 3-D structure of biological soft tissue as well as the stained pathological image. In this research, we reconstruct 23 human nipples using XDFI-CT and perform the anatomical analysis of the structure of milk ducts from the reconstructed 3-D volume.

Key words: X-ray dark field imaging, refraction-contrast computed tomography, human nipple, anatomy

著者紹介

和文でも英文でも可。



砂口 尚輝 (すなぐち なおき)

2006年：山形大学大学院理工学研究科博士前期課程修了，2006-2007年：(株)日立メディコ，2007年-2010年：山形大学大学院理工学研究科博士後期課程，2010年：同課程修了。博士（工学），2010年-2012年：高エネルギー加速器研究機構・学振特別研究員，2012年-2017年：群馬大学大学院理工学府電子情報部門・助教，2017年-：名古屋大学大学院医学系研究科医療技術学専攻・准教授（現職）。X線イメージングの研究に従事。

ここに顔写真を
貼り付けてくだ
さい。

深層学習による超音波画像からの 肝腫瘍検出に関する初期検討

堤 一晴^{*1} 中島 崇博^{*1} 道満 恵介^{*1} 目加田 慶人^{*1}

西田 直生志^{*2} 工藤 正敏^{*2}

要旨

本研究では、腹部超音波画像を対象とした深層学習による肝腫瘍検出の検討結果について報告する。腹部超音波画像診断における検査水準は実施者の経験に依存し、その均てん化のためにコンピュータ支援診断が期待されている。そこで本研究では、畳み込みニューラルネットワーク (CNN) により肝腫瘍領域を検出する手法を検討する。実験では、肝腫瘍を含む超音波画像 98 枚から抽出された肝腫瘍領域にデータ増強を施した画像 1,467 枚と非肝腫瘍領域 1,800 枚を用いて CNN を構築した。その結果、肝腫瘍領域を正しく検出できたものの、非肝腫瘍領域を過検出する傾向がみられた。

キーワード：深層学習，肝腫瘍，超音波画像

1. はじめに

現在、超音波における腹部の診断においてその検査水準は実施者の経験に影響されるため、その均てん化のためにコンピュータによる支援診断が期待されている。平成 29 年度の腹部超音波検査精度管理調査結果報告書では、適切な超音波画像所見の記載，カテゴリー判断，事後指導判定ができていない施設が，調査に参加した 241 施設のうち 26.7%認められたことが報告されている [1]。またこの報告書では，肝臓において診断が困難な領域においては，改善が必要であると指摘されている。そこで，画像認識分野において，多くのタスクで高い性能を達

成し，注目を集めている畳み込みニューラルネットワーク (CNN) を用いて超音波画像から肝腫瘍領域を検出手法について検討した。本稿ではその結果について述べる。

2. 肝腫瘍検出手法

CNN には様々な構造が提案されているが，本手法では基本的なネットワークの 1 つである AlexNet [2] を利用する。AlexNet は，5 層の畳み込み層，3 層のプーリング層，3 層の全結合層，2 層のドロップアウト層からなる。

超音波画像に対して，100×100 画素のウィンドウでスライディングウィンドウを行い，画像を分割する。分割した画像を AlexNet に入力し，入力画像が肝腫瘍領域を含むか否かを分類する。入力画像が肝腫瘍領域を含む場合には超音波画像内にその領域を矩形で描画する。

3. 実験

実験では，日本医療研究開発機構「医療ビッグデータ利活用を促進するクラウド基盤・AI 画

*1 中京大学 工学部

[〒470-0393 愛知県豊田市貝津町床立 101]

e-mail: {tsutsumi.i, nakashima.t}@md.sist.

chukyo-u.ac.jp

e-mail: {kdoman.y-mekada}@sist.chukyo-u.ac.jp

*2 近畿大学 医学部

[〒589-8511 大阪府大阪狭山市大野東 377-2]

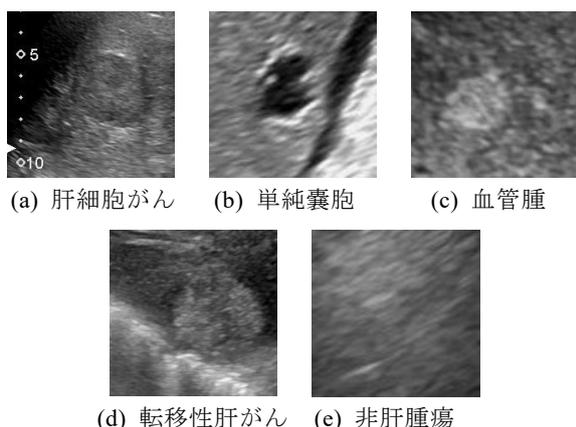


図1 学習データ

像解析に関する研究」より整備された確定診断がつけられた超音波画像データセットに含まれる、肝腫瘍を含む超音波画像 98 枚を使用した。超音波画像データセットには肝腫瘍として肝細胞がん、転移性肝がん、単純嚢胞、血管腫の4種が含まれており、これらの4種を肝腫瘍として扱った。

学習データの作成には 100×100, 150×150, 200×200 画素の3種のウィンドウを使用し、これらのウィンドウを用いてそれぞれの領域を抽出した。なお、100×100 画素を超える腫瘍については 100×100 画素に縮小し、データ増強のために左右反転を施した。ただし、非肝腫瘍画像は肝腫瘍画像に対して、極端に多くなるため、肝腫瘍画像の枚数に合わせてランダムに抽出したものを学習データとした。作成した学習データは肝腫瘍画像 1,467 枚、非肝腫瘍画像 1,800 枚であった。また、評価には学習に使用していない超音波画像を使用した。

作成した学習データを用いて AlexNet を学習した。学習は 100 エポック行い、そのうちから検証データでの正解率が最も高いエポックの重みを用いて評価した。

4. 結果・考察

推論結果の例を図2に示す。腫瘍領域を正しく推定できたが、過検出がみられた。

原因としては、学習データが少ないことが考えられるほか、非肝腫瘍画像をランダムに抽出

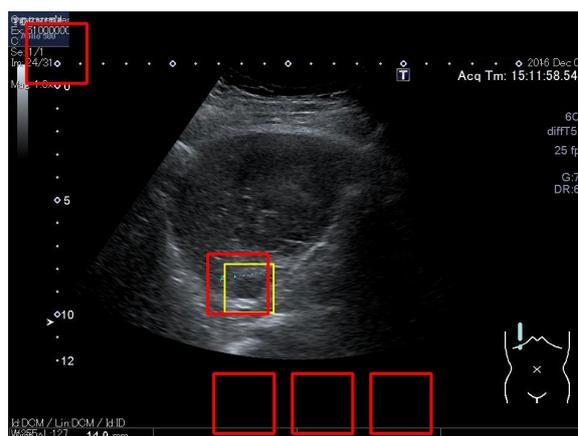


図2 肝細胞がんを含む超音波画像に対して推論を行った結果 (赤：検出領域 黄：肝細胞がん位置)

したため、非肝腫瘍領域や超音波信号外の領域を正しく分類できなかったことが考えられる。また、学習データには画像内に診断時に利用したアノテーションラベルが残っており、グレー以外の値を持っているため、その色情報を基準に判断した可能性がある。そのため、学習データの増強、画像内に付与されたアノテーションラベルを取り除くことが必要である。

5. まとめと今後の課題

CNN を用いて超音波画像から肝腫瘍を検出した。肝腫瘍を検出することはできているが、過検出が多くみられた。

今後の課題として、学習データの増強、超音波画像内に付与されたアノテーションラベルを取り除くことが課題として挙げられる。

謝辞

本研究の一部は、日本学術振興会科学研究費補助金および日本医療研究開発機構 (AMED) の援助による。

利益相反の有無

なし

文 献

- [1] 公益社団法人 全国労働衛生団体連合会：「平成 29 年度 腹部超音波検査精度管理調査結果報告書」, pp17-19, 2018
- [2] Krizhevsky A, Sutskever I, Hinton G. E: ImageNet Classification with Deep Convolutional Neural Networks. Advances in Neural Information Processing Systems 25: 1097-1105, 2012

A Study on Liver Tumor Detection from an Ultrasound Image using Deep Learning

Issei TSUTSUMI^{*1}, Takahiro NAKASHIMA^{*1}, Keisuke DOMAN^{*1}, Yoshito MEKADA^{*1}
Naoshi NISHIDA^{*2}, Masatoshi KUDO^{*2}

^{*1} School of Engineering, Chukyo University

^{*2} Faculty of Medicine, Kindai University

The quality of diagnosis depends on the operator's experience. A computer-aided diagnosis is system helpful for improving the accuracy of the quality of diagnosis. This paper reports experimental results on liver tumor detection using convolutional neural networks. In the experiments, we used 1,467 images of the liver tumor regions extracted from 98 images and 1,800 images of non-liver tumor regions. As a result of the experiment, although the tumor regions could be correctly detected by the method, some non-tumor regions were misdetected.

Key words: Deep Learning, liver tumor, ultrasound image

腹腔鏡動画像からの Fully Convolutional Network による

血管領域抽出

盛満 慎太郎*¹ 小澤 卓也*¹ 北坂 孝幸*² 林 雄一郎*¹

小田 昌宏*¹ 竹下 修由*³ 伊藤 雅昭*³

三澤 一成*⁴ 森 健策*^{1,5,6}

要旨

本稿では内視鏡動画像からの血管領域の自動抽出手法について述べる。腹腔鏡手術は難易度の高い手術であるため、腹腔鏡などで撮影した動画の自動解析による手術支援システムの開発が進められている。動画からの術具や臓器の自動認識は、コンピュータの手術工程を理解し、術者の手技の適切な支援へとつながる。手術工程の理解において、体内構造を表す血管の抽出は重要である。しかし、血管は手術中の把持や切断などにより形が変化するため、単純な処理で抽出することは困難である。そこで本研究では、深層学習を用いることにより、腹腔鏡動画像から血管領域を自動的に認識する手法の初期検討を行った。モデルには2DU-netを用い、動画中の各フレーム画像に対応する血管領域ラベルを手動で作成し、学習を行った。実験の結果から、評価用データに対するF値は約39%となり、腹腔鏡手術動画像からの血管領域の抽出が可能であることが確認された。

キーワード：FCN, U-net, 内視鏡手術動画

1. はじめに

現在、がんに対する手術として、患者への負担が少ない内視鏡手術が用いられている。内視鏡手術では鉗子の動きが制限される上に、非常に視野が狭いことから難易度が高い。従って内視鏡手術動画に映る術具や臓器をコンピュー

タで認識し、術者の手技を支援する技術が求められる。

内視鏡手術動画を利用して適切に手術支援を行うには手術工程の理解が必要となる。内視鏡手術の中でも特に、腹部を扱う腹腔鏡手術では、手術工程の理解において体内構造を表す血管の認識が重要である。しかし、解剖構造には個人差があり、血管は手術中の把持や切断などにより形が変化するため、単純な処理による抽出は難しい。

そこで本研究では、内視鏡手術動画に映る血管領域を、深層学習を用いることにより自動認識させることを試みる。

2. 提案手法

深層学習のモデルとしては医用画像処理におけるセグメンテーションに主に使われるU-net[1]を用いた。本手法ではRothら[2]が3DU-

*1 名古屋大学大学院情報学研究科

〔〒464-8601 名古屋市千種区不老町 IB 電子情報館南棟4階466号室〕

e-mail: smorimi@mori.m.is.nagoya-u.ac.jp

*2 愛知工業大学情報科学部

*3 国立がん研究センター東病院

*4 愛知県がんセンター

*5 名古屋大学情報基盤センター

*6 国立情報学研究所医療ビッグデータ研究センター

net をもとに改良したネットワークを参考に 2 次元画像用に変更したものを使用した。畳み込みは 3×3 のカーネルを用い、エンコーダー部分では 2×2 の MaxPooling, デコーダー部分では 2×2 の Upconvolution を用いた。Skip connection には Summation を用いて畳み込み前の位置情報を利用し、セグメンテーション結果を生成する。

学習, 評価に用いる画像は動画中の一部を取り出したものであり, 医師の協力の下, 正解データを手動で 2631 枚作成した。学習はミニバッチで行い, 画像 5 枚ごとにパラメータを更新した。

評価には交差検定を用い, 画素単位で F 値, 適合率, 再現率を計算して平均値を算出した。

3. 実験ならびに考察

実験では, 腹腔鏡下 S 状結腸切除術または直腸癌に対する腹腔鏡下前方切除術の動画 38 症例分を用いた。まず, 正解ラベルの存在する学習データを入力としてモデルを学習した。そして, 学習済みモデルに評価用データを入力して, 得られた画像と正解ラベルを比較して評価した。また, 最終的なモデルに手術動画を 1 枚ずつ入力して, 得られた推定ラベルと元の動画を合成することで血管領域がラベル付けされた動画を作成した。

実験の結果として評価用画像に対する評価値を表 1 に示す。また, 元画像を図 1, Ground truth を重畳表示した画像を図 2, 出力ラベルを重畳表示した画像を図 3 に示す。表 1 で F 値をみると, 約 39%と低い値となっている。しかし, 図 1 を見ると, 場面によってはかなり良く抽出できているものも存在した。一方で, 血管が脂肪に隠れている手術前半のシーンの抽出精度は著しく低く, 場面に分けた学習や, 時系列情報の追加などの工夫が必要となる。また, 今回の実験では学習用データに対する精度が 9 割を超えるのに対し, 評価用データに対する精度は低かったことから, 過学習が起きていたと考えられる。そのため, 学習データの追加も今後の課題となる。

表 1 評価用データに対する精度評価。

F 値 (%)	適合率 (%)	再現率 (%)
38.7	59.4	35.7



図 1 元画像となる手術動画中の 1 枚

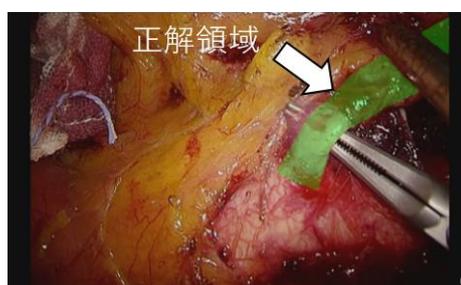


図 2 Ground truth を重畳表示した画像。

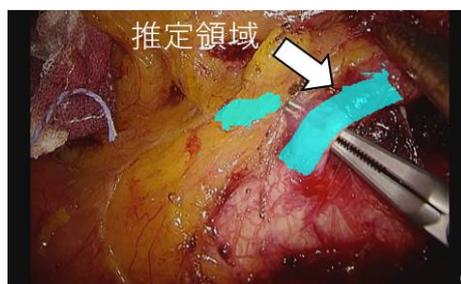


図 3 出力されたラベルを重畳表示した画像。

4. まとめ

内視鏡手術動画を利用した血管領域抽出は, 全体的な精度は低いものの, シーンによっては血管領域を抽出できた。さらなる精度向上のためには, 動画特有の時系列情報の追加が必要と思われる。

謝辞

本研究の一部は JSPS 科研費 17H00867, 17K20099, 26108006, AMED 課題番号 18he1802002, 19lk1010036h0001, 二国間交流事業, 堀科学芸術振興財団の支援を受けた。

利益相反の有無 なし

文 献

- [1] Ronneberger O, Fischer P, Brox T : U-Net: Convolutional Networks for Biomedical Image Segmentation. MICCAI 2015, **9351**: 234-241, 2015
- [2] Roth HR, Oda H, Zhou X, et al.: An application of cascaded 3D fully convolutional networks for medical image segmentation. Computerized Medical Imaging and Graphics, **66**, 90-99 ,2018

Segmentation of blood vessel regions from laparoscopic videos using fully convolutional network

Shintaro MORIMITSU^{*1}, Takuya OZAWA^{*1}, Takayuki KITASAKA^{*2}, Yuichiro HAYASHI^{*1},
Masahiro ODA^{*1}, Masaaki ITO^{*3}, Nobuyoshi TAKESHITA^{*3}, Kazunari MISAWA⁴, Kensaku MORI^{*1,5,6}

*1 Graduate School of Informatics, Nagoya University

*2 School of Information Science, Aichi Institute of Technology

*3 National Cancer Center Hospital East

*4 Aichi Cancer Center Hospital

*5 Information Technology Center, Nagoya University

*6 Research Center for Medical Bigdata, National Institute of Informatics

This paper describes an automatic extraction method of blood vessel regions from endoscopic videos. Because laparoscopic surgery is highly difficult, development of a surgical assistance system based on automatic analysis of videos captured by a laparoscope has been promoted. Automatic recognition of surgical tools and organs from laparoscopic videos leads the computer to understand the surgical process and to properly support the procedure of the surgeon. Extraction of the blood vessels that represent internal structures of a patient is important to understand the surgical process. However, it is difficult to extract blood vessels by simple image processing because their shape changes when they are cut or grasped by surgeon. In this study, we conducted an initial study of a method to automatically recognize the blood vessel region from laparoscopic videos by using deep learning. The blood vessel region labels were annotated manually and are corresponding to each images in the videos. The model was 2D U-net and annotated labels were used as the ground truth in the training. From the results of the experiment, F-value of segmentation results was about 39%. The potential of extraction of the blood vessel regions from laparoscopic video was confirmed.

Key words: FCN, U-net, Endoscopic surgery videos

非接触型微小循環観察環境の構築と 敗血症モデルラットの血行動態解析

川崎 真未^{*1} 中野 和也^{*2} 大西 峻^{*2} 羽石 秀昭^{*2}

要旨

敗血症は感染症に起因して発症し、生命に危機を及ぼす臓器障害である。発症初期には100 μm 以下の血管径である微小循環が障害される。よって敗血症に対する薬効の調査では、微小循環の変化を観察することが重要となる。先行研究では、生体の微小循環が観察可能な Sidestream Dark-Field (SDF)撮影法を用い、敗血症モデルラットの血流速度低下を確認した。しかし SDF 撮影法は装置を組織に接触させる必要があり、組織圧迫の影響や衛生面で懸念がある。そこで本発表では、非接触型撮影装置を構築し、敗血症モデルラットの微小循環の観察及び血流速度解析を行った。非接触型撮影装置による取得動画像から敗血症モデルラットの血流や血管密度の減少が確認された。また血流速度を算出した結果、健常ラットの血流速度は減少しなかったのに対して敗血症モデルラットの血流速度は減少傾向が確認された。これらの結果から、非接触型撮影装置により微小循環の変化を取得可能であることが示唆された。

キーワード：微小循環，敗血症性ショック，血流速度，非接触型撮影装置

1. はじめに

敗血症とは、感染に対する制御不十分な生体反応に起因する生命に危機を及ぼす臓器障害である [1]。敗血症が進行すると敗血症性ショックに移行し死亡率が増加する。そのため早期診断や治療が重要である。敗血症の初期段階では、100 μm 以下の血管径である微小循環が障害される [2]。よって、この微小循環障害を観察し評価することが求められている。先行研究 [3] では、非侵襲で微小循環を観察可能な Sidestream Dark-Field (SDF) 撮影法 [4] を用いて敗血症モデルラットの微小循環を観察し血

流速度の算出を行った。血流速度が減少し、微小循環障害が確認された。しかし、SDF 撮影法は装置を組織に接触させなければならない。組織が圧迫され血行動態が変化する恐れが考えられる。よって非接触で微小循環を観察することが必要である。非接触型撮影装置では血行動態への影響なしに微小循環を観察でき、血液なども付着しないことから衛生的である。そこで本発表では、非接触型撮影装置の構築と敗血症モデルラットを用いた血行動態解析を行った。

2. 非接触型撮影装置の構築

構築した非接触型撮影装置の模式図を図 1(a) に示す。非接触型撮影装置はカラーカメラ (GS3-U3-15S5C-C, FLIR Systems Inc., Pixel Size[μm]: 6.45 \times 6.45, Image Size: 1384 \times 1032), レンズ, LED リング照明 (IOTR-80-25RLGB, 有限会社シマテック), 偏光子と検光子 (USP-50C0.4-38, シグマ光機株式会社) で構成される。

*1 千葉大学大学院融合理工学府基幹工学専攻医工学コース

〔〒263-8522 千葉市稲毛区弥生町 1-33〕

e-mail: m_kawasaki@chiba-u.jp

*2 千葉大学フロンティア医工学センター

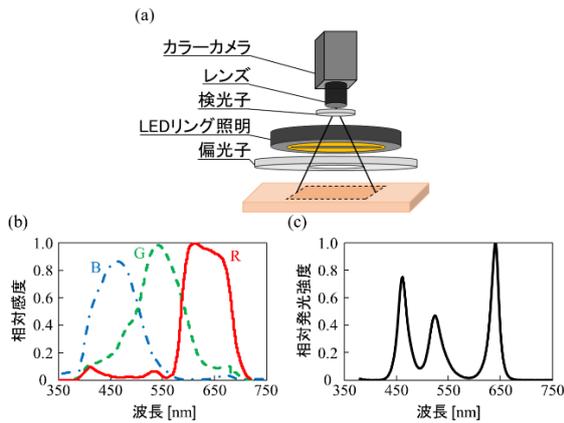


図1 非接触型撮影装置

- (a) 装置の模式図, (b) カラーカメラ相対感度, (c) LEDリング照明の相対発光強度

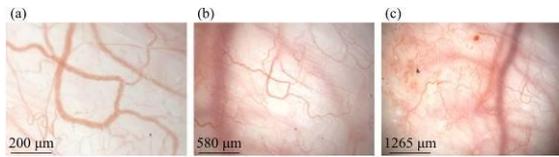


図2 取得画像例

- (a) 対物レンズ, (b) 拡大レンズ(3.5X), (c) 拡大レンズ(1.6X)

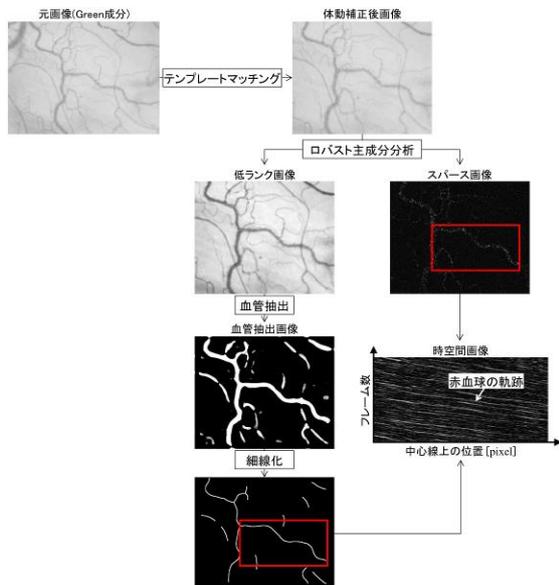


図3 血流速度算出フローチャート

図1(b)はカラーカメラの相対感度である。レンズは対物レンズ(#88-354, Edmund Optics Inc., WD(Work Distance): 13.5 mm, 10X/0.17)と拡大レンズ(AZ-3M, エヌエスライティング株式会社, WD: 36.8 mm, 倍率: 0.7X, 1.06X, 1.6X, 2.4X, 3.5X)の2種類使用した。対物レンズは倍率が高く、拡大レンズは5段階で倍率が調整可能であ

る。LEDリング照明は赤と緑、青のLEDで構成されており、同時点灯することで白色照明を疑似的に再現した。それぞれのLEDは水平面から 25° 傾いた暗視野照明である。相対発光強度を図1(c)に示す。偏光板はリング状に加工した偏光子をLEDリング照明に、円形の検光子をレンズにクロスニコル配置で取付けた。照明から偏光子を通過した光が生体表面に入射した場合、偏光は保持されるためクロスニコル配置された検光子は通過できない。一方生体内部に入射した場合、偏光が解消されるため検光子を通過できる。このように偏光板を用いて生体内部での散乱光の観察及び表面反射光の低減を図った。

図2に非接触型撮影装置を用いて同一領域を撮影した際の取得画像例を示す。対物レンズを用いた場合(図2(a)), 直径 $10\ \mu\text{m}$ 程度の細い血管を確認でき、赤血球の流れが観察可能である。拡大レンズを用いた場合(図2(b), (c)), 赤血球の流れは確認困難であるが、図2(a)よりも血管網を広く観察可能である。このように、非接触型撮影装置ではレンズなどの光学系を調整することで、目的に合わせた微小循環像を容易に取得可能である。

3. 血流速度算出手法

図3に血流速度算出のフローチャートを示す。まず元画像から赤血球を強調するためにヘモグロビンの吸収が大きいGreen成分のみを取り出す。その後、テンプレートマッチングにより体動によるブレを補正する。体動補正後画像に対してロバスト主成分分析(Robust principal component analysis: RPCA) [5]を行う。RPCAは、画素値の時間変化の小さい低ランク成分と大きいスパース成分に分離する手法である。血管や組織は画素値の時間変化が小さいため低ランク成分に、ノイズや赤血球の流れは変化が大きいためスパース成分に分類される。よってRPCAにより血管や組織と赤血球の流れを分離できる。血管領域を抽出するため、低ランク画像に対してFrangiの方法[6]を適用し、血管を抽出した。その後、血管抽出画像を細線化[7]

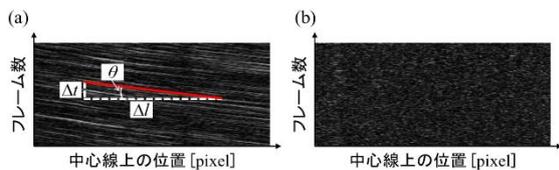


図 4 血流の有無による時空間画像の違い
(a) 血流がある場合, (b) 血流がない場合

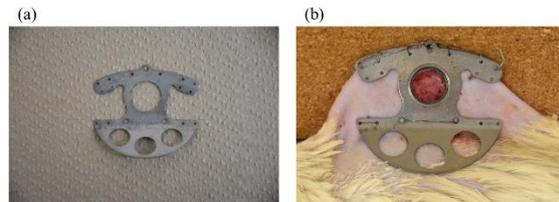


図 5 微小循環観察用チャンバー
(a) 微小循環観察用チャンバー, (b) 取付けた様子

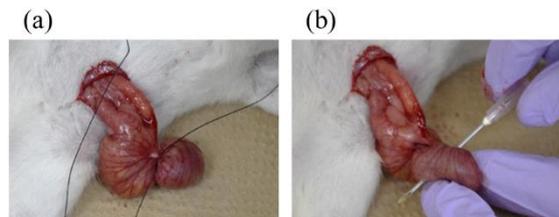


図 6 手技の様子
(a) 結紮, (b) 穿刺

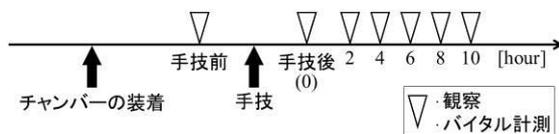


図 7 実験プロトコル

することで血管の中心線を取得した。この中心線に沿ってスパース画像の画素値を抽出・整列させ、時空間画像を生成した。時空間画像の横軸は中心線上の位置、縦軸はフレーム数となっている。図 4 に血流の有無による時空間画像の違いを示す。図 4(a)のように血流がある場合は、赤血球の流れの軌跡が時空間画像上に直線となる。血流が速いほど直線の傾きは大きくなる。よって血流速度 v は、 $v = \Delta l / \Delta t = \tan \theta$ で表される。血流がない場合は図 4(b)のように時空間画像に直線が現れない。直線の傾き θ は、時空間画像に対して 2 次元フーリエ変換を利用し算出した。

4. 実験と結果

本実験では、ラットを敗血症モデルラットと健常ラットの 2 群に分け、2 群間の微小循環の

変化を比較した。本実験は、千葉大学動物実験委員会の承認を受けている。雄系 Wistar ラット (日本エスエルシー株式会社, 12 週齢) を使用し、背部真皮の微小循環を観察した。毎回同一領域を観察するために、微小循環観察用チャンバー (図 5(a)) を使用した。観察の前にチャンバーをそれぞれのラットの背部に取付けた (図 5(b))。取付け後、敗血症モデルラットが属する Cecal Ligation and Puncture (CLP) 群 ($n=3$) と健常ラットが属する Sham (偽手術) 群 ($n=3$) に無作為に分け、それぞれ手技を施した。敗血症モデルラットとして CLP モデル [8] を採用した。CLP モデルは盲腸を結紮・穿刺することで細菌性腹膜炎を起こし、敗血症に発展させる動物モデルである。実施した CLP 群の手技手順を述べる。まず、手技開始 16 時間はラットごとに似た腸の内容物の量にするため水は自由に与えるが断食を行った。その後、開腹し腹腔から盲腸を取り出した。図 6(a) のように盲腸を回盲弁のすぐ下を 3-0 絹縫合糸 (SC003, 株式会社 河野製作所) で結紮し、図 6(b) のように血管を傷つけないように 18 ゲージの針 (NN-1838S, テルモ株式会社) で穿刺し 3 つの穴を開けた。穴から内容物を押し出した。その後盲腸を腹腔内に戻し閉腹した。Sham 群は開腹による侵襲の影響を考慮するために偽手術を行った。Sham 群は盲腸を取り出したが、結紮と穿刺は行わずに腹腔に戻した。それ以外の手技は CLP 群と同様に行った。図 7 に実験プロトコルを示す。微小循環の観察は手技直前と手技直後、その後 2 時間ごとに 10 時間後まで行った。観察と同じタイミングで乳酸値の計測も行った。すべての手技や観察、計測は 2.0% のイソフルラン (099-06571, ファイザー株式会社) の麻酔下で行った。

図 8 に対物レンズを使用した取得画像を示す。Sham 群の血管密度や血流速度はあまり変化が見られないが、CLP 群の血管の消失や血管径の縮小が見られ血管密度や血流速度の減少が取得動画から確認された。これは敗血症により微小循環が障害されたと考えられる。図 9 に乳酸値と血流速度の推移を示す。横軸は手技終了からの経過時間、縦軸は乳酸値 (図 9(a))、血流速度

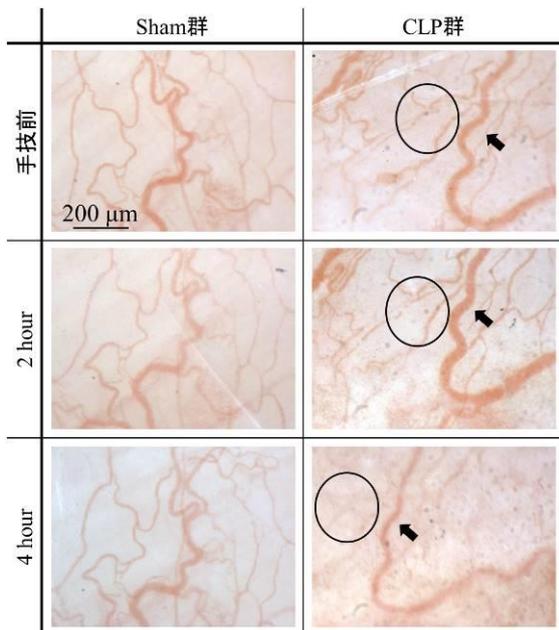


図8 対物レンズを使用した取得画像

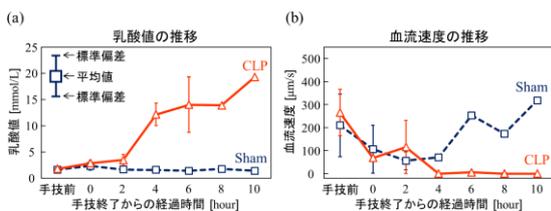


図9 乳酸値と血流速度の推移

(a) 乳酸値の時間変化, (b) 血流速度の時間変化

(図9(b))である。Sham群の乳酸値はほとんど変化がないのに対しCLP群は上昇しており、CLP群が敗血症に罹患していることが推測される。Sham群の血流速度はあまり変化していないが、CLP群は減少傾向が確認されている。以上より非接触型撮影装置を用いて微小循環の変化を取得可能であることが示唆された。

5. まとめ

非接触型撮影装置を構築し、敗血症モデルラットの微小循環を観察した。取得動画から血流速度を算出した結果、CLP群の血流速度の減少が確認された。したがって、非接触型撮影装置を用いた微小循環解析が可能であることが示唆された。今後は血流速度以外の微小循環評価指標の解析を行う。

謝辞

本研究の一部は文部科学省科学研究費補助金(課題番号: 16H01855, 19H01172)により行われた。

利益相反の有無

なし

文献

- [1] M Singer, C S Deutschman, C W Seymour, et al.: The third international consensus definitions for sepsis and septic shock (Sepsis-3). *Jama* **315**(8): 801-810, 2016
- [2] P E Spronk, D F Zandstra, C Ince: Bench-to-bedside review: sepsis is a disease of the microcirculation. *Critical care* **8**(6): 462-468, 2004
- [3] M Takahashi, T Kurata, T Ohnishi: Quantitative evaluation of blood flow obstruction in microcirculation with sidestream dark-field images. In *Proceedings of SPIE Conference on BIOS, San Francisco, 2017*, 100680A
- [4] C Ince: Sidestream dark field imaging: an improved technique to observe sublingual microcirculation. *Critical care* **9**(1): 72, 2005
- [5] E J Candès, X Li, Y Ma, et al.: Robust principal component analysis?. *Journal of the ACM (JACM)* **58**(3): 11, 2011
- [6] A F Frangi, W J Niessen, K L Vincken, et al.: Multiscale vessel enhancement filtering. In *International conference on medical image computing and computer-assisted intervention* **1496**: 130-137, 1998
- [7] T Y Zhang, C Y Suen: A fast parallel algorithm for thinning digital patterns. *Communications of the ACM* **27**(3): 236-239, 1984
- [8] K A Wichterman, A E Baue, I H Chaudry: Sepsis and septic shock—a review of laboratory models and a proposal. *Journal of Surgical Research* **29**(2): 189-201, 1980

Construction of non-contact setup for microcirculation imaging and flow analysis in septic model rats

Mami KAWASAKI*¹, Kazuya NAKANO*², Takashi OHNISHI*², Hideaki HANEISHI*²

*1 Graduate School of Science and Engineering, Chiba University

*2 Center for Frontier Medical Engineering, Chiba University

Sepsis is life-threatening organ dysfunction caused by a dysregulated host response to infection. At the early stage of sepsis, it is known that the microcirculation is impaired. Thus, it is important to detect this change in the microcirculation during septic shock to investigate the drug effectiveness of septic shock. In previous study, we observed the microcirculation of sham rats and septic model rats with sidestream dark-field (SDF) imaging which is one of the methods to observe the microcirculation non-invasively. As a result, the blood velocity of the septic model rats decreased. However, the SDF imaging has several problems for instance artifacts caused by pressure and heat. Its measurement points are under pressure because the SDF imaging requires direct contact with the surface, which may affect hemodynamics. Therefore, we constructed a non-contact setup and conducted an experiment using the setup to observe the septic model rats and the sham rats. Moreover, we calculated the blood velocity using acquired motion pictures. We confirmed a slight change in blood velocity of the sham rats during the observation. However, the blood velocity of the septic model rats decreased. This finding suggests that microcirculatory alteration may be a sign of sepsis and septic shock progression.

Key words: Microcirculation, Septic shock, Blood velocity, non-contact setup

手術の多視点動画撮影および画像認識による 自動視点切替表示

梶田 大樹*¹ 大石 圭*² 高詰 佳史*³ 斎藤 英雄*² 杉本 麻樹*²

要旨

手術をビデオ撮影してモニターで表示することの有用性は以前から認識されている。多くの手術室には、すでに固定式の術野カメラが設置されている。しかし、これらカメラでは外科医の頭部や手によって術野の遮蔽が生じ、Open Surgery の動画活用が進まない一因となっていた。この課題を解決するために、多視点カメラで術野を撮影するという手法がある。本論文では、多視点カメラとして横 1 列のカメラアレイと、マルチカメラ搭載型無影灯による撮影手法を提案する。多視点の映像には画像検出を適用し、認識された術野領域の大小によってカメラを自動で選択することで、遮蔽のない術野映像を表示し続ける。ただし頻繁なカメラの切り替えは動画の視聴品質(Quality of View, QoV)を損なうので、術野の表示と QoV を両立するカメラスケジューリングを適用する。また本提案手法を実際の手術に適用し、その有用性を検証する。

キーワード：手術動画，多視点カメラ，術野カメラ，術野検出，カメラスケジューリング

1. はじめに

手術をビデオ撮影してモニターで表示することの有用性は以前から認識されている[1]。多くの手術室には、すでに固定式（天井吊り下げ型，無影灯内蔵型など）の術野カメラが設置されている。しかし、これらカメラでは外科医の頭部や手によって術野の遮蔽が生じ、手術工程が映らなくなる場合がある。このことは、特に外科医が自身の眼で術野を視認しながら手術を行う open surgery の領域で、手術動画の活用がなかなか進まない一因となっていた。

本論文では、多視点カメラで術野を撮影し、画像検出によって術野が映っているカメラを自動で選択することで、遮蔽のない術野映像を表示する手法について提案する。

2. 関連研究

本研究の先行研究として、無影灯の周囲に設置した 4 台のカメラ映像を自動で切り替えた研究を報告した[2, 3]。この手法では、無影灯が術中に移動・傾動するのに対し、カメラの角度は固定されているために、術中に無影灯が動かされ術野の距離が変化すると、術野が撮影されなくなるという課題があった。

本提案手法は、無影灯を動かしても術野を記録し続けることを目的としている。

3. 提案手法

まず前提として、術野の周囲に多数のカメラを設置する際には、手術の進行に支障がないように注意する必要がある。

1) カメラアレイによる撮影

手術室に備えられたカメラアームに多数のカメラを設置することで、無影灯の動きとは独立して、視点の異なる映像を記録できる。

2) マルチカメラ搭載型無影灯による撮影

無影灯のライトユニットはそれぞれ傾動さ

*1 慶應義塾大学医学部形成外科
〔〒160-8582 新宿区信濃町 35〕

e-mail: jmr bx767@keio.jp

*2 慶應義塾大学大学院理工学研究科

*3 慶應義塾大学医学部解剖学教室

せ、照明の広さや明るさを調整することができる。そこでカメラをライトユニットに設置し、ライトユニットの動きによらず照明とカメラの方向が一致するようにする。

3) カメラスコアリング

先行研究[2, 3]に引き続き, Cheng, et al.[4]の手法を用いて, 色とテクスチャの情報を学習して術野を検出する。あるカメラ c の時刻 t における検出領域の大きさをスコア s_{ct} と定義する。

4) カメラスイッチング

s_{ct} を比較してカメラを選択する。切替が過多となると視聴品質 (Quality of View, QoV) を損なうため, 切替が生じない最小フレーム数を視聴者が定義可能とし, 先行研究[2, 3]に引き続き, ダイクストラ法を応用して最適化を行う。

4. 実験

実際の手術を撮影し, 本提案手法の有効性を検証した。手術の映像記録および動画データの二次利用については, 慶應義塾大学医学部倫理委員会承認を得たうえで, 患者本人もしくは代諾者から書面による同意を得た。

1) カメラアレイによる撮影

天井のカメラアームにカメラ (DSC-RX0, ソニー株式会社) を 6 台並べて設置し, それぞれが術野に向くように傾けた (図 1)。

3 人の外科医が互いに頭を出して術野を観察する手術においても, ほぼ全ての時間において, いずれかのカメラでは術野の映像が記録されていた (図 2)。ただし無影灯がカメラアームにぶつかると, 術野が見えなくなる場合があった。

2) マルチカメラ搭載型無影灯による撮影

スタンド型無影灯 (LEDX II 5S, 第一照明株式会社) の灯体のライトユニットにそれぞれカメラ (Phoenix 3.2 MP Model, LUCID Vision Labs Inc.) を設置し, 画角が照光部に一致するよう調整した (図 3)。

やはりほぼ全ての時間において, いずれかのカメラでは術野が撮影されたが, 術野に照明があまり届かない場合には, いずれのカメラでも術野が見られないこともあった (図 4)。



図 1 カメラアームに 6 台のカメラが設置されている (矢印)

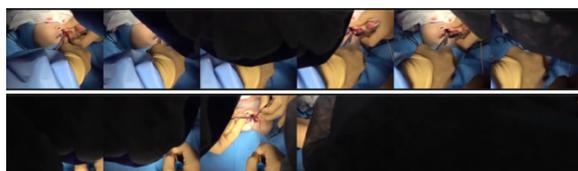


図 2 視点が横にずれた同時刻の 6 画像を並べたもの。; 上段: 3 視点で術野が見えている。; 下段: 1 視点でのみ術野が見えている。



図 3 無影灯の 5 つライトユニットそれぞれの中央に 1 台ずつカメラが設置されている (矢印)

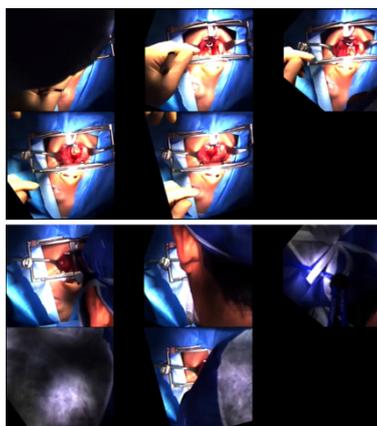


図 4 ライトユニットに設置したカメラで得られた同時刻の 5 画像を並べたもの。; 上段: 4 視点で術野が見えている。; 下段: 1 視点でのみ術野が見えているが, 暗い。



図 5 口内の術野を検出した例.

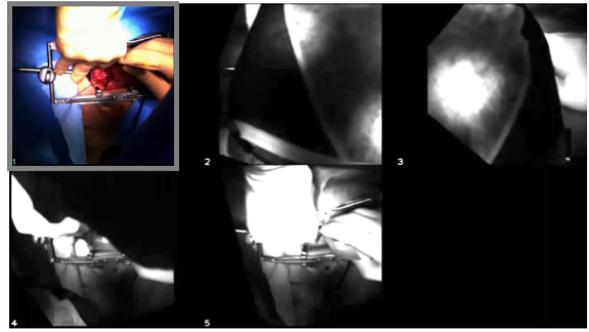


図 6 検出結果にもとづいてカメラを選択した例.

3) スイッチング結果

検出器の学習には、それぞれの映像から無作為に選んだ約 100 枚の画像を用いた。「術野」の定義は、それぞれの手術が対象とする部位に応じて行った (図 5)。

このスコアによってカメラを選択し (図 6)、最小フレーム数を調整することで、良好な視点自動切替による映像の表示が可能であった。

5. まとめ

提案手法では、外科医が普段通りに無影灯を操作して手術を行っても、術野の多視点カメラ撮影が可能であった。今後は、VR・MR等の展開を見据え、本手法の映像に隠消現実感の技術を適用したり[5]、自由視点映像を作成したりすることも検討したい。

謝辞

本研究は、JST CREST(JPMJCR14E3)、AMED(JP18he1902002h0001)の支援を受けたものです。

利益相反の有無

なし。

文 献

- [1] Yan Xiao, Stephen Schimpff, Colin Mackenzie, et al.: Video Technology to Advance Safety in the Operating Room and Perioperative Environment. *Surgical Innovation* **14**: 52-61, 2007
- [2] 大石圭, 齋藤英雄, 梶田大樹 他: マルチカメラ搭載型无影灯により記録された手術動画の自動視点切替. 動画像処理実利用化ワークショップ 2019 講演論文集: 301-308, 2019.
- [3] 大石圭, 齋藤英雄, 梶田大樹 他: 多視点手術動画の自動視点切替. 研究報告コンピュータビジョンとイメージメディア (CVIM) **2019-CVIM-215(18)**: 1-6, 2019.
- [4] Li Cheng, Kris M. Kitani: Pixel-level hand detection in ego-centric video. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*: 3570-3577, 2013.
- [5] 前澤桃子, 大石圭, 森尚平 他: マルチカメラ搭載型无影灯を使用した手術動画を利用した作業領域の DR 表示. **2019-CVIM-215(14)**: 1-5, 2019.

Multi-Viewpoint Video Recording for Surgery and Automated Camera Switching by Image Recognition Technology

Hiroki KAJITA^{*1}, Kei OISHI^{*1}, Yoshifumi TAKATSUME^{*1}, Hideo SAITO^{*1}, Maki SUGIMOTO^{*1}

^{*1} Keio University

The usefulness of video recording and monitor display of surgery has long been recognized. In many operating rooms, fixed surgery cameras are already installed. However, with these cameras, the surgeon's head and hands often cause the surgical field to be occluded, and this has been a main factor in the inability to utilize the videos in the field of open surgeries. Multiple-viewpoint camera system is one of the methods to solve this problem. In this study, we propose a multi-viewpoint camera array and multi-camera mounted shadowless lamp to record open surgeries. Image detection is applied to multi-viewpoint images, and a camera is automatically selected according to the size of the recognized surgical fields, thereby to display the process of the surgery without occlusion. However, frequent camera switching impairs the quality of view (QoV) of the videos, so camera scheduling that achieves both the displayed area of the surgical field and QoV is applied. Also, we applied the proposing method to actual surgery and verified its usefulness.

Key words: Surgical videos, Multiple viewpoint cameras, surgical cameras, Surgical field detection, Camera scheduling

Movie

覚醒下脳腫瘍摘出術における術中情報を用いた脳機能マッピング工程同定手法の提案

佐藤 生馬^{*1}, 南部 優太^{*1}, 藤野 雄一^{*1}, 堀瀬 友貴^{*2},
楠田 佳緒^{*2}, 田村 学^{*2}, 村垣 善浩^{*2}, 正宗 賢^{*2}

要旨

脳腫瘍摘出手術において、熟練医は最大限の腫瘍摘出と最小限の術後合併症リスクを実現するため、患者の脳構造や機能を把握し、独自の判断プロセスにより腫瘍を切除する。この判断プロセスは、熟練医が培った知識や経験にもとづく暗黙知とされており、医療の質の向上や若手医師教育のために可視化が望まれている。本研究では、覚醒下脳腫瘍摘出術において患者毎に異なる腫瘍付近の脳機能を把握する脳機能マッピング時の暗黙知の可視化に向け、術中情報を用いた脳機能マッピング工程同定手法を提案する。本提案手法では、術中MRIやナビゲーションシステムからの位置情報および顕微鏡などからの動画より特徴量を抽出し、これらの特徴量を用いて2階層からなる階層型隠れマルコフモデルより、手術の流れと脳機能マッピング時の工程を可視化する。そして、過去の臨床データを用いて、本手法により手術工程を同定し、その精度を評価したので報告する。

キーワード：覚醒下脳腫瘍摘出術，手術工程，ナビゲーションシステム，機械学習，深層学習

1. はじめに

脳腫瘍摘出手術において、熟練医による手術では最大限の腫瘍摘出と最小限の術後合併症リスクを実現するため、患者の脳構造や機能を把握し、独自の判断プロセスにより腫瘍を切除する。この判断プロセスは、熟練医が培った知識や経験にもとづく暗黙知とされており、医療の質の向上や教育支援のためには若手医師などと共有することが望まれる。そのため、本研究では熟練医の判断プロセスを可視化することで暗黙知の共有を目指す。

本研究では、覚醒下脳腫瘍摘出術において患者毎に異なる腫瘍付近の脳機能を把握する脳機能マッピング時の暗黙知の可視化に向け、術中情報を用いた脳機能マッピング工程同定手法を提案する(図1)。そして、手術工程モデルを構築し機械学習による手術工程同定を行い、その精度を評価する。

2. 脳機能マッピング工程同定用手術工程モデルの構築

手術工程および脳機能マッピング工程の同定するため、術中情報を用いて手術工程モデルを構築する。本研究で構築するモデルの対象として、熟練医の手技や判断プロセスが含まれるとされる覚醒下脳腫瘍摘出術におけるMRI撮像後の手術準備から腫瘍切除終了までとする。対象とした症例の手術映像やナビゲーションシステムから取得した術具の位置を手動で記録し、手術工程の要素とした。

構築した手術工程モデルは術中の脳機能位置同定工程である脳機能マッピング工程の同定に特化させた2階層から構成される。この手術工程モデルは1階層目には摘出前処置・皮質マッピング・腫瘍摘出・白質マッピングの4工



図1 手術工程同定手法の外観

^{*1} 公立はこだて未来大学大学院
システム情報科学研究科
[〒041-8655 北海道函館市亀田中野町 116-2]
^{*2} 東京女子医科大学 先端生命医科学研究所

程であり、2階層目には皮質・白質マッピングの詳細な工程であるの電気刺激準備および電気刺激・痙攣波への対処および機能野のマッピングの2工程から構成される。

3. 機械学習による手術工程同定

本提案手法では、術中情報からの特徴量を用いて2階層からなる階層型隠れマルコフモデルより、手術の流れと脳機能マッピング時の工程を同定する。手術工程の同定に使用する術中情報は、術中MRIやナビゲーションシステムからの位置情報(ログ情報)および顕微鏡や覚醒下の脳機能マッピングで使用されるIEMASからの動画である。これら複数の医療機器から得られる情報から機械学習および深層学習により手術工程の特徴量を取得する。そして、本手法では手術ナビゲーションシステムで術具のマーカの遮蔽問題により、ログ情報が取得できない場合に対して、顕微鏡画像からの術具検出により、特徴量を補完する。

本手法における手術工程同定は、以下の4ステップで行う。①脳構造上での処置位置の取得、②使用する術具の種類取得、③IEMAS動画の音声より電気刺激時の時間の取得、④取得結果を用いた手術工程の同定。

- ① 手術ナビゲーションシステムのログ情報とMRI画像から医用画像処理によって、脳構造上の処置位置(腫瘍内部、脳表、正常脳、脳領域外)を取得する。
- ② 手術顕微鏡動画から機械学習のYOLO(You Only Look Ones)を用いて術具(バイポーラ、電気刺激プローブ、剪刀)を取得する。
- ③ IEMAS動画の音情報より電気刺激装置による脳への電気刺激時の音を機械学習により、抽出して電子刺激時間を取得する。
- ④ ①②で取得した情報から手術工程モデルにもとづいてHHMM(Hierarchical Hidden Markov Model)を用いて工程を同定する。この同定処理を1秒ごとに1回行い、リアルタイムに手術工程の同定を行う。さらに、第1階層の同定結果に前後2秒での多数決による平滑化処理を行った。その後、同定結果お

よび③の情報を用いて、脳へ電気刺激の工程を同定する。

4. 手術工程同定精度評価実験

左脳に腫瘍があり覚醒下脳腫瘍摘出術を行った1症例(約120分)に対して、手術工程同定精度を評価する。臨床データは本手法で使用する術中MRI画像、顕微鏡動画、IEMAS動画、ナビゲーションシステムの術具位置情報を用いて同定する。同定は、1秒間に1回の同定を行い、あらかじめ手動で作成した正解同定結果と自動同定結果を比較し精度を評価した。

手術工程同定精度の評価結果として、4工程に分類した第1階層の同定精度は99.5%であり、摘出前処置は100%、皮質マッピングは97.1%、腫瘍摘出は95.8%、白質マッピングは94.7%であった。皮質・白質マッピングの詳細な工程である第2階層の同定精度の平均は93.3%であった。皮質マッピング時の電気刺激準備および電気刺激は96.0%、痙攣波への対処および機能野のマッピングは94.9%であった。白質マッピング時の電気刺激準備および電気刺激は90.3%、痙攣波への対処および機能野のマッピングは91.8%の精度であった。そして、音情報を用いた電気刺激時間の同定精度は18.6%であり、皮質マッピング時は34.4%、白質マッピング時は2.8%であった。

5. 結語

本研究では、術中情報を用いて脳機能マッピング工程同定用手術工程モデルの構築および手術工程同定を行った。過去の臨床データを用いて、手動で作成した正解モデルと自動同定精度を評価した結果、第1階層の同定結果精度は99.5%、第2階層では93.3%となった。しかしながら、音情報を用いた電気刺激時間の同定精度は18.6%であった。精度が低下した要因として、機械学習による誤検出とそれら情報を用いた同定の誤判定に原因がある。特に、音情報はノイズや出力された音が急に小さくなるなどがあり、精度に影響を与えた。今後は、更なる精度向上を目指すとともに暗黙知可視化に向けた同定・解析システムの開発を行う。

謝辞:本研究はAMEDの課題番号JP18he1602003の支援を受けた。

利益相反の有無:「なし」

GAN を用いた病理組織画像における異常組織の自動同定法

林 大誠*¹, 中山 良平*¹, 檜作 彰良*¹

黒住 眞史*², 真鍋 俊明*²

要旨

本研究の目的は、正常組織のみを含む病理組織画像を GAN (Generative Adversarial Nets) に学習させることにより、病理組織画像から異常組織を自動同定するアルゴリズムを開発することである。実験試料は、ヘマトキシリン・エオジン染色された腫瘍を含む病理組織標本、腫瘍を含まない病理組織標本を倍率 20 でデジタル化した画像を用いた。GAN の学習では、学習用の腫瘍を含まない病理組織画像から抽出した関心領域を GAN に入力することにより、正常組織構造をネットワークに学習させた。そして、学習済みネットワークを用いて、正常組織構造とは異なる構造を有すると評価された関心領域を異常組織として同定した。学習した GAN を評価用画像データに適用した結果、正答率 91.6% が得られ、提案手法の有用性が示唆された。

キーワード: GAN, 異常組織同定, 病理組織画像

1. はじめに

近年、がん罹患者数の増加に伴い、確定診断である病理組織診断の件数も大幅に増大している。しかし病理組織診断を実施する病理医は年々減少し、慢性的な病理医不足が問題となっている。そこで、畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) を用いた病理組織の自動診断や診断支援に関する研究が報告されている[1, 2]。CNN を用いた手法の多くは、病理医により手動で付与されたアノテーション情報に基づき、各病理組織画像から正常組織/異常組織の関心領域を抽出し、関心領域に対する教師データ (確定診断結果) を CNN に学習させている[3]。しかし、多忙な病理医がアノテーションを付与する必要がある、訓練データの構築が非常に困難な問題がある。

そこで本研究では、アノテーションが不要な正常組織のみを含む病理組織画像を学習に用いて、正常組織とは異なる特徴を有する領域を異常組織として検知する手法を提案する。深層学習を用いた異常検知の一つとして、敵対生成ネットワーク (GAN: Generative Adversarial Nets) がある[4]。GAN は、Generator と Discriminator の 2 つのネットワークで構成される。これらのネットワークの敵対的学習により、Generator は訓練データに似た新しい画像を生成し、Discriminator は訓練データと生成画像を判別することが可能となる。そして、訓練データと生成画像の差分に基づき、異常検知が実施される。

本研究では、正常組織の関心領域のみを用いて学習させた GAN の Discriminator により、病理組織画像の各関心領域を正常組織と異常組織に分類する。

*1 立命館大学理工学部電子情報工学科

[〒525-8577 草津市野路東 1-1-1]

e-mail: ri0053he@ed.ritsumeiji.ac.jp

*2 滋賀県立総合病院研究所

2. 方法

1) 実験試料

実験試料は滋賀県立総合病院で採取され、H & E (ヘマトキシリン・エオジン) 染色された 25 胸部病理組織標本 (非腫瘍: 18 症例, 腫瘍: 7 症

例) のデジタルスライド画像である。バーチャルスライドスキャナ (NanoZoomer, 浜松ホトニクス, 浜松市) により, スキャン倍率 20 でデジタル化された。

2) GAN を用いた異常組織の自動同定

本研究では, DCGAN (Deep Convolutional GAN) [5] を病理組織画像に適する構成に変更した。Generator は, 300 次元のランダムノイズを入力とする入力層, 次に, 正規化層, アップサンプリング層, 畳み込み層, ReLU (Rectified Linear Unit) 活性化関数を 1 セットとする層の組み合わせを 2 セット, そして, 正規化層, 畳み込み層, tanh 活性化関数で構成される。各畳み込み層のフィルタサイズは 3 で, フィルタ数は順に 64, 32, 3 である。Discriminator は 200×200 の生成画像/訓練データを入力とする入力層, 次に, 畳み込み層, LeakyReLU 活性化関数, Dropout 層を 1 セットとする層の組み合わせを 4 セット, そして, 全結合層で構成される。各畳み込み層のフィルタサイズは 3 で, フィルタ数は 16, 32, 64, 128 である。また, LeakyReLU の傾きは 0.2 と設定し, Dropout 層は 0.25 の割合でノード削除を行った。

GAN の学習に用いる訓練データの作成として, 腫瘍を含まない病理組織画像から, スーパーピクセルおよび閾値処理により, 組織を含む 200×200 の関心領域を抽出した。そして, 関心領域を下式により正規化を行った。

$$\hat{x}_i = \frac{x_i - 127.5}{127.5} \quad (1)$$

GAN の各ネットワークの学習において, まず, 一様分布からランダムに抽出したノイズ値 300

個を Generator に入力し, 200×200 画像を 64 枚生成する。そして, 生成画像を Discriminator に入力し, 識別結果に応じて Generator を更新する。Discriminator の学習は, Generator から生成した画像 32 枚, 訓練データ 32 枚を Discriminator に入力し, 識別誤差が低下するように Discriminator を更新する。このネットワークの更新を 1,000,000 回になるまで, 繰り返し, 交互に実施する。

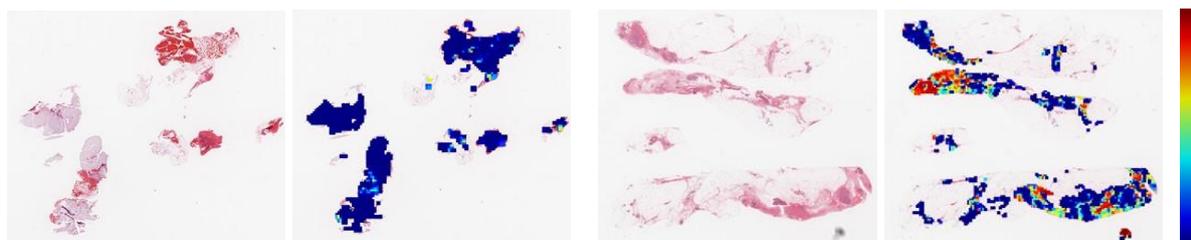
最後に, 正常な病理組織の分布を学習した Discriminator に評価用の画像を入力し, 学習済み分布との違いに基づき, 異常組織の可能性を評価する。

3. 結果と考察

図 1 に腫瘍を含まない/含む病理組織画像と各関心領域の評価結果に基づき作成した異常組織の可能性画像を示す。異常組織の可能性画像において, 暖色は異常組織の可能性が高く, 寒色は低いことを表す。腫瘍を含まない病理組織画像の異常組織可能性画像において, 大部分の関心領域が異常組織の可能性が低いと正確に評価されていることがわかる。一方, 腫瘍を含む病理組織画像の異常組織可能性画像では, 異常組織の可能性が高いと評価された関心領域が部分的に集簇している箇所がみられた。学習した GAN を評価用 7 画像データに適用した結果, 正答率 91.6% が得られた。

4. まとめ

本研究では, GAN を用いて, 病理組織画像に含まれる異常組織の同定を行った。その結果, 正答率 91.6% が得られ, 異常組織可能性画像を



腫瘍を含まない病理組織画像

腫瘍を含む病理組織画像

図 1 異常組織の可能性画像

用いて異常組織の同定が可能であることが示唆された。

謝辞

本研究で使用した病理標本をご提供して頂いた滋賀県立総合病院の皆様に厚く感謝の意を表します。

利益相反の有無

なし

文 献

- [1] Wei Shao, Liang Sun, Daoqiang Zhang: Deep active learning for nucleus classification in pathology images. 2018 IEEE 15th International Symposium on Biomedical Imaging.
- [2] John X. Qiu, Hong-Jun Yoon, Paul A. Fearn, et al.: Deep Learning for Automated Extraction of Primary Sites From Cancer Pathology Reports. IEEE JOURNAL OF BIOMEDICAL AND HEALTH INFORMATICS, VOL. 22, NO. 1: 244-251, 2018
- [3] Sonia Mejbri, Camille Franchet, Ismat Ara Reshma, et al: Deep Analysis of CNN Settings for New Cancer whole-slide Histological Images Segmentation: the Case of Small Training Sets. 6th International conference on BioImaging (BIOIMAGING 2019), 2019
- [4] Thomas Schlegl, Philipp Seeböck, Sebastian M. Waldstein, et al: Unsupervised Anomaly Detection with Generative Adversarial Networks to Guide Marker Discovery. arXiv:1703.05921v1, 2017
- [5] Alec Radford, Luke Metz, Soumith Chintala: Unsupervised representation learning with deep convolutional generative adversarial networks. arXiv:1511.06434v2, 2016

Computerized Scheme of Identifying Abnormal Tissues on Pathological Images using GAN

Daisei HAYASHI*¹, Ryohei NAKAYAMA *¹, Akiyoshi HIZUKURI*¹,
Mafumi KUROZUMI*², Toshiaki MANABE*²

*1 Science and Engineering, Ritsumeikan University

*2 Shiga General Hospital Research Center

The purpose of this study was to develop a computerized scheme for identifying abnormal tissues from pathological images using GAN which was trained pathological images including only normal tissues as anomaly detection. In this study, our database consisted of pathological images by scanning pathological specimens with/without tumor with the magnification ratio of 20 times. Those specimens were stained with Hematoxylin and Eosin. In training GAN phase, regions of interest (ROIs) extracted from non-tumor pathological images were input to GAN to learn the normal tissue structure. In testing GAN phase, ROIs with structure different from normal structure were evaluated as abnormal tissues by using trained GAN. The computerized scheme with GAN exhibited the classification accuracy of 91.6%, and can be useful in identifying abnormal tissues on pathological images.

Key words: GAN, pathological images, anomaly detection

3次元CT画像を用いた じん肺の重症度診断支援システム

森 奈々^{*1} 日野 公貴^{*1} 松廣 幹雄^{*2} 鈴木 秀宣^{*2} 河田 佳樹^{*2}
仁木 登^{*2} 加藤 勝也^{*3} 岸本 卓巳^{*4} 芦澤 和人^{*5}

要旨

じん肺は、粉じんを肺に吸入することによって生じる職業性呼吸器疾患である。我国において毎年24万人前後の粉じん労働者がじん肺健康診断を受診している。じん肺診断では胸部単純X線写真を用いているが近年ではCT画像を用いた定量的な診断法が検討されている。本報告では、じん肺CT画像の第0型0/1, 第1型1/0, 第1型1/1, 第1型1/2, 第2型2/2からマニュアル処理によって粒状影を抽出し、じん肺CT画像データベースを作成する。このデータベースを用いてX線写真の診断結果と粒状影の個数・大きさ・重症度別に解析・比較・評価・診断支援システムの開発を行う。

キーワード: CT, CAD, 医用画像処理

1. はじめに

じん肺は、粉じんを肺に吸入することによって生じる職業性呼吸器疾患である。日本の粉じん作業従事労働者数は昭和60年をピークに減少し、平成12年で35万人であったが、近年は約50万人前後で推移しており増加傾向となっている。じん肺が進行すると肺結核・続発性気胸・肺がんなどの合併症に罹患しやすくなるため、健康診断で適切な診断・治療が必要である。

また、じん肺健康診断として胸部単純X線撮影や肺機能検査が実施されている。胸部単純X線写真によって第0型、第1型、第2型、第3

型、第4型に分類され、第1型以上の患者は労災認定となるが第0型の患者は労災認定の対象とならないため正確に診断しなければならない。ここで、近年では胸部CT検査による定量的な診断法が検討されている。本報告では、じん肺CT画像の第0型0/1, 第1型1/0, 第1型1/1, 第1型1/2, 第2型2/2からマニュアル処理によって粒状影を抽出し、じん肺CT画像データベースを作成する。このデータベースを用いてX線写真の診断結果と粒状影の個数・大きさ・重症度別に解析・比較・評価・診断支援システムの開発を行う。

2. 撮影条件と手法

岡山ろうさい病院で診断されたじん肺25症例(0/1 - 5例, 1/0 - 5例, 1/1 - 5例, 1/2 - 5例, 2/2 - 5例)を用いて解析を行った。撮影条件を表1に示す。これらのCT画像に(1)じん肺CT画像データベースの作成, (2)粒状影の定量評価を適用した。

*1 徳島大学大学院先端技術科学教育部
〔〒770-8502 徳島県徳島市南常三島町2-1〕
e-mail: c501938019@tokushima-u.ac.jp

*2 徳島大学大学院社会産業理工学研究部

*3 川崎医科大学

*4 岡山ろうさい病院

*5 長崎大学

表 1 撮影条件

装置	Aquilion PRIME
管電圧[kV]	120
管電流[mA]	240
スライス厚[mm]	1.0
画素間隔[mm]	0.625, 0.781
再構成間隔[mm]	1.0
再構成関数	FC13-H,FC52

(1) じん肺 CT 画像データベースの作成

(1) - (a) 粒状影のマニュアル抽出

WL500, WW1500 で設定し, Axial 面を用いて右肺尖部, 右肺底部, 左肺尖部, 左肺底部の順で抽出する. 抽出は 2 回行い 1 回目と 2 回目の読影間隔は半年以上と 1 週間を置いた. 1 回目と 2 回目の論理和をマニュアル抽出結果とする.

(1) - (b) CAD を用いた結節の自動抽出

本研究室で開発されている CAD の結節自動抽出結果とマニュアル抽出結果を重ね合わせ新たに見直し, 未抽出の粒状影があればじん肺 CT 画像データベースに追加する.

(2) 粒状影の定量評価

じん肺の重症度を粒状影の個数, 大きさと CT 値, 分布型によって評価する. 粒状影の大きさは, 粒状影が球であると仮定して, 体積から求められる直径と定義する. 病型区分の分類に必要な粒状影の大きさと分類数の検討をするために各大きさ別の粒状影数でクラスタリングを行い, クラス数を求める.

3. 結果

第 0 型 0/1 と第 1 型 1/0 の粒状影の抽出結果例を図 1 に示す. 粒状影数を見ると診断結果と一致しない症例があった. 図 2 に粒状影の直径と累積頻度の関係を示す. 重症度に関わらず直径 3mm 以上の粒状影では指数関数的に数が増

加しているが 3mm 以下になると緩やかになる傾向が見られた.

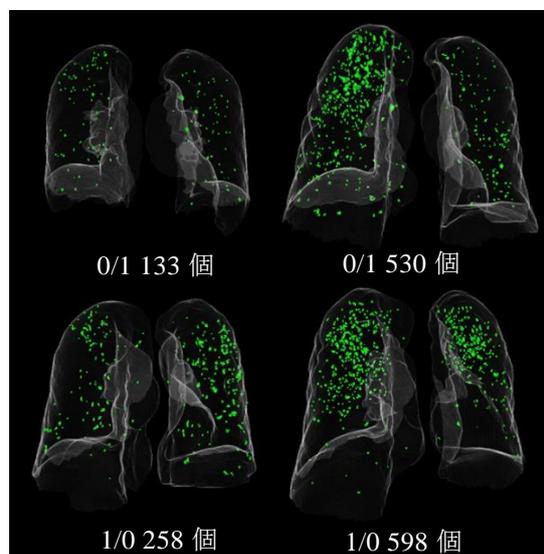


図 1 粒状影の抽出結果

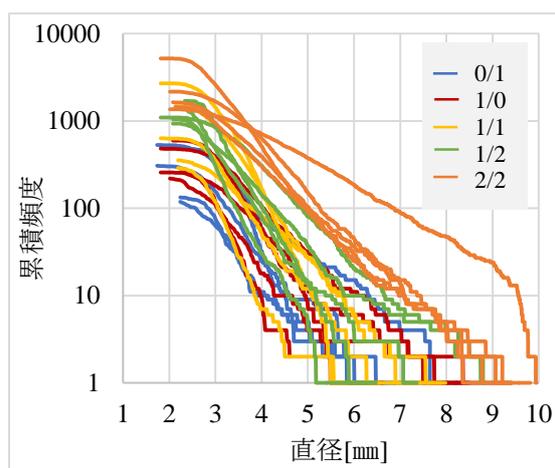


図 2 粒状影の直径と累積頻度

次に, 大きさ別における粒状影数を用いてクラスタリングを行った. 分類結果を X 線写真の重症度分類と比較すると, 3mm 以上では十分に分類できず, 2.5mm 以上の微小な粒状影の検出が必要である. また, CT 分類後の粒状影大きさ別平均 CT 値と, 部位別における粒状影の大きさと個数の関係をそれぞれ図 3, 4 に示す. 2-5mm の粒状影は, 同じ大きさでも分類別に CT 値の差があった. 肺の部位別における粒状影の個数と大きさの関係では 25 症例中 18 症例が上部に粒状影のある割合が高く, 左肺より右肺のほうが多い傾向が見られた.

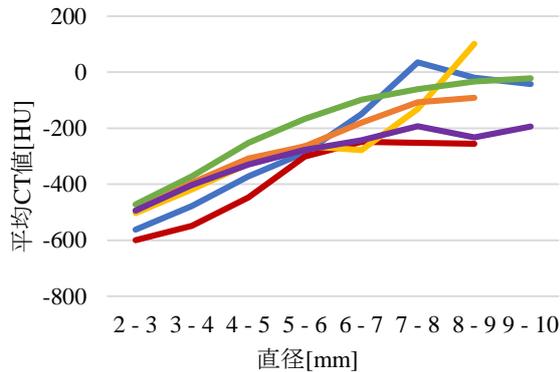


図3 CT分類後における粒状影の大きさと平均CT値の関係

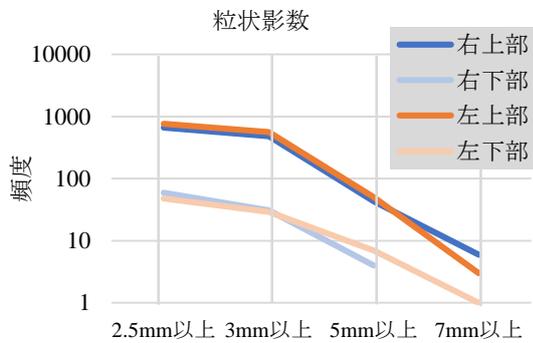


図4 肺の部位別における粒状影の個数と大きさの関係

4. まとめ

じん肺 CT 画像からデータベースを作成し、粒状影の個数、大きさと CT 値、分布型からじん肺の重症度を定量評価し、X 線写真の診断結果と比較・評価した。今後の課題として多症例の粒状影を統計解析し、高精度なじん肺診断支援システムの開発を目指す。

利益相反の有無

なし

文 献

- [1] H. Suzuki, Y. Kawata, N. Niki, et al: Computer aided diagnosis for severity assessment of pneumoconiosis using CT images, Proc. SPIE Medical Imaging, Vol.9785, pp.978531-1-6, 2016.
- [2] K. Kanazawa, Y. Kawata, N. Niki, et al: Computer-aided diagnosis for pulmonary nodules based on helical CT images, Comput. Med. Imag. Graphics, vol. 22, no. 2, pp. 157-167, 1998.
- [3] Y. Kawata, N. Niki, H. Ohmatsu, et al: Quantitative classification based on CT histogram analysis of non-small cell lung cancer: Correlation with histopathological characteristics and recurrence-free survival, Medical Physics, vol.39, no.2, pp.988-1000, 2012.
- [4] 松廣幹雄, 鈴木秀宣, 河田佳樹, 他: 胸部マルチスライス CT 画像における葉間裂抽出法, 電子情報通信学会論文誌, Vol.J.96-D, no.4, pp.834-843, April, 2013.
- [5] 滝島任, 中村雅夫, 千代谷慶三: じん肺患者の呼吸機能検査ハンドブック. 真興交易医書出版部, 1991, P3-10
- [6] 永井厚志編: 呼吸器疾患 第3版. 日本医事新報社, 2015, P241-250
- [7] K. Hino, M. Matsuhiro, H. Suzuki, et al: Quantitative assessment for pneumoconiosis severity diagnosis using 3D CT images, Proc. SPIE Medical Imaging, Vol.10575, pp.105753J-1-6, 2018.
- [8] 日野公貴, 松廣幹雄, 鈴木秀宣, 他: 胸部 3 次元 CT 画像を用いたじん肺の重症度診断基準に関する粒状影の定量的評価, 電子情報通信学会技術研究報告医用画像, Vol.118, No.286, pp.13-15, 2018.11

A Computer Aided Diagnosis system for pneumoconiosis severity using 3D CT images

Nana Mori^{*1}, Koki Hino^{*1}, Mikio Matsuhiro^{*2}, Hidenobu Suzuki^{*2}, Yoshiki Kawata^{*2}, Noboru Niki^{*2}
Katsuya Kato^{*3}, Takumi Kishimoto^{*4}, Kazuto Ashizawa^{*5}

*1 System Innovation Engineering Graduate School of Advanced Technology and
Science The University of Tokushima

*2 Tokushima University

*3 Kawasaki Medical School

*4 Okayama Rosai Hospital

*5 Nagasaki University

Pneumoconiosis is an occupational respiratory illness that occur by inhaling dust to the lungs. 240,000 participants are screened for diagnosis of pneumoconiosis every year in Japan. Radiograph is used for staging of severity rate in pneumoconiosis worldwide. CT imaging is useful for the differentiation of requirements for industrial accident approval because it can detect small lesions in comparison with radiograph. In this paper, we extracted lung nodules from 3D pneumoconiosis CT images by two manual processes and automatic process, and created a database of pneumoconiosis CT images. We used the database to analyze, compare, and evaluate visual diagnostic results of radiographs and quantitative assessment (number, size and volume) of lung nodules. This method was applied to 25 pneumoconiosis patients. Initial results showed that the proposed method can assess severity rate in pneumoconiosis quantitatively. And we analyzed the CT values and the distribution types of result. This study demonstrates effectiveness on diagnosis and prognosis of pneumoconiosis in CT screening. .

Key words: X-ray image, CT, Medical image processing

Generative adversarial network を用いた肺結節の 3 次元 CT

画像の生成

西尾瑞穂^{*1,2} 野口峻二郎³ 尾上宏治² 子安翔² 八上全弘^{1,2}

村松千左子⁴ 藤田広志⁴ 富樫かおり²

要旨

GAN による肺結節の 3 次元 CT 画像の生成を行い、放射線科医による評価を行った。LUNA16 のデータセットの 888 セットの 3 次元 CT 画像、1415 個の肺結節を用いて、GAN の学習データとした。トレーニングには 1281 個、テストには 134 個の肺結節を利用し、L1 loss と GAN loss を混合したものを最適化のためのロスとした。学習時には random erasing をベースにした data augmentation を行った。テスト用の 134 個の肺結節につき、ランダムに真の肺結節と生成された肺結節を提示し、二名の放射線科医が評価した。放射線科医には真の肺結節である確信度を入力させた。放射線科医の AUC は 0.705 と 0.891 であった。正診率は 71.6% と 81.3%、感度は 71.0% と 78.3%、特異度は 72.3% と 84.6% であった。GAN により真偽の判断が難しい肺結節画像を生成できる可能性が示された。

キーワード：肺結節，CT，深層学習，敵対的生成ネットワーク

1. はじめに

近年、画像認識などで深層学習がめざましい成果をあげており、深層学習の医療への応用にも期待が寄せられている。一般に医用画像の診断支援には高度な画像認識が必要であり、深層学習は医用画像の診断支援の医療機器開発に効果が高いと期待されている。しかしながら、

深層学習が効果を発揮するためには大量の学習データが必要であり、医用画像では個人情報保護や画像収集コストが高いことなどから大量の学習データを用意することは容易ではない。そこで、Modeling/Simulation 技術を用いて擬似の医用画像を生成し、それを医療機器開発に活用するという方法が考えられる。

論文 [1] によると、米国の Food and Drug Administration は医療機器開発において治験のような randomized controlled trial は必ずしも必要ないと考えているとのことである。論文 [1] では医療機器開発に randomized controlled trials が不必要な場合、これに代わるものとして Modeling/Simulation 技術の活用が期待されており、擬似の医用画像の生成にはこうした活用が期待できる。

敵対的生成ネットワーク (generative adversarial network, GAN) は深層学習による画像生成の手法で [2]、過去 10 年で最も興味深い

1 京都大学附属病院 先制医療・生活習慣病研究センター

2 京都大学大学院医学研究科 放射線医学講座 (画像診断学・核医学)

3 大阪赤十字病院 放射線診断科

4 岐阜大学工学部電気電子・情報工学科

* 責任著者：西尾瑞穂. 〒606-8507 京都市左京区聖護院川原町 53 . jurader@yahoo.co.jp

アイデアの機械学習の手法と評されることがある。オリジナルの GAN は画像を生成する Generator と生成画像と実画像とを鑑別する Discriminator の二つから構成される。Generator は任意の乱数データから Discriminator を騙す画像を生成するように学習を行い、Discriminator は実画像と Generator による生成画像とを鑑別できるように学習を行う。

本研究の目的は GAN を用いて肺結節の 3D の CT 画像の生成を行うことである。将来的には生成画像が医療機器開発に有用かどうかを検討する予定であるが、本研究では GAN で生成された擬似肺結節の病変としての妥当性を検証することを主目的とする。

2. 方法

本研究は既存の公開済みデータベースを用いた研究であり、日本の人を対象とする医学系研究に関する倫理指針に従えば指針の対象外となる。

本研究では LUNA16 [3] のデータセットに含まれる 888 セットの 3 次元 CT 画像、1415 個の肺結節を用い、このうちトレーニングに 1281 個

の肺結節、テストに 134 個の肺結節を利用した。個々の肺結節に対し 40x40x40 voxels の volume of interest をセットして CT 画像を切り出し、その CT 値を 1000 で除算して正規化を行った。変更した 3 次元 Resnet を generator, 変更した 3 次元 VGG を discriminator とし、GAN を構成した [4] [5]。これは pix2pix のネットワークの 3D 版に相当するものである [4] [5]。L1 loss と GAN loss を混合したものをネットワークの最適化のためのロスとした。

学習時には random erasing をベースにした data augmentation を行った [4] [6]。図 1 にその例を示す。本研究では GAN の学習の際には、真の肺結節の画像の結節部分に対して random erasing に相当する処理を行い、その画像を用いて GAN による肺結節の生成を行った。

テスト用の 134 個の肺結節につき、ランダムに真の肺結節と生成された擬似の肺結節を提示し、二名の放射線科医が評価した。放射線科医には真の肺結節である確信度を入力させ、それを用いて ROC 解析による Area under the curve (AUC) を計算した。

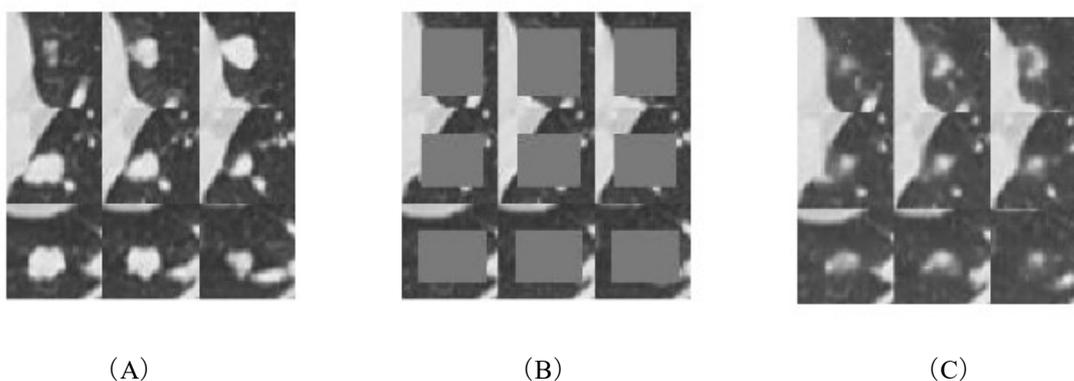


図 1 真の肺結節の画像，GAN の入力に使われた画像，生成された肺結節の画像。

(A)(B)(C)はそれぞれ真の肺結節の画像，GAN の入力に使われた画像，生成された肺結節の画像である。(A)(B)(C) の上段・中段・下段は同一の肺結節の横断像，冠状断像，矢状断像の 3 スライス画像である。(B)は，(A)から random erasing に相当する処理を行い，肺結節の全体もしくは一部を削除したものである。GAN は(B)から(C)を生成する。(A)と(C)との間で，L1 loss と GAN loss を混合したものを低減するように GAN の学習が行われる。

3. 結果

肺結節を評価した二名の放射線科医の AUC は 0.705 と 0.891 であった。正診率は 71.6% と 81.3%，感度は 71.0% と 78.3%，特異度は 72.3% と 84.6% であった。ここで，感度は放射線科医が真の肺結節を真の肺結節と評価した割合，特異度は擬似肺結節を擬似肺結節と評価した割合とした。生成された擬似結節の画像を図 2，3 に示す。

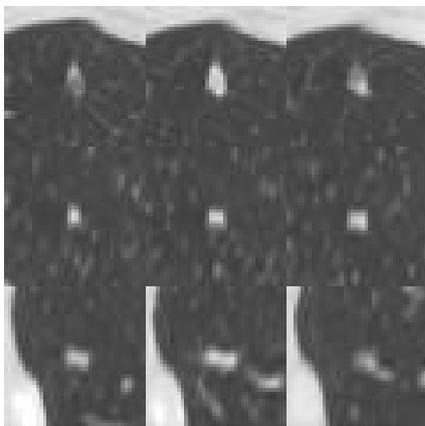


図 2 放射線科医が真の肺結節と評価した擬似結節

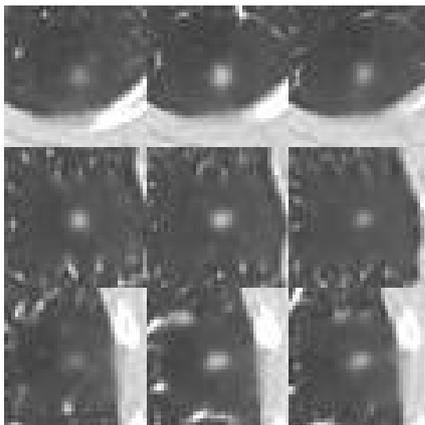


図 3 放射線科医が容易に擬似結節と評価した擬似結節

4. まとめ

GAN によって，放射線科医による真偽の判断が難しい肺結節の 3 次元 CT 画像の肺結節を生成できる可能性が示された。

謝辞

本研究は JSPS 科研費 JP19H03599 の助成を受けたものです。

利益相反の有無

なし。

文 献

- [1] Faris O, Shuren J. An FDA Viewpoint on Unique Considerations for Medical-Device Clinical Trials. *N Engl J Med.* 2017 Apr 6;376(14):1350-1357.
- [2] Salimans T, Goodfellow I, Zaremba W, Cheung V, Radford A, Chen X. Improved Techniques for Training GAN. arXiv:1606.03498
- [3] LUNA16. <https://luna16.grand-challenge.org/>
- [4] Jin D, Xu Z, Tang Y, Harrison AP, Mollura DJ. CT-Realistic Lung Nodule Simulation from 3D Conditional Generative Adversarial Networks for Robust Lung Segmentation. arXiv:1806.04051
- [5] Isola P, Zhu JY, Zhou T, Efros AA. Image-to-Image Translation with Conditional Adversarial Networks. arXiv:1611.07004
- [6] Zhong Z, Zheng L, Kang G, Li S, Yang Y. Random Erasing Data Augmentation. arXiv:1708.04896

Generation of 3D CT images of lung nodule using generative adversarial network

Mizuho Nishio^{*1,2}, Shunjiro Noguchi³, Koji Onoue², Sho Koyasu², Masahiro Yakami^{1,2}, Chisako Muramatsu⁴, Hiroshi Fujita⁴, Kaori Tokashi²

1 Preemptive Medicine and Lifestyle-related Disease Research Center, Kyoto University Hospital

2 Department of Diagnostic Imaging and Nuclear Medicine, Kyoto University Graduate School of Medicine

3 Department of Radiology, Osaka Red Cross Hospital

4 Department of Electrical, Electronic and Computer Engineering, Faculty of Engineering, Gifu University

* Corresponding author

Generation of 3D CT images of lung nodule was performed using generative adversarial network (GAN), and the generated images were evaluated by radiologists. 1415 lung nodule depicted on 888 sets of 3D CT images were used, which were obtained from LUNA16. Mixture of L1 loss and GAN loss were utilized for optimization target of GAN network. Data augmentation based on random erasing was performed during training of GAN. For test set of 134 lung nodules, either true lung nodule or generated nodule were given to two radiologists, then the two radiologists recorded their confidence score of being true nodule. Receiver operator characteristics analysis was performed, and area under the curve (AUC) was calculated. AUC of the two radiologists was 0.705 and 0.891, respectively. Accuracy, sensitivity, and specificity of the two radiologists were as follows: accuracy, 71.6% and 81.3%; sensitivity, 71.0% and 78.3%; specificity, 72.3% and 84.6%. These results indicate that it might be possible to generate lung nodules which were difficult for radiologists to judge whether the lung nodules are true nodules or not.

Key words: lung nodule, CT, deep learning, generative adversarial network

眼底画像における OCT 検査結果を用いた CNN による 網膜神経線維層欠損解析

渡邊 颯友*¹ 村松 千左子*² 周 向栄*³ 畑中 裕司*⁴

原 武史*³ 藤田 広志*³

要旨

緑内障は日本における中途失明原因の第 1 位とされており、40 歳以上の 20 人に 1 人が緑内障と推定されている。しかし、早期の緑内障は自覚症状が非常に少ないため、早期発見のためには定期検査が必要である。定期検査の中でも特に眼底検査では、緑内障診断の指標の一つとして網膜神経線維層 (RNFL) 欠損の有無を調べる。また、OCT 検査は精密検査であり、網膜神経線維層の厚みを定量する。しかし、定期検査においては一般的に OCT 検査ではなく眼底検査が行われる。そこで、我々は同時期に得られた眼底画像と OCT 検査結果をそれぞれ学習データ、教師データとして全量込みニューラルネットワークの学習を行い、眼底画像単体から RNFL が薄い領域を特定するコンピュータ支援診断システムを構築した。評価方法は、視神経乳頭中心部から眼底画像を 8 方向に分割し、各領域の一致率を調べた。結果として、眼底画像単体から OCT 検査結果を用いて RNFL を解析することに成功した。

キーワード：緑内障，網膜神経線維層欠損 (NFLD)，眼底画像，OCT

1. はじめに

緑内障は日本における中途失明原因の第 1 位とされており、40 歳以上の 20 人に 1 人が緑内障と推定されている[1]。しかし、早期の緑内障は自覚症状が非常に少ないため、早期発見のためには定期検査が必要である。定期検査の中でも特に眼底検査では、緑内障診断の指標の一つ

として網膜神経線維層欠損 (NFLD) の有無を調べる。NFLD は、最も早期に生じる緑内障性眼底変化であり、網膜神経線維層 (NFL) への障害が厚みの減少として現れる[2]。また、OCT 検査は精密検査であり、網膜神経線維層の厚みを定量する。しかし、定期検査においては一般的に OCT 検査ではなく眼底検査が行われる。そのため、定期検査において、眼底画像を用いて OCT 検査のような精度の高い検査を行うことができれば、緑内障の早期発見に有益となる。

本研究では、同時期に得られた眼底画像と OCT 検査結果を組み合わせることで深層学習を行い、眼底画像上で NFLD を解析することによって、眼底画像単体における NFLD の診断精度向上を目指した。

*1 岐阜大学大学院自然科学技術研究科
知能理工学専攻

〔〒501-1193 岐阜市柳戸 1-1〕

e-mail: naberyu@fjt.info.gifu-u.ac.jp

*2 滋賀大学データサイエンス学部

*3 岐阜大学工学部電気電子・情報工学科

*4 滋賀県立大学工学部電子システム工
学科

投稿受付：2019 年 3 月 29 日

2. 方法

最初に、眼底画像(図 1)と OCT 眼底画像(図 2)から血管画像を作成した。まず、眼底画像の緑色(G)成分に対して、ブラックトップハット変換を行うことで、血管領域を抽出し、眼底血管画像(図 3)を作成した。また、眼底血管画像を用いて血管消去画像(図 4)を作成した。同様に OCT 眼底画像に対してもブラックトップハット変換を行うことで、血管領域を抽出し、OCT 血管画像(図 5)を作成した。

次に、作成した血管画像と OCT 血管画像は、モダリティが異なるため、位置合わせを行った。まず、血管画像と OCT 血管画像の抽出結果は、視神経乳頭部分で大きく異なるため、OCT 厚みマップに示される DISC 領域を用いて、OCT 血管画像から視神経乳頭部分を削除した。その後、眼底血管画像上の視神経乳頭部分を中心とした 220×220 のテンプレートを作成し、OCT 血管画像上でテンプレートマッチングを行うことで、位置合わせを行った。位置合わせの際は、x, y 軸に対して平行移動、回転、拡大・縮小のずれが見られたため、x 軸($-25 \leq x \leq 25$, 1 ピクセルずつ)、y 軸($-25 \leq y \leq 25$, 1 ピクセルずつ)、回転(± 8 度, 2 度ずつ)、拡大縮小(75~100%, 5% ずつ)の範囲で画像に変化を加えて位置合わせを行った。また、時間短縮のために、血管画像と OCT 血管画像は半分の大きさにリサイズした後位置合わせを行い、評価値には SAD を用いた。

血管画像の位置合わせに用いた値をもとに、眼底画像と OCT カラーマップ(図 6)に対しても同様に位置合わせを行った。その後、位置合わせを行った OCT カラーマップから、RNFL 厚がデータベース平均と比較して小さい領域(赤色領域)とやや小さい領域(黄色領域)を抽出し、教師画像を作成した。

そして、眼底画像を学習画像とし、ペアとなる教師画像とを FCN に入力し、深層学習を行った。データ拡張には、 γ 変換と左右反転を使用し、学習回数は 40epochs とした。最後に、出力画像にラベリングを行い、面積の小さい NFLD 候補領域に対して閾値処理を行う

ことで、候補領域の削除を行った。

評価方法は、全 133 症例のうち、データセット 1, データセット 2, データセット 3 を 27 症例とし、データセット 4, データセット 5 を 26 症例として、5 分割交差検証を行った。結果画像の評価では、視神経乳頭を中心として、教師画像を 8 方向に分割し、各方向の不正解数、一致率、真陰性率を評価に用いた。

本研究は岐阜大学の倫理審査委員会の承認を得ている。



図 1 眼底画像

図 2 OCT 眼底画像

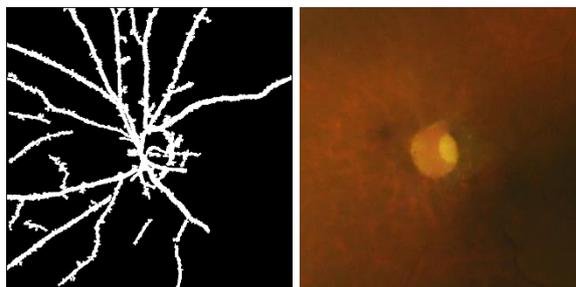


図 3 眼底血管画像

図 4 血管消去画像

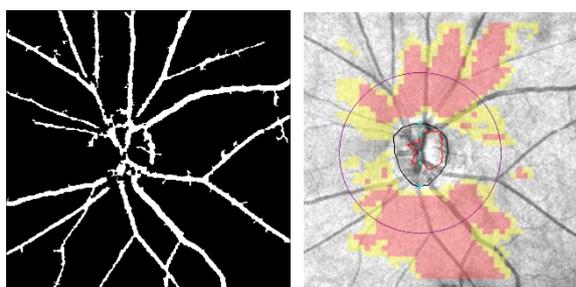


図 5 OCT 血管画像 図 6 OCT カラーマップ

3. 結果

5 つのデータセットの平均は、1 症例当たりの不正解数は 1.79(方向)、正解率は 40%、真陰性率は 70%となった。

4. 考察

OCT 検査結果は詳細な情報を含んでおり、その情報を使用することにより、眼底画像上で NFLD 領域を解析することができたが、一致率が 50%に満たない領域が多く存在した。これは学習画像、教師画像共に NFL 厚が減少している領域の境界線が曖昧であることが原因の一つであると考えられる。そのため、今後は一致率に加え類似度などを考慮した学習方法を検討する必要があると考える。

5. まとめ

眼底画像と OCT 検査結果を組み合わせた学習を行うことで、眼底画像上で RNFL を解析することに成功した。

謝辞

本研究の一部はマツダ財団による研究助成と文部科学省科学研究費補助金(新学術領域)(No. 26108005)により行われました

利益相反の有無

なし

文献

- [1] Yamamoto T, Iwase A, Araie M, et al.: The Tajimi study report 2: prevalence of primary angle closure and secondary glaucoma in a Japanese population. *Ophthalmology* **112**: 1661-1669, 2005
- [2] 井上洋一：どう診る？緑内障視神経乳頭, メジカルビュー社, 東京, 2006, pp80-93

Analysis of nerve fiber layer defects on fundus images using CNN trained with OCT data

Ryusuke WATANABE^{*1}, Chisako MURAMATSU^{*2}, Xiangrong ZHOU^{*3}, Yuji HATANAKA^{*4}, Takeshi HARA^{*3},
Hiroshi FUJITA^{*3}

^{*1} Department of Intelligence Science and Engineering, Graduate School of
Natural Science and Technology, Gifu University

^{*2} Department of Data Science, Shiga University

^{*3} Department of Electrical, Electronic and Computer Engineering, Gifu
University

^{*4} School of Engineering, The University of Shiga Prefecture

Glaucoma is the first leading cause of blindness in Japan. However, glaucoma only has a few warning signs or symptoms. Thus, screening is important to detect glaucoma in early stages. Fundus examination, in which fundus photographs are used, is one of the screening methods for the detection of nerve fiber layer defect (NFLD). In contrast, optic coherence tomography (OCT) examination is not a screening, but a complete check-up, in which the thickness of the whole retina as well as the thickness of the retinal nerve fiber layer is measured. Therefore, we investigated the learning system using both a fundus photograph and OCT examination result to perform a better analysis on fundus examination using the fundus alone. A convolutional neural network (CNN) with deconvolutional layers was trained to detect regions with decreased NFL. As to the evaluation, we divided the output image of CNN into eight segments around the optic nerve head. In each segment, the detected region was considered as a true positive if more than half of the region was overlapped with the gold standard regions. As a result, we could analyze NFL on fundus images using CNN trained with OCT data.

Key words: Glaucoma, Nerve Fiber Layer defect (NFLD), Fundus Image, OCT

小児腸閉塞患者の CT 像における CycleGAN を用いた電子洗浄手法の検討

西尾 光平*¹ 小田 紘久*¹ 千馬 耕亮*² 北坂 孝幸*³

伊東 隼人*¹ 小田 昌宏*¹

檜 顕成*² 内田 広夫*² 森 健策*^{1,4,5}

要旨

本研究では、小児腸閉塞患者の CT 像における、CycleGAN を用いた電子洗浄手法を提案する。これまでの腸管閉塞部位検出手法は造影されていない残渣を含んだ腸管を対象としており、残渣と濃度値の類似した腹水などを誤抽出する場合があった。そこで、腸管内の濃度値を空気と同程度に変換し、残渣が含まれていない CT 像の生成（電子洗浄）を目指す。多くの電子洗浄手法は残渣が造影された CT 像に対する手法であり、血液の造影のみである小児腸閉塞患者の CT 像に適用することは困難である。そこで、本研究では CycleGAN を用いた電子洗浄手法について検討する。残渣の多い小児腸閉塞患者の CT 像と残渣の少ない大腸 CT 検査画像を学習データとして、CycleGAN による双方向それぞれの画像生成モデルを学習する。その後、残渣の多い画像から残渣の少ない画像への生成モデルを小児腸閉塞患者の CT 像に適用する。実験の結果、小児腸閉塞患者の CT 像から残渣の少ない CT 像を得ることができた。

キーワード：Computer-Aided Detection (CADe), 腸閉塞, 電子洗浄, 小児外科

1. はじめに

腸閉塞（イレウス）患者の約 5 分の 1 は、放置すると腸管壊死等の重篤な状態を引き起こすため、緊急手術が行われる [1]。手術が必要か否かの判断には、腹部 CT 像において拡張した腸管を辿り、閉塞部位の位置や状態を確認する必要がある。これは、救急医などイレウス診

断の経験の浅い医師には容易でなく、自動で閉塞部位を検出し、診断を支援するシステムが求められる。

イレウス診断では、血管造影 CT 像により腸壁を造影することで、拡張した腸管を辿ることを容易にしている（図 1 参照）。従来研究では、この腸壁が造影されていることに着目し、拡張した腸管を抽出し探索することにより腸管閉塞部位の検出を行った [2]。しかし、とりわけ小腸では、腸管内に含まれる残渣が腹水等と濃度値の差が小さいことや、腸管は複雑に折り重なっており、精度が低下する問題があった。そこで本研究では、抽出が困難である残渣を電子的に洗浄し、残渣が含まれていない CT 像を生成することで腸管閉塞部位検出の精度向上を

*1 名古屋大学大学院情報学研究科
〔〒464-8601 名古屋市千種区不老町〕
e-mail: knishio@mori.m.is.nagoya-u.ac.jp

*2 名古屋大学大学院医学系研究科

*3 愛知工業大学情報科学部

*4 名古屋大学情報基盤センター

*5 国立情報学研究所医療ビッグデータ
研究センター

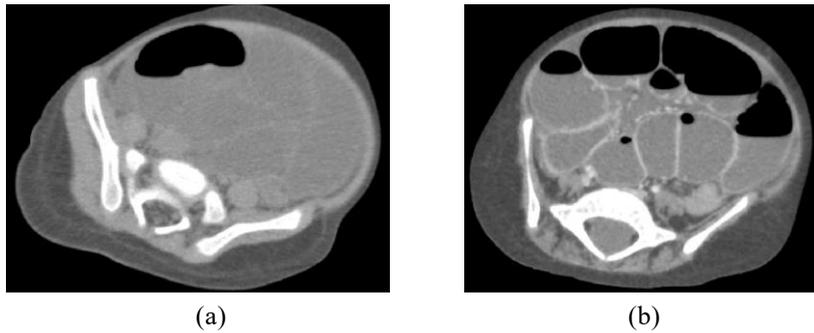


図1 血管造影 CT 像の例. (a) 腸壁の判別が困難な例. (b) 腸壁の判別が容易な例

目指す. 多くの電子洗浄手法は残渣が造影された CT 像に対する手法であり, 小児腸閉塞患者の CT 像に適用することが困難である. そこで, 本研究では CycleGAN [3]を用いた電子洗浄手法について検討する.

2. 手法

本手法は, 残渣を含む小児腸閉塞患者の CT 像と残渣を含まない大腸 CT 検査画像を学習データとし, CycleGAN による双方向それぞれの画像生成モデルを学習する. 得られた残渣を含む CT 像から残渣を含まない CT 像を生成するモデルにより残渣を電子的に洗浄する. 手法の概要図を図 2 に示す. 2つの生成器 G, F はそれぞれ, 残渣を含む画像から残渣を含まない画像に変換する生成器(G)とその逆の残渣を含まない画像から残渣を含む画像へ変換する生成器(F)である. また, 2つの識別器 D_X, D_Y はそれぞれ, 変換前の画像と生成画像を識別する識別器である. 識別器 D_Y 残渣を含まない変換前の画

像と残渣を含む画像から G によって生成された画像を正しく識別するようにモデルを学習するのにに対し, 生成器 G は変換前の画像と識別できない画像を生成するようにモデルを学習する. 識別器 D_X , 生成器 F も同様にモデルを学習する. さらに, 変換前の画像と対応した画像を生成するため, サイクル一貫性を利用する. 生成器 G により生成した画像から生成器 F を用い生成した画像は元の画像と一致していることが望ましい. その逆のサイクルを含め,

$$\begin{aligned} \mathcal{L}_{\text{cyc}} = & \mathbb{E}_{x \sim P(x)} [\|F(G(x)) - x\|_1] \\ & + \mathbb{E}_{y \sim P(y)} [\|G(F(y)) - y\|_1] \end{aligned} \quad (1)$$

を最小化するようにモデルを学習する.

学習に用いる残渣を含む画像は, それぞれ小児腸閉塞患者の血管造影 CT 像から残渣を含む腸管がパッチ内に 10%以上含まれるパッチを Axial 平面から切り出し, 使用する. 同様に, 残渣を含まない画像は, 成人の大腸 CT 検査画像から残渣を含まない腸管パッチ内に 10%以上含まれるパッチを Axial 平面上で $-60 \sim 60$ 度の回転をランダムに行い, パッチを切り取る.

3. 実験と結果

小児腸閉塞患者の血管造影 CT 像 7 症例, 成人の大腸 CT 検査画像 8 症例を用い, 実験を行った. CT 像の仕様は, 画像サイズ $512 \times 512 \times (257-701)$ 画素, ピクセルサイズ $0.39-0.63$ mm, スライス間隔 $0.40-1.00$ mm であった. それぞれ 2 症例ずつをテストデータ, それ以外の症例を学習データとする. パッチサイズを 128×128 画素 (残渣を含む腸管のパッチ: 2464 枚, 残渣を含まない腸管のパッチ: 2385 枚), $\lambda=5$ とし,

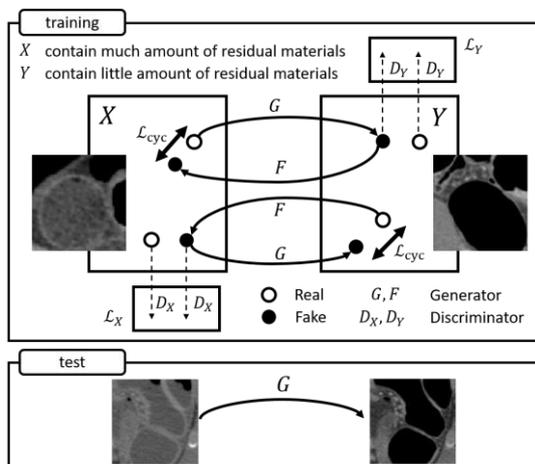


図2 手法の概要図

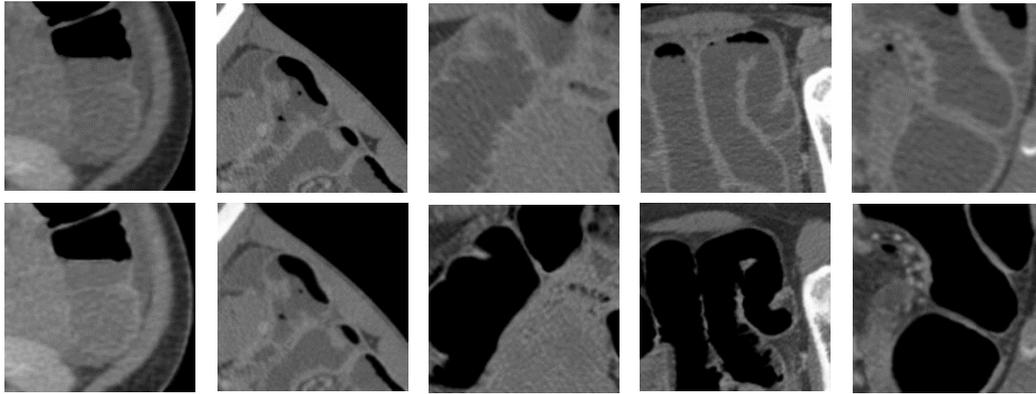


図3 パッチごとの結果例. 上: 変換前の画像. 下: 生成画像

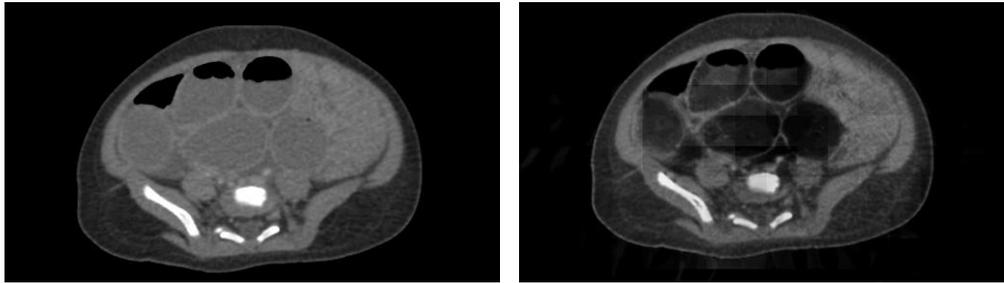


図4 スライスの結果例. 左: 変換前の画像. 右: 生成画像

200epoch モデルの学習を行った。学習後，小児腸閉塞 CT 像のテストデータからランダムで切り出したパッチに対し，残渣を含む画像から残渣を含まない画像へ変換する生成器 G を適用し生成した画像の例を図3に示す。また，スライスから 64 画素間隔でパッチを切り出し，生成器 G を適用し生成した結果を組み合わせる結果のスライスを作成した(図4)。生成した結果が重なっている部分は平均値とした。

4. 考察

提案する CycleGAN を用いた電子洗浄手法により，造影されていない残渣を含む CT 像から残渣を含まない CT 像を生成することが可能であった。また，残渣を含まない CT 像を生成することで腸管閉塞部位検出の精度向上に対しても有用であると考えられる。しかし，腸管が大きく拡張していない，一部の腸管しか写っていないなど残渣を含む腸管が小さく写る画像において，残渣を含まない画像の生成に失敗することを確認した。そのため，パッチの切り出す部分により残渣が残り，図4で示すように残渣を完全に消すことが出来なかったと考えられる。

5. むすび

本稿では，CycleGAN による造影されていない残渣を含む CT 像からの電子洗浄手法を提案した。小児腸閉塞患者の CT 像から残渣の少ない良好な CT 像を得ることができた。今後，電子洗浄の精度向上を図るとともに，腸管閉塞部位検出精度の比較により定量評価を行うことを考えている。

謝辞 本研究の一部は堀科学芸術振興財団，JSPS/MEXT 科研費 (26108006, 17H00867, 17K20099), AMED-NII (19lk1010036h0001) ならびに JSPS 二国間交流事業によった。

利益相反の有無 なし

文献

- [1] 加藤治文 他編 : 標準外科学第13版. 医学書院, 2013
- [2] 西尾光平 他 : Fast Marching Algorithm に基づく小児 CT 像からの腸管閉塞部位検出手法. 第37回日本医用画像工学会大会: 90-92, 2018
- [3] Zhu J, Park T, Isola P, Efros A: Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks. ICCV: 2223-2232, 2017

A Study on Electronic Cleansing using CycleGAN on CT Volumes of Pediatric Ileus Patients

Kohei NISHIO ^{*1}, Hirohisa ODA ^{*1}, Kosuke CHIBA ^{*2}, Takayuki KITASAKA ^{*3},
Hayato ITOH ^{*1}, Masahiro ODA ^{*1}, Akinari HINOKI ^{*2}, Hiroo UCHIDA ^{*2}, Kensaku MORI ^{*1,4,5}

*1 Graduate School of Informatics, Nagoya University

*2 Nagoya University Graduate School of Medicine

*3 School of Information Science, Aichi Institute of Technology

*4 Information Technology Center, Nagoya University

*5 Research Center for Medical Bigdata, National Institute of Informatics

In this paper, we propose electronic cleansing on CT volumes of pediatric intestine obstruction patients that blood-vessels are contrast enhanced. Our previous obstruction detection method was designed to process intestines that contain non-contrast-enhanced residual materials. This method segments regions of outside intestines, e.g. abdominal dropsy, which have similar intensities residual materials. We replace intensities of voxels inside the intestines by those of the air to generate CT volumes that do not contain residual materials. Since intestines that contain non-contrast-enhanced residual materials, conventional electronic cleansing methods cannot be applied. Therefore, we introduce CycleGAN for electronic cleansing. We produce bidirectional image translation models between 1) pediatric CT volumes of ileus patients that contain much amount of residual materials, and 2) CT volumes for CT colonography that contain little amount of residual materials. Using the models, 1) the pediatric CT volumes are converted as if 2) CT volumes for CT colonography. Experimental results showed that CT volumes that contain less amount of residual materials were obtained from pediatric CT volumes.

Keywords: Computer-Aided Detection (CADe), Ileus, Electronic cleaning, Pediatric surgery

低線量 CT 画像に基づいた骨ミネラル量の推定法

山田 凌大^{*1} 石原 匡彦^{*2} 原 武史^{*1} 周 向栄^{*1}

片渕 哲朗^{*3} 藤田 広志^{*1}

要旨

核医学画像の定量解析の中で、骨に集積する放射性薬剤の SUV の計算では、全身の骨ミネラル量の測定が重要である。本研究は、低線量 CT 画像を用いた骨ミネラル量の推定法の開発を目的とした。等方化した CT 画像に閾値処理や空間フィルタを利用し、骨格抽出を行う。骨格の MIP 画像を基に骨面積を定める。骨面積に骨密度を乗じた値を骨ミネラル量の推定値とする。日本人健常者 2411 人に対し行われた体組成計測における DXA の測定データにより、全身の骨ミネラル量の回帰式が定められている。この回帰式から算出される症例の全身の骨ミネラル量と、107 症例の CT 画像に基づき推定した胸部骨ミネラル量の相関係数は 0.86 であった。また、骨格を解剖学的構造に基づいて分類し、部位ごとの骨ミネラル量の推定も可能である。以上より、CT 画像に基づく骨ミネラル量の定量解析の有用性が示唆された。

キーワード：骨ミネラル量，低線量 CT 画像

1. はじめに

PET 検査や SPECT 検査といった核医学検査は悪性腫瘍の診断に用いられている。放射性薬剤の集積程度の判定量的指標として Standardized Uptake Value(SUV)が扱われている。SUV は、患者の単位体重あたりの薬剤投与量に対する組織の薬剤集積量の比で表される。SUV を骨のみに適用することを考えると、このときの SUV は、単位骨量(骨ミネラル量)あたりの薬剤投与量に対する骨組織の薬剤集積量の比となる。骨についての SUV の計算には骨ミネラル量の測定が重要となる。

本研究では、PET/CT 検査で撮像された低線量 CT 画像 107 症例から骨格を抽出し、骨ミネラル量を推定する方法の開発を目指した。

2. 方法

等方ボクセル化した CT 画像から、閾値処理やラプラシアンフィルタにより骨格を抽出する。また、解剖学的構造に基づき、細線化処理等を用いて、骨格を頭部、脊柱、腕部、骨盤、脚部に分類する[1]。骨格の MIP 画像を作成し、骨面積を定める。骨面積に骨密度を乗じた値を骨ミネラル量の推定値とする。骨密度には、日本人健常者 2411 人を対象に行った体組成計測データ[2]による、年代別平均骨密度を用いる。

3. 実験

体組成計測データ[2]において、DXA の測定結果により、年齢、性別、身長、体重を変数とする全身の骨ミネラル量の回帰式が定めら

*1 岐阜大学大学院自然科学技術研究科
知能理工学専攻

[〒501-1194 岐阜県岐阜市柳戸 1-1]

e-mail: ryama@fjt.info.gifu-u.ac.jp

*2 岐阜大学医学部附属病院放射線部

*3 岐阜医療科学大学保健科学部

れている。回帰式より算出される全身の骨ミネラル量と、本手法により求められる骨ミネラル量との相関係数を求める。

なお、使用した CT 画像には撮像時の患者の姿勢や撮像範囲の違い (図 1) があるため、頭部、腕部、脚部を除き (図 2)、胸部のみの骨ミネラル量の算出値を用いた。

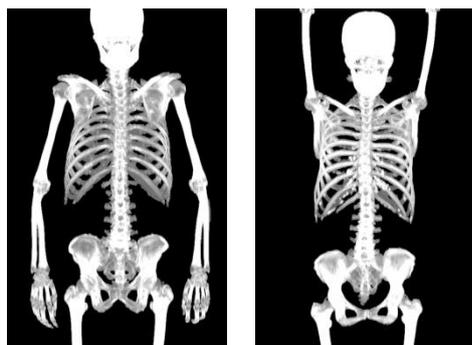


図 1 使用画像の MIP 画像

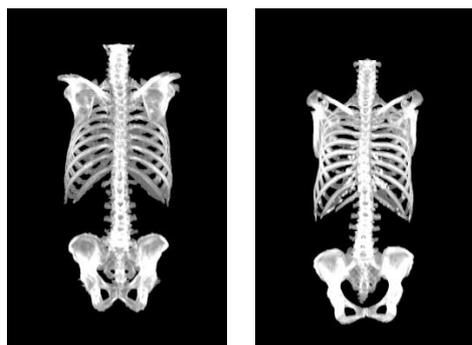


図 2 胸部のみの MIP 画像

4. 結果

本手法により求められた胸部の骨ミネラル量と、回帰式より算出される全身の骨ミネラル量との相関係数は 0.86 であり、強い相関を示した。

縦軸を胸部の骨ミネラル量、横軸を全身の骨ミネラル量とし、BMI によって色を変えてプロットした散布図を示す (図 3)。BMI が高い程、全身の骨ミネラル量に対し胸部の骨ミネラル量が低くなる傾向が見られた。回帰式では体重が重い程骨ミネラル量が高く算出されるが、本手法では体重による影響を受けずに骨ミネラル量の推定が行えている。

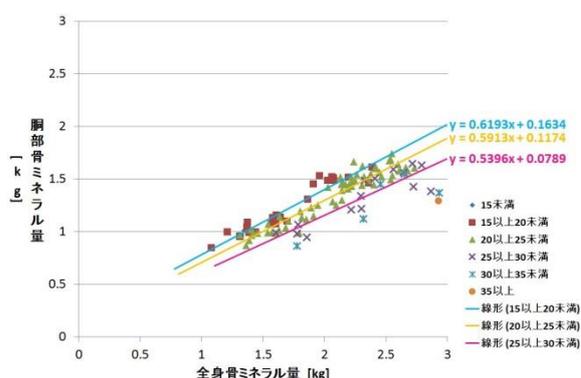


図 3 BMI 別散布図

5. まとめ

低線量 CT 画像から骨格を抽出し、骨ミネラル量の推定を行った。本手法により推定した胸部の骨ミネラル量と、体組成計測データの回帰式から算出される全身の骨ミネラル量との相関係数は 0.86 と強い相関を示した。CT 画像を利用することで、より正確な骨ミネラル量の推定が可能であることが示唆された。

謝辞

本研究を進めるにあたり、有益なご助言をいただきました研究室の方々に感謝の意を表します。本研究の一部は、文部科学省科研費・新学術領域研究 (26108005) および基盤研究 C (17K10455, 18K12102) の補助によって行われました。

利益相反の有無

なし

文献

- [1] 林達郎, 周向榮, 原武史 他: 体幹部 X 線 CT 像における自動的な骨格の構造認識手法の開発. 第 25 回日本医用画像工学大会, OP3-4, 2006
- [2] Ito H, Ohshima A, Ohto N, et al.: Relation between body composition and age in healthy Japanese subjects. European Journal of Clinical Nutrition 55, 462-470, 2001

Estimation of bone mineral content based on low-dose CT images

Ryota YAMADA^{*1}, Tadahiko ISHIHARA^{*2}, Takeshi HARA^{*1}, Xiangrong ZHOU^{*1},
Tetsuro KATAFUCHI^{*3}, Hiroshi FUJITA^{*1}

*1 Department of Intelligence Science and Engineering, Graduate School of Natural Science and Technology, Gifu University

*2 Department of Radiology Services, Gifu University

*3 Faculty of Health Science, Gifu University of Medical Science

Measurement of whole body bone mineral content is important in calculation of SUV of radiopharmaceutical accumulated in bone in quantitative analysis of nuclear medicine image. This study aimed to develop a method to estimate bone mineral content using low dose CT images. Bone extraction is performed using threshold processing and spatial filter on the isotropic CT image. The bone area is determined based on the MIP image of the bone. The value obtained by multiplying the bone area by the bone density is used as the estimated value of the bone mineral content. The regression data of whole body bone mineral content is defined by the measurement data of DXA in body composition measurement performed on 2411 healthy Japanese people. The correlation coefficient between whole body bone mineral content of the case calculated from this regression equation and trunk bone mineral content estimated based on the CT image of 107 cases was 0.86. In addition, it is possible to classify the bone based on the anatomical structure and estimate the bone mineral content of each part. These results suggest the usefulness of quantitative analysis of bone mineral content based on CT images.

Key words: bone mineral content, low-dose CT

胸部 CT 像中の肺結節の良悪性鑑別における自動抽出された画像特徴の可視化

平島 翔^{*1} 平野 靖^{*1} 木戸 尚治^{*2} 岩野 信吾^{*3} 本田 健^{*4}

関 順彦^{*4} 金 亨燮^{*5}

要旨

肺に関する病気には、CT 像上に肺結節と呼ばれる高 CT 値の陰影が写し出されるものがある。医師はその CT 像から画像所見の有無や程度を評価することにより、肺結節の良性・悪性を判断している。また、近年では Deep Learning を用いた画像診断支援などの研究が活発に行われている。しかし、Deep Learning の判断過程は解釈が難しく、なぜその結果が得られたのかが分からない。このことから、判断結果に対して医師や患者が納得しない可能性があり、説明できる AI(Explainable AI, XAI)に関する研究も進められ始めている。

本研究では Deep Learning によって構築された CADx(Computer-Aided Diagnosis)システムの判断結果の根拠を明示的にするために、Deep Learning が抽出した画像特徴の可視化を目的とする。これにより、CADx システムの判断結果に対する信頼性の向上が期待できる。

本稿では、肺結節周辺の 3 次元画像を用いて CNN (Convolutional Neural Network)の学習と識別を行い、Guided Grad-CAM(Guided Gradient-weighted Class Activation Mapping)を用いることで CNN の抽出した画像特徴をクラスごとに可視化した。これにより、肺結節の良悪性鑑別における CNN の注目箇所を特定した。

キーワード：画像所見, CT, Deep Learning, Grad-CAM, XAI

1. はじめに

肺がんなどの肺に関する病気には、CT 像上に肺結節と呼ばれる高 CT 値の陰影が写し出されるものがある。医師はその CT 像から画像所見の有無や程度を評価することにより、肺結節

の良性・悪性を判断している[1]。また、近年では Deep Learning を用いた画像診断支援などの研究[2][3]が活発に行われている。しかし、Deep Learning の判断過程は解釈が難しく、なぜその結果が得られたのかが分からない。このことから、判断結果に対して医師や患者が納得しない可能性があり、説明できる AI(Explainable AI, XAI)[4]に関する研究も進められ始めている。

そこで、本研究ではコンピュータによって得られた判断結果の根拠を明示的にするために、Deep Learning が抽出した画像特徴の可視化を行う。これにより、Deep Learning を用いた画像診断支援の結果に対する信頼性の向上が期待できる。

Deep Learning にはいくつかの手法があるが、

*1 山口大学大学院創成科学研究科電気電子情報系専攻

[〒755-8611 宇部市常盤台 2-16-1]

e-mail: b059vg@yamaguchi-u.ac.jp

*2 大阪大学大学院医学系研究科

*3 名古屋大学医学部放射線医学教室

*4 帝京大学医学部附属病院

*5 九州工業大学大学院工学研究院

画像を入力として特徴を認識・検出するためには一般的に CNN(Convolutional Neural Network) を用いる。CNN は人間の視覚野のニューロンの結合と似たニューラルネットワークであり、画像認識に対して高いパターン認識能力を示す [5]。従来手法では、人の手で画像認識に有効な特徴を特徴量として算出し、その特徴量をもとに分類アルゴリズムを構築して分類していた。しかし CNN により、人の手による特徴量の設定をせずにデータ分類が可能になった。

抽象度の高い認識能力を獲得した CNN が、実際に画像のどこに着目しているか特定する手法として Grad-CAM(Gradient-weighted Class Activation Mapping)がある [6]。これは着目している特徴箇所をクラスごとにヒートマップで強調するものであるが、解像度が低く、見ている内容の詳細がわからない。また、拡張手法である Guided Grad-CAM はクラスごとにピクセルレベルで出力するため、より詳細な情報を得ることができる。

本研究では、まず医師によって良悪性に関するラベルが与えられた肺結節周辺の CT 像を用いて、CNN の学習を行い、良悪性を分類する識別器を作成する。作成した識別器に肺結節周辺画像を入力して良悪性を識別する。このときに、Guided Grad-CAM を用いることで抽出された画像特徴が画像中のどこに対応するかを可視化することができる。

2. 提案手法

本研究での手法の流れを図 1 に示す。また、以下に提案手法の詳細を示す。

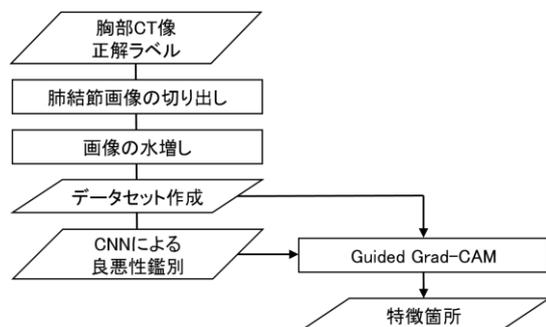


図 1 提案手法の流れ

1) CT 像の等方性ボクセル化

撮影された CT 像は CT 像ごとにサイズや解像度が異なる。さらに一般的にボクセルの形状は立方体ではなく z 軸方向に長く伸びた直方体になっている。等方性ボクセル化によって 3 軸方向全ての解像度を等しくすることで、肺結節の立体的な形状判断や既存構造の認識が容易になる。一般には、xy 面内の解像度に比べ、z 軸方向の解像度が低い傾向にある。本研究では、各 CT 像の z 軸方向の解像度を線形補間法によって xy 平面の解像度に統一した。

2) 肺結節画像の切り出し

着目する肺結節に対し肺野全体の CT 像は非常に大きいため、肺結節を中心に切り出しを行った。その際、CNN の予測結果に影響を与えないよう、結節の周囲構造(胸壁や血管など)との関係を損なわないサイズを試行錯誤的に決定した。本研究では、肺結節を中心とし、60×60×60[voxel]の大きさで画像を切り出した。

3) 画像の水増し

Deep Learning では学習する際にデータ量が少ない場合、過学習が発生することが多い。過学習とは、モデルが学習データに過剰に適合し、未知データでは精度が低く、汎化性がない状態のことである。過学習を抑制するために、平行移動・回転・鏡映を用いて学習に用いる画像枚数を水増しした。本研究では 1[volume]の 3 次元画像に対し 85 通りの座標変換を行うことで、86[volumes]の 3 次元画像を生成した。

4) 階調変換

CT 像は一般的に 4096 階調の 3 次元画像である。しかし、データ量が多いため階調数を減らす必要がある。また、肺結節周辺画像中の良悪性鑑別に有用と考えられる CT 値の濃度域は限定的であるため、画像から -1000~200[HU]をとり、256 階調に変換した。

5) CNN を用いた肺結節の良悪性識別

肺結節周辺画像の内、80%を学習データ、

20%をテストデータとして、CNNの学習を行い、良悪性の識別器を作成した。なお、学習データについては前述の方法で水増しを行った。ネッ

トワークのモデルを表1に示す。また、学習率を0.00005、減衰率を0.0005、バッチサイズを32とした。

表1 CNNモデル

	フィルタ サイズ	ストラ イド	出力マップ サイズ	チャネル 数	活性化 関数
input	-	-	60×60×60	1	-
convolution	3×3×3	1	60×60×60	16	ReLU
max pooling	2×2×2	2	30×30×30	16	-
convolution	3×3×3	1	30×30×30	32	ReLU
convolution	3×3×3	1	30×30×30	32	ReLU
max pooling	2×2×2	2	15×15×15	32	-
fully connect	-	-	-	16	ReLU
fully connect	-	-	-	1	sigmoid

6) Guided Grad-CAM

データセットから原画像の肺結節周辺画像を識別器に入力し、良悪性の識別を行い、Guided Grad-CAMを用いて予測結果を可視化した。Guided Grad-CAMの処理を以下の式(1)と(2)より示す。

$$a_n^c = \frac{1}{Z} \sum_i \sum_j \sum_k \frac{\partial y^c}{\partial A_{ijk}^n} \quad (1)$$

まず、予測クラス c の確率スコア y^c を n 番目の特徴マップのボクセル (i, j, k) における強度 A_{ijk}^n について微分して勾配 $y^n / \partial A_{ijk}^n$ を計算した。次にそれらの全ボクセルについて、特徴マップサイズ Z を用いて平均をとることで、クラス c の n 番目のフィルタに関する重み係数 a_n^c を計算した。この重み係数 a_n^c が大きいほど、その特徴マップ A_{ijk}^n がそのクラス c にとって重要であるということである。

$$L_{Grad-CAM}^c = ReLU \left(\sum_n a_n^c A^n \right) \quad (2)$$

式(1)の重み係数 a_n^c により n 個のフィルタの加重平均を計算し、活性化関数 $ReLU(x) \equiv \max\{x, 0\}$ を適用したものをヒートマップ出力として定義した。式(2)の結果を従来手法である Guided

Backprop[7]と掛け合わせて出力することで、クラスごとにピクセルレベルで可視化した。

3. 実験

1) 実験データ

実験では、2種類のデータセットを使用した。1つは帝京大学医学部附属病院で撮影された胸部CT像42症例、もう1つは、名古屋大学医学部附属病院で撮影された胸部CT像38症例である。また、本研究では医師の評価した肺結節の良悪性を正解ラベルとした。CT像の詳細を以下に示す。

帝京大学医学部附属病院で撮影された症例

- 症例数：42 症例(良性 2 症例, 悪性 40 症例)
- スライスサイズ：512×512~632×632[pixel]
- スペーシングサイズ：0.529~0.742[mm]
- スライス厚：0.5~3.0[mm]
- スライス枚数：257~649[枚]

名古屋大学医学部附属病院で撮影された症例

- 症例数：38 症例 (良性 38 症例)
- スライスサイズ：512×512[pixel]

- スペーシングサイズ : 0.625~0.702[mm]
- スライス厚 : 0.5[mm]
- スライス枚数 : 531~771[枚]

2) 評価方法

肺結節の良悪性について CNN を用いて学習と識別を行い、水増しを行っていないテストデータに対して CNN が出力した識別結果が正解ラベルと一致した場合を正解とした。データセットから切り出した肺結節画像群を5つに分け、1つをテストデータ、残りの4つを学習データとして、5分割交差検証によって評価を行った。データセットの内訳を表2に示す。単位は[volumes]である。

表2 良悪性鑑別実験に用いたデータセット

	set_1	set_2	set_3	set_4	set_5	合計
良性	8	8	8	8	8	40
悪性	8	8	8	8	8	40
合計	16	16	16	16	16	80

4. 結果

良悪性鑑別実験における識別率を表3に示す。単位は[%]である。

表3 良悪性鑑別の識別率

	テストデータ					平均 ± 標準 偏差
	set_1	set_2	set_3	set_4	set_5	
識別率	93.8	87.5	93.8	87.5	87.5	90.0 ± 3.1
誤差	0.09	0.13	0.38	0.20	0.50	-

表3から、最も識別率の高い set_1 と set_3 のうち、学習時の識別率が高く、誤差の低い set_1 をテストデータとしたモデルから Guided Grad-CAM を用いて悪性の画像特徴の可視化を行う。

入力画像、Grad-CAM の結果、Guided Grad-CAM の結果を図3~図7に示す。また、注目度の高い箇所を赤く、注目度が低くなるにつれて徐々に緑、青と表示している。Grad-CAM をそのまま表示すると全体的に青い画像になるため、最大値を1、最小値を0に注目度を正規化し、0.1以下の場合色を付けていない。

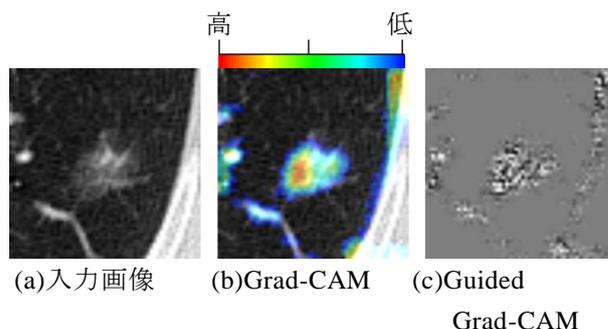


図3 すりガラス濃度の所見を持つ悪性結節[8]

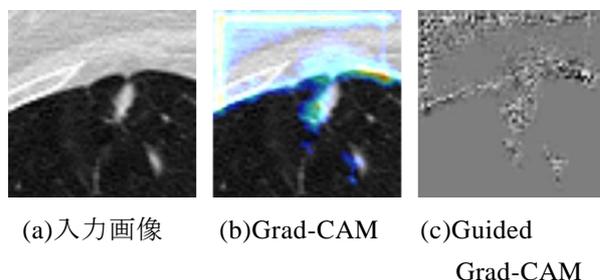


図4 やや辺縁が不明瞭、すりガラス濃度、胸膜陥入像[8]

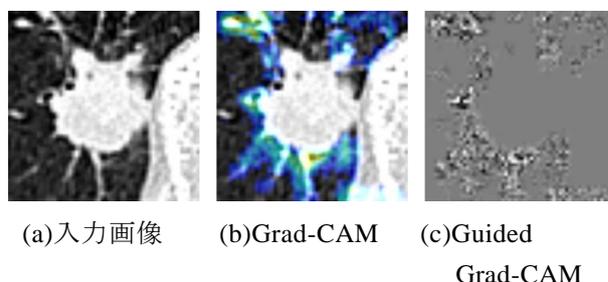


図5 ノッチ、スピキュラ、肺血管・気管支の集束像[8]

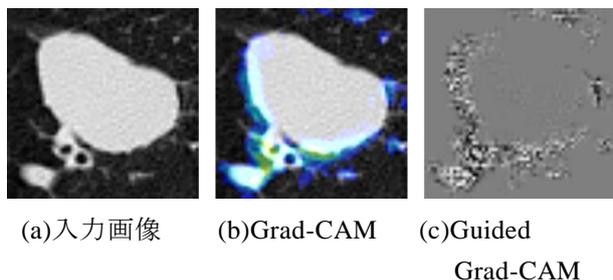


図 6 肺血管・気管支の圧排像[8]

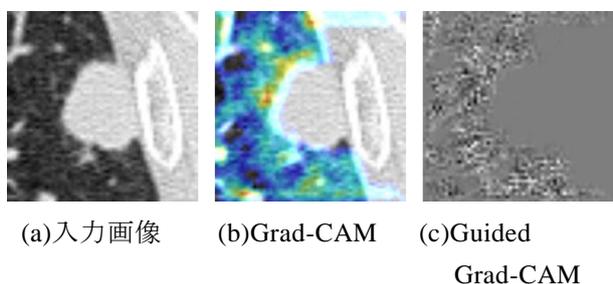


図 7 ノッチ，肺血管・気管支の集束像[8]

5. 考察

1) 良悪性鑑別実験のについて

本研究ではまず，肺結節の良悪性を識別する CNN モデルを作成した．CNN の識別結果について考察を行う．肺結節の良悪性鑑別の識別率は $90.00 \pm 3.01[\%]$ であった．無作為に 2 クラス分類した場合の識別率が $50[\%]$ であることを考慮すると，精度の良い結果といえる．しかし本研究では，良性と悪性でデータが撮影された施設が異なることから，良悪性鑑別の識別率が向上した可能性が考えられる．画像特徴の可視化は行えるため，良悪性の識別には成功しているが，改めて撮影条件を揃えたデータを用いて実験を行う必要があると考えられる．また，表 3 から，識別率が $93.8[\%]$ と $87.5[\%]$ の 2 パターンしかないことが分かる．これは，識別率の算出に用いた水増しを行っていないテストデータが $16[\text{volumes}]$ しかなく， $1[\text{volumes}]$ あたりの識別率への影響が大きいためである．このことから，水増しを行っていないテストデータを増やことで，より精度と信頼性の高い結果を得られることが予想される．

2) 画像特徴の可視化について

図 3～図 7 は水増しを行っていない肺結節画像を良悪性について，良悪性鑑別実験で作成した CNN モデルを用いて識別し，抽出した悪性の画像特徴を Grad-CAM と Guided Grad-CAM を用いて可視化した結果である．それぞれの画像について考察を行う．

図 3 は，すりガラス濃度の肺結節画像から得られた画像である．この肺結節について医師と CNN がともに悪性であると判断している．この図では，すりガラス濃度の肺結節全体を画像特徴として可視化している．これは，すりガラス濃度の肺結節が悪性の画像特徴であると CNN が判断したと考えられる．また，図から胸壁についても注目していることが分かる．医師による評価では胸壁に関する所見はないとなっているため，CNN が悪性と識別するのに注目している特徴は，医師と全く同じであるとは限らないことが分かる．

図 4 は，やや辺縁が不明瞭，すりガラス濃度であり，胸膜陥入像の所見がみられる肺結節画像から得られた画像である．この肺結節について医師と CNN がともに悪性であると判断している．この図では，CNN が肺結節や胸壁を画像特徴として可視化している．肺結節の辺縁や濃度については注目度が高いことが分かる．しかし，胸膜陥入像については青色で表示され，あまり注目されておらず，所見とは異なる箇所を最も注目している．このことから，この画像において CNN が悪性であると識別する画像特徴は，医師が診断に用いる所見より重視する箇所があるということが分かる．

図 5 は，ノッチ，スピキュラ，肺血管・気管支の集束像の所見がみられる肺結節画像から得られた画像である．この肺結節について医師と CNN がともに悪性であると判断している．この図では，スピキュラ，肺血管・気管支の集束像を特徴箇所として抽出していることが分かる．しかし，ノッチを画像特徴として抽出していない．これは，CNN はあくまで良悪性について識別を行っており，肺結節の所見の有無を

学習に用いていないため、所見をすべて表示していないからである。

これらのことから、CNN が自動抽出した悪性の画像特徴は、医師が診断に用いる所見と同じ箇所であることが多いが、それとは異なる画像特徴も抽出している。特に胸壁を画像特徴として抽出した結果が多くみられた。これは、医師が診断に用いる一般的な画像所見とは異なる画像所見が存在する可能性が考えられる

6. まとめ

本研究では、良悪性鑑別における CNN の識別結果の根拠を明示的にし、信頼性を向上するために、自動抽出した画像特徴の可視化を行うことを目的とした。そこで、本稿では CT 像より切り出した肺結節周辺の 3 次元画像を用いて CNN の学習と識別を行い、Guided Grad-CAM を用いることで CNN の抽出した画像特徴を可視化する手法を提案した。良悪性鑑別に用いた CNN の識別率は $90.00 \pm 3.01[\%]$ であった。本研究では、CNN のパラメータを試行錯誤的に決定したため、今後は、パラメータを調整することでより精度のよい抽出が行えると考える。また、可視化した画像特徴から、CNN がどこに着目して良悪性を識別しているかが分かった。本手法を用いることにより、今後、CNN による識別結果の根拠を明示的にすることで、信頼性が向上することが期待できる。

今後の課題として、Deep Learning を用いた新しい所見の発見や所見の重要度の評価などが考えられる。

謝辞

御助言及び御協力を頂きました本研究室の大学院生、学部生の皆様に心よりお礼申し上げます。本研究は日本学術振興会科学研究費補助金新学術領域研究(26108009)、および基盤研究(B)(17H02110)による支援を受けた。

利益相反の有無

なし。

文献

- [1] 森谷浩史, 秋元達也, 中川学 他 : 肺結節の CT/MRI 診断, 臨床画像, **26**, 144-160, 2010
- [2] Tu X, Xie M, Gao J, et al. : Automatic Categorization and Scoring of Solid, Part-Solid and Non-Solid Pulmonary Nodules in CT Images with Convolutional Neural Network, Scientific Reports, **7**, Article number: 8533, 2017
- [3] 上野翔子, 杉山治, 西尾瑞穂 他 : 患者情報を考慮した胸部 CT 画像の診断支援の試み, SIG-AIMED, 004-04, 2017
- [4] Gunning D. : Explainable Artificial Intelligence (XAI), DARPA, DARPA-BAA-16-53, 2016
- [5] Krizhevsky A, Sutskever I, Hinton G E : ImageNet Classification with Deep Convolutional Neural Networks, NIPS, 2012
- [6] Selvaraju R R, Cogswell M, Das Abhishek, et al. : Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization, arxiv, 1610.02391, 2017
- [7] Springenberg J T, Dosovitskiy A, Brox T, et al. : Striving for Simplicity: The All Convolutional Net, arxiv, 1412.6806, 2015
- [8] 日本肺癌学会編 : 臨床・病理肺癌取扱い利用規約. 第 7 版, 金元出版, 2010

Visualization of automatically extracted image features in benign / malignant discrimination of lung nodules in chest CT images

Kakeru HIRASHIMA^{*1}, Yasushi HIRANO^{*1}, Shoji KIDO^{*2}, Shingo IWANO^{*3}, Takeshi HONDA^{*4},
Nobuhiko SEKI^{*4}, Hyoungeop KIM^{*5}

*1 Graduate School of Sciences and Technology for Innovation, Yamaguchi University

*2 Graduate School of Medicine, Osaka University

*3 Nagoya University Graduate School of Medicine

*4 Teikyo University Hospital

*5 Graduate School of Engineering, Kyushu Institute of Technology

Lung nodules in CT images are presented as regions with high CT number. The doctor judges the benignancy / malignancy of the lung nodule by evaluating the presence or absence, and extent of the medical findings of tumors in from CT images. Recently, researches on diagnosis support using Deep Learning have become actively. However, the judgement process in Deep Learning is difficult to interpret.

In this paper, we propose to visualize image features extracted from Deep Learning in order to clarify the grounds of results obtained by CAD (Computer-Aided Diagnosis) systems based on Deep learning.

In this paper, we used three-dimensional image cut out the peripheral regions of lung nodules from the original CT images. We created discrimination model using CNN (Convolutional Neural Network) and carried out the discrimination for those images. We visualized image features extracted from CNN by using Guided Grad - CAM (Guided Gradient-weighted Class Activation Mapping). As a result, the attention points of CNN were specified.

Key words: Medical findings, CT, Deep Learning, Grad-CAM, XAI

CT 画像を用いた脊柱海綿骨の骨密度定量化

李 新^{*1} 光本 浩士^{*1} 平野 雅嗣^{*2}

山崎 克人^{*3} 田村 進一^{*4}

要旨

近年,高齢化に伴い,骨粗鬆症患者が年々増加している.このため,骨粗鬆症患者の CT 画像を対象としたコンピュータ支援システムの開発がなされ骨密度の計測が報告されている.

本稿ではより精密な計測を目的にし,まず,抽出した脊柱の各スライスに対し,海面骨と皮質骨の境界を検出し,海綿骨領域のデータ値を用いた CT 値の平均を求める.その結果,脊柱に沿った骨密度の変化,椎骨ごとの変化を計測することができた.

キーワード: 骨粗鬆症、海綿骨、皮質骨、領域拡張処理

1. はじめに

近年,高齢化に伴い,骨粗鬆症患者が年々増加している.その影響により医師による CT 像の読影が膨大化し,多大な時間と労力が必要になり,見落としが危惧されている.このため,骨粗鬆症患者の CT 画像を対象としたコンピュータ支援システムの開発がなされている.先行研究として高橋ら[1]のシステムでは,安定して骨粗鬆診断が行えているが,プログラムはオープンになっていない.骨密度は設定した楕円内のみ計測している.より細かい計測をするにはより精度のよい手法を開発しなければならない.また,海綿骨の抽出に関し,近藤ら[2]は Snakes による手法を検討している.この手法はパラメータの設定によって輪郭の持つ形状や濃度値などに

左右され,試行錯誤によってすべての輪郭が抽出可能となる値を決める必要がある.

本稿では,三次元 CT 画像から脊柱データを抽出し,脊柱データを用い,海綿骨と皮質骨の領域分割処理を行い,海綿骨の骨密度を計測する手法を提案し,椎骨内での変化を計測した.

2. 骨粗鬆症

骨粗鬆症とは,骨の強度が低下し骨折しやすくなる病気である.全身の骨がもろくなるため,軽い力が加わるだけで様々な部位の骨折が起こる.骨粗鬆症になると,立った姿勢から転んだくらいでも,椎体(背骨),大腿骨近位部(足の付け根)などに骨折を起こしやすくなる.

2.1 皮質骨と海綿骨

骨は,皮質骨と海綿骨に分けられる.外側にある皮質骨はカルシウムやリンを主成分とする硬い骨で,海綿骨は骨髓腔内に広がる骨梁と呼ばれる小さな骨の柱の集合体である(図 1).

海綿骨は表面積が大きく,骨髓と広く接し,骨代謝回転は皮質骨に比べて約 10 倍と言われている.従って,初期の骨量減少が認められるのは海綿骨である.従って,骨粗鬆症に経過観察のためには,海綿骨の骨密度を計測すべきである.

*1 大阪電気通信大学大学院
〔〒572-8530 寝屋川市初町 18-3〕
e-mail: mi18a003@oecu.jp

*2 新居浜工業高等専門学校

*3 栄宏会小野病院

*4 (株) NBL 研究所

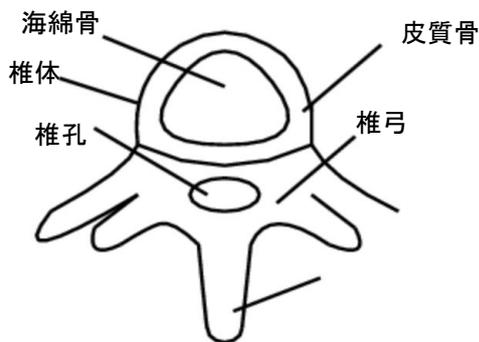


図 1 人の椎骨

3 脊柱抽出処理の流れ

処理の流れを図 2 に示す。CT データを読み込み、メディアンフィルタでスパイクノイズを除去し、二値化処理を行う。領域拡張の開始点を決め、領域拡張処理をし、脊柱領域のみを抽出する。

3.1 開始点決定手法

脊柱抽出には、領域拡張法を使用する。領域拡張処理とは、円、球などの構造要素を設定し、構造要素内のすべての点がある条件を満たす際、この構造要素を領域に含み、満たさない場合は含まない。この処理を指定した開始点から繰り返すことにより構造要素ごとに領域を抽出することができる処理である。従って、構造要素の大きさにより脊柱と肋骨が分離できるが、開始

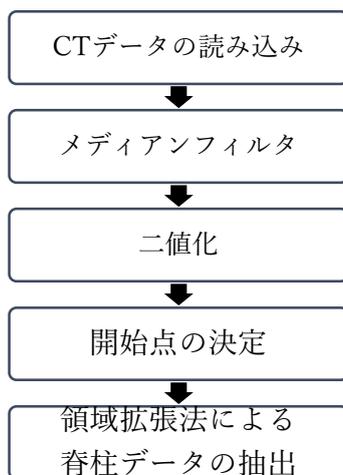


図 2 脊柱抽出処理

点を肋骨部や骨以外の位置に設定すると脊柱抽出はできない。

従来手法として北坂ら[3]は領域拡張の開始点を、入力画像の中央のスライス(入力された n 枚のスライスのうち $n/2$ 枚目のスライス)における最大連結成分の重心としている。しかし、この手法では開始点が椎孔と呼ばれる穴に設定される事があり、領域拡張法が動作しない。

対策として、円形度を用いた脊柱抽出処理を用いることにより脊柱領域を安定的に抽出することができる手法を開発した。

3.2 空洞処理

空洞処理とは、スライス画像の骨領域内に存在する大きな空洞を埋める手法である。領域分割処理でスライス画像を生成する。骨の輪郭を抽出し、点(0,0)を開始点として輪郭の外部領域を領域拡張処理で埋める。処理後の画像を白黒反転し、骨領域内部に存在する大きな空洞を埋める。

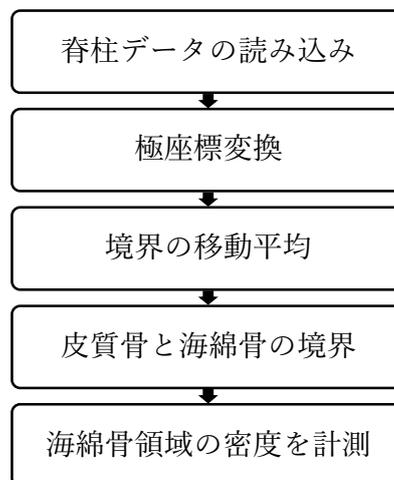


図 3 皮質骨と海綿骨の領域分割処理

4. 皮質骨と海綿骨の領域分割処理

4.1 処理の流れ

処理の流れを図 3 に示す。脊柱データを読み込み、各スライス画像を生成する。そして、スライス画像ごとの重心位置を求め、極座標変換し画素値の移動平均を行う。その画素値から境界点を求め、境界点の移動平均を行う。境界点座標を極座標から直交座標に変換し、皮質骨と海面骨

の境界を決める。

4.2 脊柱スライス画像の極座標変換

極座標とは (r, θ) で点の位置を示す方法である(式(1))。

$$r = \sqrt{x^2 + y^2}, \theta = \tan^{-1} \frac{y}{x} \quad (1)$$

スライス画像の重心位置 (px, py) を中心 (cx, cy) に平行移動し,CT データと骨領域データを同時に 0 から 359 度になるまで 1 度ずつ回転 (θ) させ,その際の骨領域データと同じ座標に位置する CT データの画素値を中心から上 (r) へ出力画像に代入していた。

4.3 境界点計算

原点 $(0,0)$ から縦軸下方向に 1 ピクセルずつ調べ,縦軸の画素値の最大値より 9/10 以下の画素値を検出したとき,その座標を境界点とする.そして横軸 1 度進め,横 0 から 360 度の範囲で繰り返す,合計 360 点を検出する。

境界点決定後,座標の逆変換(式(2))行うことで極座標から直交座標へ戻すことができる.最後に画像座標へ変換(式(3))を行い,各点を線で結ぶことで領域境界を決定することができる

$$x = r \cos \theta, y = r \sin \theta \quad (2)$$

$$dx = cx - x, dy = cy - y \quad (3)$$

5. 海綿骨の骨密度計算

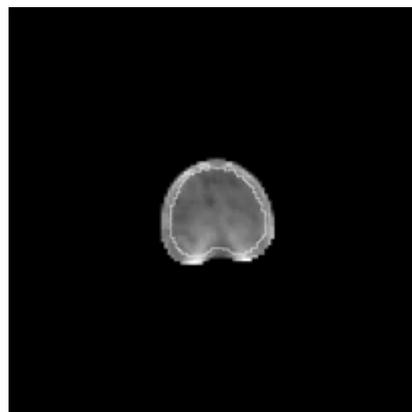
皮質骨と海綿骨の境界を決定した後,領域拡張処理を用い,境界の外部領域に 255 を代入する.海面骨のみの領域を求める.処理後,海綿骨領域の座標を利用し,元データである CT データの CT 値を海綿骨領域に代入し,骨密度(BMD)を計算する。

5.1 骨密度の計算

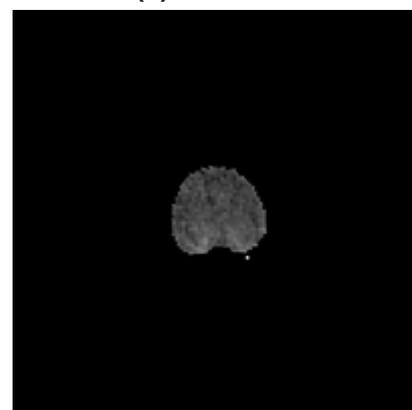
海綿骨領域内の CT 値が高い点のみに対し,メディアンフィルタ処理を行う.処理した後,海綿骨領域内の CT 値の合計と面積から平均 CT 値を求め,これを骨密度(BMD)とする。

6. 実験結果

CT 画像 388 枚の中,脊柱のスライス画像である 210 枚用い実験を行った.図 4(a)の白いラインは海綿骨と皮質骨の境界を表す.図 4(b)は海綿骨領域のみを表す.スライスごとの骨密度を計測した結果が図 5 に示す。



(a) 境界輪郭



(b) 海綿骨領域

図 4 海綿骨の領域分割

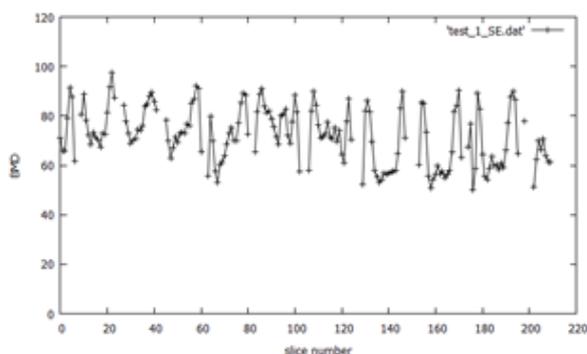
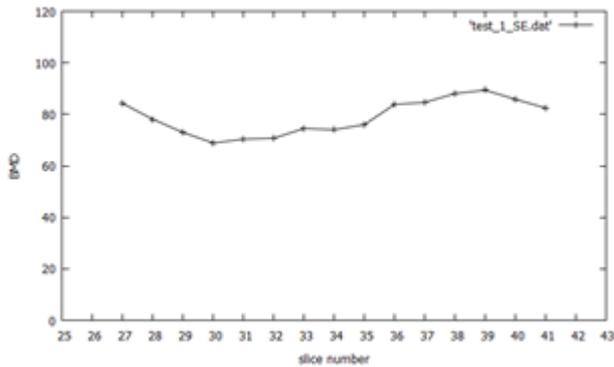
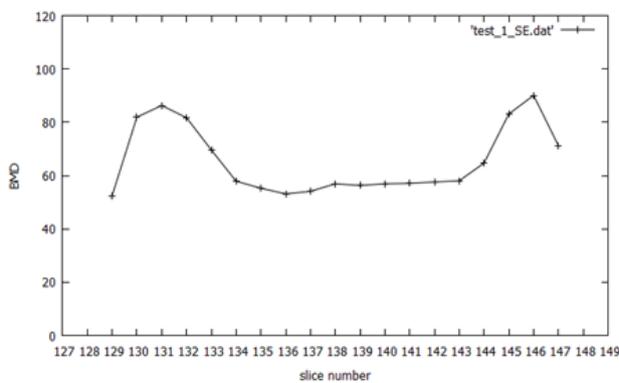


図 5 スライスごとの骨密度

図 6 の(a)と(b)は椎骨ごとの骨密度を示す.(a)では骨密度は一定に保っている.(b)の骨密度は周辺部が高くなっている.(a)と比較すると,椎骨内での変化が大きくなっている.(b)では下半身に向かって骨密度が若干大きくなって



(a) スライス番号:25~43



(b) スライス番号:127~149

図 6 椎骨の骨密度

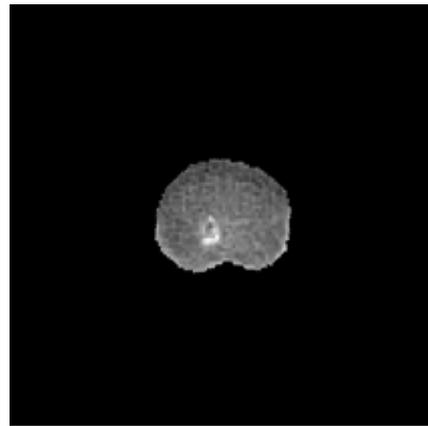
いることが見られる。

131 番目と 138 番目の海綿骨領域のスライスを図 7 に示す。図 6(b)から見ると 131 番目の骨密度が 138 番目より大きいため、該当スライド画像を示す。

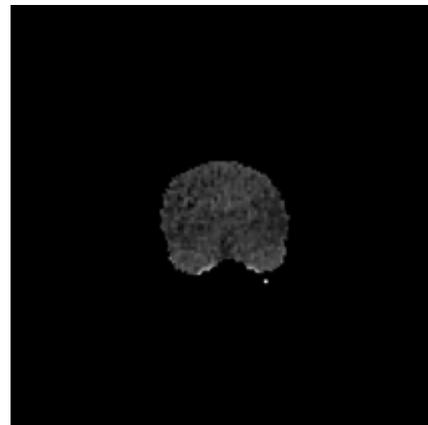
7. まとめ

本稿では、三次元 CT 画像から脊柱を抽出するため、領域拡張の開始点を、円形度を基準とした脊柱のスライス画像から選択している。次に骨粗鬆症が進行すると脊柱内に空洞が存在し、空洞が大きいため、領域拡張処理が止まってしまう、空洞処理を追加した。抽出した脊柱データのスライス画像を極座標変換し、海綿骨と皮質骨の境界を検出した。そして、海綿骨のみの領域を用い、海綿骨の骨密度を計測する手法を提案し、椎骨内での骨密度の変化を計測した。

今後の課題として、骨梁を立体的に把握し、その大きさを定量化したい。



(a) 海綿骨領域:131 番



(b) 海綿骨領域:138 番

図 7 海綿骨領域

利益相反の有無

なし

文 献

- [1] 高橋秀次,鈴木英宣,仁木登 他:胸部マルチスライス CT 画像を用いた骨粗鬆症診断システム.信学論 D,vol.J96-D,no.4:892-900.2013
- [2] 近藤一光,尾川浩一,長岡智明 他:Snakes を用いた脊椎形状認識と骨粗鬆症診断への応用,法政大学計算科学研究センター報告,17:73-77,2004
- [3] 北坂孝幸,小川浩史,横山耕一郎 他:解剖学的知識に基づく非造影 3 次元腹部 X 線 CT 像からの複数臓器領域の抽出,コンピュータ支援画像診断学論,vol.9,no.1:1-14,2005

Bone Density Quantification in The Spinal Column Cancellous Bone Using CT Images

Xin LI^{*1}, Hiroshi MITSUMOTO^{*1}, Masatsugu HIRANO^{*2}, Katsuhito YAMASAKI^{*3}, Shinichi TAMURA^{*4}

*1 Osaka Electro-Communication University Graduate School of Engineering

*2 Niihama National College of Technology

*3 Eikokai Ono Hospital

*4 NBL Technovator Co., Ltd.

In recent years, osteoporosis patients are increasing year by year with the aging of the population. For this reason, measurement of bone density for which development of a computer support system for CT images of osteoporosis patients has been made has been reported.

In this paper, for the purpose of more precise measurement, for each slice of the displaced and extracted spine, the boundary between the sea surface bone and the cortical bone is detected, and the average of the CT values using data values of the cancellous bone region is calculated. It was possible to measure changes in bone density along the spine and changes from vertebra to vertebra.

Key words: Osteoporosis, Cancellous bone, Cortical bone, Region growing method

二段階分類による胸部 X 線画像を用いた 異常部位検出システムの検討

堂園貴弘^{*1} 吉村裕一郎^{*2} 田中久美子^{*3}

中田孝明^{*3} 織田成人^{*3} 中口俊哉^{*2}

要旨

集中治療室における移動困難な重症患者の経過観察のため X 線ポータブル撮影が用いられる。しかし、座位や仰臥位などの様々な体位での撮影となるため、一般的な立位での撮影と臓器状態に差異が生じることで読影が困難であり、診断精度の低下が課題となっている。そこで本研究では胸部 X 線ポータブル画像からの肺疾患の診断能を向上するため深層学習の適用を試みた。提案システムは、無気肺と肺炎を 1 クラスとして異常なし、胸水の 3 クラスで分類後、無気肺または肺炎と分類された画像を 2 クラス分類する 2 段階分類を行う。評価実験には千葉大学医学部附属病院で収集されたデータと米国立衛生研究所のデータの 2 種類を用いた。データ拡張として左右反転と±7 度回転処理を行い、データ数を 14 倍に拡張し、評価方法は 3 分割交差検証法を用いた。結果として、提案する 2 段階分類手法は 4 クラス同時分類時よりもモデル全体の分類精度が向上することを確認できた。

キーワード：深層学習、胸部 X 線ポータブル画像、畳み込みニューラルネットワーク

1. はじめに

術後の患者の術後管理、院内で発生した重症患者、他院からの紹介や救急外来から直接入院した重症患者の治療を目的に病院内に集中治療室が設置されている。ここでは、移動が困難な重症患者に対して胸部 X 線ポータブル装置を用いることで、治療に必要な気管内チューブなどのデバイスの位置異常を発見することや併発している病状を診断している。胸部 X 線ポータブル画像は、CT 画像や MRI 画像に比べて情報量が限られるため、病変部の見落としなどにより治療介入が遅れる懸念がある。また、ポータブル画像を撮影する際、座位や仰臥位での撮影が主となり、立位で撮影された X 線画像とは臓器状態に差異が生じるため、診断が困難である要因となっている。先行研究において、胸部 X 線画像に対する診断感度は約 64%[1]とされており、制度の改善が求められている。

そこで、本研究では、ICU 患者の胸部 X 線ポータブル画像からの診断精度向上を目的とする画像認識技術を用いた診断支援システムを検討する。画像認識技術に用いられる手法として、Convolutional

*1 千葉大学大学院融合理工学府基幹工学専攻医工学コース
〔〒263-8522 千葉市稲毛区弥生町 1-33〕 e-mail: dozono0224@chiba-u.jp

*2 千葉大学フロンティア医工学センター

*3 千葉大学大学院医学研究院救急集中治療医学



図 1 VGG16 の構造

Neural Network (CNN)がある。これは、近年医用画像分野においても多く用いられている手法であり、Neural Network を多層化し、畳み込み処理を繰り返すことで自動的に画像特徴を抽出することが可能である。

CNN を用いた先行研究として、胸部 X 線画像を用いた多クラス分類実験が挙げられる[2]。この研究では入力画像を 14 種の病状に分類しているが、課題としてクラス間における精度差が大きく、全クラスに対応できていない。そこで、本研究の目的を関連研究において低精度であるクラスの精度改善による高精度分類モデルの構築とする。本研究は、[2]において低精度となっている肺炎と無気肺に加えて、胸水、異常なしを対象にする。

2. 提案手法

2.1. 使用手法

本研究においては、CNN の中でも画像認識コンテスト ILSVRC2014 において、高成績をおさめた VGG16 で実験を行う。このモデルは、畳み込み層が 13 層、全結合層 3 層からなるシンプルな構造となっている(図 1)。実験に使用する際には、ILSVRC2014 データセット(1000 クラス、120 万枚の一般物体画像)で学習済みの重みを使用して転移学習をする。転移学習を導入することで、学習時にランダムに初期値を設定した場合と比較して高い性能が期待できる[2]。転移学習した後、再学習するにあたり全結合層の構造を改良した(図 2)。通常学習する際、誤差発散防止のために学習率を小さくして行う。しかし、欠点として学習が遅くなってしまうため収束するまで長い時間を要する。そこで、正規化処理である Batch Normalization を全結合層に追加した。その結果、大きな学習率を設定することが可能とな

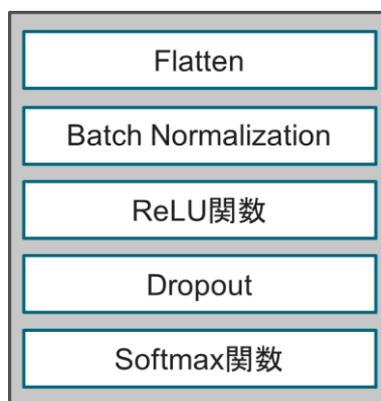


図 2 用いた全結合層の構造

り、学習時間の短縮がすることが確認できた。

2.2. 2段階分類手法

事前実験において、肺炎を除いた無気肺と胸水、異常なしの3クラス分類および無気肺を除いた肺炎と胸水、異常なしの3クラス分類で行ったところ、無気肺、肺炎の分類精度が0.886、0.723であったが、対象とする4クラス全てを同時に分類した際には無気肺、肺炎の分類精度が0.526、0.605と他のクラスよりも低精度だった。このことから、無気肺と肺炎を他のクラスと同時に分類することが困難であると判明した。

そこで、無気肺と肺炎を1クラスとして胸水や異常なしと分類後に、別のネットワークモデルで無気肺と肺炎の2クラスに分類する2段階分類手法を構築した(図3)。一度に分類するクラスを減少させて対象クラスを限定する段階的な分類を行うことで、精度向上が期待できると考え、今回検証実験を行った。

3. 実験

本実験で使用する画像は、千葉大学医学部附属病院救急科で撮影された胸部X線ポータブル画像(以下、病院データとする)とアメリカ国立衛生研究所が公開しているデータ(以下、NIHデータとする)の2種類である。2種類の画像を使用するにあたり、前処理として、両データの画像サイズを1024×1024pixelに統一するための病院データのトリミングおよびリサイズと、全データのコントラスト調整にガンマ補正を用いた。使用枚数は無気肺と肺炎、胸水、異常なし各418枚である。これらの画像に対して3分割交差検証を用いて、2つの実験を行った。

3.1. 無気肺と肺炎を1クラスとし、胸水や異常なしと分類する3クラス分類(段階1)

まず、提案手法の段階1にあたる無気肺と肺炎を1クラスとしてまとめ、胸水や異常なしと分類する3クラス分類と4クラス同時分類の精度比較を行った。実験条件は、学習率0.0001、学習回数500回、バッチサイズ16とし、データ拡張に左右反転、±7度回転を用いた。モデルの各クラスの精度を、F値において評価した。モデル作成時、無気肺と肺炎をまとめて1クラスとする際、各209枚ずつ計418枚とし、他2クラスとの枚数を統一した。

実験結果を表1に示す。無気肺と肺炎を1クラスにまとめたことで、他のクラスとの識別性能が向上し、またモデル全体の精度も改善された。深層学習モデルにおける分類において、同時に他のクラスと

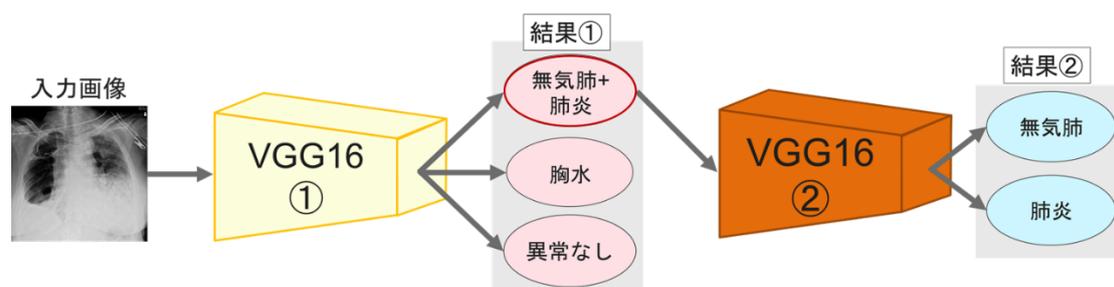


図3 提案段階的の分類手法

表 1 3.1 節実験結果

	4クラス同時分類	2段階分類手法の段階1の出力
無気肺	0.526	0.801
肺炎	0.605	
胸水	0.794	0.840
異常なし	0.854	0.896

の分類が困難な無気肺と肺炎を1つのクラスにまとめて分類させることの有効性が示唆された。

3.2. 無気肺と肺炎の2クラス分類(段階2)

次に提案手法の段階2にあたる無気肺と肺炎の2クラス分類と4クラス同時分類の精度比較を行った。実験条件は、3.1節の実験と同様である。使用枚数は、無気肺と肺炎の各418枚である。作成したモデルの精度検証を行う際には、段階1において無気肺または肺炎と判断された画像を使用した。

2段階分類手法全体の結果を表2に示す。無気肺を除く他3クラスでは、精度向上が確認できた。無気肺の精度が低下した要因としては、段階1において4クラス同時分類時よりも使用枚数を減らしたことが考えられる。このことから、無気肺のほうが肺炎よりもモデルでの判断が困難であることが示唆される。

以上のことから、2段階分類を導入することで、4クラス同時分類に比べ、複数のクラスにおいて精度向上が可能であることが考えられる。

4. まとめ

集中治療室における胸部 X 線ポータブル画像を用いた深層学習による自動診断支援システムの構築を目的に、本研究では2段階分類手法を提案した。無気肺、肺炎、胸水、異常なしを対象としてVGG16を用いて実験で検証したところ、提案手法の有効性が無気肺を除き示唆された。今後は、使用画像の調整を行ったうえでの実験、VGG16以外のCNNモデルの検討や分類根拠提示方法を検討する。

利益相反の有無

なし

表 2 2段階分類手法 結果

	4クラス同時分類	2段階分類手法
無気肺	0.526	0.483
肺炎	0.605	0.667
胸水	0.794	0.840
異常なし	0.854	0.896

文献

- [1] Nazerian P, Volpicalli G, Vanni S, et al.: Accuracy of lung ultrasound for the diagnosis of consolidations when compared to chest computed tomography. The American Journal of Emergency Medicine Vol. 33: 620-625, 2015
- [2] Nima T, Jae S, Suryakanth G, et al.: Convolutional Neural Network for Medical Image Analysis: Full Training or Fine Tuning? IEEE Transactions on Medical Imaging Vol. 35: Issue 5, 2016
- [3] Rajpurkar P, Irvin J, Zhu K, et al.: CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning. [online] Available: <https://arxiv.org/abs/1711.05225:2017>

Investigation of abnormal site detection system using chest X-ray image by Two-step classification

Takahiro DOZONO^{*1}, Yuichiro YOSHIMURA^{*2}, Kumiko TANAKA^{*3}
Takaaki NAKADA^{*3}, Shigeto ODA^{*3}, Toshiya NAKAGUCHI^{*2}

*1 School of Engineering, Chiba University

*2 Center of Frontier Medical Engineering, Chiba University

*3 Department of Emergency and Critical Care Medicine,
Graduate School of Medicine

Chest X-ray portable radiography is used for the follow-up of severe patients who have difficulty moving in the intensive care unit. However, since imaging is performed in various postures such as sitting position and supine position, interpretation is difficult due to the difference of image in organ status of standing position, and the reduction in diagnostic accuracy is low. In this study, we tried to apply deep learning to improve the diagnosis of lung diseases from chest X-ray portable images. The proposed system is classified into two-step: three classes of images classified of atelectasis and pneumonia as one class, not emergency or pleural effusion, and two classes of images classified as atelectasis or pneumonia. For evaluation experiments, two types of data collected at Chiba University Hospital and data from the National Institutes of Health were used. We performed left-right inversion and ± 7 -degree rotation processing as data expansion, expanded the number of data to 14 times, and used the three-part cross validation method as the evaluation method. As a result, it has been confirmed that the proposed two-step classification method improves the classification accuracy than the four-class classification model.

Key words: Deep Learning, Chest portable X-ray images, Convolutional Neural Network

ブロックマッチング 5D フィルターを用いたダイナミック PET スキャンのための画像ノイズ除去

大手 希望*¹ 橋本二三生*¹ 垣本 晃宏*¹ 磯部 卓志*¹

犬伏 知生*¹ 得居 葵*¹ 吉川 悦次*¹ 大村 知秀*¹

尾内 康臣*²

要旨

陽電子断層撮影装置(positron emission tomography; PET)による PET リガンドの取込みの定量には、ダイナミックスキャンが必要となる。ダイナミックスキャンは、短時間フレームの繰り返しよりなるため、データがノイズになりやすい。そこでダイナミック PET 画像のノイズ除去のために、ブロックマッチング 4D フィルター(block matching and 4D filter; BM4D)を時空間に拡張した BM5D を提案する。BM5D は、類似した 4D パッチを集めて 5D のグループとし、それをまとめて変換することでスパース性を増強し、信号とノイズを分離しやすくする。計算機シミュレーション、健常ボランティア実験データにより、BM5D、ガウシアンフィルター、BM4D の性能を比較した。BM5D は最も高いピーク信号対雑音比、構造化類似度を示し、実験データにおいて最も良好な画像を示した。

キーワード：画像ノイズ除去，画像フィルタリング，画像復元，Positron emission tomography (PET)

1. はじめに

陽電子放射断層撮影装置(positron emission tomography; PET)によるダイナミックスキャンは、PET トレーサーの取込みの定量に不可欠である。しかし、ダイナミックスキャンは短時間フレームの繰り返しで構成され、雑音の多い画像となりやすい。そのため、ガウシアンフィルタ(Gauss)による平滑化が良く用いられているが、画像エッジがぼけてしまう問題がある。そこで、非局所平均フィルタ (non-local means; NLM)やブロックマッチング 3D フィルタ(block

matching and 3D filter; BM3D) などのエッジ保存型平滑化フィルタが提案されている。Dutta らは、ダイナミック PET 画像のノイズ除去のために NLM を時空間に拡張した[1]。また、Maggioni らは、BM3D を 3D 画像に拡張した BM4D を開発した[2]。しかし、これまでダイナミック PET 画像のノイズ除去のために BM4D を時空間に拡張する研究はなされていない。そこで本研究では、ダイナミック PET 画像ノイズ除去のために BM4D を時空間に拡張した BM5D を提案し、その性能を評価する。

方法

1) BM5D

BM5D は、ダイナミック PET 画像のノイズ除去のために BM4D を時空間に拡張したものである。図 1 に BM5D の処理の流れを示す。本実装ではパッチサイズをハード閾値処理では 4 ×

*1 浜松ホトニクス株式会社中央研究所
〔〒434-8601 浜松市浜北区平口 5000〕

e-mail: kibou@crl.hpk.co.jp

*2 浜松医科大学



図1 提案 BM5D の処理の流れ。ハード閾値処理(左), ウィーナーフィルタリング(右)の2ステップからなる。

参照パッチに類似した4Dパッチを集めて5Dグループとし、まとめてノイズ除去す

$4 \times 4 \times N$, ウィーナーフィルタリングでは $5 \times 5 \times N$ とした。ここで, N は総フレーム数であり, 雑音の標準偏差 σ により平滑化の強さを調整する。

2) 計算機シミュレーション

本手法の有効性を確認するため、数値脳ファントムによるダイナミック $[^{18}\text{F}]\text{FDG}$ PET シミュレーションを行った。フレームを 4×30 秒, 4×40 秒, 4×60 秒, 4×180 秒, 14×300 秒に分割し, 総カウント 5×10^8 相当のポアソンノイズを付与した。

4) 健常ボランティアの PET 計測

浜松医科大学の倫理委員会の承認のもと $[^{11}\text{C}]\text{MeQAA}$ [3] を投与された健常ボランティアを頭部用 PET 装置 (Hamamatsu HITS-655000 [4]) にて計測した。フレーム分割は 4×30 秒, 20×60 秒, 8×300 秒とした。

3. 結果

図2に計算機シミュレーションにおけるピーク信号対雑音比(peak signal to noise ratio; PSNR), 構造化類似度(structural similarity measure; SSIM)の結果を示す。図3に冠状面における実験データの結果を示す。

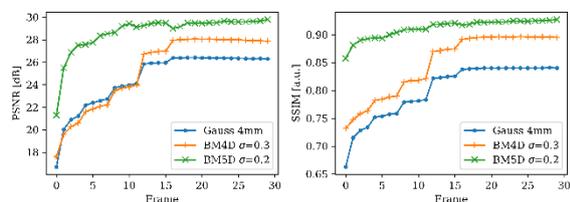


図2 シミュレーション結果。PSNR(左)と SSIM(右)。

4. 考察およびまとめ

本研究では, ダイナミック PET 画像のノイズ除去のために BM4D を時空間に拡張した BM5D を提案した。シミュレーション結果より, BM5D

は他手法と比較し, すべてのダイナミックフレームにおいて PSNR, SSIM が向上した。また, 実機での PET 計測においても同様の結果がえられた。これらの結果より BM5D のダイナミック PET 画像ノイズ除去の有効性が示唆された。

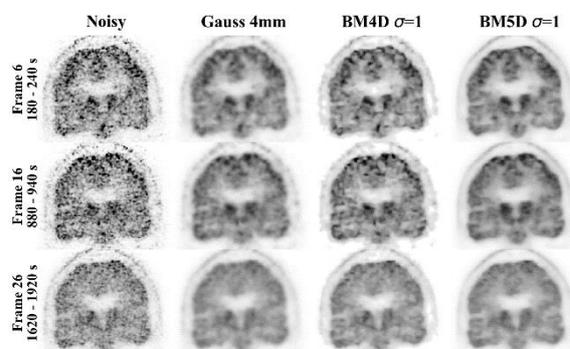


図3 冠状面における実験データの結果。左からノイズ, Gauss 4mm, BM4D $\sigma=1$, BM5D $\sigma=1$ 。

利益相反の有無 なし

文献

- [1] Dutta J, Leahy R M, Li Q: Non-local means denoising of dynamic PET images. PLoS ONE **8**: e81390, 2013
- [2] Maggioni M, Katkovnik V, Egiazarian K et al: A nonlocal transform-domain filter for volumetric data denoising and reconstruction. IEEE Trans Image Process **22**: 119-133, 2013
- [3] Nakaizumi K, Ouchi Y, Terada T et al: In vivo depiction of $\alpha 7$ nicotinic receptor loss for cognitive decline in Alzheimer's disease. J Alzheimers Dis **61**: 1355-1365, 2018
- [4] Watanabe M, Saito A, Isobe T et al: Performance evaluation of a high-resolution brain PET scanner using four-layer MPPC DOI detectors. Phys Med Biol **62**: 7148-7166, 2017

Image Denoising for Dynamic PET Scans Using a Block Matching and 5D Filter

Kibo OTE^{*1}, Fumio HASHIMOTO^{*1}, Akihiro KAKIMOTO^{*1}, Takashi ISOBE^{*1}, Tomoo INUBUSHI^{*1}, Aoi Tokui^{*1},
Etsuji YOSHIKAWA^{*1}, Tomohide OMURA^{*1}, Yasuomi OUCHI^{*2}

*1 Hamamatsu Photonics K.K.

*2 Hamamatsu University School of Medicine

Dynamic positron emission tomography (PET) scans are required to estimate the uptake of PET ligands quantitatively. Since such dynamic short-frame PET scans are noisy, we propose block matching and 5D filtering (BM5D) that extends BM4D to time space for accomplishing dynamic PET image denoising. The proposed algorithm is based on an enhanced sparse representation in transform domain. Sparsity is enhanced by grouping similar 4D patches of dynamic PET images (e.g., time-activity curves in a small volume) into an array of 5D data known as a “group.” Because of the similarity between the grouped patches, the transform of a 5D group can achieve a highly sparse representation of the true signal, and the noise can be well separated by shrinkage. We used both computer simulation data and experimental data comparing the methods with BM5D, Gaussian filter, and BM4D. In simulation, the proposed algorithm improved the peak signal to noise ratio, as well as the structural similarity measure, in all time frames, compared to the other methods. In computation of real experimental data, the proposed algorithm achieved best image quality among the three methods. The present results confirm that the proposed algorithm enables efficient denoising of dynamic PET images.

Key words: Image denoising, Image filtering, Image restoration, Positron emission tomography

Super-resolution of clinical CT volumes with modified CycleGAN using micro CT volumes

Tong ZHENG^{*1}, Hirohisa ODA^{*1}, Takayasu MORIYA^{*1},
Takaaki SUGINO^{*1}, Shota NAKAMURA^{*2}, Masahiro ODA^{*1},
Masaki MORI^{*3}, Hirotsugu TAKABATAKE^{*4},
Hiroshi NATORI^{*5}, and Kensaku MORI^{*1,6,7}

Abstract

This paper presents a super-resolution (SR) method with unpaired training dataset of clinical CT and micro CT volumes. For obtaining very detailed information such as cancer invasion from pre-operative clinical CT volumes of lung cancer patients, SR of clinical CT volumes to μ CT level is desired. While most SR methods require paired low- and high-resolution images for training, it is infeasible to obtain paired clinical CT and μ CT volumes. We propose a SR approach based on CycleGAN, which could perform SR on clinical CT into μ CT level. We proposed new loss functions to keep cycle consistency, while training without paired volumes. Experimental results demonstrated that our proposed method successfully performed SR of clinical CT volume of lung cancer patients into μ CT level.

Keywords : Super-resolution, Clinical CT, μ CT, CycleGAN, Unpaired learning

1. Introduction

Lung cancer causes largest number of deaths per year among cancers of male [1]. Currently, precise diagnosis of lung cancer mainly depends on clinical CT volumes. However, we could not obtain enough pathological information due to its low resolution. Super-resolution (SR) of clinical CT into μ CT-like level is desired.

Deep learning-based methods have been proved to outperform other methods in SR. These approaches are often supervised, requiring aligned pairs of low-resolution (LR) and high-resolution (HR) patches to train a model. However, it is infeasible to obtain spatially corresponding patch pairs of clinical CT and μ CT because registration between them is difficult. SR methods that can be trained by using unpaired images are desired.

*1 Graduate School of Informatics, Nagoya University [Furou-cho, Chikusa-ku, Nagoya 464-0814, Japan]
e-mail: tzheng@mori.m.is.nagoya-u.ac.jp

*2 Nagoya University Graduate School of Medicine

*3 Sapporo-Kosei General Hospital

*4 Sapporo Minami-sanjo Hospital

*5 Keiwakai Nishioka Hospital

*6 Information Technology Center, Nagoya University

*7 Research Center of Medical Bigdata, National Institute of Informatics

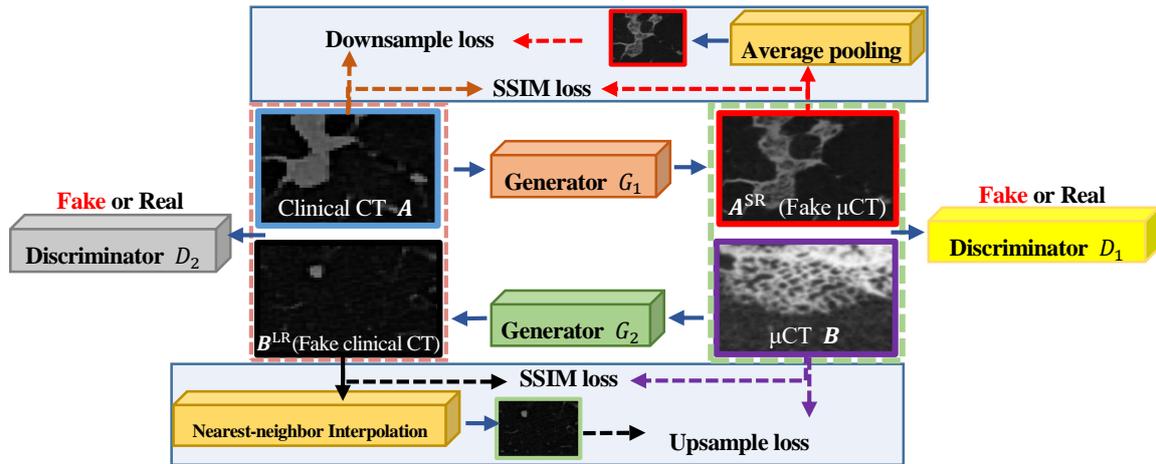


Figure 1 Network structure used for training. Compared to original CycleGAN, proposed method uses loss functions for maintaining cycle consistency. We calculate SSIM loss between A and A^{SR} , B and B^{LR} . Further, we calculate downsample loss between average-pooled A^{SR} and A , as well as upsample loss between B and upsampled B^{LR} .

One of the first approaches that formalizes the possibility to transpose from a source domain to a target domain in the absence of paired examples is called CycleGAN [2]. For instance, pictures of the zebra are converted into those of the horse. Nevertheless, CycleGAN is not designed for SR.

In this paper, we propose an SR method of clinical CT into μ CT-level by our modified CycleGAN. Unpaired clinical CT and μ CT volumes are used for training.

2. Overview

In prior to inference, training of the network is required using clinical CT and μ CT volumes. For inference, patches clipped from clinical CT volumes are input. In our study, scale of original μ CT volumes is at least 8-times larger than the clinical CT volumes. Because of this, we consider 8-times SR to be the most proper.

Input of our networks are 2D patches clipped from the volumes. The input clinical CT patch size is 32×32 pixels, while input μ CT patch size is 256×256 pixels.

1) Network Structure

Figure 1 shows the network structure of our proposed method. The first input is clinical CT patch A , and generator G_1 generates corresponding SR patch A^{SR} from A . Similar to CycleGAN, the generator G_1 is aimed to produce image patches that are similar to the ones in the target domain (μ CT domain) by trying to fool the discriminator D_1 . Vice versa, the same work is done upon μ CT patch B by using generator G_2 and discriminator D_2 to keep the consistency of proposed framework.

2) Loss functions

Like CycleGAN, our method uses cycle consistency while training the network. However, in SR problem, the cycle consistency between corresponding LR and SR image is different with that in image translation problem. In SR problem, corresponding LR and SR image are desired to have similarity in structure and average intensity, while the loss function

used in original CycleGAN could not obtain this.

Here we propose several loss functions in our pipeline to create the cycle consistency (blue blocks in Fig. 1). Without cycle consistency, the network would simply produce arbitrary patch in the target domain with no relationship to the structures contained in the input patch.

The first loss function we proposed to keep cycle consistency is downsample loss. It is defined to maintain similarity while transforming clinical CT volume to μ CT scale as

$$l_{\text{downsample}}(\mathbf{A}) = \text{MSE}(\mathbf{A}, f(\mathbf{A}^{\text{SR}})),$$

where $f()$ is an average pooling function, reducing the size of \mathbf{A}^{SR} to the same as \mathbf{A} , since \mathbf{A}^{SR} is SR patch, 8 times larger than \mathbf{A} . MSE is the mean squared error. Analogously, we name the second loss function the upsample loss as

$$l_{\text{upsample}}(\mathbf{B}) = \text{MSE}(\mathbf{B}, g(\mathbf{B}^{\text{LR}})),$$

where $g()$ is the nearest-neighbor interpolation function, upsampling the size of generated clinical-CT like \mathbf{B}^{LR} to the original size of \mathbf{B} .

Although the first and second loss function could keep the cycle consistency while training network, both loss functions depend on intensity differences between generated and target image patches, which is not very well matched to perceived visual quality. Here we propose third and fourth loss functions, which we name as clinical-SSIM loss and micro-SSIM loss

$$l_{\text{clinical-SSIM}} = \frac{1}{\text{SSIM}(\mathbf{A}, f(\mathbf{A}^{\text{SR}}))},$$

$$l_{\text{micro-ssim}} = \frac{1}{\text{SSIM}(\mathbf{B}, g(\mathbf{B}^{\text{LR}}))},$$

where SSIM is the structural similarity proposed in paper [3]. While training our model, third and fourth loss function helps protecting the model from generating blurred image patches.

3) Training

We perform training process using 2D clinical CT patches as input of Generator G_1 and 2D μ CT patches as input of Generator G_2 . Output of Generator G_1 is the generated μ CT-like SR patches. Discriminator D_1 is used to discriminate output of Generator G_1 is real or fake. Furthermore, for more stable training, we mixed downsampled μ CT patches in clinical CT patches as input. The percentage of downsampled μ CT patches is 25%.

4) Inference

For testing, we input 2D patch clipped from clinical CT volumes into the trained Generator G_1 . Output is a SR patch based on the input patch.

Table 1 Profiles of clinical CT and μ CT volumes

	μ CT	Clinical CT
pixels in one slice	1024×1024 pixels	512×512 pixels
number of slices	545~1082 slices	435~554 slices
size of each pixel	34~53 μ m	0.625mm
slide thickness	34~53 μ m	0.6mm

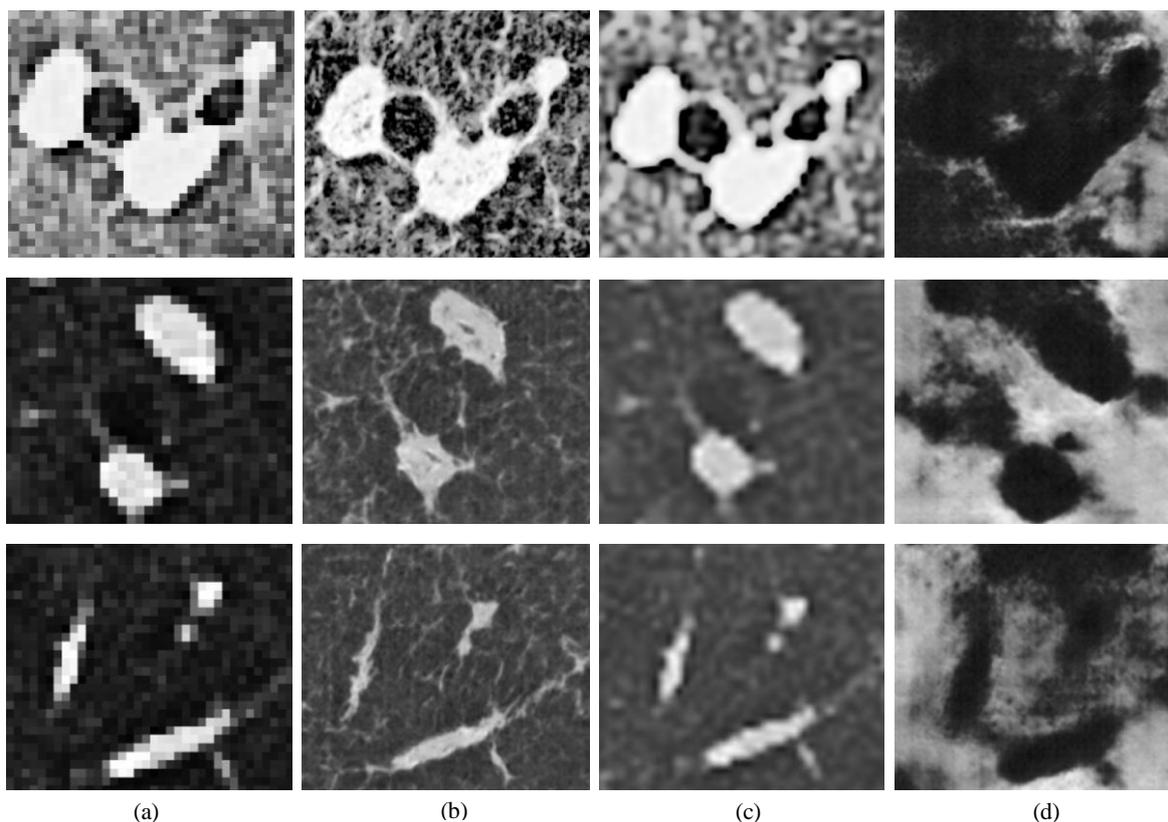


Figure 2 Example and comparison of proposed method. (a) original clinical CT, (b) proposed SR result, (c) bicubic interpolation, and (d) CycleGAN (without proposed loss functions).

3. Experiments and results

We utilized five lung cancer cases in the experiment. Clinical CT volumes were acquired by SOMATOM Definition flash (SIEMENS, Germany) from lung cancer patients. After surgical dissection of the lung cancers, μ CT volumes of the dissected specimens were acquired by a μ CT scanner, inspeXio SMX-90CT Plus (SHIMADZU, Japan). The profiles of clinical CT and μ CT volumes are listed in Table 1.

In our experiment, we used clinical CT and μ CT volumes obtained from same patients, meaning one patient has one clinical CT volume and one μ CT volume. We used 5 cases of clinical CT and μ CT for training in our experiment. The epoch number is 200. For testing, we used 1 case of clinical CT.

SR results of our proposed method were compared to bicubic-interpolation and original CycleGAN, as shown in Fig. 2. We could obtain more details from SR results than bicubic-interpolation results. Lung anatomies, such as the bronchus looks more clearly than bicubic-interpolation. Original CycleGAN's result has produced very different results from original clinical CT volumes.

4. Discussion and conclusion

We proposed a novel SR method with unpaired training dataset of clinical CT and micro CT volumes. New loss functions are introduced to keep cycle consistency in SR task. Experimental result showed that our method could apply

SR on clinical CT to μ CT level.

Because training of proposed method is unpaired, we do not have corresponding ground truth for certain input, quantitative evaluation of output result becomes difficult. Our future work is quantitative evaluation of SR results.

Competing interests

None.

Acknowledgement

Parts of this research was supported by MEXT·JSPS KAKENHI (26108006, 17H00867, 17K20099), the JSPS Bilateral International Collaboration Grants, the AMED18lk1010028s0401, the AMED19lk1010036h0001 and the Hori Sciences & Arts Foundation.

References

- [1] Vital Statistics Japan (Ministry of Health, Labour and Welfare)
- [2] Zhu J, Park T, Isola P, et al.: Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks. IEEE International Conference on Computer Vision: 2242-2251, 2017
- [3] Zhou W, Alan C, Hamid R, et al.: Image Quality Assessment: From Error Visibility to Structural Similarity. IEEE Trans Image Processing **13**: 600-612, 2004

μCT を用いた改良版 Cycle-GAN による臨床用 CT 像の超解像処理

鄭 通^{*1}, 小田 紘久^{*1}, 守谷 享泰^{*1}, 杉野貴明^{*1}, 中村 彰太^{*2}, 小田 昌宏^{*1},
森 雅樹^{*3}, 高島博嗣^{*4}, 名取 博^{*5}, 森 健策^{*1,6,7}

*1 名古屋大学大学院情報学研究科

*2 名古屋大学大学院医学系研究科

*3 札幌厚生病院

*4 札幌南三条病院

*5 恵和会西岡病院

*6 名古屋大学情報基盤センター

*7 国立情報学研究所医療ビッグデータ研究センター

本稿では、臨床用 CT 像の超解像手法を提案する。肺がん症例の臨床 CT 像から腫瘍の浸潤状況など疾患に関する情報を取得するため、肺臨床 CT に超解像を適用し、μCT レベルの解像度を得る手法が求められている。多くの超解像手法における教師あり学習では、対応関係のある低解像度と高解像度の画像ペアが必要となるが、臨床 CT と μCT の画像ペアは正確に位置合わせを行うことが困難である。我々は CycleGAN を改良し、臨床用 CT 像と μCT 像間の相互変換において一貫性を保持するための新しい損失関数を導入することによって、ペアなしの超解像手法を実現する。実験の結果、臨床 CT 像の μCT レベルへの超解像が可能であった。

キーワード：超解像, 臨床 CT, μCT, CycleGAN, ペアなし学習

視覚情報提示による頭部 PET 体動抑制手法の開発

鈴木 海斗*¹ 岩男 悠真*² 高橋 美和子*² 山谷 泰賀*^{2,3}

要旨

近年、頭部 PET 装置の開発が進むなど PET の高解像度化が進む中、体動による画質劣化への関心が高まっている。バンド等を用いて物理的に被験者を拘束することはあまり望ましくはない。画像再構成時に体動を補正する手法が報告されているが、既存装置への組み込みが困難であるため実用化は進んでいない。そこで、本研究では、非拘束かつ撮像システムに依存しない体動抑制法の開発を目的とした。具体的には、Kinect を用いて被験者の体動を計測し、体動をリアルタイムに可視化することで被験者自らが体動を抑制できるシステムを開発した。実際の頭部の体動の特性を分析し、認識が容易な体動の可視化手法についての検討を行うことでシステムを改良し、システムの有効性を複数の被験者を対象としたボランティア試験により検証した。結果として開発システムにより体動の標準偏差が 50.1%と大きく抑制できることを確認した。

キーワード：体動抑制，頭部 PET

1. 研究背景

近年開発された新しい Positron emission tomography (PET)用標識薬剤により、アルツハイマー病をはじめとする認知症診断に有効なタウタンパクやアミロイドβといった物質の可視化が可能となった[1]。こうした背景のもと、脳に特化した頭部専用 PET 装置が求められていることから、放射線医学総合研究所（放医研）では半球形の検出器配置を特徴とする図1のようなヘルメット型 PET の開発に取り組んできた[2]。

座位姿勢での測定が可能なヘルメット型 PET では、仰臥位で測定する一般的な全身用 PET に比べ、日常の生活状態に近い体制での

PET 検査が可能になるほか、装置小型化などのメリットもあると期待される。

また、空間分解能は逐次近似画像再構成法で約 1.4mm であり、2~3mm 解像度の全身用市販 PET 装置と比較して優れた性能を持つことが示されている。一方で座位による測定でも、被験者の頭部の動きを十分に抑制できるかどうかはまだ明らかになっていない。被験者の体動は、画質の大幅な低下に繋がるためできる限り抑制する必要がある。

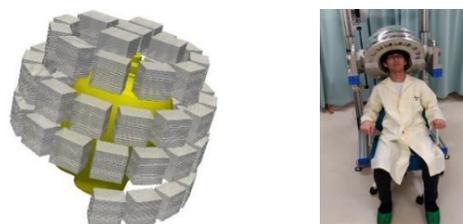


図1 放医研が開発したヘルメット PET

*1 千葉大学大学院融合理工学府

〔〒263-8522 千葉市稲毛区弥生町 1-33〕

e-mail: k.suzuki@chiba-u.jp

*2 国立研究開発法人量子科学技術研究
開発機構放射線 放射線医学総合研究所

*3 千葉大学 フロンティア医工学センター

投稿受付：2019年5月15日

2. 研究目的

本研究では、座位スタイルでの測定を行う頭部 PET の体動を抑制するシステムについての検討を行う。具体的には、非接触かつ PET 機器とは完全に独立した構成の体動抑制シス

テムの開発し、被験者の体動を可視化して提示することで、被験者自らが体動を抑制可能な手法の検討を行う。

3. 提案手法

本研究では、被験者の体動を Kinect により取得し、体動の情報を可視化して画面に表示して被験者自らが画面を見ながら頭部位置を調整可能なシステムを構築した。システム要件として、リアルタイムに体動を取得・可視化が可能なこと、およびヘルメット型 PET 装置の空間分解能を許容量の目安として平行移動は 2mm、回転量は 2 度以内の精度に体動を抑えることを目標とした。頭部位置の計算をリアルタイムに行うため本研究では Kinect SDK による人体トラッキング機能を用いた。C++、.NET Framework、および OpenGL を用いたシステムを開発した。

4. 実験

本システムを使用した場合と使用しない場合の対象実験（20 分間）によって体動の変化があるかどうかを検証した。実験の結果、表 1 のように提案システムの効果が認められる結果が得られた。また、本実験での x,y,z 軸の方向は図 2 の通りである。

表 1 システムの有無による体動の差

体動の平均±SD	平行移動[mm]	回転[度]
システムあり	1.85±0.94	1.41±0.61
システムなし	12.98±4.21	5.22±1.86

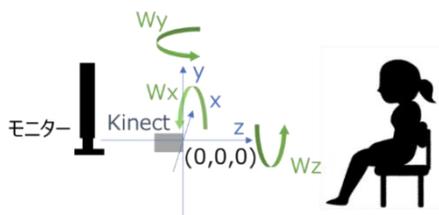


図 2 提案システム概要と軸の定義

本システムでは 3 軸に対しての移動量と回転の 6 パラメータを一画面に表示しており、被験者が慣れるまで時間がかかったため、表示するパラメータを減らすことを検討するため再実験を行った。被験者の体動を 6 パラメータごとに測定し、主成分分析を行ったところ図 3 ような結果が得られた。各パラメータの軸は先ほどの実験と同様である。このことから x 軸と z 軸が独立に大きな体動をしていると考えられる。

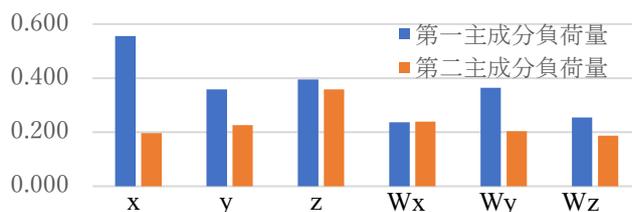


図 3 主成分分析の結果

5. まとめ

体動を可視化する提案システムによって頭部体動を抑える方法のコンセプト実証に成功した。今後は、可視化表示する情報を絞り込むことで、利用者が理解しやすい動き情報提示方法を検討していく予定である。

利益相反の有無
なし

文献

- [1] Maruyama, M., et al., Imaging of tau pathology in a tauopathy mouse model and in Alzheimer patients compared to normal controls. *Neuron*, 79, 1094—1108, 2013
- [2] Tashima, H. et al., "Development of the Helmet-Chin PET Prototype", IEEE NSS-MIC 2015 M3CP-97, 2015.

Development of the motion suppress system using the visual information for head dedicated PET measurement

Kaito SUZUKI*¹, Yuma IWAO*², Miwako TAKAHASHI*², Taiga YAMAYA *^{2,3}

*1 Chiba University Graduate School of Science and Engineering

*2 National Institutes for Quantum and Radiological Science and Technology –QST

*3 Chiba University Center for Frontier Medical Engineering

In head PET devices that are currently attracting attention, one of the issues is to prevent deterioration of the acquired image due to body movement.

Conventional methods include a method of physically constraining a subject using like a band , and a method of correcting body movement at the time of image reconstruction. However, the current situation is that many problems remain because of the increased burden on subjects and the difficulty of incorporating into existing equipment. So, in this research, we study for the purpose of development of the motion suppression method which does not depend on the imaging system. Specifically, we developed a system that can control the motion of the subject by acquiring the motion of the subject using Kinect and visualizing the motion in real time.

We analyzed the characteristics of human motion in the human head and examined the method of visualizing the motion that was easy to recognize, and verified the effectiveness of the system by a volunteer test for multiple subjects. As a result, it was confirmed that the standard deviation of body movement can be suppressed to 50.1% by the development system.

Key words:Motion suppress, head dedicated PET

著者紹介

鈴木 海斗 (すずき かいと)

2019年千葉大学工学部メディカルシステム工学科卒。現在、千葉大学大学院融合理工学府基幹工学専攻医工学コース博士前期課程在籍。

岩男 悠真 (いわお ゆうま)

2015年 横浜国立大学大学院環境情報学府・博士後期課程修了。2015年より放射線医学総合研究所・博士研究員、2018年より同研究所研究員、現在に至る。博士(情報学)。医用画像処理に関する研究に従事。

高橋 美和子 (たかはし みわこ)

2008年 東京大学大学院医学系研究科 博士課程修了、2008年東京大学医学部附属病院助教、2014年同講師、2018年放射線医学総合研究所・主幹研究員。臨床PET研究に従事

山谷 泰賀 (やまや たいが)

2000年東京工業大学(東工大)大学院物理情報工学専攻博士課程修了。放射線医学総合研究所(放医研)ポスドク、東工大助手を経て、2004年より放医研研究員。2009年よりチームリーダー。専門は医用画像工学。特にPETイメージング機器開発の研究に従事。

静止型 SPECT システムを用いた心筋画像再構成

藤代 鷹平*¹ 村田 一心*² 本村 信篤*³ 尾川 浩一*²

要旨

マルチピンホールコリメータを装着した SPECT システムは、検出器を回転させることなく多方向から検出器へ進入するガンマ線の飛来方向を推定可能であり、静止型 SPECT システムとして使用できる。静止型 SPECT システムを用いた心筋画像再構成における問題点は、データ収集角度が一定程度限定されること、肝臓等の他の臓器による散乱線の影響、高集積臓器によるストリークアーチファクトなどである。本研究では、静止型 SPECT におけるこれらの問題点を検討するために、モンテカルロ法による光子輸送計算を用い、臨床に近い状態で収集された投影データを作成し、心筋画像の評価を行なった。ファントムは DMCAT ファントムを用い、3 検出器 (11 ピンホールコリメータ) のジオメトリを想定し、画像再構成には ML-EM 法を用いた。この結果、3 個の検出器を 1 回だけ 60 度だけ回転したデータ収集では、ピンホール投影データには散乱線が含まれるものの、臨床上使用可能と思われる画像を得ることができた。

キーワード：心筋 SPECT イメージング、マルチピンホールコリメータ、モンテカルロシミュレーション、DMCAT ファントム

1. はじめに

心疾患は世界的な死因の一つであり [1]，医用画像処理技術の飛躍的な発展は心疾患の診断精度向上に大きく貢献している。心疾患の診断方法としては、機能評価に優れている SPECT が用いられている。近年 SPECT においては、複数のガンマカメラにコリメータを装着することで、検出器を回転させる必要がない静止型 SPECT システムが開発されている。静止型 SPECT システムは、検出器を回転させる必要がないため、データ収集時間の短縮やシステム時間分解能の向上による動態機能イメージングが期待されている。

静止型 SPECT システムを用いた心筋画像再構成における問題点は、データ収集角度が限定されること、肝臓等の他の臓器による散乱線の影響、高集積臓器によるストリークア

ーチファクトなどによる心筋再構成画像の定量性の低下である。

本研究では、静止型 SPECT システムによる心筋画像再構成のシミュレーションを行い、心筋画像の評価を行なった。

2. シミュレーション方法

本研究では、キヤノンメディカルシステムズから販売されている 3 検出器型 SPECT システム GCA9300R を想定している。GCA9300R を静止型 SPECT システムとして使用するために、マルチピンホールコリメータ (11 ピンホールコリメータ) を装着した。これにより、多方向から検出器へと進入してくるガンマ線の飛来方向を推定可能なシステムを構築した。

そして、静止型 SPECT システムで取得した心筋再構成画像が临床上使用可能かどうかの検討を行うために、3 次元 DMCAT ファントムを用いてシミュレーションを行なった。3 次元 DMCAT ファントムは、1 秒を 1 周期として 16 位相の画像で構成されている。図 1 は第 1 位相における 3 次元 DMCAT ファントムの画像である。また、光子輸送計算およ

*1 法政大学大学院理工学研究科

〔〒184-8584 小金井市梶野町 3-7-2〕

e-mail: yohei.fujishiro.7m@stu.hosei.ac.jp

*2 法政大学理工学部

〔〒184-8584 小金井市梶野町 3-7-2〕

*3 キヤノンメディカルシステムズ株式会社

び画像再構成には研究室内ソフトウェアを用いて行なった。

次に、光子輸送計算および画像再構成で用いたジオメトリを図 2 に示す。回転中心からコリメータまでの距離は 300 mm、コリメータから検出器表面までの距離は 76 mm とした。再構成画像は 64×64×64 ボクセル (ボクセルサイズ: 6.25×6.25×6.25 mm³)、検出器は 256×512 ピクセル (ピクセルサイズ: 0.8×0.8 mm²)、エネルギー分解能 10% FWHM @ 140 keV、固有空間分解能 4 mm FWHM とした。Triple Energy Windows 法 [2] を用いた散乱線除去を行うために、メインウィンドウを 126~154 keV、サブウィンドウを 119~133 keV と設定した。シミュレーションにおけるデータ収集は心電同期を想定しており、3 検出器を一度だけ回転させることで 6 角度位置のデータ収集を行なった。

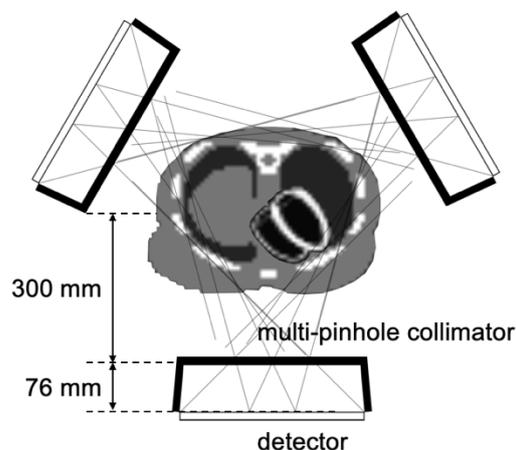


図 2. シミュレーションジオメトリ

画像再構成には逐次近似再構成手法の 1 つである ML-EM 法 [3] を適用し、繰り返し回数は 100 回とした。データ補正として散乱線補正、吸収補正、コリメータ開口補正 [4]、感度補正 [5] を適用した。また、後処理として、フィルタ次数 2 遮断周波数 20/64 のバターースフィルタを再構成画像にかけている。

3. 結果

第 1 位相の原画像と心筋再構成画像を図 3 に、そのプロファイルを図 4 に示す。プロファイルは、図 3 に示す矢印の位置で計算した。

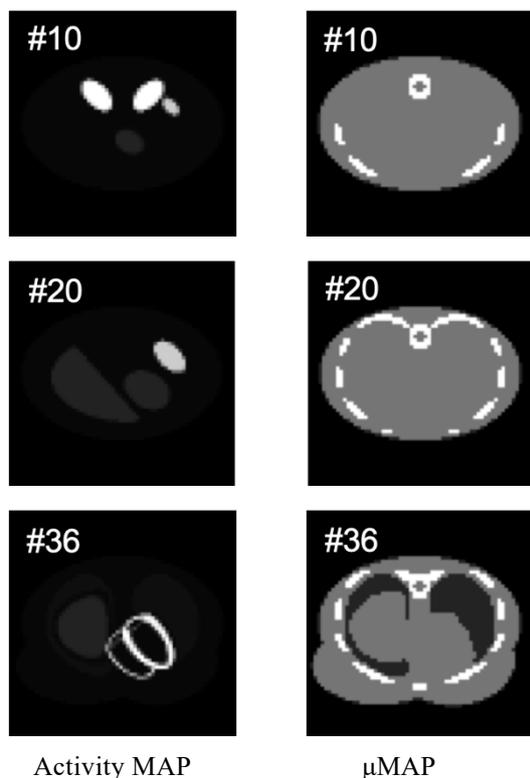


図 1. 3次元 DMCAT ファントム

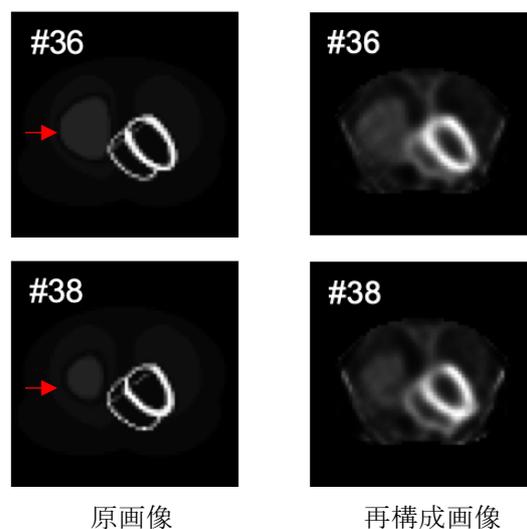


図 3. 第 1 位相の原画像と再構成画像

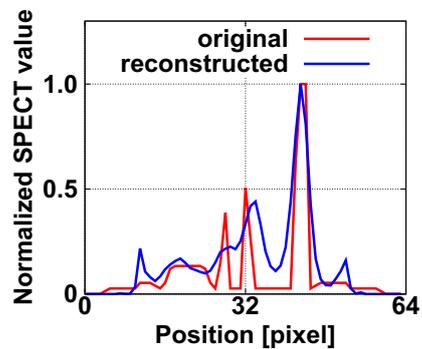
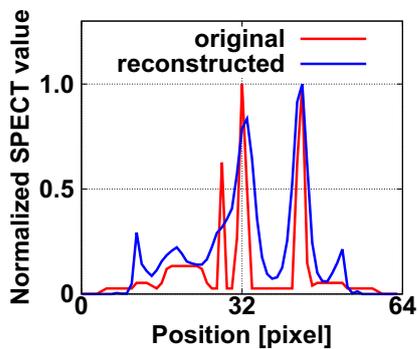
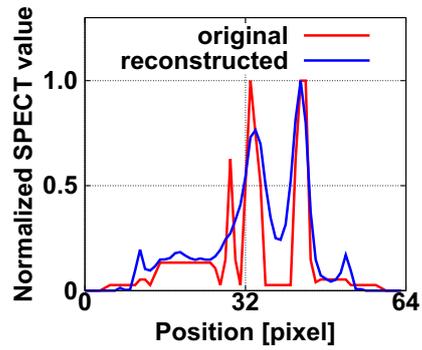
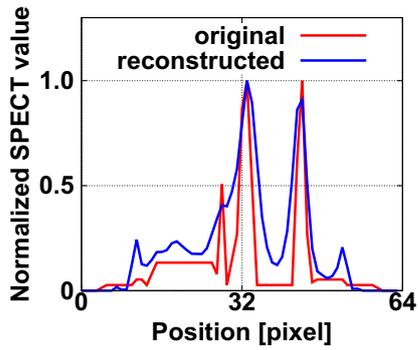


図 4. 第 1 位相の原画像と再構成画像のプロファイル (上: #36, 下: #38)

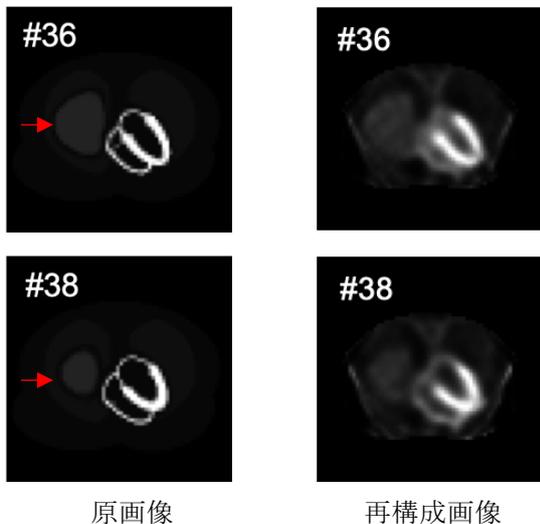
図 6. 第 8 位相の原画像と再構成画像のプロファイル(上: #36, 下: #38)

次に、第 8 位相の原画像と心筋再構成画像を図 5 に、そのプロファイルを図 6 に示す。プロファイルは、図 5 に示す矢印の位置で計算した。

4. 考察

図 4 と図 6 から、心電同期を想定して取得した投影データによる再構成画像は原画像の特徴を再現できていることがわかる。これは、マルチピンホールコリメータを装着した 3 検出器型 SPECT システムを一度だけ回転させることを許せば再構成するのに十分な投影データを得られるのではないかと考えられる。

また、図 3 と図 5 の再構成画像の両端に直線状のアーチファクトが見受けられる。これは、3 つの検出器が正三角形の形で固定されているため、アーチファクトが生じたと考えられる。このアーチファクトを除去するためには、回転中心からコリメータまでの距離を離して再構成空間を大きくするという方法が考えられるが、この方法は再構成画像の空間分解能が低下してしまうというデメリットがある。



原画像 再構成画像
図 5. 第 8 位相の原画像と再構成画像

5. まとめ

本研究では、3 検出器型 SPECT システムにマルチピンホールコリメータを装着した SPECT システムを一度だけ回転させて 6 角度位置データ収集することで、心筋画像再構成を行なった。その結果、比較的アーチファクトが少なく臨床上使用可能と思われる心筋再構成画像を得ることができた。

利益相反

本研究の一部はキヤノンメディカルシステムズ株式会社の研究費を受けて実施された。

謝辞

本研究は、文部科学省科学研究費補助金、基盤研究 (C) 19K12849 による助成を受けた。

文献

- [1] Choi S, Kim H, Oh J, et al.: Segmentation of the left ventricle in myocardial perfusion SPECT using variational level set formulation. IEEE Nucl Sci Symp, 3060-3064, 2007
- [2] Ogawa K, Harata Y, Ichihara T, et al.: A practical method for position dependent Compton-scatter correction in single photon emission CT. IEEE Trans Med Imag **10**: 408-412, 1991
- [3] Shepp L. A, Vardi Y: Maximum likelihood reconstruction for emission tomography. IEEE Trans Med Imag **1**: 113-122, 1982
- [4] Andreyev A, et al.: Pinhole SPECT reconstruction using blobs and resolution recovery. IEEE Trans Nucl Sci **53**: 2719-2728, 2006
- [5] Jansen FP, et al.: Uniformity correction using non-uniform floods. IEEE Nucl Sci Symp Conf Record (NSS/MIC), 2314-2318, 2010

Myocardial image reconstruction using a stationary SPECT system

Yohei FUJISHIRO^{*1}, Kazumi MURATA^{*2}, Nobutoku MOTOMURA^{*3}, Koichi OGAWA^{*2}

*1 Graduate School of Engineering, Hosei University

*2 Faculty of Science and Engineering, Hosei University

*3 Canon Medical Systems

A gamma camera equipped with a multi-pinhole collimator can acquire photons that enter a detector with many different angles, and so it is able to establish a stationary SPECT system with several gamma cameras. However, if we apply this system for the myocardial imaging, there are some issues such as limited angles, scattered photons emitted from surrounding organs, streak artifacts due to highly accumulated organs, etc. In this study, we evaluated the feasibility of the stationary SPECT system for the myocardial imaging with a 3D-DMCAT phantom. We assumed the geometry consisted of a triple head gamma camera with multi-pinhole collimators. And the ML-EM algorithm was used to reconstruct an image. In addition, we performed an attenuation correction, scatter correction, and efficiency correction of pinholes. The simulation results showed that we could reconstruct myocardial images with reasonable quality when we rotated three detectors once by 60 degrees.

Key words: myocardial SPECT imaging, multi-pinhole collimator, Monte Carlo simulation, DMCAT phantom

マルチ CNN による MRI 画像におけるノイズ低減

金子 幸生*¹ 野口 喜実*¹ 尾藤 良孝*² 荻野 昌宏*¹

要旨

MRI (核磁気共鳴撮像装置) は、頭部をはじめ様々な部位の検査に用いられているが、撮像時間が長い点が課題である。近年、撮像時間の短縮に関する研究が進んでおり、画像再構成に対して畳み込みニューラルネットワーク (CNN) を適用する研究が注目されている。本研究では、MRI 撮像の高速化を目指して、少数の計測データから再構成された低画質画像に対するノイズ低減について検討を行った。MRI 装置を用いて通常撮像および撮像時間を 1/2 とした撮像実験を行い、撮像画像データから約 90,000 枚の学習パッチを作成した。学習パッチに含まれる輝度情報の特徴を基にサブセットに分類し、各サブセットに対してネットワークを作成した。撮像時間 1/2 の画像を領域分割し、各領域ごとに最適なネットワークを選択し、画像を出力した。結果、単一 CNN の場合と比べ、本手法では PSNR が約 0.5 dB 向上し、ノイズ低減効果を確認した。

キーワード：MRI, 画像再構成, 高画質化, CNN

1. はじめに

MRI (Magnetic Resonance Imaging: 核磁気共鳴撮像装置) は、頭部をはじめとして様々な部位の検査に用いられているが、撮像時間が長い点が課題である。MRI 撮像における高速撮像技術としては、各受信コイルの k 空間データと受信コイルの感度分布の違いを利用する Parallel Imaging[1]や、近年では、k 空間信号を間引いて計測し、未計測信号を復元する Compressed Sensing[2]のような手法の開発が進んでいる。しかし、Compressed Sensing では、繰り返し最適化処理に時間がかかる課題がある。

その中、Deep Learning を用いた画像処理技術の研究が急速に進んでいる[3]。画像処理でよく用いられる CNN (Convolutional Neural Network)

は多数のフィルタ処理で構成されている為、繰り返し処理が不要で、GPU (Graphical Processing Unit) 等の並列計算に適用しやすく、高速な処理が期待できる。

これらの状況を踏まえ、本報告では、MRI 検査のスループット向上を目的とし、Deep Learning を用いた画像処理技術として、MRI 画像の高速撮像時における高画質化に関する検討を行った。具体的には、3T MRI 装置においてルーチンで撮像されている画像を基準として、撮像時間を 1/2 に減らした高速撮像法により低画質画像を取得し、Deep Learning を用いることにより画質改善効果が得られるか確認した。また、さらなる画質改善を目指し、複数の CNN を用いた学習によるノイズ低減方法について検討した。

2. 方法

はじめに、3T MRI 装置を用いた健常ボランティア撮像実験により、学習用のデータを取得した。具体的には、頭部ルーチン撮像 (T2 強調画像)、および Parallel Imaging による高速撮像を行った。Parallel Imaging では、k 空間上の信号を特定の間隔で間引いて複数受信コイルで

*1 株式会社 日立製作所 研究開発グループ

〔〒185-8601 東京都国分寺市東恋ヶ窪 1 丁目 280 番地〕

e-mail: yukio.kaneko.zy@hitachi.com

*2 株式会社 日立製作所 ヘルスケアビジネスユニット

同時に計測する。今回は、 k 空間データを $1/2$ に間引き、撮像時間を $1/2$ とした高速撮像の場合について検討した。

次に、学習データ用の画像からパッチの切り出しを行った。今回は、画像 1 枚当たり 512×512 の画素サイズに対し、 32×32 のサイズのパッチを複数枚取得した。結果、学習用データセットとして 92928 パッチ、バリデーションデータセットとして 49152 パッチを作成した。

作成したパッチを入力として、SRCNN (Super-Resolution Convolutional Neural Network) による学習を行った。さらに、本報告では、学習パッチに含まれる輝度情報の特徴を基にサブセットに分類し、各サブセットに対してネットワークを作成した[4]。(以下、マルチアダプティブ CNN 再構成 (Multi-Adaptive Convolutional Neural Network Reconstruction : MA-CNNR) と呼ぶ。) 図 1 に MA-CNNR の構成図を示す。なお、今回は学習パッチを 2 つに分類し、2 つのネットワークを作成した。

最後に、撮像時間 $1/2$ の画像を領域分割し、各領域ごとに最適なネットワークを選択した上で、推定画像を出力し、ノイズ低減効果を検討した。

なお、本研究のボランティア撮像データは、(株) 日立製作所研究開発グループで定める倫理審査基準に則り審査され、すべての被験者からインフォームド・コンセントを得た上で取得された。

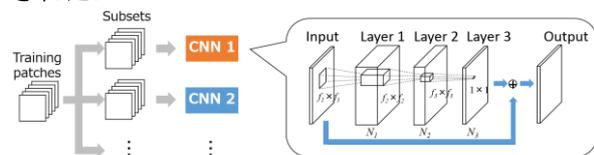


図 1 MA-CNNR の構成図

3. 結果

図 2 に、単一 CNN を用いた場合の結果を示す。(b) の高速撮像時の画像に比べ、(c) の方が画像のざらつきが減っていることがわかる。また、(d) と比べ、(e) の方が (a) の正解画像 (ルーチン撮像) との差が小さくなっており、CNN によりノ

イズ低減されていることがわかる。さらに、単一 CNN の場合と比べ、MA-CNNR では PSNR で約 0.5 dB 向上し、MA-CNNR によるノイズ低減効果の向上を確認した。

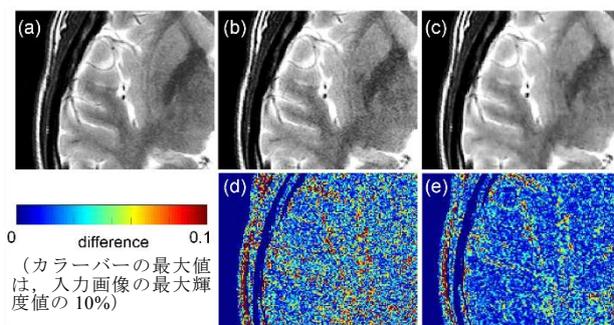


図 2 ノイズ低減結果。(a)正解画像 (ルーチン撮像)、(b)高速撮像画像、(c)CNN による推定画像、(d)(a)と(b)の差分画像、(e)(a)と(c)の差分画像。

4. まとめ

MRI 検査のスループット向上を目的とし、複数 CNN によるノイズ低減技術を開発した。結果、単一 CNN の場合と比べ、MA-CNNR においてノイズ低減効果が高くなり、MA-CNNR による MRI 画像の高画質化の可能性が示唆された。

利益相反の有無

著者は株式会社日立製作所の社員である。

文献

- [1] Pruessmann KP, et al., SENSE: Sensitivity Encoding for Fast MRI. *Magnetic Resonance in Medicine* 42:952-962, 1999.
- [2] Lustig, M et al., Sparse NRU: The Application of Compressed Sensing for Rapid MR Imaging. *Magnetic Resonance in Medicine* 58: 1182-1195 2007.
- [3] Bo Z et al., Image reconstruction by domain-transform manifold learning, *NATURE* 555(7697), 487-492, 2018.
- [4] 野口 喜実他, クラスタリングに基づく CNN 選択による MRI 高画質化の検討, OP2-8, JAMIT, 2018.

Noise Reduction for MRI by Using Multi-CNN

Yukio KANEKO*¹, Yoshimi NOGUCHI*¹, Yoshitaka BITO*², Masahiro OGINO*¹

*1 Research and Development Group, Hitachi, Ltd.

*2 Healthcare Business Unit, Hitachi, Ltd.

One of the issues for MRI (Magnetic Resonance Imaging) is long scanning time. Recently, the deep learning techniques for high-speed or high-quality scanning in MRI have been reported. The purpose of this study is the development of the noise reduction technique for high-speed scanning in MRI by using deep learning. First, we conducted the volunteer study by MRI system. The routine images were obtained as high quality images, and the under-sampling images by using parallel imaging (scanning time is 1/2) were obtained as low quality images. The CNN (Convolutional Neural Network) was constructed with these images. In this study, we developed MA-CNNR (Multi-Adaptive CNN Reconstruction) technique, and training patches were divided into several subsets, according to the characteristics of intensity distribution in each patch. In this study, two CNNs were trained by using two subsets. We evaluated the effect of noise reduction in the cases of conventional CNN and MA-CNNR. It was demonstrated that MA-CNNR contributes to noise reduction in the low quality images by parallel imaging more than conventional CNN. PSNR (Peak Signal to Noise Ratio) increased by 0.5 dB in the case of MA-CNNR. It is shown that MA-CNNR technique can contribute to improving image quality for high-speed scanning.

Key words: MRI, Image Reconstruction, High Image Quality, CNN

全身撮影可能な立位 CT の開発：

ファントムスタディ，人体に対する重力の影響

横山 陽一*¹ 山田 祥岳*¹ 名倉 武雄*² 中原 健裕*¹

成田 啓一*¹ 山田 稔*¹ 南島 一也*³ 荻原 直道*⁴ 陣崎 雅弘*¹

要旨

【目的】①立位 CT の物理特性の評価，②大血管と骨盤底への重力の影響を評価すること。【方法】ファントムを用いて立位 CT と臥位 CT，それぞれの物理特性の評価を行った。健康人ボランティアを対象に立位 CT と臥位 CT を同日に施行，大静脈と大動脈の面積と骨盤底の変化を評価した。【結果】立位 CT と臥位 CT 両者の物理特性に有意差は見られなかった。仰臥位と比較して直立位では，上大静脈の面積は有意に小さく，横隔膜の高さでの下大静脈の面積に有意差は見られず，下大静脈下端部での面積は有意に大きくなった。一方，大動脈の面積に関しては姿勢による有意差は見られなかった。骨盤底は直立位で下降した。

【結論】立位 CT と臥位 CT の性能はほぼ同等であり，立位 CT は，人体に対する重力の影響を評価するのに有用であった。

キーワード：臥位 CT，立位 CT，人体に対する重力の影響の可視化，大血管・骨盤底への重力の影響

【背景】

人間の臓器・解剖学的構造は重力の影響を大きく受け，多くの疾患や症状は姿勢によって変化することが知られている。現在 CT は多くの疾患の診断に活用されている。しかし，1972 年に開発されて以来現在に至るまで，臥位撮影のみ行われてきた。人は基本的に立位や座位で活動しており，これらの姿勢における多くの病態や身体機能の評価が CT で行えていなかった。こうした現状を打破すべく産学共同で立位 CT の開発を行い，2017 年に当院に第一号機が導入された。これまで US による仰臥位と側臥位での下大静脈の変化を検討した報告や，MRI による臥位と座位での骨盤底の位置の違いを検討した報告はあるが，我々が知る限り，立位と臥位での大血管径の違いや骨盤底の位置の違いについての論文報告はない。

*1 慶應義塾大学医学部放射線科学教室
(診断)

*2 慶應義塾大学医学部整形外科学教室

*3 慶應義塾大学病院放射線技術室

*4 慶應義塾大学理工学部機械工学科

【目的】①立位 CT の物理特性の評価，②大血管と骨盤底への重力の影響を評価することであった。

【方法】

1. 今回使用した撮像装置の詳細を示す。立位 CT として，TSX-401R，臥位 CT として，Aquilion ONE Vision edition を用いた。いずれもキヤノンメディカルシステムズ社製であり，ガント

リ一回転速度は 0.275 秒/回転, 320 列 (16cm 幅) の面検出器を備えている。これらの撮像装置を用いて物理評価用ファントムおよび健常人ボランティアを撮像した。

2. 物理評価用ファントムは Catphan 504 phantom

(The Phantom Laboratory 社製) を用いた。このファントムは CTP528, CTP486, CTP404 の 3 つのモジュールから構成されている。CTP528 を用いて x-y 平面および z 軸方向の変調伝達関数 (MTF: modulation transfer function) を解析し空間分解能を評価した。CTP486 を用いて一平面のノイズパワースペクトラム (NPS: noise power spectrum) を解析しノイズ特性を評価した。CTP404 を用いて CT 値を解析した。前述のファントムを立位 CT および臥位 CT で撮像した。正確度を向上させるため、立位 CT および臥位 CT の各々で同じスキャン位置で 5 回撮像を行った。

3. 健常人ボランティア撮像の詳細を示す。対象は 30 代から 60 代の各年齢層男女 4 名ずつ、計 32 名の無症候性ボランティアとした。倫理委員会によって承認され、被験者全員より書面による同意を得た。全身の正常な解剖学的構造を評価するために、喫煙歴、糖尿病、高血圧、高脂血症などの疾患や手術既往を有している場合、対象から除外された。被験者は同日に立位 CT と臥位 CT を撮像された。撮像条件は管電圧: 120kVp, ガントリ一回転速度: 0.5 秒/回転, 80 列, ノイズインデックス: 頭部 CT は SD4 for 5mm, 体幹部 CT は SD 15 for 5mm, ヘリカルピッチ: 頭部 CT は 51, 体幹部 CT は 65 とした。取得された立位・臥位 CT 画像に関して下記項目を測定した。

① 大血管の断面積と扁平率 $[(長径-短径)/(長径)]$ を測定した。測定部位は以下の 6 つの部位である。

大静脈:

- (1) 腕頭静脈合流部直下の上大静脈
- (2) 横隔膜貫通部高位の下大静脈
- (3) 下大静脈下端部 (総腸骨静脈合流部頭側の部位)

大動脈:

- (1) 上行大動脈 (Sinotubular junction: ST junction 高位)
- (2) 横隔膜貫通部高位の大動脈
- (3) 腹部大動脈下端部 (総腸骨動脈分岐部頭側の部位)

② 骨盤底の計測項目

- (1) 膀胱頸部から恥骨尾骨線 (PC line) までの距離
- (2) 肛門直腸接合部 (Anorectum junction) から恥骨尾骨線 (PC line) までの距離

① は最初に心臓血管放射線科医に、②は最初に泌尿生殖器放射線科医によって 32 名分の計測が行われた。①、②ともに最初の測定の数ヶ月後に、同じ計測者と一般放射線科医によって 16 名分の計測が行われた。いずれもランダム化された状態で計測を行い、観察者間・観察者内一致率の評価も行った。

4. 統計解析に関しては下記の通りである。

①血管の断面積と扁平率、②骨盤底の計測項目の立位と臥位における測定値の変化はウィルコクソンの符号順位検定を用いて評価した。

②の骨盤底の計測項目における男女間の差に関してはマン・ホイットニーの U 検定を用いて評価した。全ての計測データは市販の統計解析ソフトウェア (SPSS ver.24, IBM 社) を用い、P 値 0.05 未満 (両側) を有意とし、観察者間および観察者間一致率は、級内相関係数 (ICC) で評価した。

【結果】

1. ファントムスタディ

立位 CT のノイズ特性と空間分解能は、臥位 CT と同等であった。立位 CT の平均 CT 値は、臥位 CT と同様に、正確であった。

2. 健常人ボランティア撮像

①大血管の断面積と扁平率

被験者の平均年齢は 48.4 ± 11.5 歳 (30-68 歳)、平均の BMI は、 $22.5 \pm 3.0 \text{kg/m}^2$ ($16.7-30.6 \text{kg/m}^2$) であった。立位では臥位と比較して、上大静脈の断面積は 80%減少し (39.9 ± 17.4 対 $195.4 \pm 52.2 \text{mm}^2$, $P < 0.001$)、下大静脈下端部では 37%増大した (346.6 ± 96.9 対 $252.5 \pm 93.1 \text{mm}^2$, $P < 0.001$)。扁平率は上大静脈では 56%増大した (0.42 ± 0.14 対 0.27 ± 0.12 , $P < 0.001$)。一方で下大静脈下端部では 58%減少した (0.15 ± 0.08 対 0.36 ± 0.16 , $P < 0.001$)。横隔膜貫通部においては断面積および扁平率に有意差を認めなかった (428.3 ± 87.9 対 $426.1 \pm 82.0 \text{mm}^2$, $P = 0.866$; 0.44 ± 0.08 対 0.42 ± 0.08 , $P = 0.096$)。大静脈の結果と対照的に、大動脈の断面積・扁平率は 3 つの測定部位のいずれにおいても姿勢による有意差を認めなかった。

②骨盤底の計測項目

膀胱頸部から恥骨尾骨線 (PC line) までの距離、肛門直腸接合部 (Anorectum junction) から恥骨尾骨線 (PC line) までの距離はいずれとも臥位と比較して立位で有意に下降した (下降距離 $9.4 \pm 6.0 \text{mm}$, $P < 0.001$; $8.0 \pm 5.6 \text{mm}$, $P < 0.001$)。

立位による膀胱頸部の下降は、女性が男性に比して有意に下降した (12.2 ± 5.2 対 $6.7 \pm 5.6 \text{mm}$, $P = 0.006$)。一方で、肛門直腸接合部 (Anorectum junction) から恥骨尾骨線 (PC line) までの距離の変化に関しては男女間での有意差は認めなかった (女性: $9.1 \pm 5.7 \text{mm}$; 男性 $6.9 \pm 5.4 \text{mm}$, $P = 0.196$)。

①, ②のいずれにおいても観察者間・観察者内の一致率は良好であった。

【考察】

ファントムスタディにて立位 CT の空間分解能、ノイズ特性、CT 値は、従来の臥位 CT と同程度であり、立位 CT と従来の臥位 CT は、物理的な性能が同等であると考えられた。

健常人ボランティア撮像にて、重力によって大静脈の断面積が変化していた。すなわち、臥位と比して立位において上大静脈の径は有意に小さくなり、横隔膜貫通部の高さでは径に有意な変化は見られず、下大静脈下端部では有意に大きくなった。大動脈の面積は全ての部位で有意差は見られなかった。重力が大動脈と大静脈に及ぼす影響の違いは、おそらく血管壁の弾性の違いによるものと考えられる。大静脈で見られた変化は、上半身では低い静水圧を示し、下半身では高い静水圧を示すという、過去のシミュレーション研究に一致しているが [1]、今回それを初めて CT で可視化したと言える。今後、立位 CT 画像が中心静脈圧の推定に有用である可能性が示唆される。

骨盤底は臥位と比較し立位で下降していた。MRI を用いた以前の研究では、座位と臥位で女性の骨盤底の位置に差がないことが報告されている [2] が、本研究によって、立位では、骨盤底が下降することが示され、また、以前に報告されている臥位で努責した時と同様の骨盤底の変化が、立位でも生じることが示された。また、膀胱頸部が下降する傾向は、男性よりも女性においてより顕著であった。女性は骨盤底機能障害のリスクが高いことが知られている [3]。我々の結果は、膀胱を囲む女性の骨盤底が実際に弛緩していることを示しており、これは女性で尿失禁が起こりやすい理由を示唆するものかもしれない。

【結論】ファントムスタディにて、立位 CT の性能は従来の臥位 CT とほぼ同等であった。大静脈の断面積、扁平率は重力の影響を受け、体位によって変化した。骨盤底は臥位に比して立位で有意に下降した。膀胱頸部は男性より女性で有意に下降した。立位 CT は人体に対する重力の影響を可視化する点で有用であると考えられる。また、従来の臥位 CT では明らかにすることができなかった機能性疾患の病態解明に有用である可能性がある。

利益相反の有無

あり

キヤノンメディカルシステムズ社

文 献

[1] Mookadam F, Warsame TA, Yang HS, Emani UR,

Appleton CP, Raslan SF. Effect of positional changes on inferior vena cava size. *Eur J Echocardiogr* 2011;12:322-325. doi: 10.1093/ejehocardi/12/3/322

[2] Fielding JR, Versi E, Mulkern RV, Lerner MH, Griffiths DJ, Jolesz FA. MR imaging of the female pelvic floor in the supine and upright positions. *J Magn Reson Imaging* 1996;6:961-963.

[3] Bitti GT, Argiolas GM, Ballicu N, et al. Pelvic floor failure: MR imaging evaluation of anatomic and functional abnormalities. *Radiographics* 2014;34:429-448. doi: 10.1148/rg.342125050

[4] MacLennan AH, Taylor AW, Wilson DH, Wilson D. The prevalence of pelvic floor disorders and their relationship to gender, age, parity and mode of delivery. *BJOG* 2000;107:1460-1470.

Development of Upright CT with area detector for whole body scans:

Phantom study, effect of gravity on human body

Yoichi Yokoyama^{*1}, Yoshitake Yamada^{*1}, Takeo Nagura^{*2}, Takehiro Nakahara^{*1}, Keiichi Narita^{*1}, Minoru Yamada^{*1},
Kazuya Minamishima^{*3}, Naomichi Ogihara^{*4},
Masahiro Jinzaki^{*1}

*1 Department of Diagnostic Radiology, Keio University School of Medicine

*2 Department of Orthopedic Surgery, Keio University School of Medicine

*3 Division of Radiological Technology, Keio University Hospital

*4 Laboratory of Evolutionary Biomechanics, Department of Mechanical Engineering, Keio University

[Objective] The purpose of this study was to evaluate the performance of upright CT in a phantom study and the effect of gravity on large vessels and the pelvic floor. [Methods] We compared the physical characteristics in a phantom between upright and supine CT. Asymptomatic volunteers underwent both CT examinations. The area of vena cava and aorta and the changes of pelvic floor were evaluated. [Results] The performance of upright CT was comparable to that of supine CT. In the upright position compared with the supine position, the area of SVC was significantly smaller, the area at the level of the diaphragm was similar, and the area of IVC was significantly larger, while the areas of aortas were not significantly different; the pelvic floor descended in the upright position. [Conclusion] Upright CT was comparable to supine CT in physical characteristics and useful in clarifying the effect of gravity on human body.

Key words: supine CT, upright CT, visualization of the gravity effect on human body, gravity on large vessels and the pelvic floor

GAN を用いた人工股関節全置換術術後 CT 画像の 金属アーチファクト低減

阪本 充輝*¹ 日朝 祐太*¹ 大竹 義人*¹ 高尾 正樹*²

菅野 伸彦*² 佐藤 嘉伸*¹

要旨

人工股関節全置換術において、術後 CT 画像の解析は人工股関節設置位置や筋骨格形状の評価に重要な役割を果たす。しかし術後 CT 画像では、金属製のインプラントによって発生するアーチファクトが画像解析の精度を大幅に低下させる要因となる。我々はこれまでに、解析の方法とシミュレーション画像を用いて学習した CNN (Convolutional Neural Network) を組み合わせることで、術後 CT 画像での筋肉セグメンテーション精度を向上させる手法を提案してきた。しかし、学習に用いたシミュレーション画像と術後実画像には乖離があり、それが術後実画像でのセグメンテーション誤差の原因であると考えている。そこで本研究では、GAN (Generative Adversarial Network) を活用し、シミュレーション画像と術後実画像からの変換結果の分布が近づくような画像変換手法について検討する。本稿では定量評価のため、アーチファクトの程度を変化させて生成したシミュレーション画像で実画像を代替して実験を行い、本手法の有効性を検証した。

キーワード：金属アーチファクト低減, Generative Adversarial Network, ドメインシフト

1. はじめに

人工股関節全置換術 (THA) において、術後 CT 画像の解析は人工股関節設置位置や筋骨格形状の評価に非常に重要である。しかし術後 CT 画像では、金属製のインプラントによるアーチファクトが画像解析の精度を大幅に低下させる要因となる。我々はこれまでに、解析的方法である NMAR (Normalized Metal Artifact

Reduction) [1]とシミュレーション画像を用いて学習した CNN (Convolutional Neural Network) を組み合わせる事で、術後 CT 画像での筋肉セグメンテーション精度を向上させる手法を提案してきた[2]。しかし、学習に用いたシミュレーション画像と術後実画像には乖離があり、それが術後実画像でのセグメンテーション誤差の原因であると考えている。

このような学習データとテストデータに乖離のある問題はドメインシフトと呼ばれ、Lucら[3]や Shrivastava ら[4]によって敵対的学習を応用した手法が提案されている。

本研究では、シミュレーション画像と術後 CT 画像からの変換結果の分布が近づくような GAN (Generative Adversarial Network) を活用した画像変換について検討する。本稿では、画像

*1 奈良先端科学技術大学院大学先端科学技術研究科情報科学領域

〔〒630-0192 生駒市高山町 8916-5〕

e-mail: sakamoto.mitsuki.si2@is.naist.jp

*2 大阪大学大学院医学研究科

投稿受付：2019年5月22日

変換精度の定量評価のため、シミュレーション画像を用いた実験によって本手法の有効性を検証した。

2. データセット

本研究では、大阪大学医学部附属病院で撮影された THA 術前 CT 画像 20 症例、THA 術後 CT 画像 59 症例を用いた。これらは全て片側疾患の症例である。マトリックスサイズは 512×512 、スライス間隔は $1.0 \sim 6.0$ mm で撮影した後、ボリューム全体が 1.0 mm となるように補間した。

3. 手法

3.1 概要

本手法は、NMAR 適用後の術後実画像から術前画像への変換を行う関数を推定する事を目的とする。まず、術前画像から[1]と同様の手法により術後シミュレーション画像を生成し、ペアの画像集合を構築する。本稿ではこれを source ドメインと呼び、一方、術後実画像集合を target ドメインと呼ぶ。target ドメインでは対応するペアの術前実画像は得られないため、教師データなしで両ドメインの乖離による影響を低減する必要がある。そこで本手法では、source ドメインと target ドメインそれぞれから変換した結果の分布が近づくような関数を GAN により推定する。

3.2 GAN による金属アーチファクト低減

NMAR 適用後のシミュレーション画像 x を術前実画像 t へ変換する生成器を G とすると、この生成器は source ドメイン I_{source} のペアの画像集合を用いて、式(1)の誤差関数を最小化することにより求められる。

$$\mathcal{L}_{source} = \sum_{(x,t) \in I_{source}} \|G(x) - t\|_1 \quad (1)$$

次に、source ドメイン I_{source} と target ドメイン I_{target} から変換した結果の分布を近づけるため、術前実画像 t と術後実画像 y からの変換結果を判別する識別器 D を導入する。その誤差関数

は式(2)で表される。

$$\mathcal{L}_{target} = \sum_{t \in I_{source}} \log D(t) + \sum_{y \in I_{target}} \log(1 - D(G(y))) \quad (2)$$

以上より、GAN の誤差関数は、式(1)に式(2)をペナルティ項として加えて定義される (ただし、 λ はペナルティ項の重みを調整するハイパーパラメータ)。従って、最適な生成器 \hat{G} は、式(4)の最適化で求められる。

$$\mathcal{L}_{total} = \mathcal{L}_{source} + \lambda \mathcal{L}_{target} \quad (3)$$

$$\hat{G} = \arg \min_G \max_D \mathcal{L}_{total} \quad (4)$$

4. 実験

4.1 概要

本稿では画像変換精度の定量評価のため、シミュレーション画像を用いた実験によって本手法の有効性を検証した。

本実験では術後実画像の代わりに、アーチファクトシミュレーションのパラメータを変化させて生成したシミュレーション画像を使用した (図 1)。ただし術前実画像においては、インプラントを疑似的に挿入した部分は $[-10, 10]$ HU 内のランダムな整数値で置換した。

提案法の生成器には U-Net[5]を、識別器には PatchGAN[6]を使用し、式(3)において $\lambda = 0.01$ とした。また、学習用画像は 256×256 にリサイズし、インプラントが挿入されている側のみをクロップする事で入力画像のサイズは 128×256 とした。さらに -150 HU 以下の画素値は 0 、 350 HU 以上の画素値は 255 となるように、その間を線形に変換した。

以上の条件の下、識別器を用いず U-Net のみで学習した場合の結果をベースラインとし、4-

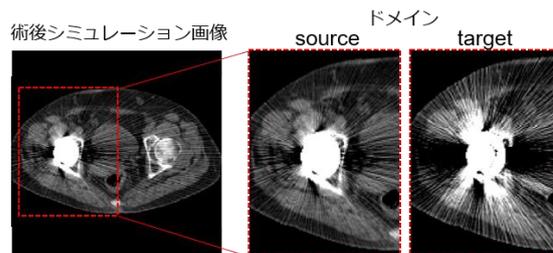


図 1 シミュレーションで生成した source ドメインと target ドメインの例

fold 交差検証によって提案法による結果と比較した。

4.2 結果

本実験での結果について述べる。本実験では各症例の大腿骨小転子の位置を統計形状モデルにより求め、特にアーチファクトが激しい小転子より上のスライスにおいて評価を行った (図 2(a))。また、画質評価指標には Mean Absolute Error を用いた。

表 1 に、ベースラインである U-Net を source ドメインのデータのみで学習・テストした場合の結果と学習データの症例数を示す。また、表 2 に Target ドメインのテストデータを用いて評価した場合の結果を示す。提案法では 8 症例 (約 1200 スライス) の Target ドメインの画像を学習に使用した。U-Net は source ドメインではアーチファクトを低減できているが、ドメインシフトを考慮していないため target ドメインでは誤差が大きくなっている。一方、提案法は U-Net と比較して target ドメインでアーチファクトをより低減できている、MAE の平均値に有意に差が見られた。さらに図 2 に示した変換結果を見ると、特に入力画像と正解画像の誤差が大きいスライスで提案法による効果が大きいことがわかる。

表 1 source ドメインでのテスト結果

	# Subjects	MAE
	Source	Avg+Std
NMAR	8	14.253 ± 2.938
U-Net		10.784 ± 2.113

表 2 target ドメインでのテスト結果

	# Subjects		MAE
	Source	Target	Avg+Std
NMAR	8	0	22.114 ± 7.273
U-Net			16.533 ± 5.790
提案法	8	8	14.669 ± 3.170

5. まとめ

本研究では、GAN によってドメインシフトを解消するアプローチを取り入れ、THA 術後 CT 画像におけるアーチファクト低減手法を提案した。シミュレーション実験によって、提案法は特に、アーチファクトの影響が大きい領域において効果的である事を示した。一方、小転子付近などの領域では、提案法の精度が低下した例が見られた。それらの領域では source ドメインと target ドメインの分布が近いため識別器による判別が困難になり、生成器の学習が不安定になった可能性がある。その対策として、各スライスのアーチファクトの程度に応じて提案法と GAN を用いない既存手法を使い分ける

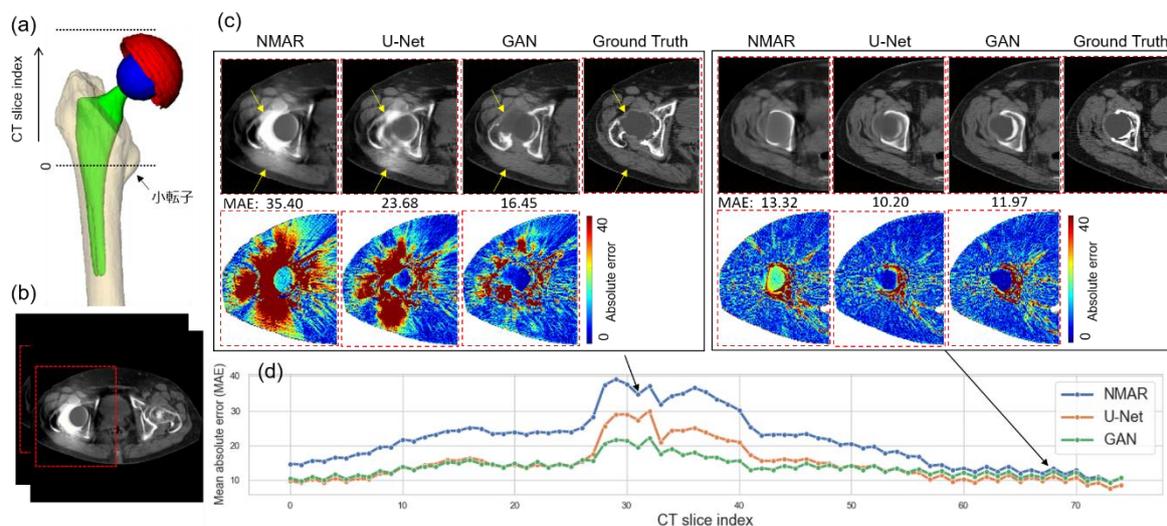


図 2 target ドメインでのテスト結果

事が考えられる。今後は、術後 CT 画像からの金属材質やノイズスケールの推定について検討していく。

謝辞

本研究の一部は、KAKENHI 19H01176 及び KAKENHI 26108004 の支援による。

利益相反の有無

なし

文 献

- [1] Meyer E, Raupach R, Schmidt B, et al.: Normalized metal artifact reduction(NMAR) in computed tomography. *Medical physics* **37**: 5482-5493, 2010
- [2] Sakamoto M, Hiasa Y, Otake Y, et al.: Automated segmentation of hip and thigh muscles in metal artifact contaminated CT using CNN. *Proc. SPIE Conf.* 11050, 2019
- [3] Luc P, Couprie C, Chintala S, et al.: Semantic segmentation using adversarial networks. *NIPS Workshop on Adversarial Training*, 2016
- [4] Shrivastava A, Pfister T, Tuzel O, et al.: Learning from simulated and unsupervised images through adversarial learning. *CVPR* 2107-2116, 2017
- [5] Ronneberger O, Fischer P, Brox T.: U-net: Convolutional Neural Networks for biomedical image segmentation. *MICCAI* 234-241, 2015
- [6] Isola P, Zhu J Y, Zhou T, et al.: Image-to-Image translation with conditional adversarial networks. *CVPR* 1125-1134, 2017

Metal Artifact Reduction from Postoperative CT images of Total Hip

Arthroplasty using GAN

Mitsuki SAKAMOTO*¹, Yuta HIASA*¹, Yoshito OTAKE*¹,
Masaki TAKAO*², Nobuhiko SUGANO*², Yoshinobu SATO*¹

*1 Graduate school of Information and Science, Nara Institute of Science and Technology

*2 Graduate school of Medicine, Osaka University

In total hip arthroplasty, analysis of postoperative CT images is important to evaluate surgical outcome. However, the metal artifact due to the replaced metallic implant degrades the measurement accuracy. In this study, we proposed a method to improve the segmentation accuracy at postoperative CT images by combining Normalized Metal Artifact Reduction (NMAR) and Convolutional Neural Network (CNN). We assumed that However, there is a gap between the simulated images used in training and the real postoperative images. Therefore, by utilizing a Generative Adversarial Network (GAN), we proposed an image translation method in which the difference of gray level distribution of the results of simulated and real images is minimized. Preliminary results from a simulation experiment showed the effectiveness of the proposed method.

Key words: Metal Artifact Reduction, Generative Adversarial Networks, Domain Shift

複数の皮膚毛細血管における血流速度推定の自動化

塚本 唯斗^{*1} 瀧本 麦^{*2} 中野 和也^{*3} 大西 峻^{*3} 羽石 秀昭^{*3}

要旨

皮膚毛細血管は、組織の健全性に関わる重要な血管系である。毛細血管のモニタリングにより組織状態の把握が可能となるが、このための定量評価手法は発展途上にある。当研究室では、皮膚毛細血管の定量評価に向け、撮影装置及び血流速度推定手法の開発を進めてきた。しかし、従来手法は血管内の局所的な画素値に着目したオプティカルフローに基づいた手法であるため、体動やノイズの影響を受けやすい問題があった。そこで本研究では、血管内全域の画素値を考慮することで、ノイズや血球動態にロバストな手法構築を行った。被験者3名の前腕部内側の皮膚毛細血管に対して提案手法を適用し、血流速度の推定を行った。提案手法による血流速度推定値の妥当性検証のため、手動追跡及び従来手法で推定した血流速度との比較を行った。その結果、従来手法と比較し推定誤差の低減を確認したことにより、提案手法の有効性が示唆された。

キーワード：皮膚毛細血管，血流速度，深層学習

1. はじめに

皮膚毛細血管とは、皮膚表面に分布する直径5–20 μm の血管であり、生命維持において重要な役割を担う。毛細血管の観察により組織の健全性及び疾患の状態把握が可能である [1]。したがって、血行動態を定量化することで疾患の定量評価が期待できる。そこで、我々は皮膚毛細血管における血行動態の定量評価に向け、撮影装置の構築及び血流速度の推定を進めてきた [2]。しかし、先行研究の推定手法であるLucas-Kanadeによるオプティカルフロー法 [3] は、体動やノイズの影響を受けやすく推定値に影響を及ぼす。また、画像内に存在する特定の血管のみを対象とした解析技術であるため、複数の毛細血管における血流速度分布の把握が

困難といった課題がある。そこで本発表では、体動やノイズにロバストかつ複数の毛細血管に対して適用可能な血流速度推定手法を提案する。また、提案手法を適用し、血流速度推定値の妥当性を検証した。

2. 皮膚毛細血管撮影装置

皮膚毛細血管撮影装置の外観を図 1(a)に示す。図 1(a)に示すように、白色 LED リング照明 (OPDR-LA74-48W-2, オプティクス・エフエー)、CCD カメラ (GS3-U3-15S5, FLIR) 及びレンズ (#88-354, Edmund Optics, Work Distance: 13.5 mm, 10X/0.17) を組み合わせた撮影装置である。矩形の開口部を有する金属板に皮膚を密着させ、開口部の下から白色光を照射させて撮影する機構となっている。撮影時には、開口部にカバーガラスを置き、カバーガラスと皮膚の間をオリーブオイルで満たす。これにより皮膚表面の反射を低減させ、血管の視認性を向上させる。本撮影装置を用いて、 $0.89 \times 0.67 \text{ mm}^2$ の視野を $1384 \times 1032 \text{ pixels}$, 30 fps の条件で撮影する。取得画像例を図 1(b)に示す。

*1 千葉大学大学院融合理工学府
〒263-8522 千葉市稲毛区弥生町 1-33]
e-mail: y.tsukamoto@chiba-u.jp

*2 花王株式会社

*3 千葉大学フロンティア医工学センタ
ー

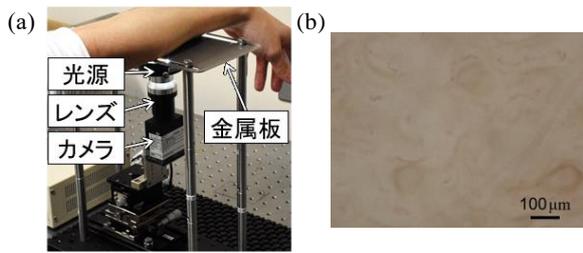


図1 皮膚毛細血管撮影装置
(a) 装置の外観, (b) 取得画像例

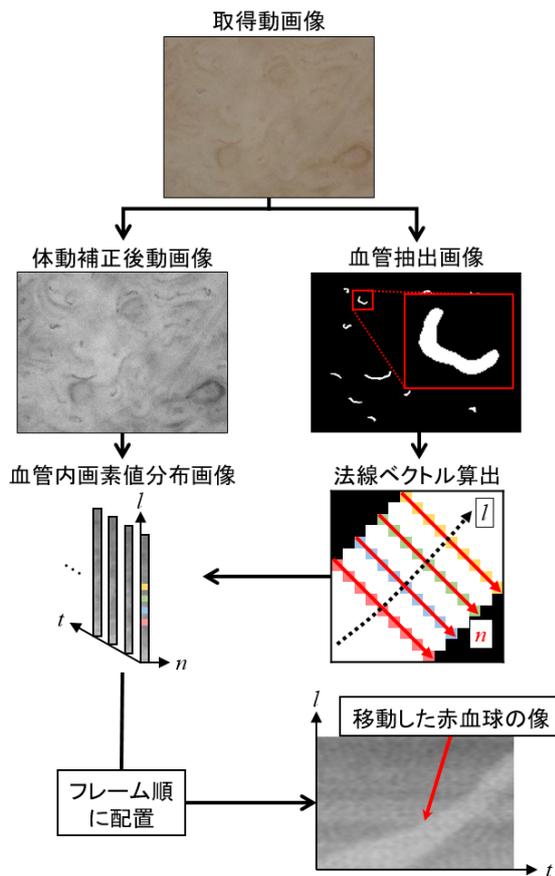


図2 血流速度推定フロー

3. 血流速度推定手法

3.1. 概要

手法の流れを図2に示す. まず, 取得動画像のグリーン成分に対し, テンプレートマッチングを用いて, 被験者の体動によるブレを補正する. そして, 取得動画像中の血管を深層学習に基づく領域抽出手法により抽出する. 作成した血管抽出画像に対して細線化処理を施し, 血管中心線の座標を B-spline 曲線で補間することで血管の中心を通る曲線 l を算出する. 曲線 l に

対する法線ベクトル n 上の画素値を体動補正後動画像から取得し, 曲線 l の位置ごとに並べることで血管内画素値分布画像を作成する. これをフレーム順に並べることで時系列の血管画像を作成し, 現れる赤血球の移動による像の傾きから血流速度を算出する. この一連の処理を抽出された血管全てに対して行う.

3.2. 血管抽出手法

深層学習に基づく領域抽出手法を用いて血管領域の抽出を行う. 学習モデルとして U 字型の畳み込みニューラルネットワークベースのモデル [4] を用いた. 学習時は, 皮膚毛細血管像 1384×1032 pixels からランダムなパッチ画像 512×512 pixels を切り出し, ミニバッチ学習としてモデルへ入力する. この時, パッチ画像に対してランダムにガンマ補正処理 ($\gamma=0.9 \sim 1.1$) を施すことにより学習データを水増した.

学習データには, 成人男女の健常者 5 名から各 3 枚ずつ取得した皮膚毛細血管像計 15 枚を使用した. パッチ画像は, 被験者 1 名につき 10 枚ずつ, 合計 150 枚生成した. Ground Truth として取得画像から目視で確認できる血管領域を手動でアノテーションした画像を作成した. 学習済みネットワークを未学習の被験者の皮膚毛細血管像に適用することで血管抽出画像を生成し, 血流速度の推定が可能な長さを持つ血管を抽出するためラベリング処理を用いたノイズ除去を行った.

3.3. 血流速度算出方法

血流速度は, 時系列の血管画像に現れる赤血球の像の傾きから算出する. まず, Canny 法により赤血球の像をエッジとして抽出する. 次に時刻 $t_i - t_{i+1}$ 間に存在する各エッジの座標を最小二乗法により直線に近似し, 傾きの平均値 $m_{l,t_i,t_{i+1}}$ を算出する. 時刻 t_i における血流速度 v_i は次式のように求めることができる.

$$v_i = m_{l,t_i,t_{i+1}} \cdot w \cdot p \cdot f \quad (1)$$

w は血管内画素値分布画像の幅, p は画素分解能, f はフレームレートである.

4. 実験と結果

成人男女の健常者3名に対し、前腕内側の皮膚毛細血管を撮影し、提案手法を適用した。精度評価のため、被験者1名あたり毛細血管5本に対して手動追跡及び従来手法で推定した血流速度との比較を行った。手動追跡では、手動により赤血球の先頭座標を追跡し、その移動量から速度を算出し、従来手法は、Lucas-Kanadeによるオプティカルフロー法を用いて推定した移動量から速度を算出した。また、精度評価は、取得動画像から血流が確認できる血管に限定して実施した。

被験者1名分の血流速度分布を図3に示す。各毛細血管による血流速度にばらつきがあることを確認した。これは、撮影時の金属板への皮膚の押し当て具合により生じたものと考えられる。また、血流速度が0 $\mu\text{m/s}$ の血管は、取得動画像から赤血球の流れが確認できないため、推定が困難であった。また、被験者1名分の精度評価の結果を図4に示す。従来手法と比較し、提案手法の方が概ね手動算出値に近い血流速度を算出可能であることを確認した。

被験者3名分の手動算出値と従来手法、提案手法間の最大絶対誤差及び平均絶対誤差の算出結果を表1に示す。提案手法と従来手法を比較すると、手動算出値との推定誤差が改善されていることが確認できる。また、提案手法と手動算出値との間の誤差要因としては、手動追跡は明瞭に確認可能な赤血球の先頭から算出した速度であるのに対し、提案手法は、複数の赤血球による像の傾きを平均化し算出した速度であるため、それぞれで血流速度の算出対象となる赤血球の数が異なる点が考えられる。

5. まとめ

皮膚毛細血管撮影装置を用いて撮影した動画像から血流速度を推定する手法を提案した。提案手法を適用した結果、従来手法と比較して推定誤差の低減を確認し、提案手法の有効性が示唆された。今後は、血流状態を変化させた場合の血流速度の推定精度の評価を行うとともに血管抽出精度の向上を検討する。

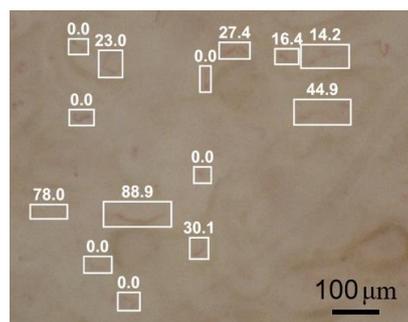


図3 血流速度分布

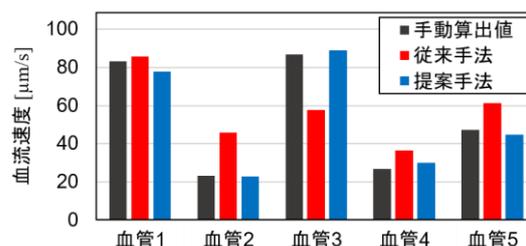


図4 手動算出値，従来手法との比較

表1 手動算出値との誤差

	従来手法	提案手法
最大絶対誤差 [$\mu\text{m/s}$]	29.03	13.22
平均絶対誤差 [$\mu\text{m/s}$]	13.28	4.02

利益相反の有無

なし

文献

- [1] Maldonado G, Guerrero R, et al.: Nailfold capillaroscopy in diabetes mellitus. *Microvascular Research* **112**: 41-46, 2017
- [2] 瀧本 他: ヒト皮膚毛細血管観察システムの構築と血流速度の分布解析. *メディカルイメージング連合フォーラム* 2018, 沖縄, 2018, pp.105-108
- [3] Lucas B, Kanade T: An iterative image registration technique with an application to stereo vision. *Proceedings of Imaging Understanding Workshop, Vancouver, 1981*, pp.121-130
- [4] Cui Y, Zhang G, et al.: A Deep Learning Algorithm for One-step Contour Aware Nuclei Segmentation of Histopathological Images. *arXiv:1803.02786*, 2018

Automated estimation of blood flow velocity in skin capillaries

Yuito TSUKAMOTO*¹, Baku TAKIMOTO*², Kazuya NAKANO*³, Takashi OHNISHI*³, Hideaki HANEISHI*³

*1 Graduate School of Science and Engineering, Chiba University

*2 Kao Corporation

*3 Center for Frontier Medical Engineering, Chiba University

Skin capillaries are an important blood circulatory system regarding the health of tissues. The tissue condition can be assessed by monitoring capillaries, however the quantitative evaluation method of skin capillaries is yet to be sufficiently developed. Therefore we have developed an image capturing system and an estimation method of blood flow velocity for quantitative evaluation of skin capillaries. The conventional method based on optical flow is affected by body movement and noise because it focuses on local pixel values in blood vessels. In this study, we proposed a robust estimation method for this problem. The proposed method was applied to the skin capillaries inside the forearm of three subjects, and the accuracy was verified by comparison with the blood flow velocity calculated by manual tracking. The results showed that the estimation errors were decreased compared to the conventional method. In conclusion, we confirmed the effectiveness of the proposed estimation method.

Key words: Skin capillary, Blood flow velocity, Deep learning

TMS 検査のための脳 MRI 画像からの誘導電流強度の回帰 とその推定誤差分散推定

牧 豊大*¹ 酒井 隆志*² Ilkka Laakso*⁴ 宇川 義一*⁵ 村上 丈伸*⁵

横田 達也*¹ 平田 晃正*² 本谷 秀堅*¹

要旨

本研究では TMS 検査において、頭部に配置したコイルが脳内に誘発する電流強度分布を高速に高い精度で回帰する DNN について報告する。TMS 検査に際して、脳内に生じる誘導電流分布が患者頭部に配置するコイルの位置と向きを変化させたときにどのように変化するかを推定することは重要である。このため既に、患者の頭部 MR 画像より脳内の各位置における電気特性をモデル化し、誘導電流分布を高速にシミュレートする手法が開発されてきた。しかし電気特性分布のモデル化のためには、現状ではこの領域分割に数時間を要することが問題となっていた。そこで我々は、DNN を用いることにより、頭部 MR 画像とコイル位置から直接実時間で誘導電流分布を回帰するシステムを構築した。DNN の学習には 37 人の頭部 MR 画像からシミュレーションにより求めた 261,072 通りの誘導電流分布のデータを利用した。また、DNN により回帰する誘導電流分布の推定誤差を自己評価するための手法も併せて提案する。

キーワード：TMS 検査, VCM, DNN, U-Net, ベイズ推論

1. はじめに

経頭蓋磁気刺激法(TMS: Transcranial Magnetic Simulation)は神経的で精神的な病気の治療やリハビリテーションを目的として提案された手法である[1]。TMS はコイルを用いて磁場を作り、それを頭皮に当てることで、脳内に磁場による非侵襲的な刺激を行う手法である。さらに脳の特定位を刺激したときの被験者の反応を観察することで、刺激した部位が司っている体の部位を特定できる。本研究は後者に焦点を当てる。脳の一部と体の部位を対応づけるためには、コイルによって誘発された脳内の電流強

度を推定することが必須である。このため頭部 MRI 画像から算出された VCM を用いる有限要素法[3]が提案されているが、推定に数時間必要である。そこで、DNN を用いた高速な電流強度の回帰手法を提案する。

2. DNN を用いた電流強度の推定手法

本研究では、頭部 MRI 画像と脳に磁場を与えるコイルの位置と姿勢からそのコイルによって誘発される電流強度を、DNN を用いて回帰する。DNN の入出力のサイズを削減するために、コイル直下の領域のみを考慮する。本研究では U-Net[4]を DNN のアーキテクチャとする。目的関数は DNN の出力と教師信号の間の 2 乗誤差

*1 名古屋工業大学大学院情報工学専攻

*2 名古屋工業大学大学院電気・機械工学専攻

*4 Aalto University

*5 福島医科大学

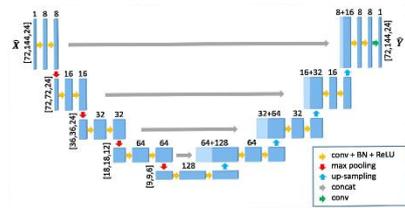


図 1 U-Net の構造

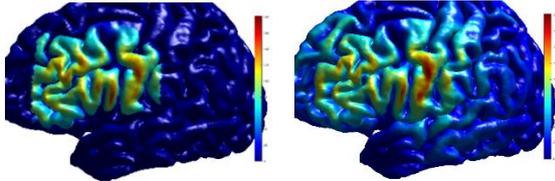


図 2 回帰結果

図 3 真値

とする。U-Net のアーキテクチャを図 1 に示す。加えて、DNN を用いた電流強度の推定を定量化するために、[4]で提案されたベイズアプローチを採用する。この手法では DNN の係数に Dropout を適用することで、DNN を用いて回帰モデルの係数 \mathbf{W} の事後確率分布を近似的に変分推論することができる。DNN の目的関数は、 \mathbf{W} の事後確率分布とそれを近似する関数の KL 情報量となり、次式の通りである。

$$\frac{1}{2N} \sum_{i=1}^N \|Y_i - \hat{Y}_i\|_2^2 + \sum_{m \in \mathbf{M}} \frac{l^2(1-p)}{2\tau N} m^2 \quad (1)$$

N は学習データの総数、 \mathbf{Y} は DNN の出力信号、 $\hat{\mathbf{Y}}$ は教師信号、 p は Dropout を行う確率、 \mathbf{M} は \mathbf{W} を Dropout する前のパラメータ、 l^2 は各 \mathbf{W} の事前分布 $N(0, l^{-2})$ の確度、 τ は回帰モデルの出力の分布 $N(\mathbf{Y}, \tau^{-1})$ の確度を表す。 \mathbf{Y} は DNN の出力を表す。回帰結果は \mathbf{Y} の期待値で評価する。

2. 実験

本実験では、図 1 に示した U-Net の各畳み込み層のカーネルに Dropout を適用させ誘導電流強度を回帰する。テストデータの教師信号とその推定結果を図 2, 3 にそれぞれ示す。本研究では、誘導電流強度は比例尺度であると仮定し、推定の曖昧性を変動係数で表現する。推定の曖昧性は入力した MRI 画像により引き起こされるため、MRI 画像と重ねたものを図 4 に示す。図 4 より脳の皺と皺の間に大きな曖昧性が存在

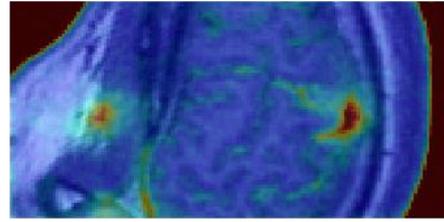


図 4 回帰値の事後確率分布の分散推定結果

することが分かる。加えて、左右のコイルの輪の中心も変動係数の値が高く、曖昧性が大きい。

3. 結論

本研究では、DNN の曖昧性を推定する手法を用いて、電流強度の回帰における信頼度を各ボクセル単位で評価した。その曖昧性は構造的に分布しており、コイルの輪の中心と脳の皺と皺の間に分布していると考察する。

利益相反の有無

なし

文献

- [1] Barker AT, Jalinous R: Non-invasive magnetic stimulation of human motor cortex. *Lancet*, 1:1106–1107, 1985
- [2] Laakso, I., Hirata, A: Fast multigrid-based computation of the induced electric field for transcranial magnetic stimulation. *Physics in Medicine & Biology*, 57(23), 7753, 2012
- [3] Gal, Y., Ghahramani, Z: Dropout as a Bayesian approximation: Representing model uncertainty in deep learning. In *international conference on machine learning* 2016, June, pp. 1050-1059
- [4] Ronneberger, O., Fischer, P., Brox, T: U-net: Convolutional networks for biomedical image segmentation. *International Conference on Medical image computing and computer-assisted intervention*. Springer, Cham. pp. 234-241 2015, October

Regression of induced current intensity and estimation of its error variance from MRI image for TMS

toyohiro MAKI^{*1}, takashi SAKAI^{*1}, Ilkka Laakso^{*2}, yoshikazu UGAWA^{*3}, takenobu MURAKAMI^{*3}, tatuya YOKOTA^{*1}, akimasa HIRATA^{*1}, hidekata HONTANI^{*1}

*1 Nagoya Institute of technology

*2 Aalto University

*3 Fukushima Medical University

In this TMS research, we report DNN that regress the current intensity distribution induced by a coil placed in the head with high speed and high accuracy. It is important to estimate the change that induced current distribution in the position and orientation of the coil. Therefore, methods have been developed to simulate the induced current distribution with high speed by modeling the electrical volumes at each position in the brain from the patient's head MRI image. However, in order to model the electrical property distribution, it has been a problem that this region segmentation requires several hours at present. So, we constructed a system to regress the induced current distribution in real time directly from the head MRI image and the coil position by using DNN. The training data for DNN is obtained by simulation. We use 225, 792 samples from 32 subjects. We also propose a method for self-estimating the estimation variance of the induced current distribution that is regressed by DNN.

Key words: TMS, VCM, DNN, U-Net, Bayes estimation

開腹手術映像における遮蔽物除去システムの VR 化

北坂 孝幸*¹ 伊藤 幹也*¹ 駒形 和哉*¹

三澤 一成*² 森 健策*³

要旨

開腹手術は外科医が習得しなければならない手技の一つであり、これまでに開腹手術映像の知的アーカイブに関する研究を行ってきた。これは、手術を撮影した複数台のカメラ映像を基に術者自身の手や頭といった遮蔽物を除去し、開腹手術のビデオ教材の質的向上を目指したものである。これまでに遮蔽物を良好に除去し、術野を見やすくする遮蔽物除去システムを開発してきた。本稿では、本システムの VR 化による没入感の表現方法について基礎的な検討を行ったので報告する。

キーワード：開腹手術映像，Virtual Reality，Oculus

1. はじめに

腹部の手術は大きく分けて開腹手術と腹腔鏡手術の二種類がある。腹腔とは臓器をお腹に納めている袋のことである。腹腔は通常は萎んだ状態であるが、腹腔鏡手術ではお腹に針を刺して小さな穴を開け、ここから炭酸ガスを注入して風船のように膨らませ、できたスペースに穴を介して内視鏡を入れて、お腹の中を観察する。さらに3~4本の小さな穴を開け、これらの穴から腹腔鏡用のハサミなど入れて手術をする。このため切らずに手術ができる。

しかし、腹腔鏡手術で腹部に対する全ての処置が可能ではないため若い研修医は腹腔鏡手術に加え開腹手術も学ぶ必要がある[1]。

過去の研究では複数台のカメラを使い、死角となる部分を別角度のカメラから補完し映像を作成することで学習教材としての価値を向

上させる研究を行ってきた。複数の角度のカメラ映像からマーカの点群を検出し、ICPによる点群位置合わせを行う。その後、TPSを用いて合成を行ったが依然として内部の映像にブレが生じているためFFDを導入することで、合成精度の向上を図った[2]。

本研究では、手術や術具、患者を仮想空間内に表現し、ヘッドマウントディスプレイによる没入感のある映像提示(VR化)を行うことを目的としている。

2. システムの VR 化

過去の研究でリアルタイムに遮蔽物の除去ができるプログラムを利用して Unity 上で仮想空間の実現を目指す。Unity で手術室を再現したシーンを作成し、複数視点から撮影された映像にFFDなどの処理を行う。そして補完された映像を人体モデルに投影し、ユーザーは Oculus Rift[3]を用いて観察する。

3. 仮想空間での手術室製作

本研究では、リアルタイムで TPS 処理、透過処理などを行った開腹手術映像を VR 空間で見するため、実際の手術室に近い仮想空間を製作す

*1 愛知工業大学情報科学部

〔〒470-0392 愛知県豊田市八草町八千草1247〕 e-mail: kitasaka@aitech.ac.jp

*2 愛知県がんセンター

*3 名古屋大学情報連携統括本部

る必要がある。VR化はUnity上で行うため手術室製作もUnity上で行い(図1)、オブジェクトの制作と変形にはUnity内で3DCGを作成できるProBuilder[4]を使用する。人体モデルは人型の3Dモデルが制作できるアドオンであるManuelBastioniLAB[5]を用いて行う(図2)。製作した人体モデルに開腹手術映像を投影するため、平面のオブジェクトを配置し、人体モデルの形に合わせて変形させる。

4. 点群対応付け、合成処理

複数の映像を合成するには合成する画像の対象物を一致させる必要があるため、画像同士の対応付けを行う。対応付けの基準はマーカーを用いて行う。その後検出された特徴点群同士の対応付けをし、ICPアルゴリズムによる点群の対応付け、TPSによる画像変形を行う。最後に動物体や遮蔽物の検出し別角度の画像を用いて補完を行う[2]。

5. 実験結果と考察

Unity上でシーンを実行し実験を行なった。使用したOculus RiftはOculus社が開発、販売しているものでバージョンは1.33である。作成したシーンを図3に示す。

VR空間であらゆる方向から映像を観察することができ教材としての価値を向上することができた。しかし、平面に映像を投影しているため立体視することが難しくなってしまった。改善点として、赤外線などのセンサーを用いてカメラからの距離の情報を入手し投影時に反映させることでより立体視できるようになると思われる。

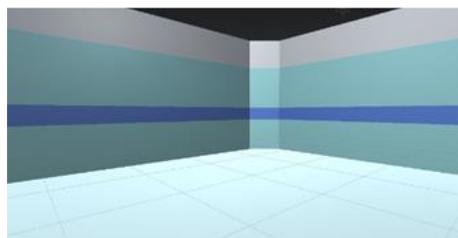


図1 手術室



図2 人体モデル

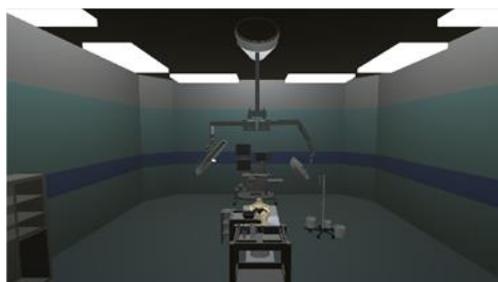


図3 実験結果

6. まとめ

本研究では、研修医が学ぶ学習教材としての価値を高めるため、開腹手術映像における遮蔽物除去映像の仮想現実を検討した。今後の課題として、VR空間で映像をより立体視できるよう新たな手法を用いる必要があることが挙げられる。

謝辞

本研究はJSPS科研費26108006, 17H00867の助成を受けたものです。

利益相反の有無

なし

文献

- [1] Dr.堤治の世界 腹腔鏡下手術 腹腔鏡下手術論 http://www.dr-tsutsumi.jp/endscope/details/e_03.php
- [2] 奥田透生, 佐藤隼, 豊田誠仁, “FFDを利用した開腹手術映像における遮蔽物除去システムの高精度化” 愛知工業大学情報科学部情報科学科 2017年度卒

- 業研究卒業制作要約集 pp101,102, 2019
- [3] Oculus Rift <https://www.oculus.com/>
- [4] ProBuilder
[https://unity3d.com/jp/unity/features/world
building/probuilder](https://unity3d.com/jp/unity/features/world-building/probuilder)
- [5] ManuelBastioniLAB
<http://www.manuelbastioni.com>

Virtual reality in surgical area retrieval system of Laparotomy

Takayuki KITASAKA^{*1}, Mikiya ITO^{*1}, Kazuya KOMAGATA^{*1},
Kazunari MISAWA^{*2}, Kensaku MORI^{*3}

*1 School of Information Science, Aichi Institute of Technology

*2 Aichi Cancer Center Hospital

*3 Information and Communications Headquarters, Nagoya University

Laparotomy is one of important surgical operations. We have developed an intelligent archive of the laparotomy videos, which enables medical students and young surgeon to study actual laparotomy operations through the video archives. We developed a surgical area retrieval system of the laparotomy to retrieve important surgical areas from obstructions by surgeon's head and hands. In this report, we describe a preliminary study of the virtual reality system of surgical area retrieval and investigate how to augment the immersion of the system.

Key words: Laparotomy video, Virtual reality, Oculus

手術器具検出を用いた整形外科手術の工程認識における 最適な Data Augmentation の検討

西尾 祥一^{*1} Belayat Hossain^{*1} 八木 直美^{*1,*2} 新居 学^{*1}

平中 崇文^{*3} 小橋 昌司^{*1}

要旨

整形外科手術は腹腔鏡手術や開腹手術と比較して手術工程および使用する手術器具が多く、外科手術中に医療器具の受け渡しを行う看護師は大きな負担を強いられている。我々は過去に人工膝関節置換術を対象とした整形外科手術における手術室看護師を支援するためのナビゲーションシステムを提案した。この研究では畳み込みニューラルネットワークを用いて手術画像全体に基づいた画像認識により手術工程の認識を試みたが、実用化に必要とされる精度には及ばなかった。本研究では整形外科手術における手術工程の認識精度の改善を実現するために、手術映像から取得したフレーム毎に物体検出(YOLO)を行い、器具のクラス情報と位置座標を検出する。スマートグラス(眼鏡型のデバイス)を用いて記録した整形外科手術映像は手術間で照明環境や撮影角度が大きく異なっており、それらの影響を低減させるための最適なデータの前処理法やデータ拡張法を検討した。

キーワード：深層学習，手術支援，物体認識，整形外科手術，医用画像処理

1. はじめに

整形外科手術は腹腔鏡手術や開腹手術と比較して手術工程及び使用する手術器具が多く、外科手術中に医療器具の受け渡しを行う看護師は大きな負担を強いられている。我々は過去に器械出し看護師に対してリアルタイムで手術情報を周知させることを目的とした整形外科手術ナビゲーションシステム[1]を提案している。

ナビゲーションシステム構築に必要な技術として術者視点での手術映像の自動認識が挙げられる。自動認識の方法としては畳み込みニューラルネットワーク(CNN)を用いた画像認識法を提案した[2]。しかし、手術の工程(手術手技)の認識精度は平均で 32.5%であり、システムの実用化に向けては十分な認識精度を達成できていない。

本研究では物体検出モデル(YOLO[3])を用いた手術器具の検出を行い、器具のクラス情報と位置座標を検出する。また、手術映像には各手術間で照明環境が異なっていることや医師の手が器具を認識する際のオクルージョン(障害物)となっているといった問題が見られる。本研究ではデータ拡張(Data Augmentation)技術を用いることでそれらの問題に対して頑健性の高

*1 兵庫県立大学工学研究科電子情報工学専攻

〔〒671-2280 姫路市書写 2167〕

e-mail: messi240exe@gmail.com

*2 姫路独協大学

*3 高槻病院

いモデルを構築することを目的とする。

2. 提案手法

2.1 Yolov3 を用いた手術器具検出ネットワーク

本研究では手術動画の各フレームを入力画像として物体検出ネットワーク YOLO を用いることにより、画像中から手術器具の領域候補とそれに対応する手術器具の種類の推定を行う。

2.2 オクルージョン及び照明環境変化に対する頑健性獲得のためのデータ拡張手法

本研究で用いるデータ拡張手法は Zhong らが提案する Random Erasing[4]とガンマ補正による画像コントラスト変化による学習データの水増し手法を用いた。

Random Erasing は画像中の認識対象物体上のオクルージョンに対して頑健性を向上させるために提案されたデータ拡張手法である。早稲田大の藤江らは脳腫瘍摘出手術の分野で手術器具検出を用いた工程認識法や Random Erasing を用いたデータ拡張手法の提案を行っている[5]。

入力画像上に存在する物体の Ground Truth(物体領域候補)の座標を $(x_{min}, y_{min}, x_{max}, y_{max})$ とする。消去領域は各 Ground Truth ごとに後述するパラメータの範囲内の大きさでランダムに生成される。元画像と消去領域生成後の画像例を図 1 に示す。

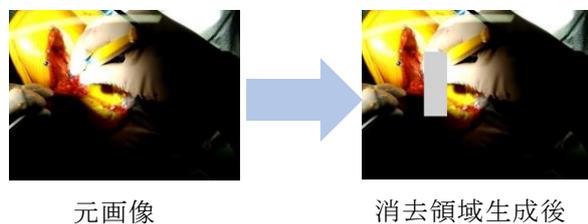


図 1 消去領域生成後画像の例

各 Ground Truth の面積を S とすると、消去領域の面積 S_e はランダムに初期化される。 S_e/S は最小値 S_l 、最大値 S_h の範囲内で決定される。消去領域のアスペクト比は r_e として設定してお

り、 r_1 と r_2 の間で r_e はランダムに初期化される。

ガンマ補正はガンマ値を変化させることで画像コントラストを調整するための手法である。富樫らは極端な照明条件下で物体検出する手法としてガンマ補正を行いながら検出を行う手法を提案している[6]。ガンマ補正に関する式を以下に示す。 $I(x,y)$ が入力画像の画素値、 I_{max} が画素の最大値、 γ はガンマ値である。

$$I'(x,y) = I_{max} \left(\frac{I(x,y)}{I_{max}} \right)^{\frac{1}{\gamma}} \quad (1)$$

γ が 1 より大きければ補正前の画像よりもコントラストが大きくなり、 γ が 1 より小さければ補正前画像よりコントラストが小さくなる。画像に対してガンマ値を変更させたときの画像例を図 2 に示す。

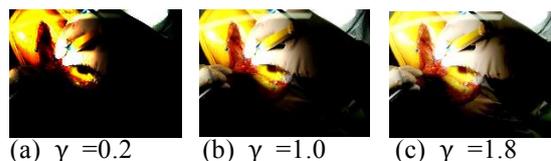


図 2 ガンマ補正後の画像例

Random Erasing とガンマ補正によるデータ拡張手法はモデルの学習中に動的に使用する。具体的にはバッチサイズが N 個の学習条件下であれば、バッチサイズは $N+1$ 個まで増加することを意味する。

3. 実験

3.1 使用データ

使用データは高槻病院で行われた全人工膝関節置換術(TKA)及び単顆人工膝関節置換術(UKA)の 6 症例のビデオで構成されている。ビデオの撮影にはスマートグラス(InfoLinker, ウェストユニティス株式会社)で撮影しており、手術には ZIMMER BIOMET 社の手術器具が使用されている。使用データに含まれる手術器具は Scalpel, Electriccautery, Resection Drill, Needle Holder の合計 4 種類である。図 3 に手術器具の例を示す。

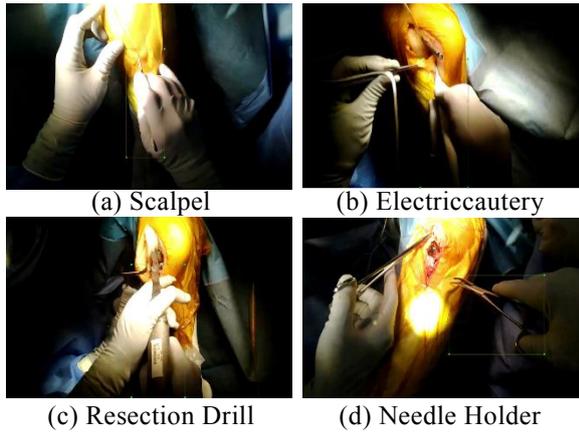


図 3 手術器具の画像例

また各手術器具の画像枚数を表 1 に示す.

表 1 各手術器具の画像枚数

Tool	Number of labeled images
Scalpel	264
Electrocautery	334
Resection drill	296
Needle holder	300

実験の評価方法としては LOOCV 検証を用いた. 症例 1,2,3,4,5 を学習データとしたとき, 症例 6 を評価データとした. 次に症例 1,2,3,4,6 を学習データにしたとき, 症例 5 を評価データとした. 各症例が 1 回は評価データとして用いられるように検証するという方法で検証を行った. 各症例の手術画像枚数を表 2 に示す.

表 2 各症例の画像枚数

Case	Number of labeled images
1	156
2	94
3	144
4	114
5	353
6	333

3.2 実験条件

本実験では手術器具の検出に YOLOv3[7]を用いる. 本モデルは事前に The COCO dataset[8]で学習を行っている. 事前学習後に本データセットで転移学習を行った. 学習回数を表すエポックは 30 に, バッチサイズは 2 とした. 最適化には Adam を用いており, 学習率を 1×10^{-4} としている. Random Erasing における消去領域面

積の最小値パラメータ S_l は 0.02, 最大値パラメータ S_h は 0.1, 0.2, 0.3 の 3 条件で, r_1 と r_2 はそれぞれ 1/3 と 3 に設定している. ガンマ値 γ は 0.8 から 1.2 の範囲でランダムに変化するように設定した.

またデータ拡張を利用せずに学習を行った場合(without)と Random Erasing だけをデータ拡張に利用した場合(Erasing), ガンマ補正を利用した場合(Gamma), Random Erasing とガンマ補正を組み合わせてデータ拡張を行った場合(Erasing + Gamma)の 4 種の条件で学習を行い, 評価を行った.

3.3 実験結果・考察

本実験では Random Erasing およびガンマ補正の本データセットに対する有効性の検証を行う. 検証の方法としては画像データの正解ラベル(手術器具の種類)と学習させたモデルによって推定されたラベルを比較することで検証する. (#of correctly recognized frames)はラベルが一致した数, (#of all frames)は画像枚数の合計である. 検証に用いた式を以下に示す.

$$Accuracy = \frac{\#of\ correctly\ recognized\ frames}{\# of\ all\ frames} \quad (2)$$

Normal, Erasing, Gamma, Erasing + Gamma の各実験条件下で LOOCV 検証を行い平均化することで各手術器具の平均認識精度として算出を行った. Erasing に関しては消去領域生成の最大値パラメータ S_h を 0.1, 0.2, 0.3 の 3 条件で評価を行った. 算出された実験結果を表 3 に示す.

データ拡張手法を用いず学習したモデル(without)の平均認識精度は 43.8%であった. Random Erasing を用いて学習したモデル(Erasing)の精度は $S_h=0.1$ の場合に 49.5%と最良の精度が得られ, without と比べ 5.7%向上した. ガンマ補正を用いて学習したモデル(Gamma)の精度は 48.9%であり, without に比べ 5.1%向上した.

Erasing + Gamma の実験に関しては消去領域生成の最大値パラメータ $S_h=0.1$ に設定して評価

表 3 各実験条件下における評価結果

Tool	Conditions					
	without	Erasing ($S_h=0.1$)	Erasing ($S_h=0.2$)	Erasing ($S_h=0.3$)	Gamma	Erasing + Gamma
Scalpel	55.7	62.2	58.8	62.5	67.5	58.4
Electrocautery	36.8	35.5	29.5	37.1	37.7	36.6
Resection drill	59.6	66.8	59.9	61.2	62.0	57.7
Needle holder	22.8	33.3	28.3	28.1	28.5	29.2
Average	43.8	49.5	44.1	47.2	48.9	45.5

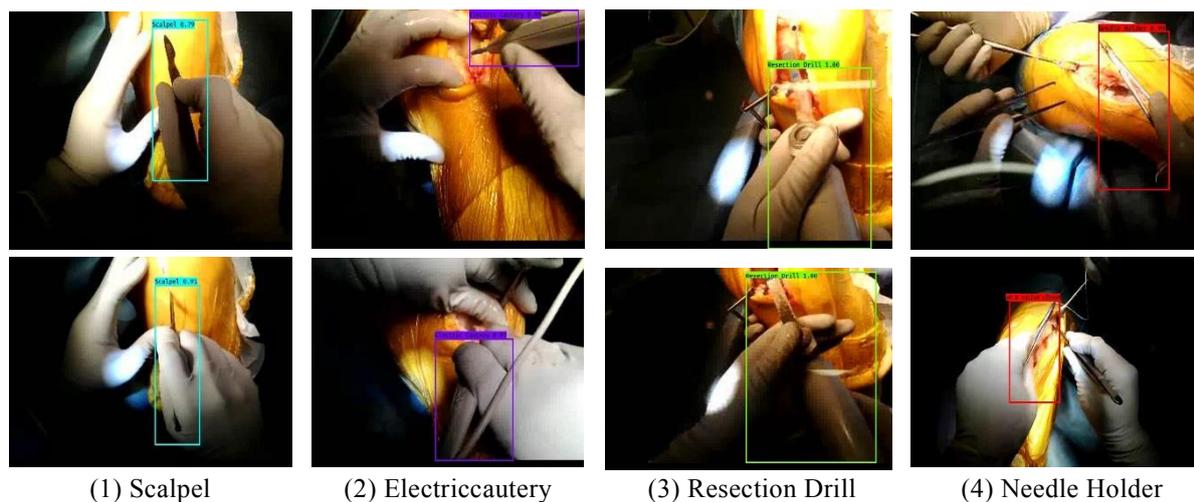


図 4 テスト画像の検出成功例

を行った．実験より平均認識精度は 45.5%であり，without に比べ 1.7%向上した．Erasing と Gamma を組み合わせてデータ拡張を行ったにも関わらず，それぞれ独立してデータ拡張を行った場合と比較しても精度の向上が低かった．原因としては学習エポック(学習回数)が最適でないといった問題が考えられる．全ての実験条件でエポックを 30 として行ったが，エポックを 30 から増加して実験を行った場合に各実験条件下で異なった結果が得られることが予想される．

4. まとめ

本研究は整形外科手術の一種である人工膝関節置換術の手術映像を対象とした物体検出ネットワーク YOLO を用いた手術器具検出において，オクルージョン，照明環境変化に頑健なモデルの構築による認識精度向上を目指した．Random Erasing，ガンマの補正を用いたデ

ータ拡張により学習データの増加を行った．実験結果はデータ拡張を用いずに学習を行ったモデルの平均認識精度が 43.8%，Random Erasing を用いて学習を行ったモデルの精度は 49.5%，ガンマ補正によるデータ拡張を用いたモデルの精度は 48.9%であった．Random Erasing およびガンマ補正の適用により平均認識精度の向上が見られたため，本データセットに対しては有効なデータ拡張手法であることが証明された．

今後の課題としては各データ拡張手法の最適なパラメータを実験的に算出するのではなく，使用データの情報に基づいて自動的に算出することが必要である．自動での算出が可能になれば物体検出ネットワークの学習においてより効果的なデータ拡張手法として活用できると考えられる．

謝辞

本研究は JSPS 科研費 18F18377 の助成を受けたものです．

利益相反の有無

なし

文 献

- [1] S. Nishio, M. Hossain, B. Hossain et al. "Real-Time Orthopedic Surgery Procedure Recognition Method with Video Images from Smart Glasses Using Convolutional Neural Network," presented at the 2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC), 2018.
- [2] S. Nishio, B. Hossain, M. Nii et al. "Workflow Recognition from knee Surgical Videos: Role of Deep Neural Networks," presented at the 2018 International Society of Affective Science and Engineering (ISASE), 2019.
- [3] S. D. Joseph Redmon, Ross Girshick, Ali Farhadi, "You only look once: Unified, real-time object detection," in *IEEE conference on computer vision and pattern recognition*, 2016, pp. 779-788.
- [4] Z. Zhong, L. Zheng, G. Kang et al. "Random Erasing Data Augmentation." arXiv preprint arXiv:1708.04896, 2017.
- [5] 藤江宏紀, 平田啓樹, 堀込貴央 et al. "手術具の検出および追跡による脳腫瘍摘出手術の工程認識法における Data Augmentation のパラメータ値の検討" 信学技報, IEICE Technical Report MI 2018-105, pp185-189.
- [6] 富樫由美子, 大町真一郎, 阿曾弘具, "ガンマ変換を用いた照明変動に頑健な物体検出," 信学論 (D), Vol.J91-D, No.8, pp.2188-2191, Aug. 2008.
- [7] A. F. J Redmon, "Yolov3: An incremental improvement," *arXiv:1804.02767*, 2018.
- [8] M. M. T.-Y. Lin, S. Belongie, J. Hays, P. Perona, D. Ramanan, P. Dollar, and C. L. Zitnick, "Microsoft COCO: Common objects in ' context," in *ECCV*, 2014.

Investigation of Optimal Data Augmentation for Recognizing Surgical Workflow using Surgical Tools Detection in Orthopaedic Surgery

Shoichi Nishio^{*1}, Belayat Hossain^{*1}, Naomi Yagi^{*1,*2}, Nii Manabu^{*1}
Takafumi Hiranaka^{*1,3}, Syoji Kobashi^{*1}

*1 University of Hyogo

*2 Himeji Dokkyo University

*3 Takatsuki General Hospital

The orthopedic surgery involves more surgical procedures and surgical instruments than abdominal and vaginal surgery, and nurses who deliver medical instruments during surgery are under heavy burden.

Our previous study proposed a navigation system to support operating room nurses in orthopedic surgery for total knee arthroplasty. In this research, we attempted to recognize the surgical process by image recognition based on the whole surgical image using a convolutional neural network, but it did not reach the accuracy required for practical use. In this research, in order to improve the recognition accuracy of the surgical process in orthopedic surgery, object detection (YOLO) is performed for each frame acquired from the surgical image, and class information and position coordinates of the instrument are detected. Orthopedic surgery images recorded using smart glasses (eyeglass-type devices) have greatly different illumination environments and shooting angles between operations, and optimal data pre-processing methods and data expansion to reduce their effects Consider the law.

Key words: Deep Learning, Assisting Surgery, Object Recognition, Orthopaedic Surgery, Medical Imaging

敵対的生成ネットワークによる

MRI 脳画像の頭蓋骨除去

藤山 眞悟*¹ 茶山 祐亮*¹ 彌富 仁*¹ 大石 健一*²

要旨

神経障害の診断のために MRI によるニューロイメージングが日々行われている。MRI 画像を用いた脳の研究において、自動診断支援や類似症例検索実現のためには、MRI 画像から頭蓋骨、皮膚、脂肪、眼球のような非脳組織を取り除く skull-stripping (SS) と呼ばれる処理が必要不可欠である。しかし既存の SS 手法は処理時間、除去精度において問題が存在する。本研究は高速かつ正確な SS を実現する adversarial generative skull-stripping (AGSS)法を提案する。AGSS 法は、ディープラーニング分野において近年多くの成果を挙げている generative adversarial networks を応用し、限られた数の脳抽出データの学習を元に、優れた SS 画像を短時間で生成する。既存で最も優れている SS 手法の 1 つである MRICloud による SS 結果を正解データとした 398 例の評価実験において AGSS 法は F1-score=97.28%を達成する一方、実行時間は症例あたり約 3 秒であり従来手法の 1/400 程度を実現した。

キーワード：skull-stripping, MRI, generative adversarial networks

1. はじめに

神経学的疾病は一般的な障害の一つであり、神経障害の診断およびのために、臨床のほか、様々なニューロイメージングが行われている。特に magnetic resonance imaging (MRI) は放射線被爆なしに脳の解剖学的な構造や病理を撮影可能なため、診断や診断支援等を目的とした研究のために広く活用されている。

MRI 画像を用いた研究においては、撮影された MRI 画像から頭蓋骨、皮膚、脂肪、眼球のような非脳組織を取り除き、脳領域を抽出する頭蓋骨除去 (skull-stripping : SS)と呼ばれる処理が必要不可欠である。SS はその処理精度によって後に続く様々な分析に直接影響を及ぼす可能性があるため、正確かつ高速な SS が求められている。しかし、3次元画像である MRI 画像において人手による脳領域の抽

出は非常にコストがかかるため、MRICloud[1], FreeSurfer [2]などの自動 SS 手法が提案されてきたが、処理時間が長く、除去精度が不十分である場合が多い。

一方、深層学習技術を医療分野に適用する試みが近年活発に行われている。特に convolutional neural networks (CNN) による診断支援や、CNN をベースとした U-Net [3]や SegNet [4]は腫瘍や臓器、脳等に対するセグメンテーションで高い精度を実現している。しかし、これらの手法には大量のデータが必要であり、3次元画像である MRI 画像に対して人間の手によりアノテーションをつける作業は非常にコストがかかり困難である。近年、敵対的生成ネットワーク (generative adversarial networks : GANs) [5]による画像の生成を行う研究が活発に行われている。本研究では GANs 手法を応用した adversarial generative skull-stripping (AGSS)法を提案する。AGSS 法は脳 MRI 画像から脳領域のみを描画する generator(G)と、生成された画像が本物の脳画像か、G により生成された偽の脳画像かを判定する discriminator(D)が敵対的に学習することで、高速かつ正確な SS 画像を生

*1 法政大学大学院理工学研究科

[〒184-8584 小金井市梶野町 3-7-2]

e-mail:

{shingo.fujiyama.5a@stu ,yusuke.chayama.2t@stu, iyatomi@}hosei.ac.jp

*2 Department of Radiology

Johns Hopkins University School of Medicine

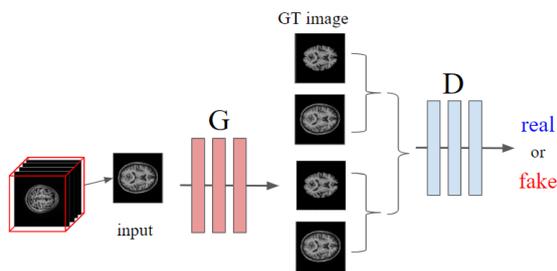


図 1 AGSS の概要図

成する。AGSS 法は、3 次元 MRI 画像を 2 次元スライスの連続として扱い統合することで、極めて少ない学習画像のみから極めて信頼性の高い 3 次元脳構造を生成することができる。

2. 手法

2.1. データセット

本研究では学習用データセットとして、公開されている 3 次元脳 MRI データセットである ADNI2 の 398 症例を使用した。学習用データとして 358 症例、検証用データとして残りの 40 症例を使用した。ADNI2 には頭蓋骨を除去し脳領域を抽出した教師データが存在しないため、現時点で SS において最も精度が高い手法の一つである MRICloud による処理結果を教師データ (Ground Truth, GT) とした。また、前処理としてゼロパディングを行い入力画像と教師画像の画像サイズを $256 \times 256 \times 256$ にする処理を施した。

2.2. Adversarial generative skull-stripping (AGSS)

本研究で提案する AGSS は近年、深層学習分野において成果を上げている研究である GANs の一種である pix2pix [6] の技術を応用し、撮影された MRI 画像から SS を行い、脳領域画像を生成するものである。

3 次元の MRI 画像を直接生成することは、計算コストの課題の他、パラメータ数および利用できる症例数の観点から過学習に陥る可能性が高いため、AGSS では 3 次元画像から

2 次元画像のスライスを抽出し、連続する 2 次元画像として処理を行う。これにより計算コストが大幅に減少するだけでなく、スライス画像毎に位置や角度変化などのデータオーグメンテーション (拡張) も導入することが可能となり、学習画像を大幅に増加させることができる。具体的には、各症例を 3 方向 (Coronal, Sagittal, Transverse plane), 256 スライス/症例、位置・角度に対するオーグメンテーションを $18 \times 21 = 378$ 通り導入することにより 1 症例あたり約 300,000 枚を学習画像とした。

AGSS の学習時の概要を図 1 に示す。G は入力された MRI 画像から脳領域を抽出した画像を生成する生成器 (generator)。D は入力された SS が行われた画像が G によって生成された画像であるか、教師データの画像であるかを識別する識別機 (discriminator) である。このとき、G は D を騙すことができる画像を生成できるように学習を進め、D はより正確に生成された画像であるか教師データの画像であるかを識別できるように学習を進める。これにより学習した G は学習した D を騙せるほど正確な SS を行い、脳領域のみを抽出した画像を生成できるようになる。

AGSS による SS 画像生成は Coronal, Sagittal, Transverse plane の 3 方向それぞれを入力とすることにより、1 症例ごとに 3 つの SS 画像を生成することができる。それぞれの方向において端のスライスにおいては精度低下が起こる場合がある。そのため、これを軽減するために 3 方向によって生成された SS 画像を回転により位置合わせし、平均処理を行う。

3. 実験

本研究では、図 2 に示す U-Net ベースの Generator を用い、撮影された MRI 画像から SS を行い、脳領域を抽出した画像を生成する。Discriminator には、カーネルサイズ 4×4 、ストライド 2 の畳み込み層と batch normalization, Leaky ReLU による処理を 5 回繰り返す CNN を用い、生成器によって生成

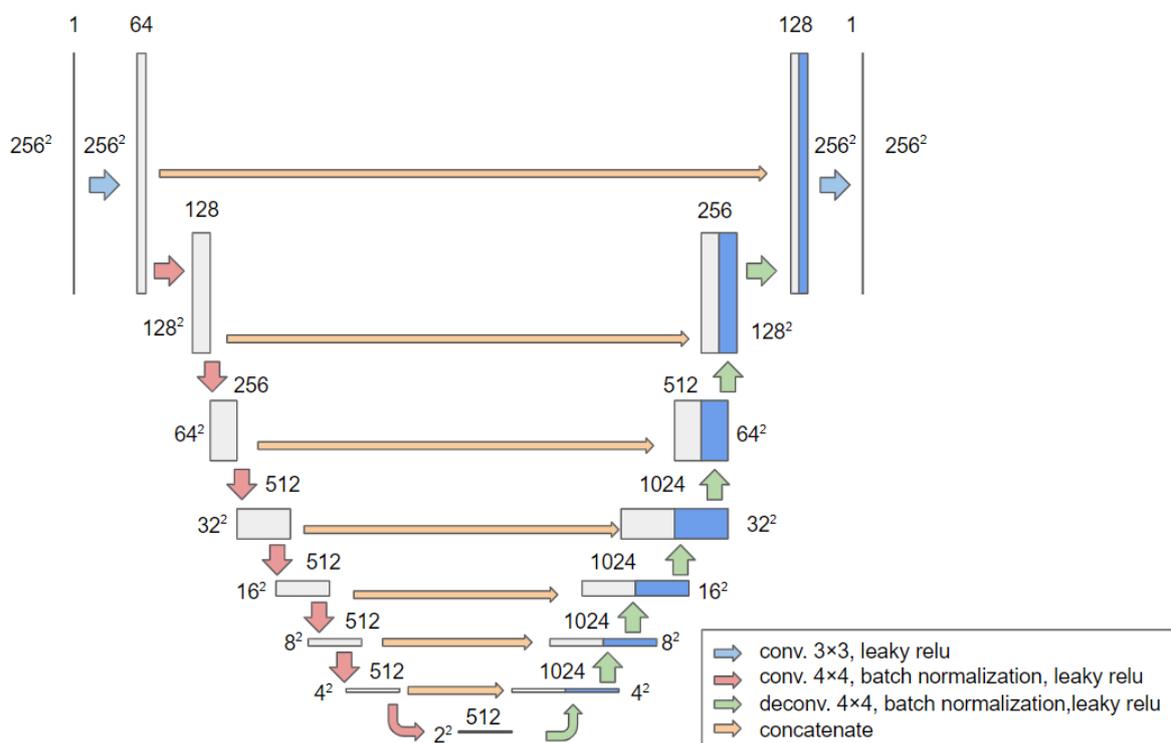


図 2 U-Net ベースの Generator

された画像であるか GT 画像であるかの判別を行う。

以上の生成器と識別器を用いた AGSS の学習を行い、検証用データにより評価を行った。評価指標には、IOU, precision, recall, F1-score を用いた。

検証用データに対する各評価値の平均値を表 1 に示す。また、3 方向のそれぞれの入力によって AGSS が生成した SS 画像の結果例を図 3 に示す。生成結果例をみると GT 画像と同等な SS 画像を生成できていることがわかる、また、それぞれの評価指標値を見ても高い精度で抽出できていることがわかる。

AGSS が SS 画像を生成するのにかかる時間は 1 症例当たり約 3 秒程度 (Core i7-6850K@3.80GHz, RAM: 64GB, NVIDIA GTX 1080 Ti)であり、既存の SS 手法である FreeSurfer と比較すると約 1/400 程度で SS を行うことが可能である。

表 1 AGSS の脳領域生成結果

	IOU [%]	recall [%]	precision [%]	F1 [%]
Transverse	94.17	98.68	95.37	96.99
Sagittal	94.08	98.70	95.27	96.95
Coronal	94.32	98.57	95.64	97.08
Ensemble	94.70	99.02	95.60	97.28

3. まとめ

GANs を応用した SS 手法である AGSS を提案し、GT 画像の作成に使用した MRICloud による SS 画像と同等な脳領域画像を約 1/400 の程度の実行速度で生成を可能とした。

利益相反の有無

なし

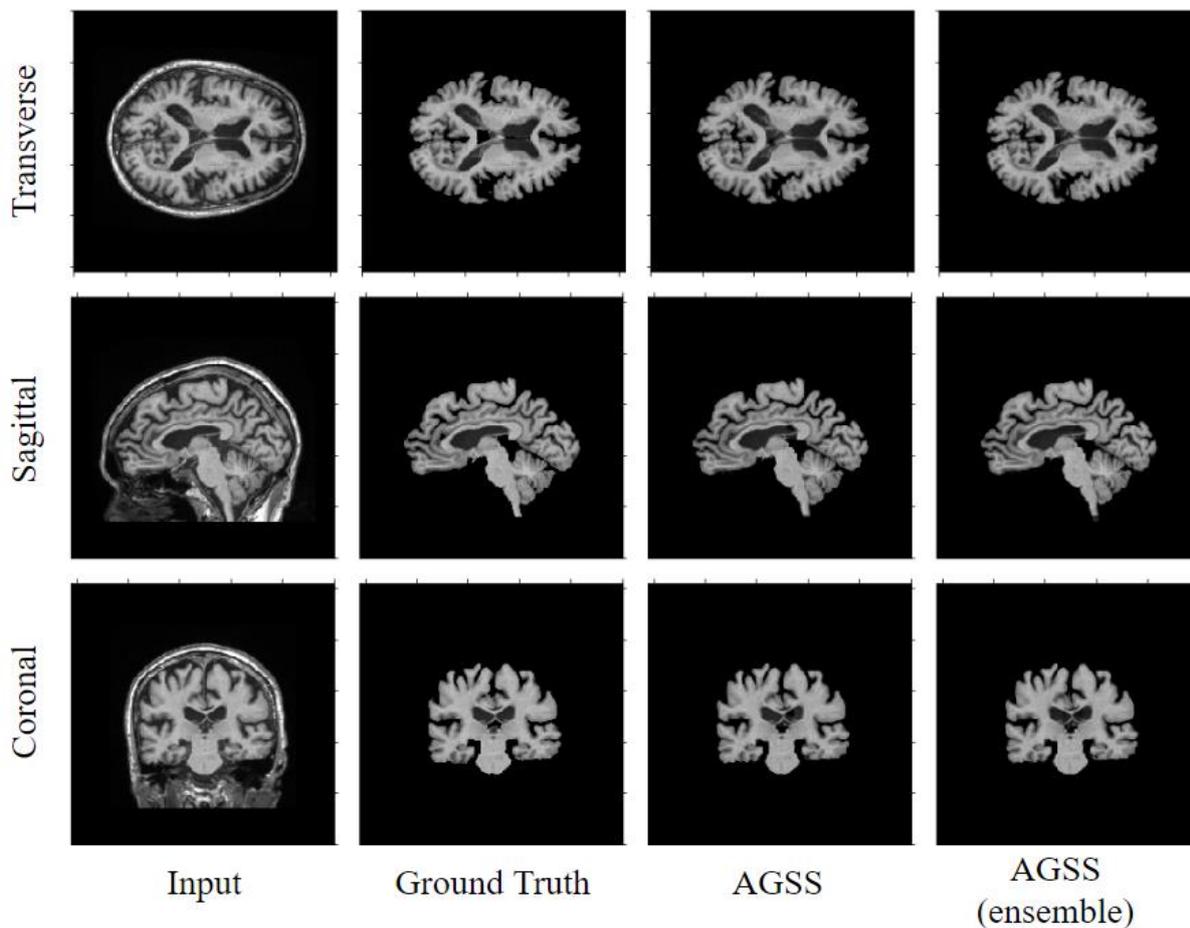


図 3 AGSS による脳領域生成結果

文献

- [1] X. Tang, K. Oishi, A. V. Faria, et al: “Bayesian parameter estimation and segmentation in the multi-atlas random orbit model,” *PloS one*, vol. 8, no. 6, p. e65591, 2013.
- [2] B. Fischl, “Freesurfer,” *Neuroimage*, vol. 62, no. 2, pp. 774–781, 2012.
- [3] O. Ronneberger, P. Fischer, T. Brox, “U-net: Convolutional networks for biomedical image segmentation.”, In *MICCAI*, pages 234–241. Springer, 2015. 2, 3
- [4] V. Badrinarayanan, A. Kendall, R. Cipolla, “Segnet: A deep convolutional encoder-decoder architecture for image segmentation,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 39, no. 12, pp. 2481–2495, 2017.
- [5] I. Goodfellow, J. Pouget-Abadie, M. Mirza,, et al, “Generative adversarial nets,” in *Advances in neural information processing systems*, 2014, pp. 2672–2680.
- [6] P. Isola, J.-Y. Zhu, T. Zhou, et al , “Image-to-image translation with conditional adversarial networks,” in *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, July 2017.

Skull-stripping for MRI Images

using generative adversarial networks

Shingo FUJIYAMA^{*1}, Yusuke CHAYAMA^{*1}, Hitoshi IYATOMI^{*1}, Kenichi OISHI^{*2}

*1 HOSEI University

*2 Johns Hopkins University, School of Medicine.

Extracting the brain region from a MRI is known as skull-stripping (SS), removing skull and eyeball, other non-brain tissue. It is an essential preprocessing for many neuroimaging tasks and several automatic SS methods have been proposed. However, processing time and improvement for accuracy are known issues. In this paper, we propose adversarial generative skull-stripping (AGSS) method to solve these problems. The heart of AGSS is composed of generative adversarial networks (GANs) and it generates excellent skull-stripped MRI results very fast with a limited number of training images. In our experiments, we used a total of 398 cases from the ADNI2 dataset and their SS results by MRICloud, which is one of the best existing SS methods, as the gold standard. As a result, our AGSS achieved 97.28% in F1-score and approximately 3 second for processing time per a case, which is almost 1/400 of conventional methods.

Key words: skull-stripping, MRI, generative adversarial networks

著者紹介

藤山 眞悟 (ふじやま しんご)
2019年 法政大学理工学部応用情報工学科
卒業
2019年 同大学大学院 理工学研究科応用
情報工学専攻 修士課程



彌富 仁 (いやとみ ひとし)
1998 慶大・理工・電気卒, 2000年同大大
学院・理工研・電気修士課程, 2004年同博
士
課程修了. 2000-2004 日本ヒューレット・
パッカード (株).
現在, 法政大・理工・教授. 博士 (工学),
博士 (医学). 機械学習および, それらを
元にした画像解析, 言語処理, セキュリテ
ィなどの研究に従事.

深層学習を用いた腹腔鏡手術動画像の

出血領域自動セグメンテーション

山本 翔太*¹ 小田 紘久*¹ 林 雄一郎*¹ 北坂 孝幸*²

小田 昌宏*¹ 伊藤 雅昭*³ 竹下 修由*³ 森 健策*^{1,4,5}

要旨

本稿では、腹腔鏡手術動画像に対して、深層学習を用い出血領域のセグメンテーションを自動的にを行う手法について検討する。出血領域のセグメンテーション結果は、内視鏡手術の安全性を高める研究において利用価値が高い。しかし、手術映像中における出血領域を手動でセグメンテーションするのは困難であるため、効率的にセグメンテーションを行う手法が求められている。本研究では、深層学習を用いた出血領域の自動セグメンテーションを行う。出血領域を詳細にセグメンテーションするため、出血領域を含む局所領域を切り出したデータで学習した U-net (局所 U-net) と、画像全体で学習した U-net (広域 U-net) を用意し、広域 U-net の抽出結果に局所 U-net の抽出結果を統合することでセグメンテーション結果を得る。実験により、2段階の抽出を行うことで 76.3% の F 値を示した。

キーワード：深層学習、内視鏡手術動画、セグメンテーション、U-net、出血領域

1. はじめに

現在、日本内視鏡外科学会の技術認定評価項目では、評価対象として出血に関する項目が設定されている。しかし、その評価は手術経験に基づく評価であり、定量的評価を行うのは現状困難である。それに伴い、次世代への技術の継承作業に客観性が乏しいという問題がある。そのため、内視鏡手術動画を計算機的に解析し、出血領域を解明することは、手術手技の定量化に大きな貢献となりうる。

また、解析結果を基にした新たな治療支援技術の開発への応用も期待される。

本研究では、腹腔鏡手術動画像中に出現する出血領域の自動抽出を行うことを目的とする。

2. 出血領域自動抽出手法

本手法では、医用画像処理に広く用いられている U-net[1]を用い、腹腔鏡手術動画像中の任意のフレーム画像から、大まかな抽出を行う広域 U-net と詳細な抽出を行う局所 U-net による2段階の出血領域抽出を行う。広域 U-net の抽出結果に、局所 U-net の抽出結果を統合することで自動抽出結果を得られる(図1)。

学習処理では、出血が出現する手術動画中の一部のフレーム画像と、それに対応する出血領域のラベル画像を用いる。広域 U-net の学習では、画像全体を 256 pixel × 256 pixel へ縮小させた画像を学習用画像として用いる。これには画像中に出現する出血領域の大まかな位置を特定する目的がある。また、局所 U-net の学習では、出血領域周辺の切り出し画像を学習用画像

*1 名古屋大学大学院情報学研究科

〔〒464-8601 名古屋市千種区不老町 IB 電子情報館南棟 4 階 466 号室〕

e-mail: syama@mori.m.is.nagoya-u.ac.jp

*2 愛知工業大学情報科学部

*3 国立がん研究センター東病院

*4 名古屋大学情報基盤センター

*5 国立情報学研究所医療ビッグデータ研究センター

として用いる。これには、出血領域の詳細な抽出を行う目的がある。

推定処理では、初めに対象画像から広域 U-net を用いて大まかな出血領域の抽出を行う。次に、抽出結果の出血領域が中心となるように対象画像から出血周辺画像を切り出し、その切り出し画像を局所 U-net に入力し詳細な抽出を行う。局所 U-net の抽出結果を、広域 U-net から得られた結果に OR 演算により統合することで対象フレーム画像の出血領域自動抽出結果を得る。

3. 実験と結果

実験では、広域 U-net, 局所 U-net, 広域 U-net と局所 U-net の 2 段階抽出の抽出精度の比較実験を行った。ただし、局所 U-net に関しては、対象画像を 256 pixel×256 pixel で分割した画像を入力とし、出力された分割画像を再構築することで抽出した。13 症例分の腹腔鏡手術動画から出血領域を手動でラベル付けしたフレーム画像 900 枚で学習し、129 枚で推定を行った。各手法による出血領域自動抽出結果は図 2 の通りとなった。また、それぞれの再現率、適合率、F 値を表 1 に示す。

4. 考察

2 段階抽出手法の再現率が比較手法の中で最大の値を示した。局所 U-net で出血領域周辺のみを抽出することで、微小な出血領域も詳細に抽出されたからだと考えられる。F 値に関しても 2 段階抽出手法が最大の値を示したが、適合率に関しては広域 U-net が最大の値を示した。これは、2 段階抽出手法における広域 U-net の誤抽出に関しても局所 U-net で抽出することにより、誤抽出領域が増加したからだと考えられる。2 段階での抽出結果の統合法を再検討する必要がある。

5. むすび

本稿では、深層学習を用いた腹腔鏡手術動画からの出血領域自動抽出手法についての検討を行い、その有効性を確認した。今後は精度の向上を図るとともに、自動抽出結果に基づく手術手技定量化手法も検討し、治療支援技術への応用を目指す。

謝辞

本研究の一部は JSPS 科研費 17H00867, 17K20099, 26108006, 26560255, 二国間交流事業, 堀科学芸術振興財団, AMED の課題番号 18he1802002, 18lk1010028, 19lk1010036h0001 の支援を受けた。

利益相反の有無 なし

文献

- [1] Roth HR, Oda H, Zhou X, et al.: An application of cascaded 3D fully convolutional networks for medical image segmentation. CMIG, 66: 90-99, 2018

表 1 出血領域の自動抽出精度

	適合率	再現率	F 値
局所 U-net	39.2%	80.7%	46.9%
広域 U-net	77.8%	60.7%	65.2%
2 段階抽出	73.9%	85.5%	76.3%

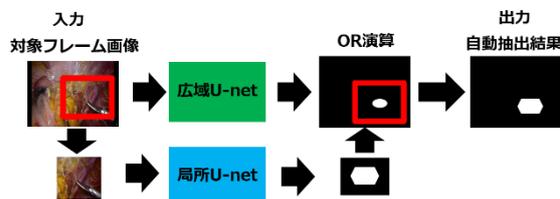


図 1 出血領域の自動抽出手法。2 段階の抽出結果を統合することで対象フレーム画像から自動抽出結果を得る。

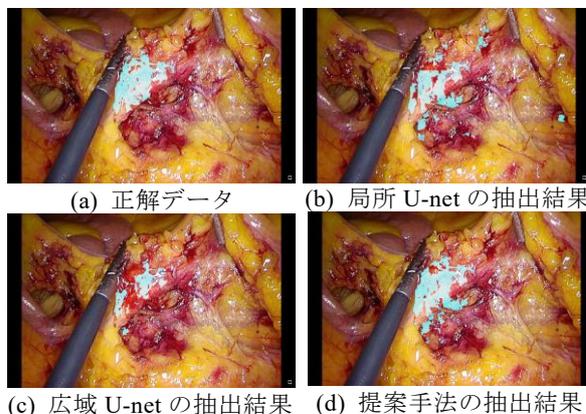


図 2 各手法の自動抽出結果と対象フレーム画像の重畳表示(図中青色)。

Automated Segmentation of Bleeding Area from Laparoscopic Surgical Movie Using Deep Learning

Shota YAMAMOTO^{*1}, Hirohisa ODA^{*1}, Yuichiro HAYASHI^{*1}, Takayuki KITASAKA^{*2},
Masahiro ODA^{*1}, Masaaki ITO^{*3}, Nobuyoshi TAKESHITA^{*3}, and Kensaku MORI^{*1,4,5}

*1 Graduate School of Informatics, Nagoya University

*2 Faculty of Information Science, Aichi Institute of Technology

*3 National Cancer Center Hospital East

*4 Information Technology Center, Nagoya University

*5 Research Center for Medical Big Data,

National Institute of Informatics

We discuss a method for automated segmentation of bleeding area using deep learning from laparoscopic surgical movie in this paper. Segmentation results of bleeding area are valuable for research to enhance the safety of endoscopic surgery. However, since manual segmentation of bleeding area from surgical movies is difficult, an automated bleeding area segmentation method is required. We used a global U-net to identify rough locations from the whole frame image. Then, we apply a local U-net to segment bleeding area in detail from local images clipped based on the global segmentation results. Segmentation results are obtained by integrating the segmentation result of the local U-net into the segmentation result of the global U-net. We compared automatic bleeding region segmentation accuracy by using local U-net, global U-net, and both of them in the experiments. We obtained 76.3% F-measure when we used both of local and global U-nets.

Key words: Deep learning, Laparoscopic Surgical Movie, Segmentation, U-net, Bleeding Area

血管仮想操作のための脳血管描画方法の検討

田中 康太^{*1} 篠原 寿広^{*1} 中迫 昇^{*1}

要旨

現代の日本人の主な死因の1つに脳血管疾患がある。脳血管構造は複雑であるため3次元で可視化する際に死角ができ、手前の血管に隠れる血管は観察しにくい。そこで、著者らは、脳血管をより直感的に観察することを目的に、注目する血管を隠す血管を仮想的に操作し、注目する血管を観察可能にする血管仮想操作を提案している。本稿では、血管仮想操作を実現するための脳血管描画方法を提案する。はじめにCTA (Computed Tomography Angiography) 画像から抽出した脳血管をサーフェイスレンダリング法で描画する。次に、注目血管を隠す血管に対し、同じCTA画像から推定した血管の心線データを用いて、チューブ状の簡易血管描画に切り替えて、心線データを操作することで、血管の仮想操作を実現する。実際のCTA画像から抽出した脳血管および推定した血管の心線データを用いて実験を行い、本描画手法の有効性の一端を確認した。

キーワード：血管仮想操作，血管描画，脳血管疾患，診断支援

1. はじめに

現代の日本人の主な死因の1つに脳血管疾患がある[1]。脳血管疾患とは、脳動脈の異常が原因でおこる疾患の総称であり、脳卒中やくも膜下出血などが挙げられる。脳血管疾患の死亡率は減少傾向にあるものの依然として高く、死亡に至らなくても、手足の麻痺や言語障害、意識障害、運動障害などの後遺症が残ることが多いため、早期の発見が必要である。現在、医療技術、画像処理技術の発展によりCT (Computed Tomography) やMRI (Magnetic Resonance Imaging) を用いて3次元的に体内の医療用画像を得ることができるようになったため、病変部の早期発見が可能になった。しかし、病変部の特定は医師達の手作業によって行われており、大きな負担がかかる。また、脳血管の構造は複雑であるため、3次元で可視化する際に、死角ができてしまい、手前の血管に隠れる血管は観察しにくい。

そこで著者らは、脳血管をより直感的に観察できるようにすることを目的に、脳血管を3次元的に描画し、注目する血管を隠す血管を仮想的に操作し、注目する血管を観察できるようにする血管仮想操作を提案している。本稿では、血管仮想操作を実現するための脳血管描画方法を提案する。

2. 血管仮想操作のための血管描画方法

本研究では、操作する血管は注目血管を隠す血管であり、すでに観察済みであると想定しているため、実際の血管の振る舞いや形状を忠実に再現する必要はない。血管を操作する際、DICOM (Digital Imaging and Communication in Medicine) 画像におけるボリュームデータを直接処理することは難しいため、3次元モデル相関法[2]を用いてCTA (CT Angiography) 画像から血管の中心位置情報 (X, Y, Z座標)、半径情報およびX, Y, Zの各方向ベクトルを抽出した心線データを用いる。心線データは予め血管の名称に基づき、別々に管理されており、編集が容易で、さまざまな血管の振る舞いを実現することが

^{*1} 近畿大学大学院生物理工学研究科
〔〒649-6493 和歌山県紀の川市西三谷930〕
e-mail: 1933730015t@waka.kindai.ac.jp

できる（ただし、血管の振る舞いは今後検討を行う）。また、操作する血管は心線データの位置情報および半径情報を用いてチューブ状の簡易表現に切り替える。心線データを用いた血管の描画方法を以下に述べる。

まず、心線データを用いて抽出した血管データ[3]を図1のように描画する。ここで、同図の緑色の血管の裏に病変部が隠れており、緑色の血管を操作するものとする。次に、ポインティングデバイスにより、操作したい緑色の血管上をクリックし、心線データの位置情報および半径情報を基に当たり判定を行う。クリックした位置が血管に当たっていれば、図2のように心線データに基づいてチューブ状の簡易表現された血管を描画する。さらに操作前の血管のボリュームデータを透明化することで操作された血管をボリュームデータ表現からチューブ状の簡易表現へ切り替えを行う。このとき、ボリュームデータの各ボクセルはユークリッド距離の最も短い心線データと対応付けられているため、心線データに基づき各血管を透明化することができる。図3のように、チューブ状に簡易表現された血管を操作することにより隠されていた病変部を観察できるようになる。

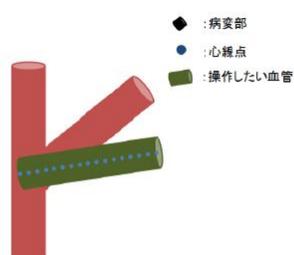


図1 血管データによる描画

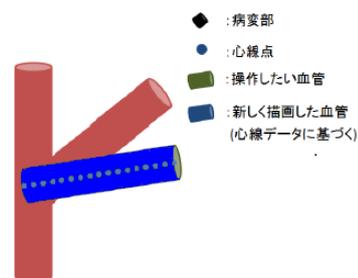


図2 チューブ状の簡易表現による血管描画

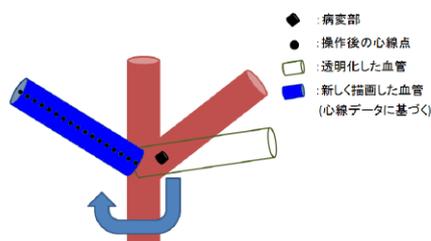


図3 チューブ状簡易血管の操作

3. 実験

3.1 実験概要

提案する血管仮想操作のための血管描画方法の有効性を確認するため、実際のCTA画像を用いて実験を行った。元の血管の描画にはVTK (Visualization Toolkit) [4]を用いて、サーフェスレンダリングによるマーチングキューブ法[5]で描画した。実験に用いたCT画像の撮影条件を以下の表1に示す。

表1 CT画像の撮影条件

使用する画像枚数	430枚
画像の解像度	0.35mm/pixel
断面画像の間隔	0.3mm
スライス厚	0.625mm

3.2 実験結果

心線データを用いて抽出した脳血管を図4に示す。椎骨動脈に対して、血管操作を行う。

椎骨動脈をクリックすることで血管のボリュームデータによるサーフェイスレンダリング法からチューブ状の簡易表現に切り替えた様子を図5に示す。分かりやすさのために、心線データの半径情報に基づきチューブ状の簡易表現の血管に色付けを行っている。また、その後、血管を平行移動させた様子を図6に示す。



図4 サーフェイスレンダリング法による描画

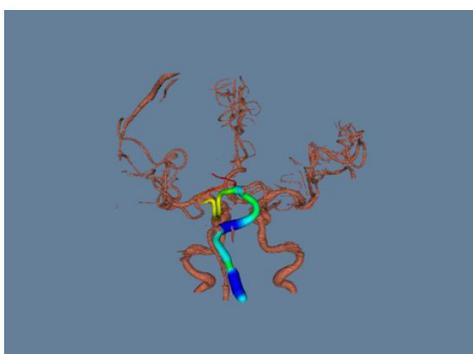


図5 描画切り替え後の画像

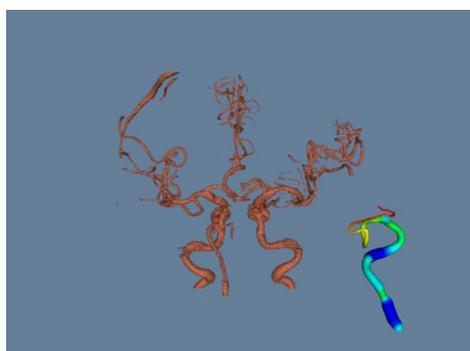


図6 血管操作後の画像

リアルタイムに血管の描画の切り替えを行い、注目する血管を隠す血管を仮想的に操作し、注目する血管を観察できることが本実験により確認できた。

4. まとめ

血管仮想操作のための血管描画方法の提案を行った。実際の脳血管画像および心線データを用いて実験を行い、リアルタイムに血管の描画の切り替え、血管操作が可能であることを確認した。今後は直感的に血管を操作するための血管の振る舞いの検討を行うとともに、実際の臨床現場で使用し、血管仮想操作の有効性の確認を行う予定である。

利益相反の有無

なし

文 献

- [1] 人口動態統計 - 厚生労働省 (URL:<http://www.mhlw.go.jp/english/database/db-hw/dl/81-1a2en.pdf>)
- [2] 篠原寿広, 岡田康希, 中迫昇: 血管位置および径推定のための血管追跡における球面を用いた血管分岐検出の検討. 第34回日本医用画像工学会大会予稿集, OP6-2, 2015
- [3] 宮内亮太郎, 篠原寿広, 中山雅人 他: 血管位置と径情報および輝度分布を利用したベイズ定理に基づく頭部CTA画像からの脳血管の抽出. 第31回日本医用画像工学会大会予稿集, OP1-2, 2012
- [4] VTK -The Visualization Toolkit (URL:<http://vtk.org>)
- [5] ビジュアル情報処理編集委員会: ビジュアル情報処理. CG-ARTS 協会, 2017, pp69-70

Drawing cerebral blood vessel for vascular virtual handling

Kota TANAKA^{*1}, Toshihiro SHINOHARA^{*1}, Noboru NAKASAKO^{*1}

^{*1} Graduate school of Biology-Oriented Science and Technology, Kindai University

When the cerebrovasculature is visualized in three dimensions blind spots occur, since cerebrovasculature is complicated and the blood vessels in the front hide the ones in the back. These blind spots make it hard to observe cerebrovasculature. In order to solve this problem, we proposed a blood vessel virtual handling system that enables us to virtually handle blood vessels to eliminate the blind spots and allows us to observe blood vessels of interest intuitively. In this paper, a blood vessel drawing method for this blood vessel virtual handling is proposed. First, the brain blood vessels extracted from the CTA (Computed Tomography Angiography) image are drawn by the surface rendering method. Then, drawing of the blood vessel that hides the blood vessel of interest is switched to a tube-like simple drawing by using the center line data of the blood vessel estimated from the same CTA image, that is, the centerline position and radius information of the blood vessel. The virtual handling of blood vessels is realized by manipulating this center line data. The feasibility of this proposed drawing method of blood vessels was confirmed by using center line data of cerebral blood vessels estimated and blood vessels extracted from an actual CTA image.

Key words: Blood vessel virtual handling, Blood vessel drawing, Cerebrovascular diseases, Diagnosis support

転移学習を用いた腹部 thick-slice CT 像における 多臓器領域の自動抽出の初期検討

申 忱^{*1} Holger R. Roth^{*1} 林 雄一郎^{*1} 小田 昌宏^{*1}

小田 紘久^{*1} 三澤 一成^{*2} 森 健策^{*1,3,4}

要旨

本稿では、転移学習を用いた腹部 thick-slice CT 像における多臓器領域の自動抽出に関して検討する。臓器領域の自動抽出は医用画像処理において重要な役割を果たしている。近年、スライス厚が 0.5mm 程度の thin-slice CT 像を用いた臓器領域の自動抽出が多く行われているが、スライス厚が 5mm 程度の thick-slice CT 像も医療現場において多く利用されている。そのため、スライス厚が厚い CT 像においても臓器領域の自動抽出ができれば有用である。しかし、CT 像の体軸方向の間隔が異なるため、従来の 3 次元 fully convolutional networks を用いた thick-slice CT 像における臓器領域の自動抽出手法をそのまま適用することは困難である。本研究では、thin-slice CT 像の学習済みモデルを用いて転移学習を行うことにより、thick-slice CT 像における腹部多臓器の自動抽出を行う。実験では、転移学習により thick-slice CT 像からの腹部多臓器の自動抽出精度が 4% 向上したことを確認した。

キーワード：多臓器抽出，深層学習，転移学習，thick-slice CT

1. はじめに

腹部 3 次元 CT 像における多臓器領域の自動抽出の研究は、コンピュータ支援診断 (CAD) やコンピュータ支援外科 (CAS) システムの開発に有用である。深層学習の発展に伴い、畳み込みニューラルネットワークを用いた医用画像処理の研究が盛んに行われてきた。その中で、Fully convolutional networks (FCNs) [1] は臓器抽出の手法としてよく使われている。これまでの臓器領域抽出の研究では、スライス厚が 0.5mm 程度の thin-slice CT 像を対象としたものが多い

[2]。医療現場においては、スライス厚が 5mm 程度の thick-slice CT 像も多く使われているため、thick-slice CT 像からも臓器領域を自動抽出することができれば有用である。しかし、thick-slice CT 像は体軸方向の解像度が低いため、従来の thin-slice CT 像で学習した 3D FCNs 手法を用いて end-to-end で多臓器領域を自動抽出することは困難である。そこで、本稿は thin-slice CT 像の学習済みモデルを転移学習することにより、thick-slice CT 像における多臓器領域の自動抽出を行ったので報告する。

2. 手法

本手法の流れを図 1 に示す。本手法で使用した FCN の構造は、文献 [2] に示される 3D U-Net [3] と同一である。従来手法では、スライス厚が 0.5mm 程度の腹部 thin-slice CT 像を用いて、多臓器の自動抽出を行ったが、本手法では、スライス厚が 5mm の thick-slice CT 像を対象とする。

*1 名古屋大学大学院情報学研究科
〔〒464-8601 名古屋市千種区不老町〕
e-mail: cshen@mori.m.is.nagoya-u.ac.jp

*2 愛知県がんセンター

*3 名古屋大学情報基盤センター

*4 国立情報研究所

医療ビッグデータ研究センター

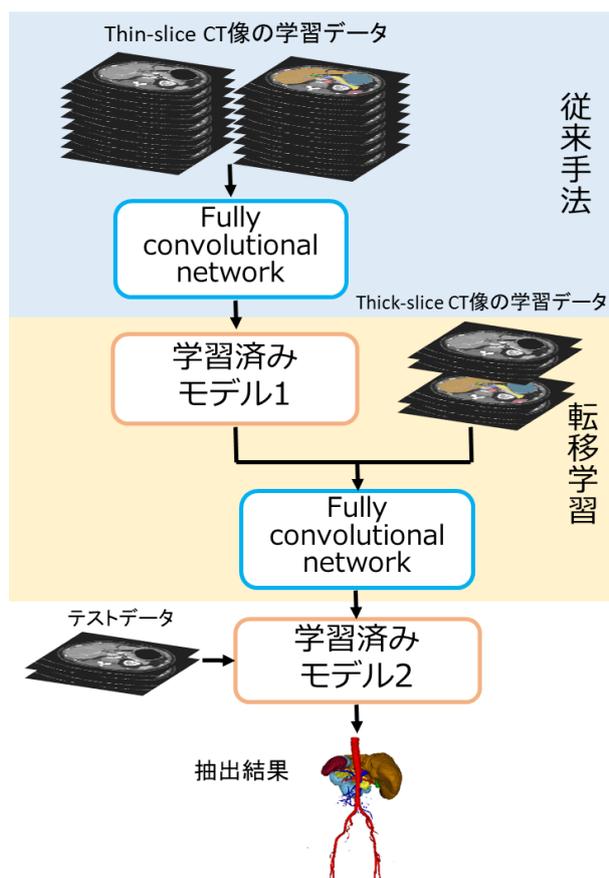


図1 学習の流れ. FCNの構造は従来手法[2]と同一である.

まず、従来手法と同様に Thin-slice CT 像で学習して得られたモデルを学習済みモデル1とする。そして、学習済みモデル1と thick-slice CT 像を用いて同一の FCN 構造に基づいて転移学習を行い、学習済みモデル2を得る。テストデータを用いて、学習済みモデル2において臓器領域を推定する。

3. 実験と結果

実験では、門脈相の造影腹部 thick-slice CT 像 415 症例を使用した。評価のため、全症例をランダムに学習データ 380 症例とテストデータ 35 症例に分割した。抽出対象の7つの臓器(動脈, 門脈, 肝臓, 脾臓, 胃, 胆嚢, 膵臓)および背景の8クラスの正解領域を作成した。本研究で使用する thick-slice CT 像は、従来の thin-slice CT 像から線形補間を使用し、体軸方向の解像度を 5mm に変換することで作られた。FCN の入力画像と出力画像のサイズは $64 \times 64 \times 32$ ボ

クセルで、ミニバッチサイズは 3 とした。Adam により最適化し、学習回数は 60,000 イテレーションとした。転移学習で使用する学習済みモデル1は、文献[2]の手法で、55,000 イテレーション学習したモデルを使用した。文献[2]の手法を thick-slice CT 像のみで学習したモデル(転移学習なし)と thin-slice CT 像で学習したモデルを thick-slice CT 像を用いて転移学習したモデル(転移学習あり)による腹部多臓器領域の自動抽出結果例を図2に示す。また、転移学習ありモデルと転移学習なしモデルによる多臓器領域の自動抽出精度を Dice coefficient score により評価した結果を表1に示す。

4. 考察

本実験では、thick-slice CT 像のみで学習したモデルと thin-slice CT 像で学習したモデルを thin-slice CT 像を用いて転移学習したモデルと比較した。表1から、転移学習なしモデルと転移学習ありモデルの平均 Dice 係数は 80.5%と 84.5%であった。転移学習を行うことにより、胃以外の領域において大幅の精度向上が見られた。特に、胆嚢領域において、16.4%の精度向上が見られる。転移学習は、thick-slice CT 像からの臓器領域抽出において有用であると考えられる。しかし、抽出結果では誤検出が増加したため、胃の抽出精度が 10%ほど減少した。これに関しては、さらなる実験を踏まえた検討が必要となる。

5. まとめ

本稿では、腹部 thick-slice CT 像から多臓器領域を自動抽出する手法を提案した。thin-slice CT 像での学習済みのモデルを thick-slice CT 像に用いて転移学習し、thick-slice CT 像のみで学習した結果と比較した。実験の結果、転移学習により、平均の抽出精度が 4%向上したことを確認した。

今後の課題としては、学習データ数が転移学習で臓器抽出を行う際に与える影響や非造影 thick-slice CT 像における多臓器領域の自動抽出の検討などが考えられる。さらに、学習で用いる FCN 構造を改良することで、より高精度の臓器抽出を目標とする。

謝辞

日頃から熱心に御討論頂く森研究室の諸氏に感謝する。本研究の一部は、AMED 臨床研究等 ICT 基盤構築・人工知能実装研究事業 19k1010036h0001, 堀科学芸術振興財団, 文部科学省・JSPS 科研費 26108006, 17H00867, 17K20099 ならびに日本学術振興会二国間交流事業によった。

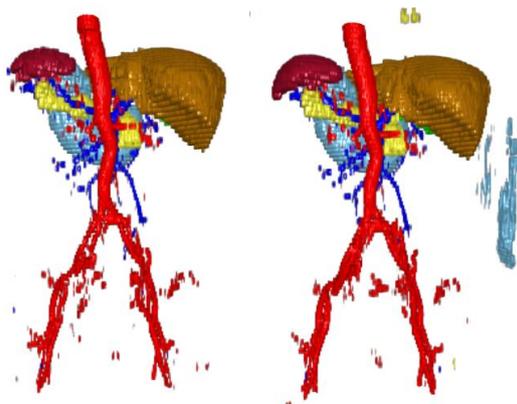
利益相反の有無

なし。

文献

- [1] Long J, Shelhamer E, Darrell T: Fully convolutional networks for semantic segmentation. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition: 3431–3440, 2015
- [2] Shen C, Roth H, Oda H, et al.: Evaluation of 3D fully convolutional networks for multi-class organ segmentation in contrast-enhanced CT. International Journal of Computer Assisted Radiology and Surgery 2018 vol.13, Issue 1 Supplement: 21-22, 2018
- [3] Özgün Ç, Abdulkadir A, Lienkamp S, et al.: 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. MICCAI 2016 Part II: 424–432, 2016.

■ 動脈 ■ 門脈 ■ 肝臓 ■ 脾臓 ■ 胃 ■ 胆嚢 ■ 膵臓



(a) 転移学習なし (b) 転移学習あり

図 2 それぞれの手法による抽出結果の 3D レンダリング。

表 1 従来手法と提案手法の抽出結果の Dice 係数。各臓器における最大値を太字にて示す。

Dice	転移学習なし	転移学習あり
動脈	81.3%	84.6%
門脈	78.0%	82.8%
肝臓	92.2%	96.6%
脾臓	87.6%	92.5%
胃	91.2%	80.9%
胆嚢	57.4%	73.8%
膵臓	75.7%	80.4%
平均	80.5%	84.5%

Study on Multi-class Organ Segmentation from Abdomen Thick-slice CT Volumes using Transfer Learning

Chen SHEN^{*1}, Holger R. ROTH^{*1}, Yuichiro HAYASHI^{*1}, Masahiro ODA^{*1},
Hirohisa ODA^{*1}, Kazunari MISAWA^{*2}, Kensaku MORI^{*1,3,4}

*1 Graduate School of Informatics, Nagoya University

*2 Aichi Cancer Center Hospital

*3 Information Technology Center, Nagoya University

*4 Research Center for Medical Bigdata, National Institute of Informatics

In this paper, we study on the influence of transfer learning in automated multi-class organ segmentation using abdominal thick-slice CT volumes. Automated organ segmentation plays a critical role in medical image processing. Despite thick-slice CT volumes with the thickness of 5 mm are used widely in clinical field, many researches have been done using thin-slice CT volumes with the thickness of 0.5 mm recently. Therefore, organ segmentation method for thick-slice CT volume is also necessary. However, direct application of 3D FCN trained by the thin-slice CT volume to thick-slice CT volume cause sever deteriorate in segmentation accuracy. Because the reconstruction pitch of the body axis is different. In this work, we apply transfer learning to a model which is trained using thin-slice CT volumes to improve the segmentation accuracy on abdominal multi-class organ segmentation in thick-slice CT volumes. In our experiment, the segmentation accuracy of thick-slice CT was improved 4% by when we used the transfer learning method.

Key words: Multi-class organ segmentation, Deep learning, Transfer learning, Thick-slice CT volumes

歯科的個人識別のための Relation Networks for Object Detection を用いた歯科用 Cone-beam CT における歯牙の検出

杓名 将太*¹ 村松 千左子*² 林 達郎*³ 周 向栄*²

西山 航*⁴ 有地 淑子*⁵ 原 武史*²

勝又 明敏*⁴ 有地 榮一郎*⁵ 藤田 広志*²

要旨

地震や津波などの大災害時には、多数の身元不明の遺体が生じる。その身元確認のために歯科情報が用いられることがあり、歯科的個人識別と呼ぶ。歯科的個人識別にはデンタルチャートという用紙に遺体の口腔内の所見を記録する必要があるが、一般の歯科医師も記録に協力する際、遺体を対象とした記録の経験に乏しいことから記録ミスや精神的負担が危惧される。そのため X 線写真から自動的にデンタルチャートの作成に必要な情報を取得する手法の開発が望まれている。本研究では、歯科用 Cone-beam CT を対象とし、情報の取得の前段階として画像上の歯牙領域を検出する。検出ネットワークとしてオブジェクト同士の関係性を学習できるとされる Relation Networks for Object Detection を使用する。提案手法を 10 症例 20 上下顎に適用したところ、平均検出率は 97.6%、誤検出数は 0.8(個/顎)であった。検出に成功した歯牙に関して、歯種の分類成功率は 95.5%であり、良好な結果が得られた。

キーワード：歯科 CT 画像、深層学習、歯科的個人識別

1. はじめに

地震や津波などの大災害時において遺体の身元確認作業に歯科情報が用いられることが

あり、これを歯科的個人識別と呼ぶ。歯科情報は指掌紋や DNA 型の情報に比べ、生前試料の入手が容易であるという点や、遺体の損傷に強い点で優位性があり、東日本大震災でも高い有効性を示した。

歯科的個人識別には口腔内の所見を記録する必要があり、災害時には一般の歯科医師もその記録を行う。しかし、一般の歯科医師は遺体を対象とした記録の経験に乏しく、精神的負担が危惧されている[1]。また、所見データの照合に際しシステムティックな生前データの記録も必要となる。そのため、生前及び死後に撮影された歯科用 X 線写真から自動的に口腔内の所見を取得する方法の開発が望まれている。

*1 岐阜大学大学院自然科学技術研究科
知能理工学専攻知能情報学領域

[〒501-1194 岐阜県岐阜市柳戸 1-1]

e-mail: kutsuna@fjt.info.gifu-u.ac.jp

*2 岐阜大学工学部電気電子情報工学科
情報コース

*3 メディア株式会社

*4 朝日大学歯学部口腔病態医療学講座
歯科放射線学分野

*5 愛知学院大学歯学部歯科放射線学講座

従来研究[2]において、深層学習を用いて歯種の分類を行っており、高い精度が得られた。本研究では、従来研究が歯牙の検出と分類を2ステップで行うのに対し、Relation Networks for Object Detection [3] を用い1ステップで歯科用 Cone-beam CT(図1)上の歯牙の検出方法を提案し、その精度を評価した。

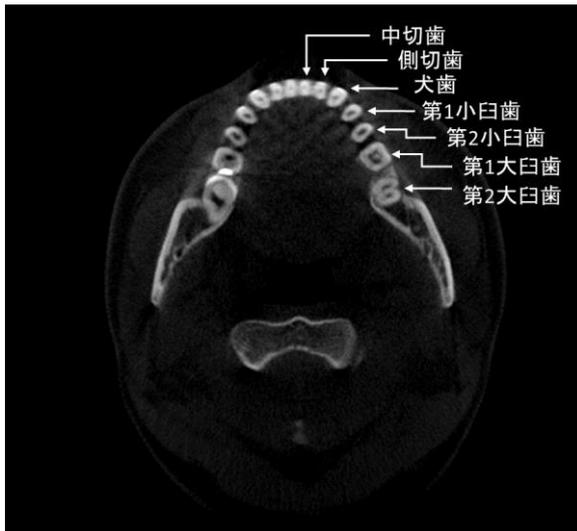


図1 歯科用 Cone-beam CT

2. 方法

2.1 試料画像

検出ネットワークへの入力画像は体軸断面のスライス画像をリサイズしたものを使用する。検出対象となる歯牙は中切歯～第3大臼歯の8種類となっている。

2.2 深層学習による歯牙の検出

本研究では検出ネットワークとして Relation Networks for Object Detection を利用する。このネットワークは物体間の関連性を学習できるよう構築されており、歯牙の並びや位置関係が歯種の分類において重要な要素となることから本研究に有効であると考えられる。

Relation Networks for Object Detection では物体候補領域を Region Proposal Network [4] から得た後に、relation module という新たに提案された関連性を学習する構造を利用し物体の分類と Box 回帰を行う。

2.3 検出結果の統合

同一症例の複数スライスで同位置に Box が検出されていれば、その Box は歯牙を正確に検出している可能性が高い。そこで、検出結果の統合を行う。各スライスにおける検出 Box 同士の一一致率が 0.7 以上の Box 群を同一の歯牙を検出しているとみなす。Box 群の座標の平均値を最終的な Box 座標の値とする。この時、同一の歯牙を検出しているとされる Box 群のうち群内の Box 数が 3 以下の群は偽陽性と判断する。

3. 結果

テスト症例には 10 症例を用いた。1 症例あたり 40 枚前後のスライス画像における検出結果を上下顎それぞれで統合し、20 の画像に対して検出精度を評価した。平均検出率は 97.6%、誤検出数は 0.8(個/枚)であった。検出に成功した歯牙に関して、歯種の分類成功率は 95.5% であり、良好な結果が得られた。

結果例を図2に示す。図2は成功例であるが、失敗例の典型として、誤分類となった歯牙から順に隣り合う歯牙が誤分類となるケースがみられ、物体間の関連性を学習した弊害であると考えられる。

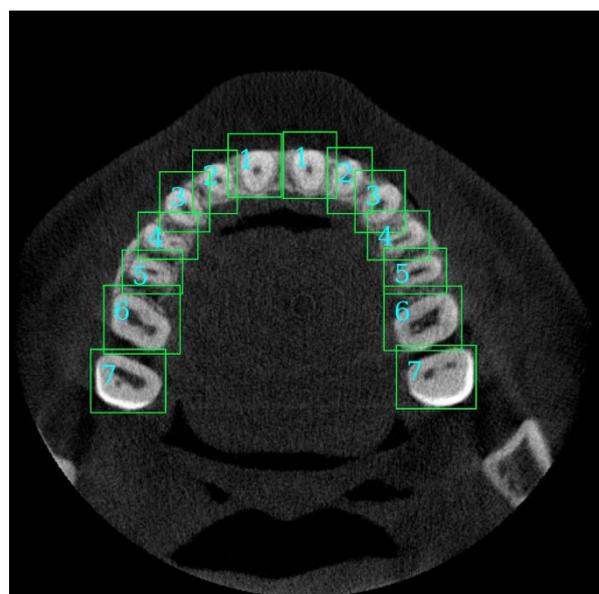


図2 結果画像例

図中の 1~7 は中切歯～第2大臼歯に対応

4. まとめ

本研究では、物体間の関連を学習するネットワークを用いた歯牙の検出手法を提案した。9割を超える精度を示し、本研究における提案手法は歯科的個人識別のシステム化に貢献できる可能性を示唆した。

謝辞

本研究を行うにあたり、有益なご助言を頂いた原・周研究室の皆様、朝日大学、愛知学院大学の皆様、メディア株式会社の皆様に感謝の意を表します。本研究の一部は、科学研究費新学術領域研究(課題番号 26108005)及び文部科学省科学研究費補助金(基盤 C 19K10347)によって行われました。

利益相反の有無

なし

文 献

- [1] 鈴木敏彦：歯科情報に基づく大規模災害時の個人識別. 日補綴会誌 **7**: 129-134, 2015
- [2] Miki Y, Muramatsu C, Hayashi T, et al.: Classification of teeth in cone-beam CT using deep convolutional neural network. Computers in Biology and Medicine **80**: 24-29, 2017
- [3] Han H, Jiayuan G, Zheng Z, Jifeng D, et al.: Relation Networks for Object Detection. The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018, pp. 3588-3597
- [4] Shaoqing R, Kaiming H, Ross G, et al.: Faster R-CNN: Towards real-time object detection with region proposal networks. NIPS, 2015

Tooth detection for dental identification with Relation Networks for Object Detection on dental Cone-beam CT

Shota KUTSUNA^{*1}, Chisako MURAMATSU^{*2}, Tatsuro HAYASHI^{*3}, Xiangrong ZHOU^{*2}, Wataru NISHIYAMA^{*3},
Yoshiko ARIJI^{*5}, Takeshi HARA^{*2}, Akitoshi KATSUMATA^{*4}, Eichiro ARIJI^{*5}, Hiroshi FUJITA^{*2}

*1 Graduate School of Natural Science and Technology, Gifu University

*2 Department of Electrical, Electronic and Computer Engineering, Information Course, Gifu University

*3 Media Co., Ltd

*4 Department of Oral Radiology, Asahi University School of Dentistry

*5 Department of Oral and Maxillofacial Radiology, Aichi-Gakuin University School of Dentistry

A large number of unidentified corpses are found in a disaster such as earthquakes and tsunami. Dental information is sometimes used for identification of corpses and is called dental identification. There are risks of mental burden and mistakes due to inexperience when general dentists cooperate in recording dental chart which is a record of oral findings. Therefore, development of a method that automatically acquires information necessary for filing dental charts from dental radiographs is expected. In this study, we aim to detect teeth on dental cone-beam CT as a preliminary step of acquiring information using the Relation Networks for Object Detection, which takes into account the order of the dentition. The proposed method was applied to 10 test cases with upper and lower jaws. The average detection rate was 97.6% with 0.8 false positives per jaw. For those correctly detected teeth, the classification accuracy of tooth types was 95.5%. The result indicates the potential usefulness of the proposed method.

Key words: Dental CT, Deep learning, Dental identification

時間 - 周波数解析と CNN を用いた

呼吸音の自動分類

南 弘毅^{*1} 陸 慧敏^{*1} 金 亨燮^{*1}

平野 靖^{*2} 間普 真吾^{*2} 木戸 尚治^{*3}

要旨

呼吸器疾患の診断方法としては、聴診器を用いた呼吸音の聴診が長年用いられてきた。これは簡便で安全な診断方法である一方、聴診音の診断には定量的な評価基準がないため、医師の診断支援を行うシステムの開発が必要である。そこで本論文では、畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) を用いた呼吸音の自動分類手法の提案を行う。主な手法の流れとしては、呼吸音データに対して短時間フーリエ変換と連続ウェーブレット変換を適用し、スペクトログラム画像およびスカログラム画像を生成する。その後、生成した画像を用いて CNN による正常呼吸音、連続性ラ音、断続性ラ音の識別を行う。提案手法を呼吸音データ 22 症例に適用した結果、分類性能として Accuracy = 79.44[%], AUC = 0.942 を得た。

キーワード: 呼吸音, コンピュータ支援診断, 短時間フーリエ変換, 連続ウェーブレット変換, 深層学習

1. 序論

呼吸器疾患とは、呼吸器に起こる疾患の総称である。世界中で何億人もの人々が呼吸器疾患で苦しんでおり、毎年 400 万人以上の人々が死亡しているといわれている^[1]。また、世界保健機関(WHO: World Health Organization)の調査によると、2016 年における全世界での死因上位 10

位のうち 4 つを呼吸器疾患が占めており (3 位: 慢性閉塞性肺疾患 (COPD: Chronic Obstructive Pulmonary Disease), 4 位: 下気道感染症, 6 位: 気管, 気管支, 肺腫瘍, 10 位: 結核), 重大な疾患であると考えられる^[2]。

呼吸器疾患の診断方法として、聴診器を用いた呼吸音の聴診がある。聴診は簡便で安全な診断手法として広く用いられてきた。一方、聴診音の診断には定量的な評価基準がなく、医師の主観的判断によって診断が下される。そのため、経験を十分に積んだ医師でなければ異常音を聞き分けることが難しく、医師の技量によって診断結果が左右されるといった問題がある^[3]。そこで、医療データをデジタル化し、コンピュータによる定量化および解析を行い、出力結果を「第二の意見」として提示するコンピュータ支援診断(CAD: Computer Aided Diagnosis)システムのような、定量的かつ信頼性の高いシステムが必要であると考えられる^[4]。

*1 九州工業大学

〔〒804-8550 福岡県北九州市戸畑区仙水町 1-1〕

e-mail: Minami.koki689@mail.kyutech.jp

*2 山口大学

〔〒755-8611 山口県宇部市常盤台 2-16-1〕

*3 大阪大学

〔〒565-0871 大阪府吹田市山田丘 2-2〕

ところで近年、人工知能の分野において深層学習が注目を集めている。その中でも畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) が画像認識分野において最重要技術として位置づけられるようになった。医用画像処理分野においてもその重要性は増す一方である。呼吸音分類に関連した研究例としては、記録された心音データの正常・異常の分類を CNN によって行う手法が提案されているが改善すべき課題も多く残されている^[5]。

そこで本論文では、呼吸音データの一次元信号から二次元画像への変換を行い、呼吸音の特徴を示す画像を CNN に入力することにより、呼吸音の分類を行うための CAD システムの開発を試みる。

2. 手法

入力した呼吸音データを二次元画像に変換し、CNN の学習および識別に変換した画像を用いることにより、呼吸音の分類を行う。以下に詳細を示す。

(1) 音声信号の前処理

入力した呼吸音データはデータごとに音量の大きさが異なるため、音量の違いによる影響を低減するために音量の正規化を行う。また、100~2000[Hz]の帯域通過フィルタを原呼吸音データに適用し、聴診に重要な周波数帯域以外の信号の除去を行う^[6]。

(2) 信号変換

前処理を行った呼吸音データに対し、信号変換を行う。本論文では短時間フーリエ変換を用い、スペクトログラムと呼ばれる画像に変換する方法および連続ウェーブレット変換を用いたスカログラムと呼ばれる画像に変換する方法を使用する。各手法について以下に詳細を示す。

(A) 短時間フーリエ変換^[7-9]

短時間フーリエ変換の定義について説明していく。まず、有限な時間長 L を有する窓関数と

呼ばれる信号を用意する。窓関数を式(1)に示す。

$$\omega(t) = \begin{cases} 1, & \left(-\frac{L}{2} \leq t \leq \frac{L}{2}\right) \\ 0, & (\text{otherwise}) \end{cases} \quad (1)$$

窓関数は、解析対象の信号を切り出す役目もっている。本論文で用いる窓関数はハミング窓 (Hamming Window) である。ハミング窓を式(2)に示す。

$$\omega(t) = 0.54 - 0.46 \cos\left(\frac{2\pi t}{L}\right) \quad (2)$$

窓関数を時間軸上移動させながら信号 $f(t)$ との積をとり、切り出した有限長信号を式(3)に示す。

$$\omega(t - \tau)f(t) \quad (3)$$

ここで τ は時間位置 (窓関数の位置) である。こうして窓関数で切り出された有限長信号に対してフーリエ変換を適用することにより、短時間フーリエ変換が定義される。短時間フーリエ変換を式(4)に示す。

$$F_{\omega}(\omega, \tau) = \int_{-\infty}^{+\infty} \omega(t - \tau)f(t)e^{-j\omega t} dt \quad (4)$$

また、短時間フーリエ変換によるパワースペクトルを式(5)に表す。

$$|F_{\omega}(\omega, \tau)|^2 = \left| \int_{-\infty}^{+\infty} \omega(t - \tau)f(t)e^{-j\omega t} dt \right|^2 \quad (5)$$

パワースペクトルを2次元平面 ($\tau - \omega$ 平面: 時間-周波数平面) 上に3次的に表現すると、時間に応じてパワースペクトルがどのように変化するかを視覚的にとらえることができる。このような図をスペクトログラムと呼ぶ。

本論文では、時間長 L を40[ms]、時間位置 τ を20[ms]ずつずらしながら短時間フーリエ変換を行い、スペクトログラムの生成を行った。生成した画像の例を図1に示す。

(B) 連続ウェーブレット変換^[7, 10, 11]

連続ウェーブレット変換は、ウェーブレット関数 $\psi(t)$ から生成される信号と、対象とする信号 $f(t)$ との内積で定義されている。連続ウェーブレット変換を式(6)に示す。

$$W_{\psi}(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} f(t)\psi\left(\frac{t-b}{a}\right) dt \quad (6)$$

ここで a は時間軸のスケール比率、 b は時間軸状

の推移（移動）を表している。また、本論文ではウェーブレット関数 $\psi(t)$ にガボール（モルレー）ウェーブレットを用いる。ガボールウェーブレットを式(7)に示す。

$$\psi(t) = \frac{1}{2\sqrt{\pi}\sigma} e^{-\frac{t^2}{2\sigma^2}} e^{-it} \quad (7)$$

式(6)の 2 乗関数

$$|W_\psi(a, b)|^2 = \left| \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} f(t) \psi\left(\frac{t-b}{a}\right) dt \right|^2 \quad (8)$$

は時間-スケール平面上のある点での成分のエネルギー分布を表す。このエネルギー分布をスカログラムと呼ぶ。生成した画像の例を図 2 に示す。

(3) 画像枚数の拡張

作成した画像は、スペクトログラム、スカログラムともにフレーム長 5[s]、フレームシフト長 1[s]として画像を切り取り、CNN への入力画像とした。フレーム長を 5[s]に設定した理由としては、安静時の健康な成人の平均的な呼吸数が毎分 12~20 回であることから^[12]、呼気および吸気の特徴をとらえた画像を入力とするためである。

(4) CNN による分類

本論文では大規模なイメージデータセットである ImageNet を用いて学習した VGG-16^[13] ネットワーク構造をベースに転移学習を行った。本論文で用いるネットワーク構造を表 1 に示す。なお、畳み込み層 10 層までの重みを凍結し、それ以降の層を生成した画像で再学習を行った。

3. 実験と結果

(1) 呼吸音データの詳細

実験に用いる症例は書籍の付録 CD^[14]に収録されているデータを用いた。分類は三上らが報告した呼吸音分類の原案^[15]に基づいている。症例数は正常呼吸音(normal)6 症例、連続性ラ音(continuous sound)6 症例、断続性ラ音(crackle)10 症例の計 22 症例である。また音声データの長さは 17~47 秒である。

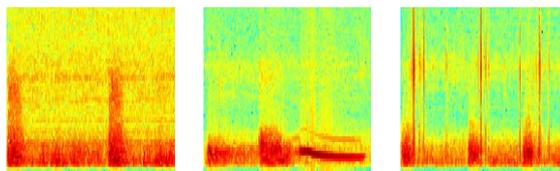


図 1 スペクトログラムの例

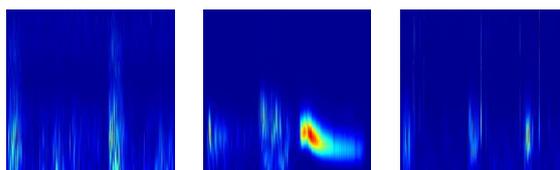


図 2 スカログラムの例

(2) 評価方法

本論文では 3 分割交差検証法により、各テストデータに対する全体正解率 (accuracy) [%]および ROC (Receiver Operating Characteristic) 曲線に基づく AUC (Area Under the Curve) を求め、その平均を算出することにより、分類器の性能評価を行う。なお、ROC 算出時の分類結果については連続性ラ音および断続性ラ音を異常、正常呼吸音を正常として評価を行う。各データセットのデータ数を表 2 に示す。

(3) 実験結果

表 3 に 3 分割交差検証法による分類器の性能評価の結果を示す。ランダムに構成したデータセットに対し、平均 Accuracy: 79.44, 平均 AUC: 0.942 を得た。

4. 考察

呼吸音データセットに対し画像変換を行い、CNN による正常・異常音の自動分類を行った結果、良好な結果を得たが、一部のデータにおいては正しく分類できない例もあった。

誤分類が起きた原因としては、CNN の学習段階で呼吸音の特徴を十分に捉えることができなかったためであると考えられる。同じ分類を示す呼吸音でも、疾患の違いや症状の進行度によってスペクトログラムおよびスカログラムの示す特徴が異なるためである。本論文では学

表 1 ネットワーク構造

Layer	Filter size	Stride	Output size	Remarks
Input	-	-	192×192×3	-
Conv.1	3×3	1×1	192×192×64	ReLU
Conv.2	3×3	1×1	192×192×64	ReLU
Pool.1	2×2	2×2	96×96×64	-
Conv.3	3×3	1×1	96×96×128	ReLU
Conv.4	3×3	1×1	96×96×128	ReLU
Pool.2	2×2	2×2	48×48×128	-
Conv.5	3×3	1×1	48×48×256	ReLU
Conv.6	3×3	1×1	48×48×256	ReLU
Conv.7	3×3	1×1	48×48×256	ReLU
Conv.8	3×3	1×1	48×48×256	ReLU
Pool.3	2×2	2×2	24×24×256	-
Conv.9	3×3	1×1	24×24×512	ReLU
Conv.10	3×3	1×1	24×24×512	ReLU
Conv.11	3×3	1×1	24×24×512	ReLU
Conv.12	3×3	1×1	24×24×512	ReLU
Pool.4	2×2	2×2	12×12×512	-
Conv.13	3×3	1×1	12×12×512	ReLU
Conv.14	3×3	1×1	12×12×512	ReLU
Conv.15	3×3	1×1	12×12×512	ReLU
Conv.16	3×3	1×1	12×12×512	ReLU
Pool.5	2×2	2×2	6×6×512	-
FC1	-	-	1×1×4096	ReLU, Dropout
FC2	-	-	1×1×4096	ReLU, Dropout
FC3	-	-	1×1×3	Softmax

表 2 各データセット数

	Dataset1	Dataset2	Dataset3
Continuous	90	90	90
Crackle	172	172	172
Normal	72	72	72
Total	334	334	334

表 3 CNN の精度評価

Dataset	Accuracy[%]	AUC
1	78.14	0.913
2	85.03	0.979
3	75.15	0.934
Average	79.44	0.942

習データが少数でありかつ学習データ数が症例ごとに偏っていたため、データ数を増やし、偏りを改善することにより性能を向上させることができると考えられる。また、短時間フーリエ変換と連続ウェーブレット変換以外の音声信号から画像信号への変換手法の適用、およ

びCNNの構造の改良を行うことを検討したい。

最後に、本論文では書籍の付録 CD に収録されている呼吸音データで実験を行った。そのため、呼吸音データを録音条件が統一されていない。本論文の有効性をより示すためには、録音条件が統一されたデータで実験を行うことが

必要であり、これらも今後の課題である。

5. 結論

本論文では、呼吸音データの一次元信号から二次元画像への変換を行い、呼吸音の特徴を示す画像を CNN に入力することにより、呼吸音の分類を行うための CAD システムの開発を行った。提案手法を呼吸音 22 症例に適用した結果、分類器の性能として accuracy = 79.44[%], AUC = 0.942を得ることができた。

今後は、さらなる分類精度の向上のため、データ数の増加、新たに音声信号から画像信号への変換手法の考案や、CNN の構造の改良と、録音条件が統一された新たなデータで実験を行い、本論文の有効性を示す予定である。

謝辞

本研究を進めるにあたり、貴重なご助言を賜った東京慈恵会医科大学付属病院の橋本典生先生に深く感謝いたします。

利益相反の有無

なし

文 献

- [1] Ferkol T, Schraufnagel D: The global burden of respiratory disease. *Annals of the American Thoracic Society* **11**(3): 404-406, 2014
- [2] <https://www.who.int/en/newsroom/factsheets/detail/the-top-10-causes-of-death>
- [3] Kandaswamy A, Kumar CS, Ramanathan RP, et al.: Neural classification of lung sounds using wavelet coefficients. *Computers in Biology and Medicine* **34**(6): 523-537, 2004
- [4] Doi K: Computer-aided diagnosis in medical imaging: Historical review, current status and future potential. *Computerized Medical Imaging and Graphics* **31**(4, 5): 198-211, 2007
- [5] Rubin J, Abreu R, Ganguli A, et al.: Classifying heart sound recordings using deep convolutional neural networks and mel-frequency cepstral coefficients. *2016 Computing in Cardiology Conference*: 813-816, 2016
- [6] Göğüş FZ, Karlik B, Harman G: Classification of asthmatic breath sounds by using wavelet transforms and neural networks. *International Journal of Signal Processing Systems* **3**(2): 106-111, 2015
- [7] 和田：よくわかる信号処理—フーリエ変換からウェーブレット変換まで。森北出版, pp.14-84, 2009
- [8] 谷萩：デジタル信号処理の理論 1 基礎・システム・制御。コロナ社, pp73-80, 1985
- [9] 小野：短時間フーリエ変換の基礎と応用。日本音響学会誌 **72**(12): 764-769, 2016
- [10] 新井：ウェーブレット解析の基礎理論。森北出版, pp.20-29, 2000
- [11] Rioul O, Vetterli M: Wavelets and signal processing. *IEEE Signal Processing Magazine* **8**(4): 14-38, 1991
- [12] Barrett KE, Barman SM, Boitano S, et al.: *Ganong's Review of Medical Physiology, Twenty-Four Edition*. McGraw-Hill Education, New York, 2012, p.619
- [13] Simonyan K: Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*: 2014
- [14] 川城, 阿部, 菊池 他：CD による聴診トレーニング 呼吸音編 改訂第 2 版。南江堂, pp.25-64, 2011
- [15] Mikami R, Murao M, Cugell DW, et al.: *International Symposium on Lung Sounds. Synopsis of proceedings*. *Chest* **92**(2): 342-345, 1987

Automatic Classification of Respiratory Sounds Based on Time-Frequency Analysis and Convolutional Neural Network

Koki MINAMI^{*1}, Huimin LU^{*1}, Hyoungseop KIM^{*1}, Yasushi HIRANO^{*2}, Shingo MABU^{*2}, Shoji KIDO^{*3},

*1 Kyushu Institute of Technology

*2 Yamaguchi University

*3 Osaka University

Auscultation of respiratory sounds is very important for discovery of respiratory disease. However, there is no quantitative evaluation method for the diagnosis of respiratory sounds. It is necessary to develop a system to support the diagnosis of respiratory sounds. We describe the development of an algorithm for the automatic classification of respiratory sounds as normal, continuous sound or crackle. Our approach consists of two major components. Firstly, transformation of one-dimensional signals into two dimensional time-frequency representation images using short-time fourier transform and continuous wavelet transform. Secondly, classification of images using convolutional neural networks. In this paper, we apply our proposal method to 22 respiratory sound data, and achieved accuracy of 79.44[%] and AUC based on ROC curve of 0.942.

Key words: Respiratory Sounds Classification, Computer Aided Diagnosis, Short-Term Fourier Transform, Continuous Wavelet Transform, Convolutional Neural Network

HE 染色標本画像と診断テキストデータを併用する 免疫染色パターン推定

橋本 典明^{*1} 横田 達也^{*1} 中黒 匡人^{*2} 高野 桂^{*2}

中村 栄男^{*2} 竹内 一郎^{*1,3,4} 本谷 秀堅^{*1}

要旨

悪性リンパ腫は血液細胞に由来するがんで、白血球の1種であるリンパ球ががん化した病気である。これらの病気は多くのサブタイプに細分され、病理診断ではヘマトキシリン・エオジン(HE)染色標本を観察したのち複数の免疫染色標本を観察することで最終的な病名の決定が行われる。病理画像解析技術を用いた悪性リンパ腫の診断支援応用として HE 染色標本画像からのサブタイプ分類などが考えられるが、実際の診断においてもサブタイプ分類には複数の免疫染色の施行が必要であることから、HE 染色標本画像からの病名の同定は困難であることが予想される。本研究では、病理診断テキストデータが持つ免疫染色情報を解析し、HE 染色画像と組み合わせることにより、各症例の HE 染色標本画像に対するサブタイプの候補群を推定し、サブタイプを一意に決定するための免疫染色の組み合わせを求める手法を提案する。

キーワード：悪性リンパ腫，病理画像，免疫組織化学染色，バーチャルスライド

1. はじめに

悪性リンパ腫は血液細胞に由来するがんで、白血球の一種であるリンパ球ががん化した病気である。これらの病気は多くのサブタイプに細分され、病理診断ではヘマトキシリン・エオジン(HE)染色標本を観察したのち複数の免疫染色標本を観察することで最終的な病名の決定が行われる。病理画像解析技術を用いた悪性リンパ腫の診断支援応用として HE 染色標本画像からのサブタイプ分類などが考えられるが、同じサブタイプに対しても異なる免疫染色が

行われることから、HE 染色画像から得られる情報は症例ごとにばらつきがあり解析が困難な症例も存在することが予想される。

本稿では、病理診断テキストデータが持つ免疫染色情報を解析し HE 染色画像と組み合わせることにより、HE 染色標本画像からサブタイプを一意に決定するための免疫染色パターンを予測する手法の提案を目的とし、各症例間における免疫染色データの解析を行う。

2. 手法

本研究で用いる悪性リンパ腫組織病理標本は、2003-2018年に診断コンサルテーションのため名古屋大学医学部附属病院宛てに送られたものであり、5539症例について診断名、施行免疫染色、部位などからなるテキスト情報が与えられている。診断病名から得られる総サブタイプは修飾語が異なるものを含め約2700種類、また使用された免疫染色は110種類である。図1に悪性リンパ腫標本画像の例を示す。

*1 名古屋工業大学大学院工学研究科
〔〒466-8555 名古屋市昭和区御器所町〕
e-mail: hashimoto.noriaki@nitech.ac.jp

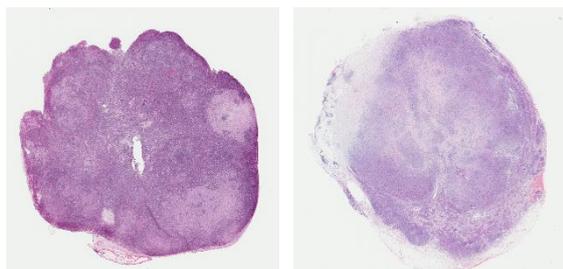
*2 名古屋大学医学部附属病院

*3 理化学研究所

*4 物質・材料研究機構

各症例に対するテキストデータには施行した免疫染色の組み合わせおよびその反応が含まれており、実際には同じサブタイプの症例においても施行されている免疫染色の組み合わせにばらつきがあることから、HE 染色標本の観察で得られる情報にも違いがあることが推察される。免疫染色パターンと HE 染色標本画像の有する特徴の関係性を示すことにより、HE 染色標本画像から適切な免疫染色の組み合わせを予測する問題などへの応用も考えられる。

本研究では数量化 III 類[1]を用いて免疫染色および症例の関係性を数量化する。数量化 III 類は各サンプルが変数に反応したか否かといった質的データに基づき数量化を行う手法であり、ここでは各症例が免疫染色 110 種類に対して各染色を施行したか否かを二値で表したデータを用いて手法を適用する。



(a) 混合細胞型 (b) 結節硬化型

図 1 悪性リンパ腫の例 (ホジキンリンパ腫)。

3. 実験

5539 症例の免疫染色情報に対して数量化 III 類を適用した。対象の症例に関して、第 1, 第 2 数量を x 軸, y 軸としてプロットしたものを図 2 に示す。今回対象としたサブタイプは混合細胞型ホジキンリンパ腫(HLMC), 結節硬化型ホジキンリンパ腫(HLNS), びまん性大細胞型 B 細胞リンパ腫(DLBCL), 血管免疫芽球性 T 細胞リンパ腫(AITL)であり, DLBCL については胚中心 B 細胞型(GCB)と非胚中心 B 細胞型(nGCB)に細分され, 計 5 種類のサブタイプの症例を示している。図中の各点は互いに近ければ近いほど施行された免疫染色の組み合わせが類似していることを示しており, ホジキンリンパ腫, B 細胞由来リンパ腫, T 細胞由来リンパ腫の 3 種類の疾患群のプロットが大別できる分布が確認

された。独立かつ密集した症例はそのサブタイプの特徴をよりよく表す典型的な症例であることが予想され, 一方で異なるサブタイプ間で分布が重なっている症例においては他のサブタイプと判断に迷うような非典型的な症例であることが考えられる。このような数量に対し, 第 3 数量までを使用した 3 次元空間内でカーネル密度推定を適用し, 各症例に対するサブタイプらしさを典型度として定量化した。

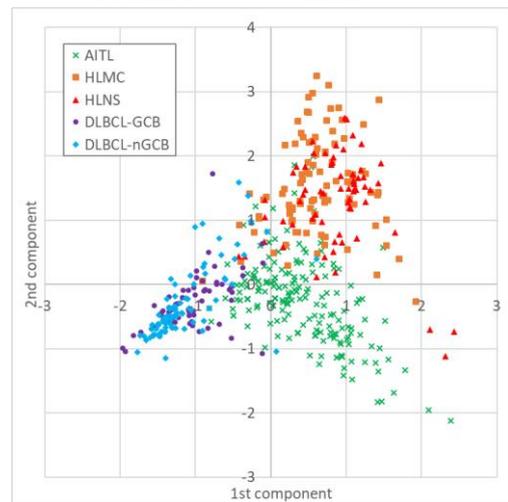


図 2 数量化 III 類により算出された, 免疫染色の組み合わせ間の相関に基づく症例の分布。サブタイプごとにまとまった分布が観察される。

4. まとめ

悪性リンパ腫の診断テキストデータ中の免疫染色情報を解析することで, 各症例のもつサブタイプの典型度の算出を行った。撮影された HE 染色画像を組み合わせた解析を行うことで, 提案した典型度の妥当性を検証していく。

謝辞

本研究は堀科学芸術振興財団の助成を受けて行われた。

利益相反の有無

なし

文献

- [1] Hayashi C: On the prediction of phenomena from qualitative data and the quantification of qualitative data from the mathematico-statistical point of view. *Annals of the Institute of Statistical mathematics*, **3**: 69-98, 1951

Prediction of Immunostaining Patterns by Combining H&E Stained Pathological Images and Diagnostic Text Data

Noriaki HASHIMOTO*¹, Tatsuya YOKOTA*¹, Masato NAKAGURO*², Kei KOHNO*², Shigeo NAKAMURA*²,
Ichiro TAKEUCHI*^{1,3,4}, Hidekata HONTANI*¹

*1 Nagoya Institute of Technology

*2 Nagoya University Hospital

*3 RIKEN

*4 National Institute for Materials Science

Malignant lymphoma is a group of blood cancers that develop from lymphocytes, a kind of white blood cell. As these diseases are classified into more than 70 subtypes, pathological diagnosis is performed by observing hematoxylin and eosin (H&E) stained tissues and several immunohistochemically stained tissues. For computer aided diagnosis, subtype classification of malignant lymphoma from digital HE stained tissue images is considered, but it is quite challenging because of varieties of malignant lymphoma tissue specimens and difficulties of diagnosis even by expert pathologists. In this study, by analyzing immuno staining information included in diagnostic text data and combining with H&E stained tissue images, we develop a method to predict immuno staining patterns required to determine diseases.

Key words: Malignant lymphoma, Pathological image, Immunohistochemical staining, Whole slide image

舌の表面特徴に基づく機械学習を用いた

舌苔分布推定手法の検討

吉村裕一郎^{*1}, 太田雄大^{*2}, Vladimir Bochko^{*3}, Pauli Falt^{*4},

Markku Hauta-Kasari^{*3}, 並木隆雄^{*5}, 中口俊哉^{*1}

要旨

近年コンピュータ支援による定量的な舌診断に関する研究が進められている。舌診は漢方の診断法の一つであり、舌の色彩、形状、湿潤、舌苔の状態等から患者の体調を診断するが、計測の難しさから舌苔を解析する研究は少ない。そこで、本研究ではRGB画像からの機械学習を用いて舌苔の推定を試みた。具体的には、舌苔に関する指標である舌苔の物理量と被覆領域を推定した。教師データとしては、先行研究で舌苔計測における有効性が示された、蛍光撮影画像を用いる。回帰型学習器を用いて蛍光量を推定し、蛍光量と物理量との関係式から物理量を推定した。また被覆領域推定においては、分類型学習器を用いて蛍光撮影画像から小領域単位で被覆有無のラベルを作成し、舌苔被覆の有無を判別した。実験では学習器としてRandom Forestを用いて性能を評価した。13名の舌画像から3231サンプルを抽出し交差検証を行った結果、通常撮影されたRGB画像からの舌苔被覆領域推定手法の有効性が示唆された。

キーワード：舌画像解析，漢方医学，舌苔，機械学習，テクスチャ解析

1. 研究目的

漢方医学の診断法の一つである舌診は、舌の色彩、形状、湿潤、舌苔の状態等の舌所見から、患者の体調や血流の状態、病気の進行度合いを診断する。漢方医学の分野に於いて古くから舌診は重視されているが、その理論は医師の主観に深く依存しており、客観性、系統性が欠けている。そこで近年では、コンピュータ支援によ

る定量的な舌診断に関する研究が進められている[1]-[8]。一方で対象は舌本来の(舌苔が無い舌質)領域の色彩や形状、湿潤等に注目しており、舌苔を計測、解析する研究は少ない。

舌苔とは舌表面に付着している苔状の物質である。主として糸状乳頭に由来する剥離上皮、食物残渣、唾液、微生物、白血球などの堆積によって形成されたものとされる。医師が舌苔を診る際には色や量、被覆状態、湿潤状態について観察する。過剰な舌苔は、消化器疾患や糖尿病と関連付けられる[9]ことが知られており、健康状態と生活習慣の悪化を、舌苔量より推測することができることから、舌診において重要な指標の一つとされる。

舌苔計測の先行研究として、波長405nmにピークを持つ光源により舌苔中の細菌が励起して蛍光を発することを用いた蛍光撮影がある[10]。舌苔の量に応じて蛍光が強くなることが

*1 千葉大学フロンティア医工学センター
〔〒263-8522 千葉市稲毛区弥生町 1-33〕 e-mail: yysmr@chiba-u.jp

*2 千葉大学大学院融合理工学府

*3 Electrical Engineering and Energy Technology, University of Vaasa

*4 University of Eastern Finland

*4 千葉大学医学部和漢診療科

投稿受付：2018年5月15日

確認されており、蛍光撮影の舌苔計測における有効性が示されている。しかし、蛍光撮影は紫外光に近い光源を用いており、専用の蛍光撮影装置が必要であるため、汎用性や安全性に課題が残る。そこで本研究では、通常撮影された舌の RGB 画像から機械学習を用いて舌苔量に関連する指標である蛍光を推定することで、舌苔量を推定する事を試みた。

2. 撮影環境

1) 舌撮影装置

本研究では舌の RGB 画像と蛍光撮影により取得される蛍光画像を使用する。各画像の撮影には、図 1 に示す積分球を使用した舌撮影装置 (TIAS : Tongue Image Analyzing System, タカノ株式会社)[2]を用いた。図 1 はそれぞれ TIAS の外観を示しており、図 1(b)に確認できる穴正面に顔を置き、舌画像を撮影する。TIAS では、積分球内で照明を使用することにより内部で拡散反射が生じ、舌全体に対して光が均一に照射される。これにより、舌粘膜や唾液による光沢が発生しない画像が取得でき、外部の環境に依存しない撮影が可能となる。また被験者の顎を顎台に固定することにより、被験者が安定した姿勢で舌を出すことが可能となるよう工夫を施している。よって撮影装置に対する舌の角度と距離を一定に保った上、同一の環境での舌の撮影が可能となる。撮影には Canon 製の EOS Kiss X7(画像サイズ : 5184 画素×3456 画素, 階調 : RGB8 ビット)を使用した。

2) 蛍光撮影

文献 11, 12 より、歯垢に含まれる口腔内細菌が 405nm の波長光に励起され、605nm の波長の蛍光を発することが報告されている。また歯垢と舌苔に含まれている細菌には関連があり、舌苔も同様に 405nm の波長光に励起され、蛍光が発生することが、舌苔の採取前後の蛍光画像と舌苔の乾燥質量を使用した実験によって確認されている[10]。本研究における蛍光撮影は、これらの先行研究において開発された撮影方法を TIAS に導入したものであり、紫外域に近い波長光を撮影対象に照射し、対象物が発した蛍

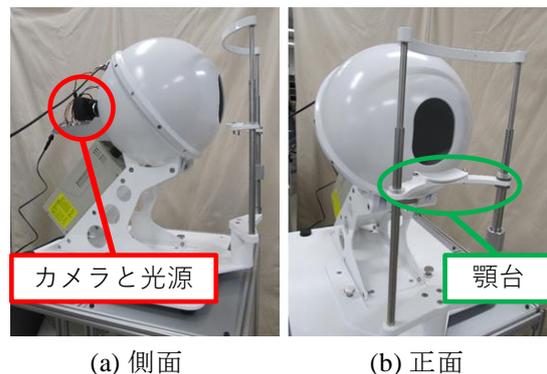


図 1 積分球を用いた舌撮影装置(TIAS) [2]



図 2 TIAS 内部に設置した励起光源

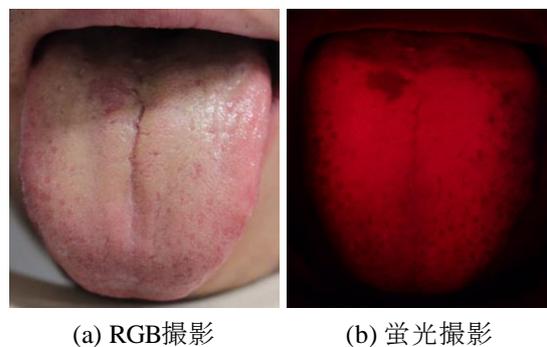


図 3 TIAS による撮影画像例

光を取得する。

蛍光撮影には 405nm にピークを持つ LED 光源(OSV5XME1C1E, OptoSupply Co.Ltd.)を TIAS 内部に 12 個設置した。設置した光源を図 2 に示す。光源により舌苔が励起され発生した蛍光を取得することで蛍光画像を撮影する。蛍光撮影装置で使用する励起光源は近紫外領域に近く、撮影対象も粘膜組織である舌であるため安全性に配慮が必要である。提案システムでは、

ACGIH(American Conference of Governmental Industrial Hygienists)の指針である、波長 380nm の場合、最大 $47\text{J}/\text{cm}^2$ という指標に対して、 $245\ \mu\text{W}/\text{cm}^2$ であり、およそ 53 時間連続照射しない限り基準値を超えない事を確認した。更に安全性をより高めるために励起光源の照射時間を最小にすることを試みた。励起光源と撮影装置をストロボで同期させ、撮影する瞬間のみ励起光源を照射した。

舌撮影装置による同被験者の RGB 撮影画像と蛍光撮影画像例を図 3 に示す。図 3(a)において、舌苔が被覆している部位は白みが強く示されており、舌苔量が増すほど図 3(b)において、蛍光が強くなっていることが確認できる。

3. 提案手法

初めに TIAS により舌の RGB 画像と蛍光撮影された蛍光画像を取得する。RGB 画像から算出された複数の画像特徴量を入力とし、蛍光画像を教師データとした学習器により、舌の蛍光強度を推定する。また同様に蛍光画像を教師データとした学習器により、舌苔被覆領域の推定も行った。舌の RGB 画像と蛍光画像の画像サイズは共に 5184 画素×3456 画素である。

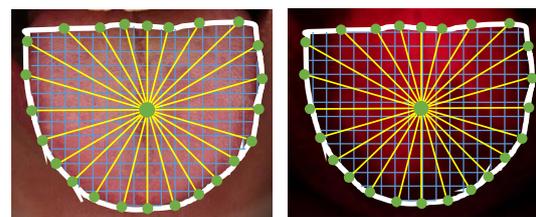
1) 舌輪郭の位置合わせ

TIAS を用いた実験では、RGB 画像と蛍光画像を取得する際、異なった光の照射を行っているため、同時に撮像する事は出来ない。従って舌領域において同一箇所の特徴量と教師データを生成するために RGB 画像と蛍光画像における舌輪郭の位置合わせを行う必要がある。

舌輪郭の位置合わせ手法は村井らの手法[5]を用いた。まず図 4 中の白線のようにそれぞれの舌画像において舌輪郭を手動で指定する。そして、黄色に示す重心を通る水平な線を基準に 15° ごと引いた直線と、緑点で示した輪郭線との 24 の交点と重心点を対応点として Thin Plate Spline method[13]により変形を行った。

2) 蛍光強度の推定

舌輪郭の位置合わせを行った舌画像を使用し、図 4 中の青いグリッド線に示すように、その領域内を 100 画素×100 画素の矩形の小領域



(a) RGB撮影

(b) 蛍光撮影

図 4 舌輪郭の位置合わせと小領域分割

表 1 学習に使用した特徴量

●	R, G, B, R/G, R/B値の平均
●	L*, a*, b*, a*/b*値の平均
●	H, S, V値の平均
●	グレースケール値の平均
●	フラクタル次元 (FD) 値
●	ガボールフィルタ (GF) 値 波長0.1, 0.2, 0.3, 0.4, 0.5[mm]
●	フーリエ解析の高周波成分
●	同時生起行列 14種類の特徴量
●	輝度値ヒストグラムの統計量 分散, 歪度, 尖度

に分割する。小領域ごとに、RGB 画像からはテクスチャや色彩に関する計 37 種類の特徴量を算出して学習器に入力した。蛍光画像からは小領域内の平均輝度値を蛍光強度として算出し、学習器出力の教師データとして使用した。算出した特徴量を表 1 に示す。色彩に関する特徴量として RGB 値や $L^*a^*b^*$ 値等をはじめとした基本的な色成分とそれらの比を用いた値を使用した。またテクスチャ特徴量としてフラクタル次元やガボールフィルタを算出し、舌表面の凹凸等の部分的変化を定量化した。

機械学習手法としては Random Forest 法[14]を使用し、ハイパーパラメータは Grid Search により最適化した。提案手法により学習された学習器を用いて舌の RGB 画像から舌表面の小領域ごとの蛍光強度を推定した。

3) 舌苔被覆領域の推定

蛍光強度の推定が可能となったことにより、矩形の小領域毎の蛍光量から、機械学習を用い

表 2 被験者の諸元

被験者	年齢	性別	疾患
1	24	男性	無し
2	22	男性	無し
3	24	男性	無し
4	25	女性	無し
5	22	女性	無し
6	22	女性	無し
7	23	女性	無し
8	24	女性	無し
9	24	男性	無し
10	22	男性	無し
11	23	男性	無し
12	24	男性	無し
13	22	女性	無し

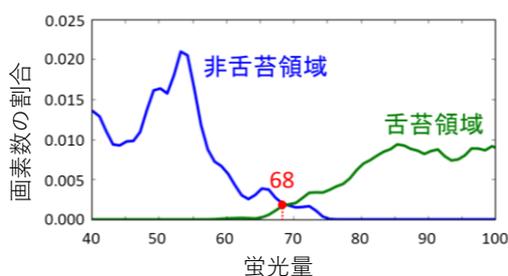


図 5 舌苔被覆領域の蛍光量分布

て舌苔領域の推定を行うことを検討した。

蛍光量を基に舌苔の被覆領域を決定するためには、蛍光量のしきい値を設定する必要がある。そこで比較的被覆領域が明瞭な 3 名の被験者の舌画像から、舌苔が被覆している領域と被覆していない領域のマーキングデータを作製した。図 5 に抽出した領域における、蛍光量の確率密度分布を示す。図 5 中の緑線は舌苔が被覆している領域の蛍光量を表し、青線は舌苔が被覆していない領域の蛍光量を表す。本研究においては、確率密度分布の交点である蛍光量 68 を舌苔被覆領域のしきい値として設定した。

この基準を基に、全ての蛍光画像から舌苔領域のマーキングデータを作製する。本データは RGB 画像と共に舌苔領域推定のための、機械学習における教師データとして使用する。機械学習手法には、同様に Random Forest 法を使用し、ハイパーパラメータは Grid Search により最適化した。提案手法により学習された学習器を用いて舌の RGB 画像から舌表面の小領域ごとの

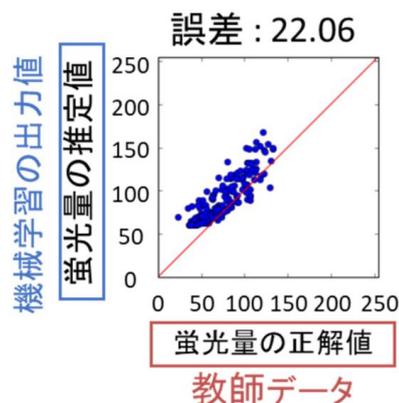


図 6 推定結果例

舌苔被覆の有無を推定した。

4. 実験

1) 蛍光強度の推定実験方法

蛍光強度推定における提案手法の有効性を評価するために 13 名の被験者に対して実験を行った。それぞれの被験者の諸元を表 2 に示す。尚、後述する実験結果などにおける被験者番号は、全て表 2 の被験者と対応している。実験では TIAS を用いて舌の RGB 画像と蛍光画像を連続して撮影し、上記の手法を用いて画像を矩形の小領域に分割する。全被験者の小領域の合計は 3231 サンプルとなった。

Leave One Subject Out (LOSO)の交差検証を行い、全ての被験者の舌画像で評価を行った。LOSO 交差検証とは、一人の被験者から得られるデータセットを評価用セット、残り被験者の全データセットを学習用セットとし、N 人の被験者に対して評価者を切り替えて N 回の評価を実施する交差検証法である。今回の評価では 13 名の被験者で LOSO 交差検証を実施した。

有効性を評価するために、提案手法により推定される蛍光強度と撮影された蛍光画像から取得される蛍光強度の差を平均平方二乗誤差により評価した。また、より視覚的に評価するために縦軸を提案手法により推定される蛍光強度、横軸を蛍光画像から取得される蛍光強度として交差検証ごとに誤差図を作成した。推定結果の出力例を図 6 に示す。誤差図内の青い点は矩形領域ごとの結果を示しており、正確な推

表 3 特徴量の重要度(1%以上)

特徴量	重要度 [%]
R/G	16.35
H	15.70
a*/b*	14.34
a*	12.04
R/B	7.57
S	5.73
G	4.06
B	2.34
GF[波長:0.2mm]	2.08
FD	1.78
グレースケール	1.59
歪度	1.44
R	1.37
GF[波長:0.3mm]	1.35
L*	1.33
GF[波長:0.4mm]	1.19
GF[波長:0.5mm]	1.07

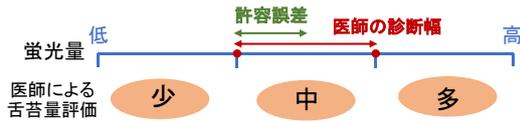


図 7 許容誤差決定における医師の基準

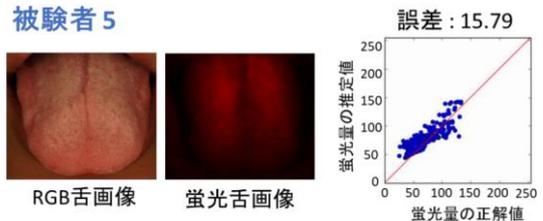
定である程，対角を結ぶ赤で示した理想直線の近くに位置する。

また特徴量の重要度を算出することで，各特徴量が推定精度にどの程度寄与しているかについて検証を行った。重要度が 1%以上である上位 17 種類の特徴量とその重要度を表 3 に示す。全 37 種類の特徴量を学習器に入力した場合と，前述の基準で選択した 17 種類の特徴量のみを学習器に入力した場合で精度評価を行い，特徴量選択の有効性を評価した。

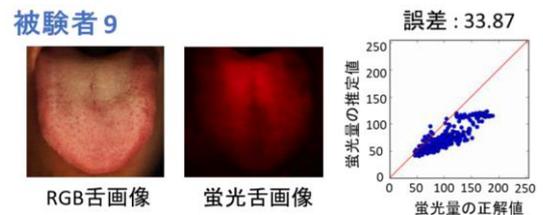
更に蛍光量推定の精度評価における許容誤差を設定した。許容誤差決定の概要図を図 7 に示す。漢方医学における従来の舌苔評価は，医師の目視による経験的評価がなされており，舌苔の厚さは 3 段階で評価される。この時実際に医師が見分けている診断幅は赤矢印で示した範囲で存在することから，今回は医師が見分けている診断幅の半分の値を許容誤差として設定した。よって本研究における医師の診断幅は

表 4 平均平方二乗誤差による評価

(a)37特徴量		(b)17特徴量	
被験者	二乗平均平方根誤差	被験者	二乗平均平方根誤差
1	36.14	1	31.38
2	23.89	2	23.36
3	18.72	3	17.07
4	18.01	4	17.70
5	15.99	5	15.79
6	20.00	6	14.49
7	19.33	7	16.75
8	34.24	8	32.87
9	37.97	9	33.87
10	9.86	10	13.68
11	15.72	11	20.98
12	21.14	12	22.84
13	19.23	13	16.92
平均	22.33	平均	21.35



(a) 被験者 5 の結果(許容誤差範囲内)



(b) 被験者 9 の結果(許容誤差範囲外)

図 8 蛍光量推定の評価結果

$$\text{医師の診断幅} = \frac{\text{蛍光量}_{max} - \text{蛍光量}_{min}}{3\text{段階}} \quad (1)$$

で示され許容誤差は

$$\text{許容誤差} = \frac{\text{医師の診断幅}}{2} \quad (2)$$

として設定する。

2) 蛍光強度の推定実験

被験者 13 名を交差検証し，平均平方二乗誤差により評価をした。全 37 種類の特徴量を入力した場合と 17 特徴量のみを学習器に入力した場合の交差検証における推定誤差を表 4 に示

す。平均推定誤差，最大推定誤差及び 13 名中 10 名の被験者における推定誤差で 17 特徴量のみを使用した場合の精度が，上回ったことを確認した。従って特徴量選択の有効性が示唆されたことから，後述する実験においては 17 特徴量のみを使用した結果を示す。

交差検証の平均誤差は 21.35，最大誤差は 33.87 となった。また本実験における許容誤差は式(1)，(2)と表 4(b)より 27.29 である。交差検証の推定結果において，許容誤差範囲内にある被験者例を図 8(a)に，範囲外の被験者例を図 8(b)にそれぞれ示す。

評価結果より，13 名中 10 名の被験者は許容誤差範囲内となった。図 8(a)に示すように，誤差が少ない被験者の場合，蛍光画像から取得された蛍光量が上昇するにつれて，提案手法により推定した蛍光量が上昇していることが確認できる。つまり舌苔の被覆度合いに応じた，正確な推定がなされていることが確認できる。一方で，図 8(b)に示す被験者においては，推定誤差が大きく，許容誤差が達成できていない。また推定結果より，舌苔の被覆が少ない領域においては推定精度が高いが，舌苔が多く被覆している領域においては，推定精度が低いことが確認された。これらの誤差が大きい被験者は，舌苔が比較的少量に被覆している傾向が確認できることから，学習データの多様性が十分では無いことが考えられる。本実験で用いたデータセットにおいて，舌苔が少量に被覆しており，蛍光量が非常に大きいサンプルや，舌苔の色調が異なるサンプルが被験者毎にのみ存在する場合がある。この誤差は多様な舌苔サンプル画像を取得する事で改善が可能であるため，新たな画像の収集を試みることを検討する。

3) 舌苔分布の推定実験方法

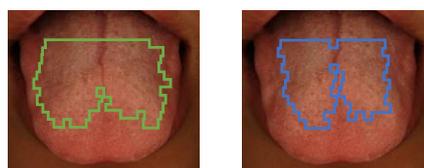
提案手法により RGB 画像より，舌苔量の推定が可能となったことから，次に舌苔分布の推定を行う。教師データとしては，引き続き舌輪郭の位置合わせ済みの，RGB 画像と蛍光画像を用いる。学習及び識別時には，前述の実験と同様に，100 画素×100 画素の矩形の小領域ごとに有無を判別する。正解ラベルは，被験者ごと

表 5 混同行列と識別率

		舌苔推定	
		陽性	陰性
正解ラベル	あり	78.9%	21.1%
	なし	31.0%	69.0%

正答率 74.2%

被験者 5 正答率：81.0%

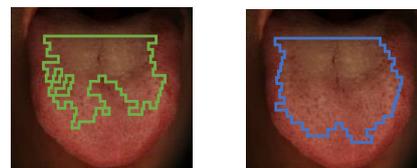


推定領域

正解領域

(a) 被験者 5 の推定結果

被験者 9 正答率：72.1%



推定領域

正解領域

(b) 被験者 9 の推定結果

図 9 舌苔被覆領域の推定結果

の蛍光画像から，3.3 節にて設定したしきい値を用いて舌苔の被覆の有無を判定する。舌苔被覆領域の推定精度は推定結果と正解ラベルを比較し，混同行列と識別正答率によって評価する。被験者数及び小領域数は前述の実験と同一の条件である。

混同行列を表 5 に示す。識別正答率は 74.2% であり，感度は 78.9%，特異度は 69.0% となった。被験者ごとの舌苔被覆領域推定結果例を図 9 に示す。図 9(a)は比較的高精度で舌苔被覆領域が推定された例であり，図 9(b)は一部の舌苔被覆領域が推定できていない例である。これは 3.3 節にて設定した，しきい値や小領域中に舌苔が占める割合が少ないような，境界付近の蛍

光量推定精度が起因していると考えられる。従って今後、医師などの専門家が領域を指定したマーキングデータを作製し、実験を行うことにより、精度が向上する事が期待できる。

5. 結論

本研究において、通常撮影された RGB 画像のみを用いて、舌苔の蛍光強度と舌苔分布を推定する手法を提案した。積分球を用いた舌撮影装置(TIAS)により取得される舌の RGB 画像から特徴量を算出する。また舌の蛍光画像から教師データとして蛍光強度を算出し、同一領域から特徴と蛍光強度を算出するために、RGB 画像と蛍光画像の舌輪郭の位置合わせを行った。

Random Forest 法により蛍光強度と舌苔被覆領域を推定し、実験により有効性を評価した。

今後の課題として、現在 20 から 24 歳の被験者 13 名からなるデータセットにより評価を行っており、データセット中の舌苔の多様性が不足していることが挙げられる。様々な年齢層、健康状態の被験者の舌画像を取得し、学習データセットにおける舌苔の多様性を向上させることが、今後の課題である。また舌苔の被覆領域を推定できたことにより、専門医が舌苔量を基準として診断を行う所見に対して、舌診断支援システムを開発し診断の提示方法について検討を行う。

利益相反の有無

なし

文 献

- [1] S. Yamamoto, Y. Ishikawa, T. Nakaguchi, et.al.: Temporal Changes in Tongue Color as Criterion for Tongue Diagnosis in Kampo Medicine, *Forsch Komplementmed* 2012, 80-85, 2012
- [2] Toshiya Nakaguchi, Kanako Takeda, Yuya Ishikawa, et.al.: Proposal for a new non-contact method for measuring tongue moisture to assist in tongue diagnosis, and development of the Tongue Image Analyzing System, which can separately

record the gloss components of the tongue, *BioMed Research International*, vol. 2015, ID 249609, 10, 2015

- [3] Fumina Kobayashi, Akira Morita, Takeshi Oji, et.al.: Breadth Measurement of Sublingual Vein using Near-Infrared Photography, *Proc. 1st International Conference on Advanced Imaging (ICAI2015)*, 269-271 (PB1-07), 2015
- [4] Yudai Ota, Toshiya Nakaguchi, Masami Shishikura, et.al.: Evaluation of Color Conversion Accuracy using Tongue Color Chart, *Proc. of 13th AIC Congress 2017*, OS24-04, 2017
- [5] Kazunari Murai, Toshiya Nakaguchi, Akira Morita, et.al.: Association Analysis of Tongue Color Spatial Distribution and Physiological Index based on Tongue Shape Normalization, *Proc. of 13th AIC Congress 2017*, OS24-03, 2017
- [6] Kazunari Murai, Toshiya Nakaguchi, Yuichiro Yoshimura, et.al.: Optimization for Thin Plate Spline Registration of Tongue Spectral Images, *Proc. of NOLTA2018*, 5183, 196-199, 2018
- [7] Tingxiao Yang, Yuichiro Yoshimura, Akira Morita, et.al.: Fully Automatic Segmentation of Sublingual Veins from Retrained U-net Model for Few Near Infrared Images, *The Ninth International Workshop on Image Media Quality and its Applications (IMQA2018)*, 46-52, 2018
- [8] Qichao Tang, Tingxiao Yang, Yuichiro Yoshimura, et.al.: Full Automation of The Tongue Image Analyzing System, *The Ninth International Workshop on Image Media Quality and its Applications (IMQA2018)*, 53-56, 2018
- [9] 小島 健, “舌苔の臨床的研究”, *日本口腔外科学会*, 31(7), 1659-1678 (1985)
- [10] Yudai Ota, Shuhei Iino, Toshiki Ichinose, et.al.: Proposal and Evaluation of

- Fluorescence Imaging System for Non-Contact Tongue Coating Measurement and Tongue Protrusion Guide, 第 35 回日本医用画像工学会大会 (JAMIT2016), 48, 2016
- [11] Coulthwaite L, Pretty IA, Smith PW, et.al.: The microbiological origin of fluorescence observed in plaque on dentures during QLF analysis, *Caries Res*, 40(2), 112-116, 2006
- [12] Thomas RZ, Van der Mei HC, Van der Veen MH, et.al.: Bacterial composition and red fluorescence of plaque in relation to primary and secondary caries next to composite : an in situ study, *Oral Microbiol Immunol*, 23(1), 7-13 ,2008
- [13] Bookstein, F. L.: Principal Warps: Thin-Plate Splines and the Decomposition of Deformations, *IEEE Transactions on Pattern Analysis and Machine Intelligence*.11(6): 567–585, 1989
- [14] Breiman, L.: Random Forests, *Machine Learning*, Vol.45, 5-32, 2001

A Study for Tongue Coating Estimation via Machine Learning using Tongue Surface Features

Yuichiro YOSHIMURA^{*1}, Yudai OTA^{*2}, Vladimir Bochko^{*3}, Pauli Falt^{*4}, Markku Hauta-Kasari^{*3},
Takao NAMIKI^{*5}, Toshiya NAKAGUCHI^{*1}

*1 Center for Frontier Medical Engineering, Chiba University

*2 Graduate School of Science and Engineering, Chiba University

*3 Electrical Engineering and Energy Technology, University of Vaasa

*4 University of Eastern Finland

*5 Dept. of Japanese-Oriental(Kampo) Medicine, Chiba University

Tongue diagnosis, which is one of the diagnostic methods of Kampo medicine, diagnoses the physical condition of patients from tongue features. Recently, computer-aided tongue diagnosis researches are in progress. However, there are few studies to measure tongue coating which is one of the most important tongue feature. Therefore, we aim to estimate fluorescence intensity related to tongue coating amount via machine learning from RGB images. First, the tongue image is divided into small rectangular regions. For each rectangular region, 17 feature values related to texture and color are calculated and input into the classifier. The tongue fluorescence images are used as the ground truth. The 3231 samples are extracted from 13 tongue images. The stable accuracy is confirmed, and the possibility of estimation indicated fluorescence intensity from RGB images.

Key words: tongue image diagnosis, Kampo medicine, tongue coating, machine learning, texture analysis

Dense V-Net automated segmentation approach
for gross tumor volumes on 3D planning CT images
for lung cancer stereotactic body radiation therapy

Risa NAKANO^{*1}, Hidetaka ARIMURA^{*2}, Mohammad HAEKAL^{*3},
Saiji OHGA^{*4}, Tadamasu YOSHITAKE^{*4}, Yoshiyuki SHIOYAMA^{*4}

Abstract

Automated segmentation of gross tumor volumes (GTVs) for lung cancer are highly demanded in clinical practice of stereotactic body radiation therapy (SBRT) to reduce intra- and inter-observer variabilities in GTV contours, which may lead to the variability of treatment dose distributions. Hence, we attempted to develop an automated segmentation approach for lung cancer GTVs using a dense V-Net deep learning, which has more advantages to the segmentation of smaller structures than the conventional V-Net. Datasets of 3D planning CT images and GTV contours determined by radiation oncologists for 194 lung cancer cases were fed into the dense V-Net as input and teacher data, respectively. Dice's similarity coefficients (DSCs) were calculated to evaluate the proposed approach. The proposed approach achieved an average DSC of 0.792. The average DSCs for solid and part solid GGO types were 0.807 and 0.782, respectively. The proposed approach could be useful to delineate the various types of GTVs in treatment planning for lung cancer SBRT.

Keywords : deep learning, segmentation, dense V-Net, 3D-medical image

1. Introduction

Delineation of the gross tumor volumes (GTVs) constitutes one of the most important phases of treatment planning [1]. However, the delineation is time-consuming and has a potential source of errors in radiation therapy, because the GTV regions are manually delineated on treatment planning computed tomography (CT) images by treatment planners with having different skill level in current radiation therapy [2]-[5]. In this regards, automated segmentation approaches of GTVs are highly demanded in clinical practice of stereotactic body radiation therapy (SBRT) to reduce intra- and inter-observer variabilities in GTV contours, which may lead to the variability of treatment dose distributions. In past studies, a lot of efforts have been made in developments of more accurate segmentation approaches of the GTVs using

*1 Department of Health Sciences, Graduate School of Medicines, Kyushu University [3-1-1 Maidashi, Higashi-ku, Fukuoka 812-8582, Japan]
e-mail: rs19nkn@gmail.com

*2 Department of Health Sciences, Faculty of Medical Sciences, Kyushu University

*3 Department of Physics, Faculty of Mathematics and Natural sciences, Institut Teknologi Bandung

*4 Department of Clinical Radiology, Graduate School of Medicines, Kyushu University

machine learning techniques including deep learning to recognize structures in various imaging modalities (e.g. CT, positron emission tomography, and magnetic resonance imaging) [6]-[8]. Hence, we have attempted to develop an automated segmentation approach for lung cancer GTV in SBRT using a dense V-Net deep learning, which has more advantages in the segmentation of smaller structures with a novel loss function based on Dice's similarity coefficient (DSC) than the conventional V-Net [9],[10].

2. Materials and Methods

This study was performed under the approval of the Institutional Review Board of our university hospital. Datasets of three dimensional (3D) planning CT images and GTV contours determined by radiation oncologists for 194 lung cancer cases, who received SBRT were selected for this study. They were fed into the dense V-Net as input (3D-planning CT images) and teacher (GTV contours) data, respectively, by using a NiftyNet platform, which is an open source convolutional networks platform for medical image analysis and image-guided therapy [11]. The dense V-Net uses a fully convolutional neural network and enables high-resolution activation maps through memory-efficient dropout and feature reuse. Our dense V-Net was trained and tested in a 10-fold cross validation test with the 3D-planning CT volumes. In the training step, we employed an augmentation technique (flip, rotation and scaling) to avoid overfitting [12]. Table 1 shows the summary of hyper-parameters of this study. As a loss function, we selected a Dice loss function, which directly maximizes the similarity between the predicted GTVs and the reference regions over all voxels. In order to evaluate the proposed approach, we calculated DSC, which denotes the similarity between the reference region determined by radiation oncologists and the GTV region estimated using proposed approach and ranges from 0 to 1.

Table 1 Hyper-parameters for dense V-Net deep learning.

Number of iterations	25000 times
Batch size	1
Learning rate	0.0001
Dropout	0.75
Activation function	Scaled exponential Linear Unit
Network	Dense V-Net
Number of data	194
Types of augmentations	Rotate, flip, scale
Loss function	Dice function
Optimizer	RMSprop

3. Results and Discussion

Figure 1 illustrates segmentation results for 3 cases with reference GTVs (white line) and regions estimated by the proposed approach (green line). The proposed approach achieved an average DSC of 0.792. The average DSCs for solid and part solid GGO types were 0.807 and 0.782, respectively.

In this study, we attempted to develop an automated approach for delineation of GTV region and compare the accuracy by using DSC. As a result, the dense V-Net deep learning approach achieved the better performance for lung cancer cases. However, the number of data in this study is not sufficient for deep learning. Therefore, we attempt to use

augmentation technique which can increase training cases similar to clinical cases with artifact and noise at the same time as collecting high quality data.

In conclusion, the proposed approach can show the potential to be useful to delineate the various types of GTVs in treatment planning for lung cancer SBRT.

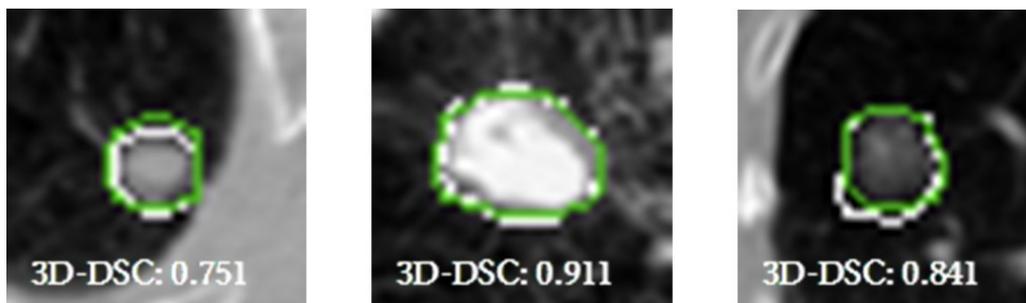


Fig. 1 Segmentation results for 3 cases. White line shows the reference GTVs and green line shows the regions estimated by the proposed method. 3D-DSCs are shown in these planning CT images.

Competing interests

The authors have no conflicts of interest to declare. The authors alone are responsible for the contents and writing of the paper.

Acknowledgement

The authors are grateful to all members in Arimura laboratory (<http://web.shs.kyushu-u.ac.jp/~arimura>), whose comments made enormous contribution to this study.

References

- [1] Shalini KV, Michael GJ, Myo M, et al.: Uncertainties in volume delineation in radiation oncology: A systematic review and recommendations for future studies. *Radiother Oncol J Eur Soc Ther Radiol Oncol*, 121 (2): 169-179, 2016
- [2] Emmanuel RV, Hugi JWLA, Yuhua G, et al.: A semiautomatic CT-based ensemble segmentation of lung tumors: Comparison with oncologist's delineations and with the surgical specimen. *Radiotherapy and Oncology*, 105(2):167-173 2012
- [3] Tim L, Johan van S, Mark G, et al.: Clinical evaluation of atlas and deep learning based automatic contouring for lung cancer. *Radiotherapy and Oncology*, 126(2): 312-317, 2018
- [4] Sharp G, Fritscher KD, Pekar V, et al.: Vision 20/20: perspectives on automated image segmentation for radiotherapy. *Medical Physics*, 41(5), 2014
- [5] Angela VB, Geert B, Liesbeth B, et al.: ET-CT-Based Auto-Contouring in Non-Small-Cell Lung Cancer Correlates With Pathology and Reduces Interobserver Variability in the Delineation of the Primary Tumor and Involved Nodal Volumes. *International Journal of Radiation Oncology*Biophysics*, 68(3):771-778, 2018

- [6] Kawata Y, Arimura H, Ikushima K, et al.: Impact of pixel-based machine-learning techniques on automated frameworks for delineation of gross tumor volume regions for stereotactic body radiation therapy. *Physica Medica*, 42: 141-149, 2017
- [7] Liu Y, Stojadinovic S, Hrycushko B, et al.: A deep convolutional neural network-based automatic delineation strategy for multiple brain metastases stereotactic radiosurgery. *PLoS One*, 12(10), 2017
- [8] Men K, Chen X, Zhang Y, et al.: Deep Deconvolutional Neural Network for Target Segmentation of Nasopharyngeal Cancer in Planning Computed Tomography Images. *Front Oncol*, 2017
- [9] Eli G, Francesco G, Yipeng H, et al.: Automatic Multi-Organ Segmentation on Abdominal CT With Dense V-Networks. *IEEE Transactions on Medical Imaging*, 37(8):1822-1834, 2018
- [10] Fausto M, Nassir N, Seyed-Ahmad A, et al.: V-net: Fully convolutional neural networks for volumetric medical image segmentation. *3D Vision*, 2016
- [11] Eli G, Wenqi L, Carole S, et al.: NyftyNet : a deep-learning platform for medical imaging. *Computer Methods and Programs in Biomedicine*, 158:113-122, 2018
- [12] Hussain Z, Gimenez F, Yi D, et al, Differential Data Augmentation Techniques for Medical Imaging Classification Tasks.” *AMIA Annu Symp Proc*. 2017: 979–984, 2017

半教師あり学習を用いた根拠提示可能なメラノーマ識別

村林 誠也*¹ 彌富 仁*¹

要旨

深層学習を用いたメラノーマ自動診断支援における信頼性向上のため、我々は識別根拠の提示技術において一定の成果を実現してきた。しかしながら臨床現場で利用される指標に基づく可読性の高い教師データ作成は医師に依頼する必要があるため数が限られ、それに起因する予測器の過学習、精度面での改善の必要性が残されていた。そこで本研究では、半教師あり学習手法である Virtual adversarial training を応用し、限られた数の教師ラベル付きデータに加え、比較的入手しやすい異なる関連するラベル（診断ラベル）付きのデータを活用することで、メラノーマの診断指標である 7-point checklist の各項目予測器の改良を検討した。教師ラベル付きの 226 症例に加えて、メラノーマ or 母斑の診断ラベルのみが付与された 9,124 症例を学習に利用することで、診断指標各項目の予測誤差は 2%程度改善、診断指標の各数値から求められる診断精度は AUC で 6.5%程度向上し、同診断指標を適用した皮膚科医と同等の診断精度を実現した。

キーワード：ダーモスコピー、コンピュータ自動診断 (CAD)、深層学習、半教師あり学習

1. はじめに

診断が難しい悪性度の高い皮膚がんであるメラノーマ（悪性黒色腫）の早期発見と高精度な診断実現のため、特に近年深層学習技術による自動診断手法の開発が行われている [1]。これらの手法は専門医に匹敵する高い識別精度を実現しているが、識別根拠を提示できず信頼性の面で改善の余地が残されていた。この問題に対し我々は臨床現場で利用される診断指標に基づくダーモスコピー特徴の数値予測器を試作した [2]。しかし、学習のために必要な教師データは医師に依頼する必要から作成コストが高く、極めて少量 (226 例) のデータのみで構築された予測器においては、精度面での改善の必要性が残されていた。一方、少量のラベル付き学習データに加え、大量のラベルなしデータを学習に活用する半教師あり学習の枠組みの中で、Virtual adversarial training (VAT)[3] は、なめらかな識別境界を構築する制約を導入することで優れた成果を実現している。

本研究では VAT を応用することで、限られた数

の教師つきデータと、それらの情報のないより多くの画像データを用いて上記診断指標の優れた予測器を構築した。本研究の目的は、他に多く見られる自動診断精度を追及する事ではなく、ブラックボックス化されたシステムの結果に対する可読性・信頼性向上のために、診断根拠の定量的な提示を目指したものである。

2. 方法

1) 深層学習を用いた診断指標予測器

本実験では、一般物体画像で事前学習済みの ResNet-101 を用い、臨床におけるメラノーマの診断指標である 7-point checklist [4] {S1:不規則な網構造, S2:青白い領域, S3:不規則な血管パターン, S4:不規則な枝状構造, S5:不規則な色素沈着, S6:不均一な点, S7:色素抜け構造}の有無[1, 0]とメラノーマ/母斑の計 8 項目の予測器を構築した。診断指標 7 項目の学習には 4 人の皮膚科専門医によって同項目への評価がなされた 226 症例のデータを用い、メラノーマ/母斑の学習にはメラノーマ/母斑ラベルのみ付与済みの 9,124 症例も用いた。

2)半教師あり学習による準ラベルデータ活用
本実験では、半教師あり学習手法の一つである

*1 法政大学大学院理工学研究科応用情報工学専攻

[〒184-8584 東京都小金井市梶野町 3-7-2]

e-mail:seiya.murabayashi.9j@stu.hosei.ac.jp

表 1 7-point checklist 各項目の予測

ID	皮膚科医 (σ)	(i)教師あり (MAE)	(ii)半教師 (MAE)	(iii)半教師+MN (MAE)
S1	0.250	0.342	0.324	0.329
S2	0.209	0.200	0.141	0.154
S3	0.072	0.106	0.090	0.071
S4	0.154	0.244	0.327	0.369
S5	0.297	0.265	0.174	0.191
S6	0.250	0.314	0.299	0.322
S7	0.148	0.225	0.206	0.213
ave	0.197	0.242	0.222	0.236

表 2 7-point checklist に基づく診断結果†

評価指標	診断精度		
	感度[%]	特異度[%]	AUC
皮膚科医	76.0	80.3	0.781
(i) 教師あり	59.6	82.8	0.712
(ii) 半教師	63.6	92.3	0.780
(iii) 半教師+MN	72.7	84.6	0.787

†: $2 \times (S1 + S2 + S3) + S4 + S5 + S6 + S7 \geq 3.0$ が悪性

Virtual adversarial training (VAT)を参考に、教師データ付与済みの226症例に加え、診断指標の情報はないものの、最終的な診断結果であるメラノーマ or 母斑のラベルのみが付与された計9,124症例のデータも診断指標予測器の学習に利用し、予測能向上への影響を検証した。

3) 評価実験

本研究では以下の3条件で予測器の学習を行い、比較を行った。

- (i) 教師あり：診断指標ラベル付き 226 例のみ
- (ii) 半教師：VAT 適用，226 例+9,124 症例
(メラノーマ or 母斑ラベル非活用)
- (iii) 半教師+MN：VAT 適用，226 例+9,124 症例
(メラノーマ or 母斑ラベル活用)

7-point checklist の各項目の数値予測能は平均絶対誤差 (MAE) で、7-point checklist の各数値から求められる診断結果については、10-fold cross validation 法で評価した。

3. 結果

7-point checklist 各項目の予測結果および皮膚科医 4 名による評価の分散を表 1 に示す。また、

7-point checklist に基づく診断結果の感度、特異度、area under the ROC curve (AUC)を表 2 に示す。

7-point checklist 各項目の予測において半教師あり学習適用後の予測誤差は2%程度改善した。また、診断指標の各数値から求められる診断精度は AUC で 6.5%程度向上し、特にメラノーマ or 母斑ラベル利用時には皮膚科医を上回る結果を示した。

4. 考察とまとめ

半教師あり学習手法を用いた非ラベルまたは異なるラベル情報が付与されたデータの追加活用により、臨床で使用される指標に基づく可読性高い診断において皮膚科専門医に匹敵する診断精度を示した。これにより、純粋なメラノーマ/母斑識別について90%程度である同識別器と併せて用いることで高精度かつ定量的な診断根拠の提示可能な自動診断の実現が期待できる。

今後、各予測項目と実際のダーモスコピー特徴の対応について更なる妥当性の検証を行う。

利益相反の有無

なし

文 献

- [1] A. Esteva, B. Kuprel, R. A. Novoa et al.: Dermatologist-level classification of skin cancer with deep neural networks. Nature 542, 115-118, doi:10.1038/nature21056, Feb. 2017.
- [2] 村林誠也, 彌富仁: 深層学習器を用いた悪性黒色腫自動識別の識別根拠の評価. 第37回日本医用画像工学会大会, 2018
- [3] T. Miyato, S. Maeda, S. Ishii, et, al.: Virtual Adversarial Training: A Regularization Method for Supervised and Semi-Supervised Learning. IEEE Trans Pattern Analysis and Machine Intelligence, 2018
- [4] G. Argenziano, G. Fabbrocini, P. Carli et al.: Epiluminescence microscopy for the diagnosis of ABCD rule of dermatoscopy and a new 7-point checklist based on pattern analysis. Archives of Dermatology No.134, pp.1536-1570 1998.

Explainable melanoma diagnosis using semi-supervised learning

Seiya MURABAYASHI*¹, Hitoshi IYATOMI*¹

*1 Graduate school of Science and Engineering, Hosei University

In order to improve the readability of automated diagnosis support for melanoma, we have realized certain achievements on quantifying their clinical findings such as 7-point checklist. Here, we need to ask dermatologists to create gold standard label based on the criteria in advance, while it is so expensive that the number of available labeled data is limited. Therefore, there remains a need for improvements in over-fitting and accuracy in our previous model. In this study, we applied a virtual adversarial training (VAT) as a semi-supervised training framework and build a reliable estimator of each item defined in the 7-point checklist using quite limited number of labeled data and larger number of data with relevant but different label. We used a total of 226 labeled images and other 9,124 images with different type of label information, i.e. melanoma or benign. In our model, the prediction error of each clinical item is improved by about 2% and the diagnostic accuracy obtained based on them is improved by about 6.5% by AUC. We confirmed the diagnosis performance is equivalent to expert dermatologists who applied the same criteria.

Key words: Dermoscopy, Computer-aided diagnosis (CAD), Deep learning, Semi-supervised learning

著者紹介



村林 誠也 (むらばやし せいや)
2018年法政大・理工・応用情報工
卒。現在、同大大学院修士課程在学
中。電子情報通信学会学生会員。



彌富 仁 (いやとみ ひとし)
1998年慶大・理工・電気卒。2000
年同大大学院・理工研・電気修士課
程，2004年同博士課程修了。2000-
2004年日本ヒューレット・パッカ
ード(株)。現在，法政大・理工・
教授。博士(工学)，博士(医学)。
機械学習および，それらを元にした
画像解析，言語処理，セキュリティ
などの研究に従事。

肝臓がん検出器のための Conditional GAN による病変画像生成

池田 裕亮*¹ 道満 恵介*¹ 目加田 慶人*¹ 縄野 繁*²

要旨

肝がんの読影において CT 画像を医師が目視で行っており、医師の負担となっている。そのため、機械学習による読影支援が求められているが、機械学習に用いる症例画像を大量に集めることは困難である。そのため病変画像の生成手法が研究されている。従来手法である DCGAN による病変画像生成では、学習データに見えが異なる病変画像を混ぜて用いたため、異なる特徴が混ざった病変が生成される問題があった。本稿では CGAN を用いた病変画像生成手法を提案し、CNN で構築した検出器の精度により評価した結果を報告する。肝臓の辺縁部と非辺縁部の 2 種類のラベルを付与し、CGAN の学習を行った。学習後、CGAN で生成した病変画像を検出器の学習に用いた結果、検出率が 0.85、一症例当たりの誤検出が 0.20 となり、従来手法より検出精度が向上した。

キーワード：CT 画像、深層学習、コンピュータ診断支援、画像生成

1. はじめに

肝がんの診断は CT 画像を医師が目視で行っている。医師の負担を軽減するため機械学習を用いた自動検出による読影支援が求められている。しかし、機械学習に用いる大量の学習データを集めることは困難である。そのため病変画像の生成手法が研究されている。

これまで我々は肝臓がん検出器を二次元の畳み込みニューラルネットワーク (2D-CNN) と三次元の CNN (3D-CNN) で構築した[1]。また、検出器の学習データの不足を補うため以下の 3 つの手法で生成した。

- Poisson Blending 法 (PB 法) [2]
- 肝がんの濃度分布を模擬する方法 (濃度分布法) [3]
- Deep Convolutional Generative Adversarial Networks (DCGAN) [4][5]

上記の 3 つの手法で生成した病変画像と実病変画像を検出器の学習データとして用いることで検出精度が向上した。しかし、DCGAN を用いた病変画像生成手法では 3 次元の DCGAN の学習に肝臓辺縁部と非辺縁部にある見えが異なる病変画像を混ぜて用いたため、それらの特徴が混在した不自然な病変画像が生成される問題があった。

そこで本稿では DCGAN で表現できる病変の多様性を維持しながら、不自然な病変画像の生成を抑制するため、ラベル情報を用いることで特徴が異なる病変を別々に学習する Conditional GAN (CGAN) を用いた病変画像生成を提案する。

*1 中京大学 大学院工学研究科
〔〒470-0393 豊田市貝津町床立 101〕
e-mail: ikeda.y@md.sist.chukyo-u.ac.jp
e-mail: kdoman@sist.chukyo-u.ac.jp
e-mail: y-mekada@sist.chukyo-u.ac.jp
*2 国際医療福祉大学三田病院
e-mail: snawano@iuhw.ac.jp



(a) 非辺縁 (b) 辺縁

図 1 辺縁と非辺縁の実病変画像断面

表 1 2D-CGAN の学習データ

ラベル	実病変	回転等
辺縁	255	1785
非辺縁	482	3374

表 2 3D-CGAN の学習データ

ラベル	実病変	回転等	PB 法	濃度分布法
辺縁	26	390	6087	5072
非辺縁	84	1260	4554	5926



(a) 非辺縁 (b) 辺縁

図 2 CGAN で生成した病変画像断面

2. CGAN を用いた画像生成

転移性肝がんは肝臓辺縁部と非辺縁部において異なる特徴を持つ。非辺縁部では図 1 (a) のように病変は球形になるが辺縁部では図 1 (b) のように辺縁に沿った形になる。そのため CGAN の学習データに辺縁部と非辺縁部の 2 つのラベルを付与する。検出器は 2D-CNN と 3D-CNN で構成されているため CGAN も二次元の CGAN (2D-CGAN) と三次元の CGAN (3D-CGAN) の二つのモデルを作成する。

3. 実験

CGAN で生成した病変画像を評価するため検出器の学習データとして生成画像を用いた。検出器には学習に未使用の 20 症例の CT 画像を入力し、その検出率と一症例当たりの誤検出率を用いて提案手法の評価を行う。以降、CGAN の学習データ、検出器の学習データ、検出結果、考察について述べる。

表 3 検出器に共通の学習データ

モデル	実病変	PB 法	濃度分布法	非肝がん
2D	737	3,000	3,000	4,500
3D	110	1,000	1,000	1,500

表 4 手法ごとに異なる検出器の学習データ

手法	モデル	DCGAN	CGAN	
			辺縁	非辺縁
従来	2D	3,000	0	0
	3D	1,000	0	0
CGAN 辺縁	2D	0	3,000	0
	3D	0	1,000	0
CGAN 非辺縁	2D	0	0	3,000
	3D	0	0	1,000
CGAN	2D	0	1,500	1,500
	3D	0	500	500

表 5 検出器の検出結果

手法	検出率	誤検出率
従来	0.80	0.25
CGAN 辺縁	0.85	0.35
CGAN 非辺縁	0.75	0.20
CGAN	0.85	0.20

3.1. CGAN の学習データ

2D-CGAN の学習に用いた病変画像を表 1 に、3D-CGAN の学習に用いた病変画像を表 2 に示す。これらの表中の「回転等」は、幾何変形に基づくデータオーギュメンテーションによる水増しを表している。3D-CGAN の学習データにおいては実病変の数が十分ではないために学習が収束しない。そのため文献[3]と同様に、PB 法と濃度分布法で生成した病変画像を加えて学習を行った。

これらの条件で学習した病変を図 2 に示す。これらの生成した病変画像を検出器の学習データとして用いる。

3.2. 検出器の学習データ

検出器の学習に用いたデータのうち実病変等の数を表 3 に、DCGAN または CGAN によって生成したデータ数を表 4 に示す。

3.3. 結果

20 症例に対する検出器の検出結果を表 5 に示す。従来手法と比べ CGAN で生成した辺縁部

と非辺縁部の病変のどちらも学習に用いた場合では検出率は上がり、一症例当たりの誤検出率は低下した。このことから提案手法の有効性を確認できる。

3.4. 考察

CGANで生成した辺縁部に特有なアピアランスを持った病変画像のみで学習した場合、検出率は向上したが、1症あたりの誤検出数は増えた。また、非辺縁部の特徴のみを持った病変画像で学習した場合はこれとは逆の結果となった。一方、これら両方を用いた場合、検出率と1例あたりの誤検出数が共に最も良い結果になった。学習データ数の比率については検討の余地があるものの、辺縁と非辺縁の特徴を個別に生成して利用することは有効であることが示唆された。

4. まとめ

機械学習のために必要な大量の学習データを生成する手法として、CGANを用いた病変生成手法を提案した。肝臓がんにおいては、肝臓の辺縁部と非辺縁部においてその見た目が異なるため、それぞれ個別に生成し、CNNによる検出器の学習データとして利用することで、DCGANを用いた病変生成手法よりも検出器の検出精度が向上した。しかし、評価に用いた症例が20症例と少ないため十分な評価とはいえない。そのため今後大規模な評価実験を行う必要がある。

謝辞

本研究の一部は、日本学術振興会科研費補助金の援助による。

利益相反の有無

なし

文 献

- [1] 小西他, “人工的な病変画像を用いた3D-CNNによる転移性肝がん検出”, 電子通信学会 医用画像研究会(MI)技術研究報告, vol.116, no.393, pp.21-22, Jan. 2017
- [2] P. Perez et al. “Poisson image editing”, ACM Special Interest Group on Computer 2003, pp.27-31, July 2003
- [3] 小西他, “人工的病変画像を用いたCNNによる転移性肝がん検出手法”, Medical Imaging Technology 「研究速報(A)」, vol.37, no.1, pp46-50, Jan.2019
- [4] A. Radford et al. “Unsupervised representation learning with deep convolutional generative adversarial networks”, Int. Conf. on Learning Representations 2016, 67, May. 2016
- [5] T. Konishi et al. “Lesion image synthesis using DCGANs for metastatic liver cancer detection”, Proc. of Int. Workshop on Frontiers of Computer Vision 2018, O4-4, Feb. 2018

Image Generation using Conditional GAN for Constructing a Metastatic Liver Cancer Detection

Yusuke IKEDA^{*1}, Keisuke DOMAN^{*1}, Yoshito MEKADA^{*1}, Shigeru NAWANO^{*2}

^{*1} Graduate School of Engineering, Chukyo University

^{*2} International University of Health and Welfare Mita Hospital

The diagnosis for liver cancer is visually performed by doctors with CT images, which take a lot of time. For this reason, an interpretation support using machine learning is required. It is, however, difficult to collect a large number of case images for machine learning. Thus, we study a lesion image generation method. In the conventional method using DCGAN, lesion images with different appearance features were mixed and used as learning data. As a result, generated images had features with different features mixed. The method proposed in this paper generates lesion images using CGAN. CGAN is trained with learning data labeled with “edge” and “non-edge” of the liver. We confirmed that the proposed method achieved the detection rate of 0.85 and the false detection per case of 0.20. The detection accuracy was higher than the conventional method.

Key words: CT image, Deep Learning, Computer Aided Diagnosis, Image Synthetic

Deep CNN における分類器のアテンションメカニズムを 利用した CT 画像からの乳腺領域の自動抽出法

山岸 誠也*¹ 周 向栄*¹ 原 武史*¹ 加賀 徹郎*²

加藤 博基*² 松尾 政之*² 藤田 広志*¹

要旨

本研究は、様々な検査の目的で撮影された 3 次元 CT 画像から乳腺領域を自動抽出することを目的とする。CT 画像における乳腺領域の自動抽出に関する先行研究として、確率的アトラスに基づくアプローチが提案され、良好な抽出結果が示された。しかし、従来法では確率アトラスの作成に時間と労力が必要であった。本研究は、以上の確率アトラスを患者ごとに自動生成する方法を提案する。具体的には、深層学習によって得られた画像分類器から乳腺領域の Attention Map を生成して確率アトラスとして代用する。提案手法を体幹部 CT 画像 16 症例に適用した結果、生成した Attention Map は真の乳腺領域との一致度の平均値が 49.6%であることを確認した。また、この Attention Map を従来法に組み込んで乳腺領域を抽出した結果、一致度が 65.3%に向上した。実験結果から、提案手法によって各 CT 画像に適切な Attention Map を動的に生成することが可能であり、乳腺領域の自動抽出の効率化が期待できる。

キーワード：乳腺領域, Attention Map, 深層学習

1. はじめに

近年、女性における乳癌の罹患率が増加している。乳癌は女性が罹患する癌の中で最も罹患率が高く、早期発見が求められている[1]。乳癌検診において、マンモグラフィの高濃度乳腺では乳癌発症リスクが増加することは確実である[2]。計算機で乳腺量を定量できれば、乳癌発症リスクの予測に関する計算機支援診断が可能になる[3]。

また、医療現場では CT 検査が頻繁に行われ、

検査対象とする臓器以外の画像情報の活用が望ましい。他の診断目的で撮影された 3 次元 CT 画像から乳癌のリスク評価への応用が期待される[4]。その際には、3 次元 CT 画像から乳腺領域の自動抽出が必要とされる[5-6]。

先行研究では、解剖構造の類似性に基づいて推定された乳腺位置（以下では確率アトラスと呼ぶ）を CT 画像上の濃淡分布（尤度画像と呼ぶ）に合わせて、乳腺領域を自動的に抽出する処理手法が提案され、66 例の CT 画像に適用した結果から確率アトラスの有効性が確認された[7]。しかし、確率アトラスの作成には、数多くの CT 画像から乳腺領域を手動で抽出する必要があり、作業時間がかかる問題があった。また、作成された確率アトラスが汎用なものでなく、患者の個人状況を表現する能力が不十分であった。そのために、各患者に個別な確率アトラスを効率的に生成する方法が期待されてい

*1 岐阜大学大学院自然科学技術研究
科知能理工学専攻

〔〒501-1193 岐阜県岐阜市 1-1〕

e-mail: syama@fjt.info.gifu-u.ac.jp

*2 岐阜大学医学部附属病院放射線科

る[7].

本研究は、各患者に乳腺の確率アトラスを動的に生成する方法を提案する。具体的には、乳腺濃度を分類するためのニューラルネットワークが、入力された CT 画像上に注目する領域 (Attention Map と呼ぶ) を乳腺領域の確率アトラスとして活用する。これにより、従来法[7]に必要とされる確率アトラスの構築に関する手作業を軽減して、CT 画像からの乳腺領域の抽出処理の効率化を目指す。

2. 方法

2.1 深層学習による Attention Map の生成

Attention Map は Global Average Pooling の特性を利用し、深層学習に得られたネットワークが入力画像上に注目している領域を可視化したものである。今回、Attention Map を作成する手法として Grad-CAM[8]を使用した。Grad-CAM は可視化手法の 1 つであり、分類モデルの特徴マップから確率スコアの変化に影響を与えた箇所を特定する手法である。画像処理分野において、深層学習のパラメータの調整や、判断根拠の理解に利用されている[9]。

深層学習のネットワークは CT 画像上にある乳腺領域を 2 つのカテゴリーに分類する AlexNet[10]を利用した。学習サンプルとして、3 次元 CT 画像 80 症例において乳頭方向を回転軸とする 2 次元断面画像 (28800 枚) を利用した。医師が乳腺濃度を 2 つのカテゴリーに分類し、その分類結果を深層学習の教師信号として利用した。深層学習で得られたネットワークを利用して、入力の CT 画像から乳腺領域の Attention Map を生成する。

2.2 乳腺の確率アトラス

確率アトラスは、複数の患者データにより作成される、解剖学的な構造上に乳腺位置の頻度を表すマップである。従来法では、確率アトラスの作成過程で大量な CT 画像から乳腺領域の正解画像を必要とした[7]。手動で抽出した複数の乳腺領域を、解剖学的なランドマークによって位置合わせし、空間的に乳腺領域の頻度を測

定することで確率アトラスを作成している[7].

本手法は深層学習に基づく画像分類器の Attention Map を確率アトラス (L_{atlas}) として活用する。ここで、乳腺濃度 (密度) を分類する際に、画像分類器が CT 画像上にある乳腺領域のみを注目することと想定して、大まかな乳腺領域の位置が深層学習を通じてネットワークに記憶されることを想定する。画像分類器の学習過程に真の乳腺領域が必要とされないため、従来法より確率アトラスの構築作業を容易行うことができる。

2.3 乳腺領域の尤度画像

深層学習から得られた Attention Map と CT 画像の濃淡値分布から乳腺の存在確率を表す画像 ($L_{mammary}$) を作成する。図 1 に処理の流れを示す。

まず、乳腺領域の位置尤度画像 ($L_{density}$) を作成する乳腺領域の濃淡分布を正規分布と仮定し、正規分布のパラメータ μ と σ を以下手順で推定する。

- (1) 乳腺領域の濃淡分布の最頻値を乳腺領域の平均濃淡値 μ とする
- (2) μ 以下の濃淡分布を削除し、 μ を基点とした線対称の濃淡分布を作成する。
- (3) 作成された濃淡分布から標準偏差 σ を推定する。

推定されたパラメータをガウス関数に基づいた式へ代入する(式 1)。ここで(式 1)中の $V_{x,y,z}$ は CT 画像の座標 (x,y,z) における CT 値を表す。CT 画像(図 2-a)を $L_{density}$ に変換する(図 2-b)。図 2-b において、緑で示される箇所が $L_{density}$ で最も値の大きい領域となっている。直感的に、CT 画像の CT 値が乳腺領域の平均濃淡値 μ に近いほど値が大きくなる。 $L_{density}$ に Attention Map(図 2-c) を乗じることで乳腺の存在確率画像 ($L_{mammary}$) を生成する(図 2-d)。作成された $L_{mammary}$ に膨張処理と収縮処理を施した後、閾値処理によって得られた領域を乳腺領域の抽出結果とする[11]。

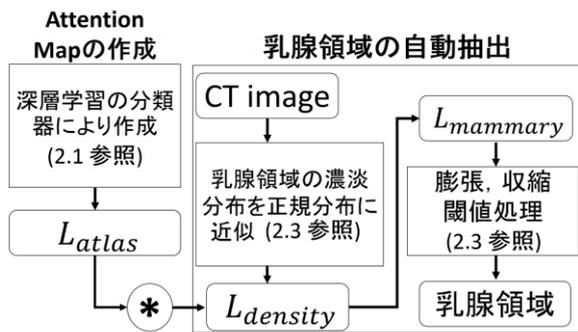


図 1 CT 画像からの乳腺領域の自動抽出の流れ

$$L_{density} = \exp\left\{-\frac{(v_{xyz}-\mu)^2}{2\sigma^2}\right\} \quad (1)$$

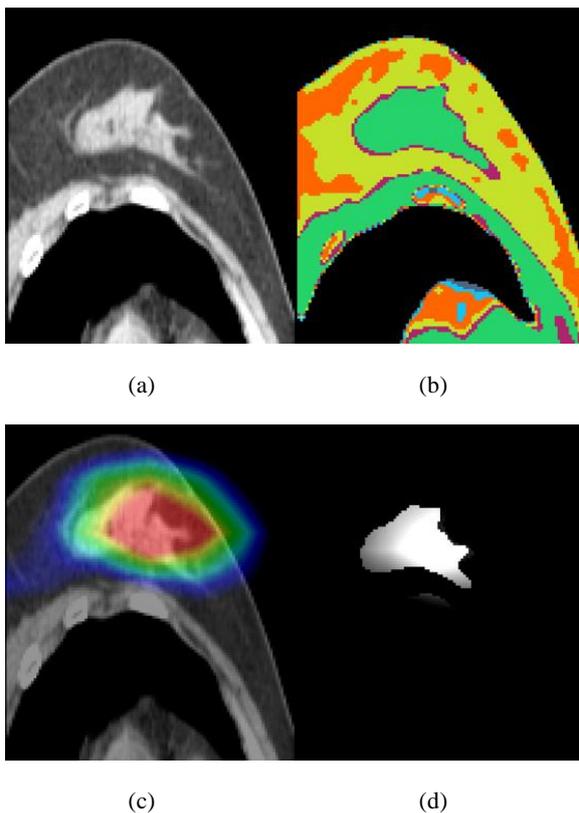


図 2 CT 画像と乳腺領域の抽出結果

- (a) : CT 画像 (1 断面) (b) : $L_{density}$
 (c) : Attention Map (d) : $L_{mammary}$

3. 実験と結果

3.1 Attention Map の性能評価

Attention Map による乳腺領域の位置推定の精

度を確認する。Attention Map での画素値 (確率) が 0.5 以上を示す箇所を乳腺領域と推定したと仮定する。正解領域は医師の指導の下、16 症例の乳腺領域を手動で作成した。推定した領域と乳腺領域の正解領域との Dice 値によって評価する。Dice 値の平均が 49.6%であった。Attention Map は乳腺領域の大まかな位置を示していることを確認した。乳腺領域が散在している症例に対しての過抽出が平均一致度低下の原因となった。

3.2 乳腺領域の自動抽出

Attention Map を確率アトラスとして従来法に組み込むことにより得られた最終的な抽出結果と、正解領域の Dice 値により抽出精度の評価を行う。乳腺領域の正解画像は 3.1 で使用した 16 症例と同様のものとする。

本手法によって求められる Dice 値の平均は 65.3%を示した。ガウス関数で使用した μ と σ の 16 症例の平均はそれぞれ 157.0[HU]と 36.0[HU]であった。Attention Map に $L_{density}$ を乗じることで散在する乳腺領域や乳腺領域の末端を抽出可能にしている。図 3 に抽出結果の画像を示す。抽出に失敗している症例は $L_{density}$ の作成段階で乳腺領域と脂肪領域の分離が不十分であることを確認した。(図 4)



図 3 乳腺領域の抽出結果(成功例)

左 : CT 画像 中 : 正解領域(黄) 右 : 抽出結果(緑)

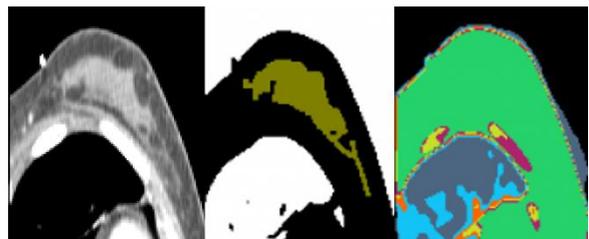


図 4 乳腺領域の抽出結果(失敗例)

左 : CT 画像 中 : 正解領域(黄) 右 : $L_{density}$

4. 考察

提案手法では各 CT 画像に対する患者の乳腺位置を動的に推定することが可能である。乳腺領域の正解画像の作成に1症例あたり平均で57分かかった。それに対して、Attention Mapの作成には1症例あたり2分で行うことができる。特に、低濃度乳腺の正解画像の作成には多くの時間が必要となる。今回テストに使用した16症例のうち、8症例が低濃度乳腺となっている。低濃度乳腺の正解画像の作成には平均で1時間21分の時間が必要であった。また、乳腺領域の正解画像の作成は医師の経験則に頼る部分が多い。以上より、多症例にわたる従来法での確率アトラスの作成は困難であり、本提案手法による乳腺位置の自動推定が現実的な解決法と言える。さらに、従来法では確率アトラスの作成において不可欠であった、解剖学的ランドマークによる画像位置合わせと乳腺領域の変形処理を削減できるため、本手法による乳腺領域の自動抽出の効率化が期待できる。

作成された Attention Map が真の乳腺領域を推定することができれば、適切な濃淡分布のパラメータ μ と σ の推定が可能となる。现阶段では推定結果として 49.6% を示しており、適切なパラメータを推測できていないと考える。精度の高い Attention Map を作成することで尤度画像を用いた抽出結果が向上すると考えられる。また、分類器は患者専用の Attention Map を作成するため、従来の確率アトラスと比べて精度が良いと考える。よって、Attention Map を確率アトラスとして利用することは乳腺領域の抽出に適していると考ええる。

今後は高精度の Attention Map を作成するために、深層学習における分類器の作成を工夫する必要があると考える。

5. まとめ

本研究は、CT 画像からの乳腺領域の自動抽出を目指して、従来法の難点であった確率アトラスを自動的に生成する方法を提案した。深層学習のアプローチを従来の処理手順に組み込んで、CT 画像における乳腺領域の自動抽出の

効率化を進めた。体幹部 CT 画像に適用した結果から、提案法の有効性が示された。

謝辞

本研究の一部は文部科学省科学研究費・新学術領域研究(課題番号 26108005)、及び JSPS 科学研究費補助金(基盤研究(C) 26330134)によって行われました。

利益相反の有無

なし

文 献

- [1] 池戸祐司, 福岡大輔, 原武史, 他: 全乳房超音波画像における腫瘍像自動検出システムのための左右乳房画像の比較による偽陽性削除法. 電子情報通信学会論文誌 D **91**: 1923-1926, 2008
- [2] Huo CW, Chew GL, Britt KL, et al.: Mammographic density—a review on the current understanding of its association with breast cancer. *Breast Cancer Research and Treatment* **144**: 479-502, 2014
- [3] Zhou X, Kano T, Cai Y, et al.: Automatic quantification of mammary glands on non-contrast X-ray CT by using a novel segmentation approach. *SPIE Medical Imaging 2016* **9785**: 97851Z, 2016
- [4] 藤田広志: 肺がん CT 検診 CAD システムの現状と今後の展望. *医学物理* **35**: 163-166, 2015
- [5] Liu S, Salvatore M, Yankelevitz D, et al.: Segmentation of the whole breast from low-dose chest CT images. *Proceedings of SPIE Medical Imaging 2015* **9414**: 94140I, 2015
- [6] Liu S, Margolies L, Xie Y, et al.: Fully automated Breast density assessment from low-dose chest CT. *Proceedings of SPIE Medical Imaging 2017* **10134**: 101340R, 2017
- [7] Zhou X, Kan M, Hara T, et al.: Automated segmentation of mammary gland regions in non-contrast torso CT images based on probabilistic atlas. *Proceedings of SPIE Medical Imaging 2007* **6512**: 65123O, 2007

- [8] Selvaraju RR, Cogswell M, Das A, et al.: Grad-cam: Visual explanations from deep networks via gradient-based localization. 2017 IEEE International Conference on Computer Vision (ICCV), 618-626, 2017
- [9] Iizuka T, Fukasawa M, & Kameyama M: Deep learning-based imaging classification identified cingulate island sign in dementia with Lewy bodies. *BioRxiv* **592865**: 2019
- [10] Krizhevsky A, Sutskever I, & Hinton GE: Imagenet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems*, 1097-1105, 2012
- [11] Zhou X, Kitagawa T, Hara T, et al.: Constructing a probabilistic model for automated liver region segmentation using non-contrast X-ray torso CT images. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* 856-863, 2006

Automatic segmentation of mammary gland region on CT images based on attention mechanism in deep learning classifier

Seiya YAMAGISHI^{*1}, Xiangrong ZHOU^{*1}, Takeshi HARA^{*1}, Tetsuro KAGA^{*2}
Hiroki KATO^{*2} Masayuki MATSUO^{*2} Hiroshi FUJITA^{*1}

^{*1} Department of Intelligence Science and Engineering, Graduate School of
National Science and Technology, Gifu University

^{*2} Department of Radiology, Gifu University Hospital

The purpose of this study is to automatically segment mammary gland region on 3D CT images that scanned for various diagnostic purposes. In our previous work, we proposed an approach that used a probabilistic atlas to segment mammary gland regions on CT images and showed good performance with promising experimental results. However, constructing a probabilistic atlas that required in our previous work was time-consuming and effort-expensive. In this study, we propose a method to automatically generate a probabilistic atlas for each patient. Our method uses the attention map of a deep learning classifier as a substitute for probabilistic atlas. We applied the proposed method to 16 cases of torso CT images and confirmed that the average value of the coincidences between the attention map with the ground truth of mammary gland region was 49.6%. We integrated these attention maps into our previous method to segment the mammary gland region, and confirmed the coincidence value was improved to 65.3%. These experimental results demonstrated the capability of our proposed method that can dynamically generate a probabilistic atlas for each CT image specifically. This progress is expected to improve the efficiency of automatic segmentation of the mammary gland region on CT images.

Key words: Mammary Gland, Attention Map, Deep Learning

Automated approach for estimation of sizes of lung tumor
on planning CT images using dense V-net CNN
with non-negative matrix factorization

Zhuangfei MA^{*1}, Hidetaka ARIMURA^{*2}, Risa NAKANO^{*1},
Tadamasa YOSHITAKE^{*2}, Yoshiyuki SHIOYAMA^{*2}

Abstract

Assessment of the change in tumor volume is a substantial factor in the clinical evaluation of cancer treatment. However, it is tedious and difficult for medical doctors to manually measure the longest diameters of lung tumors (≥ 10 mm) in three-dimensional medical images such as computed tomography (CT) images, and evaluate tumor responses. We have developed an automated approach to estimate lung tumor sizes on planning CT images using dense v-net CNN with non-negative matrix factorization (NMF). The longest, middle and shortest diameters of lung tumor were estimated by the largest, middle and smallest standard deviations in the coefficient matrices, respectively. The errors of estimated lung tumor sizes in the longest, middle and shortest diameters were 17.53%, 21.14% and 20.58%. The NMF would have a potential for estimating the longest diameters in the lung tumor sizes.

Keywords : lung tumor sizes, planning computed tomography images, dense v-net CNN, non-negative matrix factorization

1. Introduction

Lung tumor is the commonest fatal malignancy in the developed world [1]. It has been reported by world health organization (WHO) that lung tumor causes more than 1.3 million deaths each year in the world [2],[3]. Lung tumor is the most commonly occurring tumor in men and the third most commonly occurring tumor in women [4],[5]. Evaluation of lung tumor treatment outcome is a crucial task by radiologists [6]. Assessment of the change in tumor volume is an important feature of the clinical evaluation of lung tumor therapeutics: both tumor shrinkage (objective response), and disease progression are useful endpoints in clinical trials [7]. In clinical practice, three-dimensional (3D) medical images such as computed tomography (CT) images are used to measure the lung tumor sizes and evaluate their change. However, it is tedious and difficult for medical doctors to manually measure lung tumor longest

*1 Department of Health Sciences, Graduate School of Medicines, Kyushu University [Maidashi 3-1-1, Higashiku, Fukuoka 812-8582, Japan]
e-mail: ma_zhuangfei@outlook.com

*2 Department of Health Sciences, Faculty of Medical Sciences, Kyushu University

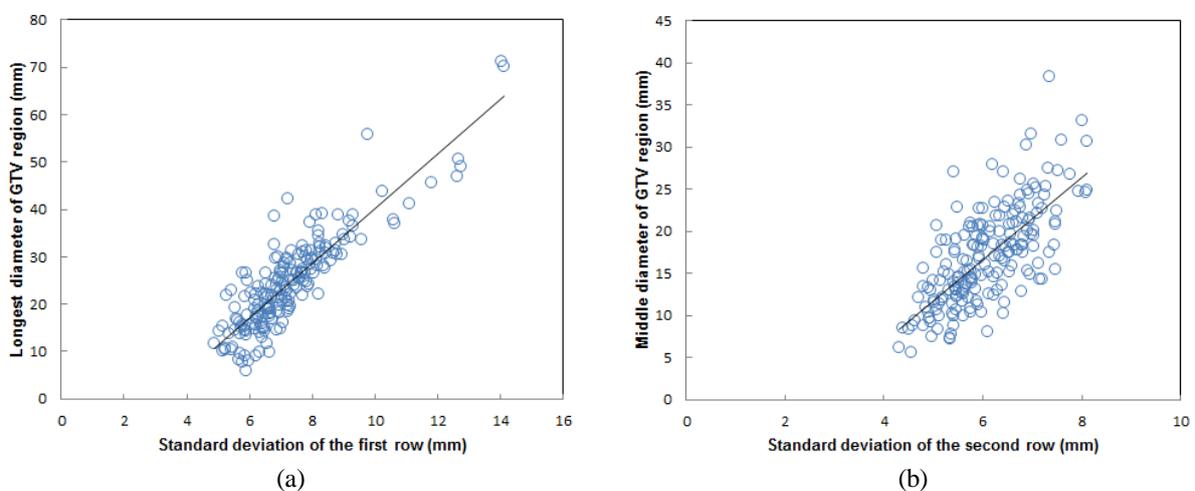
diameters (≥ 10 mm) in CT images, and evaluate tumor responses (Complete Response: CR, Partial Response: PR, Progressive Disease: PD, Stable Disease: SD). Dense V-net convolutional neural network has advantage to segment small structures such as stage I lung tumor (≤ 5 cm) in stereotactic body radiation therapy (SBRT) from medical images. Non-negative matrix factorization (NMF) can make a new coordinate system to obtain a linear representation of data. Therefore, we have developed an automated approach for estimation of sizes of lung tumor on planning CT images using dense v-net CNN with NMF.

2. Materials and Methods

Three-dimensional planning CT images and gross tumor volumes (GTV) regions for 193 lung tumor cases (size: 4.77 mm - 71.1 mm) were selected in this study. The sizes of lung tumor were calculated in terms of a longest, middle and shortest diameter which are orthogonal to each other by using matlab. The input data (3D planning CT images) and teacher data (GTV regions) were fed into the dense V-Net convolutional neural network in a NiftyNet platform which produced estimated GTV regions. The coordinates of voxels within an estimated GTV region were extracted to be inputted as the matrix to NMF. The NMF calculated the basis matrix and coefficient matrix. The standard deviation of each row in the coefficient matrix was calculated for estimation of sizes of lung tumor. The longest, middle and shortest diameters of lung tumor were estimated from the largest, middle and smallest standard deviations in the coefficient matrices, respectively.

3. Results and Discussion

Figure 1 shows the relationship between the reference lung tumor sizes in the longest, middle and shortest diameter and the largest (a), middle (b) and smallest (c) standard deviations which are calculated from NMF. The errors of estimated lung tumor sizes in the longest, middle and shortest diameters were 17.53%, 21.14% and 20.58%, respectively.



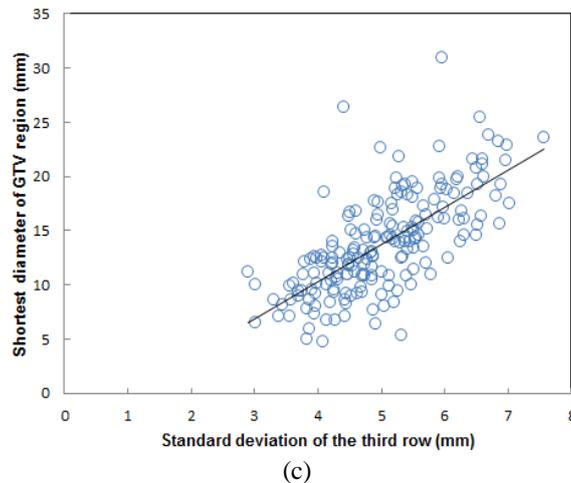


Fig.1 Relationship between the reference lung tumor sizes and the largest (a), middle (b) and smallest (c) standard deviations using NMF

In this study, the estimation error of the longest diameter was smaller than 20%, but the estimation error of the middle and shortest diameter were larger than 20%, because the NMF method was not appropriate for estimation of the middle and shortest diameters. Another limitation of this study is the limited number of patients (only 193). Therefore, we have to increase the number of cases to improve our approach.

In conclusion, the proposed approach would have a potential for estimating the longest diameter in lung tumor sizes.

Competing interests

The authors have no conflicts of interest to declare. The authors alone are responsible for the contents and writing of paper.

Acknowledgements

My special thanks are given to all members of Arimura's laboratory in Kyushu University for their great contributions to this research.

References

- [1] Sethi T: Lung cancer. Introduction. *Thorax* 57(11): 992-993, 2002
- [2] Sun S, Bauer C, Beichel R: Automated 3-D segmentation of lungs with lung cancer in CT data using a novel robust active shape model approach. *Medical imaging, IEEE Transaction on*, 31(2): 449-460, 2012
- [3] Cheng W, Ma L, Yang T, et al: Joint Lung CT Image Segmentation: A Hierarchical Bayesian Approach, 11(9): e0162211, 2016
- [4] de Margerie-Mellon C, de Bazelaire C, de Kerviler E: Image-guided biopsy in primary lung cancer: Why, when and how, 97(10): 965-972, 2016
- [5] Zhu H, Pak CH, Song C, et al: A novel lung cancer detection algorithm for CADs based on SSP and Level Set, 25(S1): 345-355, 2017
- [6] Peungjesada S, Chuang HH, Prasad SR, et al: Evaluation of cancer treatment in the abdomen: Trends and advances, 5(3): 126-142, 2013
- [7] Eisenhauer EA, Therasse P, Bogaerts J, et al: New response evaluation criteria in solid tumours: revised RECIST guideline

(version 1.1), 45(2): 228-247, 2009

非ランダム間引き収集による MR 圧縮センシング の深層学習再構成

佐藤 佑紀*¹ 風間 棕*² 伊藤 聡志*¹

要旨

MRI は撮像の高速化が課題であり、近年では圧縮センシング(Compressed Sensing : CS)を用いた高速撮像が利用され始めている。CS にはサンプリングのランダム性による画質変動、反復処理に伴う計算時間の大きさなどの課題がある。ランダム性による画質変動の改善と再構成の高速化を目的として本研究では非ランダム間引き収集信号の畳み込みニューラルネットワークによる再構成について検討を行った。その結果、ランダム間引きよりも構造の保存性に優れた良好な再生像を得ることができた。本研究により深層学習の利用によって圧縮センシングの間引き法に関して新たな可能性が示された。

キーワード：非ランダム間引き，圧縮センシング，深層学習，残差学習法，再構成

1. はじめに

核磁気共鳴現象を利用した生体断面の撮像法(Magnetic Resonance Imaging: MRI)は、一般的に X 線 CT に比べると撮像時間が長く、緊急性を要する場合には使用できないなどの課題がある。撮像の高速化を目的として圧縮センシング(Compressed Sensing : CS)[1,2]を使用した高速撮像法[3]が研究され、一部は臨床で応用され始めている。CS によれば、少数の信号から画像を得られるため MRI に応用することにより撮像時間の短縮が期待される。一方で、CS による画像再構成には数理的な反復処理に伴う計算コストの大きさや信号収集点の間引き方に依存した画質変動といった課題がある。MRI の 2 次元撮像に CS を応用するとき、信号は位相エンコード方向にランダムに間引きが行われる。ランダム間引き収集された信号から画像再構成を行うとき、全信号を収集した場

合のように再構成像は一意に定まるものではなく、収集点の間引き方のランダムさ、すなわち収集点の選び方に依存して画質は変動する。ここで、信号の間引き方を非ランダムとすることができれば信号収集点分布のランダム性を排除できるため、再構成像の画質安定化と信頼性の向上が期待できる。これまでに我々は非ランダム間引き収集について検討を行ってきた。結果、スパース化変換にマルチスケール化したカーブレット変換を使用することによりランダム間引きに比肩する画質の再構成像を得ることができた[3]。しかしながら、この方法でも再構成にはランダム間引きと同程度の計算コストを必要とした。

近年、医用画像の再構成や雑音除去に深層学習を利用する方法が検討されている[4]。画像に生じた誤差成分をネットワークにより推定する残差学習法は、高い精度で画像を復元できること、および処理が従来法と比べて極めて短時間であることの 2 点により大きな注目を集めている[5]。深層学習によれば信号の間引きによる誤差を学習することができるため、信号の間引きは必ずしもランダムである必要は無く、規則的なアーティファクトの方

*1 宇都宮大学 大学院地域創生科学研究科
工農総合科学専攻
情報電気電子システム工学プログラム
〒321-8585 栃木県宇都宮市陽東 7-1-2)
e-mail: mc196833@cc.utsunomiya-u.ac.jp

*2 現在、医療システムズ株式会社

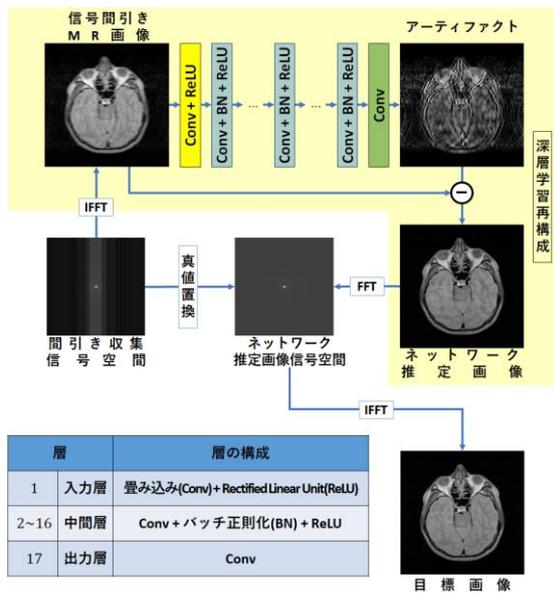


図 1. DRL-CNN のアーキテクチャ

が学習をより容易にする可能性もある。そこで、本研究では再構成のさらなる高速化と再構成像の高品質化を目的として、残差学習法を応用した非ランダム間引き収集を利用した CS 深層学習再構成について検討を行った。ランダム間引き収集による再構成像と比較を行い本方法の有効性を検証する。

2. 残差学習法

残差学習法は、K. He らが提案した残差学習[6]にバッチ正規化[7]を組合せて応用したものである。残差学習法では、雑音重畳画像から雑音除去像を推定するのではなく、ネットワークに入力された画像に重畳している雑音成分を推定し、それを入力画像から減算処理することで雑音除去像を出力する。K. Zhang らは残差学習法を利用した CNN を雑音除去に応用し、従前の非線形フィルタを上回る雑音除去性能が得られることを示した。

3. 深層学習を利用した CS 再構成

本研究では残差学習法を用いる CNN(Deep Residual Learning CNN: DRL-CNN と称する)を使用する。図 1 に DRL-CNN のアーキテクチャ

を示す。DRL-CNN は全 17 層で構成され、畳み込み処理(Conv)とバッチ正規化(BN)、Rectified Linear Unit(ReLU)の 3 つの処理から構成される。Conv と ReLU には入力データの特徴を抽出する役割があり、BN には学習効率向上の役割がある。入力層では Conv と ReLU を、中間層では Conv と BN と ReLU を、出力層では Conv を行う。DRL-CNN では、信号の未収集点にゼロデータを充填して再構成を行った画像(ゼロフィル再構成画像)に生じるアーティファクトを推定し、ゼロフィル再構成画像から推定したアーティファクトを減算処理することで目標とする画像を出力する。

4. 画像再構成シミュレーション

4.1 学習用データセット

本研究では、学習用データセットにフルデータ像とゼロフィル再構成画像の画像対 40 組を用いた。書面により同意を得たボランティアに対し、主磁界強度が 1.5T のキャノンメディカル社製 MRI によって撮像を行った頭部のプロトン密度強調像を使用した。撮像条件として、高速スピネコー法を使用し、各パラメータは TR が 3000ms, TE が 13ms, スライス厚 3.0mm, フリップ角度90°, 分解能 0.94mm, マトリクスサイズ256 × 256である。

4.2 ネットワークの学習条件と計算機環境

ネットワークの学習および画像再構成に用いた計算機環境を表 1 に示す。学習には GPU を用いて約 20 分を要した。また、学習の際に使用したネットワークの設定を表 2 に示す。パラメータ更新に用いる損失関数は、真のアーティファクトと推定アーティファクトの平均二乗誤差 $l(\theta)$ とした。全 N 枚の学習用画像のうち i 番目の画像における損失関数には次の式(1)を使用した[8]。このとき θ はネットワークのパラメータを表している。

$$l(\theta) = \frac{1}{2N} \sum_{i=1}^N \|R(y_i; \theta) - (y_i - x_i)\|_2^2 \quad (1)$$

表 1 計算機環境

CPU	Intel Core i7-4790 (3.60GHz)
RAM	32GB (PC3-12800)
GPU	NVIDIA GeForce GTX1800
Software	MATLAB R2017b MatConvNet 1.0-beta25 CUDA Toolkid 9.0/ cuDNN 7.0.5

表 2 学習時のネットワーク設定

パラメータ更新手法	Adam
バッチサイズ	128
パッチ マトリクスサイズ	40 × 40
パッチのストライド	10
エポック数	30
学習用画像	MR 実画像 40 枚
学習係数	1~10 エポック : 10^{-3} 11~20 エポック : 10^{-4} 21~30 エポック : 10^{-5}

4.3 画像再構成

学習用データセットとは異なる 7 枚のプロトン密度強調像を使用し、信号収集比を 30%, 40%, 50% として画像再構成を行った。使用した信号間引き収集のパターンを図 2 に、再構成の結果を図 3 に示す。

画質の定量的評価にはピーク信号対雑音比 PSNR(Peak Signal-to-Noise Ratio)および画像の構造的類似性を評価する SSIM(Structural SIMilarity index)[9]を用い、7 枚の再構成画像の評価値を平均したものを比較に使用した。表 3 に PSNR と SSIM の評価結果を示す。

5. 考察

非ランダム間引きによる再構成とランダム間引きによる再構成を比較すると、図 3 より非ランダムの方が弱いアーティファクトがやや多く認められるが、図 3(b)に示す CNN に入力したゼロフィル再構成像上の殆どのアーティファクトを除去することができた。これは非ランダム間引きによってゼロフィル再構成像に生じたアーティファクトがランダム雑音状にならずにコヒーレント性の強い規則的な現れ方をすることにより、CNN による学習が容易になり、効果的にアーティファクトの除去が行われたものと考ええる。表 3 に示す PSNR と SSIM の評価結果より、PSNR と SSIM のいずれも非ランダム間引きの方が優れた数値が得られた。また、再構成像の拡大図においてコントラストの表現を比較すると、信号収集比が小さい場合のランダム間引きによる再構成は、ややぼやけた画像になる傾向にあったが、非ランダムによる再構成ではより鮮鋭な画像が得られた。赤矢印に示す個所に着目すると、非ランダム再構成の方が鮮鋭さを有しており、画像の構造保存性が高いことがわかる。コントラストの面でも良好な復元が行われていた。規則的に信号間引きを行うと折り返しアーティファクトが現れるが、像自体に“ぼけ”は生じにくい。一方、ランダム間引きでは、アーティファクトのコヒーレンス性は低くなるが、画像に“ぼけ”が生じる傾向がある。そのため、アーティファクトを正確に検出・除去することができれば、規則

表 3 再構成画像の評価結果

信号収集比	信号間引き法	PSNR[dB]	SSIM
30%	非ランダム	30.74	0.9532
	ランダム	27.81	0.9320
40%	非ランダム	33.66	0.9761
	ランダム	29.65	0.9508
50%	非ランダム	38.16	0.9913
	ランダム	33.00	0.9714

なし

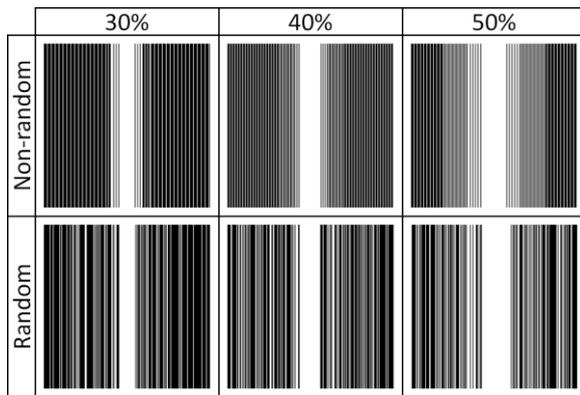


図2 本研究で使用した信号間引き収集パターン

的な間引きを行う提案法の方が鮮鋭な画像を再構成できる可能性がある。以上の理由により、表3に示すように非ランダムな間引き収集による再構成像は、PSNRとSSIMともにランダム間引きよりも高い値を示したものと考える。CNNを利用する再構成法にあっては、規則的な間引きは有望な方法である可能性が本研究により示された。

6. まとめ

本研究では、圧縮センシングのMRI応用において再構成像の品質安定化と再構成の高速化を目的として、非ランダム間引き収集を利用した深層学習再構成について検討を行った。その結果、汎用的なランダム間引き収集を利用したCS深層学習再構成よりも構造の保存性に優れ、かつコントラストの良好な再構成像を得ることができた。今後は再構成像のさらなる高品質化に向けてネットワークアーキテクチャの改良について検討するほか、3次元撮像について検討を行う予定である。

謝辞

本研究の一部は、科学研究費補助金(16K06379, 19K04423)の補助を受けて実施された。また、研究遂行にあたり、画像データを提供いただいたキャノンメディカルシステムズ(株)に感謝の意を表します。

文献

- [1] Donoho DL: Compressed sensing. *IEEE Trans Inform Theory*, **52**: 1289–1306, 2006
- [2] Candès EJ, Wakin MB: An Introduction To Compressive Sampling. *IEEE Signal Processing Magazine*, **25**: 21–30, 2008
- [3] Ito S, Ito K, Shibuya M, et al: Compressed Sensing MRI using Higher Order Multi-scale FREBAS for Sparsifying Transform Function, *SPIE Medical Imaging 2015*, 9413-16, Orlando, USA, 2015
- [4] Wang S, Su Z, Ying L, et al: Accelerating magnetic resonance imaging via deep learning. *IEEE 13th International Symposium on Biomedical Imaging*, Prague, 2016, pp514-517
- [5] Han YS, Lee D, Yoo J, et al: Accelerated Projection Reconstruction MR imaging using Deep Residual Learning. *25th Annual Meeting of International Society for Magnetic Resonance in Medicine*, Hawaii, O690, 2017
- [6] He K, Zhang X, Ren X, et al: Deep Residual Learning for Image Recognition. *IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, 2016, pp770-778
- [7] Ioffe S, Szegedy C: Batch normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *32nd International Conference on Machine Learning*, **37**, 448-456, 2015
- [8] Zhang K, Zuo W, Chen Y, et al: Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising. *IEEE Transactions on Image Processing*, **26**, 3142-3155, 2017
- [9] Wang Z, Bovik AC, Sheikh HR, et al: Image Quality Assessment: From Error Visibility to Structural Similarity. *IEEE Trans Image Proc*, **13**:600-612, 2004

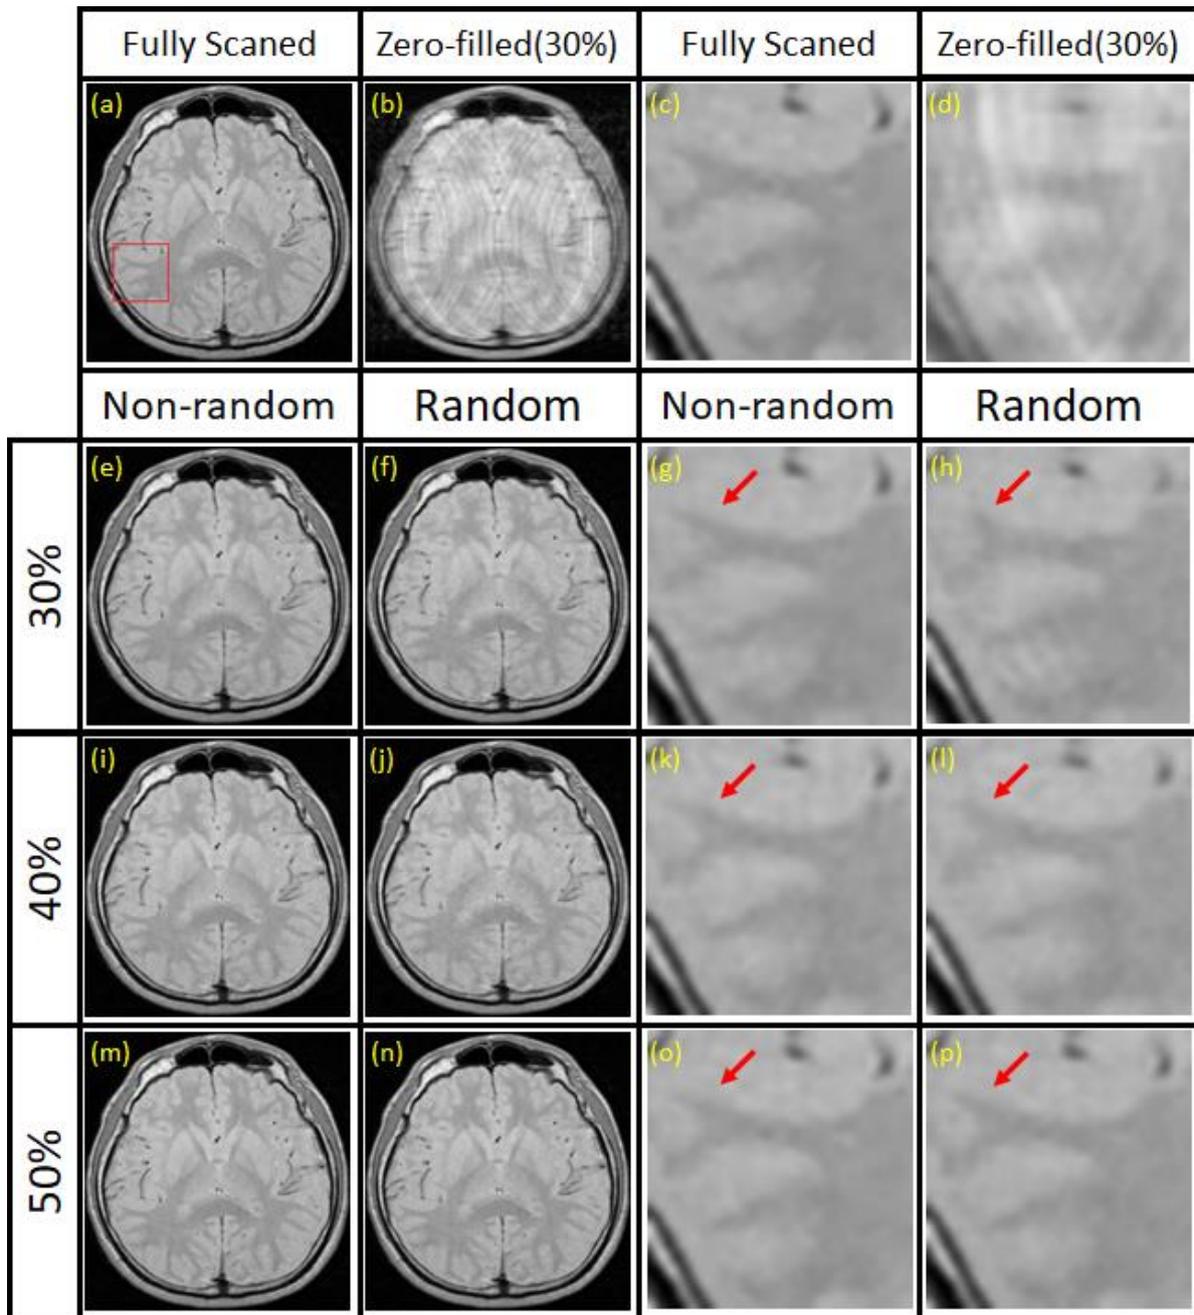


図3 再構成結果 : (a, c)フルデータ像, (b, d)ゼロフィル再構成画像, (e, g, i, k, m, o)非ランダム間引き再構成, (f, h, j, l, n, p)ランダム間引き再構成

Deep Learning based Image Reconstruction in MR Compressed Sensing using Non-randomly Under-sampled Signal

Yuki SATO^{*1}, Ryo KAZAMA^{*2}, Satoshi ITO^{*1}

^{*1} Graduate School of Regional Development and Creativity, Utsunomiya University

^{*2} Medical Systems Co., Ltd.

Reduction of acquisition time is a major issue in MRI. A recently proposed theory, Compressed Sensing (CS) has been applied to MR imaging (CS-MRI). In general, random under-sampling in signal space is used in CS-MRI and high-quality images can be reconstructed using small amount of signal; however, image quality depends on the randomness of sampling pattern. We have been studied a new CS-MRI method that uses regularly under-sampled signal in order to stabilize the obtained image quality.

In this paper, a novel CS-MRI image reconstruction method for non-randomly under-sampled signal using Deep learning was proposed and demonstrated. Simulation and experiments showed that high quality images having sharp edges and keeping the contrast of tissue were obtained.

Key words: Non-randomly sampling, Compressed Sensing, Deep Learning, Residual Learning, Reconstruction

CT 画像再構成における メタルアーティファクト除去の新技术法

千北 一期^{*1} 工藤 博幸^{*1} 森 和希^{*1} 金 鎔采^{*1}

要旨

金属クリップや歯科用インプラント等, 人体に比べて吸収係数が高いオブジェクトを含む対象に対して CT 画像再構成を行った場合, ビームハードニング等の物理現象によって再構成画像にメタルアーティファクトが発生する. 従来は step 1.メタル部分を同定し, step 2.金属部分を通過する投影データを補間等によって埋めることでアーティファクトを抑制していた. この方法は 2step 必要であり演算の過程で数理的に不確かな仮定を置くことによって解かれる. 提案法では, これらの問題を解決する. 方法は Kudo によって提案されたフォルトトレラント画像再構成 [1] に基づいており金属部分を通過した投影データを異常値としてみなしこれを除去する再構成法として適用する. また, データ項には Huber ノルム, 損失項には NonLocalTV [2] を適用することで, 従来の方法と同程度の精度の再構成画像を構築することができ, メタルアーティファクト問題に対する新しい方向性の枠組みが提唱された.

キーワード: CT 画像再構成, メタルアーティファクト, フォルトトレラント CT, NonLocalTV, Row-Action

1. はじめに

人体の吸収係数に比べて高いオブジェクトを含む物体に対して CT 画像再構成を行うと, 筋状のアーティファクトや黒い帯状のアーティファクト等が発生する. 原因は連続 X 線が物質を透過する際, 高エネルギーのものに比べ低エネルギーのほうがより吸収するという性質のためである. この結果, エネルギーのピークが本来の位置よりも低い方向にシフトしてしまい画像に不合理が発生する. これらの問題は総称としてメタルアーティファクトと呼ばれ

る.

これまでこの問題に対して, 主にセグメンテーションによってメタルの位置を同定し, この事前情報を用いた再構成法[3] が多く取られてきた. この方法ではまず, メタル部分を二値化処理等でマスクし, メタル部分の投影データ上での影響を逆投影を用いて考える. 次に, 投影データ上でのメタルの影響が現れる部分をマスクしたデータから導き出し, ここを線形補間や反復的な手法によってメタルの影響のない状態の画像を復号する. これを背景画像と呼ぶ. 最後にマスクしたメタル画像と背景画像を画像的に重ね合わせ最終的にメタルアーティファクトを除去した画像を得る.

この方法は背景画像とメタル画像を分離するステップと背景画像を復号するステップの二段階のステップが必要であり, その過程で数理的に不確かな仮定を置く必要がある, メタルを正しく分離する必要があるといった問題が

*1 筑波大学大学院システム情報工学研究科コンピュータサイエンス専攻
[〒305-8573 つくば市天王台 1-1-1]
e-mail:chigita@imagelab.cs.tsukuba.ac.jp

投稿受付: 2019 年 5 月 15 日

残る.

これらの問題点を解決するため本研究では、フォルトトレラント再構成法に基づく方法を提案する。フォルトトレラント再構成法は投影データ上に真値から大きく外れた値があるときにも、この外れ値や異常値の影響に頑健な再構成法である。

フォルトトレラント再構成法を適用することで、従来必要だった2つのステップを統合し、数理的に正しい仮定のもとで問題を解くことができる。本研究では歯科用CT及び腹部CT画像に対してメタルアーティファクトの除去の実験を行った。

2. 手法

2.1 従来手法

フォルトトレラント再構成法について説明するため、まずは通常のCT画像再構成の方法について示す。

通常の逐次近似的手法では評価関数としてデータ項 $f(\mathbf{x})$ と正則化項 $\psi(\mathbf{x})$ の和によって表す方法である。特にデータ項は式(1)のように表される。

$$f(\mathbf{x}) = \|\mathbf{Ax} - \mathbf{b}\|_2^2 \quad (1)$$

ここで、 $\mathbf{x} \in \mathbb{R}^I$ は再構成対象となる画像の画素を並べたベクトル、 $\mathbf{b} \in \mathbb{R}^I$ は投影データの標本地を並べたベクトル、 $\mathbf{A} \in \mathbb{R}^{I \times J}$ は投影操作を意味するシステム行列とする。

本論文では L^1 ノルムを用いたフォルトトレラント再構成法及び、Huber損失関数を用いたフォルトトレラント再構成法の2つについて示す。

2.2 提案手法 1: L^1 ノルムを用いる方法

こちらのフォルトトレラント再構成法ではデータ項 $f(\mathbf{x})$ に対して、 L^1 ノルムを用いる。適用すると式(2)となる。

$$\begin{aligned} f(\mathbf{x}) &= \|\mathbf{Ax} - \mathbf{b}\|_1 \\ &= \sum_{i=1}^I |\mathbf{a}_i^T \mathbf{x} - b_i| \end{aligned} \quad (2)$$

フォルトトレラント再構成法において、式(2)のように L^1 ノルムを用いる理由として、異常値の影響を受けないように正しい画像を再構成し、異常値に対して頑健であるためである。また通常の再構成法の L^2 ノルムを用いる方法に比べて異常値に対して鈍感に再構成されるため、異常値部分だけを取り除くことができる。

この再構成法が用いられる例として、CT装置の一部の検出器が壊れているケース、ある投影方向のデータのみ欠損しているケースなどが挙げられる。これらは観測に失敗した欠損値を異常値として捉えることで、フォルトトレラント再構成法を適用している。

メタルアーティファクト除去に適用する場合にも同様に考える。メタルによる影響を異常値として捉えることで、メタル位置やその影響を同定し、影響を受けていない画像をフォルトトレラント再構成法によって作る。よって最終的に以下の式(3)の一式のみを解くことでメタルアーティファクトの除去を実現する。

$$\min_{\mathbf{x}} \|\mathbf{Ax} - \mathbf{b}\|_1 + \beta\psi(\mathbf{x}) \quad (3)$$

正則化項 $\psi(\mathbf{x})$ は再構成画像の隣接画素のなめらかな輝度変化を評価するTotalVariationのうち、局所的な変化に対しても適切に評価されるNonLocalTVを用いる。ここで β は重みを示すパラメータである。

2.3 提案手法 2: Huber損失関数を用いる方法

こちらのフォルトトレラント再構成法ではデータ項 $f(\mathbf{x})$ に対してHuber損失関数を用いるこれを適用すると式(4)となる。ただし、式(4)中で出てくる関数 $H(\mathbf{x})$ はHuber損失関数であり、式(5)で表される。

$$\begin{aligned} f(\mathbf{x}) &= \|\mathbf{Ax} - \mathbf{b}\|_T \\ &= \sum_{i=1}^I H(\mathbf{a}_i^T \mathbf{x} - b_i) \end{aligned} \quad (4)$$

$$H(x) = \begin{cases} \frac{x^2}{2} & |x| < T \\ T|x| - \frac{T^2}{2} & \text{otherwise} \end{cases} \quad (5)$$

また、式 (5) において T は原点付近での L^2 ノルムの振る舞いを行う部分とその他領域での L^1 ノルムの振る舞いを行う部分の境目を担う閾値である。

この性質はメタルアーティファクト除去においては、 L^1 ノルムが異常値に対して鈍感に作用した結果、メタルアーティファクト以外のノイズに対しても鈍感に反応してノイズがうまく消されない問題を解決する。 L^2 ノルムの振る舞いを行う部分で通常のノイズを除去し、 L^1 ノルムの振る舞いを行う部分によってメタルアーティファクトを除去することにつながる。最終的には式 (6) のみを解くことで再構成画像を得る。正則化項は L^1 ノルムを用いる方法と同様に NonLocalTV を用いる。

$$\min_x \|Ax - b\|_T + \beta\psi(x) \quad (6)$$

2.4 NonLocalTV

NonLocalTV は、エッジ保存が効く非線形フィルタである (NonLocalMeans: NLM) をハイパーパラメータとして用いる TV の拡張方法の一つである。NLM の重みは線模様のようなものに対して大きくなる性質がある。そのため、メタルアーティファクトによって生じる線状のアーティファクトに対しても通常の TV や重み付き TV に比べてノイズ除去に大きく寄与することが予想される。

2.5 反復式

式 (3) 及び式 (5) を Row-Action 型の近接スプリットティング[4] によって解くために反復式の形に変形する。まとめたものを Algorithm1 に示す。

Algorithm 1 : Proposed Method

[step0] 初期化

Require: $\alpha_0 > 0, \varepsilon > 0, \mathbf{x}^{(0,1)} \leftarrow \mathbf{0}$

Ensure: $\mathbf{x}^{(n,1)}$

for $k \leftarrow 1, n$ **do**

[step1] stepsize の更新

$$\alpha^{(k)} \leftarrow \frac{\alpha^0}{1+\varepsilon k}$$

[step2] 各投影方向に対する演算

for $i \leftarrow 1, I$ **do**

$$e \leftarrow -\frac{b_i - \mathbf{a}_i^T \mathbf{x}^{(k,i)}}{\alpha^{(k)} \|\mathbf{a}_i\|_2^2}$$

$$\lambda \leftarrow \begin{cases} -1 & e \leq -1 \\ e & -1 < e < 1 \\ 1 & e \geq 1 \end{cases}$$

[step3] 解の更新

$$\mathbf{x}^{(k,i+1)} \leftarrow \mathbf{x}^{(k,i)} - \lambda \alpha^{(k)} \mathbf{a}_i$$

endfor

[step4] 正則化項の最適化問題を解く

$$\mathbf{x}^{(k,I+2)} \leftarrow \text{prox}_{\alpha^{(k)}\psi(x)}(\mathbf{x})$$

[step5] k の更新

$$\mathbf{x}^{(k+1,1)} \leftarrow \mathbf{x}^{(k,I+2)}$$

endfor

return $\mathbf{x}^{(n,1)}$

3. 実験結果

3.1 データ作成

今回の実験ではメタルアーティファクトの原因となる主に2つの現象をシミュレーションする。対象画像は歯科用 CT で用いられたデータである。埋め込むメタルは直径 2.6mm, 3.6mm, 4.6mm の円形、素材はアマルガムとし、これらを画像中に埋め込む。画像は 185mm×185mm とした。投影方向数は 512 方向とした。表示するコントラストレンジは μ 換算で [0.0, 1.0] とした。

シミュレーションはビームハードニングに関するもの[5-6] と、ポアソンノイズに基づく計測誤差の2つである。

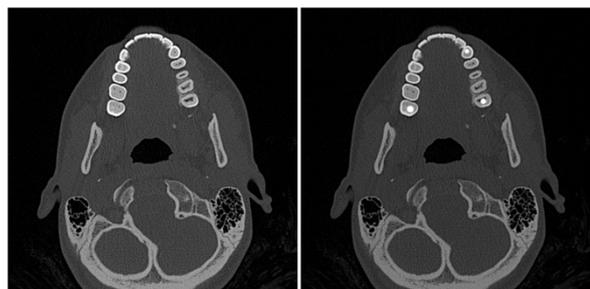
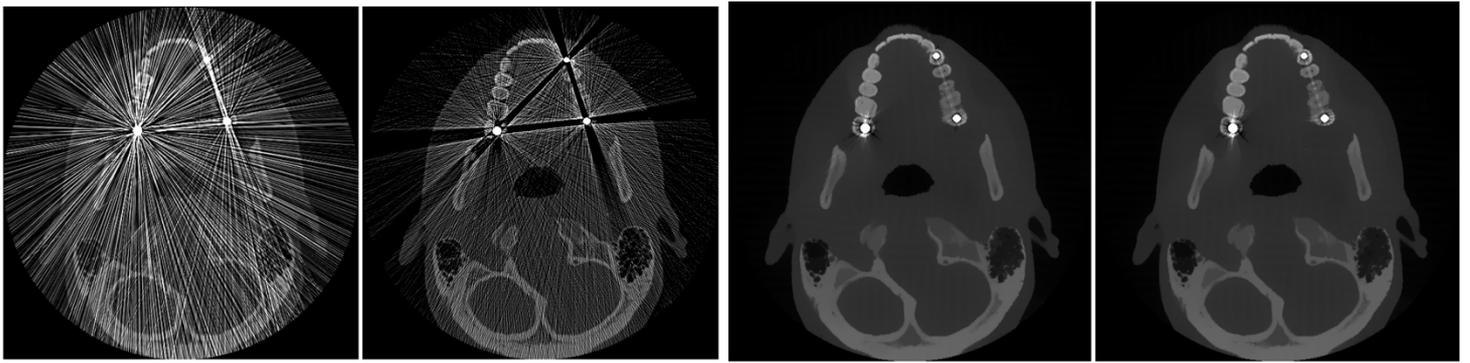


図 1 歯科用 CT 画像(左)及びメタルを含んだ歯科用 CT 画像(右)



FBP 法

OS-SART+TV 法

提案法(L^1 ノルム)

提案法(Huber 損失関数)

図 2 実験結果

表 1 数値評価

	FBP 法	OS-SART+TV 法	提案法 1 (L^1 ノルム)	提案法 2 (Huber 損失関数)
RMSE	0.411738	0.476509	0.233891	0.2332707
PSNR	37.168181	35.899183	42.080355	42.124429
SSIM	0.921136	0.961689	0.995088	0.995033

図 1 にメタルを埋め込む前の画像及び、メタルを埋め込んだ理想的な再構成画像を示す。

3.2 評価指標

定量的な評価指標として RMSE, PSNR, SSIM を用いる。また定性的にも評価する。各指標の式は以下ようになる。

$$RMSE = \sqrt{\frac{1}{J} \sum_{j=1}^J (x_j - \hat{x}_j)^2} \quad (7)$$

$$PSNR = 20 \log_{10} \left(\frac{MAX^2}{\frac{1}{J} \sum_{j=1}^J (x_j - \hat{x}_j)^2} \right) \quad (8)$$

$$SSIM = \frac{(2\mu_x \mu_{\hat{x}} + c_1)(2\sigma_{x\hat{x}} + c_2)}{(\mu_x^2 + \mu_{\hat{x}}^2 + c_1)(\sigma_x^2 + \sigma_{\hat{x}}^2 + c_2)} \quad (9)$$

3.2 実験

比較対象として FBP 法, OS-SART+TV 法 [7], 提案法(L^1 ノルムを用いるもの), 提案法(Huber 損失関数を用いるもの)で比較する。実際に再構成された画像を図 2 に示す。また、これらの数値評価の結果を表 1 に示す。

まず定量的に評価する。表 1 を見ると提案法がどの従来法に比べても良い結果を示してい

ることがわかる。特に SSIM で比較した時により良い結果を示している事がわかる。これは評価指標から考えるに、細部の構造が他の方法に比べて詳細に再構成できていることを意味する。

次に、定性的に評価する。定性的にみると、提案法は他の 2 つの手法に比べてストリークアーティファクトが除去できている。これは、正則化項として、NonLocalTV を採用した結果と考えられる。NonLocalTV は各サポートウィンドウの中で重みを最小にする効果があるため、この結果が出ていると定性的に評価できる。

4. まとめ

実験により、メタルアーティファクトの問題を 1 つの単純な式の求解にモデル化できたこと、フォルトトレラント再構成法がメタルアーティファクトの除去に有効な手法であることが示された。また、これが Row-Action 型の反復式によって解くことが可能であることも示された。

さらに、正則化項に NonLocalTV を用いることでより効率的にノイズを除去できることが分かった。

今後の課題として、より細かなコントラストの保存の手法の検討が求められる。

利益相反の有無
なし

文 献

- [1] H.Kudo, K.Takaki, F.Yamazaki et al.: Proposal of fault-tolerant tomographic image reconstruction Proceedings Volume 9967, Developments in X-Ray Tomography X; 99671K, 2016.
- [2] Xavier Bresson.: A Short Note for Nonlocal TV Minimization, Technical Report, 2009.
- [3] Xiaomeng Zhang, Lei Xing.: Sequentially reweighted TV minimization for CT metal artifact reduction. Med. Phys., vol. 40, no. 7, pp. 071907-1-071907-12, 2013.
- [4] PL.Comettes,J.-C.Pesquet.:Proximal splitting method in signal processing, Fixed Point Algorithmsfor Inverse Problems in Science and Engineering, 2010.
- [5] B. De Man, et al.: Metal Streak Artifacts in X-ray Computed Tomography: A Simulation Study.IEEE Trans. Nuclear Science Symposium, pp. 1860-1865, 1998.
- [6] Ramakrishna K, Muralidhar K, Munshi P.: Beam-hardening in simulated X-ray tomography.NDT&E International. vol 39, pp 449-457, 2006.
- [7] R. Gordon, R. Bender, and G. T. Herman. Algebraic reconstruction techniques (ART) for threedimensional electron microscopy and x-ray photography. J. Theor. Biol., Vol. 29, pp. 471481,1970.

A New Framework for Metal Artifacts Reduction in CT Image Reconstruction

Kazuki CHIGITA^{*1}, Hiroyuki KUDO^{*1}, Kazuki MORI^{*1}, Yongchae KIM^{*1}

^{*1} Graduate School of Information and Systems University of Tsukuba

Metal artifacts caused by implants for teeth degrade quality of CT image. In this study, we propose a new framework to solve the problem of metal artifact in CT image reconstruction. Up to now, the algorithm for metal artifact reduction needs two step. In the first step, detecting metal in sonogram image. The second step, reconstruct CT image which exclude effect of metal using first step data with interpolation. However, our solution consists from only one step. The key idea of this method is using Fault-Tolerant image reconstruction. Fault-tolerant image reconstruction was developed for image of including deficit measurement data by Kudo et al [1]. We apply to the problem of metal artifacts reduction. In Fault-tolerant image reconstruction, it uses L1 norm error or Huber error for data term, and total variation for regularization term. In proposed method, NonLocal TV [2] is used for regularization term, and solved with proximal splitting. The results demonstrate that the proposed method is able to reduce the metal artifacts successfully most cases.

Key words: CT Image Reconstruction, Metal Artifact, Fault-Tolerant Image Reconstruction, NonLocal TV, Row-Action

Computed Tomography Image Reconstruction from Neighbor Slices using 2D U-Net Convolutional Networks

Shuqiong WU^{*1}, Megumi NAKAO^{*1}, Keiho IMANISHI^{*2}
Mitsuhiro NAKAMURA^{*3}, Tetsuya MATSUDA^{*1}

Abstract

Usually, computed tomography (CT) image reconstruction refers to a process of creating tomographic images from the sinogram. To reduce the radiation during the scanning, many algorithms were proposed to realize the reconstruction from sparse viewpoints. Generally, these methods can be divided into two categories: analytical and iterative approaches. Analytical methods are difficult to achieve high accuracy, whereas iterative algorithms suffer from high computation cost. To solve the problem, we apply 2D U-Net convolutional networks to CT image reconstruction. In contrast to the conventional methods, the proposed approach realizes the reconstruction from already created CT slices, not the sinogram. Using the U-Net, we can create a middle slice between two adjacent CT slices. This means that we can decrease the number of slices to reduce the radiation. We compared the proposed algorithm with linear interpolation. Experiment results show that the proposed approach totally outperforms the linear interpolation.

Keywords : Computed tomography, sinogram, U-Net, CNN, reconstruction

1. Introduction

Medical diagnosis based on CT images brings people great benefits because they can present every detail of the inner human body. However, the patients also suffer from radiation during a CT scanning. To solve the problem, many researchers focus on developing approaches for low-dose CT. The mainstream is sparse-view-based image reconstruction [1-3], which reduces the radiation by scanning from less viewpoints. One popular method is Filtered back-projection (FBP) that can reconstruct CT images from the sinogram in a high speed [1]. However, noise and artifacts often occur as the number of scanning viewpoints reduces. To address this issue, many studies apply iterative techniques to refine the reconstruction, though it brings more calculation [2]. Recently, an approach based on convolutional neural networks (CNN) was proposed to reconstruct the CT images [3]. It outperforms many traditional methods in both accuracy and speed. Differently from these algorithms, our study aims at reconstructing CT images from already reconstructed slices, i.e. a new middle slice can be created from two adjacent slices. Then the radiation can be reduced by using less slices.

*1 Graduate School of Informatics, Kyoto University [Yoshida-honmachi, Kyoto, 606-8501, JAPAN]

e-mail: wusq@i.kyoto-u.ac.jp [Shuqiong Wu]

*2 e-Growth Co., Ltd. [403, Shimo-Maruya-cho, Nakagyo-ku, Kyoto, 604-8006, JAPAN]

*3 Graduate School of Medicine, Kyoto University [53 Kawahara-cho, Shogoin, Kyoto, 606-8507, JAPAN]

This idea is almost novel, and a straightforward method to fulfill this goal is interpolation. However, to achieve higher accuracy, we propose a U-net based method for the reconstruction.

2. Proposed algorithm

Recently, U-net was widely applied to medical image segmentation because of its high efficiency. It is a CNN whose layers are aligned in a U structure [4]. It performs better on medical images than other machine-learning methods because the U structure extracts both global and local features. In this research, the U-net is adopted for creating new images instead of segmenting images. The whole architecture of the proposed method is shown in Fig. 1.

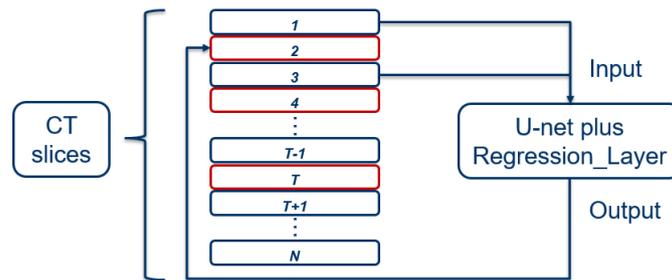


Fig. 1 Architecture of the proposed algorithm

Figure 1 shows the CT slices of one patient, where T denotes the index and N denotes the total number of the slices. The inputs of the U-net are two slices ($T-1$ and $T+1$), and the output is the middle slice (T) between the two inputs. The proposed method reconstructs half of the slices by U-net rather than CT scanning, so that the radiation can be halved. In our experiment, we totally collected CT data from 130 patients. We used 5 cross-validation to evaluate the proposed method, which means 104 are for training, and the remained 26 are for test. We used the absolute error in gray scale ([0-255]) for the evaluation. The proposed algorithm was compared with the traditional linear interpolation. Table 1 summarizes all the comparison results of five crosses, which shows that an average of 14.49% improvement was achieved by the proposed method. Figure 2 shows an example of the reconstructed CT images. The proposed method reduces noise and artifacts significantly comparing with the linear interpolation. Here, GT means the ground truth.

Table 1 Comparison of the proposed method with linear interpolation

Mean-error-rate	Interpolation	Proposed method	Improvement
Cross-validation1	2.138	1.860	13.00%
Cross-validation2	2.481	2.124	14.39%
Cross-validation3	2.603	2.313	11.14%
Cross-validation4	2.677	2.289	14.49%
Cross-validation5	2.839	2.287	19.44%

3. Conclusions

This paper proposes a U-net-based method for CT image reconstruction. It reconstructs high quality CT images from adjacent slices. Compared with linear interpolation, the proposed approach reduces the absolute error rate significantly.

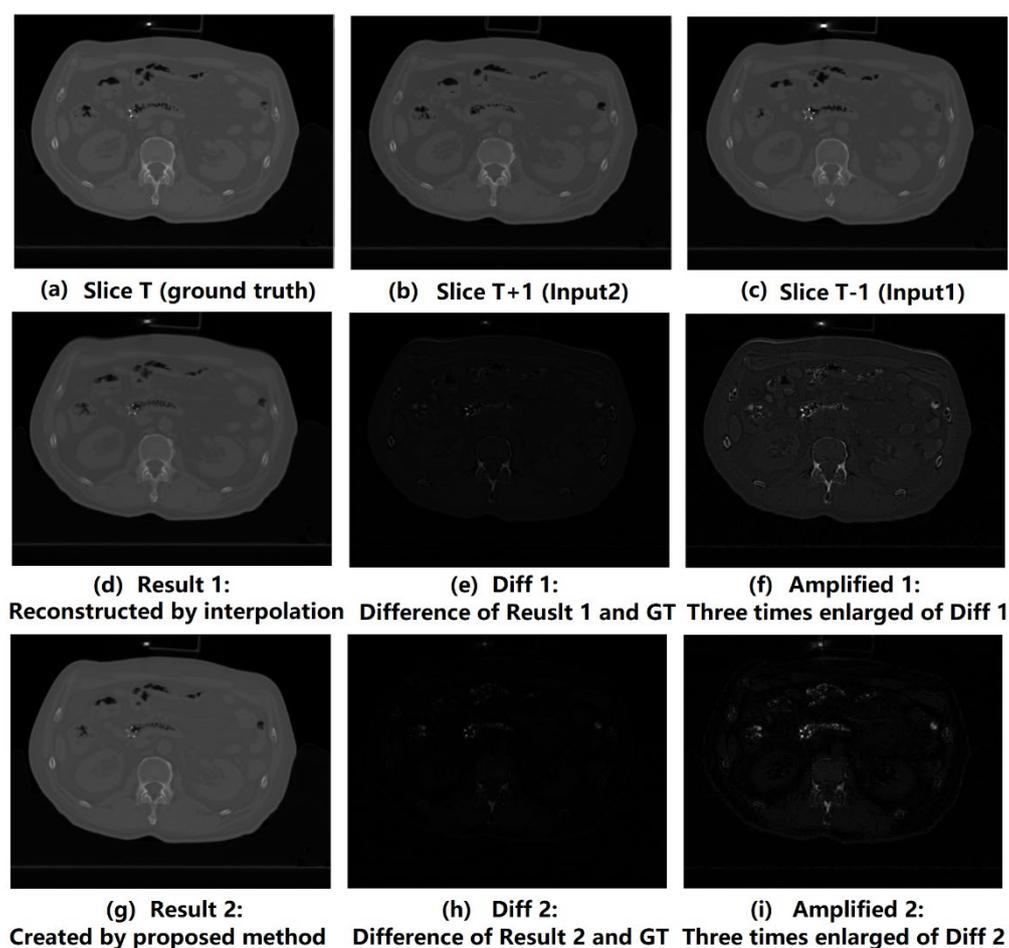


Fig. 2 Example of the CT image reconstruction

Competing interests

No conflict of interest

Acknowledgement

This research was funded by the Japan Agency for Medical Research (AMED) and the Acceleration Transformative Research for Medical Innovation (ACT-M) Program. A part of this study was also supported by JSPS Grant-in-Aid for Scientific Research (B) (grant number 18H02766). This study was performed in accordance with the ethics committee, Kyoto University.

References

- [1] Zhang S, Li W, Tang G, et al: Study on image reconstruction algorithm of filtered backprojection. Journal of Xianyang Normal University 23: pp. 47-49, 2008.
- [2] Selim M, Rashed E.A, Atia M.A, et al.: Image reconstruction using self-prior information for sparse-view computed tomography.

The 9th Cairo International Biomedical Engineering Conference, pp. 146-149, 2018.

- [3] Gupta H, Jin K.H, Nguyen H.Q, et al.: CNN-based projected gradient descent for consistent CT image reconstruction. IEEE Transactions on Medical Imaging Vol. 31, No. 6, pp. 1440-1453, 2018.
- [4] Long J, Shelhamer E, Darrell T: Fully convolutional networks for semantic segmentation. CVPR: pp. 3431-3440, 2015.

TV 正則化と辞書学習を用いた OS-EM 法における PET 画像再構成

奥村 直裕^{*1} 庄野 逸^{*1*2}

要旨

陽電子放射撮影(Positron Emission Tomography : PET)スキャンは、癌の発見などの病理診断で注目されている。PET スキャンにおいて鮮明な画像を得ようとすれば、S/N 比をあげる必要があり、これは観測時の被曝量増加につながる。このため被曝量を抑えつつ、画像の S/N 比をあげることが望まれている。本研究ではこの問題に対して、実画像表現とサイノグラム表現のそれぞれにおけるノイズ除去手法を組み合わせた手法を提案する。サイノグラム表現に対するノイズ除去手法としては、辞書学習を用いた手法を適用した。実画像表現に対するノイズ除去手法としては、正則化アプローチに基づいた手法を適用した。このような 2 種類のノイズ除去手法を組み合わせてノイズ除去を行うアプローチは、従来手法と比較して有効であることを確認した。

キーワード：PET 画像再構成，スパースモデリング，辞書学習，K-SVD

1. はじめに

現在、癌の発見といった病理診断において、陽電子放射断層撮影 (Positron Emission Tomography : PET) スキャンが有効とされている。PET スキャンでは、トレーサと呼ばれる陽電子を放射する放射性物質を患者に注入し、複数方向から観測を行うスキャナに測定部位を通すことでトレーサの分布データを採集する。観測は投影とも呼ばれ、得られた観測データはサイノグラムと呼ばれる。サイノグラムから元の空間でのトレーサ濃度の分布を画像化する方法は、画像再構成と呼ばれる。画像再構成は、サイノグラムからトレーサの濃度をパラメータとして推定し、この推定濃度値を画素値とし

て扱うことが多い。このようなパラメータを推定する方法の 1 つに最尤推定法 (Maximum Likelihood estimation : ML 法) がある。最尤推定法は取得したデータに対して、モデルとなる確率分布が、最も尤もらしくなるパラメータ値を推定する手法である。ML 法を用いた場合、推定に用いるデータが多いほど、より正確にパラメータを推定することができる。PET 画像や CT 画像において、最尤推定法を用いて再構成画像を得る手法としては、ML-EM (Maximum Likelihood Expectation Maximization) 法が提案されており [1], ML-EM 法を高速化する手段として OS-EM (Ordered Subsets EM) 法が提案されている [2]。このような最尤推定ベースの手法で S/N 比の高い鮮明な画像を得ようとした場合、十分な投影角度数で S/N 比の高い観測データが必要となる。PET において、このような観測データを得ようとすると被曝量を増やさなければならず、患者に健康上の悪影響を及ぼす可能性がある。逆に、患者に考慮した観測を行うと、S/N 比の低い画像しか得られず、アーチファク

*1 電気通信大学情報理工学研究科情報学専攻

[〒182-8585 東京都調布市調布ヶ丘 1-5-1]

e-mail: okumura.naohiro@uec.ac.jp

*2 e-mail: shouno@uec.ac.jp

トと呼ばれるノイズが発生してしまう。そのため、患者への被曝量を抑えつつ、画像の S/N 比の高い鮮明な画像を得ることが望まれている。

本研究ではこの問題に対して、実画像表現とサイノグラム表現の各々においてノイズ除去手法適用した画像再構成手法を提案している。サイノグラム表現に対するノイズ除去では、K-SVD 法と呼ばれる辞書学習手法を適用した。辞書学習はスパースモデリングの一種でデータ表現を少ない基底の線形和で表現するための手法である。一方の実画像表現に対するノイズ除去としては正則化アプローチに基づいた手法を適用した。正則化項としては、TV(Total Variation)ノルムを用いた TV-EM 法(Total variation EM)を導入した [3]。この我々の提案手法でノイズ除去をした画像と、従来手法で得られた再構成画像について、定量評価を行い結果の比較を行った。

2. 手法

本研究では、2 つのノイズ除去手法を組み合わせた画像再構成手法を提案する。ここでは、提案手法でノイズ除去に用いる、画像再構成手法と辞書学習を用いたノイズ除去手法について述べる。

2-1. 画像再構成のモデル化

本研究では、Shepp & Logan の想定した観測モデルを用いている [4]。図 1 に観測モデルの概略図を示す。まず、撮像空間を図 1 のように正方格子状に区切り、ここに観測対象を配置するものとする。各正方格子には観測対象の断面

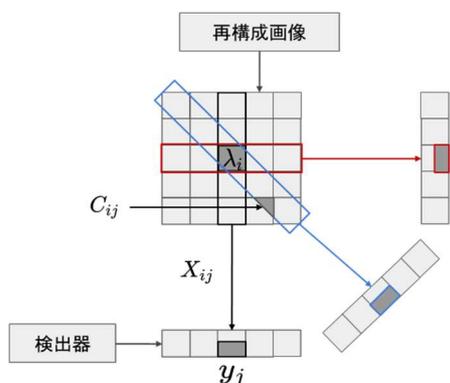


図 1 再構成画像モデルの概略図

の小領域が割り当てられるので、この正方格子状の各領域をセルとして考える。以後、各々のセルを再構成画像の 1 画素として扱う。各セル内から放射された放射線は、外部に設置された検出器において観測される。検出器の 1 つのセンサに対して、観測されるセルからの放射線の総和を 1 つの観測データとして扱う。

ここで、セルの番号を i 、センサの番号を j とした時、セル i からセンサ j への放射線量を x_{ij} とし、センサ j で観測される光子数データ y_j とする。また放射線量 x_{ij} は、ポアソン観測過程に従うものとし、各セルに割り当てられた推定パラメータ λ_i と j 番目のセンサから見えるセルの面積 c_{ij} によって支配されていることを仮定する。すなわち、推定すべきパラメータ λ_i が実画像表現となる。一方、このような定式化のもとで最尤推定を行おうとすると、放射線量 x_{ij} が非観測な不完全データとなるため、期待値最大化 (Expectation Maximization: EM) アルゴリズムなどを適用する必要がある。この最尤推定原理に EM アルゴリズムを組み合わせた手法を ML-EM 法と呼ぶ。導出の詳細は付録に記すが推定パラメータの更新式としては

$$\lambda_i = \frac{1}{\sum_j c_{ij}} \sum_j \frac{y_j c_{ij} \lambda_i^t}{\sum_l c_{jl} \lambda_l^t} \quad (9)$$

が得られる。ただし、 λ_i^t は一回前に推定したパラメータで、次の繰り返しでは新たに求めた λ_i を λ_i^t として推定を行う。以上のように求めた更新式を用いてパラメータ λ_i の推定を行う。

ML-EM 法には推定を収束させるために膨大な繰り返し回数と計算時間を要してしまう。この問題を解決する為に開発された手法が OS-EM 法である。OS-EM 法では、観測データをいくつかのサブセットに分割し、サブセット毎にパラメータ λ^t を更新する。そして、全てのサブセットでパラメータ λ^t の更新を行った時点で、1 回の繰り返しとしている。これにより 1 回の繰り返しでパラメータ λ^t を更新する回数が多くなり、結果として収束が早くなる。

2-2. TV-EM 法

ML-EM 法に対して正則化項を導入して解の

向上やノイズ除去を行う手法も存在する．特に正則化項付きの尤度関数の最大化は MAP (Maximum A Posteriori) 法に対応するため MAP-EM 法と呼ばれる [6]．MAP-EM 法は正則化項を適切に設定することにより，低 S/N 比のデータからでも鮮明な画像を再構成することが出来る．MAP-EM 法における λ_i の更新式も，ML-EM 法と同様に導出でき，次式のようにかける：

$$\lambda_i = \frac{1}{\sum_j c_{ij} + \alpha \frac{\partial}{\partial \lambda_i} U(\lambda^t)} \sum_j \frac{y_j c_{ij} \lambda_i^t}{\sum_l c_{jl} \lambda_l^t} \quad (10)$$

ここで， $U(\cdot)$ は正則化項， α は，正則化項をどの程度の強さで入れるかを表す制御パラメータである．この正則化項として式(11)で表される TV ノルムを用いた手法が TV-EM 法である [7]．

$$U(\lambda) = TV(\lambda) = \sum_{m,n} |(\nabla \lambda)_{m,n}| \\ = \sum_{m,n} \sqrt{(\lambda_{m,n} - \lambda_{m+1,n})^2 + (\lambda_{m,n} - \lambda_{m,n+1})^2} \quad (11)$$

ここで， m, n は画像値のインデックスを表している．TV ノルムによる正則化は，隣接画像の変化を画像全体で少なくすることにより，エッジや細かな造形を保存しつつノイズを滑らかにする効果がある．そのため，TV ノルムによる正則化を導入した TV-EM 法では，ノイズ除去をすると同時に，エッジを保存した画像再構成が行われることが期待できる．

2-3. 辞書学習を用いたノイズ除去手法

本研究では，実画像表現におけるノイズ除去だけでなく，サイノグラム表現においてもノイズ除去を適用している．サイノグラム表現におけるノイズ除去方式としては辞書学習と呼ばれる手法を用いた．サイノグラム表現においては，実画像表現における TV ノルムのような正則化指標が有効であるかどうかは不明なため，データ駆動型のノイズ除去手段を導入した．辞書学習は，スパースモデリングの一種で，出来るだけ少数の基底の線形和で入力を表そうとした際の基底をサンプルデータから推定する手法である．ここではサイノグラム表現に対し

て K-SVD 法[8]を用いて辞書を構築している．ここで，サイノグラムは列方向に角度 θ ，行方向にセンサが捉えたデータ \mathbf{s} とする行列として考える．任意の角度 θ^* におけるデータ \mathbf{s} をひとつのデータとして捉え，このデータがひくつかの基底 (アトム) とその係数の線形和で表されるものとする．ここで， i 番目の角度 θ_i のデータの集合を $\mathbf{S} = \mathbf{s}_i$ とし，アトムの集合は 1 つ 1 つがデータ \mathbf{s}_i と同じ大きさで， K 個からなる集合 $\mathbf{D} = \mathbf{d}_k$ と考える．このアトムの集合 \mathbf{D} を辞書と呼ぶ．さらに， i 番目のデータに対する k 番目のアトムの結合係数を $\mathbf{X} = \mathbf{x}_{ik}$ とすると， i 番目のデータ \mathbf{s}_i の線形結合は次式で与えられる．

$$\mathbf{s}_i = \sum_k \mathbf{x}_{ik} \mathbf{d}_k \quad (12)$$

以上の関係を表した概念図を図2に示す．式(12)は， $\mathbf{S} = \mathbf{D}\mathbf{X}$ と表されるが，データとして持っている量は \mathbf{S} のみであり， \mathbf{D} と \mathbf{X} とは一般的には求めることができない．そこで，係数行列 \mathbf{X} に対してスパース制約を導入する．辞書学習におけるスパース性とは，可能な限り少ないアトム数で入力を表現することを意味する．ここでは辞書を入力データから獲得することを考えるため， \mathbf{X} の i 番目の結合係数のベクトルを \mathbf{x}_i と置くと，K-SVD 法における最適化関数は次式のように与えられる．

$$\min_{\mathbf{D}, \mathbf{X}} \|\mathbf{S} - \mathbf{D}\mathbf{X}\|_F^2 \text{ subject to } \forall_i, \|\mathbf{x}_i\|_0 \leq T_0 \quad (13)$$

ただし， $\|\cdot\|_0$ は L_0 ノルムであり，ベクトル中の非 0 要素の個数を表わしている．また， $\|\cdot\|_F^2$ はフロベニウスノルムであり，各要素の 2 乗和により入力と辞書による復元結果の差を表している．この差を小さくするような辞書 \mathbf{D} と係数 \mathbf{X} を各

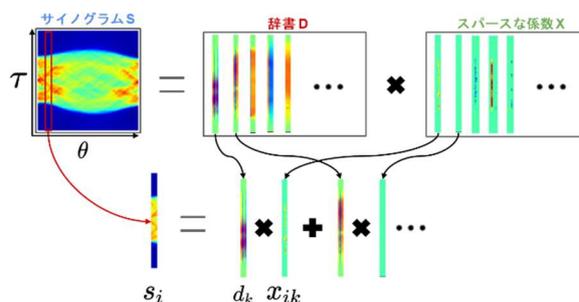


図 2 サイノグラム表現辞書の概念図

係数ベクトル \mathbf{x}_i の非 0 要素が T_0 個以下になるように更新を行う。

K-SVD 法は、辞書を固定し、使用する基底とその係数を求める STEP1 と、係数を固定し、入力との誤差を小さくするようアトムを更新する STEP2 を繰り返すことで学習する。提案手法では STEP1 として、OMP (Orthogonal Matching Pursuit) [9] を用いた。OMP では、観測信号 \mathbf{S} をアトムとサポート (非 0 の係数集合) との線型結合で近似した時の残差が最小になるような基底をサポート集合に逐次的に追加していくことで、使用するアトムと係数を求めている。

次に STEP2 を考えてみよう。K-SVD 法では、1 回につき 1 つのアトムを更新するため、まず更新する k 番目のアトム \mathbf{d}_k とその係数ベクトル \mathbf{x}_k^T に着目し、式(13)の最適化関数を次式のように書き変える。

$$\|\mathbf{S} - \mathbf{D}\mathbf{X}\|_F^2 = \left\| \mathbf{S} - \sum_{j=1}^K \mathbf{d}_j \mathbf{x}_j^T \right\|_F^2 \quad (14)$$

$$= \left\| \left(\mathbf{S} - \sum_{j \neq k} \mathbf{d}_j \mathbf{x}_j^T \right) \mathbf{d}_k \mathbf{x}_k^T \right\|_F^2 \quad (15)$$

$$= \|\mathbf{E}_k - \mathbf{d}_k \mathbf{x}_k^T\|_F^2 \quad (16)$$

\mathbf{E}_k は入力とアトム \mathbf{d}_k 以外のアトムと係数により復元した結果との残差を表している。すなわち、 k 番目のアトムはこの残差成分を効率良く表すことが求められている。式(16)を最小化する最適な \mathbf{d}_k と \mathbf{x}_k^T は \mathbf{E}_k を SVD (Singular Value Decomposition) により第一特異値に付随する特異ベクトルで近似することで求めることができる。ただし、SVD によって得られる係数ベクトルは密なベクトルとなるため、非 0 要素を増やしてしまう。この問題を解決するために \mathbf{x}_k^T の非 0 要素のインデックスを表すような ω_k を以下のように定義する。

$$\omega_k = \{i | 1 \leq i \leq N, \mathbf{x}_k^T(i) \neq 0\} \quad (17)$$

さらに、 $(\omega_k(i), i)$ の位置の要素のみが 1 であるような大きさ $N \times |\omega_k|$ 配列 Ω_k を考える。これを \mathbf{x}_k^T に掛けることにより以下のような非 0 要素のみで構成されるベクトル \mathbf{x}_k^R に変換することができる。

$$\mathbf{x}_k^R = \mathbf{x}_k^T \Omega_k \quad (18)$$

また \mathbf{E}_k も同様に、 Ω_k を掛けたものを \mathbf{E}_k^R と置く。これらを用いて式(16)を以下のように書き換えることができる。

$$\|\mathbf{E}_k \Omega_k - \mathbf{d}_k \mathbf{x}_k^T \Omega_k\|_F^2 = \|\mathbf{E}_k^R - \mathbf{d}_k \mathbf{x}_k^R\|_F^2 \quad (19)$$

これにより \mathbf{E}_k^R を SVD によりランク 1 近似した解を直接使用することができ、アトムと係数のベクトルを同時に更新することが可能となる。

以上のような STEP1 と STEP2 を繰り返し行い、サイノグラム表現に対する辞書を構築する。学習後、構築した辞書 \mathbf{D} を用いて、入力のサイノグラムに対する係数を OMP により求める。このとき学習データに現れないノイズ成分等は係数値が小さいアトムで表現されることが期待できる。このため前述の T_0 個以下のアトムしか使わないというスパース制約条件を用いるとノイズ成分を除去することが可能になる。

3. シミュレーション実験

本章では、前章で説明した提案手法を用いた画像再構成手法を、辞書学習によるノイズ除去手法のみを用いてノイズ除去を行い OS-EM 法により画像再構成する手法と TV-EM 法による画像再構成の 2 つの従来手法との性能比較をした。実験設定、定量評価手法、実験結果については各節で説明をする。

3-1. 画像データ

評価実験に用いる画像データは東京都長寿医療センター研究所から提供された 2 種類のデータを用いた。1 つ目は、HOFFMAN 3D 脳ファントム画像である [10]。Hoffman ファントムの画像例を図 3 に示す。これは通常の脳中のラジオアイソトープ分布を解剖学的に正確に 3 次元で観察することができるプラスチックモデルであり、放射線同位体を含む液体を注入し、ファントム内での液体の摂取比 4:1:0 (赤色:水色:青色) でシミュレートできる。Hoffman ファントムの観測データは高さ方向に 20 分割した画像枚数は脳を 20 分割した 20 枚である。サイノグラムと再構成画像の例を図 4 に示す。サイノ

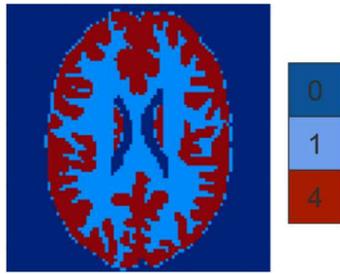
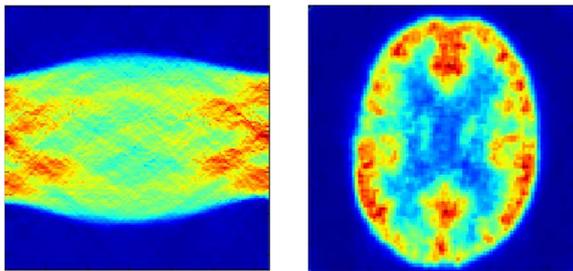


図 4 HOFFMAN 3D 脳ファントム画像の画像例



(a) サイノグラム (b) 再構成画像

図 3 サイノグラムと再構成画像の例

グラムの枚数は、1回の観測で63スライス撮像を行う観測を一定時間間隔で40回行ったため、 63×40 枚である。提案手法、従来手法による再構成はこのサイノグラムを用いて行った。この2種類の画像のサイズは共に 90×90 pixelである。

3-2. PETデータの概要

実機での観測は、1回の観測で3分間スキャンを行い、全観測が終了するまでに120分を要した。観測に使われた放射性同位体は ^{11}C であり、半減期は20.39分である。観測時の放射線量の減衰の推移を図5に示す。このように時間が経過するに連れて徐々に放射線量が減少していることがわかる。本実験では、観測から90分以上、すなわち30回目以降の観測データは放射線量の減少により極端にノイズが多くなるため、再構成を行わないものとする。

3-3. 画像再構成

本実験では、提案手法、辞書学習による画像再構成手法、TV-EM法により画像再構成を行った。提案手法ではいくつかのパラメータを決定する必要があるが、本研究では以下の値で実験を行った。ただし辞書学習においては辞書を構

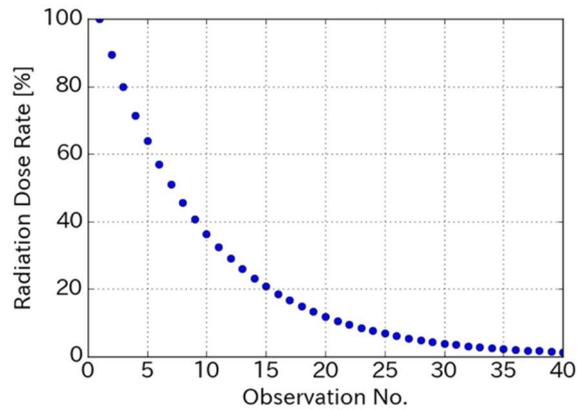


図 5 放射線量減衰の推移

成するための学習データが必要であるため、これらは、ILSVRC2012[11]で用いられた自然画像データセットをラドン変換したものを用いている。

- ①辞書のアトム数：256
- ②再構成する際に用いるアトム数 L ：20
- ③K-SVDの繰り返し回数 $iter$ ：200
- ④辞書の学習に用いるデータセット： 128×128 pixelの自然画像400枚をサイノグラムに変換したデータ $400 \times 128 = 51200$ 枚。画像例を図6に示す。
- ⑤OS-EM法のサブセット数：8

観測回1, 15, 30, スライス19, 投影角度数64, 8, EM法の繰り返し回数1, 5, 10の画像再構成結果を図7, 図8, 図9に示す。この再構成結果の定性評価を行う。投影角度数64の場合、観測回数1回では十分に観測信号が強いためどの手法でも元の脳構造を再現できていると評価できる。しかし、観測回数1回以降からは徐々にノイズが増加していき、観測回数30回にな

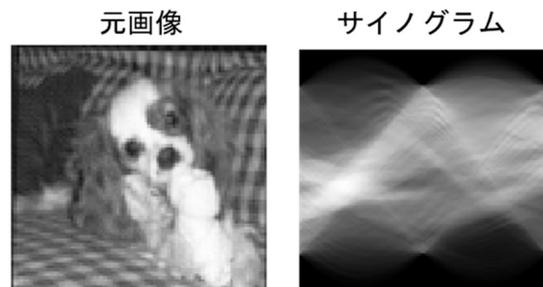


図 6 学習データの画像例

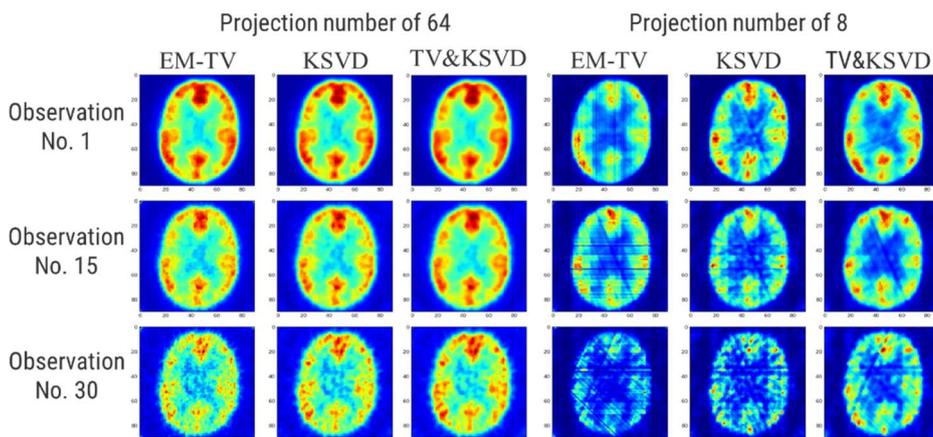


図 7 EM 法の繰り返し回数 1 回の再構成画像

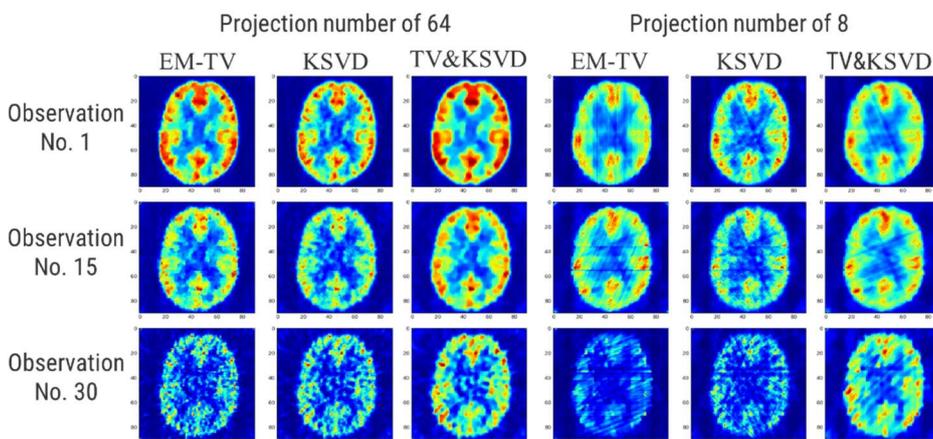


図 8 EM 法の繰り返し回数 5 回の再構成画像

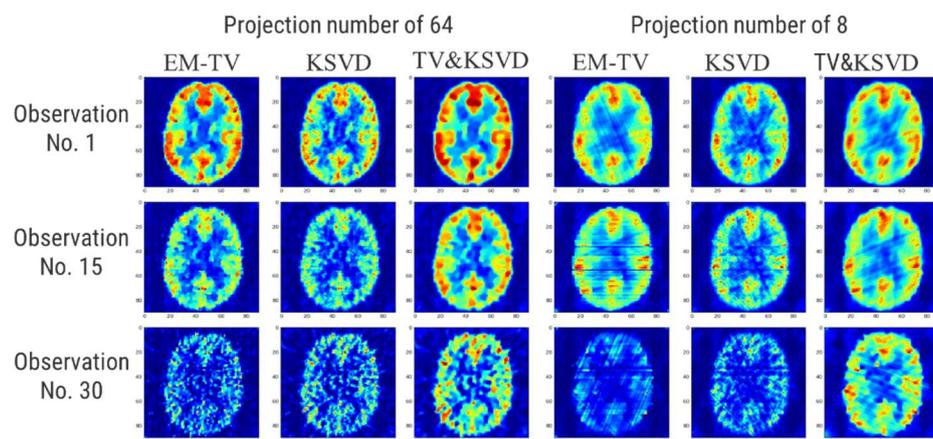


図 9 EM 法の繰り返し回数 10 回の再構成画像

ると従来手法ではノイズにより脳構造が消え、提案手法でも微かに元の脳構造がわかる程度になっていることがわかる。

投影角度数 8 の場合、観測回数 1 回から EM-

TV 法の再構成画像はノイズにより細かな脳構造が消えており、観測回数 30 回まで脳構造を保持出来ているのは僅差ではあるが提案手法のみであることがわかる。

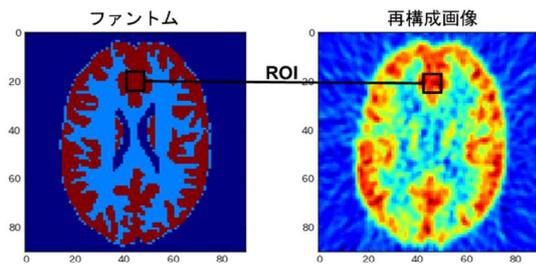


図 10 ROI の抽出場所

3-4. 定量評価

視覚的な定性評価は PET ではあまり意味を持たず、ある領域における放射線量がどれだけあり、どの程度変化したかが重要である [12]. そこで、図 10 のようにファントム内の放射線量が一樣な分布である領域から Region of Interest (ROI) と呼ばれる局所領域を抽出し、この ROI 内の画素値の時間経過による推移に着目し定量評価を行った. 具体的には、各観測回数において ROI 内の画素値の総和を計算し、総和の分散を箱ひげ図を用いて比較した. 定量評価結果を図 11, 図 12, 図 13 に示す. この定量評価では、ROI 中の分散が小さければ小さほど ROI 中の変化が少なく、放射線量の減衰に左右されない、適切に観測が表現できている手法だと考える. 定量評価結果を確認すると、各 EM 法の繰り返し回数において提案手法が他の 2 つの手法より分散を小さく出来ていることから、サイングラム表現と実画像表現の両方でのノイズ除去が従来手法と比較して有効であることがわかった. また、各 EM 法の繰り返し回数での提案手法同士の比較も行った. この結果を図 14 に示す. 投影角度数が十分にある場合、各繰り返し数で最も分散が小さかったのは 1 回の時であり、投影角度数が少ない場合、各繰り返し数で最も分散が小さかったのは 10 回の時であった. この結果から、投影角度数が十分にある場合に最適な EM 法の繰り返し回数は 1 回であり、投影角度数が少ない場合に最適な EM 法の繰り返し回数は 10 回であることがわかった.

4. まとめ

本研究では、PET スキャンにより得られたサ

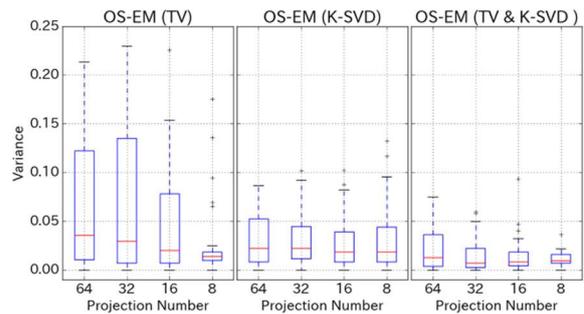


図 11 EM 法の繰り返し回数 1 回の定量評価結果

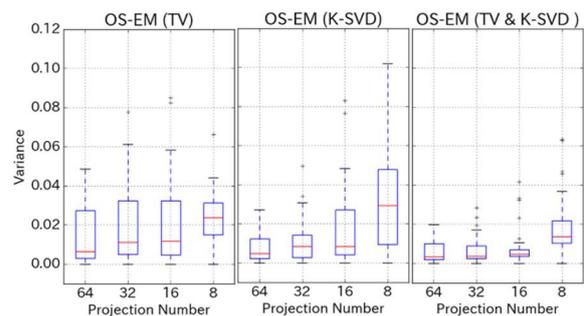


図 12 EM 法の繰り返し回数 5 回の定量評価結果

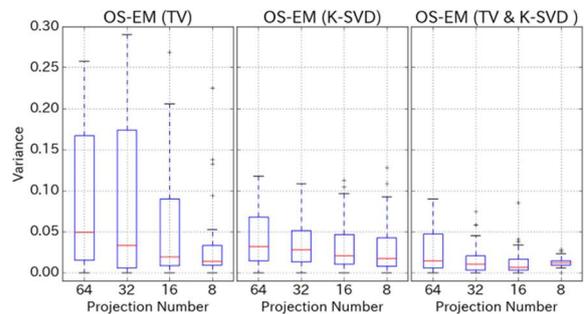


図 13 EM 法の繰り返し回数 10 回の定量評価結果

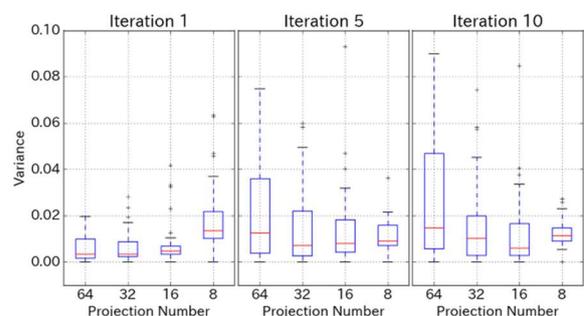


図 14 各 EM 法の繰り返し回数における提案手法の定量評価結果

イングラムに対し、辞書学習を用いたノイズ除去手法と EM-TV 法を組み合わせる手法を提案

し、これを用いて画像再構成を行うことでノイズ除去することを提案した。提案手法と従来手法との比較実験では、再構成画像に対して ROI を用いた定量評価を行い結果を比較した。結果、サイノグラム表現と実画像表現の両方でのノイズ除去が従来手法と比較して有効であること、提案手法の EM 法の繰り返し回数は投影角度数が十分にある場合 1 回、投影角度数が少ない場合 10 回の時が最も良く観測を表現できることがわかった。今後の展望として、現在辞書学習を用いて学習しているサイノグラム表現の辞書を深層学習により学習することで、更なる性能改善することを考えている。

謝辞

本研究の PET スキャンデータを提供頂いたと共に、医学的観点より多くのご助言を頂きました。東京長寿医療センター研究所の坂田氏に深く感謝申し上げますと共に本稿の結びとさせていただきます。本研究は科学研究費 基盤(C) 16K00328 の支援を受けて実施された。

利益相反の有無

なし

付録

A. ML-EM 法の導出

図 1 の関係から次のような確率モデルを考えることができる。

$$p(y_i|x_{ij}) = \delta\left(y_i - \sum_j x_{ij}\right) \quad (1)$$

$$p(y|x) = \prod_j p(y_i|x_{ij}) \quad (2)$$

ここで $\delta(\cdot)$ はクロネッカーのデルタ関数である。各セルから発生する信号 x_{ij} は母数 λ_i に基づくポアソン分布に従うものと仮定する。この母数 λ_i はセル i からの放射線に関するパラメータであり、再構成画像の画素値として扱う。

あるセルに対して、センサの幾何学的な位置によって放射線量が変動するため、 i 番目のセルから放射された放射線がどの程度 i 番目のセン

サに観測されるかを示すパラメータ c_{ij} を考える。 c_{ij} は、センサの有効範囲付近に放射される放射線の割合で決定できる。すなわち、図 1 の青い枠のような領域を考え、この中でセンサが観測する放射線を観測可能であるとする。この時、重なる領域とセルの面積との比により c_{ij} を求める。

こうした条件のもとで x_{ij} の確率分布を以下のように表現できる。

$$p(x_{ij}|\lambda_i; c_{ij}) = \frac{(c_{ij}\lambda_i)^{x_{ij}}}{x_{ij}!} \exp(-c_{ij}\lambda_i) \quad (3)$$

以上のモデルを用いて、観測データ列 $\{y_j\}$ からパラメータ λ_i を推定することで再構成画像が得られる。本研究で取り扱う Shepp & Logan の観測モデルの場合、観測データ列 $\{y_j\}$ 、未知のパラメータ列 $\{\lambda_i\}$ 、 i 番目のセルから、 j 番目のセンサに観測される信号 x_{ij} を考える必要がある。このとき y_j は式 2 より、複数のセルからの放射線 x_{ij} の和となる。しかし、 x_{ij} は実際には観測されておらず、最尤推定の際に隠れ変数 x_{ij} を含むこととなる。この時、 $\{y_j\}$ のみで構成される観測データを不完全データ、 $\{y_j, x_{ij}\}$ で構成される観測データを完全データと呼ぶ。

Shepp & Logan の観測モデルでは、不完全データからの推定問題と捉えることができるため、対数尤度関数は以下のように考えることができる。

$$L(\{\lambda_i\}) = \log p(\{y_j\}, \{x_{ij}\}; \{\lambda_i\}) \quad (4)$$

この対数尤度関数を解くには、隠れ変数 $\{x_{ij}\}$ を含む最尤推定を行う必要があるが、尤度関数が複雑化し閉じた解を与えることができない。そのためより効率的な推定法として EM 法 (Expectation Maximization) [5] を用いて解を導くことを考える。EM 法は隠れ変数を持つモデルのパラメータの最尤推定値を求めるための推定法である。この手法は、 Q 関数と呼ばれる完全データの対数尤度の条件付き期待値を求める E-step と、 Q 関数が最大となるパラメータを求める M-step を交互に繰り返すアルゴリズムである。

ここで、断層画像に ML-EM 法を適用するこ

とを考える。まず E-step で、求める Q 関数を Q_{ML} として、完全データの条件付き対数尤度の期待値を求める。

$$Q_{ML}(\lambda|\lambda^t) = E_{x;\lambda^{(t)}}[\log p(\mathbf{y}, \mathbf{x}; \lambda)] \quad (5)$$

この時、平均をとる確率分布を得るには λ を決定しておく必要がある。そのため、ここでは適当な値 λ^t を用いる。最終的に Q 関数は次式のように求まる。

$$Q_{ML}(\lambda|\lambda^t) = \sum_j \sum_i \log \lambda_i \frac{y_j c_{ij} \lambda_i^t}{\sum_l c_{jl} \lambda_l^t} - \sum_j \sum_i c_{ij} \lambda_i + \text{const} \quad (6)$$

ここで、const は λ に関わらない定数項である。次に M-step で、 Q 関数の最大化を考える。これは、 λ に関して Q 関数を微分し、値が 0 になる場合を求めることで与えられる。

$$\frac{\partial Q_{ML}(\lambda|\lambda^t)}{\partial \lambda_i} = \frac{1}{\lambda_i} \sum_j \frac{y_j c_{ij} \lambda_i^t}{\sum_l c_{jl} \lambda_l^t} - \sum_j c_{ij} \quad (7)$$

最大値であるための十分条件は

$$\frac{\partial Q_{ML}(\lambda|\lambda^t)}{\partial \lambda_i} = 0 \quad (8)$$

であればよいので、 λ_i の更新式は式(9)のように求まる。

文 献

- [1] L.A.Shepp, Y.Vardi: Maximum Likelihood Reconstruction for Emission Tomography. IEEE Transactions on Medical Imaging **1**: 113-122, 1982
- [2] Hudson HM: Accelerated image reconstruction using ordered subsets of projection data. IEEE Transactions on Medical Imaging **13**: 601-609, 1994
- [3] M.Ahron, M.Elad: Image denoising via sparse and redundant representations over learned dictionaries. IEEE Transactions on Image Processing **15**: 3736-3745, 2006
- [4] L.A.Shepp, B.F.Logan: The Fourier reconstruction of a head section. IEEE Transactions on Image Processing **21**: 21-43, 1974
- [5] A.P.Dempster, N.M.Laird D.B.Rubin: Maximum likelihood from incomplete data via the EM algorithm. Journal of the Royal Statistical Society Series B **39**: 1-38, 1977
- [6] 山本翔, 庄野逸: ベイズアプローチに基づいた断層画像の再構成, MPS 2009 **76-36**: 1-6, 2009
- [7] V.Y. Panin, G.L. Zeng, G.T. Gullberg: Total variation regulated EM algorithm. IEEE Transactions on Nuclear Science **46**: 2202-2210, 1999
- [8] M.Aharon, M.Elad: K-SVD: An Algorithm for Designing Overcomplete Dictionaries for Sparse Representation. IEEE Transactions on Signal Processing **53**: 4311-4322, 2006
- [9] Y.C.Pati, R.Rezaiifar P.S.Krishnaprasad: Orthogonal matching pursuit: recursive function approximation with applications to wavelet decomposition. Proceedings of 27th Asilomar Conference on Signals, Systems and Computers : 40-44, 1993
- [10] E.J.Hoffman: 3-D phantom to simulate cerebral blood flow and metabolic images for PET. IEEE Transactions on Nuclear Science **37**: 616-620, 1990
- [11] Olga Russakovsky, Jia Deng, Hao Su, et al.: ImageNet Large Scale Visual Recognition Challenge. International Journal of Computer Vision **115**:211-252,2015
- [12] Nodoka Iida, Hayaru Shouno: Quantitative Evaluation of Reconstructed Image with Filtered Back Projection Bayes Method. PDPTA 2015 **1**: 324-329, 2015

Ordered Subsets EM algorithm for PET Image Reconstruction by use of Dictionary Learning and TV regularization

Naohiro Okumura^{*1}, Hayaru Shouno^{*1}

^{*1} The University of Electro-Communications

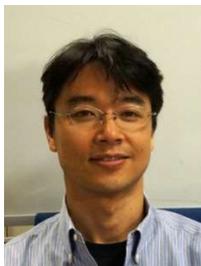
Nowadays, Positron Emission Tomography (PET) scan is focused in the field of pathological diagnosis. In order to obtain a clear image in the PET scan, it is necessary to increase the S/N ratio, which leads to an increase in exposure dose at the time of observation. For this reason, it is desired to increase the S/N ratio of the image while suppressing the exposure dose. In this research, we applied a method combining two noise reduction methods to this problem. First, we used a noise reduction method using dictionary learning for the sinogram representation. The second used a noise reduction method for the real image representation based on the regularization approach. As a result, it was found that an approach combining two noise reduction methods is more effective than the conventional method.

Key words: PET image reconstruction, Sparse modeling, Dictionary learning, K-SVD

著者紹介



奥村 直裕 (おくむら なおひろ)
2018年津山工業高等専門学校専攻科・電子・情報システム工学専攻卒。現在、電気通信大学博士課程前期課程。これまでに自己組織化マップの深層化、PET画像のノイズ除去などに関する研究に従事。



庄野 逸 (しょうの はやる)
1992年大阪大・基礎工学部・生物工学科卒。1994年同大学院博士前期課程修了。現在、電気通信大学 情報理工学 研究科・教授。工博。画像処理などを応用先とした機械学習、ニューラルネットワークに関する研究に従事。IEEE, 電子情報通信学会, 情報処理学会, 物理学会, 神経回路学会, 各会員。

拡散尖度撮像法のパラメタ推定のための生成型 Q 空間学習 における最適雑音量の自動決定に向けて

内濱 良介^{*1} 河野 智奈美^{*1} 佐々木 公^{*1,*2} 増谷 佳孝^{*1}

要旨

我々は、深層ニューラルネットワークの学習に合成データのみを用いる生成型 Q 空間学習による拡散 MRI パラメタ推定の研究を行っている。これまでに学習用の合成データと推定対象のデータの雑音量が同等の場合、最も頑健な推定が可能であることが実験により示唆されているが、実画像の雑音量を測定することは容易ではない。そこで本研究では、拡散尖度撮像法(DKI)のパラメタ推定を例として、与えられた実画像に対して最適な雑音量の学習データを決定するための方法を検討したので報告する。

キーワード: Q 空間学習, 拡散尖度, 深層学習, 雑音量

1. はじめに

生体内水分子の拡散を定量化する拡散 MRI では、様々な信号値モデルに含まれるパラメタの推定によって、対象部位の局所の構造、性質等の情報が得られる。本研究では、拡散の非ガウス性を定量評価できるモデルである拡散尖度撮像法(Diffusional Kurtosis Imaging: DKI)を対象とする。DKI はパラメタとして拡散係数 D および拡散の非ガウス性特徴である拡散尖度 K を持つ。パラメタ推定は最小二乗法によるフィッティング(Least squares fitting: LSF)が主流であるが、機械学習でパラメタを推定する Q 空間学習が提案されている[1]。また、学習を合成データのみで行う生成型 Q 空間学習がある[2]。我々

は、生成型 Q 空間学習によるパラメタ推定のための深層ニューラルネットワーク(Deep Neural Network: DNN)の研究を行ってきた。これまでに学習用の合成データと推定対象の実画像の雑音量が同等の場合、最も頑健な推定が可能であることが実験により示唆されている[2]。しかし、実画像の雑音量を測定することは容易ではない。そこで本研究では、DKI のパラメタ推定を例として、与えられた実画像に対して最適な雑音量の学習データを決定するための方法を検討したので報告する。具体的には、生体領域と空気領域の信号値の統計、推定値分布の LSF との比較である。

2. 方法

1) 使用した DKI データ

推定対象の実画像として、3 名の正常ボランティアの脳 DKI 画像を広島平和クリニックにて撮影した(倫理委員会承認済)。撮像条件は、ボクセルサイズが $2\text{mm} \times 2\text{mm} \times 2\text{mm}$ 、マトリックスサイズ $256 \times 256 \times 70$ 、MPG の印加方向が $(0,1,0)$ 、 b 値が 0, 311, 1244, 2800(s/mm^2)、信号加算回数 (nex) 1~4 の 4 種である。

*1 広島市立大学大学院情報科学研究科
医用情報科学専攻 [〒731-3166 広島市安
佐南区大塚東 3-4-1]

e-mail: uchihama@medimg.info.hiroshima-cu.ac.jp

*2 広島平和クリニック [〒730-0856 広
島県広島市中区川原町 1-31]

2) 生成型 Q 空間学習

以下の範囲で学習データを生成した.

- 基準信号値 S_0 : 500~8000
- 拡散係数 D : $0.2 \sim 6.0 \times 10^{-3} (mm^2/s)$
- 拡散尖度 K : 0.0~2.0
- 拘束条件 $D \cdot K$: $\leq 2.0 \times 10^{-3}$

これらに基づき、実画像データと同じ $b=311$, 1244, 2800 (s/mm^2)での信号値の組を信号値モデルの式に基づき 10^5 サンプル発生させ、各信号値にライス分布雑音を付加した。雑音の標準偏差の S_0 に対する割合を学習ノイズ比とし、0.0, 0.1, 0.2, 0.3, 0.4, 0.5 の 6 種類とした。学習は異なる初期値で 10 回行った。

3) 空気領域と生体領域の信号比

大津の閾値処理法[3]を複数回適用して生体領域と空気領域の分離を行った。この閾値処理により分離した生体領域と空気領域の平均信号値の比 R を各データに対して得た。

4) 推定値の分布および推定エラー

LSF および 6 種の学習ノイズ比の DNN により D と K の推定を行い、分布のピークを観察した。また、推定値が負となったボクセル数の脳領域全体に対する割合をエラー率として求めた。

3. 結果

大津の閾値処理法を 4 回適用した結果が生体領域と空気領域の分離に適していた。 R は nex の増加とともに増加する傾向が見られた。

推定値の分布のピークを比較すると、学習ノイズ比の上昇に伴い拡散係数 D では LSF より高い値に、拡散尖度 K では低い値にシフトした。また、図 1 および 2 に被験者 1 のエラー率の結果を示す。DNN による D の推定のエラー率は LSF より低く、ノイズ比 0.0 で最も低かった。また、 K でも LSF よりエラー率が低く、ノイズ比 0.5 において最もエラー率が低かった。

4. まとめ

MRI 画像に含まれるノイズ量の直接の測定は困難であるが、本研究で求めた空気領域と生体領域の信号値比および最小二乗法との推定値

分布のピーク差が、最適な学習ノイズ量を決定に寄与することが示唆された。

謝辞:データの取得にご協力頂いた広島平和クリニックの皆様へ感謝致します。

利益相反の有無：なし

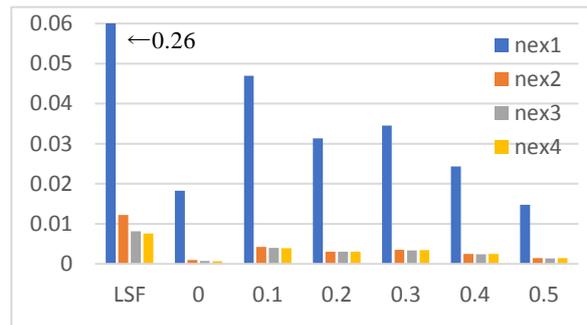


図 1 拡散係数 D におけるエラー率 (縦軸:%)

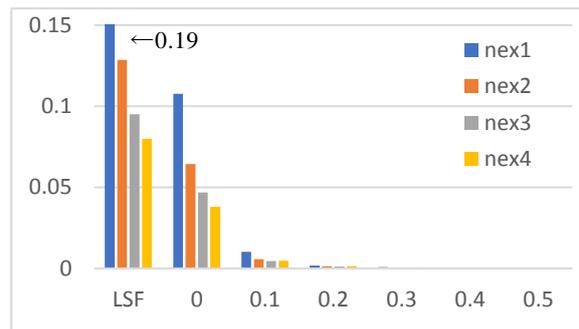


図 2 拡散尖度 K におけるエラー率 (縦軸:%)

文 献

- [1] V. Golkov, et al. q-Space Deep Learning: Twelve-Fold Shorter and Model-Free Diffusion MRI Scans, IEEE Trans. Med. Img., vol.35, no.5, pp1344-1350 (2016)
- [2] Y. Masutani, Noise Level Matching Improves Robustness of Diffusion MRI Parameter Inference by Synthetic Q-Space Learning, proc. ISBI 2019, April. (2019)
- [3] N. Otsu, A threshold selection method from gray-level histograms, IEEE Trans. Sys. Man. Cyber, vol.9, no.1, pp.62-66 (1979)

Toward Automatic Determination of Optimal Noise Level in Synthetic Q-Space Learning for DKI Parameter Inference

RYOUSUKE UCHIHAMA^{*1}, CHIINAMI KAWANO^{*1}, KOU SASAKI^{*1, *2}, YOSHITAKA MASUTANI^{*1}

^{*1} Hiroshima City University

^{*2} Hiroshima Heiwa Clinic

We have been studying on synthetic Q-space learning for diffusion MRI parameter inference. So far, it was revealed that noise level matching between training data and test data brings most robust inference results. However, it is not simple to estimate noise level in clinical MRI data. In this study, we examined several methods for determination of the optimal noise level for DKI parameter inference by Q-space learning.

Key words: Q-space learning, diffusional kurtosis, deep learning, noise level

著者紹介

内濱 良介 (うちはま りょうすけ)
2019年広島市立大学情報科学部医用情報科学科卒。同大学院博士前期課程在学。日本医用画像工学会学生会員。

河野 千奈美 (かわの ちなみ)
2019年広島市立大学情報科学部医用情報科学科卒。

佐々木 公 (ささき こう)
2018年広島市立大学大学院情報科学研究科博士前期課程修了。同後期課程在学。広島平和クリニックにて診療放射線技師として勤務。

増谷 佳孝 (ますたに よしたか)
1991年東大・工・精密機械工学科卒。
1994年同大学院・工学系・精密機械工学専攻修士課程, 1997年同博士課程了。
ハンプルク大医用数学・情報処理研究所, シカゴ大病院放射線科, 東大病院放射線科などを経て2018年現在, 広島市立大学大学院医用情報科学専攻・教授。
2003年日本医用画像工学会論文賞および奨励賞受賞。博士(工学)・博士(医学)。拡散MRIを中心とした多次元の医用画像解析の研究に従事。医用画像工学会, 電子情報通信学会, 磁気共鳴医学会, IEEE など, 各会員。

カラー腹腔鏡画像診断のためのコントラスト強調と SRCNN 超解像処理の最適条件に関する考察

河畑 則文*¹ 中口 俊哉*²

要旨

医用画像診断におけるコントラスト処理は、各部位の領域を強調させ、異常が無いかを分類・認識することを目的としている。これらの処理の多くは、コントラスト強調に加えて、超解像処理を用いて画像解像度を上げてから分類・認識することで精度が上がるとされる。一方で、医用画像分野における深層学習の普及により、超解像処理においても精度が上がってきたが、多種多様なパラメータが存在し、それらの調整によっては十分な性能が発揮されるとは限らないことがある。そのため、どのパラメータをどのように調整すればよいかを実験により検証し、実用化する必要がある。そこで、本研究では、カラー腹腔鏡画像のコントラスト強調と超解像処理の関係について、超解像に特化した深層畳み込みニューラルネットワークである SRCNN に基づいた waifu2x-caffe (UpResNet10) で実験を行い、最終的に PSNR を測定し、どの程度、精度よく画像が生成できているのかを検証した。

キーワード：腹腔鏡画像、コントラスト強調、超解像、waifu2x-caffe, Super-Resolution Convolution Neural Network (SRCNN)

1. まえがき

医用画像工学分野において、従来から、各部位の領域を強調させるコントラスト強調は画像診断技術における重要な要素の一つである。画像のコントラストを強調することで、病変部位の画像分類や異常がないかどうかといった画像認識に関する処理能力や精度向上を目的としている。一方で、近年の急速なコンピュータシステムの演算処理技術の向上により、医用画像工学研究においても積極的に深層学習が導入可能になっている。このような背景から、本研究では、医用画像におけるコントラスト強調について考える。

我々は今までに、腹腔鏡画像における符号化欠損情報の自動検出を想定した医用画像診断の検討として、客観評価法である PSNR (Peak

Signal to Noise Ratio) [1]-[5], サポートベクターマシン (Support Vector Machine: SVM)[1]-[4] による分類, S-CIELAB 色空間を用いて、輝度値、色差値を測定することで、色情報解析を行い、相互に医用画像診断に応用可能かどうかを検討してきた [1]。確かに、色情報(輝度や色差)に関しては一定の知見が得られたが、色情報と関係のあるコントラスト強調と超解像に関する議論まではしていなかった。コントラスト強調の処理を行うにあたっては、色情報は勿論のこと、画面解像度も関係してくるし、それにより、強調後の画像の内容も変わってくるが多く、今まで明らかでなかった知見が得られることも多い。また、我々が利用している腹腔鏡画像を処理する際に、深層学習を導入していなかった。確かに、非医用画像に対しては、著者の先行研究で検証したことがあるが [5], 医用画像でも同じ傾向が出るとは限らないし、どの程度、深層学習が有効であるかについて、本研究では検証したいと考える。

本研究では、カラー腹腔鏡画像において、コントラスト強調と超解像処理の関係について、SRCNN に基づいた waifu2x-caffe (UpResNet10) [6] を用いることで、最終的に PSNR を測定し、画質とコントラスト、超解像処理、深層学習の

*1 東京理科大学理工学部情報科学科
[〒278-8510 千葉県野田市山崎 2641]
e-mail: norifumi@rs.tus.ac.jp

*2 千葉大学フロンティア医工学センター
[〒263-8522 千葉県千葉市稲毛区弥生町 1-33]
e-mail: nakaguchi@faculty.chiba-u.jp

投稿受付：2019年5月22日

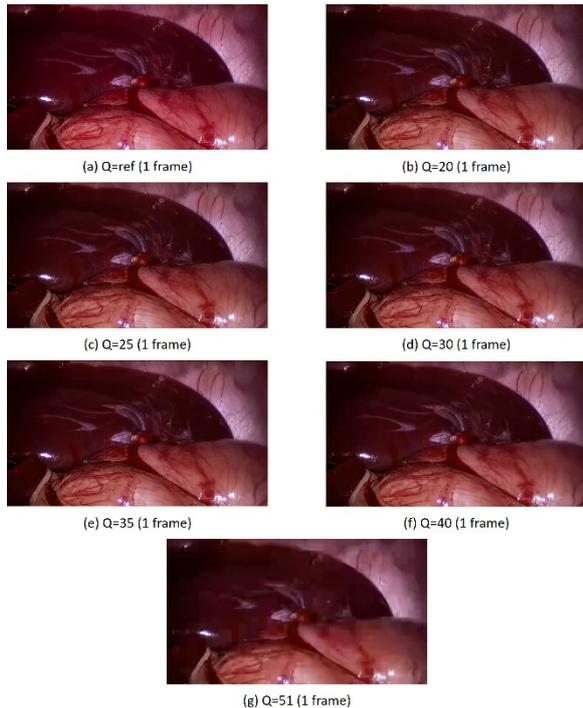


図 1: 本研究で使用した腹腔鏡カラー画像
(コントラスト強調前)

観点から客観的な実験を行い、画像診断に応用できるかどうか考察を行った。

2. 関連研究

関連研究として、以下の3点に着目できる。

- (a). 適応ヒストグラム均等法によるコントラスト強調に関する研究 [7]-[12]
- (b). 医用画像におけるコントラスト強調に関する研究 [13]-[14]
- (c). 画質の観点からのコントラスト強調または超解像処理に関する研究 [15]-[20]

(a)では、本研究で扱う Adaptive Histogram Equalization (AHE) に関するアルゴリズムや手法に着目して研究がなされている。

(b)では、医用画像に関するコントラスト強調の研究がされており、主に、顕微鏡画像検査や熱音響断層撮影の例が挙げられている。

(c)では、人間視覚システムを考慮したコントラストの測定や画質評価に関する研究が多い。超解像処理を扱うものでは、超解像処理手

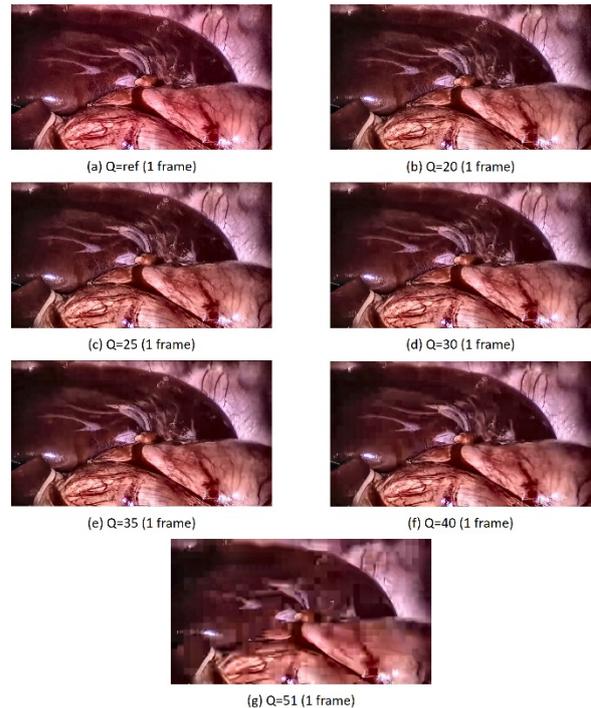


図 2: 本研究で使用した腹腔鏡カラー画像
(コントラスト強調後, AHE=1 の場合)

法を提案して、従来手法と比較して、その後、画質評価や画質改善を行うものが多い。画像処理分野から深層学習分野へのアプローチもあるが、深層学習分野から画像処理分野へのアプローチも増えてきている。

本研究では、関連研究とは異なり、(a)-(c)の全ての内容を網羅しているため、その点において新規性があり、コントラスト強調、超解像、深層学習の関係に関して、研究及び検証する価値があると考えた。

3. コントラスト強調と超解像処理

3.1. 本研究で使用した医用画像

本研究で使用した医用画像は、図 1 に示すように、内視鏡により取得した、肝臓と胃の周辺を撮影した腹腔鏡下手術動画画像 (約 15 秒間) をフレーム画像として切り出したものである。図 2 は、次節で説明する適応ヒストグラム均等法 (Adaptive Histogram Equalization: AHE) を用いてコントラスト強調を行った例である。使用した動画画像は特定の治療行為は行っていない。

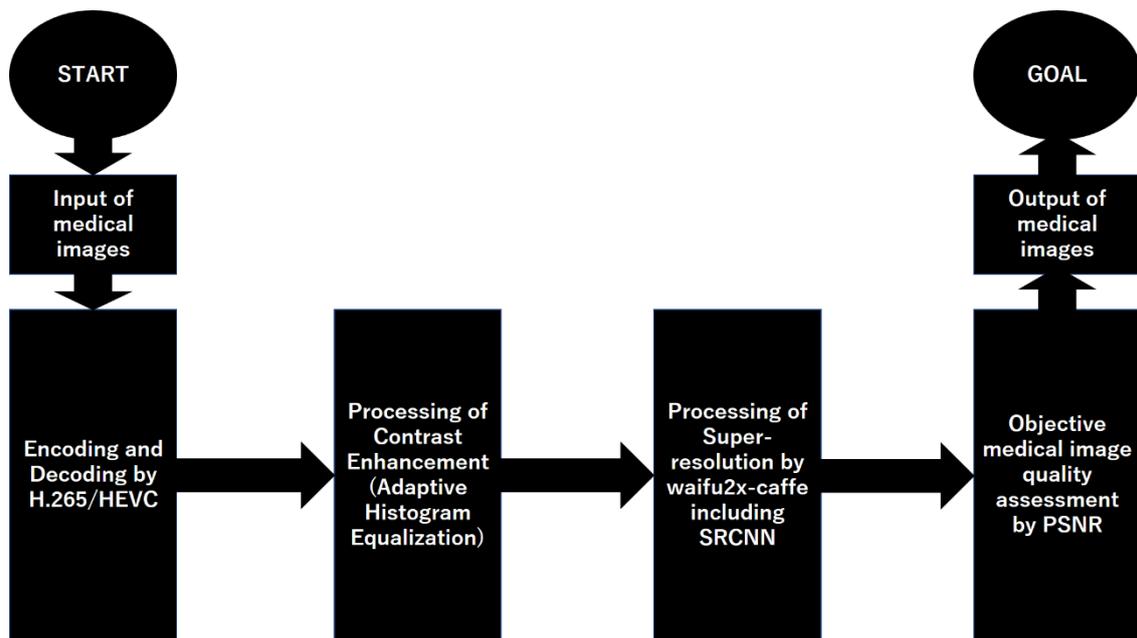


図 3: 医用画像の入力から出力までのフローチャート

3.2. 実験手順

実験手順を図 3 に示す。以下に、本研究の実験手順を(a)-(f)の順に説明していく。

- (a). まず、腹腔鏡下手術動画画像（以下、腹腔鏡静止画像または動画画像）をフレーム静止画像として切り出し処理を行う。本研究では、全部で 426 枚を切り出した。
- (b). 次に、フレーム静止画像として切り出した 426 枚の腹腔鏡画像に対して、約 71 枚間隔で 7 枚のフレーム静止画像を選択する。
- (c). 7 枚のフレーム画像に対して、画像全体に、H.265/HEVC 符号化を行う [21]。量子化パラメータ (Quantization Parameter: $Q = ref, 20, 25, 30, 35, 40, 51$) を 7 通り設定して符号化処理を行う。
- (d). HEVC 符号化画像に対して、コントラスト強調を行う。本研究では、適応ヒストグラム均等法 (Adaptive Histogram Equalization (AHE))というコントラスト強調手法を用いて、 $L = ref, 0.25, 0.5, 1, 2, 4$ の 6 段階に設定して強調処理を行う。
- (e). コントラスト強調後、超解像処理を行う。動画画像からフレーム静止画像として切り出した画像は 1280×720 (pixels)であるが、

本実験では、 1920×1080 (pixels)に超解像処理を行う。超解像手法としては、機械学習を用いて人工知能で予測、復元させる画像拡大ツール waifu2x-caffe を用いる。特に、ツールの中で UpResNet10 (Up Residual Network 10: 残差ネットワーク, Residual Learning と呼ぶ) と呼ばれる深層学習手法を用いて拡大処理を行う。拡大処理の時間であるが、我々の実行環境 (Windows 10 Pro, Intel(R) Core(TM) i7-4770 CPU @ 3.40GHz, NVIDIA GeForce GT 635)では、全パターン (294 通り) を処理するのに、約 2 時間かかった。

- (f). カラー腹腔鏡フレーム静止画像の原画像と評価画像に対して、PSNR (Peak Signal to Noise Ratio)を用いることにより、符号化画質を客観的に評定する。評価方法としては、客観評価指標 PSNR (Peak Signal to Noise Ratio)を用いた。PSNR はあるデータが元データからその程度劣化したかを表す指標である。値が大きいほど劣化は小さく、値が小さいほど激しい劣化になる。元画像 I_{orig} , 評価画像 I_{code} とするとき、2つの画像の PSNR は次の式 (1) (Mean Squared

Error: MSE), (2) (PSNR)のように表される.

$$\text{MSE} = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} (I_{orig}[i,j] - I_{code}[i,j])^2 \quad (1)$$

$$\text{PSNR} = 10 \log_{10} \left(\frac{\text{MAX}^2}{\text{MSE}} \right) \quad (2)$$

3.3. 実験方法と評価方法

実験方法としては、本研究では、コンピュータによる客観評価を主としているため、ヒトによる主観評価実験は考慮していない。実験の主な仕様としては、コンピュータの動作環境 (Windows 10 Pro, MATLAB R2016a), 画像の画面解像度 (1280×720 (動画像から切り出した基準の画像)), 1920 × 1080 (waifu2x-caffe (UpResNet10)を用いて超解像した画像)である。評価方法としては、原画像と符号化画像に対し、PSNR を計算し、287 通りについて分析した。

4. 実験結果

カラー腹腔鏡フレーム静止画像をコントラスト強調した画像の PSNR を表した棒グラフを図 4~9 に示す。また、コントラスト強調した画像に waifu2x-caffe による超解像処理をした画像の PSNR を表した棒グラフを図 10~15 に示す。ここで、図 4~15 の縦軸は PSNR, 横軸は AHE における L (Luminosity)とフレーム番号である。また、図 16, 17 は各々コントラスト強調後と超解像処理後の全体の PSNR を示している。そして、図 18~23 はコントラスト強調後の画像の PSNR と超解像処理後の画像の PSNR の差分(絶対値)を表している。

4.1. コントラスト強調後の腹腔鏡画像

図 4~9 の結果から、AHE の値が(1) ref, (2) 0.25, 0.5, (3) 0.1, 0.2, 0.4 とで PSNR の変動に違いが見られた。フレーム間においては、AHE が ref の場合ではほぼ差は見られないが、ref 以外の場合ではフレーム間で特徴が見られた。

4.2. waifu2x-caffe 超解像処理後の腹腔鏡画像

図 10~15 の結果から、超解像処理後の PSNR は処理前と比較して、PSNR の値がやや下がるものの、誤差に近い程度に抑えられており、waifu2x-caffe (UpResNet10)による超解像処理は有効であると考えられる。

5. 考察

実験結果から、コントラスト強調の場合、Q のパラメータ変動のみが PSNR に影響しているわけではないことがわかる。これは、画像強調を行うことにより、輝度の増減が発生し、強調前には明らかでなかった部位の表示が可能になった、あるいは、明らかであった部位の表示が明らかでなくなったことで、通常、Q が低くなれば、PSNR が高い傾向にあるが、そうとは限らなくなったのではないかと考えられる。

6. まとめ

本研究では、カラー腹腔鏡画像診断のための腹腔鏡画像のコントラスト強調と超解像処理の関係について、深層学習を導入することにより、実験を行い、考察を行った。

本研究の結果から、コントラスト強調のパラメータ L が(1) ref, (2) 0.25, 0.5, (3) 1, 2, 4 とで PSNR の値の傾向の違いが見られた。Waifu2x-caffe による超解像処理に関しては、処理前と比べて PSNR は誤差に近い程度であり、拡大処理が問題無く実行されていることが確認できた。図 24 から、コントラスト強調処理画像では、L=0.5, 1 の時に、超解像処理前後の差が見られたので、コントラスト強調と超解像に関する関係が見られた。

今後の展望としては、画像を高品質に提示するために、画質改善手法や深層学習のパラメータを工夫することにより医用画像における最適な画像提示方法について考慮していく。

謝辞

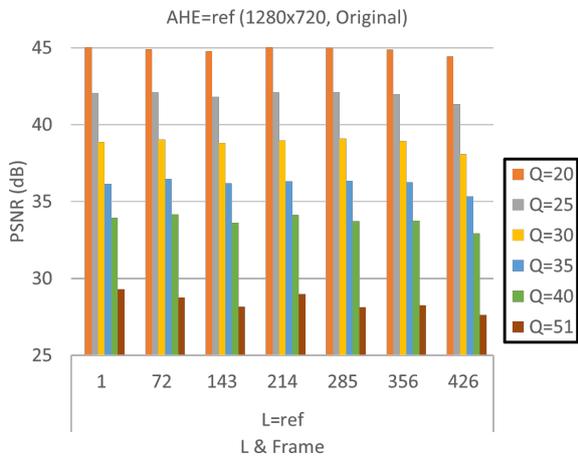
本研究は、千葉大学フロンティア医工学センターの協力の下で実施されたので、感謝する。

利益相反の有無

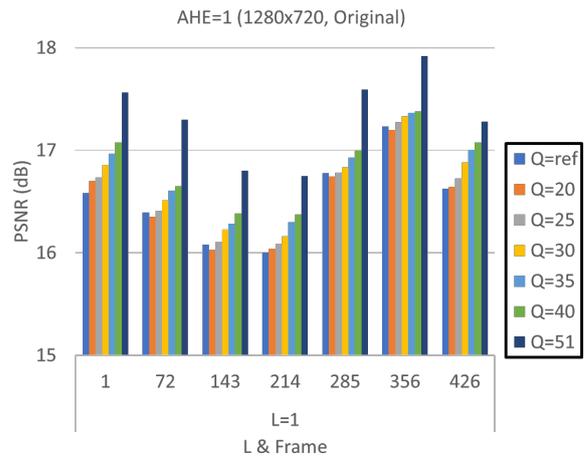
本研究における利益相反は無い。

文 献

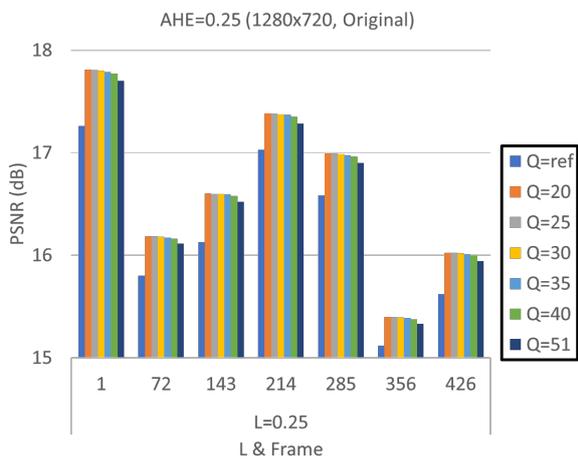
- [1]. 河畑則文, 中口俊哉: “画像領域別のテクスチャ解析に基づく腹腔鏡画像の領域分割に関する基礎検討”, 映情学技報, vol.43, no.5, ME2019-37, pp.125--130, 2019年2月.
- [2]. 河畑則文, 中口俊哉: “画像領域別のテクスチャ解析に基づく腹腔鏡画像の医用画像診断への応用”, 日本コンピュータ外科学会誌, vol.20, no.4, pp.366--367, 2018年11月.
- [3]. 河畑則文, 中口俊哉: “符号化欠損領域の自動検出を想定した腹腔鏡画像の色情報解析と医用画像診断における改善と効率的な分類器パラメータの適用”, 信学技報, vol.118, no.286, MI2018-42, pp.21--26, 2018年11月.
- [4]. N. Kawabata: “Image Diagnosis for Coded Defect Detection on Multi-view 3D Images,” *Proc. of The Ninth International Workshop on Image Media Quality and its Applications (IMQA2018)*, PS-10, pp.110--119, September 2018.
- [5]. N. Kawabata: “HEVC Image Quality Assessment of the Multi-view and Super-resolution Images Based on CNN,” *Proc. of 2018 IEEE 7th Global Conference on Consumer Electronics (GCCE 2018)*, POS1A-3, pp.38--39, October 2018.
- [6]. waifu2x-caffe:
<https://github.com/lltcggie/waifu2x-caffe/releases>, accessed May 22, 2019.
- [7]. G. Park, H. Chuo, and M. Choi: “A Contrast Enhancement Method using Dynamic Range Separate Histogram Equalization,” *IEEE Trans. on Consumer Electronics*, Vol.54, No.4, November 2008.
- [8]. T. Kim and J. Paik: “Adaptive Contrast Enhancement Using Gain-Controllable Clipped Histogram Equalization,” *IEEE Trans. on Consumer Electronics*, Vol.54, No.4, pp.1803--1810, November 2008.
- [9]. K. Gu, X. Yang, and W. Zhang et al.: “Automatic Contrast Enhancement Technology With Saliency Preservation,” *IEEE Trans. on Circuits and Systems for Video Technology*, Vol.25, No.9, pp.1480--1494, September 2015.
- [10]. W. Ke, C. Chen, and C. Chiu: “BiTA/SWCE: Image Enhancement with Bilateral Tone Adjustment and Saliency Weighted Contrast Enhancement,” *IEEE Trans. on Circuits and Systems for Video Technology*, Vol.21, No.3, March 2011.
- [11]. C. Sun, S. Ruan, M. Shie et al.: “Dynamic Contrast Enhancement based on Histogram Specification,” *IEEE Trans. on Consumer Electronics*, Vol.51, No.4, pp.1300--1305, November 2005.
- [12]. J. Shin and R. Park: “Histogram-Based Locality-Preserving Contrast Enhancement,” *IEEE Signal Processing Letters*, vol.22, no.9, pp.1293--1296, September 2015.
- [13]. J. Song, Z. Zhao, J. Wang et al.: “Evaluation of Contrast Enhancement by Carbon Nanotubes for Microwave-Induced Thermoacoustic Tomography,” *IEEE Trans. on Biomedical Engineering*, vol.62, no.3, pp.930--938, March 2015.
- [14]. S. Cakir, D. C. Kahraman, R. Centin-Atalay et al.: “Contrast Enhancement of Microscopy Images Using Image Phase Information,” *IEEE Access*, vol.6, pp.3839--3850, January 2018.
- [15]. K. A. Panetta, E. J. Wharton, and S. S. Agaian: “Human Visual System-Based Image Enhancement and Logarithmic Contrast Measure,” *IEEE Trans. on Systems, Man, and Cybernetics—Part B: Cybernetics*, vol.38, no.1, pp.174--188, February 2008.
- [16]. W. Kao, J. Ye, and M. Chu et al.: “Image Quality Improvement for Electrophoretic Displays by Combining Contrast Enhancement and Halftoning Techniques,” *IEEE Trans. on Consumer Electronics*, Vol.55, No.1, February 2009.



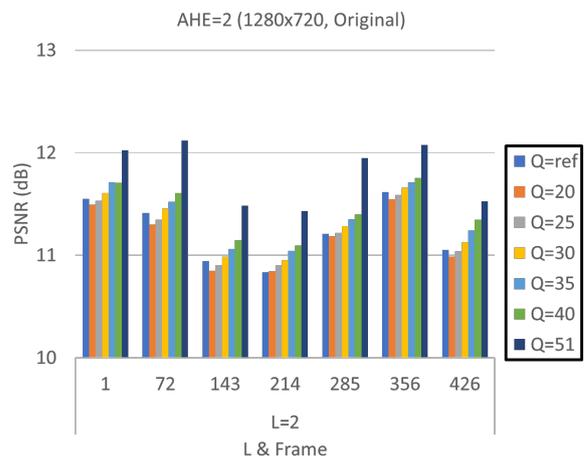
☒ 4: AHE=ref (1280x720, Original)



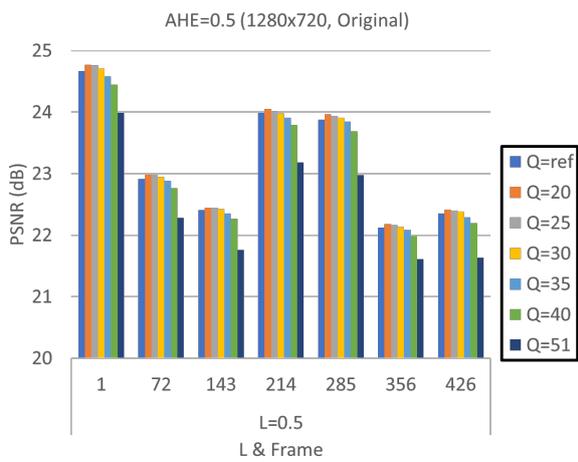
☒ 7: AHE=1 (1280x720, Original)



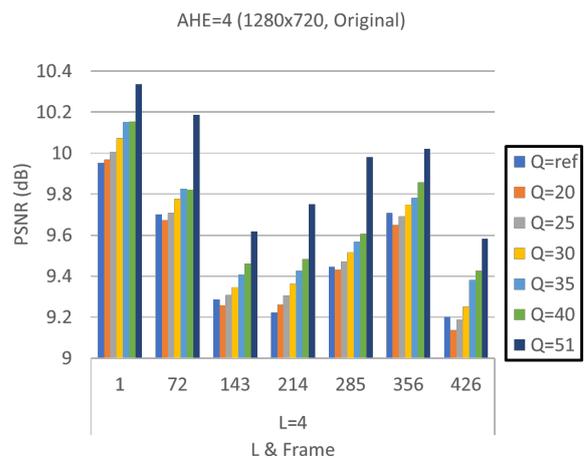
☒ 5: AHE=0.25 (1280x720, Original)



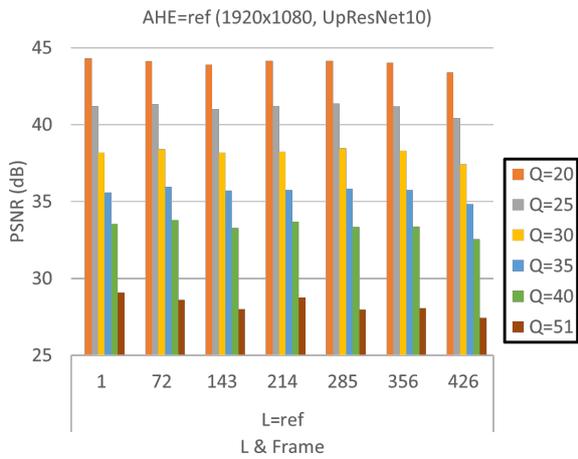
☒ 8: AHE=2 (1280x720, Original)



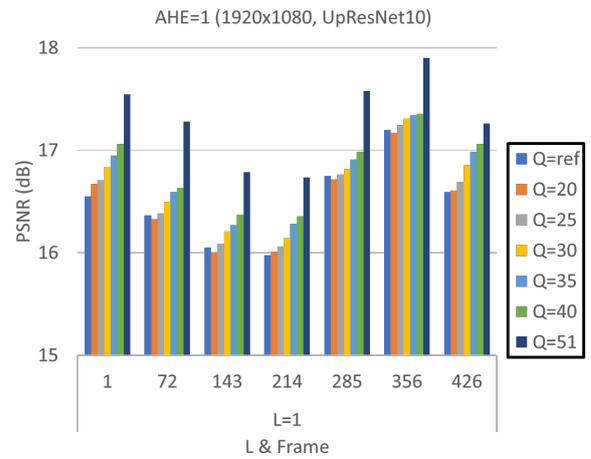
☒ 6: AHE=0.5 (1280x720, Original)



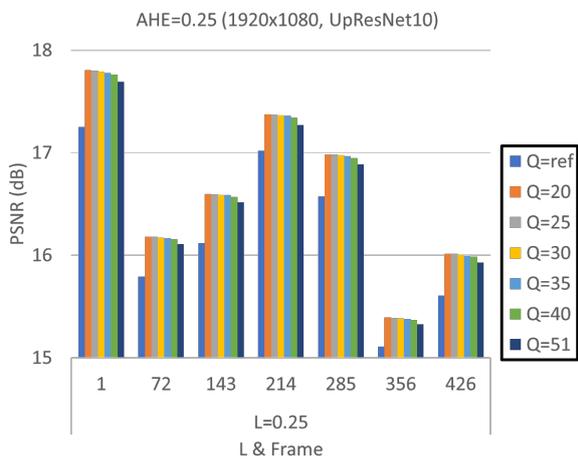
☒ 9: AHE=4 (1280x720, Original)



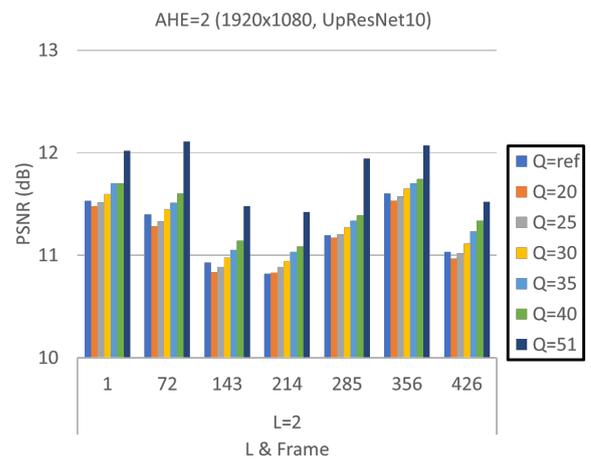
10: AHE=ref (1920x1080, UpResNet10)



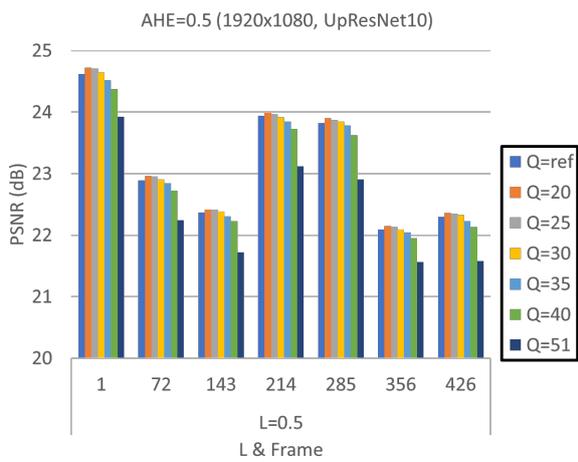
13: AHE=1 (1920x1080, UpResNet10)



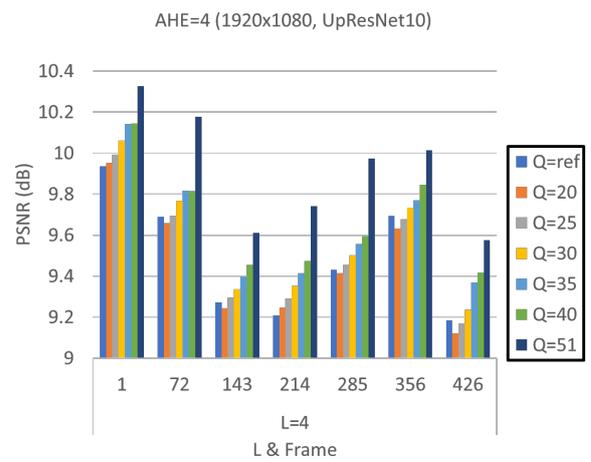
11: AHE=0.25 (1920x1080, UpResNet10)



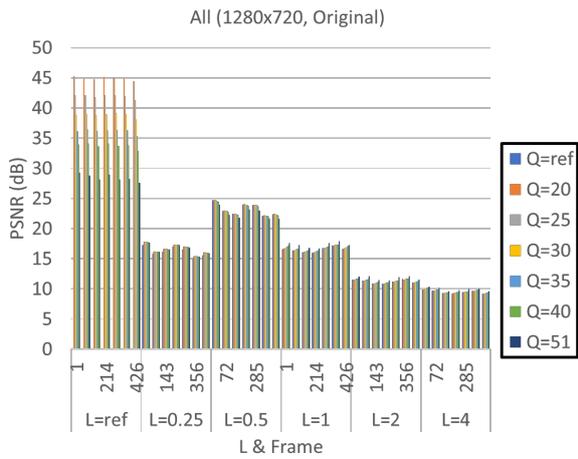
14: AHE=2 (1920x1080, UpResNet10)



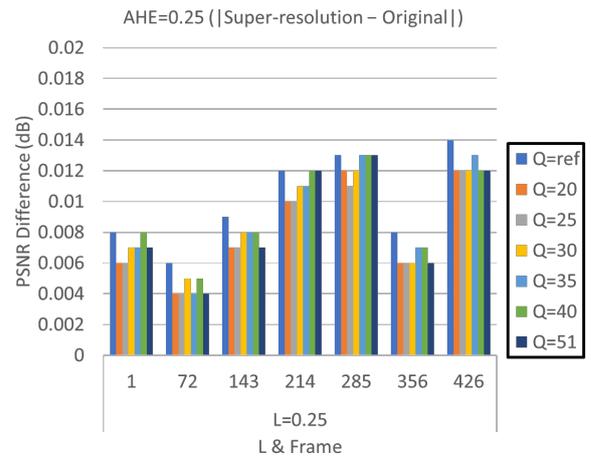
12: AHE=0.5 (1920x1080, UpResNet10)



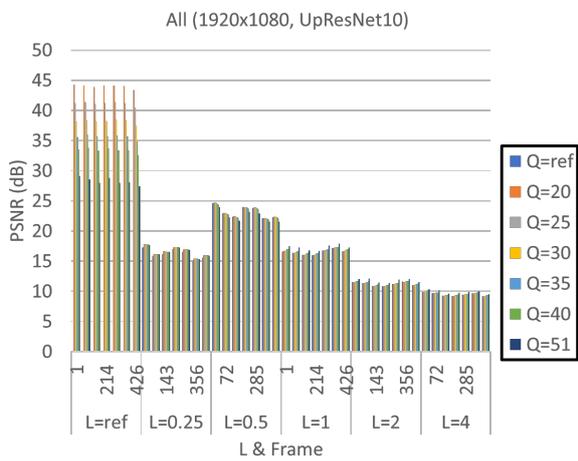
15: AHE=4 (1920x1080, UpResNet10)



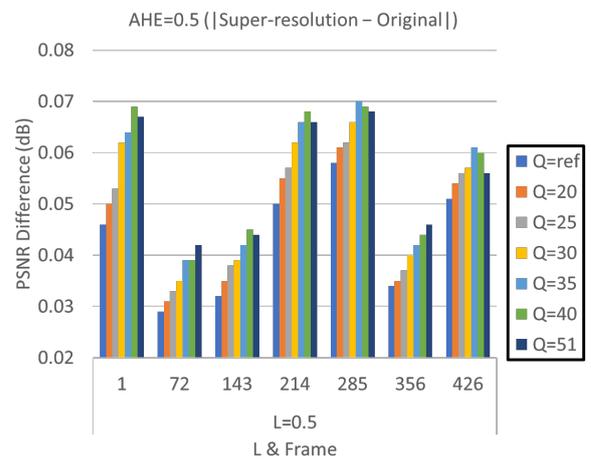
16: All (1280x720, Original)



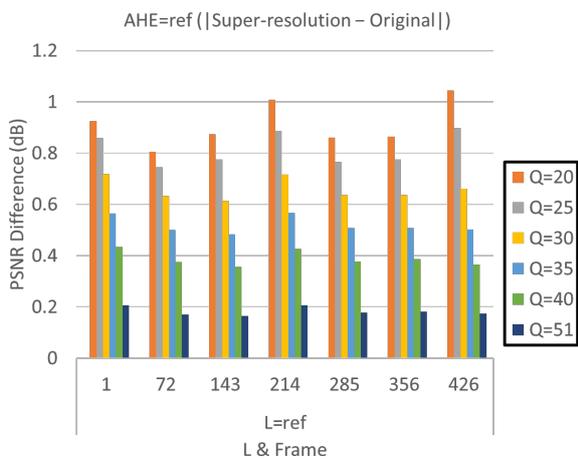
19: AHE=0.25 (|SR-Orig|)



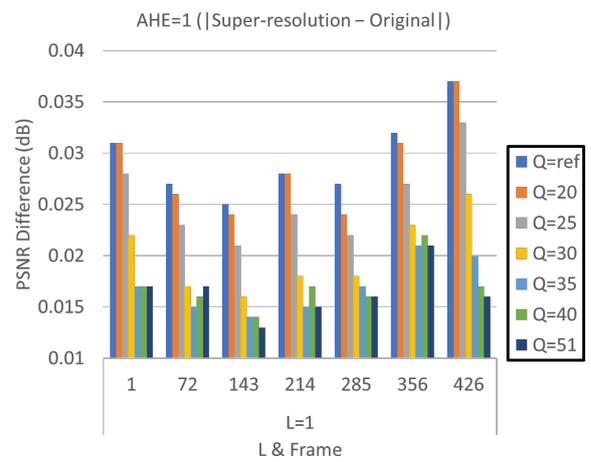
17: All (1920x1080, UpResNet10)



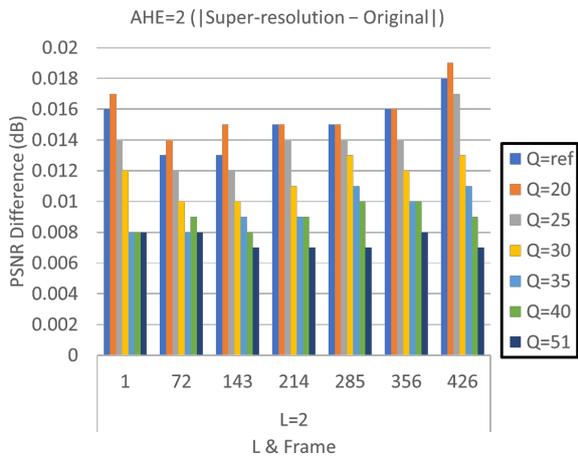
20: AHE=0.5 (|SR-Orig|)



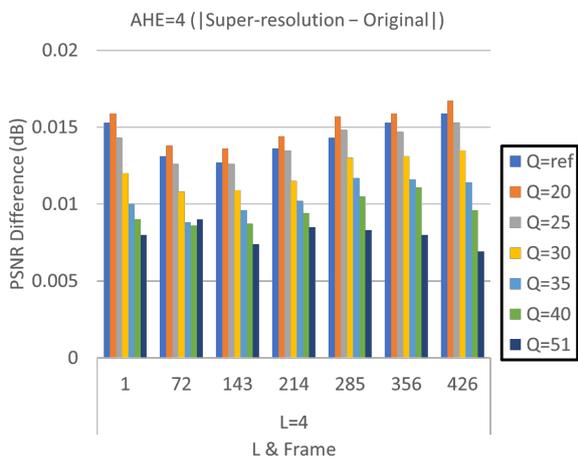
18: AHE=ref (|SR-Orig|)



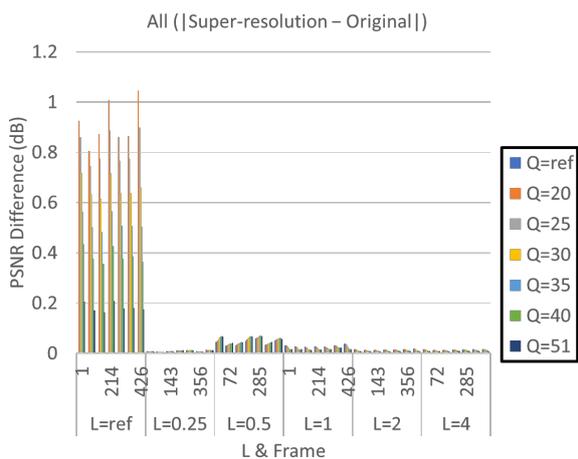
21: AHE=1 (|SR-Orig|)



☒ 22: AHE=2 (|SR-Orig)



☒ 23: AHE=4 (|SR-Orig)



☒ 24: All (|SR-Orig)

- [17].M. Abdoli, F. Nasiri, and P. Brault et al.: “Quality assessment tool for performance measurement of image contrast enhancement methods,” *IET Image Process.*, Vol. 13, Iss. 5, pp.833--842, 2019.
- [18].T. Celik: “Spatial Entropy-based Global and Local Image Contrast Enhancement,” *IEEE Trans. on Image Process.*, vol.23, no.12, pp.5298--5308, December 2014.
- [19].K. Gu, G. Zhai, and W. Lin et al.: “The Analysis of Image Contrast: From Quality Assessment to Automatic Enhancement,” *IEEE Trans. on Cybernetics*, vol.46, no.1, pp.284--297, January 2016.
- [20].W. Shi, J. Caballero, and F. Huszár et al.: “Real-Time Single Image and Video Super-resolution Using an Efficient Sub-Pixel Convolutional Neural Network,” *Proc. of CVPR2016*, pp.1874--1883, 2016.
- [21].F. Bossen, D. Flynn, and K. Sühring, “HM Software Manual,” https://hevc.hhi.fraunhofer.de/svn/svn_HEVCSoftware/, accessed May 22, 2019.

A Discussion on Optimum Condition between Contrast Enhancement and SRCNN Super-resolution Processing to Diagnose Color Laparoscopic Image

Norifumi KAWABATA^{*1}, Toshiya NAKAGUCHI^{*2}

^{*1} Department of Information Sciences, Tokyo University of Science

^{*2} Center for Frontier Medical Engineering, Chiba University

The contrast image processing in the medical image diagnosis is purposed to classify and recognize whether there is fault or not by enhancing each body region. To improve precision, most of these image processing is classified and recognized after image resolution improvement by processing of super-resolution in addition to contrast enhancement. On the other hand, appearing of deep learning in medical imaging technology field, the precision of super-resolution processing is improved, however, there are many types of parameter in this processing, and it may not be enough to perform whether there is adjustment of them or not. Therefore, we need to practice by verifying in experiments how to adjust parameter. In this study, we carried out experiments by using waifu2x-caffe (UpResNet10) based on Super-Resolution Convolutional Neural Network (SRCNN) specialized to super-resolution processing for the relation between contrast enhancement (Adaptive Histogram Equalization: AHE) and super-resolution processing with the color laparoscopic medical images, and then, we measured Peak Signal to Noise Ratio (PSNR). Finally, we discussed whether these methods can be generated how well images accurately or not.

Key words: Laparoscopic Image, Contrast Enhancement, Super-resolution, waifu2x-caffe, Super-Resolution Convolution Neural Network (SRCNN)

動作計測による顔の粘弾性シミュレーション

黒田 嘉宏*¹ 加藤 弘樹*¹ 谷川 千尋*^{2,3} 吉元 俊輔*¹

大城 理*¹ 高田 健治*^{2,4}

要旨

顔の動きは感情を身体的に表出することから、コミュニケーションにおいて重要な役割を担う。生体組織のもつ粘弾性的な性質は年齢や傷によって変化し、動きに大きく影響する。しかし、従来は顔の動きの表現に着目した医療支援システムは少ない。本研究では、加齢や手術による顔の運動様態の変化を表現することを目的として、顔の粘弾性特性の計測を行うとともに粘弾性モデルに基づく顔の変形シミュレーションを再現するシステムを構築した。実際に計測した運動を元に、顔の運動する様子を計算して表現することを可能とする。発表では、本研究における粘弾性モデルおよびシミュレーション結果について報告する。

キーワード：粘弾性シミュレーション，顔変形，特徴追跡，有限要素法，術後予測

1. はじめに

人が他者とコミュニケーションを行うとき、言語以外の情報として顔の表情なども重要な役割を果たす。顔の表情のうち、顔の動きは代表的な感情の身体的表出の一つである。顔の動きの CG 生成や本人の顔の動きを取り込んだ 3D アバター生成など様々な研究開発がなされている。

医療分野においては外科手術後の顔形態の予測は重要な意味をもち、顔の変形を対象とした物理シミュレーションや物理パラメータの計測が行われてきた。Flynn らは筋による皮膚変形を連続体に基づく有限要素法を用いてシ

ミュレーションしている[1]。また、医学分野では皮膚の粘弾性の計測が盛んに行われている。皮膚にせん断変形を行った場合や吸引した際の皮膚の応答を観測し、瞬時弾性と呼ばれる急峻な皮膚変形とその後の粘性の強い緩やかな皮膚変形が生じることを前提に皮膚の力学的応答を定量化して、年齢や皮膚疾患の有無による違いが調査されている[2]。バネ要素とダンパ要素から構成される Zener モデルは弾性と粘性による複合的な軟組織の変形を表現する基本的なモデルである。しかし、上記の実測結果と一致しないという問題が残る。

本研究では、有限要素法に基づいた顔形状の運動シミュレーションを目的として、複合的な粘弾性パラメータにより顔表面の皮膚変形を表現し、さらにその複合的なパラメータを近似する手法を提案する。

2. 有限要素法による複合粘弾性表現のための粘弾性パラメータの動的切り替え手法

並列した一つずつのばねとダンパから構成される粘弾性モデルに対して、一定の外力 f_c の

*1 大阪大学大学院基礎工学研究科
〔〒560-8531 豊中市待兼山町 1-3〕
e-mail: ykuroda@bpe.es.osaka-u.ac.jp

*2 大阪大学国際医工情報センター

*3 大阪大学大学院歯学研究科

*4 シンガポール国立大学

投稿受付：2019年5月15日

ステップ入力を与えたときの変位 u の応答は、以下の式で表される。

$$u = \frac{f_c}{k} \left(1 - \exp\left(-\frac{t}{\tau}\right) \right), \quad \tau = \frac{\eta}{k} \quad (1)$$

ただし、 t は時間、 k, η はそれぞれ弾性係数、粘性係数であり、 τ は時定数を表す。さらに、同モデルを直列に多層接続した場合の応答は、以下の式で表される。

$$u = f_c \sum_{i=1}^N \frac{1}{k_i} \left(1 - \exp\left(-\frac{t}{\tau_i}\right) \right), \quad \tau_i = \frac{\eta_i}{k_i} \quad (2)$$

本研究では、複数の粘弾性パラメータを時間的に切り替えることによって式(2)を近似し、顔形状を表現する3次元メッシュの各要素に成り立つ運動方程式を有限要素法によって離散化して顔の運動をシミュレーションする。例えば、2層の場合は、以下のように切り替えることとする。切り替える時間は時定数等から決定する。

$$k = \begin{cases} k_1 & (t \leq t_1) \\ k_2 & (t > t_1) \end{cases}, \quad \eta = \begin{cases} \eta_1 & (t \leq t_1) \\ \eta_2 & (t > t_1) \end{cases} \quad (3)$$

3. 粘弾性の計測とフィッティング

顔表面の粘弾性を計測するために、吸引圧 50 kPa、プローブ測定開口部 2 mm の条件のもと、吸引 3 s とそれに続く開放（無吸引） 3 s を 1 セットとして、被験者 41 名に対して頬、鼻下、咬筋、上唇、下唇の 5 部位を 3 セットずつ計測した。データについては、大阪大学国際医工情報センター研究倫理委員会の承認(001)を得て取得された。図 1 は、1 層と 2 層のモデルで計測変位にフィッティングした場合、そして粘弾性パラメータをある時刻に切り替えた場合のフィッティング結果を示す。本実験では、切り替える時間として、医学分野で瞬時弾性の時間として一般的に想定されている 0.1 s とした[2]。また、最小化問題の解法としてはシンプレックス探索法を用いた。

三次元メッシュの一部の点を駆動し、有限要素法を用いて粘弾性シミュレーションした結果の例を図 2 に示す。駆動する際には、デブスカメラ Kinect v2 を用いて顔の変位の計測を行い、対応点に対して与える変位を境界条件として、残りの点の変位を算出した。

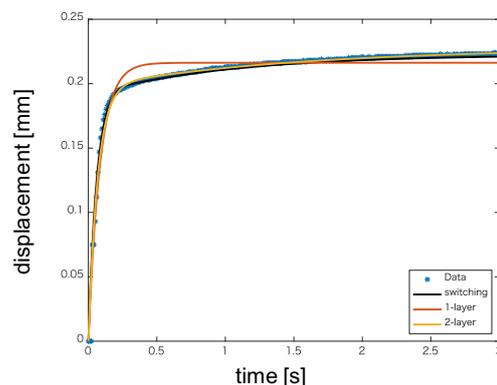


図 1 フィッティング結果の例。計測データに対して 1 層モデルは大きく異なるのに対して、2 層モデルおよび動的切り替え手法は概ね一致した。

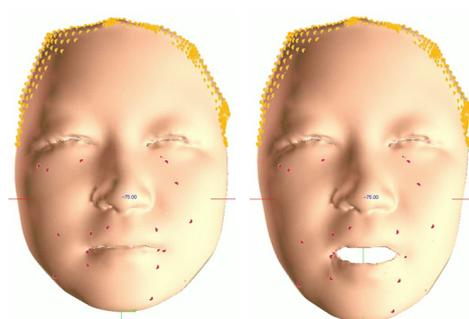


図 2 有限要素法を用いて顔を変形した結果の例。

3. まとめ

本研究では、有限要素法により表現可能な動的切り替えに基づく複合粘弾性表現手法を提案した。

利益相反の有無

なし

文 献

- [1] Flynn C, Stavness I, Lloyd J, et al: A finite element model of the face including an orthotropic skin model under in vivo tension. *Computer Methods in Biomechanics and Biomedical Engineering*, 18(6): 571–582, 2013.
- [2] Barel O, Lambrecht R, Clarys P: Mechanical Function of the Skin: State of the Art. *Skin Bioengineering*, 26: 69–83, 1998.

Viscoelastic Facial Simulation based on Motion Measurement

Yoshihiro KURODA ^{*1}, Hiroki KATO ^{*1}, Chihiro TANIKAWA ^{*2,3}, Shunsuke YOSHIMOTO ^{*1}, Osamu OSHIRO ^{*1},
Kenji TAKADA ^{*2,4}

*1 Graduate School of Engineering Science, Osaka University

*2 Global Center for Medical Engineering and Informatics, Osaka University

*3 Graduate School of Dentistry, Osaka University

*4 National University of Singapore

Facial motion plays an important role in communication as it represents emotion physically. Viscoelastic characteristics change by age and wound, and effect on facial motion. However, a few conventional studies of medical support system focused on representation of facial motion. The aim of this study is to represent changes of behavior of facial motion depending on age and plastic surgery. We developed a system representing facial deformation by viscoelastic model in addition to measurement of facial viscoelastic properties. Based on the measured motion, the system enabled to represent facial motion by simulation. In this presentation, we report the viscoelastic model and the simulation results.

Key words: Viscoelastic simulation, Facial deformation, Feature tracking, Finite element method, Postoperative prediction

3次元点群の位置合わせによる顔の対称面検出

細木 大祐*¹ 陸 慧敏*¹ 金 亨燮*¹

木村 菜美子*² 大河内 孝子*² 野添 悦郎*² 中村 典史*²

要旨

口唇裂とは、胎児の顔面が癒合する過程において唇が完全に形成されない場合に生じる先天異常で、日本においては約 500 人に 1 人の割合で発生する。左右対称な口唇と外鼻を形成することを目的として治療が行われているが、医師の主観に依存した判断基準に基づいているため、手術部位の対称度を定量的に判断する必要がある。本論文では、手術部位の対称性を解析するための顔の対称基準となる面を検出する手法を提案する。提案法では被験者の顔を撮影した 3 次元点群データに対し、顔器官を点として検出したのうち、口唇裂による形状変化の影響が顕著とされる上唇から鼻尖点までの領域を除外した鏡像反転点群との位置合わせを行う。次に、元の点群内の 1 点と鏡像反転像内の対応点の間を垂直 2 等分する平面を求めることにより対称基準面を設定する。提案法を実 3 次元点群データに適用した結果、良好な精度で対象基準面を検出することができた。

キーワード：口唇裂，対称性解析，3 次元点群，ICP 法

1. 序論

口唇裂は世界で最も頻度の高い先天異常の 1 つとされており、胎児の顔面が癒合する過程において唇が完全に形成されない場合に生じる先天異常である[1, 2]。手術は複数回に渡って行われ、生後 3 カ月頃に機能的な問題を解決するための一次手術を行い、それ以降は左右対称な外鼻および上唇を形成するための手術を行う。しかし、術部の非対称性を示す定量的な評価法がないため、判断基準が医師の主観に依存することから、患者や家族らには定性的な評価しか提示できないのが現状である。そこで、術部の非対称性を表す指標を与えるにあたって、

顔に潜在的に存在する対称基準を検出する必要がある。

顔の対称性解析手法の一般的な方法として 2 次元顔写真の画像解析が挙げられる[3]。画像解析は幅広い分野で応用されており、口唇裂解析において有用であると思われる。しかし、2 次元顔写真を利用した顔の対称性解析において、顔の凹凸形状まで考慮できないことから、立体的な情報が不足しているといえる。よって、3 次元データ解析を用いた顔の潜在的な対称面を検出し、それに基づいた手術部位の非対称度を立体的に評価し、口唇裂による形態的な影響を踏まえた定量的指標を提示することは、医用画像解析による新しい指標提供の面で有用であり、その開発が求められている。本論文では、手術部位の対称性解析を可能とするため、口唇裂患者の顔の 3 次元点群データからの対称面の検出手法を提案し、実データによる有効性を検証する。

*1 九州工業大学工学部工学専攻
〔〒804-8550 福岡県北九州市戸畑区仙水町 1-1〕

e-mail: kimhs@cntl.kyutech.ac.jp

*2 鹿児島大学大学院医歯学総合研究科

2. 手法

本論文では、口唇裂手術前後における口唇外鼻形態の定量的解析を可能とすべく、口唇裂患者の顔面の対称基準面を自動で設定するための画像処理手法を提案する。顔面の対称性を解析するにあたって、カメラで患者の顔を撮影した2次元の画像解析が有効であると考えられる。しかし、手術部位の口唇外鼻形態を精密に解析するためには、2次元顔写真では表面の凹凸形状の情報が欠落しているといえる。そこで立体的、すなわち3次元的な形状を把握して解析するため、本論文では非接触型3次元形状測定装置を用いて得た顔の3次元点群データに対し、その対称基準を自動的に設定する手法を提案する。手法全体の流れを図1に示す。

2.1. 顔器官検出

まず、2次元画像上で顔器官を検出するため、3次元点群（図2左）を xy 平面に投影する。作成する画像の大きさを 512×512 [pixel]とし、点群の重心が中心となるように平行移動させ、全体が画像内に収まるように点群のサイズを100分の1にリサイズする。その後、 xy 平面上で点群内の各点を近傍のピクセルに割り当て、割り当てられた点の色の平均値をそのピクセルの画素値とする。このとき、割り当てられた点の z 座標の平均値を奥行き情報としてそのピクセル

に保持する。これは顔器官検出の最後の処理で検出された、2次元画像上の点を3次元点群上に復元するために用いる。

次に、顔器官を検出する領域を画像内で決定するため、HOG特徴量[4]を用いた物体検出手法により顔領域を決定する。HOG特徴量の計算はまず、各ピクセルの輝度値からその勾配強度と勾配方向を求め、勾配方向で量子化を行う。セルと呼ばれる領域ごとに勾配方向で量子化された勾配強度のヒストグラムを作成する。複数のセルを持つ、ブロックと呼ばれる領域ごとにヒストグラムの正規化を行うことにより、特徴量が抽出できる。顔領域の検出には検出窓内のHOG特徴量を入力とした線形SVM[5]を用いる。重なり合ったブロックを敷き詰めた検出窓を、すべての位置・スケールで設定し、各ブロック内においてHOG特徴量を計算する。検出窓内の特徴量をSVMに入力し、顔の有無を検出窓ごとに決定する[4]。

検出された顔領域に対し、Kazemiらの手法[6]により顔器官のランドマーク位置を決定する。これは、回帰を繰り返すことによって顔の推定形状を求めるものである。顔のすべてのランドマークの位置を1つの形状 S でベクトル表現すると、次式によってランドマークの推定が繰り返される。

$$\hat{S}^{(t+1)} = \hat{S}^{(t)} + r_t(I, \hat{S}^{(t)}) \quad (1)$$

最後に、2次元画像上で決定した顔器官のランドマーク点を3次元点群上に再投影する。これは、点群を画像上に投影した際に各ピクセルに保持させた奥行き情報を用いる。まず、ランドマーク点の存在するピクセルの座標から、 xyz 座標空間上の xy 座標を決定する。次に、そのピ



図1 処理全体のフローチャート

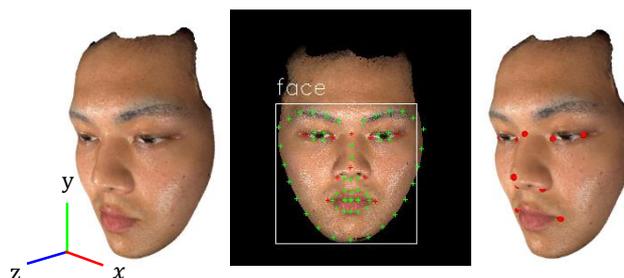


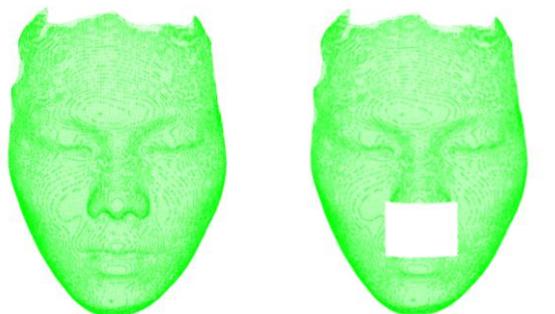
図2 顔器官検出

クセルの奥行き情報で大まかに点群上の位置(z座標)へ移動し、その位置の最近傍に存在する点を3次元点群上のランドマーク点の位置とする。本手法で用いるランドマーク点は、右目の外眼角・鼻尖・口角を示すもののみを用いる。以上の処理により得られた点群データを図2右示す。

2.2. 領域分割

次処理において左右非対称な領域、すなわち口唇裂による口唇外鼻の形態変化が顕著に現れる領域を含んだままであると、鏡像反転像との位置合わせを精度よく行うことが困難である。そこで本処理では、口唇外鼻の形態変化が影響を及ぼす領域(非対称領域)とそうでない領域(対称領域)とに分割する。

口唇裂は上唇に裂が生じ鼻孔周辺にまで至るものもある。よって、この領域を非対称領域として取り除くため、顔器官検出で得られたランドマーク点のうち、左右の口角を示す2点と鼻尖点を示す1点を用いて非対称領域を設定する。左右の口角2点を結ぶ線分を底辺として持ち、鼻尖点からその線分までの距離を高さとする長方形を作成し、これを非対称領域とする。その領域内を法線方向に平行移動した空間にある点をすべて取り除くことにより、点群内の非対称な部分を除去し、対称領域のみを残す。以上より得られる非対称領域の除去例を図3に示す。



(a) 元の点群画像 (b) 非対称領域除去後の画像

図3 非対称領域除去例

2.3. 対称面検出

まず、Global Registrationにより、2つの点群を大まかに重ね合わせたのち、Local Registrationで精密な位置合わせを行う。位置合わせを行ったのち、元の点群から一点を選択し、その点を反転した点を鏡像反転した点群内から選択する。これら2点の位置関係から潜在的対称軸となる平面を生成する。以下に概要を示す。

(A) Global Registration

Global Registrationの流れを図4に示す。まず、対応付けを行う点を選択するため、点群の各点においてHarris 3D特徴量[7]を計算する。

これは、2次元画像におけるHarris特徴量[8]が輝度勾配を用いている代わりに、3次元座標空間における各点の法線を用いて記述される。Harris 3D特徴量を計算することにより、点群内の凹凸が顕著な点が検出できるため、その点においてFPFH(Fast Point Feature Histogram)特徴量[9]を計算する。FPFH特徴量は点の局所的な幾何学的性質を記述する。そのため、潜在的軸対称である顔において、顔の右側と鏡像反転した顔の左側が類似した形状であるように、ある一



図4 Global Registrationのフローチャート

点と反転像内におけるその点の近傍点で計算された特徴量は類似したものが得られると考えられる。そして、元点群と反転点群との特徴量間距離が最近傍となる点同士を対応付ける。しかし、これらの対応の中には誤対応(Outlier)が含まれるため、RANSAC(Random Sample Consensus)によりそれらを取り除く[10]。最後に、残った対応からSVD(Singular Value Decomposition)[11]により、反転点群を元点群に位置合わせする剛体変換ベクトルを推定する。以上の計算で求められた剛体変換ベクトルを適用した例を図5に示す。同図では、反転点群(灰色)を元点群(緑色)へ位置合わせ(赤色)している。

(B) Local Registration

局所位置合わせの手法として、点と点との距離を最小化すべき目的関数として用いる point-to-point ICP[12]を適用する。Point-to-point ICPの流れは、2点群間における各点を最近傍点と対応付けたのち、剛体変換を推定する。剛体変換推定では、変換後の点群と位置合わせ先の点群間で対応付けられた点間の距離の2乗誤差、

$$D = \sum \| \mathbf{y}_i - (\mathbf{R}\mathbf{x}_i + \mathbf{t}) \|^2 \quad (2)$$

を最小化する回転行列 \mathbf{R} と並進ベクトル \mathbf{t} を求める(ただし、 \mathbf{y}_i は元の点群、 \mathbf{x}_i は鏡像反転した点群の各点の座標を示す)。

(C) 平面計算

2点群の位置合わせが完了したのち、元の点

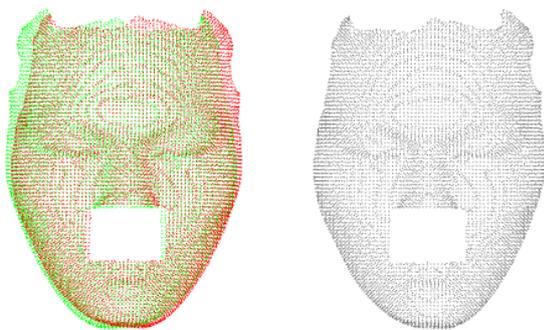


図5 Global Registration 適用例

群の任意の点 \mathbf{K}_p と鏡像反転した点群内の対応点 \mathbf{K}_m を結ぶ線分のベクトル \mathbf{n} を次式で計算する(図6)。

$$\mathbf{n} = \frac{\mathbf{K}_m - \mathbf{K}_p}{\| \mathbf{K}_m - \mathbf{K}_p \|} = (x_n, y_n, z_n) \quad (3)$$

本手法においては、任意の点 \mathbf{K}_p を顔器官検出で得られたランドマーク点のうち、右目の外眼角点を用いる。これは、点群の重心点を \mathbf{K}_p とした場合、 \mathbf{K}_p は点群の中央付近に位置するため、重ね合わせにより \mathbf{K}_p と \mathbf{K}_m 間の距離が短くなると考えられ、位置合わせで残った誤差により、平面が大きく回転してしまう恐れがある。ここで \mathbf{K}_p を点群の中央から離れている点を用いることにより、位置ずれ精度の影響を低減することができる。そこで、点群の中央から離れており、かつ確実にその点を選択できるため、顔器官検出で得られる外眼角点を選択し、これを点 \mathbf{K}_p とする。次に、対応点 \mathbf{K}_p と \mathbf{K}_m 間の midpoint \mathbf{c} を次式により求める。

$$\mathbf{c} = \frac{\mathbf{K}_m + \mathbf{K}_p}{2} = \left(\frac{x_{km} + x_{kp}}{2}, \frac{y_{km} + y_{kp}}{2}, \frac{z_{km} + z_{kp}}{2} \right) = (x_c, y_c, z_c) \quad (4)$$

以上より、法線 \mathbf{n} を持ち、点 \mathbf{c} を通る平面を次式

$$x_n(x - x_c) + y_n(y - y_c) + z_n(z - z_c) = 0 \quad (5)$$

で求める。

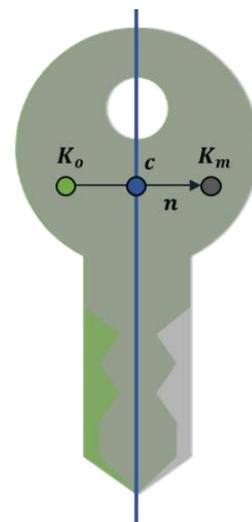


図6 平面計算の概念図

3. 実験結果

本論文では Canfield Scientific 社製の VECTRA® H1 で撮影された口唇裂患者の顔面の 3 次元点群データ 23 症例を用いた。用いる PC は CPU3.4[GHz]メモリ 16.0[GB]であった。

検出した平面の精度評価は、医師の指導の下で作成した対称平面を Ground Truth とし、提案法により得られた基準面との比較により行った。3 次元空間上で比較を行うため、精度評価に用いるパラメータとして x 軸方向の平行移動距離、 y 、 z 軸方向の回転角度の計 3 つを用い、結果と Ground Truth との差を誤差として計算した。図 7 に示すように、任意の 2 平面は、 x 軸方向の平行移動、 y 、 z 軸方向の回転によって平面同士を重ね合わせることができる。つまり、2 平面の位置・角度差はこれら 3 つのパラメータで表現できるため、精度評価として用いた。まず、本手法を用いて得られた対称基準面の確かさを検証するため、完全な左右対称モデル（図 8）を対象に実験を行った。1 データ当たり用いた点群は約 1 万点であり、計算時間は 1 分程度であった。その結果を表 1 に示す。次に、完全に左右対称でない人の顔に対する有効性を確認するため、口唇裂患者の顔データ 23 例に対して実験を行った。図 9 は本手法を適用した結果の一例である。その結果を表 2 に示す。

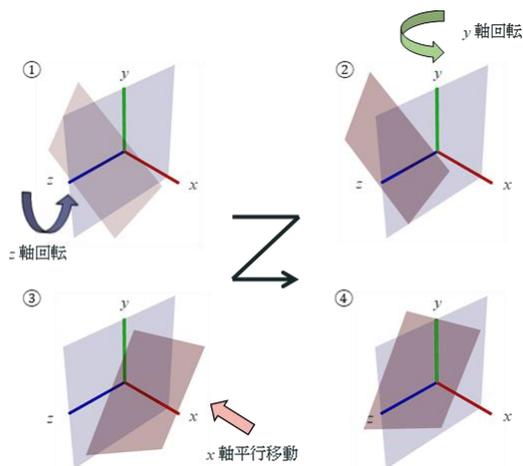


図 7 2 平面の重ね合わせ

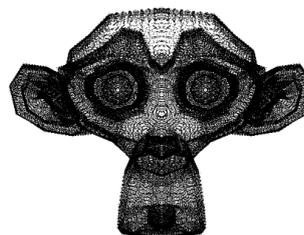


図 8 2 完全左右対称モデル

表 1 実験結果（完全な左右対称モデル）

X 軸回転誤差 [mm]	Y 軸回転誤差 [deg]	Z 軸回転誤差 [deg]
0.1900×10^{-6}	0	0.4000×10^{-6}

表 2 実験結果（口唇裂患者データ）

X 軸回転誤差 [mm]	Y 軸回転誤差 [deg]	Z 軸回転誤差 [deg]
0.6871	0.8342	1.3633

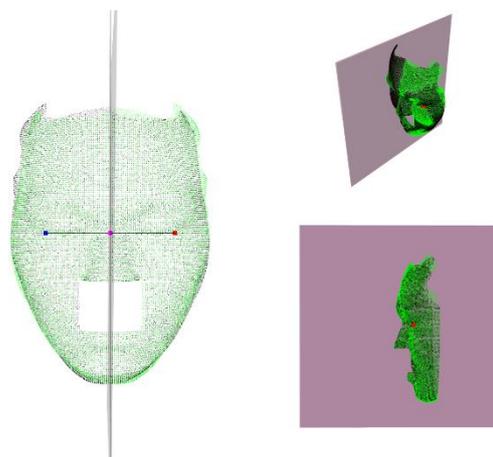


図 9 実験結果例

4. 結論

本論文では、口唇裂患者の顔を撮影して得た 3 次元点群データから、手術部位の左右対称性を定量評価するために必要となる、顔の対称基準を検出する手法を提案した。

本手法により完全な左右対称モデルの対称基準を検出でき、患者 23 名のデータに対しては、全体として x 軸方向の並進誤差、 y 軸、 z 軸方向の角度誤差はそれぞれ、 $0.687[\text{mm}]$ 、 $0.834[\text{deg}]$ 、 $1.363[\text{deg}]$ となり、顔の対称性解

析の基準として提示できる精度であった。

今後の課題は、本手法により検出した顔の対称基準をもとに、手術結果の対称性解析手法の提案やさらなる高速画像位置合わせ法の開発などである。

謝辞

本研究の一部は、文部科学省科学研究費補助金(19K10271)の補助を受けている。

利益相反の有無

なし

文 献

- [1] 高橋 他, “口唇裂・口蓋裂の基礎と臨床,” 日本歯科評論社, pp.1-29, 1996.
- [2] 森口 他, “口唇裂口蓋裂の総合治療成長に応じた諸問題の解決,” 克誠堂出版株式会社, 2006.
- [3] Kimura N, Kim HS, Okawachi T, Fuchigami T, Tezuka M, Kibe T, Yamada S, Amir MS, Ishihata K, Nozoe E, Nakamura N, “Pilot study of visual and quantitative image analysis of facial surface asymmetry in unilateral complete cleft lip and palate,” *Cleft Palate-Craniofacial J*, E-published ahead of print, 2018.
- [4] Dalal *et al.*, “Histograms of oriented gradients for human detection,” *Computer Vision and Pattern Recognition*, 2005. CVPR 2005. IEEE Computer Society Conference on, vol. 1, pp.886-893, 2005.
- [5] Vapnik *et al.*, “Pattern recognition using generalized portrait method,” *Automation and remote control*, vol. 24, pp.774-780, 1963.
- [6] Kazemi *et al.*, “One millisecond face alignment with an ensemble of regression trees,” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.1867-1874, 2014.
- [7] Sipiran, Ivan *et al.*, “Harris 3D: a robust extension of the Harris operator for interest point detection on 3D meshes,” *The Visual Computer*, vol. 27, no. 11, pp.963-976, 2011.
- [8] Harris *et al.*, “A combined corner and edge detector,” *Alvey vision conference*, vol.15, no.50, 1988.
- [9] Rusu *et al.*, “Fast point feature histograms (FPFH) for 3D registration,” *Robotics and Automation, ICRA'09. IEEE International Conference on. IEEE*, pp.3212-3217, 2009.
- [10] Fischler *et al.*, “Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography,” *Communications of the ACM*, vol.24, no.6, pp.381-395, 1981.
- [11] Arun *et al.*, “Least-squares fitting of two 3-D point sets,” *IEEE Transactions on Pattern Analysis & Machine Intelligence*, vol.5, pp.698-700, 1987.
- [12] Besl *et al.*, “Method for registration of 3-D shapes,” *Sensor Fusion IV: Control Paradigms and Data Structures*, vol.1611, International Society for Optics and Photonics, pp.586-607, 1992.

Detection of Facial Symmetric Plane

Based on Registration of 3D Point Cloud

Daisuke HOSOKI^{*1}, Huimin LU^{*1}, Hyonseop KIM^{*1}

Namiko KIMURA^{*2}, Takako OKAWACHI^{*2}, Etsuro NOZOE^{*2}, Norifumi NAKAMURA^{*2}

*1 Kyushu Institute of Technology

*2 Kagoshima University.

Cleft lip is a birth defect that occurs when the lips are not completely formed during healing of the face of the fetus. In Japan, it occurs in about 1 in 500 people. Although treatment is performed to form a symmetrical outer nose, it is necessary to evaluate the degree of symmetry of the surgical site quantitatively because it is based on the judgment criteria that depend on the doctor's subjectivity. In this paper, we propose a method to detect the plane which is the symmetry basis of the face to analyze the symmetry of the operation site. In the proposed method, the face organ is detected as points from 3D point cloud of the face. Then, the mirror image inversion excluding the area affected by shape change due to cleft lip is aligned with the original point cloud. Next, a symmetric plane is set by finding a plane that bisects vertically between one point in the original point cloud and the corresponding point in the mirror image. As a result of applying the proposed method to real 3D point cloud, we could detect the symmetric plane with good accuracy.

Key words: Cleft Lip, Symmetric, Analysis, Point Cloud, Iterative Closest Point

放射光 CT を用いた

肺 3 次元マイクロ血管解析

島谷峻平*¹ 斉藤くるみ*¹ 泓田彰汰*¹ 河田佳樹*² 仁木登*²梅谷啓二*³ 阪井宏彰*⁴ 中野恭幸*⁵ 岡本俊宏*⁶ 伊藤春海*⁷

要旨

肺の正常形態と極早期の疾患形態のマイクロレベルでの画像化とその定量的な形態解析は、次世代の胸部画像診断への貢献が期待できる。しかし、3次元のマイクロ構造と細血管は十分に解析されていないという現状がある。本研究は、高輝度放射光 CT で撮影した肺 3 次元画像血管系を可視化して定量的に解析する。

キーワード：放射光 CT, 肺, SPring-8, 血管解析

1. はじめに

肺の正常形態と極早期の疾患形態のマイクロレベルでの画像化とその定量的な形態解析は、次世代の胸部画像診断に貢献することが期待できる。高輝度な放射光 CT を利用することは、微小焦点の X 線管を用いたマイクロ CT と比較して、高い信号雑音比で数 μm オーダの空間分解能を有する高精細な CT 画像の収集が期待される。ビームハードニング効果の影響を受けずに微細構造の高コントラストな画像を得ることにより、マイクロ形態の定量的な計測への応用にも期待される。しかし、3次元の細血管は十分に解析されていないという現状がある。本研究では肺標本を高輝度放

射光 CT で撮影し、その画像から血管系の微細構造を 3 次元的に可視化して定量的に解析する。

2. 放射光 CT の撮影条件と肺標本

撮影対象の伸縮固定肺標本は直径 3.6 cm であり、Heitzman 法に準じて作成された。二次小葉の細血管を観察するためにナノ粒子造影剤としてバリウムを使用した。撮影した肺標本は米国人肺標本である。撮影装置には大型放射光施設 SPring-8 の BL20B2 ビームラインを使用した。

3. 肺胞房領域の解析

肺胞房は呼吸細気管支から先の肺胞管と肺胞嚢をまとめた領域である。肺胞房は Fig.1 の手順に従って肺胞房領域の血管系を解析する [1]。まず、閾値処理により壁構造を抽出し、膨張・収縮処理を行うことで肺動静脈を抽出して、太い箇所をマニュアルで補正する。次に、肺細動静脈を抽出する。肺細動静脈は造影剤が充填しており CT 値が高いと考えられる (Fig.2) ので閾値処理により抽出する。毛細血管は、径が $10\mu\text{m}$ 以下といわれている。本研究で使用している再構成画像は $1\text{ pixel} = 3\mu\text{m}$ であるため、毛細血管は 1 から 3 pixel であ

*1 徳島大学大学院先端技術科学教育部
〔〒770-0856 徳島市南常三島町 2-1〕

e-mail: 501938020@tokushima-u.ac.jp

*2 徳島大学大学院社会産業理工学研究部

*3(公財)高輝度光化学研究センター

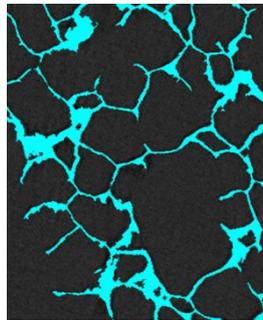
*4 兵庫県立尼崎総合医療センター

*5 滋賀医科大学

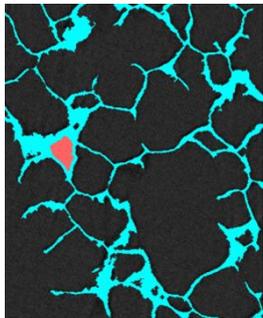
*6 Cleveland Clinic Heart

*7 福井大学

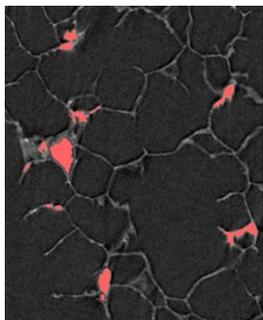
る. よって目視で抽出することは困難である. そのため 4 次元曲率やヘシアンフィルタなどの各種フィルタを用い抽出する. 抽出結果より, 血管系を定量的に解析する.



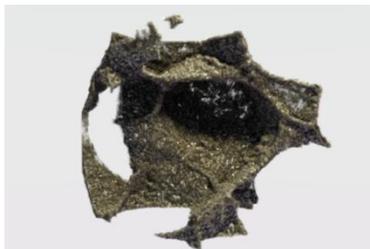
(a) 壁構造の抽出



(b) 肺動静脈の抽出



(c) 造影剤領域である肺細動静脈の抽出



(d) Exposure Render での毛細血管の抽出

Fig.1 血管系の解析手順

■ 壁ラベル

■ 肺動脈

■ 肺動脈
WL -500
WW 1500

末梢血管

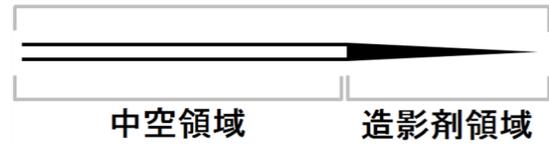


Fig.2 末梢血管の造影状態を示した模式図

4. 抽出結果

肺胞房領域における血管系の抽出結果を Fig.5 に示す. Fig.5 は肺細動静脈まで抽出したものである.

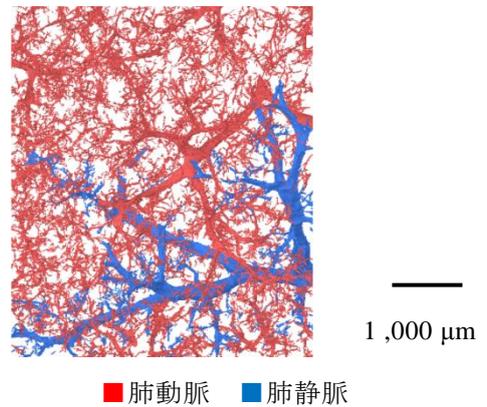


Fig.5 血管系の抽出結果

■ 肺動脈 ■ 肺静脈

4. まとめ

肺標本の放射光 CT 画像から, 肺胞房領域の肺細動静脈を抽出できた. 今後は, 血管系の自動抽出アルゴリズムを構築する.

利益相反の有無

なし

文献

- [1] K.Saito, S.Ohnishi, Y kawata et al: Pulmonary blood vessels extraction from dual-energy CT images using a synchrotron radiation micro-CT, Proc.SPIE Medical Imaging,2019

Analysis of 3D microstructure of the lung using synchrotron radiation micro-CT image.

Ryohei SHIMATANI^{*1}, Kurumi SAITO^{*1}, Shota FUKETA^{*1}, Yoshiki KAWATA^{*2}, Noboru NIKI^{*2}
Keiji UMETANI^{*3}, Hiroaki SAKAI^{*4}, Yasutaka NAKANO^{*5}, Toshihiro OKAMOTO^{*6}, Harumi ITO^{*7}

^{*1} Tokushima University Graduate School of Advanced Technology and Science

^{*2} Tokushima University Graduate School of Technology, Industrial and Social and Science

^{*3} Japan Synchrotron Radiation Research Institute

^{*4} Hyogo Prefectural Amagasaki General Medical Center

^{*5} Shiga University of Medical Science

^{*6} Cleveland Clinic Heart and Vascular Institute

^{*7} University of Fukui Biomedical Imaging Research Center

Microscopic imaging of the normal form of the lung and the disease form at the very early stage and its quantitative morphological analysis can be expected to contribute to the next generation chest imaging. However, three-dimensional microstructures and microvessels are not fully analyzed. This study visualizes and quantitatively analyzes the lung three-dimensional imaging vasculature taken by high-intensity radiation CT.

Key words: :synchrotron radiation micro-CT (SR μ CT), lung, SPring-8, blood vessel analysis

CT 画像と顎運動情報を用いた VR 咬合器の開発

伊藤崇弘^{*1}, 重本修伺^{*1}, 伊藤光彦^{*1}, 木原琢也^{*1},
井川知子^{*1}, 重田優子^{*1}, 小川 匠^{*1}

要旨: 我々は、歯科臨床において患者個々の形態と機能をより正確に再現できる VR 咬合器 (Virtual Reality Articulator) の開発を進めている。VR 咬合器は CT 画像による顎頭蓋形態情報、歯列模型による口腔内形態情報、顎運動測定による顎運動情報を同一座標系で統合することで得られ、患者の実際の顎口腔系の形態と機能を仮想空間上で再現することができる。今回、顎変形性関節症症例の術前、術中の顎位の妥当性や機能評価に VR 咬合器を応用し、高い有用性が認められたので報告する。

キーワード: CT, 顎運動, VR 咬合器

1. 緒言

歯科臨床においては、咬合および顎口腔系の機能を正しく検査、診断することは非常に重要である。従来は、顎口腔系の一部の形態と機能を単純化して再現する咬合器 (図 1-a) を用いて評価されることが一般的である。しかし従来型の咬合器は患者の形態や、顎運動を直線近似的に再現するもので、全ての患者情報を表現するものではない。そこで我々は、患者個々の形態と機能をより正確に再現するとともに顎機能評価が可能な VR 咬合器 (Virtual Reality Articulator) の開発を進めている (図 1-b)。VR 咬合器は CT 画像から得られる形態情報と、顎運動測定により得られる機能情報を同一座標系にて統合することで、従来型の咬合器では観察できなかった機能運動時 (咀嚼時など) の咬

合接触状態や関節窩に対する下顎頭の位置を仮想空間上で可視化することができる (図 1)。

今回、顎関節の変形性関節症症例に対して患者情報を用いて VR 咬合器を構築し術前・術中の治療顎位の妥当性や機能評価に応用した結果、高い有用性が認められたので報告する。

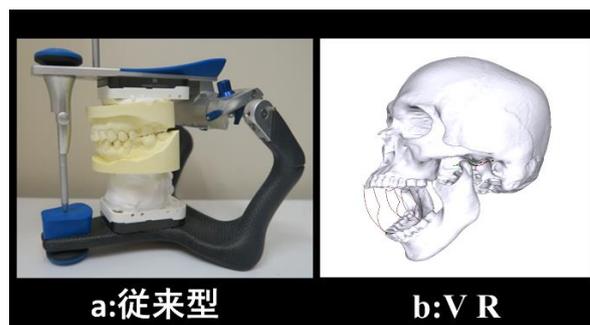


図 1 従来型と VR 咬合器

2. 方法

1) VR 咬合器の構築 (図 2)

CT 撮影: 本学附属病院設置の高速らせん型 X 線 CT 画像装置 RADIX-Prima (日立メディコ) を用いて行った (撮像マトリックス: 512×512, スライス厚: 0.625mm, FOV: 210mm)。得られた DICOM デ

*1 鶴見大学歯学部クラウンブリッジ
補綴学講座 [〒230-8501 神奈川県横浜市
鶴見区鶴見 2-1-3]

e-mail: ito-t@tsurumi-u.ac.jp

ータは3次元画像処理ソフト Amira (Visage Imaging) にて顎顔面頭蓋骨の関心領域についてセグメンテーション処理後、頭蓋骨および下顎骨の三次元モデルをCT座標系 (Σ_{CT}) で製作した。

歯列形態計測：患者の口腔内の型取りから得た歯列石膏模型を、パターン投影法を原理とした三次元形状計測装置 D900 (3Shape) を用いて計測し、歯列形態の三次元モデルをスキャナー座標系 (Σ_{SC}) で製作した。

顎運動測定：独自に開発した磁気ベクトル空間方式顎運動測定器 MMJ3 を用いて顎運動測定を行った。被験運動は咬頭嵌合位から始まる矢状面内限界運動とし、サンプリング周波数 100Hz で3回測定した。顎運動座標系 (Σ_{MM}) は図2に示す上顎歯列上の3標点 (切歯点 IN, 左右第一大臼歯中心窩 L6, R6) をとおる上顎咬合平面座標系で前方, 左方, 上方を正とする右手座標系である。

座標系の統一：CT座標系 (Σ_{CT})、スキャナー座標系 (Σ_{SC}) と顎運動座標系 (Σ_{MM}) を Σ_{MM} に座標系を統一した。 Σ_{SC} は、上顎歯列上の3標点 (IN, L6, R6) のそれぞれの座標系における座標値から座標変換行列 T_{SC-MM} を求め Σ_{MM} に変換した。 Σ_{CT} は、まず Σ_{SC} に変換するために特徴点の座標値から変換行列 T_{CT-SC} を求めた。その後、 T_{SC-MM} を用いて Σ_{MM} に変換した。座標系の統一、可視化および解析は、三次元データ処理ソフトウェア Leios (EGS srl) と Visual C++ (Microsoft) を用いた自作のアプリケーションを使用した。

2) 症例概要および治療経過

患者 64 歳女性。上下前歯部の咬耗, 下顎臼歯部欠損および咬合時左側顎関節疼痛を認めた (図3)。パノラマエックス線所見では左側下顎頭に変形を認めた。パノラマ顎関節4分割パノラマエックス線所見では下顎頭位は、左側が後上方位, 右側が後下位に変位していた。また左側下顎頭の並進運動の制限を認めた (図4)。

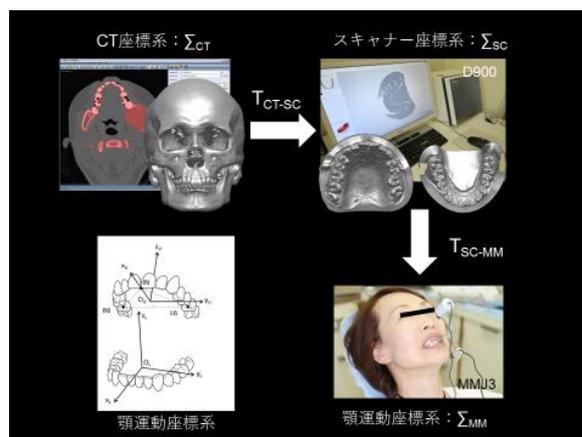


図2 VR咬合器の構築

MR所見では、左側顎関節の関節円板前方転位を認めた (図5)。上記所見より低位咬合を伴う左側顎関節の変形性関節症と診断した。咬合高径の挙上を伴う下顎位の修正が必要であることを患者に説明し、同意が得られたため術前の顎運動検査, CT撮影と歯列模型の計測を行った。治療顎位の決定後、上下顎プライマリプロビジョナルレストレーションを製作, 口腔内に装着した。プロビジョナル装着5ヶ月後 (術中) (図5) の顎運動測定をと歯列模型の計測を行った。術前, 術中のVR咬合器を構築し, 設定した治療下顎位の妥当性と機能評価を行った。



図3 術前口腔内写真

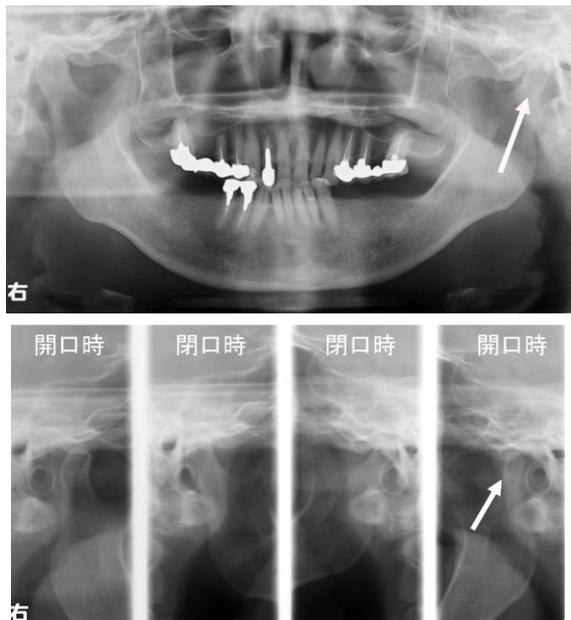


図4 パノラマおよび四分画 X線写真
 上段矢印：左側下顎頭の後上方位を認める
 下段矢印：開口時の並進運動の制限を認める

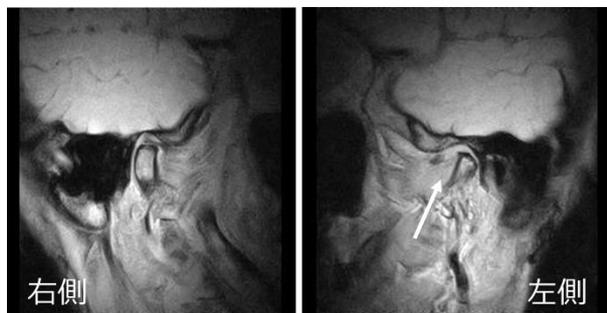


図5 MR画像
 矢印：関節円板の前方転位を認める



図6 術中口腔内写真

3) 治療顎位と顎機能の評価

上顎骨に対する下顎骨の治療顎位と顎機能の評価には全運動軸 (Kinematic Axis:KA) [1]および最小運動軸 (Least Motion Axis:LMA) [2]を用いた。KAは、矢状面における運動範囲は下顎頭付近で最も収斂した軸として表される。KAは顎機能異常者では求められない場合がある。LMAは矢状面における運動範囲が最小になる軸であり、顎機能異常の有無を問わず軸として算出される。顎機能健常者においてKAに対して前方約5mm,下方約30mmの位置に算出される(図7)。KAおよびLMAはshigemotoの方法[3]に準じて自動で算出した。KA, LMAの直線性, 各軸点の運動軌跡および両軸の位置関係より機能の評価した。

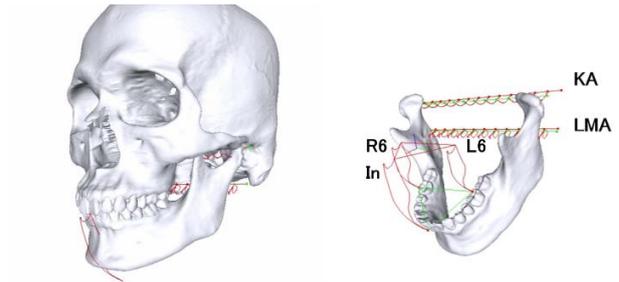


図7 顎機能健常者のKAおよびLMA
 In:切歯点, L6, R6:左側, 右側第一大臼歯中心窩

3. 結果, 考察

形態情報と顎運動情報を統合することで、機能運動時(咀嚼時など)の上顎骨に対する下顎の空間的な位置を仮想空間上で直感的に理解することが可能となった。しかし、下顎位や顎関節の運動範囲を客観的に評価するためには、基準となる解析点, 軸, 平面などを定義する必要がある。今回は、形態情報と顎運動情報上に加えて顎歯列上の3標点(In,L6,R6)とこれらを通る上顎咬合平面および下顎骨の立体運動を表現する運動軸KAとLMAを可視化できるVR咬合器を構築した。

治療顎位：術前の上顎骨を基準として VR 咬合器を用いて評価すると治療顎位では，下顎骨が右側に偏位して開口しているのが視覚的に理解できた．術中の咬頭嵌合位は左側全運動軸点で平均 0.95mm 前下方，右側で平均 1.5mm 下方にあった．切歯点は，術前に対して後方に平均 1.39mm，右側に平均 0.81mm，下方に平均 4.90mm 移動していた（図 8）．

顎機能評価：VR 咬合器を用いて評価すると図 9 に赤丸で示すように，術前では，患側である左側において全運動軸点（KAP）が適切な位置に算出されない場合があった（図 9）．最小運動軸点（LMA）は全ての計測で直線状に分布していた．術中では，3 回全ての計測において KAP および LMA が直線上に算出され，KA に対して LMA は平均約 5.5mm 前方，21.6mm 下方に位置していた（図 10）．治療により KAP が直線状に算出でき KA と LMA の関係に健常者と同様の傾向が認められたことから顎機能が改善したことが示されたと考えられる．

次に，個々の KAP と LMAP の運動軌跡について検討した．術前では，健側である右側において KAP は図 5 に示す顎機能健常者と同様に下に凸の弓状の顎路を移動するが，患側である左側に向かうに従い運動範囲は小さく，顎路は直線的になり，KAP が直線上に算出されなかった（図 9）．下顎位を修正した術中では，KAP は患側である左側においても健側に近い形態の顎路上を移動していた．LMA は術前，術中ともに直線上に分布していたが，個々の運動範囲を観ると患側の左側ほど運動範囲が小さくなっている．これは左側下顎頭の並進運動が制限され主として回転運動で開口量を担保していたと考えられる．

術中は術前に対し左側での LMAP の運動範囲が広がっていることから下顎位を修正することで，左側下顎頭が並進運動できるように改善したと考えられる．CT 画像より得られた三次元モデルは，

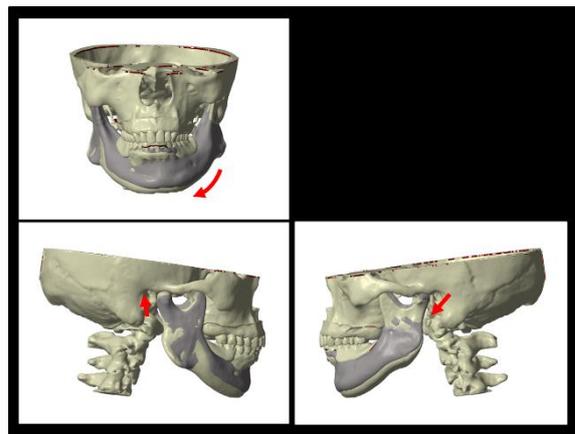


図 8 治療顎位の評価
術前の下顎骨をグレーで示す

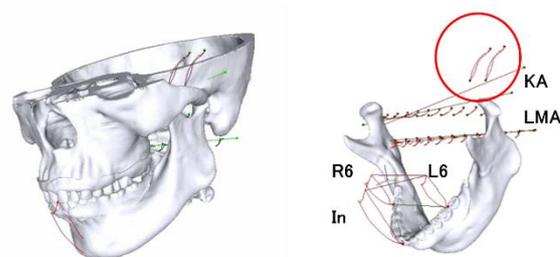


図 9 術前時の KA と LMA（KA 非算出例）

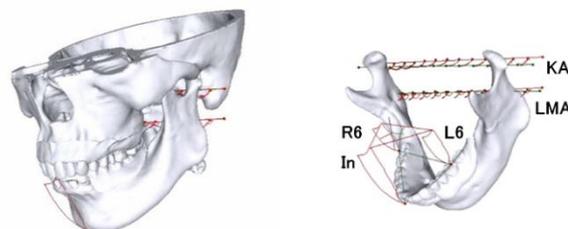


図 10 術中の KA と LMA

術前，術中の上顎に対する下顎の位置の変化を仮想空間上で可視化できる．

また三次元モデルに運動情報を統合することで，治療顎位の妥当性や顎口腔系の機能に改善状態を客観的に評価することができた．これにより最終的な治療開始次期を客観的に決定できることから，VR 咬合器が日常歯科臨床において有用であることが示された．

利益相反の有無

なし

文 献

- [1] 河野正司：下顎の矢状面内運動に対応する顎頭運動の研究 第二報マルチフラッシュ装置による矢状面運動軸の解析. 補綴誌 1968; 12, 350-380.
- [2] Hirai S, et al: relationship between the mandibular movements and deformation of the Coronoid process and the Condyle. J Jpn Assoc Oral Rehabil 2016; 29: 35-46.
- [3] Shigemoto S, et al. :Effect of an exclusion range of jaw movement data from the intercuspal position on the estimation of the kinematic axis point. Medical Engineering and Physics 2014; 36(9): 1162-1167.

Development of virtual articulator utilizing

CT data and jaw kinematic data

Takahiro ITO*¹, Shuji SHIGEMOTO*¹, Mitsuhiko ITO*¹, Takuya KIHARA*¹,
Tomoko IKAWA*¹, Yuko SHIGETA*¹, Takumi OGAWA*¹

*1 Department of Fixed Prosthodontics, Tsurumi University School of Dental Medicine

We developed a virtual reality (VR) articulator technique that can reproduce exact structure and function of masticatory system for individual patients and be used easily in a dental clinical setting. The cranium and mandible models are created from CT scan data, and the upper and lower dental surface models are created using a noncontact 3D laser scanner. Jaw movements are measured using an electromagnetic jaw tracking device. This technique requires accurate methods combining three-dimensional (3D) imaging and jaw movement data. By transforming these imaging and jaw tracking data into one coordinate system, structure and function of masticatory system of individual patients can be visualized in computer graphics.

In this study, we evaluated the treatment planning and status of masticatory function in osteoarthritis of the temporomandibular joint by applying VR articulator technique, and then found its high usability in dental practice.

Key words: computed tomography, jaw movement, virtual reality articulator

グラフ畳み込みニューラルネットワークを用いた

腹部動脈血管名自動命名の初期検討

日比 裕太*¹ 林 雄一郎*¹ 北坂 孝幸*² 伊東 隼人*¹

小田 昌宏*¹ 三澤 一成*³ 森 健策*^{1,4,5}

要旨

本稿では、3次元腹部CT像から抽出された腹部動脈領域に対してグラフ畳み込みニューラルネットワークを用いた血管名自動命名についての検討を行ったので報告する。血管は構造が複雑で個人差が大きく、その構造の把握は困難である。血管名を自動命名することにより医師が外科手術の際に患者の血管構造を把握する助けとなり、医師の負担を軽減することができる。そのため、これまで腹部動脈領域に対して機械学習を用いた血管名自動命名を行う手法がいくつか提案されてきた。また、近年ではグラフ構造に対する機械学習が盛んに行われており、その有用性が示されている。そこで本稿では、血管構造をグラフ構造と捉え、血管が持つ太さや長さ、腹部臓器との位置関係などを特徴量としてグラフ畳み込みニューラルネットワークを用いた機械学習による血管名自動命名を行った。100症例のCT像に対して血管名自動命名を行った結果、平均精度は85.2%であった。

キーワード：血管，グラフ畳み込みニューラルネットワーク，3次元CT像，解剖学的名称認識，血管構造解析

1. はじめに

外科手術を行う際には、患者の正確な血管構造を術前に得られる3次元腹部CT像から把握することが重要である。これまでも腹部動脈領域に対して自動命名を行う手法がいくつか提案されてきた。鉄村らは血管に対する解剖学的名称自動命名を、木構造として表現された血管領域全体にわたる各血管枝の血管ラベル推定問題として捉え、条件付確立場を用いた機械学習により自動命名を行った[1]。また、近年盛んに研究されているグラフ構造における

機械学習は、ソーシャルネットワーク解析・創薬・材料科学などの多岐にわたる分野でその有用性を示している。そこで、本稿では血管木構造をグラフと捉え、グラフ畳み込みニューラルネットワークを用いた血管名自動命名手法について検討する。

2. 手法

本手法は従来手法[1]と同様に、3次元腹部CT像から腹部動脈領域の木構造の構築、および各血管枝が持つ特徴量を抽出する。特徴量には、血管の長さや直径、血管を除く7つの臓器（肝臓、脾臓、右腎、左腎、胃、胆嚢、膵臓）とのユークリッド距離および方向ベクトルなどを使用する。

学習と推定にはグラフ畳み込みニューラルネットワークであるMoNet[2]を用いる。グラフ畳み込みとは、グラフ上の注目ノードとその隣接ノードの特徴量を集約し、フィルタをかけることで次の層のノードの特徴量とするものである。本手法では、血管木構造を重みなし無向グラフと捉えMoNet[2]を適用する。このグラフ

*1 名古屋大学大学院情報学研究科
〔〒464-8601 名古屋市千種区不老町〕

e-mail: yhibi@mori.m.is.nagoya-u.ac.jp

*2 愛知工業大学情報科学部

*3 愛知県がんセンター

*4 名古屋大学情報基盤センター

*5 国立情報学研究所 医療ビッグデータ研究センター

では、各血管枝をノード、血管枝が持つ特徴量をノードの特徴量、血管枝の接続関係をノード間の接続関係に対応させる。入力には、ノードの接続関係と各ノードの特徴量及び学習用の正解ラベルデータを使用する。ネットワークは2回のグラフ畳み込みの後に softmax 関数によるクラス分類を行い、各ノードについてその推定ラベルを出力する。

3. 実験と結果

本稿では、腹腔鏡下手術を行う際に重要となる22種類の腹部動脈を主な自動対応付けの対象とする。また、ラベルの推定には前述の22種類の血管とそれ以外の血管を含め、全45種類を対象とする。この学習と推定には MoNet[2]を使用し、初期学習率は0.01、結果は3000epoch学習後のものとする。実験には3次元腹部CT像から半自動で抽出した血管領域画像100症例に対して10分割交差検定法を用い、自動命名をおこなった。精度の評価にはF値を使用した。血管名自動命名精度は平均85.2%であり、従来手法[1]の平均精度95.7%には及ばなかった。また、提案手法による自動命名結果を表1に、自動命名結果の例を図1に示す。

4. 考察

表1のように自動命名精度が平均85.2%であったことは、グラフ畳み込みニューラルネットワークを用いた血管名自動命名手法の初期検討としては十分な成果であり、本手法の有用性を示すことができたといえる。しかし、図1からわかるように、推定結果に出現しない血管がある。これは血管によってノード数に偏りがあり、数が少ない血管については精度が低いと考えられる。精度向上にはこの問題について考慮した学習データの調整が必要であるといえる。

5. むすび

本稿では、グラフ畳み込みニューラルネットワークを用いて3次元腹部CT像から抽出した

動脈領域に対する自動命名手法の検討を行い、その有用性を確認した。今後は精度の向上を図るとともに、血管の全自動抽出結果への手法の適用も検討し、半自動抽出結果に適用したものと同程度の精度となる手法の構築を目指す。

謝辞

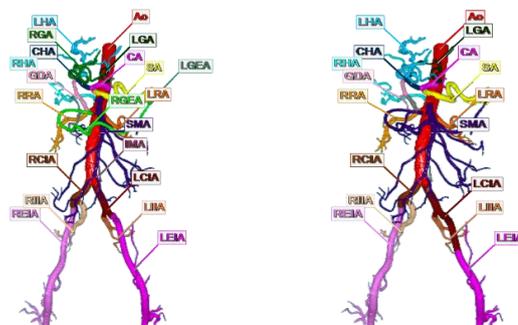
日頃から熱心に御討論頂く名古屋大学森研究室の諸氏に感謝する。本研究の一部は科研費17H00867, 17K20099, 26560255, 26108006, AMED191k1010036h0001, 堀科学芸術振興財団, JSPS 二国間交流事業によった。

利益相反の有無

なし。

文献

- [1] 鉄村悠介, 林雄一郎, 小田昌宏 他: 機械学習を用いた腹部動脈血管名自動命名におけるデータ拡張法の適用に関する検討. 信学技報 **118**: 191-196, 2019
- [2] Monti F, Boscaini D, Masci J, et al.: Geometric Deep Learning on Graphs and Manifolds Using Mixture Model CNNs. CVPR: 5115-5124, 2017



(a) 正解データ

(b) 推定結果

図1 血管名自動命名例 (同じ色は同じラベル。(a)で存在するRGEA, RGA, LGEAが(b)では出現しない。)

表1 提案手法による各データセットの自動命名精度

データセット	1	2	3	4	5	6	7	8	9	10	平均
F値 (%)	82.9	80.9	85.5	86.5	84.2	86.6	83.4	87.3	85.6	86.9	85.2

Study on Automated Anatomical Labeling of Abdominal Arteries Using Graph Convolutional Neural Network

Yuta HIBI^{*1}, Yuichiro HAYASHI^{*1}, Takayuki KITASAKA^{*2},
Hayato ITOH^{*1}, Masahiro ODA^{*1}, Kazunari MISAWA^{*3} and Kensaku MORI^{*1,4,5}

*1 Graduate School of Informatics, Nagoya University

*2 Faculty of Information Science, Aichi Institute of Technology

*3 Aichi Cancer Center Hospital

*4 Information Technology Center, Nagoya University

*5 Research Center for Medical Bigdata, National Institute of Informatics

In this paper, we report an automated anatomical labeling using graph convolution neural networks for abdominal artery regions extracted from 3D abdominal CT images. Because the structure of the blood vessels is complex and individual differences are large, understanding it is difficult. The automated anatomical labeling of the blood vessels can help surgeons to understand the patient's blood vessel structure in surgery, thus reducing the burden on surgeons. Therefore, several automated blood vessel labeling techniques have been proposed using machine learning for the abdominal artery region. In recent years, machine learning for graph structures has been actively studied, and its usefulness has been shown. In this paper, we considered blood vessel structure as graph structure, and examined blood vessel automated anatomical labeling by machine learning using graph convolution neural networks that utilize feature values including the thickness and length of blood vessels and positional relationships of them to abdominal organs. As a result of automated anatomical labeling for CT volumes of 100 cases, the average accuracy was 85.2%.

Key words: Blood vessel, Graph convolutional neural network, CT volume, Anatomical names recognition, Blood vessel structures analysis

FCN を用いた骨シンチグラムにおける骨格認識処理の改良

星野 ゆり*¹ 齊藤 篤*¹ 大崎 洋充*² 吉田 敦史*³ 東山 滋

明*³ 河邊 讓治*³ 清水 昭伸*¹

要旨

本報告では、前後面のラベルを同時に入力可能な butterfly 型の fully convolutional network (FCN)を用いた骨シンチグラム上の骨格認識処理の改良について報告する。提案手法では、従来の手法により認識された前後面の骨格ラベルと確率マップの画像、および、骨格の正解ラベルを用いて FCN の学習を行う。この学習済みネットワークに未知症例に対する従来の前後面の骨格認識ラベルを入力することで、ラベルに含まれる誤りを訂正する。本稿では、提案手法を実際の 246 症例に対する従来手法による骨格認識ラベルに適用した結果について示し、提案手法の有効性や限界について議論する。

キーワード：骨シンチグラム、骨格認識、butterfly 型ネットワーク、全畳み込みネットワーク

1. はじめに

骨シンチグラム上の骨転移による異常集積の検出は容易ではなく[1]、コンピュータによる検出支援が求められている。本研究室で開発したシステムは、骨格認識と異常集積検出の2つの処理からなり[2][3]、医師による病変の検出を支援する。従来の骨格認識処理[2]では、高濃度の異常集積の存在や骨の向きや形状の違いが原因で認識に失敗することがあった。

本稿では、butterfly 型の fully convolutional network(FCN)[4]を用いた改良法について提案する。また、提案法を実際の症例 246 症例を用いて性能評価した結果についても報告する。

2. butterfly 型の FCN を用いた誤りの訂正

提案法は、従来の骨格認識処理の出力ラベル (128×576 pixel) を入力とし、図 1 に示すネットワークによりラベルに含まれる誤りを訂正する。前後面のラベル画像を同時に処理するために、butterfly 型をしており、U-Net と同様に encoder 側から decoder 側に向けてリンクを張っ

た。encoder では、convolution と max-pooling を 3 回繰り返した後、前後面の特徴マップを結合し、さらに convolution と max-pooling を 2 回行う。decoder では、encoder 側と同じ回数の convolution と up sampling (deconvolution) を繰り返し、入力画像と同サイズの画像を、対象の骨格数に 1 (背景) を加えた数だけ出力する。なお、全ての convolution と deconvolution では batch normalization と ReLU 関数を使用した。ネットワーク構造を図 1 に示す。

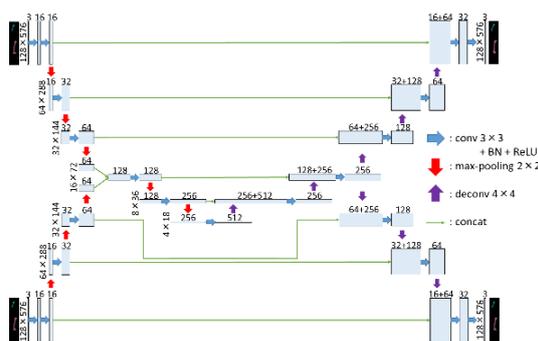


図 1 butterfly 型の FCN

ネットワークの学習の損失関数にはソフトマックスロスエントロピーを用いた(式(1))。

$$Loss = -\frac{1}{N} \sum_{i=1}^N t_i \log \left(\frac{e^{y_i}}{\sum_{i=1}^N e^{y_i}} \right) \quad (1)$$

ここで、 N は総クラス数、 i は各クラスを表す変数であり、 t_i は正解ラベル、 y_i は出力である。

提案手法では、学習データ数を補うために、

*1 東京農工大学大学院工学研究院

[〒184-8588 東京都小金井市中町 2-24-16]

e-mail: s191637v@st.go.tuat.ac.jp

*2 群馬県立県民健康科学大学大学院診療放射線学研究科

*3 大阪市立大学医学部附属病院核医学科

従来の認識結果のラベルだけでなく、ラベルにする前の確率の画像も利用し、また、ラベルや確率画像の反転を行った。さらに、汎化性を高めるために、encoder側とdecoder側を結ぶリンクに対して dropout[5]を行った。

3. 実験条件と実験結果

3.1 実験条件

試料画像には、骨シンチグラム 246 症例 492 枚 (512*1024[pixel], 2.8[mm/pixel]) を用い、入力には従来の処理による骨格認識ラベル (大腿骨と上腕骨) とした。評価値は、3-fold CV 法でテスト症例に対して計算した dice score(DS), 連結成分数(8 連結)と穴の数(4 連結)の、正解との差分値#(Δ connected component (Δ CC)), #(Δ hole)とした。学習時のミニバッチ数は 16, optimizer には adam[6]を使用し、パラメータは $\alpha=0.001, \beta_{-1}=0.9, \beta_{-2}=0.999$ とした。

3.2 実験結果・考察

提案手法を全例に適用した結果を表 1 に示す。また、平均#(Δ CC)が減少した例を図 2 に示す。

表 1 全症例適用結果

手法	平均 DS	平均 #(Δ CC)	平均 #(Δ hole)
従来[2]	0.8685	0.1688	0.08025
提案	0.8682	0.0742	0.03455

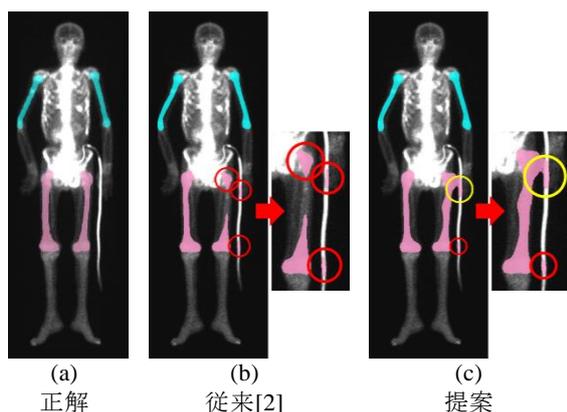


図 2 骨格認識改良結果例

表 1 より、平均 DS は先行研究よりも低下しているが、平均#(Δ CC)と平均#(Δ hole)は減少している事が分かる。また、図 2 より、改良前は #(Δ CC)は 3 個であった (図 2(b)赤丸) が、提案

法により 1 個 (図 2(c)赤丸) に減少した事が分かる。しかし、黄丸で示すように、拾いすぎにより不自然な結果が得られるなどの問題も確認された。

4. まとめ

本稿では、butterfly 型のネットワークによる骨格認識処理の改良を提案した。また、本手法により、平均#(Δ CC), 平均#(Δ hole)を削減することができたが、解剖学的に不自然な形状に再構成してしまう症例も存在した。今後は、不自然な形状になるのを防ぎつつ平均 DS の向上および平均#(Δ CC), 平均#(Δ hole)を零に近づけるために、損失関数や入力画像を工夫することにより、さらなる改良精度向上を行う予定である。

文献

- [1] 小野慈: 骨シンチによる骨転移診断. 南江堂, 東京, 2002, pp1-30
- [2] 金森巧: “骨シンチグラムからの解剖学的骨格認識処理の改良”. 東京農工大学修士論文, 2019
- [3] H. Wakabayashi, A. Saito, S. Higashiyama, J. Kawabe, S. Shiomi, A. Shimizu, “Detection of bone metastasis in a scintigram using U-Net,” Proc. of Computer Assisted Radiology and Surgery(CARS 2018), Berlin, Germany, S260 June 2018.
- [4] A. Sekuboyina, M. Rempfler, J. Kukačka, G. Tetteh, A. Valentinitich, J. S. Kirschke, B. H. Menze, “Btrfly Net: Vertebrae Labelling with Energy-based Adversarial Learning of Local Spine Prior”, arXiv: 1804. 01307, 2018
- [5] Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, Ruslan Salakhutdinov” Dropout: A Simple Way to Prevent Neural Networks from Overfitting”, Journal of Machine Learning Research 15, 2014
- [6] D. P. Kingma, J. Ba, “Adam: A Method for Stochastic Optimization”, 3rd International Conference for Learning Representations, San Diego, 2015

Improvement of skeleton recognition from a bone scintigram using a FCN

Yuri HOSHINO^{*1}, Atsushi SAITO^{*1}, Hiromitsu DAISAKI^{*2}, Atsushi YOSHIDA^{*3}, Shigeaki HIGASHIYAMA^{*3},
Joji KAWABE^{*3}, Akinobu SHIMIZU^{*1}

*1 Tokyo University of Agriculture and Technology

*2 Gunma Prefectural College of Health Sciences

*3 Osaka City University Hospital

Abstract:

This paper reports an improvement of skeletal recognition process using a butterfly type fully convolutional network (FCN) which allows simultaneous input of both anterior and posterior skeleton labels. The proposed network is trained using anterior and posterior skeleton labels and their probability maps recognized by the previously proposed approach as well as true labels of skeletons. The errors in anterior and posterior skeleton labels by the previously proposed approach will be corrected by the trained network. This paper presents the results of applying the proposed network to the skeleton labels of 246 cases and discuss the effectiveness and limitation of the proposed method.

Key words: bone scintigram, skeleton recognition, butterfly type network, fully convolutional network

Mask R-CNN を用いた小児胸部 X 線画像における

肺領域の自動抽出

魚住 春日*¹ 松原 尚輝*¹ 寺本 篤司*¹ 日木 あゆみ*²

本元 強*² 河野 達夫*³ 齋藤 邦明*¹ 藤田 広志*⁴

要旨

小児には肺炎の高い感染、重症化のリスクが存在するため、正確な診断や治療が早急に求められる。そこで本論文では、小児肺炎などの胸部疾患を対象としたコンピュータ支援診断システムの開発を目的に、解析領域である肺野の抽出手法を提案する。肺野の抽出には Deep learning の一種で、物体検出と領域抽出を同時に行う Mask R-CNN を用いた。Mask R-CNN の学習には ChestX-ray8 データベースより選択した小児 200 枚、成人 800 枚の合計 1000 枚の胸部 X 線画像を用いた。肺炎と診断された小児の胸部 X 線画像を用いて検証したところ、Jaccard index の平均値は 93.1%、Dice index の平均値は 96.4%となり、高い肺野抽出精度が確認された。

キーワード：人工知能、コンピュータ支援診断、胸部 X 線画像、肺野抽出、小児

1. はじめに

免疫力が低く、集団生活の中にいることが多い小児は、肺炎への感染や重症化のリスクが高い。そして WHO の調査によると 5 歳未満の小児の死因の 16%を肺炎が占めている[1]。肺炎が疑われると胸部 X 線検査が行われるが、小児はポジショニングが難しいうえに、成長に伴い肺野が大きく変化するため再現性の低い画像となる。そのため医師は症状だけでなく、年齢など様々な条件を考慮したうえで診断を下しており、その負担は大きい。また、小児にみられる疾病は種類が多い一方で発生数が少ないため、1 つの疾病に対する医師の経験が不足しやすい[2]。

現在までに肺炎をはじめとする胸部疾患を対象としたコンピュータ支援診断技術(以下 CAD)が複数報告されているが、小児を対象としたものはない。

小児を対象とした胸部 X 線画像による CAD システムの実現に向けた最大の課題は、肺野の位置、大きさ、FOV など多様な像が存在することである。そのため、解析領域を肺野に限定す

るために肺野の抽出が必要となる。

肺野の抽出は肺野内の病変検出において必要不可欠な処理であり、様々な胸部 CAD で用いられている。これまでにヒストグラムを用いた閾値処理による手法[3]や、解剖学的特徴に基づいて特異点を設置し、その特異点における閾値を利用した手法[4, 5]、パターン認識や特徴量解析に基づいて肺野の境界を決定する手法[6]

*1 藤田医科大学大学院保健学研究科
〔〒470-1192 愛知県豊明市沓掛町田楽ヶ窪 1 番地 98〕

e-mail: teramoto@fujita-hu.ac.jp(寺本篤司)

*2 茨城県立こども病院 〔〒311-4145 茨城県水戸市双葉台 3 丁目 3-3 番地 1〕

*3 東京都立小児総合医療センター 〔〒183-8561 東京都府中市武蔵台 2 丁目 8-29〕

*4 岐阜大学 工学部 電気電子・情報工学科 〔〒501-1112 岐阜県岐阜市柳戸 1-1〕

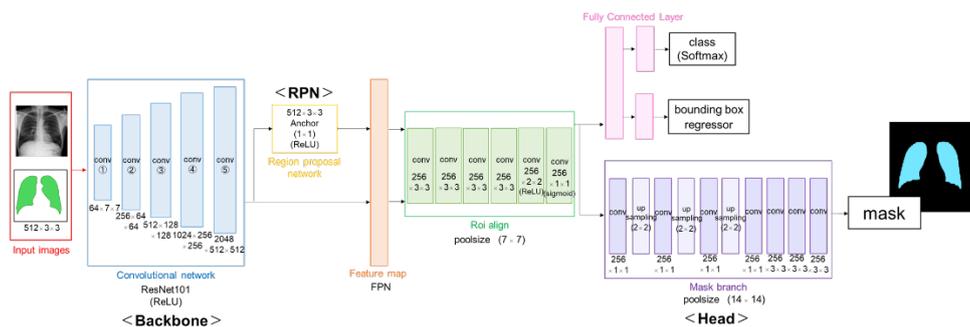


図1 Mask R-CNN のアーキテクチャ

などが報告され、病変検出精度に大きく貢献している。しかし、いずれも肺野の境界に関する一般的な仮定や統計的な特徴に基づいた手法であるため、前述したように多様な像が存在する小児胸部 X 線画像には適した方法でない。また近年、高い物体認識力をもつ Deep learning を用いた手法が報告されている。Deep learning における Semantic segmentation 技術には FCN(Fully Convolutional Networks)[7], U-net[8], Segnet[9]などがある。Rabia Rashid らは FCN を用いた肺野抽出手法を報告した[10]。247 枚の胸部 X 線画像を含む Japanese Society of Radiological Technology(JSRT)データセットと Montgomery County データセットと独自で作成したデータセットの 3 つを用い、各データセットを FCN の学習用とテスト用に 3:2 に分け 10 分割交差検証を行った。その結果、それぞれ 97.1%, 97.7%, 94.2%の肺野抽出精度が得られた。Alexey A. Novikov らは U-net をベースに、パラメータによる最適化を試みた[11]。JSRT データセットを用いて 3 分割交差検証を行った結果、U-net に Dropout を適用した場合が最も高精度で、Jaccard index は 94.8%となった。また、Wei Dai らは FCN によって生成されたマスクと Gold standard を敵対させ、精度を高めるネットワークを構築し、FCN を単独で用いた場合よりも物体検出精度の指標である Intersection over Union(IoU)が 4.3%向上したことを報告している[12]。Jyoti Islam らは、学習させる 758 枚の胸部 X 線画像を拡大、トリミング、反転などの処理を加え Data augmentation を行ったのち U-net の学習を行い、98.6%の肺野抽出精度が得られた[13]。

Youbao Tang らは、Multimodal Unsupervised Image-to-image Translation (MUNIT) を用いた Data augmentation と Semantic segmentation 技術の一つである Criss-Cross Network (CCNet)[14]による肺野抽出手法を発表し、U-net を用いた場合よりも正確に肺野が抽出された[15]。上記のように様々な手法が考案されているがいずれも小児を対象としたものではない。

そこで本研究では、Deep learning 手法のひとつであり、Object detection と Instance segmentation を同時に行う Mask R-CNN[16]を用いて小児胸部 X 線画像における肺野の自動抽出を試みた。

2. 方法

2-1. Mask R-CNN のモデル

本研究で使用した Mask R-CNN の構造を図 1 に示す。Backbone は ResNet101 で構成され、入力画像に対する特徴マップを出力する。その後 RPN にて、この特徴マップを用いながら Bounding box を決定する。Backbone は非常に深いネットワークであるため入力画像が荒くなってしまう。そこで FPN[17]にて、入力画像をアップサンプリングすることで解像度を回復する。Roi align layer では Bounding box の pixel レベルでの位置ずれを補正し、Head にて Bounding box 内の Segmentation を行う。なお Head は畳み込み層 7 層の FCN で構成されている。

2-2. Mask R-CNN の学習

Mask R-CNN の学習には NIH が公開している ChestX-ray8 データベース[18]を使用した。このデータベースから肺野を明確に定義することができる成人の胸部 X 線画像 800 枚、小児の画

像を 200 枚の合計 1000 枚をランダムに選択し、抽出対象である肺野領域のみを一定のラベル値で塗りつぶしたラベル画像を作成し、原画像とのペアを学習データとした。初期重みには、Microsoft COCO(MS COCO)[19]により学習された重みを用い、独自に作成した学習データによってネットワーク全体を再度学習することで、重みを更新した。学習環境を表 1 に示す。

表 1 学習環境とパラメータ

学習環境	使用機器	CPU : Core i7 7700k
		GPU : NVIDIA GeForce GTX 1080Ti
		メインメモリ : 16GB
		OS : Ubuntu 16.04 LTS
パラメータ	学習回数	150 回
	画像サイズ	512×512
パラメータ	学習係数	0.001
	最適化手法	SGD

3. 検証

本手法による肺野抽出には ChestX-ray8 データベースに保存されている肺炎と診断された 0～15 歳までの胸部 X 線画像 17 症例を用いた。Mask R-CNN における肺野抽出精度を評価するため、正解画像と出力画像の類似度を評価した。定量評価には 2 つの集合の類似度を表す Jaccard index[20] と Dice index を用いた[21]。

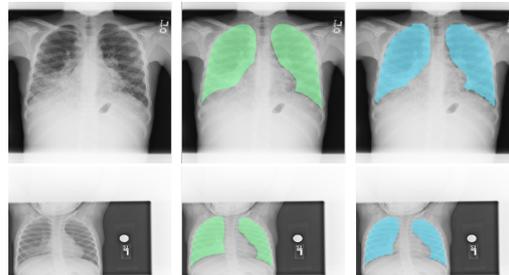
$$Jaccard\ index = \frac{|A \cap B|}{|A \cup B|} \quad (1)$$

$$Dice\ index = \frac{2|A \cap B|}{|A| + |B|} \quad (2)$$

4. 結果と考察

本手法による肺野抽出結果の一例を図 2 に示す。Jaccard index の平均値は 93.1%，Dice index の平均値は 96.4% となり、肺野の大部分が正確に抽出された。炎症の程度や肺野の大きさに依存することのない良好な結果が得られたが、肺野の境界部分の検出が不十分である傾向が確認された。これは肺野抽出技術において共通の課題であるが、肺尖、肺底部、縦郭との境界部のコントラストが不鮮明であ

ることが原因である。しかし、この課題はスムージング処理やダイレーション処理を行うことで容易に改善できる課題であると考えられる。



(a) 入力画像 (b) 正解画像 (c) 出力画像
図 2 Mask R-CNN による肺野抽出結果

3. まとめ

小児胸部 X 線画像における肺野抽出を Mask R-CNN を用いて行った。その結果、炎症の程度や肺野の大きさに影響されることなく、良好な検出結果が得られた。

利益相反の有無

なし

文献

- [1] World Health Organization: WHO: Pneumonia. 2015 <https://www.who.int/en/news-room/fact-sheets/detail/pneumonia>
- [2] 相田典子：小児科領域における医療技術を考える。映像情報メディカル 47/13 2015 年 12 月号: 1138-1142, 2015
- [3] Samuel G.Armato, Maryellen L.Giger, Heber MacMahon: Automated lung segmentation in digitized posteroanterior chest radiographs Author links open overlay pane. Academic Radiology 5: 245-255, 1998
- [4] Matthew S.Brown, Laurence S.Wilson, Bruce D.Doust, Robert W.Gill, et al.: Knowledge-based method for segmentation and analysis of lung boundaries in chest X-ray images. Computerized Medical Imaging and Graphics 22: 463-477, 1998

- [5] Á. Horváth, G. Horvath: Segmentation of Chest X-ray Radiographs, a New Robust Solution. *IFMBE Proceedings***37**: 655-658, 2011
- [6] L Li, Y Zheng, M Kallergi, et al.: Improved method for automatic identification of lung regions on chest radiographs. *Academic Radiology***8**: 629-638, 2001
- [7] Long, Jonathan, Evan Shelhamer, Trevor Darrell: Fully Convolutional Networks for Semantic Segmentation. *Proceedings of the IEEE conference on computer vision and pattern recognition*: 3431-3440, 2015
- [8] Ronneberger, Olaf, Philipp Fischer, Thomas Brox: U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention***9351**: 234-241, 2015
- [9] Badrinarayanan, Vijay, Alex Kendall, Roberto Cipolla: SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE transactions on pattern analysis and machine intelligence***39**: 2481-2495, 2017
- [10] R. Rashid, M. U. Akram, T. Hassan: Fully Convolutional Neural Network for Lungs Segmentation from Chest X-Rays. *Image Analysis and Recognition***10882**: 71-80, 2018
- [11] Alexey A. Novikov, Dimitrios Lenis, David Major, et al.: Fully Convolutional Architectures for Multiclass Segmentation in Chest Radiographs. *IEEE transactions on medical imaging***37**: 1865-1876, 2018
- [12] Wei Dai, Joseph Doyle, Xiaodan Liang, et al.: SCAN: Structure Correcting Adversarial Network for Organ Segmentation in Chest X-rays. *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support, Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support***11045**: 263-273, 2017
- [13] Jyoti Islam, Yanqing Zhang: Towards Robust Lung Segmentation in Chest Radiographs with Deep Learning. *arXiv preprint arXiv:1811.12638*: 2018
- [14] Zilong Huang, Xinggang Wang, Lichao Huang, et al.: Ccnet: Criss-cross attention for semantic segmentation. *arXiv preprint arXiv:1811.11721*: 2018.
- [15] You-Bao Tang, Yu-Xing Tang, Jing Xiao, et al.: XLSor: A Robust and Accurate Lung Segmentor on Chest X-Rays Using Criss-Cross Attention and Customized Radiorealistic Abnormalities Generation. *MIDL 2019 Conference Full Submission*: 1-11, 2019
- [16] Kaiming He, Georgia Gkioxari, Piotr Dollar, et al.: Mask R-CNN. *Proceedings of the IEEE international conference on computer vision*: 2961-2969, 2017
- [17] Tsung-Yi Lin, Piotr Dollar, Ross Girshick, et al.: Feature pyramid networks for object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*: 2117-2125, 2017
- [18] Xiaosong Wang, Yifan Peng, Le Lu, et al.: Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. *Proceedings of the IEEE conference on computer vision and pattern recognition*: 2097-2106, 2017
- [19] Tsung-Yi Lin, Michael Maire, Serge Belongie, et al.: Microsoft coco: Common objects in context. *European conference on computer vision***8693**: 740-755, 2014
- [20] P. Jaccard: Distribution comparée de la flore alpine dans quelques régions des Alpes occidentales et orientales. *Bulletin de la Soci et e Vaudoise des Sciences Naturelles***37**: 81-32, 1902
- [21] Dice, Lee R.: Measures of the amount of ecologic association between species. *Ecology***26**: 297-302, 1945

Lung Region Segmentation on Pediatric Chest X-rays using Mask R-CNN

Haruka UOZUMI^{*1}, Naoki MATSUBARA^{*1}, Atsushi TERAMOTO^{*1}, Ayumi NIKI^{*2}, Tsuyoshi HONMOTO^{*2},
Tatsuo KONO^{*3}, Kuniaki SAITO^{*1}, Hiroshi FUJITA^{*4}

*1 Graduate School of Health Sciences, Fujita Health University

*2 Ibaraki Prefectural Children's Hospital

*3 Department of Radiology, Tokyo Metropolitan Child Medical Center

*4 Department of Electrical, Electronic & Computer Engineering, Gifu University

Children have a high risk of pneumonia infection due to low immunity and collective life living in a group, so accurate diagnosis and early treatment are required. The purpose is to develop the decision support system for thoracic diseases using chest X-ray images in this paper. And as a pilot study, we propose extraction of the lung region using Mask R-CNN. Mask R-CNN is a kind of deep learning and perform object detection and segmentation at the same time. 1000 images including 200 child images and 800 adult images were used to train Mask R-CNN.

High accuracy of lung field extraction has been confirmed even if various chest X-ray images of children such as lung field size exist, average of Jaccard index was 93.1% and Dice index was 96.4%.

Key words: Artificial intelligence, CAD, Chest X-ray image, Lung segmentation, Pediatrics

深層学習を用いた非造影 CT 画像からの 複数臓器領域の抽出に関する検討

林 雄一郎^{*1} 申 忱^{*1} Holger R. Roth^{*1} 小田 昌宏^{*1}

三澤 一成^{*2} 森 健策^{*1,3,4}

要旨

本稿では深層学習を用いた非造影 CT 画像からの複数臓器領域の抽出について述べる。医用画像解析において医用画像から人体の解剖学的構造を自動認識することは重要な処理である。我々はこれまで深層学習を用いて造影 CT 画像から複数の臓器領域を自動抽出する研究を行ってきた。医療現場では、非造影の CT 画像も数多く使用されているため、非造影の CT 画像からも複数臓器領域を自動抽出することができれば非常に有用である。本研究では、従来研究と同様に 3D U-net を用いて非造影 CT 画像から複数臓器領域を自動抽出する。学習の際に、従来研究において造影 CT 画像を用いて学習したモデルを初期値とし、非造影 CT 画像を用いてファインチューニングを行う。実験の結果、ファインチューニングした 3D U-net により非造影 CT 画像から複数臓器領域を抽出できることを確認した。

キーワード：セグメンテーション、ディープラーニング、U-net、ファインチューニング、CT 画像

1. はじめに

コンピュータ支援診断 (Computer Aided Diagnosis; CAD) システムやコンピュータ支援外科 (Computer Aided Surgery; CAS) システムにおいて様々な機能を実現するためには、医用画像中の人体の解剖学的構造を自動認識することは重要である。そのため、これまでに医用画像から様々な解剖学的構造を自動抽出する研究が行われてきた。腹部領域におい

ても、CT 画像から複数の臓器領域を自動抽出する手法が複数の研究グループから報告されている [1-5]。我々の研究グループにおいても、深層学習を利用した複数臓器領域の自動抽出手法を提案してきた [4, 5]。この手法では門脈相の造影 CT 画像を対象としていたが、医療の現場では造影された CT 画像に加えて非造影の CT 画像も数多く撮影されているため、非造影の CT 画像からも臓器領域を自動抽出することができれば非常に有用である。そこで本稿では、これまで我々の研究グループで開発してきた 3D U-net を用いた複数臓器領域の自動抽出手法を用いて非造影 CT 画像からの複数臓器領域の自動抽出を検討したので報告する。

*1 名古屋大学大学院情報学研究科
〔〒464-8601 名古屋市千種区不老町〕
e-mail: yhayashi@mori.m.is.nagoya-u.ac.jp

*2 愛知県がんセンター消化器外科

*3 名古屋大学情報基盤センター

*4 国立情報学研究所医療ビッグデータ
研究センター

2. 提案手法

提案手法では、3D U-net を用いた造影 CT

画像からの複数臓器領域の抽出手法 [4, 5] を基にして、非造影 CT 画像から動脈、門脈、肝臓、脾臓、胃（内部）、胆嚢、膵臓の 7 つの臓器領域を抽出する。従来研究では 340 画像と多数の造影 CT 画像を用いて学習を行っていたため、得られた学習済みモデルは、非造影 CT 画像からの臓器抽出においても有用であると考えられる。そこで提案手法においても 3D U-net を用いて非造影 CT 画像から複数臓器領域の抽出を行う。学習では、従来研究で得られた学習済みのモデルを初期値とし、非造影 CT 画像を用いてファインチューニングする。また、学習の際には学習データを増加させるために、入力画像に平行移動、回転、B スプラインを用いた非剛体変形を適用してデータ拡張を行う。

3. 結果ならびに考察

44 症例の非造影 CT 画像を、30 症例の学習用画像と 14 症例の評価用画像に分割して実験を行った。CT 画像の仕様は、画像サイズ 512pixel×512pixel、画素サイズ 0.625mm～0.812mm、スライス枚数 488 枚～663 枚、スライス厚 1.0mm、再構成間隔 0.8mm である。実験ではディープラーニングのフレームワークとして Keras [6] を用いた。また、非造影 CT 画像から血管領域を抽出することは困難であることが多いため、同一症例の動脈相と門脈相の造影 CT 画像と非造影 CT 画像との非剛体レジストレーションを行い、位置合わせされた複数時相の CT 画像を用いて臓器の正解ラベル画像を作成した。

抽出結果のボリュームレンダリング表示を図 1 に示す。ここでは、2 症例のファインチューニング前後のモデルによる抽出結果を、胃領域を除いて示している。また、Dice 係数を用いて抽出結果を評価したところ、ファインチューニング前の平均 Dice 係数は 0.69、ファインチューニング後の平均 Dice 係数は 0.79 であった。表 1 に各臓器領域の平均 Dice 係数を示す。図や表から非造影 CT 画像を用いて、造影 CT 画像で学習済みのモデルをファ

インチューニングすることで抽出精度が向上したことが確認できる。特に、血管領域は抽出精度の向上が大きいことが確認できる。また、造影 CT 画像を用いて学習したモデルでも肝臓や脾臓などの比較的大きな臓器は良好に抽出できていることが確認できる。

4. むすび

本稿では、深層学習を用いた非造影 CT 画像からの複数臓器領域の自動抽出について述べた。造影 CT 画像を用いて学習された 3D U-net を非造影 CT 画像によりファインチューニングすることで、非造影 CT 画像からの臓器領域の抽出精度が向上することが確認できた。今後の課題としては、より多くの症例での評価、抽出精度の向上などが挙げられる。

謝辞

日頃ご討論いただく名古屋大学森研究室諸氏に感謝する。本研究の一部は JSPS 科研費 26108006, 17H00867, 17K20099, JSPS 二国間交流事業, AMED の課題番号 18lk1010028s0401, 19lk1010036h0001, 堀科学芸術振興財団によった。

利益相反の有無

なし

文献

- [1] Shimizu A, Ohno R, Ikegami T, et al.: Segmentation of multiple organs in non-contrast 3D abdominal CT images. *Int J Comput Assist Radiol Surg* **2**: 135-142, 2007
- [2] Okada T, Linguraru MG, Hori M, et al.: Abdominal multi-organ segmentation from CT images using conditional shape-location and unsupervised intensity priors. *Med Image Anal* **26**: 1-18, 2017
- [3] Zhou X, Takayama R, Wang S, et al.: Deep learning of the sectional

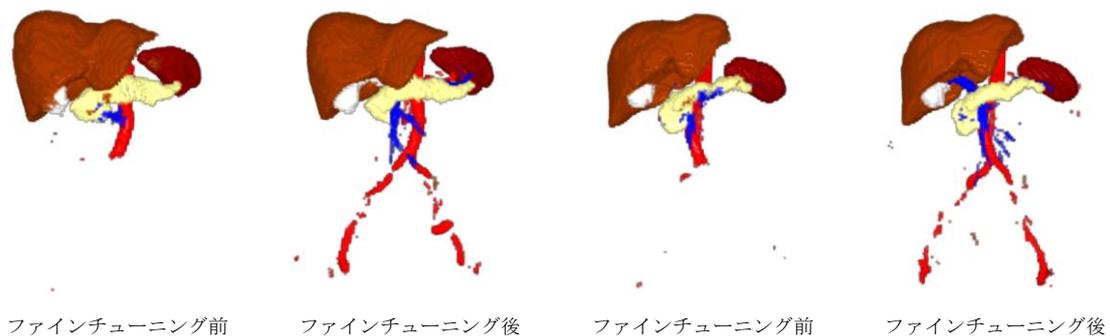


図 1 抽出結果のボリュームレンダリング表示

表 1 抽出された各臓器領域の Dice 係数

	動脈	門脈	肝臓	脾臓	胃	胆嚢	膵臓
ファインチューニング前	0.67	0.24	0.92	0.91	0.98	0.50	0.62
ファインチューニング後	0.77	0.57	0.96	0.94	0.97	0.60	0.69

- appearances of 3D CT images for anatomical structure segmentation based on an FCN voting method. *Med Phys* **44**: 5221-5233, 2017
- [4] Roth HR, Oda H, Zhou X, et al.: An application of cascaded 3D fully convolutional networks for medical image segmentation. *Computerized Medical Imaging and Graphics* **66**: 90-99, 2018
- [5] Shen C, Roth HR, Oda H, et al.: Evaluation of 3D fully convolutional networks for multi-class organ segmentation in contrast-enhanced CT. *International Journal of Computer Assisted Radiology and Surgery* **13**: s21-s22, 2018
- [6] Chollet F and others: Keras, <https://keras.io>, 2015

A study on segmentation of multiple organs using deep learning from non-contrast CT volume

Yuichiro HAYASHI^{*1}, Chen SHEN^{*1}, Holger R. ROTH^{*1}, Masahiro ODA^{*1},
Kazunari MISAWA^{*2}, Kensaku MORI^{*1,3,4}

*1 Graduate School of Informatics, Nagoya University

*2 Department of Gastroenterological Surgery, Aichi Cancer Center Hospital

*3 Information Technology Center, Nagoya University

*4 Research Center for Medical Bigdata, National Institute of Informatics

This paper reports segmentation of multiple organs from non-contrast CT volume using deep learning. In medical image analysis, it is important to recognize patient specific anatomical structures in medical images such as CT volumes. We have studied on multiple organs segmentation method from contrast-enhanced CT volume. Since non-contrast CT volumes are also usually used in the medical field, segmentation of multiple organs from non-contrast CT volume is useful. In this study, we extract multiple organs from non-contrast CT volume using 3D U-net proposed in our previous studies. We perform fine-tuning from pre-trained model using non-contrast CT volumes. The experimental results showed that the fine-tuned 3D U-net model could extract multiple organs from non-contrast CT volume.

Key words: Segmentation, Deep learning, U-net, fine tuning, CT volume

顎口腔領域の CT 画像における金属アーチファクト低減を

用いた筋骨格セグメンテーション

-金属アーチファクトのシミュレーションによる精度検証-

森谷 友香^{*1} Abdolali Fatemeh^{*1} 阪本 充輝^{*1} 大竹 義人^{*1}

重田 優子^{*2} 井川 知子^{*2} 三島 章^{*2} 小川 匠^{*2} 佐藤 嘉伸^{*1}

要旨

顎口腔領域における病気の診断・治療計画では、筋骨格構造の解析が重要であり、この観測には一般的に CT が用いられる。しかしながら、金属製の歯科充填物等がある場合、CT 画像上には金属アーチファクトが生じ、筋骨格構造の認識が困難である。我々は、金属アーチファクトのある CT 画像において、筋骨格セグメンテーションの精度を向上させる研究を進めてきた。しかし、これまではアーチファクト低減後の画像から作成した正解データを用いて精度評価を行っており、真に正確な評価ができていないことが問題であった。また、金属部分が既知でないとき、NMAR に失敗する場合があった。そこで本研究では、金属アーチファクト低減において NMAR に処理を一部追加・変更した手法を提案し、金属アーチファクトをシミュレーションして得られた CT 画像によって自動セグメンテーションの精度検証実験を行ったため、その結果を報告する。

キーワード：CT 画像、金属アーチファクト低減、金属アーチファクトのシミュレーション、3D U-Net

1. はじめに

顎口腔領域の筋骨格構造解析は、顎変形症や顎関節症といった顎口腔機能異常の診断、手術計画、術後評価に有用であり、対象の筋骨格を自動抽出し解析することが求められている。しかし、CT 撮影範囲内に金属製の歯科充填物等がある場合、CT 画像上には金属アーチファクトが生じ、この場合、CT 画像からの筋骨格セグメンテーションは困難である。

我々はこれまで、CT 画像における金属アーチ

ファクトを Normalized Metal Artifact Reduction (NMAR) [1] を用いて低減し、低減後の画像から畳み込みニューラルネットワークを用いることにより、患者固有の筋骨格の自動セグメンテーション精度を向上させる研究を進めてきた [2] [3]。しかし、顎口腔領域において、これまでは金属アーチファクト低減後の画像から作成した正解データを用いて精度評価を行っており、真に正確な評価ができていないことが問題であった。また、金属アーチファクトのある CT 実画像に対して NMAR を適用する場合、撮影対象者の口腔内に存在する金属製の歯科充填物等の位置や形状の情報が既知でないため、これまではしきい値により金属と考えられる部分の抽出を行い、これを用いて NMAR を適用していたが、症例によっては図 1 に示すように NMAR に失敗してしまう場合があった。

そこで、本稿では、金属アーチファクトをシ

*1 奈良先端科学技術大学院大学先端科学技術研究科

〔〒630-0192 奈良県生駒市高山町 8916-5〕

e-mail: moritani.yuka.mt0@is.naist.jp

*2 鶴見大学歯学部

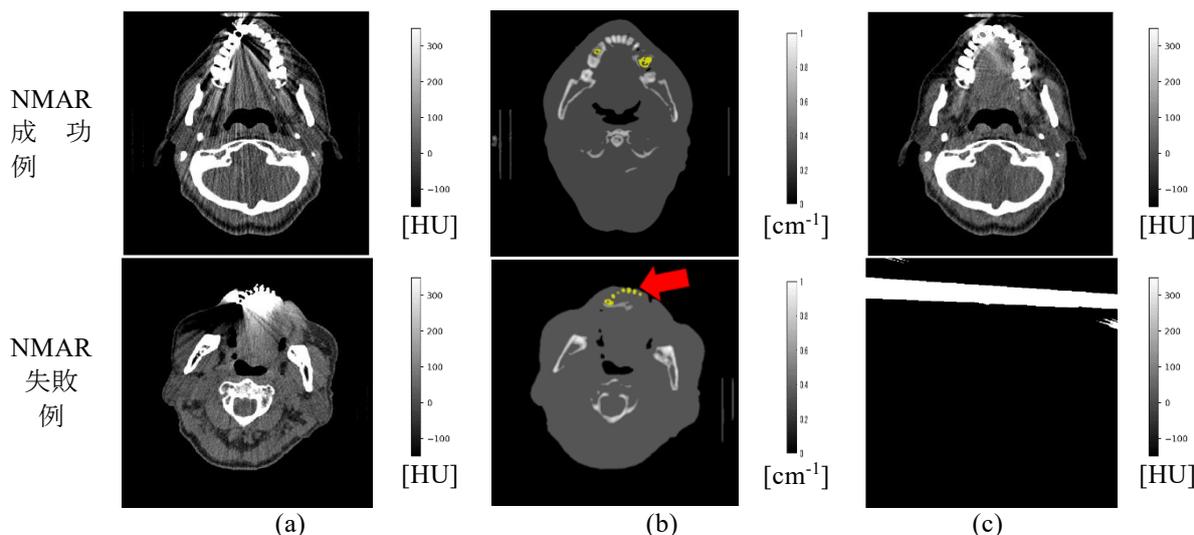


図1 NMAR 成功例と失敗例. (a):金属アーチファクトあり CT 実画像 (NMAR 前), (b):prior, (c):NMAR 後. NMAR 失敗例では, しきい値により抽出した金属部分 (b)中の黄色部分)の一部が prior の空気領域に重なり (赤の矢印で示す部分), このため NMAR に失敗する.

ミュレーションして得られた CT 画像を用い, NMAR や NMAR に処理を一部追加・変更した提案手法を用い, 精度検証を行うことを目的とする.

2. 手法

まず, 金属アーチファクトのない CT 実画像に対し, 画像上の歯の一部分に金属部分を仮定して, シミュレーション[4]によって金属アーチファクトのある CT 画像を得る. 次に, シミュレーションにより得られた CT 画像に対し, NMAR を用いて金属アーチファクト低減を行う. 最後に, 金属アーチファクト低減後の CT 画像に対し 3D U-Net [5] を用いて筋骨格の自動セグメンテーションを行う.

2.1. NMAR

本研究では次の 3 種類の NMAR を適用し, それぞれ検証実験を行った. 1 つめは, 金属部分の位置や形状が既知でないと仮定し, しきい値により金属部分を推定して NMAR を適用する手法である. 2 つめは, シミュレーションに際して作成した金属部分の位置や形状の情報を用いて NMAR を適用する手法である. 3 つめは, NMAR において金属部分をしきい値によ

り抽出し, 処理を一部追加・変更した手法である. 本稿ではこれらを順に NMAR1, NMAR2, NMAR3 とする.

NMAR3 についてさらに説明する. そもそも NMAR によって図 1 に示したような問題が生じる原因として, NMAR で uncollected sinogram を prior sinogram で除算した際に 0 に近い値で除算してしまい, normalized sinogram の金属領域の線形補間に影響があるためであると考えられる. このため, NMAR では normalized sinogram において, 投影された金属領域の両端の線形補間を行っているのに対し, NMAR3 では, 図 1 のような問題が生じるとき, normalized sinogram の線形補間を行う範囲を変更する処理を追加する. 具体的には, 以下のとおりである.

1. normalized sinogram 上の値が 3 より大きいかどうかを判定する.
2. 上記 1. で 3 より大きい場合, normalized sinogram の線形補間において, 通常の NMAR での線形補間領域の両端のうち, どちらか一方の値が 2 より大きいかどうかを判定する.
3. 上記 2. で 2 より大きい場合, その位置に最も近い局所的最小値の位置を金属領域内で新たに算出し, その位置と金属領域のもう一方の端の線形補間に変更する.

表 1 シミュレーションにて仮定したパラメータとそのときの金属アーチファクトの程度

金属アーチファクトの程度	Mild artifact	Severe artifact	
金属の密度	6.0, 8.0, 11.6 g/cm ³	5.0, 6.0, 8.0, 11.6, 13.0 g/cm ³	
金属の種類	チタン	鉄	パラジウム合金
ポワソンノイズの程度	10 ¹⁰ , 10 ¹¹	10 ⁹ , 10 ¹⁰ , 10 ¹¹	10 ⁹ , 10 ¹⁰ , 10 ¹¹
金属の位置のパターン	2 種類		
パラメータの組み合わせの合計	30	30	

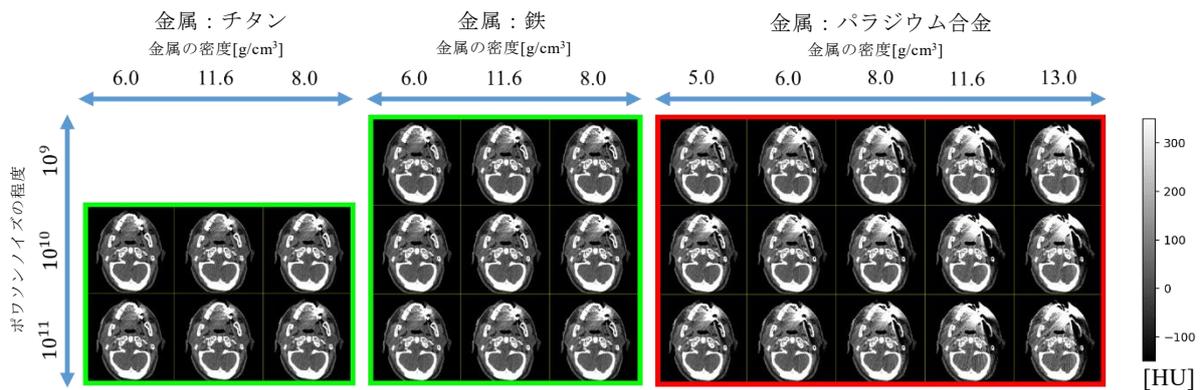


図 2 シミュレーションにて仮定したパラメータとそのとき生成された CT 画像の例. 本研究では, 緑線で囲んでいるものを Mild artifact, 赤線で囲んでいるものを Severe artifact とした.

なお, 上記手順 1. にて normalized sinogram 上の値が 3 以下である場合は通常の NMAR と同様の処理を行うこととした.

3. 実験

3.1. 使用データ

本実験では, 顎口腔領域を対象とした CT 実画像を使用した. 金属アーチファクトのシミュレーションに 1 症例, 3D U-Net における学習用・検証用およびテスト用データとして 35 症例, 計 36 症例の CT 実画像を用いた. これらの CT 画像は鶴見大学歯学部にて撮影され, 36 症例すべての CT 画像において金属アーチファクトは含まれていない. 画像サイズは 512×512×77~100, 1 voxel あたりのサイズは 0.41mm×0.41mm×1.00mm となるようリサイズやクロップを行った.

3.2. シミュレーションにて考慮するパラメータ

金属アーチファクトのシミュレーションにおいて, 金属の種類をチタン, 鉄, パラジウム

合金の 3 種類, 金属の密度 5 種類および CT 画像上に生じるポワソンノイズの程度 3 種類を仮定し, 様々な CT 画像撮影条件を想定したシミュレーションを行った. その中で金属アーチファクトの程度を目視で確認し, 表 1 および図 2 のように, Mild artifact と Severe artifact の 2 グループに分けた.

3.3. 生成画像の画質精度評価

生成画像の画質精度の評価には, PSNR および相互情報量(MI)を用いる. なお, PSNR の算出に用いる画像は CT 画像を WW=500, WL=100 で正規化したものであり, また, MI の算出には, CT 画像を-1000HU から 4000HU の範囲でビン数 255 の度数分布にしたものを用いる.

3.4. セグメンテーションの精度評価

本稿の自動セグメンテーション結果の精度評価では, 金属アーチファクトのない CT 実画像から作成したマニュアルセグメンテーションを ground truth とする. 評価指標は平均表面

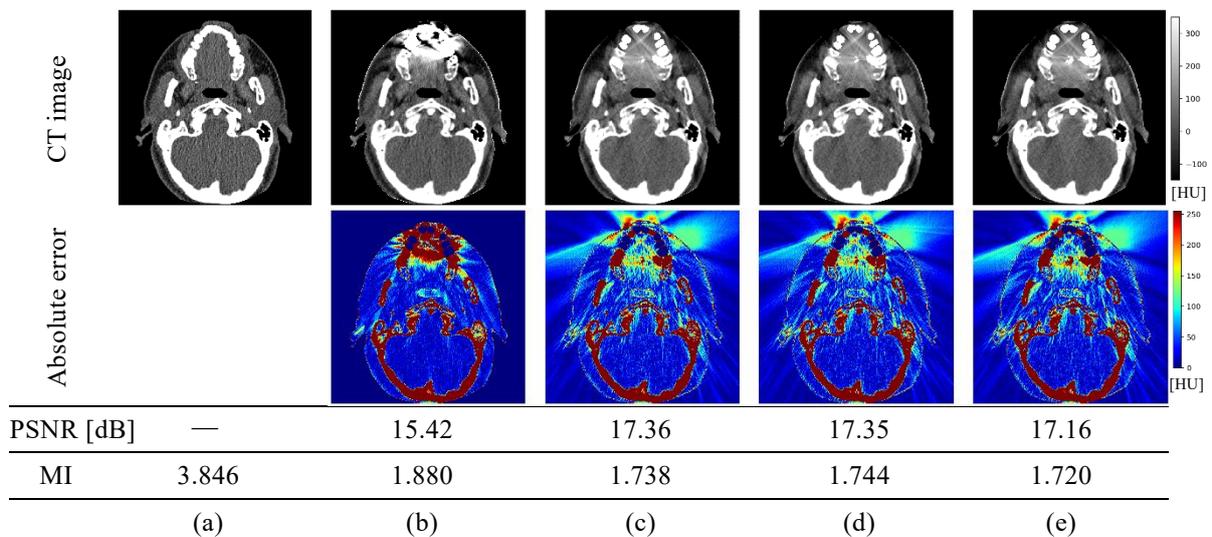


図3 Mild artifact の場合の低減結果の一例. (a):金属アーチファクトなし CT 画像, (b):NMAR 前, (c):NMAR1 後, (d):NMAR2 後, (e):NMAR3 後.

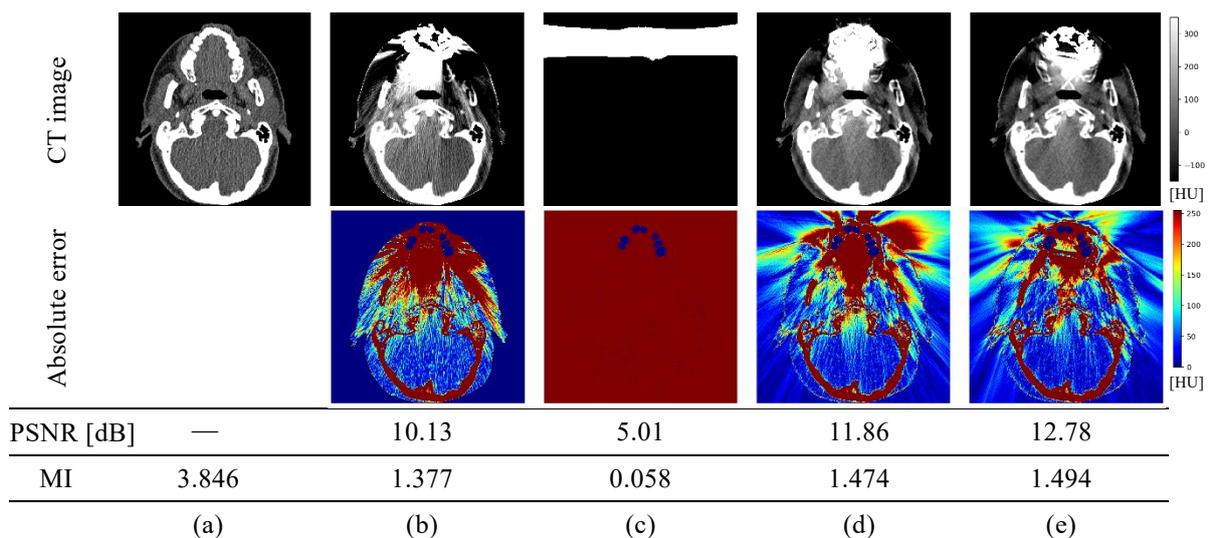


図4 Severe artifact の場合の低減結果の一例. (a):金属アーチファクトなし CT 画像, (b):NMAR 前, (c):NMAR1 後, (d):NMAR2 後, (e):NMAR3 後.

間距離誤差(Average Symmetric Surface Distance: ASD) を用いた.

4. 実験結果

4.1. NMAR 結果

金属アーチファクトのない CT 実画像に金属部分を追加しシミュレーションおよび金属アーチファクト低減を行った結果の一例を図3および4に示す. 図3は密度 6.0 g/cm^3 のチタン, 図4は密度 6.0 g/cm^3 のパラジウム合金を仮定

し, どちらもノイズの大きさは想定した3種のうち中程度ものを仮定した際の結果である. PSNR および MI は, いずれも金属アーチファクトなし CT 画像と各生成画像により算出したものである.

図3より, Mild artifact の場合, NMAR1, 2, 3いずれを使用した場合も NMAR 前より PSNR の値が高くなり, MI は同程度であった. また, 3種の NMAR 間の差は大きくないことが読み取れる.

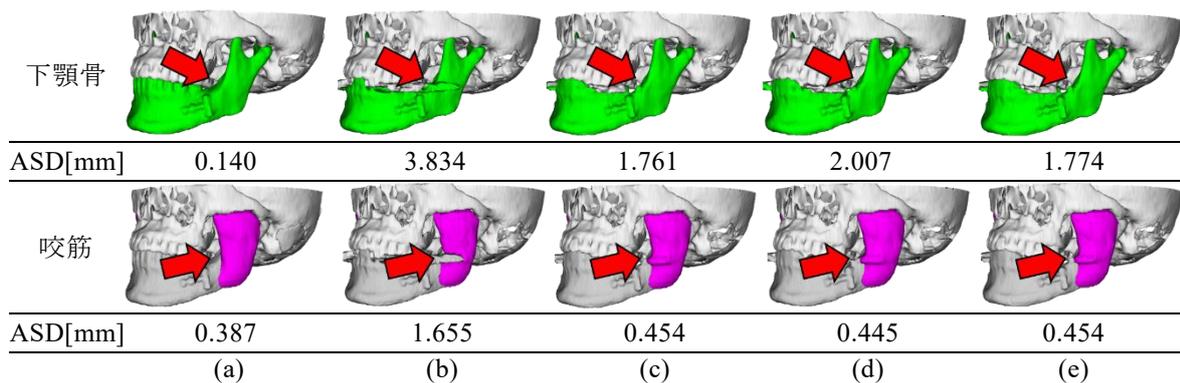


図 5 セグメンテーション結果の一例. (a):金属アーチファクトなし CT 画像, (b):NMAR 前, (c):NMAR1 後, (d):NMAR2 後, (e):NMAR3 後.

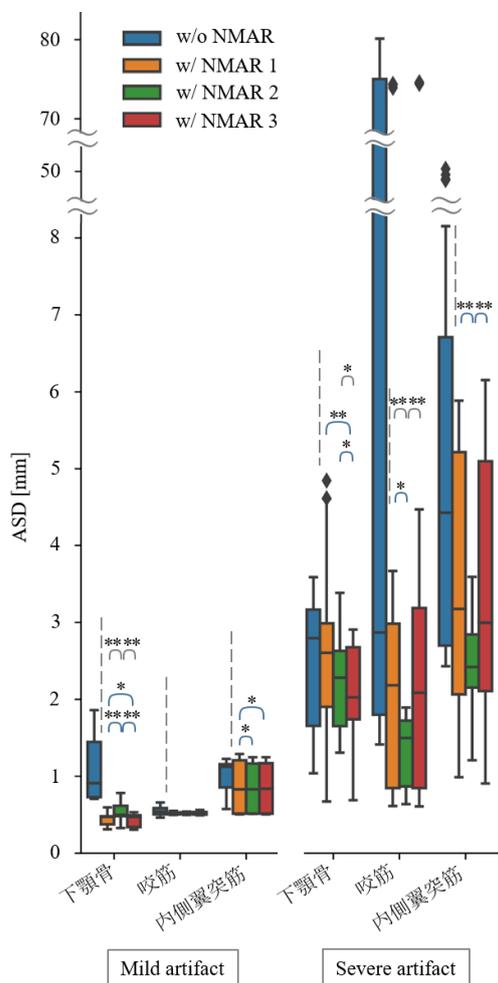


図 6 NMAR 前後の画像を用いたセグメンテーション結果の ASD. 有意差は**: 0.01 , *: 0.05 であり, 青色で示した有意差は対応のある t 検定の結果, 灰色で示した有意差は Wilcoxon の符号順位検定の結果である. なお, NMAR 前後の有意差の算出は行っていない.

図 4 より, Severe artifact の場合, NMAR2, 3 を適用した場合に NMAR 前より PSNR と MI の値が高くなった. 図 4 に示しているスライスでは, NMAR1 を適用した場合に図 1 と同様の問題が生じ, NMAR に失敗している. ただし, Severe artifact の場合のすべてのスライスにおいて NMAR1 適用時に NMAR に失敗しているわけではなく, また, この問題が生じている場合, スライスによっては NMAR3 を適用した際にも NMAR に失敗する場合があった.

4.2. セグメンテーション結果

NMAR 前後の画像を用いた場合の下顎骨・咬筋のセグメンテーション結果の一例を図 5 に, 下顎骨・咬筋・内側翼突筋のセグメンテーション結果の ASD のグラフを図 6 に示す. 図 5 の赤の矢印で示した部分において, NMAR 前後でセグメンテーション結果が異なり, NMAR 後の方が NMAR 前と比較して ASD が小さくなっていることが読み取れる. また, 図 6 より, まず NMAR 前後で比較すると, 金属アーチファクトの程度に関わらず, 下顎骨・咬筋・内側翼突筋すべてにおいて NMAR 後の方が ASD が小さく, セグメンテーション精度の向上が見られる.

さらに図 6 より, Mild artifact の場合, NMAR の種類による ASD の違いは小さく, Severe artifact の場合, NMAR の種類による ASD の違いが顕著であることが読み取れる. 特に下顎骨のセグメンテーションにおいて, 対応のある t 検定より, NMAR3 後の ASD と NMAR1 後の

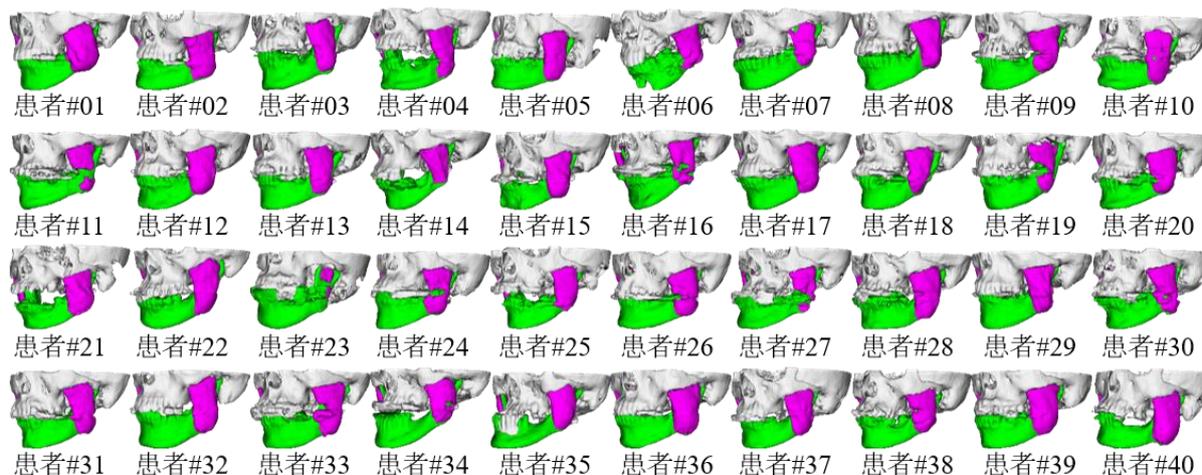


図7 大規模データベースでのセグメンテーション結果（一部抜粋）.

ASD, および NMAR3 後の ASD と NMAR2 後の ASD それぞれで有意差ありとなっており, NMAR2, 3, 1 の順に ASD が小さく, セグメンテーション精度の向上がみられるといえる. 一方, 咬筋および内側翼突筋のセグメンテーションにおいては, NMAR2 を適用したときの ASD がそれぞれ最も小さく, NMAR1 後と NMAR3 後に精度の差は見られなかった.

4.3. 大規模データベースでの結果

以上の結果をふまえ, 金属アーチファクトのある CT 実画像 395 症例に対して NMAR3 を用いて金属アーチファクト低減を行ったのち 3D U-Net により筋骨格の自動セグメンテーションを行った. 結果の一覧を図7に示す. この結果より, 下顎骨, 咬筋の形状は患者間で様々であることがわかる.

5. 考察

Severe artifact の場合, 3 種の NMAR 間で ASD の値が異なった理由を次のように考察する.

本実験で NMAR1 適用時に NMAR に失敗してしまった 81 スライスについて, NMAR2 適用時には, どのスライスにおいても NMAR の失敗は見られなかった. これが, 下顎骨・咬筋・内側翼突筋すべてにおいて NMAR1 後の ASD と NMAR2 後の ASD に有意な差が表れた理由であると考えられる. 一方, NMAR3 適用時に

NMAR に失敗したのは 64 スライスであり, NMAR に失敗したスライス数は NMAR1 適用時と比較して 17 減少した. しかし, この 17 スライスにおいて, 金属アーチファクトは残存しており, その影響により筋肉部分の目視による確認が困難であった.

また, NMAR3 は, そもそも NMAR 失敗の判定や normalized sinogram の線形補間領域の指定に用いる normalized sinogram の値を実験的に決めている. これらの値は, 本研究にて金属アーチファクトのある CT 実画像に NMAR1 を適用する際に NMAR に失敗する問題に直面し, これを解決する値としてあくまで実験的に定めた値であり, 最適な値であるとはいえない. このため, NMAR3 後は NMAR1 後と比較して下顎骨のみ ASD に有意差が表れるにとどまると考えられる.

6. まとめ

本稿では, セグメンテーション精度について, NMAR 前後, および 3 種の NMAR 間での比較検証を行った. 今後, より多くの金属アーチファクトなし CT 実画像を用いて金属アーチファクトのシミュレーションを行い, 手法 NMAR3 の精度検証を通じて大規模データベースでのセグメンテーションの精度向上を目指す. また, その結果を用い, さらなる解剖学的解析を行う予定である.

謝辞

本研究の一部は KAKENHI 26108004 の支援による。

利益相反の有無

なし

文 献

- [1] Meyer E, Raupach R, Lell M, et al.: Normalized metal artifact reduction (NMAR) in computed tomography. *Medical physics*, vol.37, no.10, pp.5482-5493, 2010.
- [2] Sakamoto M, Hiasa Y, Otake Y, et al.: Automated segmentation of hip and thigh muscles in metal artifact contaminated CT using CNN. *International Forum on Medical Imaging in Asia 2019*. Vol. 11050. International Society for Optics and Photonics, 2019.
- [3] 森谷 友香, Fatemeh Abdolali, 阪本 充輝, et al.: 顎口腔領域の CT 画像における金属アーチファクト低減を用いた筋骨格セグメンテーション, In *proceedings of 医用画像研究会(MI)*, Okinawa, 2019
- [4] Zhang Y, Yu H: Convolutional neural network based metal artifact reduction in X-ray computed tomography. *IEEE Trans Med Imag* 37.6: 1370-1381, 2018
- [5] Çiçek Ö, Abdulkadir A, Lienkamp S, et al.: 3D U-Net: learning dense volumetric segmentation from sparse annotation. *International conference on medical image computing and computer-assisted intervention*, pp. 424-432, 2016

Musculoskeletal Segmentation of Metal Artifact-Reduced Maxillofacial CT Images — Evaluation Using Metal Artifact-Simulation —

Yuka MORITANI^{*1}, Fatemeh ABDOLALI^{*1}, Mitsuki SAKAMOTO^{*1}, Yoshito OTAKE^{*1},
Yuko SHIGETA^{*2}, Tomoko IKAWA^{*2}, Akira MISHIMA^{*2}, Takumi OGAWA^{*2}, Yoshinobu SATO^{*1}

^{*1} Graduate School of Information Science, Nara Institute of Science and Technology

^{*2} School of Dental Medicine, Tsurumi University

The segmentation of musculoskeletal structures, e.g. masseter muscle and mandible, in computed tomography (CT) images is important for the diagnosis and treatment planning of maxillofacial disorders. However, the presence of a metal prosthesis, such as dental fillings, leads to metal artifacts in the CT images that degrade the segmentation accuracy. In our previous study, we developed a musculoskeletal segmentation method applied to metal artifact-reduced CT images and evaluated it based on the manual trace produced from metal artifact-reduced CT images. In this research, instead, we simulated metal artifacts in the CT images and evaluated the segmentation accuracy using labels produced from CT images without metal artifact. In addition, we proposed an improvement of the conventional Normalized Metal Artifact Reduction (NMAR) method, and compared the impact of three metal artifact reduction methods on the segmentation accuracy.

Key words: CT Image, Metal Artifact Reduction, simulation of metal artifacts, 3D U-Net

Faster R-CNN による肝臓がん候補領域の抽出法

古月 夢奇*¹ 陸 慧敏*¹ 金 亨燮*¹

平野 靖*² 間普 真吾*² 田辺 昌寛*³ 木戸 尚治*⁴

要旨

近年、肝臓がんは男女計で世界第 4 位の死亡者数となっている。肝臓がんの代表的な治療法として、手術が挙げられる。手術を行うには、事前にかんの個数やその大きさの情報を知る必要がある。その際に利用されるのが X 線 CT をはじめとする画像診断である。これらの診断では、得られた CT 像から肝臓の領域やがんの領域を抽出 (セグメンテーション) することにより、最終的に 3 次元でその形状を復元することができる。本論文では、ダイナミック CT におけるがん領域を効率的に抽出するための画像解析法を構築するための前段階として、画像上に大まかながんの関心領域としての矩形領域を初期領域として求める手法を提案する。手法としては入力画像に前処理を施した後、改良を加えた Faster R-CNN を用い、がん領域を含む関心領域を矩形で抽出する。本手法をダイナミック CT の動脈相 11 症例に適応した結果、Recall : 71.72[%], AP : 64.60[%]という結果が得られた。

キーワード：コンピュータ支援診断、畳み込みニューラルネットワーク、物体検出、Faster R-CNN

1. 序論

肝臓がんの診断において、X 線 CT, MRI などの画像診断は極めて重要な役割を持つ。特に、造影 CT において、造影剤を急速静注して経時的に撮影するダイナミック CT は、がんの鑑別、描出、病期診断に非常に有用であるといわれて

いる[1]。しかしながら、ダイナミック CT は複数の時相画像の経時変化を比較読影する必要があるため、患者一人あたりに要する読影量は通常の撮影の数倍に膨れ上がっている。さらに、CT 装置の高精度化に伴い、一度に撮影されるデータ量が激増しているため、医師の読影負担は深刻な問題になっている。そのため、医師が短時間に肝がんを見落とすことなく診断できる環境の整備が必要とされ、CAD(Computer Aided Diagnosis)システムの開発に対する要望が高まっている。

そこで本論文では、肝臓がんの診断および治療計画立案のため、コンピュータを用いた定量的な解析を可能にすべく、がんの候補領域を矩形で抽出・その矩形内のがん領域の抽出(セグメンテーション)の 2 つを基軸とする、CAD(Computer Aided Diagnosis)システムの開発を最終目標とする。すなわち、がんの自動抽出から関心領域の自動設定の後に、がんのセグメンテーションを行うことにより、医師への負担軽減を行うためのシステム構築を目指す。

*1 九州工業大学大学院工学府工学専攻
〔〒804-8550 福岡県北九州市戸畑区仙水町 1-1〕

e-mail: kimhs@cntl.kyutech.ac.jp

*2 山口大学大学院創成科学研究科工学系学域知能情報工学分野
〔〒755-8611 山口県宇部市常盤 2-16-1〕

*3 山口大学大学院医学系研究科 放射線医学講座
〔〒755-8505 山口県宇部市南小串 1-1-1〕

*4 大阪大学大学院医学系研究科 人工知能画像診断学共同研究講座
〔〒565-0871 大阪府吹田市山田丘 2-2〕

具体的には，CNN(Convolutional Neural Networks)を用いた物体検出手法の一つである Faster R-CNN による，がんの候補領域を矩形で抽出した後，その矩形内でがんのセグメンテーションを行う．従来の肝臓がんの検出に関する研究の多くは，肝臓領域内でそれぞれのがんに関心領域を設定せず，がんのセグメンテーションを行っている．そのため，複数のがん領域の間隔が近い場合において，セグメンテーション精度が低下するという問題がある[2]．その問題を改善するため，事前にかんに関心領域を自動で設定し，その関心領域内で最終的ながん領域のセグメンテーションを行うことにより，セグメンテーション精度の低下を防ぐ．本論文では，これらの目標を達成するための第一段階として，がんに関心領域を，CNN を用いて自動で設定する手法を提案する．

2. 手法

本手法の流れは，肝臓領域の抽出とその抽出結果の切り出しによる前処理と深層学習による関心領域の抽出となる．また，本手法ではダイナミック CT における動脈相の CT 画像のみを用い，がんの初期候補領域を矩形で抽出する．

2.1. 画像領域の抽出及び切り出し

前処理における肝臓領域の抽出とその抽出結果の切り出しを行う．図 1 に動脈相における肝臓領域を緑色で示す．その肝臓領域を切り抜いた CT 画像を図 2 に示す．肝臓領域を特定する理由は，肝臓領域内でがんの抽出を行うためである．これにより，肝臓以外の骨や他の臓器の誤抽出を防ぐことが可能である．ただし，本論文ではこれらの肝臓領域抽出処理はすべて手動で行った．

2.2. 深層学習

画像解析の分野では，深層学習は文字認識や一般物体の分類に限らず，物体検出やセグメンテーションにも広く応用されている[3]．本論文では，CNN を用いた一般物体検出アルゴリズムの一つである R-CNN(Region-based CNN)に改良を加えた Faster R-CNN[7]を用い，がんの候補領域を矩形で抽出する．



図 1 肝臓領域

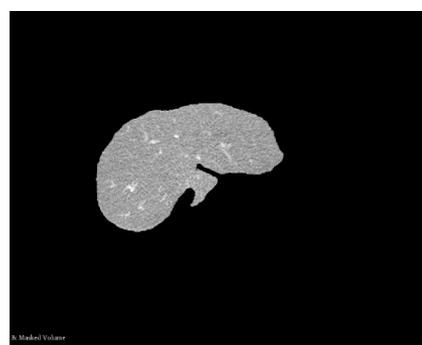


図 2 肝臓領域の切り出し例

CNN における物体検出は，画像中から対象物体の位置とその物体が何であるかを特定する技術であり，コンピュータビジョンの分野で重要なトピックスの一つである．また，バウンディングボックスと呼ばれる，物体を取り囲む矩形領域を特定することを目標とする．代表的な一般物体検出アルゴリズムに R-CNN 系，YOLO(You only Look Once)系，SSD(Single Shot Detector)系の 3 つがある[4-6]．R-CNN 系は，この 3 つのアルゴリズムの先駆けであるため拡張性が高いことから，本論文における処理対象であるがんの候補領域の抽出に Faster R-CNN[7]を使用した．

2.3. Faster R-CNN

Faster R-CNN は，CNN を用いた一般物体検出アルゴリズムの一つである[7]．このネットワークの前身には，R-CNN，SPP(Spatial Pyramid Pooling)Net，Fast R-CNN が存在する[8,9]．Faster R-CNN は，これらのネットワークの欠点を改善したものになる．次に，Faster R-CNN のネット

ワーク構造を図 3 に示す。ただし、FC(Fully Connected)は全結合層である。Faster R-CNN のネットワーク構造は、backbone 部, RPN(Region Proposal Network)部, head 部の 3 つに分けることができる。

(A) backbone 部

backbone 部では、入力画像の特徴を抽出する役割がある。この backbone 部では、複数の畳込み層から構成される、既存のネットワークアーキテクチャの全結合部を除いた部分を利用する。このネットワークアーキテクチャには、VGG(Very Geometry Group)や ResNet(Residual Network)などがある。本論文では、事前に ImageNet で訓練された ResNet101 を採用した [10]。

(B) ResNet

画像分類問題において、ネットワークの層の深さは重要な要素であり、層が深いほど精度が向上すると考えられているが、より深いネットワークを学習させようとすると、勾配消失問題などが発生して精度が悪化することが知られている。ResNet(Residual Network)は、このような深いネットワークにおいて発生する、精度劣化問題の解決を目指して考案された。ResNet は、勾配消失問題を防ぐため、残差を用いた学習を行う。複数積み重ねられた層が、直接最適な写像となるように学習するのではなく、残差の写像が最適となるように学習する [10]。

(C) RPN

RPN(Region Proposal Network)部では、物体らしき領域候補を抽出する役割がある [7]。RPN では、sliding window (3x3[pixel]のボックス)を backbone 部の出力から得られた特徴マップ上でスライドさせる。その後、sliding window に複数のアンカーボックスを適応し、“物体とみなすか否か”と“正解とする領域からどれだけずれているか”を出力する。すなわち、アンカーボックス内の物体及び非物体に関する確率とボックスの中心座標及び幅と高さを出力する。また、アンカーボックスの数は基本的に 9 個(スケール：128,256,512[pixel]とアスペクト比：1:2,1:1,2:1 の組み合わせ)である。

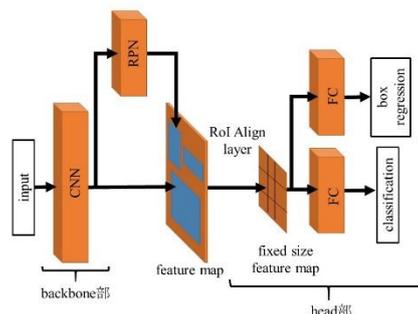


図 3 Faster R-CNN の構造

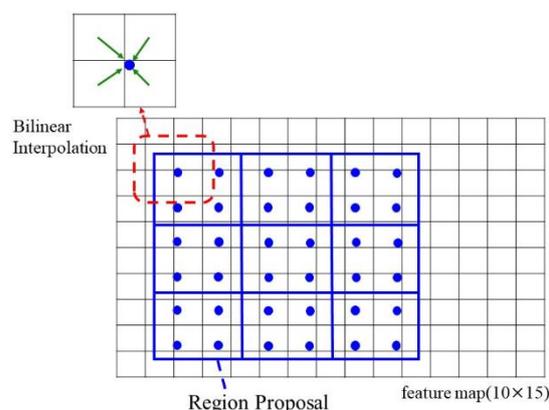


図 4 RoI Align layer

(D) RoI Align layer

図 3 の RoI Align layer について説明する。本来、Faster R-CNN のこの部分の層には RoI Pool layer と呼ばれる層があった [7]。この部分の層の役割は RPN から出力されたサイズが様々な領域候補(Region Proposal)をプーリングにより、最終的に統一されたサイズの特徴マップとして出力することである。しかしながら、RoI Pool layer はプーリングを行う際、Region Proposal のサブピクセルサイズのずれを考慮してリサイズを行う。そのため、最大 0.5[pixel]のずれが発生してしまう。これは最終的に出力される画像において、16[pixel]のずれに相当する。

そこで本論文では、RoI Pool layer の代わりに RoI Align layer を用いる。RoI Align layer は、Mask R-CNN に利用されており、図 4 のように Region Proposal の領域をそのまま等分割を行う [11]。その後、サブピクセル座標を持つグリッド点の値を特徴マップ上の近傍の 4 つの画素から

バイリニア補間法(Bilinear Interpolation)を用いて算出する[8].そして、この4つのグリッド点の値を用いてプーリングを行う.このようにして、図4では3x3サイズの特徴マップとして出力される.ただし、本論文でのRoI Align layerでは図4と異なり、最終的に7x7サイズの特徴マップで統一を行った.このRoI Align layerを用いることにより、最終的に出力される画像におけるRegion Proposalのずれを解消することができる.

(E) head 部

head部では、RoI Align layerで得られた結果を用い、物体の位置とその物体が何であるかを特定する.図3より、2つのFC部はそれぞれユニット数1024で全結合されている.classification,すなわち、クラス識別層では、クラス数と同じ数のユニットで全結合されており、活性化関数にsoftmax関数を用い、それぞれ領域候補においてクラスごとの確率を得る.box regression,すなわち、領域抽出層ではクラス数の4倍の数のユニットで全結合されており、領域候補に対する4つの位置情報(バウンディングボックスの中心座標と幅と高さ)を得る.

3. 実験と結果

本論文における実験で使用されたデータセットの画像情報を表1に示す.症例数は11である.使用する画像は、すべて動脈相のCT画像である.また、11症例すべてに、少なくとも1個以上のがんが存在する.

3.1. 評価方法

Faster R-CNNによるがん領域の抽出には、n分割交差検証(n-fold cross validation)による性能評価を行う.これは、全てのデータを症例ごとにランダムでn分割し、(n-1)組を学習に用い、残る1組をテストに用いる方法である.実験で用いたデータセットの詳細を表2に示す.また、それぞれのデータセットにおいて左30度回転を行うことによるデータ水増しを行っている.本論文では、4分割交差検証により、各テストデータセットに対するAP(Average precision)を求め、その平均を算出することにより、がんを

含む矩形領域の抽出精度を評価する.APは、precision-recall curveの下部面積(AUC:Area Under Curve)から求めるため、recall(再現率)とprecision(適合率)の両方を平等に評価している指標である.recallとは、実際にかんであるもののうち、正しくがんであると抽出されたものの割合を意味する.precisionとは、がんであると抽出したもののうち、実際にかんであるものの割合を意味する.recall, precisionは次式で与えられる.

$$recall = \frac{a}{a+b+c} \times 100[\%] \quad (1)$$

$$precision = \frac{a}{a+d} \times 100[\%] \quad (2)$$

ここで、式(1)と式(2)のa, b, c, dは、それぞれ表3に示す混合行列に含まれる領域の数を意味する.

3.2. 実験結果

11症例に対し、前処理を行ったCT画像をFaster R-CNNの入力として用いた.これにより得られたそれぞれのデータセットにおけるがんのrecallとAP及びその平均を表4に示す.ただし、表4はRoI Pool layerを用いた従来手法[7]とRoI Align layerを用いた提案手法の比較結果である.続いて、従来手法及び提案手法を使用したときの出力画像の例をそれぞれ図5と図6に示す.

表1 画像情報

画像サイズ	512×512[pixel]
症例数	11[症例]
画像枚数	800[枚](200枚は、がんを含む)

表2 実験データセットの詳細

データセット	病変がある画像枚数	病変がない画像枚数
1	96	203
2	28	132
3	77	210
4	71	229

表 3 性能評価のための混合行列

			病変の真のラベル	
			positive	negative
抽出結果	抽出	病変	a	d
		非病変	b	e
	未抽出	c	f	

表 4 実験結果

データセット	RoI Pool layer (従来手法[7])		RoI Align layer (提案手法)	
	recall	AP	recall	AP
1	0.9375	0.8804	0.9479	0.8894
2	0.6522	0.5722	0.6087	0.5682
3	0.6000	0.4488	0.6000	0.4595
4	0.6301	0.6097	0.7123	0.6689
平均	0.7049	0.6270	0.7172	0.6460

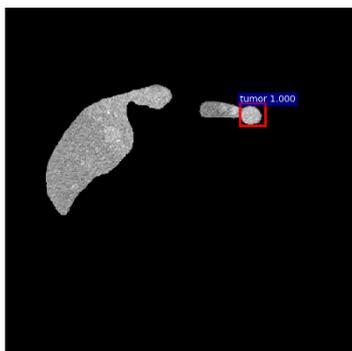


図 5 従来手法を使用した場合

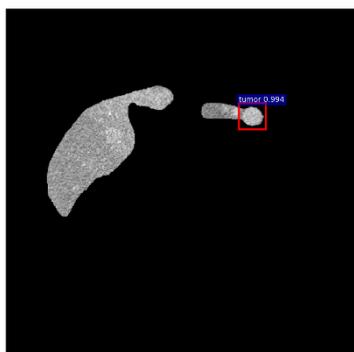


図 6 提案手法を使用した場合

4. 考察

本論文では、ダイナミック CT におけるがん領域を効率的に抽出するための画像解析法を構築するための前段階として、画像上に大まかながんの関心領域としての矩形領域を初期領

域として求めるための画像解析法を提案した。Faster R-CNN に対し、RoI Pool layer (従来手法 [7]) 及び RoI Align layer (提案手法) のそれぞれ用いて抽出を行った結果、表 4 より recall の平均がそれぞれ 70.49[%]と 71.72[%]となり、AP の平均がそれぞれ 62.70[%]と 64.60[%]となった。表 4 の結果はがんの TP(True Positive)を判断するときの基準である IoU(Intersection over Union)の閾値を 0.6 と設定した場合の結果である。すなわち、Faster R-CNN で出力されたバウンディングボックスと grand truth のバウンディングボックスの IoU が 0.6 以上の場合、そのボックスの中の物体をがんとみなす。そのため、表 4 における recall と AP はほとんど変化のない結果となっている。しかしながら、図 7 と図 8 に示すように閾値である IoU の値を上げるにつれて、recall と AP のそれぞれの値が RoI Pool layer (従来手法) 及び RoI Align layer (提案手法) を用いた場合において顕著な差が発生している。ただし、図 7 と図 8 は recall と AP のそれぞれの差が最も顕著だったデータセット 1 を使用した場合のグラフである。図 7 及び図 8 より、IoU の閾値が 0.8 のときにおいて、提案手法のほうが従来手法より recall 及び AP で大幅に高くなっていることがわかる。このことから提案手法は従来手法と比べ、バウンディングボックスの位置に関して高精度な抽出ができていていることがわかる。

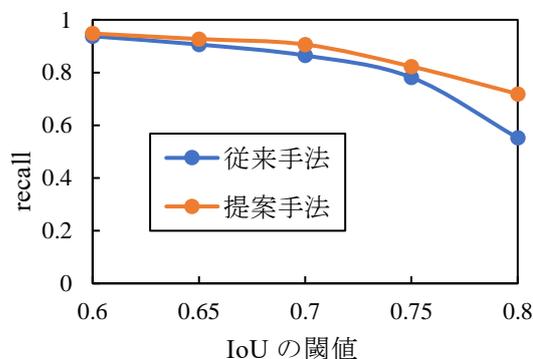


図 7 IoU の閾値を変化させたときの recall

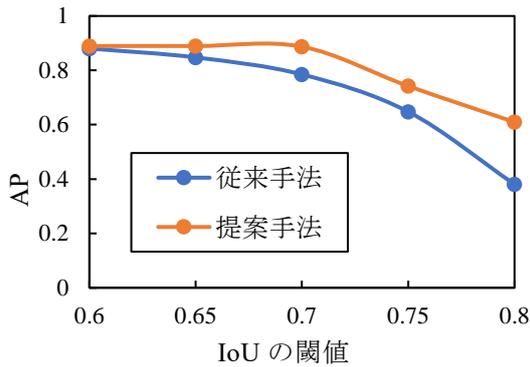


図 8 IoU の閾値を変化させたときの AP

また、図 5 及び図 6 より、提案手法のほうが従来手法よりバウンディングボックスの中心にがんが位置することからも、提案手法のほうがバウンディングボックスの位置に関して高精度な抽出ができていことがわかる。

5. まとめ

本論文では、ダイナミック CT におけるがん領域を効率的に抽出するための画像解析法を構築するための前段階として、画像上に大まかながんの関心領域としての矩形領域を初期領域として求めた。手法としては入力画像に前処理を施した後、Faster R-CNN を用い、がん領域を含む関心領域を矩形で抽出した。RoI Pool layer(従来手法)及び RoI Align layer(提案手法)のそれぞれ用いて抽出を行った結果、提案手法は従来手法と比べ、バウンディングボックスの位置に関して高精度な抽出ができた。

今後の課題としては、抽出された矩形領域内で最終的ながん領域のセグメンテーションを行い、従来のセグメンテーション手法との比較検討を行う必要がある。

利益相反の有無

なし

文 献

[1] 尾川浩一 他：医用画像工学ハンドブック．日本医用画像工学会，2018,pp.567-571
 [2] Grzegorz Chlebus, Andrea Schenk, et al.:

Deep learning based automatic liver tumor segmentation in CT with shape-based post-processing. MIDL 2018 Conference: paper 62, 2018
 [3] 岡谷貴之：深層学習．株式会社 講談社サイエンティフィック，2018,pp.1-54, pp.79-110
 [4] R. Girshick, J. Donahue, T. Darrell, et al.: Rich feature hierarchies for accurate object detection and semantic segmentation. CVPR '14 Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition, pp.580-587, 2014
 [5] J. Redmon, S. Divvala, et al.: You only look once: Unified, real-time object detection. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.779-788, 2016
 [6] W. Liu, D. Anguelov, et al.: SSD: Single shot multibox detector. European Conference on Computer Vision (ECCV), pp.21-37, 2016
 [7] S. Ren, K. He, R. Girshick, et al.: Faster R-CNN: Towards real-time object detection with region proposal networks. NIPS, Vol.1, pp.91-99, 2015
 [8] K. He, X. Zhang, et al.: Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition. European Conference on Computer Vision (ECCV), pp.346-361, 2014
 [9] R. Girshick: Fast R-CNN. IEEE International Conference on Computer Vision (ICCV), pp.1440-1448, 2015
 [10] K. He, X. Zhang, et al.: Deep Residual Learning for Image Recognition. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.770-778, 2016
 [11] K. He, G. Gkioxari, et al.: Mask R-CNN. International Conference on Computer Vision (ICCV), pp. 2961-2969, 2017

A Detection Method for Liver Cancer Region Based on Faster R-CNN

Muki FURUZUKI^{*1}, Huimin LU^{*1}, Hyungseop KIM^{*1}

Yasushi HIRANO^{*2}, Shingo MABU^{*2}, Masahiro TANABE^{*2}, Shoji KIDO^{*3}

*1 Kyushu Institute of Technology

*2 Yamaguchi University.

*3 Osaka University

In recent years, liver cancer has become the fourth-largest number of deaths in the world for men and women in total. The treatment of liver cancer mainly needs surgical removal of the cancer and surrounding liver tissue. Therefore, in order to perform surgery, it is necessary to know in advance the number and size of cancer. To analyze the liver cancer, multi-phase CT images is used. In these diagnoses, the shape can be finally restored in 3D by extracting the region of the liver and the region of cancer from the CT image. In this paper, we propose a method of obtaining a rectangular region as a rough cancerous region of interest, as a preliminary step to construct an image analysis method for efficiently extracting cancerous regions in multi-phase CT. As a method, after preprocessing the input image, using Faster R-CNN which has been improved, the region of interest including the liver cancer region is extracted as a rectangle. We applied our method to 11 cases of arterial phase of multi-phase CT, and the result of recall of 71.72 %, average precision (AP) of 64.60 % was obtained.

Key words: Computer Aided Diagnosis, Convolutional Neural Network, Object Detection, Faster R-CNN

Binary Malignancy Classification of Skin Tissue using Reconstructed Reflectance from Macropathology Multi-Spectral Images

Eleni ALOUPOGIANNI^{*1}, Hiroyuki SUZUKI^{*2}, Takaya ICHIMURA^{*3},
Atsushi SASAKI^{*3}, Hiroto YANAGISAWA^{*3}, Tetsuya TSUCHIDA^{*3},
Masahiro ISHIKAWA^{*4}, Naoki KOBAYASHI^{*4}, Takashi OBI^{*2}

Abstract

This study investigates whether reconstructed spectral reflectance from macropathology multi-spectral images (macroMSI) can assist binary classification of tissue malignancy to identify excised tissue margin during skin cancer diagnosis. We captured high resolution 7-channel macroMSI of 10 samples before and after formalin fixing and a pathologist labeled 115 regions of interest. We reconstructed spectral reflectance by adaptive Wiener Estimation. Subsets of reconstructed spectra were input to k-Nearest Neighbors (kNN) and Support Vector Machine (SVM) classifiers and evaluated by average area under curve of stratified 5-fold cross validation. Results revealed that unfixed spectra were a superior feature set as classifier input. SVM outperformed kNN classifier.

Keywords : macropathology, multispectral imaging, skin cancer classification, spectral reflectance

1. Introduction

Skin cancer has been an increasing health concern in Japan with crude mortality rates doubling in a span of fifteen years [1]. At present, macropathology lacks standardization [2] and is manually performed, allocating high workload to pathologists. The purpose of this study is to investigate the effectiveness of binary malignancy classification of skin cancer with traditional machine learning, using reconstructed spectral reflectance from macropathology multi-spectral images (macroMSI) in order to automate detection of malignancy margins.

2. Materials and Methods

We captured macroMSI of excised skin using a multi-spectral camera with RGB sensitivity across 7 channels in the visible spectrum resulting to the raw subimages shown in Fig. 1. After approval of experimental procedures from the council of Saitama Medical University Hospital, we collected skin specimens from 10 patients, who provided

*1 Department of Information and Communications Engineering, Graduate School of Engineering,

Tokyo Institute of Technology [Tokyo, Japan] e-mail: aloupogianni.e.aa@m.titech.ac.jp

*2 Research Institute for Innovation in Science and Technology, Tokyo Institute of Technology [Tokyo, Japan]

*3 Faculty of Medicine, Saitama Medical University [Saitama, Japan]

*4 Faculty of Health and Medical Care, Saitama Medical University [Saitama, Japan]

informed consent, at the Central Pathology Department of the hospital. A trained pathologist identified and labeled a total of 115 regions of interest (ROI) of skin tissue at 3 states: a) specimen surface prior formalin fixing (unfixed), b) specimen surface after fixing (fixed) and c) interior after cross-sectioning (cross-sectioned), as described in Table 1. We captured a macroMSI for each specimen at every tissue state. For comparison purposes, we also measured the reflectance spectrum of each ROI.

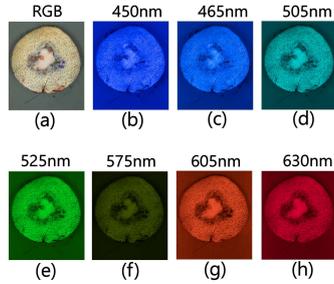


Fig. 1 Example of the captured multi-spectral image

Table 1 Breakdown of the malignancy and fixing state of the captured dataset.

Tissue State	Malignant	Benign	Total
Unfixed	21	14	35
Fixed	23	18	41
Cross-sectioned	24	16	39

From the raw macroMSI and for known camera system parameters, we reconstruct the reflectance spectrum of each ROI by Wiener estimation, with smoothing matrix modeled as the correlation of measured spectra and spatial denoising using Bayesian inference [3]. Reconstruction results were evaluated using average Normalized Root Mean Square Error (NRMSE). Binary classification of skin cancer malignancy is tested with 5-fold stratified cross validation on two traditional machine learning classifiers: k-Nearest Neighbors (KNN) and Support Vector Machine (SVM). Performance was evaluated using balanced accuracy [4] defined as the average of specificity and sensitivity, and standalone specificity. High specificity is crucial in computer-aided diagnosis systems, due to false positive predictions creating high costs for further treatment as well as an additional burden to the patient.

3. Results

The use of MSI improved reflectance reconstruction compared to RGB images, halving NRMSE as shown in Table 2. Additionally, NRMSE was lower for unfixed dataset compared to tissue after fixing. In Fig. 2, we observe that reconstruction for benign tissue is worse than malignant tissue for all tissue datasets, especially for tissue after fixing. Comparison of classification performance in Fig. 3 showed that SVM had greater specificity compared to KNN for all tissue fixing states both for measured and reconstructed spectral as input. Although KNN classifier resulted in higher prediction accuracy, the compromise for low false positive rates makes SVM more

Table 2 NRMSE of reflectance spectrum reconstruction for various combinations of image source and tissue state.

Source	Unfixed	Fixed	Cross-Sectioned	Total
RGB	0.1329	0.0964	0.1590	0.1084
MSI	0.0517	0.0649	0.0707	0.0542

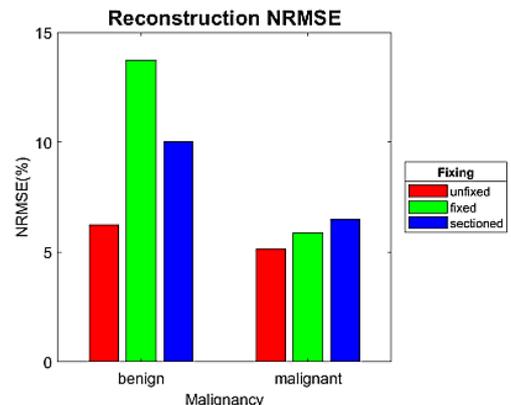


Fig. 2 MSI-based reconstruction NRMSE per malignancy class for various tissue states.

suitable for diagnosis in the present study. SVM-based classification using measured input achieved balanced accuracy around 80% and specificity above 80%, whereas reconstructed input exceeded only 60% and 75% respectively. Such a difference in performance is expected for reconstructed input, considering the small amount of channels that estimated the entire length of the spectrum. The inclusion of unfixed data in classification showed improved accuracy for both measured and reconstructed input. While observing that fixed tissue has higher specificity for measured input, this does not hold for reconstructed input, possibly due to the high NRMSE of fixed tissue. Additionally, the high NRMSE of benign tissue reconstruction may be the cause of low specificity and low accuracy.

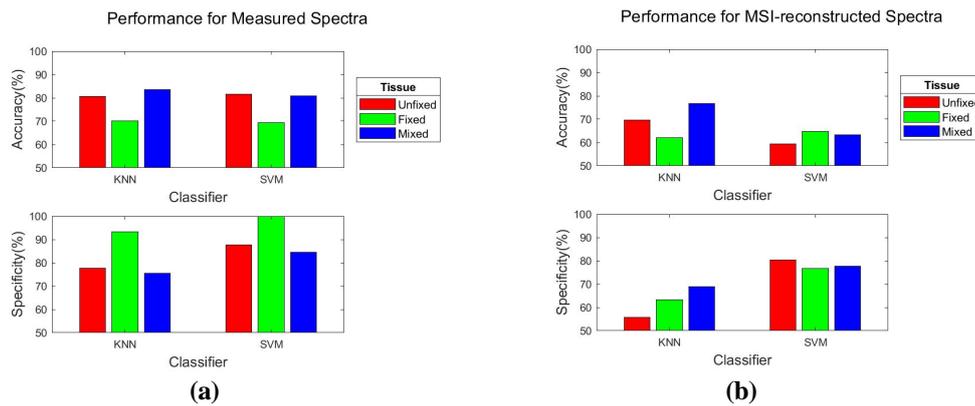


Fig. 3 – Classification performance using (a) measured and (b) reconstructed reflectance spectra as input to the classifiers.

4. Conclusions

We investigated reflectance reconstruction from macroMSI images for use in binary malignancy classification of skin cancer specimens during pathological diagnosis. Results revealed the superiority of SVM for practical use in terms of specificity, and the importance of including unfixed tissue in the analysis due to its low reflectance reconstruction error. Comparison of classification based on measured and reconstructed input suggests reflectance as a useful feature for binary malignancy classification of skin tissue.

Conflict of interest

In this work, the authors have no conflict of interest to declare.

Acknowledgement

We are thankful to Olympus Corporation for the provision and support of the camera equipment during capturing.

References

- [1] J. Cancer Information Service National Cancer Center: National estimates of cancer incidence based on cancer registries in Japan (1975-2013). 2013
- [2] Romaguera R., Nassiri M. and Morales A.R: Tools to Facilitate and Standardize Grossing. *Histologic*, **1**:17-21, 2003
- [3] Urban P., Rosen M. R. and R. S. BERNIS: A Spatially Adaptive Wiener Filter for Reflectance Estimation. *Color and Imaging Conference, Society for Imaging Science and Technology*, 2008(1): 279-284 , 2008
- [4] Brodersen K. H., Ong C. S., Stephan K. E., et al: The Balanced Accuracy and Its Posterior Distribution. *Proceedings of 20th International Conference on Pattern Recognition, Istanbul*, 3121-3124 , Aug. 2010

FDG PET-CT の腫瘍領域教師データを半自動的に作成する

アルゴリズムの提案と性能評価

平田健司^{*1}, 古家翔^{*1}, 真鍋治^{*1}, 孫田恵一^{*2}, 小林健太郎^{*1},

渡邊史郎^{*1}, 豊永拓哉^{*3}, 玉木長良^{*4}, 志賀哲^{*1}

要旨

FDG PET-CT での悪性病変のセグメンテーションは深層学習に期待される課題であるが、放射線科医に定義された膨大な教師データを必要とする。PET では閾値処理により教師データ作成が比較的容易ではあるが、腫瘍集積と生理的集積が隣接するとき用手的作業を要する。この作業を効率化し再現性を高めるアルゴリズムを考案し、実装および操作者間の再現性を確認したので報告する。このアルゴリズムでは、最初に $SUV \geq 2.5$ を満たすボクセルを自動で抽出し、操作者は確実に腫瘍内であるボクセルを指定する。非腫瘍部分が結合している場合には、確実に腫瘍外であるボクセルを追加で指定する。次に 2 点を分離できる最小閾値を探索し、これで解決できない場合は最急降下法および最近傍法を用いる。頭頸部癌と婦人科癌の計 23 例に対して 2 人の核医学医師が本法で教師データを作成したところ、Dice similarity coefficient が 0.98 ± 0.03 と高い一致率が得られた。今後の教師データの作成に有用であると考えられた。

キーワード：FDG PET-CT, 深層学習, 教師データ作成, アルゴリズム,

1. はじめに

FDG PET-CT での悪性病変のセグメンテーションは、深層学習にとって最も期待される課題の 1 つである。深層学習に基づく効率的な AI 構築には、放射線科医によって定義された膨大なデータベースが重要である。CT および MRI と比較して、PET では閾値法や勾配法を用いて自動的なセグメンテーションが成功することが多いため、PET 上の腫瘍境界決定（教師データ作成）は比較的容易である。しかし、生理学的または炎症性の取り込みに隣接する腫瘍を分離するには、通常は手動操作を要するが、時間がかかるだけでなく再現性の低下をもたらす。そこで今回、腫瘍と非腫瘍が隣接するときに、高速かつ高い再現性で腫瘍のみを分離するアルゴリズムを考案し実装した。アルゴリズムの詳細と再現性実験の結果を報告する。

2. 方法

中咽頭癌の原発巣のみを取り出す作業を例に、全体の流れを図 1 に示す。まず $SUV \geq 2.5$ を満たす全てのボクセルを抽出する。次に、確実に原発腫瘍内と考えられる空間内の点を操作者が指定する（赤マークを配置）。原発巣が他の集積体（転移や炎症・生理的集積）の近くに位

*1 北海道大学大学院医学研究院画像診断学教室

〔〒060-8638 札幌市北区北 15 条西 7 丁目〕

e-mail: khirata@med.hokudai.ac.jp

*2 北海道大学病院放射線部

*3 米国イェール大学 PET センター

*4 京都府立医科大学放射線医学教室

置している場合、それらの集積体も赤でマークされるため、これを除去する作業が必要となる。これら非腫瘍性の構造物の内部に、操作者は青マークを置く。同一領域内に赤マークと青マークを持つため、ラベルが衝突し、一時的に緑で表示される。両者を分離することができる最小の閾値を探索することで、ラベル衝突を解決する。最小閾値が見つからない場合は最近傍法を用いる。操作者が満足するまでこの操作を繰り返す。

再現性を評価するために、2人の操作者が独立に、頭頸部癌(N=13)と婦人科癌(N=10)の原発巣を分離する課題に取り組んだ。いずれの症例も原発巣にFDGの集積亢進が認められた。結果の評価には、以下の式で計算される Dice similarity coefficient (DSC)を用いた。

$$DSC = \frac{2|VOI_A \cap VOI_B|}{|VOI_A| + |VOI_B|}$$

ここで、VOI_AとVOI_Bは2人の操作者によって定義されたVOIである。DSCは0から1までの実数を取り、大きいほど高い再現性を表す。

3. 結果

この方法は全対象患者に対して成功した。DSCは0.98±0.03(平均±SD)と高い再現性が得られた。23人中、14人(頭頸部癌の6/13人、婦人科癌の8/10人)においてDSCは1.0(完全一致)となった。なお、対応するmetabolic tumor volume (MTV)は96±127 mL対97±126 mL (VOI_A対VOI_B)であった。

4. 結論

FDG PET-CTに腫瘍領域教師データを作成するための効率的なアルゴリズムを考案し、高い再現性を確認した。今後の教師データの作成に有用であると考えられた。

謝辞

本研究はJSTのCOI若手連携研究ファンドの助成を受けた(採択番号H31W09)。

利益相反の有無

なし

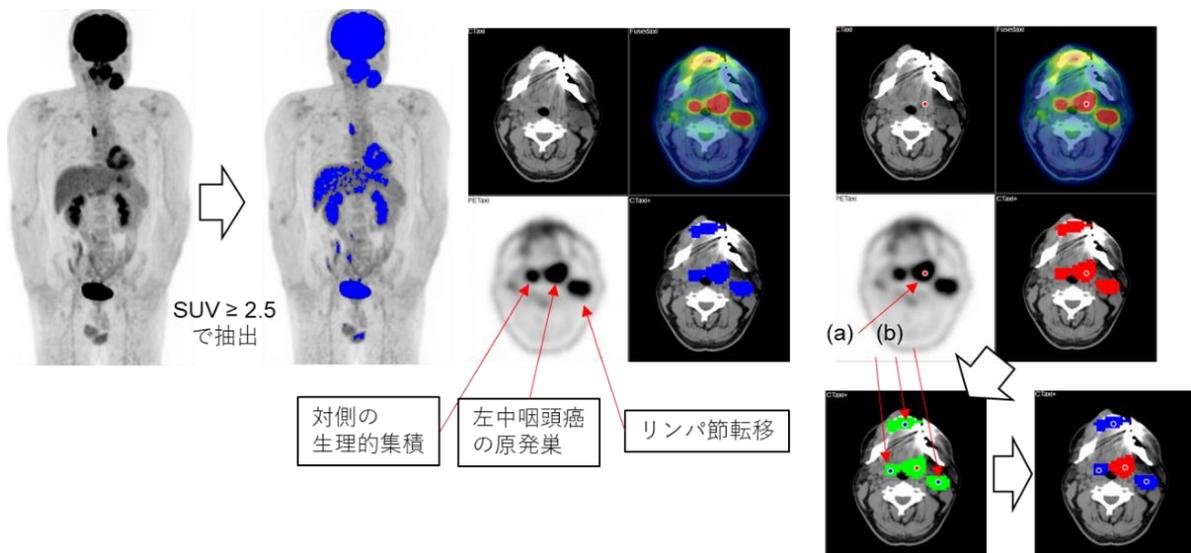


図1 ここでは中咽頭癌の原発巣のみを分離することを目指す。操作者は原発巣に赤マーク(a)を配置すると、これと連続した領域すべてが赤になる(頸部リンパ節とは他スライスで連続している)。次に原発巣以外の青マーク(b)を配置すると、同一領域内に赤マークと青マークを持つため緑に変化する。そこで考案したラベル衝突解決アルゴリズムが、自動的に原発巣(赤)とその他(青)に分離する。

An algorithm to generate training data semi-automatically on FDG PET-CT

Kenji HIRATA^{*1}, Sho FURUYA^{*1}, Osamu MANABE^{*1}, Keiichi MAGOTA^{*2}, Kentaro KOBAYASHI^{*1},
Shiro WATANABE^{*1}, Takuya TOYONAGA^{*3}, Nagara TAMAKI^{*4}, Tohru SHIGA^{*1}

*1 Department of Nuclear Medicine, Hokkaido University, Sapporo, Japan

*2 Division of Medical Imaging and Technology, Hokkaido University Hospital, Sapporo, Japan

*3 PET center, Yale University, New Haven, CT, USA

*4 Department of Radiology, Kyoto Prefectural University of Medicine, Kyoto, Japan

Segmentation of malignant lesions with FDG PET-CT is a greatly expected task for deep learning, but a large amount of training data defined by radiologists is required to train AI system. Although threshold-based segmentation is relatively easier for PET images compared to CT and MR images, manual modification of segment is needed when tumor accumulation and physiological/inflammatory accumulation are adjacent. We aimed to propose an algorithm to prepare training data efficiently and reproducibly, and to test the reproducibility between two operators. In this algorithm, first, PET image voxels that satisfy $SUV \geq 2.5$ are automatically extracted, and the operator specifies voxels that are definitely in the tumor. If non-tumor accumulation is connected to the tumor, the operator is requested to specify voxels that are definitely outside of the tumor. Next, the minimum threshold that can separate two points (i.e., tumor and non-tumor) is exhaustively searched. Using this method, two nuclear medicine physicians segmented the primary lesion of head-and-neck cancer and gynecological cancer (N=23). As the results, the Dice similarity coefficient was 0.98 ± 0.03 . In conclusion, the new method may be useful for training data preparation on FDG PET-CT.

Key words: FDG PET-CT, deep learning, training data, algorithm

乳腺領域の自動抽出を用いた深層ニューラルネットワークによる乳房超音波画像における腫瘍検出

楊凱文*¹ 叶嘉星*² 鈴木藍雅*^{1,*2} 坂無英徳*^{1,*2}

要旨

乳房超音波検査における腫瘍の発見率向上のために、機械学習技術を用いた診断支援システムの実現が期待されている。従来の手法では、画像中のノイズと乳腺以外の脂肪や筋肉の影響で、腫瘍を過検出することが多い。本稿ではこの問題を解消するために、乳腺領域の自動抽出と腫瘍候補領域の検出を組み合わせた深層ニューラルネットワークによる腫瘍検出手法を提案する。提案手法では、深層学習モデルである AlexNet と U-Net を用いて腫瘍候補と乳腺領域を検出し、両者から出力される腫瘍らしさと乳腺らしさの尤度を統合して最終的な判定を行う。実験では、実際の乳腺超音波検査にて取得されたデータセットを用いて、従来手法と比べ検出精度が向上し、過検出が削減されることを確認した。

キーワード：乳房超音波画像、コンピューター診断支援、異常検知、深層ニューラルネットワーク、画像セグメンテーション

1. はじめに

乳がんによる死亡者数の増加は深刻な社会問題となっており、早期発見による良好な予後のためには定期的な乳がん検診が重要である。がん検診における乳房超音波検査では、医師(検査者)が超音波プローブを操作すると同時に、描出される乳房超音波画像を観察し、病変部位を発見する複数の作業を要する。そのため、乳がんの正確な発見には検査者の技量や経験を要し、経験の浅い検査者は病変を見落とす危険性がある。乳房超音波検査における病変の見落とし防止のため、乳房超音波画像から病変を自動検出するコンピューター診断支援システムが開発されている^[1]。

近年、深層学習に代表される人工知能技術の発展が著しく、超音波診断支援に適用した研究も多く報告されている^{[2][3]}。山崎らの文献^[4]では、乳腺以外の部位における過検出を抑制するため、乳腺組織を自動抽出し、乳腺以外に位置する腫瘍候補を抑制することで検出精度の

向上を図る手法が提案されている。しかし、山崎らの手法では乳腺の周辺領域における領域分割の精度が低く、腫瘍の検出精度が十分ではなかった。

そこで本稿では、深層ニューラルネットワークを用いた腫瘍候補の検出と乳腺領域の抽出結果を統合し、高精度な腫瘍検出を行う手法を提案する。

2. 乳房超音波画像

乳房超音波検査では、検査者(医師)が超音波プローブを乳房にあて、超音波プローブを操作しながら超音波診断装置のディスプレイに表示される超音波画像を観察する。プローブから組織に超音波を放射し、反射された超音波の振幅をグレースケールの輝度値に変換することで画像を描出する。組織の構造に応じて反射される超音波の振幅が異なるため、明るさの違いとしておのおのの組織の構造を観察することができる。乳房における超音波画像では、画像上部から順に、皮膚や脂肪、乳腺、筋肉と肋骨が順に描出される。乳腺組織で発生するがんが乳がんであり、乳房超音波検査では、乳腺組織に着目して検査を行う。

*1 筑波大学大学院システム情報工学研究科
知能機能システム専攻

[〒305-8577 つくば市天王台 1-1-1]

e-mail : kevin.yang@aist.go.jp

*2 産業技術総合研究所

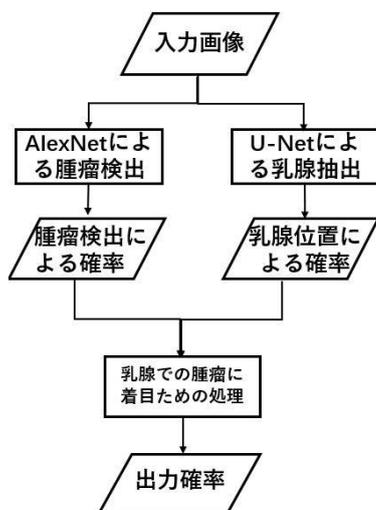


図1 提案手法のフローチャート

3. 提案手法の構成

本研究で検出の対象とする乳がんは、超音波画像診断において、皮下脂肪と筋肉の中間に位置する乳腺組織に腫瘍像として観察される。そのため、過検出の抑制のためには、画像中の乳腺組織の占める位置を検出する必要がある。

提案手法の流れ図を図1に示す。提案手法において、腫瘍像の検出を行う超音波画像は、異なる2つのニューラルネットワークモデルに入力される。腫瘍候補領域の検出(図1左)には、事前学習済みのAlexNetを利用し、画像中の局所領域に腫瘍が含まれるかの検出を行う。さらに検出結果による過検出を抑制するために、乳腺領域の抽出(図1右)では、U-Netによる乳腺領域抽出を行う。最終的な腫瘍候補の提示の際には、U-Netによる乳腺領域の抽出結果と腫瘍検出モデルの出力を統合することで、乳腺領域以外に生じた腫瘍像の過検出を削減する。

3.1 AlexNetによる腫瘍像の検出

Krizhevskyらが提案したAlexNet^[5]は、大規模画像認識コンペティションであるILSVRC 2012の画像認識タスクにおいて、最高の認識率を達成したモデルである。AlexNetは227×227pxのRGB画像(3チャンネル)カラー画像を入力に取り、1000個のオブジェクトカテゴリへ分類するモデルである。腫瘍候補領域の検出において

は、乳房超音波画像は既定サイズに分割された矩形領域(パッチ)単位ごとにリサイズを行いAlexNetへと入力され、パッチ毎に乳腺らしさの確率(0~1)が出力される。AlexNetのもつ汎化性能を十全に引き出すために、転移学習の技術を用いて、一般画像(ImageNet)で事前学習済みのAlexNetモデルに乳房超音波画像における腫瘍候補を検出させる。転移学習とは、医療画像のように学習データが少量に限られるタスクへと機械学習手法を適用する際に、データ量の多い別のドメインのタスクについて学習させたモデルがあるとき、関連する別ドメインのタスクに対して学習済みのモデルを利用する手法である^[6]。

実際の乳房超音波画像データにおいて、腫瘍(異常)の箇所は正常箇所に対して相対的に少なく、クラス間のデータ量が著しく不均衡である。そのため、転移学習の際にデータ数の大きいクラスに出力が過剰に適合し、病変の見落としに繋がる。したがって、学習の際に学習データの不均衡に対して、その影響を削減するための対策が必要である。

本研究では、AlexNetの学習における損失関数に、クラス不均衡を削減する重み付きクロスエントロピー損失^[7]を用いて、上記の問題の解消を図った。モデルの出力 Y と、真のラベル T の間の重み付きクロスエントロピー損失 L は式(1)で与えられる：

$$L = -\frac{1}{N} \sum_{n=1}^N \sum_{i=1}^K w_i T_{ni} \log(Y_{ni}) \quad (1)$$

ここで N はデータセットのサンプル数、 K はクラス数である。 w は誤差関数のハイパーパラメータで各クラスごとの損失の重みを表す。 w は一般にクラスごとのデータ数の割合によって定める。提案手法ではこの重み付きクロスエントロピー損失関数を用いて、クラス間のコストを均衡させ、AlexNetの転移学習を行う。

3.2 U-Netによる乳腺領域のセグメンテーション

セマンティックセグメンテーションは画像の各画素を、クラスに分割する問題の総称である。すなわち、画像から特定の物体や領域の占

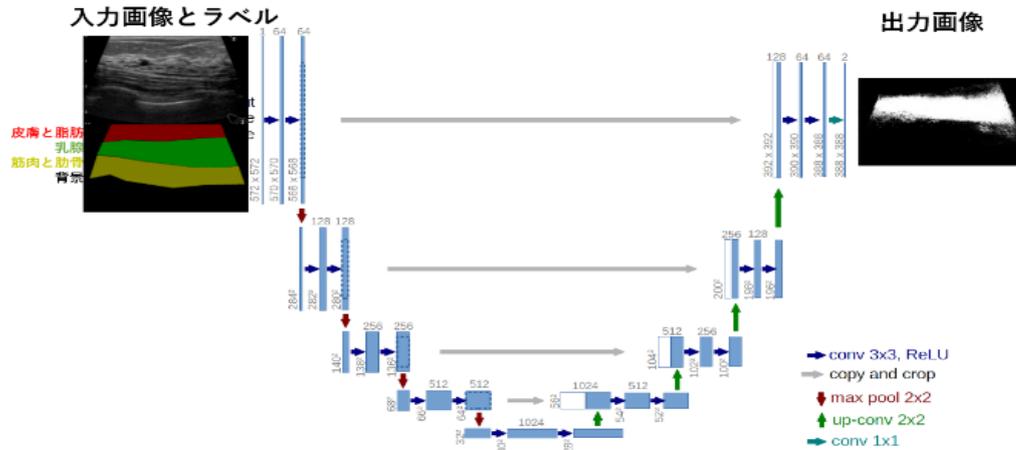


図2 U-Netの構造 [8]より引用、一部改変

める空間的情報を最も精緻に抽出する問題とも言える。

U-Net [8] は 2015 年に発表されたピクセル単位の画像セグメンテーションを行うためのモデルであり、主に医用画像を対象として設計されている。U-Net は図 2 のような Encoder-Decoder 構造を持つモデルである。

提案手法においては乳腺組織領域を抽出するために、U-Net を用いた。U-Net の学習の際には、脂肪、乳腺、筋肉組織とそれ以外の背景の 4 クラスにセグメンテーションを行い、超音波画像の各画素に対して、乳腺領域の確率を算出する。

3.3 乳腺領域の確率による腫瘍検出

本節では、AlexNet を用いた腫瘍を含むパッチ画像の検出結果と、U-Net による乳腺領域の抽出結果の統合手法について述べる。まず、AlexNet により腫瘍が検知されたパッチのうち、出力の Softmax 層において $P_{AlexNet} = 0.9$ 以上の確率で腫瘍を含むと検出されたパッチ画像を腫瘍候補として検出する。

これらの腫瘍候補は、乳腺組織の位置を考慮しない矩形切り出しから得られているため、乳腺領域の過検出を多く含む。そこで 3.2 節で得られた各ピクセルに対する乳腺の確率の算出結果を用いて、乳腺領域外から得られた腫瘍候補のパッチ画像を除去する。いま、U-Net の出

力として得られた各ピクセルの乳腺領域の確率マップを $I_{ij} \in \mathbb{R}^{w \times h}$ とする。ここで $w = 794, h = 493$ はそれぞれ画像の横および縦のピクセル数である。はじめに、画像の乳腺領域に関する確率マップを大津の二値化法 [9] によって、バイナリ画像に変換する。ここでピクセル値が 1 の画素が、U-Net により乳腺領域とされた領域である。次に式 (3) のように画像の各縦方向の位置 j における乳腺領域の確率を算出する：

$$P_{\cdot j}^{Seg} = \frac{\sum_{i=1}^w I_{\cdot j}}{\max_j \sum_{i=1}^w I_{\cdot j}} \quad (3)$$

ここで検知矩形領域の中心ほど乳腺が存在する確率が高いという仮定の下で、矩形領域中の腫瘍に注目するため、1次元ガウスマルタ処理を行う。1つの異常候補の検知窓に対して式 (4) のように、腫瘍である確率 P_{detect} を算出する。

$$P_{detect} = P_{AlexNet} \sum_{y=1}^{100} P_{\cdot y}^{Seg} \cdot \mathcal{N}_{50}(y) \quad (4)$$

ここで、 $\mathcal{N}_{50}(y)$ は平均 50、分散 225 のガウス分布であり、大きさ 100×100 px の検知窓の中心にピークを持つ。

P_{detect} を一つの入力データセットから得られた Q 個の腫瘍候補領域すべてに対して求め、腫瘍の検出確率の列 $[P_{d1} P_{d2} \dots P_{dQ}]$ を得る。最終的な腫瘍の検出の際には、これらの腫瘍の検出確率の列 $[P_{d1} P_{d2} \dots P_{dQ}]$ に対して、1次元の K-means [10] を利用し、過検出と正例の 2 クラスタ

に分類する。これらのクラスタ中心のうち、大きな値を持つ方を正例とし、このクラスタ中心 θ_{TP} を腫瘍検知の閾値として $P_{\text{detect}} > \theta_{TP}$ を満たす矩形領域を腫瘍として検出する。

4. 実験

4.1 AlexNet による腫瘍像の検出

4.1.1 データセット

実験では AlexNet の入力として、乳房超音波画像から切り出した $100 \times 100 \text{px}$ のパッチ画像を用いた。画像の前処理として、各パッチ画像に対して、超音波画像に多く含まれるスペックルノイズを低減し、腫瘍の輪郭を強調するために、ヒストグラム均等化^[11]を行った。学習データにおいて、腫瘍を含むパッチ画像のサンプル数は、正常な画像と比較して少ないため、異常データに対してはデータ拡張によるサンプル数の水増しを行った。データ拡張には、腫瘍像を中心とした上下左右 5 px の位置ずらし、及び 3、6、9° ごとの回転によるリサンプリングを行った。これらの処理により、1つの腫瘍像に対して 12 枚のパッチ画像を生成した。実験に用いた異常・正常を含むパッチ画像のデータ量を表 1 に示す。

表 1 腫瘍像検知のデータセット

	正常 画像	異常画 像拡張 なし	異常画 像拡張 あり
学習用 (12 名)	90,405	1,471	17,652
検証用 (2 名)	21,454	462	/
テスト用 (3 名)	29,805	162	

4.1.2 比較手法

実験では、四つの比較手法を用いて腫瘍の検出精度の比較を行った。Method1 と Method2 は、ImageNet により学習済みの AlexNet のモデルであり、Method1 は重み付き Softmax 層、Method2 は通常の Softmax 層を用いた。重み付き Softmax 層におけるクラスごとの重みは正常: 0.1、異

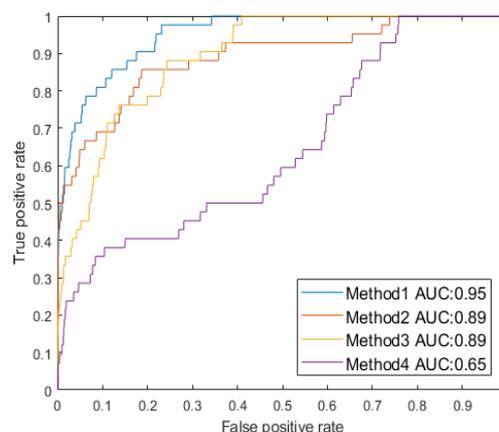


図 3 ROC 曲線による各手法の比較

常: 0.9 とした。Method3 と Method4 では、転移学習を用いずに AlexNet のモデルを利用した。Method3 は重み付き Softmax 層を利用したモデル、Method4 は通常の Softmax 層を用いたモデルである。

4.1.3 評価方法と結果

腫瘍の検出性能を評価指標として、receiver operating characteristic (ROC)^[12] 曲線を用いた。ROC 曲線は、検知結果の過検出率(false positive fraction)と検出率(true positive fraction)をプロットした軌跡を表したグラフである。ROC 曲線が左上に近づくほど異常検出性能が高いといえる。更に、ROC 曲線が左上に近づくことを定量的に表した指標が (area under the curve; AUC) 値である。AUC 値は ROC 曲線の右下領域の面積を表し、AUC 値が 1 に近いほど異常検出の性能が高いことを表している。実験の結果得られた ROC 曲線と AUC 値を図 3 に示す。

図 3 から、Method 1 の ROC 曲線は Method2、3、4 と比較して左上にあり、AUC 値が最も高いことがわかる。

4.2 U-Net による乳腺領域のセグメンテーション

4.2.1 データセット

U-Net の学習においては、7 名の被験者から得られた 475 枚の $794 \times 493 \text{px}$ 超音波動画像を

学習データとして使用した。ラベルは手作業で脂肪と乳腺と筋肉と背景の4種類を付けた。検証データセットには同一の患者を含まない44枚の乳房超音波画像を用いた。

4.2.2 評価方法と結果

画像セグメンテーションの性能を評価指標として、最も広く用いられる Intersection over Union (IoU) を用いた。各クラスの IoU は、正しく分類されたピクセル数と、真にそのクラスに含まれるピクセルの合計数の比率である。

$$\text{IoU スコア} = \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}} \quad (5)$$

ここで TP, FP, FN はそれぞれ真陽性、偽陽性、および偽陰性のピクセル数を表す。

U-Net の学習においては、最適化アルゴリズムに慣性項付き確率的勾配降下法 (Momentum-SGD) を用いた。慣性項は $\alpha=0.9$ 、学習率は $\eta=0.005$ 、Weight decay における L2 正則化項は 0.005 とし、学習曲線が十分に収束するまで 1000 エポックの学習を行った。上記のパラメータで学習させたモデルによるセグメンテーションの結果を表2に示す。

表2 U-Net による IoU の結果

	学習	テスト
背景	0.8022	0.6590
脂肪	0.7859	0.6460
乳腺	0.7050	0.6208
筋肉	0.4706	0.2403

4.3 乳腺領域の確率による腫瘍検出

提案手法の有効性を検証するため、腫瘍ありと判定された5名の患者 (AlexNet と U-Net に使用しないデータ) から撮影された乳房超音波画像を用いて腫瘍検出実験を行った。

4.3.1 実験条件

実験で使用した超音波画像は 256 階調値のグレースケール画像であり、縦 493px、横 794px、

フレームレートは 34fps の動画画像である。異常検知実験のデータでは、フレーム画像から縦横各 100px のパッチ画像を使用した。テスト画像からの腫瘍検出においては、動画画像の各フレームに対して横方向 20px、縦方向 10px の移動幅で、100×100px の検知窓を切り出して検出を行った。

4.3.2 評価方法と結果

提案手法の評価には学習データに含まれない5名の患者から撮影された乳房超音波動画画像をテスト画像として用いた。提案手法による、検知窓単位での検出結果を表3に示す。また、テスト画像に含まれる腫瘍像の検出率を表4に示す。

表3 腫瘍検知と過検出を抑制する結果

患者 ID	検出窓総数	異常検出ネット	提案手法	正解
01	575,672	5599	811	344
02	512,272	516	32	32
03	616,248	5654	167	85
04	811,520	3415	202	51
05	1,298,432	6489	752	446
合計	3,814,816	21673	1964	959

表4 腫瘍を含むフレーム数ごとの評価

患者 ID	動画のフレーム総数	腫瘍を含む	AlexNet で検出	提案手法で検出
01	227	29	29	29
02	202	6	6	6
03	243	15	15	10
04	320	8	8	8
05	512	47	47	47
合計	1504	105	105	100

表3から読み取れるように、AlexNet 単体による腫瘍の検出精度は $959/21673=4.42\%$ であるのに対して、提案手法による結果は $959/1964=48.8\%$ と、提案手法により過検出を大

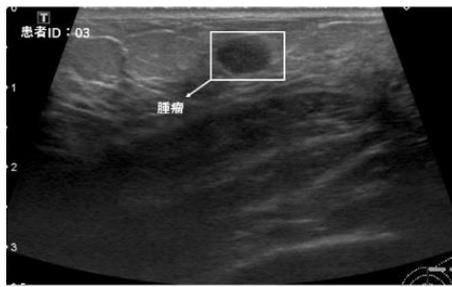


図 4 フレームで見落としの例

幅に抑制できることがわかった。一方で、表 4 に見るように、AlexNet 単体による腫瘍の再現率は 100%であるのに対し、提案手法では 95.2%患者 03 の腫瘍を含む 5 フレームで見落としが生じた。これは AlexNet による腫瘍候補領域の検出の際に Softmax 層の出力の閾値を 0.9 と高く設定したためであると考えられる。図 4 に被験者 03 における見落としフレームの例を示す。

提案手法により、AlexNet 単体の結果と比較して、過検出が大幅に抑制されたものの、提案手法で除去できない乳腺領域における過検出は依然として多い。過検出の例を図 5 に示す。これらの過検出を一層抑制するための、今後の課題としては、以下が挙げられる。

- ① 腫瘍検出モデルと乳腺領域分割モデルそれぞれの性能を向上させる
- ② 超音波検査が動画である特性を活かし、時間方向の隣接フレーム情報も加えて、腫瘍検出を行う
- ③ 腫瘍候補の検知モデルを乳腺の画像のみで学習させる。

5. まとめ

本論文では、乳がんの発生する乳腺以外での腫瘍の過検出を低減するために、乳腺領域の自動抽出と腫瘍候補領域の検出を組み合わせた、深層ニューラルネットワークによる腫瘍検出

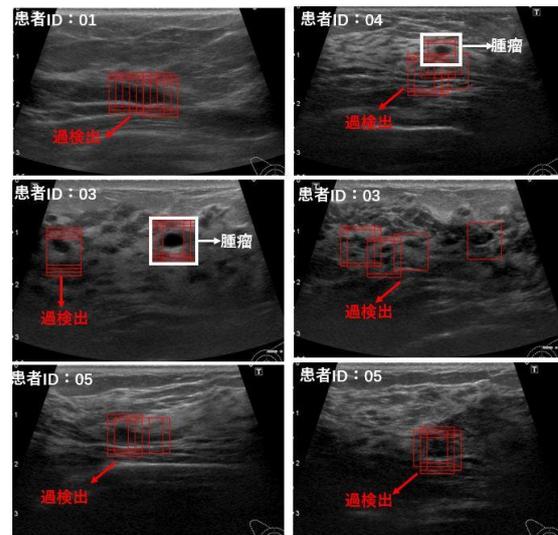


図 5 過検出の例

手法を提案した。提案手法では、画素単位の領域分割を行う深層学習モデルである U-Net を用いて、乳房超音波画像から腫瘍が発生しうる乳腺領域の抽出を行い、超音波画像中から乳腺領域の位置を推定する。次に、事前学習済みの深層畳み込みニューラルネットワークと重み付き識別層を組み合わせた転移学習モデルを用いて、超音波画像中のパッチ画像からの腫瘍検出を行った。

実験では提案手法の有効性を検証するため、腫瘍ありと判定された 5 名の患者から撮影された、乳房超音波画像に対して提案手法を適用した。提案手法による、腫瘍像のフレーム単位での検出率は 95.24%であり、さらに乳腺領域の抽出結果との統合によって、異常検知のみを用いる手法と比較し過検出を大幅に低減した。

利益相反の有無

本研究における利益相反は存在しない。

文 献

- [1] Cheng, Heng-Da, et al. "Automated breast cancer detection and classification using ultrasound images: A survey." *Pattern recognition* 43.1 (2010).299-317.
- [2] Haskins, Grant, Uwe Kruger, and Pingkun Yan. "Deep Learning in Medical Image

- Registration: A Survey." arXiv preprint arXiv:1903.02026 (2019).
- [3] Razzak, Muhammad Imran, Saeeda Naz, and Ahmad Zaib. "Deep learning for medical image processing: Overview, challenges and the future." *Classification in BioApps*. Springer, Cham, (2018). 323-350.
- [4] 山崎優大, et al. "乳腺超音波画像からの異常検出に関する研究." 電気情報通信学会東京支部学生会研究発表会, 東京 13 (2012).
- [5] K Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks [C]//Advances in neural information processing systems. (2012). 1097-1105.
- [6] Pan, Sinno Jialin, and Qiang Yang. "A survey on transfer learning." *IEEE Transactions on knowledge and data engineering* 22.10 (2009).1345-1359.
- [7] Guiaşu, S. Weighted entropy. *Reports on Mathematical Physics*, 2(3), 165-179. (1971).
- [8] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation[C]//International Conference on Medical image computing and computer-assisted intervention. Springer, Cham, (2015).234-241.
- [9] Otsu N. A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, (1979).9(1). 62-66.
- [10] Jain, Anil K. "Data clustering: 50 years beyond K-means." *Pattern recognition letters* 31.8 (2010).651-666.
- [11] Singh R P, Dixit M. Histogram equalization: a strong technique for image enhancement[J]. *International Journal of Signal Processing, Image Processing and Pattern Recognition*, (2015). 8(8).345-352.
- [12] Hanley, James A., and Barbara J. McNeil. "The meaning and use of the area under a receiver operating characteristic (ROC) curve." *Radiology* 143.1 (1982). 29-36.

Tumor Detection in Breast Ultrasound Images by Deep Neural Network with Automatic Extraction of Mammary Gland Region

Kaiwen YANG^{*1}, Jiaying YE^{*2}
Aiga SUZUKI^{*1,*2}, Hidenori SAKANASHI^{*1,*2}

*1 Graduate School of Systems and Information Engineering, University of Tsukuba

*2 National Institute of Advanced Industrial Science and Technology (AIST)

The realization of a diagnosis support system using machine learning technology is expected in order to improve the detection rate of a mass in breast ultrasonography. Conventional methods overdetect the mass due to noise in the image and the effects of fat and muscle other than the mammary gland. In this paper, in order to solve this problem, we propose a mass detection method by deep neural network combining automatic extraction of mammary gland area and detection of mass candidate area. In the proposed method, we use the deep learning model AlexNet and U-Net to detect the mass candidate and the mammary gland region, integrate the likelihood of the mass likelihood and mammary likelihood output from both, and make the final judgment. In the experiment, it was confirmed that detection accuracy was improved and over-detection was reduced compared to the conventional method, using a data set acquired by actual mammary gland ultrasonography.

Key words: Breast ultrasound images, Computer-aided detection, Anomaly detection, Deep neural network, Image segmentation

レディオミクスによる肺がんの再発リスクの予測

-レディオミクス特徴量の比例ハザード性の検証-

吉岡 拓弥*¹ 内山 良一*²

要旨

レディオミクス研究では、生存時間分析の代表的な手法であるコックス回帰モデルが用いられることが多い。しかし、病変から取得したレディオミクス特徴量は、比例ハザード性を満たしていない可能性がある。本研究では、肺がんの再発リスクの予測にコックス回帰モデルを適用した。患者の治療前 CT 画像の腫瘍領域を手動でマーキングし、腫瘍領域から 367 項目のレディオミクス特徴量を取得した。367 項目から Lasso を用いて 5 項目を選択し、選択された 5 項目のレディオミクス特徴量を入力変数としてコックス回帰モデルを構築した。レディオミクス特徴量の比例ハザード性を Schoenfeld 残差によって検証した。実験の結果、レディオミクス特徴量が比例ハザード性を満たす可能性は低く、比例ハザード性を仮定しないモデルを適用すべきとの知見を得た。

キーワード：レディオミクス、再発、肺がん、コックス回帰モデル、比例ハザード性

1. 緒言

病院内に蓄積されたビッグデータを活用し、知的情報処理技術を用いて医療の支援を行う研究に、コンピュータ支援診断[1]とレディオミクス[2-8]がある。コンピュータ支援診断は、病変の存在診断や良悪性の鑑別診断の支援に応用されてきた。一方、レディオミクスは、病変を発見した後の医療のプロセスを支援するもので、サブタイプ分類や予後予測に関する研究が行われている。医療は、存在診断、鑑別診断、治療の順番に行われるから、コンピュータ支援診断は前半の医療を、レディオミクスは後半の医療を支援するシステムとして分類できる。

レディオミクスによる予後予測に関する研究では、画像の病変部から得た高次元画像特徴

量（レディオミクス特徴量）を入力変数としたコックス回帰モデルが用いられることが多い[8-10]。コックス回帰モデルを用いるときの不可欠な仮定は、「比例ハザード性」である。もし比例ハザード性が成り立たなければ、モデルの線形成分が時間とともに変化するを意味する。レディオミクス特徴量は、病変の形状や濃度変化など病変の活動と関係した特徴量であるため、レディオミクス特徴量の値が時間とともに変化する可能性が高い。そこで本研究では、肺がんの再発リスクの予測を例に、肺がん患者の治療前 CT 画像から得たレディオミクス特徴量が、比例ハザード性を満たすのかを検討した。

2. 実験試料

本実験では、The Cancer Imaging Archive[11]の NSCLC-Radiogenomics を用いた。NSCLC-Radiogenomics には、非小細胞肺癌患者 211 例が収録されている。そのうち、ステージ I に分類された 80 例を選択し、それらの治療前 CT 画

*1 熊本大学大学院保健学教育部
[〒862-0976 熊本県熊本市中央区九品寺 4 丁目
24 番 1 号]

e-mail: 181w0210@st.kumamoto-u.ac.jp

*2 熊本大学大学院生命科学研究部（保）

像および再発までの時間を実験に用いた。

3. 方法

本手法の概要を述べる。まず、取得した患者の CT 画像から腫瘍領域を手動でマーキングし、マーキングした領域のレディオミクス特徴量を一般公開されているソフトウェア MaZda[12]を用いて 367 項目取得した。次に、367 項目のレディオミクス特徴量から再発リスクの予測に有用な特徴量を least absolute shrinkage and selection (Lasso)[13]を用いて 5 項目選択した。選択した 5 項目のレディオミクス特徴量を入力変数としたコックス回帰モデルを用いて再発リスクの予測を行った。コックス回帰モデルは、比例ハザード性を仮定したモデルである。よって、レディオミクス特徴量が比例ハザード性を満たすのかの検証を行った。

1) 腫瘍領域のマーキング

80 例の CT 画像に対して、腫瘍が最も大きく描出されているスライス画像を 1 枚選択して実験に用いた。腫瘍領域は著者の 1 人が手動でマーキングした。この際、腫瘍の形状特徴が正確に計算できるように、スピキュラも含めてマーキングした。

2) レディオミクス特徴量の計測と選択

マーキングした腫瘍領域のレディオミクス特徴量は特徴量解析ソフトウェアとして一般公開されている MaZda[12]を用いて 367 項目取得した。レディオミクス特徴量を取得する際のパラメータは MaZda のデフォルト値をそのまま用いた。例えば、テクスチャ特徴量を計算するための濃度共起行列を取得する際のパラメータは、濃度階調が 16、画素間の距離が 1~5、方向が 0 度、45 度、90 度、135 度である。

実験に用いた患者が 80 例であるのに対し、レディオミクス特徴量が 367 項目であるため、再発の予測に有用なレディオミクス特徴量を選択して次元削減を行う必要があった。そこで、Lasso[13]を用いてレディオミクス特徴量を 5 項目選択した。

3) 再発リスクの予測

再発リスクの予測法は、2 つのモデルに大別される。1 つ目は、1 年後などの期間を固定した場合に、再発した症例と再発しない症例の 2 群を区別するパターン認識の問題として取り扱う考え方。2 つ目は、再発までの時間を入力変数として用いて生存時間分析の問題として取り扱う考え方である。後者の利点は、単に再発の有無を予測できるだけでなく、再発までの時間の予測が可能であるため、経過観察をどのくらいの間隔で行えば良いかの目安を得ることができる点である。そこで本研究では、後者のモデルを検討した。

(1) コックス回帰モデル

コックス回帰モデル[14]は、生存時間分析の基本的なモデルである。本研究では、再発リスクの予測に応用するために、死亡のイベントを再発に置き換えることでモデルを構築した。ある特定の時間における当該患者の死亡のハザードが p 個のレディオミクス特徴量 X_1, X_2, \dots, X_p の値 x_1, x_2, \dots, x_p に依存すると仮定した場合、 i 番目の患者のハザード関数 $h_i(t)$ は、次式で表すことができる。

$$h_i(t) = \exp(\beta_1 x_1 + \dots + \beta_p x_p) h_0(t) \quad (1)$$

ここで、 β_p はレディオミクス特徴量の係数を表す。また、 $h_0(t)$ はベースラインハザード関数と呼ばれ、すべてのレディオミクス特徴量の値がゼロである患者のハザード関数を表す。パラメータ係数 β_p の値は、実験データから最尤法を用いて決定することができる[14]。ハザード関数は、当該患者が時点 t で生存していたという条件のもとでその時間に死亡する確率である。しかし、このハザード関数は結果の表示には用いられず、一般的には生存関数（本研究では再発関数と表現するのが適切かもしれない）が用いられる。生存関数とは、生存時間が t 以上となる確率 $S(t)$ であって、ハザード関数から累積ハザード $H(t)$ を求め、 $S(t) = \exp\{-H(t)\}$ に代入することによって求められる。

(2) 比例ハザード性

コックス回帰モデルを用いるときの不可欠な仮定は、「比例ハザード性」である[14,15]. ここで、1つの変数を含むコックス回帰モデルを考える. (1)式のハザード関数を

$$h(t, x, \beta) = \exp(\beta x)h_0(t) \quad (2)$$

と表現する. このハザード関数の対数を $g(t, x, \beta) = \ln[h(t, x, \beta)]$ と定義すると,

$$g(t, x, \beta) = \ln[h_0(t)] + x\beta \quad (3)$$

となる. このとき、 $x = a$ から $x = b$ までの変化の対数ハザード関数の差は、

$$[g(t, x = a, \beta) - g(t, x = b, \beta)] = (a - b)\beta \quad (4)$$

であるから、対数ハザードの差は時間に依存しない. この仮定を「比例ハザード性」と呼ぶ. もし、比例ハザード性が成り立たないならば、モデルの線形成分 ($x\beta$: 変数の値) が時間とともに変化することを意味する. 一般に、病変から得たレディオミクス特徴量の値が時間とともに変化しないという仮定は成り立つのだろうか. 病変は、悪性度が高くなるに連れて、形状や濃淡が歪になるのではないか. もし、そうであるならば、コックス回帰モデルを用いた解析は、レディオミクス研究には、不適切であると判断できる.

Schoenfeld 残差は、コックス回帰モデルを当てはめた後の比例ハザード性の評価に用いられる. 詳細は文献[14,15]に譲るが、Schoenfeld 残差が、ランダムにゼロ付近に散在しているならば、比例ハザード性を満たす. そこで本研究では、各レディオミクス特徴量の Schoenfeld 残差を求めてプロットすることによって、比例ハザード性の検証実験を行った.

4. 実験結果及び考察

Lasso により選択された5項目のレディオミクス特徴量を表1に示す. Perc.90 は、腫瘍領域を二値化処理する際に、全領域の90%が画素値0(黒)となる画素値の値を表す. GrKurtosis は、注目画素(x, y)に対して、($x-1, y$)と($x+1, y$)の差の2乗、ならびに($x, y-1$)と($x, y+1$)の差の2乗の和の平方根を注目画素における濃度勾配と定義した時、領域内の各画素の濃度勾配の尖

度を表す. GeoY は、腫瘍領域の重心の垂直 (y 軸) 座標を表している. GeoAox は、オリエンタル角度を表している. GeoW9 は、腫瘍領域に外接する長方形の面積を腫瘍領域に存在する画素数で除した値である.

表1 選択されたレディオミクス特徴量

	レディオミクス特徴量
#1	Perc.90
#2	GrKurtosis
#3	GeoY
#4	GeoAox
#5	GeoW9

図1に、5項目のレディオミクス特徴量に関する Schoenfeld 残差の散布図および平滑化曲線を示す. 図に見られるように、残差の値がゼロ付近に散在しているとは言えず、平滑化曲線も大きく湾曲している. したがって、レディオミクス特徴量は、比例ハザード性を満たしているとは考えられず、コックス回帰モデルを用いた解析は、不適切である判断できる.

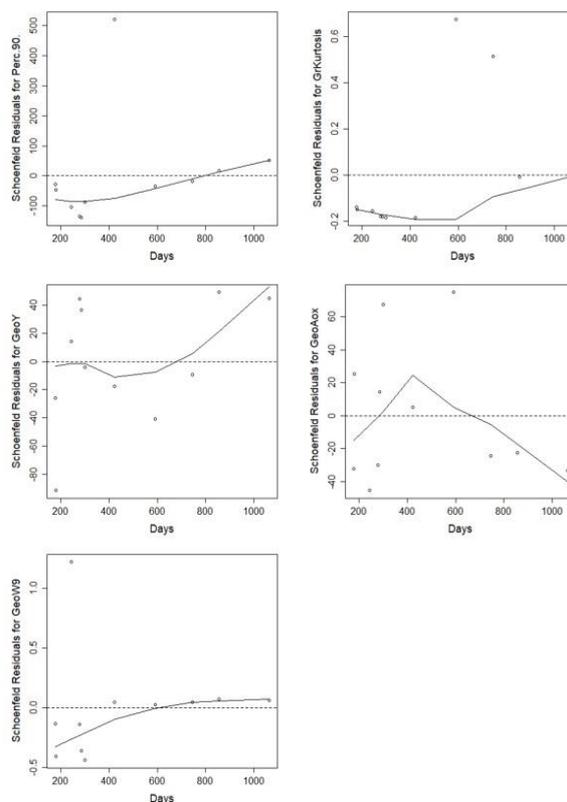


図1 選択された5項目のレディオミクス特徴量に関する Schoenfeld 残差の散布図および平滑化曲線

5. まとめ

治療前の CT 画像から得たレディオミクス特徴量を用いて肺がん患者の再発リスクを予測する手法を考案した。レディオミクス特徴量は比例ハザード性を満たしていない可能性が高いため、一般的に生存時間分析で用いられるコックス回帰モデルを用いた分析手法は、レディオミクス研究には不適切であると判断できる。今後は、比例ハザード性を仮定しない生存分析の手法を採用して再発リスクを予測する方法の研究開発を行う予定である。

利益相反の有無

なし

文 献

- [1] Li Q, Nishikawa RM, Computer-aided detection and diagnosis in medical imaging, CRC Press, 2015.
- [2] Gillies RJ, Kinahan PE, Hricak H, Radiomics: images are more than pictures, they are data, *Radiology*, 278(2), 563-577, 2016.
- [3] Mazurowski MA, Radiogenomics: what it is and why it is important, *Journal of American College of Radiology*. 12(8):862-866, 2015.
- [4] Phillips I, Ajaz M, Ezhil V, et al., clinical applications of textural analysis in non-small cell lung cancer, *Br J Radiol*, 91(1081): 20170267, 2018.
- [5] Thawani R, McLane M, Beig N, et al., Radiomics and radiogenomics in lung cancer: A review for the clinician, *Lung Cancer*, 115: 34-41, 2018.
- [6] Shi L, He Y, Yuan Z, et al., Radiomics for response and outcome assessment for non-small cell lung cancer, *Technology in Cancer Research & Treatment*, 17: 1-14, 2018.
- [7] Ferreira Junior JR, Koenigkam-Santos M, Cipriano FEG, et al., Radiomics-based features for pattern recognition of lung cancer histopathology and metastases, *Computer Methods and Programs in Biomedicine*, 159: 23-30, 2018.
- [8] Aerts HJ, Velazquez ER, Leijenaar RT, et al., Decoding tumour phenotype by noninvasive imaging using a quantitative radiomics approach, *Nature Communications*, 5:4006, 2014.
- [9] Li Q, Kim J, Balagurunathan Y, et al., CT imaging features associated with recurrence in non-small cell lung cancer patients after stereotactic body radiotherapy, *Radiat Oncol.*, 12: 158, 2017.
- [10] Mattonen SA, Davidzon GA, Bakr S, et al., [18F] FDG Positron Emission Tomography (PET) Tumor and Penumbra Imaging Features Predict Recurrence in Non-Small Cell Lung Cancer. *Tomography*. 5(1): 145-153, 2019.
- [11] NSCLC-Radiomics, <https://wiki.cancerimagingarchive.net/display/Public/NSCLC-Radiomics>, 最終アクセス日 2019年5月11日.
- [12] MaZda, <http://eletel.eu/mazda>, 最終アクセス日 2019年5月11日.
- [13] 杉山将, 井出剛, 神鷲敏弘, 他, 監訳. 統計的学習の基礎 データマイニング・推論・予測. 共立出版, 東京, 2014.
- [14] Collett D: Modelling survival data in medical research, second edition. Chapman & hall CRC, 2003.
- [15] David WH, Lemeshow S, May S: Applied survival analysis, regression modeling of time-to-event data, second edition, John Wiley & Sons, Inc., 2008.

Prediction of the recurrence risk in patients
with lung cancer using radiomics
-Verification of proportional hazards property of radiomic features-

Takuya YOSHIOKA^{*1}, Yoshikazu UCHIYAMA^{*2}

^{*1} Gradient School of Health Science, Kumamoto University

^{*2} Department of Medical Physics, Faculty of Life Sciences, Kumamoto University.

Cox regression model, which is a typical method for survival data analysis, is often used in radiomics researches. However, radiological features obtained from the lesions might not satisfy with proportional hazards property. In this study, Cox regression model was applied to predict the recurrence risk of lung cancer. First, we manually segmented the tumor regions and subsequently determined 367 radiomic features. Five radiomic features were selected by using least absolute shrinkage and selection (Lasso). Cox regression model with 5 selected radiomic features was employed for the estimation of recurrence risk. The proportional hazards property of the radiomics features were verified by Schoenfeld residuals. As the experimental result, we found that the possibility in which radiomics features satisfy with proportional hazards property was low. Therefore, we got a knowledge that another model which does not assume proportional hazards property should be used for the survival data analysis in radiomics researches.

Key words: Radiomics, Recurrence, Lung cancer, Cox regression model, Proportional hazards property

深層学習を用いた胃 X 線検査画像における 腫瘍領域自動検出の試み

市川 梨沙*1 野村 敬清*2 彌富 仁*1 橋本 順*2

要旨

X 線検査は CT や MRI, 内視鏡検査などの専門的検査方法と比べて容易なため, がんのスクリーニングとして集団検診で広く利用され検診者母数が極めて大きい. 一方でがん等疾病の検出感度は専門的検査と比較して低いという問題がある. 機械学習を用いた自動診断支援に関する研究も主に後者の専門的検査結果を対象としたものがほとんどであり, 胃部 X 線検査に対する近年の成果は極めて数少ない. こうした背景から本研究では物体検出と識別を同時に行う深層学習手法である **single shot multibox detector (SSD)**を用いた胃部 X 線検査画像を対象とした腫瘍領域の自動検出システムを試作した. 本システムは胃がん患者 39 名, 計 375 枚の胃部 X 線検査画像を元に構成され, 患者ベースの 5-fold cross validation を用いた腫瘍検出能として平均 F 値=14.81(再現率=92.82%, 特異度=8.05%)を実現した.

キーワード: 胃部 X 線, 深層学習, 自動診断支援, 集団検診

1. はじめに

日本では年間約 100 万例のがんが新たに診断され, 約 37 万人の死亡が確認されている. 死亡数を部位別にみると胃がんは第三位で約 12% を占める. 胃がんは進行が早期の段階であるほど発症後の生存率が高く, ステージ 1 で診断された場合の 5 年相対生存率は 94.9%である. このため早期発見が重要とされている[1].

発生率法を用いた胃がん検査感度の報告では, 内視鏡検査は 95.4%であり胃 X 線検査の 85.5%と比較して疾患の検出精度は高い[2]. しかし, 一日に診断できる人数に限りがあるため全ての受診者を検査することは困難である. このようながん検診の現状から, 検査が容易であり集団検診で広く利用されている胃 X 線検査でのスクリーニングによる高精度な診断が望

まれている.

近年画像認識手法である **Convolutional Neural Networks(CNN)**の医療分野への応用に関する研究が広がっている. 内視鏡画像からの胃がん検出においては再現率 92.2%, 適合率 30.6%を実現している[3]. 一方で消化管 X 線検査画像に対する診断システムの研究成果は極めて少ない.

そこで本研究では医師の胃 X 線検査での腫瘍の見逃しを無くすこと目的として, 胃 X 線検査画像において CNN による自動病変領域検出・識別システムを試作した.

2. 方法

2.1 データセット

東海大学医学部より提供された胃 X 線画像を元にデータセットを構築した. 胃に腫瘍のある患者の胃 X 線画像に対し, 専門医による腫瘍位置のマークを元に腫瘍を囲む最小の長方形(計 39 患者 375 画像中, 731 箇所)を **Ground True boxes (GT)**として生成することでデータセットを作成した.

*1 法政大学理工学部応用情報工学科
〒184-0002 東京都小金井市梶野町 3-7-2]
e-mail: iyatomi@hosei.ac.jp

*2 東海大学医学部専門診療学系画像診断学

2.2 single shot multibox detector(SSD)[4]

SSDは一般的なCNNであるVGG-16モデルをベースとしたネットワークを使用しており、本実験では入力画像を 300×300 pixelとするSSD300を用いた。SSD300は1枚の画像につき8732個のBoxを提案する。SSDの学習時には、GTとのIntersection over Union(IoU)が0.45以上の。また、本実験では予測領域に対する予測値が $\theta = \{0.15, 0.2\}$ 以上のBoxのみを表示させた。

2.3 評価手法

患者ベースの5-fold cross validationを用い、適合率および再現率を算出することで性能評価を行った。評価段階では正解領域と予測領域のIoUが0.1以上で検出成功とした。

3. 結果

表1に胃X線画像における腫瘍検出結果精度、図1に病変領域検出結果画像例を示す。

表1 腫瘍領域検出結果.

予測値 θ	0.15	0.20
適合率[%]	8.46	17.83
再現率[%]	92.82	86.33

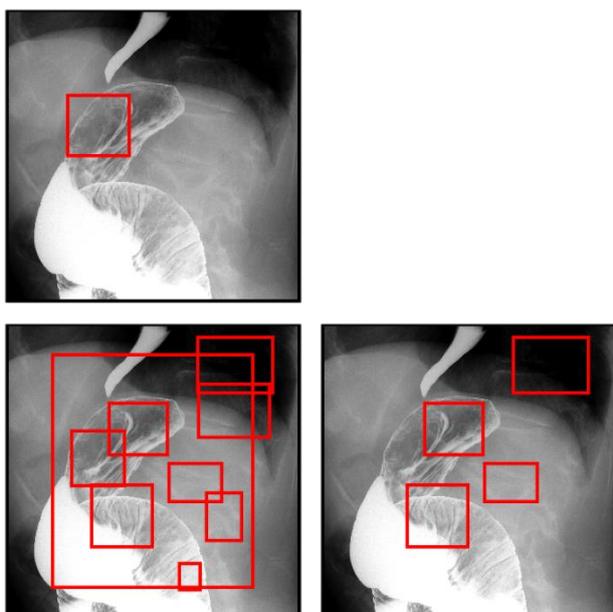


図1 腫瘍検出結果例(上段:腫瘍正解位置 下段左(検出成功): $\theta = 0.15$ 下段右(検出失敗): $\theta = 0.2$)

4. 考察とまとめ

表1より $\alpha = 0.15$ の場合、再現率において医師の診断を超える精度を実現したが、適合率が低いため誤検知が多いことがわかる。一方で $\alpha = 0.2$ の場合、誤検出は少ないが検出すべき領域の見逃しも多い。再現率と適合率はトレードオフの関係であり、予測値 θ の低いBoxを非表示とすることで誤検出の削減が可能である。しかし、本研究の目的は医師の診断見逃しを無くすることであるため、複数個の予測領域のうち正解領域が含まれ、医師の注意を引くことができれば有意義であると考えられる。

患者39名分の極めて小さいデータセットを用いて医師に匹敵する精度を実現したことから、CNNにより胃X線検査画像からの腫瘍領域の検出は可能であると考えられる。新たな患者や健全な人のデータセットを加えることにより病変領域検出精度の向上が期待できる。

利益相反の有無

なし

文献

- [1] 国立がん研究センターがん情報サービス, <https://ganjoho.jp/reg_stat/statistics/index.html>, (参照2019-5-10)
- [2] Hamashima C, Okamoto M, Shabana M, et al.: Sensitivity of endoscopic screening for gastric cancer by the incidence method. Int J Cancer, 2013
- [3] Hirasawa T, Aoyama K, Tanimoto T, et al.: Application of artificial intelligence using a convolutional neural network for detecting gastric cancer in endoscopic images. Gastric Cancer :653-660, 2018
- [4] Liu W, Anguelov D, Erhan C, et al.: Ssd:Single shot multibox detector. European Conference on Computer Vision :21-37, 2016

Preliminary study on automated detection of involved regions from abdominal X-ray images

Risa ICHIKAWA^{*1}, Takakiyo NOMURA^{*2}, Hitoshi IYATOMI^{*1}, Jun HASHIMOTO^{*2}

^{*1} Hosei University Faculty of Science and Engineering

^{*2} Tokai University School of Medicine

X-ray exams are widely used in mass screening because they are more convenient than specialized examinations such as CT, MRI, and endoscopy. On the other hand, however, there remains a problem that the sensitivity of X-ray exams them is low compared to the specialized ones. Most of studies on automated diagnosis support using machine learning is mainly for the latter, while there are very few investigations on abdominal X-ray examination despite the large number of potential patients. In such a situation, we developed an automatic tumor area detection system for abdominal X-ray images using single shot multibox detector (SSD). We used a total of 375 abdominal X-ray images from 39 patients and trained SSD. Our system attained an average F-value of 14.81 (recall=92.82%, precision=8.05%) under patient-based five-fold cross validation.

Key words: abdominal X-ray, deep learning, automated diagnosis support, mass screening

疾患股関節の CEA の自動計測と大規模データベースでの 有用性の検討

田中 雄基*¹ 日朝 祐太*¹ 大竹 義人*¹ 高尾 正樹*²

上村 圭亮*² 菅野 伸彦*² 佐藤 嘉伸*¹

要旨

大規模医用画像データベースに対する病態解析の必要性が高まっている。そこで我々は変形性股関節症に着目し、大規模医用画像データベースに対する変形性股関節症の分類である一次性と二次性の自動分類を目標とする。本研究ではそのための第一歩として三次元 CT 画像から Convolutional Neural Network (CNN) を用いて解剖学的特徴点を特定し、臨床で用いられている Center Edge Angle (CEA) を自動で計測する。また診療科を問わず網羅的に収集された約一万症例の CT データベースから変形性股関節症の有病率の測定に利用できるかを検討する。

キーワード：大規模医用画像データベース, CNN, CEA, 変形性股関節症, 解剖学的特徴点

1. はじめに

変形性股関節症とは関節軟骨の変性あるいは摩耗により関節に退行性の変化をきたす一連の疾患である。一次性と二次性に分類されており、日本では臼蓋による大腿骨頭の被覆が浅くなることによって不安定になる臼蓋形成不全に続発する二次性が多い[1]。また、股関節の骨形態異常により大腿骨頭から頸部または臼蓋に衝突が生じることで障害をきたす大腿骨寛骨臼インピンジメントが一次性的変形性股関節症の原因であると報告されている[2]。これらの疾患を診断するために単純 X 線画像を用いて臼蓋と骨頭の位置関係の評価を行い、CT 画像からより詳細な位置関係の評価し、立体的把握や術前計画に利用している。Wiberg らは骨頭中心と臼蓋外側縁を結ぶ線と骨盤水平線に対する垂線のなす角度である CEA を提案し、臨床において重要な判断材料の一つとして用いら

れている[3]。そこで本研究では、この手法を大規模医用画像データベースに自動で適用することで、変形性股関節症の有病率の測定を行うことを目的とする。本稿では、CNN を用いて三次元 CT 画像から解剖学的特徴点を自動で抽出し、CEA の計測の自動化を行い、大規模データベースへの有用性を検討する。

2. 手法

提案方法のフローチャートを図 1 に示す。CNN は三次元 CT 画像の各 Axial 断面スライスを入

*1 奈良先端科学技術大学院大学 先端科学技術研究科 情報科学領域

〔〒630-0192 奈良県生駒市高山町 8916-5〕

e-mail: tanaka.yuki.tw4@is.naist.jp

*2 大阪大学大学院 医学研究科

投稿受付：2019 年 5 月 22 日

力とし、ランドマークを推定するためのヒートマップを出力する。ただし、CT 画像に対して[-150, 350]区間での階調処理を行った画像を入力する。テスト時にはヒートマップを出力した後に、後処理として、カーネルサイズ 15x15x15、シグマ 5 pix のガウシアンスムージングを行い、三次元画像内で最大値を持つ座標を最終的なランドマークとする。

3. データセット

本研究で用いた臨床用 CT 画像は大阪大学病院で撮影された股関節変形症患者の in vivo な画像である。患者数は 88 人であり、画像の Field of view は 360x360 mm²、マトリクスサイズは 512x512、画像の解像度は 0.703125x0.703125 mm、スライス間隔は 1.0-6.0 mm で撮影した後、ボリューム全体のスライス厚が 1.0 mm になるように補間した。ランドマークの正解として 3D Slicer(NAMIC, 2008)を用いて、左右の大腿骨頭中心と臼蓋外側縁に計 4 点の解剖学的特徴点を手動で抽出した。

4. 実験

CNN の学習時に用いる正解データとして、解剖学的特徴点を中心とする三次元のガウス球 (sigma=15 pix)を作成した。自動で推定した CEA と正解の CEA との誤差で評価した。2-fold 交差検証により提案手法の有効性を検証した。CNN の構造には U-Net[4]を用いた。CEA の誤差の Boxplot を図 2 に示す。CEA の最大誤差は 52.360 deg, 最小誤差は 0.010 deg, 中央値は 5.933 deg となった。

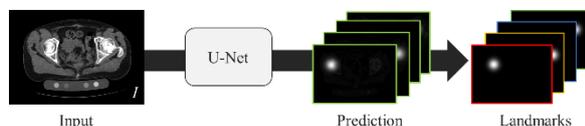


図 1 提案手法のフローチャート

5. 考察

CEA の推定誤差が大きい要因として、Axial 平面に垂直な方向でのずれが大きいと考えられる。これは CNN の入力画像が 2D のため、三次元的な骨形状を考慮出来ていないことが原因であると考えられる。

また、CEA は骨盤が後傾することによって減

少することが報告されている[5]。そのため、正確な正面像が必要になる。しかしながら、正確に正面像を撮影することは容易ではなく、本手法で推定可能な三次元方向での角度を考慮に入れた判断も臨床では重要となるのではないかと考えている。

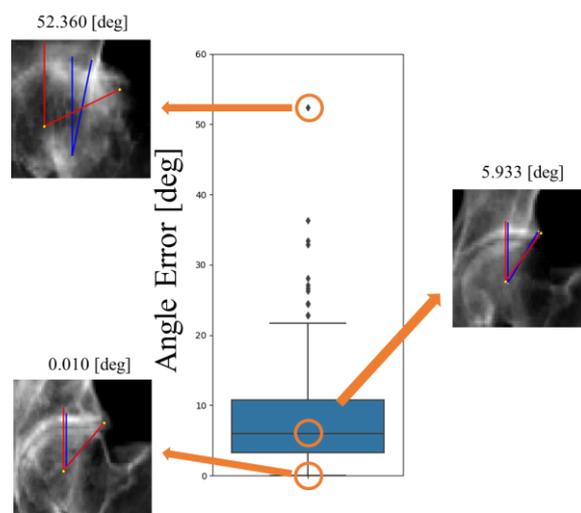


図 2 CEA の BoxPlot と最大誤差と最小誤差と中央値のときの予測結果を示す。青い角度線が CNN の予測結果であり、赤い角度線が正解である。

6. まとめ

本研究では、CNN を用いて股関節 CT 画像から CEA を測定するための解剖学的特徴点の自動抽出する手法を提案した。今後は大規模医用画像データベースに適用し、有病率の測定および、別の臨床で用いている定量的指標も含めることで変形性股関節症を評価する判断材料を増やす予定である。

謝辞

本研究の一部は、KAKENHI 19H01176 および KAKENHI 26108004 の支援による。

利益相反の有無

なし

文献

[1] Noguchi Y, Miura H, Takasugi S, et al.: Cartilage and Labrum Degeneration in the Dysplastic Hip Generally Originates in the Anterosuperior Weight-Bearing Area. An Arthroscopic Observation. *Arthroscopy* **15**: 196-506, 1999

- [2] Pollard TCB, Villar RN, Norton MR, et al.: Genetic influences in the aetiology of femoroacetabular impingement. *J Bone Joint Surg Br* **41**:209-216, 2010
- [3] Hanson JA, Kapron AL, et al.: Discrepancies in measuring acetabular coverage: revisiting the anterior and lateral center edge angles. *J Hip Preserv Surg.* 2:280–286, 2015
- [4] Ronneberger, et al.: U-Net: Convolutional networks for biomedical image segmentation. *MICCAI*, **9351**: 234-241, 2015.
- [5] 幸博和, 原俊彦 他 : 骨盤後傾に伴う股関節の荷重部傾斜角と CE 角の変化について-MPR 像を用いた検討. *整外と再外* **57**: 332-336, 2008

Automated Measurements of CEA of Diseased Hip Joint And The Usefulness in Big Database Analysis

Yuki TANAKA^{*1}, Yuta HIASA^{*1}, Yoshito OTAKE^{*1}, Masaki TAKAO^{*2}, Keisuke UEMURA^{*2},
Nobuhiko SUGANO^{*2}, Yoshinobu SATO^{*1}

*1 Graduate School of Information Science, Nara Institute of Science And Technology

*2 Graduate School of Medicine, Osaka University

The need for automatic approaches for pathophysiological analysis in big databases of medical images is increasing. In this study, we aim at the automatic classification of primary and secondary osteoarthritis in a big database. Anatomical landmarks were localized from 3D CT images by using a convolutional neural network (CNN). The center of edge angle (CEA), which is used in the diagnosis of osteoarthritis, was estimated. Preliminary results show the efficiency of the proposed method. We will further examine its feasibility on a large database consisting of approximately 10,000 CT images.

Key words: Big Medical Image Data, CNN, CEA, Osteoarthritis, Anatomical Landmarks

A Study on Quantitative Evaluation of Kidney Tumors using 3D Fully Convolutional Network

Chenglong Wang¹, Masahiro Oda², Yuichiro Hayashi², Naoto Sassa³,
Tokunori Yamamoto³, Kensaku Mori^{2,4,5}

Abstract

Partial nephrectomy is a common treatment for kidney tumors. Due to the wide variety of tumor's anatomical structures, relations between tumor's morphology and surgical outcomes have gained a lot of research interests. Quantitative evaluation of kidney tumor can help physicians to have a better understand of tumor status. Manual segmentation of kidney and tumor is a time-consuming and expensive task. In this work, we used a 3D fully convolutional network to automatically segment kidneys and tumors, and then use traditional statistical analysis methods to quantitatively evaluate the kidney tumor. By using deep-learning based method, kidneys and tumors can be precisely extracted from 3D CT scans. The quantitative analysis can be used for further surgical planning, such as renal clamping strategy. Our segmentation accuracies of kidney and tumor were 93.4% and 42.3%.

Keywords : Kidney tumor, FCN, Quantitative analysis of tumor

1. Introduction

Nowadays, partial nephrectomy is a common treatment for kidney tumors. Due to the wide variety of tumor's anatomical structures, relations between tumor's morphology and surgical outcomes have gained a lot of research interests. Tumor's morphology is a major factor affecting the nephrectomy surgical planning. However, traditional manual segmentation of kidney and tumor is a time-consuming. An automatic computer-aided diagnosis (CAD) system for quantitative analysis of kidney tumors can contribute to a more efficient diagnosis. To quantitatively analyze kidney and tumor, a precise segmentation of both two regions is needed. In this work, we use a fully convolutional network (FCN) to automatically segment kidney and tumor. Then, quantitative measures, such as sphericity, distance and intensity deviation, are used to analyze kidney tumor. This quantitative analysis can be used for further surgical planning, such as renal clamping strategy.

2. Methods

In this work, we use a 3D U-Net like architecture incorporated with a spatially-aware unit to segment kidney and

-
1. Graduate School of Information Science, Nagoya University.
 2. Graduate School of Informatics, Nagoya University.
 3. Nagoya University Graduate School of Medicine.
 4. Information and Communications Headquarters, Nagoya University.
 5. Research Center for Medical Bigdata, National Institute of Informatics.

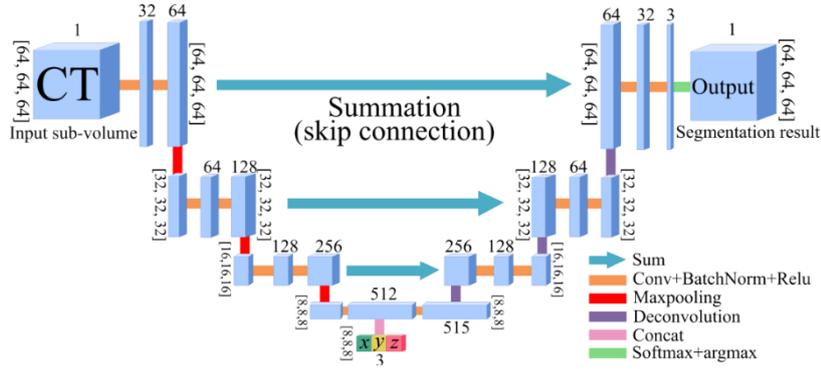


Fig. 1 Overall architecture of our FCN.

tumor. The major difference between our network and original U-Net architecture [1] is that we incorporate spatial information into our FCN. Since anatomical position of human tissue is almost invariant, the introduction of spatial information can effectively reduce outliers (false positives). The architecture of our FCN is illustrated in Fig. 1. The input volumes of the network are sub-volumes cropped using sliding-window method. As shown at the bottom of architecture, we introduced a 3-channel spatial information containing relative coordinate information which can be calculated by $\left[\frac{x}{W}, \frac{y}{H}, \frac{z}{D}\right]$, where x, y, z denote voxels' coordinates of input volume, W, H , and D represent width, height, and depth of input CT volume. At a training phase, randomly cropped sub-volumes were fed to network for training FCN. We used sliding-window strategy to crop CT volume into $96 \times 96 \times 96$ sub-volumes feeding to the FCN. Output results were voxelwise segmentation results. At a prediction phase, test CT volume was first cropped into sub-volumes using sliding-window method, then, voxelwise segmentation results were obtained by the trained FCN. Finally, segmented sub-volumes were merged to a single segmentation volume.

After segmentation of kidney and tumor regions, quantitative analysis is performed for kidney tumor regions. In this work, we consider three measurements, including intensity deviation, sphericity, and distance between a kidney and a tumor. Let V, S and D denote these three measurements respectively. Measurements for single tumor can be described as:

$$\begin{aligned}
 V_i &= |\mathbf{T}_i - E(\mathbf{T})|, \\
 S &= \pi^{\frac{1}{3}}(6N)^{\frac{2}{3}}/F, \\
 D &= d(\mathbf{g}_T, \mathbf{g}_K),
 \end{aligned} \tag{1}$$

where, \mathbf{T} denotes tumor region, $E(\cdot)$ is mean value, $i \in N$ denote index of voxel inside of tumor region. N and F represent the number of voxels of whole tumor region and its surface. \mathbf{g}_T and \mathbf{g}_K denote the gravity position of the tumor and kidney regions. $d(\cdot)$ is Euclidean distance. Based on these measurements, we can obtain a rough quantitative description of tumors segmented.

3. Experiments

In this work, we have 20 contrast-enhanced CT scans. Each case contains one kidney tumor confirmed by clinicians. Considered the limited dataset, we first used a public dataset, kits19 [2], for pre-training of our FCN and then finetune the FCN on our own dataset. We randomly separated our data into training/test with rate of 0.9/0.1, and performed Monte-Carlo cross-validation (MCCV) three times. Thus six cases were tested in our experiments.

Table 1 Quantitative segmentation results of six test cases. *DSC* denotes Dice score.

	Case 1	Case 2	Case 3	Case 4	Case 5	Case 6	Mean
Kidney <i>DSC</i> (%)	77.6	97.3	95.1	96.6	98.0	95.9	93.4
Tumor <i>DSC</i> (%)	0.0	70.3	32.4	67.2	82.2	2.1	42.3

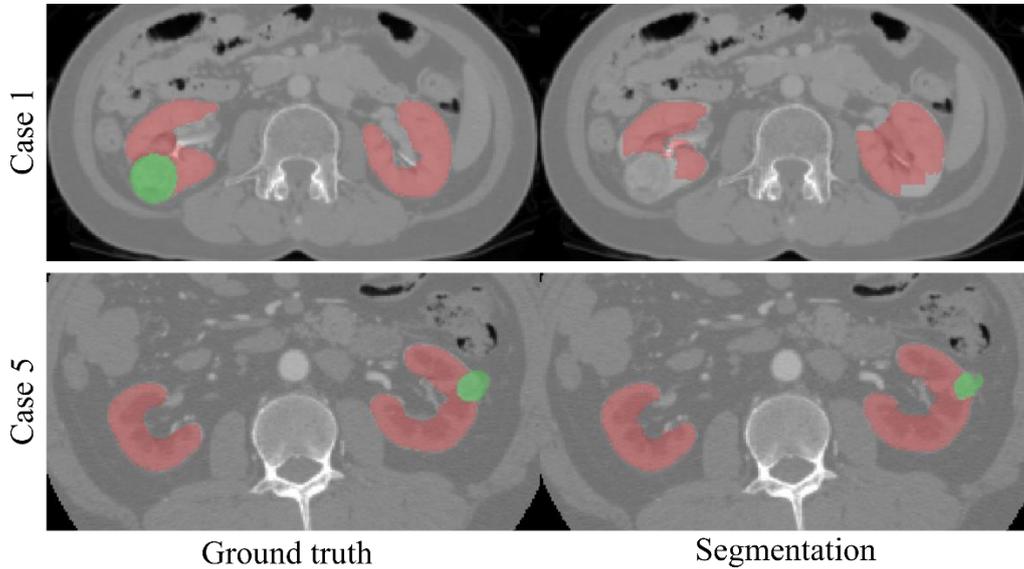


Fig. 2 Two examples of segmentation results. Kidney and tumor regions are marked in red and green.

No data augmentation was performed during training. The learning rate for pre-training and finetuning is set to 0.001 and 0.0001. Adam optimizer was used in this work. Batch size was set to 6 during training. Training epoch was set to 5000 times.

Detailed quantitative segmentation results are shown in Table 1. From Table 1, we can find that Dice scores (*DSC*) of kidney were reasonable high but *DSCs* of tumors were low and not robust. Several segmentation results are shown in

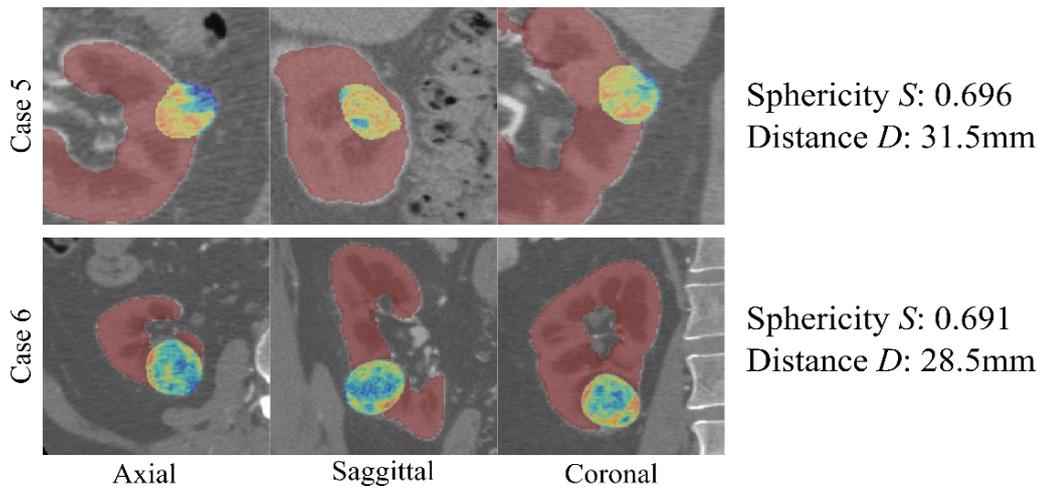


Fig. 3 Two examples of quantitative analysis results of kidney tumors. Square of voxelwise intensity deviation is rendered with pseudo-color mapping 0 to blue and 1 to red.

Fig. 2. Tumor segmentation accuracy of Case 5 is reasonable acceptable. However, segmentation accuracy of Case 1 is deteriorated, tumor was totally under-segmented. One considerable reason is that the contrasting conditions of Case 1 is slightly different from other cases. In this paper, we used manually annotated data to quantitatively analyze tumors regarding the low segmentation accuracy. We demonstrated two quantitative analysis examples in Fig. 3. For a clear visualization, we visualized the square of intensity deviation V^2 . We first normalized V^2 to $[0, 1]$, and rendered the tumor in pseudo-color mapping 0 to blue and 1 to red color. Sphericity is an important measurement of tumor. Lower sphericity suggests the higher possibility of cancer. Distance between a tumor and a kidney effect the blood feeding. Shorter distance indicates the high risk of faster-growing tumor.

4. Conclusions

In this work, we presented a preliminary study on quantitative evaluation of kidney tumors using 3D fully convolutional network. We used a 3D FCN to segment kidney and tumors automatically. Three measurements, intensity deviation, sphericity, and distance between a kidney and a tumor, are used to quantitatively analyze tumors. As aforementioned, although the segmentation accuracy of tumors was low and not robust, the experimental results showed the potential of using FCN in kidney tumor segmentation task. The quantitative analysis results of tumors can be used for further precise surgical planning. To validate our approach on larger dataset is one of our future works.

Competing interests

This work has no conflict.

Acknowledgement

Parts of this research was supported by MEXT/JSPS KAKENHI (26108006, 26560255, 17H00867, 17K20099) and Hori Foundation, and the JSPS Bilateral Collaboration Grant and AMED (191k1010036h0001)

References

- [1] Çiçek Ö., Abdulkadir A., Lienkamp S.S., et al: 3D U-Net: learning dense volumetric segmentation from sparse annotation. In: International conference on medical image computing and computer-assisted intervention **9901**: 424-432, 2016
- [2] KiTS19 Challenge, <https://kits19.grand-challenge.org>

網膜動脈硬化症分類のための静脈口径計測

畑中 裕司*¹ 立木 宏和*² 川崎 良*³ 齋藤 公子*⁴

村松千左子*⁵ 藤田 広志*⁶

要旨

網膜動脈硬化症の主な所見である網膜動静脈交叉現象の診断を支援するために、網膜動静脈交叉部の近くの静脈口径を計測する処理の開発を目的とする。従来に提案した手法は、血管の抽出時に血管壁が滑らかに検出できず、計測位置によって静脈口径の値がばらつく問題点があった。本研究では、P型フーリエ記述子を用いて血管壁と血管の骨格を平滑化して、問題を改善させた。さらに、二値画像および濃淡画像の二次微分値を用いた血管壁の決定処理を開発し、静脈口径の計測精度を高めた。提案した方法を95枚の眼底画像に適用したとき、手動計測した静脈径との平均誤差と標準偏差は 1.39 ± 1.11 画素と良好な結果を得た。

キーワード：口径計測，エッジ検出，プロファイル解析，交叉現象，動脈硬化

1. はじめに

網膜動脈硬化症は自覚症状を伴わずに進行することがあり、網膜の血管閉塞性病変の前段階または脳梗塞などの全身疾患の前段階であるといえるため、その早期発見が必要である。一方で、眼底は人体で血管を直視できる唯一の領域であるので、高血圧や動脈硬化などの循環器系の検査に眼底検査が利用されている。眼底検査は非侵襲かつ簡便な検査方法であるので、人間ドックでは必須項目となっている。眼底画像の循環器疾患の分類には、長年に渡って

Scheie 分類 [1] や Keith-Wagner 分類慶大変法が用いられてきた。Scheie 分類では高血圧性変化と動脈硬化性変化に分けて判定が行われ、0～4の5段階判定の動脈硬化性変化の1～3度が動静脈交叉現象（以下、交叉現象）の程度で判定されている。交叉現象は、硬化する動脈が交叉する静脈を圧迫し、静脈の形状や走行方向が変化する現象である。また、交叉現象は現在の血圧だけでなく過去の血圧にも関連しているとの報告 [2]、交叉現象を有する人は、有さない人の2倍の確率で脳卒中を発症する可能性があるとの報告 [3] がある。したがって、交叉現象を早期に発見することが不可欠である。

早期発見の機会である人間ドックや健診では、眼底検査は眼底カメラにて撮影した画像診断が定着している。しかし、画像を目視判定する主観的かつ定性的な方法が一般的であり、静脈口径の計測などの定量的な判定は殆ど行われていないことが実情である。

コンピュータによる動静脈交叉部における定量的な血管解析に関する報告がある [4-7]。横内らは、方向付き微分法で血管壁を強調して

*1 滋賀県立大学電子システム工学科
〔〒522-8533 滋賀県彦根市八坂町 2500〕
e-mail: hatanaka.y@e.usp.ac.jp

*2 滋賀県立大学大学院工学研究科電子システム工学専攻

*3 大阪大学大学院医学系研究科視覚情報制御学

*4 篠田総合病院眼科

*5 滋賀大学データサイエンス学部

*6 岐阜大学工学部電気電子・情報工学科
投稿受付：2019年5月15日

抽出することによって、交叉現象を解析する手法を提案した [4]. Nguyen らは、交叉の影響を受けない位置の静脈口径を用いた矩形を交叉部付近の静脈にマスクし、マスク内で実際にセグメンテーションした静脈の面積を求めることによって、交叉部の静脈口径を推測する手法を提案している [5]. われわれは、交叉部付近に同心円を設定し、円周上の静脈領域の画素値プロファイルをゼロクロス法によって静脈壁を決定し、静脈口径を計測する手法を提案している [6]. また、抽出した血管の良壁と骨格を通る直線の長さが最短のときを静脈口径とする手法も提案している [7]. しかし、従来手法 [6, 7] は静脈の抽出精度に依存する問題があった. 本論文では、P 型フーリエ記述子を用いて血管抽出後の血管壁と血管の骨格を平滑化することにより、抽出精度のばらつきを抑制する処理を提案する. さらに、二値画像および濃淡画像の二次微分値を用いた血管壁の決定方法についても述べる.

2. 方法

交叉現象は、図 1 に示すように交叉する動脈の影響を受けない位置の静脈口径 V_1 と交叉付近の静脈口径 V_2 の比 (V_2/V_1 , 静脈口径比) を用いて判定される [8]. 交叉現象は、硬化した動脈が静脈を圧迫し、交叉部の静脈が細く見える現象であるので、静脈口径比が小さくなるほど異常である. 本論文では、 V_2 と V_1 を計測する処理について述べる.

提案する手法は図 2 のように 5 つの処理から構成する. 医師は眼底画像から診断に最も有用な交叉部を選んで、その静脈口径比を考慮するため、本研究では眼底画像からユーザがマウス等で交叉点 CP を与えることにした.

2.1 前処理と血管抽出

RGB カラー眼底画像の G 成分の波長の光をヘモグロビンが吸収するため、動脈と静脈のコントラストが共に高くなる. そこで、ユーザが指定した CP を中心とした関心領域 (ROI: Region of Interest) を設定し、G 成分画像の ROI

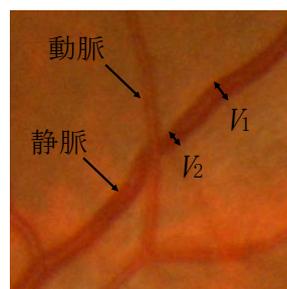


図 1 静脈口径比の計測

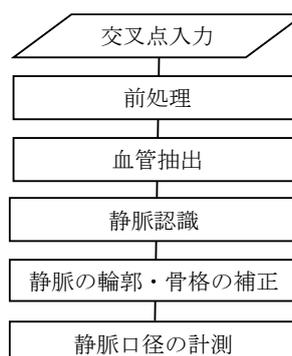


図 2 静脈口径計測処理の流れ

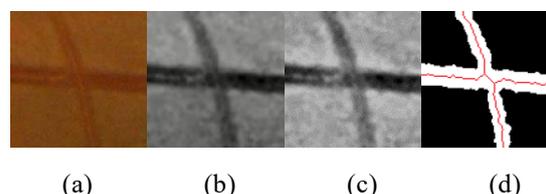


図 3 血管の骨格抽出. (a)原画像, (b)前処理画像, (c)血管強調, (d)決定した血管領域 (白) とその骨格 (赤)

から血管を抽出する.

まず、G 成分画像にガンマ補正および線形関数による階調処理を行い、図 3(b)のように血管を強調する. 撮影光で血柱反射が生ずると、血管抽出に失敗することがあるため、Closing 処理によって血柱反射の影響を軽減した. 次に、筆者らが開発した二重リングフィルタとブラックトップハット変換を組み合わせた手法 [9] を用いて血管を強調する (図 3(c)). そして、二値化処理を適用して血管領域を決定し、Hilditch の方法 [10] で細線化することによって、図 3(d) のように血管の骨格を抽出した.

2.2 静脈認識

最初に ROI 内の血管構造を理解するために分岐点と交叉点を検出する。骨格の任意の画素の 8 近傍に骨格をなす画素が 4 画素存在すれば交叉点, 3 画素存在すれば分岐点として検出した [11]。ここで, ユーザ指定の CP に最も近い交叉点を静脈口径比計測の対象とする。

図 4 に示すように血管抽出処理によって血管の一部領域が欠損したり, 動脈硬化の進行によって交叉する静脈が奥に押し込まれて写ったりしていない場合, 図 4(a) のようなパターンにならず, 上述の方法では交叉として認識できない。そこで, 図 4(a)~(c) に示すパターン 1, 2, 3 を想定して交叉部を認識する。まず, パターン 1 は上述の処理で認識できる。次に, パターン 2, 3 は, 上述の方法が CP 付近で分岐点と認識された場合に該当する。図 4(d) に示すように, 分岐点から半径 r 以内に他の血管領域(ラベル)が存在する場合はパターン 2, 存在しない場合はパターン 3 とする。

最後に, CP 付近の交叉部を消去し, 血管を枝に分割する。この段階で, パターン 1, 2 の場合は 4 本, パターン 3 は 3 本の枝が認識される。そして, 交叉点で向かい合う 2 つの枝領域を同一の血管と定義する。各枝領域の骨格を 2 pixel 膨張した領域の G 成分の画素値の平均値を計算し, 枝のペアの認識に利用する。同種の血管同士の場合, 異種の血管同士の場合と比較して, G 成分の画素値の差は小さいため, 平均値に近い 2 本の枝をペアとする。また, G 成分画像において, 静脈は動脈よりも画素値が低くなる傾向にあるので, 平均値が高いペアを動脈, 低いペアを静脈と定義した。

2.3 静脈の輪郭と骨格の補正

2.1 の処理を用いると, 図 5(a) のように血管壁が凸凹に抽出されることがある。このような領域を細線化すると, 細線も蛇行してしまう。特に, 図 5(b) に示すように交叉部の骨格が正確に得られないことが多い。そこで, 交叉部における静脈の骨格をスプライン補間して, 図 5(c) に示すように平滑化した。

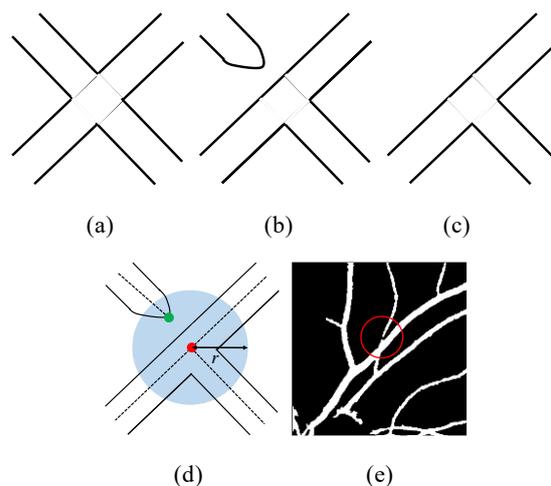


図 4 交叉パターンと血管の一部が欠損した交叉の例。(a)パターン 1: 通常の交叉, (b)パターン 2: 交叉部をなす血管の一部欠損, (c)パターン 3: 交叉をなす血管の一本の半分が欠損, (d)(b) と(c)の判別法, (e)血管の一部欠損のある例。

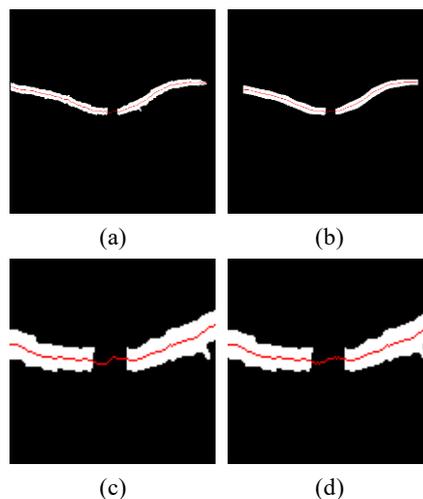


図 5 血管の輪郭と骨格の補正。(a)補正前, (b)骨格と血管壁の平滑化後, (c)(a)の拡大, (d)交叉部の骨格補正

この段階では, 血管の骨格線と血管壁が波打っている状態である。P 型フーリエ記述子 [12] を用いて, 血管壁や骨格の凸凹を表現する高周波成分を除去することにより, 図 5(c) のように交叉部以外で蛇行する血管の輪郭と骨格を補正した。P 型フーリエ記述子を適用した理由として, 図形の輪郭線や平面上の曲線を周波数領

域で記述するものとしてフーリエ記述子が知られているが、骨格や血管壁は開曲線であるので、開曲線に適用可能な P 型フーリエ記述子を選定した。

2.4 静脈口径の計測

静脈の口径は、骨格の各画素において骨格の走行方向と垂直な直線 (P-line) を考え、P-line 上で血管壁を 2 点検出し、それらのユークリッド距離とした。ここで、P-line は一定長さとし、交叉領域に重なる場合は除外した。P-line の一例を図 6 に示す。本論文では、3 種類の血管壁の検出法 (手法 1, 手法 2 および手法 3) を提案し、それぞれを比較した。

手法 1 ではまず、2.3 で平滑化した静脈の輪郭と P-line が交わる画素 ep を図 7(a) のように探索した。図 7(b) に ep の例を示す。次に、画素 ep を含む血管壁の画素を n 個抽出し、それらに対して最小二乗法を適用して、図 7(c) に示すような $n-1$ 次方程式を得た。最後に、近似式と P-line の交点を求め、交点間の距離を静脈口径とする。

手法 2 では、G 成分画像にヒストグラム平坦化処理を適用し、P-line 上のプロファイルからゼロクロス法 [13] によって血管壁を決定することを試みた。しかし、静脈の血柱反射の影響で血管壁以外がゼロクロスで検出されてしまう問題があった。そこで、血管の骨格 (プロファイルの中心) から見て二次微分の値が最大となる点 (図 8 青点) を求め、最大値の外側の最初のゼロクロス点 (図 8 赤点) を血管壁とした。

手法 3 は、手法 1 と手法 2 の組合せである。予備実験において、手法 1 では実際の血管壁よりも外側の画素を血管壁として検出する傾向があった。また、手法 2 で用いた最大二次微分値をもつ画素は、実際の血管壁よりも内側に存在する傾向があった。そこで、手法 1 と 2 を組み合わせる。まず、図 9 のように 2.3 で得た静脈の輪郭 (輪郭画素を 255, 非輪郭画素を 0 とした 256 階調の画像) をガウシアンフィルタを用いて平滑化した。この画像を重み分布と定義する。続いて、P-line 上で血管壁らしさ IVW を式(1)のように定義し、計算した。

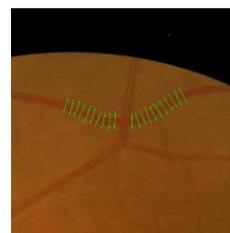


図 6 骨格に垂直な直線 P-line の例

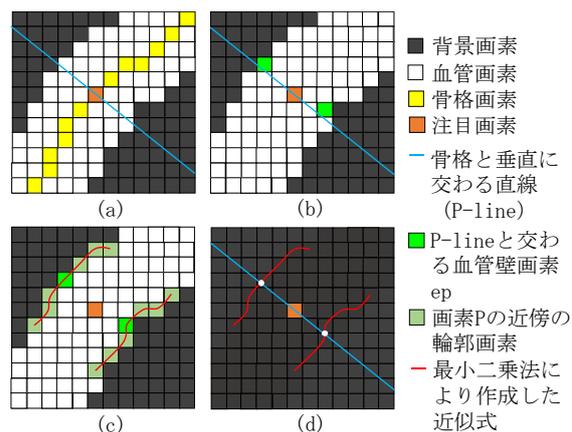


図 7 口径計測の手法 1 の流れ。(a) P-line と血管の輪郭の交点画素の探索、(b) 探索された ep の例、(c) 血管壁の近似式の例、(d) P-line と近似式の交点の計算

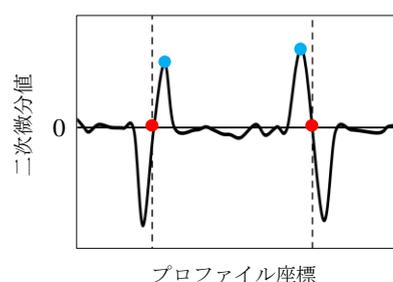


図 8 ゼロクロス法ベースの血管壁の決定例。青点：左右での最大二次微分値。赤点：決定した血管壁。

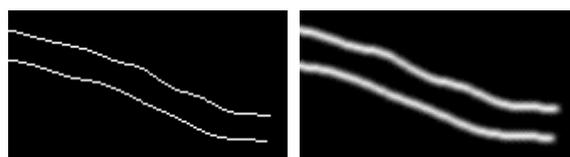


図 9 血管壁の重み分布。左：手法 1 の血管壁。右：ガウシアンフィルタ適用後の重み分布。

$$IVW=SD \times VWV \quad (1)$$

ここで、SDV は P-line における二次微分値、WV は P-line における重み分布の画素値である。P-line 上で IVW が最大となる点を血管壁とした。

3. 実験結果と考察

検診で撮影された眼底画像を用いて、提案手法を評価する。対象はトプコン社の眼底カメラ TRC-NW200 で撮影された 95 枚であり、2048×1536 pixels の 24bit カラー画像である。本実験は、滋賀県立大学「研究に関する倫理審査委員会」の承認下で行った。

3.1 静脈口径の手動計測

最初に、眼底画像の研究を担う 3 名が全画像の交叉部付近の静脈の口径を手動で計測した。眼底画像 1 枚毎に観察者 1 名が交叉点 CP を指定した。その CP を中心として 10 画素刻みで半径 10~110 画素の同心円を描画し、各円周に交わる静脈の口径を手動計測した。ただし、交叉と分岐によって明らかに口径が変化した箇所は計測の対象外とした。3 名の観察者が計測した静脈口径の違いを調べるため、観察者間の計測誤差を絶対誤差の平均および標準偏差を求めた。表 1 にその結果を示すが、観察者間には平均約 1.4pixel の計測誤差がみられた。眼底画像全体の血管口径計測のためのデータベース REVIEW [14] において、3 名の専門家が正解を作成しているが、専門家間で最大約 1.3pixel の誤差が生じた報告があることから、本手動計測の誤差は許容できると考えた。

3.2 交叉点 CP の指定ズレによる交叉部の認識精度

実際にユーザが交叉点 CP を指定する際、マウス操作の場合は位置ずれが生じて再現性がない。CP の位置ずれが生じた際に、交叉部の認識精度が保証できるかを検討した。CP がずれると ROI が変化するため、前処理などの画像の強調処理に影響し、血管の抽出結果が変化すると予想できる。ここでは、3.1 で指定した CP を基

表 1 観察者 A~C 間の計測誤差

観察者	絶対誤差の平均±標準偏差
A-B	1.10±0.897 pixels
B-C	1.70±1.15 pixels
C-A	1.43±1.12 pixels

表 2 交叉点の位置ずれによる交叉部の認識

交叉の位置	認識率	交叉パターン 1, 2, 3			
		1	2	3	NG
CP	1.00 (95/95)	84	8	3	0
CP+ (+5, +5)	0.979 (93/95)	84	7	2	2
CP+ (+5, -5)	0.968 (92/95)	83	7	2	3
CP+ (-5, +5)	0.968 (92/95)	84	6	2	3
CP+ (-5, -5)	0.968 (92/95)	82	7	3	3

表 3 静脈口径の計測誤差

計測手法	絶対誤差の平均±標準偏差
1	2.07±1.34 pixels
2	3.32±3.19 pixels
3	1.39±1.11 pixels
従来手法	2.41±1.34 pixels

準として、上下左右に各 5pixels 位置ずれした場合の交叉部の認識精度を調べた。表 2 にその結果を示す。数値は分類した交叉部の数である。観察者が指定した CP の位置を基準にすれば、95 箇所全ての交叉を認識でき、84 箇所を正しくパターン 1 に分類できた。しかし、CP から 5pixel 位置ずれすると、コントラストの低い血管の抽出精度が下がり、パターン 1 以外に分類される場合があった。認識できなかった交叉部も、コントラストの低い動脈を十分に抽出できなかったことが原因である。

3.3 静脈の口径計測法の比較

2.4 で述べた 3 つの血管壁の決定手法による静脈口径の計測誤差について調べた。また、誤差の大きさの目安を知るために、従来手法 [7] の絶対誤差も調べた。95 箇所の交叉部に対して絶対誤差を求めた結果を表 3 に示す。

手法 1 は、血管抽出後に二値化された画像から P 型フーリエ記述子による血管壁や骨格の線

分の平滑化を行うことから、網膜領域の模様の影響を受けにくい。誤差の要因としては、計測手法が血管抽出の精度に依存していることがあげられる。近年は深層学習を用いたセグメンテーション手法の開発が盛んであるが、多くの学習データを用意することが困難であること、少ないデータでも静脈口径を計測できる手法を目指したことから、本研究では機械学習を用いないフィルタベースの手法を適用した。

手法2は、ゼロクロス法を基本としているため、血柱反射や網膜の色むらからゼロクロスが多く生じてしまう。特に、血管領域内の小さなエッジを誤検出してしまうことが目立った。つまり、手法2では実際の血管壁の内側を検出してしまうことが多いため、本研究では手法1, 2を組み合わせた手法3を考えた。

さらに、血管壁の決定方法について、手法3の最大二次微分値 SVD を用いて血管壁を決定する手法を新たに定義して検討する（手法4とする）。また、手法1と手法4がそれぞれ決定した血管壁の中点を血管壁とする手法5も新たに定義する。95箇所交叉部に適用したところ、絶対誤差の平均は手法4が2.08pixels, 手法5が1.48pixelsであった。手法4の絶対誤差は手法1と同等、手法5の絶対誤差も手法3に近い値となった。しかし、血管と網膜のコントラストが低い場合、すなわちSDVの変動が小さい場合、手法4では血管壁近くの網膜の色むらを血管壁として誤検出する可能性があり、手法5を用いた計測の結果にも悪影響を与えられられる。以上のことより、静脈口径の計測のための血管壁の決定には手法3が良いと結論づける。

3. まとめ

本論文では、網膜動脈硬化症の診断支援のために、網膜動脈交叉部における静脈口径の計測法について言及した。従来手法では血管抽出の精度が口径計測に強く影響していた。本論文では、静脈の骨格および輪郭をスプライン補間およびP型フーリエ記述子を用いて平滑化することによって、従来の問題点を軽減させた。また、複数の血管壁の検出手法を考え、比較実験を行

った。その結果、二値画像および濃淡画像の二次微分値を用いた手法が良好であった。観察者による手動計測との絶対誤差の平均±標準偏差は 1.39 ± 1.11 pixelとなり、観察者間で生ずる絶対誤差と同等であり、提案手法は人間が血管壁を凝視して計測する水準に達したといえる。コントラストが低い血管の抽出精度の向上が課題として残っており、さらなる開発が必要である。本研究では検診施設の眼底画像を使用したため、明確に交叉現象の進行した症例が含まれず、交叉現象の判定実験を行わなかった。異常例を多く収集し、評価実験を行う必要がある。

謝辞

研究遂行にあたり貴重なご助言を賜りました滋賀県立大学工学部の奥村進氏および小郷原一智氏に深謝いたします。本研究の一部は公益財団法人テルモ科学技術振興財団、JSPS 科研費16K01415および26108005の助成を受けたものです。

利益相反の有無

なし。

文 献

- [1] Scheie HG: Evaluation of ophthalmoscopic changes of hypertension and arteriolar sclerosis. Arch Ophthalmol **49**: 117-138, 1953
- [2] Wong T, Mitchell P: The eye in hypertension. Lancet **369**: 425-435, 2007
- [3] Wong T, Klein R, Couper D, et al.: Retinal microvascular abnormalities and incident stroke: The atherosclerosis risk in communities study. Lancet **358**: 1134-1140, 2001
- [4] 横内久猛, 山本真司, 鈴木孝治, 他: 眼底写真の自動認識(その1) 血管境界線抽出による眼底写真中の交叉現象の自動認識. 医用電子と生体工学 **12**: 123-130, 1974
- [5] Nguyen U, Bhuiyan A, Park L, et al.: An

- automated method for retinal arteriovenous nicking quantification from color fundus images. *IEEE Trans Biomed Eng* **60**: 3194-3203, 2013
- [6] 高橋 亮, 畑中裕司, 中川俊明, 他: 眼底画像における高血圧症診断支援のための血管交叉部の自動解析. *Med Imag Tech* **24**: 270-276, 2006
- [7] Hatanaka Y, Muramatsu C, Hara T, et al.: Automatic arteriovenous crossing phenomenon detection on retinal fundus images. *Proc SPIE Medical imaging 2011* **7963**: 79633V, 2011
- [8] 中島章, 新井宏明: 成人病の眼底検査. キヤノン販売株式会社, 東京, 1984
- [9] 岩瀬達彦, 村松千左子, 畑中裕司, 他: 眼底画像における細動脈狭窄評価のための主幹動静脈の自動検出および分類法. *電子情報通信学会技術報告* **109**: 189-193, 2010
- [10] Hilditch CJ: Comparison of thinning algorithms on a parallel processor. *Imag Cision Comput* **1**: 115-132, 1983
- [11] 畑中裕司, 原 武史, 周 向榮, 他: 眼底写真における血管の追跡処理による動脈の口径不同の自動検出. *生体医工学* **42**: 236-240, 2004
- [12] 上坂吉則: 開曲線にも適用できる新しいフーリエ記述子. *電子情報通信学会論文誌 A* **J64-A**: 166-173, 1984
- [13] Marr D, Hildreth E: Theory of edge detection. *Proc Royal Soc London B: Biol Sciences* **207**: 187-217, 1980
- [14] Al-Diri B, Hunter A, Steel D, et al.: REVIEW - A reference data set for retinal vessel profiles. *Proc 30th Int Conf IEEE Eng Med Biol Soc*: 2262-2265, 2008
- [15] 中川俊明, 林佳典, 畑中裕司, 他: 眼底画像診断支援システムのための血管消去画像を用いた視神経乳頭の自動認識及び擬似立体視画像生成への応用. *電子情報通信学会論文誌* **J89-D**: 2491-2501, 2006

Retinal Vein Diameter Measurement for Arteriosclerosis Retinae Classification

Yuji HATANAKA^{*1}, Hirokazu TACHIKI^{*2}, Ryo KAWASAKI^{*3}, Koko SAITO^{*4}
Chisako MURAMATSU^{*5}, Hiroshi FUJITA^{*6}

*1 Department of Electronic Systems Engineering, School of Engineering, the University of Shiga Prefecture

*2 Division of Electronic Systems Engineering, Graduate School of Engineering, the University of Shiga Prefecture

*3 Department of Vision Informatics, Graduate School of Medicine, Osaka University

*4 Department of Ophthalmology, Shinoda General Hospital

*5 Faculty of Data Science, Shiga University

*6 Department Electrical, Electronic & Computer Engineering, Faculty of Engineering, Gifu University

The purpose of this study is to develop a vein diameter measurement in order to aid diagnosis of arteriovenous nicking, which is main retinal arteriosclerosis. The previous method could not detect a blood vessel wall smoothly, thus variation of vein diameters measured was large. In this study, the vein diameter measurement was improved by smoothing the blood vessel walls and vessel skeletons using P-type Fourier descriptors. Moreover, this method was also improved by developing a vessel wall detection method using binarized vessel image and second derivative in gray-level one. The mean absolute error and standard deviation of vein diameter measurement was reached to 1.39 ± 1.11 in 95 region of interest with arteriovenous crossing points.

Key words: Measurement of vessel diameter, Edge detection, Profile analysis Retinal image, Arteriovenous nicking, Arteriosclerosis

第 38 回日本医用画像工学会大会 (JAMIT2019)
大会役員委員会名簿

五十音順・敬称略

大会長		
佐藤 嘉伸		奈良先端科学技術大学院大学
大会長補佐		
大竹 義人		奈良先端科学技術大学院大学
業務委員長		
宮崎 靖		日立製作所
チュートリアル委員長		
原 武史		岐阜大学
企業連携委員長		
中田 典生		東京慈恵会医科大学
プログラム委員会		
委員長		
増谷 佳孝		広島市立大学
委員		
有村 秀孝		九州大学
石田 隆行		大阪大学
伊藤 聡志		宇都宮大学
彌富 仁		法政大学
上村 幸司		国立循環器病研究センター
内山 良一		熊本大学
大沢 博之		キヤノンメディカルシステムズ
大城 理		大阪大学
小田 昌宏		名古屋大学
小尾 高史		東京工業大学
河田 佳樹		徳島大学
北坂 孝幸		愛知工業大学
北村 圭司		島津製作所
木戸 尚治		大阪大学
金 亨燮		九州工業大学
木村 裕一		近畿大学
工藤 博幸		筑波大学
椎名 毅		京都大学
清水 昭伸		東京農工大学
周 向榮		岐阜大学
庄野 逸		電気通信大学
陣崎 雅弘		慶応義塾大学
菅 幹生		千葉大学
杉本 直三		京都大学
滝沢 穂高		筑波大学
田中 利恵		金沢大学
陳 延偉		立命館大学
中口 俊哉		千葉大学
根本 充貴		近畿大学
野村 行弘		東京大学
畑中 裕司		滋賀県立大学
花岡 昇平		東京大学
羽石 秀昭		千葉大学
平野 靖		山口大学
本谷 秀堅		名古屋工業大学
目加田慶人		中京大学
森 健策		名古屋大学
八上 全弘		京都大学
山谷 泰賀		量子科学技術研究開発機構 放射線医学総合研究所
湯浅 哲也		山形大学

日本医用画像工学会 (JAMIT)
役員名簿
(平成31年4月22日現在)

五十音順・敬称略

	氏名	所属
会 長	尾川 浩一	法政大学
副 会 長	工藤 博幸	筑波大学
	佐藤 嘉伸	奈良先端科学技術大学院大学
常任幹事	大沢 博之	キヤノンメディカルシステムズ
	小尾 高史	東京工業大学
	北坂 孝幸	愛知工業大学
	清水 昭伸	東京農工大学
	中田 典生	東京慈恵会医科大学
	原 武史	岐阜大学
	花岡 昇平	東京大学
	宮崎 靖	日立製作所
	目加田慶人	中京大学
	湯浅 哲也	山形大学
	幹 事	石垣 武男
石田 隆行		大阪大学
伊藤 聡志		宇都宮大学
上村 幸司		国立循環器病研究センター
大松 広伸		網走刑務所
岡田 知久		京都大学
掛川 誠		中央システム技研
笠井 聡		コニカミノルタ
勝俣健一郎		国際医療福祉大学
川岸 将実		キヤノン
木戸 尚治		大阪大学
黒木 嘉典		新村病院、博愛会 HPN 東京
真田 茂		公立小松大学
陣崎 雅弘		慶応義塾大学
杉本 直三		京都大学
滝沢 穂高		筑波大学
武田 徹		北里大学
陳 延偉		立命館大学
土居 篤博		富士フイルム
縄野 繁		国際医療福祉大学
仁木 登		徳島大学
野崎 太希		聖路加国際病院
長谷川純一		中京大学
畑中 裕司		滋賀県立大学
羽石 秀昭		千葉大学
平野 靖		山口大学
藤田 広志		岐阜大学
細羽 実		京都医療科学大学
増谷 佳孝		広島市立大学
森 健策		名古屋大学
森 雅樹		札幌厚生病院
山谷 泰賀		量子科学技術研究開発機構 放射線医学総合研究所
吉川 悦次		浜松ホトニクス
監 事	安藤 裕	JCHO 埼玉メディカルセンター
	篠川 毅	鳥津製作所