

# **JAMIT Annual Meeting 2023** 第42回日本医用画像工学会大会

会期:2023年7月27日(木)~29日(土)

会 場:大阪大学中之島センター

大会長:木戸尚治(大阪大学)



- - 一般社団法人 保健医療福祉情報システム工業会 一般社団法人 電子情報技術産業協会

特定非営利活動法人 日本核医学技術学会

一般社団法人 日本コンピュータ外科学会

一般社団法人 日本写真学会

公益社団法人 日本超音波医学会

医用画像情報学会 協 賛: 一般社団法人 可視化情報学会 看護理工学会 一般社団法人 情報処理学会 公益社団法人 日本医学物理学会 一般社団法人 日本医療情報学会

公益社団法人 応用物理学会 一般社団法人 画像電子学会 三次元画像コンファレンス実行委員会 一般社団法人 電子情報通信学会 公益社団法人 日本医学放射線学会 一般社団法人 日本核医学会 日本画像医学会 一般社団法人 日本磁気共鳴医学会 公益社団法人 日本生体医工学会 公益社団法人 日本放射線技術学会

## 学会長ご挨拶

第42回日本医用画像工学会大会(JAMIT 2023)を、会期7/27(木)~7/29(土)にわたって、大阪大 学中之島センターにて、木戸尚治先生(大阪大学)大会長のもと開催させていただくことになりました。 COVID-19の感染がようやく治まった状況から現地開催を決定して、精力的に準備を進めてきました。

JAMIT2023のテーマは、木戸尚治先生に「臨床サイドからみた AI ~あらたなる飛躍をめざして~」と 決定していただきましたが、その意図を以下に述べさせていただきます。

工学は実世界の問題に応用する段階まで完成させ人間生活や社会に役立つことがゴールの学問であり、 我々も様々な医用画像技術を臨床に役立てることを目指さなくてはなりません。2010年代中盤から始まっ た AI 技術(特に深層学習や機械学習)を応用した様々な医用画像技術は基盤技術がほぼ完成してきた状況 にあり、今後は臨床応用や産業化にシフトした研究開発が進んでいくもと予想されます。そこで、JAMIT で長年活躍して多様な成果をあげられ AI 技術に長けている放射線科医の木戸尚治先生に大会長をお願いし た所、ご快諾いただき上記の主旨を意識したプログラムを構築していただきました。また、JAMIT の学会 の在り方として、工学系に偏らず医学系の会員数やアクテビティを増やし医学と工学の融合領域を扱う学会 にしたい、という話も JAMIT 理事会や私の周辺ではよく話題になり、上記の主旨で大会を実施するモチベー ションの一つになっていると考えています。

木戸先生を中心に組織委員会(プログラム委員長:平野靖先生(山口大学)、大会長補佐:鈴木裕紀先生 (大阪大学))で大変魅力的な企画物をご準備いただき、以下にその全体像を紹介します。2件の特別講演は、 大阪大学の忽那賢志先生に「新興再興感染症 COVID-19 これまでとこれから」のご講演、慶應義塾大学の百 島祐貴先生に「画像診断の歴史」のご講演、をお願いしました。両先生にお考えいただいた講演タイトルは、 我々医用画像工学の技術者の誰もが興味を持つ魅力的なタイトルで、また両先生とも各々の分野のリーダー で大変ご高名であると同時に誰にでも分かりやすくお話しされるのが上手とうかがっており、私自身薄学で すが拝聴するのを大変楽しみにしています。シンポジウムは、AIの臨床応用や産業化を意識した「ベンチャー 企業が挑む AI 開発」、及び次世代の CT 技術のブレークスルーと期待されている「フォトンカウンティング CT の衝撃」、の2件を企画しました。加えて、今回の大会のテーマを意識して、特別企画「AI ホスピタル プロジェクトの現在」を企画しました。最近の JAMIT 大会と比較すると、臨床応用や産業化に関するご講 演が多めの作りになっています。ので、工学系分野の参加者の方は医学系に近い新鮮な内容に接する機会、 基礎研究分野の参加者の方は産業化のような新鮮な内容に接する機会になるだろうと考えています。

最後に、JAMIT2022から新たに開始したシンポジウム「JAMITの未来をつくろう」を継続して実施する ことにしました。このシンポジウムで取り扱う内容は若手研究者を意識したもので、「研究の方法論や様式 が目まぐるしく変化する現代において、若手研究者が元気に活躍して成功を納めJAMITの未来を作るには どうすればよいか」という大変難しいながら重要な問題です。元気のよい若手研究者に思いや本音を述べて もらう、年配研究者から若手研究者に問いかけ、のようなスタイルのものを考えています。JAMIT2022で は若手の様々な本音や思いが聞けてその中で実現可能なものは理事会で実現を進めている状況ですが、時間 が限られていたため「JAMIT の未来をつくろう」を継続的に数年続けることで、現在の若手の人々が中心 の次世代 JAMIT になる時にどういう方向性がよいかが具体的に見えてくるのだろうと期待しています。例 年好評のハンズオンとチュートリアル講演会は JAMIT 理事会の教育委員会で内容を企画して、ハンズオン は既に過去の大会で参加済の方でも新しいより高度の内容を学びステップアップできる作りの形態、チュー トリアル講演会は今後研究が進むと予想される深層学習を用いた医用画像処理の新しい方向性を整理してま とめた「医用画像工学における最新 AI 研究の課題とその展望について」のタイトルで準備しました。他には、 JAMIT2021から様式を改めた田中栄一記念賞受賞者講演を含む会員集会、二日目と三日目のランチョンセ ミナーを予定しています。

会場の大阪大学中之島センターは、皆さんご存じのように中州の場所に存在し、近年再開発が進み多くの 観光スポットや飲食店が存在するエリアで繁華街にも近い便利がよい立地です。私は10年ぶりですが前回 訪問した時とは様相がかなり変化していると予想され、大変楽しみにしている所です。COVID-19が治まり アフターファイブの時間を利用した交流、懇親会などができる状況になると COVID-19以前の JAMIT 大会 に戻りよいのでしょうが、無理はまだできません。JAMIT2021(慶応義塾大学)はハイブリッド開催しま したが会場にお越しいただいた参加者数はかなり少なく、JAMIT2022(名古屋大学)では参加者数は244 名で例年に近い状況まで戻り、今回は例年以上の参加者数で大成功にしたい所です。COVID に負けず何が あっても医用画像工学発展の火を弱めてはいけないというのが数年間の JAMIT のスタンスでしたが、本当 にその実現がかないそうで感無量であり、是非 JAMIT2023 に参加して医用画像工学の益々の発展を味わっ ていただけたらと考えています。

> 日本医用画像工学会(JAMIT) 会長 工藤 博幸

# 大会長ご挨拶

第42回日本医用画像工学会(JAMIT)大会を2023年7月27~29日に大阪大学中之島センターにて開催させて頂くことになりました.大会のテーマは、「臨床サイドからみた医療AI~あらたなる飛躍をめざして~」と致しました.

大阪大学中之島センターは、大阪大学医学部が吹田に移転する前に立地した場所にあり、私もこの地で学 生生活を送りました.この場所は梅田の繁華街に大変近くて賑やかですが、最近では、整備が進み国立国際 美術館、大阪中之島美術館や大阪市立科学館などが集積して文化発信の地となっています.また緒方洪庵が 江戸時代後期に大坂船場に開いた蘭学の私塾である適塾も徒歩圏内にあり、いわば大阪医学の発祥の地であ ります.

本大会のポスターには太陽の塔の写真を掲載いたしましたが、これは大阪のアイコンとして大変有名です. しかしながら背部の「黒い太陽」についてはあまりご存じないかもしれませんが、過去を象徴しているとさ れています.これは会場の中之島センターが大阪大学医学部発祥の地にあることへのメタファーであります が、本年の大会が例年とはやや趣を異にして「医」の側面を強調した大会にしたいという思いからでもあり ます.写真の撮影は休日に私がおこないました.

特別講演は本大会のテーマにふさわしいお二人にお願い致しました.お一人目は、大阪大学大学院医 学系研究科感染制御医学講座教授の忽那賢志先生です.忽那先生は、皆様もよくご存じのとおり、現在 COVID-19診療の第一線でご活躍されています.ご講演の内容は、「新興再興感染症と COVID-19 これまで とこれから」ということで、COVID-19を含む新興再興感染症を幅広く解説していただきます.また、お二 人目は、慶應義塾大学医学部予防医療センター副センター長の百島祐貴先生です.百島先生は画像診断の教 科書を多数ご執筆ですが、医学史に関しても造詣が深く多くの著書をご執筆されています.お話しいただく のは、「画像診断の歴史」です.以前に百島先生のご講演を拝聴しましたが、大変面白くて理解しやすく、 医学系・工学系を問わず大変有意義なご講演になると思います.

特別企画は、AI ホスピタルプロジェクトの現在についてです。AI ホスピタルによる高度診断、治療シス テムは、「内閣府戦略的イノベーション創造プログラム(SIP)」で採択された国家プロジェクトですが、AI による医療分野における社会課題の解決を目指しています。本特別企画においては、プログラムディレクター としてこのプロジェクトを進めてこられた医薬基盤・健康・栄養研究所理事長の中村祐輔先生に全体を俯瞰 するご講演をいただき、大阪大学、慶應義塾大学、国立成育医療研究センターの先生方による各施設での取 り組みをご紹介いただきます。

シンポジウムでは、3つの話題を提供します.ひとつめは、今最も元気のある医療系ベンチャー企業による AI 開発のホットな講演です.病理、眼底、内視鏡の各分野で活躍されている先生方で、全員が医学系出 身と学会のテーマにふさわしい方々です.次に、国内でも導入が始まっている次世代型検出器を搭載したフォ トンカウンティング CT に関して、技術や臨床に詳しい先生方に解説をいただき、次世代 CT への理解を深 めていただきたいと思います.また、前回より始まった若手研究者によるシンポジウムも引き続きおこない ます.若手研究者の方々がこのシンポジウムによる交流をとおして医用画像工学分野で活躍してくれる一助 になればと思います.チュートリアル講演やハンズオンセミナーも例年通り開催します.できるだけ多くの 方々に参加いただき医用画像工学に関する知識や技術を深めていただければと思います.

日本医用画像工学会大会は、「医」と「工」が対等に参加することを目標としていますが、最近は「工」 主体の時代が長く続きました. 2021年は慶應義塾大学医学部放射線科の陣崎雅弘教授、2022年は名古屋大 学大学院情報学研究科の森健策教授が大会長をされて、再び「医」と「工」が循環するよい流れができてき たのではないかと感じています.

COVID-19 は終息する兆しをみせませんが,多くの研究会や学会がオンラインからオンサイトに移行しつ つあります.本大会は現地参加でおこなう予定ですが,オンサイトによる学会は人の交流などのオンライン にない魅力があると思います.多くの方々のご参加による盛況な会になることを祈願しています.

> 第42回日本医用画像工学会大会 大会長 木戸 尚治(大阪大学)

2

交通案内



### 大阪大学中之島センターまでのアクセス

#### ■電車によるアクセス

- ●京阪中之島線 中之島駅より徒歩約5分
- ●阪神本線 福島駅より徒歩約9分
- ●JR東西線 新福島駅より徒歩約9分
- ●JR環状線 福島駅より徒歩約12分
- ●地下鉄四つ橋線 肥後橋駅より徒歩約10分
- ●地下鉄御堂筋線 淀屋橋駅より徒歩約16分

#### ■バスによるアクセス

- ◆大阪市バス(53系統)
   大阪駅前バスターミナル→
   中之島四丁目(旧玉江橋) 下車 徒歩1分
- ●大阪市バス(75系統) 大阪駅前バスターミナル→田蓑橋下車 徒歩2分
- ●北港バス(中之島ループバス ふらら) 淀屋橋発(土佐堀通/住友ビル前)→ 大阪大学中之島センター前 下車 徒歩1分

#### 遠方からのアクセス

#### ■新幹線でお越しの方は

- ●「JR新大阪駅」からタクシー (約30分、3,000円程度)
- ●「JR大阪駅」から市バス
   (53、75系統田蓑橋下車すぐ)
- ●「JR大阪駅」からタクシー (約10分、1,000円以内)
- ●地下鉄御堂筋線で「淀屋橋駅」下車。6番出口から徒歩16分。

#### ■飛行機でお越しの方は

大阪空港・関西空港からはJR大阪駅まで直通バスが 運行されています。

- ●「JR大阪駅」から市バス
   (53、75系統田蓑橋下車すぐ)
- 「JR大阪駅」からタクシー
   (約10分、1,000円以内)
- ●「JR大阪駅」から徒歩約25分。

会場案内図







第 <b>1</b> 佐治敬王	<mark>会場</mark> <sup>王ホール</sup>
	非常用 EV ロビー 路役

- 1. 会期: 2023年7月27日(木)~29日(土)
- 2.会場:大阪大学中之島センター
   〒530-0005 大阪府大阪市北区中之島4丁目3-53
   https://www.onc.osaka-u.ac.jp/

#### 3. 参加登録

参加登録ページよりオンラインにて参加登録を完了してください.現地参加される際は,参加 費の決済完了メールをプリントアウトして受付までご持参ください. https://jamit2023.jamit.jp/registration.html

- 1) 登録期間:5月29日(月)~7月29日(土)16:00
- 2) 参加費:正会員(賛助会員含む):13,000円
  - 学生会員:2,000円 関連学会(応用物理学会)会員:13,000円 非会員一般:20,000円 非会員学生:4,000円
- 3) 現地受付開設時間
  - 7月27日(木) 12:30~18:00
  - 7月28日(金) 9:00~18:30
  - 7月29日(土) 9:00~15:00

#### 4. 会員集会

日時:7月28日(金)13:30~14:30 会場:第1会場(佐治敬三メモリアルホール)

#### 5. 予稿集について

ダウンロード (PDF) 形式で作成し, ダウンロードパスワードを参加者にお知らせいたします.

#### 6. 発表者へのご案内

一般演題の発表は,発表時間が口演7分,討論3分です. 発表はご自身の PC でお願いします. PC 受付は設けませんので,発表データの確認は事前にお 願いいたします.

#### 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、6月末日までに入会のお申込みをいただき、7月14日(金)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/)
 〒1043-0013 東京都中央区日本橋人形町 2-24-4
 にほんばしコスモ 15 ビル (株) メイプロジェクト内
 TEL: 03-6667-0922 FAX: 03-6661-1490 E-mail: taikai@jamit.jp

#### 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」 (http://www.jamit.jp/outline/agreement/rieki.html)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.

#### 11. 第 13 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) 「医用画像工学における最新 AI 研究の課題とその展望について」 第 42 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 13 回日本医用画像工学会 (JAMIT)チ ュートリアル講演会 「医用画像工学における最新 AI 研究の課題とその展望について」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いたします。

- 日 時:7月27日(木) 13:00~16:00
- 座 長: 滝沢 穂高(筑波大学)

中田 典夫 (東京慈恵会医科大学)

- 講演1:(TU1)医用画像工学における大規模言語モデルの基礎 中田 典生 (東京慈恵会医科大学)
- 講演2:(TU2) 脳 MRI の AI 解析と大量データ解析からみえる課題
   森 進 (ジョンズ・ホプキンス大学)
- 講演3:(TU3) AI における分類問題の評価指標とその解釈

青井 久 (立命館大学)

#### 12. 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(教育委員会企画)

ハンズオンセミナーは、資料に基づいて参加者の PC に環境を構築し、すぐにでも実験がで きる環境を提供します. 2023 年度は、PyTorch の利用を中心として、DICOM 画像の取り扱い、 ROC 解析などの統計的な手法を用いた評価も取り扱います. いずれも入門から中級程度の課題 を用意し、深層学習を利用した実験の流れを実践的に習得します. セミナーでは課題 1 から課 題4を用意します(各回 90 分). ご興味ある課題を自由に受講ください. それぞれ受講人数を 24 名程度に制限します. なお、ハンズオンの参加には JAMIT2023 大会への登録と、ハンズオ ン専用ページから別途参加登録(7月1日開始)が必要です. 当日は、コンピュータの持参が必 要です. 事前に持参するコンピュータに環境を構築してください. GPU は不要ですが実質的に 動作しない課題があります. 詳細はハンズオン専用ページをご覧ください.

課題1:ハンズオンセミナー・コンテストに向けて「環境構築と深層学習による回帰の実現」 課題2:やり直し深層学習超入門「画像の分類から領域分割」

課題 3:深層学習のための前処理と後処理「DICOM 画像の読み込み/ROC などの統計処理」 課題 4:幅広い深層学習「小規模言語処理や音声認識における深層学習技術」

(内容は変更となる場合があります)

(ハンズオンセミナー・コンテスト)

これまでのハンズオンセミナーは、画像分類や回帰、領域分割を5年以上取り上げてきました. 2023 年度はそれらの小規模チャレンジとして、胸部 X 線画像から年齢を推定する精度をみなさんで比較する「ハンズオンセミナー・コンテスト」を企画しました. 参加対象は、最近深層学習の研究や実験を始めた初学者/初級者の個人/グループです. サンプルプログラムとデータ、実行環境はハンズオンセミナーのウェブページで配布します. 7/28 に実施する「JAMIT2023 ハンズオンセミナー・コンテスト」では、主催者がもつ画像データを公開し、その年齢を回答していただきます. 優秀な結果となった個人/グループを表彰します(副賞あり). また、ハンズオンセミナーの第1回(7/28,10:00開始)では、配布するプログラムと実行方法の解説を行います. 奮ってご参加ください. 詳細はハンズオンセミナーのウェブサイトをご覧ください.

(開催形態・会場)

ハンズオンセミナーは、会場内の 1 部屋を利用して対面形式で実施します. 事前に公開する セットアップ資料と題材に基づいて、セミナー開催までにご自身の PC に環境を構築して、そ の PC をご持参ください. もしくは会場に持参した PC から環境構築済みの PC ヘリモートロ グインできるようご準備をお願いします. 会場内では無線 LAN 形式で Eduroam によるネット ワーク接続が可能です. ご自身で Eduroam アカウントの確認,接続する PC の設定をお済ませ ください. PC の電源アダプターや増設コンセント類はご持参ください.

(参加登録)

7 月 1 日から JAMIT2023 大会ページにあるハンズオンセミナーへのリンクから参加申込を 開始します. ハンズオンセミナーへの参加には, JAMIT2023 大会への参加登録が必要です. (スケジュール)

- 7月1日 参加登録開始
- 7月18日 セットアップ資料の公開/コンテストサンプルプログラム・データの公開
- 7月25日 セミナー資料の公開
- 7月28日~29日 ハンズオンセミナー開催
- 7月28日 10:00~ 課題1, 15:00~ 課題2
- 7月28日 17:00~ JAMIT2023 ハンズオンセミナー・コンテスト
- 7月29日 9:30~ 課題3, 14:00~ 課題4

#### (各回の予定:90分)

- 00:00~00:05 達成目標の確認
- 00:05~00:10 プログラム実行のデモ
- 00:10~00:30 自分の PC での実行確認
- 00:30~00:50 プログラムの説明, GPU との比較
- 00:50~01:10 結果の確認/評価方法
- 01:10~01:20 自分の結果の再確認
- 01:20~01:30 問題点洗い出し/質疑応答/まとめ

(運営スタッフ)

原 武史 (岐阜大学), 滝沢 穂高 (筑波大学), 小田 昌宏 (名古屋大学)

中田 典生 (東京慈恵医科大学), 近藤 世範 (新潟大学)

(協力)

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 大学人工知能研究推進センター、東海国立大学機構健康医療ライフデザイン統合研究教育拠点 の協力で実施します.

(ハンズオンのウェブサイト) http://micv.sakura.ne.jp/jamitho/

### 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:株式会社 HPC テック/株式会社アスク 富士フイルム株式会社
- 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:株式会社 HPC テック
   菱洋エレクトロ株式会社
   株式会社ジーテップアドバンス
- 広 告 掲 載: 株式会社医療福祉工学研究所 エーザイ株式会社 株式会社オーム社 バイエル薬品株式会社 株式会社フィリップス・ジャパン

共 催: 大阪大学

- 後 援: 一般社団法人 日本画像医療システム工業会 一般社団法人 保健医療福祉情報システム工業会 一般社団法人 電子情報技術産業協会
- 協 賛: 医用画像情報学会
  - 公益社団法人 応用物理学会
  - 一般社団法人 可視化情報学会
  - 一般社団法人 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
  - 一般社団法人 情報処理学会
  - 一般社団法人 電子情報通信学会
  - 公益社団法人 日本医学物理学会
  - 公益社団法人 日本医学放射線学会
  - 一般社団法人 日本医療情報学会
  - 一般社団法人 日本核医学会
  - 特定非営利活動法人 日本核医学技術学会
  - 日本画像医学会
  - 一般社団法人 日本コンピュータ外科学会
  - 一般社団法人 日本磁気共鳴医学会
  - 一般社団法人 日本写真学会
  - 公益社団法人 日本生体医工学会
  - 公益社団法人 日本超音波医学会
  - 公益社団法人 日本放射線技術学会

# 第1日目/7月27日(木)

	第1会場	第2会場	第3会場	ハンズオン会場
	10 階 佐治敬三メモリアルホール	7階 セミナー室 7C+D	7 階 セミナー室 7A	6 階 セミナー室 6D
9:00				
9.00 -				
10:00-				
11:00-				
12:00-				
	12:50~13:00 閉会式			
13:00-	13:00~16:00			
	チュートリアル講演会			
	医用画像工学における最新AI研究の			
14 : 00-	課題とその展望について			
	日本 (10) 医用画家工子における入院候告 語モデルの基礎			
	中田 共主 TU2 脳 MRIの AI 解析と大量データ			
15:00-	解析からみえる課題 <b>森 進</b>			
	TU3 AIにおける分類問題の評価指標 とその解釈			
	青井久			
16:00—				
	16:10~17:40			
	シンポジウム 1			
	JAMIT の未来をつくろう!			
17:00—	   座長:橋本 二三生、健山 智子   パラリスト・堀 巻輔 赤松 剛 山口 知子			
	ホーム 「「「「」」」」、「」」、「」」、「」」、「」、「」、「」、「」、「」、「」、「			
18:00-	17:50~18:50	17:50~18:50 血心口日王 へ	17:50~18:50	
	│	一版通過2 教育・診断支援システム	一版通過3	
	0P1-1~0P1-6	0P2-1~0P2-6	0P3-1~0P3-5	
	座長 : 佐藤 嘉伸、青山 正人	座長:森健策、河田佳樹	座長:北坂 孝幸、 滝沢 穂高	
19:00-				

### 第2日目/7月28日(金)

	第1会場	第2会場	第3会場	ハンズオン会場
	10 階 佐治敬三メモリアルホール	7階 セミナー室 7C+D	7階 セミナー室 7A	6 階 セミナー室 6D
9:00 —				
10:00-				
	10:00~11:00 特別講演 1			10:00~11:30
	新興再興感染症と			-
	COVID-19 これはでここれから 座長:木戸尚治			ハンズオンセミナー 1
11:00-	演者 : 忽那 賢志			-
	11:10~12:10	11:10~12:10	11:10~12:10	
			一般演題10	
	スパースビュー CT・圧縮センシンク OP4-1~OP4-6	テーダ払張 OP7-1~OP7-6	核医学画像 OP10-1~OP10-6	
12:00-	座長:山登 一輝、庄野 逸	座長:根本 充貴、伊東 隼人	座長:北村 圭司、山谷 泰賀	
	12:20~13:20	-		
	ランチョンセミナー1			
	生成系 AI とリアルタイム AI で さらに進化する医用画像 AI			
13:00-	座長 : 奥山 義弘 注意: 100			
	澳伯·山田 氽水			
	13:30~14:30			
14:00-	会冒集会			
	14:40~16:40			
15:00-				15:00~16:30
	特別企画			
	AI ホスピタルプロジェクトの現在			-
	座長:富山 憲幸、 木戸 尚治			ハンズオンセミナー2
16:00-	演者:中村 祐輔、陣崎 雅弘、 武田 理宏、笠原 群生			-
				-
	16:50~17:40	16:50~17:40	16:50~17:40	_
17:00-	一般演題5	一般演題8	一般演題11	17:00~18:30
	ア測モデル OP5-1~OP5-5	两理画家 OP8-1~OP8-5	超胜1家 · 100种相运 0P11-1∼0P11-4	
	座長:目加田 慶人、花岡 昇平	座長:本谷 秀堅、間普 真吾	座長: 彌冨 仁、清水 昭伸	JAMIT2023
18 . 00-	17:50~19:00	17:50~19:00	17:50~18:50	- ハンズオンセミナー・コンテスト
10.00	一般演題6	一般演題 9	一般演題12	
	セグメンテーション 0P6.1~0P6-7	イメージング	分類・検出 OP12-1~OP12-6	
	座長:健山智子、中山良平	座長:伊藤 聡志、小尾 高史	座長:畑中 裕司、野村 行弘	
19:00—				-

### 第3日目/7月29日(土)

	第1会場	第2会場	第3会場	ハンズオン会場
	10 階 佐治敬三メモリアルホール	7階 セミナー室 7C+D	7階 セミナー室 7A	6階 セミナー室 6D
9:00 -				
	9:30~11:00			9:30~11:00
10:00-	シンポジウム2			
10.00	│ │ フォトンカウンティング CT の衝撃			
	座長:工藤 博幸、粟井 和夫			ハラスオラセミナー3
	演者:田口 克行、大野 良治、 梁川 雅弘、樋渡 昭雄			
11:00-				
	11:10~12:10	11:10~12:10	11:10~12:10	
	一般演題13	一般演題14	一般演題15	
	非画像情報 OP13-1~OP13-6	脳 0P14-1~0P14-6	手術映像等 OP15-1~OP15-6	
12:00-	座長:神谷 亨、 上村 幸司	座長:菅 幹生、増谷 佳孝	座長:中口 俊哉、小田 昌宏	
	12:20~13:20 ランチョンセミナー2			
	Deep Learning 技術による			
13:00-	読影支援の最前線     座長:梁川 雅弘			
	演者:北村 嘉郎			
	13:30~14:30			
	特別講演2			
14:00-	画像診断の歴史			14:00~15:30
	演者:百島 祐貴			
				ハンブナンセンナーク
15.00	14:40~16:10			
15:00-	9719943			
	ベンチャー企業が挑む AI 開発			
	座長:森 健策、稲井 邦博 演者:平岡 悠、飯塚 統			
16:00-	髙橋 秀徳、金井 宏樹			
	16:10~16:20 閉会式			
17:00-				
18:00-				
19:00-				

# 特別講演

#### 7月28日(金)

### 第1会場(10F 佐治敬三メモリアルホール)

#### 特別講演1

10:00~11:00 SL1「新興再興感染症と COVID-19 これまでとこれから」

座長:木戸 尚治(大阪大学)

SL1 新興再興感染症と COVID-19 これまでとこれから 忽那 賢志 大阪大学大学院医学系研究科 感染制御学

#### 7月29日(土)

### 第1会場(10F 佐治敬三メモリアルホール)

#### 特別講演2

13:30 ~ 14:30

SL2「画像診断の歴史」

座長: 陣崎 雅弘 (慶應義塾大学)

SL2 画像診断の歴史

百島 祐貴

慶應義塾大学病院予防医療センター

### 第1会場(10F 佐治敬三メモリアルホール)

### 特別企画

SE「AI ホスピタルプロジェクトの現在」  $14:40 \sim 16:40$ 座長: 富山 憲幸 (大阪大学) 木戸 尚治 (大阪大学) AI ホスピタルプロジェクト; AI・デジタルで心温まる医療を SE1 中村 祐輔 国立研究開発法人 医薬基盤・健康・栄養研究所 SE2 IT/AI の病院への実装を目指して 陣崎 雅弘 慶應義塾大学 医学部 放射線科学 SE3 AI研究に向けた医用画像とアノテーションデータの同時収集 武田 理宏 大阪大学大学院医学系研究科情報統合医学講座医療情報学 AI ホスピタルプロジェクトの現在 SE4 笠原 群生

国立成育医療研究センター

# シンポジウム

#### 7月27日(木)

#### 第1会場(10F佐治敬三メモリアルホール)

### シンポジウム1

16:10~17:40 **SY1「JAMIT の未来をつくろう!」** 

座長:橋本二三生(浜松ホトニクス株式会社)

健山 智子 (藤田医科大学)

パネリスト

堀 拳輔
順天堂大学 保健医療学部診療放射線学科
東京医科歯科大学大学院 医歯学総合研究科
赤松 剛
量子科学技術研究開発機構
山口 智子
神戸大学
遠田 涼
名古屋大学大学院 情報学研究科 知能システム学専攻
Gu Yi
奈良先端科学技術大学院大学 情報科学研究科 生体医用画像研究室
岡本 尚之
千葉大学 フロンティア医工学センター

#### 7月29日(土)

### 第1会場(10F 佐治敬三メモリアルホール)

シンポジウム2

9:30 ~ 11:00 SY2「フォトンカウンティング CT の衝撃」

座長:工藤 博幸(筑波大学)

粟井和夫(広島大学)

SY2-1 フォトンカウンティング CT の原理

田口 克行

Johns Hopkins University School of Medicine

 SY2-2
 高精細 CT および新型面検出器 CT の現状と将来展望

 大野 良治
 藤田医科大学 医学部 放射線医学教室,藤田医科大学 医学部 先端画像診断共同研究講座

- SY2-3
   胸部画像診断における Photon Counting CT の可能性

   梁川 雅弘
   大阪大学 大学院医学系研究科 放射線医学統合講座放射線医学
- SY2-4
   フォトンカウンティング CT の神経放射線領域への応用

   樋渡 昭雄
   名古屋市立大学大学院医学研究科 生体防御・総合医学専攻 生体総合医療学講座 放射線医学講座

#### 7月29日(土)

### 第1会場(10F 佐治敬三メモリアルホール)

### シンポジウム3

14:40 ~ 16:10 SY3「ベンチャー企業が挑む AI 開発」

座長:森 健策(名古屋大学)

稲井 邦博(福井大学)

- SY3-1
   ロボティクス、AIを活用した微生物検査グラム染色自動化機器の開発

   平岡
   悠

   大阪大学医学部附属病院,大阪大学大学院医学系研究科人工知能画像診断学,株式会社 GramEye
- SY3-2
   病理 AI による診断支援と活用の展望

   飯塚
   統

   メドメイン株式会社
- SY3-3ベンチャー企業が挑む AI 開発髙橋 秀徳DeepEyeVision 株式会社,学校法人自治医科大学
- SY3-4
   世界に挑戦する内視鏡 AI

   金井 宏樹<sup>1</sup>,多田 智裕<sup>1</sup>

   <sup>1</sup>株式会社 AI メディカルサービス

# チュートリアル講演会

7月27日(木)

#### 第1会場(10F 佐治敬三メモリアルホール)

#### チュートリアル講演会

13:00~16:00 TU「医用画像工学における最新 AI 研究の課題とその展望について」

座長:滝沢 穂高(筑波大学)

中田 典生 (東京慈恵会医科大学)

- TU1
   医用画像工学における大規模言語モデルの基礎

   中田
   典生

   東京慈恵会医科大学
   人工知能医学研究部
- TU2
   脳 MRI の AI 解析と大量データ解析からみえる課題

   森<進</td>
   近

   Johns Hopkins University 放射線科
- TU3
   AI における分類問題の評価指標とその解釈

   青井
   久

   立命館大学
   理工学部

   数理科学科

# ハンズオンセミナー

#### 7月28日(金)

#### ハンズオン会場(6F セミナー室 6D)

### ハンズオンセミナー1

10:00 ~ 11:30 HS1 ハンズオンセミナー・コンテストに向けて

#### 「環境構築と深層学習による回帰の実現」

### ハンズオンセミナー2

15:00~16:30 HS2 やり直し深層学習超入門「画像の分類から領域分割」

### JAMIT2023 ハンズオンセミナー・コンテスト

17:00 ~ 18:30 **HSC** 

#### 7月29日(土)

ハンズオン会場(6F セミナー室 6D)

### ハンズオンセミナー3

9:30 ~ 11:00

HS3 深層学習のための前処理と後処理

「DICOM 画像の読み込み / ROC などの統計処理」

### ハンズオンセミナー4

14:00 ~ 15:30

HS4 幅広い深層学習

「小規模言語処理や音声認識における深層学習技術」

# ランチョンセミナー

7月28日(金)

#### 第1会場(10F佐治敬三メモリアルホール)

### ランチョンセミナー1

#### 12:20 ~ 13:20 LS1「生成系 AI とリアルタイム AI でさらに進化する医用画像 AI」

座長: 奥山 義弘 (株式会社 HPC テック)

 LS1
 生成系 AI とリアルタイム AI でさらに進化する医用画像 AI

 山田 泰永
 エヌビディア合同会社

7月29日(土)

### 第1会場(10F 佐治敬三メモリアルホール)

### ランチョンセミナー2

12:20 ~ 13:20

LS2「DeepLearning 技術による読影支援の最前線」

座長:梁川 雅弘(大阪大学)

LS2 DeepLearning 技術による読影支援の最前線 北村 嘉郎 富士フイルム

### プログラム

#### 7月27日(木)

### 第1会場(10F 佐治敬三メモリアルホール)

### 開会式

12:50 ~ 13:00

### チュートリアル講演会

13:00 ~ 16:00

TU「医用画像工学における最新 AI 研究の課題とその展望について」

座長: 滝沢 穂高(筑波大学)

中田 典生 (東京慈恵会医科大学)

TU1	医用画像工学における大	、規模言語モデルの基礎
	中田 典生	
	東京慈恵会医科大学	人工知能医学研究部

脳 MRIの AI 解析と大量データ解析からみえる課題 TU2 森 進 Johns Hopkins University 放射線科

TU3 AIにおける分類問題の評価指標とその解釈 青井 久 立命館大学 理工学部 数理科学科

### シンポジウム1

16:10~17:40 SY1 JAMIT の未来をつくろう!」

座長:橋本二三生(浜松ホトニクス株式会社)

健山 智子(藤田医科大学)

#### パネリスト

堀 拳輔
順天堂大学 保健医療学部診療放射線学科
東京医科歯科大学大学院 医歯学総合研究科
赤松 剛
量子科学技術研究開発機構
山口 智子
神戸大学
遠田 涼
名古屋大学大学院 情報学研究科 知能システム学専攻
Gu Yi
奈良先端科学技術大学院大学 情報科学研究科 生体医用画像研究室
岡本 尚之
千葉大学 フロンティア医工学センター

#### 一般演題1

17:50~18:50 OP1 防骨格系」

#### 座長: 佐藤 嘉伸(奈良先端科学技術大学院大学) 青山 正人(広島市立大学)

- OP1-1
   FPA LRSE U-Net を用いた CT 画像からの脊椎領域の自動抽出 木佐貫航平<sup>1</sup>、寺澤 岳<sup>2</sup>、神谷 亭<sup>1</sup>、青木 隆敏<sup>2</sup>

   <sup>1</sup>九州工業大学、<sup>2</sup>産業医科大学
- OP1-2
   体幹部筋骨格の年齢変化統計モデルの構築

   坂本龍士郎<sup>1</sup>,政木勇人<sup>1</sup>,大竹義人<sup>1</sup>,崇風まあぜん<sup>1</sup>,上村 圭亮<sup>2</sup>,高尾 正樹<sup>2</sup>,明石 敏明<sup>3</sup>, 森 健策<sup>45</sup>,合田 憲人<sup>4</sup>, 菅野 信彦<sup>2</sup>,佐藤 嘉伸<sup>1</sup>

   <sup>1</sup>奈良先端科学技術大学院大学,<sup>2</sup>大阪大学,<sup>3</sup>順天堂大学,<sup>4</sup>国立情報学研究所,<sup>5</sup>名古屋大学
- OP1-3
   U-Net を用いた健常膝関節 MR 画像からの半月板領域抽出と損傷例への適用 武智 涼恵<sup>1</sup>,青山 正人<sup>1</sup>

   「広島市立大学大学院情報科学研究科
- OP1-4 超音波による複数パノラマ断層撮影と統計形状モデルフィッティングを用いた患者個別下肢全体 筋骨格形状の予測
  - 富木田悠生<sup>1</sup>, 政木 勇人<sup>1</sup>, 大竹 義人<sup>1</sup>, 崇風まあぜん<sup>1</sup>, 上村 圭亮<sup>2</sup>, 高尾 正樹<sup>2</sup>, 菅野 伸彦<sup>2</sup> <sup>1</sup>奈良先端科学技術大学院大学,<sup>2</sup>大阪大学

- OP1-5
   深層学習を用いた側弯症レントゲン画像の自動計測

   藤森 孝人<sup>1</sup>,鈴木 裕紀<sup>2</sup>,中嶋 望<sup>3</sup>,喜多 洸介<sup>2</sup>,蟹江 祐哉<sup>1</sup>,武中 章太<sup>1</sup>,海渡 貴司<sup>1</sup>, 岡田 誠司<sup>1</sup>,木戸 尚治<sup>2</sup>

   <sup>1</sup>大阪大学医学部整形外科,<sup>2</sup>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,<sup>3</sup>市立 堺病院整形外科
- OP1-6 注意機構を用いた畳み込みニューラルネットワークによる胸部 X 線画像から骨密度の推定 岩尾 佳幸<sup>1</sup>, 汐月 剣志<sup>1</sup>, 橋本 二三生<sup>2</sup>, 落合 昂大<sup>1</sup>, 畑中 裕司<sup>3</sup>, 賀川 経夫<sup>3</sup>, 永田 亮一<sup>3</sup>, 衞藤 路弘<sup>45</sup>, 吉田 幸人<sup>1</sup> <sup>1</sup>大分大学医学部附属病院 医療技術部放射線部門,<sup>2</sup>千葉大学大学院融合理工学府,<sup>3</sup>大分大学 理 工学部 共創理工学科知能情報システムコース,<sup>4</sup>日本文理大学 保健医療学部 保健医療学科 診療 放射線学コース,<sup>5</sup>大分大学大学院工学研究科博士後期課程

7月27日(木)

#### 第2会場(7F セミナー室7C+D)

#### 一般演題2

17:50 ~ 18:50

#### OP2「教育・診断支援システム」

座長:森 健策(名古屋大学)河田 佳樹(徳島大学)

- OP2-1
   乳がん CAD 併用読影における画像診断学習システムの開発

   菅原 暉典<sup>1</sup>,安倍 和弥<sup>1</sup>,武尾 英哉<sup>1</sup>,縄野 繁<sup>2</sup>

   <sup>1</sup>神奈川工科大学 工学部 電気電子情報工学科,<sup>2</sup>新松戸中央総合病院
- OP2-2 診療放射線技師教育用ファントムを活用した画像解析競技の有用性 近藤 啓介 駒澤大学 医療健康科学部
- OP2-3
   腹腔鏡手術シミュレーションにおける臓器の把持および変形操作の実装

   宮崎琳太郎<sup>1</sup>,林 雄一郎<sup>1</sup>,小田 昌宏<sup>21</sup>,森
   健策<sup>134</sup>

   <sup>1</sup>名古屋大学大学院情報学研究科、<sup>2</sup>名古屋大学情報連携推進本部情報戦略室、<sup>3</sup>国立情報学研究所医療ビッグデータ研究センター、<sup>4</sup>名古屋大学情報基盤センター
- OP2-4
   3時相腹部造影 CT 画像を用いた小径腎腫瘍の解析 越野 魁都<sup>1</sup>,西岡 大<sup>1</sup>,河田 佳樹<sup>2</sup>,小針 悠希<sup>3</sup>,池田 篤史<sup>4</sup>,仁木 登<sup>5</sup>
   <sup>1</sup>徳島大学大学院創成科学研究科,<sup>2</sup>徳島大学ポストフォトニクス研究所,<sup>3</sup>東京女子医科大学,<sup>4</sup>筑波 大学医学医療系,<sup>5</sup>株式会社医用科学研究所
- OP2-5
   糸球体上皮細胞画像を用いた曖昧境界に対する領域抽出方法の開発 大野 侑亮<sup>1</sup>, 松浦 勉<sup>2</sup>

   <sup>1</sup>群馬医療福祉大学 医療技術学部,<sup>2</sup>群馬大学 数理データ科学教育研究センター
- OP2-6
   U-Net を用いた X 線画像による慢性便秘症の診断支援 高島 直也<sup>1</sup>,藤田 大輔<sup>1</sup>,佐貫 毅<sup>2</sup>,木下 芳一<sup>2</sup>,小橋 昌司<sup>1</sup>

   <sup>1</sup>兵庫県立大学大学院工学研究科,<sup>2</sup>兵庫県立はりま姫路総合医療センター

### 第3会場(7F セミナー室7A)

#### 一般演題3

17:50~18:50 **OP3「画質改善・画質評価」** 

座長:北坂 孝幸(愛知工業大学)

滝沢 穂高(筑波大学)

- OP3-1
   DICOM 保存された CT 画像からノイズを取り除く

   西本<</td>
   聡

   兵庫医科大学 形成外科
- OP3-2
   入力画像の雑音量調整による深層学習雑音除去法の性能改善 高橋佳太郎<sup>1</sup>, 植田 貴之<sup>1</sup>, 山登 一輝<sup>1</sup>, 伊藤 聡志<sup>1</sup>

   <sup>1</sup>宇都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム
- OP3-3
   異常データ検知トモグラフィと深層学習を用いた CT メタルアーティファクト除去のハイブリッド手法

   『
   『 澤娜<sup>1</sup>, 金 喜正<sup>1</sup>, 藤井 克哉<sup>1</sup>, 滝沢 穂高<sup>1</sup>, 工藤 博幸<sup>1</sup>

1筑波大学システム情報系情報工学域

- OP3-4
   深層学習による血液エコーの非スペックル成分識別のロバスト性向上 森 友雅<sup>1</sup>,大村 眞朗<sup>2</sup>,長岡 亮<sup>2</sup>,高 尚策<sup>2</sup>,長谷川英之<sup>2</sup>

   「富山大学大学院 医薬理工学環,<sup>2</sup>富山大学 学術研究部工学系
- OP3-5
   高時間分解能を保持した超音波周波数特性解析の広帯域化

   大村 眞朗<sup>1</sup>,長岡 亮<sup>1</sup>,八木 邦公<sup>2</sup>,長谷川英之<sup>1</sup>

   <sup>1</sup>富山大学 学術研究部工学系,<sup>2</sup>金沢医科大学 医学部

#### 7月28日(金)

### 第1会場(10F 佐治敬三メモリアルホール)

#### 特別講演1

10:00 ~ 11:00 SL1「新興再興感染症と COVID-19 これまでとこれから」

座長:木戸 尚治(大阪大学)

SL1新興再興感染症と COVID-19 これまでとこれから<br/>忽那 賢志

大阪大学大学院医学系研究科 感染制御学

#### 一般演題4

11:10 ~ 12:10

OP4「スパースビュー CT・圧縮センシング」

座長:山登 一輝(宇都宮大学)

庄野 逸(電気通信大学)

 
 OP4-1
 確率的 Dykstra 型スプリッティングによる統一的なブロック反復型画像再構成法の構成: CT と PET への応用

 工藤 博幸<sup>1</sup>,金 喜正<sup>1</sup>,藤井 克哉<sup>1</sup>

 <sup>1</sup>筑波大学システム情報系情報工学域

- OP4-2
   深層学習にフラクタル画像を用いたスパースビュー CT 再構成

   川口
   廉<sup>1</sup>, 橋本 雄幸<sup>1</sup>

   <sup>1</sup>杏林大学大学院保健学研究科
- OP4-3
   深層学習を用いた角度欠損 CT 画像再構成の敵対的反例とその解決法: 深層学習と逐次近似再構成法のハイブリッド法 市木 翔吾<sup>1</sup>, 佐藤 悠輝<sup>1</sup>, 岡部 蒼太<sup>1</sup>, 藤井 克哉<sup>1</sup>, 工藤 博幸<sup>1</sup>

   「抗波大学システム情報系情報工学域
- OP4-4
   スパース空間学習を利用した MR 画像の深層学習再構成

   笹谷
   晃斗<sup>1</sup>,大内
   翔平<sup>2</sup>,山登
   一輝<sup>1</sup>,伊藤
   聡志<sup>1</sup>

   <sup>1</sup> 宇都宮大学大学院
   地域創生科学研究科
   情報電気電子システム工学プログラム
   伊藤・山登研究室,<sup>2</sup>

   小山工業高等専門学校
- OP4-5
   アンサンブル学習による CS-MRI 深層学習再構成の性能改善

   古田
   真輝<sup>1</sup>, 山登
   一輝<sup>1</sup>, 伊藤
   聡志<sup>1</sup>

   <sup>1</sup>宇都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム
- OP4-6
   サンプリングパターンの拡張による CS-MRI 深層学習再構成の性能改善 山登 一輝<sup>1</sup>, 渋井 雅希<sup>2</sup>, 伊藤 聡志<sup>2</sup>

   <sup>1</sup>宇都宮大学 工学部 基盤工学科, <sup>2</sup>宇都宮大学大学院 地域創生科学研究科 情報電気電子システム工学 プログラム 伊藤・山登研究室

### ランチョンセミナー1

12:20~13:20 LS1「生成系 AI とリアルタイム AI でさらに進化する医用画像 AI」

座長:奥山 義弘(株式会社 HPC テック)

 LS1
 生成系 AI とリアルタイム AI でさらに進化する医用画像 AI

 山田 泰永
 エヌビディア合同会社

### 会員集会

13:30 ~ 14:30

#### 特別企画

14:40~16:40 SE「AIホスピタルプロジェクトの現在」

座長: 富山 憲幸 (大阪大学)

木戸 尚治 (大阪大学)

- SE1
   AI ホスピタルプロジェクト; AI・デジタルで心温まる医療を

   中村 祐輔
   国立研究開発法人 医薬基盤・健康・栄養研究所
- SE2
   IT/AI の病院への実装を目指して

   庫崎 雅弘
   慶應義塾大学 医学部 放射線科学
- SE3 AI 研究に向けた医用画像とアノテーションデータの同時収集 武田 理宏 大阪大学大学院医学系研究科情報統合医学講座医療情報学
- SE4
   AI ホスピタルプロジェクトの現在 笠原 群生

   国立成育医療研究センター

#### 一般演題5

16:50~17:40 **OP5「予測モデル**」

座長:目加田慶人(中京大学) 花岡 昇平(東京大学)

- OP5-1
   自己符号化器付 U-net の部分教師あり学習とその胸部 CT 画像における陰影領域抽出への応用 濱田 拓也<sup>1</sup>, 杉水 俊輝<sup>2</sup>, 間普 真吾<sup>1</sup>, 木戸 尚治<sup>3</sup>

   <sup>1</sup>山口大学大学院創成科学研究科,<sup>2</sup>筑波大学大学院理工情報生命学術院,<sup>3</sup>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
- OP5-2 3次元 CT 画像によるじん肺の重症度別粒状影解析
   新居 蓮叶<sup>1</sup>, 松廣 幹雄<sup>2</sup>,河田 佳樹<sup>3</sup>,大塚 義紀<sup>4</sup>,岸本 卓巳<sup>5</sup>, 芦澤 和人<sup>6</sup>,仁木 登<sup>7</sup>
   <sup>1</sup>徳島大学大学院創成科学研究科,<sup>2</sup>鈴鹿医療科学大学保健衛生学部放射線技術学科,<sup>3</sup>徳島大学大学院社会産業理工学研究部,<sup>4</sup>北海道中央労災病院,<sup>5</sup>岡山ろうさい病院,<sup>6</sup>長崎大学大学院医歯薬学総 合研究科,<sup>7</sup>(株)医用科学研究所
- OP5-3
   TKI 治療後における肺腫瘍成長の経時変化予測モデル

   古田凜太郎<sup>1</sup>,有村 秀孝<sup>2</sup>,田中謙太郎<sup>3</sup>,加葉田雄太郎<sup>4</sup>,内野 恭美<sup>1</sup>,江頭 舞<sup>1</sup>

   <sup>1</sup>九州大学大学院医学系学府保健学専攻医用量子線科学分野,<sup>2</sup>九州大学大学院医学研究院保健学部門,

   <sup>3</sup>九州大学病院呼吸器科内科学,<sup>4</sup>長崎大学情報データ学部
- OP5-4
   骨シンチグラムの陽性高集積検出支援システム設計時におけるテストデータ再利用による性能の バイアスとその補正 山中 陽大<sup>1</sup>, 中岡 竜介<sup>2</sup>, 清水 昭伸<sup>1</sup>

1 東京農工大学大学院工学研究院, 2 国立医薬品食品衛生研究所 医療機器部

OP5-5 MRIによる前立腺癌スクリーニングのための要精査領域検出モデルの検討

橋本 綾斗<sup>1</sup>, 立花 泰彦<sup>1</sup>, 岸本 理和<sup>1</sup>, 熊切 俊夫<sup>12</sup>, 森 慎一郎<sup>1</sup>, 森 康久仁<sup>3</sup>, 若月 優<sup>1</sup>, 須鎗 弘樹<sup>3</sup>

<sup>1</sup>国立研究開発法人 量子科学技術研究開発機構, <sup>2</sup>千葉大学 大学院融合理工学府, <sup>3</sup>千葉大学 大学院 工学研究院

### 一般演題6

17:50 ~ 19:00

### OP6「セグメンテーション」

#### 座長:健山 智子(藤田医科大学) 中山 良平(立命館大学)

- OP6-1
   CNN による頭部 Thick-slice CT 画像からの脳内血腫領域の自動抽出

   永澤
   朗<sup>1</sup>,藤田 大輔<sup>1</sup>,渡辺 翔吾<sup>2</sup>,連
   乃駿<sup>2</sup>,飯原 弘二<sup>2</sup>,小橋 昌司<sup>12</sup>

   <sup>1</sup>兵庫県立大学,<sup>2</sup>国立循環器病研究センター
- OP6-2 肺がん定位体放射線治療における3次元計画CT画像上のGTVに対する深層学習ネットワークのセグメンテーション性能への訓練対テスト比の影響
   崔 雲吴<sup>1</sup>,有村 秀孝<sup>2</sup>,吉武 忠正<sup>3</sup>,塩山 善之<sup>4</sup>,藪内 英剛<sup>2</sup>
   <sup>1</sup>九州大学大学院医学系学府保健学専攻,<sup>2</sup>九州大学大学院医学研究院保健学部門,<sup>3</sup>九州大学大学院 医学研究院臨床放射線科学分野,<sup>4</sup>九州国際重粒子線がん治療センター
- OP6-3
   深層学習を用いた放射線肺臓炎の領域抽出とその放射線治療計画への応用 福士 晴哉<sup>1</sup>, 国枝 悦夫<sup>2</sup>, 尾川 浩一<sup>1</sup>

   <sup>1</sup>法政大学 理工学部,<sup>2</sup>総合東京病院放射線治療センター
- OP6-4
   心機能評価のための心臓 CT のセマンティック・セグメンテーション手法に関する研究 佐々木諒介<sup>12</sup>,黒瀬 優介<sup>12</sup>,原田 達也<sup>12</sup>

   <sup>1</sup>東京大学大学院,<sup>2</sup>理化学研究所

### OP6-5 乳房超高速造影 MRI 画像における U-Net を用いた腫瘍血管抽出に関する検討 橋本 陽菜<sup>1</sup>, 片岡 正子<sup>2</sup>, 藤本 晃司<sup>23</sup>, 飯間 麻美<sup>24</sup>, 高田 正泰<sup>5</sup>, 戸井 雅和<sup>6</sup>, 川瀬 貫互<sup>7</sup>, 大橋 茜<sup>8</sup>, 本田 茉也<sup>29</sup>, 中本 裕士<sup>2</sup> <sup>1</sup>京都大学大学院 医学研究科 人間健康科学系専攻,<sup>2</sup>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),<sup>3</sup>京都大学大学院 医学研究科 高度医用画像学講座,<sup>4</sup>京都大学医学部附属病 院 先端医療研究開発機構,<sup>5</sup>京都大学大学院 医学研究科 外科学講座 乳腺外科学,<sup>6</sup>がん・感染症 センター都立駒込病院 乳腺外科,<sup>7</sup>天理よろづ相談所病院 放射線診断科,<sup>8</sup>ルンド大学医学部付属 病院 放射線診断科,<sup>9</sup>関西電力病院 放射線診断科

- OP6-6
   血管強調画像を用いた腹部 CT 像からの多臓器領域抽出

   大野 真奈<sup>1</sup>,申
   忱<sup>1</sup>, RothHolger R<sup>2</sup>,小田 昌宏<sup>31</sup>,林 雄一郎<sup>1</sup>,三澤 一成<sup>4</sup>,森 健策<sup>15</sup>

   <sup>1</sup>名古屋大学大学院情報学研究科,<sup>2</sup>NVIDIA Corporation,<sup>3</sup>名古屋大学情報連携推進本部情報戦略室,

   <sup>4</sup>愛知がんセンター,<sup>5</sup>国立情報学研究所医療ビッグデータ研究センター
- OP6-7
   多時相造影 CT 画像データベースの腎臓・腎腫瘍の抽出

   西岡
   大<sup>1</sup>、越野
   患都<sup>1</sup>、河田
   佳樹<sup>2</sup>、小針
   悠希<sup>3</sup>、池田
   篤史<sup>4</sup>、仁木
   登<sup>5</sup>

   <sup>1</sup>徳島大学大学院創成科学研究科理工学専攻、<sup>2</sup>徳島大学ポスト LED フォトニクス研究所、<sup>3</sup>東京女子
   医科大学、<sup>4</sup>筑波大学医学医療系、<sup>5</sup>株式会社医用科学研究所

#### 第2会場(7F セミナー室7C+D)

#### 一般演題7

11:10~12:10 OP7「データ拡張」

#### 座長: 根本 充貴(近畿大学)

#### 伊東 隼人 (名古屋大学)

 
 OP7-1
 Stable Diffusion による乳がん腫瘤の人工症例画像生成と良悪性鑑別への応用 安倍 和弥<sup>1</sup>, 武尾 英哉<sup>1</sup>, 縄野 繁<sup>2</sup>

 <sup>1</sup>神奈川工科大学,<sup>2</sup>新松戸中央総合病院

- OP7-2
   3D/2D U-Net を用いた CT 画像からの副腎領域の抽出に関する基礎的検討

   平岡 大季<sup>1</sup>,西本絋嗣郎<sup>2</sup>,滝沢 穂高<sup>3</sup>,工藤 博幸<sup>3</sup>

   <sup>1</sup> 筑波大学大学院情報理工学位プログラム,<sup>2</sup>埼玉医科大学国際医療センター,<sup>3</sup> 筑波大学システム情

   報系
- OP7-3 クロス擬似ラベルに基づく腸のセグメンテーション
   安 芹<sup>1</sup>,小田 紘久<sup>2</sup>,林 雄一郎<sup>1</sup>,北坂 孝幸<sup>3</sup>,滝本愛太朗<sup>4</sup>,檜 顕成<sup>4</sup>,内田 広夫<sup>4</sup>, 鈴木耕次郎<sup>5</sup>,小田 昌宏<sup>61</sup>,森 健策<sup>1,78</sup>
   <sup>1</sup>名古屋大学大学院情報学研究科,<sup>2</sup>静岡県立大学経営情報学部,<sup>3</sup>愛知工業大学情報科学部,<sup>4</sup>名古屋 大学大学院医学系研究科,<sup>5</sup>愛知医科大学医学部放射線科,<sup>6</sup>名古屋大学情報連携推進本部情報戦略室,
   <sup>7</sup>名古屋大学情報基盤センター,<sup>8</sup>国立情報学研究所医療ビッグデータ研究センター

OP7-4 肺マイクロ CT 像中の小葉間隔壁抽出のための教師データ生成に関する検討

深井 大輔<sup>1</sup>,小田 紘久<sup>2</sup>,林 雄一郎<sup>1</sup>,鄭 通<sup>1</sup>,中村 彰太<sup>3</sup>,小田 昌宏<sup>41</sup>,森 健策<sup>156</sup> <sup>1</sup>名古屋大学大学院情報学研究科,<sup>2</sup>静岡県立大学経営情報学部,<sup>3</sup>名古屋大学大学院医学系研究科,<sup>4</sup> 名古屋大学情報連携推進本部情報戦略室,<sup>5</sup>名古屋大学情報基盤センター,<sup>6</sup>国立情報学研究所医療ビッ グデータ研究センター

OP7-5腹部 CT 画像からの複数臓器抽出における CutMix の有用性の検討<br/>中山 晃平<sup>1</sup>,大野 真奈<sup>1</sup>,申 忱<sup>1</sup>,小田 昌宏<sup>12</sup>,林 雄一郎<sup>1</sup>,三澤 一成<sup>3</sup>, Ben Glocker<sup>6</sup>,<br/>Daniel Rueckert<sup>67</sup>,森 健策<sup>145</sup><sup>1</sup>名古屋大学大学院情報学研究科、<sup>2</sup>名古屋大学情報連携推進本部情報戦略室、<sup>3</sup>愛知県がんセン<br/>ター、<sup>4</sup>国立情報学研究所医療ビッグデータ研究センター、<sup>5</sup>名古屋大学情報基盤センター、<sup>6</sup>Imperial<br/>College London、<sup>7</sup>Technical University of Munich

 OP7-6
 Alpha-blending によるデータ拡張と敵対的学習を用いた DeepLab v3 による歯種セマンティックセグメンテーション

 渋谷
 恒介<sup>1</sup>、中山
 良平<sup>1</sup>、檜作
 彰良<sup>1</sup>、村田
 乾<sup>2</sup>

(〒 戸), 〒田 R干, 福口 彰良, 村田 乾 <sup>1</sup>立命館大学理工学部, <sup>2</sup>タカラテレシステムズ株式会社

### 一般演題8

16:50 ~ 17:40 OP8「病理画像」

座長:本谷 秀堅(名古屋工業大学)

間普 真吾 (山口大学)

OP8-1 呼吸器内視鏡迅速細胞診における AI 診断支援 尾見 康夫<sup>1</sup>,桐田 圭輔<sup>23</sup>,香川 洋輔<sup>2</sup>,高橋 真理<sup>4</sup>,後藤 功一<sup>2</sup> <sup>1</sup>NEC 医療機器ソフトウェア統括部,<sup>2</sup>国立がん研究センター東病院 呼吸器内科,<sup>3</sup>上尾中央総合病院 呼吸器内科,<sup>4</sup>国立がん研究センター東病院 トランスレーショナルリサーチ検体管理室,内視鏡セン ター

 
 OP8-2
 階層的クラス構造のためのマルチモーダル分類

 橋本 典明<sup>1</sup>,花田 博幸<sup>1</sup>,三好 寛明<sup>2</sup>,永石 美晴<sup>2</sup>,佐藤 健作<sup>2</sup>,大島 孝一<sup>2</sup>,本谷 秀堅<sup>3</sup>, 竹内 一郎<sup>1,4</sup>

 <sup>1</sup>理化学研究所,<sup>2</sup>久留米大学,<sup>3</sup>名古屋工業大学,<sup>4</sup>名古屋大学

OP8-3 Contrastive Learning を用いた甲状腺組織画像の識別と学習に有用なデータ拡張の検討 集住 航大<sup>1</sup>,間普 真吾<sup>1</sup>,八田 聡美<sup>23</sup>,稲井 邦博<sup>2</sup>,樋口 翔平<sup>24</sup>,木戸 尚治<sup>5</sup> <sup>1</sup>山口大学大学院創成科学研究科,<sup>2</sup>福井大学医学部病因病態医学講座分子病理学,<sup>3</sup>福井大学医学部 附属病院病理診断科/病理部,<sup>4</sup>福井県立病院病理診断科,<sup>5</sup>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

 
 OP8-4
 CEA 術後病理画像を用いた異常検知による循環器病発症予測

 石田 修也<sup>1</sup>,盛田 健人<sup>12</sup>,蓮 乃駿<sup>2</sup>,渡辺 翔吾<sup>2</sup>,小橋 昌司<sup>23</sup>,畠山 金太<sup>2</sup>,飯原 弘二<sup>2</sup>, 若林 哲史<sup>1</sup>

 <sup>1</sup>三重大学大学院 工学研究科,<sup>2</sup>国立循環器病研究センター,<sup>3</sup>兵庫県立大学大学院 工学研究科

 OP8-5
 高解像度 H&E 染色全スライド画像におけるカラーアンミキシングのための自動 ROI 選択

 ョウキナン<sup>1</sup>, 武山 彩織<sup>1</sup>, 山口 雅浩<sup>1</sup>

 <sup>1</sup>東京工業大学

### 一般演題9

17:50~19:00 **OP9「イメ**ージング」

座長:伊藤 聡志(宇都宮大学)

小尾 高史(東京工業大学)

- OP9-1
   高空間分解能位相コントラスト CT を得るための X 線回折波 2 重撮影法の開発

   砂口 尚輝<sup>1</sup>,湯浅 哲也<sup>2</sup>,島雄 大介<sup>3</sup>,黄 卓然<sup>1</sup>,市原 周<sup>4</sup>,西村理恵子<sup>4</sup>,岩越 朱里<sup>4</sup>, GuptaRajiv<sup>5</sup>,安藤 正海<sup>6</sup>

   <sup>1</sup>名古屋大学,<sup>2</sup>山形大学,<sup>3</sup>大阪物療大学,<sup>4</sup>名古屋医療センター,<sup>5</sup>マサチューセッツ総合病院,<sup>6</sup>高 エネルギー加速器研究機構
- OP9-2
   U-Net に逆投影演算を組み込んだ直接 PET 画像再構成法の提案 橋本二三生<sup>1</sup>,大手 希望<sup>1</sup>,大西 佑弥<sup>1</sup>

   <sup>1</sup>浜松ホトニクス株式会社中央研究所

- OP9-3
   3 検出器 SPECT 装置の新たなステップ間隔によるデータ収集法の提案

   皆川 智哉<sup>12</sup>, 堀 拳輔<sup>34</sup>, 橋本 雄幸<sup>2</sup>

   <sup>1</sup>東邦大学医療センター大橋病院放射線部,<sup>2</sup>杏林大学大学院保健学研究科,<sup>3</sup>順天堂大学保健医療学部,

   <sup>4</sup>東京医科歯科大学大学院医歯学総合研究科
- OP9-4
   モデルベース型深層学習画像再構成による MR 定量値マッピングの高速化の検討 藤田 直人<sup>1</sup>、横沢 俊<sup>2</sup>、白猪 亨<sup>2</sup>、寺田 康彦<sup>1</sup>

   <sup>1</sup>筑波大学 数理物質系 物理工学域、<sup>2</sup>富士フイルム株式会社 メディカルシステム開発センター

 OP9-5
 数値シミュレーションによる腹壁運動を伴う MR エラストグラフィにおける誤差低減法の検討

 玉田 綾<sup>1</sup>,谷口 陽<sup>12</sup>,西原 崇<sup>2</sup>,瀧澤 将宏<sup>2</sup>,菅 幹生<sup>13</sup>

 <sup>1</sup>千葉大学 融合理工学府 医工学コース,<sup>2</sup>富士フイルムヘルスケア株式会社,<sup>3</sup>千葉大学 フロンティ

 ア医工学センター

 OP9-6
 3 周波数同時加振 MR エラストグラフィにおける最適撮像条件の検討

 高崎 晴也<sup>1</sup>, 菅 幹生<sup>12</sup>, 岸本 理和<sup>3</sup>, 小畠 隆行<sup>3</sup>

 <sup>1</sup>千葉大学 融合理工学府 医工学コース,<sup>2</sup>千葉大学 フロンティア医工学センター,<sup>3</sup>量子科学技術研究開発機構

### OP9-7 Deep Image Prior を用いた蛍光 X 線 CT 画像再構成 對馬 結太<sup>1</sup>, 松岡 将宏<sup>2</sup>, 佐藤 和樹<sup>1</sup>, 草刈 颯太<sup>3</sup>, 笹谷 典太<sup>2</sup>, 砂口 尚樹<sup>4</sup>, 河嶋 秀和<sup>5</sup>, 兵藤 一行<sup>6</sup>, 湯浅 哲也<sup>2</sup>, 銭谷 勉<sup>1</sup> <sup>1</sup>弘前大学大学院理工学研究科, <sup>2</sup>山形大学大学院理工学研究科, <sup>3</sup>弘前大学理工学部, <sup>4</sup>名古屋大学大 学院医学系研究科, <sup>5</sup>京都薬科大学放射性同位元素研究センター, <sup>6</sup>高エネルギー加速器研究機構物質 構造科学研究所

#### 7月28日(金)

第3会場(7Fセミナー室7A)

#### 一般演題10

11:10~12:10 OP10「核医学画像」

座長:北村 圭司(株式会社 島津製作所)

山谷泰賀(量子科学技術研究開発機構)

- OP10-1
   3 次元類似性駆動型メディアン正則化を用いたピンホール SPECT の画像再構成 丹羽 英之<sup>1</sup>,尾川 浩一<sup>1</sup>

   <sup>1</sup>法政大学 理工学部
- OP10-2
   画像再構成を用いない機能・形態ハイブリッドイメージング装置の提案

   大西 佑弥<sup>1</sup>, 橋本二三生<sup>1</sup>, 大手 希望<sup>1</sup>, 大田 良亮<sup>1</sup>

   <sup>1</sup>浜松ホトニクス株式会社 中央研究所
- OP10-3
   量子 PET のモンテカルロシミュレーション:ポジトロニウム寿命のモデル化

   田島 英朗<sup>1</sup>,田久 創大<sup>1</sup>,錦戸 文彦<sup>1</sup>,高橋美和子<sup>1</sup>,山谷 泰賀<sup>1</sup>

   <sup>1</sup>量子科学技術研究開発機構
- OP10-4
   深層学習を用いた異種モダリティ変換による PET のブラインド吸収補正: 簡便な投影空間によるアプローチ

   平戸航之介<sup>1</sup>,山下 皓大<sup>1</sup>,佐藤 悠輝<sup>1</sup>,工藤 博幸<sup>1</sup>

   <sup>1</sup>筑波大学システム情報系情報工学域

- OP10-5
   重粒子線がん治療における初の臨床適用に向けた OpenPET 装置開発

   田島英朗<sup>1</sup>, 寅松千枝<sup>1</sup>, MohammadiAkram<sup>1</sup>, 岩男悠真<sup>1</sup>, 赤松 剛<sup>1</sup>, 稲玉 直子<sup>1</sup>, 姜 韓圭<sup>1</sup>,

   田尻 稔<sup>1</sup>, 水野 秀之<sup>1</sup>, 小藤 昌志<sup>1</sup>, 山谷泰賀<sup>1</sup>

   <sup>1</sup> 量子科学技術研究開発機構
- OP10-6
   Whole Gamma Imaging 4 号試作機の PET・コンプトンカメラハイブリッドイメージングシミュ レーション

   菊地 智也<sup>1</sup>, 田久 創大<sup>2</sup>, 菅 幹生<sup>13</sup>, 田島 英朗<sup>2</sup>, 錦戸 文彦<sup>2</sup>, 山谷 泰賀<sup>2</sup>

   <sup>1</sup>千葉大学 融合理工学府 医工学コース、<sup>2</sup>量子科学技術研究開発機構、<sup>3</sup>千葉大学 フロンティア医工

一般演題11

16:50~17:40 OP11「超解像・微細構造」

学センター

座長: 彌冨 仁(法政大学理工学部)

清水 昭伸(東京農工大学)

- OP11-1
   ESRGAN による医用画像の超高解像度化の検討 大坂 亮二<sup>1</sup>,安倍 和弥<sup>1</sup>,武尾 英哉<sup>1</sup>

   <sup>1</sup> 神奈川工科大学 工学部 電気電子情報工学科
- OP11-2
   拡散モデルを用いた胸部 CT 像の超解像

   関口
   樂<sup>1</sup>, 稲井
   邦博<sup>2</sup>, 清水
   昭伸<sup>1</sup>, 木戸
   尚治<sup>3</sup>

   <sup>1</sup>東京農工大学
   大学院
   工学研究院, <sup>2</sup>福井大学
   医学部
   分子病理学, <sup>3</sup>大阪大学
   大学院
   医学

   系研究科
- OP11-3
   深層学習とセグメント PSFT 信号を利用した MR 画像の超解像に関する基礎検討

   藤澤舜太郎<sup>1</sup>, 山登 一輝<sup>1</sup>, 伊藤 聡志<sup>1</sup>

   <sup>1</sup>宇都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム
- OP11-4
   X 線暗視野法を用いた膵管内乳頭粘液性腫瘍における乳頭状構造の3次元解析

   天野 遥菜<sup>1</sup>,砂口 尚輝<sup>1</sup>,黄 卓然<sup>1</sup>,岩越 朱里<sup>2</sup>,末永 雅也<sup>2</sup>,市原 周<sup>2</sup>,西村理恵子<sup>2</sup>, 島雄 大介<sup>3</sup>,湯浅 哲也<sup>4</sup>,安藤 正海<sup>5</sup>

   <sup>1</sup>東海国立大学機構名古屋大学,<sup>2</sup>国立病院機構名古屋医療センター,<sup>3</sup>大阪物療大学,<sup>4</sup>山形大学,<sup>5</sup> 高エネルギー加速器研究機構

一般演題12

17:50~18:50 **OP12「分類・検出」** 

座長:畑中 裕司 (大分大学)野村 行弘 (千葉大学)

OP12-1 気管支超音波画像と深層学習を用いた肺末梢病診断手法の開発

王 慧涛<sup>1</sup>, 鹿野 幸平<sup>2</sup>, 中島 崇裕<sup>3</sup>, 李 ジャオ<sup>4</sup>, 野村 行弘<sup>5</sup>, 中口 俊哉<sup>5</sup>
 <sup>1</sup>千葉大学 融合理工学府基幹工学, <sup>2</sup>千葉大学大学院医学研究院 呼吸器内科学, <sup>3</sup>獨協医科大学 呼吸 器外科学, <sup>4</sup>同済大学附属東方医院, <sup>5</sup>千葉大学フロンティア医工学センター

- OP12-2
   U-Net を用いた胸部 X 線像からの左肺境界の検出 永田 亮一<sup>1</sup>,畑中 裕司<sup>1</sup>

   <sup>1</sup>大分大学 理工学部
- OP12-3
   3D U-Net における非造影 CT 画像の大動脈・冠動脈の検出と分類 庄野未彩季<sup>1</sup>,鈴木 秀宣<sup>2</sup>,河田 佳樹<sup>3</sup>,杉浦 寿彦<sup>4</sup>,田邊 信弘<sup>5</sup>,丸茂 一義<sup>6</sup>,金子 昌弘<sup>7</sup>, 仁木 登<sup>8</sup>
   <sup>1</sup>徳島大学大学院創成科学研究科,<sup>2</sup>徳島大学理工学部,<sup>3</sup>徳島大学大学院社会産業理工学研究部,<sup>4</sup>千 葉大学,<sup>5</sup>千葉大学,<sup>6</sup>東京都予防医学協会,<sup>7</sup>東京都予防医学協会,<sup>8</sup>(株)医用科学研究所
- OP12-4
   2.5 次元特徴抽出及び 3 次元特徴選択による COVID-19 自動分類モデルの汎化性能に関する検討 遠田 涼<sup>1</sup>, 伊東 隼人<sup>1</sup>, 小田 昌宏<sup>21</sup>, 林 雄一郎<sup>1</sup>, 大竹 義人<sup>34</sup>, 橋本 正弘<sup>5</sup>, 明石 敏昭<sup>6</sup>, 青木 茂樹<sup>6</sup>, 森 健策<sup>17,4</sup>
   <sup>1</sup>名古屋大学大学院情報学研究科, <sup>2</sup>名古屋大学情報連携推進本部情報戦略室, <sup>3</sup>奈良先端科学技術大 学院大学先端科学技術研究科, <sup>4</sup>国立情報学研究所医療ビッグデータ研究センター, <sup>5</sup>慶應義塾大学医 学部, <sup>6</sup>順天堂大学医学部, <sup>7</sup>名古屋大学情報基盤センター
- OP12-5 3 次元 CT 画像を用いた 2 段階 3D U-Net によるじん肺粒状影抽出法 松廣 幹雄<sup>1</sup>,新居新居 蓮叶<sup>2</sup>,河田 佳樹<sup>2</sup>,大塚 義紀<sup>3</sup>,岸本 卓巳<sup>4</sup>,芦澤 和人<sup>5</sup>,仁木 登<sup>6</sup> <sup>1</sup>鈴鹿医療科学大学 保健衛生学部 放射線技術科学科,<sup>2</sup>徳島大学大学院理工学研究部,<sup>3</sup>北海道中 央労災病院,<sup>4</sup>岡山ろうさい病院,<sup>5</sup>長崎大学病院,<sup>6</sup>株式会社医用科学研究所
- OP12-6Soft-boundary を導入した SVDD-AE による胸部 CT 画像の異常検知<br/>GaoZhihui<sup>1</sup>、中山 良平<sup>1</sup>、檜作 彰良<sup>1</sup>、木戸 尚治<sup>2</sup>「立命館大学大学院 理工学研究科、<sup>2</sup>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<br/>講座

#### 7月28日(金)

### ハンズオン会場(6Fセミナー室6D)

### ハンズオンセミナー1

10:00~11:30 | HS1 ハンズオンセミナー・コンテストに向けて

#### 「環境構築と深層学習による回帰の実現」

### ハンズオンセミナー2

15:00 ~ 16:30 HS2 やり直し深層学習超入門「画像の分類から領域分割」

#### JAMIT2023 ハンズオンセミナー・コンテスト

17:00 ~ 18:30 **HSC** 

### 第1会場(10F佐治敬三メモリアルホール)

### シンポジウム 2

9:30 ~ 11:00 SY2「フォトンカウンティング CT の衝撃」

座長: 工藤 博幸(筑波大学)

粟井 和夫 (広島大学)

SY2-1	フォトンカウンティング CT の原理
	田口 克行
	Johns Hopkins University School of Medicine

- SY2-2
   高精細 CT および新型面検出器 CT の現状と将来展望

   大野
   良治

   藤田医科大学 医学部 放射線医学教室
- SY2-3
   胸部画像診断における Photon Counting CT の可能性

   梁川 雅弘
   大阪大学 大学院医学系研究科 放射線医学統合講座放射線医学
- SY2-4 フォトンカウンティング CT の神経放射線領域への応用 樋渡 昭雄 名古屋市立大学大学院医学研究科

#### 一般演題13

11:10 ~ 12:10

OP13「非画像情報」

座長: 神谷 亨(九州工業大学)上村 幸司(国立循環器病研究センター)

OP13-1 肺高血圧症の予測:胸部 CT 画像、性別、年齢、血液検査データを用いた医用画像診断支援シス テム

富山 実幸

大阪大学医学系研究科人工知能画像診断学共同研究講座

- OP13-2
   胸部 MRI を用いた Radiomics の安定性評価

   高瀬 真衣<sup>1</sup>,坂 知樹<sup>1</sup>,鎌田 洋<sup>1</sup>,岩澤 多恵<sup>2</sup>

   <sup>1</sup>金沢工業大学,<sup>2</sup>神奈川県立循環器呼吸器病センター
- OP13-3
   3 次元点群動画像を用いた顔の時系列変化の検出および非対称度評価

   木原 成海<sup>1</sup>,神谷 亨<sup>1</sup>

   <sup>1</sup>九州工業大学
- OP13-4
   非侵襲的なドライバー遺伝子変異有無の識別のための Radiomics 特徴量に基づく 2 クラス分類

   渡邊 至恩<sup>1</sup>,神谷 亨<sup>1</sup>

   <sup>1</sup>九州工業大学

OP13-5 頭部 CT 所見文重要度分類における能動学習アルゴリズムの比較

綿谷 朋大<sup>1</sup>, 佐藤 淳哉<sup>1</sup>, 喜多 洸介<sup>1</sup>, 富山 実幸<sup>2</sup>, 鈴木 裕紀<sup>1</sup>, 木戸 尚治<sup>1</sup>, 富山 憲幸<sup>2</sup> <sup>1</sup>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,<sup>2</sup>大阪大学大学院医学系研究科 放射線統合医学講座 放射線医学

 OP13-6
 UTH-BERT と注意機構を用いた医療診断レポートにおける部位識別

 成田 紗弥<sup>1</sup>,間普 真吾<sup>1</sup>,木戸 尚治<sup>2</sup>

 <sup>1</sup>山口大学大学院創成科学研究科,<sup>2</sup>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

### ランチョンセミナー2

#### 12:20~13:20 LS2 [DeepLearning 技術による読影支援の最前線]

座長:梁川雅弘(大阪大学)

LS2 DeepLearning 技術による読影支援の最前線 北村 嘉郎 富士フイルム

### 特別講演2

13:30~14:30 SL2「画像診断の歴史」

座長: 陣崎 雅弘 (慶應義塾大学)

 SL2
 画像診断の歴史

 百島
 祐貴

 慶應義塾大学病院予防医療センター

### シンポジウム3

14:40~16:10 SY3「ベンチャー企業が挑む AI 開発」

座長:森 健策(名古屋大学)稲井 邦博(福井大学)

- SY3-1
   ロボティクス、AIを活用した微生物検査グラム染色自動化機器の開発

   平岡
   悠

   大阪大学医学部附属病院,大阪大学大学院医学系研究科人工知能画像診断学,株式会社 GramEye
- SY3-2
   病理 AI による診断支援と活用の展望

   飯塚
   統

   メドメイン株式会社

- SY3-3ベンチャー企業が挑む AI 開発高橋 秀徳DeepEyeVision 株式会社、学校法人自治医科大学
- SY3-4
   世界に挑戦する内視鏡 AI

   金井
   宏樹,多田
   智裕

   株式会社 AI メディカルサービス
   メディカルサービス

### 閉会式

16:10 ~ 16:20

7月29日(土)

### 第2会場(7Fセミナー室7C+D)

### 一般演題14

OP14 「脳」 11:10 ~ 12:10

座長: 菅 幹生(千葉大学)増谷 佳孝(東北大学)

- OP14-1
   Vision Transformer と Brodmann area を用いた脳 SPECT 画像の認知症分類

   若尾 紘嵩<sup>1</sup>,深澤 誠<sup>2</sup>,飯塚 友道<sup>2</sup>,清水 昭伸<sup>1</sup>

   <sup>1</sup>東京農工大学大学院工学研究院.<sup>2</sup>複十字病院認知症疾患医療センター
- OP14-2
   3DCNN を用いた脳 MR 画像の 3 次元位置合わせ 馬場星太郎<sup>1</sup>,神谷
   亨<sup>1</sup>

   <sup>1</sup>九州工業大学
   <sup>1</sup>九州工業大学
- OP14-3
   MRI FLAIR 画像を用いた異常検知による脳梗塞再発予測の検討 渡辺 翔吾<sup>1</sup>,連 乃駿<sup>1</sup>,盛田 健人<sup>2</sup>,中奥由里子<sup>1</sup>,尾形宗士郎<sup>1</sup>,小橋 昌司<sup>3</sup>,飯原 弘二<sup>1</sup>

   <sup>1</sup>国立循環器病研究センター,<sup>2</sup>三重大学,<sup>3</sup>兵庫県立大学
- OP14-4
   神経メラニン画像を利用した黒質緻密部分類に関する初期的検討

   伊東 隼人<sup>1</sup>,小田 昌宏<sup>21</sup>,斉木 臣二<sup>3</sup>,鎌形 康司<sup>4</sup>,石川 景一<sup>4</sup>,佐光 亘<sup>4</sup>,服部 信考<sup>4</sup>, 青木 茂樹<sup>4</sup>,森 健策<sup>1256</sup>

   <sup>1</sup>名古屋大学 大学院情報学研究科,<sup>2</sup>名古屋大学 情報連携推進本部,<sup>3</sup>筑波大学 神経内科,<sup>4</sup>順天堂大 学 医学部,<sup>5</sup>名古屋大学 情報基盤センター,<sup>6</sup>国立情報学研究所 医療ビッグデータ研究センター

 OP14-5
 定量的磁化率マップ QSM のヒト頭部オブリーク撮像:皮質脊髄路の QSM 値の分析

 高橋 哲彦<sup>1</sup>, 星野美紗子<sup>2</sup>, 小島 陸<sup>3</sup>, 駒 萌乃<sup>1</sup>, 丁嵐 亮<sup>1</sup>

 <sup>1</sup>群馬県立県民健康科学大学,<sup>2</sup>群馬県立県民健康科学大学(現 上尾中央総合病院),<sup>3</sup>群馬県立県民

 健康科学大学(現 美原記念病院)
OP14-6
 MobileNetV2の Fine tuning を用いた Neuromelanin 画像からの Parkinson 病進行度の推定

 奥田 健太<sup>1</sup>, 高橋 洋人<sup>1</sup>, 三浦あづさ<sup>1</sup>, 崎須賀敬央<sup>1</sup>, 綿谷 朋大<sup>1</sup>, 松尾 千聡<sup>1</sup>, 有澤亜津子<sup>1</sup>, 富山 美幸<sup>2</sup>, 佐藤 淳哉<sup>2</sup>, 喜多 洸介<sup>2</sup>, 鈴木 裕紀<sup>2</sup>, 木戸 尚治<sup>2</sup>, 梶山 裕太<sup>3</sup>, 小河 浩太郎<sup>3</sup>, 望月 秀樹<sup>3</sup>, 富山 憲幸<sup>1</sup>

 <sup>1</sup>大阪大学医学系研究科 放射線統合医学講座 放射線医学教室,<sup>2</sup>大阪大学医学系研究科 人工知能 画像診断学共同研究講座,<sup>3</sup>大阪大学医学系研究科 神経内科学講座

## 7月29日(土)

# 第3会場(7F セミナー室7A)

## 一般演題15

11:10~12:10 OP15「手術映像等」

座長:中口 俊哉(千葉大学) 小田 昌宏(名古屋大学)

OP15-1 ラベル平滑化を用いた腹腔鏡映像からの手術箇所の認識に関する検討 林 雄一郎<sup>1</sup>, 三澤 一成<sup>2</sup>, 森 健策<sup>1,3</sup> <sup>1</sup>名古屋大学大学院情報学研究科,<sup>2</sup>愛知県がんセンター消化器外科,<sup>3</sup>国立情報学研究所医療ビッグデー タ研究センター

- OP15-2Multi-step Fine-tuning for Tracking Invisible Vein during Laparoscopic Surgery<br/>ZHAOXINKAI<sup>1</sup>,林雄一郎<sup>1</sup>,小田昌宏<sup>21</sup>,北坂孝幸<sup>3</sup>,三澤一成<sup>4</sup>,森 健策<sup>156</sup><br/>
  <sup>1</sup>名古屋大学大学院情報学研究科、<sup>2</sup>名古屋大学情報連携推進本部情報戦略室、<sup>3</sup>愛知工業大学情報科<br/>
  学部、<sup>4</sup>愛知県がんセンター、<sup>5</sup>名古屋大学情報基盤センター、<sup>6</sup>国立情報学研究所医療ビッグデータ<br/>
  研究センター
- OP15-3U-Net を用いた股関節斜視鏡画像からの股関節唇および大腿骨頭の抽出<br/>川上申之介<sup>1</sup>,福田 紀生<sup>2</sup>,西井 孝<sup>3</sup>,大竹 義人<sup>4</sup>,佐藤 嘉伸<sup>4</sup><sup>1</sup>関西女子短期大学,2脳情報通信融合研究センター,3大阪急性期・総合医療センター,4奈良先端科<br/>学技術大学院大学
- OP15-4 広視野撮影による皮膚毛細血管の多数同時観察とセマンティックセグメンテーションを用いた密 度推定

瀧本 麦<sup>1</sup>, 尾藤 宏達<sup>2</sup>, 田口 浩之<sup>3</sup>, 播 さや香<sup>4</sup>, 羽石 秀昭<sup>5</sup>
 <sup>1</sup>花王株式会社 解析科学研究所,<sup>2</sup>花王株式会社 コーポレート戦略部門 デジタル事業創造部,<sup>3</sup>
 花王株式会社 研究開発部門 研究戦略・企画部,<sup>4</sup>花王株式会社 ヘルス&ウェルネス研究所,<sup>5</sup>千
 葉大学 フロンティア医工学センター

OP15-5 舌画像解析と機械学習を用いた漢方医学病態予測 鈴木萌仁伽<sup>1</sup>,石川 堅也<sup>2</sup>,渡邊 悠紀<sup>3</sup>,並木 隆雄<sup>3</sup>,森田 智<sup>4</sup>,村上 綾<sup>5</sup>,野村 行弘<sup>6</sup>, 中口 俊哉<sup>6</sup> <sup>1</sup>千葉大学工学部総合工学科医工学コース、<sup>2</sup>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、

<sup>3</sup>千葉大学大学院医学研究院和漢診療学,<sup>4</sup>千葉大学医学部附属病院東洋医学センター墨田漢方研究所, <sup>5</sup>横浜薬科大学薬学教育センター,<sup>6</sup>千葉大学フロンティア医工学センター

 OP15-6
 前眼部画像から感染性角膜炎の原因を予測する AI モデルの作成

 佐藤貴輝<sup>1</sup>,奥村直毅<sup>1</sup>,松村拓弥<sup>1</sup>,SaravanaSangavi<sup>2</sup>,LakshmipathyMeena<sup>2</sup>,

 SudhirRachapalle<sup>2</sup>,小泉範子<sup>1</sup>

 <sup>1</sup>同志社大学大学院生命医科学研究科,<sup>2</sup>Sankara Nethralaya

# ハンズオン会場(6F セミナー室 6D)

# ハンズオンセミナー3

9:30~11:00 HS3 深層学習のための前処理と後処理

「DICOM 画像の読み込み / ROC などの統計処理」

# ハンズオンセミナー4

14:00~15:30 HS4 幅広い深層学習

「小規模言語処理や音声認識における深層学習技術」

7月27日(木)

# チュートリアル講演会

13:00~16:00 TU「医用画像工学における最新 AI 研究の課題とその展望について」

座長: 滝沢 穂高(筑波大学)

## 中田 典生 (東京慈恵会医科大学)

現在、深層学習によって始まった第三の AI ブームは、ChatGPT に代表される大規模言語モデルを使用した生成系 AI などにより題4の AI ブームへ移行していると推定されます。そこで今回のチュートリアルでは、①大規模言語モデル の基礎と実態を医用画像工学の視点から解説。②最新の脳 MRI の AI 開発の最前線について MRI 研究の第一人者であ り AI のエキスパートでもある先生からの解説。③最後に AI 研究には欠かせない、AI の評価について数理科学の専門 家からの解説を企画いたしました。

TU1 医用画像工学における大規模言語モデルの基礎

#### ○中田 典生

東京慈恵会医科大学 人工知能医学研究部

本講演では、医用画像工学における大規模言語モデルの理論と応用に焦点を当てる.まず、核心である Attention メカニズムと Transformer アーキテクチャの理論について紹介し、これらの技術が大量のテキストデータからどのように情報を抽出するかを明らかにする.その後、医療現場での具体的な応用例に移り、医療記録や医療画像の説明などのテキストデータと実際の医療画像との結びつけの重要性を解説する.大規模言語モデルはその複雑な関係性を理解する手助けをすること.また大規模言語モデルの持つ創発的能力が、医用画像工学の未来にどのような影響を与えるかについても議論する.この講演を通じて、参加者は大規模言語モデルの基本理解を深め、その医用画像工学への応用について新たな視点を得ることが期待される.

 TU2
 脳 MRI の AI 解析と大量データ解析からみえる課題

○森 進

Johns Hopkins University 放射線科

医療画像データはデジタル情報であるにもかかわらず,活用されずに眠っている状態である.その活用方法としては,個々の患者の画像診断と人口レベルでの病態解析が考えられる.脳画像の特徴抽出を長年開発してきた演者は,現在古典的機械学習と最近の AI の双方を用いて,脳 MRI の大量データ解析を行っている.そこから得られた知見として,医療画像大量データ解析にはいくつかの「壁」がある.それは、「AI 技術の壁」、「大量データ収集の壁」、「教師データ正確性の壁」、「画像情報の包括性の壁」、「データの均一性の壁」、そして最も大切な「抽出情報の有用性の壁」である.本講演では、この研究を通して得られたこれらの知見を共有する.

TU3 AIにおける分類問題の評価指標とその解釈

○青井 久

立命館大学 理工学部 数理科学科

分類問題は、機械学習の中でも最も広く使われる基本的な問題の一つである.しかしながら、その評価指標は数多く存在し、 現実のデータに対しては複数の指標を駆使して解釈を与えることが求められる.例えば、一般には正解率 (Accuracy) だけでは 正しく評価できない場合が多々生じる(例:データが不均衡な場合).様々な状況に対応するべく、他の指標や閾値との兼ね合 いを元に検証する必要がある.評価指標は数学 / 統計学の理論を元に展開されており、その関連を知ることで議論の見通しが 良くなることが期待できる.

本講演では,長らく用いられている基礎的な指標(適合率,ROC 曲線など)から,実用を踏まえて新たに用いられるようになった指標(マシューズ相関係数, Cost 曲線など)に至るまで具体例と共に紹介する.

# 第1会場(10F 佐治敬三メモリアルホール)

# 一般演題1

17:50~18:50 **OP1「筋骨格系」** 

#### 座長: 佐藤 嘉伸 (奈良先端科学技術大学院大学)

青山 正人 (広島市立大学)

OP1-1 FPA LRSE U-Net を用いた CT 画像からの脊椎領域の自動抽出

○木佐貫航平<sup>1</sup>, 寺澤 岳<sup>2</sup>, 神谷 亨<sup>1</sup>, 青木 隆敏<sup>2</sup>
 <sup>1</sup>九州工業大学, <sup>2</sup>産業医科大学

骨転移は悪性腫瘍患者にしばしば合併する.骨転移の管理は、生命予後だけでなく日常生活動作や生活の質にも影響を及ぼ すため、早期発見が重要である.本論文では、同一被験者の過去及び現在のCT 画像から脊椎領域の位置合わせを行い、差分 演算を施すことにより、骨転移個所をビジュアライズするためのシステム開発を目的に、深層学習を用いたCT 画像における 脊椎領域の自動抽出を目指す.脊椎の小領域の抽出精度の改善を図るため、U-Net のエンコーダの最終層に、異なるスケール のコンテキスト情報を考慮したアテンションを行う Feature Pyramid Attention モジュールとデコーダに Lightweight Residual Squeeze-and-Excitation を採用したモデルを構築し、10 症例の現在画像を用いた 5 分割交差検証を行い、IoU による抽出精度 を求めた結果、92.0% の精度を得た.

OP1-2 体幹部筋骨格の年齢変化統計モデルの構築

○坂本龍士郎<sup>1</sup>,政木 勇人<sup>1</sup>,大竹 義人<sup>1</sup>,崇風まあぜん<sup>1</sup>,上村 圭亮<sup>2</sup>,高尾 正樹<sup>2</sup>,明石 敏明<sup>3</sup>, 森 健策<sup>45</sup>,合田 憲人<sup>4</sup>,菅野 信彦<sup>2</sup>,佐藤 嘉伸<sup>1</sup> <sup>1</sup>奈良先端科学技術大学院大学,<sup>2</sup>大阪大学,<sup>3</sup>順天堂大学,<sup>4</sup>国立情報学研究所,<sup>5</sup>名古屋大学

体幹部筋骨格モデルを構築し、加齢変化に基づく、体幹部筋骨格の変形過程を理解することは、手術計画や生体力学解析に 重要である.本研究では、大規模な CT データベースを用いて、連続的な各年齢の男女別の体幹部筋骨格の統計形状モデル (SSM) を構築する.J-MID データベースと共同研究施設で収集した4万症例以上のデータを活用し、従来は部分的な骨格形状に限定 されていた SSM 構築を、本研究では体幹部の複数の筋骨格構造を含めた SSM の構築を行う.構築された各年齢の統計形状モ デルの性能評価を行い、筋骨格形状の加齢変化について調査する.

OP1-3 U-Net を用いた健常膝関節 MR 画像からの半月板領域抽出と損傷例への適用

○武智 凉恵<sup>1</sup>,青山 正人<sup>1</sup>
 <sup>1</sup>広島市立大学大学院情報科学研究科

近年,医用画像からの領域抽出では、Convolutional Neural Network (CNN)を用いた手法が多く提案されているが、CNN の学習には多くの学習症例が必要とされている.本研究で対象とする半月板領域抽出では、三次元の健常膝関節 MR 画像20 症例、 損傷5 症例と、少数の画像データを扱う、そこで、Coronal 断面でリスライスした二次元画像データを入力とする U-Net によ り学習モデルを構築した。

領域抽出結果は5分割交差検証で評価した. バッチサイズ12, エポック80の設定で得られた Dice 係数は0.721 ± 0.028(平均±標準偏差)であった. 最も Dice 係数が高かった(0.767)分割時の学習モデルを用いて損傷5症例の半月板領域を抽出した ところ0.682 ± 0.064であった. このことから少数の健常例のみで学習したモデルでも損傷半月板の抽出がある程度可能である ことが確認できた.

- OP1-4 超音波による複数パノラマ断層撮影と統計形状モデルフィッティングを用いた患者個別下肢全体 筋骨格形状の予測
  - ○冨木田悠生<sup>1</sup>, 政木 勇人<sup>1</sup>, 大竹 義人<sup>1</sup>, 崇風まあぜん<sup>1</sup>, 上村 圭亮<sup>2</sup>, 高尾 正樹<sup>2</sup>, 菅野 伸彦<sup>2</sup> <sup>1</sup>奈良先端科学技術大学院大学,<sup>2</sup>大阪大学

超音波画像診断装置は、非侵襲・短時間で撮影可能であり高時間高分解能な画像が取得できるため、筋肉の解析に適したモ ダリティである.しかし、撮影範囲には制限があり、3次元的な解析が困難である.そこで本研究では下肢を撮像した複数の パノラマ超音波断面を用いて、下肢全体の筋骨格の形状を予測することを目的とする.具体的には、パノラマ超音波の複数断 面の撮像には、モーションキャプチャーを用いて、パノラマ断面とそれに対応する位置情報を取得する.筋骨格の形状予測には、 CT データベースを用いて統計形状モデルを構築し、構築したモデルと取得したデータを用いることで、筋骨格の形状を予測し、 推定精度を求めるため、1人の被験者から得られた同一箇所の3次元 MRI 画像と複数の超音波パノラマ断面を用いて、定量的 な評価を行う.この手法により、パノラマ超音波画像を複数取得するだけで、広範囲の筋骨格形状を取得することが可能となる.

- OP1-5 深層学習を用いた側弯症レントゲン画像の自動計測
  - ○藤森 孝人<sup>1</sup>, 鈴木 裕紀<sup>2</sup>, 中嶋 望<sup>3</sup>, 喜多 洸介<sup>2</sup>, 蟹江 祐哉<sup>1</sup>, 武中 章太<sup>1</sup>, 海渡 貴司<sup>1</sup>, 岡 田 誠司<sup>1</sup>, 木戸 尚治<sup>2</sup>
    - 1大阪大学医学部整形外科,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,3市立堺病院整形外科

脊柱アライメントは側弯症を評価する上で重要である.しかし,手動測定は時間がかかり,誤差もある.本研究では深層学 習を用いて測定の自動化を試みた.

側弯症 434 名の全脊柱画像 1197 枚(正面 696 枚,側面 501 枚)を対象とした.2人の脊椎外科医が C7 から S1 までの椎骨の 4 頂点をラベル付けし、グランドトゥルースとした.モデルは DeepLab3 を使用した.

グランドトゥルースと AI の平均絶対誤差 (MAE) は, 主カーブが 3.2° ± 3.5°, 冠状バランスが 2.9 ± 2.4 ピクセル, T1tilt が 1.9 ° ± 1.6°であった. 矢状面パラメータについては, MAE は胸椎後弯で 4.4° ± 3.5°, 腰椎前弯で 5.3° ± 4.5°, 仙骨角で 4.3° ± 3.8 °である. グランドトゥルースと AI の計測における相関係数は主カーブで 0.99, 胸椎後弯で 0.89 であった. AI の測定誤差は, 実臨床で使用可能な範囲内であった.

OP1-6 注意機構を用いた畳み込みニューラルネットワークによる胸部X線画像から骨密度の推定

〇岩尾 佳幸<sup>1</sup>, 汐月 剣志<sup>1</sup>, 橋本 二三生<sup>2</sup>, 落合 昂大<sup>1</sup>, 畑中 裕司<sup>3</sup>, 賀川 経夫<sup>3</sup>, 永田 亮一<sup>3</sup>, 衛藤 路弘<sup>45</sup>, 吉田 幸人<sup>1</sup>

<sup>1</sup>大分大学医学部附属病院 医療技術部放射線部門,<sup>2</sup>千葉大学大学院融合理工学府,<sup>3</sup>大分大学 理工学部 共創理工 学科知能情報システムコース,<sup>4</sup>日本文理大学 保健医療学部 保健医療学科 診療放射線学コース,<sup>5</sup>大分大学大学 院工学研究科博士後期課程

本研究の目的は、畳み込みニューラルネットワークに注意機構を組み合わせた深層学習モデルを用いて、胸部 X 線画像から 骨密度を推定することである. DXA 法を用いて腰椎の骨密度を測定する検査, および胸部 X 線検査を受けた患者を対象とした. 畳み込みニューラルネットワークの ResNet 50 に注意機構を組み合わせた深層学習モデルを用いて、胸部 X 線画像から骨密度 の推定を行った. 5 分割交差検証を用いてモデルの精度評価を行い、DXA 法により測定した骨密度との相関を回帰分析により 求めた. Bland-Altman 分析により、骨密度に対する DXA 法および、深層学習モデルの一致性を評価した. DXA 法および深 層学習モデルを用いて推定した骨密度の相関係数は 0.769 を示した. Bland-Altman 分析において、96% の患者が一致限界の範 囲内に収まった. 畳み込みニューラルネットワークに注意機構を組み合わせることで、DXA 法と高い相関を持つ骨密度の推定 が可能であることが示された.

# 第2会場(7Fセミナー室7C+D)

# 一般演題2

17:50~18:50 **OP2「教育・診断支援システム」** 

## 座長:森 健策(名古屋大学)

河田 佳樹(徳島大学)

OP2-1 乳がん CAD 併用読影における画像診断学習システムの開発

○ 菅原 暉典<sup>1</sup>, 安倍 和弥<sup>1</sup>, 武尾 英哉<sup>1</sup>, 縄野 繁<sup>2</sup> <sup>1</sup> 神奈川工科大学 工学部 電気電子情報工学科,<sup>2</sup> 新松戸中央総合病院

一般的に, 医学生や研修医や経験の浅い医師は, 典型的な症例や特徴的な症例を集めた画像症例集, いわゆるティーチングファ イルを利用して画像診断の読影法を学んでいく.一方, CAD (コンピュータ支援診断)の普及により異常陰影候補の検出結果 も参考にしながら最終的な診断を行うこともあるが, 現在のところそのような診断法における画像診断学習システムは存在し ない.

そこで本研究では、CAD 併用を前提とした読影における画像診断学習システムを提案する. これにより、CAD の癖も含め て学ぶこともできるようになる. さらに本システムは、特定の病院に導入された CAD がその病院の画像を用いて追加学習を 行うことで自動的に性能向上し、症例 DB にも逐次追加されていく機能も持つ.

本システムで学んだ場合を、従来のティーチングファイルにより学習した場合と比較し、本システムを用いた学習法の有効 性を確認する.

OP2-2 診療放射線技師教育用ファントムを活用した画像解析競技の有用性

○近藤 啓介

駒澤大学 医療健康科学部

診療放射線技師教育において、自ら考え行動できる教育を目的に、考察型の教育用ファントムを開発した、開発したファントムは、X線の吸収率が異なる3種類(黄色・青色・橙色)の立方体ファントム(XCUBE)と、XCUBEが縦横高さ各3個の計27個が入るブラックボックス(BBOX)で構成されている。教育課題は、27か所の各位置に3種類の立方体ファントムの何色が設置されたかをX線撮影した画像から解析する。

3大学6チームによる対面での競技大会「BBOX コンテスト」を開催した.事前に撮影した7方向から撮影したX線画像から最初に3種類を用いて解析し,追加で残りの方向の画像を選択して利用ができる.解析の正確性と利用したX線画像が少ない方が高得点となる.アクティブラーニングとして自ら考え行動できる教育として利用可能であること,チーム戦でのコミュニケーション能力やチーム力の育成に有用であったので報告する.

OP2-3 腹腔鏡手術シミュレーションにおける臓器の把持および変形操作の実装

○宮崎琳太郎<sup>1</sup>,林 雄一郎<sup>1</sup>,小田 昌宏<sup>21</sup>,森 健策<sup>134</sup>

<sup>1</sup>名古屋大学大学院情報学研究科,<sup>2</sup>名古屋大学情報連携推進本部情報戦略室,<sup>3</sup>国立情報学研究所医療ビッグデータ研 究センター,<sup>4</sup>名古屋大学情報基盤センター

本研究では、八分木構造および Position Based Dynamics(PBD) 法に基づく変形モデルを応用し、腹腔鏡鉗子による臓器モデ ルの把持および変形操作を実装した。手術シミュレーションは医師や医学生が手術技術を習得するための有効な手段の一つと して期待されている。腹腔鏡手術用のシミュレータは既に製品化され、手術手技の習得に有効であることが示されている。し かし、臓器のような柔軟物体の変形シミュレーションは計算量が多くなりやすく、リアルタイム性を確保するために臓器モデ ル自体のポリゴン数や操作デバイスとの接触判定の効率化が求められる。本研究では、臓器モデルから生成した八分木構造の ラフモデルを PBD 法によって変形する。さらにそのモデルと操作デバイスの接触判定を行うことでその効率化をおこなう、本 手法をゲームエンジンである Unity に実装し、リアルタイムでの操作を実現した。

#### OP2-4 3時相腹部造影 CT 画像を用いた小径腎腫瘍の解析

○越野 魁都<sup>1</sup>, 西岡 大<sup>1</sup>, 河田 佳樹<sup>2</sup>, 小針 悠希<sup>3</sup>, 池田 篤史<sup>4</sup>, 仁木  $3^{5}$ 

<sup>1</sup>徳島大学大学院創成科学研究科,<sup>2</sup>徳島大学ポストフォトニクス研究所,<sup>3</sup>東京女子医科大学,<sup>4</sup>筑波大学医学医療系, <sup>5</sup>株式会社医用科学研究所

腎がんと診断して手術を行っても良性腫瘍が10%であり,特に腫瘍径が小さい場合は良性腫瘍の頻度が高く注意が必要である.3時相の造影CT画像を用いて腎臓・腎腫瘍を解析することで,小径の腎がんと良性腫瘍の鑑別の可能性を追求する.淡明細胞型腎細胞がん12症例,嫌色素性腎細胞がん29症例,乳頭状腎細胞がん29症例,オンコサイトーマ16症例,血管筋脂肪腫14症例の解析を行う.手法は,(1)2DU-Netを用いて腎臓・腎腫瘍を自動抽出(2)抽出した多時相の腎臓・腎腫瘍を剛体レジストレーション(3)腎臓及び腎腫瘍にプロット点を与え混合分布法を用いてクラスタリング(4)多時相間におけるCT値の経時変化の解析からなる.腎臓・腎腫瘍内の造影パターンを用いて,小径の腎がんと良性腫瘍の鑑別の可能性を示す.

OP2-5 糸球体上皮細胞画像を用いた曖昧境界に対する領域抽出方法の開発

#### ○大野 侑亮<sup>1</sup>, 松浦 勉<sup>2</sup>

1群馬医療福祉大学 医療技術学部,2群馬大学 数理データ科学教育研究センター

人間が何らかの特徴を見出そうとするとき、自分にとって都合の良い情報を無意識に集めてしまう確証バイアスがかかる. 我々はこのバイアスを再現することで、機械学習の学習効率を上げることが出来ると考えている.本研究では、この一例として、 腎疾患によって糸球体上皮細胞の足突起が変性することを客観的に捉えるために撮影された SEM 画像を用いることで、この画 像の中で無意識に注目していると考えられる領域の自動抽出手法の開発を目的とする.本画像には、我々の興味がある領域と それ以外の領域の境界が曖昧である問題が存在する.近年の領域抽出に関する研究では、学習を用いる場合が多いが、少量し かデータを集められない場合を想定して、ここでは楕円形状のフィルターと輝度勾配ベクトルを組み合わせることで、学習を 伴わない手法の開発を行った.本手法を用いることで、後処理が少なく、手動で抽出したものと比較して高精度な領域抽出を 可能とした.

## OP2-6 U-Net を用いた X 線画像による慢性便秘症の診断支援

○高島 直也<sup>1</sup>,藤田 大輔<sup>1</sup>,佐貫 毅<sup>2</sup>,木下 芳一<sup>2</sup>,小橋 昌司<sup>1</sup> <sup>1</sup>兵庫県立大学大学院工学研究科,<sup>2</sup>兵庫県立はりま姫路総合医療センター

2019 年現在便秘の有訴者率は 34.8% と高く,加齢に伴って増加している.腹部 X 線画像から便秘の重症度やタイプを読影す るためには習熟を要し、また主観的である.そのため、便秘の重症度や分類の手掛かりとすることを目的とし、ガスと便の量 および所在を特定する技術が望まれている.腸管内ガスを定量的に評価する指標として GVS(gas volume score) があるが、医 師が手動で算出する必要があり、実臨床への導入は難しい.そこで本研究では便秘診断支援法として、U-Net を用いた腹部単 純 X 線画像からの便とガス領域の自動抽出法を提案する.加えて、便における同様の指標 SVS(stool volume score) と、ガス・ 便量を総合的に評価する指標 JVS(joint volume score) を提案する.本自動化手法による抽出領域と熟練消化器内科医によるマ スク領域を比較したところ GVS、SVS、JVS がそれぞれ相関係数で最大 0.938、0.879、0.751 であった.また、同様に比較した ところガス領域、便領域、ガスと便の結合領域において DICE 係数はそれぞれ最大 0.650、0.480、0.674 であった.

# 第3会場(7F セミナー室7A)

# 一般演題3

17:50~18:50 | **OP3**「画質改善・画質評価」

## 座長:北坂 孝幸 (愛知工業大学)

滝沢 穂高(筑波大学)

OP3-1 DICOM 保存された CT 画像からノイズを取り除く

○西本 聡

兵庫医科大学 形成外科

CT 撮影範囲内に X 線吸収率が高い物質が存在するとメタルアーチファクトと呼ばれるノイズが画像に現れる.撮影時にアー チファクトを軽減する方法も模索されているが、ノイズの含まれた DICOM 画像から 3 次元骨モデルを再構成しようとすると CT スライス 1 枚ごとに手作業でメタルアーチファクトやベッドを取り除く作業が必要となっている. U-net 機械学習により頭 蓋顔面 CT 画像中のノイズを低減して骨領域を抽出するシステムを構築した. 頭頸部腫瘍患者の CT アーカイブ画像を使用し、 512 x 512 = 262,144 pixel の検証画像 2000 枚において 1 画像辺り平均 14.83 pixel の誤差で予測できた. 自動処理ができるため、 大量データを処理することができる.

OP3-2 入力画像の雑音量調整による深層学習雑音除去法の性能改善

○高橋佳太郎<sup>1</sup>, 植田 貴之<sup>1</sup>, 山登 一輝<sup>1</sup>, 伊藤 聡志<sup>1</sup>
 <sup>1</sup>宇都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム

MR 画像の雑音除去問題では、生体構造の保持と雑音除去性能の双方を高めることが要求される.深層学習の登場により雑音処理能力は高められたが、それでも雑音量が多くなるにつれて雑音除去による生体構造の平滑化の度合いが大きくなる.本研究では、雑音除去処理前にローパスフィルタにより見かけの雑音量を低減した後に雑音除去フィルタを適用し、雑音除去後にハイパスフィルタにより高周波成分を復元する方法の検討を行った.本法では、雑音除去前に雑音量が減じられているので、雑音除去フィルタによる生体構造の損失は大きく低減される.深層学習雑音除去フィルタ(DnCNN)を利用した初期実験の結果、ハイパスフィルタによる雑音の増幅は大きくなく、一方で生体構造の保存程度が顕著に改善される可能性が示された. PSNRとSSIM による定量的評価によっても改善が確認された.

- OP3-3 異常データ検知トモグラフィと深層学習を用いた CT メタルアーティファクト除去のハイブリッド手法
  - ○賈 澤娜<sup>1</sup>, 金 喜正<sup>1</sup>, 藤井 克哉<sup>1</sup>, 滝沢 穂高<sup>1</sup>, 工藤 博幸<sup>1</sup>
     <sup>1</sup>筑波大学システム情報系情報工学域

本研究では、CT分野で重要な未解決問題のメタルアーティファクト除去を取り扱う、CT撮影において被写体に金属が含ま れている場合、フィルタ補正逆投影(FBP)法や通常の逐次近似再構成法では、ビームハードニング・統計雑音・散乱線の影 響により再構成画像に著しいストリークアーティファクトが発生する。近年、歯科にとどまらず人体に金属を埋め込む治療が 多く行われるようになり、この問題の重要性は高まっているが完全な解決策は存在しないのが現状である。本研究では、投影デー タに含まれる異常データを除外して画像再構成を行う巧妙な逐次近似再構成法である異常データ検知トモグラフィー(ABD-CT、 工藤 JAMIT2022, Kudo et al. SPIE, 2016)と深層学習を組み合わせた驚くほど強力なメタルアーティファクト除去手法を提案 する.提案手法では、FBP 法の再構成画像と ABD-CT の再構成画像を 2 入力 1 出力の畳み込みニューラルネットワーク(CNN) に入力して、良い所を組み合わせて画質を改善した再構成画像を出力する原理に基づいている。CNN の訓練は、シミュレーショ ンにより作成した金属あり画像(FBP 再構成画像及び ABD-CT 再構成画像)と金属なし正解画像の組を多数集めた学習データ を用いて、教師あり学習により行う、既に、筆者らのグループは低線量 CT とスパースビュー CT の画像再構成に対して同じ 原理の再構成法を提案しており(JAMIT2020, 工藤、森),提案手法はこの手法をメタルアーティファクト除去の問題に拡張し たものと位置づけられる。歯科用 CT 画像のデータセットを用いたシミュレーション実験を行った結果、提案手法は ABD-CT、 深層学習を単独で用いた場合と比較して、各々の欠点を補い合い高画質の画像を出力することが明らかになった. OP3-4 深層学習による血液エコーの非スペックル成分識別のロバスト性向上

○森 友雅<sup>1</sup>,大村 眞朗<sup>2</sup>,長岡 亮<sup>2</sup>,高 尚策<sup>2</sup>,長谷川英之<sup>2</sup> <sup>1</sup>富山大学大学院 医薬理工学環,<sup>2</sup>富山大学 学術研究部工学系

静脈を対象とした高速超音波イメージングにおいて得られる血液エコーでは、血球からの斑紋状パタン(スペックル成分) に加えて、非スペックル成分がみられることがある、非スペックル成分はスペックル成分とは異なる要因で発生しているもの と想定され、この2つの成分を識別することで血液性状評価が可能になると考えられる、非スペックル成分が高輝度エコー帯 の場合は視認や閾値処理などで識別できるが、血液エコーの輝度変化が不明瞭化した際に識別が困難になると考えられる。こ れまでにエコーシミュレーションデータに対し、深層学習を用いて非スペックル成分の識別を試みている、実計測データ解析 の課題として、ノイズの混在や流れ状態における識別結果のフレーム不連続性が挙げられる。そこで本検討では、学習モデル の改良を検討し、新たに識別結果のノイズロバスト性を確認するとともに、実計測データ解析の安定化を試みた。

OP3-5 高時間分解能を保持した超音波周波数特性解析の広帯域化

○大村 眞朗<sup>1</sup>,長岡 亮<sup>1</sup>,八木 邦公<sup>2</sup>,長谷川英之<sup>1</sup> <sup>1</sup>富山大学 学術研究部工学系,<sup>2</sup>金沢医科大学 医学部

これまでに高速超音波イメージングにおいて,超音波伝搬方向に対する周波数特性(後方散乱係数)を解析することで,低 ずりにおける血しょう中の赤血球凝集・連鎖および高ずりにおけるそれらの解放(赤血球単体)状態の評価可能性を検討して きた.一方,それら状態を指標化する上で,散乱源の大きさを数 µm~10 µmのスケールで高精度に推定するためには超音 波プローブの受信帯域の制約を受ける.本研究では,広帯域プローブの複数周波数励起条件を新たに検討し,広帯域および高 時間分解能・感度を保持したロバストな後方散乱係数解析法の確立を目指す.粒径が既知な均質ファントムの散乱体サイズや 流れ状態の摘出ブタ血液の赤血球サイズ推定を検討し,推定精度の安定性を評価した.

#### 7月28日(金)

## 第1会場(10F佐治敬三メモリアルホール)

## 特別講演1

10:00 ~ 11:00

## SL1「新興再興感染症と COVID-19 これまでとこれから」

#### 座長:木戸 尚治(大阪大学大学院医学系研究科)

SL1 新興再興感染症と COVID-19 これまでとこれから

○忽那 賢志

大阪大学大学院医学系研究科 感染制御学

流行から3年が経ち,mRNAワクチンは感染者・重症者を減らすことに大きく貢献した.また当初は重症患者のみにデキサ メタゾンやトシリズマブなどの治療が行われていたが,徐々に軽症患者の重症化予防のための治療薬が開発されるようになり, 早期診断・早期治療によって予後を改善できることが明らかとなった.

このように、COVID-19に対する診断・治療・予防は大きく進歩した一方で、SARS-CoV-2は変異を繰り返しながら性質を変 え、感染力の増加や免疫逃避といった能力を獲得してきた. 従来の mRNA ワクチンの感染・発症予防効果は大きく低下し、特 にオミクロン株の拡大以降は多くの人が感染した. 2023 年 5 月現在、日本では 4 割の人が過去に COVID-19 に感染したと考え られ、徐々に感染が広がりにくい状況が形成されつつある. 今後は、重症化する人をできる限り減らしながら、流行の規模を 小さく保ちつつ、ゆっくりと既感染者が増えていくことで流行が起こりにくい状況に近づいていくことを目指すことになるが、 全く性質の異なる変異株が出現した場合には感染対策の揺り戻しが起こることも可能性としては想定しつつ、緩和を進めてい く必要がある.

# 第1会場(10F 佐治敬三メモリアルホール)

## 一般演題4

## 11:10~12:10 OP4 [スパースビュー CT・圧縮センシング]

座長:山登 一輝 (宇都宮大学)

庄野 逸(電気通信大学)

 
 OP4-1
 確率的 Dykstra 型スプリッティングによる統一的なブロック反復型画像再構成法の構成: CT と PET への応用

○工藤 博幸<sup>1</sup>, 金 喜正<sup>1</sup>, 藤井 克哉<sup>1</sup>

1 筑波大学システム情報系情報工学域

CTや PET の画像再構成では、対数尤度(最小二乗誤差)+正則化項の凸評価関数を高速に最小化する逐次近似画像再構 成法が必要になる.特に,評価関数を部分評価関数の和に分解して部分評価関数毎に画像更新を行うブロック反復型再構成 法(特別な場合が Row-Action 型再構成法)が有効であることが知られるが.厳密に真の解に収束せず雑音特性が悪いこと が長年問題とされてきた. その解決策として,緩和係数をゼロに近づけながら画像更新を行う手法 (Browne,DePierro,1996, Tanaka,Kudo,2003, Dong,Kudo,2019)がよく用いられるが、厳密な解に収束する証明がなく緩和係数制御に経験的なパラメー タ設定が必要である.また,近年スパースビュー CT や低線量 CT の画像再構成では正則化項に微分不可能な Total Variation などがよく使われ、それに対応する必要があることがこの問題を難しくしている、筆者らは、緩和係数制御が不要なブロック 反復型再構成法として既に DUCOA 法(李, 工藤, 2004), Dykstra 型スプリッティングに基づく Row-Action 型反復法(DLPM) 法)(Kim,Sadakata,Kudo,2022, Sadakata,Kim,Kudo,2022)を構築したが、実用的に上手く動作する一方厳密な収束が保証され る手法とは言えていない、本研究では、これらの問題点を解決する新しいブロック反復型再構成法構築の数学的枠組みとして 「確率的 Dykstra 型スプリッティング」と呼ばれる枠組みを提案して、CTの(複数の)正則化項+最小二乗誤差を最小化する 画像再構成問題, PET の非負制約付き対数尤度+正則化項を最小化する画像再構成問題に適用した. その結果, どちらの場合 も提案手法は非常に上手く動作して高速に収束し、計算時間や実装の容易さは既存の収束が保証されない類似手法と同等であっ た. 確率的 Dykstra 型スプリッティングの収束性を保証するキーは、Dykstra 型スプリッティングに(強凸性がない最適化で 問題の)摂動項の影響を消すトリックを精密に組み込む、データアクセス順序をランダムにする(Tanaka,Kudo,2003)、の二つ である.また、実用的に上手く動作するデータアクセス順序についても検討を行った.更に、提案手法の収束性を数学的に考 察して、厳密な評価関数の最小解に収束することを証明することに成功した、証明は、提案手法が近年最適化分野で注目され ている「確率的主双対座標降下法」の特別な場合になっていることを示すことに基づき行った。最後に、発表では CT と PET の実データへの適用例を紹介する予定である.

OP4-2 深層学習にフラクタル画像を用いたスパースビュー CT 再構成

○川口 廉<sup>1</sup>, 橋本 雄幸<sup>1</sup>
 <sup>1</sup>杏林大学大学院保健学研究科

CT 検査における被ばく低減の手法として投影数を減らすスパースビュー CT がある.しかし,投影数を減らしていくと再構 成画像にストリーク状のアーチファクトが発生する.深層学習を用いたスパースビュー CT の研究では,従来の再構成画像よ りも画質が高くなることが報告されている.また,事前学習にフラクタル画像を用いた深層学習の研究では,画像認識精度が 向上するという報告がある.そこで本研究では,深層学習にフラクタル画像を用いてスパースビュー CT の画質向上が図れる かを検討した.フラクタル画像の生成には,Iterated Function System を用いた.フラクタル画像を事前学習に用いた場合と 用いていない場合での比較を行った結果,フラクタル画像を用いた再構成画像の画質が高くなった.深層学習には多くの実画 像が必要となるが,フラクタル画像を事前学習に用いることで実画像を減らせる可能性が示された. OP4-3 深層学習を用いた角度欠損 CT 画像再構成の敵対的反例とその解決法: 深層学習と逐次近似再構成法のハイブリッド法

○青木 翔吾<sup>1</sup>, 佐藤 悠輝<sup>1</sup>, 岡部 蒼太<sup>1</sup>, 藤井 克哉<sup>1</sup>, 工藤 博幸<sup>1</sup> <sup>1</sup> 筑波大学システム情報系情報工学域

本発表では、問題として重要性が高く歴史がある角度欠損がある投影データからの CT 画像再構成問題を取り扱う.角度欠 損がある投影データの場合には、フィルタ補正逆投影法などの解析的再構成法では著しい画質劣化が発生し、画像と投影デー タの関係式を反復法で解く逐次近似再構成法が有効であることがよく知られるが、未だに投影データが完全な場合と同等の画 像を得ることは困難である.これに対して、近年深層学習を用いた再構成法が有効という研究が精力的に行われている.本発 表は、大きく以下に述べる2つの内容から構成される。一つ目として、角度欠損CTの画像再構成を深層学習単独(FBP法の 再構成画像を教師あり学習で設計した U-Net で画質改善)で行った場合に、顕著な構造物の欠損が発生する幾つかの典型的な 敵対的反例を示す。二つ目として、敵対的反例の画質劣化を改善するため、深層学習と逐次近似再構成法を組み合わせたハイ ブリッド再構成法を提案する.提案手法では、第一ステップで深層学習で画像再構成を行い、その再構成画像を圧縮センシン グに基づく逐次近似再構成法の先験情報として正則化項に組み込み、第二ステップで圧縮センシング再構成法を用いて画像再 構成する原理に基づいている、いわゆる深層学習と逐次近似再構成法のハイブリッド再構成手法の一形態である.逐次近似再 構成法の正則化項としては、通常の圧縮センシングの正則化項であるトータルバリエーション(TV)に加え、再構成画像と深 層学習(CNN)で得られた画像(先験情報)の差のL1ノルムを用い、逐次近似法の初期画像として収束を速めるため深層学 習(CNN)の再構成画像を用いる.評価関数を最小化する逐次近似法としては、筆者らが開発した高速に収束する「Dykstra 型スプリッティング基づく Row-Action 型反復法(DLPM 法)」を用いる.腹部 CT 実画像データセットを用い投影データ測定 角度範囲が 90 度の設定でシミュレーション実験を行った結果,深層学習または逐次近似再構成法を単独で用いた場合にはどち らも画質劣化が著しいのに対して、提案するハイブリッド再構成法では高画質の再構成画像が得られることが明らかになった. 不完全投影データからの画像再構成においては、深層学習と圧縮センシングに基づく逐次近似法を巧妙に組み合わせたハイブ リッド再構成法が有効であることを示す顕著な例になっている.

OP4-4 スパース空間学習を利用した MR 画像の深層学習再構成

○笹谷 晃斗<sup>1</sup>, 大内 翔平<sup>2</sup>, 山登 一輝<sup>1</sup>, 伊藤 聡志<sup>1</sup>

<sup>1</sup>字都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム 伊藤・山登研究室,<sup>2</sup>小山工業高等専 門学校

近年,少数の収集信号から画像の再構成を行う,CS-MRI 再構成に深層学習 (DL) を利用する方法が注目されている.DL 再構成では,画像 - 画像間,信号 - 信号間,信号 - 画像間などの,MRI の特徴を活かした様々な方法がある.

本研究では、多重解像度解析手法の一つである、eFREBAS変換空間において学習を行う DL 再構成について検討を行い、 得られた再構成像の品質と特徴を画像空間学習や信号空間学習と比較した。

その結果,提案法は,画像空間 CNN よりも高品質な画像を得ることができ,より目標画像に近い構造を再生できた場合も あった.さらに,異なる二つの種類の CNN をカスケード状に接続することで,単体のネットワークによる再構成像よりも高品 質な画像を得られた.以上より,eFREBAS 変換空間を深層学習に適用することで,再構成画像の画質改善が期待できることが 示された.

OP4-5 アンサンブル学習による CS-MRI 深層学習再構成の性能改善

○古田 真輝<sup>1</sup>, 山登 一輝<sup>1</sup>, 伊藤 聡志<sup>1</sup>

1字都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム

近年, 圧縮センシング MRI(CS-MRI)の画像再構成に深層学習を利用した研究が注目されている. MRI などの医用画像では, 画像データベースを十分に確保できない場合がある.

本研究では、CS-MRI 深層学習再構成にアンサンブル学習を導入し、再構成性能を向上させる方法について検討を行った. 画像は、通常の MR 画像のほかにフレネル変換と呼ばれる一種のぼかし処理を施した画像を作成し、ぼかしの程度を変えて画 像特徴の異なる複数のデータセットを作成し、それぞれのデータセットで学習を行った. 画像再構成時には、複数のネットワー ク出力の加算平均を行うので、Test Time Augmentation でもある.

画像再構成シミュレーションの結果、単一の深層学習ネットワークよりも高い再構成性能を得ることが確認できた. さらに、 U-Net や ADMM—Net など複数ネットワークのアンサンブル学習により再構成性能が向上する可能性が示された OP4-6 サンプリングパターンの拡張による CS-MRI 深層学習再構成の性能改善

 ○山登 一輝<sup>1</sup>, 渋井 雅希<sup>2</sup>, 伊藤 聡志<sup>2</sup>
 <sup>1</sup>宇都宮大学 工学部 基盤工学科,<sup>2</sup>宇都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム 伊藤・ 山登研究室

MRIの撮像時間短縮のために、サンプリング定理を満たさない少数データから元の情報を復元できる Compressed Sensing (CS)を MRI に応用する CS-MRI が提案されている. CS-MRI は限られた観測信号から MR 画像を再構成でき、信号の収集時間を短縮できるが、CS の最適化アルゴリズムを解く必要があり、その実行時間や再構成性能には限界がある.一方、CS の最適 化アルゴリズムの各種パラメータを再構成対象に対して適切な値に学習できる深層学習手法として、Unrolling-based ネットワークが提案されており、CS-MRI に適用することで再構成像の画質改善や実行時間の短縮されることが報告されている. このような深層学習を利用する CS-MRI は、一般に、単一のサンプリングパターンに基づいて再構成モデルを学習するため、学習パターン以外では再構成性能の低下が避けられない. そこで、複数パターンを学習することで、未学習パターンでも再構成性能を改善できる深層学習再構成法を提案する. 提案法の有効性を実験により確認したところ、未学習パターンでも高い再構成性能を確認した.

## 7月28日(金)

# 第1会場(10F佐治敬三メモリアルホール)

# 特別企画

14:40~16:40 SE [AI ホスピタルプロジェクトの現在]

座長: 富山 憲幸 (大阪大学)木戸 尚治 (大阪大学)

SE1 AI ホスピタルプロジェクト; AI・デジタルで心温まる医療を

○中村 祐輔

国立研究開発法人 医薬基盤・健康・栄養研究所

医療は、医学のみならず、他の多くの研究領域と融合する形で、驚異的な速度で進歩し、高度化、複雑化、先進化、多様化、 そして個別化してきています。まさに、多様なニーズに応じつつ最適化された医療の提供が求められているようになってきて います。世界でも突出した超高齢社会を迎え、医療の需要がますます大きくなることが必至な状況で、医療従事者の負担軽減 を図りつつ、最先端の医療を提供するという大きな課題に直面しています。日本における CT や MRI などによる画像診断や病 理診断も、放射線診断医や臨床病理医の過度な負担で日常の診療体制が維持されています。医療の質の維持・向上には、画像・ 病理診断補助 AI の開発が不可欠ですし、心電図の AI による不整脈の鑑別診断も、専門医と同等のレベルとなっています。内 閣府 AI ホスピタルプロジェクトでは 2021 年 4 月に AI プラットフォーム技術研究組合を立ち上げ、日本医師会に設置された A I ホスピタル推進センターと連携しつつ、利用者側のニーズやコストを含めた使い勝手などを考慮しつつ、同時に利用され る AI の質を確保することを目指しています。

SE2 IT/AI の病院への実装を目指して

○陣崎 雅弘

慶應義塾大学 医学部 放射線科学

2018 年より内閣府の戦略的イノベーション創造プログラムの AI ホスピタルプロジェクトに当院も参加し、患者への安心・ 安全で先進的な医療サービスの提供と医師・医療スタッフの負担軽減を推進し、現時点で可能な AI ホスピタルのモデルを構 築することを目指してきた。

実施するにあたって2つのことに留意した。1つは、AI に興味を持つ一部の人が関わっているという状態ではなく多くの人 が参画しているような組織の構築で、各診療科に AI 担当医を配置し、中枢組織は小さく、裾野の広い組織にした。これにより、 bottom up で課題が上がってくるようになり、課題の共有もできるようになった。2つめは、診療科に限定的な高度なことよ りも、病院全体に共通する単純な課題に重点を置いたことである。この2点を行ったことで、我々の AI ホスピタルプロジェク トは病院全体での取り組みになり、DX に近づいたように思う。 SE3 AI研究に向けた医用画像とアノテーションデータの同時収集

○武田 理宏

大阪大学大学院医学系研究科情報統合医学講座医療情報学,大阪大学医学部附属病院 医療情報部

医療画像を使用した AI 研究には、大量の画像データと良質なアノテーションデータを収集する必要がある.

大阪大学医学部附属病院は連携する医療機関と,大阪臨床研究ネットワーク(OCR ネット)を構築している. OCR ネットでは, 画像収集ゲートウェイを各医療機関に配置し,電子カルテに組み込んだ電子症例報告書で指定した医用画像を前向きに収集す る仕組みと,画像検査リストから対象画像を一括で後ろ向きに収集する仕組みを導入している.

また,我々は,自然言語処理により,画像診断レポートから観察物やその臨床所見を部位やサイズなどの修飾表現を合わせ て情報抽出する機械学習モデルを構築し, OCR ネットの画像診断レポートに適応した.

本仕組みにより, 医用画像を効率的に収集するとともに, 電子症例報告書で収集した臨床情報や画像診断レポートから情報 抽出した部位所見情報をアノテーションデータとして画像 AI 研究を行うことが可能である.

SE4 AIホスピタルプロジェクトの現在

○笠原 群生

国立成育医療研究センター

近年,人工知能(artificial intelligence; AI)が搭載された医療・診断支援のためのプログラムの開発が世界中で行われている. 一方で,成人では使えた AI 診断支援技術等がそのまま小児あるいは妊婦にも適用できるわけではなく,子どもや妊婦に対応で きる小児・周産期医療の現場に合った AI 技術の開発が必要である.成育医療研究センターは受精・妊娠に始まり,胎児期,新 生児期,乳児期,学童期,思春期を経て次世代を育成する成人期へと至るライフサイクルに生じる疾患(成育疾患)に関する 医療(成育医療)と研究を推進している.2018-2022年度には,戦略的イノベーション創造プログラム(SIP)の一つである「AI(人 工知能)ホスピタルによる高度診断・治療システム研究事業」に参画し,小児・周産期医療の観点から,医療現場における AI 技術の必要性と課題を踏まえ,医療 AI 技術の実証研究を進めてきた.本講演では,成育医療研究センターにおける AI ホスピ タルプロジェクトの取り組みを紹介し,AI ホスピタルプロジェクトの現在と今後について概説する.

## 7月28日(金)

# 第1会場(10F佐治敬三メモリアルホール)

## 一般演題5

16:50~17:40 **OP5「予測モデル」** 

座長:目加田慶人(中京大学)花岡 昇平(東京大学)

OP5-1 自己符号化器付 U-net の部分教師あり学習とその胸部 CT 画像における陰影領域抽出への応用

 ○濱田 拓也<sup>1</sup>, 杉水 俊輝<sup>2</sup>, 間普 真吾<sup>1</sup>, 木戸 尚治<sup>3</sup>
 <sup>1</sup>山口大学大学院創成科学研究科,<sup>2</sup>筑波大学大学院理工情報生命学術院,<sup>3</sup>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

医用画像に深層学習を適用する場合、学習に十分な量の完全な教師ラベル付データの確保が難しい. 胸部 CT 画像では、例 えば各画像に存在する代表的な陰影のみアノテーションされているというように、複数の陰影について細かくアノテーション されていることは稀である. したがって、胸部 CT 画像のセグメンテーションタスクを学習するには、陰影ごとに独立したモ デルを作成する必要があり、陰影間の関係性は考慮できなかった. 本研究では、セグメンテーションネットワークの特徴抽出 部を全陰影で共通とし、画像生成部を陰影ごととすることで胸部 CT 画像内の多様な特徴を捉えられるモデルを提案した. また、 学習時にアノテーション領域とセグメンテーション領域を近づける損失関数と遠ざける損失関数を使い分けることで、複数陰 影のセグメンテーションを効率的に学習可能な方式を実現した. 複数陰影が混在する胸部 CT 画像のセグメンテーションタス クにおいて、F 値の向上が確認できた. OP5-2 3次元 CT 画像によるじん肺の重症度別粒状影解析

○新居 蓮叶<sup>1</sup>, 松廣 幹雄<sup>2</sup>, 河田 佳樹<sup>3</sup>, 大塚 義紀<sup>4</sup>, 岸本 卓巳<sup>5</sup>, 芦澤 和人<sup>6</sup>, 仁木 登<sup>7</sup>
<sup>1</sup>徳島大学大学院創成科学研究科,<sup>2</sup>鈴鹿医療科学大学保健衛生学部放射線技術学科,<sup>3</sup>徳島大学大学院社会産業理工学研究部,<sup>4</sup>北海道中央労災病院,<sup>5</sup>岡山ろうさい病院,<sup>6</sup>長崎大学大学院医歯薬学総合研究科,<sup>7</sup>(株)医用科学研究所

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。本研究では、3次元 CT 画像を用いてじん肺 の診断支援システムの開発を目指している。このために、3次元 CT 画像を用いて粒状影を抽出し、粒状影数,発生位置を比較 することで重症度を評価する。炭坑夫肺 33 症例とけい肺 15 症例の CT 画像を用いて、じん肺 CT 画像データベースを作成し、 肺葉分割ラベルの作成、その結果を用いてじん肺の肺葉別粒状影評価を行う。また、各肺葉内の粒状影の分布を評価するために、 パーシステントホモロジーを用いて粒状影の位相的解析を行う。3次元 CT 画像を用いてじん肺の粒状影を抽出し、重症度別・ 肺葉別に個数、大きさ、分布を定量的に解析した。0/1 型と 1/0 型の診断は粒状影数が大きく関わっており、右上葉に粒状影 が多く存在し、各葉の粒状影の数は一様に増加している。位相的解析より、重症度ごとに粒状影の密集度を示し、進行を定量 化した。

## OP5-3 TKI 治療後における肺腫瘍成長の経時変化予測モデル

○古田凜太郎<sup>1</sup>,有村 秀孝<sup>2</sup>,田中謙太郎<sup>3</sup>,加葉田雄太郎<sup>4</sup>,内野 恭美<sup>1</sup>,江頭 舞<sup>1</sup>
 <sup>1</sup>九州大学大学院医学系学府保健学専攻医用量子線科学分野,<sup>2</sup>九州大学大学院医学研究院保健学部門,<sup>3</sup>九州大学病院
 呼吸器科内科学,<sup>4</sup>長崎大学情報データ学部

本研究の目的は、上皮成長因子受容体(EGFR)のチロシンキナーゼ阻害剤(TKI)治療を行う非小細胞肺がん(NSCLC) 患者における腫瘍成長の経時変化予測モデルを構築することである。TKI治療を受けたEGFR 陽性 NSCLC 患者 26 名を選択し、 治療前後のCT 画像における肉眼的腫瘍体積の輪郭を抽出した。各患者の腫瘍細胞数は輪郭抽出を行ったCT 画像から求めた 腫瘍体積に腫瘍細胞密度を乗じることで算出し、参考値として使用した。最後に、TKI に対する腫瘍の増減を表現する微分方 程式モデルを構築し、パラメータを最適化することで腫瘍の経時変化の軌跡を推定した。本研究で構築したモデルは、平均絶 対パーセント誤差(MAPE)とスピアマンの相関係数(SCC)で評価し平均値はそれぞれ7.50%,0.918 であった。先行研究のモデ ルの結果(MAPE:11.1%,SCC:0.913)と比較してより腫瘍の経時変化を表現できる可能性がある。本研究のモデルは、EGFR-TKI を受けている NSCLC 患者に対する治療効果予測法の基礎モデルとなりうると考える。

OP5-4 骨シンチグラムの陽性高集積検出支援システム設計時におけるテストデータ再利用による性能の バイアスとその補正

## ○山中 陽大<sup>1</sup>, 中岡 竜介<sup>2</sup>, 清水 昭伸<sup>1</sup>

1 東京農工大学大学院工学研究院, 2 国立医薬品食品衛生研究所 医療機器部

本報告では、コンピュータ支援診断システムを開発する際に、同一のテストデータの再利用によって生じる性能のバイアス に注目する.まず、前立腺がん患者の骨シンチグラムを用いて、学習データや初期値を変えて、異なる複数個の陽性高集積検 出モデルを学習する.次に、それらの学習済みモデルを同一テストデータに適用し、AUC が最大のモデルを逐次的に選択しな がら複数のモデルを組み合わせたアンサンブルモデルを構築する.本報告では、このアンサンブルモデルの性能を、設計時に 再利用したテストデータと、それとは異なるフレッシュなテストデータを用いて評価し、両者を比較することで、再利用した テストデータによる性能に混入するバイアスを確認する.また、従来の研究を参考にバイアスを低減させる方法を適用した結 果についても確認し、その有効性について考察する.

OP5-5 MRIによる前立腺癌スクリーニングのための要精査領域検出モデルの検討

〇橋本 綾斗<sup>1</sup>, 立花 泰彦<sup>1</sup>, 岸本 理和<sup>1</sup>, 熊切 俊夫<sup>12</sup>, 森 慎一郎<sup>1</sup>, 森 康久仁<sup>3</sup>, 若月 優<sup>1</sup>, 須鎗 弘樹<sup>3</sup>

1国立研究開発法人 量子科学技術研究開発機構, 2千葉大学 大学院融合理工学府, 3千葉大学 大学院工学研究院

背景

MRI による前立腺癌診断を実践的に補助するためには、最終的に癌でなくとも専門医が要精査と考える疑わしい所見を検出 する AI が必要である.そこで、診断医の読影を模し、広域画像とその一部である局所画像を並列に処理し検出を行うニューラ ルネットワークモデルを開発した.本研究では広域と局所を併用する意義について検討する.

方法

226 患者 (347 要精査領域)を対象とした.提案モデルは、A:広域画像をセグメンテーションする Encoder-decoder モデルおよび、B:局所画像とAの出力から要精査か否かを分類する CNN からなる.得られる検出マップの精度を、A+B(提案法)とAのみの場合で、Jaccard 係数を指標として比較した (Wilcoxon 符号付き順位検定、P<.05 を有意).

結果と結論

訓練データと独立したテストデータにおいて、Jaccard 係数は A のみのモデルで 0.52 ± 0.050、提案モデルで 0.60 ± 0.097 で あり、差は有意 (P = 0.0075)、この結果は広域画像と局所画像を併用する意義を支持する.

# 第1会場(10F 佐治敬三メモリアルホール)

# 一般演題6

17:50 ~ 19:00 **OP6 [セグメンテーション]** 

座長:健山 智子(藤田医科大学)

中山 良平(立命館大学)

OP6-1 CNN による頭部 Thick-slice CT 画像からの脳内血腫領域の自動抽出

○永澤  $gl^1$ ,藤田 大輔<sup>1</sup>,渡辺 翔吾<sup>2</sup>,連 乃駿<sup>2</sup>,飯原 弘二<sup>2</sup>,小橋 昌司<sup>12</sup> <sup>1</sup>兵庫県立大学,<sup>2</sup>国立循環器病研究センター

脳血管疾患のうち代表的な脳内血種 (ICH: intracerebral hematoma)は、発症から診断まで迅速な対応が求められる.診断に は頭部CT 画像からの ICH 領域の体積、形状、位置などが有効である.従来の ICH 領域抽出法はセマンティックセグメンテーショ ンに基づき、頭部 CT 画像における脳内の高吸収領域を抽出するため、ICH と脳室内出血 (IVH: intraventricular hemorrhage) の双方を有する症例において精度が低下する問題点がある.本研究では、イメージパッチ識別に基づく新しい ICH 領域抽出法 を提案する.同手法は、ボクセルごとに CNN によるクラス分類により、高吸収領域における ICH と IVH を識別する.提案法 を評価するため、9 例に適用した.交差検証は LOOCV を用いた. CNN は 7 層の original CNN, VGG16, resnet50 を比較した. 実験結果より、VGG16 が最良で、テストデータに対して、Precision 83.0%、Accuracy 72.6%、F 値 81.6% であった.

OP6-2 肺がん定位体放射線治療における3次元計画 CT 画像上の GTV に対する深層学習ネットワーク のセグメンテーション性能への訓練対テスト比の影響

○崔 雲昊<sup>1</sup>,有村 秀孝<sup>2</sup>,吉武 忠正<sup>3</sup>,塩山 善之<sup>4</sup>,藪内 英剛<sup>2</sup>
<sup>1</sup>九州大学大学院医学系学府保健学専攻,<sup>2</sup>九州大学大学院医学研究院保健学部門,<sup>3</sup>九州大学大学院医学研究院臨床放射線科学分野,<sup>4</sup>九州国際重粒子線がん治療センター

To achieve better performances in deep learning approaches, a large number of data would be generally necessary, but it would be very hard to collect enough clinical cases for deep learning, especially SBRT cases. This study aimed to explore the impact of the training-to-test number ratio (TTR) on the segmentation performance of deep learning networks for gross tumor volumes (GTVs) on 3D planning computed tomography (CT) images for lung cancer stereotactic body radiotherapy (SBRT). 192 patients [solid: 118; part-solid: 53; ground-glass opacity (GGO): 21] who underwent SBRT were included in this study. Regions of interest were cropped based on the centroids of GTVs, which were manually extracted by two radiation oncologists with more than six years of experience. TTR was defined as the ratio of the original number of cases in the training and test dataset. 3D U-Net, V-Net, and dense V-Net were trained with five datasets with different TTR 1.00 (training data: validation data: test data=40:20:40), 0.791 (35:20:45), 0.531 (31:10:59), 0.291 (20:10:70), and 0.116 (10:5:85), which were generated from the whole dataset. Three models were compared to each other based on their Dice's similarity coefficients, precisions, and recalls. V-net achieved the highest DSC of 0.788 among the three models with a precision of 0.826 and recall of 0.794 at a TTR of 0.116. The results indicated that the segmentation performance could stay acceptable even though the training and validation data were reduced to 10 and 5%.

OP6-3 深層学習を用いた放射線肺臓炎の領域抽出とその放射線治療計画への応用

○福士 晴哉<sup>1</sup>, 国枝 悦夫<sup>2</sup>, 尾川 浩一<sup>1</sup>

<sup>1</sup>法政大学 理工学部,<sup>2</sup>総合東京病院放射線治療センター

肺がんの放射線治療において,照射の対象となる腫瘍部位よりも広がって放射線肺臓炎が発生する場合がある.現在,放射線 肺臓炎の評価は肉眼的な CT 所見,症状などによっているが主観的な要素が強く,より客観的な評価が望まれる.本研究は放射 線治療計画と放射線肺臓炎の発生範囲の関係性を調べ,放射線肺臓炎の正確な評価を目的としている.本研究では放射線肺臓 炎の発生部位を深層学習によって抽出した.この際,まず肺野領域を抽出し,その後肺臓炎部の抽出を行った.肺臓炎部の抽 出では放射線肺臓炎の症例が少ないため,類似の症状となる新型コロナウィルス罹患患者の X 線 CT 画像を利用した.この領 域と線量計画時の投与線量との相関を調べたところ有意な相関があることが明らかとなった. OP6-4 心機能評価のための心臓 CT のセマンティック・セグメンテーション手法に関する研究

○佐々木諒介<sup>12</sup>, 黒瀬 優介<sup>12</sup>, 原田 達也<sup>12</sup>
 <sup>1</sup>東京大学大学院,<sup>2</sup>理化学研究所

心機能診断のために CT 画像を用いて可視化する手法は一般に用いられるようになり,特に心臓の拍動を連続的に撮像でき る CT も広く使われるようになった.心機能の評価においては,拍出により送り出される血液量の推定が重要な指標として用 いられており,そのために右心室や左心室といった心臓内の各器官の動作を正確に追跡することが重要となる.現状でも推定 可能なソフトウェアは存在するが,医師がマニュアルで結果を修正する必要があり,労力を要する.そこで本研究では,撮影 した CT 画像から心機能評価を自動で行うために,セマンティック・セグメンテーションによる心臓の各部位の推定結果を用 いて,心機能の指標を推定する手法を提案する.提案手法の有効性を評価するために,CT 画像データセットを提案手法に適用 して評価を行った.

OP6-5 乳房超高速造影 MRI 画像における U-Net を用いた腫瘍血管抽出に関する検討

〇橋本 陽菜<sup>1</sup>, 片岡 正子<sup>2</sup>, 藤本 晃司<sup>23</sup>, 飯間 麻美<sup>24</sup>, 高田 正泰<sup>5</sup>, 戸井 雅和<sup>6</sup>, 川瀬 貫互<sup>7</sup>, 大橋  $\overline{\text{tb}}^{8}$ , 本田 茉也<sup>29</sup>, 中本 裕士<sup>2</sup>

<sup>1</sup>京都大学大学院 医学研究科 人間健康科学系専攻,<sup>2</sup>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),<sup>3</sup>京都大学大学院 医学研究科 高度医用画像学講座,<sup>4</sup>京都大学医学部附属病院 先端医療研究開発機構,<sup>5</sup>京 都大学大学院 医学研究科 外科学講座 乳腺外科学,<sup>6</sup>がん・感染症センター都立駒込病院 乳腺外科,<sup>7</sup>天理よろづ 相談所病院 放射線診断科,<sup>8</sup>ルンド大学医学部付属病院 放射線診断科,<sup>9</sup>関西電力病院 放射線診断科

腫瘍血管は腫瘍増殖との関連が注目されるが未だ定量化する指標が定まっていない.本研究では定量化の前段階として,乳 腺腫瘍と同時に周囲の腫瘍血管まで描出可能な Ultrafast Dynamic Contrast-Enhanced (UF-DCE) MRI 画像を用いて腫瘍血管の 自動抽出手法を検討した.対象は京都大学病院にて乳癌疑いで UF-DCE MRI を受けた 106 症例. 20 相の連続画像から血管が 描出され始める 7 相目以降を使用した. UF-DCE MRI 画像から MIP 画像を作成し,腫瘍周囲を 128 × 128pixel (12 × 12cm) でトリミング,放射線科医の監督下に血管部分を領域抽出したものを教師画像として U-Net モデルを学習させた. 5-fold 交差 検証にて Dice 係数平均値は 0.820 となり明瞭な血管は過不足なく抽出されたことから,提案手法が腫瘍血管の自動抽出に有用 であることが示唆された.

OP6-6 血管強調画像を用いた腹部 CT 像からの多臓器領域抽出

 ○大野 真奈<sup>1</sup>, 申 忱<sup>1</sup>, RothHolger R<sup>2</sup>, 小田 昌宏<sup>31</sup>, 林 雄一郎<sup>1</sup>, 三澤 一成<sup>4</sup>, 森 健策<sup>15</sup>
 <sup>1</sup>名古屋大学大学院情報学研究科, <sup>2</sup>NVIDIA Corporation, <sup>3</sup>名古屋大学情報連携推進本部情報戦略室, <sup>4</sup>愛知がんセン ター, <sup>5</sup>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、血管強調画像を用いた Fully Convolutional Network (FCN) による3次元腹部CT 像からの多臓器領域抽出手法 について述べる.近年、コンピュータによる診断・手術支援システムに関する研究が多く進められている.多臓器領域抽出は これらのシステムの開発のための重要な要素技術であり、高精度な臓器領域抽出手法の開発が必要とされている.

従来の多臓器領域抽出手法では、腎臓や肝臓、脾臓などの形状が単純な臓器については高精度の抽出が可能である一方、血管や膵臓などの形状が複雑な臓器は抽出が難しい.そこで提案手法では特に血管領域の抽出に注目し、CT 像に管状構造を強調するフィルタを適用した血管強調画像を FCN の学習に利用し、多臓器領域抽出を行った.284 症例の CT 像を用いて実験した結果、全臓器の平均 Dice は 87.89% であった.

OP6-7 多時相造影 CT 画像データベースの腎臓・腎腫瘍の抽出

 ○西岡 大<sup>1</sup>, 越野 魁都<sup>1</sup>, 河田 佳樹<sup>2</sup>, 小針 悠希<sup>3</sup>, 池田 篤史<sup>4</sup>, 仁木 登<sup>5</sup>
 <sup>1</sup>徳島大学大学院創成科学研究科理工学専攻, <sup>2</sup>徳島大学ポスト LED フォトニクス研究所, <sup>3</sup>東京女子医科大学, <sup>4</sup>筑波 大学医学医療系, <sup>5</sup>株式会社医用科学研究所

多時相3次元造影CT 画像から腎臓・腎腫瘍を精密に解析して悪性・良性腫瘍の高精度な鑑別法を開発し、このために、腎 臓・腎腫瘍の200症例の多時相造影CT 画像データベースを構築する.この多時相腹部造影CT 画像データベースを用いて腎 臓と腎腫瘍5種類(淡明細胞型腎細胞がん、乳頭状腎細胞がん、嫌色素性腎細胞がん、血管筋脂肪腫、オンコサイトーマ)を 3D U-Net を用いて高速・高精度に抽出し動脈相・門脈相・平衡相画像をレジストレーション・クラスタリングして関連付ける. 小径の腎腫瘍の循環動態を解析して高精度な小径の腎腫瘍の鑑別法を示す.

# 第2会場(7F セミナー室7C+D)

# 一般演題7

11:10~12:10 **OP7「データ拡張」** 

#### 座長: 根本 充貴(近畿大学)

伊東 隼人 (名古屋大学)

OP7-1 Stable Diffusion による乳がん腫瘤の人工症例画像生成と良悪性鑑別への応用

○安倍 和弥<sup>1</sup>, 武尾 英哉<sup>1</sup>, 縄野 繁<sup>2</sup> <sup>1</sup>神奈川工科大学, <sup>2</sup>新松戸中央総合病院

現在, 医療の様々な分野において AI 技術を用いた画像支援診断(CAD: Computer Aided Diagnosis)の研究・開発が行われている.

AIによる CAD 開発における症例画像の不足を補うことを目的に、人工的に症例画像を作成する取り組みが以前から行われている.過去に筆者らも、人工症例を含む学習データを用いて設計した判別器による検証から、CADへの有用性の一例を示した.

しかし,従来の人工症例画像は病変の存在しない画像に腫瘤等の病変を埋め込むことにより作成を行うもので,本質的には 症例数が増加しているとはいいがたい.

本研究では、Stable Diffusion 技術を用いた画像生成 AI により、乳がん腫瘤の人工症例画像の生成を行う.また、生成した 画像を用いて機械学習を行い、AI による人工症例画像の CAD への有効性検証を行う.腫瘤画像を良性・悪性に分けて画像生 成を行い、良悪性鑑別 CAD へと適応して有効性を確認する.

OP7-2 3D/2D U-Net を用いた CT 画像からの副腎領域の抽出に関する基礎的検討

○平岡 大季<sup>1</sup>, 西本絋嗣郎<sup>2</sup>, 滝沢 穂高<sup>3</sup>, 工藤 博幸<sup>3</sup> <sup>1</sup> 筑波大学大学院情報理工学位プログラム,<sup>2</sup>埼玉医科大学国際医療センター,<sup>3</sup> 筑波大学システム情報系

本研究では、腹部 CT 画像に 2D, 3D U-Net を適用して副腎領域を抽出した場合の精度の比較を行った.本報告では次の 4 つの実験を実施した.1 つ目の実験では、原画像を U-Net に入力した.2 つ目は、アフィン変換でデータ拡張を行い、U-Net に入力した.3 つ目は、輝度を正規化した画像を U-Net に入力した.4 つ目は、データ拡張と輝度の正規化をおこなった画像を U-Net に入力した.これらの 4 つの実験を 49 症例の画像データセットに適用し、精度の比較を行う.

OP7-3 クロス擬似ラベルに基づく腸のセグメンテーション

<sup>1</sup>名古屋大学大学院情報学研究科,<sup>2</sup>静岡県立大学経営情報学部,<sup>3</sup>愛知工業大学情報科学部,<sup>4</sup>名古屋大学大学院医学 系研究科,<sup>5</sup>愛知医科大学医学部放射線科,<sup>6</sup>名古屋大学情報連携推進本部情報戦略室,<sup>7</sup>名古屋大学情報基盤センター, <sup>8</sup>国立情報学研究所医療ビッグデータ研究センター

In this paper, we propose an improved semi-supervised method for intestine segmentation (intestine including small and large intestines) based on Cross Pseudo Supervision (CPS), which can create the pseudo labels for unlabeled data to utilize them for training. The method can enlarge the number of data set to improve the insufficient data problem in medical image segmentation. We train two same 3D U-Net networks with different initial weights simultaneously. Specifically, the prediction from the first network is used as a pseudo label. The first network supervises the second network with the cross-entropy loss and vice versa. In the experiment, we used 2980 CT patches from 20 CT volumes labeled by clinicians for training. Sparsely labeled 5 CT volumes from different patients were used for testing. Experimental results showed that the Dice score of the CPS method was 0.726, the precision was 0.790, and the recall was 0.671. Compared with using only one 3D U-Net, our method improved the average Dice score by 0.141, the average precision by 0.104, and the average recall by 0.151. The method produced competitive segmentation performance compared to the previous methods.

OP7-4 肺マイクロ CT 像中の小葉間隔壁抽出のための教師データ生成に関する検討

 ○深井 大輔<sup>1</sup>,小田 紘久<sup>2</sup>,林 雄一郎<sup>1</sup>,鄭 通<sup>1</sup>,中村 彰太<sup>3</sup>,小田 昌宏<sup>41</sup>,森 健策<sup>15.6</sup>
 <sup>1</sup>名古屋大学大学院情報学研究科,<sup>2</sup>静岡県立大学経営情報学部,<sup>3</sup>名古屋大学大学院医学系研究科,<sup>4</sup>名古屋大学情報 連携推進本部情報戦略室,<sup>5</sup>名古屋大学情報基盤センター,<sup>6</sup>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、肺マイクロ CT 像における小葉間隔壁抽出のための教師データ作成について述べる.近年、マイクロ CT とよば れる高解像度 CT 装置により、肺の微細構造を撮像可能となった.肺マイクロ CT 画像による三次元的な肺微細構造解析から、 病態や生体機能のさらなる解明が期待される.肺微細構造の一つである小葉間隔壁の構造を明らかにするため、我々はマイク ロ CT 像からの小葉間隔壁の構造抽出を目指す.マイクロ CT 像における小葉間隔壁のアノテーションは難しく、教師データ 作成は負担が大きい.本稿では、教師データ生成の負担削減のため、少数スライスの情報を用いたラベル拡張手法を検討する. ラベル拡張手法では、少数の二次元断面に対するラベルから、面状構造強調画像を利用して三次元画像全体にラベルを拡張する. 生成された教師データから5枚の断面をランダムに取り出して評価したところ、平均の Dice 係数 0.75 でラベル拡張されている ことが確認できた.

#### OP7-5 腹部 CT 画像からの複数臓器抽出における CutMix の有用性の検討

〇中山 晃平<sup>1</sup>, 大野 真奈<sup>1</sup>, 申  $t^1$ , 小田 昌宏<sup>12</sup>, 林 雄一郎<sup>1</sup>, 三澤 一成<sup>3</sup>, Ben Glocker<sup>6</sup>, Daniel Rueckert<sup>67</sup>, 森 健策<sup>14,5</sup>

<sup>1</sup>名古屋大学大学院情報学研究科,<sup>2</sup>名古屋大学情報連携推進本部情報戦略室,<sup>3</sup>愛知県がんセンター,<sup>4</sup>国立情報学 研究所医療ビッグデータ研究センター,<sup>5</sup>名古屋大学情報基盤センター,<sup>6</sup>Imperial College London,<sup>7</sup>Technical University of Munich

本稿では、深層学習を用いた腹部 CT 画像からの複数臓器抽出において、データ拡張手法の1つである CutMix の有用性について検討した結果を述べる.腹部 CT 画像からの複数臓器抽出は、医師の画像診断を支援するシステム開発において重要な技術である.複数臓器抽出手法の中で、深層学習を用いたものが注目されている.深層学習ではデータ数の確保が重要であるが、特に医用画像では十分なデータ数を得られない場合が多い.本研究では、V-Net を学習モデルとして用いた腹部 CT 画像からの複数臓器抽出について、元の訓練データと CutMix を用いて拡張した訓練データを用い、血管を含む 9つの臓器の領域抽出の学習 を行い、テストデータに対する抽出精度を比較した.CutMix を用いた場合の抽出結果は、CutMix を用いなかった場合と比較して、訓練データが少数の場合に多くの臓器で精度の向上が見られたが、訓練データが増加するにつれて血管などの複雑な構造に 関しては精度の低下が見られた.

OP7-6 Alpha-blending によるデータ拡張と敵対的学習を用いた DeepLab v3 による歯種セマンティック セグメンテーション

○渋谷 恒介<sup>1</sup>, 中山 良平<sup>1</sup>, 檜作 彰良<sup>1</sup>, 村田 乾<sup>2</sup>
<sup>1</sup>立命館大学理工学部.<sup>2</sup>タカラテレシステムズ株式会社

本研究の目的は、DeepLab v3を用いた歯科パノラマX線画像における各歯種のセマンティックセグメンテーション法を 開発することである.実験試料は、歯科パノラマX線画像129枚である.提案手法では、まず、Alpha-blendingを用いた データ拡張により、各歯領域のテクスチャ情報だけでなく形状情報にも着目した DeepLab v3の事前学習を実施する.次に、 DeepLab v3 による予測ラベル画像と正解ラベル画像を用いた敵対的学習により、DeepLab v3 を fine-tuning する.提案手法に よる Jaccard index, Dice index は 0.722, 0.804 で, Alpha-blending を用いたデータ拡張のみ適用した DeepLab v3 (0.671, 0.764)、 敵対的学習のみ適用した DeepLab v3 (0.705, 0.791)、データ拡張と敵対的学習を適用しなかった DeepLab v3 (0.643, 0.742) より高い結果が得られ、その有用性が示唆された.

# 第2会場(7F セミナー室 7C+D)

# -般演題8

OP8「病理画像  $16:50 \sim 17:40$ 

## 座長:本谷 秀堅(名古屋工業大学) 間普 真吾(山口大学)

#### 呼吸器内視鏡迅速細胞診における AI 診断支援 OP8-1

○尾見 康夫<sup>1</sup>,桐田 圭輔<sup>23</sup>,香川 洋輔<sup>2</sup>,高橋 真理<sup>4</sup>,後藤 功一<sup>2</sup> <sup>1</sup>NEC 医療機器ソフトウェア統括部.<sup>2</sup>国立がん研究センター東病院 呼吸器内科.<sup>3</sup>上尾中央総合病院 呼吸器内科.<sup>4</sup> 国立がん研究センター東病院 トランスレーショナルリサーチ検体管理室,内視鏡センター

Rapid on-site cytologic evaluation (ROSE) for samples taken during endobronchial ultrasound guided transbronchial needle aspiration (EBUS-TBNA) is effective to improve the diagnostic yield and to avoid repeated puncture procedures. However, ROSE is not widely used due to limited human resources, especially limited availability of staff who performs benign and malignant classification. Thus, we developed an artificial intelligence system to assist in ROSE diagnoses. We had used inhouse whole slide imaging (WSI) for training and testing. The sensitivity/specificity by a conventional 2-class classification model was found to be 0.90/0.83. In ROSE, false positive should be minimized as much as possible to prevent a repeat bronchoscopy, which are an additional invasive procedure for patients. To improve specificity while maintaining sensitivity, we introduced a method consisting of several subclass classification for each cell types followed by global classification. Specificity was improved by the method from 0.83 to 0.90 while maintaining sensitivity=0.90. We also developed an image normalization method to reduce the difference in image characteristics between WSI and microscope imaging to adapt the model trained with WSI to microscope imaging. The model without the normalization method only showed an accuracy of 0.83, while that with normalization method achieved an accuracy of 0.92 for microscope imaging. To improve model's performance furthermore, we introduced a pretraining using contrastive learning considering difference of image characteristics among cells that same global class but different subclasses. The model with the pretraining provided 3% better specificity while maintaining sensitivity=0.90 than that of the model without the pretraining.

OP8-2 階層的クラス構造のためのマルチモーダル分類

○橋本 典明<sup>1</sup>, 花田 博幸<sup>1</sup>, 三好 寛明<sup>2</sup>, 永石 美晴<sup>2</sup>, 佐藤 健作<sup>2</sup>, 大島 孝一<sup>2</sup>, 本谷 秀堅<sup>3</sup>, 竹 内 一郎 1.4

1理化学研究所,2久留米大学,3名古屋工業大学,4名古屋大学

本研究ではリンパ腫病理画像データを対象とし、フローサイトメトリー (FCM) を補助情報とするマルチモーダル分類手法を 開発する.リンパ腫は複数のサブタイプからなるグループを構成する階層的なクラス構造を有しており.病理診断の際 FCM はグループの分類に有用な情報とされている.提案手法では whole slide image を扱うためのマルチインスタンス学習とクラス 構造を既知とした mixture-of-experts の枠組みを組み合わせることで各データを効果的に利用した特徴集約メカニズムを実現 し、病理医の意思決定プロセスを模倣した分類モデルを構築する.臨床実データを用いたクラス分類実験および2種類の重み の可視化による判断根拠の提示により、提案手法の有効性を確認する.

Contrastive Learning を用いた甲状腺組織画像の識別と学習に有用なデータ拡張の検討 OP8-3

○ 奥住 航大<sup>1</sup>, 間普 真吾<sup>1</sup>, 八田 聡美<sup>23</sup>, 稲井 邦博<sup>2</sup>, 樋口 翔平<sup>24</sup>, 木戸 尚治<sup>5</sup>

1山口大学大学院創成科学研究科,2福井大学医学部病因病態医学講座分子病理学,3福井大学医学部附属病院病理診断 科/病理部, 4 福井県立病院病理診断科, 5 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

本研究では、深層学習を用いて HE 染色が行われた甲状腺組織画像における癌の種類(組織型)を識別することを目的とし ているが、染色を行う施設の染色液組成や、標本作成における様々な過程によって特徴(色調)が異なり、単純な色調の違い でも識別に悪影響を与えることがある.このような染色条件による特徴の違いによらず、癌を識別するための本質的な特徴を 捉えることが重要であり、本研究では、Contrastive Learningを適用した場合の効果について検証した。具体的には、識別問 題で一般に用いられる Cross-Entropy Loss と教師あり学習型 Contrastive Learning である Supervised Contrastive Learning を甲状腺組織画像の識別タスクに適用し、単一のドメイン画像を使用した場合や、複数の異なるドメイン画像を使用した場合、 学習データとテストデータのドメインが異なる場合において、Contrastive Learning の有用性を検証した. また、Contrastive Learning で必要になるデータ拡張において、様々な拡張法を適用しそれらの有用性を検証した.

OP8-4 CEA 術後病理画像を用いた異常検知による循環器病発症予測

〇石田 修也<sup>1</sup>, 盛田 健人<sup>12</sup>, 蓮 乃駿<sup>2</sup>, 渡辺 翔吾<sup>2</sup>, 小橋 昌司<sup>23</sup>, 畠山 金太<sup>2</sup>, 飯原 弘二<sup>2</sup>, 若林 哲史<sup>1</sup>

<sup>1</sup>三重大学大学院 工学研究科,<sup>2</sup>国立循環器病研究センター,<sup>3</sup>兵庫県立大学大学院 工学研究科

頸動脈狭窄の治療法の1つとして、頸動脈内膜剥離術(carotid endarterectomy: CEA)が行われてきた.CEA により脳梗 塞の発症リスクを軽減できるとされているが、術後に長期経過した患者がどのような合併症を起こすかは明らかになっていな い.近年の AI 技術の発展により、がん腫瘍の病理画像から患者の長期予後を予測できることが示されている.CEA により取 得された頸動脈プラーク病理画像と将来の循環器病の発症の有無を検討した研究はほとんどないことから、本研究では頸動脈 プラーク病理画像を形態的に分類・解析し、プラーク内の組織の状態によって長期予後の予測を目指す.本文では f-AnoGAN を用いた異常検知により CEA 患者の術後1年以内の循環器病の発生の有無を予測した.結果として、ROC-AUC は DWI に対 して 0.79、心筋梗塞に対して 0.67、脳梗塞に対しては 0.68 となった.また、異常度を可視化したヒートマップは病理医の知見 とも一致し、循環器病の発生と関連する病理学的特徴との関連が示唆された.

# OP8-5 高解像度 H&E 染色全スライド画像におけるカラーアンミキシングのための自動 ROI 選択 〇ヨウキナン<sup>1</sup>,武山 彩織<sup>1</sup>,山口 雅浩<sup>1</sup> <sup>1</sup>東京工業大学

In the adaption of computer-aided diagnosis algorithms to digital pathology, whole slide images (WSIs) from different sources and staining processes cause color variations that affect the accuracy. Researchers developed many blind color deconvolution (BCD) methods for consistent color appearance. However, the selection method of regions of interest (ROIs) for BCD has not been investigated until now. In this paper, we develop a method for automatic ROI selection from a WSI. Based on the color unmixing results of each WSI tile (40x), we designed an evaluation function based on prior knowledge to generate a score label for each tile, indicating its suitability for the entire WSI color unmixing. The function scores tiles in terms of color unmixing results and optical density space distribution when the stain matrix obtained by the unmixing is applied to other tiles. Based on the score for each tile, it is possible to automatically select ROIs suitable for WSI color unmixing. We applied the proposed method to the WSIs of H&E-stained tissue and found that it can obtain a more accurate result of all the tiles from the color unmixing results of the selected ROI.

## 7月28日(金)

第2会場(7F セミナー室7C+D)

# 一般演題9

17:50 ~ 19:00 **OP9「イメ**ージング」

座長:伊藤 聡志(宇都宮大学) 小尾 高史(東京工業大学)

OP9-1 高空間分解能位相コントラスト CT を得るための X 線回折波 2 重撮影法の開発

〇砂口 尚輝<sup>1</sup>, 湯浅 哲也<sup>2</sup>, 島雄 大介<sup>3</sup>, 黄 卓然<sup>1</sup>, 市原 周<sup>4</sup>, 西村理恵子<sup>4</sup>, 岩越 朱里<sup>4</sup>, GuptaRajiv<sup>5</sup>, 安藤 正海<sup>6</sup>

<sup>1</sup>名古屋大学,<sup>2</sup>山形大学,<sup>3</sup>大阪物療大学,<sup>4</sup>名古屋医療センター,<sup>5</sup>マサチューセッツ総合病院,<sup>6</sup>高エネルギー加速 器研究機構

高輝度な放射光 X 線を用いる位相コントラスト CT は生体軟組織を高コントラストに撮像できるため、様々な生体試料に おける微小解剖構造の可視化に利用されてきた.しかし、これまでに提案されている位相コントラスト CT の撮像方式は、原 理的に被写体と X 線カメラの間に一定の空間を必要とするため、被写体と X 線カメラの距離を接近させて見かけ上の焦点サ イズを小さくすることできず、高空間分解能化が困難であった.本研究では、位相コントラストを生成する Laue 型 Si 角度ア ナライザーと X 線を可視光に変換するシンチレータを密着させて位相コントラスト像を得る X 線回折波 2 重撮影法 (SWIDeX: Superimposed wavefront imaging of diffraction-enhanced x-rays)を提案した.この方式により、被写体と X 線カメラの間の空 間が不要になり、従来法と比べて高い空間分解能が得られた. OP9-2 U-Net に逆投影演算を組み込んだ直接 PET 画像再構成法の提案

○橋本二三生<sup>1</sup>,大手 希望<sup>1</sup>,大西 佑弥<sup>1</sup>
<sup>1</sup>浜松ホトニクス株式会社中央研究所

計測データから深層学習技術を利用して直接断層像を生成する技術が,新しい画像再構成法として注目されている.これらの出力断層像は,一見すると正確な断層像が取得できているようにみえるが,空間的な対応関係がないサイノグラムから断層 像への逆変換を,データ駆動で正確に獲得することは難しく,テストデータでは偽像が発生することがある.そこで本研究では, サイノグラムから断層像への逆投影を,U-Netのスキップ接続中に明示的に記述することで,偽像がない高品質な断層像が出 力できる直接画像再構成法を提案する.提案手法は,サイノグラム空間で表現されるエンコーダ部の特徴量を,スキップ接続 内の逆投影演算によって断層像空間で表現されるデコーダ部に接続することができ,入力サイノグラムからの正確な空間情報 が保持できる.数値実験の結果,提案手法は従来の直接画像再構成法と比べ,偽像の発生がなく高品質な断層像が取得できる ことがわかった.

OP9-3 3検出器 SPECT 装置の新たなステップ間隔によるデータ収集法の提案

○皆川 智哉<sup>12</sup>, 堀 拳輔<sup>34</sup>, 橋本 雄幸<sup>2</sup>

<sup>1</sup> 東邦大学医療センター大橋病院放射線部,<sup>2</sup> 杏林大学大学院保健学研究科,<sup>3</sup> 順天堂大学保健医療学部,<sup>4</sup> 東京医科歯 科大学大学院医歯学総合研究科

SPECT 検査において十分な信号を得るために長時間撮像すると、患者の体動によるモーションアーチファクトを生じる可能 性が高くなる.3検出器 SPECT 装置の先行研究において、3つの検出器を不等間隔に配置する off-set 収集により効率的に投影 データを収集し、等間隔に配置した on-set 収集より少ない投影数で再構成できることを示した.しかし、検出器の動作間隔(ス テップ間隔)について詳細な検討は行っていなかった.そこで本研究では、3検出器 SPECT 装置においてステップ間隔を変え ることで検出器を等間隔に配置した上で効率よくデータを収集する新たな方法を提案する.モンテカルロシミュレーションに より取得した投影データを用いて異なるステップ間隔による再構成画像の比較を行った.その結果、新たに提案するデータ収 集法における再構成画像の精度が最も良く、SPECT 検査において更に投影数を減らせる可能性が示された.

OP9-4 モデルベース型深層学習画像再構成による MR 定量値マッピングの高速化の検討

○藤田 直人<sup>1</sup>, 横沢 俊<sup>2</sup>, 白猪 亨<sup>2</sup>, 寺田 康彦<sup>1</sup>
 <sup>1</sup>筑波大学 数理物質系 物理工学域,<sup>2</sup>富士フイルム株式会社 メディカルシステム開発センター

組織や病変によって異なる定量値画像を得る定量的 MRI は、多くの研究により診断に有用であると報告されている.しかし、 定量的 MRI を行うには、複数の MR 画像が必要であるため、撮像に非常に時間がかかるという課題がある.一方、深層学習(deep learning, DL)を用いた MRI 撮像の高速化の研究が近年盛んである.中でも、既存の画像最構成モデルを DL で拡張したモデ ルベース型のネットワークモデルが、高い画像再構成性能をもつことが報告されている.そこで本研究では、モデルベース型 DL モデルである DC-CNN を、定量的 MRI に拡張した qDC-CNN を提案する.qDC-CNN は、定量値画像を直接出力するモデ ルであり、その損失項として、定量値画像から推定される rawdata と、測定された rawdata との整合性を評価する項を追加し たものである.結果、qDC-CNN は既存の DL モデルや非 DL 法と比較してかなり高い加速率下でも高い再構成性能を維持する ことが確認された.本研究により定量的 MRI の更なる高速化の可能性が示された.

OP9-5 数値シミュレーションによる腹壁運動を伴う MR エラストグラフィにおける誤差低減法の検討

<sup>1</sup>千葉大学 融合理工学府 医工学コース,<sup>2</sup>富士フイルムヘルスケア株式会社,<sup>3</sup>千葉大学 フロンティア医工学セン ター

MRエラストグラフィ(MRE)は、組織の粘弾性率を定量的に測定できる.しかし、腹壁運動により体動アーチファクトが 発生すると誤差が生じる.本研究では,腹壁運動を伴うMREにおいて粘弾性率に生じる誤差とその低減法を数値シミュレーショ ンで明らかにする.腹部数値モデルは、腹壁変位を想定して上部が伸縮する楕円とし、楕円の伸縮はヒト腹部で測定した呼吸 動を用いた.MRデータ収集の位相エンコードステップごとに体動を加味した腹部モデルをフーリエ変換し、k空間上に1行ず つ充填した後、正規分布ノイズを加えてから逆フーリエ変換することで体動アーチファクトを含む弾性波画像を再現した.周 期や位相が異なる腹壁変位は6種類利用した.位相エンコードステップごとの腹壁変位が呼気末期と吸気末期に集中している ほど、誤差が小さくなった.この結果より、撮像中の呼吸位相の分布に注目することで誤差を低減できることが示唆された. OP9-6 3 周波数同時加振 MR エラストグラフィにおける最適撮像条件の検討

○高崎 晴也<sup>1</sup>, 菅 幹生<sup>12</sup>, 岸本 理和<sup>3</sup>, 小畠 隆行<sup>3</sup>
 <sup>1</sup>千葉大学 融合理工学府 医工学コース、<sup>2</sup>千葉大学 フロンティア医工学センター、<sup>3</sup>量子科学技術研究開発機構

複数周波数同時加振 MR エラストグラフィ (MRE) では、複数周波数の合成波により撮像対象を加振することで、通常の MRE と比べて短時間でデータ取得が可能となる.しかし、取得データから周波数ごとの粘弾性率を高精度に推定するための撮 像条件は明らかになっていない.本研究では、3 周波数同時加振 MRE における弾性波画像分離や弾性率分布推定の精度向上の ために、撮像条件のうち、加振の初期位相や加振周波数、変位を位相シフトに変換する変位エンコード傾斜磁場 (MEG)の周 波数について適切な値を数値シミュレーションにより求めることを目的とした.弾性波画像分離精度は、加振の初期位相には 依存せず、80 Hz を含む4 種類の加振周波数からの3 周波数の組み合わせで精度が良いのは40,60,90 Hz であった.加振周波 数 40,60,90 Hz に対して、弾性率推定精度が高く周期が短い MEG 周波数は 33 Hz であった.

OP9-7 Deep Image Prior を用いた蛍光 X 線 CT 画像再構成

○對馬 結太<sup>1</sup>, 松岡 将宏<sup>2</sup>, 佐藤 和樹<sup>1</sup>, 草刈 颯太<sup>3</sup>, 笹谷 典太<sup>2</sup>, 砂口 尚樹<sup>4</sup>, 河嶋 秀和<sup>5</sup>, 兵 藤 一行<sup>6</sup>, 湯浅 哲也<sup>2</sup>, 銭谷 勉<sup>1</sup>

<sup>1</sup> 弘前大学大学院理工学研究科,<sup>2</sup>山形大学大学院理工学研究科,<sup>3</sup> 弘前大学理工学部,<sup>4</sup> 名古屋大学大学院医学系研究科, <sup>5</sup> 京都薬科大学放射性同位元素研究センター,<sup>6</sup> 高エネルギー加速器研究機構物質構造科学研究所

我々のグループでは、前臨床研究での利用を目指して、非放射性ヨウ素標識化合物を用いて小動物の生体機能画像の取得を 可能とするマルチピンホール蛍光 X 線 CT システムを開発しているが、実用化には画質改善や検出限界の向上が必要となる、 本研究では深層学習を取り入れた画像復元手法である Deep Image Prior (DIP)を蛍光 X 線 CT 画像再構成に応用し、画質改 善および検出限界の向上を試みた. 散乱線補正後に、DIP 処理を行いノイズ低減させた蛍光 X 線投影画像をマルチピンホール 蛍光 X 線 CT 用 OS-EM で画像再構成した. 励起光として放射光単色 X 線を利用して物理ファントム実験を行った結果、再構 成画像のコントラストノイズ比は濃度 0.3 mg/ml のヨウ素領域にて 4.6 倍に大きく改善し、検出限界は 0.069 mg/ml から 0.035 mg/ml へと向上した. 空間分解能は 0.56 mm から 0.72 mm にわずかに劣化したが、画質と検出限界を大きく向上させること ができた.

## 7月28日(金)

# 第3会場(7F セミナー室7A)

# 一般演題10

11:10 ~ 12:10

座長:北村 圭司(株式会社 島津製作所) 山谷 泰賀(量子科学技術研究開発機構)

OP10-1 3次元類似性駆動型メディアン正則化を用いたピンホール SPECT の画像再構成

OP10「核医学画像」

○丹羽 英之<sup>1</sup>,尾川 浩一<sup>1</sup>
 <sup>1</sup>法政大学理工学部

SPECT では統計雑音の影響で再構成画像には劣化が生じ,ML-EM 法などを用いた場合は反復回数が増大するとその影響が 大きくなる.このような統計雑音の影響を低減するために、画像のなめらかさを事前確率として導入し再構成する MAP-EM 法などが提案されている.この際、ペナルティ関数として当該画素と近傍領域のメディアンの差を利用する方法 (MRP-EM)や 当該画素の近傍のメディアンとそれを囲む領域のメディアンの類似度を用いてペナルティとする方法 (SDMR-EM) などが提 案されている.本研究ではこれらの手法を3次元に拡張して、ピンホール SPECT における統計雑音を低減する方法を検討した. シミュレーションの結果から近傍領域の類似性を考慮した手法は画質が向上することが PSNR と MSSIM から明らかになった. OP10-2 画像再構成を用いない機能・形態ハイブリッドイメージング装置の提案

○大西 佑弥<sup>1</sup>,橋本二三生<sup>1</sup>,大手 希望<sup>1</sup>,大田 良亮<sup>1</sup> <sup>1</sup>浜松ホトニクス株式会社 中央研究所

近年,超高時間分解能放射線検出器を用いることで画像再構成を必要としない新たな分子イメージング技術である direct positron emission imaging (dPEI) が実証された. dPEI は電子陽電子対消滅ガンマ線を用いて生体内の機能情報を画像化でき, 小型でありながらも高精細な画像が得られることが期待される一方,形態情報を取得する方法がないため dPEI 画像のみでは 定量性に課題が残る.そこで本研究では、dPEI に対応する形態情報の取得に向けた新たな画像再構成不要イメージング技術を 提案し,その実現可能性をモンテカルロシミュレーションにより検証する.具体的には、対向配置された dPEI 検出器の一方 と被写体の間に配置された陽電子放出核種からの消滅ガンマ線のうち、被写体内でコンプトン散乱したイベントを利用するこ とで形態画像を取得する.検証の結果、dPEI と同一の検出器配置から被写体の形態画像も取得することができ、それを dPEI 画像の吸収補正に利用することで、定量性が改善された.

OP10-3 量子 PET のモンテカルロシミュレーション:ポジトロニウム寿命のモデル化

○田島 英朗<sup>1</sup>,田久 創大<sup>1</sup>,錦戸 文彦<sup>1</sup>,高橋美和子<sup>1</sup>,山谷 泰賀<sup>1</sup> <sup>1</sup>量子科学技術研究開発機構

PET 核種から飛び出た陽電子の数割は、一時的にポジトロニウム (Ps) と呼ばれる電子と陽電子のみからなる原子を経てから 消滅放射線対となる.近年、陽電子放出と同時に即発ガンマ線を放出する核種を用いて、周辺電子密度等により変化する Ps 寿 命を測定する研究が着目されている.我々は、Ps 寿命ががん酸素分圧のバイオマーカーとなる可能性を発見し、Ps 寿命イメー ジングに応用可能な Whole Gamma Imaging (WGI)の研究を進めている(量子 PET).本研究では、量子 PET の原理検証や画 像化手法開発に必要なモンテカルロシミュレータの開発を行ったので報告する.具体的には、Ps 寿命の空間分布や Ps 生成率 などを基に陽電子寿命を設定し、ポアソン分布に従った揺らぎを対消滅時刻に与えられるようにした.一対の検出器による Ps 寿命測定を模擬した結果、設定した寿命が反映されていることが確認された.

- OP10-4 深層学習を用いた異種モダリティ変換による PET のブラインド吸収補正: 簡便な投影空間によるアプローチ
  - ○平戸航之介<sup>1</sup>,山下 皓大<sup>1</sup>,佐藤 悠輝<sup>1</sup>,工藤 博幸<sup>1</sup>
    <sup>1</sup>筑波大学システム情報系情報工学域

PET 装置では、定量的な再構成画像を得るため吸収補正が必要である.吸収補正には体内のガンマ線吸収係数の分布が必要 であり、1)透過型スキャンによって測定したガンマ線吸収画像を用いる手法、2)同時に撮影した CT/MRI から計算で求めた ガンマ線吸収画像を用いる手法、3)PET 投影データのみからブラインドで吸収補正を行う手法、の3つが存在する.ブライン ドで吸収補正を行う手法はガンマ線吸収係数の画像が不要なため魅力的だが、安定に吸収補正を行うことが困難なことが古く からよく知られる.これに対して、近年、深層学習を用いて PET 投影データのみで吸収補正を行う手法が提案され、注目を浴 びている.本研究では、このカテゴリーに属するブラインド吸収補正の方法として、PET 投影データからガンマ線吸収係数画 像の投影データを深層学習を用いて直接推定して、これを用いて PET 投影データに吸収補正を施した後に画像再構成を行う手 法を提案する.提案手法では、全て投影データの空間で処理を行い画像空間は経由しない利点があり、深層学習を用いたブラ インド吸収補正の手法の中でも計算面で非常に効率的で簡便な手法と位置づけられる.全身腫瘍検査の PET 実画像を用いたシ ミュレーション実験を行った結果、提案手法は上手く動作して高精度でブラインド吸収補正が行えることが明らかになった.

OP10-5 重粒子線がん治療における初の臨床適用に向けた OpenPET 装置開発

○田島 英朗<sup>1</sup>, 寅松 千枝<sup>1</sup>, MohammadiAkram<sup>1</sup>, 岩男 悠真<sup>1</sup>, 赤松 剛<sup>1</sup>, 稲玉 直子<sup>1</sup>, 姜 韓 圭<sup>1</sup>, 田尻 稔<sup>1</sup>, 水野 秀之<sup>1</sup>, 小藤 昌志<sup>1</sup>, 山谷 泰賀<sup>1</sup>
<sup>1</sup>量子科学技術研究開発機構

開放空間を持つ OpenPET は重粒子線照射中に PET 測定が可能であり,照射によって生体内で副次的に生成された陽電子 放出核種をイメージングすることで,患者体内での飛程検証や,腫瘍内部の洗い出し(血流による)の測定による治療効果予 測ができるようになると期待されている.本研究では,OpenPET 装置を HIMAC (Heavy Ion Medical Accelerator in Chiba) の治療室へ設置し,患者への照射時に安全かつ迅速に測定を実施するために必要なシステム及び校正ソフトの開発を行った. 具体的には,治療に影響しないように装置を測定位置へセットアップするための迅速位置合わせ機構,検出器誤差を測定後で も校正可能なデータ収集法,及び半自動の校正ツールの開発を行った.そして,実際に治療室へ試験設置し,人体頭部を模擬 したファントムに対する照射及び OpenPET 測定を行った.その結果,照射範囲に陽電子放出核種が生成されていることを確 認した.発表では照射線量分布との比較を行った結果を報告する. OP10-6 Whole Gamma Imaging 4 号試作機の PET・コンプトンカメラハイブリッドイメージングシミュ レーション

○ 菊地 智也<sup>1</sup>,田久 創大<sup>2</sup>,菅 幹生<sup>13</sup>,田島 英朗<sup>2</sup>,錦戸 文彦<sup>2</sup>,山谷 泰賀<sup>2</sup> <sup>1</sup>千葉大学 融合理工学府 医工学コース、<sup>2</sup>量子科学技術研究開発機構、<sup>3</sup>千葉大学 フロンティア医工学センター

Whole gamma imaging (WGI) は、PET 検出器リングの内側に散乱検出器リングを挿入し、PET とコンプトンカメラの2つ の画像化手法を1つの装置で実現する。89Zr は抗原抗体反応を利用したイメージングに適した PET 核種であるが、陽電子放 出に比べ4倍ほど多く放出される909 keV ガンマ線が画質低下の原因になっていた。WGI はこの909 keV ガンマ線をコンプト ンカメラにより有効活用できるため、画質の向上が期待できる。本研究では、去年新たに設計した WGI4 号機の PET・コンプ トンカメラハイブリッドイメージング性能をシミュレーションにて予測した。89Zr 線源を封入したコントラストファントムを 視野中心に配置し、PET 画像とハイブリッド画像のコントラストと均一性を評価した。同じコントラストで比較した場合、ハ イブリッド画像では PET 画像より 4.4% ノイズが低減していた。また収束した際のコントラストはハイブリッド画像の方でや や低下したが、均一性は 2% 程度向上した。

## 7月28日(金)

## 第3会場(7Fセミナー室7A)

# 一般演題11

16:50~17:40 **OP11「超解像・微細構造」** 

座長: 彌冨 仁(法政大学理工学部)

清水 昭伸(東京農工大学)

OP11-1 ESRGAN による医用画像の超高解像度化の検討

○大坂 亮二<sup>1</sup>, 安倍 和弥<sup>1</sup>, 武尾 英哉<sup>1</sup>
<sup>1</sup>神奈川工科大学 工学部 電気電子情報工学科

現在,医用画像の撮影装置の性能向上等により,患者一人当たりの撮影画像数が増加しており,それを読影する医師の負担も 増加している.そこで,医用画像の解像度を高解像度化することで,1枚1枚の精度を上げることによって撮影枚数を抑える ことで医師の負担を軽減できると考えられる.例えば,CT画像の解像度は1024×1024が一般的である.今後も装置的に解像 度の向上は行われていくと思うが,2048×2048の解像度を実現した装置はほとんどない.一方,画像解像度が上がれば,診断 画質の向上や CAD の性能向上が期待できる.

そこで本研究では、AI による超解像化技術を用いた医用画像の超解像化画像生成により,診断画質の向上や CAD の性能向 上に寄与することを目的とし、GAN(Generative Adversarial Networks)を用いた ESRGAN(Enhanced Super-Resolution GAN) による医用画像の超高解像度化の検討を行った。

OP11-2 拡散モデルを用いた胸部 CT 像の超解像

○関口 樂<sup>1</sup>, 稲井 邦博<sup>2</sup>, 清水 昭伸<sup>1</sup>, 木戸 尚治<sup>3</sup> <sup>1</sup>東京農工大学 大学院 工学研究院,<sup>2</sup>福井大学 医学部 分子病理学,<sup>3</sup>大阪大学 大学院 医学系研究科

本報告では、拡散モデルを用いた胸部 CT 像の超解像について報告する.気管支や血管、および、肺胞などの陰影のエッジ 付近の超解像の精度を改善するために、Sobel フィルタを用いた重み付き損失を提案する.拡散モデルの学習は CT スライス像 の一部を切り取った部分画像を用いて行い、推論では部分画像に対する超解像結果を再構成して高解像度のスライス像を生成 した.本手法の有効性を評価するために、提案する超解像をマイクロ CT 像を bicubic ダウンサンプリングして作成した低解像 度画像に適用した.評価では、PSNR と SSIM に加えて、パワースペクトルの正解との差を用いた.推論したモデルの性能を 10 枚の CT スライス像を用いて評価し、Residual Channel Attention Networks と比較した.その結果、PSNR や SSIM では性 能が劣るが、高周波のスペクトルをより正確に表現できることが分かった. OP11-3 深層学習とセグメント PSFT 信号を利用した MR 画像の超解像に関する基礎検討

○藤澤舜太郎<sup>1</sup>,山登 一輝<sup>1</sup>,伊藤 聡志<sup>1</sup>

1宇都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム

MRI の撮像時間短縮のため、少数の収集信号から画像を再生する圧縮センシングが利用できるが、少数の信号収集量では、 再構成像の品質低下が避けられない、本研究では、位相拡散フーリエ変換映像法(PSFT)の信号をセグメント収集し、収集信 号からの超解像的画像再構成法について検討する. PSFT 信号は、汎用のフーリエ法に二次の位相変調を加えることで得られる. 先行研究では、等間隔なセグメントを間欠的に収集した PSFT 信号から反復再構成法により高品質な再構成像を確認している が、等間隔なセグメント収集では特定の位相変調係数で再構成像の品質低下の問題があった. そこで、本研究ではセグメント 幅とその間隔を不等間隔に配置することを提案する. さらに、深層学習再構成の導入により再構成像の品質向上を図った. 実 験の結果、PSNR や SSIM の向上に加えて、主観的な画像品質の改善も確認できたので報告する.

OP11-4 X線暗視野法を用いた膵管内乳頭粘液性腫瘍における乳頭状構造の3次元解析

○天野 遥菜<sup>1</sup>, 砂口 尚輝<sup>1</sup>, 黄 卓然<sup>1</sup>, 岩越 朱里<sup>2</sup>, 末永 雅也<sup>2</sup>, 市原 周<sup>2</sup>, 西村理恵子<sup>2</sup>, 島 雄 大介<sup>3</sup>, 湯浅 哲也<sup>4</sup>, 安藤 正海<sup>5</sup>

<sup>1</sup> 東海国立大学機構名古屋大学,<sup>2</sup> 国立病院機構名古屋医療センター,<sup>3</sup>大阪物療大学,<sup>4</sup> 山形大学,<sup>5</sup> 高エネルギー加速 器研究機構

放射光 X 線を光源に用いる X 線暗視野法 (XDFI: X-ray Dark field imaging) は、染色した病理組織像に匹敵するコントラス トと数μ m の空間分解能を有しており、生体軟組織の 3 次元像を高画質に再構成できる。本研究では、ヒトから切除された膵 管内乳頭粘液性腫瘍を XDFI で撮影し、膵管内に存在する腫瘍の 3 次元微細構造を可視化した. 拡張した膵管内に隆起性に増 殖する腫瘍構造に着目すると、2 次元平面では乳頭状の突起が膵管の内面に並んでいるように見えたが、ボリュームレンダリ ングを適用した 3 次元像では各隆起が独立した凸の構造ではなく、膵管の管軸方向に向かって波状・山脈状に繋がっていく様 子が確認できた. この研究では、膵管内の隆起性構造の連結性や等方性について解析し、本疾患名にも反映されている"乳頭"構 築の真の増殖形態について考察する.

## 7月28日(金)

# 第3会場(7Fセミナー室7A)

# 一般演題12

17:50~19:00 OP12「分類・検出」

座長:畑中 裕司 (大分大学)野村 行弘 (千葉大学)

OP12-1 気管支超音波画像と深層学習を用いた肺末梢病診断手法の開発

 ○王 慧涛<sup>1</sup>, 鹿野 幸平<sup>2</sup>, 中島 崇裕<sup>3</sup>, 李 ジャオ<sup>4</sup>, 野村 行弘<sup>5</sup>, 中口 俊哉<sup>5</sup>
 <sup>1</sup>千葉大学 融合理工学府基幹工学, <sup>2</sup>千葉大学大学院医学研究院 呼吸器内科学, <sup>3</sup>獨協医科大学 呼吸器外科学, <sup>4</sup>同済 大学附属東方医院, <sup>5</sup>千葉大学フロンティア医工学センター

Background: Lung cancer is the second most common cancer in the world. Millions of people die from it. This study aims to develop a computer-aided diagnosis (CAD) system to help medical doctors differentiate benign and malignant peripheral pulmonary lesions (PPLs) in endobronchial ultrasonography (EBUS) images based on deep learning.

Methods: Our CAD system is based on the ensemble learning and down-sampling technique. We trained six pre-trained convolutional neural networks (CNN) models, including ResNet-18, ResNet-34, DenseNet-121, DenseNet169, MobileNet-V2, and ShuffeNet-V2. The trained models are aggregated by the bagging ensemble and stacking ensemble techniques. We evaluated the proposed system with five-fold cross-validation in the experiments. We used a set of 600 EBUS images consisting of 69 lung cancer cases consisting of 59 malignant cases and 10 benign cases. There are 36 malignant cases and 6 benign cases in the train set, and 12 malignant cases, and 2 benign cases in the valid set and test set, respectively.

Results: In the experimental result, it was noticed that the ResNet-18 backbone achieved the highest performance among the deep-learning networks by using the average voting ensemble method. The final experimental results are the average of the five-fold experimental results showing that the accuracy, sensitivity, specificity, positive predictive value, negative predictive value, and area under the curve (AUC) values are 0.81, 0.66, 0.97, 0.97, 0.74, and 0.84, respectively.

Conclusions: The proposed CAD system has the potential ability to diagnose PPLs in EBUS images based on deep learning.

OP12-2 U-Net を用いた胸部 X 線像からの左肺境界の検出

○永田 亮一<sup>1</sup>, 畑中 裕司<sup>1</sup>
<sup>1</sup>大分大学 理工学部

肺がん診断を支援する手法として, 胸部 X 線像からの肺結節自動検出がある. この手法では肺領域内から肺結節を検出する ため, 肺境界を正しく検出することが重要となる. 本論文では, U-Net を用いて, 臓器やガスの影響が少なくない左肺の境界 を検出するための手法を提案する. 医用画像で教師あり学習を行う際, データを大量に用意することが難しいという問題があ る. そのため, 胸部 X 線像の左肺の境界上に複数の関心領域を配置し, 関心領域を画像として切り出すことでデータ数を増やす. また左肺の境界について学習する際, 左肺の特徴から左肺の境界を 4 つの領域に分割し, それぞれ別々のモデルで学習するこ とによって左肺の境界の検出精度を高める. JSRT データベースの画像に対して左肺の境界を検出した結果, 精度の指標となる Dice 係数が平均 0.644 となった.

OP12-3 3D U-Net における非造影 CT 画像の大動脈・冠動脈の検出と分類

〇庄野未彩季<sup>1</sup>, 鈴木 秀宣<sup>2</sup>, 河田 佳樹<sup>3</sup>, 杉浦 寿彦<sup>4</sup>, 田邊 信弘<sup>5</sup>, 丸茂 一義<sup>6</sup>, 金子 昌弘<sup>7</sup>, 仁 木 登<sup>8</sup>

<sup>1</sup>德島大学大学院創成科学研究科,<sup>2</sup>徳島大学理工学部,<sup>3</sup>徳島大学大学院社会産業理工学研究部,<sup>4</sup>千葉大学,<sup>5</sup>千葉大学,<sup>6</sup>東京都予防医学協会,<sup>7</sup>東京都予防医学協会,<sup>8</sup>(株)医用科学研究所

大動脈・冠動脈の石灰化によって引き起こされる心疾患の死亡率は悪性新生物に続き第2位を占めている.心疾患は日本 において主な死因の1つとされる疾患であり、早期発見・早期治療を受けることが必要とされている.この解析は正常100例 と慢性血栓塞栓性肺高血圧症の22例の非造影 CT 画像を用いる.本報告では、3D U-Net による非造影 CT 画像から大動脈・ 冠動脈石灰化を検出し、その結果を用いて、心房・心室・大動脈・肺動脈の情報をもとに大動脈・冠動脈石灰化を検出する. これらの実験結果を示す.

OP12-4 2.5 次元特徴抽出及び3次元特徴選択による COVID-19 自動分類モデルの汎化性能に関する検討

〇遠田  $凉^1$ , 伊東 隼人<sup>1</sup>, 小田 昌宏<sup>2,1</sup>, 林 雄一郎<sup>1</sup>, 大竹 義人<sup>3,4</sup>, 橋本 正弘<sup>5</sup>, 明石 敏昭<sup>6</sup>, 青木 茂樹<sup>6</sup>, 森 健策<sup>17,4</sup>

<sup>1</sup>名古屋大学大学院情報学研究科,<sup>2</sup>名古屋大学情報連携推進本部情報戦略室,<sup>3</sup>奈良先端科学技術大学院大学先端科学 技術研究科,<sup>4</sup>国立情報学研究所医療ビッグデータ研究センター,<sup>5</sup>慶應義塾大学医学部,<sup>6</sup>順天堂大学医学部,<sup>7</sup>名古 屋大学情報基盤センター

本稿では、2.5 次元の特徴抽出及び3次元の特徴選択による COVID-19 自動分類用 CNN を提案し、その汎化性能を複数のデー タセットを用いて検証する.新型コロナウイルス感染症(COVID-19)の診断において、胸部 CT 検査は不可欠であるが、CT 画像の読影は放射線科医らにとって負担が大きく、コンピュータ支援診断技術の開発が求められている.COVID-19の流行初 期から様々な自動分類モデルが提案されてきたが、その多くは小規模な内部データセットで分類性能を検証するに留まってお り、汎用的なモデルは少数である.本研究では、2次元及び3次元の特徴抽出器を組み合わせることで過学習を抑制した 2.5 次 元の CNN と、抽出された特徴から重要なパターンのみを選択する3次元の attention 機構を有する分類モデルを提案し、その 汎化性能を検証する.提案モデルを含めて6種類のモデルを用いた比較の結果、提案モデルは複数のデータセットで安定した 分類性能を示した.

- OP12-5 3 次元 CT 画像を用いた 2 段階 3D U-Net によるじん肺粒状影抽出法
  - ○松廣 幹雄<sup>1</sup>,新居新居 蓮叶<sup>2</sup>,河田 佳樹<sup>2</sup>,大塚 義紀<sup>3</sup>,岸本 卓巳<sup>4</sup>,芦澤 和人<sup>5</sup>,仁木 登<sup>6</sup>
    <sup>1</sup>鈴鹿医療科学大学 保健衛生学部 放射線技術科学科,<sup>2</sup>徳島大学大学院理工学研究部,<sup>3</sup>北海道中央労災病院,<sup>4</sup>岡 山ろうさい病院,<sup>5</sup>長崎大学病院,<sup>6</sup>株式会社医用科学研究所

じん肺は粉塵を吸い込むことで起こる職業性呼吸器疾患である.国内では年間24万人がじん肺と診断されている.病型1/0 以上のじん肺は労災認定の対象となるため、0/1と1/0を区別することが重要である.じん肺の病型分類にはX線写真が使わ れている.じん肺の診断において粒状影の認識は重要であり、3次元CT画像はより正確に粒状影を検出できるため診断に有用 である.我々は直径2.5mm以上の粒状影の数がじん肺の診断に有用であることを報告した.本報告では2段階に3DU-Netを 用いて3次元CT画像から直径2.5mm以上の粒状影を検出する方法を提案する.本手法は、微小結節と肺血管を対象とした学 習、胸壁付近の微小結節を対象とした学習、2つの3DU-Netの出力を用いた学習からなる.テストデータに対する検出結果は 0/1では精度85.7%・感度90.9%、1/0では精度95.9%・感度88.6%であった. OP12-6 Soft-boundary を導入した SVDD-AE による胸部 CT 画像の異常検知

○ GaoZhihui<sup>1</sup>,中山 良平<sup>1</sup>,檜作 彰良<sup>1</sup>,木戸 尚治<sup>2</sup> <sup>1</sup>立命館大学大学院 理工学研究科.<sup>2</sup>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

医用画像上の病変は、しばしば正常構造に似た信号パターンをもち、Variational AutoEncoder (VAE) による画像再構成に おいて病変も復元される問題がある。そこで本研究では、潜在空間において正常と異常の潜在変数分布を遠ざける学習を導入 した AE を構築し、胸部 CT 画像における病変検出に適用する。実験試料は、胸部 CT 画像 850 症例(正常:650 症例,異常: 200 症例)である。提案手法では、まず正常症例だけを用いて、サポートベクトルデータ記述法により、正常の潜在変数を潜 在空間上で可能な限り小さな超球内に収まるように学習する。次に少量の異常症例を用いて、異常の潜在変数が超球の中心か ら離れるように学習する。そして、入力画像と潜在変数から再構成した画像との差異に基づき、病変を検出する。提案手法に よる AUROC は 0.67 で、従来手法である VAE(0.58)より高い結果が得られ、その有用性が示唆された。

## 7月29日(土)

# 第1会場(10F 佐治敬三メモリアルホール)

# シンポジウム2

## 9:30~11:00 SY2「フォトンカウンティング CT の衝撃」

座長:工藤 博幸(筑波大学) 粟井 和夫(広島大学)

SY2-1 フォトンカウンティング CT の原理

○田口 克行

Johns Hopkins University School of Medicine

X線CTが発明されて以来の50年間における進歩の歴史を振り返ると、それは、幾つかの「不連続で量子的な飛躍」と、それに続く「連続的で斬新的な進歩」から構成されることが分かる。量子的な飛躍とは、X線CTが収集する被写体データの「次元」 が一つ増えることであり、斬新的な進歩とは、そのデータの質が徐々に向上することを意味している。近年、フォトンカウン ティングCTが開発され、最後の量子的な飛躍を実現した。従来型CTが得ていたスカラー量の3次元空間分布データではなく、 ベクトルの3次元空間分布データが得られるようになったのである。このプレゼンテーションでは、フォトンカウンティング 検出器の動作原理およびシステムの性能までを、物理的・工学的な観点から概説する。

SY2-2 高精細 CT および新型面検出器 CT の現状と将来展望

○大野 良治

藤田医科大学 医学部 放射線医学教室,藤田医科大学 医学部 先端画像診断共同研究講座

1999年に臨床応用された多列検出器型 CT(Multi-Detector CT:以下 MDCT)は4列 MDCT から継続的な多列化が図ら れ、その一つの完成形として 2008年に面検出器型 CT(Area-Detector CT:以下 ADCT)が臨床応用され、その臨床的有用性 はゆるぎないものになっている。そして、ADCT は様々な低線量技術、Dual-Energy CT や Subtraction CT 技術や様々な機能 CT あるいは形態・機能 CT としての臨床応用研究が行われ、新たな ADCT の可能性が継続的に模索されている。その一方で、 新たな CT の可能性を追求し、更なる高精細化を目指して 2017年以降臨床応用された高精細 CT(HIgh-Definition CT:以下 HDCT)が臨床応用され、CT における更なる高精細化の臨床的有用性の可能性が模索されている。このような状況下で 2022 年に光子計測型 CT(Photon-counting CT:以下 PCCT)が臨床応用された。本講演では ADCT および HDCT の臨床的有用性 を PCCT と比較して述べるとともに、将来展望に関しても言及したいと考える。

#### SY2-3 胸部画像診断における Photon Counting CT の可能性

○梁川 雅弘

大阪大学 大学院医学系研究科 放射線医学統合講座放射線医学

シーメンスヘルスケア社より半導体検出器を搭載した PCD-CT (photon-counting detector CT) が臨床機 (NAEOTOM Alpha) として登場した. PCD-CT は,従来の EID-CT (energy-integrating detector CT) と比較して,空間分解能 (面内分 解能 0.11mm,体軸分解能 0.20mm) やエネルギー分解能 (エネルギー bin に対応した X 線フォトン数算出) に優れ,低被曝,低造影剤量であっても,高分解能かつ物質弁別を可能にする CT 画像診断の新時代を担う装置といえる. 当院では今年の 2 月 より PCD-CT が臨床現場で稼働したところである.本講演では,EID-CT の高精細 CT と PCD-CT の画質を伸展固定肺の撮像 により比較した検討や胸部領域を中心とした臨床例を中心に,PCD-CT の臨床的有用性や課題,今後に期待される技術などに ついて文献的考察を加えながら解説する.本講演が PCD-CT の胸部画像診断について,知識の整理や明日からの臨床・研究面 において一助となれば幸いである.

SY2-4 フォトンカウンティング CT の神経放射線領域への応用

○樋渡 昭雄

名古屋市立大学大学院医学研究科 生体防御・総合医学専攻 生体総合医療学講座 放射線医学分野

従来の固体シンチレーション検出器では、X線が可視光に変換されたのち電気信号に変換されていたが、フォトンカウンティ ング検出器は、X線のフォトンを直接電気信号に変換することが可能である.また、従来必要とされていた検出器のピクセル 間の隔壁も不要である.その為、コントラスト及び空間分解能向上、放射線被曝低減、造影剤投与量削減、マルチエネルギー 情報の取得、スペクトラルイメージングの改善など、様々なメリットが提唱されている.当院では2023年3月より稼働し ており、神経放射線領域への臨床応用、基礎的検討を中心に、これまでの経験を概説したい.

## 7月29日(土)

# 第1会場(10F佐治敬三メモリアルホール)

一般演題13

11:10~12:10 | **OP13「非画像情報**」

座長: 神谷 亨(九州工業大学)

上村 幸司(国立循環器病研究センター)

OP13-1 肺高血圧症の予測:胸部 CT 画像、性別、年齢、血液検査データを用いた医用画像診断支援シス テム

○富山 実幸

大阪大学医学系研究科人工知能画像診断学共同研究講座

肺高血圧症は肺動脈圧が上昇する進行性の疾患群であり、治療介入が必要だが、確定診断される症例はまれである. その理 由として、右心カテーテル検査が唯一の確定診断方法であることが考えられる. 右心カテーテル検査は患者にとって侵襲的で あり、しばしば合併症を伴うため、スクリーニングの手段としては不適切である. そこで本研究では、胸部 CT 画像や性別、年齢、 血液検査データを用いた CAD(Computer aided diagnosis/detection) システムを開発することで、肺高血圧症のスクリーニング を目指します.

OP13-2 胸部 MRI を用いた Radiomics の安定性評価

○高瀬 真衣<sup>1</sup>, 坂 知樹<sup>1</sup>, 鎌田 洋<sup>1</sup>, 岩澤 多恵<sup>2</sup>
 <sup>1</sup>金沢工業大学,<sup>2</sup>神奈川県立循環器呼吸器病センター

ラジオミクスにはこれまで SN 比が高い CT や PET が用いられてきたが、これらには放射線被曝という問題がある.一方、 MRI であれば患者にリスクを負わせることがない. ラジオミクスに MRI を用いた先行研究は存在するが具体的な症例を対象 としており、MRI を用いたラジオミクス自体の安定性を確認する研究は存在しない. そこで本研究では、MRI で撮像された脊 柱起立筋を対象とし、その特徴量の安定性を精査する. 実験では 2020 年から 2021 年に検査を受けた 36 歳~85 歳の男女 41 名 の MRI データを使用した. 画像は脳脊髄液の値を用いて正規化した. 抽出した画像特徴量をグループに分け、統計手法を用い て類似性を確認した. その後、機械学習手法を用いて特徴選択を実施し、上位の特徴量を比較した. 実験の結果、MRI から抽 出した特徴量の安定性を精査することで、MRI を用いたラジオミクスの安定性を確認した. OP13-3 3次元点群動画像を用いた顔の時系列変化の検出および非対称度評価

○木原 成海<sup>1</sup>,神谷 亨<sup>1</sup>
 <sup>1</sup>九州工業大学

ロ唇裂は, 胎児の成長過程で唇が正常に形成されないことによって生じる先天異常である.その外科手術は複数回に渡って行われるが, 顔の左右対称性の基準は曖昧であり, 医師によって意見が変わることが問題となっている.そこで,本論文では,3次元点群動画像を用いた顔の対称性解析を定量的に行う手法を提案する.提案手法では,3次元点群データから顔のランドマーク座標を検出し, FPFH 特徴量を用いて異なるフレーム間で点のマッチングを行うことによって得られる各ランドマーク点の時系列変化を左右で比較する.また,マッチング結果を利用した口唇部領域の抽出,および分割を行い,各小領域の重心座標を左右で比較する.これら二つの方法で計算した非対称度による定量評価を行う.人工的な合成データによる実験の結果,マッチング誤差は0.09821と小さく抑えられること,および人の主観的な感覚に合致する評価を行えることが確認できた.

OP13-4 非侵襲的なドライバー遺伝子変異有無の識別のための Radiomics 特徴量に基づく 2 クラス分類

○渡邊 至恩<sup>1</sup>,神谷 亨<sup>1</sup>
 <sup>1</sup>九州工業大学

2021年の日本人の死因はがんが27%を占めており,死亡者のうち4人に1人はがんが理由で亡くなっている.また,がんに おける部位別死亡率は肺がんの割合が最も大きいため,早期発見・早期治療が重要課題となっている.そこで,肺がんの悪化 に影響を及ぼすドライバー遺伝子変異の有無の識別を非侵襲的に行うコンピュータ支援診断システムの開発を目標とした手法 を提案する.本論文では Radiomics 特徴量と性別を説明変数とし,Null Importance により次元削減を実施した後,LightGBM を用いた2クラス分類を行う.

- OP13-5 頭部 CT 所見文重要度分類における能動学習アルゴリズムの比較
  - ○綿谷 朋大<sup>1</sup>, 佐藤 淳哉<sup>1</sup>, 喜多 洸介<sup>1</sup>, 富山 実幸<sup>2</sup>, 鈴木 裕紀<sup>1</sup>, 木戸 尚治<sup>1</sup>, 富山 憲幸<sup>2</sup> <sup>1</sup>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,<sup>2</sup>大阪大学大学院医学系研究科 放射線統合医学 講座 放射線医学

【目的】頭部 CT 所見文重要度分類において,能動学習アルゴリズムを比較する.【対象・方法】2020年に大阪大学医学部附属病院で施行した頭部単純 CT の所見文 3728件に対し,放射線科医が内容の重要度を5クラスに分類し,内2385件を訓練データとした.訓練データの中から25件ずつ選択して学習データに追加して UTH-BERT を訓練する際,選択する際の能動学習アルゴリズム (不確実性サンプリング (US)4 手法,多様性サンプリング (DS)2 手法)をランダムサンプリング (RS)と比較した.【結果】学習データに 1000件を使用した時点では,US は RS より 1-2% 正答率の向上を認めた一方,DS では 1-2%低下した.また,US では RS よりも少数のデータでモデルの成績が収束した.さらに US では訓練序盤から少数クラスの所見文が積極的に学習データに追加された.【考察】US では少数のデータで効率的な学習が可能であり,アノテーションコストの削減を可能にし, さらに クラス間インバランスの是正に役立つ.

OP13-6 UTH-BERTと注意機構を用いた医療診断レポートにおける部位識別

○成田 紗弥<sup>1</sup>, 間普 真吾<sup>1</sup>, 木戸 尚治<sup>2</sup>

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人工知能画像診断学共同研究講座

深層学習には大量の教師データが必要であるため、ラベル付けを効率的に行う仕組みを構築できれば大きな貢献が可能であ る.本研究では、全身の PET-CT 画像およびそれに対応する診断レポートが存在するデータに対して、深層学習に適したラベ ル付きデータセットを構築するための第一段階として、診断レポートの各文に対して解剖学的な部位ラベルを付与すること を目的とした。先行研究では、診断レポートを UTH-BERT で解析し、文単位で部位ラベルを付与するモデルを構築した。し かし、文単位では部位の識別が困難であるものが多数あり、この問題を解決するために、識別対象文の前文も入力に加えて識 別するモデルを構築した。これより識別性能が向上したが、部位によっては前文がノイズとなり、性能が低下する結果も見ら れた。このことから、前文の重要度を自動的に判断できるモデルがあれば、さらなる性能向上につながると考え、UTH-BERT に注意機構を組み合わせたモデルを構築し、その識別性能を検証した。

# 第1会場(10F佐治敬三メモリアルホール)

# 特別講演2

13:30~14:30 SL2 「画像診断の歴史」

座長: 陣崎 雅弘 (慶應義塾大学)

SL2 画像診断の歴史

○百島 祐貴 慶應義塾大学病院予防医療センター

1896年1月1日,レントゲンによるX線発見の論文が刊行されると,わずか2週間後の1月17日には最初の臨床例が撮影され, 世界中でX線診断が試みられた.その後1年間に出版されたX線関連の論文は1000編以上,書籍は50冊におよび,医学界が X線に寄せた関心,期待の大きさがうかがわれる.その一方,体内を透視できれば病気はすべてわかる,医者などいらなくな ると言われたが,まもなくその限界も明らかとなり,以後様々な撮影法,検査法が工夫された.本講演では,X線検査,超音波, CT,MRIの発展,ならびにこれと密接な関係にある放射線障害,防護の歴史を振り返る.

## 7月29日(土)

# 第1会場(10F 佐治敬三メモリアルホール)

# シンポジウム3

14:40~16:10 SY3「ベンチャー企業が挑む AI 開発」

座長:森 健策(名古屋大学)

稲井 邦博(福井大学)

SY3-1 ロボティクス、AIを活用した微生物検査グラム染色自動化機器の開発

○平岡 悠

大阪大学医学部附属病院,大阪大学大学院医学系研究科人工知能画像診断学,株式会社 GramEye

抗菌薬の不適正利用によって抗菌薬に耐性を持つ細菌が発生する現象,薬剤耐性菌問題による死者数は,2050年には悪新生物による死者を超え,年間1,000万人になるとされている.抗菌薬の適切利用のために,迅速安価な微生物検査・グラム染色が有用であるとされている.株式会社 GramEye では染色工程・顕微鏡動作・AI 画像判定までを一気通貫で自動化するロボティクス・AI を活用した医療機器の開発を行っている.グラム染色は世界で最も実施回数の多い微生物検査で,迅速安価に菌種推定が可能であり,感染症治療方針立案に有用な検査であるが,染色から顕鏡判定までマニュアルで行われる検査であることから結果のばらつきと検査報告返却までの時間の長期化が発生しており,検査本来の潜在的な力を十分に引き出せていない状況である.

本製品では,染色工程から顕鏡工程までをロボティクスによりノンストップで自動化,AIによる菌種判定まで実施し,結果 報告の迅速化,検査室の業務量の低減,報告結果の標準化とAIの継続的なアップデートによる詳細な菌種推定を実現する.

現状は、グラム染色結果の活用が臨床現場で十分にされていない. その理由として、再現性の低さ、不十分なデジタル化、 結果の解釈の困難さが挙げられる.本機器はこれらの課題を解決するものであり、主科の医師がグラム染色画像を見ながら感 染状態に関して議論を行うことが将来的に可能になるものである.

また、検査手順の標準化、トレーサビリティの確保は検査としてのエビデンスの蓄積を促し、国内外においても類似コンセプトの製品開発は確認されておらず、日本発の国際的な塗沫画像プラットフォームの構築が期待される.

#### SY3-2 病理 AI による診断支援と活用の展望

○飯塚 統

メドメイン株式会社

深層学習により,画像認識領域における AI の開発は飛躍的な進歩を遂げており,病理画像認識における AI の開発では顕著 な成果が見られます.メドメインでは,病理診断領域におけるデジタル化の推進と,深層学習による病理 AI の研究開発に取り 組んできています.これまで,胃,大腸,肺,乳腺,前立腺,膵臓,皮膚,子宮頸部細胞診などにおける病理 AI 開発を行い実 装するとともに,深層学習による AI 開発を高速化する転移学習技術に関する基礎研究や,画像処理と自然言語処理による病理 AI の研究開発等を行ってきました.

これらの研究成果を起点とし、個別化医療を実践する基盤となる病理 AI モデルの開発へ展開していきたいと考えており、病 理における AI 開発の取り組みとその活用の展望についてご紹介いたします.

#### SY3-3 ベンチャー企業が挑む AI 開発

○髙橋 秀徳

DeepEyeVision 株式会社,学校法人自治医科大学

演者は大学眼科で臨床をしつつ動物実験や臨床研究をしてきた.2015年に松尾豊著「人工知能は人間を超えるか」と出 会い, 眼底写真を深層学習し, 半年で精度が出て大学に職務発明の届けをした.大学卒業時に起業しなかった後悔があり, DeepEyeVision 社を設立した.知財の売り込みをしたが,「顧客である医師の仕事を奪う知財は使えない」と医療機器メー カーに言われ,自力で世に出す事にした.インキュベーション施設に入り,起業指導と共にCTOを紹介して頂き,厚労省ベ ンチャー支援 MEDISO からも指導頂いた.何でも診断する AI を自分の健診業務に使っていたが,承認取得は困難だった.一 部の疾患に限定して承認を目指そうにも数年と数億円の負担が重い.そこで計測に留め,健常眼からの逸脱部位を可視化する DeepEyeVision for RetinaStation として,2021年に認証を取得した.翌年にはもう1つ取得し,上市後に多数の要望を頂き, 細やかな改善を続けている.

SY3-4 世界に挑戦する内視鏡 AI

○金井 宏樹<sup>1</sup>,多田 智裕<sup>1</sup>

<sup>1</sup>株式会社 AI メディカルサービス

当社は内視鏡 AI の開発と事業化を目指しているスタートアップです.

消化器内視鏡は日本で実用化され、国内メーカーが世界シェアの98%を占める日本を代表する産業です。日本の内視鏡医は 世界のトップクラスであり、国内には最高品質のデータが蓄積されております。

そうした中で,当社は内視鏡 AI の研究開発を進め,100 施設以上のトップ医療機関と共同研究を行うことができました.その結果,論文引用数では当者の研究チームが,現時点では世界最多となっております.今まで培った研究基盤を軸に,これからグローバルトップを狙って事業を進めます.

本講演では、当社の創業から事業化への経緯と、世界展開に向けた展望についてお話いたします.

# 第2会場(7F セミナー室7C+D)

# 一般演題14

11:10~12:10 **OP14「脳」** 

## 座長: 菅 幹生 (千葉大学)

增谷 佳孝 (東北大学)

OP14-1 Vision Transformer と Brodmann area を用いた脳 SPECT 画像の認知症分類

○若尾 紘嵩<sup>1</sup>,深澤 誠<sup>2</sup>,飯塚 友道<sup>2</sup>,清水 昭伸<sup>1</sup>
<sup>1</sup>東京農工大学大学院工学研究院.<sup>2</sup>複十字病院認知症疾患医療センター

本報告では、認知症患者(AD・DLB・FTD)と正常群(HC)の脳 SPECT 画像(3D-SSP)を対象とした、深層学習を用いた4クラス分類手法を提案する。脳 SPECT 画像(3D-SSP)を用いた診断は、各疾患に典型的な血流量の変化を見出すことにより行われる。その際、特定の部位の脳の血流量低下だけでなく、領域間の血流量の関係を踏まえて分類を行う必要がある。本報告では、脳領域を組織構造ごとに区分した Brodmann Area を利用し、Vision Transformer により分類に貢献する領域や領域間の関係性をデータドリブンに導くことが可能な方法を提案する。実験では、1 症例あたり5 種類のデータからなる 418 症例のデータセットで学習および評価を行い、既存の医学的知見との比較を行った。

OP14-2 3DCNN を用いた脳 MR 画像の 3 次元位置合わせ

○馬場星太郎<sup>1</sup>,神谷 亨<sup>1</sup>
 <sup>1</sup>九州工業大学

本論文では、アルツハイマー型認知症の脳萎縮に着目し、脳 MR 画像の経時的 3D 位置合わせによる脳萎縮率の算出を目的 とした画像処理手法を提案する。Stergios らの非線形 3D 位置合わせモデルを線形位置合わせモデルに組み替え、アフィン変換、 剛体変換での位置合わせを行う.また、症例ごとに最適化処理を行う Instance-specific Optimization により、精度向上を図る。 モデルの学習には、ADNIの脳 MR 画像を任意に線形変換した合成データを用いた.テストには合成データと実際の ADNI の 時系列データを用いた結果、合成データの剛体変換においては最適化処理の追加により、正規化相互相関(NCC)が約 15%向 上し、99.0%の精度が得られた.これにより脳 MR 画像における線形 3D 位置合わせモデルと Instance-specific Optimization の 組み合わせの有用性を確認した。

OP14-3 MRI FLAIR 画像を用いた異常検知による脳梗塞再発予測の検討

○渡辺 翔吾<sup>1</sup>, 連 乃駿<sup>1</sup>, 盛田 健人<sup>2</sup>, 中奥由里子<sup>1</sup>, 尾形宗士郎<sup>1</sup>, 小橋 昌司<sup>3</sup>, 飯原 弘二<sup>1</sup> <sup>1</sup>国立循環器病研究センター、<sup>2</sup>三重大学、<sup>3</sup>兵庫県立大学

脳血管疾患は死亡原因の第3位である.その中でも 脳梗塞はその半数以上を占めており,初回脳梗塞発症後の再発は患者の QOL に深く関わる.そこで,再発予防に向けて適切な介入を行うための再発予測は重要となる.これまでにも臨床情報を用い た脳梗塞の再発予測の研究は行われてきているが,画像を用いた成果はまだ少ない.そこで本研究では,MR 画像を用いた脳 梗塞の再発予測を検討した.脳梗塞の再発率は10%を下回るため,近年成熟しつつある深層学習モデルを用いた異常検知アル ゴリズム Semantic Pyramid Anomaly Detection(SPADE)を採用した.SPADE は単純な異常検知だけでなく,画像上のどの領 域がより異常度が高いのかを示すことができることが利点である.2017年~2019年に脳梗塞で国立循環器病研究センターに 入院した患者 66 名(再発例 5 名)の MRI FLAIR 画像を用いて1年以内の再発予測を行った結果,ROC AUC 0.80 が得られた. これにより,FLAIR 画像を用いた異常検知による脳梗塞再発予測の可能性が示唆された. OP14-4 神経メラニン画像を利用した黒質緻密部分類に関する初期的検討

〇伊東 隼人<sup>1</sup>, 小田 昌宏<sup>21</sup>, 斉木 臣二<sup>3</sup>, 鎌形 康司<sup>4</sup>, 石川 景一<sup>4</sup>, 佐光 亘<sup>4</sup>, 服部 信考<sup>4</sup>, 青木 茂樹<sup>4</sup>, 森 健策<sup>1256</sup>

<sup>1</sup>名古屋大学 大学院情報学研究科,<sup>2</sup>名古屋大学 情報連携推進本部,<sup>3</sup>筑波大学 神経内科,<sup>4</sup>順天堂大学 医学部,<sup>5</sup>名 古屋大学 情報基盤センター,<sup>6</sup>国立情報学研究所 医療ビッグデータ研究センター

この高齢化社会において、パーキンソン病は アルツハイマー病に次いで世界で2番目に多い、運動障害を伴う進行性神経変 性疾患である.高齢になるほど発病率が高いパーキンソン病に対し、進行を抑制する根本的な治療は存在しない.しかし、早 期の発見と治療開始により進行を遅らせることが可能である.さらに、神経性疾患発見に対する神経メラニンイメージングの 有効性が報告されている.パーキンソン病の特徴は黒質緻密部におけるドーパミン作動性ニューロンの進行性喪失であり、神 経メラニンは黒質緻密部のドーパミン作動性神経細胞に存在する.そのため、神経メラニンイメージングで得られた黒質緻密 部に関する信号分布(神経メラニン画像)により、パーキンソン病の発見が可能である.本発表では、神経メラニン画像を入 力とした、パーキンソン病であるか否かに関する黒質緻密部分類の初期的検討について報告する.

OP14-5 定量的磁化率マップ QSM のヒト頭部オブリーク撮像:皮質脊髄路の QSM 値の分析

○高橋 哲彦<sup>1</sup>, 星野美紗子<sup>2</sup>, 小島 陸<sup>3</sup>, 駒 萌乃<sup>1</sup>, 丁嵐 亮<sup>1</sup>

<sup>1</sup>群馬県立県民健康科学大学,<sup>2</sup>群馬県立県民健康科学大学(現 上尾中央総合病院),<sup>3</sup>群馬県立県民健康科学大学(現 美原記念病院)

定量的磁化率マップ QSM は、出血と石灰化を識別や、脳の磁化率変化を画像化でき、神経変性疾患の診断の応用が期待されている.早期のアルツハイマー病において、QSM 値は白質と灰白質の広い範囲で変化する.

実臨床で多施設の QSM 値を比較するには,高い再現性と安定性が望まれる.被験者の体位を一定にすることは困難であるが,体位の変化と QSM 値に関する研究はなかった.

本研究では、体位を変えた時の QSM 値を測定し、統計解析を行い解析した。対象は健常者7名(平均年齢 22.1 歳)、使用した MRI 装置は Ingenia 1.5 T、撮像体位は、正常軸断、頭頂上げオブリーク、顎上げオブリークの3体位とした。画像解析ソフトウェアは LiLiby QSM と ImageJ を使用した。解析部位は大脳基底核(尾状核,被殻,淡蒼球など)と白質(皮質脊髄路)とした。統計解析ソフトは R を使用した。有意水準 <0.05 で分散分析と多重比較法の t 検定を行った結果、体位と QSM 値に有意差が認められず概ね安定とわかった。

OP14-6 MobileNetV2の Fine tuning を用いた Neuromelanin 画像からの Parkinson 病進行度の推定

〇奥田 健太<sup>1</sup>, 高橋 洋人<sup>1</sup>, 三浦あづさ<sup>1</sup>, 崎須賀敬央<sup>1</sup>, 綿谷 朋大<sup>1</sup>, 松尾 千聡<sup>1</sup>, 有澤亜津子<sup>1</sup>, 富山 美幸<sup>2</sup>, 佐藤 淳哉<sup>2</sup>, 喜多 洸介<sup>2</sup>, 鈴木 裕紀<sup>2</sup>, 木戸 尚治<sup>2</sup>, 梶山 裕太<sup>3</sup>, 小河 浩太郎<sup>3</sup>, 望月 秀樹<sup>3</sup>, 富山 憲幸<sup>1</sup>

<sup>1</sup>大阪大学医学系研究科 放射線統合医学講座 放射線医学教室,<sup>2</sup>大阪大学医学系研究科 人工知能画像診断学共同研究講座,<sup>3</sup>大阪大学医学系研究科 神経内科学講座

【背景・目的】Parkinson 病(PD)は慢性進行性の神経変性疾患であり、主として筋強剛や振戦等の運動症状を呈する.PD の評価と診断は、本態である中脳黒質線状体の黒質緻密部におけるドパミン産生ニューロンの減少を捉える画像検査法がなく、 主に臨床症状等に基づいて行われてきた、近年、このドパミン産生ニューロンが含む Neuromelaninの量を捉えることができ る新しい磁気共鳴画像(Neuromelanin 画像)が報告され、PDの診断に寄与することが期待されている、本研究は、機械学習 による Neuromelanin 画像の評価が有用であることを示すことを目的として行った.【方法】HY1度から2度の早期PD症例87例、 HY3度から5度の進行期 PD 症例 94 例を対象とした.これらの症例の Neuromelanin 画像に対し特徴を強調するような画像処 理を行なったものを、ImageNet で事前訓練した MobileNetV2 に Fine tuning で学習させ、早期と進行期のどちらであるか推 定させた.【結果】Accuracy 61.0%、AUC 0.645 を得た.【結語】機械学習による Neuromelanin 画像の評価が有用であること が示された.

# 第3会場(7F セミナー室7A)

# 一般演題15

11:10~12:10 **OP15「手術映像**等」

## 座長:中口 俊哉(千葉大学)

小田 昌宏(名古屋大学)

OP15-1 ラベル平滑化を用いた腹腔鏡映像からの手術箇所の認識に関する検討

〇林 雄一郎 <sup>1</sup>, 三澤 一成 <sup>2</sup>, 森 健策 <sup>1.3</sup>

<sup>1</sup>名古屋大学大学院情報学研究科,<sup>2</sup>愛知県がんセンター消化器外科,<sup>3</sup>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,腹腔鏡映像からの手術箇所認識に関する検討について述べる.近年,手術支援のために腹腔鏡映像を解析する研究が行われている.腹腔鏡下胃切除術では,胃周囲の血管を順番に切離するため,腹腔鏡映像から処理を行っている血管を認識することができれば手術支援に応用できると考えられる.そこで,腹腔鏡映像から手術を行っている解剖学的な領域を認識する手法を検討する.提案手法では,畳み込みニューラルネットワーク(CNN)を用い手術箇所の認識を行う.また CNNの 学習の際には,ラベル平滑化により正解ラベルを平滑化して用いる.提案手法を腹腔鏡下胃切除術の腹腔鏡映像に対して適用し,腹腔鏡映像から手術箇所の認識が可能であることを確認した.

OP15-2 Multi-step Fine-tuning for Tracking Invisible Vein during Laparoscopic Surgery

○ ZHAOXINKAI<sup>1</sup>,林 雄一郎<sup>1</sup>,小田 昌宏<sup>21</sup>,北坂 孝幸<sup>3</sup>,三澤 一成<sup>4</sup>,森 健策<sup>156</sup>
 <sup>1</sup>名古屋大学大学院情報学研究科,<sup>2</sup>名古屋大学情報連携推進本部情報戦略室,<sup>3</sup>愛知工業大学情報科学部,<sup>4</sup>愛知県がんセンター,<sup>5</sup>名古屋大学情報基盤センター,<sup>6</sup>国立情報学研究所医療ビッグデータ研究センター

This work involves addressing the challenging task of tracking the invisible left gastric vein (LGV) during laparoscopic surgery. Due to the difficulty in obtaining data and annotations for laparoscopic image, we propose an innovative approach to train tracking network for invisible LGV. To begin, the network is initialized with pre-trained weight from an object tracking model that is well-versed in tracking objects in common scenarios. Subsequently, we employ multi-step fine-tuning to transfer the network's tracking capability from non-medical common objects to the intricate task of tracking the invisible LGV. To our knowledge, this is the first instance of utilizing neural networks to tackle this realistic and demanding healthcare problem. Encouragingly, our experimental results demonstrated that our approach can alert surgeons to the approximate location of invisible LGV.

OP15-3 U-Net を用いた股関節斜視鏡画像からの股関節唇および大腿骨頭の抽出

○川上申之介<sup>1</sup>,福田 紀生<sup>2</sup>,西井 孝<sup>3</sup>,大竹 義人<sup>4</sup>,佐藤 嘉伸<sup>4</sup>
 <sup>1</sup>関西女子短期大学,<sup>2</sup>脳情報通信融合研究センター,<sup>3</sup>大阪急性期・総合医療センター,<sup>4</sup>奈良先端科学技術大学院大

股関節唇の修復手術においては股関節鏡を挿入し手術が行われるが、挿入口であるポータル位置により得られる視認性が影響をうける。そのため良いポータル位置を視認性から判定するために術中の股関節鏡視野中のランドマークとしての大腿骨頭の映り込み割合と、ターゲットである股関節唇の面積を計算する必要がある。そこで我々は1症例の股関節斜視鏡による術中動画から切り出した画像(2428枚)から任意枚数(62枚)を選び作成したマスク画像を正解画像として U-Net により学習させた セグメンテーションモデルをつくり、他の症例の術中動画から切り出した画像(38枚)をテストデータとして股関節唇および大腿骨頭を抽出できるか試行したところ、9枚については正解マスク画像とほぼ一致してセグメンテーションすることができる ことがわかった。学習データとしてさらに様々な種類を追加させることでモデルを強化すれば、より推論精度を上げることが でき、加えて整形外科医による正確なセグメンテーション情報を付加したうえで正解マスク画像を作成できれば、実用的な股 関節唇および大腿骨頭のセグメンテーションができると考え、現在モデルの改良に取り組んでいるのでここに報告する。

## OP15-4 広視野撮影による皮膚毛細血管の多数同時観察とセマンティックセグメンテーションを用いた密 度推定

〇瀧本 麦<sup>1</sup>, 尾藤 宏達<sup>2</sup>, 田口 浩之<sup>3</sup>, 播 さや香<sup>4</sup>, 羽石 秀昭<sup>5</sup>

<sup>1</sup>花王株式会社 解析科学研究所,<sup>2</sup>花王株式会社 コーポレート戦略部門 デジタル事業創造部,<sup>3</sup>花王株式会社 研 究開発部門 研究戦略・企画部,<sup>4</sup>花王株式会社 ヘルス&ウェルネス研究所,<sup>5</sup>千葉大学 フロンティア医工学センター

皮膚毛細血管はキャピラロスコープを用いて非侵襲的に観察でき,その構造と血流は組織や全身の状態を反映しうる.そのため,毛細血管の撮影と画像情報の定量解析は,新規な簡易診断法への発展が期待される.毛細血管の構造は不均一であるため,信頼性の高い評価には,広視野で多数の毛細血管を撮影することが有効である.また,毛細血管の血流は間欠的であるため,静止画ではなく動画の撮影及び解析が望ましい.

そこで本研究では、広い視野と毛細血管観察に十分な空間分解能を有する撮影装置と、本装置で得た動画から毛細血管密度 を自動推定する画像解析法からなるシステムを開発した. セマンティックセグメンテーションを用いた自動解析結果は、手動 解析の結果と相関した. 本システムにより、千本以上の毛細血管の同時観察及び密度算出が可能であった. 算出された密度は 被験者、部位、皮膚バリア破壊前後で異なったことから、組織の状態評価法に繋がりうる.

OP15-5 舌画像解析と機械学習を用いた漢方医学病態予測

〇鈴木萌仁伽<sup>1</sup>,石川 堅也<sup>2</sup>,渡邊 悠紀<sup>3</sup>,並木 隆雄<sup>3</sup>,森田 智<sup>4</sup>,村上 綾<sup>5</sup>,野村 行弘<sup>6</sup>,中 口 俊哉<sup>6</sup>

<sup>1</sup>千葉大学工学部総合工学科医工学コース,<sup>2</sup>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,<sup>3</sup>千葉大学大学 院医学研究院和漢診療学,<sup>4</sup>千葉大学医学部附属病院東洋医学センター墨田漢方研究所,<sup>5</sup>横浜薬科大学薬学教育セン ター,<sup>6</sup>千葉大学フロンティア医工学センター

舌診は舌特徴を捉え, 簡便かつ非侵襲的に健康状態を把握する診断法であるが, 診断者の主観や経験に依存するため, 普遍 的・科学的な所見に向けた定量化が求められている。本研究では, 漢方医学病態のうち水滞に着目し, 舌画像から算出される 特徴量を用いた関連解析および機械学習を用いて病態予測を行った. 136 名の患者の舌画像を医師の診断に基づき水滞, 非水 滞に区分した. 舌の形状, 色彩, テクスチャに関する 307 種類の舌特徴量のうち, 2 群間において 61 種類で統計的有意差を確 認した. また, 病態予測に4種類の機械学習手法の比較を行った. Light Gradient Boosting Machine が最も高い予測性能を示し, 平均 Average Precision は 0.806 を示した. 次に経験の浅い医療従事者との予測性能を比較する実験を実施したところ, 多くの 評価指標で機械学習モデルによる予測が優れた結果を示した. 本研究は機械学習モデルによる水滞予測の有効性を示しており, 医師の診断補助に貢献する可能性が示唆された.

OP15-6 前眼部画像から感染性角膜炎の原因を予測する AI モデルの作成

○ 佐 藤 貴 輝<sup>1</sup>, 奥 村 直 毅<sup>1</sup>, 松 村 拓 弥<sup>1</sup>, SaravanaSangavi<sup>2</sup>, LakshmipathyMeena<sup>2</sup>, SudhirRachapalle<sup>2</sup>, 小泉 範子<sup>1</sup>

<sup>1</sup>同志社大学大学院 生命医科学研究科,<sup>2</sup>Sankara Nethralaya

【目的】感染性角膜炎において前眼部画像から原因を予測できる AI の作成を試みた.

【方法】細菌, 真菌, ウイルス, アカントアメーバによる感染性角膜炎と診断された患者より 336 枚の高解像度の前眼部画像 を取得した. インターネットからも 238 枚の画質の劣る画像を取得した. EfficientNet により画像分類 AI モデルを作成した. 80 枚をテストデータとして AI の性能を評価し, 眼科医 30 名による分類と比較した.

【結果】作成した AI の性能は,正解率 61.2%,適合率 61.7%,再現率 61.3%, F 値 61.2% であった.また,同じテストデータ を眼科医 30 名が分類した場合は,正解率 39.3%,適合率 41.7%,再現率 39.3%, F 値 35.6% であった.

【結論】感染性角膜炎の原因を予測する AI モデルが作成できた.現在, AI の有用性を評価するための臨床研究の準備を進めている.

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:2023年7月27日
発行者:第42回日本医用画像工学会
大会長 木戸 尚治
製作所:トーヨー企画株式会社
# FPA LRSE U-Net を用いた CT 画像からの脊椎領域の自動抽出

木佐貫 航平\*1, 神谷 亨\*1, 寺澤 岳\*2, 青木 隆敏\*2

\*1 九州工業大学 〒804-8550 福岡県北九州市戸畑区仙水町 1-1

\*2 産業医科大学 〒807-0804 福岡県北九州市八幡西区医生ケ丘 1-1

E-mail: kisanuki.kouhei933@mail.kyuetch.jp

# Automatic Extraction of Spinal Region from CT Images Using FPA LRSE U-Net

Kohei KISANUKI<sup>\*1</sup>, Tohru KAMIYA<sup>\*1</sup>, Takashi TERASAWA<sup>\*2</sup>, Takatoshi AOKI<sup>\*2</sup>

<sup>\*1</sup> Kyushu Institute of Technology, 1-1, Sensui, Tobata, Kitakyushu, Fukuoka 804-8550

\*2 University of Occupational and Environmental Health, 1-1, Iseigaoka, Yahatanishi, Kitakyushu,

# Fukuoka 807-0804

要旨:骨転移は悪性腫瘍患者にしばしば合併する.骨転移の管理は、生命予後だけでなく日常生活動作や生活の質にも影響を及ぼ すため、早期発見が重要である.本論文では、同一被験者の過去及び現在のCT画像から脊椎領域の位置合わせを行い、差分演算を 施すことにより、骨転移個所をビジュアライズするためのシステム開発を目的に、深層学習を用いたCT画像における脊椎領域の自 動抽出を目指す.脊椎の小領域の抽出精度の改善を図るため、U-Netのエンコーダの最終層に、異なるスケールのコンテキスト情 報を考慮したアテンションを行う Feature Pyramid Attention モジュールとデコーダに Lightweight Residual Squeeze-and-Excitation を採用したモデルを構築し、10 症例の現在画像を用いた 5 分割交差検証を行い、IoU による抽出精度を求めた結果、 92.0%の精度を得た.

キーワード:セグメンテーション,骨転移,コンピュータ支援診断

#### 1. はじめに

骨は悪性腫瘍の転移臓器のなかで肺や肝に次いで3番目に 多く、骨転移は骨痛・高カルシウム血症・病的骨折・脊髄圧迫 などの骨関連事象が生じた際には患者の日常生活動作や生活 の質に大きな影響を及ぼす[1,2].特に脊椎は、主要な骨転移の 発生部位である上に、脊髄への浸潤・圧排へ繋がりうるため、 早期発見の重要度が高い.

近年,技術の進歩により,医師の診断を支援するための支援 診断システムの開発が期待されている.本論文では,経時的差 分技術により同一被験者の過去・現在画像から脊椎の骨転移個 所を視覚化し,診断を支援するシステムの開発を目的とした前 段階として,セグメンテーション用の深層学習モデルである U-Net[3]に,Feature Pyramid Attention[4]と Lightweight Residual Squeeze-and-Excitation [5]を加えたモデルによる脊椎領域抽出 法を提案する.提案手法を 10 症例の CT 画像に適用し,その 結果と考察について述べる.

#### 2. 手法

過去・現在画像の各脊椎の位置合わせを行うため、CT 画像 から脊椎領域のセグメンテーションを行う必要がある.本論文 では、セマンティックセグメンテーション用の深層学習モデル の一つである U-Net をベースモデルとして脊椎領域の自動抽 出を行う.提案モデルでは、U-Net に Feature Pyramid Attention(FPA) と Lightweight Residual Squeeze-andExcitation(LRSE)を導入した.提案モデルの概要を図1に示す. 医師の指導の下,脊椎領域をラベリングし,学習を行った提案 モデルによりCT画像から,マスク画像を生成する.

# 2.1 Feature Pyramid Attention[4]

Feature Pyramid Attention(FPA)は CNN から抽出された高レベ ルの特徴に対し, ピクセルレベルのアテンションを行うモジュ ールである. FPA はピラミッド構造により異なるスケールのコ ンテキスト情報を段階的に統合することにより, 局所的な情報 を欠落させずにピクセルレベルのアテンションを行うことが できる. FPA は受容野を拡大し, 小さな物体を効率的に分類す ることが可能である. そこで本論文では脊椎の小領域の抽出精 度を改善するため, FPA を U-Net のエンコーダの最終層に導入 する.

#### 2.2 Lightweight Residual Squeeze-and-Excitation[5]

Lightweight Residual Squeeze-and-Excitation(LRSE)は推論速度 を保ちながら正確なセグメンテーションを実現するために提 案された軽量なアテンションモジュールである.本論文では Depth Wise Separable Convolutionによるモデルの軽量化を行い, エンコーダ,デコーダからの特徴に Squeeze and Excitation block(SEBlock) [6]を適用することで重要なチャンネルに重み づけを行い,効率的に特徴を抽出するため,U-Netのデコーダ において VGG ブロックの代わりに LRSE ブロックを導入する.



### 3. 実験

本実験で使用する画像は,産業医科大学病院で収集された画 像である.10症例の脊椎 CT 画像を用い,5分割交差検証を行 い,背景と脊椎の2クラスにおける IoU(Intersection over Union) を評価指標として評価する.ベースモデルである U-Net と提案 手法を比較する.

### 4. 結果と考察

本論文では, CT 画像に対して FPA LRSE U-Net, LRSE U-Net, FPAU-Net, ベースモデルである U-Net を用いて脊椎領域の自 動抽出を行った. FPA U-Net の出力結果から FPA を導入する ことによって脊椎領域の未抽出が改善される傾向が確認され た.脊椎の中心から離れた脊椎の小領域の未抽出が受容野を 拡大する作用のある FPA によって軽減されたことで抽出精度 向上につながったと考える. また LRSE U-Net において LRSE の導入により精度向上がみられた.これはU-Netのスキップコ ネクションにより引き出されるエンコーダからの特徴とデコ ーダからの特徴から重要な特徴を SEBlock[6]によって重み付 けすることで精度向上につながったと考える.また,提案手 法である FPA LRSE U-Net が IoU0.920 となり、最も高い精度 を示した(表1参照).図2の例ではU-Net, FPAU-Net, LRSE U-Net で未抽出であった領域が FPA LRSE U-Net では抽出さ れた.これは FPA によって受容野を拡大したことで獲得され た特徴が LRSE によって強調され、精度向上につながったと 考える.

#### 表 1. 精度評価

т. тт

	100
FPA LRSE U-Net	0.920
FPA U-Net	0.915
LRSE U-Net	0.913
U-Net	0.908







正解画像









U-Net

FPA U-Net 図 2.出力例

LRSE U-Net

# 5. 結論

本論文では, CT 画像から脊椎領域を自動抽出するための手 法の開発を行った結果, IoU92.0%を得た. 今後さらなる抽出性 能向上のため, さらなるデータセットの作成や CT のスライス 幅を変えた場合の検証が必要である. また, 現在・過去画像を 位置合わせし, 差分演算を施すことにより, 骨転移個所をビジ ュアライズするためのシステム開発のため, 位置合わせ手法の 検討が必要である.

#### 謝辞

本研究は, 栢森情報科学振興財団 (K33 研X X VI第 579 号)の助成を受けて遂行された.

#### 利益相反の有無

なし

- Cecchini M. et al.: Molecular and biological mechanisms of bone metastasis, EAU Update Series, Vol.3, No.4, pp.214-226, 2005
- [2] Ibrahim A. et al.: Approval summary for zoledronic acid for treatment of multiple myeloma and cancer bone metastases, Clin Cancer Res, Vol.9, No.7, pp.2394-2399, 2003.
- [3] Ronneberger O. et al.: U-Net: Convolutional networks for biomedical image segmentation, International Conference on Medical Image Computing and Computer-assisted Intervention, pp.234-241, 2015.
- [4] Li H. et al.: Pyramid attention network for semantic segmentation, arXiv preprint arXiv:1805.10180.
- [5]Zhou Q. et al.: LAEDNet: A Lightweight Attention Encoder-Decoder Network for ultrasound medical image segmentation, Computers and Electrical Engineering, Vol.99, No.4, 107777, 2022.
- [6] Hu J. et al.: Squeeze-and-excitation networks, IEEE Trans Pattern Anal Mach Intell, Vol.42, No.8, pp. 2011-2023, 2020

# 体幹部筋骨格の年齢変化統計モデルの構築

龍士郎\*1,政木 勇人\*1,大竹 義人\*1,崇風 まあぜん\*1,上村 圭亮\*2,高尾 坂本 正樹\*3. 明石 敏明\*4,森 健策\*5.6,合田 憲人\*5,菅野 伸彦 \*2,佐藤 嘉伸\*1 \*1 奈良先端科学技術大学院大学 〒639-0192 奈良県生駒市高山町 8916-5 \*2大阪大学大学院医学系研究科 〒565-0871 大阪府吹田市山田丘 2-2 \*3愛媛大学大学院医学系研究科 〒791-0295 愛媛県東温市志津川 \*4 順天堂大学 〒113-8421 東京都文京区本郷 2 丁目 1-1 \*5国立情報学研究所 〒101-8430 東京都千代田区一ツ橋2丁目1-2 \*6名古屋大学 〒464-8601 愛知県名古屋市千種区不老町 Construction of Age-related Statistical Models for Trunk Musculoskeletal Structures Ryushiro Sakamoto<sup>\*1</sup>, Yuto Masaki<sup>\*1</sup>, Yoshito Otake<sup>\*1</sup>, Mazen Soufi<sup>\*1</sup>, Keisuke Uemura<sup>\*2</sup>, Masaki Takao<sup>\*2</sup>, Toshiaki Akashi\*3, Kensaku Mori\*4,5, Kento Aida\*4, Nobuhiko Sugano \*2, Yoshinobu Sato\*1 <sup>\*1</sup>Nara Institute of Science and Technology 8916-5, Takayama, Ikoma, Nara, 630-0192, Japan <sup>\*2</sup>Osaka University Graduate School of Medicine 2-2, Yamadaoka, Suita, Osaka 565-0871, Japan <sup>\*3</sup>Ehime University Graduate School of Medicine 791-0295, Shitsukawa, Toon, Ehime, Japan <sup>\*4</sup> Juntendo University, 2-1-1 Hongo, Bunkyo-ku, Tokyo, 113-8421, Japan <sup>\*5</sup> National Institute of Informatics, 2-1-2 Hitotsubashi, Chiyoda-ku, Tokyo, 101-8430, <sup>\*6</sup> Nagoya University, Furo-cho, Chikusa-ku, Nagoya, Aichi, 464-8601, Japan

要旨: 体幹部筋骨格モデルを構築し,加齢変化に基づく,体幹部筋骨格の変形過程を理解することは,手術計画や生体 力学解析に重要である.本研究では,大規模な CT データベースを用いて,連続的な各年齢の男女別の体幹部筋骨格の 統計形状モデル (SSM)を構築する.J-MID データベースと共同研究施設で収集した 4 万症例以上のデータを活用し, 従来は部分的な骨格形状に限定されていた SSM 構築を,本研究では体幹部の複数の筋骨格構造を含めた SSM の構築を 行う.構築された各年齢の統計形状モデルの性能評価を行い,筋骨格形状の加齢変化について調査する.

キーワード: 大規模 CT データベース,統計形状モデル

# 1. はじめに

人体の骨格形状の解析は今まで様々な研究が行われている. 先行研究では、CT 画像に写る一部の骨格形状から撮影範囲外 の骨格形状を予測する研究が行われている [1]. この研究では 腹部が写っている CT 画像から上半身の解剖学的特徴点(ラ ンドマーク)を予測しているが、全身骨格の予測は行えていな W.

そこで、我々は全身骨格形状の予測と、年齢・性別ごとの全 身骨格形状解析を目指している.本研究ではその前段階とし て、約3万症例以上の体幹部大規模データで年齢・性別ごとに ランドマーク統計形状モデル(Statistical shape model, SSM)を 構築し, 各年齢・性別ごとの体幹部骨格形状の解析および脊椎 形状予測を行った. また,各年齢ごとのランドマーク SSM に加 え,ガウス重みを加えた SSM を作成し,結果を比較した.ランド マークはこれまでに提案されてきた脊椎ランドマークの自動 抽出手法[4]と、我々が提案した骨盤ランドマークの自動抽出 手法[3]を使用した.

# 2. データセット

本研究で使用した CT 画像は, 大規模 CT 画像データベー スである J-MID から、撮影部位に体幹部が撮影された画像を 用いた. 症例数は 28390 例だった(男性: 14327、女性: 14063). 今回使用したデータの年齢性別分布を図1に示す.

解析対象のランドマークは、骨盤部から7点(左右大腿骨頭 中心、左右上前腸骨棘、仙骨上面、恥骨結合)と、脊椎部から 17 点 (T1 から L5 までの椎体重心位置)の計 24 点とした. 使用したランドマーク位置は図2に示す.体幹部 CT 画像から のランドマークは既存手法[3,4]を適用して行われ、本実験で は抽出済みのものを用いた.







図 2. ランドマーク位置

#### 3. 実験内容

JMID にある体幹部 CT から抽出された 24 個のランドマーク を用い,各性別で1 才ごとに SSM を構築した.

本研究では、年齢ごとの学習データの分布の偏りによる影響を吸収するため、対象年齢に加えその周辺年齢のデータを 用い、対象年齢との年齢差に従うガウス重みを用いた weighted PCA による SSM を構築した.また、1 才ごとの SSM の主成分 ベクトルの向きや順番をそろえるため、60 才を基準に隣接する 年齢の SSM 間で主成分ベクトルの内積を計算し高い値の成分 同士を上位成分から下位成分にかけてマッチングし、主成分 ベクトルと対応する主成分スコアをソートした.本実験では重 みづけに用いるガウス分布の標準偏差は 3 とした.各性別で 1 才ごとに通常の PCA で構築した SSM をベースラインとして 比較した.

# 4. 実験結果および考察

60 代から 90 代までの各年代についてベースライン及び Gaussian weighted-PCA[5]に基づく提案手法の SSM について同 じ形状パラメータを与えたときの形状変化を図3に示す.上か ら第1主成分,第2主成分,第3主成分となっており,それぞれ赤 色が2σ,緑色が平均形状,青色が-2σの結果を表している.

ベースラインと提案手法の結果を比較すると,提案手法の方

が形状変化のばらつきが少なく一貫した形状変化の傾向を表 現できている。



5. まとめ

本研究では,JMID の大規模体幹部 CT データベースから抽 出されたランドマークを用い,性別及び年齢ごとのランドマ ーク SSM を構築した.ガウス重みを加えた統計形状モデルの ほうが,各年代間の形状変化のばらつきが少なかった.

今後はよりデータ数を増強すると共に、ランドマークのみな らずメッシュベースでの解析を行い、加齢変化予測のための統 計的な形状モデリング手法の調査を行う予定である.

#### 謝辞

本研究は JSPS 科研費 19H01176,20H04550 の助成を受けた.

#### 利益相反の有無

なし

文 献

- [1] Shouhei Hanaoka, Akinobu Shimizu, Mitsutaka Nemoto, Yukihiro Nomura, Soichiro Miki, Takeharu Yoshikawa, Naoto Hayashi, Kuni Ohtomo, and Yoshitaka Masutani. Automatic detection of over 100 anatomical landmarks in medical CT images: A framework with independent detectors and combinatorial optimization, Medicak Image Analysis, Vol. 35, p192-214, 2017
- [2] Christian Payer, Darko Stern, Horst Bischof, and Martin Urschler. Coarse to fine vertebrae localization and segmentation with spatialconfiguration-net and unet. VISIGRAPP (5:VISAPP), p124–133, 2020.
- [3] 田中雄基. 大規模 CT 画像データベースにおける骨盤形状パラメータ の全自動計測. 奈良先端科学技術大学院大学先端科学技術研究科修士 論文 pp77-87
- [4] Zhuo Cheng, Implementation and Validation of a Platform for Vertebral Alignment Analysis in Large-scale CT Image Database. Nara Institute of Science and Technology Master's Thesis pp5-9

[5] Ludovic Delchambre, Weighted principal component analysis: a weighted covariance eigendecomposition approach, Monthly Notices of the Royal Astronomical Society, Vol.446, 2014

# U-Net を用いた健常膝関節 MR 画像からの半月板領域抽出と損傷例への適用

武智 涼恵\*1, 青山 正人\*1

\*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

# Meniscus segmentation from healthy knee joint MR images using U-Net

# and its application to damaged cases

Suzue TAKECHI<sup>\*1</sup>, Masahito AOYAMA<sup>\*1</sup>

<sup>\*1</sup> Graduate School of Information Sciences, Hiroshima City University

要旨:近年,医用画像からの領域抽出では,Convolutional Neural Network (CNN)を用いた手法が多く提案されているが,CNNの 学習には多くの学習症例が必要とされている.本研究で対象とする半月板領域抽出では,三次元の健常膝関節 MR 画像 20 症例,損 傷5 症例と,少数の画像データを扱う.そこで,Coronal 断面でリスライスした二次元画像データを入力とする U-Net により学習モ デルを構築した.

領域抽出結果は5分割交差検証で評価した. バッチサイズ12, エポック80の設定で得られたDice係数は0.721±0.028(平均±標準偏差)であった.最もDice係数の平均値が高かった(0.767)分割時の学習モデルを用いて損傷5症例の半月板領域を抽出したところ0.720±0.058であった. このことから少数の健常例のみで学習したモデルでも損傷半月板の抽出がある程度可能であることが確認できた.

キーワード:医用画像診断支援,コンピュータ診断支援,深層学習,ニューラルネットワーク,U-Net

#### 1. はじめに

三次元画像データから臓器のセグメンテーションを行うた めの Convolutional Neural Network (CNN) として, Çiçek らの 3D U-Net [1] や Millerari らが提案した V-Net [2] などが存 在する.これらのネットワークを活用するには多くの症例が必 要とされる.一方,本研究で対象とする膝関節領域の疾患診断 に用いられる MRI でも三次元画像としてデータが得られるが, 多くの症例を用意することは容易ではない.

そこで本稿では、少数症例の膝関節 MR 画像から U-Net [3] を用いて半月板領域の抽出と評価を行った結果を報告する.本 手法ではまず、U-Net への入力として、実験に基づいて決定し た Coronal 断面でリスライスした二次元画像データを用い、20 症例の健常データから 5 分割交差検証を用いて学習モデルを 構築するとともに抽出結果を評価した.次に、健常データで構 築したモデルに、破格例としての円板状半月板や、損傷半月板 といった損傷 5 症例を適用して領域抽出を試みた結果につい ても述べる.なお、本研究は広島市立大学倫理審査委員会の承 認を得て実施している.

# 2. 提案手法

5 層の U-Net に,図1 に示すような Coronal 断面の二次元健 常膝関節画像(原画像,320×60 ピクセル)と二次元ラベル画

\*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 〔〒731-3194 広島市安佐南区大塚東三丁目 4-1〕 e-mail:mh69004@e.hiroshima-cu.ac.jp 像(ラベル画像,320×60ピクセル)を入力して学習し,原画 像の各画素が半月板領域である確率を出力する.20症例(左 13症例,右7症例)の原画像とラベル画像の組をランダムに4 症例ずつ5グループに分割する.このうち3グループをトレー ニング用,1グループをバリデーション用画像としてネットワ ークモデルを作成する.作成したネットワークモデルに,残る 1グループをテスト用画像として用いて評価する.これら5グ ループを循環させて5分割交差検証を行う.ネットワークのモ デル構成は学習を10回繰り返す(10エポック)ごとに行い, 200エポックまで続ける.ここで,各画像はネットワークに入 力する際に,320×60ピクセルから64×64ピクセルに圧縮さ れる.また,出力の際の画像サイズも64×64ピクセルとなる ため,出力された半月板抽出濃淡画像(以下,濃淡画像)を320 ×60ピクセルへリサイズしている.

さらに,取得した濃淡画像の二値化を,大津の二値化を用い て行う(以下,抽出画像).この時,モデルからの出力は二次 元画像になるため,症例ごとに三次元構成を行う.

最後に,抽出画像に対して正解ラベル画像を用いて Dice 係数で評価する.このときテスト用画像のグループごとの評価において,最も Dice 係数の平均値が高かった(0.767) エポック80 を本手法でのモデル構成におけるエポックとした.



原画像(320×60 ピクセル) ラベル画像(320×60 ピクセル)図1 : 膝関節 MR 画像の一例 (Coronal 断面)

# 3. 実験·結果

エポック数 80, バッチサイズ 12, 最適化関数に Adam を用 いた条件で提案手法に則り実験を行った.表1に5分割交差検 証の中で最も Dice 係数が高かった分割のモデルからの健常例 の抽出精度を,表2 に同モデルからの損傷例の抽出精度を示 す.また,図2,3に表1におけるh-2,h-4の抽出結果を,図 4,5に表2におけるd-3,d-4の抽出結果を示す.図中,赤色 が抽出領域,緑色が正解ラベル領域,黄色が重複領域(正解し た部分)とする.

主1. 健労個の Diag 低粉

	我 I: 庭市内の Dicc	小妖
	症例	Dice 係数
	h-1(左)	0.766
	h-2(左)	0.807
	h-3 (右)	0.774
	h-4(左)	0.722
	平均±標準偏差	0.767±0.030
	表 2:損傷例の Dice	係数
	症例	Dice 係数
<b>d-</b> 1	(円板状,左)	0.751
d-2	(円板状,右)	0.743
d-3	(円板状, 左)	0.766
d-4	(内側体部-後節損傷,右)	0.605
d-5	(外側切除, 左)	0.733
	平均±標準偏差	0.720±0.058





図 2:h-2(左)の抽出結果 (Dice 係数 0.807)





図3:h-4(左)の抽出結果

図4:d-3の抽出結果 (Dice 係数 0.766)

図 5 : d-4 の抽出結果 (Dice 係数 0.605)

# 4. 考察

表1より、健常例に対して提案手法を用いた際の Dice 係数

の平均±標準偏差は 0.767±0.030 であった. 図 2,3 に Dice 係 数が最高,最低となった症例の抽出結果を示す.図 2,3 にお いて,半月板領域周辺に過抽出領域が,半月板辺縁部分には未 抽出領域が確認された.過抽出領域については,周辺や,root と呼ばれる半月板の先端付近に同程度の輝度値を持つ靭帯等 の組織が存在するためと考えられ,未抽出領域については,症 例間の個体差が大きい部分であるため,現段階の学習での正確 な抽出は難しいと考えられる.特に図3に関しては,半月板の 縁に沿って過抽出領域が目立つことと,図中左上部の正解ラベ ル領域が特異的な形をしていることに対応できていないため と推測される.

表2より,健常例のみで作成した学習モデルに損傷5症例を 適用した際の Dice 係数の平均±標準偏差は 0.720±0.058 であ った.図4において,円板状半月板の特徴が抽出できているこ とが確認できた.図5においては,図中右側の半月板領域の中 央付近から下側にかけての損傷部分に未抽出領域が目立つこ とが確認できる.これは,原画像の半月板領域内に存在する損 傷による高輝度値領域が,健常例のみでの学習モデルからの抽 出に影響を与えたためと考えられる.

# 5. まとめ

本稿では、三次元の健常膝関節 MR 画像からの半月板領域抽 出を目的として、Coronal 断面の二次元画像を入力とする U-Net のモデル構築と、5 分割交差検証を用いた評価を行った.この ときの Dice 係数は 0.721±0.028 (平均±標準偏差)となり、最 も Dice 係数の平均値が高かった分割では 0.767±0.030 となっ た.また、この分割で構築した学習モデルに損傷例を適用した 場合の Dice 係数は 0.720±0.058 となった.このことから、少数 の健常例のみで学習したモデルでも損傷半月板の抽出がある 程度可能であることが確認できた.今後は半月板領域辺縁など の抽出精度の向上を目指す.

#### 謝辞

膝関節 MR 画像を提供して頂いた,北村直幸 霞クリニッ ク院長,上田英弘 霞クリニック技師長に感謝いたします.

### 利益相反の有無

なし

- Özgün Çiçek, et al. : " 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation", MICCAI, Springer, LNCS, Vol. 9901: 424-432, 2016
- [2] F.Milletari, et al. : "V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation", Fourth Int'l Conf. on 3D Vision, pp. 565-571, 2016
- [3] Olaf Ronneberger, et al.: "U-Net: Convolutional Networks for Biomedical Image Segmentation", MICCAI, Springer, LNCS, Vol. 9351: 234-241, 2015

# 超音波による複数パノラマ断層撮影と統計形状モデルフィッティングを用いた患者個 別下肢全体筋骨格形状の予測

富木田 悠生\*1, 政木 勇人\*1, 大竹 義人\*1, 崇風 まあぜん\*1,

上村 圭亮\*2,高尾 正樹\*3, 菅野 伸彦\*2, 佐藤 嘉伸\*1

\*1 奈良先端科学技術大学院大学 〒639-0192 奈良県生駒市高山町 8916-5

\*2大阪大学大学院医学系研究科〒565-0871 大阪府吹田市山田丘 2-2

\*3愛媛大学大学院医学系研究科〒791-0295 愛媛県東温市志津川

English Title Prediction of individual patient's whole lower limb musculoskeletal shape using multiple

panoramic tomography with ultrasound and statistical shape model fitting

Haruki Fukita<sup>\*1</sup>, Yuto Masaki<sup>\*1</sup>, Yoshito Otake<sup>\*1</sup>, Mazen Soufi<sup>\*1</sup>,

Keisuke Uemura<sup>\*2</sup>, Masaki Takao<sup>\*3</sup>, Nobuhiko Sugano<sup>\*2</sup>, Yoshinobu Sato<sup>\*1</sup>,

<sup>\*1</sup>Nara Institute of Science and Technology 8916-5, Takayama, Ikoma, Nara, 630-0192, Japan

<sup>\*2</sup>Osaka University Graduate School of Medicine 2-2, Yamadaoka, Suita, Osaka 565-0871, Japan

<sup>\*3</sup>Ehime University Graduate School of Medicine 791-0295, Shitsukawa, Toon, Ehime, Japan

要旨: 超音波画像診断装置は, 非侵襲・短時間で撮影可能であり高時間高分解能な画像が取得できるため, 筋肉の解析に適したモダ リティである. しかし, 撮影範囲には制限があり, 3 次元的な解析が困難である. そこで本研究では下肢を撮像した複数のパノラマ超 音波断面を用いて, 下肢全体の筋骨格の形状を予測することを目的とする. 具体的には, パノラマ超音波の複数断面の撮像には, モー ションキャプチャーを用いて, パノラマ断面とそれに対応する位置情報を取得する. 筋骨格の形状予測には, CT データベースを用い て統計形状モデルを構築し, 構築したモデルと取得したデータを用いることで, 筋骨格の形状を予測し, 推定精度を求めるため, 1 人 の被験者から得られた同一箇所の 3 次元 MRI 画像と複数の超音波パノラマ断面を用いて, 定量的な評価を行う. この手法により, パ ノラマ超音波画像を複数取得するだけで, 広範囲の筋骨格形状を取得することが可能となる. キーワード: 超音波画像,モーションキャプチャー, CT データベース,統計形状モデル(5 語以内)

# 1. はじめに

超音波画像診断装置は,非侵襲・短時間で撮影可能であり高 時間高分解能な画像が取得できるため,筋肉の解析に適したモ ダリティである.しかし,その撮影範囲は狭く,筋肉全体の解析 が困難であるため,広範囲の筋形状を観察する研究が広く行わ れている.2次元の解析に関しては,パノラマ超音波画像に関 する研究が行われている.こちらは超音波画像を複数枚つなげ ることにより,撮影範囲が拡張されており,有効性が示されて いる[1].3次元の解析に関しては、フリーハンドによる3次元 超音波画像再構成に関する研究が行われている.こちらは,位 置センサを用いて,撮影した2次元画像の相対的な位置を計算 することにより、3次元画像の再構成を行っている.近年では、 機械学習を用いた再構成の研究もおこなわれており, コストの 高い位置センサを使わずに,再構成を可能としている[2].しか し,撮影者のプローブの走査に依存するため,高精度の再構成 が困難である.そこで本研究では,複数のパノラマ超音波 断層と CT 画像の統計形状モデルフィッティングを用い た肢筋骨格3次元形状の予測を行う.本稿では,パノラマ超音 波断層撮影のためのシステムを構築したのでこれを報告する.

# 2. 撮影方法

本研究では、複数のパノラマ超音波画像とそれに対応する 位置情報を取得することで予測を行う.そこで、本システムで は、高精度な位置センサとして NaturalPoint 社が提供してい る光学式モーションキャプチャーシステムである OptiTrack を用いた.撮影方法として、超音波画像診断装置のプローブに 剛体ボディを取り付けてBモードでの撮影を行う.これにより 超音波画像とそれに対応するプローブの位置、姿勢情報が可能 となる.



図1.パノラマ超音波画像の撮影位置



図 2. ランドマークの位置

# 3. 実験方法

構築したパノラマ超音波画像撮影システムの精度検証を行 うため、被験者1人の右足大腿部を撮影した.撮影者には、撮影 前に医療用バンドとランドマーク用のマーカを取り付けてい ただいた.撮影は図1に示すように、赤い矢印に沿って撮影を 行った.ランドマークの位置を図2に示す.ランドマークは、右 上前腸骨棘(黄),膝関節点(赤),膝蓋骨中央点(緑),脛骨 点(ピンク)に取り付けて撮影を行った[3].なお、撮影時の OptiTrackのキャリブレーション時の平均誤差は、0.145mm で あった.

本実験では、精度検証の際に、MRI 画像を用いた.この MRI 画 像は大阪大学病院で撮影された同一被験者の MRI 画像であ る.MRI 画像には、超音波画像撮影時と、同一のランドマークを 手動で設定し、ランドマークをもとにした剛体位置合わせを行 った.剛体位置合わせの結果から、1枚の超音波断面に対応す る MRI 画像の断面を取得し、それぞれ手動でセグメンテーショ ンを行うことで、比較した.なお今回は、大腿骨(白)、大腿直筋 (赤)、外側広筋と内側広筋(緑)、中間広筋(青)、縫工筋(黄)、 内転筋(ピンク)の6クラスでセグメンテーションを行った.

#### 4. 実験結果および考察

図2にランドマークの剛体位置合わせの結果と MRI 画像と パノラマ超音波画像の重ね合わせ結果を示す.赤色の線で結ば れたものが超音波画像撮影の際のランドマーク,緑の線で結ば れたものが MRI 画像に手動で設定したものである.対応するラ ンドマークの平均的な誤差は 26mmであった.これは, MRI 画 像の手動でのランドマークの設定をする際にずれが生じたと 考えられる.図3の上段に作成した超音波画像と同じ位置の MRI 画像の断面,下段にそれぞれの手動セグメンテーション結 果を示す.2 つの画像を比較して見ると,大まかな筋骨格の解 剖学的構造は,類似している.しかし,超音波画像の内側広筋 (青)付近の中心部分で筋組織の境界があいまいになっている ことが分かった.これは超音波画像診断が体表面から深い部分 の情報が得られにくいことが原因であり,画像間の合成の際に, 1枚ごとの深部が多く反映していたことが考えられる.





図 3.ランドマークの剛体位置合わせ(左) と超音波画像と MRI 画像の重ね合わせ結果(右)



図 4.超音波画像と MRI 画像断面(上段)と セグメンテーション結果(下段)

#### 5.まとめ

本稿では,パノラマ超音波画像撮影システムの構築と評価を 行った.パノラマ超音波画像と MRI 画像を比較すると,超音 波画像の筋組織の境界があいまいになっている部分があり, 見直す必要があることが判明した.今後は,システムの見直 しを行いながら,CT 画像の統計形状モデルを作成し,フィッ テイングを行うことで,筋骨格の形状予測を行う予定である.

#### 謝辞

本研究は JSPS 科研費 19H01176, 20H04550 の助成を受けた.

#### 利益相反の有無

なし

- Jessica M. Scott, David S. Martin, Robert Ploutz-Snyder1 et al : Panoramic ultrasound: a novel and valid tool for monitoring change in muscle mass Journal of Cachexia, Sarcopenia and Muscle 8: 475-481, 2017
- [2] Jiahui Dong, Tianyu Fu, Yucong Lin et al: Hole-filling based on content loss indexed 3D partial convolution network for freehand ultrasound reconstruction Computer Methods and Programs in Biomedicine 221: 106421, 2021
- [3] 人間生活工学研究センター:日本の人体寸法データベース 2004-2006

# 深層学習を用いた側弯症レントゲン画像の自動計測

藤森 孝人\*1, 鈴木 裕紀\*2, 中嶋 望\*3, 喜多 洸介\*1.2 木戸尚治 2

\*1 大阪大学大学院医学系研究科器官制御外科学整形外科

\*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

\*3 市立堺病院学整形外科

# English Title Automated Measurement of Spinal Alignment for Scoliosis Using Deep Learning

Takahito FUJIMORI<sup>\*1</sup>, Yuki SUZUKI<sup>\*2</sup>, Nozomu NKAJIMA <sup>\*3</sup>, Kousuke KITA<sup>\*1,2</sup>, Shoji KIDO

<sup>\*1</sup> Department of Orthopedic Surgery, Graduate School of Medicine, Osaka University

<sup>\*2</sup>Department of Artificial Intelligence Diagnostic Radiology, Graduate School of Medicine,

**Q***aka* University

要旨: 側弯症患者における単純 X 線画像の計測項目の測定を自動化することを目的とした. 大阪大学附属病院において全脊柱 X 線画像を撮影した側弯症患者の X 線画像 428 例 1054 枚(正面像 553 枚、側面像 501 枚)を対象とした. 各画像において 2 名 の脊椎外科医が C7 から S1 椎体の 4 隅角をラベリングし, これを Ground truth とした. データセットは 5 分割交差法によってトレーニングデータとテストデータに分割し AI モデルに学習させた. AI モデルによって計測された計測値と Ground truth との誤 差を検証した. 計測角度における平均絶対誤差は 3.2°から 5.3°であった。Ground truth と AI 計測値の相関係数は 0.99 から 0.89 であった. 画像診断における補助ツールとして使用することで,診療における負担軽減が期待できる有用なツールとな りえる.

キーワード:深層学習, 側弯症, 自動計測, AI,

# 1. はじめに

側弯症は、脊柱の変形を主体とする疾患であり、病態の把握 にレントゲン計測は必須である。しかし、脊柱全体が罹患する ため、計測項目が多い。そのため、すべての計測項目を手作業 で計測することは、多大な労力を伴う。今回我々は、深層学習 を用いて、計測に必要な椎骨を認識させ、自動計測を行うシス テムを開発したため、報告する[1]。

### 2. 方法

大阪大学付属病院にて 2009年から2021年に撮影された特発性側弯症患者、434名 の全脊柱レントゲン画像1197 枚(正面,696枚,側面501枚) を対象とした.2人の整形外科 医が、第7頸椎から仙骨まで の19の椎骨の4頂点(仙骨は 頭側のみ)、合計74点をマー



キングした. このマーキングは、フリーソフトの LabelMe を用 いて行った. 100 例程マーキングした後に,一旦 AI に学習させ、 学習した AI に残りの症例に点を打たせた. AI のマーキングを 人間が修正し,修正した画像をさらに AI に学習させた。これ を数回繰り返し,最終的にすべての症例にマーキングを行っ た. すべての症例を人間が 2 人で確認し,修正を行い,このマ ーキング位置を Ground truth とした. CNN モデルは DeepLabV3 を使用した。角度の計測は Python version 3.5 と PyTorch version 1.8.1.を用いて実装された。CNN の計測と Ground truth の計測の絶対誤差を5分割交差検証で求めた。



#### ,加不

【基本データ】

対象患者の平均年齢は 16 才, 男女比は 1:10 であった. 術後画 像が 248 枚(正面 143 枚、側面 105 枚)含まれていた. Ground truth に基づく正面像の計測値は平均で, Cobb 角において Main thoracic curve で 29°, Proximal thoracic curve で 17°, Thoracolumbar/Lumbar curve で 21°であった. Ground truth に基づく側面像の計測値は平均, Thoracic kyphosis 31°, Lumbar lordosis -49°, Sacral slope 36°であった.

【絶対誤差】AIの計測と Ground truth の絶対誤差,相関係数は それぞれ, Main thoracic で 3.2°r ⊕.9Proximal thoracic で 3.2° r = 0.9, Thoracolumbar/Lumbar curve で 3.0°r =0.97 であった.

側面像における, AI の計測と Ground truth の絶対誤差,相関 係数はそれぞれ, Thoracic kyphosis で  $4.4^{\circ}$  r =0.89 Lumbar lordosis で  $5.3^{\circ}$  r = 0.83, Sacral slope で  $4.3^{\circ}$  r = 0.72 であった.

### 【計測時間】

1 枚だけを計測するとき, 8-core CPU のみを使用し約 1.4 秒 であった。バッチ(並列)処理(CPU と GPU を使用)のときは 32core CPU と RTX 3090 GPU を使用し、1 秒あたり画像 10.3 枚 (1 枚あたり 0.0971 秒)であった。



# 4. 考察

一般に、脊柱レントゲン画像のマニュアル計測では、角度の誤 差が 3~8 度程度あるとされている[2]. 今回, 我々の構築した AI モデルは, 正面像の主カーブの計測において, 平均絶対誤 差が 3.2°であり, 人間に遜色ない結果となった.ただし、主カ ーブ以外の計測においてはやや誤差が大きく改善が必要であ ると考えられた. 特に側面像, 骨盤を含む場合の計測項目にお いて誤差が大きくなった. 理由としてはこれらの部位は人間 にとっても視認し難い形状であり,その Ground Truth のバラつ きが A I の計測に反映されたと考えれた. 同様に脊柱変形が 高度の場合,その症例数が少なく,結果,学習データ不足のため 誤差が大きくなる傾向があると考えられた.

一方, 計測時間は早く,人間を遥かに上回っていた.すべての計測項目を測定すると人間は数分を要するが AI は1秒未満 で計測が可能であった.

AI は臨床上有用なツールとなり、今後は AI がまず計測を行い 医師はその結果を確認するという方式になると考えられる.

#### 謝辞

本研究は JSPS 科研費 JP22K09353 の助成を受けたものです.

#### 利益相反の有無

なし

- Fujimori T, Suzuki yTakenaka S, et al. Development of artificial intelligence for automated measurement of cervical lordosis on lateral radiographs. Sci Rep. 2022;12(1):15732.
- [2] Morrissy RT, Goldsmith GS, Hall EC, Kehl D, Cowie GH. Measurement of the Cobb angle on radiographs of patients who have scoliosis. Evaluation of intrinsic error. J Bone Joint Surg Am. 1972(3):320 -7.

# 注意機構を用いた畳み込みニューラルネットワークによる胸部 X 線画像から骨密度の推定

岩尾 佳幸\*1, 沙月 剣志\*1, 橋本 二三生\*2, 落合 昂大\*1, 畑中 裕司\*3,

賀川 経夫\*3, 永田 亮一\*3, 衞藤 路弘\*4.5, 吉田 幸人\*1

\*1 大分大学医学部附属病院医用技術部放射線部門

\*2 千葉大学大学院融合理工学府

\*3 大分大学理工学部

\*4 日本文理大学保健医療学部保健医療学科診療放射線学コース

\*5 大分大学大学院工学研究科

# Prediction of Bone Mineral Density from Chest X-ray Image by Convolutional Neural Network Combined with Attention Mechanism

Yoshiyuki IWAO<sup>\*1</sup>, Kenshi SHIOTSUKI<sup>\*1</sup>, Fumio HASHIMOTO<sup>\*2</sup>, Takahiro OCHIAI<sup>\*1</sup>, Yuji HATANAKA<sup>\*3</sup>,

Tsuneo KAGAWA<sup>\*3</sup>, Ryoichi NAGATA<sup>\*3</sup>, Michihiro ETOU<sup>\*4,5</sup>, Yukito YOSHIDA<sup>\*1</sup>

<sup>\*1</sup> Medical Technology Department, Oita University Hospital

<sup>\*2</sup> Graduate School of Science and Engineering, Chiba University

\*3 Faculty of Science and Technology, Oita University

<sup>\*4</sup> Nippon Bunri University School of Health Sciences Department of Health Sciences

<sup>\*5</sup> Graduate School of Engineering, Oita University

要旨:本研究の目的は, 畳み込みニューラルネットワークに注意機構を組み合わせた深層学習モデルを用いて, 胸部 X 線画像から 骨密度を推定するスクリーニング手法を開発することである. DXA 法を用いて腰椎の骨密度を測定する検査, および胸部 X 線検 査を受けた患者を対象とした. 畳み込みニューラルネットワークの ResNet50 に注意機構を組み合わせた深層学習モデルを用いて, 胸部 X 線画像から骨密度の推定を行なった. 5 分割交差検証を用いてモデルの精度評価を行い, DXA 法により測定した骨密度との 相関を回帰分析により求めた. Bland-Altman 分析により, DXA 法により測定した骨密度と, 深層学習により推定した骨密度の一致 性を評価した. DXA 法および深層学習を用いて推定した骨密度の相関係数は 0.769 を示した. Bland-Altman 分析において, 96%の 患者が一致限界の範囲内に収まった. 畳み込みニューラルネットワークに注意機構を組み合わせることで, DXA 法と高い相関を持 つ骨密度の推定が可能であることが示された.

キーワード:注意機構,深層学習,胸部X線画像,骨密度,骨粗鬆症

# 1. はじめに

骨粗鬆症は、骨量低下と骨組織の微細構造の異常により骨折 のリスクが増大した状態であり、骨折に伴う quality of life の低 下が懸念される.骨粗鬆症の早期発見、治療は quality of life の 保持に重要であるが、骨粗鬆症のスクリーニング検査を受ける 機会は少ない[1].そこで、最も検査件数の多い胸部 X 線画像 を用いた簡便なスクリーニング方法が報告されている[2].近 年では、胸部 X 線画像を用いた骨粗鬆症のスクリーニングに 対し、深層学習を利用したコンピュータ支援診断法が提案され [3]、精度の向上に向けた取り組みも行われている[4].これ らの技術は、医師の労力や読影能力のばらつきの軽減が期待で きる一方で、深層学習の判断根拠が乏しく、臨床応用への妨げ となっている.

そこで本研究では, 畳み込みニューラルネットワークが注視

した領域を可視化するだけでなく,精度向上にも利用できる注 意機構を組み合わせた Attention branch network [5,6]を用いて, 胸部 X 線画像から骨密度(Bone Mineral Density: BMD)を推定 するスクリーニング手法を開発することを目的とする.

# 2. 方法

対象は, 腰椎の BMD 測定, および胸部 X 線検査を行なっ た 20 歳以上の患者 522 人とした.本研究は, 倫理委員会の承 認を受け実施した. 胸部 X 線画像は, 立位後前方向で撮影さ れた画像を用いた.また, 胸部 X 線画像に対する正解ラベル には, 二重エネルギーX 線吸収測定法 (Dual energy X-ray Absorptiometry: DXA) 法を用いて測定した腰椎の BMD (BMDg) を用いた.データセットは, 学習および検証に 422 枚, テストに 100 枚を利用し, 学習時にはデータ拡張を行な った.



図1. 畳み込みニューラルネットワークに注意機構を 組み合わせた深層学習モデル

畳み込みニューラルネットワークには, ResNet50 に注意機 構を組み合わせた Attention branch network (図1)を用いた. 本ネットワークでは、前半の ResNet50 で特徴抽出を行った 後, Attention branch で Attention map を生成する. その後, ResNet50から出力された特徴マップを,注意機構を用いて注 視領域を強調した後, Perception branch で推論を行う.本研究 では,以下に示す損失関数 L が最小となるように学習を行っ た.

 $L = MSE(BMD_{at}, Output_{att}) + MSE(BMD_{at}, Output_{per}), (1)$ 

ここで, MSE は Attention branch の出力 (Output<sub>att</sub>), もしく は Perception branch の出力(Outputper) と正解ラベル BMDgt に 対する平均二乗誤差である.なお、本研究では胸部 X 線画像 を入力画像, Perception branch の出力値を BMD の推定値とし, 学習および検証用データセットを用いて 5 分割交差検証を行 なった.精度評価は、テスト用データセットを用い、BMD<sub>et</sub>に 対する Outputper の相関を回帰分析により求めた. また, Bland-Altman 分析により, BMDgt に対する Outputper の一致性を評価 した.

### 3. 結果

BMDgt に対する Outputper の関係を図 2 に示す. 相関係数は 0.769 を示し、胸部 X 線画像、年齢および性別を用いてアンサ ンブル学習を行った先行研究(R=0.63) [4] よりも、高い相関 が得られた. Bland-Altman 分析の結果を図3に示す.96%の患 者が一致限界の範囲内に収まった.

### 4. 結論

畳み込みニューラルネットワークに注意機構を組み合わせ ることで、DXA 法と高い相関を持つ BMD の推定が可能であ ることが示された.





# 利益相反の有無

なし

- 文 献
- [1] 堀場一輝, 村松千左子, 林達郎, 他: 歯科パノラマ X 線写真を用いた 骨粗鬆症早期発見のための下顎皮質骨自動厚み計測法の開発. Med Imag Tech 32(5):342-346, 2014
- [2] 石川真帆,山本浩一,松沢博明,他:胸部単純 X 線画像を利用した骨 粗鬆症のスクリーニング. 医用画像情報学会雑誌 35(2):30-34, 2018
- [3] Wang F, Zheng K, Lu L et al: Lumbar Bone Density Estimation From Chest X-Ray Images: Anatomy-Aware Attentive Multi-ROI Modeling. IEEE Trans Med Imag 42: 257-267, 2023
- [4] Sato Y, Yamamoto N, Inagaki N, et al: Deep Learning for Bone Mineral Density and T-Score Prediction from Chest X-rays: A Multicenter Study. Biomedicines 10(9):2323, 2022
- [5] Fukui H, Hirakawa T, Yamashita T, et al: Attention Branch Network: Learning of Attention Mechanism for Visual Explanation. arXiv:1812.10025v2, 2019
- [6] Sukegawa S, Yoshii K, Hara T, et al: Is attention branch network effective in classifying dental implants from panoramic radiograph images by deep learning? PLoS ONE 17(7): e0269016, 2022

# 乳がん CAD 併用読影における画像診断学習システムの開発とその有効性評価

菅原 暉典<sup>\*1</sup>, 安倍 和弥<sup>\*1</sup>, 武尾 英哉<sup>\*1</sup>, 縄野 繁<sup>\*2</sup>

\*1神奈川工科大学大学院工学研究科電気電子工学専攻

\*2 新松戸中央総合病院

# Development of an Interpretation System for Diagnostic Imaging Methods in CAD Combined Reading of Breast Cancer and Its Evaluation

Akinori SUGAWARA<sup>\*1</sup>, Kazuya ABE<sup>\*1</sup>, Hideya TAKEO<sup>\*1</sup>, Shigeru NAWANO<sup>\*2</sup>

\*1 Graduate School of Electronic & Electrical Engineering, Kanagawa Institute of Technology

\*2 Shimmatsudo Central General Hospital

要旨:一般的に, 医学生や研修医や経験の浅い医師は, 典型的な症例や特徴的な症例を集めた画像症例集を利用して読影法を学ん でいく.しかし CAD の普及により,画像だけでなく CAD の異常陰影候補検出結果も参考にしながら最終的な診断を下すことにな る.そこで本研究では, CAD 併用を前提とした読影法における画像診断法学習システムを提案する.さらに, 特定の病院に導入さ れた CAD システムがその病院の画像を用いて追加学習を行い進化していく場合を想定し, CAD の進化に伴いこの画像診断学習シ ステムも強化されていく仕組みも合わせて提案する.そして,本学習法で学んだ場合とそうでない場合の読影性能を読影実験によ り比較し,本提案システムの有効性を確認する.読影実験の結果は,学習を全く行わない場合の AUC は 0.65.従来のティーチング ファイルで学習した場合の AUC は 0.71 であった.本研究で提案する学習システムを用いた場合の AUC は 0.81 と 3 つの学習法の中 で最も向上した.

キーワード: ティーチングファイル, 読影, 乳がん腫瘤影, CAD

# 1. はじめに

一般的に, 医学生や研修医や経験の浅い医師は, 典型的な症 例や特徴的な症例を集めた画像症例集, いわゆるティーチング ファイルを利用して画像診断の読影法を学んでいく[1]. しか し, CAD (コンピュータ支援診断)の普及により, 画像だけで なく CAD の異常陰影検出結果も参考にしながら最終的な診断 を下すことになる. 現在, そのような診断法における読影学習 システムは存在しない. そこで本研究では, CAD 併用を前提 とした読影法における画像診断法学習システムを提案する。さ らに, 特定の病院に導入された CAD システムがその病院の画 像を用いて追加学習を行い進化していく場合を想定し, CAD の進化に伴いこの画像診断法学習システムも強化されていく 仕組みも提案する. CAD の進化に伴い, 画像診断法学習シス テムのティーチングファイルも増えていくものである. そして, 本学習法で学んだ場合とそうでない場合における読影性能を 読影実験により比較し, 本提案システムの有効性を確認する.

# 2. 提案するシステム導入後の流れ

CAD 診断システムを病院に導入後,CAD システムの診断結 果及び医者の診断画像をティーチングファイルとし一年間累 積をする. その後一年間蓄積した医者の診断画像を教師デー タとして CAD の学習を行い,CAD の性能の強化を行う[2].現 場の医師や研修医は導入されたティーチングファイルで学習 をすることで,CAD の癖や導入された病院に沿った読影の学習 も行うことが可能となった.本システムは診断画像をデータで 扱うことで 10 年 20 年と画像枚数が増えても保管場所を取る こともなく,ティーチングファイルの情報量も増やすことが出 来る.

### 3. 実験

#### 3.1 読影実験に使用する CAD システム

今回の CAD システムについては、乳房のマンモグラフィ画 像(腫瘤影画像)を対象としており、主に癌センター東など国 内で撮影された5施設から収集した 550 画像から構成されて いる.自動セグメンテーションの処理に Yolov5[3]を利用した. 実験で使用した CAD の性能は、未知症例 50 例(1患者につき 左右2方向の4画像なので計200画像)に対し、学習用の真陽 性率が 86%であり偽陽性数/画像数[個]は、0.505 である.評価 用 Yolo 真陽性率 91%で偽陽性数/画像数[個]は、0.24 である.

#### 3.2 読影実験の方法

本研究では、3 つのパターンでの読影実験の詳細を表1に示 す.学習の記憶が実験結果に影響するのを防ぐため、2 か月程 度の期間を空ける.実験対象者は医療画像を学んでいる学生 14 人である.評価に使用する画像は全てのパターンで同様に、 200 枚である.実験場所は研究室で行い、カーテンを閉め、電 気を消し、光や太陽光の影響がなく画像が見やすい空間で行う. 未学習の後の2回目の実験では、7 人ずつ従来手法と提案手法 に分けて行う.従来手法での学習の有無に関わらず、結果が未 学習<従来手法<提案手法になることを示すためである. 未学習の実験では、システムの動作方法を説明後、従来手法で 使用する読影評価システムでの読影評価を行った.従来手法の 実験では、参考書に記載してある腫瘤の特徴をまとめたもので 学習した後、従来手法で使用する読影評価システムで読影評価 を行った.提案手法の実験では提案型ティーチングファイルで 学習を行い、CAD併用型読影評価システムで読影評価を行っ た.その際に、CADの性能として癌を約90%見つけることが 出来る点、1患者あたりに1つ間違いを検出してしまう場合が ある点、全体の癌の中で見落としが10%程ある点について読影 評価を行う前に説明を行った.

表 1	3	つのバ	ペタ-	ーン	での読影実験の詳細	Ħ
	~	~ ~ / ·		~		ч.

未学習	従来手法	提案手法
未学習	医師の診断を	医師の診断と CAD 検
での評	基に作成した	出を基に作成した画像
価.	画像 100 枚を	200 枚を評価前に学習
	評価前に学習	する.評価時には, 評
	する.	価画像の CAD 検出画
		像を併用して行う.

#### 4. 実験結果

被験者 14 人の平均の ROC 曲線を図 1 に示す. 加えて,読 影実験による被験者の中で癌検出の結果を表 5 に示す.読影実 験の結果は,学習を全く行わない場合の AUC は 0.65.従来のテ ィーチングファイルで学習した場合の AUC は 0.71 であった.



図1 被験者 14 人の平均 ROC 曲線

#### 5. 考察

図1より,AUC 値で比較すると目的通り未学習<従来手法< 提案手法となることを確認できた.また,未学習と従来手法を 比較すると,見落しの数は減少し,高い確信度での正解は増加 しているため、従来手法であっても学習は有効である.しかし, 誤検出の数は多少増えてしまった.未学習と提案手法を比較す ると、見落しの数は約半分に減少し、高い確信度での正解は約 2 倍に増加した.さらに、誤検出の数も減少する結果となった. ROC 曲線グラフや AUC 値の比較から未学習>従来手法>提 案手法であることを確認できたが、それぞれの実験パターンの 間に有意差があるかを確認した.有意差検定の結果を図2に示 す.図2より、未学習と従来手法の場合はt値がt境界値の範 囲に含まれてなく、P値も0.05より大きいため有意差がある とは考えられない.しかし、従来手法と提案手法、未学習と提 案手法の場合はt値がt境界値の範囲に含まれており、P値も 0.05より小さいため有意差があるとは考えられる.



図2 3つの実験パターンでの有意差検定

#### 6. まとめ

今後様々な症例のティーチングファイルを作成していく中 で,症例に合わせた様々な機能を搭載することで学習の利便性 を向上させることでシステムの普及に繋がると考えられる.

#### 謝辞

研究遂行にあたり貴重なご指導を賜った武尾英哉教授に深 謝いたします.

#### 利益相反の有無

なし

- 文 献
- [1] 寒川光治, 染田邦幸, 岩村俊, 他:イントラネットによる画像診断ティーチングファイルシステムの構築. 映像情報 medical,32(12),2000, pp.670-675
- [2] 野村行弘, 増谷佳孝, 三木総一郎, 他:遠隔読影環境における多施設 連携型 CAD 開発, 実運用, および継続的性能改善. Med Imag Tech, Vol. 32, No. 2, 2014, pp.98-108
- [3] Redmon J, Divvala S, Girshick R, et al: You Only Look Once Unified, Real-Time Object Detection. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp.779-788

近藤 啓介\*1

# \*1 駒澤大学医療健康科学部

# Usefulness of image analysis competition using phantoms for training radiological technologists Keisuke KONDO<sup>\*1</sup>

# \*1 Faculty of Health Sciences, Komazawa University

要旨:診療放射線技師教育において,自ら考え行動できる教育を目的に考察型の教育用ファントムを開発した.開発したファントムはX線の吸収率が異なる3種類(黄色・青色・橙色)の立方体ファントムと,立方体ファントムが縦横高さ各3個の計27個が入るブラックボックスで構成されている.課題は27か所の各位置に3種類の立方体ファントムの何色が設置されたかをX線撮影した 画像から解析することである.

本教材を利用した競技大会「ブラックボックスコンテスト」を開催したところ、3大学6チームが対面で参加した.事前に撮影した7方向から撮影したX線画像から最初に3種類を用いて解析し、追加で残りの方向の画像を選択して利用可能とした.解析の正確性と利用したX線画像が少ない方が高得点となる.アクティブラーニングとして自ら考え行動できる教育として利用可能性と、 チーム戦でのコミュニケーション能力やチーム力育成の有用性を報告する. キーワード:教育、画像解析、ファントム、問題解決能力

1 1 . 秋日,回家开切, 7 7 7 5 1 5 ,问题开切

# 1. はじめに

社会からは大学の教育において自ら考え行動できる学生の 育成を期待されており、診療放射線技師を養成する学部学科も 同様の教育を期待されている.しかしながら、指定規則による カリキュラムが決まっており、必修科目が非常に多いのが特徴 である.つまり診療放射線技師を目指す学生は時間的余裕が少 ない.そこで、専門知識を利用しつつ、1日以内で実施可能な 新たな教育コンテンツが必要と考えられる.

そこで,新しい教育コンテンツの開発<sup>[1]</sup>を考えた,またその 教育に利用する専用の新しい教育ファントムを作成した.この 教育用ファントムを使った「ブラックボックスコンテスト」を 開催しているが,今回初めての対面での開催となった.対面に よる大会の開催方法と参加した学生や協力教員の意見より,開 発した教育コンテンツの有用性を報告する.

# 2. 教育コンテンツと教育用ファントム

開発した教育用ファントムは、3 種類の1辺の長さが2 cm の立方体ファントム(XCUBE) と XCUBE を縦横高さ各3 個 収納できる黒と透明の立方体の箱である.黒い箱を BBOX、透 明の箱を CBOX と呼ぶ.BBOX と CBOX は、5 つの各面には A から E が印字されており、底面だけは何も印字されていな い.XCUBE の特徴は2 つあり、ひとつは種類ごとに黄色・青 色・橙色の色が異なっていること、もうひとつは種類ごとに X 線の吸収率が異なることである.図1に BBOX と XCUBE を 収納した CBOX、および XCUBE の各色1個の写真を示す.図 2 には、3 種類の XCUBE から3 個を重ねる 10 パターンの組み 合わせとその X 線画像を示す

教育コンテンツとしての利用方法を説明する.

- 3 種類の XCUBE を各 9 個の計 27 個を BBOX にランダ ムに入れて封印する.
- ② BBOX をいろいろな方向から X 線撮影を行う.
- 得られた X 線画像から, BBOX のどの位置に何色の XCUBE が配置さえれているかを解析する.
- ④ 解析の正確性と時間,利用した画像枚数の少なさを点 透化して評価する.

以上を1チーム(3人から4人)で考察しながら行う,チー ム対抗戦の競技である.

撮影条件は管電圧 70 kv, 1.0 mAs, SID 1.0 m であり, FujiFilm 社の FPD で, 直線階調, 画像処理は OFF で画像化した.

#### 3. 交流大会

複数の大学の学生による交流大会を開催してきた. 2023 年 3月27日の大会では、駒澤大学に集合しての対面による開催 となった.対面では限られたX線撮影装置を交代で利用する には時間が足りない.そこで、今回は事前に7方向からX線 撮影した画像を準備して配布する方法を採用した.最初は、上 面・正面・側面から撮影した3つのX線画像を配布し、追加で 斜め45度から撮影した4方向から必要なものを選択してもら う.図3に上面から撮影した設置状況の写真とX線画像 を示す.図4に斜め45度から撮影した設置状況の写真とX線画像 を示す.図4の写真にある青色の台は、斜め45度から撮影を 補助するために作成した発泡スチロールの補助具である.図3 と図4にある通り、XCUBEの各色1個を一緒に撮影すること で、線量のばらつきを判断するための指標としている.解析方 法は、手計算のみとし、表計算ソフトやプログラミングの利用 は禁止とした. 評価方法は,正確性として 27 ヶ所の XCUBE の色を正解した個数を1個1点の最大 27 点とした. 被ばくの少なさとして利用した画像枚数により,3枚は13点,4枚は11点,5枚は8点,6枚は4点,7枚は0点とした.合計では最大40点となる.これを3回戦行い,総合得点を競い合った.

### 3. 結果と考察

各チームの得点を表にしたものを表1に示す.チーム名は申 し込み順に原子名を順番に割り振った.27ヶ所すべてを3回 戦とも正解したチームが1つだけあった,しかし利用した画像 枚数は4枚から5枚であり,難易度的には容易ではないことが 確認できる. 参加した学生や教員の意見より,開発した教育 コンテンツは考察型のアクティブラーニングとして有用であ ることが示唆された

	表 1	交流大会の	成績	
チーム	1回戦	2 回戦	3 回戦	合計
Н	5枚21コ	3枚14コ	5枚27コ	91 点
Не	3枚23コ	4枚19コ	4枚 11コ	88 点
Li	4枚 27コ	5枚27コ	4枚 27コ	111 点
Be	5枚20コ	3枚27コ	4枚 21コ	100 点
В	3枚17コ	4枚21コ	3枚17コ	92 点
С	4枚13コ	4枚16コ	4枚17コ	79 点



図 1 BBOX と CBOX と XCUBE



図2 XCUBEの3種類から3個を重ねた10パターン



図3 上面から撮影した設置状況の写真とX線画像



図4 斜め45度から撮影した設置状況の写真とX線画像

# 3. まとめ

対面での教育コンテンツとしても,開発した「ブラックボッ クスコンテスト」は有用であることが確認できた.

#### 謝辞

「ブラックボックスコンテスト」の開催当日の学生の指導に 協力いただきました,駒澤大学の志村一男教授,帝京大学の大 谷浩樹教授,日本医療科学大学の山本絵夢助教,駒澤大学の村 田渉助教に深謝いたします。本研究はJSPS 科研費 JP21K12162 の助成を受けたものです.

# 利益相反の有無

本研究で開発したファントムは株式会社京都科学から商品 化されている.

#### 文 献

[1] 近藤啓介, 志村一男:キュービックファントムを活用した論理的思考 力の教育. 駒澤大学医療健康科学部紀要:第18号,1-6,2022

# 腹腔鏡手術シミュレーションにおける臓器の把持および変形操作の実装

宮崎 琳太郎\*1, 林 雄一郎\*1, 小田 昌宏\*2,1, 森 健策\*1,3,4

\*1 名古屋大学大学院情報学研究科

\*2 名古屋大学情報連携推進本部情報戦略室

\*3 国立情報学研究所医療ビッグデータ研究センター

\*4 名古屋大学情報基盤センター

Implementation of Organ Grasping and Deformation for Laparoscopic Surgery Simulation

Rintaro MIYAZAKI<sup>\*1</sup>, Yuichiro HAYASHI<sup>\*1</sup>, Masahiro ODA<sup>\*2, 1</sup>, Kensaku MORI<sup>\*1, 3, 4</sup>

<sup>\*1</sup> Graduate School of Informatics, Nagoya University

\*2 Information Strategy Office, Information and Communications

\*3 Research Center for Medical Bigdata, National Institute of Informatics

<sup>\*4</sup> Information Technology Center, Nagoya University

要旨:本研究では、八分木構造および Position Based Dynamics (PBD)法に基づく変形モデルを応用し、腹腔鏡鉗子による臓器モデルの把持および変形操作を実装した.手術シミュレーションは医師や医学生が手術技術を習得するための有効な手段の一つとして期待されている.腹腔鏡手術用のシミュレータは既に製品化され、手術手技の習得に有効であることが示されている.しかし、臓器のような柔軟物体の変形シミュレーションは計算量が多くなりやすく、リアルタイム性を確保するために臓器モデル自体のポリゴン数や操作デバイスとの接触判定の効率化が求められる.本研究では、臓器モデルから生成した八分木構造のラフモデルを PBD 法によって変形する.さらにそのモデルと操作デバイスの接触判定を行うことでその効率化をおこなう.本手法をゲームエンジンである Unity に実装し、リアルタイムでの操作を実現した.

キーワード:腹腔鏡手術シミュレーション,変形モデル,局所細分化,マニピュレーション

### 1. はじめに

手術シミュレーションは医師や医学生が手術技術を習得す るための有効な手段の一つとして期待されている.中でも,腹 腔鏡手術シミュレータは既に製品化され、いくつかの研究調査 によって手術手技の習得に有効であることが評価されている [1, 2].シミュレータの開発において変形可能な臓器モデルは 重要な役割を持つが,臓器のような柔軟物体の変形シミュレー ションは計算量が多くなりやすく,リアルタイム性を確保する ために臓器モデル自体のポリゴン数や操作デバイスとの接触 判定の効率化が求められる.

先行研究では, 臓器モデルから生成される八分木構造のラフ モデルを Position Based Dynamics (PBD)法[3]によって変形する 手法を提案している[4].空間分割手法の一つである八分木を 利用し, 階層化されたキューブ要素で臓器モデルを離散化して いる.より高精度にマニピュレーションを行うには,モデル表 面に配置されたキューブを, 鉗子モデルの操作領域で局所的に キューブ要素を細分化し,高解像度化する必要がある.

関連研究では、四面体要素の動的な細分化手法の提案[5]や、 六面体要素の有限要素法を利用した細分化による変形計算の テスト[6]がされている.本稿では先行研究である、八分木構造 および PBD 法に基づく変形モデル[4]に、腹腔鏡鉗子モデルの 接近によるキューブ要素の動的な局所細分化を実装した.手術



図1 八分木構造と PBD 法による変形プロセス

鉗子モデルの接近による八分木構造の細分化処理の詳細を示し,胆のうモデルを例に鉗子モデルによる臓器モデルの変形操 作のシミュレーションを行う.

# 2. 手法

ここでは,先行研究[4]の変形手法について簡単にまとめ,局 所細分化の処理手法,鉗子モデルによるキューブ操作について 述べる.



1) 先行研究[4]の変形手法

図1は先行研究での臓器モデルの変形処理の流れを, 肝臓モ デルを例に2次元で図示したものである. 初めに, 高解像度の 臓器サーフェスモデルを階層的なキューブで構造化する. 次に, 各キューブ要素にキューブ形状を維持する制約を与え, PBD法 によって変形させる. 最後に, キューブ8頂点からトリリニア 補間を用いて臓器サーフェスモデル頂点をマッピングする.

2) 局所細分化の処理手法

図2は局所細分化の概念を示したものである.キューブ要素の重心が手術鉗子モデル先端からのユークリッド距離 r 内に 位置する場合に,次のような処理を行う.

Step1 キューブ要素を8分割する.

Step2 キューブ 8 要素に対して, 臓器モデルの外部にある 場合に非アクティブ化(変形計算の対象外に)する.

Step3 Step1-2 を任意の回数分繰り返す.

3) 鉗子モデルによるキューブ操作

鉗子モデルの位置と姿勢は VR コントローラによって操作 され、トリガー操作によって先端が開閉する. 鉗子モデルの先 端とキューブ頂点の距離が閾値以下のとき, 鉗子が閉じるとキ ューブ頂点が鉗子モデルに追従する.

#### 3. 実験

本研究では、八分木キューブ構造の生成と局所細分化処理を 胆のうモデルに適用し、鉗子モデルによる臓器モデルの把持と それにともなう変形のシミュレーションを行った.細分化処理 における距離rは、r=1.5 cm とした. 胆のうモデルは患者 CT 像から生成され、5000 個の三角形パッチと 2502 個の頂点を持 つ. VR 装置は Meta Quest 2 (Meta, USA)を用い、入力操作の実 装および環境構築にはゲームエンジン Unity を用いた.

#### 4. 結果と考察

図3に変形シミュレーションの結果を示す.図3(a)は把持の 様子,(b)はキューブ構造を重畳表示したものである.細分化前 のキューブ数は154個,細分化後は238個であった.また,細 分化後のフレームレートは62.8 fps であった.

現段階では,鉗子が離れても細分化されたキューブ構造の解 像度はもとに戻らないため,実用上の問題が残っている.今後 は,細分化された8キューブにおける27頂点の位置と速度か



(a) 把持の様子



(b) キューブ構造の重畳表示図3 胆のうモデルの変形シミュレーション

ら細分化前のキューブの形状を推定し,復元するアルゴリズム の構築が必要となる.また,変形の妥当性の検証も必要である と考えられる.

### 5. まとめ

本研究では、八分木構造および PBD 法に基づく変形モデル を応用し、鉗子モデルの接近によるキューブ要素の動的な局所 細分化を実装するとともに、胆のうモデルの変形シミュレーシ ョンを行った.操作領域のキューブ構造の細分化によって高精 度に行うことが可能になり、リアルタイムで変形操作が可能で あることを示した.

# 謝辞

本研究は JSPS 科研費 (21K19898, 17H00867, 26108006), JST CREST JPMJCR20D5, ムーンショット JPMJMS2033 JPMJMS2214, JST SPRING JPMJSP2125 の支援を受けたもの である.

#### 利益相反の有無

なし

- Badash I, Burtt K, Solorzano C et al: Innovations in surgery simulation: a review of past, current and future techniques. Annals of Translational Medicine 4(23): 453, 2016
- [2] Juan U González-Tova, Pallikonda S Madhulik: Systematic Review of Laparoscopic Surgery and Simulation-based Training. World Journal of Laparoscopic Surgery 10(3): 117-128, 2017
- [3] Muller M, Heidelberger B, Hennix M et al: Position Based Dynamics, J. Vis. Comun. 18(2), 109-118, 2007
- [4] Miyazaki R, Hayashi Y, Oda M et al: Octree cube constraints in PBD method for high resolution surgical simulation, Proc. SPIE 12464, Medical Imaging, 124642N, 2023
- [5] Wicke M, Ritchie D, Klingner BM et al: Dynamic local remeshing for elastoplastic simulation, ACM Transactions on Graphics, 29(4): 1–11, 2010
- [6] Gao R, Peters J: Plastic hexahedral FEM for surgical simulation. Int. J. CARS, 17(12): 2183-2192, 2022

# 3時相腹部造影 CT 画像を用いた腎腫瘍解析

越野 魁都\*1, 西岡 大\*1, 河田 佳樹\*2

小針 悠希\*3, 池田 篤史\*4, 仁木 登\*5

\*1 徳島大学大学院創成科学研究科 〒770-8506 徳島県徳島市中常三島町 2-1

\*2 徳島大学ポストフォトニクス研究所 \*3 東京女子医科大学

\*4 筑波大学医学医療系 \*5 株式会社医用科学研究所

Renal tumor analysis using multi-phase abdominal CT images

Kaito KOSHINO<sup>\*1</sup>, Dai NISHIOKA<sup>\*1</sup>, Yoshiki KAWATA<sup>\*2</sup>

Yuuki KOBARI\*3, Atsushi IKEDA\*4 Noboru NIKI\*5

<sup>\*1</sup> Graduate School of Science and Technology for Innovation, Tokushima University

<sup>\*2</sup> Institute of Post-LED Photonics, Tokushima University <sup>\*3</sup>Tokyo Women's Medical University

<sup>\*4</sup> Faculty of Medicine, Tsukuba of University <sup>\*4</sup> Medical Science Institute

要旨:マルルチスライス CT 画像の発展により, 腎臓の高精度な解析, 診断, 治療が可能となった. CT 画像撮影時に造影剤を用いる ことにより, 血管や臓器, 病変などの情報をより正確に得ることが出来る. 本研究では3時相腹部造影 CT 画像を用いて, 特に判別 が難しい乳頭状腎細胞がん, 嫌色素性腎細胞がん, オンコサイトーマの3種類の小径腎腫瘍の解析を行う. 腎腫瘍の特徴を定量化 し, 高精度の鑑別分類を目標とする.

キーワード: CT, 腎臓, 腎腫瘍

# 1. 背景·目的

腎がん患者の年間死亡者数は1万人を超え,年々増加傾向に ある.また,術前に腎がんと診断して手術を行っても,良性腫 瘍が10%であり,医師・患者ともに負担となる.特に腫瘍径が 小さい場合(2.5cm以下)は良性腫瘍の頻度が高く注意が必要 である.マルチスライス CT の発展により腎臓,腎腫瘍内にお ける多時相造影効果を明らかにすることでより正確な診断が 期待できる.本研究は動脈相・門脈相・平衡相の造影 CT 画像 を用いてに腎臓,腎腫瘍を解析することで,良性腫瘍と悪性腫 瘍の鑑別の可能性を追求する.

#### 2. 撮影条件

東京女子医科大学病院から提供を受けた腎腫瘍の3時相造 影マルチスライス CT 画像を CT 画像データベースに用いた.こ れらの画像はキャノンメディカルシステムズ社製 Aquilion ONE と Aquilion で撮影された造影マルチスライス CT 画像であ る.撮影条件は管電圧 120kV, 管電流 60~500mA,再構成間隔 1.0mm であり,腎臓付近の腹部を撮影している.造影時間は 30 秒~300 秒である.

#### 3. 手法

本研究では嫌色素性腎細胞がん症例,乳頭状腎細胞がん症 例,オンコサイトーマ症例の解析を行う.手法は,(1)2D U-Net を用いて造影 CT 画像を自動抽出(2)抽出した多時相の腎臓を 剛体レジストレーション(3)腎臓及び腎腫瘍にプロット点を 与え混合分布法を用いてクラスタリング(4)多時相間におけ る CT 値経時変化の解析からなる.

(1)造影 CT 画像から腎臓を自動抽出するために 2D U-Net を 用いる.U-Net は入力された画像に対しセグメンテーションを 行う CNN アーキテクチャである.データセットとして 100 症例 の腎臓・腎腫瘍を用い学習を行う.この学習データを用いて腎 臓・腎腫瘍を自動抽出する.2D U-Net の性能評価には Dice 係 数を用いる.抽出結果を図1に示す。性能評価結果を表1に示 す.





(a) 腎臓・腎腫瘍(b) 腎臓図1 2D U-Net を用いた腎臓・腎腫瘍の自動抽出結果

	動脈相	門脈相	平衡相
平均値(腎臓・腎腫瘍)	0.967	0.965	0.979
平均値(腎臓)	0.965	0.973	0.978

表1 2D U-Net の性能評価結果

(2) 抽出した 3 時相の腎臓・腎腫瘍を ITK を用いてレジストレ ーションを行う. レジストレーションとは関連性のある特徴を 持つ複数の画像において, 画像内の位置を他方の画像内の位置 に対応付ける空間的な返還を求める処理である。これにより 3 時相の画像間の位置合わせが可能となる.

(3) 腎臓・腎腫瘍に 5 画素間隔で 3×3×3 び 27 画素のプロッ ト点を与え, それぞれの CT 値の遷移から混合分布モデルを用 いてクラスタリングを行う. 上記の方法でクラスタリングした 結果を図 2 に示す。



図2 淡明細胞型腎細胞がんのクラスタリング結果 (4)各プロット点の CT 値遷移と平均 CT 値を3時相それぞれ で算出し,解析を行う.

# 4. 結果

嫌色素性腎細胞がん 36 症例, 乳頭状腎細胞がん 31 症例, オ ンコサイトーマ 20 症例の解析を行った.各プロット点の平均 CT 値を 3 時相それぞれで算出した結果を図 3,4 に示す.いず れの症例も腎腫瘍のクラスタが 1 つとなった.また, 嫌色素性 腎細胞がんと乳頭状腎細胞がんは動脈相で CT 値平均が 100 未 満となる症例が多くみられた.良性腫瘍であるオンコサイトー マは動脈相で CT 値平均が 100 以上となる症例が多くみられ た.

### 5. まとめ

多時相造影 CT 画像より腎臓・腎腫瘍を抽出し,腎臓の剛体 レジストレーションを行った.レジストレーションした腎臓・ 腎腫瘍の各時相の CT 値を混合分布モデルに適用してクラスタ リングした.クラス別の CT 値ヒストグラムを用いて3種類の 腎腫瘍における造影剤の循環動態を明らかにした.今後,3 時 相腹部造影 CT 画像を用いた小径の腎腫瘍の高精度な鑑別診断 が期待できることを示した.



(a) オンコサイトーマ



(b)乳頭状腎細胞がん図3各症例のクラスごとのCT値平均

# 利益相反の有無

なし

[1] 日本泌尿器科学会,日本病理学会,日本医学放射線学会,腎癌取り扱 い規約第4版,金原出版 2011.

- [2] Fahmi Khalifa et al, 3D Kidney Segmentation from Abdominal Images Using Spatial-Appearance Models, Computational and Mathematical Methods in Medicine, Vol 2017, pp1-10, 2017
- [3] Olaf Ronneberger et al, U-Net: Convolutional Networks for Biomedical Image Segmentation, Medical Image Computing and Computer-Assisted Intervention, Vol. 9351, pp234-241, Springer, LNCS, 2015
- [4] 秋山亮太,徐睿,平野靖,木戸尚治,ITKのためのGPGPUプログラミング支援環境,MEDICAL IMAFING TECHNOLOGY, Vol. 31, No. 3, pp153-158, 2013
- [5] 中野翔大,鈴木秀宣,河田佳樹,他,多時相腹部造影 CT 画像を用い た腎腫瘍解析,信学技報,vol. 120, no. 156, MI2020-21, pp. 23-24, 2020
- [6] 西平健斗,西岡大,鈴木秀宣,河田佳樹,池田篤史,小針悠希,仁木 登:3時相腹部造影 CT 画像を用いた小径腎腫瘍解析,電子情報通信 学会技術研究報告医用画像 vol.122, no.265, MI2022-71, pp.43-44, 2022.11
- [7] 西岡大,西平健斗,越野慰都,鈴木秀宣,河田佳樹,小針悠希,池田 篤史,仁木登:多時相造影 CT 画像データベースの腎臓・腎腫瘍の抽 出,電子情報通信学会技術研究報告医用画像 vol.122, no.417, MI2022-125, pp.210-211, 2023.3

# 糸球体上皮細胞画像を用いた曖昧境界に対する領域抽出方法の開発

大野 侑亮\*1, 松浦 勉\*2

\*1 群馬医療福祉大学 医療技術学部

\*2 東京都立大学大学院 人間健康科学研究科

# Developing the method of region extraction for an ambiguous border using podocyte cell images

Yusuke ONO<sup>\*1</sup>, Tsutomu MATSUURA<sup>\*2</sup>

# <sup>\*1</sup> Department of Medical Technology and Clinical Engineering Gunma University of Health and Welfare <sup>\*2</sup> Graduate School of Human Health Sciences, Tokyo Metropolitan University

要旨:人間が何らかの特徴を見出そうとするとき、自分にとって都合の良い情報を無意識に集めてしまう確証バイアスがかかる. 我々はこのバイアスを再現することで、機械学習の学習効率を上げることが出来ると考えている.本研究では、この一例として、 腎疾患によって糸球体上皮細胞の足突起が変性することを客観的に捉えるために撮影された SEM 画像を用いることで、この画像 の中で無意識に注目していると考えられる領域の自動抽出手法の開発を目的とする.本画像には、我々の興味がある領域とそれ以 外の領域の境界が曖昧である問題が存在する.近年の領域抽出に関する研究では、学習を用いる場合が多いが、少量しかデータを 集められない場合を想定して、ここでは楕円形状のフィルターと輝度勾配ベクトルを組み合わせることで、学習を伴わない手法の 開発を行った.本手法を用いることで、後処理が少なく、手動で抽出したものと比較して高精度な領域抽出を可能とした. キーワード:領域抽出、前処理、機械学習

#### 1. 緒言

畳み込みニューラルネットワーク(CNN)を用いた学習では 従来の機械学習のように特徴量の設計を行う必要はないが,大 量のデータが必要となる.少量データにおける学習では,しば しば過学習が起こり,汎化性能の低下が問題となる.近年では, Few-shot Learning のような大規模モデルを転用した手法が増 えているが,新規データに対する汎化性能を考える場合は,1 枚の画像から根拠のしっかりとした情報をなるべく多く引き 出すことが求められる.また,人間が何らかの特徴を見出そう とするとき,特定の場所に無意識に注目して,都合の良い情報 を集めてしまう確証バイアスがかかる.

このバイアスが機械学習の学習過程において再現されるこ とで、精度や学習効率が高まることを我々は期待している. 我々は、領域抽出に着目して、前処理の段階で、このバイアス を再現する方法を模索した.よって、本研究では、SEM により 撮影された糸球体上皮細胞画像を用いて、我々が画像を観察す るとき無意識に着目している領域の自動抽出手法の開発を目 的とした.

近年の領域抽出に関する研究では、FCN[1]のように学習モ デルを用いることが多い.また、従来では、文献[2]のように形 態学的な処理を行い、個々の画像ごとにパラメータを設定して、 領域抽出を行っていた.これらの共通の問題点として、特に境 界が曖昧な問題に対しては、作業者の主観が無意識に入り込む ことが挙げられる.そこで、本研究においては、従来手法のよ うに関心のある領域を直接抽出する方法ではなく、非関心領域 を推定し、これを排除することで、最終的に関心領域を残す手 法の開発を行った.

#### 2. 解析対象とする画像データ

本研究では、マウスの糸球体上皮細胞より、腎疾患による形態の変性を客観的に捉えることを目的に撮影された SEM 画像 [3]を用いる.使用したマウスは、野生型(WT)、糖尿野生型 (DMWT)、加齢型(oldWT)、変異型(Mu)、糖尿変異型(DMMu)の 5 種類である.糖尿型はすい臓ランゲルハンス島β細胞を破壊 し、強制的に I 型糖尿病を惹起したものを、変異型は SIRPaの 細胞内ドメインを欠損したマウスを使用した.撮影倍率は 13000倍、画像枚数は、それぞれ 96 枚、97 枚、96 枚、58 枚、 109 枚である.

これらの画像から人間が変性を判断するとき,中心に置かれ ている箇所を注目すると考えられ,恣意的に画像端を見て,形 態を判断することは考えにくい.よって,本研究では,画像中 心付近に抽出したい領域が存在することを前提に,我々が無意 識に注目していると考えられる関心領域の抽出を行う.ここで 問題となるのが,関心領域とそれ以外の領域である非関心領域 の境界が非常に曖昧となることである(図1).



図1 曖昧な境界の関心領域を持つ糸球体上皮細胞画像

#### 3. 提案手法

提案手法では,関心領域を直接抽出する方法ではなく,非関 心領域を推定し,これを排除することで関心領域を残す.本提 案手法は,以下の手順で計算される.

1) 前処理

SEM 画像は,被写体の状態や撮影者によって,画像の中心 輝度にばらつきがあることが予想されるため,事前に輝度の正 規化処理を行う.

#### 2) 輝度勾配画像の生成

本研究で扱う画像の関心領域には,足突起と呼ばれるかみ合わせが存在するため,輝度の起伏が激しい場合が多い.それに対して,非関心領域では輝度の勾配がぼやけてなめらかであることが多い.よって,Harris-Stephensのコーナー検出[4]を利用し,輝度勾配に基づく処理を行う.判別式を利用して,各座標に対して,フラットな領域の推定を行う(図2左).

3) 楕円フィルターの作成

関心領域が存在する確率は,画像中心から外側に向かうにつ れ低くなると考えられる.画像中の被写体がどの方向に伸長し ているかを捉え,その情報を元に楕円形状にフィルターを作成 する(図2右).

画像中心の座標を $(c_x, c_y)$ とし、任意の座標との相対座標を  $(\bar{x}, \bar{y}) = (x - c_x, y - c_y)$ とすると楕円フィルター $I_{ell}(x, y)$ は以下の式で計算される.

 $I_{ell}(x,y) = 1 - (c^2 a^{-2} + s^2 b^{-2})\bar{x}^2 + (s^2 a^{-2} + c^2 b^{-2})\bar{y}^2 + 2cs(-a^{-2} + b^{-2})\bar{x}\bar{y}$ (1)

ただし $c = \cos\theta$ ,  $s = \sin\theta$ を意味している. このとき回転角 $\theta$ は中心座標から放射線状に小領域のエッジの割合を計算し、こ れらの累積和から上位 3 方向を考えたときの中央値に当たる 方向をとる. また, a,bは楕円の長軸, 短軸を意味するが、短 軸の長さを基準にエッジの割合から推定した扁平率を掛ける ことで、これらを定める.



図2 輝度勾配要素と楕円フィルター

#### 4) 合成および後処理

輝度勾配画像は, 非関心領域を推定しているため, 中心付近 が盛り下がる関数形状に, 楕円フィルターは中心座標を頂点に 外側に向けて値が小さくなる形状になっているため, これらを 重ね合わせたとき, 必ず交点が見つかる. この交点で囲まれる 領域の内側を関心領域, 外側を非関心領域として抽出する. 合成された画像では、交点で囲まれる領域を抽出しているだけなので、孤立要素が表れることがある. そこでラベリング処理を行い、最大面積を持つ要素のみを抽出する.

#### 4. 結果,考察及び結論

提案手法により抽出した領域について,手動で抽出を行った 領域との一致率を次式で評価する.

(2)

 $P = n(I_{our} \cap I_{man})/n(I_{our} \cup I_{man})$ 

 $I_{our}$ は,提案手法により抽出した関心領域を示し, $I_{man}$ は, 手動で抽出した関心領域を示す.また, $n(\cdot)$ は,領域内の要素 数を表す.

図3に関心領域の抽出例を示す.また,表1にマウスの種類 ごとの一致率の平均を示す.



図 3 関心領域の抽出例(左:元画像,右:抽出領域) 表 1 種類ごとの一致率平均

		> • • • •			
Type	WT	DMWT	oldWT	Mu	DMMu
Ave.	0.80	0.80	0.83	0.81	0.81
SD	0.09	0.08	0.07	0.09	0.07

表1の結果より,本手法により抽出した領域と手動で抽出した領域を比較し,高い精度で関心領域の抽出が可能となった. 一方で,楕円フィルターの方向や扁平率が適切なものを抽出で きていないと一致率が小さくなることがわかった.よって,楕 円フィルターの諸元の決定方法の改善が今後の課題の一つで ある.

#### 謝辞

研究遂行に当たり画像データの提供をしていただいた群馬 県立県民健康科学大学 青木武生教授をはじめ,群馬大学 松 崎利行教授,廣村桂樹教授に感謝いたします.

#### 利益相反の有無

なし

- Lomg J, Shelhamer E, Darrell T: Fully Convolution Networks for Semantic Segmentation, CVPR2015: 3431-3440, 2015
- [2] 元川嵩介,松浦勉,青木武生:腎糸球体足細胞画像からの細胞体の抽出 とシグナル調節タンパク質αと糖尿病による細胞変性識別の試み, Med Imag Tech 33(5): 208-216, 2015
- [3] Takahashi S, Tomioka M, Hiromura K et al : SIRPα signaling regulates podocyte structure and function, Am J Physiol Renal Physiol Vol.305 : 861-870, 2013
- [4] Harris C, Stephans M: A Combined Corner and Edge Detector, in Proceedings of the 4th Alvey Vision Coference 147-151, 1988

# U-Netを用いた X線画像による慢性便秘症の診断支援

高島 直也\*1,藤田大輔\*1,佐貫 毅\*2,木下 芳一\*2,小橋昌司\*2

\*1 兵庫県立大学大学院工学研究科

\*2 兵庫県立はりま姫路総合医療センター

# Diagnostic Support for Chronic Constipation by X-ray Images Using U-Net

Naoya TAKASHIMA<sup>\*1</sup>, Daisuke FUJITA<sup>\*1</sup>, Tsuyoshi SANUKI<sup>\*2</sup>,

# Yoshikazu KINOSHITA<sup>\*2</sup>, Syoji KOBASHI<sup>\*1</sup>

<sup>\*1</sup> University of Hyogo, Graduate School of Engineering

<sup>\*2</sup> Hyogo Prefectural Harima-Himeji General Medical Center

要旨:2019 年現在便秘の有訴者率は 34.8%と高く,加齢に伴って増加している.腹部 X 線画像から便秘の重症度やタイプを読 影するためには習熟を要し,また主観的である.そのため,便秘の重症度や分類の手掛かりとすることを目的とし,ガスと便の 量および所在を特定する技術が望まれている.腸管内ガスを定量的に評価する指標として GVS(gas volume score)があるが,医師 が手動で算出する必要があり,実臨床への導入は難しい.そこで本研究では便秘診断支援法として,U-Net を用いた腹部単純 X 線画像からの便とガス領域の自動抽出法を提案する.加えて,便における同様の指標 SVS(stool volume score)と,ガス・便量を 総合的に評価する指標 JVS(joint volume score)を提案する.本自動化手法による抽出領域と熟練消化器内科医によるマスク領域を 比較したところ GVS, SVS, JVS がそれぞれ相関係数で 0.895, 0.879, 0.586 であった.また,同様に比較したところガス領域, 便領域,ガスと便の結合領域において DICE 係数はそれぞれ 0.650, 0.474, 0.640 であった. キーワード:セグメンテーション,深層学習,腹部 X 線画像,便秘,CAD

### 1. はじめに

2019年に行われた国民生活基礎調査によると便秘の有訴 者率は男性25.4%,女性43.7%,全体で34.8%と高い.男女 ともに加齢に伴って増加し,65歳以上の有訴者率は男性 64.1%,女性72.3%となっている.慢性便秘症の症状,病態 は複数あり,正しい診断に基づいて適切に治療する必要が ある.熟練の消化器内科医は,腹部X線画像の読影により, 便秘の重症度やタイプを判断し,治療法,治療薬を選定し ている.しかし,経験の少ない医師や,消化器内科医以外 の診療科医では,腹部X線画像での診断は困難である.ま た,量や所在の把握も主観的な評価で行っており,医師の 知識や経験に依存するため,験者間変動,験者内変動が大 きい.

他の手段として腹部 CT 検査があり,X線画像の読影と比較して腸内のガス・便の所在と量を容易に把握できるため, 病態鑑別に有効である[1].しかし,放射線被ばく量が多く, 患者の金銭的負担も大きい.

これらのことから,便秘の重症度の判別やタイプ分類の 手掛かりとすることを目的とし,ガスと便の量を客観的で 定量的に評価する方法や,腹部 X 線画像からの便,ガス領 域の自動抽出技術が望まれている.

本研究では、便秘の画像診断支援法として、腹部単純 X 線画像からの便とガス領域の自動抽出法を提案する.

2. 被験者及び使用データ

(旧) 製鉄記念広畑病院に来院し,腹部単純 X 線画像を 撮影し,画像上に顕著な病変を有しない患者を無作為に抽 出した 95 名 (男性 48 名,女性 47 名)を対象とした.平均 年齢は 62.3 歳で,標準偏差は 16.6 歳である.便秘症状の有 無,ガス,便の量については無作為に抽出した.

#### 3. 提案法

### 3.1 領域抽出法

ガス,便領域の抽出は医用画像からの領域分割法として 良く用いられる U-Net[2]を用いて行う.各画像に対して, 熟練の消化器内科医が,便領域とガス領域を手動で抽出し, これをアノテーションデータとしてネットワークモデルを 構築する.また,便領域とガス領域を結合した結合領域に ついても同様に抽出モデルを構築する.入力画像は3チャ ネルに,アノテーションデータはワンホット表現に変換す る.学習時は,学習データに対する過学習を抑制するため, 移動,回転,ガンマ補正によるデータ拡張を適用する.オ プティマイザは Adam を用い,検証データに対する Loss 値 を用いたアーリーストッピングを行う.また,検証データ に対する Loss 値が最小となる重みを収束モデルとする.

#### 3.2 ガス,便量,結合量の定量化

腹部のガス量を文献[3]で提案された Gas volume score (GVS)で定量化し,式(1)で定義する.便量およびガスと便の 結合量における同様の指標 Stool volume score (SVS), Joint volume score (JVS)を式(2), (3)で定義する.

$GVS = \frac{N_{GAS}}{N_{abdominal}}$	(1)
$SVS = \frac{N_{STOOL}}{N_{abdominal}}$	(2)
$JVS = \frac{N_{JOINT}}{N_{abdominal}}$	(3)

ここで、N<sub>abdominal</sub>が画像全体の画素数、N<sub>GAS</sub>はガス領域の 画素数、N<sub>STOOL</sub>は便領域の画素数、N<sub>JOINT</sub>はガスと便の結合 領域の画素数である.

#### 4. 実験結果

全データ 95 症例の 20%を評価データとし,残り 80%のデ ータを用いた4分割交差検証で実験した.バッチサイズは 16,学習率は10<sup>-4</sup>,学習減衰率は10<sup>-3</sup>を用いた.

U-Net を用いたガス領域の抽出結果例を図1に,便領域の 抽出結果例を図2に,ガスと便の結合領域の抽出結果例を 図3に示す.図1から図3は同一被験者に対する適用結果 である.

本自動化手法による抽出領域と医師が手動で抽出した領 域を比較したところ, GVS, SVS, JVS がそれぞれ 0.895, 0.879, 0.586 の相関係数でスコア算出できた.また,同様 に比較したところ,ガス領域,便領域,ガスと便の結合領 域においてそれぞれ 0.650, 0.474, 0.640 の DICE 係数で スコア算出できた.

#### 5. まとめ・考察

本研究では、U-Net を用いた便、ガス領域の自動抽出法を 提案した.また、便量及びガスと便の結合量を定量化する スコアとして、SVS、JVS を提案した.提案手法は GVS、 SVS の定量化において高い相関係数を得ることができた. 図1、図3より、各対象領域において、それぞれの最適ネッ トワークモデルによる抽出結果は、真値と類似した結果が 得られていることを確認した.これによって、X 線画像を 用いた便秘診断支援に対する U-Net を用いたセマンティッ クセグメンテーションの有効性が示された.

ガス領域と比較して便領域の DICE 係数が劣った原因とし ては,便領域がガス領域と比較して画像中で不鮮明である ことがあげられる.加えて,DICE 係数は各画像中の対象領 域の真値の画素数を基準に求められるため,画像中で真の 便領域が小さいデータについて,より厳しく評価されたこ とも原因の一つとして考えられる.

今後の課題は、データ数増加による精度検証、方法論の パラメータ調整による性能の最大化、ファインチューニン グを用いた結果との精度比較、臨床研究による本提案法の 有効性評価である.



(a) 元画像





(b) 真値画像図1ガス領域の抽出結果例









(a) 元画像

(b) 真値画像(c) 予測画像図 2 便領域の抽出結果例







(a) 元画像
 (b) 真値画像
 (c) 予測画像
 図 3 ガスと便の結合領域の抽出結果例

#### 利益相反の有無

なし

- [1] A. S. Somwaru, "Imaging of Constipation and its Complications," Constipation, 2019
- [2] O. Ronneberger P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation", International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015, pp. 234-241
- [3] A. Koide, T. Yamaguchi, T. Odaka, H. Koyama, T. Tsuyuguchi, H. Kitahara, M. Ohto, and H. Saisho, "Quantitative Analysis of Bowel Gas Using Plain Abdominal Radiograph in Patients with Irritable Bowel Syndrome," The American Journal of Gastroenterology, 95(7), 1735–1741, 2000

# DICOM 保存された CT 画像からノイズを取り除く

西本 聡\*1

\*1 兵庫医科大学医学部形成外科

**Reducing noises in DICOM formatted CT images** 

Soh NISHIMOTO<sup>\*1</sup>

<sup>\*1</sup> Department of Plastic Surgery, Hyogo Medical University

要旨: CT 撮影範囲内にX線吸収率が高い物質が存在するとメタルアーチファクトと呼ばれるノイズが画像に現れる.撮影時にアー チファクトを軽減する方法も模索されているが.ノイズの含まれた DICOM 画像から3 次元骨モデルを再構成しようとすると CT ス ライス1枚ごとに手作業でメタルアーチファクトやベッドを取り除く作業が必要となっている.U-net 機械学習により頭蓋顔面 CT 画像中のノイズを低減して骨領域を抽出するシステムを構築した.頭頸部腫瘍患者の CT アーカイブ画像を使用し.512 x 512 = 262,144 pixel の検証画像 2000 枚において1 画像辺り平均 14.83 pixel の誤差で予測できた.自動処理ができるため.大量データを処理 することができる.

キーワード: DICOM, アーチファクト, ノイズ, U-net, 機械学習

#### 1. はじめに

X線 CT を撮影する際撮影範囲内に金属製の補綴物などX線 吸収率の高い物質が存在すると、メタルアーチファクトと呼ば れるノイズが画像に現れる.撮影時にこの種のノイズを低減す る方法は存在するが.頭蓋顔面領域ではしばしば特に歯科補綴 物メタルアーチファクトが含まれた DICOM 画像が臨床医の手 元に提供される.CT 値に閾値を設定して骨領域を抽出し.3次 元の骨画像を構築するとメタルアーチファクトやベッドがノ イズとして残存する.そのため.画像処理ソフトなどを使い.ス ライスごとに手作業でノイズを除去する作業が行われている が.非常に手間と時間がかかる.そこで、骨画像を自動抽出し. ノイズを除去する機械学習システムを構築した.

# 2. 方法

すべての手順は GPU: GeForce RTX3090 24.0GB ((nVIDIA, Santa Clara, CA, USA)を搭載した Windows 10 Pro (Microsoft Corporations, Redmond, WA, USA)デスクトップ型パーソナル コンピューターで行った.プログラミング言語として Python 3.8 (Python Software Foundation, DE USA) .Keras 3 (https://keras.io/)を Spyder 4.1.4 上で用いた.

1) データセット

公開されている頭頸部扁平上皮癌患者の CT 画像: The Cancer Imaging Archive Public Access (wiki.cancerimagingarchive.net)の Head-Neck-Radiomics-HN1 をダウンロードして使用した.5mm 間隔で撮影された 512×512 画素の DICOM (Digital Imaging and Communications in Medicine)水平談画像(各画素の値は 0~4071)の順番を確 認し.頭頂部から下顎までの画像を 120 例分抽出した[1].

2) 骨画像抽出(ターゲット画像作成)[2]

1. 閾値による骨領域抽出

Python のライブラリ:pydicom(https://pydicom.github.io) を用い.各 DICOM ファイルからスライス画像を読み込んだ.骨 の領域を抽出するため、画素値 1200 未満は0に、画素値 2040 以上の領域は2040 に置き換えた. 閾値から 1020 を差し引き.4 で割り.0 から255 の範囲の数値とした. 画像は PNG (Portable Network Graphics) ファイルとして保存した.

2. 手作業によるノイズ除去

閾値処理された PNG 画像に含まれる金属痕やベッドなどの ノイズを一つ一つ目視で確認し. 画像処理ソフト GIMP (https://www.gimp.org)を用いて除去した. 画素値 10 を閾値 (0 または 255) として 2 値化し. PNG ファイル (ターゲット画 像) として保存した.

3) U-net ニューラルネットワークと学習

*1.* U-net

keras-unet (https://pypi.org/project/keras-unet/)を用 いて入出力とも 512 x512 の U-net モデルを構築した. 最終的 な出力の活性化には. ReLU (Rectified Linear Unit)を用 い.Batch normalization オプションをつけた. 損失関数とし て 平 均 二 乗 誤 差 を . 最 適 化 に は Adabelief(https://github.com/juntang-zhuang/Adabelief-Optimizer)を用いた.

2. 機械学習

元の DICOM 画像とそれに対応する対象画像のデータセット (7671 組)を.5671 組のトレーニングデータセットと 2000 組 の検証データセットに分割した.DICOM の値は 1000 で割り.タ ーゲット画像の値は 255 で割り.正規化した.U-net モデルはト レーニングデータセットを用いて.early stopping オプション (https://keras.io/api/callbacks/early\_stopping/)で学習 させ.最適な重みを保存した.

3. 検証

2000 枚の検証用データセットの DICOM 画像を学習モデルに 与え.出力画像を閾値 0.5 で二値化し予測画像とした.予測画 像とターゲット画像との間の平均二乗誤差を算出し.平均二乗 誤差と 512×512 を掛け合わせたものをデータセットの誤差画 素数とした.

視覚化するために.二値化された予測画像は緑チャンネルで 表示し.ターゲット画像は赤のチャンネルで表示した.重ね合 わせると一致する画素は黄色で表示され.エラー画素は緑色ま たは赤色で表示される.

# 3. 結果

訓練時間は42時間53分で299回の学習で最適値を得た1 画像辺りの平均二乗誤差は5.66 x 10-5.標準偏差1.58 x 10-4.誤差画素数は平均14.83 pixel.最大568 pixel であった.ヒ ストグラムを図1に示す.誤差画素数の多かったものから6枚 の重ね合わせ画像を図2に示す.再構築の1例を図3に示す.



図1 2000 枚のデータにおける誤差画素数ヒストグラム



図 2 予測画像を緑、ターゲット画像を赤、重ね合わせると一致した 画素は黄色で表示される。この例では誤差画素数は 324 であった

#### 4. 考察

メタルアーチファクトの低減法としては. 畳み込みニューラ ルネットワーク[3]や敵対的生成ネットワーク[4]を活用した ものなどいくつか報告されている. その多くは. 硬組織だけで なく軟組織の修復も意図している. 本研究は骨の抽出に特化し. ターゲット画像を二値化し単純化したことが高い予測精度に 繋がったと考える. 機械学習の精度とは. 学習データの入力と 出力の関係を表す関数法則が検証データで成立しているかど うかということである. 本研究では. アーチファクトやベッド を手動で除去した骨領域画像 (ターゲット画像)を作成するこ とが「正しさ」の鍵となっている. しかし. 元の DICOM 画像では. アーチファクトが真の情報を覆い隠している場所では完全に 再現することは不可能であり. 解剖学や臨床の知識で予測する 必要があった. そのため. 本システムによる予測の「正しさ」は 保証できないかもしれないが. 概ね満足のいくものであったと 考えている.

### 3. まとめ

機械学習により頭蓋顔面領域 CT 画像からノイズを取り除き 骨領域を取り出すシステムを構築した.

#### 利益相反の有無

この研究の一部は中谷医工計測財団および JA 共済の研究補助を受けて行われた.



図3 左は閾値で抽出した画像から再構築したもの、右はノイズ低 減後に再構築したもの

- [1] Nishimoto S, Saito T, Ishise H, et al. (2021) Three-dimensional cranio-facial landmark detection in CT slices from a publicly available database, using multi-phased regression networks on a personal computer. medRxiv: 2021.03.21.21253999.
- [2] Nishimoto S, Saito T, Ishise H, et al. (2022) Machine learningbased noise reduction for craniofacial bone segmentation in CT images. medRxiv 2022.06.26.22276925
- [3] Park HS, Lee SM, Kim HP, et al. (2017) Machine-learningbased nonlinear decomposition of CT images for metal artifact reduction. DOI: 10.48550/arxiv.1708.00244.
- [4] Nakao M, Imanishi K, Ueda N, et al. (2019) Three-dimensional Generative Adversarial Nets for Unsupervised Metal Artifact Reduction. IEEE Access 8: 109453–109465.

# 入力画像の雑音量調整による深層学習雑音除去法の性能改善

高橋 佳太郎\*1, 植田 貴之\*1, 山登 一輝\*1, 伊藤 聡志\*1

\*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

# Improvement of Deep Learning-based Image Denoising Using Noise Control

Keitaro TAKAHASHI<sup>\*1</sup>, Takayuki UEDA<sup>\*1</sup>, Kazuki YAMATO<sup>\*1</sup>, Satoshi ITO<sup>\*1</sup>

<sup>\*1</sup> University of Utsunomiya, Graduate Program in Information, Electrical and Electronic Systems Engineering

要旨: MR 画像の雑音除去問題では,生体構造の保持と雑音除去性能の双方を高めることが要求される. 深層学習の登場により雑音処理能力は高められたが,それでも雑音量が多くなるにつれて雑音除去による生体構造の平滑化の度合いが大きくなる.本研究では,雑音除去処理前にローパスフィルタにより見かけの雑音量を低減した後に雑音除去フィルタを適用し,雑音除去後にハイパスフィルタにより高周波成分を復元する方法の検討を行った.本法では,雑音除去前に雑音量が減じられているので,雑音除去フィルタによる生体構造の損失は大きく低減される. 深層学習雑音除去フィルタ(DnCNN)を利用した実験の結果,ハイパスフィルタによる雑音の増幅は大きくなく,一方で生体構造の保存程度が顕著に改善される可能性が示された. PSNR と SSIM による定量的評価によっても改善が確認された.

キーワード: 雑音, ローパスフィルタ, 深層学習, DnCNN

### 1. はじめに

生体より得られる NMR 信号は微弱であり,生体や電気信号 由来の雑音が混入する.深層学習の利用により雑音除去フィル タの性能は向上したが,それでも雑音量が多くなると画像の平 滑効果が大きくなる傾向がある.これは,雑音と振幅変化が同 程度の信号は雑音と区別することができず,雑音除去とともに 除去されるためである.そこで,本研究では雑音除去前に見か け上で雑音を抑圧した画像を作成し,雑音が減量化された画像 に対し雑音除去を行う新たな方法を提案する.本法によれば, 雑音除去に伴う画像の構造損失の抑制が期待できる.

雑音の抑圧には周波数空間においてローパスフィルタを与 え,雑音除去後には、ハイパスフィルタを与えて高周波成分を 回復させた.ハイパスフィルタにより雑音も増幅されるが、高 性能な雑音除去フィルタを使用すると処理全体として画像の 構造を残した効果的な雑音除去が期待できる.本研究では、雑 音除去性能の改善を目的として雑音除去フィルタの種類、ロー パスフィルタの特性、および雑音量を変えて性能評価を行った ので報告する.

### 2. 雑音量制御を導入した MR 深層学習雑音除去法

本研究で雑音除去前の前処理として、雑音抑圧効果が高く、 かつ可逆フィルタである式(1)のローパスフィルタを使用した.

$$L(i,j) = \frac{1}{1 + aQ(i,j)}$$
(1)

ここで、(*i*,*j*)は周波数空間のインデックス、Q(i,j)は周波数空間のハイパスフィルタに相当し、aはフィルタ強度を決めるパラメータである.入力雑音画像のサイズを $N_x \times N_y$ とするとき、Q(i,j)は以下の式となる.

$$Q(i,j) = \frac{\left(\frac{N_x}{2} + 1 - i\right)^2}{\left(\frac{N_x}{2}\right)^2} + \frac{\left(\frac{N_y}{2} + 1 - j\right)^2}{\left(\frac{N_y}{2}\right)^2}$$
(2)

雑音画像を R,ローパスフィルタを L, 雑音抑制画像を S,フ ーリエ変換とその逆変換を Fと IF とするとき,Sは式(3)によ り与えられる.

$$S = IF[F[R] \cdot L]$$
(3)

式(3)で得られた雑音抑制画像に雑音除去処理(Dn)を適用し, 雑音抑制画像 D を得る.

$$D = Dn(S) \tag{4}$$

D に対しハイパスフィルタ H = 1 + aQ(*i*, *j*) を適用し, 高周波 成分を回復させて雑音除去像 E を得る.

$$\mathbf{E} = \mathbf{IF}[\mathbf{F}[\mathbf{D}] \cdot \mathbf{H}] \tag{5}$$

本方法の処理の流れを図1に示す.本研究では雑音処理フィル タとして,深層学習利用で知られている DnCNN[1]を中心に検 討した.



図1. 本研究の雑音除去法の処理図

#### 3. DnCNN

DnCNN は入力層,中間層,出力層を含んだ 17 層によって構成された,画像の雑音除去に特化した CNN である. 各層は,

入力データの特徴抽出のための畳込み,活性化関数,バッチ正 規化から構成される. DnCNN は雑音を含む画像から雑音成分 を推定する残差学習法を用いる方法により雑音重畳画像と原 画像が類似している場合に効果的な雑音除去ができる[2].本 研究では,雑音量を変えて学習を行い,雑音量が未知な画像に 対応可能なブラインド雑音処理(BDnCNN)とした.

### 4. 雑音除去実験

MR 画像 10 枚に対し, 2.5%~7.5%のガウス型白色雑音を 重畳し, それぞれ DnCNN のみを用いた雑音除去(DnCNN), 雑 音量制御を導入した深層学習雑音除去 (Noise Controlled DnCNN: NC-DnCNN) を適用した. 雑音除去像の PSNR, SSIM をそれぞれ表1に, フィルタ係数aと PSNR の関係を表すグラ フを図2に, 雑音量 5.0%のときの雑音除去像を図3に示す.

表1に示すように、NC-DnCNN は実験を行った雑音量に対して、DnCNN よりも高い PSNR,SSIM を得ることができた. また、雑音除去像を比較すると、DnCNN は全体的に画像の平

雑音量	評価方法	BDnCNN	NC-BDnCNN	а
雑音量	PSNR	33.89	34.64	1.4
(2.5%)	SSIM	0.943	0.957	2.0
雑音量	PSNR	30.55	30.85	0.8
(5.0%)	SSIM	0.901	0.911	1.2
雑音量	PSNR	28.71	28.77	0.7
(7.5%)	SSIM	0.870	0.874	0.8

表 1. PSNR[dB]と SSIM の評価結果



図 2. フィルタの係数aと PSNR の関係

滑化が起きているのに対し, NC-DnCNN では, 画像の細部構 造とコントラストの保存性能が, DnCNN と比べて優れている.

NC-DnCNN では DnCNN による雑音除去の前にローパスフ ィルタを適用し,見かけ上の雑音量を低減させることにより BDnCNN による雑音除去の際に伴う構造の損失を少なくする ことができる.その後,ハイパスフィルタの適用によって画像 の復元ともに雑音が増幅するが,BDnCNN が効果的に雑音を 除去したために雑音の増幅は少なく,フィルタ全体として画像 の構造を残した雑音除去を行うことができた.本法では,任意 の量の雑音画像に対して雑音除去処理を行う必要があるので, ブラインド雑音処理が有効であった.

提案法は,既存の雑音除去フィルタの前処理と後処理を加え るのみで性能の改善が期待できる.本稿では示していないが, BM3D[3]やWNNM[4]などの非学習型雑音除去フィルタに適用 した場合にも PSNR の改善は少ないが細部構造の保存性に優 れる結果が得られた.BM3D やWNNM との比較において深層 学習雑音除去法の優れた性能が再確認された.また,BM3D で も有効性が認められ,雑音量制御は実用性が高い方法と考える.

# 6. まとめ

雑音除去フィルタの前後に雑音量制御をと導入することに より雑音除去性能を改善できる可能性が示された.深層学習雑 音除去法を使用した実験では,再学習せずに雑音除去性能の改 善と画像の詳細構造保存を両立することができた.今後の課題 は,パラレル雑音除去法との併用や,拡散強調画像などへの応 用である.

### 謝 辞

MR 画像を提供いただいたキヤノンメディカルシステムズ, InformationeXtractionfromImages に感謝の意を表します.

#### 利益相反の有無

なし



 K. Zhang et al., IEEE Tran Image Proc., Vol.26, 3142-3155, 2017.
 K.He, X.Zhang et al., IEEE Conference on Computer Vision and Pattern Recognition, pp.770-778, 2016.

[3] K.Dabov, A.Foi et al., "Image denoising with block-matching and 3D filtering,"SPIE Electronic Imaging '06, No.6064A-30, California, 2006.
[4]S.Gu, Q.Xie et al., "Weighted Nuclear Norm Minimization and Its Applications to Low Level Vision,"International Journal of Computer Vision, Vol.121, pp.183-208, 2017.



図 3. 雑音除去像(5.0%)への適用結果

# 異常データ検知トモグラフィと深層学習を用いた CT メタルアーティファクト除去の ハイブリッド手法

 『 澤娜<sup>\*1</sup>,金 喜正<sup>\*1</sup>,藤井 克哉<sup>\*1</sup>,滝沢 穂高<sup>\*1</sup>,工藤 博幸<sup>\*1</sup>

 <sup>\*1</sup> 筑波大学システム情報系

# A Hybrid Method of Abnormal Data Detected CT and Deep Learning for CT Metal Artifact Reduction

Jia Zena<sup>\*1</sup>, Heejeong Kim<sup>\*1</sup>, Katsuya Fujii<sup>\*1</sup>, Hotaka Takizawa<sup>\*1</sup>, Hiroyuki Kudo<sup>\*1</sup>

\*1 University of Tsukuba

要旨:本論文では,CTにおけるメタルアーティファクト除去の問題に対して,金属を通る投影データの異常値の場所を自動的に 推定し除外して再構成を行う逐次近似法である異常データ検知トモグラフィ(ABT-CT)と深層学習を組み合わせたハイブリッド型 の画像再構成法を提案する.シミュレーション実験の結果,提案手法は深層学習やABD-CTを単独で用いる場合と比較して画質改 善効果が大きく,有効であることが明らかになった.

キーワード: CT, 画像再構成, 逐次近似法, 深層学習, メタルアーティファクト

#### 1. はじめに

本研究では、CT 分野で重要な未解決問題のメタルアーティ ファクト除去を取り扱う. CT 撮影において被写体に金属が含 まれている場合、フィルタ補正逆投影(FBP)法や通常の逐次 近似再構成法では、ビームハードニング・統計雑音・散乱線の 影響により再構成画像に著しいストリークアーティファクト や黒帯アーティファクトが発生する.近年、歯科にとどまらず 人体に金属を埋め込む治療が多く行われるようになり,この問 題の重要性は高まっているが完全な解決策は存在しないのが 現状である.本研究では、投影データに含まれる異常データを 除外して画像再構成を行う巧妙な逐次近似再構成法である異 常データ検知トモグラフィ<sup>[1],[2]</sup>(ABD-CT)と深層学習を組み 合わせた強力なメタルアーティファクト除去手法を提案する. 提案手法では, ABD-CT の再構成画像を畳み込みニューラルネ ットワーク(CNN)に入力して, 画質を改善した再構成画像を 出力する原理に基づいている. CNN の訓練は、シミュレーシ ョンにより作成した金属あり ABD-CT 再構成画像と正解画像 の組を多数集めた学習データを用いて、教師あり学習により行 う. 既に, 筆者らのグループは低線量 CT とスパースビューCT の画像再構成に対して同じ原理の再構成法を提案しており,提 案手法はこの手法をメタルアーティファクト除去の問題に拡 張したものと位置づけられる. 歯科用 CT 画像のデータセット を用いたシミュレーション実験を行った結果、提案手法は ABD-CT, 深層学習を単独で用いる場合と比較して, 各々の欠 点を補い合い高画質の画像を出力することが明らかになった. アマルガム, チタン, 鉄など吸収が比較的小さい金属のみなら ず,通常の手法では困難な吸収が大きい銀の場合にも提案手法 により十分な画質の画像が得られることが明らかになった.

### 2. 提案手法

図1に,提案手法の処理手順を表すブロック図を示す.提案 手法では,まず投影データに異常データ(本論文の問題では金 属を通るビームハードニング・統計雑音・散乱線の影響を受け たデータ)が含まれている場合でもその影響を除外して高画質 で画像再構成が行える ABD-CT と呼ばれる逐次近似法を用い て、測定された投影データbの画像再構成を行い CNN の入力 画像vを生成する.

投影 データ ┣	ABD-CT 画像再構成	中間 画像 y	CNN (ResNet)	再構成   
図 1 Algori	提案するハ- ithm 1 (ABD-CTにF	イブリッ 肌いる高速反	ド再構成法の て て 復法のDLPMアル	D原理 ゴリズム)
$\vec{x}^{(0)} = 0,  \mu_i^{(0)} = k = 0, 1, 2, \cdots$	$0 (i = 1, 2, \dots, I), \vec{y}$	$\vec{z}_{I+1}^{(0)} = 0, \vec{z}^{(0)}$	= 0	
$\vec{x}^{(k,1)} = \vec{x}^{(k)}$	$+\vec{z}^{(k)}$	2 -	-1 (q < -1)	
$\vec{x}^{(k,i+1)} = \mu_i^{(k+1)} = .$	$ec{x}^{(k,i)} + (\mu_i^{(k)} - \lambda lpha)$ $\lambda lpha$	(q = -	$\frac{\left  \begin{array}{c} q & (-1 \le q \le 1) \\ 1 & (q > 1) \\ \hline b_i - \vec{a}_i^T \vec{x}^{(k,i)} - \ \vec{a}_i\ ^2 \\ \hline \alpha \ \vec{a}_i\ ^2 \end{array} \right $	<u>ル(<sup>k)</sup> データ項の処理</u>
$\vec{x}^{(k,l+2)} = \text{pro}$	$\mathbf{x}_{\alpha\beta\ \bar{x}\ _{NLTV}}(\bar{x}^{(k,l+1)} +$	$\vec{y}_{I+1}^{(k)}) \equiv \min_{\vec{x}}$	$\frac{1}{2\alpha} \ \vec{x} - (x^{(k,I+1)})\ $	$+ \vec{y}_{I+1}^{(k)} \ ^2 + \beta \ \vec{x}\ _{\text{NLTV}}$
$\vec{y}_{I+1}^{(k+1)} = \vec{y}_{I+1}^{(k)}$	$\vec{x}_{1}^{(k,l+1)} - \vec{x}^{(k,l+2)}$	)		NLTV項の処理
$\vec{x}^{(k+1)} = \vec{x}^{(k,I)}$ $\vec{z}^{(k+1)} = \vec{z}^{(k)}$	+1) + $\vec{x}^{(k,I+1)} - \vec{x}^{(k,1)}$	Proximal Mi	nimizationの処理	$\alpha > 0$ Stepsize

ABD-CT の原理を詳しく述べると以下のようになる. 通常の 圧縮センシング画像再構成では、L<sup>2</sup> ノルムからなるデータ項 L(**x**)と正則化項U(**x**)の和で構成される次式の評価関数を最小 化して画像再構成を行う.

 $f(\mathbf{x}) \equiv L(\mathbf{x}) + \beta U(\mathbf{x}), L(\mathbf{x}) = ||A\mathbf{x} - \mathbf{b}||_2^2/2, U(\mathbf{x}) = ||\mathbf{x}||_{NLTV}$  (1) ただし、本論文では滑らかな濃度変化を保存する性能が高い非 局所トータルバリエーション (NLTV) を正則化項に用いる. しかし、 $L^2$ ノルムのデータ項は金属を通る異常データに敏感に 反応して、再構成画像に強いストリークアーティファクトや黒 帯アーティファクトが発生する.そこで、ABD-CT ではその影 響を軽減するため、異常データの場所を自動的に推定し除外し て再構成を行うロバスト推定の効果を持つ  $L^1$ ノルムデータ項 を用い、次式の評価関数を最小化して画像再構成を行う.  $f(\mathbf{x}) \equiv L(\mathbf{x}) + \beta U(\mathbf{x}), L(\mathbf{x}) = ||A\mathbf{x} - \mathbf{b}||_1^1, U(\mathbf{x}) = ||\mathbf{x}||_{\text{NLTV}}$  (2) 筆者らは既に ABD-CT をメタルアーティファクト除去に応用 する研究を行ったが,  $L^1$ ノルムがアーティファクトを軽減する 効果は極めて大きい<sup>[3]</sup>. 式(2)を最小化する逐次近似法としては, 高速に収束する Dykstra 型スプリッティングに基づく反復法

(DLPM)<sup>[4]</sup>を採用する.Algorithm1に,DLPM法の反復式を まとめて示す.ABD-CTはメタルアーティファクト除去に有効 な再構成法であるが,メタルの場所を正しく推定する性能は必 ずしも十分でないため,条件が悪い場合には金属の周辺に誤差 が発生し画像を過度に平滑化しやすい問題点がある.

更に画質を改善した再構成画像を得るため、図1に示すよう に、ABD-CTの再構成画像yを画像変換のタスクを行うCNNに 入力して画質を改善した最終的な再構成画像xを求める.CNN としては、残差ブロックを導入して学習が進みやすくしたネッ トワークの ResNet を用いる.ResNet の学習は、多数の ABD-CT 再構成画像y<sub>i</sub>と正解画像x<sub>i</sub>のペア(x<sub>i</sub>, y<sub>i</sub>)(*i* = 1,2,…,*N*)を用 いて、次式の損失関数を最小化して行う.

 $f(\mathbf{\theta}) = \sum_{i=1}^{N} \|\mathbf{x}_{i} - \operatorname{ResNet}_{\mathbf{\theta}}(\mathbf{y}_{i})\|^{2}$ ただし、 $\mathbf{\theta}$ は ResNet のパラメータである. **3. シミュレーション実験**  OPC-Radiomics から取得した歯科用 CT 実画像を用いて、シ ミュレーション実験を行った. 69 人の画像から金属を含まな い断面 100 枚を切り出し、各々の歯の部分に Fe と Ag を埋め 込んだ画像を作成して 90 枚を学習画像、10 枚をテスト画像と して実験を行った. 各画像に付け加えるメタルは 2~4 個の範 囲で変化させた. 金属が Fe よりも Ag の方が吸収がはるかに 大きく、より難しい設定である. 図 2 に、金属が Fe の場合と Ag の場合の再構成画像例を示す. ABD-CT と深層学習を組み 合わせた提案手法は最も高画質の画像を再構成できており、有 効な手法であることが確認できる.

利益相反の有無: なし

# 文 献

[1] Kudo H, Takaki K, Yamazaki F, Nemoto T: Proposal of fault-tolerant tomographic image reconstruction. Proceedings of 2016 SPIE Optics + Photonics (Development in X-ray Tomography), Paper No. 9967-55, 2016

[2] 工藤: 異常データ検知トモグラフィ ABD-CT の概念提唱と事例紹介. 日本医用画像工学会第40回大会(JAMIT2021) P4-07, 2021

[3] 賈, 金, 工藤: 異常データ検知トモグラフィ ABD-CT の高速画像再構成 法とメタルアーティファクト除去への応用. 日本医用画像工学会第 41 回 大会(JAMIT2022) OP16-5, 2022

[4] Kim H, Sadakata K, Kudo H: Unified framework to construct fast row-actiontype iterative CT reconstruction methods with total variation using multi proximal splitting. Proc



(2)

図2 金属が Fe と Ag の場合の各手法の再構成画像

# 深層学習による血液エコーの非スペックル成分識別のロバスト性向上

森 友雅\*1, 大村 眞朗\*2, 長岡 亮\*2, 高 尚策\*2, 長谷川 英之\*2

\*1 富山大学大学院 医薬理工学環

\*2 富山大学 学術研究部工学系

# Improvement of Robustness in Identification of Non-Speckle Components in Blood Echoes

Using Deep Learning

# Yuga MORI<sup>\*1</sup>, Masaaki OMURA<sup>\*2</sup>, Ryo NAGAOKA<sup>\*2</sup>, Shangce GAO<sup>\*2</sup>, Hideyuki HASEGAWA<sup>\*2</sup>

<sup>\*1</sup> Graduate School of Pharma-Medical Sciences, University of Toyama

<sup>\*2</sup> Faculty of Engineering, University of Toyama

要旨:静脈を対象とした高速超音波イメージングにおいて得られる血液エコーは、血球からの斑紋状パタン(スペックル成分)に 加えて、非スペックル成分がみられることがある.非スペックル成分はスペックル成分とは異なる要因で発生しているものと想定 され、この2つの成分を識別することで血液性状評価が可能になると考えられる.非スペックル成分が高輝度エコー帯の場合は視 認や閾値処理などで識別できるが、血液エコーの輝度変化が不明瞭化した際に識別が困難になると考えられる.これまでにシミュ レーションデータに対し、深層学習を用いて非スペックル成分の識別を試みている.実測データ解析の課題として、学習モデルに おけるシミュレーションデータの特徴量への過度な適合が挙げられる.そこで本検討では、敵対的学習に基づく学習モデルの改良 を検討し、新たに識別結果のロバスト性を確認するとともに、実測データ解析の安定化を試みた. キーワード:超音波、微小血栓、セグメンテーション、深層学習、敵対的学習

# 1. はじめに

静脈血栓症の予測や網羅的な脈管機能検査のために,血液中 を循環する微小血栓の早期検出が求められる.血栓エコーなど (非スペックル成分)は血球エコー(スペックル成分)に比べ て高輝度エコー帯として観察される場合があり,包絡振幅の閾 値処理によって識別できる[1].しかし,輝度変化が不明瞭化し た際に識別が困難になると考えられる.本研究では,血液エコ ーに対して非スペックル成分の識別精度の向上を行うために 深層学習を用いる.これまでの検討ではinsilicoデータに基づ いた学習モデルを構築した[2].しかし,insilicoデータの特徴 量に学習モデルが過度に適合し,実測データへの不適合性が課 題である.本報告ではinsilicoデータに加えて実測データも関 与させる敵対的学習手法を新たに構築し,実測データにも適合 可能かつロバストな学習モデルの作成を目指す.

# 2. 学習データ

# 2.1. *in silico* データ

数値シミュレーション (Field II [3,4]) を用い,7.5 MHz リニ アプローブの送受信音場において非スペックルが含まれる血 液エコーを模擬し,段階的に非スペックルの数密度を増加させ て異なる数密度のデータを作成した.スペックル成分を模した 散乱体群を30点/mm<sup>3</sup>,非スペックル成分を模した散乱体を0 ~25点/mm<sup>3</sup>になるようにランダムに配置した.スペックル と非スペックルの散乱強度比はこれまでの検討より,安定した 識別精度を示した最低条件(スペックル:非スペックル=1:5) としている[2]. 正解ラベルについて,非スペックルの散乱体位 置において,点拡がり関数を考慮して包絡振幅のピークが 1/2 倍に落ちる領域を1とし,その他領域を0とした.

# 2.2. 実測データ

*in silico* データと同様に、スペックル成分に非スペックルが含 まれる血液エコーを模擬し、平均粒径 10 μm の粒子が 0.5%存 在する溶液 (スペックル成分) に 40 μm の粒子(非スペックル 成分)を濃度 0~0.09%で混在させた. 非スペックルの数密度 は約 0~25 点/mm<sup>3</sup>であり、散乱強度比は理論式よりスペック ル: 非スペックル=1:10 程度と推定される.

#### 3. 学習手法

提案手法の学習全体像を図 1 に示す. U-Net [5]および Discriminator [6]の学習フェーズに分けて敵対的学習を行った. experimental data (target)



図1:提案手法の学習全体像

3.1. 従来手法

これまでの深層学習モデルは U-Net を,損失関数は式(1) を用いていた.式(1) によって *in silico* データ( $x_s$ )のセグメ ンテーション結果( $\hat{x}_s$ ) と正解ラベル( $y_s$ )の損失を最小化す る深層学習モデルになるようにパラメータが更新される.

$$BCELoss = -\{y_s \log_e \hat{x}_s + (1 - y_s) \log_e (1 - \hat{x}_s)\}$$
(1)

#### 3.2. 提案手法

本検討では敵対的学習の影響を確認するために U-Net に加 えて Discriminator を用いる. U-Net の損失関数は式 (2), Discriminator が式 (3) である.

 $Loss_{U-Net} = BCELoss + w\{(\hat{\hat{x}}_t - 0.5)^2 + (\hat{\hat{x}}_s - 0.5)^2\}$ (2)  $Loss_{Discriminator} = (\hat{\hat{x}}_t - 1)^2 + \hat{\hat{x}}_s^2$ (3)

U-Net の損失関数は従来手法の目的に加えて、Discriminator の 予測値が *insilico* ( $\hat{x}_s$ ) または実測データ ( $\hat{x}_t$ ) の場合でも同等 の値 (0.5) を出力するように深層学習のパラメータが更新され る.本検討では w は 0.05 としている.対して Discriminator は U-Net のセグメンテーション結果が *in silico* データ ( $\hat{x}_s$ ) の場 合は 0,実測データ ( $\hat{x}_t$ ) の場合は 1 と出力するように深層学 習モデルのパラメータが更新される.敵対的学習により、*in silico* データのセグメンテーション精度を保持しつつ、実測デ ータの誤分類を抑制できると考えられる.

#### 4. 結果

2 つの深層学習モデルを用い, in silico および実測データの 非スペックルの検出率を算出した結果, セグメンテーション像 を図2に示す. 従来手法を用いた際, 実測データでは in silico データと比較して検出率が大きく増加しており, セグメンテー ション像も無作為な過剰抽出が多い. in silico データの特徴量 を用いた深層学習モデルにおいて, 実測データの特徴量に合致 しないケースが多いと考えられる. 対して提案手法では, 実測 と in silico データの検出率は同等であり, 実測データ間のばら つきも抑えられた. 敵対的学習によって, in silico データに過 度に依存しない深層学習モデルを実測データのセグメンテー ションに反映できた.

#### 5. まとめ

本報告では,血液エコー内の非スペックル成分をセグメンテ ーションするための深層学習において,正解ラベルの用意が困 難な実測データを含めた敵対的学習手法を新たに検討した.

結果,実測データの過度な検出を抑制し, in silico データの 傾向と類似することが確認された.今後,さらなるロバスト性 の向上のために, Discriminator の条件依存性を確認するととも に, in vivo 血液データの評価も行う.



図2:2つの学習モデルによる

非スペックル成分の検出率の比較と出力の一例

#### 謝辞

本研究の一部は JSPS 科研費 18KK0110, 20J01391, 23K17225, 田村科学技術振興財団の助成を受けたものです.

#### 利益相反の有無

なし

### 文献

- [1] Omura M, Yagi K, Hasegawa H et al: J Med Ultrason 50: 131-141, 2023
- [2] 森友雅,茂澄倫也,長谷川英之ら:深層学習による静脈内異常エコー 検出のためのシミュレーションによる基礎検討.日本音響学会秋季研 究発表会予稿集: 3-7Q-4, 2022
- [3] Jensen J.A, Svendsen N.B: IEEE Trans Ultrason Ferroelectr Freq Cont 39: 262-267, 1992
- [4] Jensen J.A, Med Biol Eng Comput 34: 351-353, 1996
- [5] Ronneberger O, Fischer P, Brox T et al: MICCAI, Springer: 234–241, 2015
- [6] Ian J. Goodfellow, Jean Pouget-Abadie, Mirza Jean et al: Generative adversarial nets, NIPS, 2014

# 高時間分解能を保持した超音波周波数特性解析の広帯域化

大村 眞朗\*1,長岡 亮\*1,八木 邦公\*2,長谷川 英之\*1

\*1 富山大学 学術研究部工学系

\*2 金沢医科大学 医学部

# Ultrasonic spectral analysis in multi-frequency excitation with high-frame-rate imaging

Masaaki OMURA<sup>\*1</sup>, Ryo NAGAOKA<sup>\*1</sup>, Kunimasa YAGI<sup>\*2</sup>, Hideyuki HASEGAWA<sup>\*1</sup>

<sup>\*1</sup> Faculty of Engineering, University of Toyama

<sup>\*2</sup> School of Medicine, Kanazawa Medical University

要冒:これまでに超音波高時間分解能イメージングを用い,超音波伝搬方向に対する周波数特性を解析することで,低ずりでの 赤血球凝集および高ずりでの解放(赤血球単体)状態の評価可能性を検討してきた.本報告では,それらの状態をより高精度に指 標化するために,広帯域解析に向けた送受信シーケンスおよび解析手法を新たに検証する.平均粒径が異なる均質な散乱体ファン トムを計測し,散乱体サイズの推定精度を比較した.従来の単一周波数での解析結果に比して,広帯域化条件での散乱体サイズ推 定誤差の低減を確認した.また,血流速と血液性状の同時評価のために in vivo 頸動脈・静脈の超音波撮像を行った.健常例の動脈 に比して,静脈の血液部分における散乱体サイズが平均2μm 大きく推定され,ファントムの散乱体サイズ推定誤差以上であった.

キーワード:超音波散乱,高時間分解能イメージング,周波数特性解析,血管,血液性状

### 1. はじめに

これまでに,超音波伝搬方向に対する周波数特性を解析する ことで,低ずりにおける血しょう中の赤血球凝集・連鎖および 高ずりにおけるそれらの解放(赤血球単体)状態を示すことが できている [1,2,3]. 我々のグループでは高時間分解能イメー ジングを用いることで,実際の in vivo 拍動流における血流速 および血球の振舞いの同時評価の可能性を示してきた [4].

ー方,それら状態を指標化する上で,散乱源となる大きさを 数 μm~10 μm のスケールで高精度に推定するためには超音波 プローブの受信帯域の制約を受ける.本報告では,広帯域プロ ーブの複数周波数励起条件を新たに検討し,高時間分解能を保 持したロバストな周波数特性解析法を提案する.

#### 2. 計測および解析手法

#### 2.1 超音波送受信シーケンス

超音波送受信システム (RSYS0016, Microsonic) と広帯域リ ニアプローブ (L18-4, Konica Minolta) を用いて超音波 RF デ ータを収集した. パルス繰り返し周波数 (PRF) 10 kHz で一回 の平面波送信を行い,受信開口 F#1 で遅延和ビームフォーミ ングすることで,低解像イメージを得た. 異なる 3 つの送信角 度 (-5, 0, 5 度)の低解像イメージを加算平均し,高解像イ メージを形成した.送信波の中心周波数は 7.8, 12.5 MHz とし, 2 周波数でのイメージング結果のフレームレートは 1736 Hz で ある.

# 2.2 計測対象

超音波周波数特性解析による散乱体サイズ推定精度を比較

するために、平均粒径が異なる均質なファントムを計測した. 粒径は10,20,30 µm であり、エコー強度を概ね同程度にする ために散乱体の重量パーセント濃度をそれぞれ2,0.8,0.4%と した.反射法により計測した減衰係数はそれぞれ0.20,0.18, 0.35 dB/cm/MHz である.

また,1心拍あたりの高時間分解能イメージングが可能かを 評価するために, in vivo 脈管の超音波撮像も行った.

### 2.3 超音波周波数特性解析

任意の深度dにおいて,超音波伝搬方向の周波数fのパワースペクトルPは式(1)のように示される.

$$P(f,d) = S(d) \cdot \exp\left[\frac{4df\alpha}{8.686}\right] \cdot BSC(f) \tag{1}$$

ここで,*S*はシステムの音場特性,*a*は減衰係数 [dB/m/MHz], *BSC*は後方散乱係数 [m<sup>-1</sup>sr<sup>-1</sup>]を示す.同様に音響特性が既知な 参照ファントムからのパワースペクトルは式(2)である.

$$P_{\rm ref}(f,d) = S(d) \cdot \exp\left[\frac{4df\alpha_{\rm ref}}{8.686}\right] \cdot BSC_{\rm ref}(f) \tag{2}$$

式(1)を式(2)で除算し、対象媒質のBSCを算出できる [5].

$$BSC = \frac{P(f,d)}{P_{\rm ref}(f,d)}BSC_{\rm ref}(f)\exp\left[\frac{4df(\alpha - \alpha_{\rm ref})}{8.686}\right]$$
(3)

ここで、 $\alpha$ 、 $\alpha_{ref}$ はファントムの減衰係数、 $BSC_{ref}$ は理論値 (Faran モデル) [6]であり、参照ファントムの粒径は 10  $\mu$ m である.

算出したBSCの特徴量として,式(4)の近似式における傾き項 n (slope)を推定した.波長に対して微小な散乱体からのBSC はレイリー散乱に従いn = 4に近づくが,散乱体サイズが大き くなるとn < 4を示す.

$$\log_{10}[BSC(f,d)] \approx n\log_{10}f + \log_{10}b \tag{4}$$

式(5)に示す波数kに対する誤差関数の最小解a(散乱体サイズ) および $\phi$ (体積分率)を求めた. $\phi$ は各ファントムの散乱体重 量パーセント濃度で固定し, $BSC_{th}$ は,流体球の構造因子(干 渉特性)を考慮した理論モデル [7]である.

$$Cost(a,\phi) = \sum_{i} \left\{ log_{10} \left[ \frac{BSC_{th}(k_i)}{BSC(k_i)} \right] \right\}^2$$
(5)

# 3. 結果および考察

粒径 10 μm ファントム, in vivo 頸動脈の血液について, 各 周波数および 2 周波数の平均パワースペクトルを図 1 に示す. -20 dB帯域について, 励起周波数が 7.8 MHz のとき約 5~10 MHz, 2 周波数のとき 5~15 MHz であり, 対従来約 50%増の 広帯域化が確認できる. 図 2 に各ファントムのBSC (a)および その特徴量を示す. slope (b)の推定結果について, 各周波数に 比べて 2 周波数の方のばらつきが小さい. 散乱体サイズの推定 結果 (c)についても, 各周波数に比べて, 2 周波数のばらつき が小さいかつ実際の平均粒径に近い傾向であり, 2 周波数のと き, 20 μm粒子ファントムでの最大平均誤差は 1 μm であった.





推定結果



図 3 in vivo 頸動脈(1)・静脈(2)の血流強調像(a), 散乱体サイズ 分布(b), 流速(c)および散乱体サイズ(d)の短時間変動

2 周波数の広帯域化により,低周波側(約5~10 MHz)の S/N を保持しつつ高周波側(約10~15 MHz)の slope 変化を捉え られたと考えられる.

健常成人男性の頸動脈・静脈において,特異値分解法に基づき血流強調像を生成し,ブロックマッチング法による流速およびずり速度解析 [4]を適用した.また,ファントムと同様の解析手法により散乱体サイズを推定した.図3に評価指標の空間分布と短時間変動を示す.動脈に比べて静脈における散乱体サイズが平均的に約2µm大きく推定された.血液は非ニュートン流体として振る舞い,動脈より静脈はずり速度が小さいため,血球サイズの違いが表れている可能性が示唆される.

### 4. まとめ

本報告では,広帯域プローブの複数周波数励起条件を新たに 検討し,広帯域・時間分解能・感度を保持したロバストな超音 波周波数特性解析を検討した.2 周波数での広帯域化により, ファントム散乱体サイズの推定精度を向上させ, in vivo 頸部脈 管では拍動周期あたりの血球サイズの推定を安定化させた.今 後, in vivo 症例や薬剤応答の定量評価も行う.

#### 謝辞

本研究の一部は JSPS 科研費 18KK0110, 20J01391, 23K17225, 田村科学技術振興財団の助成を受けたものです.

利益相反の有無なし

- [1] Higashiyama K, Kanai H et al: Jpn J Appl Phys 61: SG1046-1-10, 2022
- [2] Garcia-Duitama J, Cloutier G et al: Ultrasound in Med Biol 41: 2506-2519, 2015
- [3] Chayer B, Cloutier G et al: Clin Hemorheol Microcirc 74: 109-126, 2020
- [4] Omura M, Hasegawa H et al: Sensors 23: 2639, 2023
- [5] Yao L, Medsen E et al: Ultrasonic Imaging 12: 58-70, 1990
- [6] Faran J: J Acoust Soc Am 405: 405-418, 1951
- [7] Franceschini E, Cloutier G et al: IEEE Tran Ferroelectr Freq Cont 58: 2668-2679, 2011

# 確率的 Dykstra 型スプリッティングによる統一的なブロック反復型画像再構成法の構成: CT と PET への応用

工藤 博幸<sup>\*1</sup>, 金 喜正<sup>\*1</sup>, 藤井 克哉<sup>\*1</sup> <sup>\*1</sup> 筑波大学システム情報系

# Unified Framework to Construct Block-Iterative Image Reconstruction Methods by Stochastic

# **Dykstra-Like Splitting: Application to CT and PET**

Hiroyuki Kudo<sup>\*1</sup>, Heejeong Kim<sup>\*1</sup>, Katsuya Fujii<sup>\*1</sup>

\*1 University of Tsukuba

**要旨**:本論文では,高速に収束するブロック反復型画像再構成法を構成する新しい数学的枠組みである「確率的 Dykstra 型スプリ ッティング」を提案し,それに基づき構築した CT と PET の画像再構成法を実装して高収束性を実証した.また,確率的 Dykstra 型 スプリッティングの数学的収束性を考察して,厳密に問題の解に概収束することを示した.長年の逐次近似画像再構成分野におけ る未解決問題である,数学的に厳密な収束性を持つブロック反復法を構成する統一的な枠組みを示した研究といえる. **キーワード**: CT, PET,画像再構成,逐次近似法,近接スプリッティング

#### 1. はじめに

CT や PET の画像再構成では、対数尤度(最小2 乗誤差)に 正則化項を加えた凸評価関数を高速に最小化する逐次近似法 が必要になる.特に,評価関数を部分評価関数の和に分解して 部分評価関数毎に画像更新を行うブロック反復型(Row-Action 型)再構成法が有効であることが知られるが、厳密に真の解に 収束せず雑音特性が悪いことが長年問題とされてきた. その解 決策として,緩和係数をゼロに近づけながら画像更新を行う手 法[1],[2]がよく用いられるが、厳密な解に収束する証明がなく緩 和係数制御に経験的なパラメータ設定が必要である.また,近 年スパースビューCT や低線量 CT の画像再構成では正則化項 に微分不可能な Total Variation (TV) などがよく使われ、それ に対応する必要があることがこの問題を難しくしている.筆者 らは、緩和係数制御が不要なブロック反復型再構成法として既 に DUCOA 法<sup>[3]</sup>, Dykstra 型スプリッティングに基づく Row-Action 型反復法 (DLPM 法)<sup>[4],[5]</sup>を構築したが,実用的に上手 く動作する一方厳密な収束が保証される手法とはいえていな い.

本研究では、これらの問題点を解決する新しいブロック反復 型再構成法構築の数学的枠組みとして「確率的 Dykstra 型スプ リッティング」と呼ばれる枠組みを提案して、CTの(複数の) 正則化項+最小2乗誤差を最小化する画像再構成問題,PETの 非負制約付き対数尤度+正則化項を最小化する画像再構成問 題に適用した.その結果、どちらの場合も提案手法は非常に上 手く動作して高速に収束し、計算時間や実装の容易さは既存の 収束が保証されない類似手法と同等であった.確率的 Dykstra 型スプリッティングの収束性を保証するキーは、データアクセ ス順序をランダムにする<sup>[2]</sup>, Dykstra 型スプリッティングに(強 凸性がない最適化で問題の)摂動項の影響を消すトリックを精 密に組み込む、の2つである.また、実用的に上手く動作する データアクセス順序についても検討を行った.更に、提案手法 の収束性を数学的に考察して、厳密な問題の解に概収束 (almost sure convergence) することを証明した.

#### 2. 提案手法

本論文では,次式の評価関数を最小化する CT の画像再構成 を取り扱う.

 $f(\mathbf{x}) \equiv L(\mathbf{x}) + \beta U(\mathbf{x}), L(\mathbf{x}) = ||A\mathbf{x} - \mathbf{b}||_2^2 / 2, U(\mathbf{x}) = ||\mathbf{x}||_{TV}$  (1) ただし、 $\mathbf{x} = (x_1, \dots, x_J)^T$ は画像ベクトル、 $\mathbf{b} = (b_1, \dots, b_J)^T$ は投 影データベクトル,  $L(\mathbf{x})$ は最小 2 乗誤差で構成されるデータ項,  $U(\mathbf{x})$ は正則化項で通常 TV が用いられる. PET の画像再構成の 場合には、データ項を KL Divergence に正則化項を Relative Difference Prior などに変更することで対応でき、本論文の手法 は CT にも PET にも統一的に適用可能である.

筆者らは、文献[4],[5]において DLPM (Dykstra-Like Splitting with Proximal Minimization) 法と命名した,緩和係数制御の必要がない新しいブロック反復型再構成法を提案した. DLPM 法では,評価関数*f*(x)を次式のように部分評価関数の和の形に分解しておき,部分評価関数に順番に近接写像を作用させることで反復式を構成する.

# $f(\mathbf{x}) \equiv \sum_{i=1}^{I+1} f_i(\mathbf{x})$

 $f_i(\mathbf{x}) \equiv (a_i^T \mathbf{x} - b_i)^2/2$  (*i* = 1,2,…,*I*),  $f_{I+1}(\mathbf{x}) \equiv \beta \|\mathbf{x}\|_{\text{TV}}$  (2) DLPM 法を Algorithm 1 に示す.数学的に DLPM 法は式(1)の最 小化問題の双対問題をマルチブロックに拡張した ADMM 法で 解くことで導出できるが、マルチブロックの ADMM 法は実用 的に多くの問題に対して上手く動作する反面、厳密な収束性が 証明できないことが知られる.

本論文では、DLPM 法に厳密な収束性を持たせるため、文献 [2],[6]のようにデータアクセス順序を確率的にランダムに決定 する手法を導入し、「確率的 Dykstra 型スプリッティング (S-DLPM)」と呼ぶ.この手法では、部分評価関数のインデックス 集合を $S \equiv \{1, 2, ..., I + 1\}$ として、各反復回数nにおいてSから一 要素iをランダムに選択し、 $f_i(\mathbf{x})$ の近接写像により画像更新を 行うことを繰り返す.そして、DLPM 法で必要となる摂動項の 影響を消すトリック(Algorithm 1 における Proximal center の update)は、各部分評価関数の処理の直後に行う形に分配して、 1/(l+1)の重みで行う. S-DLPM 法を Algorithm 2 に示す.本 論文では、S-DLPM 法は厳密な問題の解に概収束(almost sure convergence)することを数学的に証明した(各点収束は言えな い). 証明のキーは、S-DLPM 法が Chambolle らの「確率的主 双対勾配降下法」<sup>[6]</sup>の特別な場合になっていることを示すこと により行った.

S-DLPM 法は、完全ランダムなデータアクセス順序を使用するため、以下の点で使い勝手が悪く実用的な収束性もDLPM 法と比較して遅い. 実際の画像再構成では、1) 各メイン反復回数kのループ内で各 index が必ず一回使用される、2) 正則化項の処理の直後に画像を取り出せる、の2 つの条件を満たすことが望ましい.この条件を満足するランダムに近い実用的なデー





 $\vec{x}^{(0)} = (\text{arbitrary}), \ \vec{y}_i^{(0)} = 0 \ (i = 1, 2, \dots, I+1), \ \vec{z}^{(0)} = 0$  $k = 0, 1, 2, \dots$ 

アクセス順序 { $\sigma_k(1), \sigma_k(2), \dots, \sigma_k(I)$ }を計算  $l = 1, 2, \dots, I + 1$   $n = k(I+1) + l, i = \begin{cases} \sigma_k(l) & (\text{for } 1 \le l \le I) \\ I+1 & (\text{for } l = I+1) \end{cases}$   $\vec{x}^{(n+1/2)} = \text{prox}_{cf_i(\bar{x})}(\vec{x}^{(n)} + \vec{y}^{(n)}_i) = \min_{\bar{x}} (\frac{1}{2\alpha} \| \vec{x} - (\vec{x}^{(n)} + \vec{y}^{(n)}_i) \|^2 + f_i$   $\vec{y}_m^{(n+1)} = \begin{cases} \vec{y}_m^{(n)} + \vec{x}^{(n)} - \vec{x}^{(n+1/2)} & (\text{for } m = i) \\ \vec{y}_m^{(n)} & (\text{otherwise}) \end{cases}$   $\vec{x}^{(n+1)} = \vec{z}^{(n)} + \vec{x}^{(n+1/2)} - \vec{x}^{(n)}$  $\vec{x}^{(n+1)} = \vec{z}^{(n)} + \vec{x}^{(n+1/2)} - \vec{x}^{(n)}$ Proximal center $\mathcal{O}$ update タアクセス順序として、以下に述べるものを提案する. 各反復 回数kの最初に、投影角度 index 集合 $\theta \equiv \{1, 2, ..., P\}$ にランダム 並べ替え(permutation)を施した数列 $\theta'_k = \{c_k(1), ..., c_k(P)\}$ を 求め、アクセス順序は投影データ index  $i \& fage_k(1)$ の動径 index 奇数 Gr (偶数 Gr)、角度 $c_k(1)$ の動径 index 偶数 Gr (奇数 Gr)、角度 $c_k(2)$ の動径 index 奇数 Gr (偶数 Gr) …角度 $c_k(P)$ の 動径 index 偶数 Gr (奇数 Gr)」の順に並べて決定する. 動径に ついて、奇数 Gr と偶数 Gr のどちらを先にするかも角度毎に ランダムに決定する. そして、このルールで決めたアクセス順 序 $\{\sigma_k(1), ..., \sigma_k(I)\}$ の順番でデータ項による画像更新を行い最 後に正則化項による画像更新を行う. そして、アクセス順序は ランダム性を最大にするため各反復回数kで決め直しする. こ の変更を加えた手法を P-DLPM 法と呼び, Algorithm 3 に示す.

S-DLPM 法と P-DLPM 法の提案が本論文の新規性である. 更に,式(1)の最小化問題に P-DLPM 法を適用して得られる具体的な反復法を Algorithm 4 に示す.また,PET の非負制約+ 正則化項付き最小化問題に P-DLPM 法を適用して得られる反 復法も導出した.スパースビューCT と PET の画像再構成に適 用した実験結果は発表で紹介する.利益相反の有無: なし

#### 文 献

 Dong J, Kudo H: Accelerated algorithm for compressed sensing using nonlinear sparsifying transform in CT image reconstruction. Med Imag Tech 35, 63-73, 2017
 Tanaka E, Kudo H: Subset-dependent relaxation in block-iterative algorithms for image reconstruction in emission tomography. Phys Med Biol 48: 1405-1422, 2003

[3] 李, 工藤: 非線形計画問題の双対性を用いた統計的 PET 画像再構成:電 子情報通信学会論文誌 J87-D-II: 62-70, 2004

[4] Kim H, Sadakata K, Kudo H: Unified framework to construct fast row-actiontype iterative CT reconstruction methods with total variation using multi proximal splitting. Proc ICBIP2021, 65-71, 2021

[5] Sadakata K, Kim H, Kudo H: Unified approach to fast convergent row-actiontype iterative methods for PET image reconstruction using multi proximal splitting. Journal of Image and Graphics 10: 82-87, 2022

[6] Chambolle A, Ehrhardt MJ, Richtárik P, Schönlieb C-B: Stochastic primal-dual hybrid gradient algorithm with arbitrary sampling and imaging applications. SIAM J Opt 28: 2783-2808, 2018

Algorithm 4 (式(1)の問題に対するP-DLPMの具	【体的アルゴリズム)
----------------------------------	------------

$\vec{x}^{(0)} = \vec{x}$ $k = 0$	= (arbitrary), $\mu_i^{(0)} = 0$ ( $i = 1, 2, \dots, I$ ), $\vec{y}^{(0)} = 0, \vec{z}^{(0)} = 0$ 0.1.2 Main Loop
アク	カセス順序 $\{\sigma_k(1),\sigma_k(2),\cdots,\sigma_k(I)\}$ を計算
l =	$1,2,\cdots,I+1$ Sub Loop
_	n = k(I+1) + l
	if $1 \le l \le I$ then $i = \sigma_k(l)$ データ項の処理
	$\bar{t} = \alpha \frac{b_i - \bar{a}_i^T \bar{x}^{(n)} + \mu_i^{(k)} / \alpha}{1 + \alpha \ \bar{a}_i\ ^2}, \ \bar{x}^{(n+1/2)} = \bar{x}^{(n)} + \bar{t}\bar{a}_i, \ \mu_i^{(k+1)} = \mu_i^{(k)} - \bar{t}$
[	if l=I+1 then TV項の処理
	$\vec{x}^{(n+1/2)} = \operatorname{prox}_{\alpha\beta \ \vec{x}\ _{\mathrm{TV}}} (\vec{x}^{(n)} + \vec{y}^{(k)}) \equiv \min_{\vec{x}} (\frac{1}{2\alpha} \ \vec{x} - (x^{(n)} + \vec{y}^{(k)})\ ^2 + \beta \ \vec{x}\ _{\mathrm{TV}})$ $\vec{y}^{(k+1)} = \vec{y}^{(k)} + \vec{x}^{(n)} - \vec{x}^{(n+1/2)}$
ľ	$\vec{z}^{(n+1)} = \vec{z}^{(n)} + \vec{x}^{(n+1/2)} - \vec{x}^{(n)}, \ \vec{x}^{(n+1)} = \vec{x}^{(n+1/2)} + \vec{z}^{(n+1)} / (I+1) \begin{array}{c} \text{Proximal center} \\ \mathcal{O}_{\text{update}} \end{array}$
## 深層学習にフラクタル画像を用いたスパースビューCT 再構成

川口 廉<sup>\*1</sup>,橋本 雄幸<sup>\*1</sup>
\*1 杏林大学大学院保健学研究科保健学専攻
東京都三鷹市下連雀 5-4-1, kawaguchi1811h@std.kyorin-u.ac.jp
Sparse-view CT reconstruction using fractal images for deep learning
Ren KAWAGUCHI<sup>\*1</sup>, Takeyuki HASHIMOTO<sup>\*1</sup>

\*1 Graduate School of Health Sciences, Kyorin University

要旨: CT 検査は医療被ばくを増加させている. 被ばくを低減する方法として,投影数を減らすスパースビューCT がある. しかし 投影数を減らすと,ストリーク状のアーチファクトが発生する. 深層学習を用いた研究では,従来の再構成法よりも高い画質が得 られると報告されている. 一般に,深層学習には多くの実画像が必要であり,医用画像では法的・倫理的な問題から収集が困難な 場合がある. 本研究の目的は,フラクタル画像を用いることで実画像の枚数を減らしても画質を向上させることができるかを検討 することである. フラクタル画像は Python で生成し,CT 画像は腹部 CT 画像を使用した. それらから 18,36,60 投影を作成し, FBP 法でスパースビュー画像を生成した. そこから作成したデータセットを用い,U-Net と FBPConvNet で学習し,画質の改善を試 みた.フラクタル画像を学習に使用することで,CT 画像のみよりも優れた画質が得られた. このことより,フラクタル画像を用い ることで実画像の枚数を減らすことができると示唆された.

キーワード: スパースビューCT, フラクタル, 深層学習

## 1. はじめに

放射線は医療に多大な恩恵をもたらす一方で, 医療被ばくを 伴う欠点がある.日本で最も多い医療被ばくは, CT (computed tomography)検査によるものである.CT検査において被ばく を低減する方法として,投影数を減らすスパースビューCTが ある.しかし,投影数を減らすと,従来の解析的手法で再構成 された画像にストリーク状のアーチファクトが発生する.画像 再構成法においては,解析的手法に代わって統計的手法が提案 されているが,高い計算コストに加え,アルゴリズムの性能を 高めるために必要ないくつかのハイパーパラメータ(正則化の 強度や収束までの反復回数など)のチューニングが必要である.

近年では,深層学習を用いた研究も広く行われている.深層 学習を用いたスパースビューCTの研究では,従来の再構成法 よりも高い画質が得られると報告されている[1].しかし,深層 学習には大量の実画像が必要であり,医療画像においては法律 的や倫理的な理由で収集が困難な場合がある.片岡らは,事前 学習にフラクタル画像を用いることで,実画像を用いるよりも 高い画像認識精度が得られることを報告した[2].そこで,事前 学習にフラクタル画像を用いることで,再構成画像の画質が向 上する可能性があると考えた.本研究の目的は,フラクタル画 像を用いることで実画像の枚数を減らした場合でも画質を向 上させることができるかを検討することである.

## 2. 方法

## 1) データセット

フラクタル画像は, Python で IFS (iterated function system) を 用いて 256×256 pixels で作成した[3]. CT 画像は, CHAOS デ ータセットから取得した腹部 CT 画像を 256×256 pixels にリ サイズしたものを用いた[4]. これらの画像からパラレルビー ムで180° 収集を仮定し, 18, 36, 60 投影のサイノグラムを取 得した. 次に, FBP (filtered back-projection) 法で再構成し, ス パースビュー画像を作成した. 深層学習用のデータセットは, 入力画像をスパースビュー画像, 教師画像を元の画像とした. データセットの内訳は, 学習にはフラクタル画像 9000 枚と CT 画像 1000 枚, テストには CT 画像 403 枚を用いた.

#### 2) 深層学習

本研究では U-Net と FBPConvNet を用いた[1]. それらのネ ットワーク構造を図 1 に示す. U-Net は、 $3 \times 3$  Convolution, Batch Normalization, ReLU の繰り返しと、プーリングにはスト ライド2の2×2 Maxpolling, アンプーリングにはストライド2 の3×3 Deconvolution で構成されている. FBPConvNet は U-Net に対し、入力を出力に add で結合している. 学習条件を表 1 に 示す.

#### 3) 評価指標

再構成画像の精度を評価するために, PSNR (peak signalto-noise ratio)と SSIM (structural similarity)の 2 つを用い た. PSNR は、以下の式で算出した.

$$PSNR = 10\log_{10}\left(\frac{MAX_Y^2}{MSE}\right) \tag{1}$$

ここで, *MAX*<sup>2</sup>は標準画像の最大画素値である. SSIM は, 以下 の式で算出した.

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}$$
(2)

ここで、 $\mu_x$ 、 $\mu_y$ は画像の平均画素値、 $\sigma_{xy}$ は画像の共分散、 $\sigma_x$ 、





図1 ネットワーク構造 (a)U-Net, (b)FBPConvNet

#### 表1 学習条件

バッチサイズ	1 *
	1 1X
エポック数	上限100回(損失が5エポック中に
	0.0001 より変化が小さい場合終了)
最適化手法	Adam
損失関数	平均二乗誤(MSE)

## 3. 結果

それぞれのネットワークを用いて画質を改善した画像を図 2 に示す. どちらのネットワークでも投影数が多くなるにつれ て視覚的にアーチファクトが低減し,構造の回復が見られた. また,フラクタル画像を用いて事前学習を行うことで,事前学 習なしの場合と比べアーチファクトが低減し,構造の回復が見 られた. SSIM は事前学習あり,なしの U-Net でそれぞれ,18 投影:0.615,0.486,36 投影:0.745,0.667,60 投影:0.781, 0.743 であった.PSNR は18 投影:12.74,12.45,36 投影:20.30, 20.20,60 投影:24.54,23.69 であった.FBPConvNet では SSIM はそれぞれ,18 投影:0.617,0.488,36 投影:0.755,0.700, 60 投影:0.814,0.746 であった.PSNR は18 投影:14.14,12.60, 36 投影:20.49,20.24,60 投影:24.69,24.50 であった.これ らより,どの投影数においても事前学習ありの SSIM と PSNR



図3 再構成画像 (a)U-Net, (b)FBPConvNet

の両方で高い評価値を示した.また,FBPConvNetはU-Netに 比べていずれも高い評価値を示した.

#### 4. まとめ

フラクタル画像を用いることで、CT 画像のみよりも画質が 向上することがわかった.このことから、フラクタル画像を用 いることで、実画像の枚数を減らすことができることが示唆さ れた.また、U-Netと比較して FBPConvNet が優れいているこ とが示された.

#### 利益相反の有無

なし

- K. H. Jin, M. T. Mccann, E. Froustey, et al. "Deep Convolutional Neural Network for Inverse Problems in Imaging." IEEE Trans. Image Process. 2017, 4509–4522.
- [2] H. Kataoka, K. Okayasu, A. Matsumoto, et al. "Pre-training without Natural Images." International Journal of Computer Vision (130), 2022, :990-1007.
- [3] Barnsley, M. F. "Fractals everywhere." New York: Academic Press, 1988.
- [4] Emre Kavur, et al. "CHAOS Challenge combined (CT-MR) healthy abdominal organ segmentation." Medical Image Analysis (69), 2021.

# 深層学習を用いた角度欠損 CT 画像再構成の敵対的反例とその解決法: 深層学習と逐 次近似再構成法のハイブリッド法

青木 翔吾<sup>\*1</sup>,藤井 克哉<sup>\*1</sup> 岡部 蒼太<sup>\*1</sup> 佐藤 悠輝<sup>\*1</sup> 工藤 博幸<sup>\*1</sup> <sup>\*1</sup> 筑波大学大学院システム情報工学研究科情報理工学位プログラム

# Practical adversarial example of deep learning in CT image reconstruction and its solution by combining deep learning and iterative CT reconstruction

Shogo AOKI<sup>\*1</sup>, Katsuya FUJI<sup>\*1</sup>, Souta OKABE<sup>\*1</sup>, Yuki SATO<sup>\*1</sup>, Hiroyuki KUDO<sup>\*1</sup>

# <sup>\*1</sup>Graduate School of Science and Technology Degree Programs in Systems and Information Engineering Master's/Doctoral Program in Computer Science, University of Tsukuba

要旨:角度欠損がある投影データの場合には、フィルタ補正逆投影法(FBP法)などの解析的手法では著しい画質劣化が発生し、画像と投影データの関係式を反復法で解く逐次近似画像再構成法が有効であることがよく知られるが、未だに投影データが完全な場合と同等の画像を得ることは困難である.本発表では、角度欠損 CT の画像再構成を近年精力的に研究されている深層学習単独で行った場合に、顕著な構造物の欠損が発生する幾つかの典型的な敵対的反例を示す.また敵対的反例の画質劣化を改善するため、深層学習と逐次近似再構成を組み合わせたハイブリッド再構成法を提案する.

キーワード: 医用画像, CT 画像再構成, 深層学習, 圧縮センシング

## 1. はじめに

本発表では、問題として重要性が高く歴史がある角度欠損 がある投影データからの CT 画像再構成問題を取り扱う.角 度欠損がある投影データの場合には、フィルタ補正逆投影法 (FBP法)などの解析的手法では著しい画質劣化が発生し、画 像と投影データの関係式を反復法で解く逐次近似画像再構成 法が有効であることがよく知られるが、未だに投影データが 完全な場合と同等の画像を得ることは困難である.これに対 して、近年深層学習を用いた画像再構成法が有効という研究 が精力的に行われている.本発表は、大きく以下に述べる2 つの内容から構成される.一つ目として,角度欠損 CT の画 像再構成を深層学習単独(FBP 法の再構成画像を教師あり U-Net で画質改善) で行った場合に, 顕著な構造物の欠損が発 生する幾つかの典型的な敵対的反例を示す.二つ目として, 敵対的反例の画質劣化を改善するため、深層学習と逐次近似 再構成を組み合わせたハイブリッド再構成法を提案する.提 案手法では、第一ステップでは深層学習で画像再構成を行 い、その再構成画像を圧縮センシングに基づく逐次近似再構 成法の先験情報として正則化項に組み込み、第二ステップで 圧縮センシングによる逐次近似再構成法で画像再構成する原 理に基づいている、いわゆる深層学習と逐次近似再構成法の ハイブリッド画像再構成手法の一形態である.腹部 CT 実画 像データセットを用い投影データ測定角度範囲が90度の設定 でシミュレーション実験を行った結果、深層学習または逐次 近似再構成法を単独で用いた場合にはどちらも画質劣化が著 しいのに対して、提案するハイブリッド再構成法では高画質 の再構成画像が得られることが明らかになった.

## 2. 提案手法

提案手法では深層学習と逐次近似再構成を組み合わせた再 構成を行う.

第一ステップでは深層学習法による画像再構成を行い,出力 された再構成画像を圧縮センシングに基づく逐次近似再構成 法の先験情報として正則化項に組み込む. 深層学習単体では投 影データから CT 画像再構成を行うことはできないため, FBP 法で再構成した後に CNN を用いて画質改善を行う. ネットワ ークの学習段階では投影データから FBP 法を用いて再構成 した画像と正解画像のペアを用意し学習を行う. 提案手法では CNN に U-Net を使用し,損失関数には平均二乗誤差(MSE)を 用いて学習を行い,画質改善を行った.

第二ステップでは圧縮センシングによる逐次近似再構成法 で画像再構成を行う. 圧縮センシングに用いる評価関数は以下 のようになる.

 $f(\vec{x}) = \beta \|\vec{x}\|_{TV} + \gamma \|\vec{x} - \vec{x}_{CNN}\|_{1}^{1} + \frac{1}{2} \|A\vec{x} - \vec{b}\|^{2}$ (1)

逐次近似再構成法の正則化項としては、通常の圧縮センシン グの正則化項であるトータルバリエーション(TV)に加え、再 構成画像と深層学習(CNN)で得られた画像(先験情報)の差 のL1ノルムを用い、逐次近似法の初期画像として収束を速め るため深層学習(CNN)の再構成画像を用いる.また評価関数 の最小化は研究室で研究を進めている Row-Action 型で高速に 収束する性質を持つ Dykstra-Like Splitting with Proximal Minimization (DLPM) 法を用いる. 最終画像に近い画像から逐 次近似の収束も速くなるので, 逐次近似画像再構成法の初期画 像にも深層学習の出力画像を用いる. このような逐次近似画像 再構成法を深層学習に後付けして更なる画質改善を実現する のが提案する深層学習と圧縮センシングのハイブリッド画像 再構成法である.

## 3. 実験

実験で使用するデータセットには腹部実CT画像データセットを使用し、投影データ測定角度範囲が90度の設定でシミュレーション実験を行った.深層学習法に用いた訓練データとバリデーションデータには患者80人の腹部CT画像合計1600枚を用いた.比較手法にはFBP法と深層学習のみを用いた再構成手法を用い、評価関数にはRMSEを用いた.

実験結果の一部を図1,図2に示す.図1は肝臓の上部に水 が溜まっていると思われる症例が写っている画像である.深層 学習法単体では画質が大幅に改善したが,水が溜まっている部 分がほとんど消失していることが分かる.これは学習データに 水が溜まっている症例がほとんど含まれていなかったために 欠損が起こってしまったことが考えられる.提案手法は正解画 像と遜色ない画像を出力しており,深層学習法で顕著な構造物 の欠損が発生した場合には圧縮センシングで欠損構造物を復 活させる一定の効果があることが分かる.

また図2は腹部下部の正常画像である.深層学習法単体では 腸などの複雑な構造物の復元が難しく,存在しない構造物を生 み出してしまっている.提案手法では余分な構造物を除去し, 高画質な画像を再構成している.



図1 珍しい症例の実験結果



図2 腹部下部の実験結果

## 4. まとめ

本研究では一般的に用いられている深層学習を用いた画像 再構成手法に圧縮センシングを組み合わせたハイブリッド型 CT 画像再構成法を提案し,投影データ測定角度範囲が90度の 設定でシミュレーション実験を行った結果,深層学習法単体で は珍しい症例の場合に病変が欠損してしまうこと,腸などの複 雑な構造物の復元が難しいことが判明したが,提案するハイブ リッド再構成法ではいずれの問題もなく,高画質な再構成画像 が得られることが分かった.今後の課題として,逐次近似再構 成法の時間短縮や,本手法が有効な他の不完全データ問題への 適用などが挙げられる.

#### 利益相反の有無

なし

- 文献
- [1] Semih Barutcu, SelinAslan, Aggelos K, Katsaggelos, DogaGursoy.: Limitedangle computed tomography with deep image and physics priors, Scientifc Reports, 2021
- [2] Olaf Ronneberger, Philipp Fischer, Thomas Brox.: U-Net: Convolutional Networks for Biomedical Image Segmentation, Proc. Int. Conf. Med. Image Comput. Comput.-Assist. Intervent. (MICCAI). Cham, Switzer- land: 234-241,2015
- [3] 工藤博幸:投影からの画像再構成, 医用画像工学ハンドブック, 日本 医用画像工学会編集, 2012 年 9 月
- [4] JiaxiWang,Li Zeng,ChengxiangWang and Yumeng Guo: ADMM-based deep reconstruction for limited-angle CT, Physics in Medicine Biology,2019
- [5] Essam A. Rasheda, Hiroyuki Kudo: Probabilistic atlas prior for CT image reconstruction, Preprint submitted to Comput. Meth. Prog. Biomed. June 22, 2016
- [6] 数尾昴, 工藤博幸, 川又健太郎: 深層学習による圧縮センシング CT 画像再構成画質改善の新手法,日本医用画像工学会大会予稿集(CD-ROM),2020,pp368-372

# スパース空間学習を利用した MR 画像の深層学習再構成

笹谷 晃斗\*1,大内 翔平\*2,山登 一輝\*1,伊藤 聡志\*1

<sup>\*1</sup> 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 <sup>\*2</sup> 小山工業高等専門学校

# Study on Deep Learning Reconstruction of MR images Using Sparsified Image Space Learning.

Akito SASAYA<sup>\*1</sup>, Shohei OUCHI<sup>\*2</sup>, Kazuki YAMATO<sup>\*1</sup>, Satoshi ITO<sup>\*2</sup>

<sup>\*1</sup> Graduate Program in Information, Electrical and Electronic System Engineering, Utsunomiya University,

\*2 National Institute of Technology, Oyama College.

要旨:深層学習再構成では、画像-画像間,信号-信号間,信号-画像間などの,MR 画像の生成過程を踏まえた多数の学習モデルが提案されている.本研究では、信号空間と画像空間の両方の性質をもつ、多重解像度解析手法の一つである eFREBAS 変換を使用し、これにより得られるスパース空間と画像空間の2つの空間において学習を行う方法について検討を行った.得られた再構成像の品質と特徴を、単一 CNN 学習と比較した.その結果、2つの異なる空間をカスケード接続して学習する方式により、単一の CNN による学習および画像空間のカスケード接続学習よりも高品質な画像を得られた.スパース空間学習と画像空間学習の併用により再構成画像の品質改善の可能性が示された.

キーワード: MRI, 圧縮センシング, 深層学習, eFREBAS 変換

## 1. はじめに

高画質な MR 画像の取得には、多くの時間を必要とする. MRIの撮像高速化のアプローチとして、少数の信号からMR画 像を再構成する方法が盛んに研究されている. 圧縮センシン グ(Compressed Sensing)を MRI に応用した CS-MRI は、その一 例であるが、再構成処理に反復的な演算を伴い、再構成像には 人工的な様相が現れる場合があるという課題がある. そこで、 畳み込みニューラルネットワーク(CNN: Convolutional Neural Network)を利用した再構成法が多数提案されている[1]. CNN は特徴を学習することができるが、予め画像を特徴別に分類し た上で学習すると学習効率が高まることが期待できる. そこ で信号空間での周波数の分解能を持ちながら、画像特徴別に 展開された多重解像度解析を利用した再構成法を考えること ができる[2,3]. Chuan らは Wavelet 変換を使用した方法を提案 し[2], Ouchi らは、eFREBAS 変換を使用した CNN を提案し画 質改善を試みている[3].

eFREBAS 変換[4]は、サイズが等しい多重解像度画像への変 換であり、また、Wavelet 変換のように分割数が 2 のべき乗と いう制限がなく、かつ複素変換であるという特徴を持つ.本研 究では、eFREBAS 変換で得られるスパース空間で学習を行う CNN (eFREBAS-CNN とする)を構築し、画像空間 CNN とカス ケードしたネットワークによりさらなる画質改善を行うこと を目的とする.

## 2. eFREBAS 変換

eFREBAS 変換は、フレネル変換の 2 つの異なるアルゴリズ ムを用いて構成される多重解像度解析手法である. 簡単のた め、一次元信号について考えると、eFREBAS 変換による展開像  $\rho_m(x)$ は、以下の式(1)、(2)のように、バンドパスフィルタによって畳み込まれた形で表される.ここで、式中のX(=  $N\Delta x$ )は入力画像のFOV、Nは入力画像のサイズ、 $\Delta x$ はピクセル幅、cは eFREBAS 変換のスケーリング係数である $D = \pi/(cN\Delta x^2)$ に影響する定数を表している.

$$\rho_m(x) = \left[\rho(x)e^{-jcx^2}e^{-j2cmXx}\right] * g(x) \tag{1}$$
$$g(x) = \operatorname{sinc}(2cXx) \tag{2}$$

eFREBAS 変換は、2 次の位相変調、フーリエ(逆)変換と展開係 数のみで任意に実行可能であり、展開像は画像のエッジが分離 された形になるため、スパース化された画像を意味する空間に なる.

#### 3. 本研究で用いたネットワーク

eFREBAS 変換により展開したサブ画像は画像の輪郭を分離 したものになる.そこで eFREBAS-CNN では,情報量,性質を 考慮しグルーピングを行い,それぞれのU-Netへ入力して学習 を行う.処理フローを図1に示す.本研究では,画像空間学習 と多重解像度空間学習を併用して画質改善を目指し, eFREBAS-CNN (eFreD とする)と画像空間 CNN の2つの CNN を図2に示すように,カスケード状に接続した.本研究では,



図 1 eFREBAS-CNN(eFreD)の処理フロー



図2 カスケード CNN の処理フロー

比較のため, 画像空間で学習を行う 2 つの CNN をカスケード したカスケードネットワークも使用した. CNN には, U-Net[5] を使用した.

## 3. 計算機実験

本研究では fastMRI データセット[6,7]の T2 強調画像を学習 とテストにそれぞれ 100 枚, 50 枚使用した.信号収集率 30%, 低周波部分を連続収集した 1 次元ランダム間引きのサンプリ ングパターンで実験を行った.学習条件を表 1 に示す.エポッ ク数は,単一 CNN は 200,カスケードした 2 つ目の CNN は 100 である.表 2 にネットワーク構成ごとの PSNR,図 3 に再 構成像を示す.単一の CNN では、画像空間(ImD) で学習する 方が高い PSNR となった.これは、eFreD 単体では画像は鮮鋭 であるが、ややアーチファクトが残ったためである.カスケー ド CNN では、eFreD の後段に ImD を接続する eFreD-ImD の方 が高い PSNR となった.また、図 3 の(f)から(h)に示した誤差 像は、単一 eFreD や ImD-ImD よりも輝度値が低いことを示し ていることから再構成誤差が減少していることがわかる.カ スケード CNN では、eFreD のアーチファクトが減少し、画質 改善が図られた.

表1学	習条件
-----	-----

パラメータ	eFreD	ImD
画像サイズ	320×320	
バッチサイズ	4	
最適化手法	Adam	
学習率	10-3~10-5	10-3

表 2 再構成像 PSNR

ネットワーク構成	PSNR [dB]	
単一 CNN	eFreD	30.45(±1.14)
	ImD	30.64(±1.10)
カスケード CNN	eFreD-ImD	<b>31.16</b> (±1.10)
	ImD-ImD	$30.97(\pm 1.09)$

## 4. 考察

画像空間同士のカスケード CNN よりも, 多重解像度解析手 法の 1 つである eFREBAS 変換空間と画像空間のカスケード



図3 各条件における拡大した再構成像 (b はサンプリングパターン(30%), f~h は各方法の誤差像)

CNN による再構成像の方が高い PSNR が得られた. eFREBAS-CNN ではややアーチファクトが現れたが,カスケード接続す ることにより,鮮鋭かつアーチファクトの少ない画像になった ものと考える.本研究により,予め特徴別に分類した多重解像 度解析を行うことにより画質改善の可能性が示された.本研究 では, eFREBAS 変換スケール係数 D を 3 として展開画像は縦 と横方向に 3 分割した.スケール係数 D は自由に変更できる ので画像の展開数を変えた検討を行う予定である.

## 5. まとめ

本研究では、多重解像度解析である eFREBAS 変換されたス パース化空間で行う学習と画像空間で行う学習をカスケード 接続し、MRI 圧縮センシングの再構成に応用した.その結果、 提案法は単体の CNN よりも高い PSNR を得ることができ、画 質改善の可能性が示された.

#### 謝辞

本研究の一部は, JSPS 科研費 19K04423 によって行われた.

#### 利益相反の有無

なし

#### 文献

- [1] D Lee et al., IEEE Trans Biomed Eng 2018; 65:1985-1995.
- [2] T. Chuan et al., Computers in Biology and Medicine, 2022;151: A.
- [3] S. Ouchi and S. Ito, IEEE 18th International Symposium on Biomedical Imaging, 2021; 290-294.
- [4] 伊藤聡志ほか, 信学論, 2010; J93-D: 999-1008.
- [5] O. Ronneberger et al., Medical Image Computing and Computer-Assisted Intervention, 2015; 234-241.
- [6] Knoll, Florian et al., Radiology. Artificial intelligence 2020; 2(1):e190007.
- [7] https://fastmri.org/dataset/

# アンサンブル学習による CS-MRI 深層学習再構成の性能改善

古田 真輝<sup>\*1</sup>,山登 一輝<sup>\*1</sup>,伊藤 聡志<sup>\*1</sup>

\*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

Improvement of Deep Learning Based Compressed Sensing Magnetic Resonance Image Reconstruction Using

**Ensemble Learning** 

## Masaki FURUTA<sup>\*1</sup>, Kazuki YAMATO<sup>1</sup>, Satoshi ITO<sup>\*1</sup>

<sup>\*1</sup> Graduate School of Regional Development and Creativity, Utsunomiya University

要旨:近年, 圧縮センシング MRI(CS-MRI)の画像再構成に深層学習を利用した研究が注目されている.しかし,単一の深層学習ネットワークを用いた再構成ではアーチファクトや平滑化による詳細構造の消失が見られ,さらなる改善が必要である.そこで本研究では, CS-MRI 深層学習再構成に複数の深層学習ネットワークを組み合わせるアンサンブル学習を導入し,再構成性能を向上させる方法について検討を行った. 画像再構成シミュレーションの結果,単一の深層学習ネットワークよりも高い再構成性能を得ることが確認できた.U-Net や ADMM-Net など複数ネットワークのアンサンブル学習により再構成性能が向上する可能性が示された. キーワード: MRI, 圧縮センシング,アンサンブル学習,画像再構成,深層学習

#### 1. はじめに

圧縮センシングを MRI に応用した圧縮センシング MRI(CS-MRI)において画像再構成に深層学習を利用する方法 が注目されている. CS-MRI 深層学習再構成の研究では, U-Net, GAN, ADMM-Net, ISTA-Net などのさまざまなネットワ ーク[1-4]が提案されている. これらのモデルにはアーチファ クト除去に対する頑健性,構造保存性,間引きパターンに対す る頑健性などそれぞれ異なる特徴を有している.

深層学習の性能を向上させる手法として、複数の深層学習ネ ットワークを組み合わせるアンサンブル学習がある [5]. MRI の超解像の分野では、5種の超解像アルゴリズムにより相補的 な事前分布を持つ高解像度画像をデータセットとして作成し、 これらデータセットで学習した5種のGANモデルの出力を畳 み込みニューラルネットワーク(CNN)で統合するアンサンブ ル学習が提案されており、単一のネットワークと比べて、アー チファクトの抑制・詳細構造の保持が確認されている[6].

そこで、本研究では異なる構造の 4 種のネットワークに対 し独立に学習を行い、それらの出力画像を U-Net の入力とし て重みを最適した統合を行うことにより、画質改善を図った. 再構成法にアンサンブル学習を導入する新たな試みによる再 構成像の画質改善を目的とする.

## 2. アンサンブル学習

アンサンブル学習 [5] とは複数のネットワークを使用して 汎化性能を上げる手法のことである. 相補的な複数のネットワ ークを作成し, それらのネットワークの出力を統合することで, 単一のネットワークよりも汎化性能向上が期待できる.

アンサンブル学習では相補的なネットワークの作成が必要 となる.一方, CS-MRI 深層学習再構成に用いるネットワーク は主にデータ駆動型とモデル駆動型に分類できる.データ駆動 型は入力 - 出力間をブラックボックスとして,そこに標準的 なネットワークアーキテクチャを使用したネットワークであ る.データ駆動型のネットワークには,U-Net[1] や SARA-GAN[2]などがある.モデル駆動型は CS 反復最適化アルゴリズ ムを展開し,その手順をもとにアーキテクチャを設計したネッ トワークである.モデル駆動型のネットワークには,ISTA-Net[3]や ADMM-Net[4]などがある.本研究では,これら4つ のネットワークにそれぞれ学習を行わせ,相補的なネットワー クを作成した.

アンサンブル学習では最後に、複数のネットワークからの出 力を統合する必要があり、主に加算平均、加重平均、スタッキ ングなどの方法がある.加算平均は、同一位置の画素ごとに輝 度値の単純な平均をとる手法である.加重平均は、各ネットワ ークに重みを割り当て、その重みをネットワークが出力した画 像全体に与えて重み付き加算する手法である.スタッキングで は、まず複数のネットワーク base-model を学習して事前予測 を得る.次に、これら事前予測を学習データとして、最終的な 予測を出力するネットワーク meta-model を学習する. MRI の 超解像の分野では、meta-model として CNN を用いた研究が ある [5].本研究では、meta-model に CNN の一つである U-Net を用いた.



図 1 アンサンブル学習の概要図

図1に本研究でのアンサンブル学習の概要図を示す.まず, ゼロフィル再構成像からアーチファクトを除去した画像を推 定する4種のネットワーク(U-Net, SARAN-GAN, ISTA-Net, ADMM-Net)を独立に学習し,これらのネットワークを basemodel とする.次に4つの base-model の出力を事前予測として チャンネル化したデータセットを作成する.最後に meta-model として base-model に用いた U-Net と同じ構造のネットワーク を用意し学習することで最終的な再構成画像を得る.再構成画 像を推定する前に,間引き処理していない部分の信号を真値信 号で置き換える処理であるデータコンシステンシー(DC)を行 う.再構成画像は、4種のネットワーク出力の画像を重み付き 加算平均したものではなく、画素レベルで4種の出力画像のア ンサンブルを取っている.よって、各出力画像の優れた部分を 合成した画像になり、加算平均による平滑化は生じない.

## 3. 画像再構成シミュレーション

アンサンブル学習の有効性の確認のため、4種のネットワー クとそれらのアンサンブル学習による画像再構成シミュレー ションを行い、単一ネットワークによる再構成画像を比較した. 単一のネットワークは U-Net, SARA-GAN, ISTA-Net, ADMM-Net とし、これら 4 つのネットワークの U-Net によ るアンサンブルを 4ens\_U-Net とした.本研究では IXI デー タセット [7] に含まれる頭部プロトン密度強調を学習に 300 枚,検証に 30 枚,テストに 30 枚使用した.学習データは, 左右反転,回転 ±20 度,0.9 倍から 1.1 倍までの拡大など のデータ拡張を行った.信号の間引き処理を収集率 35%,中 央列 30 列の信号収集点分布 (図 3(d))に従って行った.再構 成画像の定量的な画質評価には Peak-Signal-to-Noise Ratio (PSNR) と Structural Similarity Index Measure (SSIM) を使用した.

図2にテスト画像30枚を用いた再構成結果のPSNR・SSIM の平均値を、図3に再構成画像のうちの1枚を示す.また、図 3の拡大図は見やすくするためにコントラストの調整を行っ た.図2の単一のネットワークのPSNR・SSIMを見ると、デ ータ駆動型(U-Net, SARA-GAN)がモデル駆動型(ISTA-Net, ADMM-Net)を大きく下回った.また、全体ではアンサン ブル学習の4ens\_U-Netが最大のPSNR、SSIMを示した.図



図 2 再構成画像の PSNR と SSIM の平均

3の再構成画像を見ると、U-Net, SARA-GAN, ISTA-Net に よる再構成画像には一部,平滑化が見られた. ADMM-Net に よる再構成画像には平滑化は見られなかったが,細部構造を復 元できていない箇所があった. 4ens\_U-Net は単一のネットワ ークに比べ,平滑化が少なく,細部構造の再現性が高いことが 確認できた. これは, meta-model に用いた U-Net の畳み込み 処理と非線形処理により,単一のネットワークの出力に共通す る特徴を学習したためと考える.

### 4. おわりに

本研究では、CS-MRI 深層学習再構成法の性能改善を目的と して、複数のネットワークを使用したアンサンブル学習を導入 した.その結果、単一のネットワークに比べ PSNR・SSIM が 高く、平滑化・細部構造の復元性が改善された.今後は、学習 枚数を増やし、データ駆動型のネットワークの再構成性能を向 上させた上でのアンサンブルを検討する予定である.

#### 謝辞

本研究の一部は, JSPS 科研費 19K04423 によって行われた.

#### 利益相反の有無

なし

# 文献

- [1] O.Ronneberger et al, "U-Net: Convolutional Networks for Biomedical Image Segmentation"
- [2] Zhenmou Yuan et al, "SARA-GAN: Self-attention and relative average discriminator based generative adversarial networks for fast compressed sensing MRI reconstruction"
- [3] Jian Zhang et al, "ISTA-Net: Interpretable Optimization-Inspired Deep Network for Image Compressive Sensing"
- [4] Y. Yang et al, "Deep ADMM-Net for Compressive Sensing MRI"
- [5] Nakata N et al, "Ensemble Learning of Multiple Models Using Deep Learning for Multiclass Classification of Ultrasound Images of Hepatic Masses"
- [6] Q. Lyu et al, "MRI Super-Resolution with Ensemble Learning and Complementary Priors"
- [7] "brain-development.org IXI dataset," https://braindevelopment.org/ixidataset/



#### 図 3 再構成画像の比較

# サンプリングパターンの拡張による CS-MRI 深層学習再構成の性能改善

山登 一輝\*1, 渋井 雅希\*2, 伊藤 聡志\*2

\*1宇都宮大学 工学部 基盤工学科

\*2宇都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム

## Improvement of Deep-Learning CS-MRI Reconstruction Using Sampling Pattern Augmentation

Kazuki Yamato, Shibui Masaki, and Satoshi Ito

<sup>\*1</sup> Department of Fundamental Engineering, School of Engineering, Utsunomiya University

<sup>\*2</sup>Graduate Program in Information, Electrical and Electronic System Engineering, Utsunomiya university

要旨: MRI の撮像時間短縮のために、サンプリング定理を満たさない少数データから元の情報を復元できる Compressed Sensing (CS) を MRI に応用する CS-MRI が提案されている. CS-MRI は限られた観測信号から MR 画像を再構成でき、信号の収集時間を短縮で きるが、CS の最適化アルゴリズムを解く必要があり、その実行時間や再構成性能には限界がある.一方、CS の最適化アルゴリズ ムの各種パラメータを再構成対象に対して適切な値に学習できる深層学習手法として、Unrolling-based ネットワークが提案されて おり、CS-MRI に適用することで再構成像の画質改善や実行時間の短縮されることが報告されている. このような深層学習を利用 する CS-MRI は、一般に、単一のサンプリングパターンに基づいて再構成モデルを学習するため、学習パターン以外では再構成性能が低下する傾向がある. そこで、複数パターンを学習することで、未学習パターンでも再構成性能を改善できる深層学習再構成 法を提案する. 提案法の有効性を実験により確認したところ、未学習パターンでも高い再構成性能を確認した. キーワード: 圧縮センシング、MRI、画像再構成、深層学習

## 1. はじめに

MRI は、生体断面を非侵襲かつ高分解能に取得できる撮像 装置であるが、撮像には長時間を要する. そのため、MRIの撮 像高速化が求められている. Compressed Sensing (CS)を MRI に 応用した CS-MRI[1]は、サンプリング定理を満たさない限られ た信号から画像再構成が可能であり,信号収集時間の短縮によ り, 撮像時間が短縮できる. 一方で, 画像再構成には CS の最 適化問題を反復的に解く必要があり,再構成像の品質には限界 がある.近年,CSの最適化問題を深層学習ネットワークとし て構成した手法が提案され,再構成対象に応じた最適化パラメ ータを学習でき、CS-MRIの反復再構成を上回る性能を達成し ている. 深層学習 CS-MRI が学習するサンプリングパターンは 単一であるため、未学習のパターンを使用した再構成像は品質 が低下する傾向がある.本稿では、学習に用いるサンプリング パターンを拡張することによって, 単一パターン学習による CS-MRI 再構成の制約を緩和することを目的とする.具体的に は、複数のサンプリングパターンを学習に利用することで、未 学習パターンを使用した場合でも,高品質な画像再構成の実現 を目指す.提案法の有効性を確認する実験を行ったところ、未 学習パターンの再構成だけでなく,未学習の信号収集量のパタ ーンを用いた場合でも再構成像の品質改善が確認されたので 報告する.

## 2. Generic-ADMM-Net

本研究では、CS-MRIの反復再構成法の Alternating Direction Method of Multipliers (ADMM)のパラメータを学習できる Generic-ADMM-Net[2]を利用する.図1に Generic-ADMM-Net のネットワーク構成を示す.図1の $X^{(n)}$ ,  $Z^{(n)}$ ,  $M^{(n)}$ は、それ ぞれn番目の再構成層、ノイズ除去層、乗数更新層を示してお り、 $Z^{(n)}$ 層は加算層(A)、2つの畳み込み層( $C_1$ ,  $C_2$ )、非線形変



換層(*H*)から構成されている.図1のネットワークは,単一の サンプリングパターンで収集された信号が入力であり,再構成 像を取得できる.

## 3. サンプリングパターンの拡張

前節で述べた Generic-ADMM-Net 等の深層学習を利用する CS-MRIでは、単一サンプリングパターンに対してモデルを学 習するため、未学習パターンに基づいて収集された信号からの 画像再構成では高品質な再構成像の取得は困難である.この制 約を緩和するために、図2に示す複数のサンプリングパターン をモデル学習に利用するサンプリングパターンの拡張

(sampling Pattern Augmentation: sPatAug)を提案する. sPatAug では、画像ごと、および学習エポックごとに異なるサンプリン グパターンを生成、または選択することにより、複数のサンプ リングパターンを用いて学習されたモデルを生成する. また、 sPatAug で使用するサンプリングパターンの生成は、図3に示 すように、標準偏差制御パラメータα、信号収集率の2つのパ



ターン生成パラメータに従って行う. 図 3 の例では,  $\alpha = 0.5$ , 信号収集率 25%としている.なお本稿では,信号収集率は 20%, 30%, 40%の 3 通り,  $\alpha$ は 0.3, 0.5, 0.8 の 3 通りとし, それぞ れランダムに選択する.また,位相エンコード方向に間引いた カルテシアン座標系のサンプリングパターンを想定し,画像の 重要な情報が含まれる MR 信号空間の低域成分の収集量と増 加させるため,パターンの中央 30 行を連続で収集した.

## 4. 画像再構成シミュレーション

再構成シミュレーションを行った.使用画像には,IXI Dataset[3]に含まれるT<sub>1</sub>強調像75枚を使用し,学習用に50枚, テスト用に25枚をランダムに選択し,Peak Signal-to-Noise Ratio (PSNR)により再構成像の画質評価を行った.本稿では、図4(a)-(e)に示す5種類のパターンを事前に生成し,各画像・各エポッ クでランダムに選択する方法(sPatAug-5)と,各画像・各エポ ックで新たにパターンを生成する方法(sPatAug-all)の2種類 の方法について検証を行った.

表1に再構成像のPSNR, SSIMを示す.表の単一パターン は、1つの間引きパターンで学習したモデルで再構成したこと を示し、左から2-3列目は図3(c)で学習したモデル、4-5列目 は図3(f)で学習したモデルを、それぞれ表している.表より、 いずれの場合もsPatAugによる学習モデルを用いた再構成結 果は、単一パターン学習モデルによる結果を上回っており.ま た、sPatAug-allはsPatAug-5よりもPSNR,SSIMが高いことが 確認できる.図3(b)のパターンを用いた再構成像と未学習パタ ーン(図3(f))を用いた再構成像を、図5、6にそれぞれ示す.図 5(d)は学習に使用していないパターンで再構成しているため、 アーティファクトが生じているが、sPatAug-5、sPatAug-allとも にアーティファクトが抑制されている.図6は、未学習の収集 率35%のパターンの再構成結果である.図6(d)は赤矢印の箇所 の構造が崩れているが、sPatAug-5、sPatAug-allでは同箇所の構 造が保持されていることが確認できる.



図5図3(b)を使用した再構成結果



図6 未学習の収集率パターンによる再構成結果

#### 5. 考察

図 5,6から sPatAug は深層学習 CS-MRI 再構成の性能改善 に対して有効であり、特に、sPatAug-all による再構成像の再現 性が最も高いことが確認された.sPatAug-all は各画像・各エポ ックで異なるパターンを生成するため、(学習画像数)×(エポッ ク数)=50×300=15000枚で学習していることに相当する. すなわち、sPatAug は複数パターンで学習することにより、多 種多様なパターンに由来するアーティファクトを学習できる と同時に、学習データの増強手法であるデータ拡張の効果があ ると考える.本研究では、サンプリングパターンの拡張という 新たな視点に基づいた再構成法について検討を行い、深層学習 CS-MRIの性能改善に有効である結果が得られた.

## 6. おわりに

本稿では、深層学習 CS-MRI における単一パターン学習の制 約を緩和したサンプリングパターンの拡張(sPatAug)を提案 した.sPatAug は各画像・各エポックで新たなパターンを生成 し、学習に用いることで、複数パターン学習を実現している. 画像再構成実験を行ったところ、sPatAug を利用することで未 学習の収集率であるパターンによる再構成像は、未学習パター ンを単一パターン学習したモデルによる再構成像よりも高い 再現性が確認された.したがって、sPatAug は深層学習 CS-MRI 再構成の性能改善に有効である.

#### 謝辞

本研究は宇都宮大学若手研究者支援経費の助成を受けたものです.

- Lustig M, et al.: Compressed sensing mri. IEEE Signal Process Mag. Vol.25, issue 2, pp.72-82, 2008.
- [2] Yang Y, et al.: Admm-csnet: a deep learning approach for image compressive sensing. IEEE TPAMI, vol.42, issue 3, pp.521-538, 2020.
- [3] IXI Dataset, https://brain-development.org/ixi-dataset/ (accessed 2023-5-17).

# 自己符号化器付 U-net の部分教師あり学習とその胸部 CT 画像における 陰影領域抽出への応用

濱田 拓也\*1,杉水 俊輝\*2,間普 真吾\*1,木戸 尚治\*3

\*1 山口大学大学院創成科学研究科

\*2 筑波大学大学院理工情報生命学術院

\*3 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

# Partially Supervised Learning of U-net with Autoencoder and Its Application

## to Opacity Segmentation of Chest CT Images

Takuya HAMADA<sup>\*1</sup>, Toshiki SUGIMIZU<sup>\*2</sup>, Shingo MABU<sup>\*1</sup>, Shoji KIDO<sup>\*3</sup>

<sup>\*1</sup> Yamaguchi University

\*2 University of Tsukuba

\*3 Osaka University

要旨: 医用画像に深層学習を適用する場合, 学習に十分な量の完全な教師ラベル付データの収集が難しい.本研究で扱う胸部 CT 画像におけるびまん性肺疾患の陰影領域抽出では,例えば各画像に存在する代表的な陰影のみアノテーションされている等,複数の 陰影について細かくアノテーションされていることは稀である.したがって,このようなデータに対してセグメンテーションを行うため,陰影ごとに独立したモデルを作成すると,陰影間の特徴の関係性が把握できない.本研究では,特徴抽出部を陰影ごとの モデルで共有し,出力部を陰影ごととすることで多様な特徴を捉えられるようにする.さらに,アノテーション領域とセグメンテ ーション領域を近づける損失関数と遠ざける損失関数を使い分けることで,複数陰影のセグメンテーションを効率的に学習可能な 方式を実現した.複数陰影が混在する胸部 CT 画像のセグメンテーションにおいて,Dice 係数の向上が確認できた. キーワード: 深層学習,自己符号化器付 U-net,胸部 CT,びまん性肺疾患,セグメンテーション

## 1. はじめに

近年,深層学習を医用画像に応用する研究が活発に行われて いる.一般に,深層学習では多くの教師ラベル付きデータを必 要とするが,医療分野ではラベリングに専門知識と多大な労力 が必要であるため,学習に足る量の完全な教師ラベル付きデー タの収集が困難である.本研究では,1種類の陰影にのみ部分 的にアノテーションされた胸部 CT 画像や,アノテーション されていない胸部 CT 画像から効率的に学習し,精度の高い 陰影領域抽出[1]を行う.

#### 2. 方法

## 2.1 エンコーダ共有型自己符号化器付 Unet (UnCAE)

オリジナルの自己符号化器付 U-net(UnCAE)[2]は、本来の目 的であるセグメンテーション画像を出力するのと同時に入力 の再構成画像も出力するネットワークである. UnCAE では、 事前学習としてアノテーションされていないデータを用いて 自己符号化器部を学習し、さらにアノテーション付データを用 いて2段階目の学習を行う.ここで、本研究で提案する UnCAE では、陰影セグメンテーションを行う UnCAE を陰影ごとに構 築し、それらのエンコーダ部をすべて共有とする(エンコーダ 共有型 UnCAE). デコーダ部は共有せず、各々が異なるクラス のセグメンテーションを行う. 図 1 に、エンコーダ共有型 UnCAE の構造例を示す.



図1 エンコーダ共有型 UnCAE の構造例

## 2.22 つの損失関数を用いた学習

文献[3]では,損失関数を使い分けることでアノテーション されている領域とされていない領域の両方を活用する学習方 法の有用性が示されている.本研究では,アノテーションされ た領域を使用し,当該陰影に対応する領域学習部分と,当該陰 影と異なる陰影領域の学習部分で損失関数を使い分ける.使い 分ける2つの損失関数を式(1),(2)に示す.

$$L(y,\hat{y}) = \begin{cases} H(y,\hat{y}), & y \ class = \hat{y} \ class & (1) \\ 1 & y \ (y,\hat{y}) = y \ class + \hat{y} \ class & (1) \end{cases}$$

 $\left(-\frac{1}{4} \cdot \lambda \cdot H(y, \hat{y}), y \text{ class } \neq \hat{y} \text{ class}\right)$ (2)

yは教師ラベル, ŷは予測ラベル, H(.)は交差エントロピー, λは











(e)UnCAE (2Losses)



(a)アノテーション 画像

(b)U-net(1Loss)

(c)UnCAE(1Loss)

(d)エンコーダ共有 型 UnCAE(1Loss)

(f)エンコーダ共有 型 UnCAE(2Losses)

図2 複数陰影が混在する胸部 CT 画像のアノテーション画像とセグメンテーション画像の例

2 式間の重みを調整するパラメータである. 例えば, 肺気腫 データ学習時, 肺気腫識別器では肺気腫領域を正しくセグメン テーションするように, 式(1)を用いて教師領域と予測領域の 類似度が上がるように学習する.一方で, 肺気腫以外の識別器 では, 肺気腫領域を誤ってその他の陰影としないように, 式(2) を用いて教師領域と予測領域の類似度が下がる方向に学習す る. 他の陰影についても同様である.

## 3. 実験

## 3.1 実験概要

実験では、1 種類の陰影にのみ部分的にアノテーションされ たデータ 611 枚を用いて学習し、肺野内の全陰影が完全にア ノテーションされたデータ 16 枚で検証を行い、検証結果を比 較する. なお、UnCAE は、アノテーションなしデータ 3,545 枚 で自己符号化器部分の事前学習を行う. データはすべて山口大 学医学部附属病院で撮影された胸部 CT 画像である. アノテー ションは、5 つの陰影領域、浸潤影(CON)、肺気腫(EMP)、すり ガラス陰影(GGO)、蜂巣肺(HCM)、正常(NOR)について行われ ている. 式(2)におけるλの値は、予備実験の結果からλ = 10<sup>-3</sup> とした.

## 3.2 実験結果

表1に,各モデルについて,交差エントロピー関数のみで学習した場合(ILoss)と,式(1),(2)で学習した場合(2Losses)の Dice 係数を示す.エンコーダ共有型 UnCAE(1Loss)が最低値となり,エンコーダ共有型 UnCAE(2Losses)が最高値となった. また,図2に,アノテーション画像と,各モデルから出力されたセグメンテーション画像の例を示す.赤色が CON,緑色が EMP,青色が GGO,水色が HCM,黄色が NOR を表している. 図2より,エンコーダ共有型 UnCAE(2Losses)のセグメンテーション画像が,他のモデルと比較して誤識別領域が少ないことがわかる.このより,エンコーダ共有型 UnCAE(2Losses)は複数陰影が混在している胸部 CT 画像の陰影領域抽出タスクに対して有用であるといえる.

<b>表1</b> 実験	結果一覧	(Dice 係数の:	5 回平均お	よび標準偏差)
--------------	------	------------	--------	---------

モデル	Dice 係数±標準偏差
U-net(1Loss)	0.437 ± 0.040
UnCAE(1Loss)	0.487 ± 0.044
エンコーダ共有型 UnCAE(1Loss)	0.421 ± 0.027
UnCAE(2Losses)	0.439 ± 0.028
エンコーダ共有型 UnCAE(2Losses)	0 534 + 0 010

## 4. まとめと今後の課題

本研究では、部分的にアノテーションされたデータから複数 陰影に対応可能なセグメンテーションネットワークの構築と、 その効果的な学習方法を提案した.実験の結果、提案手法が複 数陰影のセグメンテーション精度向上につながることを示し た.今後の課題として、式(2)での学習により肺野領域以外の 領域もセグメンテーションされる問題に対し、肺野領域を抽出 したマスク画像を出力画像に適用することが挙げられる.

## 謝辞

本研究は JSPS 科研費 JP21H03840、JP22K12152 の助成を受け たものです.

#### 利益相反の有無

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 講座は,富士フイルム株式会社との共同研究講座です.

- [1] 村上佳菜子,橋本典明,木戸尚治他: CNN, FCN, U-Net を用いたびまん性肺疾患の領域抽出の比較.人工知能学会全国大会論文集: 1Z3-05 2018
- [2] 植田大介,間普真吾,呉本尭:SAR 画像と土地情報を用いた畳込み 自己符号化器付 U-net による土砂災害地域検出.第61回計測自動制 御学会システム工学部会研究会:55-61,2019
- [3] Suzuki Y, Kido S, Mabu S et al: Segmentation of Diffuse Lung Abnormality Patterns on Computed Tomography Images using Partially Supervised Learning. Advanced Biomedical Engineering 11: 25-36, 2022

## 3 次元 CT 画像によるじん肺の重症度別粒状影解析

新居 蓮叶\*1, 松廣 幹雄\*2, 河田 佳樹\*3, 大塚 義紀\*4,

岸本 卓巳\*5, 芦澤 和人\*6, 仁木 登\*7

\*1 徳島大学大学院創成科学研究科,\*2 鈴鹿医療科学大学保健衛生学部放射線技術学科

\*3 徳島大学大学院社会産業理工学研究部,\*4 北海道中央労災病院

\*5 岡山ろうさい病院, \*6 長崎大学, \*7 株式会社医用科学研究所

Micro-Nodule Analysis of Pneumoconiosis Progression Using 3D CT Images

Rento NII<sup>\*1</sup>, Mikio MATSUHIRO<sup>\*2</sup>, Yoshiki KAWATA<sup>\*1</sup>

Yoshinori OHTSUKA<sup>\*3</sup>, Takumi KISHIMOTO<sup>\*4</sup>, Kazuto ASHIZAWA<sup>\*5</sup>, Noboru NIKI<sup>\*6</sup>

<sup>1</sup> Tokushima University, <sup>\*2</sup> Suzuka University of Medical Science, <sup>\*3</sup> Hokkaido Chuo Rosai Hospital

<sup>\*4</sup> Okayama Rosai Hospital, <sup>\*5</sup> Nagasaki University, <sup>\*6</sup> Medical Science Insitute

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.じん肺の診断では単純X線写真を用いているが,近年では単純X線写真に比べて正確に病変を評価することができる3次元CT画像を用いた高精度の診断が期待されている.本研究では,3次元CT画像を用いてじん肺の定量的な診断支援システムの開発を目指している. キーワード:テンプレート,フォーマット

## 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.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、早期発見・早期治療が必要である. 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 線写真によって病型が第0型, 第1型, 第2型, 第3型,第4型に分類され、各型で3つに分類される.第1型 1/0以上の患者は労災認定となるが第0型0/1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. [1][2] 単純 X 線写真に比べて正確に病変を評価することができる 3 次元 CT 画像を用いた高精度な診断が期待されている.本研究 では、3次元 CT 画像を用いてじん肺の診断支援システムの開 発を目指している.このために、じん肺(けい肺、炭坑夫肺) の3次元CT画像を用いてこれらの粒状影を葉別に抽出し、粒 状影の個数と分布の割合を重症度別に比較することで定量的 に評価した.

## 2. CT 画像と手法

岡山ろうさい病院と北海道中央労災病院で撮影され, CT を 用いて診断された炭坑夫肺 33 症例(CT0/1 - 14 例, CT1/0 - 14 例, CT1/1 - 5 例)とけい肺 15 症例(CT0/1 - 6 例, CT1/0 - 7 例, CT1/1 2 例)を用いた.これらの CT 画像から(1)じん肺 CT 画像 データベースの作成, (2) 肺葉分割ラベルの作成, その結果を 用いて(3) じん肺の肺葉別粒状影の評価をし, 第 0 型 0/1 と 第1型1/0,1/1の比較評価を行った.[3][4]

(1)じん肺 CT 画像データベースの作成

じん肺の粒状影をマニュアル処理で抽出する.肺野条件 (WW:1500,WL:-500)で右肺尖部から肺底部,左肺尖部から肺底 部の順に粒状影をマニュアルで抽出する.初めに,粒状影を3 次元 CT 画像からマニュアルで抽出した.<sup>[5][6]</sup>読影者は1名ま たは2名で行い,1人で抽出した場合,期間を空け,2度読影 をした.2人で抽出した場合は,1人ずつ1度読影をし,合議 によって最終抽出結果を作成した.

(2)肺葉分割ラベルの作成

肺葉の分割は 3D U-Net を使用し、右肺を上葉、中葉、下葉 に左肺を上葉、下葉の 5 分割にした.<sup>[7]</sup> 学習データは 300 症 例用いた.

(3)じん肺の肺葉別粒状影の評価

じん肺の粒状影の位置を重心点と定義して,肺葉分割ラベル から肺葉別に粒状影を分類する.肺葉別粒状影について,粒状 影数ごとの肺葉別粒状影数と分布の割合によって評価する. パーシステントホモロジーを用いて,マクロな視点からじん肺 の粒状影のパーシステント図から位相空間の大域的な性質を 解析し,密集度や病態の進行を定量的に評価した.

#### 3. 結果

図1に示すように、炭坑夫肺とけい肺とでは直径別累積頻度 に差があることが分かる.炭坑夫肺では2-2.9mmにピークがあ り、右肩下がりになっている.また、けい肺では3-3.9mmにピ ークがあり、山なりになっている.これより炭坑夫肺はけい肺 に比べ、粒状影が小さいことが分かる.



図1 粒状影数と直径別累積頻度

図2に全肺野と肺葉別の1cm<sup>3</sup>あたりの粒状影数の比の結果 を示しており、じん肺の粒状影は右上葉に多く、中下葉ではほ とんど値が変わらないことが分かる.重要度間の各肺葉での粒 状影数の割合に変化はなく、粒状影が一様に増加している.



図2 全肺野と肺葉別の1cm<sup>3</sup>あたりの粒状影数の比

図 3 に炭坑夫肺の粒状影数ごとの右上葉の直径別粒状影数 とパーシステント図を示しており,重症度が上がると粒状影の 密集度が上がっていることがわかる.



図3 粒状影数ごとの右上葉のパーシステント図

## 4. まとめ

マニュアルで粒状影を抽出した後に 3D U-Net を使用し, 肺 を葉別に5分割した. データの結果を用いて, 重症度別にじん 肺(けい肺, 炭坑夫肺)の粒状影数, 大きさと分布の割合につ いて調べた. 炭坑夫肺とけい肺とでは粒状影の大きさと数の分 布に差があった. また重症度が高いほど全肺葉で粒状影数が多 く, 特に右上葉で顕著であった. 重症度間で各肺葉の粒状影は 一様に進行することが分かった. じん肺の重症度の評価には肺 葉の粒状影数が重要であることが分かった.

今後の課題として, 症例数の増加, 重症度の定量的な評価法 の構築がある.

#### 利益相反の有無

なし

- [1] 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
- [2] 永井厚志編:呼吸器疾患 第3版. 日本医事新報社, 2015, P241-250
- [3] 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.
- [4] 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.
- [5] 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.
- [6] Yuga Hashimoto, Mikio Matsuhiro, Hidenobu Suzuki, et al : Lobe-Specific Micro-Nodule Analysis of Pneumoconiosis Progression Using 3D CT Images, SPIE, Vol.12033, No.231, 1203325-1-6, 2021.
- [7] Çiçek Ö, Abdulkadir A, Lienkamp SS, et al:3D U-Net:Learning dense volumetric segmentation from sparse annotation.Proc. Medical Image Computing and Computer-AssistedIntervention–MICCAI 2016; 424-432.

## TKI 治療後における肺腫瘍成長の経時変化予測モデル

古田 凜太郎\*1,有村 秀孝\*2,田中 謙太郎\*3,加葉田 雄太朗\*4

\*1九州大学大学院医学系学府保健学専攻医用量子線科学分野

\*2 九州大学大学院医学研究院保健学部門

\*3九州大学病院呼吸器科内科学

\*4長崎大学情報データサイエンス学部

# Prediction model for the time variant trajectories of lung tumor growths after tyrosine kinase inhibitor therapy

Rintaro FURUTA<sup>\*1</sup>, Hidetaka ARIMURA<sup>\*2</sup>, Kentaro TANAKA<sup>\*3</sup>, Yutaro KABATA<sup>\*4</sup> <sup>\*1</sup> Division of Medical Quantum Science, Graduate School of Medical Sciences, Kyushu University <sup>\*2</sup> Division of Medical Quantum Science, Faculty of Medical Sciences, Kyushu University <sup>\*3</sup> Department of Respiratory Medicine, Faculty of Medical Sciences, Kyushu University <sup>\*4</sup> School of Information and Data Sciences, Nagasaki University

要旨:本研究の目的は、上皮成長因子受容体(EGFR)変異陽性非小細胞肺がん(NSCLC)患者に対するチロシンキナーゼ阻害剤(TKI)治療における腫瘍成長経時変化予測モデルを開発することである.TKI治療を受けたEGFR陽性NSCLC患者26名を選択し、治療前後のCT画像における腫瘍の輪郭を抽出した.各患者の腫瘍細胞数は輪郭抽出を行ったCT画像から求めた腫瘍体積に腫瘍細胞密度を乗じることで算出し、参考値として使用した.最後に、TKIに対する腫瘍成長(細胞数の増減)を表現する微分方程式モデルを開発し、モデルパラメータを最適化することで腫瘍細胞数の経時変化軌跡を予測した.本研究で開発したモデルは、平均絶対パーセント誤差(MAPE)とスピアマンの相関係数(SCC)で評価し平均値はそれぞれ7.50%、0.918であった.先行研究のモデルの結果(MAPE:11.1%, SCC:0.913)と比較して腫瘍細胞数の経時変化をより正確に表現できる可能性がある.本研究のモデルは、EGFR-TKIを受けているNSCLC患者に対する治療効果予測法の基礎モデルとなりうると考える.

#### 1. 背景

現在,上皮成長因子受容体(EGFR)変異陽性のステージIV 非小細胞肺がん(NSCLC)患者に対する治療として,チロシン キナーゼ阻害剤(TKI)による分子標的治療が広く行われてい るが,患者によってはTKIに対する抵抗性腫瘍細胞が増加す るため,治療効果を予測することは難しい.本研究では,EGFR 陽性 NSCLC 患者に対するTKI治療における腫瘍成長の経時 変化軌跡モデル(tumor growth trajectory モデル:TGT モデル) を開発した.腫瘍細胞はTKIに対して感受性または抵抗性を 示す細胞,および persister 細胞から成ると仮定した[1].

## 2. 材料と方法

患者データは、治療前から TKI 治療中止まで分子標的薬で あるオシメルチニブで治療されたステージ IV の NSCLC(腺癌) 患者 26 名を用いた.臨床医の助言のもと、関心領域 (ROI) セ グメンテーションを行った.等方ボクセル化した ROI に対し 腫瘍体積を計算した.計算した腫瘍体積に腫瘍細胞密度を乗じ ることで腫瘍細胞数を算出し、参考値として用いた.

腫瘍細胞には、感受性細胞(TKIで死滅する細胞)、persister 細胞(耐性細胞に変異する可能性のある細胞)[2]、耐性細胞 (TKI に抵抗性のある細胞)の3つの細胞集団があると仮定した.Bertalanffy-Putter (BP) 腫瘍成長モデル[1]と細胞消失(腫瘍縮小)方程式[3]を組み合わせてTGTモデルを実装した. TGTモデルの12個のパラメータは, simulated annealing 法を用いて最適化した.平均絶対パーセント誤差(MAPE)およびスピアマンの相関係数(SCC)を用いて,開発したTGTモデルを評価した.

#### 3. 結果と考察

本研究では図 1 に示すような腫瘍細胞の経時変化曲線を求 めた. 各患者の CT 画像から算出した腫瘍細胞数と TGT モデ ルによる予測細胞数との MAPE および SCC を表 1 に示す. MAPE および SCC の平均値はそれぞれ 7.50%および 0.918 で あり,先行研究(MAPE: 11.1, SCC: 0.913)と比較して改善が見 られた.

本研究にはいくつかのリミテーションがある.各患者におい て最も大きいプライマリー病変のみを扱っているため,すべて の腫瘍に着目する必要がある.また,患者数を増やし EGFR 遺 伝子変異以外の変異型にもこのモデルを適用して頑健性を評 価する必要がある.さらに,本研究は TKI 治療のみに焦点を当 てたものである.しかし,実際の臨床では,TKI治療は放射線 療法や化学療法などの他の療法と併用する場合がある.このような併用療法に対する腫瘍の反応に関する研究が今後の課題 の一つである.



図1 開発した TGT モデルによる腫瘍細胞数の経時変化の予測結果. 赤:TKI 感受性細胞,青:persister 細胞,黄:TKI 抵抗性細胞,緑:総 腫瘍細胞,青丸:CT 画像から算出した腫瘍細胞数.

## 4. まとめ

本研究は、EGFR-TKI 治療を受けている NSCLC 患者に対す る治療戦略提案の可能性を示唆するものであると考える.

## 謝辞

研究遂行にあたり貴重なご助言を頂いた有村研究室 (http://web.shs.kyushu-u.ac.jp/~arimura/)の皆様に深謝いたしま す.

#### 利益相反の有無

なし.

#### 文 献

 Grassberger C, David M, Changran G et al. Patient -specific tumor growth trajectories determine persistent and resistant cancer cell populations during treatment with targeted therapies. Cancer Res 79(14): 3776 -3788, 2019. [2] Ogawa K, Harada 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

- [2] Sehgal K, Portell A, Ivanova EV et al: Dynamic single -cell RNA sequencing identifies immunotherapy persister cells following PD -1 blockade. J C lin Invest 31(2): e135038, 2021
- [3] von Bertalanffy L: Quantitative laws in metabolism and growth, The Quarterly review of biology 32(3): 217–231, 1957

## 骨シンチグラムの陽性高集積検出支援システム設計時における

## テストデータ再利用による性能のバイアスとその補正

山中 陽大\*1, 東山 滋明\*2, 河邊 讓治\*2, 中岡 竜介\*3, 清水 昭伸\*1

\*1 東京農工大学大学院工学府

\*2大阪公立大学医学部附属病院核医学科

\*3 国立医薬品食品衛生研究所医療機器部

Performance bias by test data reuse in designing a hot spot detection support system of bone scintigram and the bias correction

Haruto YAMANAKA\*1, Shigeaki HIGASHIYAMA\*2, Joji KAWABE\*2, Ryusuke NAKAOKA\*3,

## Akinobu SHIMIZU\*1

<sup>\*1</sup> Institute of Engineering, Tokyo University of Agriculture and Technology

\*2 Department of Nuclear Medicine, Graduate School of Medicine, Osaka Metropolitan University

## \*3 Division of Medical Devices, National Institute of Health Sciences

要旨:本報告では、コンピュータ支援診断システムを開発する際に、同一のテストデータの再利用によって生じる性能のバイアス に注目する.まず、前立腺がん患者の骨シンチグラムを用いて、学習データや初期値を変えて、異なる複数個の陽性高集積検出モ デルを学習する.次に、それらの学習済みモデルを同一テストデータに適用し、ROC 下面積の AUC が最大のモデルを逐次的に選 択しながら複数のモデルを組み合わせたアンサンブルモデルを構築する.本報告では、このアンサンブルモデルの性能を、設計時 に再利用したテストデータと、それとは異なるフレッシュなテストデータを用いて評価し、両者を比較することで、再利用したテ ストデータによる性能に混入するバイアスを確認する.また、従来の研究を参考にバイアスを低減させる方法を適用した結果につ いても確認し、その有効性について考察する.

キーワード:テストデータ再利用,検出支援システム,バイアス,骨シンチグラム,アンサンブル学習

## 1. 背景と目的

人体の撮影技術の高精度化に伴い,診断に使用される画像枚 数が増加している.そこで,医師の負担を軽減して診断の効率・ 精度の向上を目指すコンピュータ支援検出/診断(Computer-Assisted Detection/Diagnosis, CAD)システムの開発が進められ ている[1]. CADシステムでは,性能評価を繰り返しながらシ ステムを設計する場合がある.例えば,深層モデルのハイパー パラメータチューニングや,複数モデルのアンサンブルを行う 場合などである[2,3]. その際,医用画像はアノテーションコス トが高く,ラベル付きのデータを大量に集めることは困難であ るため,同一のテストデータを繰り返し使用することが想定さ れるが,バイアス等の問題が指摘されている[4,5,6].

本稿では、骨シンチグラムに対する陽性高集積の検出支援シ ステムを対象に、アンサンブル学習においてテストデータを再 利用した場合をシミュレーションし、評価値に含まれるバイア スを確認する.また、従来の方法[5,6]を参考に、バイアスを低 減する補正法を適用する.

## 2. 関連研究と問題点

Gossmann ら[5]は、Dwork ら[6]の手法を拡張したバイアスを 補正するアルゴリズム*Thresholdout<sub>AUC</sub>*を提案した.そこでは、 同一テストデータによる ROC 下面積の AUC を利用して分類 器を設計する際、式(1)に従って補正を行う.

$$\widehat{AUC}_{S_h}[\phi] = \begin{cases} \widehat{AUC}_{S_h}[\phi] + \xi, & if \left| \widehat{AUC}_{S_h}[\phi] - \widehat{AUC}_{S_t}[\phi] \right| > T + \eta \\ \widehat{AUC}_{S_t}[\phi], & else \end{cases}$$
(1)

ここで、 $S_t$  は学習データ、 $S_h$ は public データの集合を表す. こ の public は、繰り返し利用する同一のテストデータを意味す る.式(1)の条件を満たす場合にのみ、public データの AUC に ノイズを加えることで、テストデータの情報が不適切に設計に 利用され、性能にバイアスが含まれることを防ぐ.

上記の先行研究[5,6]では, public データによる評価値を分類 器に用いる特徴量選択に繰り返し利用している.しかし,最近 の深層ネットワークでは,特徴量は学習の中で自動獲得される. そのため,これらの文献[5,6]の結論が,それ以外の分類器の設 計方法,例えば,複数の深層ネットワークのアンサンブル学習 の場合にも当てはまるか否かは不明である.

## 3. 深層ネットワークを利用したバイアスの検証

本稿では、骨シンチグラムから陽性高集積を検出する深層ネ ットワーク[7]に注目して、学習結果をアンサンブルする際に、 public テストデータを再利用した場合の AUC に対するバイア スの検証を行う.具体的には、まず学習データとネットワーク の重みの初期値をランダムに変えた 20 個のモデルで学習を行 う。次に 20 個のモデルについて public データと private デー タを用いて推論を行う.次に public データの AUC が最も高い モデル 1 個を選ぶ.選択したモデルとその他のモデル 19 個そ れぞれについて、予測値の単純平均を取り public データの AUC が最も高い組み合わせを選択する。次に,選ばれた2個のモデ ルとその他の18個のモデルそれぞれで同様にAUCが最良に なる組み合わせを選択する。これを20個中10個が選択される まで行い,publicデータとprivateデータのAUCを比較し,バ イアスの検証を行う.また上記に加えて,予測値の単純平均を 取りpublicデータのAUCを計算する際にGossmannらの手法 (式(1))を適用し,AUCを補正した場合の実験も行う

## 4. 実験条件

本実験では従来の高集積検出システムに用いられる ResBtrflyNet[7]をネットワークに用い、学習データとして、前 後面の骨シンチグラム 10 症例(512×1024[pixel], 2.8[mm/pixel]), 症例に対応した高集積ラベル(2 クラス)を使用する.テストデ ータとして public データ, private データそれぞれランダムに 10 症例を選択,これを 10 通り用意し実験結果の検証に用いる. 学習回数は 10,000iteration とし、ミニバッチサイズは 10, Optimizer には Adam( $\alpha$ =0.001,  $\beta_1$ =0.9,  $\beta_1$ =0.999)を使用した. 損 失 関 数 は Softmax Cross Entropy を 用 いた.また *Thresholdout<sub>AUC</sub>*のパラメータは*T*=0.05,  $\sigma$ =0.01, $\eta$ =  $N(0, 4\sigma), \xi = N(0, \sigma)$ とした.

## 実験結果・考察

10 通りのテストデータに対するアンサンブル結果を図1 に, *Thresholdout<sub>AUC</sub>*を適用した結果を図2に示す. 横軸はアンサ ンブルするモデル数,縦軸は10通りのテストデータの平均 AUC とその標準偏差を表す.



図1よりアンサンブルに使用するモデル数が増加するに従い、public と private の AUC が共に上昇していることが読み取れる. モデル数 1~10 すべてにおいて public と private の AUC について "2 群の母集団の平均値は同じである"を帰無仮説として、有意水準 0.05 の Willcoxon の符号付順位検定を行ったところ、モデル数が 3~6 までは棄却され、残りは保留となった. このことは、モデル数が 3~6 の場合について、バイアスが含まれていることを示唆している.

また図 2 よりThresholdout<sub>AUC</sub>を適用した場合に public と

private の AUC の差が縮まっていることが読み取れる. こち らでも同様に検定を行った結果すべてのモデル数において帰 無仮説が保留された. このことは

## 6. まとめ

骨シンチグラムを用いた、学習済みモデルのアンサンブルを public の AUC を評価値として行ったが、結果は public, private のどちらの AUC もアンサンブルするモデル数が一定 の数までは上昇した.検定の結果からは、モデル数が少ない場 合 に つ い て バ イ ア ス の 存 在 が 示 唆 さ れ た . ま た *Thresholdout<sub>AUC</sub>*を適用した場合、すべてのモデル数において 帰無仮説が保留されバイアスの補正ができたことが示唆され た.今後は、引き続きバイアスの検証を行ない、そのバイアス に対して、Gossmann ら[5]の手法を参考にして、バイアスの 補正を行う.

#### 謝辞

日頃から熱心にご指導・ご討論いただく東京農工大学清水昭 伸研究室の各位に感謝いたします. なお本研究は, AMED の 「AI を利用した医療機器プログラムの市販後学習時の性能評 価に資する研究」(22mk0101240 h 0101)の支援を受けています.

#### 文 献

 野村行弘,増谷佳孝,三木総一郎,他:遠隔読影環境における他施設連携型CAD開発,実運用,および継続的性能改善. Medical Imaging Technology, Vol. 32, No. 2 pp.98-108, 2014.

[2] P. Probst, A. Boulesteix, B.Bischl, "Tunability: Importance of Hyperparameters of Machine Learning Algorithms", JMLR, 2019

[3] M. A. Ganaie, M. Hu, A.K. Malik, et al. "Ensemble deep learning: A review", EAAI, vol 115, 2022

[4] R. Roelofs, V. Shankar, B. Recht, et al. "A Meta-Analysis of Overfitting in Machine Learning", NeurIPS2019

[5] A. Gossmann, A. Pezeshk, Y. Wang, et al. "Test Data Reuse for the Evaluation of Continuously Evolving Classification Algorithms Using the Area under the Receiver Operating Characteristic Curve", SIAM Journal on Mathematics of Data Science, Vol. 3, No. 2, pp.692-714, June 2021

[6] C. Dwork, V. Feldman, M. Hardt, et al. "The reusable holdout: Preserving validity in adaptive data analysis", Science, Vol. 349, No. 6248, pp.636-638, 2015

[7] A. Shimizu, H Wakabayashi, T Kanamori, et al., "Automated measurement of bone scan index from a whole-body scintigram", International Journal of Computer Assisted Radiology and Surgery Vol. 15, pp.389-400, 2019

## MRI による前立腺癌スクリーニングのための要精査領域検出モデルの検討

橋本 綾斗\*1.2, 立花 泰彦\*1, 岸本 理和\*1, 熊切 俊夫\*1.2,

森 慎一郎\*1,森 康久仁 \*3,若月 優\*1,須鎗 弘樹\*3

\*1国立研究開発法人量子科学技術研究開発機構

\*2千葉大学大学院融合理工学府

\*3千葉大学大学院工学研究院

Evaluation of the neural network detection model to facilitate efficient pickup in

## prostate cancer screening

Ayato HASHIMOTO<sup>\*1,2</sup>, Yasuhiko TACHIBANA<sup>\*1</sup>, Riwa KISHIMOTO<sup>\*1</sup>, Toshio KUMAKIRI<sup>\*1,2</sup>,

Shinichiro MORI<sup>\*1</sup>, Yasukuni MORI<sup>\*3</sup>, Masaru WAKATSUKI<sup>\*1</sup>, Hiroki SUYARI<sup>\*3</sup>

<sup>\*1</sup> National Institutes for Quantum Science and Technology

<sup>\*2</sup> Chiba University, Graduate School of Science and Engineering

<sup>\*3</sup> Chiba University, Graduate School of Engineering

**要旨**: MRI による前立腺癌診断を補助するため,最終的には癌でなくとも専門医が要精査とする所見を検出する AI が必要である. この目的のため本研究は,診断医の読影手順を模して広域画像とその一部である局所画像を並列処理する検出モデルを開発した. 広域画像のみ用いたモデルをコントロールとして検出力を比較すると,提案モデルの指標が有意に優れ,設計の意義が示唆された. **キーワード**:前立腺, MRI,人工知能,コンピュータ支援画像診断,医用画像処理

## 1. はじめに

前立腺癌診断における MRI 検査は,T2 強調画像(T2WI) と,拡散強調画像(DWI)およびみかけの拡散係数マップ(ADC Map)等の撮像シークエンスを標準的に使用する.これにダイ ナミック造影 T1 強調画像(DCE-T1WI)を加えた検査では, 画像に関心領域(ROI)を設定し観察する Time-Intensity curve 解析等の定量解析により,評価の定量性向上が期待できる.

一方,そのような解析の ROI 設定には、その簡便さに課題 がある.前立腺には画像のみで癌と判断し難い所見が少なくな いため、熟練の専門医でなければ適切な ROI 設定は難しく、 解析の有用性が知られつつも[1]、十分な普及に至っていない.

この問題を解決するためには、専門医が癌を疑い要精査とす る所見の検出モデルを開発し、ROI 設定を支援することが有用 と思われる. 先行研究では検出対象が生検等で確定した癌とす ることが一般的で [2,3],専門医が要精査とする所見を対象と したものはない. そこで我々は要精査領域検出のため、医師の 読影手順を模し、前立腺の広域と局所の情報を並列処理するニ ューラルネットワークモデルを開発した.本研究の目的は、こ のモデルにおける並列処理の意義を検討することである.

## 2. 方法

## 2. 1 データ

226 症例に対し専門医により設定された 347 個の要精査領域 を対象とし、訓練データ 250 個、検証データ 80 個、テストデ ータ 17 個にランダムに割り付けた.モデルへの入力データと して、4種の画像(T2WI, ADC Map, CE-T1WI, DCE-T1WI)よ りほぼ小骨盤領域に相当する広域画像とその一部である局所 画像を定義した(図 1a,b).また、広域画像内の要精査領域の 位置を示す正解画像(図 1c,d)と、局所画像内に要精査領域が 存在するかどうかを2値で示すラベルを生成した.



図1 学習・検証用の画像データ作成例

(a) 広域画像:前立腺全体を含む 128×128pixel の画像(例は T2WI).
 (b) 局所画像:広域画像から任意の領域をクロップした 15×15pixel の画像.学習時は要精査領域かそれ以外の領域から無作為に生成する.
 (c,d) 正解画像:広域画像に対し検出対象の位置を示す画像.教師データでは(c)のように中心を最大値とし値が正規分布を示す円,テストデータでは(d)のように直径 11pixel で値が 1 の円とした.

## 2.2 学習モデル

提案するモデルは、A: 広域画像をセグメンテーションする Encoder-decoder モデルおよび、B:局所画像とAより得た特徴 から局所画像内に要精査領域が存在するか否かを分類する CNN からなる(図2). 訓練データを用い、入力画像に対して 最終的に B より適切な分類(局所画像が要精査領域を含むか どうか)を出力できるよう最適化した.



図2 学習モデルの概要

入力は4つの撮像シークエンスの画像からなり、それぞれに対応する Encoder を持つ. Aは、広域画像を入力し、セグメンテーション画像 と特徴マップを出力する. この特徴マップは、Decoder の最終層に近 い層より、局所画像の対応する位置をクロップして得る. Bは、Aか らの特徴マップと局所画像を入力し、二値分類の結果を出力する.

## 2.3 検出マップの生成

学習済みモデルより得た広域画像に対するセグメンテーション画像と、局所画像に対する分類結果を併用し、要精査領域の検出マップを以下のように生成した. 1. Sliding Window 方式で広域画像から局所画像を走査的に生成 2. 各局所画像 を学習済みモデル分類し、その結果を対応する領域へ積算し ていくことで一時マップを生成 3. このマップにセグメンテ ーション画像を加算し、最終的な検出マップ生成.

#### 2. 4 検証方法

広域と局所を併用した提案モデル(A+B)と、広域画像の み用いたコントロールモデル(Aのみ)を比較し、広域と局所 を併用する意義を検証した.統計学的検討のため、テストデー タ各例で検出マップと評価用正解画像(図1d)の間のJaccard 係数を指標として求め平均した.このとき、検出陽性とする出 力の閾値を変化させ、各モデルの評価指標が最良となる閾値で 検出精度を比較した(Wilcoxon符号付き順位検定、P<05を有 意).さらに、各モデルの検出マップを、CE-T1WI上にカラー マップ表示し、視覚的に評価した.

#### 3. 結果と考察

閾値を最適化したときの評価指標 (Jaccard 係数) は、コント ロールモデルで 0.52 (0.47, 0.65) [平均 (最小,最大)],提案 モデルで 0.60 (0.49, 0.79) となった (図 3a).評価指標の分布 には有意差があり (P=0.0075),提案法がコントロールよりも 高い値を示した (図 3b).また,視覚的評価においても,提案 法により検出精度が改善したと考えられた (図 4).



(a) 閾値の違いによる評価指標の変化:設定する閾値により Jaccard 係数は変動するが,ほとんどの値において提案法(A+B)はコントロールよりも優れた.(b)評価指標の分布:(a)より最適化した閾値において,提案法はコントロールよりも優れ,差は有意であった.



(a) 正解位置:検出すべき要精査領域を赤色で示す.(b) コントロー ルモデルの検出マップ:正解の領域以外も多く検出しており特異度が 低い.(c)提案モデルの検出マップ:検出すべき領域をほぼ正確に表

以上より、広域情報のみを用いた場合と比べ、局所情報を併 用した方が要精査領域を高精度に検出できると考えられ、ROI 設定の支援のために、より役立つことが期待できる.

本研究の限界として症例数の少なさや、特定の機関・装置で 収集したデータのみを用いている点が挙げられる.

## 4. 結論

示できている.

本研究の結果は,提案モデルにおける広域と局所の画像を併 用する意義を支持する.

- [1] Wu X, Reinikainen P, Kapanen M et al: Dynamic contrast-enhanced imaging as a prognostic tool in early diagnosis of prostate cancer: correlation with PSA and clinical stage. Contrast Media & Molecular Imaging 2018:3181258, 2018
- [2] Aldoj N, Lukas S, Dewey M et al: Semi-automatic classification of prostate cancer on multi-parametric MR imaging using a multi-channel 3D convolutional neural network. European radiology 30:1243-1253, 2020
- [3] Lapa P, Castelli M, Gonçalves I et al: A hybrid end-to-end approach antegrating conditional random fields into CNNs for prostate cancer detection on MRI. Appl Sci 10(1):338, 2020

# CNN による頭部 Thick-Slice CT 画像からの 脳内血腫領域の自動抽出

永澤 朗\*1, 藤田 大輔\*1, 渡辺 翔吾\*2

連 乃駿<sup>\*2</sup>, 飯原 弘二<sup>\*2</sup>, 小橋 昌司<sup>\*1,2</sup>

\*1 兵庫県立大学

\*2国立循環器病研究センター

# Automatic Extraction of Intracerebral Hematoma Region from Thick-Slice

CT Images of the Head using Convolutional Neural Network

Akira Nagasawa<sup>\*1</sup>, Daisuke Fujita<sup>\*1</sup>, Shogo Watanabe<sup>\*2</sup>,

Nice Ren<sup>\*2</sup>, Koji Iihara<sup>\*2</sup>, Syoji Kobashi<sup>\*1,2</sup>

\*1 University of Hyogo

\*2*The National Cerebral and Cardiovascular Center* 

要旨:脳血管疾患のうち代表的な脳内血種(ICH: intracerebral hematoma)は、発症から診断まで迅速な対応が 求められる.診断には頭部 CT 画像からの ICH 領域の体積、形状、位置などが有効である.従来の ICH 領 域抽出法はセマンティックセグメンテーションに基づき、頭部 CT 画像における脳内の高吸収領域を抽出 するため、ICH と脳室内出血(IVH: intraventricular hemorrhage)の双方を有する症例において精度が低下する 問題点がある.本研究では、イメージパッチ識別に基づく新しい ICH 領域抽出法を提案する.同手法は、 ボクセルごとの convolutional neural network (CNN)によるクラス分類により、高吸収領域における ICH と IVH を識別する.提案法を評価するため、9 例に適用した.交差検証は leave-one-out 法を用いた.CNN は 10 層の Original CNN、VGG16、Resnet50 を比較した.実験結果より、VGG16 が最良で、テストデータに対 して、Precision 83.0%、Accuracy 72.6%、F 値 81.6%であった.

キーワード: ICH, セマンティックセグメンテーション, イメージパッチ, CNN

## 1. はじめに

脳血管疾患の代表的な例として, 脳内出血, 脳梗 塞、くも膜下出血がある.脳血管疾患の 31%を占 める脳内出血は、主に高血圧による動脈硬化によ り血管が破裂し、脳実質に出血してしまう疾患で ある.また、時間経過し凝固したものを脳内血種 (ICH: Intracerebral Hematoma)と呼ぶ. 診断には頭部 CT 画像からの ICH 領域の体積,形状,位置などが 有効であるが,専門の放射線医が常駐できないこ と, 読影自体が難しいことから, 自動抽出を行うこ とで放射線医の負担の軽減が期待できる.従来の ICH 領域抽出法[1][2]は、セマンティックセグメン テーションに基づき, 頭部 CT 画像における脳内の 高吸収領域を抽出するため, ICH と脳室内出血 (IVH: intraventricular hemorrhage)の双方を有する症 例において精度が低下する問題点がある.本研究 では, CNN を用いて頭部 Thick-Slice CT 画像から 階層的に ICH 領域を抽出する手法を提案する.

## 2. 使用データ

本研究では J-ASPECT study で収集された, ICH と IVH の双方の発症が確認された 9 名を対象とし た.研究の実施は、九州大学の倫理委員会の承認 を受けて実施した.本研究に使用した頭部 CT 画 像および正常例を図 1 に示す.また CT 画像デー タは DICOM 形式であり、詳細を表 1 に示す. 表1 DICOM データの詳細

MPR(Multi-planar reconstruction)像	Axial
画素数	512×512 pixel
空間解像度	0.47 mm/pixel
スライス間隔	9.0 mm
スライス枚数	20-50 枚



(a) 正常例 (b) ICH (c)図1 頭部 CT 画像の例

#### 3. 提案法

3.1) 高吸収域における ICH 候補領域の抽出 まず画像の CT 値を次式で調整する.

$$\mu' = \max\left(0, \min\left(\frac{\mu - TH_{\min}}{TH_{\max} - TH_{\min}} \times 255, 255\right)\right)$$
(1)

ここで, μは注目ボクセルの CT 値[HU], μ'は 変換後の値[a.u.]で, TH<sub>min</sub>とTH<sub>max</sub>は各 DICOM 画像に撮影時に設定された Window Level, Window Width を基に決定した. 次に,頭蓋骨外 側輪郭を Level-set 法を用いて抽出する。初期形 状を画像端にした Level-set 法を適用すること で,頭蓋骨外側輪郭を抽出する.得られた輪郭内 部で、しきい値の範囲内の領域を高吸収な ICH の候補領域として抽出する. しきい値は実験的 に求め, 下限を 120[a.u.], 上限を 230[a.u.]とした. 3.2) ICH 候補領域での ICH と IVH の識別

3.1 で抽出した領域は ICH と IVH から構成され る. 各画像における抽出領域の各ボクセルについ て次の処理を行う. Axial 断層画像中において,注 目ボクセルを中心とした高さH(pixel),幅W(pixel) の正方形領域をイメージパッチとして生成し, ICH, 或いは IVH のラベルと共に保存する. 切り出す領 域に画像の範囲外を指定した場合,画素値0で Padding される. 本研究では、W, H=129 とした. 生成したイメージパッチを入力し、2クラス分類を 行い ICH か IVH を出力する CNN を学習する.本 手法は,注目ボクセル及び近傍ボクセルのウィン ドウ条件調整後のイメージパッチを入力すること で、微小な特徴量の差異の抽出に有効であると想 定できる.また、ネットワーク構造が単純になり、 頭部 CT 画像全体を入力とする CNN と比較してパ ラメータ数が激減するため学習が容易に進行し易 く, 各断層画像から多数のデータセットを生成す るため、制限がある被験者数においても十分な学 習が可能になることが期待できる.

#### 4. 実験結果

本研究では, 交差検証として leave-one-out 法, ネ ットワークモデルとして3つの2D-CNN(VGG16[3], ResNet50[4], 10 層の Original CNN)を用いた. Original CNN モデル構造を図 3 に示す. 入力は前 述の W×H のイメージパッチとし, 出力層には活性 化関数に Softmax を用いて確率に変換しクラス分 類を行う. 学習データの拡張として, 水平・垂直方 向の反転と0-90°の回転操作を行った.その他の学 習パラメータを表2に示す.

表2 学習パラメータ

エポック数	50
バッチサイズ	512
損失関数	Binary Cross Entropy
最適化関数	Adam
学習率	10-6



図 3 Original CNN のモデル構造

表3に3つのCNNにおけるPrecision, Accuracy, F 値を示す.

表3 各種 CNN における評価指標

評価指標	Resnet50	VGG16	Original
Precision	82.6	83.0	81.4
Accuracy	71.9	72.6	70.3
F值	81.1	81.6	80.3

## 5.まとめ

本研究では、従来研究である CNN を用いた ICH 領域抽出法を拡張し、イメージパッチによる CNN による 2 クラス分類を利用して高吸収域内の ICH 領域を抽出する手法を提案した. ICH と IVH の識 別では CNN を用いて高吸収域内の ICH 領域の抽 出を行い, VGG16 が最良の結果を示し, テストデ ータに対して, Precision: 83.0%, Accuracy: 72.6%, F値: 81.6%であった.本手法は ICH と IVH の識別 に一定の有効性を示した.

#### 謝辞

本研究の一部は,厚生労働科学研究費補助金(政 策科学総合研究事業(臨床研究等 ICT 基盤構築・ 人工知能実装研究事業)課題番号 19AC1003 の支援 を受けて実施した.

#### 利益相反の有無

なし

## 参考文献

- [1] W. Kuo, C. Hane, P. Mukherjee, "Expert-level Detection of Acute Intracranial Hemorrhage on Head Computed Tomography Using Deep Learning," PNAS, vol. 116, article no.45, 2019
- J. Cho, K. Park, M. Karki, et al., "Improving Sensitivity on [2] Identification and Delineation of Intracranial Hemorrhage Lesion Using Cascaded Deep Learning Models," Journal of Digital Imaging, vol.32, pp.450-461, 2019.
- [3] K. Simonyan, A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," ICLR, 2015.
  [4] K. He, X. Zhang, S. Ren, et al, "Deep Residual Learning for
- Image Recognition", CVPR, 2015.

肺がん定位体放射線治療における 3 次元計画 CT 画像上の GTV に対する 深層学習ネットワークのセグメンテーション性能への訓練対テスト比の影響 崔 雲昊\*1,有村 秀孝\*2,白川 友子\*3,吉武 忠正\*4,塩山 善之\*5,藪内 英剛\*2 \*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 九州がんセンター \*4 九州大学大学院 医学研究院 臨床放射線科学分野 . \*5 九州国際重粒子線がん治療センター

# Impact of training-to-test number ratio on segmentation performance of deep learning networks for gross tumor volumes on 3D planning computed tomography images

## in lung cancer stereotactic body radiotherapy

Yunhao Cui<sup>\*1</sup>, Hidetaka Arimura<sup>\*2</sup>, Yuko Shirakawa<sup>\*3</sup>, Tadamasa Yoshitake<sup>\*4</sup>, Yoshiyuki Shioyama<sup>\*5</sup>, Hidetake Yabuuchi<sup>\*2</sup>

<sup>\*1</sup> Department of Health Sciences, Graduate School of Medical Sciences, Kyushu University

<sup>\*2</sup> Department of Health Sciences, Faculty of Medical Sciences, Kyushu University

\*3 National Hospital Organization Kyushu Cancer Center

<sup>\*4</sup> Department of Clinical Radiology, Graduate School of Medical Sciences, Kyushu University <sup>\*5</sup> Ion Beam Therapy Center, SAGA HIMAT Foundation

**要旨**: 我々は深層学習 (DL) を用いて体幹部定位放射線治療 (SBRT) の治療計画 CT 画像において肺腫瘍の領域抽出法を研究して いる。SBRT において領域抽出性能は訓練データ数に依存するが、その性能をある程度維持できる訓練データ数は研究されていな い。本研究では、訓練データ数対テストデータ数比 (training-to-test number ratio: TTR) の腫瘍領域抽出性能に対する影響を調査し た。本研究は、非小細胞肺癌患者 192 名[solid: 118 名、part-solid: 53 名、ground-glass opacity (GGO): 21 名]を対象とした。3D U-Net、V-Net、および Dense V-Net の 3 つの DL モデルを5 パターンの TTR(1.00、0.791、0.531、0.291 および 0.116)でトレーニングし た。3 つのモデルは、Dice 係数、precision、および recall に基づいて評価された。V-Net は、TTR=0.116 のとき、最も高い 0.788 の Dice 係数を達成し、precision は 0.826、recall は 0.794 であった。訓練症例が 10%、検証症例が 5%に削減されても、ある程度領域 抽出性能を維持できる可能性を示した。

キーワード:深層学習、訓練データ数対テストデータ数比、腫瘍領域抽出、体幹部定位放射線治療

#### 1. Introduction

Lung cancer is one of the most common types of cancer worldwide. Stereotactic body radiotherapy (SBRT) is one of treatment options for patients with early-stage (stage I or II) non-small cell lung cancer (NSCLC) who are medically inoperable or refuse surgery. To perform SBRT, the contours of the tumor regions should be accurately delineated, but there are intra- and inter-observer variations in those contours [1]. Therefore, automated methods [2-4], which can reduce random and systematic variations in treatment planning in manual contours, have been investigated to derive more reproducible and accurate GTVs. However, for SBRT patients, available cases for deep learning (DL) are few, and it would be very hard to collect sufficient clinical cases for deep learning. Besides, since the segmentation performance depends on the size of training dataset, there has been no study on the number of training data that can maintain the performance to some extent for SBRT cases. To explore the impact of the training data size on segmentation results, we defined the trainingto-test number ratio (TTR), which is the ratio of the number of cases in a training dataset to that in a test dataset, and we investigate the impact of TTR on the segmentation performance of deep learning networks.

#### 2. Materials and Methods

This study aimed to explore the impact of TTRs on the segmentation performance of DL networks for gross tumor volumes (GTVs) on 3D planning computed tomography (CT) images for lung cancer SBRT.

192 patients [solid: 118; part-solid: 53; ground-glass opacity (GGO): 21] who underwent SBRT from 2004 to 2008 were included in this study. Each GTV used for training the models was cropped

from the three-dimensional (3D) planning CT images based on the centroids of the tumors into  $40 \times 40$  voxel axially and include all the slices from the start slice and end slice of a tumor region. The cropped images were quantized to 8 bits with a window level of 250 and a window width of 1250 to normalize the voxel values. To enhance the edges, the normalized images were processed by a Laplacian of Gaussian filter.

Three DL networks (3D U-Net, V-Net, and dense V-Net) were trained with five datasets with different TTRs. To compare the three models, we revised the number of kernels and layers while maintaining the total number of trainable network weights, which were similar for the three models (3D U-Net: 442k trainable network weights, V-Net: 407k trainable network weights, dense V-Net: 412k trainable network weights). To avoid overfitting when using extremely small training datasets, data augmentation including image flipping, rotation, and rescaling was separately applied to the training data of all five TTR datasets just before DL models. The augmentation parameters (with or without flipping, rotation degree, and rescaling percentage) were randomly selected from uniform distributions with their ranges of 1 or 0 for flipping, -10° to 10° for rotation, and -10% to 10% for rescaling.

To evaluate the proposed approaches for the different TTR datasets, five datasets, with 40% (TTR=1.00), 35% (TTR=0.791), 31% (TTR=0.531), 20% (TTR=0.291), and 10% (TTR=0.116) allocated for training, respectively, were created based on a step-by-step random selection method from the entire dataset of 192 cases, shown in Fig. 1. The segmentation accuracies for all models were evaluated using the Dice similarity coefficients (DSCs) [21], precision, and recall.





## 3. Results and Discussion

V-net achieved the highest DSC of 0.788 among the three models with a precision of 0.826 and recall of 0.794 at a TTR of 0.116, compared to 3D u-net (DSC of 0.761, a precision of 0.715 and recall of 0.871) and dense V-net (DSC of 0.775, precision of 0.741 and recall of 0.860). Tumor regions segmented by V-net are shown in Fig. 2. The performance of all DL models gets worse but still stays acceptable even though the training and validation data were reduced to 10 and 5%.



図 2 五つの TTR で V-net を用いた solid、part-solid および GGO 症例に対して腫瘍領域抽出の実例(中央スライス)

#### 4. Conclusion

The results indicated that the segmentation performance could stay acceptable even though the training and validation data were reduced to 10 and 5%.

## 謝辞

This study was partially supported by a grant from JSPS KAKENHI Grant Number JP20K08084. The authors are grateful to all members of the Arimura Laboratory for their valuable and helpful discussion.

#### 利益相反の有無

なし

 Weiss E, Hess CF: The impact of gross tumor volume (GTV) and clinical target volume (CTV) definition on the total accuracy in radiotherapy. Strahlenther Onkol 179: 21-30, 2003.

- [2] Zhong Z, Kim Y, Plichta K, et al: Simultaneous cosegmentation of tumors in PET-CT images using deep fully convolutional networks. Med Phys 46:619–633, 2019.
- [3] Wong J, Huang V, Giambattista JA, et al: Training and Validation of Deep Learning-Based Auto-Segmentation Models for Lung Stereotactic Ablative Radiotherapy Using Retrospective Radiotherapy Planning Contours. Front Oncol 11: 2085, 2021.
- [4] Cui Y, Arimura H, Nakano R, et al: Automated approach for segmenting gross tumor volumes for lung cancer stereotactic body radiation therapy using CT-based dense V-networks. J Radiat Res 62: 346-355, 2021.

## 深層学習を用いた放射線肺臓炎の領域抽出とその放射線治療計画への応用

福士 晴哉\*1, 国枝 悦夫\*2, 尾川 浩一\*1

\*1 法政大学理工学部

\*2 総合東京病院放射線治療センター

## Extraction of radiation pneumonitis with deep learning and its application to a radiation planning

Seiya FUKUSHI<sup>\*1</sup>, Etsuo KUNIEDA<sup>\*2</sup>, Koichi OGAWA<sup>\*1</sup>

<sup>\*1</sup> Faculty of Science and Engineering, Hosei University

<sup>\*2</sup> Department of Radiation Oncology, Tokyo General Hospital

要旨:肺がんの放射線治療において,照射の対象となる腫瘍部位よりも広がって放射線肺臓炎が発生する場合がある.現在,放射線 肺臓炎の評価は肉眼的な CT 所見,症状などによっているが主観的な要素が強く,より客観的な評価が望まれる.本研究は放射線 治療計画と放射線肺臓炎の発生範囲の関係性を調べ,放射線肺臓炎の正確な評価を目的としている.本研究では放射線肺臓炎の発 生部位を深層学習によって抽出した.この際,まず肺野領域を抽出し,その後放射線肺臓炎部の抽出を行った.放射線肺臓炎部の 抽出では放射線肺臓炎の症例が少ないため,類似の症状となる新型コロナウィルス罹患患者の X 線 CT 画像を利用した.この抽出 領域と線量計画時の投与線量との相関を調べたところ有意な相関があることが明らかとなった.

キーワード:X線CT, 医用画像処理, 放射線治療, 治療計画, 深層学習

## 1. はじめに

放射線肺臓炎は放射線治療による肺の障害が原因で起こる 肺炎である.適正な放射線治療計画が行われた場合でも,患者 によって放射線への耐性や感度が異なるため,副作用として 放射線肺臓炎が発症してしまう場合がある.肺疾患の領域抽出 の問題に対し先行研究として,様々な深層学習モデルを用いて CT 画像から疾患部を領域抽出し評価するもの[1]や,新型コロ ナウィルス肺炎患者の CT 画像から感染領域を抽出する際の 様々な種類の深層学習を評価する研究[2]などがある.本研究 では放射線肺臓炎を低減することを目的とし,深層学習によっ て放射線肺臓炎の領域を抽出後,放射線肺臓炎が発生した領域 と放射線治療計画との関連性を客観的に評価する方法論を構 築することを目指している.

#### 2. 方法

本研究では入手可能な放射線肺臓炎の症例数が少ないため, 症状が類似する新型コロナウィルス罹患患者のX線CT画像 をCancer Imaging Archive [3]より取得し活用した.合計44人の 新型コロナウィルス罹患患者のX線CT画像の中から肺領域 周辺の画像のみを選び,画像枚数は合計で5187枚とした.こ れらの画像に対して,肺領域の画素のコントラストを上げて疾 患部の検出感度を高めるために, -1024から0のCT値を0~ 1の値に正規化し使用した.また,画像サイズは512×512 画 素を256×256 画素に変更し使用した.これらの画像に対して, 深層学習で肺領域抽出モデルと,疾患部を抽出するモデルを Pix2Pix[4]を用いて作成した.

肺領域抽出用の教師データはペイントツールで肺以外を黒

く塗りつぶして作成した. 訓練用データは 1290 枚, テストデ ータは 390 枚とした.

疾患部抽出用の教師データは,肺領域抽出画像から血管や気 管支などの不要な箇所を除去し疾患部だけ抽出することを目 的として,対象領域を描き塗りつぶした後,カーネルサイズ5 ×5でモルフォロジー演算のオープニング処理を行ない作成し た.訓練用データは3966枚,テストデータは1221枚とした.

#### 3. 結果と考察

#### 3.1 肺領域抽出モデルの学習

肺領域抽出モデルの学習の結果を以下に示す.図1はテス トデータの入力画像と出力画像(肺領域のみが抽出された画像) の一例である.肺領域抽出画像の定量的評価を行うために,教 師画像との間で各評価を行った結果,平均値で PSNR が 26.653, F 値が 0.902 となった.



図 1: 肺領域抽出モデルの入出力結果 (左:入力画像,右:肺領域の抽出画像)

## 3.2 疾患部領域抽出モデルの学習

疾患部領域抽出モデルの学習の結果を以下に示す.図2はテ

ストデータの入力画像と出力画像(抽出された疾患部領域を赤 で示してある)の2例である.抽出領域と教師画像の間で定量 的評価を行った結果,症例全体の平均値で Accuracy 0.901, Recall 0.481, Precision 0.713, F1 score 0.555 となった.



図 2: 疾患部領域抽出モデルの入出力結果 (左:入力画像,右:抽出された疾患部領域(赤色部分))

## 3.3 放射線肺臓炎画像への適用

新型コロナ肺炎の症例を利用して作成したモデルを放射線 肺臓炎の患者の画像に適用し,肺領域抽出ならびに疾患部領域 抽出を行った結果と,放射線治療専門医によって放射線肺臓炎 の領域を抽出した領域を比較した.8症例のデータの評価結果 (平均値)では,Accuracy0.921,Recall0.432,Precision0.216, F1 score 0.259 となった.この結果,Accuracyは大きくなった ものの,その他の評価値が低下した.この原因は新型コロナ肺 炎によるすりガラス陰影と放射線肺臓炎の症状のパターンの 違いによるものと血管領域などの不要な領域が含まれてしま ったためと考えられる.



図 3: 放射線肺臓炎の2症例への適用(左から正規化処理後の 入力画像,肺領域抽出結果,放射線肺臓炎抽出結果(赤色部 分),医師による放射線肺臓炎の部位(緑色部分))

# 3.4 肺領域内の高線量領域の体積と放射線肺臓炎領域の体積との相関

放射線治療計画において,肺領域内で55Gy以上の線量となる voxel 数と,放射線肺臓炎領域(今回の深層学習で抽出された赤色領域)の voxel 数との間の相関を図4に示す.回帰分析の結果,回帰係数0.424,相関係数0.720,P値0.044,T値2.542 となり,高線量領域と放射線肺臓炎の疾患部の領域には正の相関が認められた.



図 4:55Gy 以上の線量領域の voxel 数と放射線肺臓炎領域の voxel 数との関係

## 4. 結論

本研究では深層学習によって抽出された放射線肺臓炎の領 域と治療計画時の線量分布図から得られた高線量領域には相 関があることが明らかになった.これらの関係を深く議論する ためには,より正確な疾患部抽出モデルが必要であり,また症 例数も必要となるので今後の課題としたい.

## 謝辞

本研究は JSPS 科研費 20K08034 の助成を受けた.

## 利益相反の有無

なし

- 村上佳菜子,橋本典明,木戸尚治,他: CNN, FCN, U-Net を用いたび まん性肺疾患の領域抽出の比較. The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018
- [2] Ranjbarzadeh R, Ghoushchi SJ, Bendechache M, et al.: Lung infection segmentation for COVID-19 pneumonia based on a cascade convolutional network from CT images, Biomed Res Int, doi: 10.1155/2021/5544742, 2021
- [3] Cancer Imaging Archive https: //www.cancerimagingarchive.net/
- [4] Isola P, Zhu JY, Zhou T, et al.: Image-to-Image Translation with Conditional Adversarial Networks, https://arxiv.org/abs/1611.07004, 2017

## 心機能評価のための心臓!"のセマンティック・セグメンテーション手法に関する研究

佐々木 諒介!<sup>"\*</sup>, 黒瀬 優介<sup>!%\*</sup>, 徳永 洋二<sup>!</sup><sup>e</sup>, 伊保 純一<sup>!</sup><sup>e</sup>, 西澤 圭亮<sup>!</sup><sup>e</sup>, 林 祐作<sup>!</sup><sup>e</sup>, 堀江 誠<sup>!</sup><sup>e</sup>, 小山 靖史<sup>!\$\*</sup>, 原田 達也<sup>!%\*</sup>

"東京大学大学院情報理工学系研究科知能機械情報学専攻

!% 東京大学 先端科学技術研究センター

!<sup>\$</sup> 理化学研究所 革新知能統合研究センター

<sup>1&</sup> 医療法人渡辺医学会桜橋渡辺病院 心臓血管センター画像診断・放射線科

!"# \$%**'&**}!"\*# "%**\$&**+%, "&-+.+/)0 \$1.' \$()0 2 )/+1)0 \$1.' \$()3 4%(&%\$6 7\$54\$&+%

"#%%&'()\*)\*+, "'\*, -&%'(+, "/)0"%, -&&13/+, 4\*5\*!, 6&7\$92;:/!&, +(2%'(!4,)); \*<\*!&, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&&13/+, -&:-

 $-\&\%\&:*-*):, \stackrel{!\&}{,} > = !\$?\$:/", 0!^{!\&}, -= !\&\%! + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... + ... +$ 

!" "#\$%\$\$) \*%#+&(,-() .!/01%%20\*.#0.! (#,! 3.01#%2%4**5**7 #\*8.&9\*)%\$\$%:5%

<sup>1%</sup>; .9.(&01!<.#).&!\$%&,8(#0.,! /0\*.#0.!(#,! 3.01#%2%**457** #\*8.&9\*)**5**(\$\$!%:5%

!\$ <.#).&!\$%&,8(#0.,! "#).22\*4.#0.≯&%?.0Ø;"@AB

<sup>!&</sup>C.D(&)'.#)!%\$C\*(4#%9\*0!<(&\*%2%45(!#,!;(,\*%2%45(!:-& (E(91\*!F())(#(E.! G%D)\*(2

**要旨**:心機能診断のために!" 画像を用いて可視化する手法は一般に用いられるようになり,特に心臓の拍動を連続的に撮像できる!" も広く使われるようになった.心機能の評価においては,拍出により送り出される血液量の推定が重要な指標として用いられており,そのために右心室や左心室といった心臓内の各器官の動作を正確に追跡することが重要となる.現状でも推定可能なソフトウェアは存在するが,医師がマニュアルで結果を修正する必要があり,労力を要する.そこで本研究では,撮影した!" 画像から心機能評価を自動で行うために,セマンティック・セグメンテーションによる心臓の各部位の推定結果を用いて,心機能の指標を推定する手法を提案する.提案手法の有効性を評価するために,!" 画像データセットを提案手法に適用して評価を行った.

キーワード: 医用画像処理, 心臓!", セマンティックセグメンテーショ

#### 1. 序論

厚生労働省の統計によると心疾患による国内の死亡率が第 \$ 位であり%2, 画像診断技術による心疾患への治療支援は広く 求められている.心臓の診断のために心エコー画像,!()\*+,-.# "()(/01\*23(!"),41/5-,67%-9(5157-#)1/6/(48:)などの 様々なモダリティで画像を取得できる.特に!"は心臓の構造 把握に優れ,日本では広く普及しており,多くのデータが国内 に存在している.これらの画像を用いて心臓の挙動を正確に追 跡することは診断において極めて重要である.一方で!" 画像 中の心臓の正確な追跡のために各部位をアノテーションする 必要がある.現状でも各部位を追跡するためのソフトウェアは 存在するが,完全な追跡は困難であり医師によるマニュアルで の修正を要することが多い.

本研究では、心疾患の診断支援のために、拍動中の各時系列 における!" 画像から心臓の各部位を抽出し、その構成結果か ら診断に用いる指標を予測する手法について提案する.ここで は特に診断に重要な指標である左心室の体積容量の評価のた め、容量曲線(;(↔)-#+0--)を描画し、心機能評価への有効性 を示す.





## 2. 関連研究

心疾患への診断支援のために心臓を追跡する研究は多くな されている.特に,深層学習の大きな進展により高精度な予測 が可能になると期待されている.代表的な手法として >? @45-,# %'のような!(5=(<+,{(51 #B-+0(#B-,C(0D(!BB)をベースと した手法が広く用いられている%.!BB ベース以外の手法と しては,メッシュ表現によって三次元再構成する手法も提案さ れ,より高い表現力をもつモデル生成についても注目されてい



左) CT 画像(右) 提案手法による予測結果, 暗い, 明るい領域が右心室.

る%G.また,拍動中の心エコー画像のセグメンテーション結果 を用いて,駆出率といった心機能の指標を推定する方式も提案 されている%H.

## 3. 手法

本研究では心臓の各部位のセメンティック・セグメンテーションをする手法として、4(.-<9 E-5-969%」で事前学習した>? @\$-, %」を用いた(図1). 4(.-<9 E-5-969は医用画像における 多種多様なモダリティの画像に対して、多様な非線形変換をし たものから元画像を復元する事前タスクを学習することで、あ らゆるモダリティのタスクに対しても高い性能を有するモデ ルを生成できる.!! 画像は一回の撮影で生成するスライスの 枚数が検査により異なる.そこで入力の解像度は[幅,高さ、深 さ]=[H&\$IH&\$ID\$© 固定し、予測対象となるスライスを深さ方 向に HJKの重複を含んだ上で分割、推定した結果を統合する.

#### 4. 実験

提案手法の有効性を評価するため、心臓の各部位の領域を 推定するように 4(.-<9 E-5-969 を学習した.データセットに は、桜橋渡辺病院で収集した拡張終期・収縮終期合わせて &\$J セット分の学習データ、\$&セット分のテストデータである!" 画像をそれぞれ用いた.!" 画像の部位は背景・左心室・右心 室の>箇所に対してアノテーションされている.評価指標とし ては、正解領域と予測領域との重複を算出する:5-09-7,6(5#(=-0# @56(5 (:(@) と ?67- 係数を用いた.評価した結果、)-15#:(@ は JLMNG?67- 係数は JLMMであった.これは高精度に心臓の 部位を推定できていることを示しており、4(.-<9#E-5-969 は心 臓!" における部位予測に非常に有効であることがわかる(図 \$).さらに部位推定した結果を用いて、左心室の拍動中におけ る容量の変化をプロットした(図>).横軸は!" 画像を撮像し た時の拍動周期中の位相であり.心臓の拍動を捉えていること がわかる.



## 5. 結論

本研究では、4 (.-<9#E-5-969によるセマンティック・セグメ ンテーションを用いて、心臓の部位を正確に追跡でき、その挙 動から心機能の評価に有用であることを示した.

今後は駆出率などの心機能の評価指標との関連を評価する ことで、心機能評価を自動で高精度に推定する手法について検 討する.

#### 謝辞

本研究は, OP"#ムーンショット型研究開発事業 OQ4O4P\$J&& !8RP"# 課題番号 OQ4O!8\$J&HI#OPQP料研費 OQ&MS\$J>FMOQ\$>S&FMM及び東京大学 T-3(5.#U:#研究推進 機構の基礎研究費 VU:: 自体の進化W#D支援を受けたものですL

## 利益相反の有無

なし.

- [!] 厚生労働省"#令和\$年(\$%\$%人口動態統計
- [\$] &'()\*+,-./0+#)1#23456#7 &)1"#3)2:0'0.#;)0<)#=>3?@)1:'40}#@)0121'>0#B:>@# <C2:<)#200>121'>04D);'A23#E@2.)#F>@C?1'0.#20;#F>@C?1): &G<<'1);# E01):=)01'>0DEFFGE#\$%!1"#!J1K#E01):021'>023#F>0B):)0A)+#\$@6(1-): "# M\$IM5\$
- [5] NO79L +L1)BB)0+#) I#3)3G#3)2:0'0. &P2<);#QK>3K)2:1#<).@)0121'>0#'0#M6# A>01:2&0K20A);#A2:;'2A#FR4#F>@C?1):<#'0#P'>3>.S#20;#@);'A'0)+#\$%\$\$+# !M\$"#!%T!J!4
- [M] UV9W+#X20Q)'Y#ZE[LV9+#921K20Y#L\G66]9+#LK2Q0#;))C &3)2:0'0.# 2CC:>2AK#B>:#;':)A1#(%\$)23)#@)<K#:)A>0<1:?A1'>04#D);'A23#'@2.)#2023S<'<+# \$\%\$!+#^M"#!\\$\$\$\$4
- [T] R\VDGL+#L2:'02Y#WE[N]OR+#G0;:)QY#N§9VL]X+#W?SY['.K1 &Q)'.K1# <C21'81)@C>:23#.:2CK<#B>:#<).@)0121'>0#20;#)`)A1'>0#B:2A1'>0#C:);'A1'>0#'0# A2;'2A#?31:2<>?0;4#D);'A23#E@2.)#F>@C?1'0.#20;#F>@C?1):#G<<'<1);# E01):=)01'>0DEFFGE#\$%\$\$"#\$T1K#E01):021'>023#F>0B\$908\$)##LC:'0.):+# \$%\$\$-5a%85J%4
- [I] b\V7+#b>0.Q)'+#)1#234#D>;)3<#.)0)<'<"#W)0):'A#2?1>;';2A1'A#@>;)3<#B>:#5;#
  @);'A23#'@2.)#2023S<'<4#E0D);'A23#E@2.)#F>@C?1'0.#20;#F>@C?1):#
  G<<'<1);#E01):=)01'DEFFGE#\$%!J"#\$\$0;#E01):021'>023#F>0B):)0A)+#\$%!J+#
  LC:'0.):+#\$%!J5aM\$J54

# 乳房超高速造影 MRI 画像における U-Net を用いた腫瘍血管抽出に関する検討

橋本 陽菜<sup>\*1</sup>, 片岡 正子<sup>\*2</sup>, 藤本 晃司<sup>\*2.3</sup>, 飯間 麻美<sup>\*2.4</sup>, 戸井 雅和<sup>\*5</sup> 川瀬 貫互<sup>\*6</sup>, 大橋 茜<sup>\*7,8</sup>, 本田 茉也<sup>\*9</sup>, 中本 裕士<sup>\*2</sup>

\*1 京都大学大学院 医学研究科 人間健康科学系専攻
\*2 同医学研究科 放射線医学講座(画像診断学・核医学)
\*3 同医学研究科 高度医用画像学講座
\*4 同医学部附属病院 先端医療研究開発機構
\*5 東京都立病院機構 がん・感染症センター駒込病院
\*6 天理よろづ相談所病院 放射線部
\*7 ルンド大学トランスレーショナル医学科 放射線画像診断学
\*8 スコーネ大学病院 画像機能医学講座
\*9 関西電力病院 放射線診断科

## Segmentation of Tumor-related Vessels on Ultrafast DCE MRI using U-Net

Hina HASHIMOTO<sup>\*1</sup>, Masako KATAOKA<sup>\*2</sup>, Koji FUJIMOTO<sup>\*2.3</sup>, Mami IIMA<sup>\*2.4</sup> Masakazu TOI<sup>\*5</sup>, Kango KAWASE<sup>\*6</sup>, Akane OHASHI<sup>\*7.8</sup>, Maya HONDA<sup>\*9</sup>, Yuji NAKAMOTO<sup>\*2</sup>

<sup>\*1</sup> Dept. of Human Health Science, Graduate School of Medicine Kyoto University
 <sup>\*2</sup> Dept. of Diagnostic Imaging and Nuclear Medicine, Graduate School of Medicine Kyoto University
 Dept. of Advanced Imaging in Medical Magnetic Resonance, Graduate School of Medicine, Kyoto University
 <sup>\*4</sup> Institute for Advancement of Clinical and Translational Science, Kyoto University Hospital
 <sup>\*5</sup> Tokyo Metropolitan Cancer and Infectious Diseases Center Komagome Hospital
 <sup>\*6</sup> Department of Radiology, Tenri Hospital
 <sup>\*7</sup> Dept. of Translational Medicine, Diagnostic Radiology, Lund University
 <sup>\*8</sup> Dept. of Imaging and Functional Medicine, Skåne University Hospital
 <sup>\*9</sup> Diagnostic Radiology, Kansai Electric Power Hospital

要旨: 腫瘍血管はがん細胞の働きによって新生され、がんの性質を反映する. UF-DCE MRI では腫瘍血管の鮮明な描出が可能になった.しかし、腫瘍血管の構造は不規則で病変によっても異なるため、健常人の血管が対象の自動領域抽出では腫瘍血管特有の構造を抽出できない.本研究では、画像から腫瘍血管の教師データを作り、その特徴を U-Net に学習させることで領域抽出を行った.さらに抽出精度を向上させるため、セミオートによる教師データのクリーニング、非腫瘤性病変を中心としたデータを追加し、モデルの改良等を行った.5分割交差検証の結果、全画像に対する抽出精度は Dice 係数平均値 0.820 を達成した.また推定画像を確認した結果、不明瞭な血管の未検出、皮膚面および腫瘍の誤検出を除いて正確に血管を抽出できた. キーワード: 腫瘍血管、領域抽出、 U-net、UF-DCE MRI、機械学習

## 1. 背景と目的

がん細胞は、血管増殖因子を分泌し腫瘍血管を新生する.[1] 腫瘍血管は栄養分の供給のみならず、がんの浸潤・転移の経路

京都大学大学院医学研究科

〔〒606-8501 京都市左京区吉田近衛町〕

e-mail: hashimoto.hina.67c@st.kyoto-u.ac.jp

としても機能し、がんの悪性度を反映する. [2] Ultrafast Dynamic Contrast-Enhanced MRI (以下, UF-DCE MRI) は圧縮セ ンシングを用いた高速撮影により腫瘍血管の鮮明な描出が可 能であり [3],本技術を用いて MRI 画像上の血管量の多寡を, 腫瘍の悪性度予測や薬物療法に対する反応の指標として利用 できないかと考えた. しかし,手動による血管抽出は煩雑であ る上,作業者によって精度に差が生じる.また,腫瘍血管の構造は不規則で病変毎に異なるため,健常人の血管を対象とした自動領域抽出では腫瘍血管特有の構造を抽出できない.この問題に対して,今回我々は,乳がん患者のUF-DCE MRI 画像から腫瘍血管をラベリングし,これを教師画像として機械学習を行うことで腫瘍血管を抽出する方法を検討した.

## 2. 研究方法

2016年4月~2018年3月に乳がん疑いで MRI 検査を受けた 258 症例より, UF-DCE MRI 画像で病変及び血管の描出が確認 された計 106 症例を対象とした. 撮影装置には 3T-MRI 装置 (Prisma, Siemens), 3D gradient-echo VIBE sequence を使用。両側 乳房を水平断で撮影した。撮影条件は TR/TE=5.0/2.5ms, Flip Angle 15°, FOV 360×360mm, Slice 厚 2.5 mm. 3.7 秒間隔で連 続撮影した計 20 相の UF-DCE MRI 画像から水平断 MIP 画像 を作成。血管描出後の7相目以降の画像に対し,腫瘍を中心に 128×128pixel (12×12cm)のトリミングを行った. トリミング画 像に対し手動で血管抽出を行い、これを教師画像として U-Net ベースの領域抽出モデルを学習させた.学習済みモデルが出力 した推定画像に対し、Dice 係数・正確度・感度・特異度による 定量的評価(5分割交差検証)と, MIP 画像に推定画像を重ねた 視覚的評価を行った.初期検討後,推定画像を読影者が修正し た教師画像への変更, 非腫瘤性病変の画像データ追加, 画像拡 張(水平反転+明るさ変更[0.5-1.0]), Dropout の追加を行った.

#### 3. 結果

定量的評価の結果を以下に示す. Dice 係数 は セミオートに よる教師画像を用い Dropout を行って学習させた場合(E)が最 も高かった. またセミオート教師画像の使用, データの増量, 画像拡張, Dropout の追加によって更に Dice 係数が向上した.

	Dice 係数	正確度	感度	特異度
А	0.667	0.979	0.653	0.990
В	0.801	0.989	0.747	0.996
С	0.809	0.989	0.768	0.996
D	0.813	0.989	0.808	0.995
E	0.820	0.990	0.785	0.996

表1:教師画像作成手法、学習手法および症例数と抽出精度 A=マニュアル教師画像79症例を使用 B=セミオート教師画像 79 症例を使用
 C=セミオート教師画像 106 症例を使用
 D=セミオート教師画像 106 症例を使用、拡張画像を追加
 E=セミオート教師画像 106 症例を使用、Dropout 層を追加

視覚的評価では、領域抽出の成功・失敗例ともに確認された. 代表例を以下の図に示す.抽出に失敗した画像では、アーチフ ァクト・胸壁・腫瘍などの誤検出(矢印部)がみられた.



図 1:腫瘍血管抽出の成功例 (a,b) と失敗例 (c,d). UF-DCE MRI の MIP 画像(a,c)と血管の推定画像(赤)との融合画像(b,d)

#### 4. 考察

定量的評価において、教師画像の修正による精度向上は手動 抽出による誤差の排除の効果であり、データの追加、画像拡張、 Dropout による精度向上は過学習抑制された効果だと考えられ る. また視覚的評価における腫瘍の一部や皮膚面の誤検出は、 これらが MIP 画像上の血管に類似すること、不明瞭な血管の 未検出は、血管と背景の低コントラストが原因と考えられる. 先行研究との比較において U-Net による眼底血管の抽出では Dice 0.825 が報告されており[4]、本研究から腫瘍血管に対して も同程度の抽出精度を達成することが判明した.

## 5. 今後の方針

今後は、抽出精度向上後に、腫瘍血管の定量値を用いた悪性度 予測を行う.抽出精度向上には、コントラストの強調、モデル 及び損失関数の変更等を行い、独立したテストデータでの検証 を検討している.+分な抽出精度が得られれば、領域抽出した 画像から腫瘍血管を定量化し、乳がんの悪性度を予測する新 たな画像バイオマーカーとしての活用を目指す.

## 利益相反 なし

- [1] Weidner N. Angiogenesis in breast cancer. Cancer Treat Res. 1996;83:265-301.
- [2] Ellis LM, Fidler IJ. Angiogenesis and breast cancer metastasis. Lancet. 1995 Aug 12;346(8972):388-90.
- [3] 4) Onishi N, Kataoka M, Kanao S et al: Ultrafast dynamic contrast-enhanced mri of the breast using compressed sensing: breast cancer diagnosis based on separate visualization of breast arteries and veins. J Magn Reson Imaging. 2018 Jan;47(1):97-104.
- [4] Ding J, Zhang Z, Tang J S et al: Multichannel Deep Neural Network for Retina Vessel Segmentation via a Fusion Mechanism. Front Bioeng Biotechnol. 2021 Aug 19;9:697915.

## 血管強調画像を用いた腹部 CT 像からの多臓器領域抽出

大野 真奈<sup>\*1</sup>, 申 忱<sup>\*1</sup>, Holger R. Roth<sup>\*2</sup>, 小田 昌宏<sup>\*3,1</sup>, 林 雄一郎<sup>\*1</sup>,

三澤 一成\*4, 森 健策\*1.5

\*1 名古屋大学大学院情報学研究科

\*2 NVIDIA Corporation

\*3 名古屋大学情報連携推進本部情報戦略室

\*4 愛知県がんセンター

\*5 国立情報学研究所医療ビッグデータ研究センター

## Multi-Organ Segmentation from Abdominal CT Volumes Using Blood Vessel Enhanced Images

Mana OHNO<sup>\*1</sup>, Chen SHEN<sup>\*1</sup>, Holger R. Roth<sup>\*2</sup>, Masahiro ODA<sup>\*3,1</sup>, Yuichiro HAYASHI<sup>\*1</sup>,

Kazunari MISAWA<sup>\*4</sup>, Kensaku MORI<sup>\*1,5</sup>

<sup>\*1</sup> Graduate School of Informatics, Nagoya University

\*2 NVIDIA Corporation

<sup>\*3</sup> Information Strategy Office, Information and Communications, Nagoya University

\*4 Aichi Cancer Center

<sup>\*5</sup> Research Center for Medical Bigdata, National Institute of Informatics

要旨:本稿では、血管強調画像を用いた Fully Convolutional Network (FCN) による3次元腹部 CT 像からの多臓器領域抽出手法に ついて述べる.近年、コンピュータによる診断・手術支援システムに関する研究が多く進められている.多臓器領域抽出はこれら のシステムの開発のための重要な要素技術であり、高精度な臓器領域抽出手法の開発が必要とされている.従来の多臓器領域抽出 手法では、腎臓や肝臓、脾臓などの形状が単純な臓器については高精度の抽出が可能である一方、血管や膵臓などの形状が複雑な 臓器の抽出が困難だった.提案手法では特に血管領域の抽出に着目し、CT 像に管状構造を強調するフィルタを適用した血管強調画 像を FCN の学習に利用し、多臓器領域抽出を行った.284 症例の CT 像を用いて実験した結果、全臓器の平均 Dice は 87.89%であ った.

キーワード:セグメンテーション,機械学習,臓器領域抽出

## 1. はじめに

腹部 CT 像からの臓器領域抽出は,診断・手術を支援するシ ステムの開発のための重要な要素技術である.従来の臓器領域 抽出[1]においては,肝臓,脾臓,腎臓などの形状が単純な臓器 は抽出精度が高い一方,血管や膵臓などの形状が複雑な臓器は 抽出が難しい.そこで,本稿では特に血管領域の抽出に着目し, CT 像に管状構造を強調するフィルタ[2]を適用して生成した血 管強調画像を Fully Convolutional Network (FCN)の学習に導入 した.本実験で利用した CT 像は 284 症例であり,動脈,門脈, 肝臓,脾臓,胃,胆のう,膵臓,左右の腎臓の全9種類の臓器・ 血管を抽出対象とする.

## 2. 手法

提案手法は CT 像と血管強調画像を用いて FCN の学習を行う. 血管強調画像は CT 像に管状構造を強調するフィルタを適用することで生成される.まず CT 像に適切なスケールでガウシアンフィルタを適用する.次にフィルタ適用後の CT 像において,局所領域内の画素値の偏微分よりヘシアン行列を求める.

ヘシアンの固有値を用いて局所的な方位パターンを識別し,管 状構造を強調する.

以上の方法で生成される血管強調画像を用いて,3DU-Net[3] と Attention U-Net[4]の2つのFCNを学習させ、それぞれを用 いて多臓器領域抽出を行う.3DU-Netを用いた提案手法は、 血管強調画像をCT像と連結し、2チャンネルの入力画像とし てエンコーダに渡す.一方でAttention U-Netを用いた提案手法 は、血管強調画像をAttention Gateに入力し、その出力をデコ ーダの2か所に接続する.Attention U-Netを用いた提案手法の 概要を図1に示す.

#### 3. 実験及び結果

本実験では学習用に 228 症例,テスト用に 56 症例の全 284 症例の腹部 CT 像を用いて多臓器領域抽出を行った.実験で用 いた CT 像のスライスあたりの画像サイズは 512 × 512 pixel, スライス数は 311-1149 スライスである. また,すべての CT 像とラベルを 1 × 1 × 1 mm<sup>3</sup>の解像度にリサンプリングした. また,モデルへの画像の入力サイズは 96 × 96 × 96 voxles とし



図1 Attention U-Net を用いた提案手法の概要図. 血管 強調画像はアテンションゲートを通過し, デコーダの2 カ所に接続される.

損失関数は Dice CE Loss を用いている. 抽出結果の評価には Dice と、ラベルのセンターラインの比較を行う clDice[5]を利 用した. Dice による抽出精度の評価結果を表1に, clDice によ る評価結果を表2に示す. また,抽出結果の例を図2に示す.

## 4. 考察

表1,2より,動脈は Dice と clDice のどちらについても,血 管強調画像を用いない 3D U-Net で最も高い結果となった.こ れは,血管強調画像において細い血管があまり強調されなかっ たため,提案手法で動脈の末端の細い部分が抽出されなかった ことが影響していると考えられる.また,どの手法も Dice の 値と比較して clDice の値が 20%以上も低い結果となっており, 腹大動脈のような体積が大きい部分と比較して,体積の小さい 末端部分の精度が低いことがわかる.

一方で門脈については、Dice、clDiceのどちらも血管強調画 像を用いた手法の方が高い結果となった. これは、血管強調 画像を用いない 3D U-Net による結果では動脈の一部が門脈と して誤抽出される場合が見られたが、血管強調画像を用いた手 法ではそのような誤抽出が少なかったことが影響していると 考えられる.

## 5. まとめ

本稿では、血管強調画像を 3D U-Net と Attention U-Net の 2 つの FCN に導入し、多臓器領域抽出を行った. その結果、門 脈においては血管強調画像による精度の改善が見られた. 今後 の課題として、ガウシアンフィルタのスケールパラメータの調 整や、血管強調画像に含まれる血管以外の構造の抑制などを行 い、末端の血管の抽出を目指す.

#### 謝辞

本研究は科研費 21K19898, JST CREST JPMJCR20D5, ムー ンショット型研究開発事業 JPMJMS2033 の支援を受けたもの である.

#### 利益相反の有無

なし

- [1] 大野真奈, 申忱, Holger R. Roth 他 "境界情報を考慮する損失関数を 用いた FCN による腹部 CT 像からの臓器領域抽出に関する研究," 第 41 回日本医用画像工学会大会予稿集, 106-107, 2022
- [2] Frangi A, Niessen W, Vincken K et al: Multiscale vessel enhancement filtering. MICCAI: vol. 1496, 1998
- [3] Çiçek Ö, Abdulkadir A, Lienkamp S et al: 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation.MICCAI: 424-432, 2016
- [4] Oktay O, Schlemper J, Folgoc L et al: Attention U-Net: Learning Where to Look for the Pancreas. MIDL: 2018
- [5] Shit S, Paetzold J C, Sekuboyina A et al: clDice a Novel Topology-Preserving Loss Function for Tubular Structure Segmentation. CVPR: 16560-16569, 2021

表1 Diceによる評価.動脈は血管強調画像を用いない
 3D U-Net, 門脈は血管強調画像を用いる Attention U-Net
 でそれぞれ最も高い精度となった

		い相反こなりに	
	Attention U-Net +血管強調画像	3D U-Net +血管強調画像	3D U-Net
動脈	86.25%	86.55%	86.59%
門脈	75.12%	74.23%	73.36%
肝臓	96.61%	96.38%	96.31%
脾臓	95.85%	95.77%	95.36%
胃	84.87%	85.18%	83.53%
胆のう	82.49%	82.06%	82.92%
膵臓	77.76%	76.73%	77.74%
右腎臓	96.17%	96.31%	96.24%
左腎臓	95.91%	95.91%	95.87%
平均	87.89%	87.68%	87.55%

**表 2** ClDice による評価. 動脈は血管強調画像を用いない 3D U-Net で, 門脈は血管強調画像を用いる 3D U-Net でそれぞれ最も高い精度となった.

	Attention U-Net 十血管強調画像	3D U-Net +血管強調画像	3D U-Net
動脈	61.83%	62.71%	63.13%
門脈	64.09%	65.25%	63.43%



## 多時相造影 CT 画像データベースの腎臓・腎腫瘍の抽出

西岡 大<sup>\*1</sup>, 越野 魁都<sup>\*1</sup>, 河田 佳樹<sup>\*2</sup>, 小針 悠希<sup>\*3</sup>, 池田 篤史<sup>\*4</sup>, 仁木 登<sup>\*5</sup> <sup>\*1</sup> 徳島大学大学院創成科学研究科理工学専攻 <sup>\*2</sup> 徳島大学ポスト LED フォトニクス研究所 <sup>\*3</sup> 東京女子医科大学 <sup>\*4</sup> 筑波大学医学医療系 <sup>\*5</sup> 株式会社医用科学研究所

Extraction of kidney and renal tumors in a multi-temporal contrast-enhanced CT image database Dai NISHIOKA<sup>\*1</sup>, Kaito KOSHINO<sup>\*1</sup>, Yoshiki KAWATA<sup>\*2</sup>, Yuki KOBARI<sup>\*3</sup>, Atsushi IKEDA<sup>\*4</sup>, Noboru NIKI<sup>\*5</sup>

\*1 Program of Science and Technology, Graduate School of Creative Science, Tokushima University

<sup>\*2</sup> Institute of Post-LED Photonics, Tokushima University <sup>\*3</sup> Tokyo Women's Medical University

<sup>\*4</sup> Institute of Medicine, University of Tsukuba <sup>\*5</sup> Institute of Medical Science, Inc.

要旨:多時相3次元造影 CT 画像から腎臓・腎腫瘍を精密に解析して悪性・良性腫瘍の高精度な鑑別法を開発し、このために、腎 臓・腎腫瘍の 200 症例の多時相造影 CT 画像データベースを構築する.この多時相腹部造影 CT 画像データベースを用いて腎臓と腎 腫瘍5種類(淡明細胞型腎細胞がん、乳頭状腎細胞がん、嫌色素性腎細胞がん、血管筋脂肪腫、オンコサイトーマ)を 3D U-Net を 用いて高速・高精度に抽出し動脈相・門脈相・平衡相画像をレジストレーション・クラスタリングして関連付ける. 小径の腎腫 瘍の循環動態を解析して高精度な小径の腎腫瘍の鑑別法を示す.

キーワード: 腎臓・腎腫瘍, 多時相造影 CT 画像データベース, 学習データ, U-Net, レジストレーション

## 1. 背景・目的

腎癌患者の年間死亡者数は1万人を超え,年々増加傾向にあ る.腫瘍径が小さい場合は良性腫瘍の頻度が高く,腎癌手術後 に良性腫瘍であった患者は10%であると報告されている.マル チスライス CT 装置の発展により3次元画像による高精度な診 断が期待されている.本研究では,腎臓・腎腫瘍における CT 画像の造影効果を明らかにして診断能の向上を図る.このため に多時相造影マルチスライス CT 画像データベースを用いて腎 臓・腎腫瘍の3次元学習データを作成・利用して,腎臓・腎腫 瘍の自動抽出を高精度にする.



## 2. CT 画像の撮影条件

東京女子医科大学病院から提供を受けた腎腫瘍の3時相造影 マルチスライス CT 画像を CT 画像データベースに用いた.こ れらの画像はキャノンメディカルシステムズ社製 Aquilion ONE と Aquilion で撮影された造影マルチスライス CT 画像で ある.撮影条件は管電圧 120kV, 管電流 60~500mA, 再構成 間隔 1.0mm であり, 腎臓付近の腹部を撮影している.造影時 間は 30 秒~300 秒である. 本研究では淡明細胞型腎細胞がん,乳頭状腎細胞がん, 嫌色素性腎細胞がん,血管筋脂肪腫,オンコサイトーマ の5症例を対象に研究を行った.本手法は(1)3時相造影 CT 画像 150症例から2人の観測者によるマニュアル抽 出,2DU-Netを用いた抽出で腎臓,腎腫瘍を抽出しデー タベースを作成(2)抽出したデータベースから腎臓+腎 腫瘍の3時相造影 CT 画像 100症例を2D U-Netを用い て学習データを作成(3)学習データの抽出精度を,テスト データ 10症例を用いた Dice 係数,感度,適合率の平均 値から確かめる.

(1) 淡明細胞型腎細胞がん症例 28 症例,乳頭状腎細胞がん 症例 36 症例,嫌色素性腎細胞がん症例 31 症例,血管筋 脂肪腫症例 26 症例,オンコサイトーマ症例 29 症例から 抽出を行い,データベースを作成した.抽出した2 症例 の3次元 CT 表示画像を図1 に示す.

図1 腎臓・腎腫瘍の3次元CT表示画像

- (2) U-Net は入力された画像に対しセグメンテーションを行う CNN アーキテクチャである.本研究に作成・使用する学習データは腎臓+腎腫瘍,腎臓ともに3時相の造影 CT 画像を教師データ 95 症例,検証データ 5 症例,学習 回数を 100 回行って作成した.
- (3) テストデータは淡明細胞型腎細胞がん症例2症例,乳頭 状腎細胞がん症例2症例,嫌色素性腎細胞がん症例2症

3. 手法

例、血管筋脂肪腫症例2症例、オンコサイトーマ症例2 症例から作成した. Dice 係数は集合の大きさの平均に対 する共通集合の割合を表す.感度は正解データに対する 予測データの割合を表し、適合率は予測データに対する 正解データの割合を表す.

## 3. 結果

2D U-Net を用いて造影 CT 画像データベースから学習を繰 り返し行い学習データの作成を行った. 作成した学習データ を用いてテストデータ 10 症例の腎臓+腎腫瘍の自動抽出を行 った. 図2に各学習データの抽出結果を示す.



図2 腎臓+腎腫瘍の学習データを用いた抽出結果 学習データの抽出精度を、テストデータを用いて Dice 係数を 算出した. 学習データの Dice 係数,感度,適合率の平均値を 下の表に示す.

表 Dice 係数,感度,適合率の平均値 評価指標:Dice **動脈相 門脈相 平均値** 0.967 0.975

平衡相

0.979

河海北海、资本支		動脈相	門脈相	平衡相
許11回招標:12回百平	平均値	0.965	0.982	0.976
(テストデータ 10症例)		0.000		
(テストデータ 10症例)		0.000		
(テストデータ 10症例)		動脈相	門脈相	平衡相

このことから、今回作成した学習データの抽出精度は高いといえる.

## 4. まとめ

多時相造影 CT 画像より腎臓・腎腫瘍をマニュアル抽出し多 時相造影 CT 画像データベースを作成した.作成した CT 画像 データベースから 2D U-Net を用いて学習データを作成し、学 習データを用いて腎臓+腎腫瘍、腎臓の自動抽出を行い、学習 データの抽出精度を確認した.しかし、抽出した腎臓+腎腫瘍、 腎臓には誤差が残っているので誤差を手動で修正し、修正した 症例は造影 CT 画像データベースに用いて症例数を増やす.そ して新たなデータベースから質の高い学習データを作成し腎 臓・腎腫瘍の自動抽出の速度と精度をさらに高める.

#### 利益相反の有無

## なし

- [1] 日本腎臓学会 腎不全 治療選択とその実際(2020年度版)
- [2] 日本泌尿器科学会:腎癌取扱い規約,第4版,金原出版,2011
- [3] 金子丑之助:日本人体解剖学, 增訂第9版, 第三巻, 南山堂, 1965
- [4] 藤田恒太郎:腹部·骨盤部·背部,金原出版,1960
- [5] F.H.マティーニ, M.J.ティモンズ, M.P.マッキンリ:カラー人体解剖 学:構造と機能:ミクロからマクロまで,西村書店, 2003
- [6] 坂井建雄,橋本尚詞:ぜんぶわかる人体解剖学,成美堂出版,2010
- [7] Aoife McErlean, David M. Panicek, Emily C. Zabor, Chaya S. Moskowitz, Richard Bitar, Robert.J. Motzer, Hedvig Hricak, MichelleS.Ginsberg: Intra- and Interobserver Variability in CT Measurements in Oncology, Radiology2007, Volume: 242Issue: 3pp. 769-776
- [8] Olaf Ronneberger: U-Net: Convolutional Networks for Biomedical Image Segmentation, MICCA2015
- [9] 西平健斗,西岡大,鈴木秀宣,河田佳樹,池田篤史,小針悠希,仁木 登:3時相腹部造影 CT 画像を用いた小径腎腫瘍解析,電子情報通信 学会技術研究報告医用画像 vol.122, no.265, MI2022-71, pp.43-44, 2022.11
- [10] 西岡大,西平健斗,越野魁都,鈴木秀宣,河田佳樹,小針悠希,池田 篤史,仁木登:多時相造影 CT 画像データベースの腎臓・腎腫瘍の抽 出,電子情報通信学会技術研究報告医用画像 vol.122, no.417, MI2022-125, pp.210-211, 2023.3

# Stable Diffusion による

# 乳がん腫瘤の人工症例画像生成と良悪性鑑別への応用

# 安倍 和弥\*1 武尾 英哉\*1 縄野 繁\*2

## 要旨

現在, 医療の様々な分野において AI 技術を用いた画像支援診断 (CAD: Computer Aided Diagnosis)の研究・ 開発が行われている. AI による CAD 開発における症例画像の不足を補うことを目的に,人工的に症例画 像を作成する取り組みが以前から行われている.過去に筆者らも,人工症例画像を含む学習データを用い て設計した判別器による検証から,CAD への有用性の一例を示した.しかし,従来の人工症例画像は病変 の存在しない画像に腫瘤等の病変を埋め込むことにより作成を行うもので,本質的には症例数が増加して いるとはいいがたい.

本研究では、Stable Diffusion 技術を用いた画像生成 AI により、乳がん腫瘤の人工症例画像の生成と、生成 した画像を用いて機械学習を行い、AI による人工症例画像の CAD 適応時の有効性検証を行った. 腫瘤画 像を良性・悪性に分けて各 5000 例程度の画像生成を行い、良悪性鑑別 CAD へと適応した結果、実症例の みで構築した CAD で 83.7%であった鑑別性能が、人工症例画像のみで 86.1%、組み合わせることにより 89.2%となり、AI による人工症例画像作成が鑑別性能向上に寄与する結果が確認できた.

キーワード:人工症例画像, Stable Diffusion, 乳がん腫瘤, 良悪性鑑別, CAD

#### 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[1]. 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

\*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: <u>abex0930@ele.kanagawa-it.ac.jp</u>
\*2 新松戸中央総合病院

Network)は積極的に用いられるようになった [2].

CAD システムの開発においては、サンプル データの不足が長い間,問題とされてきた[3]. システムの有効性を示すためには多くの臨床 画像を使う必要性があるが、プライバシーの 配慮などにより症例画像の入手が困難になっ ている. その対策として, 既存のサンプルデ ータから切り出した病変を健常者の画像に埋 め込みを行い、病変の存在する CT 画像を人 工的に作成する研究が行われている[4]. この 研究は、実症例と全く見分けがつかない人工 症例画像の作成方法を確立し,大きさ,形, コントラストを変更しながら、無数に人工腫 瘍を含む模擬的な症例画像を生成することに よって、CAD システムの開発におけるサンプ ルデータ数を補完することを目的としている. 他にもサンプル不足を補う研究として重本 らの結節および血管のモデルを作り、学習デ

ータとして利用する手法[5]や,他分野ではあ るものの村瀬らの生成型学習により学習パタ ーンを既存データから補完する手法[6]など が提案されており,サンプル不足を補う手法 として一定の評価を得ている.

また,人工症例画像の作成は過去 JAMIT CAD コンテスト 2013[4]にて初めて行われた. その際の主な手法としてはαブレンディング [7]が挙げられる.これはかなり完成度の高い ものであるが腫瘍境界部で平滑化処理をする ため,そこで違和感が発生してしまうことが 多かった.もう一つの手法としてはポアソン ブレンディング[8][9]がある.これも完成度の 高いものであるが,ベースとなる画像の輝度 値の影響を受けて形や明るさに問題が発生す ることがあった.

このような問題に対して,畠山ら[10]は, 腫瘍境界付近の領域でのみポアソン方程式で 計算を行うことで,平滑化処理をせずに滑ら かな合成ができ,さらにベース画像からの影 響を受けずに明るさや大きさを指定できる手 法が開発され,この手法にて CAD コンテス ト 2014 にて優勝を果たしている.この成果よ り筆者らは,人工症例画像を含む学習データ を用いて設計した判別器による検証から,肝 腫瘍 CAD への有用性の一例を示した[11].

しかしながら,これらの研究はあくまでも 既存の症例を埋め込む形をとっており,根本 的な意味においては,症例が増加していると は言い難いものである.あまりにも大きく形 状や大きさ,コントラストを変更してしまう と明らかに人工的なアーチファクトが出てし まい易く,それを控えるとマイナーチェンジ の域を出ず,CAD 学習における人工症例画像 の検出・鑑別性能向上への寄与率が低い.

本研究では、上記問題に対し、Stable Diffusion 技術を用いた画像生成 AI により、 埋め込むのではなく一から人工症例画像を生 成し、それを用いて鑑別 CAD の CNN を学習 させる手法を提案する.これにより、埋め込 み式とは異なり、AI の学習により症例画像に 類似しつつも全く新しい人工症例画像の作成 が行え、それを用いて鑑別 CAD を学習させ ることにより、単純なマイナーチェンジによ る症例増加よりも多種多様な学習が行えるた め、鑑別性能の向上が期待できる.

Stable Diffusion は, Rombach らの論文[12] を基に作成された画像生成 AI であり、入力 テキストに沿った画像を作成するモデルであ る. 10 億個に近いパラメータを持ち,約 20 億枚の画像とテキストのペアを用いて学習さ れている.これにより,入力テキストを工夫 することによって,様々な画像を生成できる. また, Stable Diffusion に追加学習を行う手法 の一例として, Ruiz らが DreamBooth という 手法を提案している[13]. これは、入力する 画像の視覚的特徴を維持しながら,異なる文 脈でも同様の画像を出力できるように表現の 合成を行う Subject-driven generation という技 法が主となる. 生成時の文面に沿って異なる シチュエーションでも画像を崩さずに生成で きるようになる.

本研究では、上記 Stable Diffusion 技術と Dreambooth 技術を利用し、乳がん腫瘤の症例 データを学習させて、大量の人工症例画像を 生成、それを基に鑑別 CAD の学習と評価を 行い、画像生成 AI による人工症例画像の生 成とその有効性検証を行う.

本論文のポイントを以下に示す.

- 画像生成AIを用いた人工症例画像の作成.
- ② 実症例のみ、人工症例画像のみ、実症例 と人工症例画像の混合でデータセットを 作成し、各データセットで鑑別 CAD を学 習させ、鑑別性能の比較検討。

本論では、2章で画像生成 AI を用いた乳がん 腫瘤の人工症例画像の作成と、その人工症例画 像を用いた乳がん腫瘤の良悪性鑑別 CAD の学 習について、3章ではその鑑別 CAD の性能評価 の結果を示す.最後に4章、5章にて本研究の 考察・まとめについて述べる.
#### 2. 手法

#### 2.1 人工症例画像の準備

初めに本論にて実験に用いたマンモグラフィ 画像について表1に示す.

画像サイズは一般的なマンモグラフィ画像サ イズであるが、PC スペック等の問題から Stable Diffusion に画像を学習させる際に、表の切り抜 きサイズに沿って、腫瘤を中心として切り出し を行っている. CAD 学習画像サイズについては、 後述.

表1 乳がん腫瘤画像データセット

画像サイズ	2370×1770[pixel]
切り抜きサイズ	512×512[pixel]
CAD 学習画像サイズ	448×448[pixel]
撮影施設数	14[病院]
症例数(良性/悪性)	444/846[個]

#### 2.2 人工症例画像を用いた鑑別 CAD 作成の流れ

本研究での、人工症例画像作成とそれを用いた鑑別 CAD の作成・評価の流れを図1に示す.



図1 人工症例画像を用いた鑑別 CAD 作成の流れ

#### 2.3 人工症例画像の生成

本論では、Stable Diffusion[12]という画像生 成 AI を用いて、人工症例画像の生成を行う. 追加学習は DreamBooth[13]を応用し、良性・ 悪性を個別に学習させ、それぞれ Benign・ Malignant というラベルを付けた.このラベル (prompt)が追加学習を行った画像群を AI が認 識するテキストとなっており、これらと他の 単語を組み合わせることで、様々な人工症例 画像を作成できる.

今回使用した学習済みモデルは 「stable-diffusion-v1-4」,他の学習パラメータ として,エポック数は300,バッチサイズは2, 初期学習率は5×10<sup>-6</sup>,学習及び生成画像サイ ズは512×512pixelとなっている.

生成した画像は,さらに448×448 へと切り抜きを行う.これは次の鑑別 CAD の入力サイズとの兼ね合いもあるが,やはり中央部の腫瘤に着目して画像生成を行うため,生成した画像の辺縁にアーチファクトが出てしまう例が見られたための措置でもある.

#### 2.4 良悪性鑑別 CAD の学習と評価

良悪性鑑別 CAD は, CNN である VGG19[14]を用いた. パラメータとしては, 学習データとバリデーションデータの割合を ランダムで 8:2 とし, エポック数は 25, バッ チサイズは 32, 初期学習率は 3×10<sup>4</sup>, 学習 及び画像サイズは 448×448pixel となってい る.

学習では、実症例のみで学習するにあたっ ては、良性の症例枚数に合わせ、学習 300 枚、 評価 144 枚として無作為に5 度抽出し、各デ ータセットにつき N 数5 で学習と評価を行っ た.この際の評価データは以降の人工症例画 像を用いる場合においても共通とした.

人工症例画像のみの場合においては,生成 した人工症例画像から取捨選択を行った結果, 5280枚で学習を行った.実症例時と枚数を統 ーしていない点については,多量の人工症例 画像を生成できる点が利点として挙げられて いるため,意図的に少ない枚数で学習する必 要はないと考えられるためである.こちらも N数5で学習を行い,評価データは先にも述 べたが,実症例時のものと統一している.

最後に、実症例と人工症例を混合したデー タセットで学習を行った.実症例の5種のデ ータセットに一様に人工症例を追加した、5 種類の混合データセットを作成、N数5で学 習を行い、評価データも実症例時のものと同 ーである. 3. 実験

3.1 画像生成

実症例と生成した人工症例画像の例を図 2 に示す.



実症例







 実症例
 人工症例

 (b) 悪性

図2 実症例画像と人工症例画像の比較

画像生成は1枚当たり約5秒,今回は良悪 性各2万枚を指定して生成を行ったため,お よそ3日弱で良悪性の画像生成が完了した. ただ,すべての画像が完璧に人工症例画像と して使えるものではなく,また乱数次第で生 成失敗することもあるため,実運用に耐えう る画像はおよそ5000枚という結果であった.

#### 3.2 良悪性鑑別 CAD の評価

本研究で作成した鑑別 CAD の評価結果を 表2に示す.また,学習データごとの評価結 果をまとめたものを図3に示す.

表2では,各評価データを評価1~5として 表記し,結果の部分にはN数5における「最 良値/平均値」として記載する.最下段は全 体での最良値である.

#### 表2 各データセットでの評価結果の比較

	実症例 のみ	人 工 症 例 の み	混合
評価1	83.7 / 81.8	85.1 / 82.9	86.1 / 85.2
評価 2	81.9 / 79.4	82.3 / 80.8	84.0 / 82.8
評価 3	78.8 / 77.0	83.0 / 81.9	88.2 / 85.0
評価 4	83.3 / 82.0	86.1 / 84.7	89.2 / 88.3
評価 5	81.6 / 78.2	82.6 / 81.9	84.7 / 84.0
最良値	83.7	86.1	89.2



図3 各データセットの強化結果の比較

表2より、実症例のみと人工症例のみを比較した結果においても鑑別性能の向上が見られる.また、図3も併せてみると、混合したものにおいては、最良値だけでなく平均で見た場合においても抜きんでて性能が向上しているのが確認できる.また、実症例が少数である点によるものでもあるが、実症例のみのデータでは、例えば評価3のデータなどで学習データとの差異の大きさから鑑別性能が低下するなどの問題が見られるのに対して、すべての評価データセットにおいて一様に高精度で鑑別が行えているのが確認できる.

## 4. 考察

3章の表2より、人工症例画像生成による 学習データ数の増加が、腫瘤の良悪性鑑別精 度の向上に寄与していることが確認できる. また、実症例と組み合わせて CAD を作成す ることにより、5%近い鑑別性能の向上が確認 できた.この結果からも画像生成 AI による 人工症例画像生成の有効性が確認できる.ま た、今回は症例数が総数でも良性444枚、悪 性846枚と少ない中でも、従来の埋め込み式 とは異なり、バリエーションにとんだ人工症 例画像が作成できた.

ただ,人工症例画像を生成する際に,約3 割は生成失敗,さらに残りの半数は目視でも 画像に違和感を覚えるものであるなど,画像 生成の精度にはまだ改善の余地があると考え られる.失敗画像の例を図4に示す.



#### 図4 生成失敗画像の例

図4左は、一部写っていたアーチファクト が過剰に発生して、あたかも石灰化のように なってしまっている.石灰化は学習させてい ないため、当然ながら生成ミスである.また 図4右は体外部分がなぜか上下両方に発生し た失敗例である.これ以外にも根本的に腫瘤 に見えないものなども発生するため、指定数 から実運用に耐えうるものが生成できる割合 は3割弱といったところである.これらは学 習症例パターンの増加や切り抜かずに生成を 行えるようにするなどの対策が考えられる.

ただ,ビックデータが構築できる環境下に おいて同様の結果が得られるかは不明である. 本研究は,症例が入手困難なデータに対して 人工症例画像を作成してデータの水増しを測 りながら,精度を向上させることが目的であ る.そのため,少数の実症例と多数の人工症 例といった形で検討を行った.ただ,多数の 症例で高精度を得られる環境下で,人工症例 を扱う有効性は未知数である.ただ,本研究 においても混合させることで最良の結果が得 られたことに変わりはない.今後は,医療の ビックデータで構築した CAD に人工症例を 加えて学習した場合の精度の検証を行う必要 がある.

#### 5. まとめ

本研究では、画像生成 AI の一種である Stable Diffusion を用いて、乳がん腫瘤の人工 症例画像の生成を行い、それを基に良悪性鑑 別 CAD を作成、AI による人工症例画像生成 の CAD 性能向上への有効性検証を行った. その結果、実症例のみで構築した CAD で 83.7%であった鑑別性能が、人工症例画像の みで 86.1%、組み合わせることにより 89.2% となり、AI による人工症例画像作成が鑑別性 能向上に寄与する結果が確認できた.

#### 謝辞

本研究遂行に先立ち貴重なご助言を賜りま した武尾英哉教授(2023年4月逝去)に心より感 謝の意を表します.

#### 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, 全ての患者の初診時に撮影画像の研究利用を 含めた「包括的合意」にサインを受け,また 各病院にて稟議を通したうえで提供を受けた ものを使用している.

#### 利益相反の有無

なし

## 文 献

- [1] 土井邦雄:医用画像とコンピュータ支援診断 ~現状と将来の可能性~.映像 情報メディア学会誌,65(4),pp.427-431, 2011
- [2] 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
- [3] 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, 2004
- [4] 北坂孝幸:第5回 JAMIT CAD コンテ スト結果報告,JAMIT News Letter No.16, 2014
- [5] 重本加奈恵, 滝沢穂高, 山本眞司:3 次 元結節・血管モデルとテンプレートマッ チングを用いた胸部 X 線 CT 画像からの 結節陰影の高速認識, Med Imag Tech 21(2), 147-156, 2003
- [6] 村瀬洋:画像認識のための生成型学習, 情報処理学会論文誌, Vol.46, No.SIG
   15(CVIM 12), pp35-42, 2005
- [7] Perez, P., Gangnet, M. and Blake, A.:Poisson Image Editing, Proc.SIGGRAPH'03, pp.313-318,2003
- [8] Thomas Porter, Tom Duff : Compositing digital images. ACM SIG-GRAPH Computer Graphics, Vol.18, pp.253-259, 1984
- [9] 宮岡伸一郎:画像の勾配空間フィルタ リング,情報処理学会論文誌, Vol. 52, No. 2, pp.901–909, 2011
- [10] 畠山拓也,武尾英哉,高取祐介:3次 元腹部 CT 像への肝腫瘍の埋め込み,信学 技報,vol.114,No.482,MI2014-62,pp.49-54, 2015

- [11] 安倍和弥,武尾英哉,畠山拓也.他:肝 腫瘍 CAD 開発における人工症例画 像の有用性の検討, Med Imag Tech 34(1), 38-42, 2016
- [12] Rombach R, Blattmann A, Lorenz D, et al: High-Resolution Image Synthesis With Latent Diffusion Models. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022, pp. 10684-10695
- [13] Ruiz N, Li Y, Jampani V, et al: DreamBooth: Fine Tuning Text-to-Image Diffusion Models for Subject-Driven Generation. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023, pp. 22500-22510
- [14] Simonyan K, Zisserman A: Very deep convolutional networks for large-scale image recognition, Published as a conference paper at ICLR 2015, arXiv:1409.1556

# Artificial Case Image Generation of Breast Cancer Mass by Stable Diffusion and Its Application to Differentiation

## between Benign and Malignant

Kazuya ABE<sup>\*1</sup>, Hideya TAKEO<sup>\*1</sup>, Shigeru NAWANO<sup>\*2</sup>

\*1 Kanagawa Institute of Technology\*2 Shinmatsudo Central General Hospital

Currently, research and development of image-assisted diagnosis (CAD: Computer Aided Diagnosis) using AI technology is being conducted in various fields of medicine. Efforts to artificially create case images have been underway for some time, with the goal of compensating for the lack of case images in AI-based CAD development. Previously, the authors have shown an example of its usefulness for CAD, based on validation with a discriminator designed using training data including artificial cases. However, conventional artificial case images are created by embedding a mass or other lesion into an image in which no lesion exists, and it is difficult to say that the number of cases is essentially increasing.

In this study, we generated artificial case images of breast cancer masses using image generation AI based on Stable Diffusion technology, performed machine learning using the generated images, and verified the effectiveness of the AI-based artificial case images in CAD adaptation. The results showed that the discrimination performance was 83.7% with the CAD constructed using only actual cases, 86.1% with artificial cases, and 89.2% with a combination of artificial cases. The results showed that the creation of artificial case Images by AI contributed to the improvement of differential performance.

Key words: Artificial case images, Stable Diffusion, Breast Cancer Mass, Differentiation between Benign and Malignant, CAD

## 3D/2D U-Net を用いた腹部 CT 画像からの副腎領域の抽出に関する基礎的検討

平岡 大季\*1 西本 紘嗣郎\*2 滝沢 穂高\*3 工藤 博幸\*3

\*1 筑波大学大学院情報理工学位プログラム

\*2 埼玉医科大学国際医療センター 泌尿器腫瘍科

\*3 筑波大学システム情報系

## Preliminary study on extraction of adrenal glands in abdominal CT images

## by use of 3D/2D U-Net

Daiki HIRAOKA<sup>\*1</sup>, Koshiro NISHIMOTO<sup>\*2</sup>, Hotaka TAKIZAWA<sup>\*3</sup>, Hiroyuki KUDO<sup>\*3</sup>

<sup>\*1</sup> Master's Program in Computer Science, University of Tsukuba

<sup>\*2</sup> Department of Uro-oncology, Saitama Medical University International Medical Center

\*3 Institute of Systems and Information Engineering, University of Tsukuba

要旨:副腎は血圧,血糖,水分・塩分量などの体内環境を適切な状態に保つためのホルモンを生成する臓器である.副腎では原発性アルドステロン症という病気がおこり,その検査方法には副腎静脈サンプリングがあるが,手技の難易度が高いことなどの問題がある.本報告では,副腎静脈サンプリングを補完する方法として,腹部 CT 画像に 3D/2D U-Net を適用し,副腎領域を半自動的に抽出する手法を提案する.抽出精度を向上させるために,学習時には平行移動に基づくデータ拡張を適用し,認識時には大きさを正規化した.実際の腹部 CT 画像に適用した結果を示す.

キーワード: 副腎, 原発性アルドステロン症, 副腎静脈サンプリング, U-Net

## 1. はじめに

原発性アルドステロン症は、副腎からホルモンが過 剰に分泌されることにより、高血圧を呈する疾患で、 代表的な二次性高血圧である[1].原発性アルドステロ ン症の検査の1つである副腎静脈サンプリングは、手 技の難易度が高く、検査に時間がかかるため、多くの 検査を行うことが難しい.そのため、副腎静脈サンプ リングを補完する方法として、3次元腹部CT 画像から 副腎領域を抽出し、医師に情報提供する手法が必要と なる[2].本研究では、3次元腹部CT 画像に FCN の1 種である 2D U-Net[3] と 3D U-Net[4]を適用し、副腎 領域を半自動的に抽出することを試みる.

## 2. 方法

## 1) 関心領域

本報告では左副腎を抽出対象とし、左副腎の重心と 思われる画素を手動で選択し、その画素を中心とする 256x256x16pxの直方体の関心領域を作成する.図1に 関心領域の例を示す.



図1. 左副腎の関心領域

2) 3D/2D UNet の精度の比較

直方体の関心領域を 3D U-Net を使って学習・認識 する手法と,関心領域の各スライス画像を別々に 2D U-Net に入力し,学習・認識する手法を行い,抽出精度 を比較する.

3) データ拡張と輝度の正規化

アフィン変換によるデータ拡張を行う.また,造 影剤による関心領域毎の明るさの差を式(1)で正規 化する.

$$\mathbf{v}(\mathbf{x}, \mathbf{y}) = \frac{(x, y) \mathcal{O} \underline{m} \underline{x} \underline{d} - mean}{std} \times \sigma + \mu \quad (1)$$

ただし, μ=2x(全体平均)-各症例の平均画素値, σ=2 ×(画像の画素値分布の標準偏差)である.図2に原画 像と正規化した画像を示す.



(a)(b)図2.正規化処理.(a)原画像.(b)正規化した画像

## 3. 実験

提案手法を Python と Pytorch で実装し,腹部 CT 画 像 49 症例を使用し,7-fold crossvalidation (学習 35 症例,検証 7 症例,テスト 7 症例)で実験した.U-Net のエポック数を 100,バッチサイズを 8 とし,最適化 手法には Adam,損失関数にはバイナリクロスエントロ ピーを用いた.

## 4. 考察とまとめ

図3に3D U-Net での実験結果とF値を示す.原画 像は2D U-Net の方が高精度であった.これは学習デ ータ数を増やすことができたためと考えられる.また, 正規化やデータ拡張は有効であることがわかった.

今後の課題として,他のモデルを利用することや, 損失関数を細かい領域の抽出に適したものに変更する ことがある.

#### 利益相反の有無

なし

#### 文 献

[1] 日本内分泌学会「原発性アルドステロン症 診療ガイドライン2021」
[2] 平岡 大季,西本 紘嗣郎,滝沢 穂高,工藤 博幸.3DU-Net を用

いた CT 画像からの副腎領域の抽出に関する基礎検討.第41回日本 医用画像工学会大会予稿集, pp.226-227, 2022.



**図3**. 3D U-Net 実験結果画像 (a)原画像. (b)正規 化(F=0.670). (c) データ拡張(F=0.653). (d) デー タ拡張と正規化(F=0.720).

 [3] Olaf Ronneverger, Philipp Fischer, Thomas Brox. U-Net: Convolutional Networks for Biomeical Image Sementation. MICCAI 2015, pp 234-241, 2015.

[4] Özgün Çiçek, Ahmed Abdulkadir, Soeren S. Lienkamp, Thomas Brox, Olaf Ronneberger. 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. MICCAI 2016, pp.424-432, 2016.

## Intestine Segmentation based on Cross Pseudo Supervision

An Qin<sup>\*1</sup>, Hirohisa ODA<sup>\*2</sup>, Yuichiro HAYASHI<sup>\*1</sup>, Takayuki KITASAKA<sup>\*3</sup>, Aitaro TAKIMOTO<sup>\*4</sup>, Akinari HINOKI<sup>\*4</sup>, Hiroo UCHIDA<sup>\*4</sup>, Kojiro SUZUKI<sup>\*5</sup>,

Masahiro ODA<sup>\*6, 1</sup>, and Kensaku MORI<sup>\*1, 7, 8</sup>

\*1 Nagoya University, Aichi, Japan

\*2 University of Shizuoka, Shizuoka, Japan

\*3 Aichi Institute of Technology, Aichi, Japan

\*4 Nagoya University Graduate School of Medicine, Aichi, Japan

<sup>\*5</sup> Department of Radiology, Aichi Medical University, Aichi, Japan

\*6 Strategy Office, Information and Communications, Nagoya University, Aichi, Japan

<sup>\*7</sup> Information Technology Center, Nagoya University, Aichi, Japan

\*8 Research Center for Medical Bigdata, National Institute of Informatics, Aichi, Japan

**Abstract** : The intestine is an important digestive organ and can cause serious health problems once it is diseased. Segmentation of intestine regions from CT volumes is helpful for diagnosis. In this paper, we propose an improved semi-supervised method for intestines segmentation based on Cross Pseudo Supervision (CPS), which can create the pseudo labels for unlabeled data to utilize them for training. The method can enlarge the number of data sets to improve the insufficient data problem in medical image segmentation. In the experiment, we used 20 CT volumes labeled by clinicians for training. 5 CT volumes from different patients were used for testing. Experimental results showed that the Dice score of the CPS method was 0.799, the precision was 0.822, and the recall was 0.778.

Keywords: intestine segmentation, semi-supervision, pseudo label.

#### 1. Introduction

Intestinal diseases are very common and have a great impact on human health. Intestine obstruction is one kind of serious intestinal disease that includes mechanical and functional obstruction [1] of the intestines. However, compared with some large organs, such as the liver and kidneys, intestines have more complex spatial structures. The complex structure brings great difficulties for clinicians to diagnose intestinal diseases from CT volumes. Finding the region of the intestines accurately is critical for acquiring more detailed disease information and giving the preoperative diagnosis. Therefore, an automated segmented method [2] for the intestines can greatly help doctors to diagnose intestinal diseases accurately.

In addition to the complex structure, there are limited labeled data sets due to high cost and time-consuming, which is common in organ segmentation tasks. Over the last decade, segmentation methods based on deep learning have gradually played an important role in the medical image segmentation field.

Segmentation networks based on the U-Net [3] are the main methods for medical segmentation. However, the supervised methods are limited to the number of labeled data sets.

Different from the full-supervised methods, semi-supervised segmentation methods usually train two same networks with different

initial weights and take advantage of limited labeled data and a large number of unlabeled data to approach the performance with a large amount of labeled data. Semi-supervised methods can assign pseudolabels to the unlabeled data and utilize the information from unlabeled data. Considering pseudo-labels rely on the model's prediction, and if the model is not accurate, the labels generated may be inaccurate as well. To improve the reliability of pseudo labels, we use cross pseudolabels, which means the two sub-networks equally generate pseudolabels to supervise each other.

#### 2. Method

The proposed method is developed based on the semi-supervision method cross pseudo supervision [4] (CPS) and segments intestine regions from CT volumes. We introduce the soft pseudo labels to avoid producing more noises that will decrease the reliability of the pseudo labels and use mean squared error loss (MSE loss) to measure the difference between pseudo labels and predictions. The overview of the improved cross pseudo-labels is shown in Fig. 1. We aim to learn an intestines segmentation network from CT volume by exploring both the labeled and unlabeled CT volumes.

We train two 3D U-Nets with different initial weights, called 3D U-Net1 and 3D U-Net2. In the training process, we train the two sub-networks simultaneously with labeled data. And then, the two



**Fig. 1** Overall framework of CPS, where the input is CT patches cropped from CT volumes, P1, P2 are predictions of two 3D U-Nets and Y1, Y2 are pseudo labels for unlabeled images. In the model, the two sub-networks generate pseudo labels to supervise each other.

models are used to generate pseudo labels for the unlabeled data. These pseudo-labeled data are used to retain the model, and the process is repeated until convergence.

According to using both labeled and unlabeled data in the training, the overall loss function includes two sections: one that measures the difference between the prediction and ground truth, and another measures the difference between the prediction and pseudo labels. The unsupervised loss function penalizes the model for making confident but incorrect predictions on the unlabeled data. The equation of the overall loss function is  $L_{overall} = L_s + L_u$ .

The supervision loss calculates by dice loss and cross-entropy loss. To avoid producing more noise for pseudo-label loss, we directly utilize every pixel's prediction probability as soft pseudo-label. And then using MSE loss to guide the model convergence. The formula of these two loss functions as follows:

$$L_s = l_{ce}(\mathbf{p}_1, \mathbf{y}^*) + l_{dice}(\mathbf{p}_2, \mathbf{y}^*), \qquad (1)$$

$$L_u = l_{mse}(\mathbf{p}_{1,}\mathbf{y}_2) + l_{mse}(\mathbf{p}_2,\mathbf{y}_1).$$
(2)

where  $\mathbf{p}_1$ ,  $\mathbf{p}_2$  denote the prediction of two sub-networks,  $\mathbf{y}^*$  denotes the ground truth, and  $\mathbf{y}_1$ ,  $\mathbf{y}_2$  denote the pseudo labels.

#### 3. Experiment and Results

In the experiments, we got 2980 CT patches by overlapped slide windows from 16 unlabeled CT volumes and 4 labeled CT volumes for training. And we use five CT volumes for testing. Intestine segmentation results are shown in Fig. 2.

To verify the effectiveness of the proposed method, we compared the method with the original CPS and 3D U-Net. We calculated the Dice score, recall, and precision as the evaluation criteria. Table 1 shows the segmentation performance of those methods on our data set, and we bold the best quantitative result.



**Fig. 2** Segmentation results of different. We can see that the method based on CPS is better than the 3D U-Net.

Table 1	. The c	quantitative	results o	of different	methods
---------	---------	--------------	-----------	--------------	---------

Method	Dice	Recall	Precision
3D U-Net	0.585	0.520	0.686
CPS	0.671	0.605	0.753
Ours	0.799	0.822	0.778

#### 4. Discussion and summary

Our method gave a better Dice score than 3D U-Net and original CPS. The proposed method utilize the information of unlabeled data both in the two sub-networks and use prediction probability as pseudo labels to avoid producing more noise when generating the pseudo labels. However, there are still exiting some mis-segmented regions. In the future, we consider focusing more on the topology feature that is important for tubular organs, such as intestines and blood vessels, which can make a good presentation for the spatial structure of the intestines.

#### Acknowledgment

Parts of this work were supported by the Hori Sciences & Arts Foundation, the JSPS KAKENHI (17H00867, 21K19898), JSPS Bilateral Joint Research Project, the AMED (JP19lk1010036, JP20lk1010036), the JST CREST (JPMJCR20D5), the JST SPRING, and JPMJSP2125.

#### **Competing interests**

None

#### Reference

- [1] Gore R M, Silvers R I, Thakrar K H et al: Bowel obstruction. Radiologic Clinics, 53(6):1225-1240, 2015
- [2] Barr K, Laframboise J, Ungi T et al: Automated segmentation of computed tomography colonography images using a 3D U-Net, Medical Imaging 2020: Image-Guided Procedures, Robotic Interventions, and Modeling. SPIE, Vol. 11315, 635-641, 2020
- [3] Çiçek Ö, Abdulkadir A, Lienkamp S S et al: 3D U-Net: learning dense volumetric segmentation from sparse annotation, Medical Image Computing and Computer-Assisted Intervention, LNCS 9901, 424-432, 2016
- [4] Chen X, Yuan Y, Zeng G et al: Semi-supervised semantic segmentation with cross pseudo supervision, Proceedings of the IEEE CVF Conference on Computer Vision and Pattern Recognition, 2613-2622, 2021

## 肺マイクロ CT 像中の小葉間隔壁抽出のための教師データ生成に関する検討

深井 大輔\*1, 小田 紘久\*2, 林 雄一郎\*1, 鄭 通\*1,

中村 彰太\*3, 小田 昌宏\*4,1, 森 健策\*1,5,6

\*1 名古屋大学大学院情報学研究科

\*2 静岡県立大学経営情報学部

\*3名古屋大学大学院医学系研究科

\*4名古屋大学情報連携推進本部情報戦略室

\*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

A Study on Generation of Training Data for Interlobular Septa

## from Lung Micro-focus X-ray CT Volumes

Daisuke FUKAI<sup>\*1</sup>, Hirohisa ODA<sup>\*2</sup>, Yuichiro HAYASHI<sup>\*1</sup>, Tong ZHENG<sup>\*1</sup>,

Shota NAKAMURA\*3, Masahiro ODA\*4,1, Kensaku MORI\*1,5,6

<sup>\*1</sup> Graduate School of Informatics, Nagoya University

<sup>\*2</sup> School of Management and Information, University of Shizuoka

\*3 Nagoya University Graduate School of Medicine

<sup>\*4</sup> Information Strategy Office, Information and Communications, Nagoya University

<sup>\*5</sup> Information Technology Center, Nagoya University

\*6 Research Center for Medical Bigdata, National Institute of Informatics

要旨:本稿では、肺マイクロ CT 像における小葉間隔壁抽出のための教師データ生成手法について述べる.マイクロ CT とよ ばれる高解像度 CT 撮像装置により、肺の微細構造を撮像可能となった.肺マイクロ CT 像による三次元的な肺微細構造解析 に基づく病態や生体機能のさらなる解明が期待される.肺微細構造の一つである小葉間隔壁の構造を明らかにするため、我々 はマイクロ CT 像からの小葉間隔壁の構造抽出を目指す.マイクロ CT 像における小葉間隔壁の教師データ作成の負担は大き い.本稿では、教師データ生成の負担軽減のため、二次元画像のみのラベル付与から、三次元画像のラベル画像を得る方法を 検討する.本手法で得たラベル画像から5枚の断面画像をランダムに取り出して評価したところ、平均の Dice 係数は 0.75 だ った.本手法によって得られたラベル画像を元に、手動で断面画像の教師データ生成を行ったところ、作業時間が 27~30 分 から5~7分に短縮された.

キーワード:マイクロ CT, 肺微細構造, 小葉間隔壁

## 1. はじめに

本稿では, 肺マイクロ CT 像からの小葉間隔壁の教師データ 生成について述べる.マイクロ CT とよばれる高解像度 CT 撮 像装置により, 肺の微細構造を撮像可能となった. 肺マイクロ CT 像による三次元的な肺微細構造解析が, 病態や生体機能の さらなる解明につながると期待される[1].

肺小葉は気管支の枝分かれ構造の先に位置する 1~2 cm<sup>3</sup>程 度の大きさの組織であり,小葉間隔壁は肺小葉同士を区切る薄 い結合組織である.これらの解剖学的構造を明らかにするため, 我々はマイクロ CT 像からの小葉間隔壁の構造抽出を目指す.

Zhao らはヘッセ行列や Radial Structure Tensor に基づく構造 抽出フィルタを利用し、小葉間隔壁等の抽出を行った[2]. 三 次元画像に対し、小葉間隔壁を手動でラベル付与することは困 難であるため、ラベル付与の負担を軽減する方法が求められる. 本稿では、教師データの元となるラベル画像を簡易的に生成 する手法を検討する.二次元画像は三次元画像に比べ、ラベル 付与は容易である.そのため、二次元画像に対するラベル付与 のみから、三次元画像全体のラベル画像を得る方法を検討する. 本手法では、ラベル拡張手法により、与えられた二次元の断面 画像から三次元構造のラベル画像を生成する.

#### 2. 手法

本手法では,肺マイクロ CT 像と1 枚の断面画像にのみ手動 でラベルを付与したラベル画像を入力とし,三次元の小葉間隔 壁の領域を示すラベル画像を出力とする.

ラベル拡張手法では、ラベルが付与されている画素の6近傍 画素において、2つの条件を同時に満たすとき、ラベルを付与 する.小葉間隔壁は面状構造であるため、ヘッセ行列の固有値 の大小比較による面状構造強調手法[3]を用いて条件付けを行 う. 複数スケールを対象とした強調結果を得るため,入力画像 に対してマルチスケールΣのガウシアンフィルタを適用する. ラベル拡張における条件は次の通りである.

- 条件1:入力画像にヘッセ行列の固有値の大小比較による面状構造強調手法を適用し、得られた面状構造強調画像の画素値がしきい値t以上であること。
- 条件2:入力画像の画素値がしきい値v以上であること。
   ラベル拡張のアルゴリズムを以下に示す:
- $R = \{r_{ijk}\}$ : 肺マイクロ CT 像,  $S = \{s_{ijk}\}$ : 面状構造強調画像  $F = \{f_{ijk}\}$ : 入力のラベル画像
- **L** = {*l*<sub>*iik*</sub>}: 小葉間隔壁領域を示すラベル画像
- (1) 画素(*x*, *y*, *z*) = (0,0,0)から走査開始
- (2) 現在の画素を(*i*, *j*, *k*)とする

 $f_{ijk} = 1$  x b i (3) .  $f_{ijk} = 0$  t k i  $f_{ijk} = 2$  x b i (4) .

- (3) 画素(*i*, *j*, *k*)の 6 近傍画素(*i*', *j*', *k*')において、 *l<sub>i'j'k'</sub>* = 0か つ s<sub>i'j'k'</sub> ≥ t かつ r<sub>i'j'k'</sub> ≥ v のとき、 *l<sub>i'j'k'</sub>*を 1-画素、 *l<sub>iik</sub>*を 2-画素とする. (4)へ.
- (4) 全画素の走査が終了したとき(5)へ. その他のときは次の 画素へ進み, (2)へ.
- (5) L に 1-画素が存在しなければ(7)へ. 1-画素が存在する場合は(6)へ.
- (6)  $\forall \forall \tau \sigma(i,j,k) | t \forall v \tau, l_{ijk} = 1 \sigma \geq f_{ijk} = 1, l_{ijk} = 2$  $\sigma \geq f_{ijk} = 2 \geq l \tau(1) \wedge.$
- (7) すべての(*i*, *j*, *k*)に対して *L*を走査し、*l*<sub>*ijk*</sub> > 1の時*l*<sub>*ijk*</sub> = 1.
- (8) 小葉間隔壁のラベル画像 L を出力

#### 3. 実験·結果

肺がん患者の切除肺のうち肺がんに侵されていない部分の 標本を、マイクロ CT 撮影装置 Skyscan 1272 (Bruker, USA) で 撮影した.標本数は3、それらを撮影したマイクロ CT 画像の 解像度は25×25×25 μm<sup>3</sup>、画素数は806×806×482 画素で ある. ラベル拡張におけるパラメータ設定は表 1 の通りとし た.

抽出精度の評価のため、出力のラベル画像から5枚の断面画 像を選び、Dice係数を用いて定量評価を行った.また、作業時 間の評価のため、二次元断面画像に対して手動で教師データを 生成する時間と、ラベル画像を修正して教師データを生成する 時間を比較した.試行数は5回とし、作業は情報学系の学生1 名が、ソフトウェア Pluto[4]を用いてマウスでラベル付与を行 った.

図1ではラベル拡張法による小葉間隔壁の抽出結果である. Dice 係数の平均は 0.75 だった. また,作業時間は手動で 1763.2±188.8秒, ラベル画像の修正で353.4±94.4 秒だった.

## 4. 考察・まとめ

図 1(b) はラベル画像の 3D レンダリング画像であり,小葉 間隔壁の抽出が断面間で連続していることが確認できる.少数 の断面画像から三次元構造の抽出において,ラベル拡張法が有 用であることが確認できた.

本稿では,肺マイクロ CT 像中の小葉間隔壁抽出について, 教師データ生成における負担削減のため,少数の断面画像の情 報を用いたラベル拡張手法について述べた.実験の結果,教師 データ生成の際,ラベル画像から手動で修正することにより, 大幅に時間を短縮した.今後の課題として,過抽出・未抽出の 削減による更なる教師データ生成の負担軽減が求められる.

#### 謝辞

本研究の一部は堀科学芸術振興財団, JST CREST JPMJCR20D5, JSPS 二国間交流事業ならびに JSPS 科研費 (21K19898, 17H00867, 17K20099), AMED (JP20lk1010036) に よる.

#### 利益相反の有無

なし

#### 文 献

- Mori K: From macro -scale to micro-scale computational anatomy: a perspective on the next 20 years. Medical Image Analysis 33: 159-164, 2016
- [2] Zhao X, Oda H, Nakamura S et al: Investigation of extra cting interlobular septa with Hessian analysis and Radial Structure Tensor combined with roundness error in micro-CT volume. IFMIA 11050: 243-248, 2019
- [3] Sato Y, Nakajima S, Shiraga N et al: Three-dimensional multi -scale line filter for segmentation and visualization of curvilinear structures in medical images. Medical Image Analysis 2 (2): 143-168, 1998
- [4] 二村幸孝,出口大輔,北坂孝幸,他:PLUTO:医用画像診断支援共通 sssssssss プラットフォーム. Med Imag Tech 26(3):187-191,2008

表1 ラベル拡張における各標本のパラメータ設定

	Σ	t	v
標本 A	{√2,2}画素	58.23	-684.93
標本 B	{√2,2} 画素	69.67	-637.67
標本 C	{√2,2}画素	65.23	-465.28



(a)



(b)

図1 ラベル拡張法による小葉間隔壁の抽出結果. (a) 小葉間 隔壁領域のラベル画像. 黄色領域が小葉間隔壁を示す. (b) 小葉間隔壁の 3D レンダリング画像.

## 腹部 CT 画像からの複数臓器抽出における CutMix の有用性の検討

中山晃平\*1, 大野真奈\*1, 申忱\*1, 小田昌宏\*2\*1, 林雄一郎\*1, 三澤一成\*3, Ben Glocker\*4,

Daniel Rueckert<sup>\*4\*5</sup>,森健策<sup>\*1\*6\*7</sup> <sup>\*1</sup>名古屋大学大学院情報学研究科

\*2名古屋大学情報連携推進本部情報戦略室

\*3愛知県がんセンター

<sup>\*4</sup>Imperial College London <sup>\*5</sup>Tecnical University of Munich <sup>\*6</sup>国立情報学研究所医療ビッグデータ研究センター <sup>\*7</sup>名古屋大学情報基盤センター

## Study on Effectiveness of CutMix on Multi-organ Segmentation from 3D Abdominal CT Images

Kohei NAKYAMA<sup>\*1</sup>, Mana OHNO<sup>\*1</sup>, Chen SHEN<sup>\*1</sup>, Masahiro ODA<sup>\*2\*1</sup>, Yuichiro HAYASHI<sup>\*1</sup>,

Kazunari MISAWA<sup>\*3</sup>, Ben GLOCKER<sup>\*4</sup>, Daniel RUECKERT<sup>\*4\*5</sup>, Kensaku MORI<sup>\*1\*6\*7</sup> <sup>\*1</sup>Graduate School of Informatics, Nagoya University <sup>\*2</sup>Information Strategy Office, Information and Communications, Nagoya University <sup>\*3</sup>Aichi Cancer Center <sup>\*4</sup>Imperial College London <sup>\*5</sup>Tecnical University of Munich <sup>\*6</sup> Research Center for Medical Bigdata, National Institute of Informatics <sup>\*7</sup>Information Technology Center, Nagoya University

要旨:本稿では,深層学習を用いた腹部 CT 画像からの複数臓器抽出において,データ拡張手法の1つである CutMix の有用性について検討した結果を述べる.腹部 CT 画像からの複数臓器抽出は,医師の画像診断を支援するシステム開発において重要な技術である.複数臓器抽出手法の中で,深層学習を用いたものが注目されている.深層学習ではデータ数の確保が重要であるが,特に医用 画像では十分なデータ数が得られない場合が多い.本研究では,V-Net を学習モデルとして用いた腹部 CT 画像からの複数臓器抽出 について,元の学習データと CutMix を用いて拡張した学習データを用い,血管を含む 9 つの臓器の領域抽出の学習を行い,テスト データに対する抽出精度を比較した.CutMix を用いた場合の抽出結果は,CutMix を用いなかった場合と比較して,学習データが少 数の場合に多くの臓器で精度の向上が見られたが,学習データが増加するにつれて血管などの複雑な構造に関しては精度の低下が 見られた.

キーワード: 深層学習, データ拡張, 多臓器セグメンテーション, 腹部臓器

## 1. はじめに

腹部 CT 画像からの複数臓器抽出は, 医師の画像診断を支援 するシステム開発において重要な技術である. 複数臓器抽出手 法の中で, 深層学習を用いたものが注目されている. 深層学習 では十分なデータ数が得られない場合, 過学習が起き学習デー タ以外に対しての抽出精度が低下するという問題がある. 十分 なデータ数が得られない場合の解決策としてデータ拡張手法 を利用することがあげられる. 近年提案されたデータ拡張手法 として CutMix [1] がある. 本研究では, V-Net [2] を学習モ デルとして 用いた腹部 CT 画像からの複数臓器抽出について, 元の学習データと CutMix を用いて拡張した学習データを用い, 動脈, 門脈, 肝臓, 脾臓, 胃, 胆のう, 膵臓, 右腎臓, 左腎臓 の9 つの血管及び臓器の領域抽出の学習を行い, テストデータ に対する抽出精度を比較した.

2. 手法

本稿の研究では学習データに CutMix を用いたものと用いな かったものについてそれぞれ学習を行いその抽出精度を比較 し,また抽出精度の向上について学習データ数による差異を調 べる. V-Net に学習データとして腹部 CT 像とそれを画素ごと に動脈,門脈,肝臓,脾臓,胃,胆のう,膵臓,右腎臓,左腎 臓の9つの血管及び臓器と背景の10クラスでラベル付けした 正解ラベル画像を与えて学習し,入力画像に対して予測ラベル 画像を出力する.

CutMixは2枚の画像から一枚の画像を作り出す手法であり, 一枚の画像から Bounding Box (BB) を用いて切り出した部分 画像を用いて他方の画像の一部を置き換えたものを新たな疑 似画像とする[1]. CT 画像の各軸方向それぞれで2点の位置 をランダムに決定し,選ばれた点を頂点とするBBを作成する. その次の置き換え処理では,他方の画像の前の処理で決定した BB 位置と同じ位置の BB を前の処理で切り出したもので置き

155

換える. CT 画像と同様に,BB を用いた画像置き換えを CT 画 像と対応する正解ラベル画像に対しても行う. CutMix によっ て疑似画像を作成した例を図1に示す. 左および中央の画像は 実際の CT 画像を2枚選んだものの axial 断面画像を並べたも のである. 左の CT 画像で BB を選択し,中央の CT 画像の一 部を置き換えて生成した疑似画像の axial 断面画像が右の画像 である.

## 3. 実験及び結果

本実験では 10, 20, 30, 40, 50 症例の腹部 CT 画像の組を 作成し、学習データとしてこれらの CT 画像のみのデータとこ れらの CT 画像に CutMix を適用して拡張したデータについて それぞれ V-Net [2] の学習を行い、テストデータに対しての抽 出精度の比較を行った.

学習データとして 10, 20, 30, 40, 50 症例の腹部 CT 画像, またそれらに対し CutMix を適用し元のデータに加えた 15, 30, 45, 60, 75 個の拡張データを使用した.テストデータは学習デ ータとは別の 56 症例の腹部 CT 画像を使用した. 抽出結果の 評価には Dice を用いた.テストデータに対する抽出結果の Dice による評価は CutMix を用いたものが図 2, 用いなかった ものが図 3 となった.図4 は元の学習データが 10 症例のとき のテストデータの一つに対する CutMix ありと CutMix なしの 抽出結果をボリュームレンダリングを用いて可視化したもの である. 左が正解ラベル,中央が CutMix なしで学習したもの の予測ラベル,右が CutMix ありで学習したものの予測ラベル である. CutMix なしで学習したものではセグメンテーション 対象外の骨が左腎臓として誤抽出されていることがわかる.

#### 4. 考察

元のデータ数が少ないほど CutMix によって抽出精度が大き く上昇しているのはデータ数が少ないため学習データ増加に よる効果が大きいと考えられる.元のデータが多くなるにつれ 血管などの複雑な構造に対して抽出精度が低下した.これは CutMix を適用する際複雑な構造の一部を切り出してしまうこ とで実際の症例との差異が大きいものを作り出してしまうこ とが原因だと考えられる.

#### 5. むすび

本稿ではV-Netの学習をCutMix ありで行った場合とCutMix なしで行った場合の複数臓器の抽出精度をデータ数ごとに比 較した.元のデータ数が少ない場合は学習データ数の増加によ って精度の向上が見られるが,データ数が多くなるにつれて複 雑な構造に対しての抽出精度の低下が見られた.今後の課題と して他の学習モデルを用いた場合との比較,複雑な構造に対し て抽出精度が低下しないようなデータ拡張手法の改良などが 挙げられる.

謝辞

本研究は科研費 21K19898, JST CREST JPMJCR20D5, ムー ンショット型研究開発事業 JPMJMS2033 の支援を受けたもの である.

#### 利益相反の有無

なし

## 文

[1] Yun S, Han D, Oh SJ et al: CutMix: Regularization Strategy to Train Strong Classifiers with Localizable Features. ICCV 2019, 6022-6031, 2019

献

[2] Milletari F, Navab N, Ahmadi S: V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation. Fourth International Conference on 3D Vision, 565-571, 2016



図1 CutMix を適用して疑似画像を生成した例. CT 画像 (左)から一部を切り取り,他方の CT 画像(中央)の一 部を置き換えて疑似画像(右)を生成した.







図 3 CutMix ありの場合の抽出精度



図 410 症例で学習した場合の抽出例. 正解ラベル(左), CutMix なしの場合(中央), CutMix ありの場合(右)

## Alpha-blending によるデータ拡張と敵対的学習を用いた DeepLab v3 による歯種セマンティックセグメンテーション

渋谷 恒介\*1, 中山 良平\*1, 檜作 彰良\*1, 村田 乾\*2

\*1 立命館大学大学院理工学研究科

\*2 タカラテレシステムズ株式会社

## Semantic Segmentation Method for Tooth Type in Panoramic Dental X-ray Images by DeepLab v3 Using Adversarial Training and Pretraining with Alpha-blending

Kosuke SHIBUYA<sup>\*1</sup>, Ryohei NAKAYAMA<sup>\*1</sup>, Akiyoshi HIZUKURI<sup>\*1</sup>, Kan MURATA<sup>\*2</sup>

<sup>\*1</sup> Graduate School of Science and Engineering, Ritsumeikan University

\*2 TAKARA TELESYSTEMS Corporation

要旨:本研究の目的は、DeepLab v3 を用いた歯科パノラマ X 線画像における各歯種のセマンティックセグメンテーション法を開発 することである.実験試料は、歯科パノラマ X 線画像 129 枚である.提案手法では、まず、Alpha-blending を用いたデータ拡張によ り、各歯領域のテクスチャ情報だけでなく形状情報にも着目した DeepLab v3 の事前学習を実施する.次に、DeepLab v3 による予測 ラベル画像と正解ラベル画像を用いた敵対的学習により、DeepLab v3 を fine-tuning する.提案手法による Jaccard index、Dice index は 0.722, 0.804 で、Alpha-blending を用いたデータ拡張のみ適用した DeepLab v3 (0.671, 0.764)、敵対的学習のみ適用した DeepLab v3 (0.703, 0.789)、データ拡張と敵対的学習を適用しなかった DeepLab v3 (0.643, 0.742)より高い結果が得られ、その有用性が示 唆された.

キーワード:歯科パノラマX線画像,セマンティックセグメンテーション, DeepLab v3, Alpha-blending, 敵対的学習

## 1. はじめに

歯科パノラマ X 線画像は多くの歯科クリニックで使用され ているが,解像度が低いため早期カリエスなどの小さな病変の 診断が困難である.したがって,歯科医による歯の診断を補助 する診断支援システム (CAD) が切望されている.

CAD では各歯の状態を解析するため、歯種のセマンティッ クセグメンテーションが必要となることが多い. 深層学習を用 いたセマンティックセグメンテーションモデルの一つに DeepLab v3 [1]がある. DeepLab v3 は複数解像度の特徴マップ を統合する Atrous Spatial Pyramid Pooling により、マルチスケ ール解析が可能である. 歯種を対象としたセマンティックセグ メンテーションでは、各歯の位置情報が有用であるため、異な る大きさの受容野を解析できる DeepLab v3 は適すると考える.

セグメンテーションに関する従来研究において、Alphablending を用いたデータ拡張により形状に着目した学習を行 う手法[2]、予測/正解ラベル画像を用いた敵対的学習により 分割精度を改善する手法[3]が提案されている.本研究では、 Alpha-blending による学習と敵対的学習を用いた DeepLab v3 により、歯科パノラマ X 線画像の各歯種をセマンティックセ グメンテーションする手法を提案する.

#### 2. 実験試料

実験試料は歯科パノラマ X 線画像 129 枚で,画像サイズは 960×480 画素,濃度分解能は 8 bit である.本研究では,学習用 80 枚,検証用 19 枚,評価用 30 枚に分割し用いた.

## 3. 方法

## 1)提案ネットワーク構造

図1に提案手法のネットワーク構造を示す.提案ネットワー クは、各歯種をセグメンテーションする DeepLab v3 と予測ペ ア画像 (Pred pair),正解ペア画像 (Truth pair)を判別する Discriminator の2 つのサブネットワークで構成される.

## 2) Alpha-blending によるデータ拡張

図2に Alpha-blending によるデータ拡張処理を示す.まず, 正解ラベル画像に対しカラーマップを適用し, RGB ラベル画 像を作成する(図2(a)).次に症例ごとに各歯種の RGB 値が異



図1:提案手法のネットワーク構造



図2: Alpha-blending によるデータ拡張

なるように, RGB 値をシャッフルする (図 2(b)). 最後に, Alphablending により RGB 値をシャッフルしたラベル画像と歯科パ ノラマ X 線画像を合成する (図 2(c)). Alpha-blending による画 像の合成は,式(1) で定義される.

 $I_{blended} = \alpha \times I_{shuffled RGB \ label} + (1 - \alpha) \times I_{X-ray}$ (1) 本研究では、合成パラメータαを 0.7 とした.

#### 3) 敵対的学習

DeepLab v3 は Discriminator が予測/正解ペア画像を判別で きないほど,高精度な予測ラベル画像が生成するように学習す る.一方,Discriminator は予測ペア画像と正解ペア画像を正確 に判別するように学習する.ペア画像は,予測ラベル画像また は正解ラベル画像と歯科パノラマ X 線画像を各歯種の重心を 中心に 128×128 の矩形領域で切り出し,チャネル方向に連結し て作成する.DeepLab v3,Discriminator の敵対的学習で使用す る損失関数は,それぞれ式(2),(3)で定義される.

$$L_{Deep} = -\mathbb{E}_{x \sim P_x}[p(x)\log q(x)] + \mathbb{E}_{\hat{y} \sim P_{\hat{y}}}[1 - D(\hat{y})]^2$$
(2)

$$L_{Dis} = \frac{1}{2} \Big\{ \mathbb{E}_{y \sim P_{\hat{y}}} [1 - D(y)]^2 + \mathbb{E}_{\hat{y} \sim P_{\hat{y}}} [0 - D(\hat{y})]^2 \Big\}$$
(3)

xは歯科パノラマX線画像,p(x)は正解ラベル画像,そしてq(x)は予測ラベル画像を表す.  $\hat{y}, y$ は予測ペア画像, 正解ペア画像 である.また, $D(\cdot)$ は Discriminator に入力されたペア画像が正 解ペア画像である確率を表す.

## 4. 結果と考察

提案手法の Jaccard index, Dice index は 0.722, 0.804 であり, Alpha-blending を用いたデータ拡張のみ適用した DeepLab v3 (0.671, 0.764), 敵対的学習のみ適用した DeepLab v3 (0.703, 0.789), データ拡張と敵対的学習を適用しなかった DeepLab v3 (0.643, 0.742) より高い結果が得られた.

図3に各手法のセグメンテーション画像の比較結果を示す.

提案手法は他の手法に比べ,各歯種の領域内にラベルの混在が 少なく,歯根部まで正確にセグメンテーションできることが確 認された.

#### 5. まとめ

本研究では、Alpha-blending によるデータ拡張と敵対的学習 を用いた DeepLab v3 を構築し、歯種セマンティックセグメン テーションに応用した.提案手法は、Alpha-blending によるデ ータ拡張、敵対的学習を用いなかった DeepLab v3 より高い分 割精度が得られ、その有用性が示唆された.

## 6. 謝辞

本研究で使用した歯科パノラマ X 線画像を提供,研究に関 する助言をして頂いたタカラテレシステムズ株式会社の皆様 に厚く感謝の意を表します.

#### 7. 利益相反の有無

なし

#### 文 献

- [1] Liang C, George P, Florian S et al: Rethinking Atrous Convolution for Semantic Image Segmentation. 2017, arXiv preprint arXiv 1706.05587.
- [2] Christoph R, Carsten R: Increasing the Robustness of Semantic Segmentation Models with Painting-by-Numbers. Computer Vision – ECCV. 2020, pp368-387.
- [3] Mina R, Konstantin H, Will G et al: A Conditional Adversarial Network for Semantic Segmentation of Brain Tumor. Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. 2017, pp241-252.



DeepLab v3 with Adversarial training

1



## 呼吸器内視鏡迅速細胞診における AI 診断支援

尾見康夫\*1、桐田圭輔\*2,\*3、香川洋輔\*2、高橋真理\*4,\*5、後藤功一\*2

\*1 NEC ヘルスケア・ライフサイエンス事業部門 医療機器ソフトウェア統括部

\*2国立がん研究センター東病院 呼吸器内科

\*3上尾中央総合病院 呼吸器内科

\*4国立がん研究センター東病院 トランスレーショナルリサーチ検体管理室

\*5国立がん研究センター東病院内視鏡センター

AI-assisted benign and malignant classification for Rapid On-Site cytologic Evaluation (ROSE) on

lung cancer.

Yasuo Omi<sup>\*1</sup>, Keisuke Kirita<sup>\*2,\*3</sup>, Yosuke Kagawa<sup>\*2</sup>, Mari Takahashi<sup>\*4</sup>, and Koichi Goto<sup>\*2</sup> <sup>\*1</sup> Healthcare and life sciences, Medical Device Software Development, NEC Corporation <sup>\*2</sup> Department of Thoracic Oncology, National Cancer Center Hospital East <sup>\*3</sup> Department of Thoracic Oncology, Ageo Central General Hospital <sup>\*4</sup> TR Sample Management Section, Endoscopy center, National Cancer Center Hospital East.

要旨:呼吸器内視鏡検査における迅速細胞診(ROSE)は診断率の向上や穿刺回数の減少、合併症の低減などの有効性が報告されている。しかし採取した検体の良悪性分類を担う人的資源の確保が難しい等の理由から導入施設が限られている。我々は ROSE の診断支援を目的として、良悪性分類支援 AI システムの開発を進めている。国立がん研究センター東病院にて、肺癌または疑い症例に対して ROSE を併用し気管支鏡検査が施行された 26 症例を学習データに使用した。ROSE では偽陽性を最小限に抑えることが望ましいため、感度を維持しながら特異度を向上させる必要がある。我々は複数のサブクラス分類器の結合および対照学習による事前学習の導入により感度特異度の両立を試みた(提案法)。従来の2クラス分類モデルによる感度/特異度は 0.90/0.83 であったが、提案法では感度 0.90 を維持しつつ特異度を 0.90 以上に改善できた。 キーワード:迅速細胞診、対照学習、良悪性分類、分類の粒度

#### 1. Introduction

Previous clinical studies showed that Rapid on-site cytologic evaluation (ROSE) resulted in a lower puncture number compared with a non-ROSE group and less complications, and it could also prevent a repeat bronchoscopy [1-2]. However, ROSE is not widely used routinely due to limited availability of a cytopathologic technician skilled in ROSE diagnosis. The goal of our research is to provide an AI system to assist ROSE diagnosis that it must be at least as accurate as cytopathologists and capable of assisting in diagnoses to work as a second opinion.

#### 2. Materials and Methods

26 pathological slides were obtained from routine examinations for lung cancer or suspected cases in National Cancer Center East (NCCE) hospital in which bronchoscopy with ROSE was performed. 741 cells were selected and labeled by a pulmonologist and cytotechnologist, and cell images were obtained by cropping a 128x128 pixel region around the cell center from Whole Slide Imaging (WSI). Each cell was categorized globally as benign or malignant and was also categorized into 9 subclasses. Since our obtained images were an imbalanced dataset among subclasses, we applied augmentation to have a consistent number of images, i.e. every 1000 images per subclass. The cell images were randomly partitioned into five equal sized subsamples to perform 5-folds cross validation.

Since each cell types and cancer types have their own visual characteristics, it's reasonable to assign different labels to each cell types. However, the complexity of the classification problem becomes gradually higher with the increasing of number of classes. We believe that the benefits of both a model with a simplified class and that with multiple classes according to cell types can be incorporated by combining several models trained with various subclasses. We assessed the 3 models to have different level of granularity, 2-class, 5-class, 9-classs models, and their voting methods, Logical OR (XOR), Majority decision (MD) and Logical AND (XAND). To improve model's performance furthermore, we introduced a pretraining using supervised contrastive learning [3]

Since false positive should be minimized as much as possible to prevent a repeat bronchoscopy, specificity should be maximized while maintaining acceptable sensitivity. Thus, we introduced a critical index Spec@sens0.9, which means the specificity when sensitivity is 0.9.

#### 3. Results and discussion

In the first experiment, we investigated the classification performance by three models with different level of granularity and the combined models with three types of voting. Figure 1 shows a 95% confidential interval of accuracy and Spec@sens0.9 among the methods. In a comparison among the three models with different level of granularity, the 5-class and 9-class models showed better performance than the 2-class model. This indicates that the advantage of the classification with fine granularity according to cell types outweighs the disadvantage of classification problem being more complex. Since the 5-class model showed comparable performance with the 9-class model, we don't think that finer granularity is essential. In a comparison among the 3 voting methods, XAND voting showed the best Spec@sens0.9 as theoretically expected. MD and XAND voting showed superior performances than the baselines, and XOR voting negatively impacted Spec@sens0.9 as also theoretically expected. The sensitivity/specificity by a conventional 2-class classification model was found to be 0.9/0.83. By introducing the voting method, specificity was noticeably improved from 0.83 to 0.90 while maintaining sensitivity at 0.90.



**Fig1.** Performance comparison between baseline method and proposal method. (A) 95% confidential interval of accuracy among six methods (B) 95% confidential interval of Spec@sens0.9 among six methods.

We investigated effectiveness of the pretraining using supervised contrastive learning considering difference among subclasses. Figure 2 shows a 95% confidential interval of Spec@sens0.9 between a conventional learning and a contrastive learning with positive and negative samples. Two test set, testset1) actual cell images from NCCE hospital and testtset2) pseud multi-institutes images by applying color transformation and noise addition to the testset1, were used to assess robustness for difference among test sets. Noticeable improvement was observed for all models by applying the pretraining using contrastive learning shown as by comparison between Fig 3-A and Fig 3-B. Additionally, conventional learning showed 1.2-3.8%

worse spec@sens0.9 for the testset2 than that for the testset1 shown as by comparison between Fig 3-A and Fig 3-C, while contrastive learning showed comparable performance for the testset2 with that for the testset1 shown as by comparison between Fig 3-B and Fig 3-D.



**Fig2.** 95% confidential interval of Spec@sens0.9 for the following 4 cases, A) Testset1, Conventional, B) Testset1, Contrastive, C) Testset2, Conventional, D) Testset2, Contrastive.

Since the performance by our proposal method, sensitivity/ specificity=0.90/0.93, are comparable with those by a cytopathologist shown in a previous study [4], we believe that our model achieved a performance capable of working as a second opinion.

#### 4. Conclusion

We developed a novel AI system to assist ROSE diagnoses that can provide benign and malignant classification with comparable accuracy to cytopathologists by introducing a pretraining using contrastive learning and voting of several subclass classification models.

#### **Conflict of Interest**

The author is an employee of NEC corporation.

#### References

- [1] M. Oki et al.: Rapid on-site cytologic evaluation during endobronchial ultrasound-guided transbronchial needle aspiration for diagnosing lung cancer: a randomized study, Respiration, 2013;85(6):486-92
- [2] R. Trisolini et al.: Rapid on-site evaluation of transbronchial aspirates in the diagnosis of hilar and mediastinal adenopathy: a randomized trial, Chest. 2011 Feb;139(2):395-401
- [3] P. Khosla et al., Supervised Contrastive Learning, NeurIPS 2020
- [4] Kanayama et al.: Quality Management of Rapid On-site Cytologic Evaluation, The Journal of the Japan Society for Respiratory Endoscopy, vol 38, No 6, Nov 2016

## 階層的クラス構造のためのマルチモーダル分類

橋本 典明1,花田 博幸1,三好 寬明2,永石 美晴2,佐藤 健作2,大島 孝一2,

本谷 秀堅3,竹内 一郎1,4

1理化学研究所, 2久留米大学, 3名古屋工業大学, 4名古屋大学

## Multimodal Classification for Hierarchical Class Structures

## Noriaki HASHIMOTO<sup>1</sup>, Hiroyuki HANADA<sup>1</sup>, Hiroaki MIYOSHI<sup>2</sup>, Miharu NAGAISHI<sup>2</sup>,

## Kensaku SATO<sup>2</sup>, Koichi OHSHIMA<sup>2</sup>, Hidekata HONTANI<sup>3</sup>, Ichiro TAKEUCHI<sup>1,4</sup>

<sup>1</sup> RIKEN, <sup>2</sup> Kurume University, <sup>3</sup> Nagoya Institute of Technology, <sup>4</sup> Nagoya University

要旨:本研究ではリンパ腫病理画像データを対象とし、フローサイトメトリー (FCM)を補助情報とするマルチモーダル分類手法を開発する.リンパ腫は複数のサブタイプからなるグループを構成する階層的なクラス構造を有しており、病理診断の際 FCM はグループの分類に有用な情報とされている.提案手法では whole slide image を扱うためのマルチインスタンス学習とクラス構造を既知とした mixture of experts の枠組みを組み合わせることで各データを効果的に利用した特徴集約メカニズムを実現し、病理医の意思決定プロセスを模倣した分類モデルを構築する.臨床実データを用いたクラス分類実験および2種類の重みの可視化による判断根拠の提示により、提案手法の有効性を確認する.

キーワード: Mixture of experts, Whole slide image, フローサイトメトリー, マルチインスタンス学習, 悪性リンパ腫

#### 1. はじめに

リンパ腫の病理診断では、患者から採取した細胞のうち特定 の抗体に反応する細胞の存在を計測する flow cytometry (FCM) が診断時の補助情報として病理医に提供される. FCM のデー タ内において異常細胞集団が認められれば、症例が B 細胞由 来の病型であるか、あるいは T 細胞由来の病型であるかとい った病型グループ(スーパークラス)の分類に利用可能である.

本研究では画像と FCM を組み合わせたマルチモーダルクラ ス分類手法を提案する.提案手法ではマルチインスタンス学習 (MIL)を取り入れた mixture-of-experts (MoE) [1]の枠組みにおい て FCM をゲーティングに利用することで, FCM によるスーパ ークラス分類と画像によるクラス分類を効率的に学習し分類 精度の向上を図る.またモデルが計算したゲーティング重みや アテンション重みを可視化することで, 判断根拠などを示すこ とが可能な説明性の高い手法を実現する.画像と FCM を用い た MoE による分類の概要を図1 に示す.



図1 画像とFCM を用いた MoE による分類の概要.

#### 2. 提案手法

N症例の学習データを $\{X_n, Y_n, T_n\}_{n=1}^N$ とし,各症例は whole slide image (WSI)  $X_n$ に加え,2種類のデータを持つ: $Y_n$ は病型 を表すK次元の one-hot ベクトルであり, $T_n$ は FCM 中の異常 細胞の有無を表すL次元の二値ベクトルである. $T_n$ の各要素は 対応した抗体に異常細胞が認められれば1,そうでなければ0 が割り当てられる.本研究ではある症例の WSI  $X_n$ および FCM データ $T_n$ が同時に入力されたとき $Y_n$ の予測を行う.WSI  $X_n$ に は腫瘍領域の注釈が与えられていないため,症例単位のラベル のみが与えられている分類問題を扱うための手法としてアテ ンションベース MIL (AB-MIL)を用いる[2].提案手法では $X_n$ か ら切り出されたM枚のパッチ画像 $\{x_{n,m}\}_{m=1}^M$ と FCM データ $T_n$ の集合であるバッグがモデルの入力として使用される.

提案するクラス分類モデルは4つの要素,(i) 特徴抽出器, (ii) マルチモーダルゲーティングネットワーク,(iii) マルチサ ブネットワーク,(iv) AB-MIL からなる.

(i) 特徴抽出器 特徴抽出器 $g_{img}$ および $g_{FCM}$ は,入力バッグ内 の $\{x_{n,m}\}_{m=1}^{M}$ と $\mathbb{T}_n$ を各特徴量 $\{h_{n,m}\}_{m=1}^{M}$ と $h_n^{(FCM)}$ に変換する畳 み込みニューラルネットワーク (CNN)および NN である.

(ii) マルチモーダルゲーティングネットワーク マルチモー ダルゲーティングネットワーク $g_{gate}$ では、特徴量 $\{h_{n,m}\}_{m=1}^{M}$ に 対して同数コピーされた $h_{n}^{(FCM)}$ を結合しNNに入力することで、 M枚のパッチに対するゲーティング重み $\{w_{n,m}\}_{m=1}^{M}$ を出力する。  $w_{n,m}$ の次元数は設計したサブネットワークの数に等しく、各 パッチがどのサブネットワークの出力を重視するかを表す。

(iii) マルチサブネットワーク サブネットワーク $g_{gate}^{(c)}$ は  $\{h_{n,m}\}_{m=1}^{M}$ を入力として受け取り、スーパークラスcに特化した 特徴量 $\{h_{n,m}^{(c)}\}_{m=1}^{M}$ を出力する.リンパ腫の大分類として B 細胞 リンパ腫,T細胞リンパ腫,その他の3つのスーパークラスを 考えたとき,B細胞リンパ腫に対応したサブネットワークは diffuse large B-cell lymphoma (DLBCL)と follicular lymphoma (FL) をよく分類する特徴量を出力する.各パッチに対するC個の特 徴量{ $h_{n,m}^{(c)}$ } $_{c=1}^{c}$ は重み $w_{n,m}$ を用いて以下のように集約される,

$$h_{n,m}^{(agg)} = \sum_{c=1}^{C} w_{n,m}^{(c)} h_{n,m}^{(c)}$$

(1)

(2)

(iv) AB-MIL サブネットワークとゲーティング重みによって 生成されたM個の特徴量{ $h_{n,m}^{(agg)}$ } $_{m=1}^{M}$ は、AB-MIL によりひとつ のバッグ特徴量に集約される. NN 構造を持つアテンションネ ットワーク $g_{att}$ は各特徴量 $h_{n,m}^{(agg)}$ の分類への寄与を表すアテン ション重み $a_m$ を計算する. 最終的な入力バッグの特徴量は、

 $\boldsymbol{z}_n = \sum_{m=1}^M a_m \, \boldsymbol{h}_{n,m}^{(\text{agg})},$ 

と計算され,分類器gclfに入力することでバッグに対するクラ ス予測確率を得る.学習では予測確率と正解ラベルの交差エン トロピー損失関数が最小になるようモデルの最適化を行う.

#### 3. 実験

## 3.1 実験設定

今回使用したデータセットは久留米大学医学部で診断され た 600 症例のリンパ腫症例であり、6 つの病型からなる.病型 の内訳は DLBCL, FL, angioimmunoblastic T-cell lymphoma (AITL), adult T-cell leukemia/lymphoma (ATLL), classical Hodgkin's lymphoma (CHL), reactive lymphoid hyperplasia (RL) がそれぞれ 100 例であり、スーパークラスとクラスの関係は 図 1 中の表に示す通りである.各症例に対して Aperio GT450 で 40 倍撮影された WSI および FCM データが与えられている. FCM データは各免疫染色マーカーに対して異常細胞が存在す るかどうかを表す 18 次元の二値ベクトルである.

今回はクラス構造を既知としてサブネットワークの数の設定および事前学習を行う. つまり B 細胞リンパ腫のためのサブネットワークは DLBCL と FL を分類する 2 クラス分類モデルで事前学習されたものを初期値として利用する. 各バッグ内のパッチ画像の数は*M* = 100枚とし,各症例から最大で 50 バッグを作成した.データセットのうち 60%を学習,20%を検証,20%をテストに分割し5分割交差検証により評価を行った.

#### 3.2 実験結果

比較手法として以下のモデルを使用した:(I) 画像のみを用 いた6クラスAB-MIL,(II) FCM と画像を利用した階層的分類. 表1に示す各手法の交差検証における平均正解率より,提案手 法が最もよい分類結果を得られることを確認した.

また図2に計算された重みの可視化結果を示す.サブネット ワーク1および2はB細胞およびT細胞リンパ腫に特化した ネットワークであり,図中上段は各ネットワークに対するゲー ティング重み,下段はそれらにアテンション重みをかけたもの である.標本中の濾胞領域は B 細胞リンパ腫に特有な領域と して,また濾胞間は T 細胞リンパ腫に特有な領域として各ネ ットワークに重視されており,これは B 細胞リンパ腫である FL に見られる典型的な構造である.一方で濾胞間のアテンシ ョン重みは小さくなっており,最終的には濾胞内の腫瘍に注目 して分類を行っていることが確認できる.

表1 5分割交差検証による分類精度比較.	北較.
----------------------	-----

	Method I	Method II	Proposed
Accuracy	0.702	0.695	0.723



図2 ゲーティング重みとアテンション重みの可視化結果.

## 4. まとめ

本研究ではマルチモーダルゲーティングを利用した MoE 機構のリンパ腫分類モデルを提案した.提案手法では比較手法よりも高い分類精度を示し,また重みの可視化により各ネットワークの役割が適切に学習できていることを確認した.

#### 謝辞

本研究の一部は,科学研究費 (20H00601),JST CREST (JPMJCR21D3, JPMJCR22N2),JST ムーンショット型研究開発 事業 (JPMJMS2033-05),JST AIP 加速研究 (JPMJCR21U2), NEDO (JPNP18002, JPNP20006),理化学研究所革新知能統合研 究センターの補助を受けて行われた.

#### 利益相反の有無

なし

## 文 献

- Jacobs RA, Jordan MI, Nowlan SJ, and et al.: Adaptive mixtures of local experts. Neural Computation, 3: 79–87, 1991.
- [2] Ilse M, Tomczak J and Welling M: Attention-based deep multiple instance learning. Proc. ICML, 2127–2136, 2018.

## Contrastive Learning を用いた甲状腺組織画像の識別と学習に有用なデータ拡張の検討

奥住 航大<sup>\*1</sup>, 間普 真吾<sup>\*1</sup>, 八田 聡美<sup>\*2,3</sup>, 稲井 邦博<sup>\*2</sup>, 樋口 翔平<sup>\*2,4</sup>, 木戸 尚治<sup>\*5</sup>

\*1 山口大学大学院創成科学研究科

\*2 福井大学医学部病因病態医学講座分子病理学

\*3 福井大学医学部附属病院病理診断科/病理部

\*4 福井県立病院病理診断科

\*5 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

Classification of Thyroid Tissue Images Using Contrastive Learning and Examination of Effective Data

## Augmentation for Learning

Kodai UOZUMI<sup>\*1</sup>, Shingo MABU<sup>\*1</sup>, Satomi HATTA<sup>\*2,3</sup>, Kunihiro INAI<sup>\*2</sup>, Shohei HIGUCHI<sup>\*2,4</sup>, Shoji KIDO<sup>\*5</sup>

\*1 Yamaguchi University
 \*2 University of Fukui
 \*3 University of Fukui Hospital
 \*4 Fukui Prefectural Hospital
 \*5 Osaka University

要旨:本研究では, HE 染色が行われた甲状腺組織画像における癌の種類(組織型)を深層学習で識別することを目的としているが, 染色を行う施設の染色液組成や,標本作成における様々な過程によって特徴(色調)が異なり,識別に悪影響を与えることがある. したがって,染色条件による特徴の違いによらず,癌を識別するための本質的な特徴を捉える必要があり,本研究では,対照学習 (Contrastive Learning) 適用の効果を検証した.具体的には,識別問題で一般に用いられる Cross-Entropy Loss と教師あり学習型 Contrastive Learning である Supervised Contrastive Learning を甲状腺組織画像の識別タスクに適用し,単一のドメイン画像を使用した 場合や,複数の異なるドメイン画像を使用した場合,学習データとテストデータのドメインが異なる場合において,Contrastive Learning の有用性を検証した.また,Contrastive Learning で必要になるデータ拡張において,複数の拡張法を適用しそれらの有用性 を検証した.

キーワード:深層学習,対照学習,甲状腺組織画像,識別,データ拡張

## 1. はじめに

本研究では、Contrastive Learning (CL)を応用して、甲状腺組 織画像における様々な癌の種類を識別する研究を行う.甲状腺 組織画像は、取得した環境や染色を行う過程によって特徴が異 なり、識別に悪影響を与える.このような染色条件による特徴 の違いによらず、癌を識別するための本質的な特徴を捉えるこ とが重要である.CLでは、似ているデータは似た特徴ベクト ルになり、異なるデータは異なる特徴ベクトルになるように学 習でき、識別性の高い、本質的な特徴量の抽出が可能となる. 本研究では教師あり学習型の Supervised Contrastive Learning (SCL)[1]を使用することで、ラベル情報を活用してより識別性 の高い特徴量の獲得を目指す.また、CLではデータ拡張(人 工的な色調変換、画像処理)が必要であるが、どのようなデー タ拡張が有用であるかも検証する.

## 2. 方法

CL モデルの構成を図 1 に示す.大きく分けて, Encoder, Projector, Classifier からなる. CL モデルの学習は次の 2STEP

で行う.

- Encoder と Projector を用いて特徴ベクトルを抽出し, Supervised Contrastive Loss (SupCon Loss)を用いてネッ トワークの学習を行う.
- Encoder と Classifier を用いて画像分類を行う.この際, Encoder には STEP1 で学習済みの重みを使用し, Classifier の重みのみを一般的な Cross-Entropy Loss (CE Loss)による学習で更新する.



CL における Encoder と Classifier 全体を初めから学習させる CE モデルとの性能比較を行い、甲状腺組織画像の識別タスク における CL の有用性を検証する.

また, CL の学習に役立つデータ拡張方法を検証した.全ての実験でデータ拡張として,

- ランダムな上下左右反転
- ±90°以内のランダムな回転
- 色調変換

を行った.また,色調変換については,変換なしと7通りの変換の条件で各実験を行い,性能比較を行った.

- (a) 色調変換無し
- (b) l(255 に固定), a(±32), b(±32)変換
- (c) グレースケール変換
- (d) H(±23), S(±5), V(±5)変換
- (e) B(±16), G(±16), R(変化なし)変換
- (f) 濾胞癌,低分化癌は(b),乳頭癌は(e),その他のクラ スは(d)の色調変換
- (g) 濾胞型乳頭癌,正常,乳頭癌は(d),その他のクラス は(e)の色調変換
- (h) 画像ごとに、(b)~(e)からランダムに1つ選ぶ

#### 3. 実験

#### 3.1 実験概要

本研究で使用するデータは福井大学医学部で倫理審査(番号 20200084)を受けて提供された甲状腺組織画像セットで,福井 大学医学部附属病院と3市中病院(福井赤十字病院,舞鶴共済 病院,福井勝山総合病院),並びに市販のtissue array (TA)画 像が含まれている.データの分割方法は,同一症例のパッチ画 像が訓練データとテストデータに分割されないようにし,症例 の割合が訓練8割,テスト2割になるように分割した.本研究 では,4つの実験を行った.

- 実験(1): 福井大学症例のみで, 訓練データとテストデータに 分割し, CL モデルと CE モデルの性能を比較した.
- 実験(2): 実験(1)のデータに, 凍結標本を訓練データとテスト データに分割したデータを加え, CL モデルと CE モデ ルの性能を比較した.
- 実験(3): 実験(2)で構築したモデルを,他の病院(ドメイン) で取得された画像の識別に適用し,CLモデルとCEモ デルの性能を比較した.
- 実験(4): 実験(2)のデータに, TA, 3 市中病院データについて 訓練データとテストデータに分割したものを加えて, CL モデルと CE モデルの性能を比較した.

## 3.2 実験結果

表1 各実験の最も高い Accuracy[%]とその色調変換

	実験(1)	実験(2)	実験(3)	実験(4)
CE	58.23(g)	56.32(e)	30.62(h)	61.18(h)
CL	65.31(f)	58.75(e)	35.04(b)	65.42(a)
*CE It Cro	ss-Entrony 手	デル CLけ	Contractive I	earning モデ

\*CE (I Cross-Entropy  $\pm \gamma \nu$ , CL (I Contrastive Learning  $\pm \gamma$  $\nu$ 

実験結果を表1に示す.CEとCLを比較すると,全ての実 験において,CLのAccuracyがCEを上回った.したがって, CLは甲状腺組織画像の識別タスクに対して,有用であると言 える.しかし,実験(3)の結果より,学習とテストに異なるドメ インのデータを用いた場合は,他の実験と比較して性能が悪く なった.これは、ドメイン間を超える本質的な特徴量の獲得ま ではできていない可能性を示しており,未学習のドメインのデ ータに対しても有用なモデルとするためには,改良が必要であ ると考えられる.また,実験(1)では(f)の色調変換が,実験(2) では(e)の色調変換が,実験(3)では(b)の色調変換が,実験(4)で は(a)の色調変換が有用である結果となった.したがって,データ の特徴と有用な色調変換の関係について検討の余地がある.

## 4. まとめと今後の課題

本論文では、甲状腺組織画像の識別タスクに CL を適用する ことで、識別性能が向上することを明らかにした.また、単一 のドメインを使用した場合や複数の異なるドメインを使用し た場合、学習データとテストデータのドメインが異なる場合に おいて、どのような色調変換が有用であるかを明らかにした. 今後の課題として、未学習のドメインのデータに対しても有用 なモデルに改良すること、データの特徴を考慮して有用な色調 変換を検討していくことが挙げられる.

#### 謝辞

本研究は JSPS 科研費 JP21H03840, JP22K12152 の助成を受けたものです.

#### 利益相反の有無

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 講座は,富士フイルム株式会社との共同研究講座です.

#### 文 献

[1] Prannay Khosla, Piotr Teterwak, Chen Wang, Aaron Sarna, Yonglong Tian, Phillip Isola, Aaron Maschinot, Ce Liu, and Dilip Krishnan. Supervised contrastive learning. In Advances in Neural Information Processing Systems, Vol. 33, pp. 18661–18673. Curran Associates, Inc., 2020.

## CEA 術後病理画像を用いた異常検知による循環器病発症予測

石田 修也\*1,盛田 健人\*1,2,連 乃駿\*2,渡辺 翔吾\*2,

小橋 昌司\*2,3, 畠山 金太\*2, 飯原 弘二\*2, 若林 哲史\*1

\*1 三重大学大学院工学研究科情報工学専攻

\*2 国立循環器病研究センター

\*3 兵庫県立大学大学院工学研究科電子情報工学専攻

Post-operative prognosis estimation using anomaly detection and

## pathological image of CEA patients

Shuya ISHIDA<sup>\*1</sup>, Kento MORITA<sup>\*1,2</sup>, Nice REN<sup>\*2</sup>, Shogo WATANABE<sup>\*2</sup>,

Svoji KOBASHI<sup>\*2,3</sup>, Kinta HATAKEYAMA<sup>\*2</sup>, Koji IIHARA<sup>\*2</sup>, Tetsushi WAKABAYASHI<sup>\*1</sup>

<sup>\*1</sup> Graduate School of Engineering, Mie University

\*2National Cerebral and Cardiovascular Center

\*3 Graduate School of Engineering, University of Hyogo

要旨: 頸動脈狭窄に対する脳梗塞予防の外科的治療として, 頸動脈内膜剥離術(CEA)が行われてきた. CEA により取得された頸動 脈プラーク病理画像が全身の動脈硬化性病変の指標として,新たな脳卒中の発症や他の循環器病の発症の関連を検討した研究はない.本研究では頸動脈プラーク病理画像を形態的に分類・解析し,全身血管病との関連や長期予後の推定を目指す.本研究ではf-AnoGAN を用いた異常検知により CEA 患者の術後1年以内の脳卒中や循環器病の発生の有無を推定した.結果として, ROC-AUC は術 直後の新規脳梗塞に対して 0.753,退院後1年以内の脳梗塞及び心筋梗塞の発生に対してそれぞれ,0.60,0.659の予測精度を有し ていた.異常度を可視化したヒートマップは病理医の知見とも一致し,循環器病の発生と関連する病理学的特徴との関連が示唆さ れた.

キーワード:異常検知,病理画像,予後予測,頸動脈内膜剥離術,深層学習

#### 1. はじめに

循環器領域の重大な合併症として心筋梗塞や脳梗塞は死因の上位を占めており、その病態の解明と予防・治療法の確立に向け様々な研究がなされている. 頸動脈内膜剥離術 (Carotid Endarterectomy, CEA) は頸動脈狭窄に対する脳梗塞予防を目的とした外科的治療である. 近年の AI 技術の発展により、がん腫瘍の病理画像から畳み込みニューラルネットワーク

(Convolutional Neural Network, CNN)を用いて患者の長期予後 を予測できることが示されているが[1], 頸動脈プラークにお ける病理画像と脳卒中を含む循環器病の発生を検討した報告 はない.本研究では CEA 術後の頸動脈プラークの病理画像を 解析し, f-AnoGAN を用いて異常検知を行い,術後1年以内の 循環器病の発症の有無を推定する方法を提案する.

## 2. データセット

本研究では国立循環器病研究センターから提供された病理 画像を用いる. CEA 術後1年以内の脳卒中及び心筋梗塞のイ ベント(術直後の脳梗塞[DWI]、退院後の脳梗塞及び心筋梗塞 の発生)の有無に対して、イベントの非発生例を正常データと 定義し、イベントが発生した患者を異常データとする.本研究 の実施は国立循環器病研究センター倫理委員会にて承認済み である.

#### 3. 提案手法

本研究では、正常患者の画像のみで学習を行い、異常検知を 用いてCEA術後1年以内の循環器病の発症の有無を推定する. ここで、異常検知とは大多数のデータとは振る舞いが異なるデ ータを検出する仕組みのことであり、正常データのみで学習を 行うため、異常データが少ない場合に有用である.異常検知に はAnoGAN[2]を高速化した手法である f-AnoGAN[3]を用いる.

提案法では,病理画像から組織部分をセグメントし,256× 256のパッチ画像に分割する.その後,f-AnoGANを用いて学 習・テストし,異常スコアを算出する.算出した異常スコアを 元に患者ごとのスコアを算出し,ROC-AUCを求める.

## 3.1 f-AnoGAN

AnoGAN とは GAN を異常検知に適応したものであり, GAN の学 習済みモデルを使用してテスト画像に類似した画像を生成さ せる.この生成された画像とテスト画像を比較し,その差が大 きければ異常,小さければ正常とみなされる.AnoGAN は推論 時に時間がかかる問題点がある.これに対し f-AnoGAN は, GAN を学習した後,学習した GAN のモデルを用いてエンコーダの学 習を追加で行うことによって推論の高速化を図っている.

## 3.2 異常スコア

パッチ1枚当たりの異常スコア*A*(*x*)は式(1)によって求める. 画像の差分と Discriminator の中間層の特徴量の差を足し合わせている.

$$A(x) = \frac{1}{n} |x - G(E(x))|^2 + \frac{1}{n_d} |f(x) - f(G(E(x)))|^2$$
(1)

ただし、xはテスト画像、G(E(x))は生成画像、nは総画素数、  $f(\cdot)$ はDiscriminatorの中間層の次元数である.また、患者ご とのスコア $A_n$ を式(2)によって求める.

$$A_P = \frac{\Sigma_{x \in X} A(x)}{|X|} \tag{2}$$

なお,Xは異常スコア算出対象のパッチ群である.

#### 4. 実験

#### 4.1 実験データと評価指標

本実験では、ヘマトキシリン・エオジン染色された病理画像 を用いる.実験に用いたデータの内訳を表1に示す.評価指標 には、ROC-AUC および Youden Index によって決定された閾値 から計算された Precision, Recall, F 値を用いる.

ま 1・ 宝融データ

	₫ I:	天映ノーノ	
	長期予後	WSI(枚)	パッチ(枚)
学習	正常	30	226, 335
	正常	20	189, 723
テフト	異常(DWI)	16	140, 118
) ~ r	異常(心筋梗塞)	11	88, 337
	異常(脳梗塞)	4	24, 557

#### 4.2 実験結果

正常患者と DWI・心筋梗塞・脳梗塞の 3 つに対する ROC-AUC および, Recall, Precision, F 値をそれぞれ表 2 に示す. ROC-AUC は DWI と心筋梗塞, 脳梗塞に対してはそれぞれ 0.753, 0.659, 0.6 となり, F 値はそれぞれ 0.722, 0.6, 0.667 と なった.また,実験で得られた異常スコアをもとに,病理画像 上での異常度が高い箇所を可視化するヒートマップを作成した.異常度が高い場所ほど明るくなっている.図1に示す DWI 患者の病理画像と対応するヒートマップから,緑色で囲んだリンパ球浸潤や黄色で囲んだプラーク出血の存在する部位でヒートマップ値が高くなっており,これらは病理医の知見とも一致した.

	表	き 2: 実験	検結果	
	ROC-AUC	Recall	Precision	F 値
DWI	0.753	0.765	0.684	0.722
心筋梗塞	0.659	0.545	0.667	0.600
脳梗塞	0.600	0.500	1.000	0.667



図 1: DWI 患者の病理画像とヒートマップ 緑色の円はリンパ球浸潤のある箇所, 黄色の円はプラー ク出血のある箇所である.

#### 5. 結論と今後の予定

本研究では、f-AnoGAN を用いた異常検知によって CEA 術後 1年以内の循環器病の発症の有無を推定した.結果として,DWI, 心筋梗塞,脳梗塞の ROC-ACU はそれぞれ 0.753, 0.659, 0.6 と なった.また,作成したヒートマップは病理医の知見とも一致 し,循環器病の発生と関連する病理学的特徴との関連が示唆さ れた.

今後は、病理組織の分布を考慮した患者ごとのスコアの算出 方法を検討する.具体的には、f-AnoGANのエンコーダの出力 をクラスタリングすることによって、病理組織を領域分割し、 領域ごとにスコアの重みづけを行う等の方法を検討する.

#### 利益相反の有無

本研究の一部は㈱イドルシア ファーマシューティカルズジャ パンの研究助成金を得て実施された.

## 文 献

- P. Mobadersany, S. Yousefi, M. Amgad et al: Predicting cancer outcomes from histology and genomics using convolutional networks. Proceedings of the National Academy of Sciences, Vol.115, No.13, ppE2970–E2979, 2018.
- [2] T. Schlegl, P. Seebo ck, S. M. Waldstein et al: Unsupervised anomaly detection with generative adversarial networks to guide marker discovery. Information Processing in Medical Imaging, 2017.
- [3] T. Schlegl, P. Seebock, S. M. Waldstein et al: f-AnoGAN: Fast unsupervised anomaly detection with generative adversarial networks. Medical Image Analysis, Vol. 54, pp30–44, 2019.

## Automatic ROI Selection for Color Unmixing in High-resolution H&E-stained Whole Slide Images

Yinan YANG<sup>\*1</sup>, Saori TAKEYAMA<sup>\*1</sup>, Masahiro YAMAGUCHI<sup>\*1</sup>

\*1 Tokyo Institute of Technology

Abstract : In the adaption of computer-aided diagnosis algorithms to digital pathology, whole slide images (WSIs) from different sources and staining processes cause color variations that affect the accuracy. Although blind color deconvolution (BCD) methods have been developed and applied to consistent color reproduction, the selection method of regions of interest (ROIs) among image tiles in a WSI for BCD has not been investigated until now. In this paper, we present a method for automatically selecting the ROI suitable for the color correction of the WSI. We design an evaluation function to generate a score label for each tile, indicating its suitability for the entire WSI color unmixing. Based on the score for each tile, it becomes possible to automatically select ROIs suitable for WSI color unmixing.

Keywords : Automatic ROI selection, WSI, Color Unmixing, Computational Pathology, H&E staining

#### 1. Introduction

With the digitalization of histopathology specimens, the advent of a whole slide image (WSI) scanner enabled high-resolution sample scanning and displaying. It has also facilitated the development of computer-aided-diagnosis (CAD) approaches in pathology diagnosis. Histopathology specimens are stained for visualization, and the Hematoxylin-Eosin (H&E) staining is routinely used. However, the staining process is prone to variability, resulting in different color appearances. The characteristics of WSI scanners are also device dependent. Those color variations affect the accuracy of CAD algorithms. Therefore, some means of compensation, color unmixing, or normalization are crucial for the implementation of CAD [1].

Many color unmixing algorithms based on stain abundance estimation have been developed. Based on the color-unmixing method proposed by Ruifrok et al. [2], the amount of stain is determined with optical density (OD) according to Lambert-Beer law, and the OD of each pixel for each channel can be modeled as the linear combination of the H and E stain vectors in RGB space. The  $3 \times 2$  OD matrix of two representative stains (H and E) is called stain matrix M, hereafter. Recently, techniques for blind stain matrix estimation have also been proposed [3,4], in which the colors of H and E stains are estimated. For example, the BKSVD (Bayesian K-SVD) model for M matrix estimation [4] exhibits good performance. The obtained stain matrix can be used for color correction.

Since a WSI is large (gigapixel-level), we need to slice it into small tiles to use as the input to the algorithms. However, if the stain matrix is estimated in each tile for color correction, different correction parameters could be used depending on the tiles, even though the staining parameters should not vary within a single slide. Therefore, suitable regions of interest (ROIs) for color unmixing of a WSI need to be selected. In [5], the automatic ROI selection suitable for color correction was implemented, but it was specially designed for liver specimens and may not work properly in some different

#### organs.

In this paper, we propose an automatic tile selection algorithm for color unmixing of a WSI. It scores each tile and selects the most suitable tiles as ROIs for M matrix estimation and entire WSI color unmixing. The proposed method can be used independently on the organs for color unmixing algorithms.

#### 2. Proposed Method



Fig. 1 The overview of proposed method.

Figure 1 shows the overview of the proposed method. The stain vectors (M matrix) are estimated by BKSVD unmixing from each tile in the WSI. An assessment function is set based on prior knowledge for ROI selection. It consists of two scores, and the corresponding scores are generated for each M matrix based on its color-unmixing results of all the other tiles sliced from WSI. The ROIs with low F-scores are selected.

#### 2.1 S score: the off-set degree in abundance map

Using the estimated H and E stain vectors, we can calculate the abundance map consisting of the two stain amounts of all pixels. If the M matrix is suitable for the color unmixing of a tile, the distribution of points in the abundance map will be closer to the H and E color vectors. Fig 2 shows the distribution of the abundance map.  $\theta_E$  and  $\theta_H$  are angles between the two axes. Therefore, the

off-set degree  $S_i$  for the *j*-th tile can be expressed as:



Fig 2. The distribution of pixels in the abundance map.

#### 2.2 A score: the off-plane degree in OD

We design A score based on the component of residual in OD space. The residual vector is defined as the outer product of the H and E vectors in the M matrix, so that it does not contain the components of the H and E vectors. If M is chosen more appropriately, the value of the residual component of the pixel point after projection is smaller. Therefore, the deviation  $A_i$  for *j*-th tile can be expressed as:

$$A_{i} = \text{Average}\{|\text{Residual}|\}$$
(2)

#### 2.3 Overall F score for assessment

We use the M matrix to do color unmixing for all tiles. The overall S and A for an M matrix estimated from a tile are defined as:

$$S_t = \sum_{j=1}^m S_j, \qquad A_t = \sum_{j=1}^m A_j$$
, (3)

where t is the index of a tile used for M matrix estimation and m is the number of tiles, respectively. The overall F score for each M matrix is defined as,

$$F_t = \alpha A_t + \beta S_t \tag{4}$$

where  $\alpha$  and  $\beta$  are constants for normalization. The M with the smallest F score is the most suitable stain matrix for color unmixing within one WSI.

#### 4. Experiment and Results

The WSIs we used for the experiment were H&E-stained liver tissue scanned by Pannoramic DESK II under 40x magnification. Around 10% of tiles (234, 1024\*1024 pixels) from one WSI were randomly selected as an experiment dataset.

By comparing the F score of each M matrix, the most and least suitable tiles for color unmixing of the dataset are selected, and their comparison of the color unmixing is shown in Figure 3. The most suitable M matrix retained more complete color and structural information, while the least suitable M matrix had a severe distortion in color, especially since the H channel representing the nucleus could not be accurately separated from the cytoplasm.



(c) E channel by least suitable M.

Additionally, the result was compared with the manual selection of pure nucleus and cytoplasm. The M matrix calculated from single stained WSIs is also depicted in Fig. 4. The vectors computed by F score are more stable and closer to the single stain cases than those obtained by manual selection.



Fig 4. The color vectors comparison of F score and manual tile selection with ground truth.

#### 5. Conclusion

We developed an algorithm that automatically selects ROIs for estimating the M matrix suitable for color unmixing of all images within a WSI. The color separation results can be used for color correction to further refine the WSI preprocessing pipeline. In the future, we will try to analyze the accuracy and applicability of the color normalization results on different tissue datasets.

This work was conducted in part under the project JPNP20006, subsidized by the New Energy and Industrial Technology Development Organization (NEDO).

#### References

- [1] Yagi Y: Color standardization and optimization in whole slide imaging. Diagnostic pathology 6, 2011, 1-12.
- [2] Ruifrok A C, Johnston D A: Quantification of histochemical staining by color deconvolution. Analytical and Quantitative Cytology and Histology 23 (4), 2001. 291-299
- [3] Zheng Y, Jiang Z, Zhang H, et al.: Adaptive color deconvolution for histological WSI normalization. Computer Methods and Programs in Biomedicine 170, 2019, 107-120,
- [4] Pérez-Bueno F, Serra J G, Vega M, et al.: Bayesian K-SVD for H and E blind color deconvolution. Applications to stain normalization, data augmentation and cancer classification. Computerized Medical Imaging and Graphics 97, 2022,102048.
- [5] Murakami Y, Abe T, Yamashita Y., et. al.: Color processing in pathology image analysis system for liver biopsy. Proc. IS&T 22nd Color and Imaging Conf., 2014, 184-188.

## 高空間分解能位相コントラスト CT を得るための X 線回折波 2 重撮影法の開発

砂口 尚輝<sup>\*1</sup>,湯浅 哲也<sup>\*2</sup>,島雄 大介<sup>\*3</sup>,黄 卓然<sup>\*1</sup>,市原 周<sup>\*4</sup>

西村 理恵子<sup>\*4</sup>, 岩越 朱里<sup>\*4</sup>, Jong-Ki Kim<sup>\*5</sup>, Rajiv Gupta<sup>\*6</sup>, 安藤 正海<sup>\*7</sup>

\*1 名古屋大学大学院医学系研究科総合保健学専攻

\*3 大阪物療大学

\*4 名古屋医療センター

\*6 マサチューセッツ総合病院

\*<sup>7</sup> 高エネルギー加速器研究機構

# Superimposed wavefront imaging of diffraction-enhanced x-rays to obtain phase-contrast CT with high spatial resolution

Naoki SUNAGUCHI<sup>\*1</sup>, Tetsuya YUASA<sup>\*2</sup>, Daisuke SHIMAO<sup>\*3</sup>, Zhuoran HUANG<sup>\*1</sup>,

Shu ICHIHARA<sup>\*4</sup>, Rieko NISHIMURA<sup>\*4</sup>, Akari IWAKOSHI<sup>\*4</sup>, Jong-Ki Kim<sup>\*5</sup>, Rajiv GUPTA<sup>\*6</sup>,

Masami ANDO<sup>\*7</sup>

<sup>\*1</sup> Nagoya University, <sup>\*2</sup> Yamagata University, <sup>\*3</sup> Butsuryo College of Osaka,

<sup>\*4</sup> Nagoya Medical Center, <sup>\*5</sup> Daegu Catholic University,

<sup>\*6</sup> Massachusetts General Hospital, <sup>\*7</sup> High Energy Accelerator Research Organization

要旨:高輝度な放射光 X 線を用いる位相コントラスト CT は生体軟組織を高コントラストに撮像できるため、様々な生体試料における微小解剖構造の可視化に利用されてきた.しかし、これまでに提案されている位相コントラスト CT の撮像方式は、原理的に被写体と X 線カメラの間に一定の空間を必要とするため、被写体と X 線カメラの距離を接近させて半影によるボケの影響を小さくすることできず、高空間分解能化が困難であった.本研究では、位相コントラストを生成する Laue 型 Si 角度アナライザーと X 線を可視光に変換するシンチレータを密着させて位相コントラスト像を得る X 線回折波 2 重撮影法(SWIDeX: Superimposed wavefront imaging of diffraction-enhanced x-rays)を提案した.この方式により、被写体と X 線カメラの間の空間が不要になり、従来法と比べて高い空間分解能が得られた.

キーワード:位相コントラストX線CT, Laue型屈折角アナライザー,生体試料計測,SWIDeX,放射光

#### 1. はじめに

X線の位相情報を用いる位相コントラストCT は軽元素の物 質に非常に高い感度を持つため,軽元素で構成される生体軟組 織に高いコントラストを生成する.この特徴を利用した様々な 位相コントラスト撮像法が提案されており,医学応用のための 開発が進められている[1]. 我々の研究グループでは,X線暗視 野法(XDFI: X-ray Dark Field Imaging)を開発し,染色した病理像 に迫るコントラストと空間分解能を持った3次元X線イメー ジングを確立した[2,3].一方で,これまで提案されている撮像 手法は,被写体と検出器の間に空間を設ける必要があった.例 えば,XDFI 法では光学系に利用される Si 単結晶の後方でX線 ビームが2方向に回折するため,2方向のビームが重ならない

所属:名古屋大学大学院医学系研究科総合保健学専攻

住所:〒461-8673 愛知県名古屋市東区大幸南1-1-20名古屋 大学大幸キャンパス

e-mail : sunaguchi@met.nagoya-u.ac.jp

位置まで検出器を離す必要があった.一般的に,光源と被写体 までの距離と被写体と検出器の間の距離の比は,X線像に生じ る被写体のボケの大きさに関係するため,高い空間分解能を実 現するには被写体と検出器の間の距離を極力短くする必要が ある.本研究では,被写体と検出器の間の距離を最小にできる 新しい位相コントラスト撮像法を提案する.我々はこの提案手 法を X線回折波 2 重撮影法(SWIDeX: Superimposed wavefront imaging of diffraction-enhanced x-rays)と呼ぶ.ここで,SWIDeX の撮像原理を数学的に記述し,SWIDeX 法が従来の XDFI 法よ りも高い空間分解能が得られることを示す.また,非浸潤性乳 管癌を含むヒト乳腺組織を撮影し,SWIDeX 法を用いて乳管癌 の詳細構造が描出できることを示す.

#### 2. SWIDeX 法の撮像原理

図 1 は XDFI と SWIDeX の撮像原理を表す概要図である. ある屈折率分布δ(x, y)を持つ被写体には, xy 座標系と, xy 座



図1 XDFIと SWIDeX の撮像ジオメトリ

標系をφ回転した pq 座標系が設定されている. 被写体上を p 軸 に平行な X 線ビームが入射すると, X 線は被写体内のδ(x, y) に従って屈折しながら伝搬する,被写体後方に設置された Laue 型角度アナライザー(LAA: Laue-case Angle Analyzer)では, およそ Bragg 角 $\theta_B$ で X線が入射すると LAA 背面で 2 方向にビ ームが分かれる.ここで、入射 X 線と同じ方向に回折する X 線を前方回折(FD: Forward-diffraction)X線, 20<sub>B</sub>方向に回折する X 線を回折(D: Diffraction)X 線と呼ぶ. それぞれの回折強度は θ<sub>B</sub>付近における約 10<sup>-6</sup> ラジアン内の急峻な回折強度勾配に従 うため、LAA は被写体で生じた僅かなビームの角度偏差(約 10-7~8 ラジアン)を回折強度の情報(屈折コントラスト)に変え ることができる. XDFI では, FD 像と D 像が重ならない q 軸 に平行になるような位置に X 線検出器を設置して, 被写体の 屈折コントラスト像を取得していた. これに対して, SWIDeX では、LAAの直後に検出器を配置して、FD像とD像が重なっ た状態で撮像する.本研究では、この画像からδ(x,y)の分布を 再構成するために必要となる SWIDeX の投影像と $\delta(x, y)$ の関 係(ラドン変換)を明らかにした.

# $M(q) = C\Delta q \int_{-\infty}^{\infty} \frac{\partial^2 \delta(p,q)}{\partial q^2} dp + I_0.$

ここで, *C*は回折強度勾配,  $\Delta q$ は FD 像と D 像のずれ量, *I*<sub>0</sub>は 入射 X 線強度である. SWIDeX の投影は $\delta(x, y)$ の 2 階微分投 影像であり, CT を再構成することでラプラシアン画像 $\Delta\delta(x, y)$ が得られる.また, Successive over-relaxed (SOR)法などで, ポ アソン方程式( $\partial^2/\partial x^2 + \partial^2/\partial y^2$ ) $\delta(x, y) = \Delta\delta(x, y)$ を解くこと で, 被写体の屈折率分布 $\delta(x, y)$ を求めることができる.

#### 3. SWIDeX 法と XDFI 法の比較実験

SWIDeX 法と従来の XDFI 法の空間分解能を比較するため に、SWIDeX 法に基づく屈折コントラスト CT システムを高エ 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 ラインに構築し、非浸潤性乳管癌を含む乳房組織が撮影した.

#### 4. 結果

図4は非浸潤性乳管癌組織のCT再構成像であり,(a),(b),(c)



(a) (b) (c) 図 4 非浸潤性乳管癌組織の CT 像. (a)XDFI による屈折率分 布, (b) SWIDeX による屈折率分布, (c)SWIDeX による屈折率 分布のラプラシアン.

はそれぞれ XDFI 法による屈折率分布, SWIDeX 法による屈折 率分布, SWIDeX 法による屈折率分布のラプラシアン像に対応 する. すべての画像で拡張した乳管内に非浸潤性乳管癌が増殖 している様子を確認できた.図4(c)のラプラシアン像では組織 のエッジ成分のみが描出されているが, SOR 法を適用するこ とで屈折率分布に従った明暗が図4(b)のように付加された. XDFI と SWIDeX の比較では, SWIDeX が XDFI よりも組織構 造の輪郭, 非浸潤性乳管癌内の腺腔構造, 乳管外の線維構造な どを鮮明に描出できた.SWIDeX と XDFI の撮像条件の違いは, LAA とシンチレータ間の距離だけであり, この距離を短縮す ることで CT 像の空間分解能を向上できることが示された.

#### 5. まとめ

本研究では、LAA で回折した FD と D の像を重ねて撮影す る新しい屈折コントラスト CT 撮像法 SWIDeX を提案した. 今 後、LAA の薄膜化を進め、より高い空間分解能で生体組織の 微細解剖構造を明らかにする環境を整える予定である.

#### 謝辞

2023 年 5 月 1 日にご逝去された高エネルギー加速器研究機 構名誉教授安藤正海先生には、本研究を含めて放射光 X 線イ メージングの開発に多大なる貢献をしていただきました.ここ で深くご冥福をお祈りいたします.本研究は JSPS 科研費 18K13765, and 21K04077,知の拠点あいち・重点研究プロジェ クト III 期,KEK 放射光実験課題 2020G583, 2021G587, 2022G626, 2022G651 の支援を受けています.

#### 利益相反の有無

なし

#### 文 献

- C. L. Walsh, P. Tafforeau, W. L. Wagner et al, Nature methods 18, 1532 (2021).
- [2] M. Ando, A. Maksimenko, H. Sugiyama et al, Jap. J. Appl. Phys. 41, L1016 (2002).
- [3] N. Sunaguchi, T. Yuasa, Q. Huo et al, Appl. Phys. Lett. 97, 153701 (2010).

## U-Net に逆投影演算を組み込んだ直接 PET 画像再構成法の提案

橋本 二三生\*1, 大手 希望\*1, 大西 佑弥\*1

\*1 浜松ホトニクス株式会社中央研究所

## Direct PET Image Reconstruction Using Back Projection-induced U-Net Architecture

Fumio HASHIMOTO<sup>\*1</sup>, Kibo OTE<sup>\*1</sup>, Yuya ONISHI<sup>\*1</sup>,

<sup>\*1</sup> Central Research Laboratory, Hamamatsu Photonics K.K.

要旨:計測データから深層学習技術を利用して直接断層像を生成する技術が,新しい画像再構成法として注目されている.これらの出力断層像は,一見すると正確な断層像が取得できているようにみえるが,空間的な対応関係がないサイノグラムから断層像への逆変換を,データ駆動で正確に獲得することは難しく,テストデータでは偽像が発生することがある.そこで本研究では,サイノグラムから断層像への逆投影を,U-Net のスキップ接続中に明示的に記述することで,偽像がない高品質な断層像が出力できる 直接画像再構成法を提案する.提案手法は,サイノグラム空間で表現されるエンコーダ部の特徴量を,スキップ接続内の逆投影演 算によって断層像空間で表現されるデコーダ部に接続することができ,入力サイノグラムからの正確な空間情報が保持できる.数 値実験の結果,提案手法は従来の直接画像再構成法と比べ,偽像の発生がなく高品質な断層像が取得できることがわかった. キーワード:直接画像再構成,Positron emission tomography(PET),深層学習,U-Net

## 1. はじめに

深層学習が Positron emission tomography (PET) 画像再構成 に応用されて久しい. 最近では, 深層学習を利用して計測サイ ノグラムから直接断層像を行う直接 PET 画像再構成が登場し [1,2], 次世代の画像再構成法として注目されている. これら の畳み込みニューラルネットワーク (CNN, convolutional neural network)を用いた直接画像再構成法は, 高速に断層像を推論・ 生成することができる一方で, サイノグラムから断層像への正 確な逆変換をデータ駆動で獲得することは難しく, Ground truth とは異なる構造を持つ, 「偽」の PET 画像が生成されるこ とがある.

そこで本研究では、U-Net 構造 [3] に逆投影演算を組み込ん だ新規アーキテクチャ、ReconU-Net による直接 PET 画像再構 成法を提案する. ReconU-Net は、逆投影演算をスキップ接続 に組み込むことで、サイノグラム-断層像の変換を明示的に記 述できる. そのため、これまでのデータ駆動型の直接画像再構 成法では困難であった、計測データに含まれる潜在的な空間情 報を保持しつつ、データ駆動での学習が可能となる.

#### 2. 方法

CNN を利用した直接 PET 画像再構成法 [2] は,以下の最適 化問題として記述できる.

$$\theta^* = \underset{\theta}{\operatorname{argmin}} \frac{1}{N} \sum_{i \in D} E(f(\theta_{Enc}, \theta_{Dec} | y_i); x_i), \qquad (1)$$

ここで、y、xは計測サイノグラム、断層像、fは学習可能な重み係数 $\theta_{Enc}$ 、 $\theta_{Dec}$ を持つエンコーダ-デコーダ型ネットワークである。Eは平均二乗誤差などの損失関数、DはサイズNのミニバッチサンプルである。CNNを利用した直接画像再構成では、文字通りエンコーダ部によってサイノグラムが符号化され、

デコーダ部によって断層像が復号される.言い換えると,エン コーダ部,デコーダ部はそれぞれ,サイノグラム空間,断層像 空間での処理が行われているため,エンコーダ部のサイノグラ ム空間情報を,U-Netのスキップ接続によってデコーダ部の断 層像空間へ渡すことはできない.

そこで本研究では、入力サイノグラムに内在している潜在的 な断層像空間情報を、エンコーダ部からデコーダ部へ転送でき る逆投影演算を組み込んだ新規アーキテクチャ、ReconU-Net を提案する.ReconU-Netアーキテクチャを図1に示す.ReconU-Net は、サイノグラム空間で表現されるエンコーダ部から、断 層像空間で表現されるデコーダ部への特徴量のスキップ接続 を、逆投影(BP, back projection)モジュールを利用して実現す る.BP モジュールは、PET 装置の物理的なモデルに従って実 装できるため、入力サイノグラムの正確な空間情報を保持しな がら直接画像再構成の学習が実行できる.

#### 3. 結果

頭部専用 PET 装置 [4] を想定したモンテカルロシミュレー ションを用いて, BrainWeb から 20 例の PET データを生成し, 学習,検証,テストデータをそれぞれ 18:1:1 に分割した. リストモードデータから,最大リング差±15 でシングルスラ イスリビニング法を用いて 2 次元サイノグラムを生成した.補 正は事前にサイノグラム空間で実施し,提案手法の性能を, maximum likelihood expectation maximization (MLEM)法および DeepPET 法 [2] と比較した.図 2 にシミュレーション結果を 示す.図 2 赤矢印で示すように,提案手法は DeepPET 法と比 べ,より Ground truth に近い構造を保持した断層像を生成でき た.また,提案手法が最も高い Peak signal-to-noise ratio (PSNR) を示し,定量的にも画像再構成性能が向上したことがわかった.



図1 ReconU-Net アーキテクチャの概要. ReconU-Net は, BP モジュールを利用して, サイノグラム空間で表現されるエンコー ダ部から, 断層像空間で表現されるデコーダ部へ接続する.



図2 シミュレーション結果.提案手法では、赤矢印で示す前頭葉などの微細な構造が復元できた.



図3 実測データでの再構成結果.

上記シミュレーションデータを用いて学習させたネットワ ークを,同一条件の頭部専用 PET 装置で撮像された[<sup>18</sup>F]BCPP-EF PET データに適用した.画像再構成結果を図3に示す.こ の結果は,実測データでの学習を必要とせず,シミュレーショ ンデータのみで学習させたネットワークを利用して,実測デー タの PET 画像を再構成できることを示した.

## 3. まとめ

本研究では、U-Net 構造に逆投影演算を組み込んだ ReconU-Net による直接 PET 画像再構成法を提案した.シミュレーショ ンおよび実測データによる実験の結果,提案手法はこれまでの 手法と比べ,より Ground truth に近い構造を保持した断層像を

# 生成できた.

## 謝辞

本研究は JSPS 科研費 JP22K07762 の助成を受けたものである.

## 利益相反の有無

なし

## 文 献

- Zhu B, Liu J, Cauley S et al: Image reconstruction by domain-transform manifold learning. Nature 555: 487-492, 2018
- [2] Häggström I, Schmidtlein CS, Campanella G et al: DeepPET: A deep encoder–decoder network for directly solving the PET image reconstruction inverse problem. Med Image Anal 54: 253-262, 2019
- [3] Ronneberger O, Fischer P, Brox T: U-net: convolutional networks for biomedical image segmentation. Int conference on medical image computing and computer-assisted intervention 234-241, 2015
- [4] Onishi Y, Isobe T, Ito M et al: Performance evaluation of dedicated brain PET scanner with motion correction system. Ann Nucl Med 36: 746-755, 2022

## 3 検出器 SPECT 装置の新たなステップ間隔によるデータ収集法の提案

皆川 智哉\*1,2, 堀 拳輔\*3,4, 橋本 雄幸\*2

\*1 東邦大学医療センター大橋病院放射線部

\*2 杏林大学大学院保健学研究科

\*3 順天堂大学保健医療学部

\*4 東京医科歯科大学大学院医歯学総合研究科

## Proposal of a new step-angle acquisition method for triple-detector SPECT systems

Tomoya MINAGAWA<sup>\*1,2</sup>, Kensuke HORI<sup>\*3,4</sup>, Takeyuki HASHIMOTO<sup>\*2</sup>

<sup>\*1</sup> Toho University Ohashi Medical Center

\*2 Kyorin University Graduate School of HealthSciences

\*<sup>3</sup> Juntendo University

<sup>\*4</sup> Tokyo Medical and Dental University Graduate School of Medical and Dental Sciences

要旨:SPECT において, off-set 収集は少ない投影数においても良好な画像が得られる収集法であるが, 検出器を 180°対向の位置 からずらす特別な機構が必要であるため臨床への応用は難しい. そこで本研究では, 特別な機構を必要としない 3 検出器 SPECT 装置における新たな収集法を提案し, その有用性について検討した.新たに提案する収集法は, 対向データを収集せず, サンプリン グする角度が等間隔になるように収集する方法である.散乱,減弱およびコリメータ開口を考慮したモンテカルロシミュレーションにより投影データを取得した後, ML-EM 法により再構成し, FWHM および NRMSE を用いて評価した.FWHM はどの収集法においても大きな差は見られなかったが, NRMSE では提案法が最良値を示した.提案法は, 効率的に投影データを収集することで最も精度の高い再構成画像を得ることができ,少数投影 SPECT において有用であった.

キーワード:少数投影 SPECT, off-step 収集, 奇数投影数

## 1. はじめに

SPECT (Single photon emission computed tomography)におい て,良好な画質を得るためには十分な総投影数やカウント数が 必要であるが,これらを達成するためには撮像に時間を要する. 総投影数が少ない場合でも良好な画像を得る方法が広く研究 されている [1,2]. その中でも off-set 収集は,総投影数を少な くすることができる方法の1つであり,検出器を対向位置から 少しずらすことで対向データを収集せず効率的に収集するこ とができる方法である [3,4]. しかし, off-set 収集は特別な機 構が必要であり,現在臨床において使用できる SPECT 装置は 存在しない. そこで本研究では,特別な機構を必要としない3 検出器 SPECT 装置における新たな収集法を提案し,その有効 性を検討した.

#### 2. 方法

本研究では off-step 収集と half-step 収集の 2 種類の方法を提 案し,従来の収集法である on-set 収集と比較した(図1). offstep 収集は, on-set 収集同様に検出器間の角度は 120°の等間 隔のまま,特定のステップにおいて通常のステップ角の 1.5 倍 で検出器を回転させる方法である.また, half-step 収集は onset 収集の step 角を半分にした方法である.

本研究では2種類の数値ファントム(線状ファントムおよび

円柱ファントム)と脳ファントム IB-20 Advanced (京都科学) を使用した (図 2).数値ファントムは直径 204.8 mm×高さ 32 mmの円柱が水で満たされていると仮定し,それぞれ円柱内に さらに小さい円柱状の線源を配置した.脳ファントムの内部を 脱気水で満たし SPECT/CT 装置 infinia8 Hawkeye (GE Healthcare, Milwaukee, USA)を用いて CT 画像を撮影し,モンテカルロシ ミュレーションの 1 つである SIMIND (simulation of imaging nuclear detectors)を用いて投影を作成した.SIMINDの投影作



**図1** 各収集法の概略図. ψ はステップ角,矢印はある線源から各検 出器に向かう投影線を示す.上段および下段はそれぞれ投影数が奇数 および偶数の場合を示す.



図2 ファントムの横断面.(a)線状ファントム,(b)円柱ファ ントム,(c)脳ファントム.括弧内は放射能濃度比を示す.脳 ファントムの放射能濃度比は左線条体:右線条体:脳実質:骨: 脳室=8:4:1:0.75:0となるように画素値を設定した.

成条件には、低エネルギー高分解能型コリメータを装着した GCA-9300R (キャノンメディカルシステムズ)を設定し、マト リクスサイズが 128×128 pixels、ピクセルサイズが 3.2 mm× 3.2 mm、総投影数が 9 から 51 の投影データを作成した. ML-EM (maximum likelihood-expectation maximization) 法で画像再 構成を行い、線状ファントムでは FWHM (full width at half maximum), 脳ファントムでは NRMSE (normalized root mean square error) で評価した. NRMSE の評価式を以下に示す.

NRMSE[%] =  $100 \times \sqrt{\sum_{j=1}^{N} (b_j - a_j)^2 / \sum_{j=1}^{N} a_j^2}$  (1) ここで、 $a_j$  および  $b_j$  はそれぞれ j 番目の画素における基準 画像および再構成画像の画素値である.

#### 3. 結果と考察

線条体ファントムによる FWHM は、全ての収集条件において 11.2~11.7 mm の範囲であり大きな差はなかった。先行研究 で off-set 収集は空間分解能の向上が示唆されていたが、off-step 収集や half-step 収集では見られなかった [3].

円柱ファントムの再構成画像および基準画像との差分画像 を図3に示す.また,脳ファントムにおけるNRMSEを図4に 示す.総投影数が奇数の場合のon-set 収集と,総投影数が偶数 の場合のoff-step 収集は対向データを収集せず効率的に投影デ ータを収集することができるため,他の収集法より基準画像に 近い再構成画像を得ることができた.一方で,half-step 収集は 投影方向が偏っていることから,特に円の辺縁において基準画 像との差が大きく再構成画像が歪んだ.このことから少数投影 SPECT において,投影方向に偏りが少なく,対向データを収 集せず効率的に投影データを収集する方法が適していると考 えられる.今後は圧縮センシングの併用により更なる画質の向 上及び総投影数の削減について検討する[4].

## 4. まとめ

少数投影 SPECT において,全体的にバランスがよく,かつ 対向データがない効率的な収集方法が有用であった.



図3 円柱ファントムの再構成画像と基準画像との差分画像.



**図4** 脳ファントムの NRMSE. 凡例の "odd" および "even" はそれぞれ総投影数が奇数および偶数であることを示す.

## 謝辞

本研究に際し,東邦大学医療センター大橋病院放射線部の皆 様のご協力に深く感謝いたします.

#### 利益相反の有無

筆頭著者および共著者全員が利益相反はない.

#### 文 献

- Cao Z, Holder L.E., Chen C.C. : Optimal number of views in 360 degrees SPECT imaging. J Nucl Med 37: 1740-1744, 1996
- [2] Matsutomo N, Fukaya K, Hashimoto T, Yamamoto T et al: Performance of compressed sensing-based iterative reconstruction for single-photon emission computed tomography from undersampled projection data: a simulation study in 1231-N-ω-fluoropropyl-2β-carbomethoxy-3β-(4-iodopheny) nortropane imaging, Nucl Med Commun 40: 106-114, 2018
- [3] Takahashi Y, Oriuchi N, Higashino H: Improvement of image resolution of brain SPECT by use of the wide-angle offset acquisition method. Ann Nucl Med 25: 69-74, 2011
- [4] Matsutomo N, Hashimoto T, Fukami M et al: Combination of compressed sensing-based iterative reconstruction and offset acquisition for I-123 FP-CIT SPECT: a simulation study. Asia Ocean J Nucl Med Biol 10: 117-125, 2022

モデルベース型深層学習画像再構成による MR 定量値マッピングの高速化の検討

藤田 直人\*1, 横沢 俊\*2, 白猪 亭\*2, 寺田 康彦\*1

\*1 筑波大学大学院 理工情報生命学術院 数理物質科学研究群

応用理工学学位プログラム電子・物理工学サブプログラム

\*2 富士フイルム株式会社 メディカルシステム開発センター

Model-based deep learning reconstruction for accelerating quantitative MR parameter mapping

Naoto Fujita<sup>1</sup>, Suguru Yokosawa<sup>2</sup>, Toru Shirai<sup>2</sup>, Yasuhiko Terada<sup>1</sup>

<sup>1</sup>Institute of Applied Physics, University of Tsukuba, Tsukuba, Japan

<sup>2</sup> FUJIFILM Corporation, Medical Systems Research & Development Center, Japan

要旨:組織や病変によって異なる定量値画像を得ることができる定量的 MRI は、多くの研究により診断に有用であると報告されている.しかし、定量的 MRI を行うには、複数の MR 画像が必要であるため、撮像に非常に時間がかかるという課題がある.一方、深層学習(deep learning, DL)を用いた MRI 撮像の高速化の研究が近年盛んである.中でも、既存の画像最構成モデルを DL で拡張したモデルベース型のネットワークモデルが、高い画像再構成性能をもつことが報告されている.そこで本研究では、モデルベース型 DL モデルである DC-CNN を、定量的 MRI に拡張した qDC-CNN を提案する. qDC-CNN は、定量値画像を直接出力するモデルであり、その損失項として、定量値画像から推定される rawdata と、測定された rawdata との整合性を評価する項を追加したものである.その結果、qDC-CNN は、既存の DL モデルや非 DL 法と比較して、かなり高い加速率下でも高い再構成性能を維持することが確認された.本研究により、定量的 MRI の更なる高速化の可能性を示された.

キーワード: Deep Learning, MRI Reconstruction, Quantitative MRI

## 1. はじめに

組織固有の物理パラメタの定量値画像を得ることができる 定量的 MRI は、多くの研究により診断に有用であると報告さ れている.一方、深層学習(deep learning, DL)を用いた MRI 撮像の高速化の研究が近年盛んである.中でも、既存の画像最 構成モデルを DL で拡張したモデルベース型のネットワーク モデルが、高い画像再構成性能をもつことが報告されている.

そこで本研究では,モデルベース型 DL モデルである Deep cascade of convolutional neural network (DC-CNN)[1]を,定量的 MRI に拡張した Quantitative DC-CNN (qDC-CNN)を提案し,そ の性能を検証することを目的とした.

#### 2. 理論

#### 2.1 定量的 MRI

MRI の撮像法の一つであるスピンエコー法における取得画像 x は、ノイズを考慮しない場合、(1)式のように決定される.

$$x = S(S_0, T_2) = S(p) = S_0 e^{-\frac{r_2}{T_2}}$$
(1)

ここで、TE はエコー時間 (echo time) であり、MRI の撮像パラ メタである.  $S_0 \ge T_2$ は、組織固有の物理パラメタで、 $p = (S_0, T_2)$ である. 一般に $S_0 \ge T_2$ の推定には、複数の TE 値の画像を取得 し、(1)式に基づいたフィッティングが行われる.本研究では、 各 TE の画像を取得する際の信号収集点数を減らすことによる MRI の高速化を実現する.

#### 2.2 qDC-CNN

図1に qDC-CNN のネットワーク構造を示す. qDC-CNN は,



図1 qDC-CNN のネットワーク構造

画像再構成を実行する unrolled network  $f_{rec}$ と, 再構成された 各 TE に対応する画像 $x_{rec}$ を定量値画像 $p_{rec}$ に変換する mapping network  $f_{map}$ の2つのモジュールからなる.

$$x_{rec} = f_{rec}(x_0) \tag{2}$$

$$p_{rec} = f_{map}(x_{rec}) \tag{3}$$

ここで、ネットワークの入力は $x_0 = (\hat{x}_{TE1}, \hat{x}_{TE2}, ..., \hat{x}_{TEn})$ であり、  $\hat{x}_{TEi}$ は、i番目の TE 値に対応するゼロフィル画像 (Zero-filled image, ZF image)である. このゼロフィル画像は、アンダーサ ンプリングされた k空間上のデータ(undersampled k-space data; US k-space data)  $\hat{y}$ に対し、k空間上の未収集点のデータを 0 で 置換した後、逆高速離散フーリエ変換 (IFFT) を行うことで得 られる.  $f_{rec}$ は、CNN 層とデータ整合(data-consistency)層を T 回 繰り返した構造をもつ. このデータ整合層は、計測データ (US k-space data) と、予測された $p_{rec}$ から逆算されたデータとを一 致させる働きをもつ. 我々は、DC-CNN を拡張してこの $f_{rec}$ を 構築した. frecの CNN は6 層から成り,フィルタ数を 64 とし た. fmapは、5層の CNN で構成された. この各層の CNN の カーネルサイズを1×1とすることで、ピクセル単位で定量値 を推定するようにした. fmapのチャンネル数は、入力層側から 32, 128, 128, 128, 3 であった. 各ネットワークの学習時には, 以下の3つの損失を使った.

$$L_r = \|x_{gt} - x_{rec}\|_2^2$$
(4)

$$L_p = \|p_{gt} - p_{rec}\|_2^2 \tag{5}$$

 $L_{dc} = \|\hat{y} - FFT(S(p_{rec}))\|_2^2$ (6)

ここで、 $L_r$ は各エコーの正解画像 $x_{gt}$ と $x_{rec}$ との差を評価する項、  $L_p$ は正解の定量マップ $p_{gt}$ と $p_{rec}$ との差を評価する項, $L_{dc}$ は再 構成された定量マップから推定される USk-space data と, 測定 データŷの整合性を評価する項の損失を使用した. これらの損 失に重みを次の式のようにつけ、ネットワークの学習を行った. 4)

$$L_{total} = \lambda_r L_r + \lambda_p L_p + \lambda_{dc} L_{dc} \tag{4}$$

$$\lambda_r = 1, \ \lambda_p = 1.0 \times 10^{-3}, \ \lambda_{dc} = 1.0 \times 10^{-6} \& L \&.$$

## 3. 実験方法

## 3.1 データセット

本研究では, 脳シミュレーション用のデータベース Brainweb[2]中のプロトン密度 $S_0$ 画像と $T_2$ 画像から、(1)式を使 ってS(p)を計算し、それをフーリエ変換して k-space データ (Fully-sampled (FS) k-space data) を作成した. TEを 10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150, 160 ms (計 16 個)とした. ネットワーク入力である US k-space data は, FS k-space data から遡及的なサンプリングにより作成した.信 号の収集パターン(Sampling pattern)はエコーごとに異なるも のを使用した.

## 3.2 比較モデル

以下に示す, (A)-(E)の再構成手法を比較した. ここで, LSF (least squares fitting)は最小二乗法によるフィッティングを表す.

- (A) qDC-CNN  $(f_{rec} + f_{map})$
- (B) MANTIS[3]
- (C) Multiecho-DC-CNN  $(f_{rec} \mathcal{O} \not\rightarrow)$ + LSF
- (D) k-t SLR[4] + LSF
- (E) Zero-filled reconstruction + LSF

(C)のモデルfrecは(4)式の損失関数のみを用いて学習した.(D) の k-t SLR は, DL を使わない既存手法である. (C)-(E)では, それぞれの再構成法で得られた  $x_{rec}$ から LSF を使って $p_{rec}$ を 計算した.

#### 3.3 学習条件

各モデルの学習用に 16 例 960 枚, 検証用に 2 例 120 枚, テ スト用に2例120枚の画像を使用した.信号の間引きによる MRI の加速率(Acceleration factor; AF)を5, 10, 20 とした. 各 ネットワークの学習率は、1.0×10<sup>-4</sup>で、Optimizer に Adam を 使用した. また,学習の収束判定に early stopping を用い, 検証データの損失が10 epoch以上改善しなかった場合を終了 条件とした.

#### 4 結果・考察



図2 各モデルの再構成結果. 左が T2 マップの再構成結果. 右 が正解マップとの誤差を10倍に強調した画像.

図2にT2画像の計算結果を示す.(A)のqDC-CNNは他手法 や既存手法に比べて高画質な画像を出力することができた.特 に(C)の Multiecho-DC-CNN と比べると、高信号領域での誤差 の抑制されたことがわかる(赤矢印). これは mapping network が定量値推定に有効であることを示している.

#### 5. まとめ

本研究により、定量的 MRI に対して、提案手法である qDC-CNN の有効性が示された.

#### 利益相反の有無

横沢 俊と白猪 亨は, 富士フイルム株式会社の社員である.

## 1 文 献

[1] Schlemper et. al. A deep cascade of convolutional neural networks for dynamic MR image reconstruction, IEEE Trans. Med. Imaging vol. 37, no. 2, pp. 491-503, 2017.

[2]Cocosco et. a l. BrainWeb: Online Interface to a 3D MRI Simulated Brain Database NeuroImage, vol.5, no.4, part 2/4, S425, May 1997.

Liu et. al. MANTIS: Model-Augmented Neural neTwork with [3] Incoherent k-space Sampling for efficient MR parameter mapping Magn. Reson. Med., vol. 82, no. 1, pp. 174-188, 2019.

[4] Lingala et al. Accelerated Dynamic MRI Exploiting Sparsity and Low-Rank Structure: k-t SLR, IEEE Trans. Med. Imaging, vol. 30, no. 5, pp. 1042-1054, 2011.

## 数値シミュレーションによる腹壁運動を伴う MR エラストグラフィにおける誤差低減法の検討

玉田 綾\*1,谷口 陽\*1.2,西原 崇\*3,瀧澤 将宏\*3,菅 幹生\*1.4

\*1 千葉大学 融合理工学府 医工学コース

\*2 富士フイルム株式会社

\*3 富士フイルムヘルスケア株式会社

\*4 千葉大学 フロンティア医工学センター

Investigation of error reduction method on MR elastography with abdominal wall motion by numerical

simulation

Aya TAMADA<sup>\*1</sup>, Yo TANIGUCHI<sup>\*1,2</sup>, Takashi Nishihara<sup>\*3</sup>, Masahiro Takizawa<sup>\*3</sup>, Mikio Suga<sup>\*1,4</sup>

<sup>\*1</sup> Graduate School of Science and Engineering, Chiba University

\*2 FUJIFILM Corporation

\*3 FUJIFILM Healthcare Corporation

<sup>\*4</sup> Center for Frontier Medical Engineering, Chiba University

**要旨**: MR エラストグラフィ(MRE)は、組織の粘弾性率を定量的に測定できる.しかし、腹壁運動により体動アーチファクトが発生すると誤差が生じる.本研究では、腹壁運動を伴う MRE において粘弾性率に生じる誤差とその低減法を数値シミュレーションで明らかにする.腹部数値モデルは、腹壁変位を想定して上部が伸縮する楕円とし、楕円の伸縮はヒト腹部で測定した呼吸動を用いた.MRデータ収集の位相エンコードステップごとに体動を加味した腹部モデルをフーリエ変換し、k空間上に1行ずつ充填した後、正規分布ノイズを加えてから逆フーリエ変換することで体動アーチファクトを含む弾性波画像を再現した.周期や位相が異なる腹壁変位は12種類利用した.TR を呼吸周期の1/3 に設定することで体動アーチファクトと撮像対象の重畳を避けることができ、貯蔵弾性率推定誤差を低減できることが示唆された.

キーワード: MRI, MRE, エラストグラフィ, 肝エラストグラフィ

## 1. はじめに

生体組織の粘弾性率を非侵襲的かつ定量的に測定する方法として magnetic resonance imaging (MRI)を利用した MR エラストグラ フィ(magnetic resonance elastography: MRE) [1]がある. MRE は, はじめに MRI 装置内で外部加振装置を用いて撮像対象内部に弾 性波を伝播させる.次に,変位エンコード傾斜磁場(motion encoding gradient: MEG)を含む MRE パルスシーケンスを用いて 撮像することにより,弾性波を画像化する.最後に,得られた弾性 波画像を解析することで粘弾性率を推定する. MRI では撮像中の 体動によって画像にモーションアーチファクトが発生し,体動に周 期性のある場合のアーチファクトの出現間隔は先行研究によって 明らかにされている[2]. MRE では弾性波画像にモーションアーチ ファクトが発生すると粘弾性率推定誤差が生じる.本研究では,自 由呼吸下でも腹壁運動に伴うアーチファクトの影響を低減可能な MR エラストグラフィ撮像条件を数値シミュレーションで明らかにす ることを目的とした.

自由呼吸下での撮像において repetition time (TR)を呼吸周期 の約 1/3, FOV を腹部短軸長の約 3 倍に設定することで, 撮像対 象とモーションアーチファクトの重畳を避けることができると予想さ れ, 先行研究によりこの設定において貯蔵弾性率推定誤差を低減 できることが示唆された[3].また, 腹壁運動に伴った振動子の動き が生じないように振動子の位置を右脇腹に設置することで貯蔵弾 性率推定誤差がさらに低減できることが示唆された.先行研究では, MR データ収集における腹壁変位の周期や位相は 1 種類のみで あった.本研究では、TR を呼吸周期の 1/3、FOV を腹部短軸長の 約3倍,振動子を右脇腹に設置した上で、周期や位相を複数種類 にすると共に MRI 測定ノイズを付加し、腹壁変位の周期や位相と 貯蔵弾性率推定誤差の関係を評価した.

#### 2. 方法

#### 2.1 シミュレーション概要

腹壁が変位する数値ファントムを図 1 に示す.成人男性の腹部 Axial 断面を想定した楕円形状で,肝臓を模擬した楕円形状を内 包させた.貯蔵弾性率はそれぞれ 3.0 kPaと4.5 kPaとした。ファン トムの上半分は,あらかじめ実測した呼吸による腹壁運動波形を元 に上下方向に最大±1.5 cm で伸縮する設定とした.

シミュレーションのフローチャートを図 2 に示す.まず,位相エン コードステップごとに腹壁運動波形より TR に合わせたタイミングの 腹壁変位となる数値ファントムを設定した.次に,数値ファントムに あらかじめ設定した貯蔵弾性率分布から,数値シミュレーションに より定在波画像を求め,これを位相画像に追加した.この位相画像 を強度画像と共にフーリエ変換して k 空間データを求めた.この k 空間データから各位相エンコードステップに対応するデータを1行 ずつ体動シミュレーション用の k 空間データに充填した.この k 空 間データを逆フーリエ変換することで,モーションアーチファクトを 含む弾性波画像を生成した.



図1 腹壁が変位する数値ファントム概形



## 2.2 シミュレーション設定

シミュレーションパラメータを表1に示す.TR を呼吸周期の1/3 (TR 1236 ms)とそうでないもの(TR 480 ms)の2種類,FOVを腹部 短軸長の約3倍,振動子を右脇腹に設置した上で,腹壁変位の周 期や位相を12種類にするとともにMRI測定ノイズも付加し,腹壁 変位の組み合わせと貯蔵弾性率推定誤差の関係を評価した.弾 性波画像から貯蔵弾性率の算出には積分型粘弾性率分布推定手 法[4]を用いた.

TR	[ms]	480	1236
Matrix	[pixel]	256>	<256
位相エンコーディングステップ数		25	56
位相エンコード方向		A >	> P
Pixel size	[mm]	3.	.0
FOV	[mm <sup>2</sup> ]	768>	<768
加振周波数	[Hz]	6	0
振動源振幅	[rad]	1.	.0
想定弾性率(背景)	[kPa]	3.	.0
想定弾性率(内包)	[kPa]	4.	.5
振動源位置		右服	協腹
腹壁変位	[cm]	±'	1.5
付加ノイズの標準偏差		3.	.0

表1 シミュレーションパラメータ

#### 3. 結果

12 種類のシミュレーションのうち, 貯蔵弾性率推定誤差が最大・ 最小・平均的となった画像における左右方向の視野中心部分を図 3 に示す. また, 12 種類の結果における貯蔵弾性率推定結果の平 均と標準偏差, 体動なしを想定したシミュレーション結果との誤差 を表 2 に示す. 貯蔵弾性率推定値の関心領域は呼気末期時の内 包領域外周から 7 pixel 内側とした. 腹壁変位の周期や位相が異 なる場合でも, TR を呼吸周期の 1/3 にすることで, 強いアーチファ クトが撮像対象の外部に現れることが確認できた. また, 体動なしと の誤差は TR が 480 ms と比較して約 40 ポイント低かった.



図3 シミュレーション結果画像の一例

表2 シミュレーション結果

TR [ms]	480	1236(呼吸周期1/3)
貯蔵弾性率推定値 [kPa]	6.29 ± 3.46	4.51 ± 0.77
体動なしとの誤差 [%]	45.5 ± 19.1	4.33 ± 3.53

## 4. まとめ

多種類の腹壁変位の周期や位相を想定したシミュレーションによって,自由呼吸下での肝臓 MRE 撮像において,TR を呼吸周期の 1/3,振動子を右脇腹に設置することで貯蔵弾性率推定 誤差が低減できることが確認できた.

#### 利益相反の有無

なし

- 文 献
- [1] Muthupillai R et al., Science 269:1854-1857, 1995
- [2] Wood ML et al., AJR Am J Roentgenol 150(3):513-522, 1988
- [3] Suga M et al., JAMIT 41:132–133, 2022
- [4] Takeda T et al., Int J Comput Assist Radiol Surg 16:1947-1956, 2021

## 3 周波数同時加振 MR エラストグラフィにおける最適撮像条件の検討

髙﨑 晴也\*1, 菅 幹生\*1.2, 岸本 理和\*3, 小畠 隆行\*3

\*1 千葉大学融合理工学府医工学コース

\*2 千葉大学フロンティア医工学センター

\*3 量子科学技術研究開発機構

## Optimization of imaging conditions in 3-frequency simultaneous viblation MR elastography

Haruya TAKASAKI<sup>\*1</sup>, Mikio SUGA<sup>\*1,2</sup>, Riwa KISHIMOTO<sup>\*3</sup>, Takayuki OBATA<sup>\*3</sup>

<sup>\*1</sup> Graduate School of Science and Engineering, Chiba University

<sup>\*2</sup> Center of Frontier Medical Engineering, Chiba University

<sup>\*3</sup> National Institutes for Quantum Science and Technology

要旨:複数周波数同時加振 MR エラストグラフィ (MRE)では,複数周波数の合成波により撮像対象を加振することで,通常の MRE と比べて短時間でデータ取得が可能となる.しかし,取得データから周波数ごとの粘弾性率を高精度に推定するための撮像条件は 明らかになっていない.本研究では、3 周波数同時加振 MRE における弾性波画像分離や弾性率分布推定の精度向上のために,撮像 条件のうち,加振の初期位相や加振周波数,変位を位相シフトに変換する変位エンコード傾斜磁場 (MEG)の周波数について適切 な値を数値シミュレーションにより求めることを目的とした.弾性波画像分離精度は,加振の初期位相には依存せず,80 Hz を含む 4 種類の加振周波数からの3 周波数の組み合わせで精度が良いのは 40,60,90 Hz であった.加振周波数 40,60,90 Hz に対して,弾性率推定精度が高く周期が起い MEG 周波数は 33 Hz であった.

**キーワード**: MRI, エラストグラフィ

#### 1. はじめに

生体内の粘弾性特性を非侵襲的かつ定量的に測定する手法 として magnetic resonance elastography (MRE)がある[1]. MRE は, 外部加振装置を用いて生体内部に正弦波振動を伝播させ,得ら れる変位情報に粘弾性率推定式を適用することで,粘弾性率分 布を推定する.

通常の MRE では単一周波数の正弦波振動により生体内部を 加振するのに対し,複数周波数同時加振 MRE では複数周波数 の正弦波からなる合成波により加振し,撮像後に各周波数の弾 性波画像に分離してから周波数ごとに弾性率分布を推定する. これにより,通常の MRE と比べてより多くの情報が一度に得 られること,また同じ量のデータを得るために必要な撮像時間 の短縮が可能となる. 先行研究により3 周波数(40,60,90 Hz)同 時加振 MRE による初期位相数 7 での撮像により,貯蔵弾性率推 定値は真値と一致し,撮像時間短縮効果は44%となることが示され た[2].本研究では、3 周波数同時加振 MRE における弾性波画 像分離や弾性率分布推定の精度向上のために,適切な撮像パラ メータを数値シミュレーションにより求めることを目的とし た.

## 2. シミュレーション手法

MRE により得られる弾性波画像の画素値y(x,t)は、位置をx時間をt、加振周波数をf、振幅をA、撮像対象内での波長を $\lambda$ 、加振の初期位相を $\theta$ とすると以下のように表せる.

$$y(x,t) = A(x)\cos\left(2\pi ft - 2\pi\frac{x}{\lambda} + \theta\right) \tag{1}$$

上記式を用いて,40,60,80,90 Hz の弾性波画像を作成した. 表1に基準としたシミュレーションパラメータを示す.

- 表1 基進としたシミュレーション
--------------------

貯蔵弾性率	3.0 kPa
ピクセルサイズ	3.0 mm
初期位相数	7
スライス数	15
マトリックスサイズ	$128 \times 128$
振幅	10
MEG サイクル数	2
加振の初期位相	0°
MEG 周波数	40 Hz

周波数の組み合わせによるノイズ頑健性を調べるにあたり 実験条件を統一するために,弾性波画像には標準偏差 1.0 の 同一ノイズ画像を付加した.これらを用いて,3周波数の画像 とノイズ画像を加算して分離前弾性波画像とした(図1).



図1 分離前画像の作成方法
本研究では、3 種類のパラメータについて精度依存性を検討 した.一つ目は、加振の初期位相とした.加振周波数が 40,60, 90 Hz, MEG 周波数が 40 Hz の条件下で、加振の初期位相を 0°,90°,random に変えて、分離後弾性波画像を評価した(表 2).二つ目は、加振周波数の組み合わせとした.加振の初期位 相が 0°,MEG 周波数が 40 Hz の条件下で、加振周波数 40, 60,80,90 Hz から 3 つを選択して分離後弾性波画像を評価し た.三つ目は、MEG 周波数とした.加振周波数が 40,60,90 Hz,加振の初期位相が 0°の条件下で、MEG 周波数 10 から 120 Hz までを1 Hz 間隔で変化させて、貯蔵弾性率分布画像を 評価した.弾性波画像から貯蔵弾性率の算出には積分型粘弾性 率分布推定手法[3]を用いた.

表 2	加振の初期位相
1 4	

初期位相	40 Hz	60 Hz	90 Hz		
0°	0°				
90°	90°				
random	233°	80°	33°		

弾性波画像と貯蔵弾性率分布画像の精度を評価するシミュ レーション手順を図2に示す.黒枠は処理を,青枠は画像を, 背景が橙の処理はMEGによる影響が加わる処理を表している.



図2 精度評価手順(左:弾性波画像,右:貯蔵弾性率分布画像)

## 3. 結果と考察

# 3.1 加振の初期位相と分離後弾性波画像の精度との関係

分離後弾性波画像は,加振の初期位相に寄らず全て一致した. 3.2 加振周波数の組み合わせと分離後弾性波画像の精 度との関係

加振周波数組み合わせの違いによる精度評価について,分離 後弾性波画像の RMSE の合計値を表 3 に示す. RMSE の合計 値は,40,80,90 Hz の値が一番小さく,40,60,90 Hz が同程度 の値であり 40,60,80 Hz が一番大きくなった. RMSE の値が小 さい組み合わせのうち,加振周波数範囲が広く,周波数が等間 隔に近い 40,60,90 Hz の組み合わせが 40,80,90 Hz よりも測定 パラメータとして適していると考えられる.

表3 分離後弾性波画像の RMSE の合計値

我了为權及尸住使固体。" Kuise 9 日前他					
40, 60, 80 Hz	40, 60, 90 Hz	40, 80, 90 Hz	60, 80, 90 Hz		
86.97	44.95	42.62	61.41		

#### 3.3 MEG 周波数と貯蔵弾性率分布画像の精度との関係

各 MEG 周波数での分離後弾性波画像から求めた各加振周波 数の貯蔵弾性率分布画像の RMSE と,全加振周波数の RMSE 合計値をそれぞれ図 3 の左と右に示す.どの加振周波数におい ても,MEG の周期が加振周期の整数倍またはその近傍で RMSE が著しく増大した.また,MEG 周波数が加振周波数よ り少し低い周波数から RMSE が増大することが確認された. 以上の結果より,この実験に使用したパラメータでは,30 Hz を除く23 Hz から33 Hz の間の MEG 周波数で撮像することで 弾性波画像の分離と弾性率推定の精度を向上可能と考えられ る.



図 3 MEG 周波数と貯蔵弾性率分布画像の RMSE との関係 (左:各加振周波数ごとの RMSE, 右:全加振周波数の RMSE 合計値)

### 4. まとめ

3 周波数同時加振 MRE において,加振周波数組み合わせと MEG 周波数を適切に設定することで,精度が向上可能である ことを数値シミュレーションにより明らかにした.

求めたパラメータを設定した実測実験により,本手法の有効 性を確認することは今後の課題である.

## 利益相反の有無

なし

#### 文 献

[1] R. Muthupilliai et.al., SIENCE, 269(5232), 1854-1857, 1995

[2] 久慈陸, 他, 第 39 回日本医用画像工学会大会予稿集, pp.465-468, 2020

[3] T. Takeda et al., Int J Comput Assist Radiol Surg 16:1947-1956, 2021

# Deep Image Prior を用いた蛍光 X線 CT 画像再構成

對馬 結太<sup>\*1</sup>, 松岡 将宏<sup>\*2</sup>, 佐藤 和樹<sup>\*1</sup>, 草刈 颯太<sup>\*3</sup>, 笹谷 典太<sup>\*2</sup>, 砂口 尚輝<sup>\*4</sup>, 河嶋 秀和<sup>\*5</sup>, 兵藤 一行<sup>\*6</sup>, 湯浅 哲也<sup>\*2</sup>, 銭谷 勉<sup>\*1</sup>

\*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 弘前大学理工学部

\*4 名古屋大学大学院医学系研究科 \*5 京都薬科大学放射性同位元素研究センター

\*1 高エネルギー加速器研究機構物質構造科学研究所

X-ray fluorescence computed tomography image reconstruction using deep image prior

Yuta TSUSHIMA<sup>\*1</sup>, Masahiro MATSUOKA<sup>\*2</sup>, Kazuki SATO<sup>\*1</sup>, Sota KUSAKARI<sup>\*1</sup>, Tenta SASAYA<sup>\*2</sup>,

Naoki SUNAGUCHI<sup>\*3</sup>, Hidekazu KAWASHIMA<sup>\*4</sup>, Kazuyuki HYODO<sup>\*5</sup>, Tetsuya YUASA<sup>\*2</sup>, Tsutomu ZENIYA<sup>\*1</sup>

<sup>\*1</sup> Hirosaki University <sup>\*2</sup> Yamagata University <sup>\*3</sup> Nagoya University

<sup>\*4</sup> Kyoto Pharmaceutica University <sup>\*5</sup> High Energy Accelerator Research Organization (KEK)

要旨:我々のグループでは,前臨床研究での利用を目指して,非放射性ヨウ素標識化合物を用いて小動物の生体機能画像の取得を 可能とするマルチピンホール蛍光 X線 CT システムを開発しているが,実用化には画質改善や検出限界の向上が必要となる.本研 究では深層学習を取り入れた画像復元手法である Deep Image Prior (DIP)を蛍光 X線 CT 画像再構成に応用し,画質改善および検出 限界の向上を試みた.散乱線補正後に,DIP 処理を行いノイズ低減させた蛍光 X線投影画像をマルチピンホール蛍光 X線 CT 用 OS-EM で画像再構成した.励起光として放射光単色 X線を利用して物理ファントム実験を行った結果,再構成画像のコントラストノ イズ比は濃度 0.3 mg/ml のヨウ素領域にて 4.6 倍に大きく改善し,検出限界は 0.069 mg/ml から 0.035 mg/ml へと向上した.空間分 解能は 0.56 mm から 0.72 mm にわずかに劣化したが,画質と検出限界を大きく向上させることができた. キーワード:蛍光 X線 CT,画像再構成,Deep Image Prior,ノイズ低減,生体機能画像

## 1. はじめに

Positron emission tomography (PET) \* single photon emission computed tomography (SPECT)などの核医学イメージング技術 は生体内の機能情報を画像化できる. 臨床診断はもちろん, 創 薬,再生医療,病態解明などの動物を用いた前臨床研究でも重 要な役割を果たしている.しかし、PETや SPECTの検査は RI を使用するため、放射線管理区域で行う必要があり、簡単に実 施できない. 我々のグループでは、RI を使用せずに生体機能 画像を得るために、X線で励起された非放射性造影剤(ヨウ素 化合物など)から発する蛍光を利用した蛍光 X線 CTを開発し ている [1,2]. 小動物の in vivo イメージングを行うには, 画 質改善と検出限界の向上が必要となる.本研究では, 蛍光 X 線 CT の画質と検出限界を向上させるために、ターゲット画像の みから画像を復元できる畳み込みニューラルネットワーク (convolutional neural network: CNN)である Deep Image Prior (DIP) [3] を蛍光 X 線 CT 画像再構成に応用し, 画質改善効果を撮 像実験によって評価した.

## 2. 方法

## 1) 蛍光 X 線 CT

図1にマルチピンホール蛍光 X 線 CT システムの概略図を 示す.被写体に X 線が照射されると、光電効果により被写体 の造影剤部分から蛍光 X 線が発生する. 蛍光 X 線光子はマル チピンホールコリメータを通過して 2 次元検出器で検出され、 光子量の分布が投影画像として得られる.被写体を回転させる ことで複数方向からの投影画像を収集する.投影画像を再構成 することで、造影剤の 3 次元分布が得られる.



図1 マルチピンホール蛍光 X線 CT システム.

## 2) Deep Image Prior (DIP)

ターゲット画像をxo,入力として与えられるノイズ画像をz, ネットワークパラメータを $\theta$ ,ニューラルネットワークを $f_{\theta}$ と すると,ネットワークパラメータは次式で更新される.

(1)

 $\theta^* = \arg\min_{\theta} E(f_{\theta}(z); x_0)$ 

損失関数は、ターゲット画像と出力画像の平均二乗誤差 (mean square error: MSE)とした. このネットワークは、ノイズ などのランダムな画像よりも規則的な構造を持つ画像の方が 早く復元できる性質がある.ノイズ成分が復元する前にパラメ ータの更新を止めることで、自然な画像を得ることができる. 3) DIP の蛍光 X 線 CT 画像再構成への応用

図2にDIPを用いた画像再構成手順を示す.まず,散乱線補 正によって背景ノイズが除去される.散乱線補正は,造影剤(ヨ ウ素溶液)を満たしたファントムを撮像後,ヨウ素溶液を水に 入れ替えて撮像し,撮像した2種類の投影画像間で差分する. 散乱線補正された投影画像に対して DIP 処理を行い, maximum-likelihood expectation-maximization (ML-EM)法によって3次元画像を再構成する.



図2 画像再構成手順.

#### 3. 撮像実験

高エネルギー加速器研究機構の放射光ビームラインに蛍光 X線CTシステムを構築し(図3),図4に示すファントムを表 1に示す条件で撮像した.

散乱線補正された投影画像は,(1)ML-EM 法による画像再構 成(ML-EM),(2)DIP 処理後に ML-EM 法による画像再構成(DIP + ML-EM),(3)ガウスフィルター(gaussian filter: GF)後に ML-EM 法による再構成(GF + ML-EM),これら3種類の方法で再 構成し,画質を評価した.



図3 放射光ビームラインに構築した蛍光X線CTシステム



図4 撮像実験に使用されたファントム **車1** 提供条件

<b>衣</b> I 珈隊未件.				
入射 X 線エネルギー	33.2 keV			
ビームサイズ	横 35 mm×縦 5 mm			
ピンホール直径	0.2 mm			
照射時間(1投影当たり)	180 s			
投影数	180 方向(360°)			
回転中心とコリメータの距離	28.37 mm			
コリメータと検出器の距離	34 78 mm			

画質は、コントラストノイズ比(contrast-to-noise ratio: CNR), 空間解像度,検出限界(limit of detection)を用いて評価した. CNR と LOD は次式で表される.

$CNR = \frac{m_s - m_N}{\sigma}$	(2)
$LOD = m_N^{\sigma_N} + 3.29\sigma_N$	(3)

ms, mN, σNは, それぞれコントラスト領域の画素値の平均, 背景領域の画素値の平均,背景領域の画素値の標準偏差である. 本研究では, ヨウ素溶液濃度毎に CNR を計算した.

## 4. 結果

図5に再構成画像を示す.図6に再構成画像のCNRを示す. 表2に,CNR,空間分解能,検出限界の改善を示す.DIP+ML-EMを用いて再構成した画像では、ヨウ素溶液 0.3 mg/mlの領 域でCNR が4.6倍に大幅に向上し,検出限界も0.069 mg/ml か ら0.035 mg/mlに向上した.GF+ML-EMによる画像は、空間 分解能が低下した.







 ML-EM
 DIP + ML-EM
 GF + ML-EM

 図5
 ヨウ素封入ファントムの蛍光X線CT再構成画像.



**ま**9 再構成面像の面質評価指標

	ML-EM	DIP+ML-EM	GF+ML-EM		
CNR の改善	1.0	3.7 - 4.6	2.3 - 2.7		
空間分解能 (mm)	0.56	0.72	0.97		
検出限界 (mg/ml)	0.069	0.035	0.049		

## 5. まとめ

DIP を用いた画像再構成手法は,空間分解能を低下させることなく, 蛍光 X 線 CT の画質と検出限界を大きく改善できた.

#### 謝辞

本研究は JSPS 科研費 JP17H04116, JP22K19501 の助成を受けたものです.

#### 利益相反の有無

なし

[1] Takeda T, Wu J, Thet-Thet-Lwin, et al: X-ray fluorescent CT imaging of cerebral uptake of stable-iodine perfusion agent iodoamphetamine analog IMP in mice. J Synchrotron Rad 16: 57-62, 2009

- [2] Sasaya T, Sunaguchi N, Hyodo K, et al: Multi-pinhole fluorescent x-ray computed tomography for molecular imaging. Sci Rep 7: Article Number 5742, 2017
- [3] Ulyanov D, Vedaldi A, Lempitsky V: Deep Image Prior. In Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018, pp9446-9454

# 3次元類似性駆動型メディアン正則化を用いたピンホール SPECT の画像再構成

丹羽 英之<sup>\*1</sup>,尾川 浩一<sup>\*2</sup> <sup>\*1</sup>法政大学大学院理工学研究科

\*2法政大学理工学部

## Image reconstruction of pinhole SPECT using 3D similarity-driven median regularization

## Hideyuki NIWA<sup>\*1</sup>, Koichi OGAWA<sup>\*2</sup>

# <sup>\*1</sup> Graduate School of Science and Engineering, Hosei University

## <sup>\*2</sup> Faculty of Science and Engineering, Hosei University

要旨:SPECT では統計雑音の影響で再構成画像には劣化が生じ,ML-EM 法などを用いた場合は反復回数が増大するとその影響が 大きくなる.このような統計雑音の影響を低減するために、画像のなめらかさを事前確率として導入し再構成する MAP-EM 法など が提案されている.この際,ペナルティ関数として当該画素と近傍領域のメディアンの差を利用する方法 (MRP-EM)や当該画素の 近傍のメディアンとそれを囲む領域のメディアンの類似度を用いてペナルティとする方法 (SDMR-EM) などが提案されている.本 研究ではこれらの手法を3次元に拡張して、ピンホール SPECT における統計雑音を低減する方法を検討した.シミュレーションの 結果から近傍領域の類似性を考慮した手法は画質が向上することが PSNR と MSSIM から明らかになった. キーワード:SPECT、ピンホールコリメータ、MAP-EM 法、正則化、統計雑音

## 1. はじめに

ML-EM (maximum likelihood-expectation maximization)法で は、実測投影データに雑音があった場合、反復回数が増えるほ ど低画質の再構成画像が出力されてしまうことがある.このよ うな雑音の影響を抑えるため、画像の事前情報をペナルティと して追加し、雑音の影響を抑えた画像再構成を行う MAP-EM (maximum *a posteriori*-EM)法が提案されている.この MAP-E M 法の一つに、ペナルティ関数として当該画素と近傍領域の メディアンの差を利用する MRP-EM (median root prior-EM)法 [1]が提案されている.しかし、MRP-EM 法はエッジ成分も滑 らかにしてしまう欠点がある.本研究では、ペナルティとして 単純に近傍領域の中央値を取るのではなく、当該画素の近傍の メディアンと、その近傍領域の類似度を用いてペナルティとす る SDMR-EM (similarity driven median regularization-EM)法[2] による画像再構成法を3次元に拡張し、ピンホール SPECT シ ステムにおける統計雑音の低減効果を検討した.

## 2. 提案手法のアルゴリズム

MRP-EM 法は, 当該画素と近傍画素のメディアン値(中央値)との相対誤差をペナルティして与える方法であり,以下のように表される.

$$\lambda_{j}^{(k+1)} = \frac{\lambda_{j}^{k}}{\sum_{i=0}^{N-1} C_{ij} + \beta \frac{\lambda_{j}^{k} - M_{j}}{M_{j}}} \sum_{i=0}^{N-1} \frac{y_{i} C_{ij}}{\sum_{m=0}^{N-1} C_{im} \lambda_{m}^{k}}$$
(1)

ここで、 $C_{ij}$ は画素 j が検出器 i に検出される確率、k は反復回数、 $\lambda_j^k$ は k 回目の更新画像の画素 j の画素値、 $y_i$ は投影データ、 $M_j$ は画素 j の近傍領域の中央値、 $\beta$ は重みである.これに

対して、SDMR-EM 法は、MRP-EM 法のように単純に近傍内の 中央値を選択するのではなく、注目画素とその近傍画素を中心 としたそれぞれのパッチ(近傍系)の類似性によって重みを変 化させ、中央値を選択する. 画素 jの画素値を $f_j$ , jを中心とす るパッチを $N_j$ パッチ、 $N_j$ パッチ内の画素値を $f_i$ '、 $f_i$ 'を中心と するパッチを $N_j$ 'パッチとしたときの、SDMR-EM 法のエネル ギー関数 $U(\cdot)$ を以下に示す.

$$U(f_j) = \sum_{j=1}^{j} \sum_{j' \in N_j} w_{jj'} V(f_j - m_{j'})$$
<sup>(2)</sup>

ここで、 $w_{jj'}$ は重み、 $m_{j'}$ はj'を中心とする近傍のパッチの中央値、 $V(\cdot)$ はポテンシャル関数である、ポテンシャル関数を以下に示す.

$$V(\varphi) = \sqrt{\varphi^2 + \varepsilon} \tag{3}$$

ここで、 $\varphi$ と $\epsilon$ はポテンシャル関数の変数である. 重み $w_{jj'}$ は以下のように表される.

$$w_{jj'} = \frac{\overline{w}_{jj'}}{\sum_{j' \in N_j} \overline{w}_{jj'}}, \overline{w}_{jj'} = \exp\left(-\frac{\sum_{p=1}^{p} (f_{j(p)} - f_{j'(p)})^2}{\delta^2}\right) \quad (4)$$

ここで、Pはパッチ内の画素数、 $\delta$ は正のパラメータである. 注目パッチと近傍パッチの類似性が大きいほど $\overline{w_{jj'}}$ の値が1に 近くなり、相対的に大きな重みが、類似性が大きいパッチの中 央値に付与されるため、その値に近い中央値が決定されやすく なる.本研究では SDMR-EM 法における2次元のパッチ(以後 は2DSDMR-EM 法と表記)を3次元に拡張し、3×3×3のパッチ で行った(以後は3DSDMR-EM 法と表記).

## 3. シミュレーション方法

提案手法の有効性を評価するため,モンテカルロ法による光

子輸送計算を用いて投影データを計算した. 投影データはプラ イマリ光子(140 keV)を対象にして,吸収補正,開口補正,感 度補正を行った.ファントムは直径 10 cm の球状の水媒質, ファントムの中心からピンホールコリメータまでの距離は25 cm,検出器までの距離は32.5 cm とし,コリメータ径は1.3 mm,検出器は512 × 256 pixels,検出器のピクセルサイズは 0.08 × 0.08 cm<sup>2</sup>,投影数は180 とし,画像サイズは128 ×128 × 128 voxels,画像のボクセルサイズは0.2 × 0.2 × 0.2 cm<sup>3</sup> と した.使用したファントムと発生光子数を図1に示す.従来法 との比較のため,近傍として3×3 の2次元近傍を用いる 2DM RP-EM 法と3×3×3 の3次元近傍を用いる 3DMRP-EM 法を用 いた.この際,2DMRP-EM 法,3DMRP-EM 法,2DSDMR-EM 法,3DSDMR-EM 法のパラメータは最適な値を用いた.



図1 使用したファントム(スライス#63)と発生光子数

## 4. シミュレーション結果と考察

図2にスライス#63の再構成画像の比較を示す.また,スラ イス#50~#80 での平均 PSNR(peak signal to noise ratio)と MSSIM(mean structural similarity index measure)を表1に示す. 表1より,3DMRP-EM 法と3DSDMR-EM 法のPSNR,MSSIM が他の手法に比べ上回っていることが分かる.そこで,小さな 集積構造が存在するスライスを評価の対象にして,3DMRP-EM 法と3DSDMR-EM 法のそれぞれのスライスの比較を行っ た.図3にスライス#58の再構成画像を示し,表2にスライス (#58,#63)の画像のPSNRとMSSIMを示す.表2から小さな集 積構造が多く存在しているスライス(#63)では,3DSDMR-EM 法のPSNR,MSSIMが上回っており,3DSDMR-EM 法は小さ な集積構造が存在する場合に,より効果的に雑音の影響を抑え 画像再構成ができていることが分かる.

## 5. 結論

パッチ領域の類似性をペナルティとして用いて雑音の低減 を行う SDMR-EM 法を 3 次元に拡張して, ピンホール SPECT に適用したところ, 微細な構造を明瞭に再構成することができた.



図2 再構成画像の比較(スライス#63): (a)原画像, (b) ML-E M, (c) 2DMRP-EM, (d) 3DMRP-EM, (e) 2DSDMR-EM, (f) 3D SDMR-EM



図3 再構成画像の比較(スライス#58):(a)原画像,(b)3DMR P-EM,(c)3DSDMR-EM

表1. スライス(#50~#80)の平均の PSNR と MSSIM

	PSNR	MSSIM		PSNR	MSSIM
2DMRP-EM	30.823	0.973	2DSDMR-EM	30.725	0.974
3DMRP-EM	30.993	0.974	3DSDMR-EM	30.978	0.975

表 2 スライス(#58, #63)の PSNR と MSSIM

スライス#58	PSNR	MSSIM	スライス#63	PSNR	MSSIM
3DMRP-EM	30.916	0.975	3DMRP-EM	30.204	0.968
3DSDMR-EM	30.855	0.975	3DSDMR-EM	30.390	0.970

#### 謝辞

本研究は JSPS 科研費 22K12874 の助成を受けた.

## 利益相反の有無

なし

- [1] Sakari A: Generalization of Median Root Prior Reconstruction. IEEE Trans Med Imag 21: 1421-1439, 2002
- [2] Xue R, Ji J, Wen Z et al: Penalized-Likelihood PET Image Reconstruction Using Similarity-Driven Median Regularization. Tomography 8: 1 58-174, 2022

# 画像再構成を用いない機能・形態ハイブリッドイメージング装置の提案

大西 佑弥<sup>\*1</sup>,橋本 二三生<sup>\*1</sup>,大手 希望<sup>\*1</sup>,大田 良亮<sup>\*1</sup>
 <sup>\*1</sup> 浜松ホトニクス株式会社中央研究所

# Design consideration of reconstruction-free functional/morphological hybrid imaging system

Yuya ONISHI<sup>\*1</sup>, Fumio HASHIMOTO<sup>\*1</sup>, Kibo OTE<sup>\*1</sup>, Ryosuke OTA<sup>\*1</sup>

<sup>\*1</sup> Central Research Laboratory, Hamamatsu Photonics K. K.

要旨:近年,超高時間分解能放射線検出器を用いることで画像再構成を必要としない新たな分子イメージング技術である direct positron emission imaging (dPEI) が実証された. dPEI は電子陽電子対消滅ガンマ線を用いて生体内の機能情報を画像化でき,小型 でありながらも高精細な画像が得られることが期待される一方,形態情報を取得する方法がないため dPEI 画像のみでは定量性に課題が残る. そこで本研究では, dPEI に対応する形態情報の取得に向けた新たな画像再構成不要イメージング技術を提案し,その実現可能性をモンテカルロシミュレーションにより検証する. 具体的には,対向配置された dPEI 検出器の一方と被写体の間に配置された陽電子放出核種からの消滅ガンマ線のうち,被写体内でコンプトン散乱したイベントを利用することで形態画像を取得する. 検証の結果, dPEI と同一の検出器配置から被写体の形態画像も取得することができ,それを dPEI 画像の吸収補正に利用することで,定量性が改善された.

 $\neq - \mathcal{P} - \mathcal{F}$ : direct positron emission imaging (dPEI), reconstruction-free, morphological imaging, attenuation correction

## 1. はじめに

陽電子放出核種による新たな分子イメージング技術として, 近年,超高時間分解能放射線検出器「1]を用いることで画像 再構成を必要としない direct positron emission imaging (dPEI) が実証された [2]. dPEI は検出器の time-of-flight (TOF) 情報 を利用することで、同時計数された2本の電子陽電子対消滅ガ ンマ線からその信号源を直接推定し,生体内の機能情報を画像 化する. また, positron emission tomography (PET) 装置のよう なリング型の検出器配置である必要はなく,対向配置のみで小 型かつ柔軟なシステム形状を可能とする次世代モダリティと しても期待されている.しかし,臨床現場での使用を想定した 場合解決すべき課題があり、その一つに生体内を通過する際の 消滅ガンマ線の吸収による定量性の劣化が挙げられる. ガンマ 線の吸収を正確に補正するためには,被写体内の解剖学的な形 態情報を表す線源弱係数マップ (µmap)を取得する必要がある. そこで本研究では、上記で述べた dPEI の長所を残しつつ、そ れに対応する形態情報の取得に向けた direct µCompton imaging と 呼ばれる新たな画像再構成不要イメージング技術を提案し、こ れらの機能・形態ハイブリッドイメージング(図1)の実現可 能性をモンテカルロシミュレーションにより検証する.

## 2. 方法

## 1) direct µCompton imaging の原理

提案する direct µcompton imaging は dPEI と同一の検出器及び 配置で画像化でき,違いは発生させる陽電子放出核種の位置と, 利用する相互作用の種類である. direct µcompton imaging では, 対向配置された検出器の一方と被写体の間の一点に配置され た陽電子放出核種からの消滅ガンマ線のうち、被写体内でコン



図 1 (a) 形態を表す direct µ<sub>Compton</sub> imaging と(b) 機能を表 す dPEI の機能・形態ハイブリッドイメージングの概念図

プトン散乱したイベントを利用する. コンプトン散乱の発生確 率は電子密度に比例するため, コンプトン散乱が起こった場所 を画像化することで形態画像が取得できる. コンプトン散乱の 三次元位置**r**<sub>c</sub>は, 以下の方程式を解くことで直接推定すること ができる.

$$\|\boldsymbol{r}_{c} - \boldsymbol{r}_{s}\| + \|\boldsymbol{r}_{c} - \boldsymbol{r}_{2}\| - \|\boldsymbol{r}_{1} - \boldsymbol{r}_{s}\| = \Delta T \times c$$
  
s.t.  $\boldsymbol{r}_{1} - \boldsymbol{r}_{s} / / \boldsymbol{r}_{c} - \boldsymbol{r}_{s},$  (1)



図2 異なる検出器条件下での direct µCompton imaging によって取得された(a) 形態画像と(b) プロファイル結果



図 3 理想検出器条件下における direct µ<sub>Compton</sub> imaging の形態 画像を用いた dPEI 画像の吸収補正(AC) 結果

こで、 $r_s$ は陽電子放出核種の位置、 $r_1 \ge r_2$ は各検出器にて検出 された位置、 $\Delta T$ は時間差、cは光速を表す.また、立体角の補 正を行うことにより、画像内のカウント分布を一様にする.

#### 2) モンテカルロシミュレーション

提案手法の実現可能性を確認するために, Geant4 を用いた モンテカルロシミュレーションを行う.対向配置する検出器に はそれぞれ 200 × 200 × 5 mm<sup>3</sup>の BGO を採用し, 0~20 ps の時 間分解能(CTR)と 0~3 mm の空間分解能(SR)からなる検出 器条件を設定した. 画質評価には、空気と水と骨の組成からな る大きさの異なる球を埋め込んだ円柱ファントムと,厚さ 5mm の脳構造のスライスを含む水で満たされた楕円体ファン トムを使用した.また, dPEI のシミュレーション時には,灰 白質と白質のコントラストが 4:1 になるように放射能濃度を設 定した.本検証では,各イメージングにおける散乱や偶発は考 慮していない.

## 3. 結果

異なる検出器条件下での direct µcompton imaging によって取得 された画質評価ファントムの形態画像とプロファイルを図 2 に示す.理想的な検出器条件下においては,最も小さい 10 mm 球が視覚的に確認でき,空気と水と骨のコントラストも明瞭で あった.本検証では,CTR が 10 ps,SR が 1 mm の検出器が 10 mm 球を視認できる最低条件であった.理想検出器条件下にお ける direct µcompton imaging によって取得された楕円ファントム の形態画像と,それを利用した dPEI 画像の吸収補正結果を図 3 に示す.吸収補正により, dPEI 画像の定量性が改善した.

## 4. まとめ

本研究では、dPEI に対応する形態情報の取得に向けた direct µCompton imaging を提案し、画像再構成不要な機能・形態ハイブ リッドイメージングの実現可能性をモンテカルロシミュレー ションにより検証した.その結果、提案手法は被写体の形態情 報を取得することができ、さらに dPEI の吸収補正に応用する ことで dPEI 画像の定量性が改善された.

#### 利益相反の有無

なし

- Ota R, Nakajima K, Ogawa I et al: Coincidence time resolution of 30 ps FWHM using a pair of Cherenkov-radiator-integrated MCP-PMTs. Phys Med Biol 64: 07LT01, 2019.
- [2] Kwon S, Ota R, Berg E et al: Ultrafast timing enables reconstruction-free positron emission imaging. Nat Photonics 15: 914–918, 2021.

# **量子 PET のモンテカルロシミュレーション:ポジトロニウム寿命のモデル化** 田島 英朗<sup>\*1</sup>,田久 創大<sup>\*1</sup>,錦戸 文彦<sup>\*1</sup>,高橋 美和子<sup>\*1</sup>,山谷 泰賀<sup>\*1</sup> <sup>\*1</sup> 量子科学技術研究開発機構

**Modeling of positronium lifetime in Monte Carlo simulator for quantum PET** Hideaki TASHIMA<sup>\*1</sup>, Sodai TAKYU<sup>\*1</sup>, Fumihiko NISHIKIDO<sup>\*1</sup>, Miwako TAKAHASHI<sup>\*1</sup>, Taiga YAMAYA<sup>\*1</sup>

<sup>\*1</sup> National Institutes for Quantum Science and Technology

要旨: PET 核種から飛び出た陽電子の数割は、一時的にポジトロニウム(Ps)と呼ばれる電子と陽電子のみからなる原子を経てから消 滅放射線対となる.陽電子放出と同時に即発ガンマ線を放出する核種を用いて、周辺電子密度等により変化する Ps 寿命を測定する ことができる.我々は、Ps 寿命ががん酸素分圧のバイオマーカーとなる可能性に着目し、Ps 寿命イメージング法(量子 PET)の研 究を進めている.本研究では、量子 PET の原理検証や画像化手法開発に必要なモンテカルロシミュレータの開発を行ったので報告 する.具体的には、Ps 寿命の空間分布や Ps 生成率などを基に陽電子寿命を設定し、ポアソン分布に従った揺らぎを対消滅時刻に与 えられるようにした.一対の検出器による Ps 寿命測定を模擬した結果、設定した寿命が反映されていることが確認された. キーワード:量子 PET、ポジトロニウム寿命イメージング、モンテカルロシミュレーション、Whole Gamma Imaging

#### 1. はじめに

ポジトロニウム (Ps) は、電子1つと陽電子1つが結合した 原子であり、PET (Positron Emission Tomography) 測定中に患者 の体内で生成されては瞬時に消えるを繰り返している.生成か ら消滅までの時間は生体内では最大でも数十 ns であり、従来 のPET では Ps の存在が意識されることはなかった.しかしな がら、近年では Ps の寿命(生成されてから消滅するまでの平 均時間)が酸素分圧など周囲の組織環境を反映することから、 低酸素マーカーなどの新しいバイオマーカーになると注目さ れている [1,2]. ここで、寿命の測定には、陽電子崩壊と同時 に即発ガンマ線を放出する核種を用いる必要がある.即発ガン マ線がスタート信号、陽電子が電子との対消滅によって放出す る 511 keV のγ線をストップ信号とし、その時間差情報を統計 処理することで寿命を求めることができる.そして、寿命の空 間分布を画像化する Ps 寿命イメージングの実現が期待されて いる.

これまでの Ps 寿命イメージングの研究では、TOF (Time-of-Flight) PET 装置に対して 3γ 同時計数処理を実装し、各同時計 数検出イベントの発生位置は TOF 情報を用いていた[2]. 一方、 我々が開発を進めている Whole Gamma Imaging (WGI)は、PET とコンプトンイメージングを組み合わせることで、3γ 同時計 数イベントの発生位置をほぼ点として決定できるため、Ps 寿 命イメージングに有効な手法と考えられる. 我々は WGI によ る Ps 寿命イメージングを「量子 PET」と名付けた.

量子 PET の開発において, Ps 寿命分布を効率的に画像化す る手法はまだ明らかになっておらず,その研究開発は世界的な 競争下にある. Ps 寿命イメージング手法開発と検証には,空間 的な Ps 寿命分布を 3D 画像として組み込むことが可能なシミ ュレーションフレームワークが不可欠である.これまでのイメ



図 1. 量子 PET: WGI による Ps 寿命イメージング

ージングシミュレーション研究では、2D 画像に対して、シス テムマトリックスを用いた順投影計算を行ったり [3] 、測定 対象 (ターゲット) や検出器の材質など詳細情報を省いたモン テカルロシミュレーションが実施されたり [4] している. タ ーゲットや検出器素材などの詳細情報を組み込むことが可能 なシミュレーションツールとして、GATE シミュレーションツ ールキット [5] と J-PET-geant4 [6] が開発されているが、より 複雑な Ps 寿命分布の設定が容易にできるボクセル画像の入力 オプションはまだない.

#### 2. 方法

本研究では、Ps 寿命イメージング手法の開発に向けて、 Geant4 モンテカルロシミュレーションツールキット [7] を用 い、Ps 寿命分布をボクセル画像として入力可能な量子 PET シ ミュレーションフレームワークを開発した. Geant4 version 10.7.2 を用い、柔軟なジオメトリ設定と、Ps 寿命分布を含んだ イメージングターゲット設定が可能な量子 PET シミュレータ を開発した(図 2). 検出器設定とターゲット設定は別ファイ



図 2. 量子 PET シミュレーションフレームワーク

ルで定義する. 検出器設定ファイルは, 今後画像再構成を実施 する際にも共通のパラメータファイルとして使用できる.Ps寿 命は放射能や材質分布とは別の画像ファイルとして入力する. ここで、Ps にはスピン状態によりオルソ Ps (o-Ps) と パラ Ps (p-Ps) の2つの形態があるが, o-Ps の寿命は ns オーダーであ るのに対し, p-Ps は数十~数百 ps オーダーで現在の検出器の時 間分解能では検出が難しいことから, o-Ps の寿命のみを設定す るようにした. 陽電子崩壊の際, 対消滅までの時間は Ps 生成 率及び o-Ps 分岐比に基づいてダイレクト消滅, p-Ps 生成, o-Ps 生成に場合分けして寿命を設定し、それぞれの消滅時間にポア ソン過程に応じた揺らぎを与えた.その際, o-Ps 生成の場合に は陽電子崩壊の場所の寿命をボクセル画像から取得して設定 した.シミュレータの出力はシングルイベントであり、後段の イベントセレクタで同時計数イベントの抽出を行う. そして, 抽出した同時計数イベントに対して解析や画像再構成を行う. 今回, ワンペアの TOF PET 検出器モジュールによって標準物 質の Ps 寿命測定を模擬したシンプルなシミュレーションによ りシミュレータの Ps 寿命モデルを検証した(図3).

#### 3. 結果

図4に標準物質の Ps 寿命シミュレーションし、検出時間差 スペクトルとして解析した結果を示す.指数関数フィッティン グにより測定データからの寿命推定を行った結果,設定した Ps 寿命が反映されていることが確認された.

## 4. まとめ

Ps 寿命モデルを組み込んだ量子 PET シミュレータを開発した. 今後実測データとの比較や, WGI ジオメトリと複雑な寿命分布のシミュレーションを実施する予定である.



図 3. 一対の TOF PET 検出器による標準物質 Ps 寿命測 定のシミュレーション



図 4. 511 keV と 1275 keV の同時計数イベントの検出時 間差スペクトル. Fit はフィッティング範囲を表し,カッ コ内の数値は推定値を示す.

#### 謝辞

本研究は JSPS 科研費 23H03775 の助成を受けたものである.

#### 利益相反の有無

本研究の一部はコニカミノルタ科学技術振興財団の研究助 成金を得て実施された.

- K. Shibuya, et al.: Oxygen sensing ability of positronium atom for tumor hypoxia imaging. Commun. Phys. 3: 173, 2020
- [2] P. Moskal, et al.: Positronium imaging with the novel multiphoton PET scanner. Science Advances 7: eabh4394, 2021
- [3] J. Qi and B. Huang: Positronium lifetime image reconstruction for TOF PET. IEEE TMI 41: 2848-55, 2022
- [4] Z. Zhu, et al.: A statistical reconstruction algorithm for positronium lifetime imaging using time-of-flight positron emission tomography. arXiv:2206.06463
- [5] D. Sarrut, et al.: The OpenGATE ecosystem for Monte Carlo simulation in medical physics. Phys. Med. Biol. 67: 184001, 2022
- [6] R. Y. Shopa and K Dulski. Multi-photon time-of-flight MLEM application for the positronium imaging in J-PET. Bio-Algo. Med.-Sys. 18: 135-143, 2022
- [7] J. Allison, et al.: Recent developments in GEANT4. Nucl. Instr. Meth. Phys Res Sect. A 835: 186-225, 2016
- [8] S. Takyu, et al.: Two-dimensional positronium lifetime imaging using certified reference materials. Appl. Phys. Exp. 15: 106001, 2022

# 深層学習を用いた異種モダリティ変換による

PET のブラインド吸収補正: 簡便な投影空間によるアプローチ

平戸 航之介\*1,山下 皓大\*1,佐藤 悠輝\*1,工藤 博幸\*1

\*1 筑波大学システム情報系情報工学域

## PET blind attenuation correction using modality transform with deep learning

## : A simple approach in projection data space

Kounosuke Hirato<sup>\*1</sup>, Koudai Yamashita<sup>\*1</sup>, Yuki Sato<sup>\*1</sup>, Hiroyuki Kudo<sup>\*1</sup>

<sup>\*1</sup> Division of Information Engineering, Faculty of Engineering, Information and Systems,

## University of Tsukuba

**要旨**: PET 装置では,定量的な再構成画像を得るために吸収補正が必要となる.吸収補正には体内のガンマ線吸収係数の分布が必要であり,1)透過型スキャンで測定する手法,2) CT/MRI を同時に撮影し計算する手法,3) PET 投影データのみから推定する手法,の3 つが存在する.(3) は別の撮影が不要だが,安定に吸収補正を行うことが困難である.これに対して,近年,深層学習を用いる手法が提案され,注目を浴びている.本研究では,深層学習を用いてガンマ線吸収係数の投影データを PET 投影データから直接推定し,投影データ空間で吸収補正を施した後に画像再構成を行う手法を提案する.提案手法では全て投影データの空間で処理を行う利点があり,深層学習を用いたブラインド吸収補正の手法の中でも計算面で非常に効率的で簡便な手法と位置付けられる.胸部 腫瘍検査の PET 実画像を用いたシミュレーション実験から提案手法はうまく動作して高精度でブラインド吸収補正が行えることが 明らかになった.

キーワード: PET, 吸収補正, 深層学習, ブラインド

## 1. はじめに

PET(Positron Emission Tomography)画像は、人体の生体的な機能の可視化に特化しており、現在では脳の検査や研究、そしてがん検診に広く用いられている.PETの定量的な再構成に吸収補正が必要となる.吸収補正には体内のガンマ線吸収係数の分布が必要となり、現在では CT/MRI を同時に撮影し計算から求める手法が主流となっている.しかしこの手法では PET と CT という 2 つの投影データから画像再構成を試みていて、患者の体のずれによる誤差が生じたり、PET のみの撮影よりも時間がかかったりしてしまう.

これに対して PET 投影データのみから推定する手法が存在 するが,安定な吸収補正が困難であることが古くから知られて いる.しかし近年深層学習を用いる手法が提案されていてうま く動作することが示されている[1].

本研究ではこのカテゴリーに属する手法として,深層学習を 用いてガンマ線吸収係数の投影データを PET 投影データから 直接推定し, PET 投影データに吸収補正を施した後に画像再構 成を行う手法を提案する.投影データの空間のみで吸収補正を 行うのが本研究の特徴である.投影データにおいて1つの光源 から検出される光子数が計測角度によって異なる場合でも,画 像空間上では平均化されてしまうためにこのような手法をと った.また,投影データ空間上で計算を行うので,効率的かつ 簡便であるという利点もある.

#### 2. 提案手法

本研究では PET 投影データのみからガンマ線吸収係数画像の投影データの推定を行う手法を提案する.

再構成を行うと角度による光子数の差の情報が失われてし まうため、投影データを用いている.1患者ごとに180度を1 度ずつ計測した投影データを用意し、これを入力とする.そし てガンマ線吸収係数分布の投影データを出力とし、U-Netと同 様の構造で学習させる.

本研究では 4 つの手法をそれぞれ比較し、より良い推定が できるものを検討していく.

#### 3. 実験

The Cancer Imaging Archive(TICA) より 159 名(学習データ: 129 名, 教師データ:30 名)の肺がん患者と非肺がん患者の CT 画像と PET 画像を用意した.そして, CT 画像から吸収係数画 像に変換し, PET 画像は真の薬剤分布と仮定して投影シミュレ ーションを行い, PET 投影データを得た.吸収係数の投影デー タはシミュレーション途中でCT 画像から変換したものを用い て生成した.

シミュレーションは以下の手順で行った.

- 減弱係数の設定
- 2. モダリティ間の画像サイズの統一
- 3. 投影データの取得
- 4. 線形補間

CT 画像は Hounsfield Unit(HU)という水の線減弱係数を0と

した相対的な値である. その計算式は、水の線減弱係数を  $\mu_w$ 、 対象物の線減弱係数を $\mu_x$ として以下の式のように表される.

$$HU = 1000 \times \frac{\mu_x - \mu_w}{\mu_w} \tag{1}$$

この式から対象物の線減弱係数を求める式は以下となる.

....

$$\mu_x = \mu_w \times (\frac{HU}{1000} + 1) \tag{2}$$

C. Burger らによると、ガンマ線の場合の水の線減弱係数は  $\mu_w = 0.093$ である[2]. その値と式(2)を用いてガンマ線吸収係 数分布を求める.

そして, CT 画像と PET 画像で実寸サイズと画素数のどちら も異なっているため,学習時間を短縮するためにリサイズやゼ ロパディングを行い,画素数が小さい PET に合わせた.

投影データの作成をスライスごとに行い, D.shape=(スライ ス枚数, 角度分割数, スライス画像の横幅)の大きさの行列を 取得する.そして, 次元を並び替えて D'.shape=(角度分割数, スライス枚数, スライス画像の横幅)にし, 1 角度ごとの全身の 投影データを用意する.これらの工程を図2に示す.



#### 図 1 シミュレーションの流れ

そして最後に投影データを人の肺の実測長(=300mm)[3]に切 り取る.患者によってスライス幅とスライス数が異なるため線 形補間して統一した.また,光子数の値が格納されている PET 投影データはリサイズのみでは値が大きくなってしまうため, 収縮率の逆数を掛け合わせる.その後,患者ごとに正規化をし て入力とした.

U-Net の学習は 1) 患者と投影データの全てをシャッフルす る, 2) 1 バッチ1 患者全ての投影データにする, 3) 角度の差を チャンネルと捉えてチャンネル数を 180 にし, その分 U-Net の 段階を減らす, 4) (3)と同じくチャンネル数を 180 にし, その分 U-Net の最大チャンネル数を減らして何度かチャンネル数と 画素数を変えずに遷移させる, の4 パターン行った.

## 4. 結果

評価指標には PSNR と SSIM を用いる.前者は正解画像を元 信号,出力画像を劣化信号と捉えて,その劣化度を評価するた めに採用した.後者は人間の主観的な画質を反映した評価指標 であるために採用した. U-Net のトレーニングでは両者が収束するまで学習させ,テ ストを行った.それぞれの実験における PSNR と SSIM の分布 に関する値を表 1 に示す.

PSNR で実験1は40 を超える箇所があったが,20 に近い値 のものもあった.入力チャンネル数を180 にした実験3,4 では どちらも全て,バッチ数を180 にした実験2 ではそのほとん どが実験1の平均を下回っていた.

SSIM も PSNR と同様のことが言え,実験1はその75%が非常に高い値となり,4実験の中で一番良い結果となった.

表 1 実験全体の PSNR と SSIM

	最小值	第一四分位数	第二四分位数	第三四分位数	最大値	平均值
実験1	20.89	32.65	34.75	36.80	41.88	34.44
実験2	17.76	27.74	29.71	31.70	36.77	29.53
実験3	16.98	23.62	25.39	26.72	30.17	25.02
実験4	18.67	24.67	26.36	27.82	31.76	26.12

	最小值	第一四分位数	第二四分位数	第三四分位数	最大値	平均值
実験1	0.9659	0.9967	0.9981	0.9988	0.9996	0.9971
実験2	0.9359	0.9901	0.9942	0.9966	0.9991	0.9914
実験3	0.8933	0.9753	0.9837	0.9883	0.9950	0.9789
実験4	0.9166	0.9793	0.9873	0.9909	0.9968	0.9831

また、実験3,4には画像の剪断が見られた.

## 4. まとめ

本研究では4つの実験を行い PET 投影データのみからの吸 収係数分布推定を行った.180枚の投影データをそれぞれ別の 画像として U-Net に入力した場合は,高精度で推定を行えた. しかし,チャンネルとして捉えて入力した場合は別角度が影響 しあって剪断が起きてしまった.

#### 謝辞

研究にあたり、ご助言を賜ったシステム情報系情報工学域教 授工藤博幸先生に深い感謝の意を表します.

## 利益相反の有無

なし

- H. Arabi, H. Zaidi : Deep learning-guided estimation of attenuation correction factors from time-of-flight PET emission data : Medical Image Analysis 64 : 1-11, 2020
- [2] C. Burger, G. Goerres, S. Schoenes et al : PET attenuation coefficients from CT images, experimental evaluation of the transformation of CT into PET 511-keV attenuation coefficients : Springer-Verlag : European Journal of Nuclear Medicine Vol. 29 : 922-927, 2002
- [3] 栗原稔雄:心臓気管支枝の比較解剖学的研究.:昭和医学会雑誌 21巻:251-264, 1961.

# 重粒子線がん治療における初の臨床適用に向けた OpenPET 装置開発

田島 英朗<sup>\*1</sup>, 寅松 千枝<sup>\*1</sup>, Akram Mohammadi<sup>\*1</sup>, 岩男 悠真<sup>\*1</sup>, 赤松 剛<sup>\*1</sup>, 稲玉 直子<sup>\*1</sup>,
 Han Gyu Kang<sup>\*1</sup>, 田尻 稔<sup>\*1</sup>, 水野 秀之<sup>\*1</sup>, 小藤 昌志<sup>\*1</sup>, 山谷 泰賀<sup>\*1</sup>
 \*<sup>1</sup> 量子科学技術研究開発機構

## Development of the OpenPET system for the first clinical application in heavy particle cancer therapy

Hideaki TASHIMA<sup>\*1</sup>, Chie TORAMATSU<sup>\*1</sup>, Akram Mohammadi<sup>\*1</sup>, Yuma IWAO<sup>\*1</sup>,

Go AKAMATSU<sup>\*1</sup>, Naoko INADAMA<sup>\*1</sup>, Han Gyu KANG<sup>\*1</sup>, Minoru TAJIRI<sup>\*1</sup>,

Hideyuki MIZUNO<sup>\*1</sup>, Masashi KOTO<sup>\*1</sup>, Taiga YAMAYA<sup>\*1</sup>

<sup>\*1</sup> National Institutes for Quantum Science and Technology

要旨:開放空間を持つ OpenPET は重粒子線照射中に PET 測定が可能である.照射によって生体内で副次的に生成された陽電子放 出核種をイメージングすることで,患者体内でのビーム飛程検証が可能になる.さらに、腫瘍内部の血流による洗い出し効果の測 定によって治療効果予測ができるようになる可能性もある.本研究では,OpenPET 装置を HIMAC (Heavy Ion Medical Accelerator in Chiba)の治療室へ導入するために,患者への照射時に安全かつ迅速に測定を実施するために必要なシステム開発を行った.具体的 には,患者セットアップから照射開始までに遅延が生じないように装置を測定位置へセットアップするための位置合わせ機構の開 発を行った.そして,実際に治療室へ試験設置し,人体頭部ファントムに対する照射及び OpenPET 測定を行った.その際,治療計 画装置を用いて実際の頭頚部がん治療を想定した照射野を形成した.結論として、臨床に即した照射において 3 次元 PET 画像を得 ることに成功した.

キーワード:重粒子線がん治療, in-beam PET, OpenPET, 飛程検証, 臨床応用

## 1. はじめに

重粒子線がん治療は限局した固形がんに対して効果の高い 治療法であり,適用可能な対象部位も広げられている.生体深 部に線量を集中させることが可能で,X線CT画像から綿密な 計算により治療計画を立て,精密な照射を行う.しかしながら, X線CT 画像から重粒子線の阻止能比へ変換する際の不確かさ などの要因により,実際の照射範囲(飛程)には不確かさが存 在する.実際に照射された重粒子線の飛程を検証できるように なれば、分割照射ごとに照射範囲を修正したり、本照射前に少 ない線量でテスト照射したりすることで,不確かさを低減でき る可能性がある.様々な飛程検証法が研究されている中,重粒 子線と生体組織との核破砕反応によって生じる陽電子放出核 種を照射中から撮像する in-beam PET が最も有望視されている [1]. これまでに開発された in-beam PET 装置は, 対向型で間に 重粒子線を通す方式であったが、原理的に 2D 画像に限られて いた. そこで、我々は in-beam PET が可能でかつ 3D 画像化が 可能な手法として OpenPET を開発した[2-4]. OpenPET は, 円 筒を平行する 2 平面で斜めにカットした検出器ジオメトリと なっており、フルリングでありながら測定視野中にビームを通 すことが可能である [3] (図1). これまでに、ヒトサイズの OpenPET 装置を開発し [4], 重粒子線がん治療装置である HIMAC (Heavy Ion Medical Accelerator in Chiba) の物理実験室 での実証実験を実施してきた.本研究では、OpenPET 装置を HIMAC の臨床治療室へ導入し、臨床応用を可能にすることを 目的とする. なお、対象とする HIMAC 治療室には水平と垂直



図 1.3D インビーム PET を可能とする OpenPET.

の2つの照射ポートがあるが、OpenPETのin-beam 測定は水平 照射ポートのみを対象とする.治療室導入のために OpenPET の位置合わせ機構及び,検出器校正のためのソフトウェア開発 を行った.そして,治療室へ試験設置し,人体頭部等価ファン トムに対して頭頚部がん治療を想定した照射野を作成し, inbeam OpenPET 測定を実施した.

#### 2. 方法

想定する臨床応用では、ロボットアームで操作される治療台



図 2. OpenPET 装置による物理実験から臨床応用への展開.





患者セットアップの模擬

重粒子線照射とインビームPET測定

図3. HIMAC治療室での人体等価頭部ファントムを用いたinbeam PET 測定. レールを使って OpenPET 装置をアイソセン ターへ移動.

に患者をセットアップしたのちに、OpenPET 装置を in-beam 測 定のためにアイソセンター(照射の基準位置)へ移動する.本 研究では、移動時の位置の再現性を確保するためのレール機構 を開発した(図3).車輪付きの OpenPET 装置を手動で動かし、 ショックアブソーバー付のストッパーで停止させることで患 者セットアップの際に退避させても元の位置へ精度よく戻す ことが可能となる.

臨床試験を想定したファントム実験として,人体等価頭部フ アントム (CIRS Proton Therapy Dosimetry Head Model 731-HN, Computerized Imaging References System, Inc. USA) に対し, 治 療計画装置を用いて頭頚部がん治療を想定した照射野を作成 し、スキャニングビームによる重粒子線照射と OpenPET 装置 による in-beam 測定を行った.人体等価頭部ファントムの X線 CT 画像を基に四角形の照射野を形成し、生物学的効果比によ り重み付けた線量を 4Gy とした. 開発したレール機構により OpenPET 装置をアイソセンターに移動し、照射と同時に測定 を開始した. 測定時間は40分とし、そのうち照射が行われた 時間は1分であった. 測定ではシングルデータ収集を行い, 同 時計数,検出器の結晶弁別,エネルギー弁別は測定終了後にソ フトウェア処理として実施した. 照射ビームはバンチと呼ばれ る構造を持っており、1秒前後の時間で照射(ビームオン)と 休止 (ビームオフ) が繰り返されている. ビームオンの間は即 発ガンマ線が多く出ているが、ビームオフの間はバックグラウ ンドノイズの少ないデータを取得できため、ビームオフ時間の 同時計数イベントも抽出した. 画像再構成は 3D リストモード OSEM (Ordered Subset Expectation Maximization) 法を用いた.

サブセット数8で反復回数は10回とした.感度補正,減弱補 正,散乱補正を適用した.減弱補正と散乱補正には,別途撮影 したX線CT画像を変換し,アイソセンターを基準に位置合わ せした減弱係数分布画像を用いた.ポストスムージングとして 半値幅 6mm の3D ガウシアンフィルタを適用した.

## 3. 結果

図4に作成した治療計画と OpenPET 装置で撮像した PET 画



図 4. 人体頭部等価ファントムに対して治療計画装置で計算 した照射野(左)と OpenPET 装置によるインビーム測定によ って得られた,核破砕反応によって生じた陽電子放出核種の 放射能分布画像(右).

像を示す. PET 画像は CT 画像とのフュージョン画像として表示した. 重粒子線の飛程終端は人体等価頭部ファントムの中心 に位置し, 照射野は中心から画像上の左側に向かって一様な分 布をしている. 一方で, PET 画像のピークは中心よりやや手前 に位置している. 飛程の終端付近でやや手前に陽電子放出核種 が多く生成された分布は, 照射後に患者を PET 装置へ移動さ せて撮像したオフライン PET の結果と同様である[5].

#### 4. まとめ

OpenPET 装置を HIMAC 治療室へ初めて導入し, 頭頚部がん 治療を想定したファントム実験を実施した. スキャニングビー ムにより照射野を形成し, in-beam PET にて 3D 画像の取得に 成功した. 今後, 実際の患者の治療に対して OpenPET 測定を 行う臨床試験を実施する予定である.

#### 謝辞

本研究は QST 戦略的理事長ファンド(創成的研究)の助成 を受けたものである.

# 利益相反の有無

なし

- Parodi K and Polf J C: In vivo range verification in particle therapy. Medical Physics 45: e1036-e1050, 2018.
- [2] Yamaya T, et al.: A proposal of an open PET geometry. Phys Med Biol 53: 757-73, 2008.
- [3] Tashima H, et al.: A single-ring OpenPET enabling PET imaging during radiotherapy. Phys Med Biol 57: 4705-18, 2012.
- [4] Tashima H, et al.: Development of a multiuse human-scale single-ring OpenPET system. IEEE TRPMS 5: 807-816, 2021.
- [5] Bauer J, et al.: Implementation and initial clinical experience of offline PET/CTbased verification of scanned carbon ion treatment. Radiotherapy and Oncology 107: 218-26, 2013.

Whole Gamma Imaging 4 号試作機の

PET・コンプトンカメラハイブリッドイメージングシミュレーション

菊地 智也\*1,田久 創大\*2,菅 幹生\*1,3,田島 英朗\*2,

錦戸 文彦\*2, 山谷 泰賀\*2

\*1 千葉大学融合理工学府医工学コース,\*2量子科学技術研究開発機構,

\*3千葉大学フロンティア医工学センター

PET and Compton camera hybrid imaging simulation of the 4th generation Whole Gamma

Imaging prototype.

Tomoya Kikuchi<sup>\*1</sup>, Sodai Takyu<sup>\*2</sup>, Mikio Suga<sup>\*1,3</sup>, Hideaki Tashima<sup>\*2</sup>,

Fumihiko Nishikido<sup>\*2</sup>, Taiga Yamaya<sup>\*2</sup>

<sup>\*1</sup> Graduate School of Science and Engineering, Chiba University

\*2 National Institutes for Quantum Science and Technology

<sup>\*3</sup>\_Center for Frontier Medical Engineering, Chiba University

要旨: Whole gamma imaging (WGI) は、PET 検出器リングの内側に散乱検出器リングを挿入し、PET とコンプトンカメラの2つの 画像化手法を1つの装置で実現する.<sup>89</sup>Zr は抗原抗体反応を利用したイメージングに適した PET 核種であるが、陽電子放出に比べ 4 倍ほど多く放出される 909 keV ガンマ線が画質低下の原因になっていた.WGI はこの 909 keV ガンマ線をコンプトンカメラによ り有効活用できるため、画質の向上が期待できる.本研究では、去年新たに設計した WGI4 号機の PET・コンプトンカメラハイブ リッドイメージング性能をシミュレーションにて予測した.<sup>89</sup>Zr 線源を封入したコントラストファントムを視野中心に配置し、PET 画像とハイブリッド画像のコントラストと均一性を評価した.同じコントラストで比較した場合、ハイブリッド画像では PET 画像 より 4.4%ノイズが低減していた.また収束した際のコントラストはハイブリッド画像の方でやや低下したが、均一性は 2%程度向 上した.

キーワード: Whole gamma imaging, PET, コンプトンカメラ, Geant4, <sup>89</sup>Zr

## 1. はじめに

Whole gamma imaging (WGI)は PET とコンプトンイメージン グを組み合わせた新たな核医学診断装置である[1]. PET 検出 器リングの内側に散乱検出器リングを挿入することで. 異なる 二つのイメージング技術を一つのシステムで実現する. PET は 高い感度と空間分解能を有する核医学診断装置としてしられ ている.しかし,イメージング可能な線源が陽電子放出核種に 制限されてしまう.一方で,コンプトンカメラは幅広いガンマ 線の検出が可能である.そのため,WGI では PET 核種以外の 幅広い種類の線源を用いることができる.

半減期約78時間の<sup>89</sup>Zrは比較的時間を要する抗体反応に着 目した PET 核種の一つとして知られている[2]. しかし, 陽電 子の約4倍多く放出される909keVのエネルギーを持つシン グルガンマ線がPET 画像の画質劣化の原因となっている.WGI ではコンプトンイメージングによりシングルガンマを有効利 用できるため, PET イベントとコンプトンイベントを組み合わ せた画像再構成をすることで画質の向上が期待できる[3]. 一 方, どの程度画質の向上が見込めるか明らかになっていない. 本研究では去年新たに設計したWGI4号機をモデル化し[4,5], PET・コンプトンハイブリッドイメージング性能を予測した.

## 2. 方法

1) WGI4 号機のシミュレーションジオメトリ

Geant4 を用いて、散乱検出器として HR-GAGG 結晶、吸収 検出器として LGSO 結晶を用いた小動物用 WGI をモデル化し た(図 1).シミュレーションしたジオメトリの主な仕様を表 1 に示す.散乱検出器および吸収検出器のリング内径は、それぞ れ 89 mm と 320 mm である.散乱検出器の厚みは 15 mm で、 三層の相互作用の深度識別(Depth-of-interaction: DOI)が可能 である.エネルギー分解能は 511 keV で 4.6%とした.



図1 WGI-4 のシミュレーションジオメトリ

#### 表1 主なジオメトリの仕様

	吸収検出器	散乱検出器
素材	LGSO	HG-GAGG
エネルギー分解能	13.7 %	4.6 %
@511 keV		
結晶サイズ	$3.0 \times 3.0 \times 20 \text{ mm}^3$	$1.5\times1.5\times5~\mathrm{mm^3}$
結晶数/検出器	$8 \times 8 \times 1$	$16\times16\times3$
DOI	Non-DOI	3-layer
検出器数	$36 \text{ det.} \times 6 \text{ rings}$	10 det. × 4 rings

#### 2) 評価方法

<sup>89</sup>Zrを封入したコントラストファントムをモデル化し,シ ミュレーションの視野中心に配置した. 画質評価にはコントラ ストファントムのリカバリ係数 (recovery coefficient: RC) と均 一性を用いた. RC の算出には,各ロッドの半径 10 mm の円に あたる領域を関心領域 (ROI) として使用した.ホットロッド とコールドロッドの RC 値 ( $Q_H, Q_C$ )は,式(1)および式(2) により定義した.  $C_H, C_B, C_C$ はそれぞれホット,バックグラウン ド,コールド ROI の平均画素値であり, $a_H, a_B$ は放射能比であ り,それぞれ4と1である.また,バックグラウンド領域に直 径 6 mm の円を 29 個配置し,各領域から算出される変動係数 を不均一性と定義した.

コンプトン, PET, ハイブリッド画像の再構成には逐次近似 型画像再構成法の一つである list-mode OSEM 法を用いた. ハ イブリッドイメージング法では, コンプトン画像と PET 画像 を別々に生成した(図 2)[6]. これらの画像の平均値をとり, 各サブイテレーションで画像を更新した. 各画像のボクセルサ イズは 1.0 × 1.0 × 1.0 mm<sup>3</sup>, ボクセル数は 80 × 80 × 15 とした. アクティビティを含むスライスを加算した画像を評価した.

$$Q_H = \frac{(C_H/C_B) - 1}{(a_H/a_B) - 1} \times 100$$
(1)

$$Q_C = (1 - C_C / C_B) \times 100$$
 (2)



図2 PET・コンプトンハイブリッドイメージングの

#### 3. 結果

画像再構成結果を図3に示す. RC 値の収束の様子を考慮し コンプトン画像は20反復, PET とハイブリッド画像は4反復 の画像を示している.ホットロッドとコールドロッドの RC 値 評価結果では、コンプトン画像が最も悪く、PET 画像はハイブ リッド画像に近い結果となった.具体的には、ホットロッドの 95%回復係数付近のノイズは、PET 画像で 0.181、ハイブリッ ド画像で 0.173 であった(図3(d)).ハイブリッド再構成では、 同じコントラスト回復率で PET 画像再構成よりも4%ノイズ が低くなった.均一性は PET 画像で 0.084、ハイブリッド画像 で 0.080 と 2%程の改善が確認された.

## 4. まとめ

WGI4 号機の PET・コンプトンカメラハイブリッドイメージ ング性能をシミュレーションにて予測した. 収束した際のコン トラストはやや低下したが,ハイブリッド画像では PET 画像 より 4%ノイズが低減しており,均一性は 2%度向上した.

## 謝辞

本研究の一部は科研費 JP20H05667の助成を受けたものです.

#### 利益相反の有無

なし

- [1] E. Yoshida et al., Phys. Med. Biol. 65, 125013, 2020
- [2] M. A. Deri et al., Nucl. Med. Biol., 40, 3-14, 2013
- [3] H. Tashima et al., Phys. Med. Biol. 65, 225038, 2020
- [4] 菊地智也, 他, 第 41 回日本医用画像工学会大会予稿集, 206-207, 2022
- [5] S. Takyu et al., 2022 IEEE NSS MIC, MIC-04-085, 2022
- [6] H. Tashima et al., Radiol Phys Technol, 36943646, 2023





# ESRGAN による医用画像の超高解像度化の検討

大坂 亮二\*1 安倍 和弥\*1 武尾 英哉\*1

\*1神奈川工科大学工学研究科電気電子工学専攻

## Investigation of ultra-high resolution of medical images by ESRGAN

Ryoji OHSAKA<sup>\*1</sup>, Kazuya ABE<sup>\*1</sup>, Hideya TAKEO<sup>\*1</sup>

<sup>\*1</sup> Kanagawa Institute of Technology, Electrical and Electronic Engineering

要旨:現在,医療画像の撮影装置の性能向上等により,それを読影する医師の負担も増加している.そこで, 医用画像の解像度を高 解像度化(超解像)を行うことにより,画像 1 枚1枚の情報量を増やすことによって検査を行う際に行われる複数回撮影する過程を 初期の低画質の撮影画像に対し超解像処理を行うことによって撮影回数を抑えるという方法で,医師や技師の負担を軽減すること や他にも,CAD(Computer-Assisted Diagnosis)の性能向上を行うこともできるのではないかと考えた.本研究では,超解像化技術を 用いた医用画像の超解像化画像生成により,診断画質の向上や CAD の性能向上に寄与することを目的とし,ESRGAN(Enhanced Super-Resolution GAN)をもちいた医用画像の超解像化画像の利用の提案を行う.ESRGAN の学習では,前立腺領域の MRI スライス画像を用 いた.結果として,ESRGAN による医用画像の正常な超解像処理を行うことに成功した.

キーワード: 医用画像, 超解像, ESRGAN, 診断画質, CAD

## 1. はじめに

現在,医療画像の撮影装置の性能向上等により,生成される医 用画像の枚数は多いものでは患者一人当たり 600~900 枚に及 ぶこともありそれを読影する医師の負担も増加している.

現在 CT 画像では1024×1024の解像度, MRI 画像では512×512 の解像度が主流である.これらの解像度は装置の改良とともに 向上してきた.今後も解像度の向上は行われていくと思われる が, 例えば CT 画像の2048×2048の解像度は普及出来ていない. 一方, 画像解像度の向上によって, 診断画質の向上やコンピュ ータ支援診断の性能向上が図られる.

ー般画像の解像度向上には従来, 隣接する画像間の画素値を 計算により求める補間法が用いられており, 近年では, 畳み込 みニューラルネットワーク (Convolutional Neural Networks :CNN) や敵対的生成ネットワーク (Generative Adversarial Networks :GAN)を用いたもの等が存在する.

そこで、本研究では画像の解像度向上技術である超解像化技術を用いて医用画像の超解像化画像を生成することにより、診断画質の向上や CAD の性能向上に寄与することを目的とし、敵対的生成ネットワークをもちいた Xintao らにより開発された ESRGAN(Enhanced Super-Resolution Generative Adversarial Networks)[1]による医用画像の超解像化処理を行う.

## 2. 手法

## 2.1. ESRGAN による学習

Xintao らによって開発された ESRGAN は超解像を行う敵対 的生成ネットワーク(GAN)である SRGAN の強化版にあた り,SRGAN と比較すると BatchNormalization 層の削除によりア ーチファクト生成の軽減や Residual Block を置き換えることに より学習が不安定になることを防いだものになっている. ESRGAN の学習では教師あり学習が行われる.この学習は、 教師データを一度2分の1サイズに落としその後 Bicubic 補間 を行った後に教師データに近づけるものになる.

この ESRGAN の学習に用いる画像サイズは,学習環境の都合 により図 2 のような縦横それぞれ 2 等分の 4 分割画像と 4 分 割画像の各境界を中央に置いた 5 つの画像を含む 9 つの画像 を用い学習を行った.

## 2.2. 合成及び評価手法

分割した画像は元の画像に対応したピクセル間での平均値 を入力することで結合を行った.

評価には既存の手法の1つである線形補間である Bicubic 補間と超解像技術を用いている SRCNN[2]による生成画像を ESRGAN による生成画像との比較を行う.

評価方法はPSNR[3]とSSIM[4]を用いた定量評価と被験者15 人による視覚評価を行った.

視覚評価では被験者 15 人に対して ESRGAN と SRCNN, Bicubic 補間による生成画像の3枚を1セットとし,原画像に対 して最も忠実に再現できているものから 1~3 に数字で評価し てもらった.



図1 前処理の図面

## 3. 実験及び考察

本研究では,前立腺領域の MRI スライス画像を 16488 画像用 いて提案手法の評価を行った.このうち 11514 例を教師データ として用い,学習時に用いなかった画像 10 画像を評価に使用し た.超解像モデル学習時のパラメータは,ミニバッチサイズが 1,epoch 数は 20 とした.

生成された合成前画像を図1に示す.



## 図2 生成画像(左:原画像,右:ESRGAN)

図 1 に示される通り基本構造が再現されておりアーチファ クトも発生せず生成されていることが分かる.このことから ESRGAN を用いた超解像処理において基本的な構造の再現は 医用画像においても問題なく発揮できていることがわかる.

次に合成後の定量評価における結果を表1に示す.

	ESRGAN	SRCNN	Bicubic
PSNR	40.952	40.234	38.992
SSIM	0.978	0.988	0.974

## 表1 定量評価平均値(合成済み画像)

表 1 に示されるように.PSNR は若干の優位性を示した が,SSIM において SRCNN に劣っていることが分かる. 次に視覚評価における結果を表 2 に示す.

#### 表2 視覚評価実験平均値(合成済み画像)

	ESRGAN	SRCNN	Bicubic
スコア	1.569697	1.248485	2.636364

表2にある通り,SRCNNが忠実に再現されていると判断された.そこで,ESRGAN により生成された合成前の特に重要な中央の画像の定量評価を行った.その結果を表3に示す.

#### 表3 定量評価平均值(合成前画像)

	ESRGAN	SRCNN	BiCubic
PSNR	46.210	40.934	39.978
SSIM	0.995	0.989	0.967

ここから合成前においては ESRGAN に優位性があることが

分かる.

結果から ESRGAN による画像の生成には問題が無かったが, 合成した画像ではほかの手法に劣っていたことから,画像の合成に問題があることが分かった.

原因として,上げられるものに図 2 に示すような合成痕が生 成されるという問題である.



図3 合成痕例

よく見ると合成痕が生成されていることから合成処理に 問題があるため,合成処理を見直す必要がある.

## 4. まとめと今後

今回,ESRGAN による超解像画像の生成には問題はなかった が合成の段階に問題があり有効性を示すことが出来なかった. 今後は,合成の手法の改善の後視覚評価実験,CAD 性能向上へ の寄与の確認を行っていきたいと考えている.

#### 謝辞

本研究着手当時から貴重なご指導を賜りました武尾英哉教授(2023 年 4 月逝去)に心より感謝の意を表します.

# 利益相反の有無

なし

- Xintao Wang, Ke Yu, Shixiang Wu et al.,"ESRGAN: Enhanced super-resolution generative adcersarial networks, Computer Vision ECCV 2018 Workshops Part V: pp. 63-79
- [2] Chao Dong, Chen Change Loy, Kaiming He et al: Learning a Deep Convolutional Network for Image Super-Resolution, Computer Vision ECCV 2014 Part IV: pp. 184-199
- [3] Q.Huynh-Thu, M.Ghanbari: Scope of validity of PSNR in image/video quality assessment, IET vol 44: pp. 800-801
- [4] Zhou Wang, A.C.Bovik, H.R.Sheikh et al: Image quality assessment: from error visibility to structural similarity,IEEE Transactions on Image Processing vol 13: pp. 600-612

# **拡散モデルを用いた胸部 CT 像の超解像** 関ロ 樂<sup>\*1</sup>, 稲井 邦博<sup>\*2</sup>, 木戸 尚治<sup>\*3</sup>, 清水 昭伸<sup>\*1</sup> <sup>\*1</sup> 東京農工大学大学院工学研究院 <sup>\*2</sup> 福井大学医学部分子病理学 <sup>\*3</sup> 大阪大学大学院医学系研究科

# Super-resolution of chest CT images using a diffusion model

Gaku SEKIGUCHI<sup>\*1</sup>, Kunihiro INAI<sup>\*2</sup>, Shoji KIDO<sup>\*3</sup>, Akinobu SHIMIZU<sup>\*1</sup> <sup>\*1</sup>Institute of Engineering, Tokyo University of Agriculture and Technology <sup>\*2</sup>Molecular Pathology, Faculty of Medicine, Fukui University <sup>\*3</sup>Graduate School of Medicine, Osaka University

要旨:本報告では、拡散モデルを用いた胸部 CT 像の超解像について報告する.気管支や血管、および、肺胞などの陰影のエッジ付近の超解像の精度を改善するために、Sobel フィルタを用いた重み付き損失を提案する.拡散モデルの学習は CT スライス像の一部を切り取った部分画像を用いて行い、推論では部分画像に対する超解像結果を再構成して高解像度のスライス像を生成した.本手法の有効性を評価するために、提案する超解像モデルを、マイクロ CT 像を bicubic ダウンサンプリングして作成した低解像度画像に適用した.評価では、PSNR と SSIM に加えて、パワースペクトルの正解との差を用いた.推論したモデルの性能を 10 枚の CT スライス像を用いて評価し、最新の方法の一つである Residual Channel Attention Networks と比較した.その結果、PSNR や SSIM では性能が劣るが、高周波のスペクトルをより正確に表現できることが分かった. キーワード:拡散モデル、胸部 CT、超解像

## 1. はじめに

近年, 医療の分野では3次元 CT 像などの医用画像の重要性 が増している [1]. 正確な診断のために,高い解像度が望まれ るが,撮影条件などの制限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(LR)画像から高解像度(HR)画 像を生成する超解像技術が注目されている.CT 像の超解像に 取り組んだ先行研究[2][3]では,PSNR や SSIM などの観点から は高い評価が得られたが,正解画像の分布を正確に捉えること ができず,不自然な解剖構造を生成してしまうことや,ボケな どが発生してしまうという問題があった.

本稿では、近年優れた結果を達成した Diffusion Model を基 づく超解像 SR3[4]を用いて、解剖構造の正確な復元、ボケの発 生の低減を目的とした超解像モデルを作成し、性能を評価する.

## 2. 拡散モデルによる超解像

本研究では、DDPM(Denoising Diffusion Probabilistic Models) [8]を条件付き画像生成に適応させたモデルである SR3[4]を用 いる.学習過程を図1に示す.まず、ランダムに設定したノイ ズスケジューリング変数 $\gamma_t(0 < \gamma_t < 1)$ の条件で HR 画像にノ イズを付与し、ノイズ付きデータを作成する.次にノイズ付き データと LR 画像を結合してネットワーク(図2)に入力する. ネットワークはノイズを推定し、実際に与えたノイズとの誤差 を最小化することによって学習を行う.損失関数を式(1)に示 したが、*ϵ*は正規分布に従うノイズ、*ϵ*<sub>θ</sub>は推定ノイズである.

$$\mathbb{E}_{\boldsymbol{x},\boldsymbol{y}_{0},\boldsymbol{\epsilon}} \left\| \boldsymbol{\epsilon} - \boldsymbol{\epsilon}_{\theta} \left( \boldsymbol{x}, \sqrt{\gamma_{t}} \boldsymbol{y}_{0} + \sqrt{1 - \gamma_{t}} \boldsymbol{\epsilon}, \gamma_{t} \right) \right\|_{1}$$
(1)

未知画像に対するテストでは、ノイズのみの画像とLR画像 を結合した後、学習済みモデルを用いて、画像からノイズを除 去する処理(逆拡散過程)を反復してHR画像を推定する.



図 2. SR3 のネットワーク図

本研究では、気管支、血管、肺胞などのエッジに注目をする 損失として、Sobel フィルタ重み付き損失(2)を提案する.

 $\mathbb{E}_{x,y_{0},\epsilon}(s+1) \| \epsilon - \epsilon_{\theta}(x, \sqrt{\gamma_{t}}y_{0} + \sqrt{1 - \gamma_{t}}\epsilon, \gamma_{t}) \|_{1}$  (2) ここで, s は入力画像に sobel フィルタを適用した後の画素値 を表している. s を重みとして導入することにより,気管支, 血管,肺胞のエッジ付近に注目した正確な超解像を期待する.

#### 3. 実験

#### 3.1 実験条件

画素サイズ 0.28mm の LR 画像から画素サイズ 0.07mm の HR 画像を推定した. ここで LR 画像は,福井大学で作成した 人体標本をマイクロ CT により撮影し,その HR 画像を bi-cubic ダウンサンプリングにより生成した.また,超解像モデルには bi-cubic アップサンプリングにより 4 倍に拡大した LR 画像か ら切り取った 64×64[pixel]のパッチ画像を入力とした(隣接 パッチの重複は 4 pixel).推定された超解像パッチ画像を並べ, HR 画像を再構成した.その際,隣接パッチは 4 pixel 重ね,画 素値は平均とした.optimizer は Adam( $\alpha = 10^{-4}$ ),評価指標に は PSNR, SSIM, 正解パワースペクトルとの差を用いた.なお, 本研究は,福井大学(20100064)と東京農工大学(210501-3027) の倫理委員会で承認を受けて実施した.

3.2 実験結果

表1に、bi-cubic 法や先行研究[3]の Residual Channel Attention Networks (RCAN) との比較結果を示した.また、図3はそれ ぞれの推定結果を示した.表1からは、PSNR、SSIM は先行研 究より劣っていることが分かる.しかし、図3の目視評価では、 全体的なボケが低減していた.そこで、ランダムに選択したス ライスの画像中心から 256×256 の部分画像を切り取り、パワ ースペクトルを求めた (図 4). 周波数ごとの平均パワースペ クトルの推移を図5に示す.また、表2は、LR 画像のナイキ スト周波数の整数倍の各区間における正解パワースペクトル との差の平均である.パワースペクトルの観点からは先行研究 よりも優れていること、また sobel 重みは特に高周波成分の復 元に有効であることが分かった.また、 $3f_{LR} - 4f_{LR}$ においては、 エッジに重みを付けたことにより、高周波成分がより正解分布 に近いことが分かったが、これは、気管支、血管、肺胞などの エッジが正確に復元できている可能性を示唆している.

	b1-cubic	先行研究	提案手法	提案手法
		[3]	(original 損失)	(重み付き損失)
PSNR	24.36	26.26	24.30	24.34
SSIM	0.571	0.667	0.562	0.569
(a)正解画 図	像 (b)入力j (bicub 3 正解画	画像(c)先行码 ic) 像,入力画修	研究[3] (d)提案 (d)提案 (original 象,および, 超	手法         (e)提案手法           (重み付き損免)         (重み付き損免)           (解像画像)         (1100000000000000000000000000000000000
	12			

## 表2 ナイキスト周波数の整数倍の各区間における平均パワ

	-	-スペクトル			
	$0 - f_{LR}$	$f_{LR} - 2f_{LR}$	$2f_{LR} - 3f_{LR}$	$3f_{LR} - 4f_{LR}$	
提案手法( <del>櫿</del> ) (original 損失)	0.2420	2.201	0.5360	1.075	
提案手法( <del>縁</del> ) (重み付き損失)	0.7052	3.659	0.6812	0.5779	
先行研究[3]( <mark>赤</mark> )	0.7865	11.05	18.87	20.54	
	um orstoriginal) ourstoriginal) ourstored weight sr_RCAN[3]	ets 4 × 10 <sup>1</sup>	Hequery	ours(original) ours(otel weighte	
· · · · · · · · · · · · · · · · · · ·	。 100 120 波数ご	との平均パリ	<sup>5 100 105 110</sup> harmor	115 120 125 sic num.	

## 4. まとめ

胸部 CT の超解像に拡散モデルを適用することによって,先行 研究と比べて,目視では全体的にボケが少なくなったことが確 認でき,スペクトル分布では正解 HR と同様の再現をすること が分かった.また,Sobel フィルタによる重み付き損失によっ て,高周波成分の分布をより再現できることが分かった.しか し,PSNR 等の評価指標では劣ってしまっている.これは拡散 モデルがノイズから HR 画像を復元する際に,一部のエッジ付 近にノイズが残ってしまい,性能を低下させていると考えられ る.今後の予定として,PSNR の向上のために,胸部 CT 像の HR 画像が分布する多様体への超解像結果の制約や,実際の臨 床 CT に近いガウシアンブラーやモーションブラーへの適用を 検討していく

## 謝辞

日頃から熱心にご指導・ご討論いただく東京農工大学清水昭 伸研究室の各位に感謝いたします.

利益相反の有無

なし

- 橋爪誠"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
- [2] 河合良亮,他"サイクル損失を用いた 3 次元 CT 像の超解像",第 38 回日本医用画像工学会大会予稿集,2019
- [3] B. Samarth, et al. "Super Resolution of Clinical CT Scans using Deep Learning" IJCARS. 17(suppl): S28-S29, 2022
- [4] C. Saharia, et al. "Image Super-Resolution via Iterative Refinement" IEEE PAMI. 45(4):4713-4726, 2023 doi: 10.1109/TPAMI.2022.3204461
- [5] Ho J., et al. "Denoising diffusion probabilistic models". In NeurIPS, 2020

# 深層学習とセグメント PSFT 信号を利用した MR 画像の超解像

藤澤 舜太郎\*1,山登 一輝\*1,伊藤 聡志\*1

\*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

Super-resolution of MR images using deep learning and segmental PSFT signals

Shuntaro FUJISAWA<sup>\*1</sup>, Kazuki YAMATO<sup>\*1</sup>, Satoshi ITO<sup>\*1</sup>

## <sup>\*1</sup> Graduate Program in Information, Electrical and Electronic Systems Engineering Utsunomiya University

要旨:MRIの撮像時間短縮のため、少数の収集信号から画像を再生する圧縮センシングが利用できるが、少数の信号収集量では、 再構成像の品質低下が避けられない.本研究では、位相拡散フーリエ変換映像法(PSFT)の信号をセグメント収集し、収集信号か らの超解像的画像再構成法について検討する.PSFT 信号は、汎用のフーリエ法に二次の位相変調を加えることで得られる.先行研 究では、等間隔なセグメントを間欠的に収集した PSFT 信号から反復再構成法により高品質な再構成像を確認しているが、等間隔 なセグメント収集では特定の位相変調係数で再構成像の品質低下の問題があった.そこで、本研究ではセグメント幅とその間隔を 不等間隔に配置することを提案する.さらに、深層学習再構成の導入により再構成像の品質向上を図った.実験の結果、PSNR や SSIM の向上に加えて、主観的な画像品質の改善も確認できたので報告する.

キーワード: MRI, 画像再構成法, PSFT, 深層学習, 超解像

## 1. はじめに

MRI による撮像時間短縮のために、少数信号からの画像再 生が考えられるが、少数信号から高分解能な再構成像を取得す ることは難しい.本研究室では、汎用のフーリエ変換映像法 (FT)に二次の位相変調項を加えた位相拡散フーリエ変換映像 法 (PSFT: Phase Scrambling Fourier Transform imaging)を利用し た高分解能な画像再構成法が提案され[1],先行研究では信号 収集領域を複数に分割するセグメント収集を導入し、未収集信 号を内挿・外挿によって推定する手法を提案した[2].しかし、 先行手法ではセグメントを等間隔に配置したことに起因する、 特定の位相変調を行った際の再構成像の品質低下が問題であ った.本研究では、セグメントの幅・間隔を不等間隔に配置す る不等間隔セグメント収集を提案し、再構成像品質の向上を図 った.さらに、深層学習を利用して再構成像の分解能の改善を 図り、提案法を先行手法と比較することにより有効性を示す.

#### 2. PSFT

PSFT は,信号収集量を制限して再構成像に生じる誤差を拡 散する効果があり,被写体が実関数である条件で信号を事後的 に超解像できる. PSFT の信号は式(1)で表される.

$$v(k_x,k_y) = \iint_{-\infty}^{\infty} \rho(x,y) e^{-j\gamma b\tau(x^2+y^2)} e^{-j(k_x x+k_y y)} dx dy \quad (1)$$

ここで、 $\rho(x,y)$ はxy平面のスピン密度分布、 $\gamma$ は磁気 回転比、bは 2 次関数状磁界の係数、 $\tau$ は印加時間、 $k_x$ 、 $k_y$ は 空間周波数である。撮像パラメータ $\gamma b\tau$ について、データ長 をN、画素幅を $\Delta x$ とすると、再生像上において中心からの距 離が最大になる位置を $m\Delta x$ として式(2)を満足する必要があ る.



(a)中央連続収集 (b)等間隔(先行手法) (c)不等間隔(提案法) 図 1.信号収集パターン(横方向:位相エンコード)

$$\Delta x \frac{\partial (\gamma b \tau x^2)}{\partial x} \Big|_{x=m\Delta x} = 2\gamma b \tau m \Delta x^2 \le \pi$$
(2)

ここで、被写体幅が視野幅に等しい $m\Delta x = N\Delta x/2$ のとき、 式(3)を得る.

$$\gamma b\tau \le \frac{\pi}{N\Delta x^2} \ (=\overline{\gamma b\tau}) \tag{3}$$

撮像パラメータybtは位相拡散係数hを導入しybt = hybtと表 す. hが大きいほど拡散効果が大きくなるため, PSFT 信号はk空間の広い領域に分布する形状となる. なお, h = 0であれば,  $v(k_x, k_y)$ は FT 信号となる.

### 3. 信号収集パターン

図1に本研究で使用した信号収集パターンを示し、収集領域 を白,未収集領域を黒で表している.図1(a)は信号の低域のみ を収集する.(b)は先行研究で導入した収集領域を複数に分割 するセグメント収集であり、セグメント幅は中央が16、中央以 外を8、セグメント間隔を6行として等間隔に配置している. (c)は本稿で提案したパターンであり、中央の幅を16、中央か らセグメント幅は14,12,10,8,6,4,2、セグメント間隔は1,2,3, 4,5,6,7 とそれぞれ不等間隔に配置している.(c)のパターンは



図 2. Generic-ADMM-Net のネットワーク構成

信号収集領域を不等間隔に配置することで,信号のインコヒー レント性を高め,再構成像の急激な品質低下を回避することが 期待できる.(b),(c)のパターンの分割数は15,いずれも信号収 集率は25%である.

## 4. Genric-ADMM-Net

深層学習には、Yang らによって提案された交互方向乗数法 (ADMM: Alternating Direction Method of Multipliers)の解法アル ゴリズムを用いたネットワークである Generic-ADMM-Net を 使用した[3]. 図 2 に Genric-ADMM-Net のネットワーク構成を 示す. 図中の stage nは ADMM のn回目の反復処理に対応し、 再構成層 $X^{(n)}$ , 誤差除去層 $Z^{(n)}$ , 乗算更新層 $M^{(n)}$ からなる.  $Z^{(n)}$ は、2 つの畳み込み層 $(C_1^{(n,k)}; C_2^{(n,k)})$ , 非線形層 $H^{(n,k)}$ , 加算層  $A^{(n,k)}$ から構成され、 $Z^{(n)}$ 層は $N_t$ 回の反復処理からなる. Generic-ADMM-Net では、k空間からサンプリングされた信号 を入力し、 $N_t$ 個のステージを通過後、再構成層 $X^{(N_a+1)}$ で再構成 像が出力される.本研究では、図 1 の各信号収集パターンで帯 域制限した PSFT 信号を入力として、画像再構成を行った.

## 5. 再構成シミュレーション実験

提案法の有効性を確認するために、画像再構成シミュレーション実験を実施した.使用画像には IXI Dataset[4]が提供している頭部 T1 強調像 400 枚を使用し、学習に 300 枚、テストに 100 枚とした.画像サイズは 256×256 pixel である.図3の差分画像から、FT 法、中央収集、等間隔収集と比較すると、提案法が最も入力画像との誤差が少なく、図4 から、提案法の PSNR・SSIM はhにかかわらず、いずれの方法よりも上回っていることが確認される.また図3の拡大画像を比較すると、FT よりも PSFT を適用した方が、入力画像に近い画像になっていることが分かる.したがって、提案法の有効性が確認される.一方、等間隔収集はセグメント幅・間隔が一定のため、収集信号のコヒーレント性が高くなり、特定の位相変調(h = 0.7)でエイリアスが生じ、再構成像の品質が急激に低下した.提案法のようにセグメントを不等間隔に配置することで信号のコヒーレ





図 4. PSNR と SSIM

ント性が抑制できたため、等間隔セグメント収集の問題を解消 できたと考える.

## 6. おわりに

本研究では、セグメント幅・間隔を不等間隔に配置する信号 収集法を提案し、深層学習再構成を使用して再構成品質を向上 させる手法について検討した.実験結果から、提案法ではいず れの方法よりも高い PSNR・SSIM が得られ、再構成品質の向 上が確認された.また、提案法の分解能改善効果を定量的に評 価することが今後の課題として挙げられる.

#### 謝辞

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.

- [1] 伊藤聡志,劉娜,山田芳文,:位相拡散フーリエ変換法と超解像法 的手法による MRI 測定時間の短縮,日本磁気共鳴医学会雑誌,第 28 巻 2 号, pp.142-146, 2008.
- [2] Yamato K and Ito S,: Super-Resolution Magnetic Resonance Imaging using Segmented Signals in Phase-Scrambling Fourier Transform Imaging and Deep Learning. 2022 IEEE International Conference on Image Processing (ICIP), 2022, pp. 2551-2555.
- [3] Yang Y et al,: Admm-csnet: A deep learning approach for image compressive sensing. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 42, no.3, pp. 521–538, 2020.
- [4] IXI dataset. https://brain-development.org/ixi-dataset/ (2022/9/13)

## X線暗視野法を用いた膵管内乳頭粘液性腫瘍における乳頭状構造の3次元解析

天野 遥菜\*1,砂口 尚輝\*1,黄 卓然\*1,岩越 朱里\*2, 末永 雅也\*2,

市原 周\*2, 西村 理恵子\*2, 島雄 大介\*3 湯浅 哲也\*4 安藤 正海\*5

\*'東海国立大学機構名古屋大学医学部保健学科放射線技術科学専攻

\*2 国立病院機構名古屋医療センター

\*3 大阪物療大学保健医療学部診療放射線技術学科

\*4 山形大学大学院理工学研究科

\*5 高エネルギー加速器研究機構

# Three-dimensional analysis of papillary structures of intraductal papillary mucinous neoplasm

tissue using the refraction-contrast computed tomography based on X-ray dark-field imaging

Haruna AMANO<sup>\*1</sup>, Naoki SUNAGUCHI<sup>\*1</sup>, Zhuoran HUANG<sup>\*1</sup>, Akari IWAKOSHI<sup>\*2</sup>,

Masaya SUENAGA<sup>\*2</sup>, Shu ICHIHARA<sup>\*2</sup>, Rieko NISHIMURA<sup>\*2</sup>, Daisuke SHIMAO<sup>\*3</sup>,

Tetsuya YUASA<sup>\*4</sup>, Masami ANDO<sup>\*5</sup>

# \*1 Nagoya University

\*2 Nagoya Medical Center

\*3 Osaka University of Material treatment

\*4 Yamagata University

# \*5 *KEK*

要旨: X線暗視野法(XDFI: X-ray Dark field imaging)に基づく屈折コントラスト CT は,染色した病理組織像に匹敵するコントラストと数 μm の空間分解能で生体軟組織内を可視化できるため、様々な生体試料の微小解剖構造の解析に利用されている.本研究では、ヒト膵管内乳頭粘液性腫瘍の3次元微細構造を XDFI で可視化し、腫瘍が膵管内を進展していく様子を再構成画像から考察する. CT スライス像では、同スライス面の病理画像と同様の腫瘍構造が描出された. CT 像にボリュームレンダリングを適用した3次元像では、これらの各隆起が独立した凸の構造(乳頭状構造)ではなく、膵管の管軸方向に向かって波状・山脈状に繋がっていく様子が確認できた. XDFI による可視化は、病理組織像による従来の2次元観察だけでは困難であった腫瘍の3次元微細構造の把握に寄与する.

キーワード: X 線暗視野法,屈折コントラスト CT,膵管内乳頭粘液性腫瘍,放射光イメージング

## 1. はじめに

X線暗視野法(XDFI)に基づく屈折コントラストCTは,病理 画像に匹敵する組織コントラストで生体軟組織内の詳細な 3 次元構造を再構成できる.我々は XDFIを用いて乳癌組織や肺 癌組織など様々な生体試料を撮影し,3次元構築に関する形態 学的情報を集めてきた[1][2]. 膵臓腫瘍の一つである膵管内 乳頭粘液性腫瘍組織(IPMN: Intraductal Papillary Mucinous Neoplasm)は,拡張した膵管内に種々の程度に隆起性病変を形 成する腫瘍であり,良性~悪性までを含む疾患概念である.腫 瘍の分布と進行度に応じた適切な手術が必要となるが,従来 のモダリティによる正確な範囲・悪性度の術前判定は十分とは いえない[3].本研究では PMN を XDFI で可視化し,詳細な 3 次元構築に関する新たな知見を得ることを目的とする.

## 2. 方法

図1はXDFIに基づく屈折コントラスト撮像システムの概要

所属:名古屋大学 連絡先住所:〒461-8673 愛知県名古屋市東区大幸南1-1-20

e-mail : kb.55c.9782@s.thers.ac.jp

図である. XDFI は、モノクロメーターコリメータ (MC) (非 対称 Bragg 型 Si 単結晶), アクリル製円筒フィルタ, 試料回転 ステージ, Laue 角度アナライザ(LAA: Laue-case angle analyzer) (非対称 Laue 型 Si 単結晶), X 線カメラから構成される. X 線 光源には、高輝度・高指向性な放射光が利用される. シンクロ トロンから発生した放射光 X 線は、まず2 結晶分光器により 単色化された後, MC の非対称回折により、ビームの幅が拡大 される. アクリル製円筒フィルタと XY スリットを通ったビー ムは試料に入射し, 試料内の屈折率分布に従って微小に屈折し ながら伝搬する. アクリル円筒フィルタは、円筒状試料容器の 表面の屈折を打ち消す目的で利用される. 試料を透過したビー ムは後方の LAA によって前方回折ビームと回折ビームに分割



されるが、ビームの角度偏差に従ってそれぞれの回折強度は変 化する.その変化量が屈折コントラストであり、前方回折方向 に設置した X 線カメラにより屈折コントラスト像を得ること ができる.また、試料の回転毎に投影撮影を行うことで CT の 再構成に必要な投影セットを得ることができる.

撮像装置は、高エネルギー加速器研究機構フォトンファクト リーの BL14B ビームラインに構築された. 単色 X 線エネルギ ーは 19.8keV, MC の回折面は Si(111), 非対称角は 5.4 度であ る. LAA の回折面は Si(111), 厚さは 166 μm, 非対称角は 5.0 度である. 回転ステップ角は 0.144 度,投影数は 2500 枚であ る. X 線カメラのピクセルサイズは 5.5 μm, 画素数は 4608× 2592 である. 1 投影の露光時間は 4 秒である. CT は Filtered Backprojection 法により再構成される.

撮影試料は、60代男性の膵臓手術検体の病理診断後残余組織である.この試料は、病理診断に適した大きさ(約20×30×5 mm<sup>3</sup>)に切り分けられており、ホルマリン固定されている.また、術後に行われた病理診断によって混合型 IPMN であることが分かっている.今回は腫瘍を含む連続した4個の試料を撮影対象としており、各試料は、撮影の数時間前に蒸留水に浸された後に内径20 mmのアクリル製円筒容器に挿入され、アガロースゲルで埋められている.

撮影された CT 像を用いて, CT スライス像と対応する病理 像の2次元平面上での画像比較および Maximum Intensity Projection (MIP)像とボリュームレンダリング像による3次元観 察を実施した.この観察では特に,分枝膵管から主膵管にかけ て分布する腫瘍の進展について着目する.本研究で扱うヒト膵 臓の画像データの研究利用は,名古屋大学医学部保健学科及び 名古屋医療センターの生命倫理審査で承認されている.

## 3. 結果と考察

図2はパラフィン包埋(FFPE)ブロックから薄切しHE染色さ れた病理組織標本の肉眼像(a)とそれに対応する再構成断面 (b),および(b)の拡大像(c)である.病理像で青い点で囲まれた 領域において拡張した膵管内に増殖する腫瘍(IPMN)が存在し ており,一部で内腔に突出するポリープ状の腫瘍成分が肉眼的 にも確認できる.一方,(a)の黄色の点で囲まれた領域(主膵管) では肉眼的に隆起性病変がはっきりしないが,拡大像(c)では 主膵管の内壁が IPMN の疾患名の通り,微細な乳頭様の隆起性 病変で覆われていることがわかる. 図3(a)は CT ボリューム から作成されたボリュームレンダリング像であり,主膵管のみ をカラーのボリュームレンダリング像で別に作成し,フュージ ョンしている.図3(b)は主膵管を画像処理で半月切りにし,内 部から壁面の構造を観察したものである.図3(a)では,主膵管



図 2 HE 染色された病理像(a), CT 画像(b), 主膵管壁の拡大像(c)



図 3 ボリュームレンダリング像

認できる. 拡張した膵管内で隆起性に増殖する腫瘍構造に着目 すると, 2 次元平面では乳頭状の突起が膵管の内面に並んでい るように見えたが, 3 次元像では各隆起が独立した凸の構造で はなく, 膵管の管軸方向に向かって波状・山脈状に繋がってい く様子が確認できた. 図 3(b)左側の黄色の点線部分は, 山脈状 で鱗の様に重なっていることも確認された. 画像左側から右側 にいくにつれ, 乳頭状構造の密度が高くなっていることも分か る. これらの結果は従来の 2 次元平面観察では認識困難な知見 である.

## 4. まとめ

XDFIは IPMN の進展形式を3次元的に詳細に観察できる. 今後, IPMN が膵管内を進展していく様子を広範囲で可視化し, 腫瘍の進展範囲を正確に同定することを目指す.

#### 利益相反の有無

なし

- [1] Ando M, Maksimenko A, Sugiyama H, et al.: Simple X-ray dark-and brightfield imaging using achromatic Laue optics, Jpn J Appl Phys 41, L1016-L1018, 2002.
- [2] Sunaguchi N, Shimao D, Yuasa T, et al.: Three-dimensional microanatomy of human nipple visualized by X-ray dark-field computed tomography. Breast Cancer Res Treat 180, 397-405, 2020.
- [3] N. Sata, K. Kurihara, M. Koizumi, M. Tsukahara, K. Yoshizawa & H. Nagai : CT virtual pancreatoscopy: a new method for diagnosing intraductal papillary mucinous neoplasm (IPMN) of the pancreas.

# Peripheral Pulmonary Lesions Classification Using Endobronchial Ultrasonography Images Based on Ensemble Learning and Down-Sampling Technique

Huitao WANG<sup>\*1</sup>, Kohei SHIKANO<sup>\*2</sup>, Takahiro NAKAJIMA<sup>\*3</sup>, Ziyao LI<sup>\*4</sup>

Yukihiro NOMURA<sup>\*5</sup>, Toshiya NAKAGUCHI<sup>\*6</sup>

<sup>\*1</sup> Graduate School of Science and Engineering, Chiba University

\*2 Department of Respirology, Graduate School of Medicine, Chiba University.

\*3 Department of General Thoracic Surgery, Dokkyo Medical University.

<sup>\*4</sup> East Hospital of Tongji University.

\*5\*6 Center for Frontier Medical Engineering, Chiba University.

**Abstract**: Lung cancer is the second most common cancer in the world. Millions of people die from it. This study aims to develop a computeraided diagnosis (CAD) system to help medical doctors differentiate benign and malignant peripheral pulmonary lesions (PPLs) in endobronchial ultrasonography (EBUS) images based on deep learning. Our CAD system is based on the ensemble learning and down-sampling technique. We trained six pre-trained convolutional neural networks (CNN) models, including ResNet-18, ResNet-34, DenseNet-121, DenseNet169, MobileNet-V2, and ShuffeNet-V2. The trained models are aggregated by the bagging ensemble and stacking ensemble techniques. We evaluated the proposed system with five-fold cross-validation in the experiments. The final experimental results are the average of the five-fold experimental results showing that the accuracy, sensitivity, specificity, positive predictive value, negative predictive value, and area under the curve (AUC) values are 0.81, 0.66, 0.97, 0.97, 0.74, and 0.84, respectively. Conclusions: The proposed CAD system has the potential ability to diagnose PPLs in EBUS images based on deep learning.

Keywords: Lung Cancer, Endobronchial Ultrasonography (EBUS), Peripheral Pulmonary Lesions (PPLs), Ensemble Learning, Down-Sampling

#### 1. Introduction

Based on the GLOBOCAN 2020 cancer incidence and mortality estimates compiled by the International Agency for Research on Cancer, lung cancer ranks second in new cancer cases, accounting for 11.4%, and first in cancer deaths, accounting for 18% [1]. Lung cancer remains the largest cause of cancer death worldwide, with an overall five-year survival rate of only 15%. Early diagnosis is particularly important to improve lung cancer's survival rate which is the key to the successful treatment and management of lung cancer. Unfortunately, early lung cancer detection methods are not ideal [2]. In recent years, endobronchial ultrasound (EBUS) has been used more and more in the diagnosis of lung cancer because of its advantages of good real-time performance, no radiation, and superior performance. This research developed a computer-aided diagnosis (CAD) system based on the ensemble learning and down-sampling technique to differentiate the benign and malignant PPLs in EBUS images.

## 2. Materials and Proposed Method

#### 2.1 Materials

The EBUS images used in this research were acquired from Chiba University Hospital from September 2019 to April 2020. An endoscopic ultrasound system (EU-M30; Olympus) and a 20 MHz miniature radial probe (UM-S20-20R; Olympus) was utilized to acquire the EBUS images. The probe provides a 360-degree panoramic ultrasonic view of peripheral pulmonary lesions. In the experimental data, the physicians collected EBUS videos from 71 patients. There are 61 malignant cases and 10 benign cases. The format of the EBUS image is an 8-bit RGB image. The original data is a video in MOV format, the data pre-processing is used to convert EBUS video data into frame-by-frame. After that, image screening is performed to screen the noisy images. Data balancing is also performed in this study. Four types of data augmentation were used for benign cases, which are random rotation (/90°/180°/), vertical flip, and horizontal flip. Two types of data augmentation were used for malignant cases, which is random rotation (/90°/180°/) only.

#### 2.2 Proposed Method

The CAD system is shown in Figure 1. A combination of deep learning algorithms and machine learning algorithms is used in the CAD system. The key idea is that first, we train three deep learning models using train set data and then aggregate the trained models together using the idea of the ensemble. In detail, the malignant cases in the training set are divided into three equal parts. After that, the malignant cases in each part will be combined with all benign cases in the train set are used to train the CNN models, and the three trained CNN models are finally aggregated together by using the bagging ensemble and stacking ensemble techniques.



Figure 1. This graph shows the constructed CAD system which is based on downsampling and bagging ensemble learning. Firstly, the CNN models are trained, then aggregated the predictions with bagging ensemble learning.

For each CNN model, the pre-trained weights are used for each model. All convolutional layers within each used pre-trained model, are frozen, and the original fully connected layers are replaced with three-layers fully connected layers. Dropout [3] and batch normalization layers have been used in the fully connected layers. In the experiment, the probability of dropout was set to 0.2.

In this study, when training the CNN model, we set the epochs equal to 50, and the batch size as 32. All the input images will be resized into  $224 \times 224$  pixels, and then fed to the CNN models. Also, we set the learning rate as 0.001 and use the cross-entropy as the loss function and select the Adam as optimizer. The performance of the CAD system is measured by using seven evaluation indicators: accuracy, sensitivity, specificity, positive predictive value (PPV), negative predictive value (NPV), F1-score, and area under the curve (AUC). Except for seven introduced indicators, the five-fold cross-validation also is used.

#### 3. Experimental Results

The experiments were implemented in Python programming language with Python libraries such as OpenCV-python, Scikit-learn, matplotlib, and NumPy. In the ensemble experiment, six pre-trained CNN models are selected as the backbone, including ResNet-18, ResNet-34, DenseNet-121, DenseNet169, MobileNet-V2, and ShuffeNet-V2[4, 5, 6, 7]. The comparison result between the baseline and bagging and the stacking ensemble is shown in Table 1.

#### 4. Conclusion

This research developed a CAD system based on the ensemble learning and down-sampling technique to differentiate the benign and malignant PPLs in EBUS images. Two kinds of ensemble methods have been utilized bagging and stacking ensemble. The final experimental results are accuracy, F1-Score, AUC, PPV, NPV, sensitivity, and specificity are 0.81, 0.77, 0.84, 0.97, 0.74, 0.66, and 0.97 respectively. From the experiment results, the developed CAD system has the potential ability to diagnose PPLs by using the EBUS images based on deep learning.

#### **Conflict of Interest: None**

#### References

- [1] Sung H, Ferlay J, Siegel RL, Laversanne M, Soerjomataram I, Jemal A, Bray F. Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries. CA Cancer J Clin 2021, 71, 209-249.
- [2] McWilliams A, Lam B, Sutedja T. Early proximal lung cancer diagnosis and treatment. European Respiratory Journal 2009, 33, 656-665.
- [3] Hinton G E, Srivastava N, Krizhevsky A, et al. Improving neural networks by preventing co-adaptation of feature detectors. arXiv 2012, 1207.0580.
- [4] Kaiming He and Xiangyu Zhang and Shaoqing Ren and Jian Sun. Deep Residual Learning for Image Recognition. 2015, 1512.03385
- [5] Gao Huang and Zhuang Liu and Laurens van der Maaten and Kilian Q. Weinberger. Densely Connected Convolutional Networks. 2018, 1608.06993
- [6] Mark Sandler and Andrew Howard and Menglong Zhu and Andrey Zhmoginov and Liang-Chieh Chen. MobileNetV2: Inverted Residuals and Linear Bottlenecks. 2019, 1801.04381
- [7] Ma, Ningning and Zhang, Xiangyu and Zheng, Hai-Tao and Sun, Jian. Shufflenet v2: Practical guidelines for efficient cnn architecture design. Proceedings of the European conference on computer vision (ECCV) 2018, 116–131.

	Model Name	Accuracy	F1-Score	AUC	PPV	NPV	Sensitivity	Specificity
	ResNet-18	0.59	0.60	0.61	0.65	0.50	0.60	0.59
Baseline	DenseNet-121	0.62	0.66	0.66	0.68	0.54	0.68	0.54
	MobileNet-V2	0.63	0.56	0.62	0.76	0.59	0.50	0.78
Bagging	Majority Voting	0.77	0.71	0.77	0.97	0.69	0.58	0.97
Stacking	-	0.75	0.70	0.81	0.90	0.68	0.60	0.91
Bagging								
+Stacking	-	0.81	0.77	0.84	0.97	0.74	0.66	0.97

Table1. This table shows comparison results between baseline and ensemble models.

U-Net を用いた胸部 X 線像からの左肺境界の検出

永田 亮一\*1, 畑中 裕司\*1 \*1 大分大学理工学部

Detection of Left Lung Boundary in Chest Radiographs Using U-Net Ryoichi NAGATA<sup>\*1</sup>, Yuji HATANAKA<sup>\*1</sup> <sup>\*1</sup> Faculty of Science and Technology, Oita University

要旨:肺がん診断を支援する手法として,胸部X線像からの肺結節自動検出がある.この手法では肺境界で囲まれた領域内から 肺結節を検出するため、肺境界検出が重要となる.本論文では、U-Netを用いて、臓器やガスの影響が少なくない左肺境界を検 出するための手法を提案する. 医用画像で教師あり学習を行う際, データを大量に用意することが難しいという問題がある. そ のため、胸部 X 線像の左肺境界上に複数の関心領域を配置し、関心領域を画像として切り出すことでデータ数を増やす.また左 肺境界について学習・検出する際、左肺の特徴から左肺境界を4つの領域に分割し、それぞれ別々のモデルで学習することによ って左肺境界の検出精度を高める. JSRT データベースの画像に対して左肺境界を検出した結果, Dice 係数が平均 0.644 となった. キーワード: 胸部 X 線像, コンピュータ支援診断, 肺境界, U-Net, 関心領域

#### 1. はじめに

肺がんは、早期発見が重要である. 定期健康診断時には読 影医が多くの胸部 X 線像を読影するため,診断負荷が大きい. また,肺がんを専門とする読影医の不足なども課題となって いる [1]. 肺がん診断の支援手法として、胸部 X 線像から の肺結節自動検出 [2] がある. この手法では肺境界で囲ま れた領域内から肺結節を検出するため,肺境界の検出が重要 となる. 胸部 X 線像から解剖学的構造の一部である領域や線 構造の領域を抽出する手法 [3] では、抽出対象の領域ごと に U-Net を用いる.本論文では、文献 [3] と同様に複数の U-Net を用いて、臓器やガスの影響を受けやすい、線構造の 領域のみからなる左肺境界全体を検出する手法を提案する.

#### 2. 提案手法

まず、大まかな左肺領域を検出する.次に、検出された左 肺領域の輪郭情報をもとに左肺境界と思われる位置に関心 領域を置き, 関心領域中から左肺境界を抽出する.

1) 左肺領域の学習と検出

U-Net に学習用の胸部 X 線像と正解データとしての左肺 領域マスク画像をセットで入力し、学習を行う(図 1(a)). 学習によって得られる左肺領域抽出モデル(U-Net CR)にテ スト用の胸部 X 線像を入力する事で, 左肺領域候補を抽出す る. そして, 面積最大の領域を左肺領域とする (図 1(b)). 2) 関心領域の決定と画像切り出し

本論文では, 関心領域中に左肺境界が存在する事を想定し ているため、以下の①と②の画像において、 左肺境界を含む よう関心領域を配置する.

① 学習に使用する胸部 X 線像,正解である左肺領域マスク

画像, 左肺境界マスク画像

② テストに使用する胸部 X 線像, U-Net CR から抽出される 左肺領域のマスク画像

なお、検出精度向上の為に、左肺境界を top・bottom・right・ left のパーツ (図 2(a)) を含む 4 つの領域に分ける. そして, 4つの領域毎に関心領域を配置する.

まず、①に対する処理について述べる. 左肺領域マスク画 像の輪郭座標情報から輪郭の外接矩形を求める(図 2(b)).



(a) 学習例 (b) 検出例 胸部 X 線像と左肺領域マスク画像 図 1





4つのパーツ

(b) 輪郭と外接矩形 図 2 4つのパーツと輪郭および外接矩形







(b) (a) (c)(a): 関心領域を配置, (b): 胸部 X 線像上の関心領域 (c): 左肺境界マスク画像上の関心領域

(d): 切り出し画像

図 3 学習のための関心領域切り出し例

外接矩形の情報を用いて4つの領域ごとに関心領域の位置と サイズを決める.データ数を増やす為,各関心領域を移動さ せながら,対応する領域を学習用の胸部 X 線像と左肺境界マ スク画像から画像として切り出す (図 3).それぞれの画像の 集合を  $ROI_{A_{1\sim4}}$   $\geq ROI_{B_{1\sim4}}$   $\geq$   $\tau$  = 5.

次に、②に対する処理について述べる.2.1)より求まる左 肺領域画像の左肺領域マスク画像から作成する左肺境界マ スク画像の輪郭座標情報から輪郭の外接矩形を求める.外接 矩形の情報を用いて4つの領域ごとに関心領域の位置とサイ ズを決める.対応する領域をテスト用の胸部 X 線像から画 像として切り出し、その画像の集合を ROI\_C<sub>1~4</sub> とする. 3) 左肺境界の学習と検出

まず、ROI\_A<sub>1~4</sub> と ROI\_B<sub>1~4</sub> をセットにして対応する 4 つ の領域毎の U-Net<sub>1~4</sub> に入力し、それぞれで学習を行う.次に、 ROI\_C<sub>1~4</sub>を対応する学習済みの境界抽出モデルに入力する. 領域毎に抽出される境界を結合し左肺境界とする(図 4).

正解画像 A と U-Net の出力画像 B との類似度を評価指数 とする Dice 係数 (式 1) によって,提案手法を評価する.

(1)

Dice 係数 =  $(2 \times |A \cap B|)$  / (|A|+|B|)

また,4つの領域毎に,正しい左肺境界と提案手法によっ て検出される左肺境界を比較し,正位置に途切れなく検出で きている場合はgood,その他の場合はpoor として評価する.

## 3. 実験

実験では、文献[4]の胸部 X 線像 247 枚を用いた.正解 データとしての各マスク画像には、SCR データベース [5] を利用した.性能評価のために、k-分割交差検証を行った.

実験の結果, Dice 係数の平均値は 0.644 となった. 図 5 に Dice 係数の度数分布を, 図 6 に Dice 係数が高かった例と低 かった例を示す. また, 表 1 にパーツ毎に正しい左肺境界と 提案法によって抽出した左肺境界を比較した時の評価結果 を示す. good の平均が 59.5 %となった. poor では全く境界 検出できていない画像は少なく,境界が途切れていても,直 線や曲線で容易に補間できる程度のものであった(図 7).

### 4. まとめ

胸部 X 線像中に配置した関心領域から U-Net を用いて左 肺境界を検出する手法を提案した.線構造の場合,正位置で あっても線の太さが異なれば Dice 係数の値が低下するため, Dice 係数の平均値 0.644 は低い値ではないと考える.実験結 果から,提案手法はある程度有効な手法であると考えられる. 今後,検出が難しい部位は他の手法で補たり,途切れた境界 線を繋げることで,左肺境界の検出精度を向上して行きたい.



(a) 正解 (b) 検出結果 (1) Dice 係数 0.764 (c) 正解 (d) 検出結果

(2) Dice 係数 0.427

図 6 Dice 係数が高かった例(1)と低かった例(2)





図 7 左肺境界が途切れてしまった検出例

表1 抽出したパーツ毎の左肺境界の評価結果

評価	top	bottom	right	left
good	49.4%	37.7%	95.0%	55.9%
poor	50.6%	62.3%	0.5%	44.1%

### 利益相反の有無

なし

- 文 献
- [1] 三友英紀,中山富雄, 芦澤和人,他:アンケートによる検診胸部 X 線写真読影体制の全国実態調査.日本肺癌学会肺がん検診委員会 58:243-251,2018
- [2] 永田亮一,川口 剛,秋吉孝俊,他:胸部X線写真からの肺結節自 動検出のためのテンプレートマッチングを用いる偽陽性削減法,第 32回日本医用画像工学大会予稿集,pp1-11,2013
- [3] 近藤堅司,小澤 順,清野正樹,他:U-Netを用いた胸部 X 線画像 からの解剖学的構造の領域抽出,人工知能学会全国大会(第32回) 2J4-04:1-4,2018
- [4] 日本放射線技術学会:標準デジタル画像データベース. 1997
- [5] Ginneken B, Stegman M, Loog M: Segmentation of anatomical structures in chest radiographs using supervised methods: a comparative study on a public database. Medical Image Analysis 10:19-40, 2006

# 3DU-Net による

# 非造影 CT 画像の大動脈・冠動脈石灰化の検出と分類

庄野未彩季\*1 河田 佳樹\*2 杉浦寿彦\*3

田邊信宏\*3 丸茂一義\*4 金子昌弘\*4 仁木 登\*5

\*1 徳島大学大学院創成科学研究科理工学専攻

徳島県徳島市南常三島町1丁目1番地

c612336006@tokushima-u.ac.jp

\*2徳島大学ポストフォトニクス研究所 \*3千葉大学 \*4東京都予防医学協会 \*5(株)医用科学研究所

## By 3DU-Net Detection and classification of aortic and

## coronary calcification on non-contrast-enhanced CT images

Misaki SHONO<sup>\*1</sup> Yoshiki KAWATA<sup>\*2</sup> Toshihiko SUGIURA<sup>\*3</sup>

Nobuhiro TANABE<sup>\*3</sup> Kazuyoshi MARUMO<sup>\*4</sup> Masahiro KANEKO<sup>\*4</sup> \*Noburu NIKI<sup>\*5</sup>

<sup>\*1</sup> Graduate School of Science and Technology for Innovation, Tokushima University

<sup>\*2</sup> Institute of Post-LED Photonics, Tokushima University

<sup>\*3</sup>Chiba University <sup>\*4</sup> Tokyo Preventive Medicine Association <sup>\*5</sup> Medical Science Insitute<sup>\*</sup>

要旨:大動脈・冠動脈の石灰化によって引き起こされる心疾患の死亡率は悪性新生物に続き第2位を占めている. 心疾患は日本に おいて主な死因の1つとされる疾患であり,早期発見・早期治療を受けることが必要とされている. この解析には正常100例と慢 性血栓塞栓性肺高血圧症の22例の非造影 CT 画像を用いる.本報告では,U-Net による非造影 CT 画像から大動脈・冠動脈石灰 化を抽出し,その結果を用いて,心房・心室,大動脈・肺動脈の情報をもとに大動脈・冠動脈石灰化の検出・分類結果を示す.

キーワード: CT, CAD, 医用画像処理

## 1. はじめに

石灰化は、動脈にカルシウムが沈着している状態のこと であり、動脈硬化の場合に見られ、加齢とともに多く見られ る.動脈硬化が引き起こす疾患は心疾患であり、心疾患の死 亡率は悪性新生物に続き第2位を占めており、年々増加傾向 にある.

そこで本研究では,正常例と慢性血栓塞栓性肺高血圧症例 における冠動脈・大動脈石灰化の特徴を解析し,縦隔領域にマ スクをかけ,U-Netを用いて冠動脈・大動脈石灰化の自動検出 法を構築することを目標とする.[1]

## 2. CT 画像

東京都予防医学協会で撮影された正常 100 例と千葉大学で 撮影された慢性血栓肺高血圧症の 22 例を用いた.東京都予防 医学協会から提供を受けた非造影 CT 画像は、キャノンメディ カルシステムズの 32 マルチスライス CT システムで撮影され、 撮影条件は、管電圧 120kV、管電流 30mA、再構成圧 1.0mm で あり、千葉大学から提供を受けた非造影 CT 画像は、キャノン メディカルシステムズの 320 列エリアディレクターCT システ ムで撮影され、撮影条件は、管電圧 120kV、管電流 112-295mA、 再構成圧 0.5mm である.大動脈石灰化と冠動脈石灰化の非造影 CT 画像を図 1、図 2 に示す.



図2 冠動脈の石灰化

## 3. 手法

図 3 のフローチャートの手順でこれらの非造影 CT 画像から(1)学習データの作成,(2)縦隔領域の学習,(3)非造影 CT 画像 に縦隔領域のマスクをかけ,冠動脈・大動脈の学習,(4)抽出し た結果を用いて,冠動脈・大動脈石灰化の検出・分類結果を示 す.



図3 冠動脈・大動脈石灰化の抽出手順 (1) 学習データの作成

冠動脈・大動脈石灰化をマニュアルで抽出する.石灰化 は日本心臓協会で CT 値 130HU 以上と定義されているため,CT 値 130HU 以上を抽出し,冠動脈・大動脈石灰化にそれぞれ異 なるラベル番号付けを行い,学習・評価データを作成した.縦 隔領域は,Felson による縦郭区分を用いて胸椎3番から10番 までを縦隔領域と定義し,ラベル付けを行なった.[1] (2)縦隔領域の学習

非造影 CT 画像と作成した縦隔領域のラベル画像を教師 データとし,症例ごとにトレーニングデータ:バリデーション データ:テストデータ=8:1:1 にわけ,データサイズ 512× 512(pixel),エポック数 800 回で学習させ,抽出を行った.

(3) 非造影 CT 画像に縦隔領域のマスクをかけ、冠動脈・大動 脈の学習

非造影 CT 画像と作成した縦隔領域のラベル画像に冠 動脈・大動脈のラベル画像を加え,教師データの入力を非造影 CT 画像,縦隔のラベル画像の2入力とし,縦隔領域の学習と 同様の手順で学習を行なった.

(4) 冠動脈・大動脈の検出・分類

出力画像を用いて,心房・心室,大動脈・肺動脈の情 報をもとに冠動脈・大動脈の検出・分類を行う.

### 4. 抽出結果

テストデータを用いて評価を行なった. (a), (b) 非造影 CT 画像, (c) 大動脈石灰化の出力画像, (d) 冠動脈石灰化の出力 画像を図4に示す. 縦隔領域の抽出精度は dice 値 0.97±0.08 を示し, 冠動脈・大動脈の石灰化の抽出精度は dice 値 0.72± 0.11 を示した. 図4(c)の例では, 器官の軟骨部の誤抽出が見 られた.



図4 (a) 非造影 CT 画像





(b) 非造影 CT 画像



(c) 大動脈石灰化の出力画像

# (d) 冠動脈石灰化の出力画像

## 5. まとめ

本報告では、マニュアルで冠動脈・大動脈の石灰化、縦郭 領域の学習データを作成した後、U-net を利用して、縦郭領 域,冠動脈・大動脈の石灰化の抽出を行った.今後の課題とし て、症例数を増やし、有用性の高いデータベースの作成を目 指す.

利益損反の有無なし

## 文 献

[1] 村田 喜代史,村上 貞之: 胸部の CT 第 3 版, 1998, pp66-74
[2] H. Suzuki, Y. Kawata, N.Niki et al: Segmentation of aorta and main pulmonary artery of non-contrast CT images using U-Net for chronic thrombotic pulmonary hypertension: Evaluation of robustness to contacts with blood vessels. Vol 1203325-, pp1-5, 2022

# 2.5 次元特徴抽出及び 3 次元特徴選択による COVID-19 自動分類モデルの 汎化性能に関する検討

遠田 涼<sup>\*1</sup>, 伊東 隼人<sup>\*1</sup>, 小田 昌宏<sup>\*2,1</sup>, 林雄一郎<sup>\*1</sup>, 大竹 義人<sup>\*3,4</sup>, 橋本 正弘<sup>\*5</sup>,

明石 敏昭\*6, 青木 茂樹\*6, 森 健策\*1.7.4

\*1 名古屋大学大学院情報学研究科

\*2名古屋大学情報連携推進本部情報戦略室

\*3 奈良先端科学技術大学院大学先端科学技術研究科

\*4 国立情報学研究所ビッグデータ研究センター

\*5慶應義塾大学医学部,\*6順天堂大学医学部,\*7名古屋大学情報基盤センター

Study on generalization ability for COVID-19 automated classification model

# with 2.5D feature extraction and 3D feature selection

Ryo TODA<sup>\*1</sup>, Hayato ITOH<sup>\*1</sup>, Masahiro ODA<sup>\*2,1</sup>, Yuichiro HAYASHI<sup>\*1</sup>, Yoshito OTAKE<sup>\*3,4</sup>,

Masahiro HASHIMOTO<sup>\*5</sup>, Toshiaki AKASHI<sup>\*6</sup>, Shigeki AOKI<sup>\*6</sup>, Kensaku MORI<sup>\*1,7,4</sup>

<sup>\*1</sup> Graduate School of Informatics, Nagoya University

<sup>\*2</sup> Information Strategy Office, Information and Communications, Nagoya University

<sup>\*3</sup> Graduate School of Science and Technology, Nara Institute of Science and Technology

<sup>\*4</sup> Research Center for Medical Bigdata, National Institute of Informatics

<sup>\*5</sup> Keio University School of Medicine

\*6 School of Medicine, Juntendo University

<sup>\*7</sup> Information Technology Center, Nagoya University

要旨:本稿では、2.5 次元の特徴抽出及び3 次元の特徴選択による COVID-19 自動分類用 CNN を提案し、その汎化性能を複数のデ ータセットを用いて検証する.新型コロナウイルス感染症(COVID-19)の診断において、胸部 CT 検査は不可欠であるが、CT 画 像の読影は放射線科医らにとって負担が大きく、コンピュータ支援診断技術の開発が求められている. COVID-19 の流行初期から 様々な自動分類モデルが提案されてきたが、その多くは小規模な内部データセットで分類性能を検証するに留まっており、汎用的 なモデルは少数である.本研究では、2 次元及び3 次元の特徴抽出器を組み合わせることで過学習を抑制した 2.5 次元の CNN と、 抽出された特徴から重要なパターンのみを選択する 3 次元の attention 機構を有する分類モデルを提案し、その汎化性能を検証する. 提案モデルを含めて6種類のモデルを用いた比較の結果、提案モデルは複数のデータセットで安定した分類性能を示した. キーワード: COVID-19、分類、CNN、Attention 機構、汎化性能

## 1. はじめに

2019 年末に報告され,世界中で爆発的に流行している新型 コロナウイルス感染症(COVID-19)に関して,その診断を支 援すべく,CT 画像を対象とした様々な分類モデルが提案され てきた[1].しかし,こうしたモデルの大部分は,非公開の小 規模データセットを用いて訓練されており,公開データセッ トを用いた評価も不十分であることから,汎化性能が低い可 能性が高いとの指摘がある[2].

本稿では、2次元及び3次元の特X 徴抽出器を組み合わせる ことで過学習を抑制した 2.5 次元 CNN と、抽出された特徴か ら重要なパターンのみを選択する 3 次元の attention 機構を有 する分類モデルを提案し、その汎化性能を複数の胸部 CT 画像 データセットを用いて検証する.

## 2. 手法

本研究で使用する 2.5 次元 CNN[3]は、192×192×64 ボクセ ルの 3 次元胸部 CT 画像を入力とし、入力された症例が COVID-19 典型例であるか、非典型例であるかを出力する. axial, coronal, sagittal の各スライスについて特徴抽出を行っ たのち、各断面の特徴マップを結合し、3 次元での特徴抽出 を行う. 抽出された特徴について attention 機構を通じて重要 な特徴を選択する. Attention機構は、一般画像を対象とした2 次元の手法[4]を 3 次元に拡張したもので、重要なパターンを 選択する channel attention と、空間上の重要な位置に高い重み を設定する spatial attention から構成される. 前者は3層のニュ ーラルネットワーク、後者は浅い CNN により実現できる. Attention機構によって選択された特徴に基づき、COVID-19典 型及び非典型の分類を行う.

## 3. 実験及び結果

国内の複数医療機関で撮像された 1,507 症例の胸部 CT 画像 で構成される内部データ及び 2 種類の公開データ[5,6]を使用 した.内部データは,北米放射線学会が定める COVID-19 典 型度分類[7]に従い,放射線科医によって 4 カテゴリのラベル 付けが行われている.典型度上位及び下位の各 2 カテゴリを それぞれ COVID-19 典型,非典型と扱った.公開データは COVID-19 確定症例と正常症例で構成され,前者を典型,後 者を非典型とした.モデルの学習は内部データの一部を用い て行い,検証データでの分類性能によりパラメータを決定し た.残る全データは評価のみに使用した.データセットに関 する詳細を表 1 に示す.

学習には Adam を用い,初期学習率 1.0×10<sup>4</sup>,以降 10 エポ ック毎に学習率を 0.85 倍に減少させた.学習回数は 100,ミ ニバッチサイズは 16 である.

比較手法として, (a) 提案モデルから attention 機構を除いた モデル (2.5D), (b) 提案モデルの特徴抽出過程に attention 機構 を 4 か所追加したモデル (2.5D + 5attn), (c)2 次元特徴抽出器 を持たない 3 次元 CNN (3D) [3], (4) 3 次元 CNN に attention 機構を加えたもの (3D + attn), (5) 2.5 次元 CNN のアンサンブ ル学習 (2.5D + ens) [8]の 5 種類のモデルを使用した.

評価のため感度,特異度に基づきROC曲線を作成した.全 評価データの分類結果から作成したROC曲線を図1に示す. 提案手法(Proposed)が最も良好な結果を示した.

#### 4. 考察

図1より,2.5 次元構造, attention 機構のいずれも汎化性能 の向上に寄与していることが推測される.一方で, attention 機構を多数設けた場合には,分類に有効な特徴抽出が行われ る前に特徴選択が行われることにより,性能が低下している と考えられる.

#### 5. まとめ

本稿では, COVID-19 自動分類用 CNN を提案し, その汎化 性能を3種類のデータセットにより検証した.提案 CNN は6 種類のモデルの中で最も良好な汎化性能を示したことから, 2 次元・3次元を組み合わせた特徴抽出及び3次元での特徴選択 の有効性が示唆された.

## 謝辞

本研究の一部は NICT 222A03, JSPS 科研費 JP21K19898, JP26108006, JST CREST JPMJCR20D5, JST SPRING

JPMJSP2125の助成を受けたものです.

## 利益相反の有無

なし

## 文 献

- Kanne J, Bai H, Bernheim A et al: COVID-19 Imaging: What We Know Now and What Remains Unknown. Radiol 299(3):E262-279, 2021.
- [2] Roberts M, Driggs D, Thorpe M et al: Common pitfalls and recommendations for using machine learning to detect and prognosticate for COVID-19 using chest radiographs and CT scans. Nat Mach Intell 3: 199-217, 2021.
- [3] Oda M, Zheng T, Hayashi Y et al: Automated classification method of COVID-19 cases from chest CT volumes using 2D and 3D hybrid CNN for anisotropic volumes. Proc SPIE Med Imag 12033: 1203309, 2022.
- [4] Woo S, Park J, Lee JY et al: CBAM: Convolutional Block Attention Module. Proc ECCV: 3-19, 2018.
- [5] Afshar P, Heidarian S, Enshaei N et al:COVID-CT-MD, COVID-19 computed tomography scan dataset applicable in machine learning and deep learning. Sci Data 8: 1-8, 2021.
- [6] Rahimzadeh M, Attar A, Sakhaei S: A fully automated deep learning-based network for detecting COVID-19 from a new and large lung CT scan dataset. Biomed Signal Process Control 68:102588, 2021.
- [7] Simpson S, Kay F, Abbara S et al: Radiological Society of North America Expert Consensus Document on Reporting Chest CT Findings Related to COVID-19: Endorsed by the Society of Thoracic Radiology, the American College of Radiology, and RSNA. Radiol Cardiothorac Imaging 2: e200152, 2020.
- [8] Toda R, Oda M, Hayashi Y et al: Improved method for COVID-19 classification of complex-architecture CNN from chest CT volumes using orthogonal ensemble networks. Proc SPIE Med Imag 12465: 124650D, 2023.

表1 3種類のデータセットの詳細

	用途	典型	非典型	合計
	学習	596	368	964
内部データ	検証	149	92	241
	評価	187	115	302
公開データ 1[5]	評価	169	76	245
公開データ 2[6]	評価	95	282	377



図1 全評価データにおける ROC 曲線の比較

# 3 次元 CT 画像を用いた 2 段階 3D U-Net によるじん肺粒状影抽出法

松廣 幹雄\*1 新居 蓮人\*2 河田 佳樹\*2

大塚 義紀\*3 岸本 卓巳\*4 芦澤 和人\*5 仁木 登\*6

\*1 鈴鹿医療科学大学保健衛生学部 \*2 徳島大学大学院理工学研究部

\*3 北海道中央労災病院 \*4 岡山ろうさい病院 \*5 長崎大学病院 \*6 株式会社医用科学研究所

**Detection of micronodules in pneumoconiosis of 3D CT images using two-stage 3D U-Net** Mikio MATSUHIRO<sup>\*1</sup>, Rento NI<sup>\*2</sup>, Yoshiki KAWATA<sup>\*2</sup> Yoshinori OHTSUKA<sup>\*3</sup>, Takumi

KISHIMOTO<sup>\*4</sup>, Kazuto ASHIZAWA<sup>\*5</sup>, Noboru NIKI<sup>\*6</sup>

\*1 Suzuka University of Medical Science \*2 Tokushima University \*3 Hokkaido Chuo Rosai Hospital \*4 Okayama Rosai Hospital \*5 Nagasaki University \*6 Medical Science Institute Inc

要旨:じん肺は粉塵を吸い込むことで起こる職業性呼吸器疾患である.国内では年間24万人がじん肺と診断されている.病型1/0以上のじん肺は労災認定の対象となるため,0/1と1/0を区別することが重要である.じん肺の病型分類にはX線写真が使われている.にん肺の診断において粒状影の認識は重要であり,3次元 CT 画像はより正確に粒状影を検出できるため診断に有用である. 我々は直径2.5mm以上の粒状影の数がじん肺の診断に有用であることを報告した.本報告では2段階に3DU-Netを用いて3次元 CT 画像から直径2.5mm以上の粒状影を検出する方法を提案する.本手法は,3DU-Netを利用して,トレーニングデータを用いて 胸壁周辺の粒状影の学習,縦隔周辺の粒状影の学習,粒状影・肺血管の学習を行う.3つの3DU-Netをトレーニングデータに適用 し、抽出した粒状影を入力して再び学習する.4つの3DU-NetによりCT 画像より高精度に粒状影を抽出した. キーワード:CT,3DU-Net,じん肺

## 1. 目的

じん肺は, 粉塵を肺に吸い込むことによって起こる職業性呼 吸器疾患であり,日本では年間 30万人の方が放射線じん肺検 診を受けている[1].じん肺の診断には単純 X線画像が使用さ れ,病型区分がある[2].病型 1/0型以上は労働災害として認定 される対象となるため,病型 0/1型と病型 1/0型を正確に診断 することが重要である.そのために,軽度のじん肺に見られ る粒状影を定量化することが重要である.3次元 CT 画像は, 単純 X線画像よりも粒状影を検出する感度が高い.以前,3次 元 CT 画像を用いてじん肺の重症度を定量化するために,肺結 節の大きさと頻度の関係が報告された[3][4].また,マニュア ルデータベースから得られた2.5mm 以上の微小結節の大きさ と数が,じん肺のタイプ分類に有用であることが報告されてい る[5].ここでは,3D U-Net[4]を用いて,3次元 CT 画像から 2.5mm 以上の微小結節を高精度で検出する方法を提案する.

## 2. CT 画像

本研究で用いる CT 画像は GE LightSpeed VCT, CANON Aquirion PRIME で撮影された. GE LightSpeed VCT の撮影条件 は通常線量撮影の CT 画像(再構成間隔 1.25mm, スライス厚 1.25mm, 管電流 167~698mA, 管電圧 120kV, ピクセルサイズ 0.527mm~0.742mm), 再構成関数 LUNG である.

CANON Aquirion PRIME の撮影条件は通常線量撮影の CT 画像(再構成間隔 1.0mm, スライス厚 1.0mm, 管電流 240mA, 管

電圧 120kV, ピクセルサイズ 0.625mm~0.781mm), 再構成関数 FC52 である.

3 次元 CT 画像中の粒状影は,手動で抽出した.表示はウィンドウレベル 500,ウィンドウ幅 1500 に設定した.読影は, 右肺尖,右肺底,左肺尖,左肺底の順で行った.この手順を2~3回繰り返した.

厚生労働省のガイドラインに基づき, 医師が診断したじん肺 は, 0/0, 0/1, 1/0, 1/1, 1/2, 2/1, 2/2, 2/3, 3/2, 3/3, 3/+, 4A, 4B, 4C の 15 ステージ. タイプ 0/1, 1/0, 1/1, 1/2, 2/1 の 14 症例をトレーニングデータとして使用した.

GPU (QuadroGV100 (32GB); NVIDIA) を搭載したコンピュ ータを使用した.機械学習用のライブラリとして, Pytorch 1.9.0+cu111 と Monai 0.7.0 を使用した[6].

## 3. 手法

3 次元 CT 画像から 3D U-Net によって粒状影抽出を行うが, 粒状影ラベルを用いて直接学習すると胸壁周辺,縦隔周辺の粒 状影抽出が不足し,粒状影の過抽出が現れることが実験的に分 かったため4つの3D U-Net を学習する.学習にはトレーニン グデータを用いる.

1)4 つの 3D U-Net の学習

3D U-Net.1 胸壁周辺の粒状影を用いた 3D U-Net の学習

事前に用意した肺野・胸壁の情報を用いて胸壁から10mm以 内の粒状影のみを取り出し正解として,3次元 CT 画像を用い て 3D U-Net の学習を行う.

3D U-Net.2 縦隔周辺の粒状影を用いた 3D U-Net の学習

事前に用意した肺野・縦隔の情報を用いて縦隔から10mm 以 内の粒状影のみを取り出し正解として,3次元 CT 画像を用い て 3D U-Net の学習を行う.

3D U-Net.3 粒状影・肺血管を用いた 3D U-Net の学習

粒状影をラベル番号 1,事前に準備した肺血管領域をラベル 番号 2 とし正解として, 3 次元 CT 画像を用いて 3D U-Net の 学習を行う.

トレーニングデータの3次元 CT 画像に対して 3D U-Net.1~ 3D U-Net.3 を適用し, 粒状影抽出を行いマージする. この画像 を粒状影画像とする.

3D U-Net.4 粒状影を用いた 3D U-Net の学習

粒状影を正解として,3次元 CT 画像と粒状影画像を用いて 3D U-Net の学習を行う.

2)4 つの 3D U-Net による粒状影抽出

3 次元 CT 画像に対して 3D U-Net.1~3D U-Net.3 を適用し, 粒状影抽出を行いマージする. この画像を粒状影画像とする. 3 次元 CT 画像と粒状影画像に対して 3D U-Net.4 を適用して粒 状影抽出結果を得る.

## 4. 結果

テストデータに対して粒状影抽出を行った.図1に抽出結果の3次元表示を示す.



図1 粒状影抽出結果

## 5. まとめ

部位別に分けた粒状影, 肺血管と共に学習した粒状影を用いて 3D U-Net を学習することで粒状影を抽出することができた. 抽出した粒状影を画像として用いて学習することで過抽出を 減らすことができた.

#### 利益相反の有無

なし.

- 文献
- [1] 厚生労働省, "第 24 回労働政策審議会安全衛生分科会じん肺部会 じん肺健康管理状況," 2023.
- [2] 滝島任,中村雅夫,千代谷慶三著,"じん肺患者の呼吸機能検査ハンドブック,"1990.
- [3] H., Suzuki, M., Matsuhiro, Y., Kawata, N., Niki, K., Kato, T., Kishimoto, K., Ashizawa: Computer aided diagnosis for severity assessment of pneumoconiosis using CT images. Proceedings for Medical Imaging - SPIE, vol. 9785, pp. 978531 (2016)
- [4] K., Hino, M., Matsuhiro, H., Suzuki, Y., Kawata, N., Niki, K., Kato, T., Kishimoto, K., Ashizawa: Quantitative assessment for pneumoconiosis severity diagnosis using 3D CT images. Proceedings for Medical Imaging -SPIE, vol. 10575, pp. 105753J-1-6 (2018)
- [5] Çiçek, Ö., Abdulkadir, A., Lienkamp, S. S., Brox, T., Ronneberger, O.: 3D U-Net: learning dense volumetric segmentation from sparse annotation. International conference on medical image computing and computer-assisted intervention, pp. 424-432. Springer, Cham (2016)
- [6] MONAI Homepage, https://monai.io/2023/5/30

# Soft-boundary を導入した SVDD-AE による胸部 CT 画像の異常検知

GAO Zhihui<sup>\*1</sup>,中山 良平<sup>\*1</sup>,檜作 彰良<sup>\*1</sup>,木戸 尚治<sup>\*2</sup>

\*1 立命館大学大学院 理工学研究科

\*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

# Anomaly Detection for Lung CT Images Using SVDD-AE with Soft-boundary

Zhihui GAO<sup>\*1</sup>, Ryohei NAKAYAMA<sup>\*1</sup>, Akiyoshi HIZUKURI<sup>\*1</sup>, Shoji KIDO<sup>\*2</sup>

<sup>\*1</sup> Graduate School of Science and Engineering, Ritsumeikan University

<sup>\*2</sup> Department of Artificial Intelligence Diagnostic Radiology, Osaka University Graduate School of Medicine

要旨: 医用画像上の病変は、しばしば正常構造に似た信号パターンをもつ. したがって、Variational AutoEncoder (VAE) などの異常 検知モデルによる画像再構成において、正常構造だけでなく病変も復元される問題がある. そこで本研究では、潜在空間の正常と 異常の潜在変数分布を遠ざける学習を導入した AE を構築し、胸部 CT 画像における病変検出に適用する. 実験試料は、胸部 CT 画 像 850 症例(正常:650 症例,異常:200 症例)である. 提案手法では、まず正常症例だけを用いて、サポートベクトルデータ記述 法により、正常の潜在変数を潜在空間上で可能な限り小さな超球内に収まるように学習する. 次に少量の異常症例を用いて、正常 と異常の潜在変数分布が離れるように学習する. そして、潜在変数から再構成した画像と入力画像の差および潜在変数と超球の中 心との距離に基づき、病変を検出する. 提案手法による AUROC は 0.69 で、従来手法である VAE (0.58) より高い結果が得られ、 その有用性が示唆された.

## キーワード:異常検知, CT 画像, SVDD-AE

#### 1. はじめに

近年,病変の早期発見を目的とした CT (Computed Tomography)による検診が実施されている. CT 検査では受診者から多くのスライス画像が取得されるため,読影医にとって大きな負担となっており,AI (Artificial Intelligence)による病変の自動検出技術の開発が望まれている.

これまでに提案された病変検出法の多くは、AI に対象病変 の画像特徴を学習させる手法である.このアプローチは、対象 病変が含まれる異常画像を大量に収集しなければならないこ と、また、対象病変しか検出できないことが問題であった.一 方、異常検知のアプローチは正常構造を学習させるため、大量 の異常画像を収集する必要がなく、また、正常構造と異なる部 位を検出するためすべての病変を検出対象とすることが可能 である.

VAE (Variational AutoEncoder) は異常検知によく用いられる 生成モデルであるが、ガウス分布に基づく潜在変数から画像を 再構成するため、再構成画像がボケる問題がある[1].また、 医用画像上の病変はしばしば正常構造と似た信号パターンを もつため、再構成画像において病変も復元される問題がある.

そこで本研究では、ガウス分布の代わりに Soft-boundary を 導入した SVDD-AE (Support Vector Data Description-AutoEncoder) を構築し、再構成画像の復元精度を改善した胸部 CT 画像の異 常検知(病変検出)アルゴリズムを提案する.また、潜在空間 の正常と異常の潜在変数分布を遠ざける学習を導入すること により、病変の再構成を抑制し、異常検知精度を改善する.

#### 2. 実験試料

実験試料は、検診で撮影された 850 症例(正常:650 症例, 異常:200 症例)の胸部 CT 画像である.画像サイズは 512× 512 画素で,スライス画像数は 72~124 枚,濃度分解能は 12 bit である.本研究では,提案手法の学習用に 550 例(正常: 500 例,異常:50 例)、検証用に 100 例(正常:50 例,異常: 50 例),評価用に 200 例(正常:100 例,異常:100 例)を使用 した.

## 3. 方法

## 1) SVDD-AE

図1に SVDD-AE のネットワーク構造を示す. SVDD は,固定のカーネル関数を用いて入力画像を潜在空間に射影し,潜在空間上で正常と異常を分離する手法である.本研究では,固定のカーネル関数の代わりに学習可能なエンコーダを用いることにより,よりデータに適した射影変換を行う.



Soft-boundary を導入した SVDD-AE では、まず、エンコーダ で入力画像を潜在変数に次元圧縮し、潜在空間に射影する.こ こで、正常画像の潜在変数が出来るだけ小さな超球内に射影さ れるように制御する.そして、射影された潜在変数から、デコ ーダで入力画像を復元する.提案モデルは超球内の潜在変数か ら入力画像が復元できるように学習するため、超球外にある潜 在変数からは正確な復元が出来ない.したがって、異常画像を 入力すると異常(病変)を減弱した画像が復元される.本研究 では、入力画像と再構成画像の差および射影した潜在変数と超 球の中心との距離に基づき、異常検知を行った.

## 2) 超球の中心決定

正常の潜在変数だけを含む初期超球の中心を決定するため, 式(1)を用いて,学習用正常画像による AE の事前学習を行 った.そして,学習済みのエンコーダに学習用正常画像を入力 し,潜在変数の平均を超球の中心と決定した.

$$Loss_{1} = (x - x')^{2} + 1000 * MS_SSIM(x, x')$$
(1)

第一項は入力画像xと再構成画像x'の二乗誤差で, 第二項は Multi Scale Structural Similarity である.

## 3) SVDD-AE の学習

学習済みの AE のパラメータを SVDD-AE のネットワークの 初期パラメータとした.式(2)を用いて,正常の潜在変数を 含む超球を最小化した.

 $Loss_2 = Loss_1 + R^2 + \frac{1}{vn} \sum_{i}^{n} \max\{0, ||z - c||^2 - R^2\}$  (2) 第一項は再構成精度に関する項であり、第二項は超球の半径R を最小化する項である.また、第三項は潜在変数zと超球の中 心cとの距離が半径Rより大きい場合にペナルティを与える項 である.vはペナルティを調整する係数であり、nは学習データ 数である.そして、異常画像を含むすべての学習用画像を SVDD-AE に入力し、超球外にある潜在変数に-1のラベルを付 与した.また、超球外にある潜在変数と同数の超球内にある潜 在変数をランダムに選択し、+1のラベルを付与した.

SVDD-AE では,式(3)により,正常画像を超球内に,異常 画像を超球から遠ざけるように学習する.

 $Loss_3 = Loss_1 + \frac{1}{n+m} \sum_{i=1}^n ||z - c||^2 + \frac{1}{n+m} \sum_{j=1}^m (||z - c||^2)^{y_j}$  (3) 第三項で、 $y_j$ にラベル値を代入することにより、超球内にある 潜在変数をより球心に近づけ、超球外にある潜在変数を球心か らより遠ざけるように射影する. nはラベルがない潜在変数数 であり、mはラベルがある潜在変数数である.

## 4. 結果と考察

表1に提案手法と VAE による異常検知精度の比較を示す. 提案手法の正答率,感度,特異度,AUROC (Area under the Receiver Operating Characteristic curve) は 64%, 65%, 63%, 0.69

表1:提案手法とVAEによる異常検知精度の比較							
	正診率	感度	特異度	AUC			
VAE	0.61	0.72	0.50	0.58			
SVDD-AE	0.64	0.65	0.63	0.69			
入力画像		VAE	再構成画像 SV	DD-AE			
正 常		Ð	Đ				
異常	3)						

図 2:提案手法と VAE による再構成画像の比較

であり, VAE (61%, 72%, 50%, 0.58) より高かった. 図2に 提案手法と VAE による再構成画像の比較を示す. 提案手法, VAE ともに, 再構成画像において異常部位 (矢印部) は復元さ れなかったが, VAE は正常構造も復元できなかった. 提案手法 による再構成画像はボケが抑制され, 正常構造をより正確に復 元できることが確認された.

CT 画像に含まれる臓器の位置や形状は大きく異なるため, ガウス分布からサンプリングされた潜在変数に基づき画像を 再構成するのは困難である.一方, Soft-boundary を導入した SVDD-AE では,射影された正常の潜在変数を再構成に用いる ため,病変の再構成を抑制しつつ,正常構造をより正確に復元 することができたと考える.

#### 5. まとめ

本研究では, 潜在空間において正常と異常の潜在変数分布を 遠ざける学習を導入した AE を構築し, 胸部 CT 画像上の異常 検知を行った.提案手法の AUC は, 従来の VAE より高く, そ の有用性が示唆された.

#### 利益相反の有無

なし

- Zhao S., Song J., Ermon S.: Towarsd Deeper Understanding of Variational Autoencodering Models. arXiv: 1702.08658, 2017
- Ruff L., Vandermeulen R., Goernitz N. et al.: Deep One-Class Classification, Proceedings of the 35<sup>th</sup> International Conference on Machine Learning Research, 80:4393-4402, 2018

## 胸部 MRI を用いた Radiomics の安定性評価

高瀬 真衣\*1,坂 知樹\*1,鎌田 洋\*1, 岩澤 多恵\*2

\*1 金沢工業大学

\*2 神奈川県立循環器呼吸器病センター

# **Evaluation of Radiomics Stability Using Chest MRI**

Mai TAKASE<sup>\*1</sup>, Tomoki SAKA<sup>\*1</sup>, Hiroshi KAMADA<sup>\*1</sup>, Tae IWASAWA<sup>\*2</sup>

<sup>\*1</sup> Kanazawa Institute of Technology

<sup>\*2</sup> Kanagawa Cardiovascular and Respiratory Center

要旨:Radiomics においては主に CT や PET が用いられているが、一方で MRI はその画像の不均一性が結果の安定性に影響を与え る可能性があるため、一般的には用いられていない.本研究では MRI を用いた Radiomics の安定性の精査を目的とし、脊柱起立筋 を対象として安定性を評価する手法を提案する.実験では、通常の T2 強調画像群と脂肪抑制した T2 強調画像群をそれぞれ 2 グル ープに分割し、機械学習手法を用いて特徴量を順位付けした.実験の結果、通常画像群では 2 グループ間で順位付けされた特徴量 に有意差があり、脂肪抑制画像には有意差がないことが示唆された.これは脂肪抑制することで対象部位のコントラストがより豊 かになり、結果として情報が増えたためと考えられる.今後はより大きなデータセットおよび信頼性の高いマスク画像を用いた検 証が望まれる.

キーワード:Radiomics, MRI,脊柱起立筋,脂肪抑制画像,T2強調画像

## 1. はじめに

Radiomics では、これまで S/N 比が高い CT や PET が用いら れてきたが、これらには放射線被曝という問題がある.一方、 MRI であれば患者にリスクを負わせることがない.しかしな がら、MRI は装置や撮影条件によって画像に大きく差が生じ ることから、Radiomics に用いるためには再現性や安定性の課 題がある.MRI を用いた Radiomics の先行研究は複数存在する が具体的な症例を対象としており、安定性が示されたわけでは ない.そこで本研究では、MRI で Radiomics を実行し、特徴量 が安定していること、およびその条件の確認を目的とする.

## 2. 手法とデータ

本研究では、病変部位ではなく「脊柱起立筋」を対象として Radiomics を実行し、特徴量の安定性を評価する手法を提案す る.脊柱起立筋は胸部 MRI の軸断面像において一貫して観察 可能であり、体動の影響を受けにくい部位である.さらに、筋 肉と癌は両者とも「軟部組織」に分類され、その MRI 信号特 性が類似する可能性があるため、脊柱起立筋を対象として Radiomics の安定性を確認することは意義深い.

実験データには、2020~2021年に撮像された77セットのMRI を使用した.そこから気管支の分岐が不明瞭であった7セット を除外し、残った70セット(M=21,F=18,Age:36~85)を使用し た.このセットには通常のT2強調画像と脂肪抑制付加T2強 調画像が含まれていた.実験で使用した画像はすべて軸断面像 であり、スライスは気管支が分岐する直前のものであった.

## 3. 実験

#### 3.1前処理

まず,撮像した画像の脊柱起立筋および脳脊髄液に手動でベジェ曲線を描き,マスク画像を作成した(図1).すべての画像の信号値から,最大値と最小値を取得し,それらの値を包含するように全画像をウィンドニングした.次にウィンドニング後の画像と,マスク部の値を取得し,脳脊髄液の平均値を計算した.この値を用いてすべての画像を正規化した.



図1 使用した画像(左)とマスク画像(右)の抜粋.

#### 3. 2 実験

まず,通常画像群(以後 SP 群)と脂肪抑制画像群(以後 FS 群)に対して Pyradiomics<sup>[1]</sup>を用いた特徴抽出を行った.次に, それぞれの画像群を 2 つのグループ(以後 SP1,SP2,FS1,FS2) にランダムに分割し,各グループに対して相関行列のクラスタ ーマップを作成した.その後,線形 SVM を使用して特徴選択 を実施した.最後に,選択された特徴量の分布はグループ間に 差がないとする帰無仮説を設定し Kruskal-Wallis 検定を行った.

## 4. 結果

検定の結果, SP 群では帰無仮説が棄却され, FS 群では棄却 されなかった. 図 2 に FS1, 図 3 に FS2 のクラスターマップを 示す. また,表 1 に FS1, FS2 の特徴量上位 10 選を示す. ク
ラスターマップでは、ヒートマップの行と列を階層的クラスタ リングで再配置し,似た特性を持つ行や列が近くに配置される.



図 3 FS2 のクラスターマップ.

### 5. 考察

表1より FS 群では9つの特徴が共通していること、また、 検定により FS 群はグループ間に差がなく、結果が安定してい ることがわかった.これはランダムなグループ分割を10回く りかえしても同様の結果が得られた.このことより,脂肪抑制 した T2 画像を用い,脳脊髄液で正規化を行った画像であれば, MRI でも Radiomics の結果が安定することが示唆された.

また, FS 群の共通特徴量が SP 群 (5 つ) より多かったのは, 脂肪抑制した T2 強調画像においては水成分を含む腫瘍や浮腫 等の信号が通常画像に比べ相対的に高くなることに起因する と考えられる. 信号が相対的に高くなるということは、対象部 位のコントラストが上がり、より多くの情報が得られたことを 意味する.したがって,通常画像よりも脂肪抑制画像を用いる ことで特徴選択の結果がより安定すると考えられる.

表1線形 SVM による FS2 の特徴量上位 10 選.

	FS1	FS2
1	firstorder_10percentice	gldm_LGLE
2	gldm_LGLE	firstorder_10Percentile
3	firstorder_Median	glcm_JointAverage
4	firstorder_Minimum	gldm_LDLGLE
5	gldm_LDLGLE	firstorder_Median
6	glcm_JointAverage	glcm_Autocorrelation
7	firstorder_Mean	gldm_HGLE
8	glcm_Autocorrelation	firstorder_Mean
9	gldm_HGLE	firstorder_RMS
10	glrlm_LGLRE	glrlm_LGLRE

### 6. まとめ

本研究では、MRI に対して Radiomics を実行し、取得した特 徴量が安定していること、およびその条件を確認することが目 的であり,脊柱起立筋を対象に Radiomics を実行する手法を提 案した.実験では SP 群と FS 群に対して線形 SVM を用いて特 徴を選択し,特徴量の安定性を精査した.実験の結果,グルー プ間のランキングの帰無仮説は SP 群で棄却され, FS 群では棄 却されなかった.脂肪抑制画像では、脂肪成分が通常に比べて 低信号で描出されることにより,対象部位のコントラストが上 がり,結果としてより多くの情報が得られたからと考えられる.

本実験は医学を専門としない者がマスキングを行ったが,今 後は複数の専門医で合意したマスク画像を使用した再検証が 望まれる.また,用いたデータセットが70セットと少ないた め、大規模なデータセットで検証することが望ましい.

ただし、具体的な MRI 信号値が脊柱起立筋と特定の癌組織 で一致するかどうかは、多くの要素に依存する.これらの要素 を考慮に入れながら、脊柱起立筋を通して Radiomics の再現性 と安定性を評価するこの手法は、Radiomics の信頼性を向上さ せさらに癌患者に対する応用につながる可能性がある.

#### 謝辞

本実験は金沢工業大学および神奈川県立循環器呼吸器病セ ンターの倫理委員会の承認のもと,個々の患者より書面による 同意書を得て行った、関係各位に深謝する、

#### 利益相反の有無

なし

献 [1] van Griethuysen, J. J. M., Fedorov, A., et al: Computational Radiomics System to Decode the Radiographic Phenotype. Cancer Research, 77(21), 2017

文

### 3次元点群動画像を用いた顔の時系列変化の検出および非対称度評価

木原 成海<sup>\*1</sup>,野元 菜美子<sup>\*2</sup>,大河内 孝子<sup>\*3</sup>,李 光旭<sup>\*4</sup>,中村 典史<sup>\*2</sup>,神谷 亨<sup>\*1</sup> \*<sup>1</sup>九州工業大学大学院,<sup>\*2</sup> 鹿児島大学大学院医歯学総合研究科,

\*3 国立病院機構鹿児島医療センター歯科口腔外科,\*4 天津工業大学電子情報工学科

## Detection of Temporal Change and Asymmetry Analysis of Face

from A Video Image of 3D Point Cloud

Narumi KIHARA<sup>\*1</sup>, Namiko KIMURA-NOMOTO<sup>\*2</sup>, Takako OKAWACHI<sup>\*3</sup>,

Guangxu LI<sup>\*4</sup>, Norifumi NAKAMURA<sup>\*2</sup>, Tohru KAMIYA<sup>\*1</sup>

<sup>\*1</sup> Kyushu Institute of Technology, <sup>\*2</sup> Kagoshima University,

<sup>\*3</sup> National Hospital Organization Kagoshima Medical Center, <sup>\*4</sup> Tiangong University

要旨: 口唇裂は, 胎児の成長過程で唇が正常に形成されないことによって生じる先天異常である. その外科手術は複数回に渡って行われるが, 顔の左右対称性の基準は曖昧で, 医師によって術後の評価が異なることが問題となっている. そこで本論文では, 3 次元 点群動画像を用いた顔の対称性解析を定量的に行う手法を提案する. 提案手法では, 3 次元点群データから顔のランドマーク座標を検出し, FPFH 特徴量を用いて異なるフレーム間で点のマッチングを行うことによって得られる, 各ランドマーク点の時系列変化を左右で比較する. また, マッチング結果を利用した口唇部領域の抽出, および分割を行い, 各小領域内の重心座標を左右で比較する. 最後に, これら二つの方法で得られる非対称度による定量評価を行う. 人工的な合成データによる実験の結果, マッチング誤差は0.09821 と小さく抑えられること, および人の主観的な感覚に類似する評価を行えることが確認できた. キーワード: 口唇裂, 3 次元点群データ, 対称性解析

#### 1. 序論

ロ唇裂は、上口唇の両側、あるいは片側が正常に形成されな いことによって生じる先天異常で、披裂を治療するために生 後3か月頃に口唇の形成手術が行われる.しかし、一度の手術 では顔の非対称性を完全に除去できない.そこで、顔の左右差 を修正することを目的とした二次手術が症状の程度に応じて 行われるが、顔の左右対称性の基準は曖昧であるため、手術の 必要性に関する医師の見解は一致しないことがある[1].以上 の背景から、顔の左右対称性を定量的に評価する方法の開発 が期待されている.

従来手法では、対称性の解析は3次元画像を用いて行われる ことが一般的である.さらに、近年では、時間軸を考慮したデ ータを用いた手法も提案されている.例えば、Gattani[2]は、 DI4D(Dimensional Imaging)システムによって撮影された3次元 の動画像データから表情の動きを解析した.静止画は人の表 情の一瞬を切り取ったものである一方で、動画像は表情の変 化を記録できるため、より自然な状況における評価が可能と なる.しかし、この手法には、顔のランドマーク点を手動で選 択するプロセスが存在する.選択誤差は統計的に分析されて いるが、定量的な評価を行うためには、システムに人為的な要 素が存在しないことが望ましい.以上の観点から、本論文では、 3次元点群動画像を用い、かつ人の介入を必要としない顔の対 称性評価手法を提案する.

### 2. 手法

1) 疑似動画像データ

実際の3次元点群動画像データを入手することが困難なため,疑似的に動画像を作成する.動画像は静止画が時系列に連なったものであるため,静止画の3次元点群データに少しずつ異なる変化を加えたデータを複数フレーム作成することにより,人工的に変形を加える.本論文では,これを疑似動画像データと呼ぶ.以下でその作成方法を述べる.

はじめに、細木[3]の手法を用いた顔の対称面を検出する. さらに、得られた対称面が中心となり、かつ顔が正面を向くような剛体変換行列を求め、点群の座標を変換する.

次に, FFD(Free-Form Deformation)[4]を用いて点群に変形を 加える.本論文では、口唇裂の症状が口唇部に現れることを考 慮し、その周辺に変形を加える.

疑似動画像データは 60 個の点群ファイルで構成されるもの とする.フレーム1はオリジナルの点群であり、それ以外の点 群には変形が加えられている.疑似動画像データを最初から 時系列の順番で見ると、顔が徐々に変形するように見える. 2) ランドマーク点の時系列変化を利用した評価

はじめに, 疑似動画像データの最初のフレームで Kazemi[5] の手法を用いた顔のランドマーク点を検出する.この手法で は 68 点のランドマークが検出されるが,本論文では,口唇部 に相当する 10 点を解析対象とする.これは,変形領域に注目 するため,および計算時間を削減するためである. 次に、ランドマーク点のフレーム間マッチングを行う.この 処理では、特徴量として FPFH[6]を用いる.FPFHは、点群内の 注目点における局所的な幾何学的性質を記述する.したがっ て、FPFH の差が小さい二点は、類似した性質を持つ点である と見なすことができる.この性質を利用し、フレームtにおけ るランドマーク点の FPFH を基準として、フレーム(t+1)で 特徴量の差が最小となる点を探索することにより、異なるフ レームの同じランドマーク点を対応づける.以上のマッチン グ処理をt=1から始めて帰納的に繰り返し、全ての点群デー タでランドマーク座標を決定する.

最後に、ランドマーク点の時系列変化を利用した非対称度 評価を行う.時系列変化は、フレーム(*t*+1)のランドマーク 座標から、それに対応するフレーム*t*の座標を減算して得ら れるベクトル(シフトベクトル)で表現する.シフトベクトルは、 各ランドマーク点の1フレーム後の移動方向を表す.したがっ て、左右で対応するシフトベクトルを比較することにより、時 系列変化の左右差を計算することができる.左右差は3次元ベ クトルで得られるが、その長さを評価の尺度として用いる.評 価対象は 10 点であるため、同様の評価が 5 回繰り返される. したがって、その平均値を時系列変化の非対称度とする.

3) 重心座標を利用した非対称度

はじめに、口唇部の領域を長方形で抽出する. さらに、領域 を10×10に分割し、各小領域内で点群の重心座標を計算する.

次に、重心座標を用いた非対称度評価を行う. 左右で対応す る小領域内の重心座標を比較し、その左右差を表す3次元ベク トルの長さを評価に用いる. 抽出領域は100個に分割されてい るため、同様の計算が50回繰り返される. したがって、その平 均値を重心の非対称度とする.

#### 3. 実験·考察

前項で述べた手法を疑似動画像データに適用する. データ は10セット作成し、そのうち5セットは顔の右側だけに変形 を加え、残り5セットは顔の両側に同量の変形を加えた.

全ランドマークのマッチング誤差の平均値は0.09821となり, 小さく抑えられることが確認できた.誤差は,正解点とマッチ ング点間のユークリッド距離である.このことから,FPFH を 比較することによるマッチングが有効であると言える.ただ し,本論文では10セットのデータそれぞれに対して10個のラ ンドマーク点,すなわち計100点でマッチングを行ったが,そ の中の4点に関しては2.9を超える大きな誤差が発生した.そ の理由として,FPFHを比較するだけの方法では不十分である ことが考えられる.したがって,他の特徴量の導入やアルゴリ ズムの改善が今後の課題となる.



非対称度評価の結果を図1に示す.非対称な変形データでは 非対称度が大きく、対称な変形データでは非対称度が小さく なり、感覚的な評価に類似する結果となった.また、非対称な 変形データに関して、変形量の大きいデータでは非対称度が 大きくなることも確認できた.

#### 3. 結論

本論文では、3 次元点群動画像を用い、かつ人の手を必要と しない顔の非対称度評価法を提案した.実験の結果、FPFH に よるマッチングの有効性と、非対称度評価の妥当性を確認す ることができた.今後の課題は、マッチングアルゴリズムと評 価方法の改善、実データへの応用である.

#### 利益相反の有無

なし

- [1] C. A. Tortman, J. J. Faraway, H. W. Losken et al., "Functional Outcomes of Cleft Lip Surgery. Part II: Quantification of Nasolabial Movement", Vol. 44, The Cleft Palate Craniofacial Journal, 2007, pp.607-616.
- [2] S. Gattani, X. Ju, T. Gillgrass et al., "An Innovative Assessment of the Dynamics of Facial Movements in Surgically Managed Unilateral Cleft Lip and Palate Using 4D Imaging", Vol. 57, The Cleft Palate-Craniofacial Journal, 2020, pp.1125-1133.
- [3] D. Hosoki, T. Kamiya, N. Kimura-Nomoto et al., "Symmetric Plane Detection and Symmetry Analysis from A 3D Point Cloud Data of Face", International Conference on Control, Automation and Systems, 2020, pp.402-406.
- [4] T. W. Sederberg, S. R. Parry, "Free-Form Deformation of Solid Geometric Models", Vol. 20, No. 4, ACM SIGGRAPH Computer Graphics, 1986, pp.151-160.
- [5] V. Kazemi, J. Sullivan, "One Millisecond Face Alignment with An Ensemble of Regression Trees", IEEE Conference on Computer Vision and Pattern Recognition, 2014, pp.1867-1874.
- [6] R. B. Rusu, N. Blodow, M. Beetz, "Fast Point Feature Histograms (FPFH) for 3D Registration", International Conference on Robotics and Automation, 2009, pp.3212-3217.

## 非侵襲的なドライバー遺伝子変異有無の識別のための

## Radiomics 特徴量に基づく 2 クラス分類

渡邊 至恩\*1,神谷 亨\*1,寺澤 岳\*2,青木 隆敏\*2

\*1 九州工業大学 〒804-8550 北九州市戸畑区仙水町 1-1

\*2 産業医科大学 〒807-8555 北九州市八幡西区医生ヶ丘 1-1

## Two-class classification for non-invasive identification of the presence or absence

### of driver gene mutations based on radiomics features

Shion WATANABE<sup>\*1</sup>, Tohru KAMIYA<sup>\*1</sup>, Takashi TERASAWA<sup>\*2</sup>, Takatoshi AOKI<sup>\*2</sup>

<sup>\*1</sup> Kyushu Institute of Technology

### <sup>\*2</sup> University of Occupational and Environmental Health

**要旨**: 2021 年の日本人の死因はがんが約 27%を占めており,がんにおける部位別死亡率は肺がんの割合が最も高く,早期発見・早期治療が重要課題となっている.肺がんの治療方針決定に際し分子診断が推奨されているが,そのためには侵襲的な生検が必要である.そこで,ドライバー遺伝子変異の有無の識別を非侵襲的に行う CAD (Computer Aided Diagnosis)システムの開発を目標とした手法を提案する.本論文では Radiomics 特徴量と性別を説明変数とし,Null Importance により特徴量選択を行った後,LightGBM (Light Gradient Boosting Machine)を用いた 2 クラス分類を行う.提案手法を医師の指導の元で作成した 175 症例のデータセットに適用した結果,AUC (Area Under the Curve)は 98.1%, Accuracy は 92.0%,真陽性率 (TPR: True Positive Rate)は 88.1%,偽陽性率 (FPR: False Positive Rate)は 4.39%を得た.

キーワード: Computer Aided Diagnosis, Machine Learning, Radiomics, Light Gradient Boosting Machine, Null Importance

#### 1. 序論

2021 年の死因の約 27%ががんであり,がんにおける部位別 死亡率では肺がんが最も高く,早期発見・早期治療が重要課題 となっている.肺がんの治療方針決定に際し分子診断が推奨さ れているが<sup>[1]</sup>,そのためには侵襲的な生検が必要となる.CT 画 像から肺がん病変のドライバー遺伝子(肺がん細胞の増幅に関 わる遺伝子)変異の有無を診断することが可能となれば,生検 による侵襲を伴わず,病理診断の時間を短縮したうえで,適切 な治療の開始へつながる.これまでの先行研究において,CAD

(Computer Aided Diagnosis)システムによるドライバー遺伝子 変異の有無の識別に関する報告はあるものの,実用化には至っ ていない<sup>[2, 3]</sup>.

本論文では、CT 画像に性別を情報として加えた Radiomics を用い、Null Importance<sup>[4]</sup>により次元削減を実施した後、 LightGBM (Light Gradient Boosting Machine)<sup>[5]</sup>を用いて遺伝子 変異の有無を識別する手法を提案する.

### 2. 手法

### 2.1 前処理

3D slicer<sup>[6]</sup>によって胸部 CT 画像を入力し,複数枚あるス ライス画像から,腫瘍の面積が最大となるスライス画像1枚 を選択する.ここで,入力画像は,他器官へ浸潤のない腫瘍 径が50mm 以下の2次元画像を対象とする.肺がんに関する 必要な情報のみを取得するため,関心領域を医師の指導の元 セグメントし,その領域から特徴量の抽出を行う.

#### 2.2 Radiomics 特徵量

Radiomics とは「放射線医学」と「多量の情報を系統的に 扱う科学」を組み合わせた造語のことで,放射線画像から形 状・強度・テクスチャなどの特徴を抽出・解析する手法であ る<sup>[7]</sup>.従来の生検による解析と比較して,患者への負担を抑 えながら,腫瘍の高度な定量的特徴を抽出できるため,より 適切で正確な治療を行うことが可能になる.

#### 2.3 特徵量選択

特徴量選択とは、データセット内の特徴から有意な特徴の みを選択し、計算コストの削減や、不要なノイズデータへの 過学習抑制を行う手法である.本論文では、3D slicerの拡張 機能を用いて抽出した 851 個の Radiomics 特徴量から、識別 に有意な特徴量を選択するため、Null Importance という手法 を採用する. Null Importance では、目的変数の値をランダム に 100 回シャッフルさせ、シャッフル前後の特徴量の重要 度を比較することにより不要な特徴量の削減を行う.ここで、 特徴量の重要度の算出には LightGBM を用いる.シャッフル 前の重要度が全てのシャッフル後の重要度より高い場合、目 的変数の予測に寄与すると判断できるため、21 個の特徴量 を選択する.

また, テキスト情報として性別を特徴量に追加することに より精度の向上を図る.具体的には,男性を1,女性を0と した One-Hot ベクトルにすることで,テキスト情報を加味 したデータセットを作成した.

2.4 機械学習による分類

勾配ブースティング決定木の1つである LightGBM を用 いる.アルゴリズムの特徴として、勾配ブースティングの過 程で、Level-Wise ではなく Leaf-Wise に成長させる決定木で あるため、短時間かつ高精度な学習が可能である.また、 LightGBM は様々な機能が実装されており便利ではあるが、 多くのハイパーパラメータが用意されている.そこで、 optuna を用いて最適なハイパーパラメータのチューニング を実施する<sup>[8]</sup>.

#### 3. 実験

医師の指導の元作成した,175 症例のデータセットを使用する. Leave-One-Out 交差検証を行い,ドライバー遺伝子変異有 無の2クラス分類における AUC (Area Under the Curve), Accuracy, 真陽性率 (TPR: True Positive Rate),偽陽性率 (FPR: False Positive Rate) により評価を行う.特徴量を削減しない場 合と,先行研究における特徴量選択に Lasso (the Least Absolute Shrinkage and Selection Operator)を用いた手法,テキスト情報 を加味した手法<sup>[9]</sup>との比較結果を表1に示す.

#### 4. 結果と考察

175 症例の胸部 CT 画像から得られた Radiomics 特徴量を Null Importance で特徴量選択し, LightGBM を用いて遺伝子変 異有無の2クラス分類を行った. Null Importance を施した後, テキスト情報として性別を加味した場合において,全ての評価 指標で最も高い精度を示した.

本法は Null Importance によって,全ての特徴量の重要度を 目的変数のシャッフル前後で算出し,比較することで特徴量を 選択したため,冗長な特徴量を正確に除去することができた. Lassoでは,相関の高い特徴が複数ある場合,その中の1つし か選択できないため,有意な特徴量も除去していた可能性が考 えられる.

		-		
	TPR	FPR	Acc.	AUC
特徵量削減無	80.9	7.69	86.9	95.9
Lasso	85.7	7.69	89.1	98.0
Null Importance	82.1	8.79	86.9	97.4
特徴量削減無 + sex	83.3	7.69	88.0	96.8
Lasso + sex	88.1	9.89	89.1	97.7
Null Importance + sex	88.1	4.39	92.0	98.1

表 1 精度評価 (Acc.: Accuracy)

また,選択された特徴量より,ウェーブレット変換型のテク スチャ特徴が多いことがわかる.そのため,胸部 CT 画像と肺 がんドライバー遺伝子変異有無の関係に関しては,CT 画像上 の周波数帯域におけるテクスチャにおいて相関が高い可能性 がある.

本論文では、画像データ生成の際に、CT 画像内の腫瘍径が 最大となる2次元スライス画像を用いた.ここで、3次元画像 を入力に与えれば、腫瘍の特徴を最大限に抽出することが可能 になると考えられる.そのため、3次元画像からの Radiomics 特徴量の抽出による、さらなる精度の向上が期待できる.

#### 5. 結論

胸部 CT 画像からドライバー遺伝子変異有無の識別をするた めの CAD システムの開発を行った. 識別精度として, AUC98.1%, Accuracy92.0%, 真陽性率 88.1%, 偽陽性率 4.39% と非常に高い精度の結果を得た. 今後さらなる分類性能の向上 のため, 3D 画像からの特徴量抽出, データセットの拡張, 汎 化性能を保持できる特徴量選択の導入を行う予定である.

### 利益相反の有無

なし

- 肺癌診断ガイドライン一悪性胸膜中皮腫・胸腺腫瘍含む 2022 年版, https://www.haigan.gr.jp/guideline/2022/
- [2] JKR. Nair, UA. Saeed, CC. McDougall et al: Radiogenomic Models Using Machine Learning Techniques to Predict EGFR Mutations in Non-Small Cell Lung Cancer. *Canadian Association of Radiologists journal*, Vol. 72, 2021, pp. 109-119
- [3] G. Rossi, E. Barabino, A. Fedeli et al: Radiomic Detection of EGFR Mutations in NSCLC. *Cancer research*, Vol. 81, 2021 pp. 724-731
- [4] S. Kimura, D. Oda, M. Tokuhisa, Feature Selection using Modified Null Importance. 2021 IEEE Symposium Series on Computational Intelligence, 2021, pp. 1-7
- [5] K. Guolin, M. Qi, F. Thomas et al: LightGBM: A highly Efficient Gradient Boosting Decision Tree. 31st Conference on Neural Information Processing Systems, 2017, pp. 3149-3157
- [6] A. Fedorov, R. Beichel, J. Kalpathy-Cramer et al: 3D Slicer as an Image Computing Platform for the Quantitative Imaging Network. *Magnetic resonance imaging*, Vol. 30, 2012, pp. 1323-1341
- [7] TP. Coroller, P. Grossmann, Y. Hou et al: CT-Based Radiomic Signature Predicts Distant Metastasis in Lung Adenocarcinoma. *Radiotherapy & Oncology*, Vol. 114, 2015, pp. 345-350
- [8] T. Akiba, S. Sano, T. Yanase et al: A Next-Generation Hyperparameter Optimization Framework. *Proceedings of the 25<sup>th</sup> ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2019, pp. 2623-2631
- [9] S. Watanabe, T. Kamiya, T. Terasawa et al: Detection of Driver Gene Mutations from Thoracic CT Images Based on LightGBM with Radiomics Features. 2022 22nd International Conference on Control, Automation and Systems, 2022, pp. 542-545

### 頭部 CT 所見文重要度分類における能動学習アルゴリズムの比較

綿谷 朋大\*1.2, 佐藤 淳哉\*1.2, 喜多 洸介\*1, 富山 実幸\*1.2, 鈴木 裕紀\*1, 木戸 尚治\*1, 富山 憲幸\*2

\*1 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

\*2 大阪大学大学院医学系研究科 放射線統合医学講座 放射線医学

## Comparison of active learning algorithms for head CT report importance categorization

Tomohiro WATAYA<sup>\*1,2</sup>, Junya SATO<sup>\*1,2</sup>, Kosuke KITA<sup>\*1</sup>, Miyuki TOMIYAMA<sup>\*1,2</sup>, Yuki SUZUKI<sup>\*1</sup>,

Shoji KIDO<sup>\*1</sup>, Noriyuki TOMIYAMA<sup>\*2</sup>

<sup>\*1</sup> Department of Artificial Intelligence Diagnostic Radiology, Osaka University Graduate School of Medicine

<sup>\*2</sup> Department of Radiology, Osaka University Graduate School of Medicine

要旨:【目的】頭部 CT 所見文重要度分類において,能動学習アルゴリズムを比較する.【対象・方法】2020年に大阪大学医学部附属病院で施行した頭部単純 CT の所見文 3728件に対し,放射線科医が内容の重要度を5クラスに分類し,内2385件を訓練データとした.訓練データの中から25件ずつ選択して学習データに追加して UTH-BERT を訓練する際,選択する際の能動学習アルゴリズム(不確実性サンプリング(US)4手法,多様性サンプリング(DS)2手法)をランダムサンプリング(RS)と比較した.【結果】学習データに 800件を使用した時点では,US は RS より 1-2%正解率の向上を認めた一方,DS では1-2%低下した.また,US では RS より も少数のデータでモデルの成績が収束した.さらに US では訓練序盤から少数クラスの所見文が積極的に学習データに追加された. 【考察】US では少数のデータで効率的な学習が可能であり,アノテーションコストの削減を可能にし,さらにクラス間インバランスの是正に役立つ.

キーワード:能動学習,自然言語処理,UTH-BERT,放射線科所見文

### 1. はじめに

近年,主治医による放射線科所見文の見落としが医療安全上の問題になっている.そのため,所見文の重要度を自動的に判定するシステムが開発されれば,主治医への迅速な警告などに役立つと考えられる.しかし,システムの開発には膨大な量のアノテーション付きデータが必要であり,効率的なアノテーション戦略が必要である.

Mabu らは胸部 CT の肺陰影画像の分類において能動学習の 有用性を報告している[1]が,能動学習を放射線科所見文のよ うな自然言語処理(NLP)に応用した報告は少ない.本研究では 能動学習を用いることで効率的なアノテーションが可能か検 討し,また複数の能動学習アルゴリズムを比較することにした.

尚, 放射線科の扱うモダリティや対象部位は多岐にわたるため, 所見のバリエーションを制限するため, 本研究では対象を 頭部単純 CT の所見文に限定することにした.

### 2. 対象·方法

1) 対象

2020 年に大阪大学医学部附属病院で施行した頭部単純 CT の所見文 3728 件を対象とした.これらに対し,放射線科医が 0: 異常なし(561 件), 1: 軽微な異常(995 件), 2: 継続した経過 観察を要する異常(1646 件), 3: 慎重な経過観察を要する異常 (288 件), 4: 精査加療を要する異常(238 件),の5カテゴリに分 類した.3728 件のうち,20%を test データ,16%を validation デ ータとし,残りの 84%(2385 件)を train データとした. 2) 学習条件

東京大学大学院医学系研究科医療 AI 開発学講座により公開 されている UTH-BERT[2]を特徴量抽出器とし fine-tuning した. これは Bidirectional encoder representations from transformers (BERT) [3]を東京大学医学部附属病院の日本語電子カルテデー タにより事前学習したものである.

Train データの中から 25 件ずつ学習データに追加すること とし、下記の各手法で算出されるスコアφが高いものから順に 選択した.学習データへの追加後,再度学習することを、全て の学習データを使用するまで繰り返し,正解率の推移を比較し た.本検討では5回試行し、以降の結果は5回の平均を示す.

a) ランダムサンプリング(RS)

本手法ではφを乱数で生成する.

b) Least confidence (LC)

 $\varphi(x) = 1 - P(y_1|x) \tag{1}$ 

c) Marginal sampling (MS)  

$$\varphi(x) = P(y_2|x) - P(y_1|x)$$
(2)

d) Ratio of confidence (RC)

$$\varphi(x) = P(y_2|x)/P(y_1|x) \tag{3}$$

e) Entropy sampling (ES)

$$\varphi(x) = \Sigma_i^5 P(y_i|x) \times log P(y_i|x)$$
(4)

f) Euclidean distance (ED)

$$\rho(x) = min_c ||v_x - v_c|| \tag{5}$$

g) Cosine distance (CD)

 $\varphi(x) = 1 - \min_c(v_x \cdot v_c / ||v_x|| \cdot ||v_c||) \tag{6}$ 

但し、P(y; |x)は、「ある入力xに対するモデルの出力(各カテ ゴリの確率)のうち,i番目に高いもの」,vrは「ある入力xに対 する特徴量ベクトル」, v,は「学習データに含まれるカテゴリc の特徴量ベクトルの中心」を表す.

これらのうち、LC、MS、RC、ES が不確実性サンプリング 手法(US), ED, CD が多様性サンプリング(DS)である.

### 3. 結果

各手法の, 学習に使用したデータ数と test データに対する正 解率の推移を fig.1 に示す. 青色の点線は RS の結果である. US 手法では、RS と比べ概ね高い正解率を示し、800 件使用し た時点で 1-2%程度上昇した. 一方 DS では曲線は RS を下回 り,800件使用した時点で1-2%程度低下した.



#### Fig.1 能動学習各手法の正解率の推移

各手法において、学習データに追加されたデータのカテ ゴリごとの内訳を fig.2 に示す. US ではカテゴリ 3,4 の少数 カテゴリが優先的に追加された一方で、DS ではそのような傾 向を認めなかった.

### 4. 考察

NLP における能動学習の有用性は、過去にも報告されてお

り[4,5], 正解率やF1 スコアに与える効果は1-3%であった.本 手法でも特に US において同程度の正解率の上昇を認めた. US ではカテゴリ3.4の少数クラスが優先的に学習データに追加さ れており、これはクラス間インバランスの是正に役立つことを 示している.

一方で、本研究ではDSはRSよりも正解率が下がっており、 またクラス間インバランスが是正される傾向は見られなかっ た. 既報でも同様の報告を認める[4]. DS 手法では,「各クラス に属するサンプルの特徴量は、特徴量空間内で同一のクラスタ に属する」ことを仮定しており, NLP ではこれが成り立ちにく い可能性を示唆する.

本研究は,NLPにおいて能動学習,特にUSが有用であるこ とが示されたが、US の中でどの手法がより効果が高いか、ま た効率の良い能動学習のハイパーパラメータ探索については 今後の検討課題である.

#### 利益相反の有無

本講座は FUJIFILM Corporation との共同研究講座である. 謝辞

本研究は JSPS 科研費 21H03840 の助成を受けたものである.

#### 文 歃

[1] Mabu S, Kido S, Hirano Y, et al. Opacity Labeling of Diffuse Lung Diseases in CT Images Using Unsupervised and Semi-supervised Learning. Deep Learning in Healthcare: Paradigms and Applications. 2020:165-79.

[2] Kawazoe Y, Shibata D, Shinohara E, et al. A clinical specific BERT developed using a huge Japanese clinical text corpus. PLOS ONE. 2021;16(11):e0259763.

[3] Devlin J, Chang M-W, Lee K, Toutanova K. Bert: Pre-training of deep bidirectional transformers for language understanding. arXiv preprint arXiv:181004805. 2018. [4] De Angeli K, Gao S, Alawad M, et al. Deep active learning for classifying cancer pathology reports. BMC Bioinformatics. 2021;22(1):113.

[5] Dor LE, Halfon A, Gera A, et al. Active learning for BERT: An empirical study. Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP); 2020.





(c) Merginal sampling (d) Ratio of confidence G 0.8 0.6 0.4 Ratio 0.2 0.0 1000 1500 Amount of train data 1000 1500 ount of train data (g) Cosine distance 4 3 2 1 0 1000 1500 Amount of train data 2000 2500

### UTH-BERT と注意機構を用いた医療診断レポートにおける部位識別

成田 紗弥\*1 間普 真吾\*1 木戸 尚治\*2

\*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人工知能画像診断学共同研究講座

### Anatomic Classification of Medical Diagnostic Reports Using UTH-BERT and

### **Attention Mechanisms**

Saya NARITA<sup>\*1</sup>, Shingo MABU<sup>\*1</sup>, Shoji KIDO<sup>\*2</sup>

### <sup>\*1</sup> Yamaguchi University

\*2 Osaka University

**要旨**:一般に,深層学習に必要な教師データを作成するには大変な労力を要するため,データのアノテーションを効率的に行う仕 組みが必要である.本研究では,PET-CT 画像に対する診断レポートにおいて,整理されたラベル付き文章データセットの構築を 目的とする.先行研究では,診断レポートの各文をUTH-BERT で解析し,入力された文を全身,頭部,頭頚部,胸部,腹部,その 他の文章に分割するモデルを構築している.当該研究では,識別対象文のみでは部位が識別できないものが多数あり,識別対象文 の前文も入力に加えるモデルを構築している.これにより識別性能が向上したが,部位によっては前文を入力することがノイズと なり,性能が低下する結果も見られた.したがって,前文の重要度を自動的に判断できれば,さらなる性能の向上につながると考 え,UTH-BERT に注意機構を組合せたモデルを構築する.さらに,本モデルを従来手法と比較して性能を検証する.

キーワード:深層学習,自然言語処理,BERT,注意機構,診断レポート

### 1. はじめに

深層学習には大量の教師データが必要であるが、教師データ を作成するには大変な労力を要する.そのため、最小限の労力 でデータのアノテーションを効率的に行う仕組みを構築する ことが必要である.本研究では、ラベルがついていない PET-CT 画像と対になる診断レポートに対して、各文に部位ラベル を付与したデータセットを構築することを目的としている.

先行研究[1]では、アノテーションデータ作成の第1段階と して、医療文章で事前学習されたUTH-BERT[2]を用いて診断 レポートを解析し、入力された文章を6つの部位(全身、頭部、 頭頚部、胸部、腹部、その他)の文章に分割するモデルを構築 した.しかし、各文に対応する部位ラベルを付与するにあたり、 当該文のみでは部位が識別できないものが多数あり、この問題 を解決するために、識別対象文の前文も入力に加えて識別する モデルを構築した.これにより識別対象文のみで識別を行うモ デルよりも性能が向上したが、部位によっては前文を入力する ことがノイズとなり、性能が低下する結果も見られた.このこ とから、前文の重要度を自動的に判断できるモデルがあれば、 さらなる性能の向上につながると考え、UTH-BERT に注意機 構を組み合わせ、レポートを6つの部位に識別するモデルを構 築する.そして、このモデルを従来手法と比較して性能を検証 した.

### 2. 手法

2.1 概要

本研究では、以下の4つの手法を提案する.

- 提案手法1:スカラー型アテンション付きモデル
- 提案手法 2:スカラー型アテンション+UTH-BERT 再学 習①モデル
- 提案手法 3:ベクトル型アテンション+UTH-BERT 再学 習①モデル
- 提案手法4:提案手法2と3に対してそれぞれUTH-BERT
   再学習②を付与したモデル

以後,従来手法は文献[1]の方式を示す.提案手法のモデルの 概観は図1のとおりであり,図中の数は特徴次元数である.

#### 2.2 提案手法 1

提案手法1では、前文と識別対象文をそれぞれUTH-BERT に入力し、UTH-BERT で出力された前文と識別対象文の特徴 量*x*,*y*を連結させ、注意機構である複数の全結合層に接続する ことで、特徴次元数1のスカラー型アテンションaを出力する. これが前文に対する注意の役割を持つ.aを前文の特徴ベクト ルに掛けることで、前文が重み付けられた新たな特徴量x'を得 る.その後,x'とy'を部位識別部に入力し、文章の部位識別を 行う.

### 2.3 提案手法 2

提案手法2では,UTH-BERTの全結合層のみを再学習させ, その効果を検証する.



### 図1 提案手法のモデル構造の概観

### 2.4 提案手法 3

提案手法3は,提案手法2の注意機構の出力次元数をUTH-BERT の特徴次元数と同じ768 (ベクトル型アテンションa) に したものである.特徴次元数を768 に変更することで,UTH-BERT から出力された前文の特徴ベクトルの成分ごとに注目 度を計算できる.

#### 2.5 提案手法 4

提案手法4では,提案手法2と3について UTH-BERT の全 結合層およびエンコーダブロックの最終層も再学習させる.

### 3. 実験結果

各手法における部位毎の F 値の平均を表 1 に示す.表 1 右 側に示す全部位の平均に注目すると,従来手法と比較してすべ ての提案手法が高い F 値を示した.特に,提案手法 4 (スカラ 一型)が最も高い結果となった.頭部,頭頚部,胸部,腹部の 4 部位に対する平均では,提案手法 4 (ベクトル型)が最も高 い値となった.表 1 より,注意機構と UTH-BERT 再学習が部 位識別において良い効果を与えることがわかる.

### 4. まとめと今後の課題

本論文では、UTH-BERT と注意機構を用いて、医療診断レポ ートからの特徴抽出、及び識別を行う手法を提案した.実験の 結果,注意機構を用いることで、提案手法が従来手法よりも優 れていることを示した.今後の課題として、本論文では5か月 分の訓練データを用いてモデルの学習を行ったが、これを活用 して、保有する15年分のラベル付けを効率的に行う方式へ拡 張し、大規模データセットの構築につなげること、またこの実 現のため、ラベルの付与されていない大量のデータを用いて、 事前学習済みである UTH-BERT の2段階目の事前学習を行う ことを考えている.

#### 謝辞

本研究は JSPS 科研費 JP21H03840, JP22K12152 の助成を受けたものです.

#### 利益相反の有無

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 講座は,富士フイルム株式会社との共同研究講座です.

#### 文 献

- [1]前田健宏,間普真吾,木戸尚治: UTH-BERT を用いた医療診断レポ ートからの特徴抽出とその識別,第 14 回呼吸機能イメージング研究 会学術集会プログラム・抄録集, 2023, p. 71
- [2] Yoshimasa Kawazoe, Daisaku Shibata, Emiko Shinohara, Eiji Aramaki, and Kazuhiko Ohe: A clinical specific bert developed using a huge Japanese clinical text corpus. PLOS ONE, Vol. 16, No. 11, 2021, pp. 1-11

表1 各手法における部位毎のF値の平均

	手法	全身	頭部	頭頚部	胸部	腹部	その他	全部位の平均	4部位の平均*
	従来手法	0.679	0.700	0.748	0.892	0.878	0.567	0.744	0.804
	提案手法 1	0.707	0.768	0.710	0.860	0.853	0.762	0.777	0.798
	提案手法 2	0.720	0.768	0.733	0.869	0.856	0.766	0.785	0.807
F 値	提案手法 3	0.696	0.734	0.779	0.892	0.893	0.583	0.763	0.825
	提案手法 4	0.673	0.780	0.764	0.907	0.908	0.766	0.800	0.840
	(スカラー型)								
	提案手法 4	0.701	0.740	0.811	0.911	0.912	0.616	0.782	0.843
	(ベクトル型)								

\*頭部,頭頚部,胸部,腹部の平均

## Vision Transformer と Brodmann area を用いた脳 SPECT 画像の認知症分類

若尾 紘嵩\*1, 深澤 誠\*2, 飯塚 友道\*2, 清水 昭伸\*1

\*1東京農工大学工学研究院

\*2 複十字病院認知症疾患医療センター

### Dementia classification of brain SPECT volumes using Vision Transformer and Brodmann area

Hirotaka Wakao<sup>\*1</sup>, Makoto Fukasawa <sup>\*2</sup>, Tomomiti Iizuka<sup>\*2</sup>, Akinobu Shimizu<sup>\*1</sup>

<sup>\*1</sup> Institute of Engineering, Tokyo University of Agriculture and Technology

<sup>\*2</sup> Fukujuji Hospital

要旨:本報告では,認知症患者(AD・DLB・FTD)と正常群(HC)の脳SPECT 画像(3D-SSP)を対象とした,深層学習を用いた 4 クラス分類手法を提案する.脳SPECT 画像(3D-SSP)を用いた診断は,各疾患に典型的な血流量の変化を見出すことにより行わ れる.その際,脳の特定の領域の血流量低下だけでなく,領域間の血流量の関係を踏まえて分類を行う必要がある.本報告では, 脳領域を組織構造ごとに区分した Brodmann area を利用し, Vision Transformer により分類に貢献する領域や領域間の関係性をデー タドリプンに導くことが可能な方法を提案する.実験では,1 症例あたり5 種類のデータからなる 418 症例のデータセットで学習 および評価を行い,既存の医学的知見との比較を行った.

キーワード:認知症, SPECT, Brodmann area, Vision Transformer

### 1. はじめに

昨今の医療技術の著しい進歩により,平均寿命はここ数十年 で飛躍的に伸びているが,高齢化社会により認知症患者の数も 急増しており,2050年には全世界の認知症患者数は現在の3倍 以上になるといわれている[1].認知症の種類は,患者数が多い 順に,アルツハイマー型認知症(AD),脳血管性認知症(VD),レ ビー小体型認知症(DLB),前頭側頭型認知症(FTD)などがある. VD 以外の3種類の認知症は,SPECT検査で早期に識別できる 場合が多い[2].認知症を早期に発見,診断することは発症の抑

制や治療法の決定に役立つ. SPECT 検査は, 脳の血流状態を 図1のように可視化できる.しか し,実際に目視で血流が低下して いる部分を特定し,認知症を診断 することが難しい場合がある [3].そのため,コンピュータによ る診断支援が求められている.



#### 2. 先行研究と本研究の貢献

本研究では、SPECT 画像(3D-SSP[4])から正常群(HC), AD, DLB, FTD の4 クラス分類を行う診断支援システムの分類精度 の改善,および、判断根拠の可視化による説明可能性の向上を 目的とする. 関連する先行研究について以下に示す.

まず文献[5]では、HC、AD、DLB の 3 クラスの内 2 クラス を 2DCNN によって分類し、Guided Grad-CAM によってモデル の注目領域を可視化している.文献[6]では、HC、AD、DLB、 FTD の 4 クラスを Graph-CNN にて分類している.3 次元構造 を考慮した学習を行い、Graph Pooling によって解像度を落とし た後に学習した特徴量と連結することで、82.9%の分類精度を 達成した.文献[7]では、同 4 クラスを 3DCNN によって分類し ており、Attention 機構を導入することで、クラスごとに適切な 部位の特徴を強調、あるいは抑制を行っている.しかし、いず れの研究もモデルの出力と脳の解剖学的構造との関係が明確 ではない.一方,水村ら[8]は,認知症の原因となる血流異常領域の広がりを定量的に把握するために,大脳新皮質の解剖学・細胞構築学的区分である Brodmann area などに基づいて SPECT 画像を解析した臨床研究を報告している.

本稿では,水村らが注目した SPECT 画像と Brodmann area な どの関係を利用して Vision Transformer (ViT)[9]の学習を行い, モデルの出力と Brodmann area の関係を可視化する手法を提案 する.

#### 3. 提案手法

3 次元 SPECT 画像に 3D-SSP[4]を適用した脳表面血流画像 (WSFM)と、全脳(GLB)、視床(THL)、小脳(CBL)、橋(PNS) の4部位を基準として正規化した4種類のZ-Score 画像(ZSFM) の計5種類の画像を用意し、これらを図2のViTに入力する.



#### 図 2 Vision Transformer の構造

次元にベクトル化したものである.本手法では、5 種類の3次元の SPECT 画像(3D-SSP)を Brodmann area などに基づいて96分割し、各分割領域内の画素をラスタスキャン順に1次元に並べた.また、分割領域ごとに画素数が異なることから、ベクトル長を最大画素数に合わせて設定し、不足の場合には0パディングした.

ViT の重要な特徴の一つに、学習の過程で分類に重要なパッ チ間の関係を発見できることが挙げられる.そのため、認知症 の分類に重要な分割領域同士の関係がデータドリブンに導か れることを期待する.本研究では、Attention weight がモデルの 分割領域ごとの注目度に関係すると考え、本研究では、最終層 の値を注目度とする可視化法を提案する.ここで、Attention weight は脳全体の総和が1となるように症例ごとに正規化され ている.また、Multi-Head Attention のヘッド数を5とすること で、WSFMと4種類のZSFMに対応したAttention weight が求 められるよう工夫した.なお、最終的な症例の分類は、Encoder の最終出力からClass tokenと呼ばれる特徴量が集約されたベク トルを取り出し、全結合層に通すことで行われる.

#### 4. 実験

実験試料は HC100 症例, AD119 症例, DLB109 症例, FTD90 症例の全 418 症例であり, 3-fold CV により性能を評価した.

表1に分類結果を示す.先行研究で最も精度の高かった文献 [6]の手法と比べて 0.83 ポイント精度が向上したが,帰無仮説 (二つの手法の分類性能が同じ)は 5%有意水準で保留となっ た(マクネマー検定. p=0.593).

Prediction	HC	AD	DLB	FTD	Sensitivity[%]	Accuracy[%]
HC	92	4	2	2	92.00	
AD	5	91	10	13	76.47	02 72
DLB	6	5	96	2	88.07	83.73
FTD	7	9	3	71	78.89	]
Precision[%]	83.64	83.49	86.49	80.68		

表 1 実験結果

また,モデルが分類時に注目している領域の可視化を行い, モデルの注目領域の妥当性について検討した.図3の左図はAD 分類成功例の注目箇所の可視化の結果である(注目度が高いほ ど赤く表示).この可視化結果から次のことが読み取れる.

・ADの典型的な血流低下領域に注目できている

〇:ADで典型的な血流低下領域

- ・他のクラスにおける典型的な血流低下領域についても注目している.これは、AD との分類に有用であるために注目している可能性がある.
- ・実際に血流低下がみられる場合にも、いずれかのクラスで典型的な血流低下領域以外であれば、ほとんど注目しない.



#### 図3 ViT が注目した領域と入力画像の比較

注目度を分割領域ごとに症例平均を求め、平均値が 0.05 を超 えた領域に対して、医学的に良く知られている症例ごとに特徴 的な血流低下部位[2](○,△,×,□で表示)を比較したもの を表2に示した.医師が注目する領域におおよそ対応した分割 領域に対して,モデルも注目できていることが確認できた.ま た,5種類の入力画像ごとに異なる領域に注目していることも 読み取れる.これは,WSFMとZSFMの4種の画像がそれぞれ 異なる情報を持っていることを示唆し,医師が全ての画像を見 て総合的な判断を行っていることと整合している.

### 表 2 推論時の分割領域ごとの注目度 (最終層の Attention weight の症例平均)



#### 5. まとめ

本研究では、臨床で撮影された SPECT 画像(3D-SSP)を用 いた認知症の 4 クラス分類において、Vision Transformer をベー スとしたモデルを提案した.また、大脳新皮質の解剖学・細胞 構築学的区分である Brodmann area などとネットワーク出力の 関係を可視化する方法を提案し、Vision Transformer がデータド リブンに獲得した関係と、医学的知見との関係を評価した.418 症例を用いた実験からは、分類精度が 83.73%であること、また、 医学的知見との高い整合性が確認できた.

#### 謝辞

SPECT 画像と Brodmann Area の対応表をご提供いただいた, 東邦大学の水村直先生に深謝いたします.

#### 利益相反の有無

本研究の一部は日本メジフィジックス株式会社の研究助成 金を得て実施された.

#### 参考文献

- Aram So, et al: Early Diagnosis of Dementia from Clinical Data by Machine Learning Techniques, Applied Sciences, 7(7), 651, 2017
- [2] 松田博史:臨床医・RI 技師のための脳 SPECT パーフェクトガイド、メディカ出版, 2018, pp.101-156
- [3] 富士フイルム RI ファーマ株式会社:撮って診る!!認知症, http://genki55.net/spect/understand2.html (2023.5.1 閲覧)
- [4] Minoshima S, Frey KA, Koeppe RA, et al: A diagnostic approach in Alzheimer's disease using three-dimensional stereotactic surface projections of fluorine-18-FDG PET, J Nucl Med 36:1238-48, 1995
- [5] Iizuka T, et al: Deep-learning-based imaging-classification identified cingulate island sign in dementia with Lewy bodies, Scientific Reports. 9: 8944, 2019
- [6] 山家暢,他:深層学習による脳 SPECT 画像の認知症分類処理の改良,信学技報,120(431),MI2020-86:164-165,2021
- [7] Matsumoto N, et al: Improvement of dementia classification accuracy for brain SPECT volumes using the attention mechanism", IJCARS, 16 (Suppl 1) S112, 2021
- [8] Mizumura S, et al: Development of quantitative analysis method for stereotactic brain image: Assessment of reduced accumulation in extent and severity using anatomical segmentation, Annals of Nuclear Medicine. 17(4), 289–295, 2003
- [9] Dosovitskiy A, et al: An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale, ICLR, 2021

## 3DCNN を用いた脳 MR 画像の3 次元位置合わせ

馬場 星太郎,神谷 亨

九州工業大学大学院

3D image registration of brain MR images using a 3DCNN

Seitaro BABA, Tohru KAMIYA

Kyushu Institute of Technology

要旨:本論文では、アルツハイマー型認知症の脳萎縮に着目し、脳 MR 画像の経時的3D 位置合わせによる萎縮率の算出を目的とした画像処理手法を提案する. Stergios らの非線形 3D 位置合わせモデルを線形位置合わせモデルに組み替え、アフィン変換、剛体変換での位置合わせを行う.また、症例ごとに最適化処理を行う Instance-specific Optimization により、精度向上を図る.モデルの学習には、ADNIの脳 MR 画像を任意に線形変換した合成データを用いた.テストには合成データと実際の ADNI の時系列データを用いた実験の結果、合成データの剛体変換における最適化処理の追加により、正規化相互相関(NCC) が約 15%向上し、99.0%の精度が得られた.これにより脳 MR 画像における線形 3D 位置合わせモデルと Instance-specific Optimization の組み合わせの有用性を確認した.

キーワード: 3 次元位置合わせ, 脳萎縮, 3DCNN, ADNI

### 1. はじめに

認知症の患者数は世界で 5500 万人と推定されており,2030 年には 7800 万人に達すると予測されている[1]. つまり,有効 な治療法が開発されない限り,高齢化に伴い増加する傾向に あるといえる.また,高齢者の認知症の主な原因となる疾患と して,アルツハイマー型認知症(AD: Alzheimer's Disease)がある. これは精神,行動,機能低下,学習能力の喪失が進行する神経 変性疾患であり,早期診断,早期発見が重要となる[2].また, AD とその前段階の軽度認知障害(MCI: Mild Cognitive Impairment)では,症状の進行に伴い脳萎縮が発生する[3].その ため, MRI による脳萎縮の評価は有効なマーカーであり,診断 において不可欠な要素であるといえる[4].

本論文では,経時的差分技術により同一被験者の過去,現在 画像から脳萎縮を検出し,ADの診断支援システムの開発を目 的とし,線形の位置合わせモデルによる脳MR画像の3次元位 置合わせ手法を提案する.

### 2. 手法

## 2.1 位置合わせ

1)CNN モデル

図1に提案する CNN モデルを示す. 頭蓋骨は撮影条件にお ける形状変化がほとんどないということに着目し,線形変換 による位置合わせが可能である. そのため, Stergios らの非線形 3D 位置合わせモデル[5]を組み換え,線形変換のパラメータ を出力するモデルとする. これにより,モデルの軽量化と位置 合わせ精度の向上が見込める.

### 2)最適化

図1のモデルのみでは、大まかな推論結果のみが得られるた

め、高精度な位置合わせは困難である. そこで、図 2 に示す Instance-specific optimization[6]を適用し、症例ごとに再度細か く位置合わせを行うための 最適な幾何学的変換パラメータを 得る.







#### **2.2 ADNI**

本論文で使用したデータは、Alzheimer's Disease Neuroimaging Initiative(ADNI)データベース(adni.loni.usc.edu)から入手した. ADNI は MRI 等により、MCI と AD の進行の測定方法を検証す ることを主目的としている. 最新情報は[7]より確認できる.

#### 3. 実験と結果

本実験では, ADNI の AD 患者の MR 画像を使用した. モデ ルの学習には, MR 画像にランダムにアフィン変換, 剛体変換 を施し, 疑似的に過去, 現在画像のペアを作成した合成データ を使用した.

また,評価指標には式(1)に示す正規化相互相関(NCC)を用いる.NCCは値が1に近いほど画像の類似度が高いといえる.

$$R = \frac{\sum_{k=0}^{L-1} \sum_{j=0}^{N-1} \sum_{i=0}^{M-1} I(i,j,k) T(i,j,k)}{\sqrt{\sum_{k=0}^{L-1} \sum_{j=0}^{N-1} \sum_{i=0}^{L-1} I(i,j,k)^2 \times \sum_{k=0}^{L-1} \sum_{j=0}^{N-1} \sum_{i=0}^{M-1} T(i,j,k)^2}$$
(1)

本実験では、合成データ、6か月間隔のAD患者の過去、現 在画像ペアの実データに対して評価を行う. 表1に実験結果 を示す.

#### 4. 考察

表1より, 症例ごとに最適化を行うことによりすべての実験 において NCC が約 0.2 向上したことが分かる. 図 3 に合成デ ータに対する剛体変換モデルの結果画像を示す. 最適化なし では, ある程度の位置合わせができているものの, コロナル断 面の傾きや, サジタル断面の奥行の再現が不十分である. 対し て, 最適化ありでは, 正解画像をほぼ正確に再現できているこ とが画像から分かる. よって, Instance-specific optimization によ る最終的な微調節が本手法において有用であることが分かる.

合成データに比べ, 実データの NCC が低い理由は 2 つ考え られる.1 つ目は撮影条件の違いによる画像の濃淡値の違いを 補正せずに NCC を得たためである.そのため, 画像の濃淡に 影響されない評価方法または, 画像の前処理の必要がある.2 つ目は、線形変換では再現できない変形が存在するためであ

表1 実験結果(A: 合成データ B: 実データ)

	NCC					
	最適任	となし	最適化あり			
	А	В	А	В		
アフィン変換	0.756	0.730	0.981	0.928		
剛体変換	0.843	0.818	0.990	0.909		



図3 結果画像の例

る.しかし,差分画像による脳の萎縮部の検出を目的としてい るため,手法はそのままで,経時的差分画像による脳領域の変 化量の妥当性を評価できるように改良する必要がある.

#### 4. まとめ

本論文では線形 3D 位置合わせモデルと Instance-specific optimization による脳 MR 画像の3次元位置合わせ手法を提案 した. 合成データ,実データへの評価を行い,最適化による精 度向上が見られた. 今後は,頭蓋骨のみでの位置合わせや,評 価手法の改良を行い,脳萎縮部の検出に有用な位置合わせ手 法を検討していく予定である.

### 謝辞

本論文で用いた MR 画像は, ADNI データベース (adni.loni.usc.edu)から入手した.

#### 利益相反の有無

なし

- Alzheimer's Disease International: World Alzheimer Report 2021: Journey Through the Diagnosis of Dementia. London: Alzheimer's Disease International, 2021
- [2] Fonseca A.C.R.G. et al.: Cholesterol and statins in Alzheimer's disease: Current controversies, Exp. Neurol, Vol.223, pp.282-293, 2010
- [3] Okonkwo O.C. et al.: Cerebral atrophy, apolipoprotein e 64, and rate of decline in everyday function among patients with amnestic mild cognitive impairment, Alzheimers Dement, Vol.6, pp.404-411, 2010
- [4] Frisoni G.B. et al.: The clinical use of structural MRI in Alzheimer disease, Nat. Rev. Neurol, Nat. Rev. Neurol, Vol.6, pp.67-77, 2009
- [5] Stergios C. et al.: Linear and deformable image registration with 3D convolutional neural networks, Springer, Cham, Vol. 11040, 2018
- [6] Balakrishnan G. et al.: VoxelMorph: A learning framework for deformable medical image registration, IEEE Transactions on Medical Imaging, Vol.38, No.8 pp.1788-1800, 2019
- [7] www.adni-info.org

## MRI FLAIR 画像を用いた異常検知による脳梗塞再発予測の検討

渡辺 翔吾\*1, 連 乃駿\*1, 盛田 健人\*2, 中奥 由里子\*1,

尾形 宗士郎\*1, 小橋 昌司\*3, 飯原 弘二\*1

\*1 国立循環器病研究センター, \*2 三重大学, \*3 兵庫県立大学

# A feasibility study of Ischemic Stroke Recurrent Prediction based on Anomaly Detection using

## **MRI FLAIR Images**

Shogo Watanabe<sup>\*1</sup>, Nice Ren<sup>\*1</sup>, Kento Morita<sup>\*2</sup>, Yuriko Nakaoku<sup>\*1</sup>,

Soshiro Ogata<sup>\*1</sup>, Syoji Kobashi<sup>\*3</sup>, Koji Iihara<sup>\*1</sup>

<sup>\*1</sup> National Cerebral and Cardiovascular Center <sup>\*2</sup> Mie University, <sup>\*3</sup> University Hyogo

要旨:初回脳梗塞発症後の再発は患者の QOL に深く関わる.そこで,再発予防に向けた適切な介入を行うために再発予測が重要 となる.本研究では,MRI FLAIR 画像を用いた脳梗塞の再発予測を検討した.再発予測の対象には,2013 年~2019 年に脳梗塞で 国立循環器病研究センターに入院した患者のうち FLAIR 画像データが取得できた 386 名 (うち再発 40 名)を用いた.1 年以内の再 発率は 10%程度と低いため,本研究では深層学習モデルを用いた異常検知アルゴリズム Semantic Pyramid Anomaly Detection (SPADE) を採用し,畳み込みニューラルネットワーク(CNN)による教師あり学習と比較した.その結果,5-fold 交差検証における平均 ROC AUC は CNN, SPADE でそれぞれ 0.56,0.68 となった.よって1年以内の脳梗塞再発予測における異常検知の有効性が示唆された. キーワード:脳梗塞,再発予測,異常検知,MRI, FLAIR

### 1. はじめに

脳血管疾患は死亡原因の第3位である.そのうち脳梗塞は半 数以上を占めており,初回脳梗塞発症後の再発は患者のQOL に深く関わる.そこで,再発予防に向けた患者自身や家族,介 護者に注意喚起を促すために,脳梗塞の再発予測モデル開発が 重要と考えられる.

従来は年齢や性別といった患者の基本情報と喫煙歴や高血 圧の有無などの既往歴を用いた再発リスクスコアが提案され ていた. [1,2] 近年,これら臨床情報を用いた機械学習による 脳梗塞の再発予測モデルの研究がいくつか報告されている. [3] しかしながら,画像データを用いた脳梗塞の再発予測モデ ルの報告[4]はまだ少ないため、本研究では特に FLAIR 画像を 用いた再発予測を検討した.

### 2. 方法

再発予測の対象として,2013~2019年に国立循環器病研究 センターに脳梗塞で予定外入院した患者で,退院後1年以内に 再発して再入院した患者を抽出した.

MRI には複数の撮像法があるが,今回は Covert Brain Infarction (CBI)[5]と脳梗塞との関連性も視野に入れて,FLAIR 画像を使用した.また退院後の再発を予測するため,退院日に より近い画像データを使用した.本研究は,国立循環器病研究 センターの倫理委員会の承認を受けている.

現時点で収集できた画像データは 386 名のうち再発は 40 名 (10.4%)であった.これは海外の先行研究における再発率とも 符合する. [3,4] 脳梗塞の再発率は10%と低く,クラス不均衡問題による教師 あり学習の困難さが懸念されるため,再発した群を異常と定義 した異常検知に基づく再発予測を実施した.

画像ベースの異常検知モデルとして Semantic Pyramid Anomaly Detection (SPADE) [6] を採用した. SPADE は事前学習 済みの画像認識モデルを特徴抽出器として使用し, 画像単位の 異常度だけでなく, 中間層も使用することで画素単位での異常 度も求めることが可能である.

SPADE による再発予測モデル構築までの一連の流れを図 1 に示す.非再発例のみを訓練データとして使用する.FLAIR 画 像から脳実質だけを抽出する前処理を行った後,事前学習済み モデルで特徴ベクトルに変換した非再発群を保存しておく.本 研究では特徴抽出器として,白質高信号領域のセグメンテーシ ョンと退院時の modified Rankin Scale の分類で事前学習した 3D Y-Net[7] を使用した.

推論時は、テストデータに同様の処理で特徴ベクトルに変換後、訓練データの k 近傍のデータ点とのユークリッド距離の平均を計算し、異常度とする.

教師あり学習は, 畳み込みニューラルネットワーク(3DCNN) を使用し, 性能評価はそれぞれ 5-fold 交差検証で行った.

#### 3. 結果

**SPADE** による退院後1年以内の脳梗塞再発予測の ROC 曲線と AUC を図2に示す. 各 fold の ROC 曲線を5 色で, その 平均の ROC 曲線を黒の実線で, 灰色の領域が標準偏差を, そ れぞれ表している. 5-fold の平均 ROC AUC は 0.68 となった.







図2. 異常検知による1年以内の脳梗塞再発予測

表1. 教師あり学習と異常検知の比較

5-fold Cross Validation	3DCNN	SPADE
Avg. ROC AUC±Stddev.	0.56±0.03	0.68±0.01

表1に,教師あり学習 3DCNN と異常検知 SPADE の,それ ぞれの 5-fold における平均 ROC AUC を示す. 異常検知の方 が,通常の教師あり学習よりも高い精度が得られた.

図3に画素単位での異常度を可視化したものを示す.上段 が非再発例,下段が再発例,左側が入力画像,右側が異常度 マップとなっている.非再発例では全体的な異常度が低く, 再発例では脳内の白質病変周辺の異常度が高くなっている.

### 4. まとめ

本研究では、MRI FLAIR 画像を用いた異常検知による1年 以内の脳梗塞再発予測の実現可能性を検討した. 今後は DWI や MRA などでも再発予測モデルの検討を行う.



図3. 画像上の異常度の可視化

### 謝辞

画像データの抽出を行って頂いた国立循環器病研究センター情報統括部に深謝致します.本研究は AMED 研究費 22ek0210147h0003 の助成をうけたものです.

#### 利益相反の有無

なし.

- [1] Kerman N. W, Viscoli M. C, Brass M. L et al: The Stroke Prognosis Instrument II (SPI-II) A Clinical Prediction Instrument for Patients With Transient Ischemia and Nondisabling Ischemic Stroke. Stroke 31(2): 456-462, 2000.
- [2] Weimar C, Diener HC, Alberts J. M et al: The Essen Stroke Risk Score Predicts Recurrent Cardiovascular Events: A Validation Within the REduction of Atherothrombosis for Continued Health (REACH) Registry. Stroke 40(2): 350-354, 2009.
- [3] Abedi V, Avula V, Chaudhary D et al: Prediction of Long-Term Stroke Recurrence Using Machine Learning Models. J Clin Med 10(6): 1286, 2021.
- [4] Wang H, Sun Y, Zhu J et al: Diffusion-weighted imaging-based radiomics for predicting 1-year ischemic stroke recurrence. fneur: 13, 2022.
- [5] Thomas Raphael M, Johannes K, Laurent R et al: Covert Brain Infarction Towards: Precision Medicine in Research, Diagnosis, and Therapy for a Silent Pandemic. Stroke 51(8): 2597-2606, 2020.
- [6] Cohen N, Hoshen Y: Sub-Image Anomaly Detection with Deep Pyramid Correspondences. arXiv preprint arXiv:2005.02357.
- [7] Nishi H, Oishi Naoya, Ishii A et al: Deep Learning–Derived High-Level Neuroimaging Features Predict Clinical Outcomes for Large Vessel Occlusion. Stroke 51(5): 1484-1492, 2020.

## 神経メラニン画像を利用した黒質緻密部分類に関する初期的検討

伊東 隼人\*1,小田 昌宏\*2,1,斉木 臣二\*3,鎌形 康司\*4,石川 景一\*4,佐光 亘\*4,

服部 信考<sup>\*4</sup>,青木 茂樹<sup>\*4</sup>,森 健策<sup>\*1,2,5,6</sup>

\*1 名古屋大学 大学院情報学研究科

\*2 名古屋大学 情報連携推進本部

\*3 筑波大学 医学医療系

\*4 順天堂大学 医学部

\*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

Preliminary Study of Classification of Substantia Nigra Pars Compacta using Neuromelanin Images

Hayato Itoh<sup>\*1</sup>, Masahiro Oda<sup>\*2,1</sup>, Shinji Saiki<sup>\*3</sup>, Koji Kamagata<sup>\*4</sup>, Kei-ichi Ishikawa<sup>\*4</sup>, Wataru Sako<sup>\*4</sup>,

Nobutaka Hattori<sup>\*4</sup>, Shigeki Aoki<sup>\*4</sup>, Kensaku Mori<sup>\*1,2,5,6</sup>

<sup>\*1</sup> Graduate School of Informatics, Nagoya University

<sup>\*2</sup> Information and Communications, Nagoya University

\*3 Institute of Medicine, University of Tsukuba

<sup>\*4</sup> School of Medicine, Juntendo University

<sup>\*5</sup> Information Technology Center, Nagoya University

<sup>\*6</sup> Research Center for Medical Bigdata, National Institute of Informatics

**要旨**:この高齢化社会において世界で2番目に多い進行性神経変性疾患がパーキンソン病である.パーキンソン病は、高齢になる ほど発病率が高いが、進行を抑制する根本的な治療法は存在しない.しかし、早期の発見と治療開始により進行を遅らせることが 可能である.最近では、神経性疾患発見における神経メラニンイメージングの有効性が報告されている.パーキンソン病の特徴は 黒質緻密部におけるドーパミン作動性ニューロンの進行性喪失である.神経メラニンは黒質緻密部のドーパミン作動性神経細胞に 存在する.そのため、神経メラニンイメージングで得られた黒質緻密部に関する信号分布(神経メラニン画像)により、パーキン ソン病の発見が可能であるとの報告がなされている.本発表ではパーキンソン病・非パーキンソン病の2クラスにし、神経メラニ ン画像を用いた黒質緻密部分類の初期的検討について報告する.

キーワード:パーキンソン病,黒質緻密部,神経メラニン画像,テンソル表現,特徴選択

### 1. はじめに

人体における3次元構造の抽出・解析は医用画像処理におけ る本質的な課題である.例えば、パーキンソン病の診断では脳 の MRI データにおける黒質緻密部の左右非対称性や収縮に関 する観察が重要である.そこで黒質緻密部の精確な可視化に向 けた神経メラニン画像が提案されている.さらに機械学習モ デルを用いた黒質緻密部の自動抽出[1]やテンソル解析による 特徴解析[2]も報告されている.

本稿では神経メラニン画像における黒質緻密部の信号分布 を利用した,パーキンソン病・非パーキンソン病の2クラス分 類に関する初期検討について報告する.3次元パターンをテン ソル表現することにより3次元パターンにおける形状とテク スチャの両方を考慮した特徴抽出が可能である[3].訓練・評 価データセットより抽出した特徴量の識別精度を評価し,さら に特徴選択に関する検討を行う.

#### 2. テンソル分解に基づいた特徴表現

N人の神経メラニン MRI から黒質緻密部のみを抽出した信 号強度比を表す神経メラニン強調画像を 3 階のテンソル $X_i \in \mathbb{R}^{I \times J \times K}$ , i = 1, 2, ..., Nで表す. ここで $N_1 \ge N_2$ はそれぞれ非パー キンソン病者とパーキンソン病患者の黒質緻密部の数を表す ものとし,  $N = N_1 + N_2$ とする. さらに 3 階のテンソルに画像 のインデックス *i* を表すモードを 1 つ追加することで 4 階の テンソル $T \in \mathbb{R}^{I \times J \times K \times N}$ とする.  $a_j \in \mathbb{R}^I$ ,  $b_j \in \mathbb{R}^J$ ,  $c_j \in \mathbb{R}^K$ ,  $d_j \in \mathbb{R}^N$ から成る rank-1 テンソルをM個用いた CP 分解[4]は

$$\mathcal{T} = \sum_{j=1}^{M} \boldsymbol{a}_{j} \circ \boldsymbol{b}_{j} \circ \boldsymbol{c}_{j} \circ \boldsymbol{d}_{j} + \mathcal{E}$$
(1)

である. *E*と•はそれぞれ再構成残差と直積を表す.テンソルの ランク計算は一般に NP 困難であり, *M* は実験的に求める. 式(1)は $d_i = (d_{ii})$ ならびに再構成残差 $\mathcal{E}_i$ を用いて

$$\mathcal{X}_{i} = \sum_{j=1}^{M} d_{ji} (\boldsymbol{a}_{j} \circ \boldsymbol{b}_{j} \circ \boldsymbol{c}_{j}) + \mathcal{E}_{i}$$
<sup>(2)</sup>

と書ける.式(2)の $d_{ji}$ , j = 1, 2, ..., Mを並べることで $X_i$ を表すM次元特徴量ベクトルを得る.評価データの特徴抽出では訓練 データより得られた $a_j$ , $b_j$ , $c_j$ を用いてテンソル分解を行う.た だし、特徴量ベクトルの要素全てが識別に寄与するとは限ら ないため、パーキンソン病のパターンのみを表す固有ベクトル が張る低次元部分空間へと写すことで特徴選択を行う[5].

### 3. 数値計算実験

単施設にて収集した 266 症例分の神経メラニン画像を用いた.表1はデータの内訳を示す.黒質緻密部の抽出においては,神経放射線学を専門として10年の経験を持つ熟練放射線医1 名が行ったアノテーションラベルを用いた.各3次元ボリュームデータに対し,黒質緻密は信号値が[0,1]となるように正規 化を行い,黒質緻密部以外の値を0とした.訓練データより線 形判別の重みを求め,評価データにおけるパーキンソン病患 者・非パーキンソン病者を正しく識別できた割合をそれぞれ感 度・特異度として求めた.この際,ハイパーパラメータ Mおよ び低次元部分空間を張る固有ベクトルの数を変えて実験した. 図1が特徴選択前の評価データに対する識別精度を示す.図2 が M=64 に対する,特徴選択において15本の固有ベクトルを 選択した場合の訓練・評価データに対する識別精度を示す.

#### 4. 考察

図1では感度・特異度がどちらも約0.60程度であり, Mの 値を大きくするだけでは識別的な特徴量が得られないことを 示す.図2では訓練・評価データのどちらにおいても感度・特 異度の両方が0.70程度であり, 汎化性能の向上に寄与する特 徴が選択されていることを示す.しかし,専門医による診断精 度には及ばず,特徴表現に関する改良が必要である.

#### 5. まとめ

本稿では神経メラニン画像における黒質緻密部の 3 次元パ ターンを用いたパーキンソン病識別に関する初期的検討を行 った. 今後は低ランク分解が可能な空間に写した上での識別的 特徴の選択について検討を行う.

表1 実験に用いたデータセットの内訳

	# Non-PD	# PD	# ALL
訓練	73	82	155
評価	66	45	111



### 謝辞

本研究は JSPS KAKENHI (No. JP21K19898, No. JP23K16900) な らびに AMED (No. JP19dm0307101)の支援を受けた.

文 献

### 利益相反の有無

なし

- [1] Berre AL, Kamagata K, Otsuka Y, *et al.*: Convolutional neural network-based segmentation can help in assessing the substantia nigra in neuromelanin MRI. Neuroradiology 61: 1387–1395, 2019
- [2] Itoh H, Hu T, Oda M, et al.: Pattern Analysis of Substantia Nigra in Parkinson Disease by Fifth-Order Tensor Decomposition and Multi-sequence MRI. Proc. MMMI2022 LNCS 13594: 63–75, 2022
- [3] Itoh H, Imiya A, Sakai T: Pattern recognition in multilinear space and its applications: mathematics, computational algorithms and numerical validations. Machine Vision and Applications 27: 1259–1273, 2016
- [4] Kolda TG and Bader BW: Tensor decompositions and application. SIAM Review 51(3): 455-500, 2009
- [5] Fukunaga K and Koontz WLG: Application of the Karhunen-Lo'eve Expansion to Feature Selection and Ordering. IEEE Trans. Computers C-19: 311–318, 1970

## 定量的磁化率マップ QSM のヒト頭部オブリーク撮像: 皮質脊髄路の QSM 値の分析

高橋哲彦\*1,星野美紗子\*2,小島陸\*3,駒萌乃\*1,丁嵐亮\*1

- \*1 群馬県立県民健康科学大学
- \*2 群馬県立県民健康科学大学(現 上尾中央総合病院)
- \*3 群馬県立県民健康科学大学(現美原記念病院)

### Quantitative Susceptibility map of the human head oblique imaging: analysis of QSM values of the corticospinal tract

Tetsuhiko TAKAHASHI<sup>\*1</sup>, Misako HOSHINO<sup>\*2</sup>, Riku KOJIMA<sup>\*3</sup>, Moeno KOMA<sup>\*1</sup>, Ryo ATARASHI<sup>\*1</sup>

- <sup>\*1</sup> Gunma Prefectural Collage of Health Sciences
- <sup>\*2</sup> Gunma Prefectural Collage of Health Sciences (current address: Ageo Central General Hospital)
- <sup>\*2</sup> Gunma Prefectural Collage of Health Sciences (current address: Mihara Memorial Hospital)

要旨:定量的磁化率マップ QSM は,磁化率変化を画像化でき神経変性疾患の診断の応用が期待されている.早期のアルツハイマー病において,QSM 値は白質と灰白質の広い範囲で変化する.実臨床で多施設の QSM 値を比較するには,高い再現性と安定性が望まれる.被験者の体位を一定にすることは困難であるが,体位の変化と QSM 値に関する研究はなかった.本研究では,体位を変えた時の QSM 値を測定し,統計解析を行い解析した.対象は健常者 7 名,使用した MRI 装置は Ingenia 1.5 T,撮像体位は,正常軸断, 頭頂上げオブリーク,顎上げオブリークの3体位とした.画像解析ソフトウエアは LiLiby QSM と ImageJ を使用した.解析部位は 大脳基底核の尾状核・被殻・淡蒼球外節・淡蒼球内節と白質の皮質脊髄路とした.体位と QSM 値について、有意水準<0.05 で分散分析と多重比較法のt検定を行った結果,大脳基底核ではほぼ有意差が認められず,皮質脊髄路では有意差が認められたが差は小さく概ね安定とわかった.

キーワード: MRI, 定量的磁化率マップ, 脳, 白質

#### 1. はじめに

定量的磁化率マップ(quantitative susceptibility map)QSM は, 脳出血と石灰化を識別や,脳の磁化率を画像化でき,神経変性 疾患の診断に応用が期待されている.また,早期のアルツハイ マー病においては,QSM 値は白質と灰白質の広い範囲で変化 するとされている.

実臨床で多施設の QSM 値を比較するには、高い再現性と安 定性が望まれる. QSM では、静磁場の向きと被検体の向きに よって結果が異なることが懸念された. 実際の MRI 検査にお いて、被験者の体位を一定にすることは困難であるが、これま で、体位と QSM 値に関する報告はなかった.

本研究では、体位を変えた時の QSM 値を測定し統計解析を 行い、QSM 値の体位に対する安定性を調べた.

### 2. 方法

対象は健常者 7 名(平均年齢 22.1 歳 ± 0.8 歳) であった. 使用した MRI 装置は Ingenia 1.5 T (Philips 社製) であった. 撮 像体位は、枕の位置を変えた3体位(頭頂上げ,通常,頸部上 げ)とした.撮像面は、同じ撮像面になるように、頭部の向き に従って軸方向から斜め方向(おおよそ-13度~+15度)に変 更した.つまり、撮像面は脳構造に対して同じであったが、撮 像面と静磁場方向との間のオブリーク角度は変化した.(図1)

撮像シーケンスは、3 次元 (3D) gradient echo (GRE) シーケ ンスであった. QSM 画像は、3D GRE シーケンスで得た複素 MRI 画像から演算で求めた (図 2). 演算は、位相画像から全 体的な位相オフセットを除去する background field removal によ って局所位相マップ (local phase map) を得るステップと、局 所位相マップを逆演算して磁化率マップ (QSM) を得るステッ プからなった.本研究では QSM は専用ソフトウエア、LiLiby QSM (富士フイルムヘルスケア社)を用いた.このソフトウエ アの演算は、least squares estimation with adaptive edge-preserving filtering (LSE with AEFP) 法であった.この方法は、regularization を用いずに edge preserving filter を用いることで元画像の微細 構造を保持する特徴がある [1]. 画質評価は、image J を用いた. QSM 値が頭部体位によって変化するか否かの確認は, region of interest: ROI を尾状核, 被殻, 淡蒼球(内節・外節)と白質に選択し, それぞれの QSM 値を調べた. 白質の ROI は, 神経繊維 方向が比較的均質な皮質脊髄路を放射冠レベルの断面にて, 左 右半球でそれぞれ選んだ.

統計解析ソフトには R を使った.統計解析では,QSM 値が 体位に関係するかどうかについて,Shapiro-Wilk 検定にて正規 性を確認後,反復測定による分散分析または多重比較法の Wilcoxon 検定を行った.更に有意差があった部位について,ど の体位間に差があるかを確認するために多重比較法(Shaffer 法 の調整による対応のある t 検定)を有意水準は 0.05 として行 った.

本研究は、本学の倫理委員会と共同研究施設の倫理委員会で 承認済である.



図1 頭部の向きを変えた QSM の安定性の実験



図2 QSM アルゴリズムの概略説明図

### 3. 結果と考察

MRI 画像と QSM および ROI の例を図 3 に示す. ROI は, 1 名の研究者が QSM と MRI 上で用手的に決めた. 部位ごとの QSM 値と統計解析の結果を図4にまとめた. 大脳基底核では, 被殻は分散分析で有意差が認められず,その他の 3 部位(尾状 核,被殻,淡蒼球外節)では p<0.05 で体位による有意差が認 められた. 差が認められた 3 部位でどの体位間で差があったか 多重比較法を行ったが,体位間の有意差は認められなかった. 皮質脊髄路の QSM 値について反復測定による分散分析を行ったところ,有意差が認められた.どの体位に差があるか多重 比較法を行ったところ,頭頂上げオブリークが,正常軸断およ び顎上げオブリークとくらべ有意差を認めた.QSM 値の体位 間の差は約 5ppb 以内であった.



図3 各部位の QSM 値と統計解析結果

#### 3. まとめ

体位を変えた時の QSM 値を測定し統計解析を行い, QSM 値 の体位に対する安定性を調べた結果,体位と QSM 値の有意差 は大脳基底核ではほぼ認められず皮質脊髄路では有意差が認 められたが差は小さく概ね安定とわかった.

#### 謝辞

本研究を行うにあたり有益な助言をいただいた,尾藤良孝氏, 岩田吉広氏,仲山貴行氏(富士フイルムヘルスケア社)に感謝 します.本研究の一部は「あさを賞」の助成を受けている.

#### 利益相反の有無

なし.

#### 文 献

 Shirai T, Sato R, Taniguchi Y et al: Quantitative Susceptibility Mapping Using Adaptive Edge-Preserving Filtering, Proc. Int. Soc. Magn. Reson. Med, 23: 3319, 2015

### MobileNetV2 の Fine tuning を用いた Neuromelanin 画像からの Parkinson 病進行度の推定

奥田 健太<sup>\*1</sup>, 髙橋 洋人<sup>\*1</sup>, 三浦 あづさ<sup>\*1</sup>, 崎須賀 敬央<sup>\*1</sup>, 綿谷 朋大<sup>\*1</sup>, 松尾 千聡<sup>\*1</sup>, 有澤 亜津 子<sup>\*1</sup>, 富山 美幸<sup>\*2</sup>, 佐藤 淳哉<sup>\*2</sup>, 喜多 洸介<sup>\*2</sup>, 鈴木 裕紀<sup>\*2</sup>, 木戸 尚治<sup>\*2</sup>, 梶山 裕太<sup>\*3</sup>, 小河 浩太 郎<sup>\*3</sup>, 望月 秀樹<sup>\*3</sup>, 富山 憲幸<sup>\*1</sup>

\*1大阪大学医学系研究科 放射線統合医学講座 放射線医学教室

\*2大阪大学医学系研究科 人工知能画像診断学共同研究講座

\*3大阪大学医学系研究科 神経内科学講座

## Estimation of Parkinson's disease progression based on Neuromelanin images using Fine tuning in MobileNetV2

Kenta OKUDA<sup>\*1</sup>, Hiroto TAKAHASHI<sup>\*1</sup>, Azusa MIURA<sup>\*1</sup>, Takahisa SAKISUKA<sup>\*1</sup>, Tomohiro WATAYA<sup>\*1</sup>, Chisato MATSUO<sup>\*1</sup>, Atsuko ARISAWA<sup>\*1</sup>, Miyuki TOMIYAMA<sup>\*2</sup>, Junya SATO<sup>\*2</sup>, Kosuke KITA<sup>\*2</sup>, Yuki SUZUKI<sup>\*2</sup>, Shoji KIDO<sup>\*2</sup>, Yuta KAJIYAMA<sup>\*3</sup>, Kotaro OGAWA<sup>\*3</sup>, Hideki MOCHIZUKI<sup>\*3</sup>, Noriyuki TOMIYAMA<sup>\*1</sup>

\*1 Department of Diagnostic and Interventional Radiology, Osaka University Graduate School of Medicine
 \*2 Department of Artificial Intelligence Diagnostic Radiology, Osaka University Graduate School of Medicine
 \*3 Department of Neurology, Osaka University Graduate School of Medicine

要旨:【背景・目的】Parkinson 病(PD) は筋強剛や振戦等の運動症状を呈する慢性進行性の神経変性疾患である. PD の評価と診断 は、本態である中脳黒質線状体の黒質緻密部におけるドパミン産生ニューロンの減少を捉える画像検査法がなく、主に臨床症状等 に基づいて行われてきた.近年、このドパミン産生ニューロンが含む Neuromelanin の量を捉えることができる新しい磁気共鳴画像 (Neuromelanin 画像) が報告され、PD の診断に寄与することが期待されている.本研究は、機械学習による Neuromelanin 画像の評 価が有用であることを示すことを目的として行った.【方法】HY1 度から 2 度の早期 PD 症例 87 例,HY3 度から 5 度の進行期 PD 症例 94 例を対象とした.これらの症例の Neuromelanin 画像に対し特徴を強調するような画像処理を行なったものを,ImageNet で 事前訓練した MobileNetV2 に Fine tuning で学習させ、早期と進行期のどちらであるか推定させた.【結果】Accuracy 61.0%,AUC 0.645 を得た.【結語】機械学習による Neuromelanin 画像の評価が有用であることが示された. キーワード: Parkinson 病,MRI, Neuromelanin 画像,人工知能,画像解析

### 1. 背景·目的

Parkinson 病 (PD) は筋強剛や振戦等の運動症状を呈する慢 性進行性の神経変性疾患である [1]. PD の診断基準には 2015 年の International Parkinson and Movement Disorder Society が広 く用いられているが,画像検査所見は PD を直接支持する所見 が得られないことから診断基準として含まれていない. 2006 年, Sasaki らが中脳の黒質緻密部 (substantia nigra pars compacta: SNpc)に存在するドパミン産生ニューロンが含む Neuromelanin を描出する MR 画像 (Neuromelanin 画像)を報告した [2]. Neuromalanin 画像は, 3T MRI で得られる高解像度ファストス ピンエコー (FSE) T1 強調画像であり,高い SN 比,高い空間 分解能,高磁場での T1 延長による周辺脳組織の信号抑制の相 乗効果により Neuromalanin を高信号域として描出することが できる. Neuromelanin 画像は,神経変性疾患や精神疾患,その 進行で生じる SNpc のドパミン産生ニューロンの減少をその高 信号域の減少としてとらえ、病理学的変化を明らかにするとさ れる [3]. Takahashi らは, Neuromelanin 画像が進行期 PD と早 期 PD の分類にも有用であることを示した [3]. 本研究では, PD の進行度推定に Neuromelanin 画像の機械学習による分類の 有用性の検証を目的として, MobileNetV2 の Fine tuning による Neuromalnin 画像の学習と分類を行った.

### 2. 方法

### 2.1. 症例の抽出方法

2018 年 7 月から 2021 年 8 月にかけて大阪大学医学部付属病 院を受診した Parkinsonism を呈する患者 300 名を対象に頭部 MR 画像(Neuromelanin 画像)を撮影した. うち 204 名が PD と診断され, 181 名に対して Hoen-Yahr (HY) 分類を行い,早 期例(HY: 1, 2 度)が 87 名,進行例(HY: 3-5 度)が 94 名であ った.症例の抽出方法とプロファイルを示す(Fig 1, Table 1).



?%:@ 遮例の抽出方法

Q"=.+@@& TO"S# が評価された症例 \*@@1のプロファイル

!" :	分類	\$度	%度	&度	'度	(度	計
性別	男性	)	'*	%+	\$%	)	,(
	女性	*	%(	%%	\$,	\$&	)-
年齢# 歳/0	'+ ∼(,	(	%&	,	,	%	&)
	_+~*,	*	'&	&\$	\$)	\$\$	\$\$+
	)+~,,	&	-	*	,	)	&&
服薬状況	122	)	&%	\$-	%+	\$-	,%
	13	*	'+	%-	\$\$	(	),
11 P	ł	\$(	*%	'%	&\$	%\$	\$)\$

0+歳~&,歳の患者と\$++歳以上の患者は+名であった.

### "#"#%&'検査の撮影条件

\*+,#(-+."&%&画像は ?ORTQ I強調画像、52 チャンネルのヘッ ドアレイ受信コイルを備えた 5Q システム ()%'B(N+#C@<J46F ZR ヘルスケア社製)を用い、設定値 (QJ[QRW@F]1FE87 \@.%B+@ ;S%B\$&-W@8@--\@AW@F\@"P.+" \@";#%JV@D×26D@> W@F ×13F@--) によって取得した. @ @

#### "#(#!画像の前処理

\*+,#(-+."&%& 画像をニューラルネットワークに入力するための前処理を実施した(?%:@2 処理の内容を変えることで \*+,#(-+."&%&画像 2F スライスから6 種類の入力画像を得た. 以降,この6 ケースそれぞれに対してニューラルネットワーク の学習と予測を行った.

#### "#)#ニューラルネットワーク

ニューラルネットワークには < (=%.\*+;>2 に Z.(=".@AN+#":+@ !((.%&: (ZA!) 層と?,..CTB(&&+B;+MI) 層を追加したもの を採用した. <(=%.+\*+;>2 は 9-":+\*+; で事前学習させ, < (=%.+\*+;>2 ZA! 層, ?I 層を前処理後の \*+,#(-+."&%&画像

(228\_228\_5) に ",:-+&;";%(& を実施したもので ?%&+@;,&%&: た. 出力は早期例と進行例の 2 クラスとした (?%:@5

#### %/結果

中脳のみを表示した Neuromelanin 画像を用いたケース2で Accuracy 61.0%, AUC 0.645の最大性能を得た(Table 2).





Table 2. 学習・分類の結果\*

ケース No	1	2	3	4	5
Accuracy [%]	53.0	61.0	58.0	50.7	52.7
AUC [-]	.528	.645	.629	.558	.481

\*いずれも3回の学習の平均値を記載している

### &'結語

Neuromalanin 画像を MobileNetV2 の Fine tuning で学 習・分類することで最大性能として Accuracy 61.0%, AUC 0.645 を達成し, PD の進行度推定に Neuromelanin 画像の機 械学習による分類が有効であることを示した.本研究の限界は, 症例数が機械学習への入力としては小さい点,服薬状況として ON と OFF が混在している点である.

#### 利益相反の有無

筆頭演者が大阪大学大学院医学系研究科脳機能診断再建学 共同研究講座(日本光電工業株式会社,株式会社リコー,株式 会社村田製作所と共同研究)に所属している.

### 文 献

%"&ペーキンソン病診療ガイドライン 2018

 $\% \& '()^*) +, -'.) + /0 / '10') 23' 45167 / 812) 9, 9'8) : 910, ;'71* / 9) 9; 1', 8) :, 9: ! / <'2 / ; 6*'; 176216*'$ 

''')9='\*6>\*0)90,)'9,:7)',9'?)7+,9\*/9@\*'=,\*1)\*13A'5167/71B/70'C/23'"D-""'E#FFGHL'3#"J ''' =/,I"F3"FMDNF"30973FFFF##DMLP3LPM#D3)D

- ''' V/B)8,917:,;'5167/,8):,9:3A'XYZ3'X817,;)9'[/679)2'/<'7/190:19/2/:U'C/23'#"\$-"' E#F"MHI"'**&\$**GL3'=/,I"F3##"PNXYZ3"L3#FGJJ

## ラベル平滑化を用いた腹腔鏡映像からの手術箇所の認識に関する検討

林 雄一郎\*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

### A study on surgical area recognition from laparoscopic videos using label smoothing

Yuichiro HAYASHI\*1, Kazunari MISAWA\*2, Kensaku MORI\*2

<sup>\*1</sup> Graduate School of Informatics, Nagoya University

\*2 Department of Gastroenterological Surgery, Aichi Cancer Center Hospital

<sup>\*3</sup> Research Center for Medical Bigdata, National Institute of Informatics

要旨:本稿では、ラベル平滑化を用いた腹腔鏡映像からの手術箇所認識に関する検討について述べる.近年、手術支援のために腹 腔鏡映像を解析する研究が行われている.腹腔鏡下胃切除術では、胃周囲の血管を順番に切離するため、腹腔鏡映像から処理を行 っている血管を認識することができれば手術支援に応用できると考えられる.そこで、腹腔鏡映像から手術を行っている解剖学的 な領域を認識する手法を検討してきた.この手法では、畳み込みニューラルネットワーク(CNN)を用い手術箇所の認識を行う. また CNN の学習の際には、時系列情報を考慮したラベル平滑化により正解ラベルを平滑化して用いる.本稿では、ラベル平滑化の 効果を検討するため、平滑化の程度を変化させた時の認識精度を調査する.腹腔鏡下胃切除術の腹腔鏡映像に対してラベル平滑化 を用いた手術箇所の認識手法を適用したところ、ラベル平滑化が有効であることを確認した.また、一般的なラベル平滑化と時系 列情報を考慮したラベル平滑化を比較したところ、時系列情報を考慮したラベル平滑化では平滑化の程度を適切に設定することで、 手術箇所の認識精度が向上することを確認した.

キーワード:コンピュータ支援外科,手術ナビゲーション,深層学習,腹腔鏡下手術,胃

### 1. はじめに

腹腔鏡下手術は,腹壁に開けた小さな穴から腹腔鏡や手術器 具を腹腔内に挿入し,腹腔鏡から得られる映像をモニタで観察 しながら手術器具を操作して行う手術である.この手術は、従 来の開腹手術と比較して低侵襲であるため、様々な臓器の手術 で行われるようになってきた [1]. 一方,外科医にとっては高 度な技術を必要とする難易度の高い手術である. そこで, 術前 の CT 画像を利用した手術ナビゲーションシステムや、手術映 像中の解剖学的構造を抽出して提示する手術支援システムの 研究が行われている [2-5]. 我々も胃がんに対する腹腔鏡下胃 切除術を対象として,腹腔鏡映像解析に基づく手術ナビゲーシ ョンシステムの研究を行ってきた [5]. このシステムでは,畳 み込みニューラルネットワーク (Convolutional Neural Network; CNN)を用いて腹腔鏡映像から手術を行っている箇所を認識 し,手術箇所周囲の解剖学的構造を確認できる仮想腹腔鏡画像 を提示する.手術箇所に応じた適切な手術支援画像を提示する ためには,腹腔鏡映像からの手術箇所の認識精度が重要である ため、手術箇所の認識精度の向上に関する検討も行ってきた [6]. ここでは, CNN による腹腔鏡画像の分類手法に,時系 列情報を考慮したラベル平滑化と予測の不確実性を利用した 分類結果の修正手法を導入することで手術箇所の認識精度の 向上を行った.本稿では、一般的なラベル平滑化と時系列情報 を考慮したラベル平滑化において平滑化の程度を変化させた

場合の認識精度の調査を行い、ラベル平滑化を用いた手術箇所 の認識手法に関する検討を行ったので報告する.

#### 2. ラベル平滑化を用いた手術箇所の認識手法

腹腔鏡映像からの手術箇所認識手法では, CNN を用いて腹 腔鏡映像から切り出した腹腔鏡画像を,(1) 左胃大網動静脈付 近のシーン,(2) 右胃大網動静脈付近のシーン,(3) 右胃動脈 付近のシーン,(4) 左胃動静脈付近のシーン,(5) 腹腔全体を 観察しているシーン,(6) トロッカー内部のシーン,(7) 腹腔 鏡が体外に存在しているシーン,の7 つのクラスに分類する.

ラベル平滑化は正解ラベルを, 正解クラスのラベル値が1で その他のクラスのラベル値が0 であるハードなラベルからラ ベル値が0から1の値をもつソフトなラベルに変換して学習 に用いる手法である[7].ここで,腹腔鏡映像中の時刻*i*の画 像を $\mathbf{x}_i$ ,対応する正解ラベルを $\mathbf{y}_i = (\mathbf{y}_{i,1}, \dots, \mathbf{y}_{i,7})$ , ラベル平滑 後のラベルを $\overline{\mathbf{y}}_i = (\overline{\mathbf{y}}_{i,1}, \dots, \overline{\mathbf{y}}_{i,7})$ とする.一般的なラベル平滑化 [7]では,正解のクラスを $c^*$ とすると,平滑化後のラベル値 は

$$\bar{y}_{i,c} = \begin{cases} (1-\alpha), & c = c^* \mathcal{O} \succeq き\\ \alpha/6, & それ以外 \end{cases}$$
(1)

となる.ここで,αは平滑化の程度を決定するハイパーパラメ ータである.

時系列情報を考慮したラベル平滑化 [6] は,時間的に隣り合

うシーンのクラスのラベル値のみを平滑化する.まず,時間的 に連続する同じ正解ラベルを持つ画像を同じシーンと考える. ここで,時刻 i の画像 $x_i$ の正解クラスを a,時間的に隣接する シーンの正解クラスを b とし,それぞれのシーンの中央の時刻 を m と l とすると,画像 $x_i$ の平滑化後のラベル値は,

$$\begin{split} \bar{y}_{i,a} &= (1 - \beta) + \beta \times \Big( 1 - \frac{|i - m|}{|i - m| + |i - l|} \Big), \end{split} \tag{2} \\ \bar{y}_{i,b} &= \beta \times \Big( 1 - \frac{|i - l|}{|i - m| + |i - l|} \Big), \end{aligned} \tag{3}$$

と計算される.ここで、 $\beta$ は平滑化の程度を決定するハイパー パラメータである.

#### 3. 実験と考察

胃がんに対する腹腔鏡下胃切除術の 10 症例の腹腔鏡映像か ら 10 秒ごとに切り出した 10,818 枚の腹腔鏡画像を用いて実験 を行った.腹腔鏡画像の画像サイズは 431×270 画素に縮小し, DenseNet201 [8] を用いて手術箇所の分類を行った.DenseNet の学習時に一般的なラベル平滑化と時系列情報を考慮したラ ベル平滑化を行った.それぞれのラベル平滑化の際に,平滑化 の程度を決定するハイパーパラメータである式(1)の  $\alpha$ と,式 (2)と式(3)の $\beta$ を変化させて分類精度の調査を行った.実験では 腹腔鏡画像を症例ごとに 5 つに分割して 5 分割交差検証を行 った.結果を図 1 に示す.ラベル平滑化を用いない場合の分類 精度は 79.9%であった.一般的なラベル平滑化を用いることで 分類精度は 80.8% ( $\alpha = 0.1$ の時)に向上し,さらに,時系列情 報を考慮したラベル平滑化を用いることで分類精度は 81.4%

( $\beta = 0.2$ の時)となった.また,一般的なラベル平滑化では, 平滑化の程度を決めるハイパーパラメータ $\alpha$ の値を変化させ ても認識精度は大きく変化しない(図 1(a)).一方,時系列情 報を考慮したラベル平滑化では,ハイパーパラメータ $\beta$ の値を 大きくすると認識精度が低下した(図 1(b)).実験結果から, 時系列情報を考慮したラベル平滑化は手術箇所認識の精度向 上に効果があるが,平滑化の程度を適切に設定することが必要 であると考えられる.

### 4. むすび

本稿では、ラベル平滑化を用いた腹腔鏡映像からの手術箇所 の認識に関する検討について述べた.腹腔鏡下胃切除術の腹腔 鏡画像を用いた実験の結果、時系列情報を考慮したラベル平滑 化により手術箇所の認識精度が向上することを確認した.今後 の課題として、より多くのデータを用いた評価、手術箇所認識 手法のさらなる精度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 JST CREST JPMJCR20D5 , JSPS 科研費 JP17H00867によった.

#### 利益相反の有無

なし

- [1] Shiroshita H, Inomata M, Akira Set al: Current Status of Endoscopic Surgery in Japan: The 15th National Survey of Endoscopic Surgery by the Japan Society for Endoscopic Surgery. Asian J Endosc Surg5: 415-426, 2022
- [2] Hayashi Y, Misawa K, Oda M et al: Clinical application of a surgical navigation system based on virtual laparoscopy in laparoscopic gastrectomy for gastric cancer. Int J CARS 11: 827-836, 2016
- [3] Kitaguchi D, Takeshita N, Matsuzaki H et al: Computer -assisted real-time automatic prostat e segmentation during TaTME: a single -center feasibility study. Surg Endosc 79: 88-94, 2020
- [4] Tokuyasu T, Iwashita Y, Matsunobu Y et al: Development of an artificial intelligence system using deep learning to indicate anatomical landmarks during laparoscopic cholecystectomy. Surg Endosc 35: 16511658, 2021
- [5] 林雄一郎, 三澤一成, 森健策:腹腔鏡映像からの手術箇所の認識による手術ナビゲーションの検討.第40回日本医用画像工学会大会予稿 集, pp.489-491, 2021
- [6] Hayashi Y, Misawa K, Mori K: Surgical area recognition from laparoscopic images in laparoscopic gastrectomy for gastric cancer using label smoothing and uncertainty. Proc. SPIE 12466: 1246624, 2023
- [7] Szegedy C, Vanhoucke V, Ioffe Set al: Rethinking the inception architecture for computer vision. Proc. CVPR 2016, 2818-2826, 2016
- [8] Huang G, Liu Z, van der Maaten L et al: Densely connected convolutional networks. Proc. CVPR 2017, 4700-4708, 2017



(b)時系列情報を考慮したラベル平滑化図1 ラベル平滑化のハイパーパラメータと認識精度

### Multi-step Fine-tuning for Tracking Invisible Vein during Laparoscopic Surgery

Xinaki ZHAO<sup>\*1</sup>, Yuichiro HAYASHI<sup>\*1</sup>, Masahiro ODA<sup>\*2, 1</sup>, Takayuki KITASAKA<sup>\*3</sup>,

Kazunari MISAWA<sup>\*4</sup>, Kensaku MORI<sup>\*1, 5, 6</sup>

<sup>\*1</sup> Graduate School of Informatics, Nagoya University

<sup>\*2</sup> Information Strategy Office, Information and Communications, Nagoya University

<sup>\*3</sup> Department of Information Science, Aichi Institute of Technology

\*4 Aichi Cancer Center

<sup>\*5</sup> Information Technology Center, Nagoya University

<sup>\*6</sup> Research Center for Medical Bigdata, National Institute of Informatics

Abstract : This work involves addressing the challenging task of tracking the invisible left gastric vein (LGV) during laparoscopic surgery. Due to the difficulty in obtaining data and annotations for laparoscopic image, we propose an innovative approach to train tracking network for invisible LGV. To begin, the network is initialized with pre-trained weight from an object tracking model that is well-versed in tracking objects in common scenarios. Subsequently, we employ multi-step fine-tuning to transfer the network's tracking capability from non-medical common objects to the intricate task of tracking the invisible LGV. To our knowledge, this is the first instance of utilizing neural networks to tackle this realistic and demanding healthcare problem. Encouragingly, our experimental results demonstrated that our approach could alert surgeons to the approximate location of invisible LGV.

Keyword : laparoscopic surgery, video tracking, transfer learning

### 1. Introduction

Laparoscopic surgery has become a preferred treatment for gastric cancer in recent years because of its minimally invasive nature. The left gastric vein (LGV) is a critical vessel located around the stomach, but it is often hidden in fat tissue, making it invisible and difficult to track during surgery. Accidentally injuring the LGV can lead to significant blood loss and complications [1].

Deep neural networks have shown great potential in medical image processing, however, obtaining a large quantity of labels for invisible LGV is challenging. To overcome this limitation, we propose a novel approach that utilizes transfer learning. Specifically, we initialize the network using a pre-trained object tracking model and apply multistep fine-tuning to transfer the network's tracking capabilities from non-medical common objects to the invisible LGV tracking task. Our work is the first attempt to use neural networks to solve this challenging healthcare problem.

#### 2. Method

Given a video sequence of a laparoscopic procedure and a firstframe annotation of the LGV position, our goal is to anticipate the LGV position in subsequent frames, with the first-frame annotation obtained, for example, from a preoperative CT. As shown in Fig. 1, our approach leverages the STCN network architecture, which is known for its robust tracking capabilities on YouTube-VOS [3] and DAVIS [4] datasets. The detailed network architecture can be found in STCN [2].



**Fig. 1** A schematic overview of multi-step fine-tuning. The network is initialized by weights trained on non-medical common scenes and fine-tuned using the visible LGV dataset and the invisible LGV dataset.

To transfer the strong tracking capabilities of STCN to the invisible LGV tracking problem, we have developed a multi-step fine-tuning approach. Specifically, we initialize the network with the weight obtained from training on the YouTube-VOS and DAVIS datasets and stabilize the encoder and memory module of the network, while only fine-tuning the final decoder. Since the tracking task for invisible LGV is quite different from that of non-medical common scenes, we first tune the network using the visible LGV dataset.



**Fig. 2** Qualitative comparison. In green are the predictions of the network, in red are the locations of the invisible LGV, and in yellow is the intersection of the two. It shows that our method's estimation remains close to the ground truth even after lens movement and surgical forceps manipulation.

#### 3. Experiments and Results

In addition to the two publicly available YouTube-VOS [3] and DAVIS [4] non-medical scene datasets, we used two inhouse medical datasets, a visible LGV dataset and an invisible LGV dataset, for both training and evaluation. The visible LGV dataset contains a total of 18 videos consisting of 1540 frames, all of which were used for training. Meanwhile, the invisible LGV dataset contains 15 videos with 3444 frames, of which 10 videos were used for training, 2 videos for validation and 3 videos for testing.

The experimental results are shown in Table 1 and Fig. 2. We used mean Dice Coefficient (mDice) as the indicator to quantitatively evaluate our experimental results. Y&D means testing using only the weights pre-trained in Youtube-VOS and DAVIS datasets, and fully fine-tuned means fine-tuning the entire network. Due to the domain disparities, direct application of the network trained on non-medical scenes to laparoscopic videos is not tenable. By fine-tuning only, the decoder instead of the whole network, we could significantly improve the generalization ability of the network, as training the whole network would have led to overfitting due to the small amount of training data. In addition, multi-step tuning gave better results than one-step tuning. Our experimental results showed that our approach

Table	1	Quantitative	comparison.
-------	---	--------------	-------------

Network	Training Data	mDice
STCN	Y&D	0.1167
STCN	$Y\&D \rightarrow Invisible LGV$ (Fully Fine-tuned)	0.1516
STCN	$Y\&D \rightarrow Invisible LGV (Decoder Fine-tuned)$	0.2301
STCN	$Y\&D \rightarrow LGV \rightarrow Invisible LGV$ (Decoder Fine-tuned)	0.2523

is effective in tracing invisible LGV and alert the surgeon to the approximate location of invisible vein, thereby improve the quality and safety of laparoscopic surgery.

#### 4. Discussion and Conclusions

This work leverages a neural network trained on non-medical scene datasets to track invisible LGV. Specifically, to overcome the large domain differences between non-medical scenes and laparoscopic surgery videos, we applied a multi-level fine-tuning approach to transfer the tracking capability of the existing network to the task of tracking invisible LGV in laparoscopic surgery.

The experiments showed encouraging results, however, due to the insufficient dataset, the current experiments still have limitations. In particular, the average video length is only 230 frames per clip. Although our method can track invisible LGV in a short period of time, it still needs to be verified in experiment whether our method can achieve stable tracking against videos that are dozens of minutes long in clinical surgeries.

In the future, we plan to extend the length of the videos in our dataset and attempt to achieve long-term tracking of invisible LGVs throughout clinical laparoscopic surgery.

#### Acknowledgement

This work was supported in part by the JSPS KAKENHI 17H00867, in part by the JST CREST Grant Number JPMJCR20D5, and in part by the fellowship of the Nagoya University TMI WISE program from MEXT.

#### **Competing interests**

None

#### Reference

- [1] Yuasa Y, Okitsu H, Goto M et al: Three-dimensional CT for preoperative detection of the left gastric artery and left gastric vein in laparoscopy-assisted distal gastrectomy. Asian journal of endoscopic surgery 9(3):179–185, 2016.
- [2] Cheng HK, Tai YW, Tang CK: Rethinking space-time networks with improved memory coverage for efficient video object segmentation. Advances in Neural Information Processing Systems 34:11781–11794, 2021.
- [3] Xu N, Yang L, Fan Y et al: Youtube-vos: A large-scale video object segmentation benchmark. arXiv preprint arXiv:1809.03327, 2018.
- [4] Perazzi F, Pont-Tuset J, McWilliams B et al: A benchmark dataset and evaluation methodology for video object segmentation. Proceedings of the IEEE conference on computer vision and pattern recognition, 2016, pp724–732.

### U-Net を用いた股関節斜視鏡画像からの股関節唇および大腿骨頭の抽出

川上 申之介\*1, 福田 紀生\*2, 西井 孝\*3, 大竹 義人\*4, 佐藤 嘉伸\*4

\*1 関西女子短期大学医療秘書学科

\*2 脳情報通信融合研究センター

\*3 大阪急性期・総合医療センター整形外科

\*4 奈良先端科学技術大学院大学情報科学領域

### Arthroscope video image segmentation of acetabular labrum and femoral head using U-Net

Shinnosuke KAWAKAMI<sup>\*1</sup>, Norio FUKUDA<sup>\*2</sup>, Takashi NISHII<sup>\*3</sup>, Yoshito OTAKE<sup>\*4</sup>,

and Yoshinobu SATO<sup>\*4</sup> <sup>\*1</sup> Kansai Women's College <sup>\*2</sup> Center for Information and Neural Networks <sup>\*3</sup> Osaka General Medical Center <sup>\*4</sup> Nara Institute of Science and Technology

要旨:股関節唇の低侵襲修復手術においては股関節鏡を挿入し手術が行われるが,挿入口であるポータル位置により得られる視認性が影響をうける.そのため良いポータル位置を視認性から判定するために術中の股関節鏡視野中のランドマークとしての大腿骨頭の映り込み割合と、ターゲットである股関節唇の面積を計算する必要がある.そこで我々は13 症例の股関節斜視鏡による術中動画から切り出した画像(各症例約 10000 枚)から各症例 20 枚を t-SNE により選び出し、作成したマスク画像を正解画像として、テスト用の1 症例を除く他の症例の画像から U-Net により学習させたモデルをつくり、テストデータに対して股関節唇および大腿骨頭を抽出させることとした.股関節唇と大腿骨頭との区別がつきやすい画像については正解マスク画像とほぼ一致してセグメンテーションすることがわかった.学習データを追加させることでモデルを強化すれば、より予測精度を上げることができ、加えて整形外科医による正確なアノテーション情報を付加したうえで正解マスク画像を作成できれば、実用的な股関節唇および大腿骨頭のセグメンテーションができると考え、現在モデルの改良に取り組んでいるので現状をここに報告する.

キーワード: arthroscope, segmentation, U-Net, t-SNE

### 1. はじめに

股関節唇断裂などの修復には低侵襲な股関節鏡視下手術が 行われるが,わずか数センチ四方程度の狭い空間での手術であ り,視認性が手術のしやすさに影響していると考えられる.股 関節鏡はポータルと呼ばれる直径 lcm 程度の穴を股関節周囲 にあけ,そこから股関節鏡を刺入する.そのため得られる視認 性はポータル位置ですでに決定されていると考えられる.現在 我々は最適ポータル位置を推定するため,15 症例の CT 画像か ら作成したサーフェスモデルを用いた仮想股関節鏡による視 認性評価システムを開発中であるが,これらの症例に対応する 実際の手術動画に映った股関節唇およびランドマークとして の大腿骨頭をセグメンテーションし,シミュレータ側で再現す ることで,手術におけるポータル位置を推定し評価できると考 えた.この手法は膝関節では研究が進められているが[1], 股関 節に対してはまだなされておらず新規性があると考え, U-Net を用いて股関節唇および大腿骨頭をセグメンテーションした.

### 2. 画像の選定

13 症例の手術動画の撮影時間は各1時間~2時間程度であ り, 概ね股関節鏡を刺入してから手術を終えるまでが記録され ている.これから0.5秒毎に静止画像を生成すれば1症例約1 万枚前後の画像が得られる. U-Net での学習およびテストのた めの画像を選定するにあたり,修復前の股関節唇および大腿骨 頭が映っている時間帯の画像を選定する必要がある. 症例によ ってその時間帯が異なるため、人間による選定には不向きであ る.t-SNE は特徴が似た画像をクラスタリングすることができ る手法であるのでこれを利用することとし、各症例の画像群に 対して1回目の t-SNE を実施し, キャリブレーションなどに使 われている不要な画像群以外の画像群を選定する. 選定した画 像群に対し2回目の t-SNE により再クラスタリングを行い,得 られた複数のクラスターに対して個別に最終 3 回目の t-SNE を行うことで学習およびテストに必要な画像を抽出すること とした.これにより選定者の主観等を排し再現性のある画像選 定を行えると考えた. 選定した 13 症例の画像に対してアノテ ーションしマスク画像を作成する. 画像のサイズは縦横 320 画素としたため1 枚の画像の全画素数は 102400 画素である.



図1. 術中動画から作成した各症例の股関節鏡の画像の例. 右下の数字は症例番号を示す. 画像の左または右端に一部映 っている光の反射量が多い球状のものが大腿骨頭である.

### 3. 学習方法

13 症例の選定画像および対応するマスク画像セットのうち, 1 つの症例の画像セットをテスト用とし,残りの 12 症例の画 像セットを学習用としてモデルを強化することとした.結果と して 13 症例分のテスト結果が得られる.

#### 4. 結果



図2. 左:股関節鏡の画像(右下の数字は症例番号),中央: 作成したマスク画像,右:予測結果(セグメンテーション) 結果の画像の比較.マスク画像と予測結果の赤色部分は股関 節唇を表し,黒色部分は大腿骨頭を表す.

図2は代表的な3つの症例について左から股関節鏡画像,マ スク画像,予測結果(セグメンテーション)画像であり,右端に Diceの値を示す.症例3での予測結果については,股関節唇と 大腿骨頭を正しく判別できていない.これは股関節鏡画像に表 れているとおり,股関節唇と大腿骨頭がわかりにくいことが原 因である. 症例 10 では股関節唇の下部の色合いが変わってい るため判別がうまくいっていない. 症例 11 では股関節鏡画像 で股関節唇と大腿骨頭の区別がつけやすいため結果もよいこ とがわかる. 図 3 左は全 13 症例のマスク画像と予測結果画像 とで計算して得られた Dice の値である. 図 3 中央, 図 3 右は 股関節唇, 大腿骨頭についてのテスト結果であり、左側(灰色) がマスク画像の画素値, 右側(黄色)が予測された画像の画素値 である. 股関節唇の面積については, 視野の中心部に近い程良 いと考え, 式(1)に示すように $\sigma=0.5$  としてガウス分布により 重み付き画素値とした.

weighted pixel = 
$$1.0 \times \exp\left(-\frac{r^2}{2\sigma^2}\right)$$
 (1)



図 3. 左:マスク画像と予測結果との Dice の値. 中央:股 関節唇の重み付き画素数について,右:大腿骨頭の画素数に ついて,それぞれマスク画像(灰色)と予測結果(黄色)の比較.

図3左で示した Dice の値については,症例によっては股関節 唇と大腿骨頭の区別がつきにくいため予測結果がマスク画像 とかけ離れているものがある.図3中央は股関節唇のみの重み 付き画素数であり,症例によって差異があり,第5,14,15症 例についてはマスク画像と予測画像との画素値の差が顕著で ある.図3右については大腿骨頭のみの画素数であり,股関節 鏡からの光の反射があり形状が球形であるため判別しやすく, 予測結果は全症例について差異が少ないことがわかる.

### 5. まとめ

現時点での学習用画像数が各症例 20 枚と少ないこと,モデ ルが未改良であることが Diceの値が低い原因の一つと考えら れるため,学習を強化する工夫が必要であると考えられる.

文 献

### 利益相反の有無

なし.

[1] Yaqub Jonmohamadi, Yu Takeda, Fengbei Liu, Fumio Sasazawa, Gabriel Maicas, Ross Crawford, Jonathan Roberts, Ajay K. Pandey, Gustavo Carneiro: Automatic Segmentation of Multiple Structures in Knee Arthroscopy Using Deep Learning, IEEE Access, Vol.8: pp51853 - 51861, 2020

## 広視野撮影による皮膚毛細血管の多数同時観察と

## セマンティックセグメンテーションを用いた密度推定

瀧本 麦<sup>\*1</sup>,尾藤 宏達<sup>\*2</sup>,田口 浩之<sup>\*3</sup>,播 さや香<sup>\*4</sup>,羽石 秀昭<sup>\*5</sup>
 <sup>\*1</sup>花王株式会社 解析科学研究所

\*2 花王株式会社 コーポレート戦略部門 デジタル事業創造部

\*3 花王株式会社 研究開発部門 研究戦略・企画部

\*4 花王株式会社 ヘルス&ウェルネス研究所

\*5 千葉大学フロンティア医工学センター

## Observation and density estimation of numerous skin capillaries using wide-field imaging and semantic segmentation

Baku TAKIMOTO<sup>\*1</sup>, Kotatsu BITO<sup>\*2</sup>, Hiroyuki TAGUCHI<sup>\*3</sup>, Sayaka HARI<sup>\*4</sup>,

### Hideaki HANEISHI\*5

\*1 Analytical Science Research Laboratories, Kao Corporation
 \*2 Digital Business Creation, Corporate Strategy, Kao Corporation
 \*3 R&D Strategy & Planning, Kao Corporation
 \*4 Health & Wellness Products Research Laboratories, Kao Corporation
 \*5 Center for Frontier Medical Engineering, Chiba University

要旨:皮膚毛細血管は顕微鏡(キャピラロスコープ)を用いて非侵襲的に観察可能であり、その構造と血流は組織や全身の状態を 反映しうる.そのため、毛細血管の撮影と定量的な画像解析は、新規な簡易診断法への発展が期待される.毛細血管の構造は不均 ーであるため、信頼性の高い評価には、広視野で多数の毛細血管を撮影することが有効である.また、毛細血管の血流は間欠的で あるため、静止画ではなく動画の撮影及び解析が望ましい.そこで本研究では、広い視野と毛細血管観察に十分な空間分解能を有 する撮影装置と、本装置で得た動画から毛細血管密度を自動推定する画像解析法からなるシステムを開発した.セマンティックセ グメンテーションを用いた自動解析結果は、手動解析結果と相関した.本システムにより千本以上の毛細血管の同時観察及び密度 算出が可能であり、算出値は被験者、部位、皮膚バリア破壊の前後で異なったことから、組織の状態評価法に繋がりうる. キーワード:皮膚微小循環、毛細血管、キャピラロスコープ、セマンティックセグメンテーション、ディープラーニング

### 1. はじめに

皮膚や爪郭の毛細血管は顕微鏡で非侵襲的に観察でき,その 密度や構造は基底細胞癌や COVID-19 といった種々の疾患の 影響を受ける[1,2]. そのため,顕微鏡画像から皮膚毛細血管の 定量的な指標を抽出することは,組織や全身の状態を評価する 新規手法へ発展する可能性がある.

皮膚毛細血管の形状や血流は不均一であるため,信頼性の高 い評価には、多数を観察・解析することが望ましい.しかし、 一般的な毛細血管観察用の顕微鏡(キャピラロスコープ)では、 幅 10µm 以下の毛細血管を観察するために、空間分解能が高 い一方で視野が約3mm 以下に限られていた[3,4].そこで本研 究では、幅7mm 以上の広い視野と毛細血管観察に十分な分解 能で、多数の皮膚毛細血管を同時に撮影するデバイスを開発し た.さらに、本デバイスで得られる膨大な毛細血管の密度を定 量的かつ簡便に解析するために、セマンティックセグメンテー ションにより血管領域を自動で抽出・解析する手法と組み合わ せた.自動で算出した値を手動解析結果と比較し、精度を検証 した.併せて,被験者及び外部刺激の有無による推定結果の違いから,本システムの組織状態評価への適用性を考察した.

### 2. 方法

高画素数(4000×3000)で動画撮影可能な USB3.0 カメラと高 解像度テレセントリックレンズ, LED 光源を内蔵した鏡筒を 組み合わせ,広視野ビデオキャピラロスコープを作製した.こ れにより,簡便に皮膚に押し当て,7.4 mm×5.5 mmの広い領 域を空間分解能 3.5  $\mu$  m 以下で観察可能とした.

健常男性 11 名を被験者とし、それぞれ前腕内側部の7か所 を撮影部位とした.洗浄、ふき取り、20分間の馴化後に動画を 撮影し、5秒間(150フレーム)を解析に供した.また、刺激によ る皮膚微小循環への影響を観察するため、4名に対してテープ 剥離による皮膚バリア破壊を行った後にも撮影を行った.

得られた動画のブレを, テンプレートマッチングを用いて補 正した.また,血管内を間欠的に赤血球が流れる動画から,連 続的な毛細血管構造が描画された静止画を作成し,明るさの均 ー化及びコントラスト強調を行った.これらの前処理の後に, 生物・医学分野で実績を有するセマンティックセグメンテーシ ョン手法 U-net [5]を用いて,毛細血管領域の学習及び推定を行 った.1300×1000 画素(2.4 mm×1.9 mm 相当)の領域を抜粋し た画像と,そこから毛細血管領域を手動でアノーテーションし た画像を一組として学習に用いた.11 名のバリア破壊前及び 後の計 22 組の画像から,ランダムな位置で 512×512 画素の領 域を抜粋した 150 組の画像を生成し,エポック数 50,バッチ サイズ 16 にて学習処理を行った.その後,バリア破壊前また は後の 1300×1000 画素の画像 11 枚における毛細血管領域を 推定した.自動で推定された領域の数と面積を,手動で血管領 域を抽出した結果と比較し,精度を評価した.

さらに,前処理後の視野全体(7.2 mm×5.4 mm, 3900×2900 画素)から毛細血管領域の推定と数・面積を算出した. バリア 破壊を行った各被験者の処理前後の結果を比較し,被験者間の 差異と外部刺激の影響を評価した.

#### 3. 結果と考察

撮影された画像に前処理を行った結果,多数の毛細血管を観察できた(図1(a) (b)). U-net による自動抽出の結果,毛細血管 に対応する領域が抽出された(図1(c)(d)). 定量的な検証のため に,2.4 mm×1.9 mmの画像から自動抽出された領域の数及び 面積を,手動解析結果と比較した.毛細血管の数,総面積,平 均面積について,自動及び手動で抽出し算出した値の相関係数 はそれぞれ0.87,0.95,0.93となり,いずれも強い相関が得ら れた.また,前処理後の視野全体から毛細血管領域を自動抽出 できた.以上より,提案手法を用いて,広視野で膨大な毛細血 管を同時撮影し,多寡を自動で評価できることが示された.



図 1. 画像例: (a)前処理後の視野全体(7.2 mm×5.4 mm), (b) (a) の部分拡大(2.4 mm×1.9 mm), (c) (a)からの毛細血管領域推定 結果, (d) (c)における(b)と同一個所の拡大.

続いて,被験者間およびバリア破壊前後での毛細血管総面積 を推定した例を,図2に示した.バリア破壊前(平常時)の面積 は,被験者1,4より被験者2,3では少なかった.また,被験 者2ではバリア破壊によって毛細血管の総面積が増加したの に対し,被験者3では減少した.このような差異は,個人の平 常時における皮膚微小循環やその応答性を特徴付ける上で,利 用できる可能性がある.



図 2. 皮膚バリア破壊前後の4名の画像から推定された 7.2 mm ×5.4 mm 領域における毛細血管の総面積.7 か所の平均値を 示しており, エラーバーは標準偏差.

#### 4. まとめと展望

広視野で皮膚毛細血管を撮影し、その数や面積を自動解析す るシステムを提案した.算出された値は手動解析での結果と相 関した.本手法で算出した毛細血管の総面積は、平常時の値や 角層バリア破壊による変化に個人差が見られた.この差異は、 組織の状態評価や薬剤・治療等による効果の指標に繋がりうる. 本手法は既存手法より多数の毛細血管を同時に撮影・解析でき ることから、不均一な毛細血管を信頼性高く評価できる.今後、 組織・全身の状態を評価する新規手法への発展を期待している.

### 利益相反の有無

なし

- [1] Ayhan E, Ucmak D, Akkurt Z: Vascular structures in dermoscopy. An Bras Dermatol 90: 545-553, 2015
- [2] Rosei CA, Gaggero A, Famà F, et al: Skin capillary alterations in patients with acute SarsCoV2 infection. J Hypertens 40: 2385-2393, 2022
- [3] Sainthillier JM, Degouy A, Gharbi T, et al: Geometrical capillary network analysis: Geometrical capillary network analysis. Skin Res Technol 9: 312-320, 2003
- [4] Hariyani YS, Eom H, Park C. DA-Capnet: Dual Attention Deep Learning Based on U-Net for Nailfold Capillary Segmentation. IEEE Access. 8: 10543-10553, 2020
- [5] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. Lect Notes Comput Sci 9351: 234-241, 2015

## 舌画像解析と機械学習を用いた漢方医学病態予測

鈴木 萌仁伽\*1, 石川 堅也\*2, 渡邊 悠紀\*3, 並木 隆雄\*3,

森田 智\*4, 村上 綾\*5, 野村 行弘\*6, 中口 俊哉\*6

\*1 千葉大学工学部総合工学科医工学コース

\*2 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

\*3 千葉大学大学院医学研究院和漢診療学

\*4 千葉大学医学部附属病院東洋医学センター墨田漢方研究所

\*5 横浜薬科大学薬学教育センター

\*6 千葉大学フロンティア医工学センター

Prediction of Clinical Diagnosis in Kampo Medicine Using Machine Learning and Analysis of Tongue Images

Monika SUZUKI<sup>\*1</sup>, Takaya ISHIKAWA<sup>\*2</sup>, Yuki WATANABE<sup>\*3</sup>, Takao NAMIKI<sup>\*3</sup>,

Akira MORITA\*4, Aya MURAKAMI\*5, Yukihiro NOMURA\*6, Toshiya NAKAGUCHI\*6

<sup>\*1</sup> Department of Medical Engineering, Faculty of Engineering, Chiba University

<sup>\*2</sup> Department of Medical Engineering, Graduate School of Science and Engineering, Chiba University

<sup>\*3</sup> Department of Japanese-Oriental "Kampo" Medicine, Graduate School of Medicine, Chiba University

<sup>\*4</sup> Sumida Kampo Clinic, East Asian Medicine Center, Chiba University Hospital

<sup>\*5</sup> Pharmaceutical Education Center, Yokohama University of Pharmacy

<sup>\*6</sup> Center for Frontier Medical Engineering, Chiba University

要旨: 舌診は舌特徴を捉え, 簡便かつ非侵襲的に健康状態を把握する診断法であるが, 診断者の主観や経験に依存するため, 普遍的・科学的な所見に向けた定量化が求められている.本研究では, 漢方医学病態のうち水滞に着目し, 舌画像から算出される特徴量を用いた関連解析および機械学習を用いて病態予測を行った. 136 名の患者の舌画像を医師の診断に基づき水滞, 非水滞に区分した. 舌の形状, 色彩, テクスチャに関する 307 種類の舌特徴量のうち, 2 群間において 61 種類で統計的有意差を確認した.また, 病態予測に4 種類の機械学習手法の比較を行った. Light Gradient Boosting Machine が最も高い予測性能を示し, 平均 Average Precision は 0.806 を示した. 次に経験の浅い医療従事者との予測性能を比較する実験を実施したところ, 多くの評価指標で機械学習モデル による予測が優れた結果を示した.本研究は機械学習モデルによる水滞予測の有効性を示しており, 医師の診断補助に貢献する可能性が示唆された.

キーワード:舌診断支援,画像特徴,機械学習,水滞予測

### 1. はじめに

漢方医学の診察手法の1つに舌診がある.舌体の色・形・大 きさ・厚さ・潤い,舌苔の色・量などの舌特徴から健康状態を 予測する.舌診は,非侵襲的な診察手法であり,加えて短時間 で診察可能であるなど様々な利点を持つ.

我々はこれまでに、図1に示すような舌診支援のための舌撮 影装置 TIAS (Tongue Image Analyzing System)を開発した[1]. 舌の色や表面状態などの特徴が TIAS 舌画像から算出され、 様々な生体情報や疾患情報との関連が調査・解析されてきた.

漢方医学において,生体は「気」,「血」,「水」の3要素が体内を循環することによって維持されると考えられている[2]. この気血水の3要素により診断される病態のうち,水の異常である水滞は水が身体の一部に停滞することが原因であり,特に 舌診の所見との関連があるとされている.漢方医学病態の診断 は医師の主観や経験に依存し、定性的であるという問題がある. そのため、病態と舌の関連の解明および診断の定量化が求められる.以上のことから、本研究では舌画像解析による舌特徴と 水滞との関連解析および舌画像からの水滞予測を目的とする.





(a)TIAS の外観 図1 舌撮影装

(b)舌撮影の様子 舌撮影装置 TIAS

### 2. 舌画像解析による舌特徴と水滞との関連解析

本実験では、千葉大学医学部附属病院の和漢診療科外来において同意を得た患者を対象に TIAS で撮影した舌画像を 136 名 分収集した.これらの舌画像に対して十分に経験を積んだ医師のラベル付けに基づき水滞である患者(52 名)とそうでない 患者(84 名)に区分した.

まず, 舌画像から MobileNet-SSD [3] を用いて舌を検出す る. 続いて, 対象となる舌領域を DeepLabv+ [4] を用いて抽 出する. 舌特徴について, 形状 (10種)・色彩 (231種)・テク スチャ (66種) に関する特徴量 (計 307種) を算出した. これ らの特徴量について, 非水滞患者および水滞患者の2 群間の有 意差を統計検定により調査した. 説明変数の正規性および等分 散性を考慮して, Mann-Whitney U 検定, Welch's t 検定, Student's t 検定のいずれかを選択して統計検定を実施した. このとき, 有意水準は0.05とした.

統計検定の結果,非水滞患者および水滞患者の2群間におい て 61 種の舌に関する特徴量で統計的有意差を確認した.形状 に関する特徴量では統計的な有意差は確認されず,色彩では 45種,テクスチャでは 16種の特徴量で統計的有意差を確認し た.結果,算出領域にかかわらず舌全体に対して色彩やテクス チャに有意差があることが確認できた.また,色彩については CIELAB 色空間の a\*値で特に多くの有意差が認められた.以上 の結果から,水滞による舌への影響として,領域ごとの差は小 さく,舌全体に対し赤みおよび均質さが低下する可能性が示唆 された.

#### 3. 機械学習を用いた水滞予測の検討

統計検定の結果から、色彩のみ・テクスチャのみ・a\*値のみ・ 統計的有意差を確認した項目すべての 4 種類の入力特徴量の 与え方で新たに機械学習モデルを学習した. 今回は, Support Vector Machines (SVM) [5], Random Forest (RF) [6], Light Gradient Boosting Machine (LGBM) [7], Logistic Regression (LR) [8] の 4 つの機械学習モデルを用いた.

結果,入力特徴量として色彩に関する特徴量,機械学習手法 にLGBM を用いた際の予測性能が最も良く,平均 AP (Average Precision) は 0.806 となった.

#### 4. 機械学習を用いた水滞予測の検討

機械学習モデルによる水滞予測の有効性評価を目的として, 経験の浅い医療従事者との予測性能を比較する実験を実施した.本実験では,新たに30名分の舌画像を収集し,漢方熟練 医1名がラベルを付け,ラベルから非水滞患者(15名)・水滞 患者(15名)を区分した.続いて,4名の漢方診断経験の浅い 医療従事者のラベル付け結果を比較対象として用いた.なお機 械学習モデルには最も良い予測性能を示したモデル(入力特徴 量: 色彩に関する特徴量, 機械学習モデル: LGBM)を用いた.

表1の結果より,多くの評価指標で機械学習モデルによる予 測が最も良い結果を示した.Recall が最も高くなっており,偽陽 性が少ないことがわかる.このことから機械学習モデルによる 水滞予測は医療現場において除外診断・スクリーニングにおい て大きな役割を果たす可能性があると考える.

### 5. まとめ

本研究では舌画像解析による舌特徴と水滞との関連解析お よび舌画像からの水滞予測を行った.機械学習を用いた水滞予 測では,入力特徴量に色彩に関する特徴量,機械学習モデルに LGBM として予測した際に最も予測性能が高くなった.

この結果を漢方診断経験の浅い医療従事者 4 名と比較した ところ,機械学習を用いた水滞予測が最も良い性能を示し,機 械学習モデルによる水滞予測の有効性が確認された.これによ り,舌画像から算出される舌特徴を用いた水滞予測の実現可能 性が示唆された.

表1 機械学習モデルと医療従事者の予測性能

予測方法	Accuracy	Precision	Recall	F1 Score
機械学習	0.767	0.722	0.867	0.788
従事者1	0.433	0.375	0.200	0.261
従事者 2	0.733	0.769	0.667	0.714
従事者3	0.567	0.538	0.467	0.519
従事者4	0.600	0.636	0.467	0.538

#### 利益相反の有無

なし

- [1] 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, vol. 2015, Article ID 249609, 10 pages, 2015. doi:10.1155/2015/249609
- [2] 寺澤捷年:絵でみる和漢診療学,医学書院,東京,1996
- [3] Qichao Tang et al : Examination of tongue detection and region extraction for automation of tongue diagnosis support system. JAMIT, 2019
- [4] Chen L, Zhu Y, Papandreou G, Schroff F, Adam H : Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. arXiv preprint arXiv:1802.02611, 2018
- [5] Cortes C and Vapnik V, Support-vector networks. Machine Learning, 20, 273– 97, 1995
- [6] Breiman L : Random Forests. Machine Learning, 45, 5–32, DOI : 10.1023/A:1010933404324, 2001
- [7] Guolin K, Qi M, et al : LightGBM : A highly efficient gradient boosting decision tree. Neural Information Processing Systems, 3149–3157, 2017
- [8] 内田治: SPSS によるロジスティック回帰分析.オーム社,東京, 2011

## 前眼部画像から感染性角膜炎の原因を予測するAIモデルの作成

○佐藤 貴輝<sup>1</sup>、奥村 直毅<sup>1</sup>、松村 拓弥<sup>1</sup>、SaravanaSangavi<sup>2</sup>、LakshmipathyMeena<sup>2</sup>、 SudhirRachapalle<sup>2</sup>、小泉 範子<sup>1</sup>

<sup>1</sup> 同志社大学大学院 生命医科学研究科、<sup>2</sup> Sankara Nethralaya

【目的】感染性角膜炎において前眼部画像から原因を予測できるAIの作成を試みた.

【方法】細菌, 真菌, ウイルス, アカントアメーバによる感染性角膜炎と診断された患者 より336枚の高解像度の前眼部画像を取得した. インターネットからも238枚の画質の劣る 画像を取得した. EfficientNetにより画像分類AIモデルを作成した. 80枚をテストデータ としてAIの性能を評価し, 眼科医30名による分類と比較した.

【結果】作成したAIの性能は,正解率61.2%,適合率61.7%,再現率61.3%,F値61.2%で あった.また,同じテストデータを眼科医30名が分類した場合は,正解率39.3.%,適合率 41.7%,再現率39.3%,F値35.6%であった.

【結論】感染性角膜炎の原因を予測するAIモデルが作成できた.現在,AIの有用性を評価 するための臨床研究の準備を進めている.

## 第 42 回日本医用画像工学会大会(JAMIT2023) 大会役員委員会名簿

			五十音順・敬称略	
		大会役員		
大会長				
	木戸 尚治	大阪大学		
事務局長		T		
	富山憲幸	大阪大学		
業務委員長				
	橋本二三生	浜松ホトニクス		
プログラム委員会				
委員長				
	半野 靖	山口大字		
<u> </u>	<b>七山 </b>	1. 111 1. 92		
	月村 秀孝			
	伊滕 聡志	手都呂大字		
		储井天字 计 武士学		
	上刊 半可	国立省東谷病研究センター		
	小田 百厷 	□ 石白座人子 東京工業上兴		
	小毛 尚史 	□ 泉泉⊥系入子 → 川工業上営		
	仲谷 · ラ 	<u>儿</u> 州上耒人子		
	刊田 [[] [] [] [] [] [] [] [] [] [] [] [] []	一		
		发加上来入子 一 一 一 一 一 一 一 一 一 一 一 一 一 一 一 一 一 一 一		
	北州 主可	林式会社 島津聚作所		
	▲ 八村 裕一 一 一 一 一 一 一 一 一 一 一 一 一 一 一 一 一 一 一 一			
		<u> </u>		
	佐藤 嘉仲	会良尤缅科学拉彻大学阮大学 世球工费上兴。CITA %人研究证。上兴院I	用工产工作利	
	椎名 毅	之佣丄亲大子 511 総合研究所 大字院共	里上字研究科	
	有水 昭仲	果 泉 晨 山 入 子		
		电		
	一			
	「「「「」」」     「「」」     「「」」     「「」」     「「」」     「「」」     「「」」     「」     「「」」     「「」」     「」     「」     「」     「」     「」     「」     「」     「」     「」     「」     「」     「」     「     「」     「」     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「      「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「     「	十葉入字		
	杉本 追二 逆辺  捷言	<b>京都大学</b>		
	田田 · 利思	宝 (八人子) 古 会 始 十 学		
	陳 延保           土木 焼司	业命期入学 友址++学		
	· · · · · · · · · · · · · · · · · · ·	名 城人字 「 革 上 労		
	中口 俊武	一 十朱人子		
	中田 央生	果泉慾思云达科人子 立 今始上受		
		业 印		
	സ് ~ 九貝 			
		一 干朱八子		
	個平 止弘 	度應我至八子 十八十〇		
		人刀入子 車百十受		
	 	<ul> <li>木示八子</li> <li>工 苗 十 尚</li> </ul>		
		未八子 		
	床 武丈 	—————————————————————————————————————		
	  大公 本取	山口八子           夕士层工業十学		
	—————————————————————————————————————	□ 1口座上未八子		
		→ <sup>-</sup> <sup>-</sup> <sup>-</sup> <sup>-</sup> <sup>-</sup>		
	円日 六口 _	ロロハナ     宣十フイルムヘルスケア株式会社		
		由市大学		
	□ □ 加 □ 厦 八 木   ៨ 华			
	林 健衆	111/土八丁 国立研究期及注1月7利兴村农田水田水1	<b>继捷</b>	
	田台 茶 退津 折山	四立砌九两无広八里丁件子仅侧砌无崩充作 山形十学	风旧	
	汤伐 铅也	山心八子   田州安に赤吕 <b>今</b>		
安貝文	松卡 坎幻	十陌十学		
	亚P / 个 作日 齐C	八四八千		

## 日本医用画像工学会(JAMIT) 役員名簿 (令和5年4月6日現在)

五十音順・敬称略

	氏名	所属	
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	
副 会 長	原武史		
	森健策	名古屋大学	
	伊藤 聡志	宇都宮大学	
	北坂 孝幸	爱知工業大学	
	滝沢 穂高	筑波大学	
	中田 典生	東京慈恵会医科大学	
理事	橋本二三生	浜松ホトニクス株式会社	
	畑中 裕司	大分大学	
	花岡 昇平	東京大学	
	増谷 佳孝	東北大学	
	目加田慶人	中京大学	
	湯澤 史佳	キヤノンメディカルシステムズ	
	有村 秀孝	九州大学大学院	
	石田 隆行	大阪大学	
	上村 幸司	国立循環器病研究センター	
	尾川 浩一	法政大学	
	小田 昌宏	名古屋大学	
	小尾 高史	東京工業大学	
	掛川 誠	中央システム技研	
	笠井 聡	新潟医療福祉大学	
	川岸 将実	キヤノン	
	河田 佳樹	徳島大学	
	木戸 尚治	大阪大学	
	黒木 嘉典	新村病院、博愛会 HPN 東京	
	小橋 昌司	兵庫県立大学	
	近藤 世範	新潟大学	
	<u> </u>	慶応義塾大学	
	杉本 直三	京都大学	
代議員	銭谷 勉		
1 104/22 3	高橋 哲彦	群馬県立県民健康科学大学	
	高丸 和也	富士フイルム	
	武田御	青柳病院	
	健山 智子	滕田医科大字 	
	田田 利思	金沢大字	
	陳 延厚	业 印	
	守平 馬可	滕田医科天子	
		新松尸屮 <b>火総</b> 台柄阮	
	────────────────────────────────────	业	
		王 邱 加 国 际 俩 阮 千    崔    十    受	
	三 野竹 竹弘 三 三 三 三 三 三 三 三 三 三 三 三 三 三 三 三 三 三	汞八子	
	下了 禾切	中尔人子 工	
		山口大学	
		四日八丁 名古屋丁堂大学	
	<u> </u>	111/王上不八丁 	
	- 西百 家具 吉田 悦次	エリコーナシスロックレの元のスロックスのかな区土地ロックレク	
	本田 尚考	島津製作所	
監事	清水 昭伸	東京農工大学	