




JAMIT Annual Meeting 2022

第41回日本医用画像工学会大会

会 期：2022年7月29日(金)～31日(日)

会 場：名古屋大学 東山キャンパス 豊田講堂

大会長：森 健策(名古屋大学)



共 催: 名古屋大学情報基盤センター

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

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

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

公益社団法人 日本放射線技術学会

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

日本脳神経CI学会

学会長ご挨拶

第41回日本医用画像工学会大会（JAMIT 2022）を、会期7/29(金)～7/31(日)にわたって、名古屋大学豊田講堂（東山キャンパス）にて（COVID-19の状況によりオンライン開催に変更の可能性あり）、森健策先生大会長のもとで開催させていただくことになりました。当初、第41回大会は絶対に現地開催できると思い計画を始めましたが、COVID-19の状況を見て現地開催かオンラインのどちらか一方に決定する予定です（日程の延期は考えていません）。私は、COVID-19の問題が未だに解決しない状況を長期間眺めていて、JAMITが関与できるのは医用画像分野ですが、「科学技術はまだ未熟で未知の世界がありCOVID-19を直ちに打ちのめすレベルに今後益々発展させねばならない」と思うことがよくあります。特に、今後の人類を背負う若手研究者に期待する所です。さて、JAMIT大会は2016年開催の第35回大会以降、AIブームの上昇気流に乗り、参加者数300人以上・演題数100件・「ハンズオンセミナー」や「チュートリアル講演」などAI関係の企画物の高評価、他の大成功を収めてきました。私自身も、毎年大会に参加して医用画像分野の研究者・技術者のJAMIT大会への大きな期待を感じると同時に、学会長として魅力的な大会にしなければならない責任やプレッシャーも感じてきました。

継続した大成功に導くため、JAMIT2022の大会長は医用画像分野のトップ研究者の一人であり学会開催の豊富な経験を持つ森先生に期待して、大会長をお願いして快くお引き受けいただきました。そして、森先生の方で準備チームを組織してこれまで必死で準備を進め、企画物とスケジュールが確定した状況です。その全体像を以下に紹介させていただきます。最初に、大会のテーマは「コンピューティングとイメージングが切り拓く新たな医用画像工学」に設定して、JAMITがイメージングとポストプロセッシングの両方をバランス良く取り扱う学会である特徴が強く現れているものになりました。特別講演は、理化学研究所の杉山将先生と高輝度光科学研究センターの上相真之先生にお願いしました。杉山先生は誰もが知る機械学習の著名研究者であり「限られた情報からロバストに：信頼できる機械学習に向けて」というタイトルで壮大な杉山先生にしかできないようなご講演を聞けるに違いないと楽しみにしています。上相先生は、放射光を用いたCTイメージングの著名研究者であり、タイトル「小惑星探査機「はやぶさ2」帰還粒子の放射光CT観察から導かれる、小惑星リュウグウの形成・進化史」で、宇宙から持ち帰った石をイメージングして宇宙の様相が分かるという夢があるご講演をいただきます。シンポジウムに関しては、4つのシンポジウムを企画しました。シンポジウム1～3は技術的な内容で、イメージング・ポストプロセッシング・関連するデータベースやネットワークに関するものをバランスよく揃えました。具体的には、「次の医用画像工学を切り拓くHPCと機械学習」、「医用画像データベースとネットワーク」、「イメージングが切り拓く未来の医用画像工学」の3つのシンポジウムです。そして、4つ目のシンポジウムとして、「JAMITの未来を作ろう！」を企画しました。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。年配研究者から若手研究者に問いかけ、元気のよい若手研究者に思いや本音を述べてもらうようなスタイルのものを考えています。今までのJAMIT大会ではなかったシンポジウムであり、私は「年配と若手の対話により何か共通認識・やるべき新しい方向性・個々の若手研究者が成功を収めるキーのようなものが出てくればよい」と期待しています。他の企画物として、ハンズオンセミナーはJAMIT2021と同様に90分×5回をリフレッシュした内容「深層学習ハンズオンセミナー～リフレッシュ：画像認識から生成まで～」で実施します。チュートリアル講演会は益々重要性が増している「個人情報保護」に関するものを準備しています。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、ランチョンセミナーなどを予定しています。一般演題は80件の発表があります。

会場の名古屋大学豊田講堂は、名古屋大学のシンボルで著名建築士の槇文彦先生が設計されたもので、有名な歴史的建造物として知られています。JAMIT2021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、「現地で開催できたことに意義があった」大会でした。JAMIT2022は豊田講堂にCOVID-19以前のJAMIT大会に近い多くの方が集まり「実質的な現地開催ができた」としたい所ですが、無理はできず国・自治体・大学の指示に従い参加者の安全を守らなければならない、その決定を森先生と慎重に行い皆様にお伝えします。

日本医用画像工学会（JAMIT）
会長 工藤 博幸

大会長ご挨拶

来たる 2022 年 7 月 29, 30, 31 日の 3 日間、名古屋大学豊田講堂にて第 41 回日本医用画像工学会大会 (JAMIT2022) を開催いたします。新型コロナウイルス感染症の影響による国による行動制限が発出されなければ、3 年ぶりの全面的な現地開催大会となる予定です。

新型コロナウイルス感染症の影響が全世界に広まり、学術分野においても様々な影響がもたらされています。学会活動もその最たる例であるとも言えます。JAMIT 大会もその一つであり、学会員の皆様、参加者、そして、企業展示の皆様などとの間のコミュニケーションが制限される日々が続いております。

新型コロナウイルス感染症の診断治療方法の確立も医工学分野における重要な課題でもあります。医用画像工学は、肺炎の診断や治療方針の決定などにも大きく寄与する学問分野でもあります。人体内部を画像としてとらえるイメージングとそれを処理するコンピューティングは、医用画像工学におけるコアな領域であるといえます。

そこで、JAMIT 2022 では、「コンピューティングとイメージングが切り拓く新たな医用画像工学」として、イメージングとコンピューティングがどのようにして新たな医学的価値を生み出すかを皆様と議論できるような機会としたいと考えております。イメージングとコンピューティングの両面から、特別講演、シンポジウムなどを構成しております。また、今後の JAMIT を支える若手研究者によるセッションなども企画しております。

特別講演では、機械学習の最先端に関し、本分野で著名な東京大学ならびに理化学研究所の杉山将先生から、イメージングに関しては、高輝度光科学研究センターの上相真之先生から、それぞれご講演をいただく予定です。

シンポジウムでは、「次の医用画像工学を切り拓く HPC と機械学習」、「医用画像データベースとネットワーク」、「イメージングが切り拓く未来の医用画像工学」の 3 つと、将来を参加者の皆様と議論する「JAMIT の未来をつくろう！」の 4 つを企画いたしました。

機械学習を用いたデータドリブンな画像解析や自然言語処理、スーパーコンピューターなどを用いた大規模な計算技術は今後の医用画像解析において重要な位置を占めています。これらについて議論する機会として「次の医用画像工学を切り拓く HPC と機械学習」を設けています。また、名古屋大学情報基盤センタースーパーコンピューターシステム「不老」の見学会も企画しています。

医用画像研究におけるデータドリブンな画像解析においては画像データベースの構築が重要となっています。また、データの収集および利活用のためにネットワーク基盤の重要性が増しています。本シンポジウムでは、最新のデータベース構築や学術基盤ネットワークの実例を紹介していただく企画として「医用画像データベースとネットワーク」を設定しました。

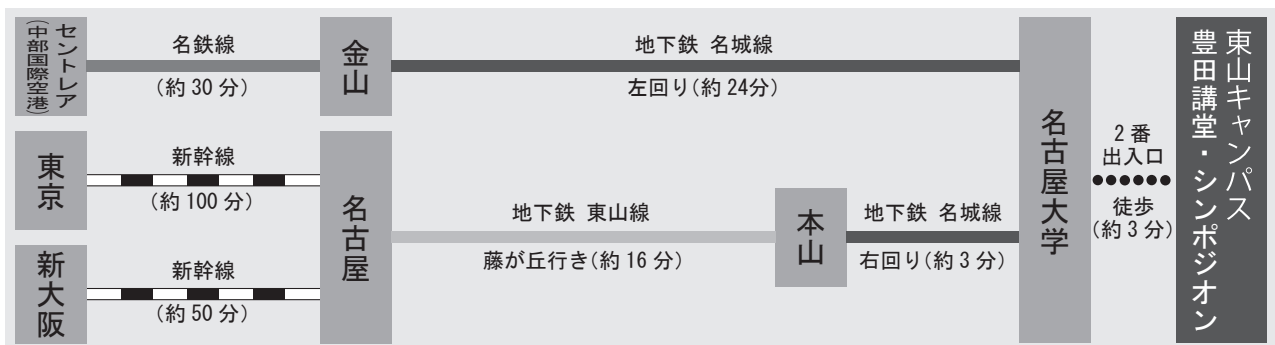
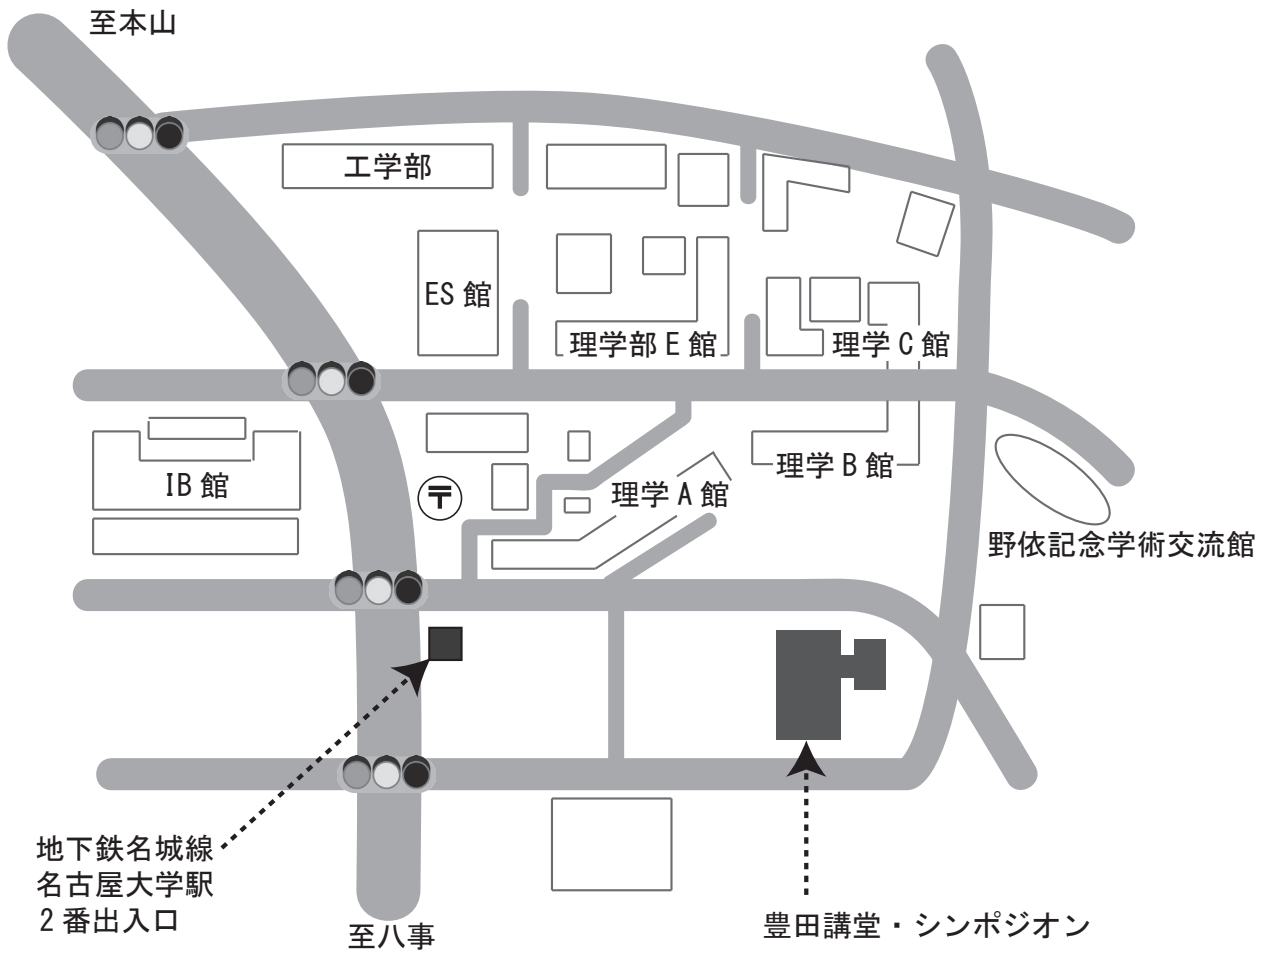
「イメージングが切り拓く未来の医用画像工学」では、最先端のイメージング手法を第一線の研究者にご紹介いただき、イメージングとコンピューティングの接点を探ってゆく機会としたいと思います。

「JAMIT の未来をつくろう！」は、経験豊富なモデレータが若い研究者の皆さんへ問いかける形で、学会のありかたを考える機会として設けました。JAMIT 創立から約 45 年の月日が流れようとしています。近年の機械学習ブームに乗って本学会の領域の研究者が増えていることは間違いないことです。しかしながら、次の 20 年、30 年の JAMIT を考えると、学生、助教レベルの研究者が「今」元気に活躍できる学会とする必要があります。また、医用画像工学の領域の研究者だけでまともな発展は期待できないと思います。近年の機械学習手法の発展に伴い、深層学習を利用した医用画像工学の研究が活発となっている一方、研究成果の再現性が重要視されるフェーズに入っています。コード・データベース・有名国際会議の査読過程の公開、など研究のあり方の大変革も起きています。このような激流に耐えうるのは JAMIT の将来を担う若手の皆さんしかありません。これらを踏まえて、本シンポジウムを企画しています。


盛夏の中での JAMIT2022 開催となりますが、参加者間の活発な議論の場を提供できるように頑張ってゆく所存です。どうかよろしく申し上げます。

第 41 回日本医用画像工学会大会
大会長 森 健策 (名古屋大学)

交通案内



会場案内図



参加者へのご案内

1. 会期：2022年7月29日(金)～31日(日)

2. 会場：名古屋大学 東山キャンパス 豊田講堂（国登録有形文化財）

〒464-8601 名古屋市千種区不老町

<https://www.nagoya-u.ac.jp/extra/map/index.html>

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://jamit2022.jamit.jp/registration.html>

1) 登録期間：5月9日(月)～7月31日(日) 16:00

2) 参加費：正会員（賛助会員含む）：13,000円

学生会員：5,000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：7,000円

3) 現地受付開設時間

7月29日(金) 12:30～18:30

7月30日(土) 8:00～18:30

7月31日(日) 8:00～16:00

4. 会員集会

日時：7月30日(土) 13:10～14:10 会場：第1会場（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8分、討論4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をお願いいたします。

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15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/>)

〒104-0033 東京都中央区新川 1-5-19 6 階 (株)メイプロジェクト内

TEL: 03-6264-9071 FAX: 03-6264-8344 E-mail: jamit@may-pro.net

10. 利益相反 (COI) について

筆頭発表者が、日本医用画像工学会における「利益相反の取扱いに関する規程」

(<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 12 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)

「医用画像研究と一般画像研究におけるプライバシー保護」

第 41 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 12 回日本医用画像工学会 (JAMIT) チュートリアル講演会 ～医用画像研究と一般画像研究におけるプライバシー保護～」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 29 日 (金) 13:10～16:00

座 長：滝沢 穂高 (筑波大学)

講演 1：(TU1) 人を対象とした研究を安心して進めるための処方箋

大西 正輝 (産業技術総合研究所 人工知能研究センター)

講演 2：(TU2) 臨床現場における個人情報保護に留意した医療 AI 開発研究

大山 慎太郎 (名古屋大学)

講演 3：(TU3) 医用画像の個人情報を取り扱う企業の取り組み

中西 隆伯 (株式会社ジェイマックスシステム)

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

深層学習の環境は年々変化しています。定期的に潮流を眺めサンプルプログラムに触れると、実験環境の構築から実験方法を再確認できます。恒例となりつつあるハンズオンセミナーは、ハンズオン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。2022 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 5 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 30 名に制限します。なお、ハンズオンの参加には JAMIT2022 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：深層学習ことはじめ：入門編（7/29 午後）

課題 2：画像の分類と回帰（7/30 午前）

課題 3：物体検知と領域分割（7/30 午後）

課題 4：異常検知とフェイク画像の生成（7/31 午前）

課題 5：自然言語・音声解析入門（7/31 午後）

（内容は変更となる場合があります）

（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 へ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 JAMIT2022 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、JAMIT2022 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 20 日 セットアップ資料の公開

7 月 25 日 セミナー資料の公開

7 月 29～31 日 ハンズオンセミナー開催

7 月 29 日 16:10～ 課題 1

7 月 30 日 8:30～ 課題 2, 16:30～ 課題 3

7 月 31 日 8:50～ 課題 4, 14:30～ 課題 5

(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)，小田 昌宏 (名古屋大学)，滝沢 穂高 (筑波大学)，
中田 典生 (東京慈恵医科大学)

(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，東海国立大学機構医療健康データ統合研究教育拠点の協力で実施します。

13. 名古屋大学情報基盤センター スーパーコンピュータ「不老」見学会

名古屋大学情報基盤センター スーパーコンピュータ「不老」の見学会を開催します。見学時間については別途会場にてアナウンスします。

ご協力団体

本大会は下記企業及び団体にご協力いただきました。心より感謝申し上げます。

共催セミナー：株式会社 HPC テック

助成： 公益財団法人 コニカミノルタ科学技術振興財団
公益財団法人 名古屋コンベンションビューロー

企業展示： 株式会社 HPC テック
株式会社ジーデップ・アドバンス
株式会社ニューテック
富士通 Japan 株式会社
株式会社ライトストーン
菱洋エレクトロ株式会社

広告掲載： 株式会社オーム社
サイバネットシステム株式会社
デル・テクノロジーズ株式会社
西日本電信電話株式会社
浜松ホトニクス株式会社
富士フイルム株式会社
富士フイルムメディカル株式会社
株式会社モリタ製作所
株式会社ユニットコム

共 催： 名古屋大学情報基盤センター

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
日本脳神経 CI 学会
公益社団法人 日本放射線技術学会

第1日目/7月29日(金)

	第1会場 (ホール)	第2会場 (シンポジオン)	第3会場 (第1会議室)
13:00	13:00-13:10 開会式		
	13:10-16:00 チュートリアル講演会 TU「医用画像研究と一般画像研究におけるプライバシー保護」		
14:00	TU-1「人を対象とした研究を安心して進めるための処方箋」 大西 正輝		
	TU-2「臨床現場における個人情報保護に留意した医療AI開発研究」 大山 慎太郎		
15:00	TU-3「医用画像の個人情報を取り扱う企業の取り組み」 中西 隆伯 座長：滝沢 穂高		
16:00	16:10-17:30 シンポジウム 1 SY1「イメージングが切り拓く未来の医用画像工学」 西澤 典彦/山田 重人/椎名 毅/砂口 尚輝 座長：伊藤 聡志/湯浅 哲也	16:10-17:30 一般演題 1 OP1「治療支援, レジストレーション」(OP1-1~6) 座長：中口 俊哉/健山 智子	16:10-17:40 ハンズオンセミナー 1 HS1「深層学習ことばじめ：入門編」
17:00			
18:00	17:40-18:40 一般演題 2 OP2「イメージング1」(OP2-1~5) 座長：杉本 直三/吉川 悦次	17:40-18:40 一般演題 3 OP3「CAD1」(OP3-1~5) 座長：内山 良一/花岡 昇平	
19:00			

第2日目/7月30日(土)			
	第1会場(ホール)	第2会場(シンポジオン)	第3会場(第1会議室)
8:00			
9:00	8:30-9:50 一般演題4 OP4「セグメンテーション1」 (OP4-1~6) 座長:大竹 義人/村尾 晃平	8:30-9:50 一般演題5 OP5「画質改善」(OP5-1~6) 座長:中尾 恵/陳 延偉	8:30-10:00 ハンズオンセミナー 2 HS2「画像の分類と回帰」
10:00	10:00-12:00 シンポジウム 2 SY2「次の医用画像工学を切り拓くHPC と機械学習」 田浦 健次郎/原田 達也/荒牧 英 治/佐藤 真一 座長:目加田 慶人/平野 靖		
11:00			
12:00		12:10-13:10 ランチョンセミナー LS「医用画像AIの進化、普及を支えるGPU関 連テクノロジー」 山田 泰永 座長:奥山 義弘	
13:00	13:10-14:10 会員集会		
14:00	14:10-14:20 スパコン「不老」紹介		
15:00	14:20-15:20 特別講演 I SL1「限られた情報からロバストに:信頼できる 機械学習に向けて」 杉山 将 座長:森 健策		
16:00	15:30-16:50 シンポジウム 3 SY3「JAMITの未来をつくろう!」 座長:森 健策		
17:00	17:00-17:50 一般演題6 OP6「解剖構造モデル, 他」 (OP6-1~4) 座長:清水 昭伸/堀田 一弘	17:00-18:00 一般演題7 OP7「微細構造解析1」 (OP7-1~5) 座長:増谷 佳孝/鈴木 秀宣	16:30-18:00 ハンズオンセミナー 3 HS3「物体検知と領域分割」
18:00			
19:00			

第3日目/7月31日(日)

	第1会場 (ホール)	第2会場 (シンポジオン)	第3会場 (第1会議室)
8:00			
9:00	8:30-9:30 一般演題 8 OP8「経時画像解析1」 (OP8-1~5) 座長：庄野 逸/間普 真吾	8:40-9:30 一般演題 9 OP9「イメージング2」(OP9-1~4) 座長：砂口 尚輝/北村 圭司	8:50-10:20 ハンズオンセミナー 4 HS4「異常検知とフェイク画像の生成」
10:00	9:30-10:20 一般演題 10 OP10「経時画像解析2, 他」(OP10-1~4) 座長：原口 亮/畑中 裕司	9:30-10:20 一般演題 11 OP11「イメージング3, 他」(OP11-1~4) 座長：菅 幹生/森田 尚孝	
11:00	10:30-11:50 シンポジウム 4 SY4「医用画像データベースとネットワーク」 漆谷 重雄/伊藤 雅昭/明石 敏昭/黒田 知宏 座長：佐藤 嘉伸/平尾 彰浩	10:30-11:50 一般演題 12 OP12「微細構造解析2」(OP12-1~6) 座長：羽石 秀昭/本谷 秀堅	
12:00			
13:00			
14:00	13:20-14:20 特別講演 II SL2「小惑星探査機「はやぶさ2」帰還粒子の放射光CT観察から導かれる、小惑星リュウグウの形成・進化史」上相 真之 座長：工藤 博幸		
15:00	14:30-15:30 一般演題 13 OP13「CAD2」(OP13-1~5) 座長：河田 佳樹/寺本 篤司	14:30-15:30 一般演題 14 OP14「セグメンテーション2」 (OP14-1~5) 座長：小橋 昌司/中村 嘉彦	14:30-16:00 ハンズオンセミナー 5 HS5「自然言語・音声解析入門」
16:00	15:40-16:40 一般演題 15 OP15「CAD3」(OP15-1~5) 座長：木戸 尚治/野村 行弘	15:40-16:40 一般演題 16 OP16「イメージング4」(OP16-1~5) 座長：山谷 泰賢/小尾 高史	
17:00	16:40-17:30 一般演題 17 OP17「CAD4」(OP17-1~4) 座長：根本 充貴/神谷 直希	16:40-17:30 一般演題 18 OP18「イメージング5」(OP18-1~4) 座長：銭谷 勉/田島 英朗	
	17:30-17:40 閉会式		
18:00			
19:00			

特別講演

7月30日(土)

第1会場(ホール)

特別講演 1

14:20 ~ 15:20

SL1 「限られた情報からロバストに：信頼できる機械学習に向けて」

座長：森 健策 (名古屋大学)

SL1

限られた情報からロバストに：信頼できる機械学習に向けて

杉山 将

理化学研究所 革新知能統合研究センター、東京大学大学院新領域創成科学研究科

7月31日(日)

第1会場(ホール)

特別講演 2

13:20 ~ 14:20

SL2 「小惑星探査機「はやぶさ2」帰還粒子の放射光 CT 観察から
導かれる、小惑星リュウグウの形成・進化史」

座長：工藤 博幸 (筑波大学)

SL2

小惑星探査機「はやぶさ2」帰還粒子の放射光 CT 観察から導かれる、小惑星リュウグウの形成・
進化史

上栢 真之

高輝度光科学研究センター

シンポジウム

7月29日(金)

第1会場(ホール)

シンポジウム 1

16:10 ~ 17:30

SY1 「イメージングが切り拓く未来の医用画像工学」

座長：伊藤 聡志 (宇都宮大学)

湯浅 哲也 (山形大学)

SY1-1 光コヒーレンストモグラフィー (OCT) の進展

西澤 典彦

名古屋大学大学院工学研究科 電子工学専攻

SY1-2 位相コントラスト CT イメージングとヒト胚子の時系列解析

山田 重人

京都大学大学院医学研究科附属先天異常標本解析センター

SY1-3 超音波と光の融合による医用画像技術の最先端：光超音波 (photoacoustic) イメージング

椎名 毅

芝浦工業大学 SIT 総合研究所

SY1-4 あいちシンクロトロン光センター BL8S2 ビームラインに構築した X 線暗視野法に基づく屈折コントラスト CT 撮像システム

砂口 尚輝

名古屋大学大学院医学系研究科 総合保健学専攻

7月30日(土)

第1会場(ホール)

シンポジウム 2

10:00 ~ 12:00

SY2 「次の医用画像工学を切り拓く HPC と機械学習」

座長：目加田慶人 (中京大学)

平野 靖 (山口大学)

SY2-1 mdx : データ活用のためのプラットフォームと、医療データでの活用について

田浦健次朗

東京大学情報基盤センター

SY2-2 機械学習を用いた画像認識の研究動向

原田 達也

東京大学先端科学技術研究センター

SY2-3 自然言語処理による読影テキスト解析の未来
荒牧 英治
奈良先端科学技術大学院大学 先端科学技術研究科

SY2-4 機械学習によるメディア画像処理～大規模学習データセットに基づく機械学習手法の威力とその限界
佐藤 真一
国立情報学研究所

シンポジウム 3

15:30 ~ 16:50

SY3 「JAMIT の未来をつくろう！」

座長：森 健策（名古屋大学）

パネリスト 黒瀬 優介（東京大学）
杉野 貴明（東京医科歯科大学）
橘 理恵（大島商船高等専門学校）
健山 智子（藤田医科大学）
橋本二三生（浜松ホトニクス株式会社）
平川 翼（中部大学）

7月31日（日）

第1会場（ホール）

シンポジウム 4

10:30 ~ 11:50

SY4 「医用画像データベースとネットワーク」

座長：佐藤 嘉伸（奈良先端科学技術大学院大学）
平尾 彰浩（株式会社 Surg storage）

SY4-1 医用画像データの利活用を支えるネットワーク基盤 SINET6
漆谷 重雄
国立情報学研究所

SY4-2 内視鏡下手術のデータベース構築とそれがもたらしうる価値
伊藤 雅昭
国立研究開発法人国立がん研究センター東病院

SY4-3 日本医学放射線学会による画像診断ナショナルデータベース（J-MID）の開発とその発展
明石 敏昭
順天堂大学放射線診断学講座

SY4-4 医用画像データベース構築の落とし穴と活かし方
黒田 知宏
京都大学 医学部附属病院 医療情報企画部

チュートリアル講演会

7月29日(金)

第1会場(ホール)

チュートリアル講演会

13:10 ~ 16:00

TU「医用画像研究と一般画像研究におけるプライバシー保護」

座長：滝沢 穂高 (筑波大学)

TU1 人を対象とした研究を安心して進めるための処方箋
大西 正輝
産業技術総合研究所 人工知能研究センター

TU2 臨床現場における個人情報保護に留意した医療 AI 開発研究
大山慎太郎
名古屋大学 未来社会創造機構 予防早期医療創成センター

TU3 医用画像の個人情報を取り扱う企業の取り組み
中西 隆伯
株式会社ジェイマックスシステム

ハンズオンセミナー

7月29日(金)

第3会場(第1会議室)

ハンズオンセミナー1

16:10 ~ 17:40

HS1「深層学習ことはじめ：入門編」

7月30日(土)

第3会場(第1会議室)

ハンズオンセミナー2

8:30 ~ 10:00

HS2「画像の分類と回帰」

ハンズオンセミナー 3

16:30 ~ 18:00

HS3 「物体検知と領域分割」

7月31日(日)

第3会場 (第1会議室)

ハンズオンセミナー 4

8:50 ~ 10:20

HS4 「異常検知とフェイク画像の生成」

ハンズオンセミナー 5

14:30 ~ 16:00

HS5 「自然言語・音声解析入門」

ランチョンセミナー

7月30日(土)

第2会場 (シンポジオン)

12:10 ~ 13:10

LS 「医用画像 AI の進化、普及を支える GPU 関連テクノロジー」

座長：奥山 義弘 (株式会社 HPC テック)

LS 医用画像 AI の進化、普及を支える GPU 関連テクノロジー
山田 泰永
エヌビディア合同会社

7月29日(金)

第1会場(ホール)

開会式

13:00 ~ 13:10

チュートリアル講演会

13:10 ~ 16:00

TU「医用画像研究と一般画像研究におけるプライバシー保護」

座長：滝沢 穂高（筑波大学）

TU1 人を対象とした研究を安心して進めるための処方箋
大西 正輝
産業技術総合研究所 人工知能研究センター

TU2 臨床現場における個人情報保護に留意した医療 AI 開発研究
大山慎太郎
名古屋大学 未来社会創造機構 予防早期医療創成センター

TU3 医用画像の個人情報を取り扱う企業の取り組み
中西 隆伯
株式会社ジェイマックシステム

シンポジウム 1

16:10 ~ 17:30

SY1「イメージングが切り拓く未来の医用画像工学」

座長：伊藤 聡志（宇都宮大学）

湯浅 哲也（山形大学）

SY1-1 光コヒーレンストモグラフィ（OCT）の進展
西澤 典彦
名古屋大学大学院工学研究科 電子工学専攻

SY1-2 位相コントラスト CT イメージングとヒト胚子の時系列解析
山田 重人
京都大学大学院医学研究科附属先天異常標本解析センター

SY1-3 超音波と光の融合による医用画像技術の最先端：光超音波（photoacoustic）イメージング
椎名 毅
芝浦工業大学 SIT 総合研究所

- SY1-4** あいちシンクロトロン光センター BL8S2 ビームラインに構築した X 線暗視野法に基づく屈折コントラスト CT 撮像システム
砂口 尚輝
名古屋大学大学院医学系研究科 総合保健学専攻

一般演題 2

17:40 ~ 18:40

OP2 「イメージング 1」

座長：杉本 直三（京都大学）
吉川 悦次（浜松ホトニクス株式会社）

- OP2-1** 位相拡散フーリエ撮像法におけるセグメント信号収集を用いた MR 圧縮センシング
山登 一輝¹, 大水 望¹, 伊藤 聡志¹
¹ 宇都宮大学工学部基盤工学科
- OP2-2** 実関数 CNN を利用した MR 位相画像の深層学習再構成
深津 純奈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
- OP2-3** Deep image prior を用いたリストモード PET 画像再構成
大手 希望¹, 橋本二三生¹, 大西 佑弥¹, 磯部 卓志¹
¹ 浜松ホトニクス株式会社 中央研究所 第 5 研究室
- OP2-4** 圧縮センシングを用いたフォトンカウンティング CT のスペクトル歪み補正
村田 一心¹, 尾川 浩一²
¹ 国立天文台, ² 法政大学 理工学部
- OP2-5** 学習データを用いた低線量 CT 逐次近似画像再構成の正則化パラメータ自動決定
工藤 博幸
筑波大学システム情報系情報工学域

7月29日(金)

第 2 会場 (シンポジオン)

一般演題 1

16:10 ~ 17:30

OP1 「治療支援, レジストレーション」

座長：中口 俊哉（千葉大学）
健山 智子（藤田医科大学）

- OP1-1** Geometric Matching CNN による指骨 CR 画像の位置合わせ手法
小野 輝¹, 神谷 亨¹, 青木 隆敏²
¹ 九州工業大学大学院工学研究院機械知能工学系知能制御工学, ² 産業医科大学
- OP1-2** 放射線治療における膀胱変位推定の為の 2D 断層画像駆動型複数臓器接触シミュレーション
原 裕貴¹, 角谷 倫之², 三目 直登³, 家永 直人³, 梅澤 玲², 神宮 啓一², 黒田 嘉宏³
¹ 筑波大学大学院 システム情報工学研究群, ² 東北大学大学院 医学系研究科, ³ 筑波大学 システム情報系

- OP1-3** 内視鏡動画解析による所見作成支援に向けた臓器判別
梅津 泉梨¹, 藤江 舞², 野村 行弘³, 加藤 順⁴, 中口 俊哉³
¹千葉大学大学院融合理工学府基幹工学専攻医工学コース, ²千葉大学医学部附属病院臨床工学センター, ³千葉大学フロンティア医工学センター, ⁴千葉大学医学部附属病院内視鏡センター
- OP1-4** GNNによる血管名自動命名手法における臓器特徴の利用に関する検討
出口 智也¹, 林 雄一郎¹, 北坂 孝幸², 小田 昌宏^{3,1}, 三澤 一成⁴, 森 健策^{1,5,6}
¹名古屋大学大学院情報学研究科, ²愛知工業大学情報科学部, ³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 消化器外科, 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
- OP1-5** X線透視画像内のデバイスを対象とした深層学習セグメンテーションモデルのための効率的な学習データ作成手法についての検討
鈴木 皓士¹, 菊池 洋平¹, 吉原 陽平¹, 松原 佳亮², 大村 知己², 木下 俊文², 松山 成男¹
¹東北大学 工学研究科 量子エネルギー工学専攻, ²秋田県立循環器・脳脊髄センター(研究所)
- OP1-6** 気管支内視鏡生検支援向け処置具3次元位置認識法における機械学習を用いた精度改善
松崎 和喜¹, 山川 恵介¹, 飯村 隆志¹, 松元 祐司², 田中 緑², 長島千恵子³, 麻生 智彦³
¹富士フィルムヘルスケア, ²国立がん研究センター中央病院内視鏡科, ³国立がん研究センター中央病院放射線技術部

一般演題 3

17:40 ~ 18:40

OP3 「CAD1」

座長：内山 良一（熊本大学）

花岡 昇平（東京大学）

- OP3-1** 画質改善処理による乳がん腫瘍影の良悪性鑑別 CAD の性能向上
工藤 颯馬¹, 安倍 和弥¹, 武尾 英哉¹, 永井 優一², 縄野 繁³
¹神奈川工科大学, ²国立がん研究センター東病院, ³松戸中央総合病院
- OP3-2** 深層学習を用いた肘関節超音波画像における OCD 診断支援
佐々木研太¹, 藤田 大輔¹, 高辻 謙太², 琴浦 義浩², 南 昌孝², 小林 雄輔², 祐成 毅², 木田 圭重², 小橋 昌司¹
¹兵庫県立大学, ²京都府立医科大学
- OP3-3** 骨シンチグラムの陽性高集積検出システムにおける市販後学習
藤本 啓輔¹, 大崎 洋充², 東山 滋明³, 河邊 譲治³, 中岡 竜介⁴, 清水 昭伸¹
¹東京農工大学大学院工学研究院, ²群馬県立県民健康科学大学大学院診療放射線学研究科, ³大阪市立大学医学部附属病院核医学科, ⁴国立医薬品食品衛生研究所医療機器部
- OP3-4** 3D-Alpha-WGAN の正常症例学習モデルを用いた FDG-PET 画像における異常集積の自動検出
内田 卓妙¹, 原 武史², 周 向榮², 片渕 哲朗³, 野崎 太希⁴, 松迫 正樹⁴, 藤田 広志²
¹岐阜大学大学院自然科学技術研究科知能理工学専攻, ²岐阜大学工学部電気電子・情報工学科, ³岐阜医療科学大学保健科学部, ⁴聖路加国際病院放射線科
- OP3-5** Memory-attention に基づくハイブリッドモデルによる不均衡データを用いたくも膜下出血 CT 画像分類
魯 仲陽¹, 小田 昌宏^{2,1}, 林 雄一郎¹, 胡 涛¹, 伊東 隼人¹, 渡谷 岳行³, 阿部 修³, 森 健策^{1,4,5}
¹名古屋大学大学院情報学研究科, ²名古屋大学情報連携推進本部情報戦略室, ³東京大学医学部附属病院放射線科, ⁴名古屋大学情報基盤センター, ⁵国立情報学研究所 医療ビッグデータ研究センター

ハンズオンセミナー1

16:10 ~ 17:40

HS1 「深層学習ことはじめ：入門編」

一般演題 4

8:30 ~ 9:50

OP4 「セグメンテーション1」

座長：大竹 義人 (奈良先端科学技術大学院大学)

村尾 晃平 (国立情報学研究所)

- OP4-1** 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
大野 真奈¹, 申 忱¹, Holger R. Roth², 小田 昌宏¹, 林 雄一郎¹, 三澤 一成³, 森 健策¹
¹名古屋大学大学院情報学研究所, ²NVIDIA Corporation, ³愛知がんセンター
- OP4-2** PET/CT 画像を用いた多臓器自動抽出に関する初期的検討
菅沼 雄太¹, 寺本 篤司¹, 齋藤 邦明¹, 藤田 広志², 鈴木 裕紀³, 富山 憲幸⁴, 木戸 尚治³
¹藤田医科大学大学院 保健学研究科, ²岐阜大学 工学部, 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, ⁴大阪大学大学院 医学系研究科 放射線医学教室
- OP4-3** U-Net を用いた頸部 X 線動画からの椎体・棘突起の抽出に関する基礎的検討
塩田 紘司¹, 目片幸二郎², 滝沢 穂高¹, 工藤 博幸¹
¹筑波大学, ²四條畷学園大学
- OP4-4** 体幹部 CT 画像における 2D U-Net を用いた体腔の同時学習による腰方形筋の自動認識
川本 真大¹, 神谷 直希¹, 周 向榮², 加藤 博基³, 原 武史^{2,4}, 藤田 広志²
¹愛知県立大学情報科学部, ²岐阜大学工学部, ³岐阜大学大学院医学系研究科放射線医学分野, ⁴東海国立大学機構医療健康データ統合研究教育拠点
- OP4-5** Erosion Consistency Training for Semi-Supervised CT Segmentation of COVID-19
柳 凱¹, 小田 昌宏^{2,1}, 鄭 通¹, 林 雄一郎¹, 大竹 義人^{3,4}, 橋本 正弘⁵, 明石 敏昭⁶, 青木 茂樹⁶, 森 健策^{1,2,4}
¹名古屋大学大学院情報学研究所, 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国立情報学研究所医療ビッグデータ研究センター, ⁵慶応義塾大学医学部放射線科, ⁶順天堂大学医学部放射線医学講座
- OP4-6** 光コヒーレンストモグラフィー画像からの 3次元血管構造の抽出
岡村 宙輝¹, 岡本 尚之¹, 羽石 秀昭²
¹千葉大学大学院融合理工学府基幹工学専攻医工学コース, ²千葉大学フロンティア医工学センター

シンポジウム 2

10:00 ~ 12:00

SY2 「次の医用画像工学を切り拓く HPC と機械学習」

座長：目加田慶人 (中京大学)

平野 靖 (山口大学)

- SY2-1** mdx : データ活用のためのプラットフォームと, 医療データでの活用について
田浦健次朗
東京大学情報基盤センター

SY2-2 機械学習を用いた画像認識の研究動向

原田 達也
東京大学先端科学技術研究センター

SY2-3 自然言語処理による読影テキスト解析の未来

荒牧 英治
奈良先端科学技術大学院大学・先端科学技術研究科

SY2-4 機械学習によるメディア画像処理～大規模学習データセットに基づく機械学習手法の威力とその限界

佐藤 真一
国立情報学研究所

会員集会

13:00 ~ 14:10

スパコン「不老」紹介

14:10 ~ 14:20

特別講演 1

14:20 ~ 15:20

SL1 「限られた情報からロバストに：信頼できる機械学習に向けて」

座長：森 健策（名古屋大学）

SL1 限られた情報からロバストに：信頼できる機械学習に向けて

杉山 将
理化学研究所 革新知能統合研究センター、東京大学大学院新領域創成科学研究科

シンポジウム 3

15:30 ~ 16:50

SY3 「JAMIT の未来をつくろう！」

座長：森 健策（名古屋大学）

パネリスト 黒瀬 優介（東京大学）
杉野 貴明（東京医科歯科大学）
橘 理恵（大島商船高等専門学校）
健山 智子（藤田医科大学）
橋本二三生（浜松ホトニクス株式会社）
平川 翼（中部大学）

一般演題 6

17:00 ~ 17:50

OP6 「解剖構造モデル, 他」

座長：清水 昭伸 (東京農工大学)

堀田 一弘 (名城大学)

OP6-1 ヒト胚子の脳の空間的に隣接する複数器官を対象とした統計的形狀モデル

近嵐 尚¹, 高桑 徹也², 山田 重人², 清水 昭伸¹

¹東京農工大学大学院工学研究院, ²京都大学 大学院医学研究科

OP6-2 白質信号自動解析の再現性に関する評価

高橋 哲彦¹, 大川 竜也^{1,2}, 林 則夫¹, 丁嵐 亮¹

¹群馬県立県民健康科学大学大学院 診療放射線学研究科, ²公益財団法人脳血管研究所附属美原記念病院 画像診断課

OP6-3 大規模 CT 画像データベースを用いた骨格ランドマークによる下肢骨格形状の加齢変化解析

下元 悠我¹, 箱谷 知輝¹, 大竹 義人¹, スーフィーマーゼン¹, 政木 勇人¹, 上村 圭亮², 高尾 正樹³, 宮本 拓馬⁴, 田中 康仁⁴, 菅野 伸彦², 佐藤 嘉伸¹

¹奈良先端科学技術大学院大学, ²大阪大学大学院医学系研究科, ³愛媛大学大学院医学系研究科, ⁴奈良県立医科大学

OP6-4 テンソル分解を用いた黒質緻密部の 3 次元パターン表現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, 服部 信孝³, 鎌形 康司³, 青木 茂樹³, 森 健策^{1,2,4,5}

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順天堂大学 医学部, ⁴名古屋大学 情報基盤センター, ⁵国立情報学研究所 医療ビッグデータ研究センター

7月30日(土)

第2会場 (シンポジオン)

一般演題 5

8:30 ~ 9:50

OP5 「画質改善」

座長：中尾 恵 (京都大学)

陳 延偉 (立命館大)

OP5-1 MR マルチスライス撮像におけるパラレルブラインドデノイズの性能改善

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

OP5-2 Pix2Pix コンディショナル GAN による頭部 MRI のモーションアーチファクトの改善

白井 桂介¹, 室 伊三男², 渋谷 周平¹, 尾川 浩一³, 後藤 政実¹, 坂野 康昌¹, 京極 伸介¹, 代田 浩之¹

¹順天堂大学保健医療学部診療放射線学科, ²無所属, ³法政大学理工学部

OP5-3 教師なし PET 画像ノイズ除去における事前学習済モデルの有用性

大西 佑弥¹, 橋本二三生¹, 大手 希望¹

¹浜松ホトニクス株式会社 中央研究所

OP5-4 MR エラストグラフィにおける腹壁運動に伴うモーションアーチファクトの低減法
菅 幹生¹, 小賀野 慎¹, 谷口 陽^{1,2}, 西原 崇², 瀧澤 将宏²
¹千葉大学, ²富士フィルムヘルスケア株式会社

OP5-5 Cycle GAN を用いた前立腺癌患者における仮想造影 MR 画像合成
平川 勇也¹, 有村 秀孝², 崔 雲昊¹, 高山 幸久³, 西江 昭弘⁴, 石神 康生⁵
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福岡大学医学部 放射線医学教室, ⁴琉球大学大学院 医学研究科 放射線診断治療学講座, ⁵九州大学大学院 医学研究院 臨床放射線科

OP5-6 頭部 PET 体動補正のための大きな動きに対応したマーカレスモーショントラッキングシステムの開発
岩男 悠真¹, 赤松 剛¹, 田島 英朗¹, 高橋美和子¹, 山谷 泰賀¹
¹量子科学技術研究開発機構 量子医科学研究所 先進核医学基盤研究部 イメージング物理研究グループ

ランチョンセミナー

12:10 ~ 13:10

LS 「医用画像 AI の進化、普及を支える GPU 関連テクノロジー」

座長：奥山 義弘（株式会社 HPC テック）

LS 医用画像 AI の進化、普及を支える GPU 関連テクノロジー
山田 泰永
エヌビディア合同会社

一般演題 7

17:00 ~ 18:00

OP7 「微細構造解析 1」

座長：増谷 佳孝（広島市立大学）
鈴木 秀宣（徳島大学）

OP7-1 深層学習に基づく共焦点顕微鏡画像超解像
呉 運恒¹, 小田 昌宏^{2,1}, 林 雄一郎¹, 武部 貴則^{3,4,5}, 長田 翔伍⁶, 河村峻太郎⁷, 森 健策^{1,8,9}
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東京医科歯科大学統合研究機構, ⁴Division of Gastroenterology, Hepatology and Nutrition, Developmental Biology, and Center for Stem Cell and Organoid Medicine (CuSTOM), Cincinnati Children's Hospital Medical Center, ⁵Department of Pediatrics, College of Medicine, University of Cincinnati, ⁶慶應義塾大学医学部外科学, ⁷東京医科歯科大学医歯学総合研究科, ⁸名古屋大学情報基盤センター, ⁹国立情報学研究所医療ビッグデータ研究センター

OP7-2 悪性リンパ腫細胞核画像の低次元表現獲得と特徴の集合に基づくサブタイプ識別器の構築
小出 新悟¹, 橋本 典明², 横田 達也¹, クグレマウリシオ¹, 大島 孝一³, 三好 寛明³, 永石 美晴³, 竹内 一郎¹, 本谷 秀堅¹
¹名古屋工業大学, ²理化学研究所, ³久留米大学 医学部 病理学講座

OP7-3 X線暗視野撮像法で描出される篩状型非浸潤性乳管癌の悪性度に着目した腺腔の解析
吉田 匠¹, 砂口 尚輝², 谷口 華奈², 黄 卓然², 島雄 大介³, 西村理恵子⁴, 岩越 朱里⁴,
市原 周⁴, 湯浅 哲也⁵, 安藤 正海⁶
¹名古屋大学医学部保健学科放射線技術科学専攻, ²名古屋大学大学院医学系研究科総合保健学専攻, ³
北海道科学大学保健医療学部診療放射線学科, ⁴名古屋医療センター病理診断科, ⁵山形大学大学院理
工学研究科, ⁶高エネルギー加速器研究機構

OP7-4 マルチモーダルゲーティングを用いた Mixture of Experts による病理画像分類
橋本 典明¹, 高木 優介², 増田 大輝², 三好 寛明³, 高野 桂³, 永石 美晴³, 佐藤 健作³,
大島 孝一³, 本谷 秀堅², 竹内 一郎^{1,2}
¹理化学研究所, ²名古屋工業大学, ³久留米大学

OP7-5 色素性皮膚病変のハイパースペクトル画像で探索的データ分析
アルポヤニエレニ¹, 市村 孝也², 浜田 芽衣², 村上 拓生³, 佐々木 惇², 中村晃一郎³, 石川 正弘⁴,
小林 直樹⁴, 小尾 高史⁵
¹東京工業大学 工学院 情報通信系, ²埼玉医科大学医学部中央病理診断部・病理診断科, ³埼玉医科大
学医学部皮膚科, ⁴埼玉医科大学 保健医療学部, ⁵東京工業大学 科学技術創成研究院 未来産業技術研
究所

7月30日(土)

第3会場 (第1会議室)

ハンズオンセミナー2

8:30 ~ 10:00

HS2 「画像の分類と回帰」

ハンズオンセミナー3

16:30 ~ 18:00

HS3 「物体検知と領域分割」

一般演題 8

8:30 ~ 9:30

OP8 「経時画像解析 1」

座長：庄野 逸 (電気通信大学)

間普 真吾 (山口大学)

- OP8-1** ICI 治療の NSCLC 患者における肺腫瘍細胞数の経時変化曲線の推定
内野 恭美¹, 有村 秀孝², 田中謙太郎³, 藪内 英剛²
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
医用量子線科学分野, ³九州大学大学院医学研究院呼吸器内科学分野
- OP8-2** 胸部 X 線画像および診断構造化ラベルを用いた機械学習による急性呼吸窮迫症候群 (ARDS) 患者の早期死亡予測
齊藤 幸喜
帝京科学大学・生命環境学部・生命科学科
- OP8-3** トポロジー画像解析による体幹部定位放射線治療を受けたステージ I 非小細胞肺癌患者の進行予測
兒玉 拓巳¹, 有村 秀孝², 二宮 健太¹, 白川 友子³, 吉武 忠正², 塩山 善之⁴
¹九州大学大学院医学系学府保健学専攻, ²九州大学医学研究院保健学部門, ³国立病院機構 九州がんセンター, ⁴九州国際重粒子線がん治療センター
- OP8-4** 3DCNN を用いた MR 画像における前立腺癌患者の術後尿禁制予測
大羽 史晃¹, 寺本 篤司¹, 住友 誠², 中村 渉²
¹藤田医科大学大学院 保健学研究科, ²藤田医科大学 医学部
- OP8-5** 深層学習を用いた小児脳 CT 画像からの脳年齢自動推定と Grad-Cam による注目箇所の可視化
森田 蓮¹, 安藤 沙耶², 藤田 大輔¹, 石川 翔³, 尾上 宏治³, 安藤久美子³, 石蔵 礼一³,
小橋 昌司¹
¹兵庫県立大学 大学院 工学研究科, ²兵庫県立尼崎総合医療センター, ³神戸市立医療センター中央市民病院

一般演題 10

9:30 ~ 10:20

OP10 「経時画像解析 2, 他」

座長：原口 亮 (兵庫県立大学)

畑中 裕司 (大分大学)

- OP10-1** 敗血症モデルラットの微小循環動画像に対する血管密度解析
田口 竣也¹, 川崎 真未¹, 羽石 秀昭²
¹千葉大学大学院融合理工学府基幹工学専攻医工学コース, ²千葉大学フロンティア医工学センター
- OP10-2** 動画像解析を用いた脳卒中中の病院前診断における顔面麻痺の自動評価
生澤 直樹¹, 吉田 陽一², 栗原 聡³, 中田 孝明², 羽石 秀昭⁴
¹千葉大学大学院融合理工学府, ²千葉大学大学院医学研究院, ³神戸市立総合医療センター脳神経外科,
⁴千葉大学フロンティア医工学センター

OP10-3 ダーモカメラ画像を用いたシワ・キメの特徴解析
浅野 祐太¹, 西澤 巧¹, 梶田 大樹², 石井 龍之², 貴志 和生², 佐藤いまり¹
¹ 国立情報学研究所 コンテンツ科学研究系, ² 慶應義塾大学 医学部

OP10-4 異なるモダリティによって撮像された医用画像の相同性評価
小林麟太郎¹, 原 武史², 周 向荣², 野崎 太希³, 松迫 正樹³, 藤田 広志²
¹ 岐阜大学院自然科学技術研究科, ² 岐阜大学工学部, ³ 聖路加国際病院放射線科

シンポジウム 4

10:30 ~ 11:50

SY4 「医用画像データベースとネットワーク」

座長：佐藤 嘉伸（奈良先端科学技術大学院大学）

平尾 彰浩（株式会社 Surg storage）

SY4-1 医用画像データの利活用を支えるネットワーク基盤 SINET6
漆谷 重雄
国立情報学研究所

SY4-2 内視鏡下手術のデータベース構築とそれがもたらしうる価値
伊藤 雅昭
国立研究開発法人国立がん研究センター東病院

SY4-3 日本医学放射線学会による画像診断ナショナルデータベース（J-MID）の開発とその発展
明石 敏昭
順天堂大学放射線診断学講座

SY4-4 医用画像データベース構築の落とし穴と活かし方
黒田 知宏
京都大学 医学部附属病院 医療情報企画部

特別講演 2

13:20 ~ 14:20

SL2 「小惑星探査機「はやぶさ2」帰還粒子の放射光 CT 観察から導かれる、小惑星リュウグウの形成・進化史」

座長：工藤 博幸（筑波大学）

SL2 小惑星探査機「はやぶさ2」帰還粒子の放射光 CT 観察から導かれる、小惑星リュウグウの形成・進化史
上楯 真之
高輝度光科学研究センター

一般演題 13

14:30 ~ 15:30

OP13 「CAD2」

座長：河田 佳樹（徳島大学）

寺本 篤司（藤田医科大学）

OP13-1 Deep Auto Encoder を用いた眼底画像からの糖尿病性網膜症の判別

安倍 和弥¹, 武尾 英哉¹, 永井 優一², 高橋 嘉晴³

¹ 神奈川工科大学, ² 国立がん研究センター東病院, ³ たかはし眼科クリニック

OP13-2 機械学習による白色上皮領域検出におけるコルポスコプ画像の実験的検討

篠原 寿広¹, 小林 陽輝¹, 村上 幸祐², 中迫 昇¹, 松村 謙臣²

¹ 近畿大学生物理工学部生命情報工学科, ² 近畿大学医学部産科婦人科学教室

OP13-3 正例とラベル無し画像からの学習による子宮頸部病変の識別

マナロマーガレット デイ¹, 青木 工太¹, 武 淑瓊¹, 新堂真利子², 上田 豊², 八木 康史¹

¹ 大阪大学 産業科学研究所 複合知能メディア研究分野, ² 大阪大学 大学院医学系研究科 産科婦人科学教室

OP13-4 補綴物検出を用いた歯科パノラマ画像の歯牙認識性能の向上

岡 和範¹, 新居 学¹, 藤田 大輔¹, 小橋 昌司¹

¹ 兵庫県立大学大学院 工学研究科

OP13-5 多施設からの眼底画像における緑内障の重症度推定

村尾 晃平¹, 佐藤 真一¹, 大本 貴士^{1,4}, 柏木 賢治², 三宅 正裕³, 二宮洋一郎¹

¹ 国立情報学研究所 医療ビッグデータ研究センター, ² 山梨大学 大学院総合研究部 医学部 眼科学, ³ 京都大学大学院 医学研究科 眼科学, ⁴ 東京大学大学院 医学系研究科 眼科学教室

一般演題 15

15:40 ~ 16:40

OP15 「CAD3」

座長：木戸 尚治（大阪大学）

野村 行弘（千葉大学）

OP15-1 臨床情報を加えた改良型 ResNet による CT 画像からの結節状陰影の識別

本田 直也¹, 鈴木 裕紀², 神谷 亨¹, 木戸 尚治²

¹ 九州工業大学大学院工学研究院機械知能工学系知能制御工学, 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

OP15-2 Vision Transformer を用いた胸部 X 線画像の画像分類による COVID-19 の診断

伴 凌輔¹, 原田 恵雨¹, 中村 嘉彦¹, 三上 剛¹

¹ 苫小牧工業高等専門学校

OP15-3 LPC と HPSS を用いた呼吸音の自動分類

田端 愛美¹, 陸 慧敏¹, 神谷 亨¹, 間普 真吾², 木戸 尚治³

¹ 九州工業大学, ² 山口大学, ³ 大阪大学

OP15-4 悪性・良性腎腫瘍鑑別のための多時相造影 CT 画像データベース作成
西岡 大¹, 西平 健斗¹, 鈴木 秀宣², 松廣 幹雄², 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理工学専攻, ²徳島大学大学院社会産業理工学研究部, ³東京女子医
科大学病院, ⁴筑波大学, ⁵徳島大学発ベンチャー企業医用科学研究所

OP15-5 3次元 CT 画像によるじん肺の重症度別粒状影解析
橋本 悠雅¹, 松廣 幹雄¹, 鈴木 秀宣¹, 河田 佳樹¹, 大塚 義紀², 岸本 卓巳³, 芦澤 和人⁴,
仁木 登⁵
¹徳島大学, ²北海道中央労災病院, ³岡山ろうさい病院, ⁴長崎大学, ⁵株式会社医用科学研究所

一般演題 17

16:40 ~ 17:30

OP17 「CAD4」

座長：根本 充貴 (近畿大学)

神谷 直希 (愛知県立大学)

OP17-1 Faster-R-CNN を用いた胸部 X 線像における肺結節の検出
韓 磊¹, 平野 靖²
¹山口大学大学院創成科学研究科, ²山口大学医学部附属病院

OP17-2 Supervised Contrastive Learning を用いた胸部 CT 画像におけるびまん性肺疾患の陰影識別
森崎 幹也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

OP17-3 Contrastive Learning に基づく次元削減による胸部 CT 画像に対する異常検知
飛世 裕貴¹, クグレマウリシオ¹, 横田 達也¹, 橋本 正弘², 大竹 義人³, 明石 敏昭⁴, 清水 昭伸⁵,
本谷 秀堅¹
¹名古屋工業大学, ²慶應義塾大学, ³奈良先端科学技術大学院大学, ⁴順天堂大学, ⁵東京農工大学

OP17-4 アノテーションが不完全な教師データを用いた腹部超音波画像からの肝腫瘍検出
池田 裕亮¹, 道満 恵介¹, 目加田慶人¹, 西田直生志², 工藤 正俊²
¹中京大学大学院工学研究科, ²近畿大学医学部

閉会式

17:30 ~ 17:40

一般演題 9

8:40 ~ 9:30

OP9 「イメージング 2」

座長：砂口 尚輝 (名古屋大学)

北村 圭司 (株式会社 島津製作所)

OP9-1 MR 深層学習再構成における MR 画像特徴を利用した学習時とテスト時のデータ拡張の有効性に関する検討

大内 翔平^{1,2}, 伊藤 聡志¹¹ 宇都宮大学大学院 工学研究科 システム創成工学専攻, ² 日本学術振興会特別研究員 DC

OP9-2 Whole Gamma Imaging による ⁸⁹Zr 撮像において 909keV コンプトンイメージングが PET の空間分解能を超える可能性

田島 英朗¹, 田久 創大¹, 錦戸 文彦¹, 菅 幹生², 赤松 剛¹, 高橋美和子¹, 山谷 泰賀¹¹ 量子科学技術研究開発機構, ² 千葉大学

OP9-3 Deep Image Prior を用いた SPECT 画像再構成における EM-TV アルゴリズムの検討

矢部 暁登¹, 松原 佳亮², 越野 一博³, 渡部 浩司⁴, 湯浅 哲也⁵, 銭谷 勉¹¹ 弘前大学大学院理工学研究科, ² 秋田県立循環器・脳脊髄センター研究所脳血管研究センター放射線医学研究部, ³ 北海道情報大学経営情報学部システム情報学科, ⁴ 東北大学サイクロトロン・ラジオアイソトープセンター, ⁵ 山形大学大学院理工学研究科

OP9-4 Dual Energy 散乱線補正と高感度マルチピンホールによる蛍光 X 線 CT の画質改善

對馬 結太¹, 松岡 将宏², 笹谷 典太², 砂口 尚輝³, 河嶋 秀和⁴, 兵藤 一行⁵, 湯浅 哲也², 銭谷 勉¹¹ 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 名古屋大学 大学院医学系研究科, ⁴ 京都薬科大学 放射性同位元素研究センター, ⁵ 高エネルギー加速器研究機構 物質構造科学研究所

一般演題 11

9:30 ~ 10:20

OP11 「イメージング 3, 他」

座長：菅 幹生 (千葉大学)

森田 尚孝 (株式会社 島津製作所)

OP11-1 データ・カルテシステム (SAKAS) の構築とマイクロ・位相 CT への適用

米山 明男^{1,3}, 河本 正秀¹, 馬場 理香^{1,2}, 廣沢 一郎¹, 妹尾与志木¹, 兵藤 一行³, 平野 馨一³¹ 九州シンクロトロン光研究センター, ² (株) 日立製作所研究開発グループ, ³ 高エネルギー加速器研究機構物質構造科学研究所

OP11-2 A reconstruction method for binary limited-data tomography using a dictionary-based sparse shape recovery

ハイサムアリ¹, 藤井 克哉², 工藤 博幸²¹ 筑波大学 大学院 システム情報工学研究群 情報理工学位プログラム, ² 筑波大学システム情報系

OP11-3 Whole Gamma Imaging 試作機のシミュレーションによる性能予測
菊地 智也¹, 田久 創大², 菅 幹生¹, 田島 英朗², 錦戸 文彦², 山谷 泰賀²
¹千葉大学, ²量研機構

OP11-4 診療放射線技師教育のための考察型教育用ファントムを用いた教育
近藤 啓介
駒澤大学 医療健康科学部

一般演題 12

10:30 ~ 11:50

OP12 「微細構造解析 2」

座長：羽石 秀昭 (千葉大学)

本谷 秀堅 (名古屋工業大学)

OP12-1 病理画像のガンらしさと正常らしさを情報量で評価する情報密度可視化法
金道 敏樹¹, 陸田 駿弥¹, 山田 壮亮²
¹金沢工業大学工学部情報工学科, ²金沢医科大学臨床病理学

OP12-2 Graph Neural Network による悪性リンパ腫のサブタイプ識別と識別根拠となる細胞核の可視化
田中 寛武¹, 橋本 典明², 横田 達也¹, クグレマウリシオ¹, 大島 孝一³, 三好 寛明³, 永石 美晴³,
竹内 一郎¹, 本谷 秀堅¹
¹名古屋工業大学, ²理化学研究所, ³久留米大学 医学部 病理学講座

OP12-3 細胞を注視する口腔細胞診画像分類
武田 啓太¹, 藤原 航平¹, 松尾 和希¹, 見立 英史², 酒井 智弥¹
¹長崎大学工学研究科, ²長崎大学医歯薬総合研究科

OP12-4 肺細胞で事前学習された畳み込みニューラルネットワークを用いた尿細胞の自動分類
道場 彩乃¹, 寺本 篤司², 桐山 諭和^{1,3}, 櫻井 映子¹, 塚本 徹哉¹
¹藤田医科大学大学院 医学系研究科, ²藤田医科大学大学院 保健学研究科, ³成田記念病院

OP12-5 ホールスライド画像を用いた特発性間質性肺炎の病型自動分類
寺本 篤司¹, 道場 彩乃², 桐山 諭和^{2,3}, 櫻井 映子², 塚本 徹哉², 今泉和良^{*2}, 齋藤 邦明¹, 藤田 広志⁴
¹藤田医科大学大学院 保健学研究科, ²藤田医科大学大学院 医学系研究科, ³成田記念病院, ⁴岐阜大学 工学部

OP12-6 U-Net を用いた大視野顕微放射光 CT の肺 3 次元ミクロ画像の肺胞壁抽出
栗田 陽生¹, 河田 佳樹¹, 鈴木 秀宣¹, 梅谷 啓二², 中野 恭幸³, 阪井 宏彰⁴, 岡本 俊宏⁵, 仁木 登⁶
¹徳島大学大学院, ²(公財)高輝度光科学研究センター, ³滋賀医科大学, ⁴兵庫県立尼崎総合医療センター, ⁵クリーブランドクリニック心臓・血管研究所, ⁶株式会社医用科学研究所

一般演題 14

14:30 ~ 15:30

OP14 「セグメンテーション 2」

座長：小橋 昌司（兵庫県立大学）

中村 嘉彦（苫小牧工業高等専門学校）

OP14-1 U-Net を用いた頭部 MRI からの舌領域自動抽出に関する研究

手塚 健太¹, 中村 嘉彦², 三上 剛², 米澤 一也³

¹ 国立高等専門学校機構苫小牧工業高等専門学校 創造工学専攻, ² 国立高等専門学校機構苫小牧工業高等専門学校 創造工学科, ³ 国立病院機構横浜病院臨床研究部

OP14-2 畳み込みニューラルネットワークを用いた頭部 MRI からの舌の自動輪郭抽出に関する研究

加藤 優弥¹, 中村 嘉彦², 三上 剛², 米澤 一也³

¹ 国立高等専門学校機構苫小牧工業高等専門学校 創造工学専攻, ² 国立高等専門学校機構苫小牧工業高等専門学校 創造工学科, ³ 国立病院機構函館病院臨床研究部

OP14-3 3D 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検討

平岡 大季¹, 西本紘嗣郎², 滝沢 穂高¹, 工藤 博幸¹

¹ 筑波大学, ² 埼玉医科大学国際医療センター 泌尿器腫瘍科

OP14-4 Expanded tube attention module を用いた tubular structure segmentation

加藤 聡太¹, 堀田 一弘²

¹ 名城大学大学院理工学研究科, ² 名城大学理工学部

OP14-5 カラー腹腔鏡符号化画像のセマンティックセグメンテーションにおける評価に関する基礎的検討

河畑 則文¹, 中口 俊哉²

¹ 北海道大学数理・データサイエンス教育研究センター, ² 千葉大学フロンティア医工学センター

一般演題 16

15:40 ~ 16:40

OP16 「イメージング 4」

座長：山谷 泰賀（量子科学技術研究開発機構）

小尾 高史（東京工業大学）

OP16-1 Encoder-decoderCNN を用いたパッチベース型 MR 画像再構成に関する検討

佐藤 裕貴¹, 山登 一輝¹, 大内 翔平¹, 伊藤 聡志¹

¹ 宇都宮大学 大学院 地域創生科学研究科

OP16-2 フレネル変換画像のアンサンブル学習による MR 圧縮センシング再構成の性能改善

阿部 真弥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

OP16-3 インテリア CT 画像再構成の新しい厳密解法と究極の高精度解法の提案

工藤 博幸

筑波大学システム情報系情報工学域

OP16-4 スペクトラルフォトンカウンティング CT の高速な統計的画像再構成法

金 喜正¹, 賈 澤娜¹, 工藤 博幸²

¹ 筑波大学 大学院 システム情報工学研究群 情報理工学位プログラム, ² 筑波大学 システム情報系情報工学域 教授

- OP16-5** 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
賈 澤娜¹, 金 喜正¹, 工藤 博幸²
¹筑波大学 大学院 システム情報工学研究群 情報理工学位プログラム, ²筑波大学 システム情報系

一般演題 18

16:40 ~ 17:30

OP18 「イメージング 5」

座長：銭谷 勉 (弘前大学)
田島 英朗 (量子科学技術研究開発機構)

- OP18-1** 深層学習を用いたマルチピンホール SPECT システムにおけるオーバーラップ投影データの分離
山口 恭平¹, 尾川 浩一¹
¹法政大学大学院 理工学研究科
- OP18-2** 静止型マルチピンホール SPECT の空間分解能改善：投影画像上における点拡がり関数の逆畳み込み
村田 一心¹, 大越 迪², 山田 桃夏², 尾川 浩一³
¹国立天文台, ²法政大学大学院 理工学研究科, ³法政大学 理工学部
- OP18-3** 深層学習を用いたピンホール SPECT システムにおける空間分解能の改善
島田 良¹, 村田 一心², 尾川 浩一³
¹法政大学大学院理工学研究科, ²国立天文台, ³法政大学理工学部
- OP18-4** 順投影モデルを利用した Deep image prior ベース P E T 画像再構成
橋本二三生¹, 大手 希望¹, 大西 佑弥¹, 田島 英朗², 山谷 泰賀²
¹浜松ホトニクス株式会社中央研究所, ²量子科学技術研究開発機構量子医科学研究所

7月31日(日)

第3会場 (第1会議室)

ハンズオンセミナー 4

8:50 ~ 10:20

HS4 「異常検知とフェイク画像の生成」

ハンズオンセミナー 5

14:30 ~ 16:00

HS5 「自然言語・音声解析入門」

7月29日(金)

第1会場(ホール)

チュートリアル講演会

13:10 ~ 16:00

TU「医用画像研究と一般画像研究におけるプライバシー保護」

座長：滝沢 穂高(筑波大学)

TU1 人を対象とした研究を安心して進めるための処方箋

○大西 正輝

産業技術総合研究所 人工知能研究センター

人を対象とした研究は個人情報保護法といった法律遵守の問題やプライバシーといった権利の問題、炎上のリスクなどを抱えており年々研究を進めるための手続きが煩雑化している。

本講演では人を対象とした画像認識の研究を進める際に注意をしていることを事例を含めながら紹介する。

TU2 臨床現場における個人情報保護に留意した医療 AI 開発研究

○大山慎太郎

名古屋大学 未来社会創造機構 予防早期医療創成センター

2013年のアベノミクスにおいて掲げた三本の矢の一つである成長戦略「日本再興戦略」において国民の健康寿命の延伸が掲げられた。さらに2018年の「統合イノベーション政策」戦略推進会議の「AI戦略2019」などを踏まえつつ策定された健康・医療戦略では、医療画像を活用した研究や産業化を支える基盤的施策として、データ利活用基盤の構築やデータ利活用人材の育成確保を促しており、国家的にも高い注力がなされている。

しかしながら医療 AI 研究や SaMD(Software as a Medical Device) 開発といった研究・開発には企業と医療従事者・医療機関の緊密な連携に基づく大量の画像情報や非テキスト情報の個人情報保護に留意しながらの収集・管理(共有)・整理が必要となる。文科省では先の国家戦略に基づく先進的医療イノベーション人材養成事業を推進しており、名古屋大学は2020年に本事業の選定を受け「保険医療分野における AI 研究開発加速に向けた人材養成産学協働プロジェクト(AI-MAILs)」拠点を構築し、医療データ活用における注意点を理解し、研究開発を企業と推進することができる医療人材、特に臨床医を養成している。本セッションでは、このような拠点教育の取り組みや拠点人材とのOJT研究開発の経験などをご紹介する。

TU3 医用画像の個人情報を取り扱う企業の取り組み

○中西 隆伯

株式会社ジェイマックスシステム

医療システム開発の企業の立場から医用画像に含まれた個人情報が漏洩すると重大インシデントとなり、開発企業はもとよりシステムを使う施設の信用を大幅に低下させる可能性がある。弊社はPACS製品の開発が主力である。

それら製品の重要な機能は、保存された医用画像の適切な表示や通信である。

開発の段階では、各種ベンダーが提供するダミーデータで試験を行うため個人情報を扱うことはない。しかし、施設に導入された製品において問題が発生した場合は、どうしても実データの解析が必要になる。その際には個人情報保護法に則って、個人情報を慎重に扱い対応を行っている。このように個人情報を取り扱う製品を開発する企業の立場から、解析の手順などを紹介する。

発表では、DICOMのタグに埋め込まれた個人情報を削除する方法についても触れ、DICOM Toolkitを用いて簡単に個人情報を仮名加工情報に変換する方法と、DICOM Toolkitを利用した変換アプリケーションを紹介する。

シンポジウム1

16:10 ~ 17:30

SY1「イメージングが切り拓く未来の医用画像工学」

座長：伊藤 聡志 (宇都宮大学)

湯浅 哲也 (山形大学)

SY1-1 光コヒーレンストモグラフィー (OCT) の進展

○西澤 典彦

名古屋大学大学院工学研究科 電子工学専攻

光コヒーレンストモグラフィー (OCT) は、広帯域光を用いた干渉計測によって、 μm オーダーの高分解能な断層イメージを非侵襲・非破壊で得ることのできる光計測手法であり、医用工学の分野を中心に注目を集めている。OCT では、光源のスペクトル幅が広いほど、高い分解能を得ることができる。また、光の侵入を妨げる主要因である散乱と吸収は波長に依存するため、光源の開発は重要である。我々は、超短パルスファイバレーザーをベースとした広帯域なスーパーコンティニューム光を複数の波長帯で生成し、それを用いて高分解能かつ高感度な OCT イメージングの研究を進めてきた。これまでに、波長 $1.7 \mu\text{m}$ 帯において、マウス脳の深部のイメージングや、光コヒーレンス顕微鏡 (OCM) による神経組織や脳内血管のイメージングに成功した。本講演では我々の最近の成果と共に、OCT 研究の動向を紹介し、今後の課題を議論する。

SY1-2 位相コントラスト CT イメージングとヒト胚子の時系列解析

○山田 重人

京都大学大学院医学研究科附属先天異常標本解析センター

ヒトの発生における時間軸として受精後日数、頭殿長 (CRL)、形態学的な特徴に基づいて区分された不連続な段階的指標である「カーネギー発生段階 (Carnegie stages, CS)」の3つが存在する。この中でもカーネギー発生段階が広く用いられているが、CS1 ~ CS23 で構成される段階的なものであり、時間的に等間隔ではないことから、時系列に沿った定量的な解析には不向きである。演者は貴重なヒト胚標本群である「京都コレクション」を所有することから、これをいかに高解像度で撮像し画像解析するかに長年取り組んできた。組織切片画像による形態学的観察所見に基づき、自家蛍光を用いた EFIC 法、小サンプルのための MRI である MR 顕微鏡や本講演で取り上げる位相コントラスト CT イメージング (位相 CT) など様々な手法で撮像を行なった。得られた画像データを用いて発生現象の定量的に理解したいと考えており、外表および内臓など複数の指標において胎児の成長を時系列に数値化することを目標としている。

SY1-3 超音波と光の融合による医用画像技術の最先端：光超音波 (photoacoustic) イメージング

○椎名 毅

芝浦工業大学 SIT 総合研究所

がん、関節リウマチ、動脈硬化、糖尿病などの主要疾患の多くは、血管や循環状態の異常として現れることから、微細血管の構造の変化や血液状態の可視化により、早期診断や良悪性の鑑別診断の精度向上が期待される。

光超音波 (photoacoustic) イメージングは、ナノパルスレーザー光を照射して、光音響効果により体内の血液等から生じる超音波を検出して、無被曝、非造影で、血管の形状や酸素飽和度などの機能を、高解像度で 3D 表示可能な新規イメージング技術として期待されている。我が国においては、京都大学とキヤノン (株) が、2006 年から文部科学省の協働研究プログラムにおいて研究を進め、乳癌診断用の光超音波マンモグラフィのプロト機を開発している。また、その成果は、2014 年の内閣府の革新的研究開発推進プログラム (ImPACT) や、2019 年 AMED の先進的医療機器開発のプロジェクトに引き継がれ、光超音波計測のより幅広い適用分野の開拓と、その実用化に向けた研究開発が進められている。本講演では、これらの光超音波イメージング技術の実用化への取り組みについて紹介したい。

SY1-4 あいちシンクロトロン光センター BL8S2 ビームラインに構築した X 線暗視野法に基づく屈折コントラスト CT 撮像システム

○砂口 尚輝

名古屋大学大学院医学系研究科 総合保健学専攻

X 線暗視野法 (XDFI) に基づく屈折コントラスト CT は、2 次元病理画像に匹敵するコントラストで生体軟組織の精密な 3 次元構造を描出できるため、我々の研究グループでは、病理診断への応用を目指して様々な XDFI 関連技術の開発を行ってきた。X 線の屈折コントラストを得るためのラウエ型アナライザー結晶は重要な構成要素の 1 つであり、結晶の厚さが薄いほど空間分解能を向上できる。我々は、約 5 cm 角の視野を有す厚さ数 10 μ m の結晶を製作し、歪なく設置する技術を開発した。また、高空間分解能の撮影に必要な X 線カメラや、高画質な CT を得る再構成アルゴリズムおよびデータ処理手法なども独自に開発してきた。こうした努力により、空間分解能は現在数 μ m まで向上し、生体軟組織から未知の組織形態学的情報や腫瘍の 3 次元構造を非破壊で取得できるようになった。昨年、新たな XDFI 装置をあいちシンクロトロン光センター (AichiSR)BL8S2 に構築し、愛知県内でも高画質な CT が得られるようになった。本発表では、AichiSR の XDFI 撮像システムと近年の撮影像について紹介する。

7月29日(金)

第 1 会場 (ホール)

一般演題 2

17:40 ~ 18:40

OP2 「イメージング 1」

座長：杉本 直三 (京都大学)

吉川 悦次 (浜松ホトニクス株式会社)

OP2-1 位相拡散フーリエ撮像法におけるセグメント信号収集を用いた MR 圧縮センシング

○山登 一輝¹, 大水 望¹, 伊藤 聡志¹

¹宇都宮大学工学部基盤工学科

少数の観測から元の情報を復元できる圧縮センシングを MRI に利用することで、MRI の撮像時間を短縮できる。しかしながら、少数の収集信号から再構成された画像の分解能低下が問題である。先行研究では、フーリエ変換に二次の位相変調を付与した位相拡散フーリエ撮像法 (PSFT) を使用し、信号の低域のみを収集し事後的に高域の信号を推定することで再構成画像の分解能改善を図った。しかしながら、再構成画像の中心部分の分解能改善が困難であった。本稿では、PSFT 信号の収集領域を複数に分割するセグメント収集方式を導入し、再構成画像の画質と中心部分の分解能改善について取り組んだ。シミュレーション実験の結果、PSFT 信号をセグメント収集した提案手法は、先行研究よりも PSFT および SSIM が高くなることが確認された。また、分解能チャートを用いて分解能を評価したところ、画像中央部分の分解能改善を確認したので報告する。

OP2-2 実関数 CNN を利用した MR 位相画像の深層学習再構成

○深津 純奈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

MR 撮像の高速化を目的として圧縮センシングの MRI 応用が進められている。深層学習を利用する再構成法では、これまで実関数 CNN を利用する研究報告が多かったが、MR 画像は位相を持つ複素画像であり、複素数に対応する畳み込みニューラルネットワーク (CNN) が必要である。しかしながら、複素数 CNN でもフィルタ関数を複素数化するものは少なく、また、フィルタを複素数化する場合でもパラメータ数が増え、学習時間が増える問題がある。本研究では、MR 信号の間引きに対称性を与えると MR 画像の実部と虚部用に対応する間引き信号を作成できる性質に着目し、実関数型の CNN を使用して複素画像を再構成する方法の検討を行った。

反復型再構成をモデルとする深層学習再構成に適用した結果、少ない学習時間で複素数対応の CNN と同等な PSNR と SSIM の画像を得ることができた。さらに実部と虚部を 1 つの CNN で学習する手法により、画質をさらに改善できる可能性が示された。本研究により、実関数 CNN を利用して位相画像を再生する新たな方法の実現可能性を示すことができた。

OP2-3 Deep image prior を用いたリストモード PET 画像再構成

○大手 希望¹, 橋本二三生¹, 大西 佑弥¹, 磯部 卓志¹

¹ 浜松ホトニクス株式会社 中央研究所 第5研究室

Deep image prior (DIP) を用いたリストモード PET 画像再構成法を提案する。提案手法は、交互方向乗数法の枠組みにより、リストモード逐次近似法と DIP による画像処理を交互に行う。DIP による画像後処理は、ノイズを除去する反面、コントラストが若干犠牲になる。提案手法はノイズを減らしながら、同時にコントラストも改善する。頭部用 PET 装置の MC シミュレーションデータを用いて、提案手法の有効性を評価した。提案手法は、従来法に比べて高いピーク信号対雑音比とコントラストリカバリ係数を示した。リストモード PET 画像再構成は、イベント数より検出器対数が多い場合により効率的となる。よって、提案手法は検出器数が多く、飛行時間差情報、相互作用位置深さ情報を備えた PET 装置において特に有用と期待される。

OP2-4 圧縮センシングを用いたフォトンカウンティング CT のスペクトル歪み補正

○村田 一心¹, 尾川 浩一²

¹ 国立天文台, ² 法政大学 理工学部

フォトンカウンティング CT は空間情報に加えてエネルギー情報も取得できることから、次世代型 CT として注目されている。しかし、複数の X 線光子が検出器の不感時間内に入射した場合、パルス・パイルアップ効果により、測定スペクトルは歪められてしまう。その影響は、解析モデルを適用することで、原理的には補正できる。しかし、最小二乗法を基にした補正方法では、わずかな雑音も増幅されてしまい、画質を劣化させてしまう。その対応策として圧縮センシングの適用が考えられるが、特にエネルギービンの数が少ない場合にはスペクトル形状を先見情報として扱うことは難しい。そこで本研究では、エネルギー・空間の両方を先見情報として扱う手法を開発した。各エネルギービンの画像に対する全変動正則化、および全データに対する低ランク行列近似を適用することで、スペクトルの歪み補正精度が向上することを確認した。

OP2-5 学習データを用いた低線量 CT 逐次近似画像再構成の正則化パラメータ自動決定

○工藤 博幸

筑波大学システム情報系情報工学域

低線量 CT の画像再構成では、トータルバリエーション (TV) 正則化項や非局所平均フィルタを用いた正則化項 (Dong, Kudo, Med. Imag. Tech., 2016) を用いた逐次近似画像再構成法が有効であり、商用装置にも採用されている。本手法の一番の問題点は正則化の強さや特性を加減する正則化パラメータの決定であり、ほとんどの場合経験的に設定されており自動決定は未検討で難しいとされているのが現状である。本研究では、撮影対象と同じ部位を撮影した学習データセット (通常線量の正解画像の集合) を用いて、正則化パラメータを自動決定する二つの手法を提案して、両者とも有効に動作することを実証する。一つ目の手法は、画像復元など一般の逆問題分野で既に類似手法の提案がある正則化パラメータのベイズ推定に基づく手法で、学習データから正則化パラメータの事前分布を求めておき、それに対数尤度を加えた評価関数を画像再構成の過程で最小化して自動決定する。二つ目の手法は、深層学習にヒントを得た全く新しい手法で、学習データに対して平均 2 乗誤差や SSIM 値を最小にする正則化パラメータ値を学習で事前に求めておき、この事前決定した正則化パラメータで画像再構成を行う。腹部 CT 実画像データセットを用いたシミュレーション実験を行った結果、どちらの手法も有効に動作して最適に近い正則化パラメータの推定値を与えるが、二つ目の手法が正則化パラメータ推定の反復ループを必要としないため計算量の点で優れることが示された。また、推定するパラメータ空間の次元が低いため、両手法とも必要な学習データの数は非常に少なく済むことも示された。

一般演題 1

16:10 ~ 17:30

OP1「治療支援, レジストレーション」

座長: 中口 俊哉(千葉大学)

健山 智子(藤田医科大学)

OP1-1 Geometric Matching CNN による指骨 CR 画像の位置合わせ手法

○小野 輝¹, 神谷 亨¹, 青木 隆敏²¹九州工業大学大学院工学研究院機械知能工学系知能制御工学, ²産業医科大学

関節リウマチは、病態が進行すると全身の関節破壊を生じ、患者の QOL を著しく阻害する。そのため、疾患の早期発見、早期治療により病態の進行を抑制することが重要である。関節リウマチの診断は、血液検査や X 線画像診断により総合的に行われている。特に、X 線画像診断は簡便に病態の進行を捉えることができるが、読影医師の負担増加や医師の主観的な評価による再現性の欠如が課題となっている。そこで、コンピュータの解析結果を第二の意見として利用するコンピュータ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・現在画像から関節リウマチの進行を捉える支援診断システムの開発を目的とし、指骨領域の位置合わせ手法を提案する。Geometric Matching CNN を画像ペアごとに最適化することにより、指骨領域の高精度な位置合わせを行う。実験では 9 症例の CR 画像に提案手法を適用し、従来手法との比較を行った結果、良好な結果を得た。

OP1-2 放射線治療における膵臓変位推定の為の 2D 断層画像駆動型複数臓器接触シミュレーション

○原 裕貴¹, 角谷 倫之², 三日 直登³, 家永 直人³, 梅澤 玲², 神宮 啓一², 黒田 嘉宏³¹筑波大学大学院 システム情報工学研究群, ²東北大学大学院 医学系研究科, ³筑波大学 システム情報系

放射線照射中に断層画像を撮影できる MR-Linac は、膵臓などの非周期的な動きをする臓器に対しての効果的な治療につながるという期待されている。しかし、撮像できるのは一部の断面画像であるため、術前の計画用 3 次元 MR 画像を、膵臓の自発的な変形や周辺臓器との接触を考慮しながら更新するのが困難である。そこで本研究では、2 次元断層画像駆動型 Material Point Method を提案する。2 次元断層画像から得られた対象臓器の位置関係から、該当断面における節点の目標位置を求め、現在位置と目標位置との差に応じた力を加えることで 3 次元ラベルを駆動させる。周辺臓器との接触を考慮した物理シミュレーションにより 3 次元モデルの変位推定を目指す。本提案では、腹部の断層画像を用い、胃を周辺臓器として提案手法の基礎的な検討を行った。その結果、5 例中 4 例で変位の推定精度が改善したことを確認した。

OP1-3 内視鏡動画解析による所見作成支援に向けた臓器判別

○梅津 泉梨¹, 藤江 舞², 野村 行弘³, 加藤 順⁴, 中口 俊哉³¹千葉大学大学院融合理工学府基幹工学専攻医工学コース, ²千葉大学医学部附属病院臨床工学センター, ³千葉大学フロンティア医工学センター, ⁴千葉大学医学部附属病院内視鏡センター

内視鏡検査では、医師が検査の記録として診断内容、検査臓器、実施処置などの項目を記入した所見を作成する。しかし、内視鏡操作のため検査中の所見作成は困難であり、医師は検査後の時間を利用して記入する。医師の作業負担軽減のため、所見作成の効率化が求められる。また、所見は医師の記憶に基づくため、記載漏れの発生も課題である。診療報酬点数の申告漏れや医療安全の観点からも、正確な検査記録が求められる。本研究では、内視鏡動画解析による所見作成の効率化と記載漏れ防止を目的とする。第一段階として、検査記録の中でも重要な情報である検査臓器の判別手法を提案する。提案手法では、CNN と LSTM を組み合わせ、時間情報を利用した臓器分類を行う。さらに、分類結果に対して検査開始時と終了時の双方向から Sliding Window(SW) によって臓器の境界を探索し、統合する双方向 SW を提案し誤分類フレームを除去する。提案手法の評価実験を行い、その有効性が示唆された。

OP1-4 GNNによる血管名自動命名手法における臓器特徴の利用に関する検討

○出口 智也¹, 林 雄一郎¹, 北坂 孝幸², 小田 昌宏^{3,1}, 三澤 一成⁴, 森 健策^{1,5,6}

¹名古屋大学大学院情報学研究科, ²愛知工業大学情報科学部, ³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 消化器外科, ⁵名古屋大学情報基盤センター, ⁶国立情報学研究所医療ビッグデータ研究センター

本稿では、3次元腹部CT像から抽出した血管領域に対するグラフニューラルネットワーク(GNN)を用いた血管名自動対応付けにおいて、使用する特徴量に関する検討を行ったので報告する。腹部動脈は個人差が大きく複雑であるため、構造の把握は困難である。そこで、外科手術における医師の血管構造把握の負担を軽減するため、血管名自動対応付けが提案されている。これまで、血管構造を木構造と捉え、血管の位置や太さ・自動抽出臓器との位置関係の特徴量としてGNNで血管名を割り当てる血管名自動命名手法が提案されてきた。

本稿では、臓器の自動抽出の失敗による自動命名への影響を低減するため、血管に関する特徴のみを用いた自動命名を試みた。実験の結果、全体の精度は89.7%で、臓器情報を用いた場合の92.4%よりも低下した。分岐が単純な部分では精度が上がったが、特に肝動脈で大きな精度の低下がみられ、複雑な構造をとる部分での臓器情報の重要性が確認できた。

OP1-5 X線透視画像内のデバイスを対象とした深層学習セグメンテーションモデルのための効率的な学習データ作成手法についての検討

○鈴木 皓士¹, 菊池 洋平¹, 吉原 陽平¹, 松原 佳亮², 大村 知己², 木下 俊文², 松山 成男¹

¹東北大学 工学研究科 量子エネルギー工学専攻, ²秋田県立循環器・脳脊髄センター(研究所)

透視画像内のカテーテルなどの線状デバイスの視認性を上げる技術は、IVRの手技の多くの作業性向上に貢献すると考えられる。本グループでは機械学習ベースのセグメンテーションにより分割した領域に合わせた視認性向上技術を検討しているが、学習には膨大な学習データが必要となる。本研究ではCT画像とデバイスの形状・構成材料の既知情報からの学習データ作成を提案する。

心臓を対象とした臨床CT画像(3次元・デバイス無し、22例)において、カテーテル領域と仮想したボクセルの値を構成材料のものに置換し、これを投影処理することで疑似透視画像を作成した。また、カテーテル領域の形状はBezier曲線からランダムに決定したが、この曲線の投影が教師データとなる。これらを元に準備したデータで学習したPAR-Netでカテーテルセグメンテーションを検証したところ、得られたDice係数は0.910となった。また、この学習済みモデルは、カテーテル像を含む心臓画像に対しても良好な性能を示した。

OP1-6 気管支内視鏡生検支援向け処置具3次元位置認識法における機械学習を用いた精度改善

○松崎 和喜¹, 山川 恵介¹, 飯村 隆志¹, 松元 祐司², 田中 緑², 長島千恵子³, 麻生 智彦³

¹富士フィルムヘルスケア, ²国立がん研究センター中央病院内視鏡科, ³国立がん研究センター中央病院放射線技術部

末梢肺病変に対する気管支内視鏡生検手技において、X線装置は腫瘍細胞を採取する処置具の位置を確認する目的で利用される。X線画像は2次元投影像のため、病変の前後方向の位置把握が困難な場合がある。これまで我々はX線装置を用いた手技支援をめざし、処置具の3次元位置認識技術を開発してきた。開発手法の位置認識精度を医師が後ろ向きに収集した臨床例で評価したところ、肺解剖構造の領域毎に傾向がある認識誤差が見られた。これらは画像取得時の呼吸相の違いに起因する規則性のある体動が主要因と考えられた。そこで本研究(倫理審査承認済)では、臨床データを用い体動を予測する機械学習モデルを構築し、開発手法の認識位置補正を試みた。その結果、補正前後の位置認識誤差は肺全体平均で27.1mmから14.6mmに改善し、特に体動が大きい肺下葉で効果が顕著だった。以上から本補正法により、手技支援法の実用性が向上できると考えられる。

一般演題 3

17:40 ~ 18:40

OP3「CAD1」

座長：内山 良一(熊本大学)

花岡 昇平(東京大学)

OP3-1 画質改善処理による乳がん腫瘤影の良悪性鑑別 CAD の性能向上

○工藤 颯馬¹, 安倍 和弥¹, 武尾 英哉¹, 永井 優一², 縄野 繁³¹ 神奈川工科大学, ² 国立がん研究センター東病院, ³ 松戸中央総合病院

マンモグラフィ(MMG)撮影は検診MMGと診断MMGの2種類に分かれている。一般的に、検診MMGは存在診断、診断MMGは鑑別診断の位置づけで撮影される。しかし、もし検診段階で良悪性鑑別ができれば、より早期の発見に繋がると考えられる。しかし、検診MMGは診断MMGと比べて、検診車などで行われることもあることから比較的簡易な撮影装置が使われるため、マンモグラムの画質は若干劣る。そのため、検診MMGの画像での良悪性鑑別CADの性能は診断MMGの画像の場合と比べて精度が落ちる。

そこで本研究では、両者の画質差を補うことを目的として、画像の粒状性とコントラストを同時に改善する画像処理を開発し、検診MMG画像での良悪性鑑別CADの性能向上を図った。その結果、そのままの検診MMG画像を使った鑑別精度85%に対して、画質改善処理を施した場合は鑑別精度が89%に向上した。診断MMG画像の鑑別精度が約90%であったことから、ほぼ同等の性能を得ることができた。良悪性鑑別CADにはCNNを用いており、学習したAIが画像中のどこに着目して判断しているのか分析したので報告する。

OP3-2 深層学習を用いた肘関節超音波画像におけるOCD診断支援

○佐々木研太¹, 藤田 大輔¹, 高辻 謙太², 琴浦 義浩², 南 昌孝², 小林 雄輔², 祐成 毅², 木田 圭重², 小橋 昌司¹¹ 兵庫県立大学, ² 京都府立医科大学

野球経験者にしばしばみられる故障に野球肘がある。上腕骨小頭離断性骨軟骨炎(osteochondritis dissecans: OCD)は代表的な野球肘の形態であり、超音波画像検査による早期発見が可能である。本研究では、肘の骨の超音波画像から深層学習による検出モデルを作製し、自動でOCD検出を実現できるようにする。本研究では、肘の外側・後方・短軸の撮影方向の超音波画像で学習を行う。被験者数はOCDが88人、異常なしが50人である。VGG16のファインチューニングにより検出モデルを作製する。5分割交差検証を用いて5つのモデルに対して評価用データにおける検出結果の平均値が正解率83.3%、適合率92.4%、再現率80.7%、F1値0.855であった。データの組み合わせにより各指標の値に差があり正解率では最低74.1%、最高92.3%であった。この差を小さくするための学習条件の設定が今後の課題である。またOCD検出のためには再現率の向上も必要である。

OP3-3 骨シンチグラムの陽性高集積検出システムにおける市販後学習

○藤本 啓輔¹, 大崎 洋充², 東山 滋明³, 河邊 譲治³, 中岡 竜介⁴, 清水 昭伸¹

¹東京農工大学大学院工学研究院, ²群馬県立県民健康科学大学大学院診療放射線学研究所, ³大阪市立大学医学部附属病院核医学科, ⁴国立医薬品食品衛生研究所医療機器部

和文:

本報告では、骨シンチグラムを用いた陽性高集積検出システムのための市販後学習の改良法を提案する。特に市販後学習のためのデータが少数の場合に注目する。データが少ない場合、すべての層の重みを対象に再学習を行うと、過学習によって性能が低下する可能性が高くなる。そこで、再学習を行うか否かを適応的に選択する方法について検討をする。具体的には、policy network を用いて再学習をする層を選択する。本稿では、市販後学習のためのデータの数を変化させて提案法の有効性を評価する。また、再学習の対象になった層の可視化結果などを使いながら提案法の有効性について議論する。

英文:

This paper presents a method to improve post-market training of a hot-spot detection system of malignant tumor in a bone scintigram. Especially, we focus on the case that the number of post-market training data is small. When re-training weights of all layers with small data, there is a high possibility that the performance will deteriorate due to overfitting to training data. To solve the problem, we have studied a method to adaptively select whether re-training weights of layers or keep as initial weights. Specifically, a policy network selects layers to be re-trained. This paper evaluates effectiveness of the proposed method changing the number of post-market re-training data. We discuss the effectiveness of the proposed method with visualizing re-trained layers.

OP3-4 3D-Alpha-WGAN の正常症例学習モデルを用いた FDG-PET 画像における異常集積の自動検出

○内田 卓妙¹, 原 武史², 周 向榮², 片淵 哲朗³, 野崎 太希⁴, 松迫 正樹⁴, 藤田 広志²

¹岐阜大学大学院自然科学技術研究科知能理工学専攻, ²岐阜大学工学部電気電子・情報工学科, ³岐阜医療科学大学保健科学部, ⁴聖路加国際病院放射線科

医用画像における網羅的な異常データの収集コストの高さは問題である。本研究では、医師の負担軽減や見落としを防ぐために、体幹部 FDG-PET 画像における悪性腫瘍の自動検出手法の開発を目的とする。ここでは、データ収集コストの低い正常症例を利用して、教師なし異常検知のアプローチで腫瘍の検出を行う。正常症例の 3 次元 FDG-PET 画像 66 症例を、3 次元画像生成モデルである 3D-Alpha-WGAN に入力して、正常画像生成モデルを得る。このモデルに異常症例を入力し、正常例様に補正された再構成画像を出力する。入出力間の差が大きい領域は、正常症例にない特徴を持つため、その領域を腫瘍候補とする。各候補に対して、体積や周辺画素との差を基に偽陽性の可能性が高い候補を削除し、残った候補を最終出力とする。異常症例 58 症例における検出率は 89.9%、1 症例あたりの平均偽陽性数は 37.9 個となり、正常症例を学習させた 3D-Alpha-WGAN モデルは腫瘍検出に有用である可能性が示唆された。

OP3-5 Memory-attention に基づくハイブリッドモデルによる不均衡データを用いたくも膜下出血 CT 画像分類

○魯 仲陽¹, 小田 昌宏^{2,1}, 林 雄一郎¹, 胡 涛¹, 伊東 隼人¹, 渡谷 岳行³, 阿部 修³, 森 健策^{1,4,5}

¹名古屋大学大学院情報学研究所, ²名古屋大学情報連携推進本部情報戦略室, ³東京大学医学部附属病院放射線科, ⁴名古屋大学情報基盤センター, ⁵国立情報学研究所 医療ビッグデータ研究センター

AI-based diagnosis is suffered in the low accuracy, resulting from data imbalance between normal and disease cases. This paper proposes a novel hybrid model to alleviate the data imbalance issue in the subarachnoid hemorrhage classification issue. We present a memory-attention concept to build up a centroid feature representation of each class dynamically and metric the distance of centroids and features as constraint conditions to enhance the classification performance. In addition, we design a novel loss function to optimize the centroids and the model dynamically. We performed experiments on a highly imbalanced brain CT dataset, including 33 cases with subarachnoid hemorrhage and 2519 normal cases. Our experiments showed that after inducting the memory-attention hybrid model, in contrast to the previous work, the classification performance has improved, confirming the proposed method's effectiveness in alleviating the classifier bias toward our mission.

一般演題 4

8:30 ~ 9:50

OP4 「セグメンテーション1」

座長：大竹 義人(奈良先端科学技術大学院大学)

村尾 晃平(国立情報学研究所)

OP4-1 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

○大野 真奈¹, 申 忱¹, Holger R. Roth², 小田 昌宏¹, 林 雄一郎¹, 三澤 一成³, 森 健策¹¹名古屋大学大学院情報学研究科, ²NVIDIA Corporation, ³愛知がんセンター

本稿では、境界情報を考慮した損失関数を導入した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。コンピュータによる診断・手術支援システムの開発において、多臓器領域抽出は重要な要素技術であり、これまで多くの多臓器領域抽出に関する研究が報告されている。

従来の医用画像抽出では、損失関数としてDice Lossが広く利用されている。しかしながら、Dice Lossは抽出領域と正解領域の重なり部分を考慮するため、学習されたモデルは臓器の境界部分の表現が曖昧になる傾向がある。このような問題を解決するため、提案手法では抽出領域の境界部分における制限を考慮するBoundary Enhancement LossをDice Lossと組み合わせた損失関数をFCNに導入して多臓器領域抽出を行った。そして、境界情報が多臓器領域抽出に与える影響を考察した。本研究では、284症例のCT像を用いて多臓器領域抽出を行った。全臓器のDice係数の平均は、3D U-Netを用いた手法で87.24%、V-Netを用いた手法で87.19%であった。

OP4-2 PET/CT画像を用いた多臓器自動抽出に関する初期的検討

○菅沼 雄太¹, 寺本 篤司¹, 齋藤 邦明¹, 藤田 広志², 鈴木 裕紀³, 富山 憲幸⁴, 木戸 尚治³¹藤田医科大学大学院 保健学研究科, ²岐阜大学 工学部, 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, ⁴大阪大学大学院 医学系研究科 放射線医学教室

【目的】PET/CT検査は腫瘍の早期発見に有用であり、検診目的でも利用されている。しかし、PET画像は空間分解能が低く、高集積を呈する臓器の同定が困難な場合がある。そこで本研究は、PET/CT画像を用いて多臓器を自動抽出する手法を検討した。【方法】本研究では仁泉会MIクリニックにて収集された90症例の全身PET/CT画像を対象とした。PET画像またはPET減弱補正用CT画像に対し、U-Netを用いて臓器領域抽出を行った。抽出対象は、肝臓・脾臓・腎臓・膵臓とし、それらの抽出精度はDice係数にて評価した。【結果】肝臓・脾臓・腎臓のDice係数は約90%、膵臓は約55%となり、膵臓以外は診断用CT画像を用いた先行研究と同等の抽出精度が得られた。【結論】診断用CT画像よりも解像度が低くノイズレベルの高いPET/CT画像であっても肝臓・脾臓・腎臓は十分な精度で抽出が可能であることが確認された。

OP4-3 U-Netを用いた頸部X線動画からの椎体・棘突起の抽出に関する基礎的検討

○塩田 紘司¹, 目片幸二郎², 滝沢 穂高¹, 工藤 博幸¹¹筑波大学, ²四條畷学園大学

誤嚥性肺炎は2019年と2020年の日本人の死因6位となっている。嚥下障害は誤嚥性肺炎の要因の一つだが、そのメカニズムは未だ解明されていない。本研究では、頸部X線動画にFully Convolutional Networkの一種であるU-Netを適用し、頸椎を構成する椎体および棘突起をそれぞれ自動で抽出することを試みる。精度向上のために、アフィン変換に基づくデータ拡張、線形・非線形の前処理フィルタの組み合わせを最適化することで精度を向上させるマルチチャンネル化、下顎骨、後頭部、肩部の境界線に基づくキャリブレーションの3つの前処理手法を提案し、比較実験を行った。実際のX線動画に適用した結果を示す。

OP4-4 体幹部 CT 画像における 2D U-Net を用いた体腔の同時学習による腰方形筋の自動認識

○川本 真大¹, 神谷 直希¹, 周 向栄², 加藤 博基³, 原 武史^{2,4}, 藤田 広志²

¹愛知県立大学情報科学部, ²岐阜大学工学部, ³岐阜大学大学院医学系研究科放射線医学分野, ⁴東海国立大学機構医療健康データ統合研究教育拠点

体幹部 CT 画像を用いた腹部組織の自動解析では、セグメンテーションに基づく骨格筋量の計測が行われている。しかしながら、第三腰椎 (L3) 断面における二次元にとどまり、さらに、L3 断面内には複数の骨格筋が含まれているが、部位別認識が実現できている領域は限られる。本研究では、これまでに部位別認識が実現できていない、腰方形筋の三次元認識手法を提案する。提案手法では、2D U-Net において腹腔と腰方形筋を同時学習することで、腰方形筋の単一領域の学習よりも高い認識精度を得ることを目指す。20 症例を用い、4 分割交差検証により提案手法による認識結果を Dice 値で評価したところ、腰方形筋のみを用いた学習時には、79.4% の認識精度であったが、体腔と腰方形筋の同時学習では、腰方形筋の認識精度は 85.6% となり、6.2% 向上した。今後は、腹腔に隣接する他の骨格筋においても腹腔の同時学習の効果の検討を行う。

OP4-5 Erosion Consistency Training for Semi-Supervised CT Segmentation of COVID-19

○柳 凱¹, 小田 昌宏^{2,1}, 鄭 通¹, 林 雄一郎¹, 大竹 義人^{3,4}, 橋本 正弘⁵, 明石 敏昭⁶, 青木 茂樹⁶, 森 健策^{1,2,4}

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国立情報学研究所医療ビッグデータ研究センター, ⁵慶応義塾大学医学部放射線科, ⁶順天堂大学医学部放射線医学講座

COVID-19 has become a worldwide disease and some variants of it spread more easily and faster which causes more affected cases. By Mar. 14, 2022, over 458 million confirmed cases have been reported in over 225 countries and territories. The segmentation of ground-glass opacities (GGO) of COVID-19 from chest CT volumes is useful for the diagnosis of COVID-19 while labeling is time-consuming. In this work, we employ a semi-supervised segmentation method that uses a few CT volumes with GGO annotations and many unlabeled CT volumes as training data. We use the co-training framework consisting of two models, in which one model is trained to predict the GGO region, and another is trained to predict the GGO region after erosion to better predict the boundary of the GGO region. We use labeled data and predicted pseudo labels of one model to supervise another model. In the experiment using the proposed method, we attained Dice score of 64.0%.

OP4-6 光コヒーレンストモグラフィー画像からの 3 次元血管構造の抽出

○岡村 宙輝¹, 岡本 尚之¹, 羽石 秀昭²

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

表層から約 1mm 程度の深さの断層像を取得できる光コヒーレンストモグラフィーは、眼底の 3 次元構造の可視化などにおいて実用化されている。特に、時間的に連続する複数フレーム間の変化量に注目することで、3 次元の血管強調像群を取得できる。しかし、血管強調群には体動によるノイズや、実際の血管領域よりも深さ方向に尾を引いたアーチファクトも含まれる。そこで本研究の目的を、血管強調像群から正確な 3 次元血管構造を抽出することとする。提案手法では、まず 3 次元血管強調像群の深さ方向の最大値投影図を作成する。次に最大値投影図における血管の連続性に注目してシード点を自動で設定し、領域拡張を行う。結果から、提案手法が体動によるノイズの低減に有用であることを確認した。

シンポジウム 2

10:00 ~ 12:00

SY2 「次の医用画像工学を切り拓く HPC と機械学習」

座長：目加田慶人(中京大学)

平野 靖(山口大学)

SY2-1 mdx：データ活用のためのプラットフォームと、医療データでの活用について

○田浦健次朗

東京大学情報基盤センター

mdx (<https://mdx.jp/>) は、データ活用に重点を置いた、全国共同利用できる計算機環境で、全国 11 の情報基盤センター、情報系の研究所が共同で運営する。仮想化された環境で各ユーザグループに擬似的な専有環境を提供できる。これにより柔軟な環境を構築できるだけでなく、各ユーザグループにストレージ、ネットワークが隔離されたセキュリティの高い環境を提供できる。本講演では mdx サービスの内容、利用事例、その上でやっている、セキュリティ・プライバシー保護のためのシステム研究、医用画像に対するプライバシー保護の研究について紹介する。

SY2-2 機械学習を用いた画像認識の研究動向

○原田 達也

東京大学先端科学技術研究センター

計算機による視覚情報理解ためには、見た目とその意味との乖離であるセマンティックギャップが長年の課題であった。しかしながら、近年の大規模かつ高品位なデータセットと GPGPU に代表される強力な計算機パワー、ディープラーニングに代表される効率的な機械学習を活用することで、セマンティックギャップを乗り越える兆しを見せている。また、この機械学習を利用した画像認識技術の発展により、画像を利用した医療診断は、大きな転換点を迎えており、一部のベンチマークにおいては人の性能に迫る手法も出始めている。そこで、本講演では機械学習を利用した、実世界認識とその医療応用について講演する。

SY2-3 自然言語処理による読影テキスト解析の未来

○荒牧 英治

奈良先端科学技術大学院大学 先端科学技術研究科

今、医療分野の言語処理が急速に進歩しています。

病院情報システムに集積される医療データは、画像、映像、検査値など様々なモダリティがありますが、所見や診断など医療テキストもかなりの割合を締めます。今、その医療テキストを扱う医療言語処理が、急速に進みつつあります。この躍進のドライビングフォースは、大規模言語モデルの進展、標準データの整備といった研究環境の整備、また、人間の判断を直接反映する医療言語処理への期待があります。本発表では、その進歩を総論的に俯瞰します。

さらに、現在もっとも難しいモダリティとされた言語処理の進歩により、病院で生成される多様なデータについて、統合的な高度の情報処理が可能となったと言えます。しかし、その結果、どのようなサービスが実現するのか、革新的な何か、巷でいう DX がどう起きるのかといった、次世代の医療サービスのビジョンについては、まだ十分なイメージがシェアされていないように思います。本発表では、アプリケーションの具体例として読影レポートの自動データベース化、自動生成など最新の試みを紹介し、今後の可能性を議論します。

SY2-4 機械学習によるメディア画像処理～大規模学習データセットに基づく機械学習手法の威力とその限界

○佐藤 真一

国立情報学研究所

深層学習に代表される機械学習技術に基づくメディア画像処理技術の性能向上は著しく、一部のタスクでは人間の認識・識別性能を凌駕するような技術が実現できている。この技術革新には、大規模で現実的な学習データセットの整備が必要不可欠である。この講演では、こうしたアプローチにより、今メディア画像処理でどこまでできるのかを概観した上で、こうしたアプローチの問題点、すなわちデータセットのノイズやデータセットのバイアスなどについても述べる。

特別講演 1

14:20 ~ 15:20

SL1 「限られた情報からロバストに：信頼できる機械学習に向けて」

座長：森 健策（名古屋大学）

SL1 限られた情報からロバストに：信頼できる機械学習に向けて

○杉山 将

理化学研究所 革新知能統合研究センター、東京大学大学院新領域創成科学研究科

深層学習を始めとする先端的な機械学習技術は、良質な教師データを大量に必要とします。しかし、医療など多くの応用分野では、質の良い教師付きビッグデータを収集することは容易ではありません。この問題に対処すべく、講演者らのグループでは、ある種の不十分な教師情報からでも学習できる弱教師付き学習手法（正とラベルなしデータからの分類、類似データからの分類、正信頼度からの分類、否定ラベルからの分類など）、ラベル雑音を含む訓練データからのロバスト学習手法（雑音遷移行列の推定、入力依存雑音への対応、2つのモデルを用いた共教示など）、バイアスを持つデータからの転移学習手法（共変量シフト適応、クラス事前確率変化適応、動的適応など）を開発してきました。本講演では、これらの研究の概要と最新の成果をご紹介しますとともに、医用画像工学への応用可能性について皆様と議論させていただければと思っています。

シンポジウム 3

15:30 ~ 16:50

SY3 「JAMIT の未来をつくろう！」

座長：森 健策（名古屋大学）

パネリスト 黒瀬 優介（東京大学）
杉野 貴明（東京医科歯科大学）
橘 理恵（大島商船高等専門学校）
健山 智子（藤田医科大学）
橋本二三生（浜松ホトニクス株式会社）
平川 翼（中部大学）

一般演題 6

17:00 ~ 17:50

OP6「解剖構造モデル, 他」

座長：清水 昭伸 (東京農工大学)

堀田 一弘 (名城大学)

OP6-1 ヒト胚子の脳の空間的に隣接する複数器官を対象とした統計的形状モデル

○近嵐 尚¹, 高桑 徹也², 山田 重人², 清水 昭伸¹¹東京農工大学大学院工学研究院, ²京都大学 大学院医学研究科

本報告では、ヒト胚子の脳の空間的に隣接する複数器官を対象とした統計的形状モデルの構築法について報告する。ヒト胚子の脳の5器官(大脳, 間脳, 中脳, 後脳吻側部と小脳, 後脳尾側部)は空間的に連続し、隣り合う器官同士は接している。従来の複数器官を対象とした統計的形状モデルでは、器官同士の「重複」や隣接する器官の間に隙間(背景)が存在する「分離」が発生してしまう。そこで、複数のレベルセット関数の符号の組み合わせを利用した器官表現を用い、器官の大きさに関する制約を加えながら器官間の重複、分離を防ぐ方法を提案する。本研究では、提案手法を京都コレクションのヒト胚子・脳の形状ラベルに適用して、従来の手法で構築した統計的形状モデルとの比較により、提案手法の有用性について議論する。

This report describes a method for constructing a statistical shape model for multiple neighboring organs of embryonic human brains. The five organs of the human embryo brain (cerebrum, interbrain, midbrain, rostral hindbrain and cerebellum, caudal hindbrain) are spatially contiguous. Conventional statistical shape models for multiple organs cause "overlap" between organs and "separation" where gaps (background) exist between adjacent organs. To solve this problem, we propose a method to prevent overlap and separation between organs while imposing restrictions on the size of organs, using an organ representation that combines the signs of multiple level set functions. We apply the proposed method to the shape labels of embryonic human brains in the Kyoto collection and discuss the usefulness of the proposed method by comparing it with statistical shape models constructed by conventional methods.

OP6-2 白質信号自動解析の再現性に関する評価

○高橋 哲彦¹, 大川 竜也^{1,2}, 林 則夫¹, 丁嵐 亮¹¹群馬県立県民健康科学大学大学院 診療放射線学研究科, ²公益財団法人脳血管研究所附属美原記念病院 画像診断課

FLAIR 画像を用いて白質高信号領域(WMH)を自動抽出し体積を計算する診断支援アプリケーションの開発が進んでおり従来のグレード判定(5段階)と比べて詳細な臨床情報が期待されている。一般にWMHの体積は健常例~低グレードでは小さく、高グレードで大きい。臨床では高グレードが重要なため、定量解析の再現性評価にはある程度のWMH体積の症例が望ましい。そこで、本研究では、検査済み臨床データを活用して再現性を評価した。

共同研究施設にて、2001年から2020年までに頭部MRI検査で撮像したFLAIR画像900例に対して、臨床所見が「白質虚血性変化あり」でかつ2回以上同一の磁場強度(3T)のMRIで検査した患者を抽出した。抽出画像に自動解析を適用した。白質の高信号領域の体積を求め、結果を統計的に解析した。(倫理委員会承認済)

抽出した症例は34例であった。統計解析の結果、抽出体積0cc~100ccの範囲で、誤差は+14.7cc, -7.5ccであった。

OP6-3 大規模 CT 画像データベースを用いた骨格ランドマークによる下肢骨格形状の加齢変化解析

○下元 悠我¹, 箱谷 知輝¹, 大竹 義人¹, スーフィーマーゼン¹, 政木 勇人¹, 上村 圭亮², 高尾 正樹³, 宮本 拓馬⁴, 田中 康仁⁴, 菅野 伸彦², 佐藤 嘉伸¹

¹奈良先端科学技術大学院大学, ²大阪大学大学院医学系研究科, ³愛媛大学大学院医学系研究科, ⁴奈良県立医科大学

人体に忠実な全身骨格モデルは、人体の骨格構造解析や動作解析において重要である。現在、骨格の表現方法の一つとして、複数人の臓器の形状データを統計的に解析した統計形状モデル (SSM) が用いられている。しかし、従来研究では一部の骨格形状のみの SSM を構築しており、全身骨格の構築は行われていない。そのため、我々は日本医学放射線学会が収集している J-MID データベースと、共同研究施設で収集する 4 万症例以上の大規模な CT データベースを用いた全身骨格の SSM 構築を目指している。本研究ではその第一歩として、下肢 (骨盤から足部まで) の大規模 CT 画像データベースから骨格上のランドマークを抽出し、そのランドマークを用いて下肢骨格の解析を行った。下肢のランドマークデータを年齢・性別ごとに分け、骨格形状の加齢変化について調査を行ったので報告する。

OP6-4 テンソル分解を用いた黒質緻密部の 3 次元パターン表現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, 服部 信孝³, 鎌形 康司³, 青木 茂樹³, 森 健策^{1,2,4,5}

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順天堂大学 医学部, ⁴名古屋大学 情報基盤センター, ⁵国立情報学研究所 医療ビッグデータ研究センター

パーキンソン病に関しては疾患者の黒質緻密部における神経細胞の減少が報告されている。報告においては、T2 強調画像や神経メラニン強調画像を介した観察によってパーキンソン病患者の黒質緻密部の変化を確認できることが知られている。本研究ではテンソル分解を用いて健常者・パーキンソン病患者の黒質緻密部のボリュームデータをテンソル分解して解析を行う。テンソル分解して得られたテンソル空間中の基底を用い、パーキンソン病に関連する黒質緻密部の形状パターン表現方法を検討する。

7月30日(土)

第2会場 (シンポジオン)

一般演題 5

8:30 ~ 9:50

OP5 「画質改善」

座長：中尾 恵 (京都大学)

陳 延偉 (立命館大)

OP5-1 MR マルチスライス撮像におけるパラレルブライントデノイジングの性能改善

○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

MR 画像において構造的特徴の保持と雑音除去性能の両立する雑音除去法が求められている。昨年に隣接するスライス画像間にある密度値の高い相似性と雑音の低い相関性を利用し、重み係数の異なる複数の加算平均画像を作成し、それらを深層学習を利用した雑音除去後にスライス毎に分離するパラレルデノイジング法を提案した。この方法では加算平均の重み係数は正の値を使用したため、重み係数を変えたことによる雑音分布の変化は僅かであった。本研究では、新たに負の重み係数を使用する。負の重み係数の導入により、1) 一方の雑音の位相が反転するため加算された雑音の分布が大きく変化する、2) 加算平均画像は S/N が低下するために深層学習により除去される雑音量が大きくなる、の 2 点により雑音除去効果の改善が期待される。雑音量を未知とするブライント雑音除去法を適用した結果、画像の鮮鋭さを保ったまま単一画像雑音除去や従来法を顕著に上回る雑音除去性能を得ることができた。

OP5-2 Pix2Pix コンディショナル GAN による頭部 MRI のモーションアーチファクトの改善

○白井 桂介¹, 室 伊三男², 渋川 周平¹, 尾川 浩一³, 後藤 政実¹, 坂野 康昌¹, 京極 伸介¹, 代田 浩之¹

¹順天堂大学保健医療学部診療放射線学科, ²無所属, ³法政大学理工学部

頭部 MRI では体動によるモーションアーチファクトが画像診断の妨げとなる。近年は多くの深層学習による補正法が報告されるが、人体頭部画像での実装には教師データの確保が課題である。そこで、モーションアーチファクトをシミュレートした学習データを用いて、Pix2Pix コンディショナル GAN による画質改善の精度を評価した。本研究では、20 例の頭部画像からモーションアーチファクト有りの T2 強調横断像を 6420 枚作成した。このデータの 90% で学習し残りを検証に使用した。学習データはアーチファクトの出現方向を垂直および水平に分け、学習データとの組み合わせによる影響を検証した。評価は、アーチファクト無し画像との構造的画像類似度 (SSIM) とピーク信号雑音比 (PSNR) を求めた。その結果、SSIM の平均値が 0.62 から 0.92、PSNR の平均値が 26dB から 29dB となり、本学習モデルによる改善効果が実証された。

OP5-3 教師なし PET 画像ノイズ除去における事前学習済モデルの有用性

○大西 佑弥¹, 橋本二三生¹, 大手 希望¹

¹浜松ホトニクス株式会社 中央研究所

統計ノイズの多い positron emission tomography (PET) 画像に対し、事前に学習データセットを必要としない deep image prior (DIP) を用いた教師なしノイズ除去やその応用研究が近年数多く行われているが、これらの技術を発展させるためには、根拠となる DIP 自体のさらなる性能向上が不可欠である。本研究では、自己教師あり表現学習に注目することで PET 画像のみで汎用的な学習済みモデルを作成し、それを教師なし学習へ転用することでノイズ除去の性能向上を検討する。数値シミュレーションおよび実測データを用いて評価を行った結果、学習済モデルを利用することで定量性を維持しつつノイズ除去性能が向上した。さらに、先行研究におけるドメイン変換型の学習済モデルと比較し、他の PET 薬剤に対する汎用性も示された。

OP5-4 MR エラストグラフィにおける腹壁運動に伴うモーションアーチファクトの低減法

○菅 幹生¹, 小賀野 慎¹, 谷口 陽^{1,2}, 西原 崇², 瀧澤 将宏²

¹千葉大学, ²富士フィルムヘルスケア株式会社

腫瘍や肝硬変などの病変組織は正常組織と比較して硬くなる。MRI を用いて非侵襲的に生体軟組織の粘弾性分布を評価可能な手法として MR elastography (MRE) がある。自由呼吸条件下では腹壁運動に伴うモーションアーチファクトにより MRE 粘弾性率推定精度が低下するため、一般的には息止め条件下で撮像する。本研究では、腹壁運動に伴うモーションアーチファクトの影響を低減可能な MRE 撮像条件を数値シミュレーションにより明らかにすることを目的とした。形態画像に生じるモーションアーチファクトの間隔が呼吸周期と撮像時間に関係する知見を元に、MRE 撮像パラメータの 1 つである repetition time を呼吸周期の 3 分の 1 に設定することでモーションアーチファクトを撮像対象から外すことができ、息止め条件下での弾性率推定値との誤差は 3% 以下となることを確認した。以上の結果より、撮像中に呼吸周期が安定している場合には、自由呼吸条件下での MRE 撮像が可能であることが示唆された。

OP5-5 Cycle GAN を用いた前立腺癌患者における仮想造影 MR 画像合成

○平川 勇也¹, 有村 秀孝², 崔 雲昊¹, 高山 幸久³, 西江 昭弘⁴, 石神 康生⁵

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福岡大学医学部 放射線医学教室, ⁴琉球大学大学院 医学研究科 放射線診断治療学講座, ⁵九州大学大学院 医学研究院 臨床放射線科

Fat-suppressed contrast-enhanced T1-weighted images with high spatial resolutions can depict extra-prostatic extension, neurovascular bundle involvement and seminal vesicle invasion. However, gadolinium-based contrast agents have been reported to cause residual brain parenchyma, and thus alternative techniques may be required. We attempted to develop a cycle generative adversarial network (GAN) model to synthesize virtual contrast-enhanced T1-weighted images from real contrast-free T1-weighted and T2-weighted magnetic resonance (MR) images for prostate cancer patients.

Contrast-enhanced T1-weighted MR images with gadolinium-based contrast agents and non-contrast T1-weighted and T2-weighted images in 43 prostate cancer patients were selected for this study, and they were randomly divided into 30 training cases and 13 test cases. The proposed cycle GAN model consisted of a generator to produce contrast-enhanced images from contrast-free images and a discriminator to judge whether input images are real or mimic contrast images. Peak signal-to-noise ratio (PSNR) and structural similarity index (SSIM) were evaluated in the whole images and tumor regions generated by the model.

The proposed model achieved an average PSNR of 29.3 ± 2.94 and SSIM of 0.780 ± 0.0795 . Our study suggests that the proposed cycle GAN model can produce virtual contrast-enhanced MR images of prostate cancer patients.

OP5-6 頭部 PET 体動補正のための大きな動きに対応したマーカレスモーショントラッキングシステムの開発

○岩男 悠真¹, 赤松 剛¹, 田島 英朗¹, 高橋美和子¹, 山谷 泰賀¹

¹量子科学技術研究開発機構 量子医科学研究所 先進核医学基盤研究部 イメージング物理研究グループ

頭部の体動は、体動計測ができれば正確に補正することが可能である。そこで、顔表面の立体構造をマーカとすることで、体表装着型マーカが不要な体動補正システムを開発した。しかし、左右の首振りに対する正解値と検出角度の線形性は 30 度を境に大きく乖離する傾向があり、ボランティア試験では 30 度を超える大きな動きが問題となった。

そこで本研究では、Kinect Fusion と呼ばれる 3D スキャンアルゴリズムを改良したトラッキング手法を開発した。マッチングを行うフレーム間の差異を最小とし、形状の類似度を高めるため、対象フレームは直前のフレームのモーションによって変換し、リファレンスとなるモデルとのオーバーラップ部分のみを用いる。頭部モデルをモータステージにより可動させた実験では、検出角度の線形性が約 60 度まで大幅に向上した。さらに提案法をボランティア試験に適用し、従来法よりも体動補正効果が高いことを実証した。

7月30日(土)

第2会場 (シンポジオン)

ランチョンセミナー

12:10 ~ 13:10

LS 「医用画像 AI の進化、普及を支える GPU 関連テクノロジー」

座長：奥山 義弘 (株式会社 HPC テック)

LS 医用画像 AI の進化、普及を支える GPU 関連テクノロジー

○山田 泰永

エヌビディア合同会社

一般演題 7

17:00 ~ 18:00

OP7「微細構造解析1」

座長：増谷 佳孝(広島市立大学)

鈴木 秀宣(徳島大学)

OP7-1 深層学習に基づく共焦点顕微鏡画像超解像

○呉 運恒¹, 小田 昌宏^{2,1}, 林 雄一郎¹, 武部 貴則^{3,4,5}, 長田 翔伍⁶, 河村峻太郎⁷, 森 健策^{1,8,9}

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東京医科歯科大学統合研究機構, ⁴Division of Gastroenterology, Hepatology and Nutrition, Developmental Biology, and Center for Stem Cell and Organoid Medicine (CuSTOM), Cincinnati Children's Hospital Medical Center, ⁵Department of Pediatrics, College of Medicine, University of Cincinnati, ⁶慶應義塾大学医学部外科学, ⁷東京医科歯科大学医歯学総合研究科, ⁸名古屋大学情報基盤センター, ⁹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 used a method based on deep learning to improve the resolution of confocal microscope images. The confocal microscope is a kind of microscope commonly used in vivo imaging for biomedical research. However, when the confocal microscope takes high-resolution images, the field of view is very small. On the contrary, when expanding the imaging range and taking a wide-field microscopy image, the images will be low resolution. Therefore, in order to obtain wide-field and high-resolution confocal microscope images, this paper uses the super-resolution method based on deep learning to improve the resolution of confocal microscope images. Through image processing and deep learning methods to improve the resolution of confocal microscope images, rather than replacing the higher resolution microscope, which can be more conveniently for biomedical researchers to observe the research objects more conveniently.

OP7-2 悪性リンパ腫細胞核画像の低次元表現獲得と特徴の集合に基づくサブタイプ識別器の構築

○小出 新悟¹, 橋本 典明², 横田 達也¹, クグレマウリシオ¹, 大島 孝一³, 三好 寛明³, 永石 美晴³, 竹内 一郎¹, 本谷 秀堅¹

¹名古屋工業大学, ²理化学研究所, ³久留米大学 医学部 病理学講座

悪性リンパ腫のサブタイプ同定は治療法や予後を決定するため重要である。細胞核形態の違いに基づくサブタイプ識別は、病理医の経験に基づいた定性的な判断によるところが大きい。本研究では、細胞核形態を病理医の知見に基づき定量化する手法を提案する。また、定量化により得られた形態特徴量の集合を入力とする識別を行う。識別対象とするサブタイプはDLBCL, FL, Reactiveである。まず、病理医の方から注目すべき形態特徴を聴き、その形態についての類似度を計測する。類似度から細胞核どうしの類似、非類似を決定したうえで Contrastive Loss による低次元射影を行う。得られた特徴の集合を入力として識別を行う。結果として、細胞核形態の低次元特徴量を獲得することができた。識別ではDLBCLは8割を超える識別率となった。DLBCLは肥大化した細胞核が多く分布しているため識別が容易であると考えられる。

OP7-3 X線暗視野撮像法で描出される篩状型非浸潤性乳管癌の悪性度に着目した腺腔の解析

○吉田 匠¹, 砂口 尚輝², 谷口 華奈², 黄 卓然², 島雄 大介³, 西村理恵子⁴, 岩越 朱里⁴, 市原 周⁴, 湯浅 哲也⁵, 安藤 正海⁶

¹名古屋大学医学部保健学科放射線技術科学専攻, ²名古屋大学大学院医学系研究科総合保健学専攻, ³北海道科学大学保健医療学部診療放射線学科, ⁴名古屋医療センター病理診断科, ⁵山形大学大学院理工学研究科, ⁶高エネルギー加速器研究機構

放射光光源を用いるX線暗視野法(XDFI)は、生体軟組織内を高コントラスト・高空間分解能で可視化できる。我々の研究グループでは近年、XDFIを用いて乳癌の初期段階である非浸潤性乳管癌(DCIS)を撮影し、DCISの篩状構造(微小なバブル状の腺腔構造)と2次元平面上では見分けが付きにくい通常型乳管過形成の腺腔構造に3次元形状や分布で差異があることを示した。一方で、DCISの篩状構造を持つ症例の中でも形状や分布に大きな違いがあった。本研究では、この違いが生じるメカニズムを知るために、DCISの篩状構造から得られる形状や分布の情報を低中高3段階の病理組織学的悪性度(グレード)ごとに分類した。この結果、腺腔の密度は低~中グレードにかけて大きく増加するが、中~高グレードにかけて低下する傾向が見られた。また、腺腔の体積は低~中グレードにかけて低下し、中~高グレードにかけて大きく増加することが分かった。

OP7-4 マルチモーダルゲーティングを用いた Mixture of Experts による病理画像分類

○橋本 典明¹, 高木 優介², 増田 大輝², 三好 寛明³, 高野 桂³, 永石 美晴³, 佐藤 健作³, 大島 孝一³, 本谷 秀堅², 竹内 一郎^{1,2}

¹ 理化学研究所, ² 名古屋工業大学, ³ 久留米大学

近年、医用分野において画像だけではなくその他の患者情報や検査結果を組み合わせたマルチモーダル解析の研究が行われている。本研究では mixture of experts の枠組みを利用し、診断情報を組み合わせることで各入力画像に対してどの expert で特徴抽出を行うかを決定する分類モデルを提案する。問題設定として巨大画像を対象としたマルチインスタンス学習を扱うが、提案手法はバッチ画像単位でゲーティングを行うことでより詳細な役割を各 expert に与えることを可能とする。本稿では画像として病理標本バーチャルスライド、診断情報としてフローサイトメトリー (FCM) データを使用し、リンパ腫症例の分類実験を行うことで提案手法の有効性を確認する。また各症例に対するゲーティングの重みを解析することで、FCM データから自動的に学習した各 expert の役割を明らかにする。

OP7-5 色素性皮膚病変のハイパースペクトル画像で探索的データ分析

○アルボヤニエレニ¹, 市村 孝也², 浜田 芽衣², 村上 拓生³, 佐々木 惇², 中村晃一郎³, 石川 正弘⁴, 小林 直樹⁴, 小尾 高史⁵

¹ 東京工業大学 工学院 情報通信系, ² 埼玉医科大学医学部中央病理診断部・病理診断科, ³ 埼玉医科大学医学部皮膚科,

⁴ 埼玉医科大学 保健医療学部, ⁵ 東京工業大学 科学技術創成研究院 未来産業技術研究所

Amid the global Covid-19 pandemic, the importance of telepathology and computer-assisted diagnosis is prominent. Skin cancer has a high incidence worldwide and early detection is key for successful treatment. Hyper-Spectral Imaging (HSI) is an emerging non-invasive modality for the gross pathology of the skin. Spectral signatures of skin tissue samples can help detect valuable pathological features and discriminate malignancies. In this study, we applied exploratory data analysis on a new HSI dataset of 20 ex-vivo skin samples during pathology. Hyper-spectral imaging was performed using a custom imaging system that operates in the range [420,730] nm with step 1nm. We evaluated histology-validated cancer margins against components derived from Principal Component Analysis, Reconstructed Independent Component Analysis and Spectral Angle Mapper, among others. Data insights were evaluated by medical professionals. Preliminary findings show that the first principal components can provide information regarding the condition of the underlying tissue. Such information can be used to determine optical cancer margins.

一般演題 8

8:30 ~ 9:30

OP8「経時画像解析1」

座長：庄野 逸 (電気通信大学)

間普 真吾 (山口大学)

OP8-1 ICI治療のNSCLC患者における肺腫瘍細胞数の経時変化曲線の推定

○内野 恭美¹, 有村 秀孝², 田中謙太郎³, 藪内 英剛²¹九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医用量子線科学分野, ³九州大学大学院医学研究院呼吸器内科学分野

本研究では、免疫チェックポイント阻害剤(ICI)により治療された非小細胞肺癌(NSCLC)患者のCT画像を用いて、腫瘍細胞数の経時変化曲線(TGT)を推定する方法を研究した。ICI治療(Atezolizumab)を受けたNSCLC患者7人を用い、腫瘍輪郭を抽出し腫瘍細胞数を計算した。腫瘍輪郭は治療前CTとフォローアップCT画像で抽出した。各腫瘍細胞はICIに対して耐性、感受性または効果の持続性を持ちうると仮定し、Bertalanffy - Putterモデルを用いてTGTを予測した。また、焼きなまし法を用いてTGTモデルの14個のパラメータを最適化した。各CT撮影時点における腫瘍細胞数と予測値の関係を、スピアマン相関係数を用いて評価した。スピアマン相関係数の平均値は0.5322であった。本手法はICI治療患者のTGTを推定できる可能性がある。

OP8-2 胸部X線画像および診断構造化ラベルを用いた機械学習による急性呼吸窮迫症候群(ARDS)患者の早期死亡予測

○斉藤 幸喜

帝京科学大学・生命環境学部・生命科学科

急性呼吸窮迫症候群(ARDS)とは、重症肺炎や敗血症などの様々な疾患が原因となり重度の呼吸不全となる症状の総称である。

本研究では、胸部X線ビッグデータ(MIMIC-CXR-JPG)を用いて作成した機械学習モデルを用いてARDS患者の早期死亡予測について検討した。機械学習には160枚の胸部X線画像および診断構造化ラベルを用い、DataRobotを利用したマルチモーダルな解析を行った。最適化したモデルで死亡予測を行ったところ、AUC=0.9524を達成した。

このモデルを用いて、学習および評価で使用していない10名のARDS患者の入院初期の画像および構造化ラベルを用いて死亡の早期予測について検討した。さらに、この内の1名について時系列で死亡予測を行ったところ、予測した死亡確率の緩やかな上昇が認められ、死亡確率0.4程度で重点的な早期介入が必要であることが示唆された。

OP8-3 トポロジー画像解析による体幹部定位放射線治療を受けたステージI非小細胞肺癌患者の進行予測

○児玉 拓巳¹, 有村 秀孝², 二宮 健太¹, 白川 友子³, 吉武 忠正², 塩山 善之⁴

¹九州大学大学院医学系学府保健学専攻, ²九州大学医学研究院保健学部門, ³国立病院機構 九州がんセンター, ⁴九州国際重粒子線がん治療センター

Treatment options for early-stage non-small cell lung cancer (NSCLC) patients are surgery and stereotactic ablative radiotherapy (SABR), and the outcome of SABR is comparable to that of surgery. Hence, pretreatment prediction of cancer progression after the treatment is crucial for choosing more appropriate treatment options. Some previous studies reported the prognostic predictability of topological radiomics features for lung cancer patients. This study aimed to explore a topological radiomics signature on pretreatment planning computed tomography images to predict time to progression (TTP) of stage I NSCLC patients after SABR. 125 primary NSCLC patients treated with SABR including 44 progression cases (local relapse, n = 28; lymph node metastasis, n = 15; distant metastasis, n = 21) were divided into training (n = 88) and test datasets (n = 37). The progression predictability of topological features (TFs) was compared with that of conventional wavelet-based features (WFs). TFs were obtained from Betti maps that can quantify the tumor heterogeneity, holes, and cavitation. A signature was constructed with significant features selected based on a Cox-net algorithm, and radiomics scores were calculated from the signature. The patients were stratified into high-risk and low-risk groups using the median of the radiomics scores in the training. The predictability was evaluated in the test using p-values (log-rank test) between Kaplan-Meier curves for the TTP of the two groups, concordance index (c-index), and multiplication of negative logarithm of p-value and c-index (nLPC), which was considered a comprehensive evaluation index. For the test, the p-values, c-indices, and nLPCs were 3.28×10^{-2} , 0.80, and 1.19 for TFs and 3.13×10^{-2} , 0.72, and 1.08 for WFs, respectively. TFs showed a statistically significant difference ($p < 0.05$) and higher predictive performance than WFs according to the nLPCs. A potential of the topological signature for progression prediction of stage I NSCLC patients prior to SABR were suggested.

OP8-4 3DCNN を用いた MR 画像における前立腺癌患者の術後尿禁制予測

○大羽 史晃¹, 寺本 篤司¹, 住友 誠², 中村 渉²

¹藤田医科大学大学院 保健学研究科, ²藤田医科大学 医学部

前立腺癌は他の悪性腫瘍に比べ進行が緩徐であるため適切な治療により根治が期待でき、近年は、治療法の1つである手術療法において低侵襲なロボット手術の普及により、従来の手法に比べ早期の社会復帰が可能となっている。しかし、依然として副作用である尿失禁が生じた場合、患者の日常生活への影響は無視できないため、術後の尿禁制予測は、治療法選択の一助となることが期待される。そこで本研究では、多施設にて診断時に撮影されたMR画像に対し画像信号強度の不均一補正や3次元的なトリミングといった前処理を行った後、3DCNNに入力し、症例ごとに尿禁制良好および不良の分類を行った。尿禁制の程度については、術後6か月の時点における1日の尿パッド交換枚数を基に良好と不良に分けた。結果は、尿禁制良好の正解率が82.5%、尿禁制不良では61.9%となり、Balanced Accuracyが72.2%であった。以上の結果より、本手法が前立腺癌患者の術後尿禁制予測に有効であることが示唆された。

OP8-5 深層学習を用いた小児脳 CT 画像からの脳年齢自動推定と Grad-Cam による注目箇所の可視化

○森田 蓮¹, 安藤 沙耶², 藤田 大輔¹, 石川 翔³, 尾上 宏治³, 安藤久美子³, 石蔵 礼一³, 小橋 昌司¹

¹兵庫県立大学 大学院 工学研究科, ²兵庫県立尼崎総合医療センター, ³神戸市立医療センター中央市民病院

0歳から3歳の小児期における子供の脳の発育はとても急速である。この時期における脳の成長を定量的に評価する方法が求められている。本研究では小児の脳CT画像に人工知能を適用し脳の発達年齢を推定する手法を提案する。この手法では、まずCT画像から頭蓋領域を抽出し、姿勢と位置の校正を行う。次に、3次元畳み込みニューラルネットワーク(3DCNN)を用いて、CT画像から特徴を抽出し、全結合層で脳の発達年齢を推定する新しいニューラルネットワークモデルを提案した。このモデルを0から47ヶ月(3歳11ヶ月)までの脳神経医学的に異常のない小児264人を用いて学習と評価を行った。また、頭蓋の校正方法が年齢推定に与える有効性を検証した。予測年齢と患者の実年齢の間の平均絶対誤差(MAE)は 4.11 ± 2.87 月で相関係数は0.91であった。また、勾配加重クラスマッピング(Grad-CAM)を用いてモデルが推定に際して着目した脳領域の可視化を行った結果についても検討した。

一般演題 10

9:30 ~ 10:20

OP10「経時画像解析 2, 他」

座長：原口 亮 (兵庫県立大学)

畑中 裕司 (大分大学)

OP10-1 敗血症モデルラットの微小循環動画像に対する血管密度解析

○田口 竣也¹, 川崎 真未¹, 羽石 秀昭²¹千葉大学大学院融合理工学府基幹工学専攻医工学コース, ²千葉大学フロンティア医工学センター

敗血症は感染症に起因して発症し、生命に危機を及ぼす臓器障害である。発症初期には100 μ m以下の血管径である微小循環が障害される。このため敗血症に対する薬効の調査では、微小循環の変化を観察することが重要となる。先行研究では、小動物実験による敗血症モデルラットの微小循環動画像群の収集及び血流速度による経時変化解析が行われた。ここでは血流速度を算出し、敗血症モデルラットでは低下傾向、薬剤を投与したラットは回復傾向が確認された。本研究では、敗血症モデルラットの微小循環動画像群の同一領域の経時変化解析を行うために、動画像群に対し位置合わせを行った。位置合わせは血管の分岐点を特徴点とした手法を用いて行った。また、位置合わせ結果を用いて、同一領域での血管密度による経時変化解析を行った。血管密度を算出したところ、敗血症モデルラットの血管密度は減少した一方で、薬剤を投与したラットの血管密度は一部の動画像群で回復傾向が確認された。

OP10-2 動画像解析を用いた脳卒中の病院前診断における顔面麻痺の自動評価

○生澤 直樹¹, 吉田 陽一², 栗原 聡³, 中田 孝明², 羽石 秀昭⁴¹千葉大学大学院融合理工学府, ²千葉大学大学院医学研究院, ³松戸市立総合医療センター脳神経外科, ⁴千葉大学フロンティア医工学センター

脳卒中の病院前診断において顔面麻痺は重要な項目の一つである。顔面麻痺は顔面神経の障害部位により中枢性と末梢性に分けられ、脳卒中などによって引き起こされる中枢性では顔の下半分に症状が表れるという特徴がある。本研究では、深層学習を用いて顔の特徴点を自動認識した上で、特徴点の動画像解析によって中枢性顔面麻痺を自動評価する。具体的には入力動画像から患者の顔の認識・特徴点の検出を行い、口の特徴点を用いて口の動きの対称性・口の動きの量・口の形状などを反映した評価指標を算出する。臨床医によって再グレーディングされた末梢性顔面麻痺のデータセットを用いて各指標に関する有意差検定を行った結果、顔面麻痺を判別できる可能性が示唆された。また、末梢性顔面麻痺のデータセットと中枢性顔面麻痺のデータセットを用いて分類性能検証を行った結果、概ね良好な結果が得られた。

OP10-3 ダーモカメラ画像を用いたシワ・キメの特徴解析

○浅野 祐太¹, 西澤 巧¹, 梶田 大樹², 石井 龍之², 貴志 和生², 佐藤いまり¹¹国立情報学研究所 コンテンツ科学研究系, ²慶應義塾大学 医学部

人間の皮膚は、外的要因から体内を守り、恒常性を保つ重要な役割を担う器官であるが、一方で美容的な観点からも皮膚の状態評価が重要である。皮膚の評価項目の一つとして、皮膚のシワ・キメと呼ばれる肌の細かい凸凹の形状パターンから皮膚の状態を評価するが、撮影された皮膚画像からシワ・キメは判別しづらく、正確に可視化することは困難である。

そこで、シワ・キメを可視化するために、通常の画像(「非偏光画像」)および偏光板を用いて直接反射光成分を減らした画像(「偏光画像」)の2枚の画像を入力とした画像処理手法を開発した。皮膚表面での直接反射光の差分を抽出するために、非偏光画像と偏光画像の画素毎の輝度比を算出する。そして、皮膚の色による背景輝度のムラを削減するために、ガウシアンブローを適用した偏光画像との差分を算出することで、正確なシワ・キメの可視化を行う。このシワ・キメの可視化画像についてのGabor特徴量を解析することで、シワ・キメの間隔や方向性のパターンを定量的に評価した。

OP10-4 異なるモダリティによって撮像された医用画像の相同性評価

○小林麟太郎¹, 原 武史², 周 向栄², 野崎 太希³, 松迫 正樹³, 藤田 広志²

¹岐阜大学院自然科学技術研究科, ²岐阜大学工学部, ³聖路加国際病院放射線科

Ultrashort TE (以降 UTE) 画像はエコー時間を短くすることで皮質骨内の水分を検出でき、X 線 CT 検査の代わりとして利用できる可能性が示されている。本研究の目的は、X 線 CT 装置で撮像された膝画像と UTE 法によって撮像された MRI 膝画像において、皮質骨領域の形状の相同性を、物理評価と主観評価の 2 つから評価することである。CT 画像、MRI 画像の同患者を含む全ペアに対して、物理評価では特徴量を用いた L2 ノルムによる類似度評価、主観評価では専門医による類似度評価を行う。物理評価と主観評価の相関係数は約 0.360 となり、やや相関係数があることがわかった。今後の展望は、主観評価、物理評価ともに精度向上を目指すとともに、UTE により撮像された MRI 画像が CT 画像の代替となり得るかの判断を、主観評価と物理評価がどの程度近似したら下すのか、専門医と検討し決定することである。

7月31日(日)

第 1 会場 (ホール)

シンポジウム 4

10:30 ~ 11:50

SY4 「医用画像データベースとネットワーク」

座長：佐藤 嘉伸 (奈良先端科学技術大学院大学)

平尾 彰浩 (株式会社 Surg storage)

SY4-1 医用画像データの利活用を支えるネットワーク基盤 SINET6

○漆谷 重雄

国立情報学研究所

国立情報学研究所では、全国約 1,000 の大学や研究機関等のための学術専用のネットワーク基盤 (SINET: Science Information NETwork) を運用している。SINET は、インターネットと閉域網の両面で利用可能であり、医療分野の研究においては、セキュリティの観点から後者としての利用が主となっている。例えば、AI を用いた医療画像診断支援、手術支援ロボットの遠隔操作、8K 映像を用いた病理診断、医療情報の遠隔バックアップ等、SINET のセキュアかつ高性能 (超高速、短遅延、一時的な帯域確保等) という特徴を活かした利用が増えている。また、研究者との共考共創により、研究に必要なネットワーク機能を開発し高度な利用に繋げるケースも多くある。本講演では、2022 年 4 月に運用を開始した全国を 400Gbps で接続する SINET6 について、その特徴、提供サービス、活用事例などについて解説する。

SY4-2 内視鏡下手術のデータベース構築とそれがもたらしうる価値

○伊藤 雅昭

国立研究開発法人国立がん研究センター東病院

手術現場に内視鏡技術が導入され 30 年以上の年月が経過した。その間に内視鏡手術を検証するための臨床試験が世界中で施行され、今やあらゆる疾患領域において内視鏡手術は標準的な役割を果たすようになった。整容性や低侵襲などの優位性が示される中、内視鏡手術の本質は動画情報のリアルタイムでの共有であるともいえる。内視鏡手術は術中の外科医間での情報共有を可能とし、今やその録画情報のデータベース化を構築する研究開発が国内外で進みつつある。アカデミアの研究材料としてのみでなく、企業が製品開発に翻訳できるような価値のあるデータベース構築のための整備作業はまさに未来の外科学に求められるものである。

国立がん研究センター東病院では内視鏡手術動画のデータベース構築に関する事業 (AMED: 「内視鏡外科手術のデータベース構築に資する横断的基盤整備」)、および手術動画のデータベースからの情報を AI に学習させ製品化を目指す研究開発を行ってきた。本講演ではこれらの開発経験から得られた知見と未来展望についてお話する。

SY4-3 日本医学放射線学会による画像診断ナショナルデータベース (J-MID) の開発とその発展

○明石 敏昭

順天堂大学放射線診断学講座

日本医学放射線学会は画像診断のナショナルデータベースとして日本医用画像データベース (Japan-Medical Image Database: J-MID) を 2017 年に AMED の支援によって構築した。現在国内の 10 大学病院より CT・MR 画像とそのレポートを仮名加工後に J-MID サーバーに送信し、年間約 1 億枚のペースで画像が収集されている。これらのデータは国立情報学研究所のクラウド基盤にも送信し、artificial intelligence (AI) の研究等に利活用できるシステムの開発を行っている。各施設には J-MID 規格のアノテーションを付与し、送信するシステムが導入されており、放射線専門医の協力により迅速な教師データの収集を可能にしている。これまでに COVID-19 肺炎や腎癌、くも膜下出血などを対象とした AI 研究を行ってきたが、現在は COVID-19 肺炎検出 AI を用いて J-MID 内での発生をモニタリングするというサーベイランス研究を実施している。

SY4-4 医用画像データベース構築の落とし穴と活かし方

○黒田 知宏

京都大学 医学部附属病院 医療情報企画部

近年、医療画像 AI 開発の礎として、教師データとなる医用画像データベースを作る取り組みが各方面で進められている。しかし、画像データを活用の際には、様々な法的・金銭的な制約があるため、予め適切な出口戦略を描いておかなければ、得られた知識を社会に展開することすら難しくなってしまう可能性がある。日本医療研究開発機構 (AMED) では、医療画像系学会が画像データベースを構築する研究の支援を 2016 年から実施したが、その際に発生した問題を解決し、適切な出口戦略を描くための参考に、日本医療情報学会に「ガイドライン」作成を求めた。本講演では、このガイドラインを参考に、医用画像データベース構築は始める前に確認しておくべき事柄についてご紹介する。

7月31日(日)

第1会場 (ホール)

特別講演 2

13:20 ~ 14:20

SL2 「小惑星探査機「はやぶさ2」帰還粒子の放射光 CT 観察から導かれる、小惑星リュウグウの形成・進化史」

座長：工藤 博幸 (筑波大学)

SL2 小惑星探査機「はやぶさ2」帰還粒子の放射光 CT 観察から導かれる、小惑星リュウグウの形成・進化史

○上相 真之

高輝度光科学研究センター

小惑星探査機「はやぶさ2」は 2020 年に小惑星リュウグウの表面の物質を採取し、地球に帰還することに成功した。放射光実験施設 SPring-8 の BL20XU では、2021 年に JAXA から配分された 1-4mm 程度のリュウグウ粒子の 20 粒子以上を、放射光 CT による非破壊 3 次元観察を行った。その結果、小惑星リュウグウは、炭素質コンドライト隕石と呼ばれる、母天体上で水による変成を強く受け、有機物に富む隕石のグループと極めてよく一致する特徴を持つことが分かった。また、CT データの 3 次元解析からは、流体が流れたためにフラットになった面や、亀裂に沿って形成された水成鉱物など、特に液体の水と関連する特徴を多数観測することが出来ている。発表では、データ解析の結果の一例を紹介し、現在進んでいる「はやぶさ2」帰還試料の分析結果から得られた小惑星リュウグウの形成・進化の描像を紹介する。

一般演題 13

14:30 ~ 15:30

OP13「CAD2」

座長：河田 佳樹(徳島大学)

寺本 篤司(藤田医科大学)

OP13-1 Deep Auto Encoder を用いた眼底画像からの糖尿病性網膜症の判別

○安倍 和弥¹, 武尾 英哉¹, 永井 優一², 高橋 嘉晴³¹ 神奈川工科大学, ² 国立がん研究センター東病院, ³ たかはし眼科クリニック

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。

糖尿病性網膜症とは、糖尿病の三大合併症の一つであり、日本における中途失明の代表的な原因であるとされる。従来の糖尿病性網膜症の診断は、医師が経時的に撮影した複数の眼底画像を比較読影することで診断しており、診断能は医師の技能によるところが大きく、病変を客観的かつ正確に把握することがやや困難であった。

本研究では、Deep Learning 技術を用いた Auto Encoder により、糖尿病性網膜症を判別する手法について研究を行う。Auto Encoder により原画像から Decode 画像を作成、それと原画像を比較することにより異常部位を検出する。Auto Encoder は、あらかじめ正常な眼底画像だけで学習させて構築する。学習済みの Auto Encoder に疾患のある眼底画像が入力された場合、Decode 画像には異常部位が復元されないため、両者の差分をとることで異常陰影の検出が可能となる。異常陰影の提示を行うことにより、客観性のある識別が可能となり診断精度の向上が期待できる。

OP13-2 機械学習による白色上皮領域検出におけるコルポスコブ画像の実験的検討

○篠原 寿広¹, 小林 陽輝¹, 村上 幸祐², 中迫 昇¹, 松村 謙臣²¹ 近畿大学生物理工学部生命情報工学科, ² 近畿大学医学部産科婦人科学教室

子宮頸がん診断において、コルポスコブとよばれる拡大鏡を用いて子宮頸部の目視による検査が行われている。本検査はコルポスコピーとよばれ、子宮頸がんの確定診断を行う組織診のための組織を採取する部位を決定する非常に重要な検査である。子宮頸部の病変はさまざまな所見を呈するため、コルポスコピーには豊富な知識と経験が必要とされる。本研究では、コルポスコブ画像を用いて機械学習による診断支援を行ってきた。これまで初期検討として、撮影条件などを考慮せずに撮影したコルポスコブ画像を試行的にそのまま使用していた。しかしながら、コルポスコブ画像は撮影条件や個人差などにより色合いが大きく異なる。そこで、当該研究では、畳み込みニューラルネットワークを用いた、子宮頸部の代表的な病変の一つである白色上皮の判別において、コルポスコブ画像の色合いに着目した画像選択による判別精度の影響について実験的に検討した。

OP13-3 正例とラベル無し画像からの学習による子宮頸部病変の識別

○マナロマーガレット ディー¹, 青木 工太¹, 武 淑瓊¹, 新堂真利子², 上田 豊², 八木 康史¹¹ 大阪大学 産業科学研究所 複合知能メディア研究分野, ² 大阪大学 大学院医学系研究科 産科婦人科学教室

Cervical screening is a crucial component in the mitigation and treatment of cervical cancer. Multiple procedures are often used to produce a diagnosis, most of which are not readily accessible in low-resource regions. Thus, visual inspection has been designated as an economical alternative despite its subjectivity. Many have attempted to automate and improve visual inspection with machine learning by training models on cervigrams, however most rely on the assumption that the data is fully labeled when in reality such data is often dependent on the limited biopsies done. In this paper, we assume that a multilabel cervigram dataset is positive-unlabeled, meaning labeled cervical lesions are confirmed positives and unlabeled lesions are either positive or negative. Learning was done through simultaneous training of a classifier model and a propensity model which estimates the likelihood of a lesion being labeled. This approach was compared against a supervised learning model commonly used for classification tasks. Results showed our model outperforms the other on several evaluation metrics used to assess classification performance.

OP13-4 補綴物検出を用いた歯科パノラマ画像の歯牙認識性能の向上

○岡 和範¹, 新居 学¹, 藤田 大輔¹, 小橋 昌司¹

¹ 兵庫県立大学大学院 工学研究科

現在の歯科診療の現場では口腔領域をレントゲン撮影した歯科パノラマ画像が広く用いられている。歯科パノラマ画像を基に医師や歯科助手がカルテを作成するが、治療に直接関係しない歯牙を含む全ての歯牙を一つずつ確認し、治療痕の有無等を記述する必要がある。これらの負担によって誤記入などの医療の質の低下につながる可能性がある。そのため、診療に際して歯科パノラマ画像の自動解析が望まれている。CNNを用いた歯牙自動認識の研究があるが、口腔内に類似した歯牙が複数存在するため十分な精度が得られていない。本研究ではYOLOv5を用いた歯牙検出に加え、4種の補綴物を含む歯牙の検出を行い、それらに対して事前知識モデルを用いた組み合わせ最適化によって歯牙認識を行う手法を提案する。提案手法の実験結果として認識精度最大97.17%を達成した。また、補綴物を用いた歯牙検出を併用し、事前知識モデルを用いた最適化の有用性を示した。

In the current dental practice, many panoramic dental images of the oral cavity are taken by x-ray. Based on the dental panoramic images, the physician or dental assistant prepares a medical record. However, it is necessary to check all the teeth one by one, including those not directly related to the treatment, and to describe the presence or absence of treatment scars. These burdens can lead to a deteriorate the quality of medical care, such as erroneous entries. Therefore, automatic analysis of panoramic dental images is needed in medical practice. There is research on automatic tooth recognition in dental panoramic images using convolutional neural networks (CNN), but it is difficult to obtain sufficient accuracy due to the presence of multiple similar teeth in the mouth. In this paper, we use YOLO v5, a type of CNN developed in 2020, to detect teeth, including four types of prosthetic teeth. We propose a teeth recognition method for the teeth based on combinatorial optimization using a prior knowledge model. The proposed method achieved a maximum recognition accuracy of 97.17% as an experimental result. Therefore, the usefulness of optimization using prior knowledge models in combination with prosthetic tooth detection was demonstrated.

OP13-5 多施設からの眼底画像における緑内障の重症度推定

○村尾 晃平¹, 佐藤 真一¹, 大本 貴士^{1,4}, 柏木 賢治², 三宅 正裕³, 二宮洋一郎¹

¹ 国立情報学研究所 医療ビッグデータ研究センター, ² 山梨大学 大学院総合研究部 医学部 眼科学, ³ 京都大学大学院 医学研究科 眼科学, ⁴ 東京大学大学院 医学系研究科 眼科学教室

日本眼科学会が全国14施設から収集した眼底画像について、正常および11種類の疾患に分類した約1万3千画像がある。これをもとに緑内障のクラスを重症度別に3クラスに分割した14クラスの識別器を作成したところ緑内障の識別率は93%、重症度の識別率は43%であった。なお、施設によって画像サイズやスケールが異なるため、スケールを合わせるような規格化の前処理を考案し、規格化した画像を用いて学習・識別を行った。

一般に、分類すべきクラスが多いとエントロピーが大きくなり推定が困難になる。そこで、緑内障の有無の識別とは別に、緑内障の重症度を専門に判定する識別器を作成して組合せることで精度向上できるのではないかと考えた。前段で作成した識別器を緑内障有無の判定に使い、緑内障有と推定された症例に重症度判定の識別器を使うようにしたところ、緑内障の識別率はそのまま、重症度の識別率を64%に向上させることができた。

一般演題 15

15:40 ~ 16:40

OP15「CAD3」

座長：木戸 尚治 (大阪大学)

野村 行弘 (千葉大学)

OP15-1 臨床情報を加えた改良型 ResNet による CT 画像からの結節状陰影の識別

○本田 直也¹, 鈴木 裕紀², 神谷 亨¹, 木戸 尚治²¹九州工業大学大学院工学研究院機械知能工学系知能制御工学, 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

近年、肺がんの検査方法として CT 検査が多く用いられているが、得られる CT 画像の枚数は膨大であり、読影医師の大きな負担となっている。そこで、この問題を軽減するためにコンピュータ支援診断システムの開発が行われている。一般に医師が診断を行う際、画像情報以外に患者情報も加味していることから、これを機械で模倣することにより、診断精度を向上させる新しい取り組みが行われている。

そこで本論文では、画像以外にカルテ情報を追加することによる診断精度の向上を目的とした肺結節の識別法を提案する。画像特徴から誤認識の一因とされる血管影の分岐情報や血管影、結節状陰影などを教師ラベルとして付与し、未知データからの分類を行う。実験では 159 枚の結節画像を含む計 636 枚に対し、臨床情報を追加した場合の識別結果は、画像情報のみを用いた場合と比較して、真陽性率と正解率は 1% 向上し、臨床情報の追加による精度向上が確認できた。

OP15-2 Vision Transformer を用いた胸部 X 線画像の画像分類による COVID-19 の診断

○伴 凌輔¹, 原田 恵雨¹, 中村 嘉彦¹, 三上 剛¹¹苫小牧工業高等専門学校

COVID-19 は様々な診断方法が提案されている。PCR 検査は最も一般的だが結果の判明に時間を要するなどの問題があった。そのため高速な診断のために機械学習による研究が行われている。また、自然言語処理で利用される Transformer を画像処理に転用した Vision Transformer (ViT) は、一般的な画像分類で用いられる CNN を用いずに CNN と同等以上の精度になることがわかっている。本研究では ViT を用いて COVID-19 患者の胸部 X 線画像の分類による迅速な診断を目的とする。ハイパーパラメータ最適化に Optuna を使用し、選択されたオプティマイザ Adam 及び学習率で学習を行った。また、正解率などの指標で評価した結果、各指標で約 90% の精度を出すことが分かった。また、課題として誤分類の解消が必要である。今後は軽症患者と正常者の判別が困難なために誤分類が起こると仮定し重症度分析を行う。

OP15-3 LPC と HPSS を用いた呼吸音の自動分類

○田端 愛美¹, 陸 慧敏¹, 神谷 亨¹, 間普 真吾², 木戸 尚治³¹九州工業大学, ²山口大学, ³大阪大学

呼吸器疾患の多くは世界の死因上位に挙げられており、年間 800 万人近い死者が出ている。呼吸器疾患の主な診断方法は聴診器を用いた聴診である。しかし、定量的な基準がなく、経験豊富な医師が不足する発展途上国や、災害現場では診断が困難になる場合がある。この問題を解決するため、呼吸音を定量的に分析・分類し、「第二の意見」として出力するコンピュータ支援診断 (CAD: Computer Aided Diagnosis) システムが必要である。本論文では、呼吸音データを調波打楽器音分離 (HPSS: Harmonious / Percussive Sound Separation) によって異常呼吸音特徴を強調分離し、分離前を含む 3 種類の音声データを、それぞれ線形予測分析 (LPC: Linear Predictive Coefficient) によって得られたスペクトル包絡から画像生成を行う。3 種類の画像を CNN (Convolutional Neural Network) と LightGBM (Light Gradient Boosting Machine) を用いて分類する。提案手法を ICBHI (International Conference on Biomedical and Health Informatics) 2017 Challenge で使用されたデータセットに適用した結果、Sensitivity は 58.8%, Specificity は 87.0%, Average Score は 72.9%, Harmonic Score は 70.2%, Accuracy は 73.7%, Area Under the Curve は 86.8%, 偽陰性率は 29.4% を得た。

OP15-4 悪性・良性腎腫瘍鑑別のための多時相造影 CT 画像データベース作成

○西岡 大¹, 西平 健斗¹, 鈴木 秀宣², 松廣 幹雄², 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理工学専攻, ²徳島大学大学院社会産業理工学研究部, ³東京女子医科大学病院, ⁴筑波大学, ⁵徳島大学発ベンチャー企業医用科学研究所

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する。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, 性別, 年齢, 腎腫瘍の体積・形, 種類, 非造影・動脈相・門脈相・平衡相画像を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。

To develop a highly accurate differentiation method for malignant and benign tumors by precisely analyzing kidney and renal tumors from multi-temporal 3D contrast-enhanced CT images. To this end, a database of multitemporal contrast CT images of 200 cases of kidney and renal tumors will be constructed. Using this multi-temporal phase abdominal contrast CT image database, 5 types of kidney and renal tumors (pallidocystic renal cell carcinoma, pigmented renal cell carcinoma, papillary renal cell carcinoma, angiomyolipoma, and oncocytoma) will be extracted with high speed and accuracy using 3D U-Net and analyzed by gender, age, volume and shape of renal tumor, type, non contrast, arterial phase, portal vein Clustering and association of phase and equilibrium phase images. We present a highly accurate method for the identification of small renal tumors by analyzing the circulatory dynamics of small renal tumors.

OP15-5 3 次元 CT 画像によるじん肺の重症度別粒状影解析

○橋本 悠雅¹, 松廣 幹雄¹, 鈴木 秀宣¹, 河田 佳樹¹, 大塚 義紀², 岸本 卓巳³, 芦澤 和人⁴, 仁木 登⁵

¹徳島大学, ²北海道中央労災病院, ³岡山ろうさい病院, ⁴長崎大学, ⁵株式会社医用科学研究所

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。日本において毎年 24 万人前後の粉じん労働者がじん肺健康診断を受診している。じん肺健康診断として胸部単純 X 線撮影や肺機能検査が実施されている。胸部単純 X 線写真によって第 0 型, 第 1 型, 第 2 型, 第 3 型, 第 4 型に分類され, 第 1 型以上の患者は労災認定となるが第 0 型の患者は労災認定の対象とならないため正確に診断しなければならない。ここで, 近年では単純 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 画像を用いたじん肺の診断支援システムの開発を目指している。重症度別の症例の 3 次元 CT 画像からじん肺の粒状影を肺葉別に抽出した。じん肺の病種別に粒状影の個数, 大きさ, 分布を比較することで定量的に重症度の進行と診断基準を評価した。

一般演題 17

16:40 ~ 17:30

OP17「CAD4」

座長：根本 充貴(近畿大学)
神谷 直希(愛知県立大学)

OP17-1 Faster-R-CNN を用いた胸部 X 線像における肺結節の検出

○韓 磊¹, 平野 靖²¹ 山口大学大学院創成科学研究科, ² 山口大学医学部附属病院

肺がんは悪性腫瘍の中で発生率、死亡率ともに第1位となっている。肺がんは早期発見により、早期に治療が開始できれば生存率の上昇が期待される。そのため、通常、集団検診においては胸部 X 線検査によるスクリーニングが行われ、悪性の可能性がある肺結節が発見されれば、CT 画像などによる精密検査が行われる。集団検診で撮影される胸部 X 線像の数は膨大であり、読影医の負担が大きくなっている。また、肺結節は様々な濃度や形状を持つうえ、肋骨や心臓などと重なって撮影された場合には発見が難しい。

そこで本研究では、医師の負担の軽減と肺結節の見落としの削減を目的として、Deep Learning の一種である Faster-R-CNN を用いて肺結節の検出手法の構築を行った。日本放射線技術学会(JSRT) データベースを用いて提案手法の学習と評価を行った。その結果、検出容易・比較的容易・困難とされた症例では真陽性率は 78.0[%]、適合率は 64.1[%] となった。一方、検出が非常に困難・極めて困難とされた症例では、それぞれ 36.0[%] および 51.7[%] となった。

OP17-2 Supervised Contrastive Learning を用いた胸部 CT 画像におけるびまん性肺疾患の陰影識別

○森崎 幹也¹, 間普 真吾¹, 木戸 尚治²¹ 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

識別問題では、Cross-Entropy Loss を用いることで、特徴量空間において特徴量を分離できる。一方 Contrastive Learning では、同じクラスに属するデータの特徴量は近く、異なるクラスに属するデータの特徴量は遠くなるように学習を行うことで、識別性の高い、そのクラスに本質的な特徴量の抽出が可能となる。本研究では、教師あり学習の枠組みの中で、ラベル情報を活用してより適切な特徴の埋め込みを行う Supervised Contrastive Learning に着目し、胸部 CT 画像の陰影識別タスクに適用した。2つの異なるドメイン(大阪大学病院症例, 山口大学病院症例)各々への適応, およびドメインを超えた適応の観点から行った4つの検証パターン全てにおいて Accuracy が向上した。また、t-SNE を用いた特徴量の可視化により、クラス毎のより明確なグループの形成を確認した。

OP17-3 Contrastive Learning に基づく次元削減による胸部 CT 画像に対する異常検知

○飛世 裕貴¹, クグレマウリシオ¹, 横田 達也¹, 橋本 正弘², 大竹 義人³, 明石 敏昭⁴, 清水 昭伸⁵, 本谷 秀堅¹¹ 名古屋工業大学, ² 慶應義塾大学, ³ 奈良先端科学技術大学院大学, ⁴ 順天堂大学, ⁵ 東京農工大学

医用画像診断支援を目的として、胸部 CT 画像中の異常部位検知手法を提案する。正常・異常を分類する2クラス識別器を学習する際、正常データと異常データの学習データ数に不均衡が存在すると識別器の学習が困難となる。本研究では、正常なパッチ画像の確率密度分布に基づく1クラス識別器の考え方を採用することにより、学習データ数のクラス間の不均衡を緩和する。確率密度分布はパッチ画像空間で直接求めるのではなく、画像間の異同がユークリッド距離で表現されるような低次元空間で求める。そこで、Contrastive Loss に基づく学習による次元圧縮法を採用する。Contrastive Loss は利用者が定める変換に対する不変性を獲得する上で有用であり、提案法では並進や反転といった変換に対して不変な射影を学習する。本稿では提案法による胸部 CT 画像中の異常部位の検出結果について報告する。

OP17-4 アノテーションが不完全な教師データを用いた腹部超音波画像からの肝腫瘍検出

○池田 裕亮¹, 道満 恵介¹, 目加田慶人¹, 西田直生志², 工藤 正俊²

¹中京大学大学院工学研究科, ²近畿大学医学部

本稿では、物体検出においてアノテーションが不完全な教師データを用いた場合の損失関数の調整に基づく検出精度向上に関する報告する。腹部超音波画像からの肝腫瘍検出においては、肝細胞がん、転移性がん、のう胞、血管腫など様々な見えの腫瘍を検出することが期待される。これまでの研究では物体検出アルゴリズム YOLO を用いて肝腫瘍検出を行ってきたがそのデータセットには各画像には一つの腫瘍領域が指定されたものを使用していた。転移性肝がんは複数の腫瘍領域が写っていることが多いため使用したデータセットではアノテーションが不完全であった。そのため転移性肝がんの検出精度は他の腫瘍の比べて低い問題があった。そこで、YOLO の学習時に腫瘍の種類に応じた損失の重みを追加した。転移性肝がんの損失を他の腫瘍より小さくすることで不完全なアノテーションの教師データを用いた肝腫瘍検出の精度改善に効果があるのか実験的に示す。

7月31日(日)

第2会場 (シンポジオン)

一般演題 9

8:40 ~ 9:30

OP9 「イメージング 2」

座長：砂口 尚輝 (名古屋大学)

北村 圭司 (株式会社 島津製作所)

OP9-1 MR 深層学習再構成における MR 画像特徴を利用した学習時とテスト時のデータ拡張の有効性に関する検討

○大内 翔平^{1,2}, 伊藤 聡志¹

¹宇都宮大学大学院 工学研究科 システム創成工学専攻, ²日本学術振興会特別研究員 DC

MR 画像の CNN 再構成法は数多く提案されており、近年では既存の画像解析手法と CNN の併用法が注目されている。我々が昨年度に報告した eFREBAS-CNN はその一種であり、多重解像度解析手法の eFREBAS 変換と CNN を併用し、異なる周波数成分から構成される複数枚の変換像を、グループごとに別個の CNN で学習することで、高周波成分の復元性能の向上を図った。本研究では eFREBAS 変換が複素変換である性質を利用した、さらなる画質改善法を提案する。位相を有する複素画像の実部と虚部は、一般に正と負の値をもつ。撮像時のエコー信号が現れる座標を -x 軸にする、あるいは、位相を反転させた場合には実部や虚部の輝度値を反転した MR 画像が出現することが有り得る。そこで、オリジナルの輝度を持つ画像と輝度反転画像を併用することで、Data Augmentation や Test Time Augmentation を行ったときと同等の効果を得られる手法を導入した。実験の結果、提案手法の導入により、従来法よりもアーチファクトの除去性能が向上し、PSNR を改善させることができた。

OP9-2 Whole Gamma Imaging による ⁸⁹Zr 撮像において 909keV コンプトンイメージングが PET の空間分解能を超える可能性

○田島 英朗¹, 田久 創大¹, 錦戸 文彦¹, 菅 幹生², 赤松 剛¹, 高橋美和子¹, 山谷 泰賀¹

¹量子科学技術研究開発機構, ²千葉大学

PET は陽電子飛程と角度揺動によって理論的に空間分解能が制限される。一方、コンプトンイメージングはそれらの制限を受けない。本研究では、WGI (Whole Gamma Imaging) によるコンプトンイメージングが PET の空間分解能を超える可能性を検証するためにモンテカルロシミュレーションを実施した。具体的には、PET リング (LGSO, 厚さ計 20mm, 直径 320mm, ピクセル $1.5 \times 1.5 \times 6.67\text{mm}^3$) に散乱検出器リング (Si, 厚さ計 20mm, 直径 86mm, ピクセル $0.25 \times 0.25 \times 0.5\text{mm}^3$, エネルギー分解能 $0.3\% @ 511\text{keV}$) が挿入された WGI を Geant4 でモデル化した。陽電子と 909keV のシングルガンマ線を両方放出する ⁸⁹Zr を充填した分解能評価用ロッドファントムを、視野中心及び端に置いた場合それぞれの測定を模擬した。エネルギーウィンドウにより、PET イベント及び、909keV のコンプトンイベントを抽出し、それぞれリストモード OSEM 法により画像再構成を行った。その結果、中心に置いた場合には PET と同程度、端に置いた場合には PET では分解できなかった 1mm ロッドまで分解することができた。WGI においてコンプトンイメージングが PET より高い空間分解能を得られる可能性が示された。

OP9-3 Deep Image Prior を用いた SPECT 画像再構成における EM-TV アルゴリズムの検討

○矢部 暁登¹, 松原 佳亮², 越野 一博³, 渡部 浩司⁴, 湯浅 哲也⁵, 銭谷 勉¹

¹ 弘前大学大学院理工学研究科, ² 秋田県立循環器・脳脊髄センター研究所脳血管研究センター放射線医学研究部, ³ 北海道情報大学経営情報学部システム情報学科, ⁴ 東北大学サイクロトロン・ラジオアイソトープセンター, ⁵ 山形大学大学院理工学研究科

我々のグループでは高解像度 SPECT 装置を開発しているが, 十分なカウントが得られない場合, 画質が劣化してしまう。我々は事前学習が不要で, ターゲット画像のみで画像を復元できる DIP(Deep Image Prior)を利用することで画質改善に成功した。本研究では更なる画質改善を目指して, DIP 処理に加えて, トータルバリエーション (TV) を正則化項として組み込んだ EM-TV アルゴリズムを用いた再構成法を検討した。数値ファントムを用いたシミュレーション実験を行い, DIP 無 TV 無, TV のみ, DIP のみ, DIP 有 TV 有で再構成した画像を比較, それぞれの PSNR(dB) は 32.09, 40.3, 41.64, 41.72, SSIM は 0.8590, 0.9355, 0.9462, 0.9467 と DIP と TV の組み合わせが最も良かった。また, 実測データによる再構成画像も, DIP 有 TV 有によってノイズが低減され, ファントムの構造が鮮明になった。DIP と EM-TV による SPECT 画像の画質改善効果が示された。

OP9-4 Dual Energy 散乱線補正と高感度マルチピンホールによる蛍光 X 線 CT の画質改善

○對馬 結太¹, 松岡 将宏², 笹谷 典太², 砂口 高輝³, 河嶋 秀和⁴, 兵藤 一行⁵, 湯浅 哲也², 銭谷 勉¹

¹ 弘前大学大学院理工学研究科, ² 山形大学大学院理工学研究科, ³ 名古屋大学 大学院医学系研究科, ⁴ 京都薬科大学放射性同位元素研究センター, ⁵ 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, 非放射性ヨウ素化合物を用いて生体機能画像の取得を可能とするピンホール蛍光 X 線 CT 装置の開発をしているが, 被写体からの散乱線の影響によりヨウ素のコントラストが低くなる。また, シングルピンホールは感度が低いため統計ノイズが大きくなる。本研究では, Dual energy 散乱線補正法と高感度マルチピンホールを組み合わせた新しい手法によって, 蛍光 X 線 CT 画像のコントラストノイズ比 (CNR) の改善を試みた。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 CNR は, 濃度 0.3 mg/ml のヨウ素にて, シングルピンホール・散乱線補正無しに比べ, 散乱線補正により 3.0 倍に, マルチピンホール化により 2.2 倍に, 両方適用で 4.6 倍に改善された。Dual energy 散乱線補正法とマルチピンホールの相乗効果により再構成画像の画質が大きく改善された。

7月31日(日)

第2会場 (シンポジオン)

一般演題 11

9:30 ~ 10:20

OP11 「イメージング 3, 他」

座長: 菅 幹生 (千葉大学)

森田 尚孝 (株式会社 島津製作所)

OP11-1 データ・カルテシステム (SAKAS) の構築とマイクロ・位相 CT への適用

○米山 明男^{1,3}, 河本 正秀¹, 馬場 理香^{1,2}, 廣沢 一郎¹, 妹尾与志木¹, 兵藤 一行³, 平野 馨一³

¹ 九州シンクロトロン光研究センター, ² (株) 日立製作所研究開発グループ, ³ 高エネルギー加速器研究機構物質構造科学研究所

マイクロ CT や位相 CT 等の放射光を用いたイメージング法により取得した画像データについて, サンプルの名前や状態に加え, X 線カメラやビームラインの計測条件から, 再構成の画像処理に至る全ての条件を統合的に取り扱い, 保存するデータ・カルテシステム (SAKAS: SAga-LS data KAрте System) の構築を進めている。本システムでは, 従来は個別に保存していた条件を, テキスト形式 (windows の ini ファイル形式) で 1 個のカルテ・ファイルとして管理するため, どのような処理がどのような条件で行われたか容易に確認することが出来る。現在, 初版の仕様策定と制御及び処理ソフトの製作を終え, SAGA-LS BL 07 や PF BL14C で試験的な運用を行っている。本発表では SAKAS の仕様と, マイクロ CT 及び位相 CT への適用結果等について紹介する。

OP11-2 A reconstruction method for binary limited-data tomography using a dictionary-based sparse shape recovery

○ハイサムアリ¹, 藤井 克哉², 工藤 博幸²

¹筑波大学 大学院 システム情報工学研究群 情報理工学位プログラム, ²筑波大学システム情報系

Binary tomography is concerned with reconstructing a binary image from a very small number or other limited CT projection data. This problem itself not only possesses several medical imaging applications but also can be considered a model of general inverse problems to recover the object shape from limited measured data. Several approaches such as Mumford-Shah method and various

level-set methods have been investigated, but most of them lead to a non-convex optimization due to the difficulty to handle the binary constraint. We propose a new method based on a convex optimization inspired by dictionary-based Compressed Sensing. In the proposed method, object boundary of binary image is represented by a level set of linear combination of basis vectors in the dictionary. Using the dictionary, the object boundary is reconstructed by finding weights of linear combination which best match to the measured data and the regularization term is the L1 norm of weights to enforce the sparsity (roughness) of binary image. We investigated two different methods to create the dictionary. The first method is based on locating Gaussian functions at non-sparse grid points in the image. The second method is to prepare a very small number of elementary shapes like circles and triangles followed by enlarging the size of dictionary by applying geometric transformations (translation, rotation, scaling) to the elementary shapes. The simulation results of CT image reconstruction from only four projection data demonstrate that the proposed method is able to recover the object boundary more accurately compared with other competitive approaches such as TV reconstruction followed by binarization, empirical Discrete ART (DART) method, and dual method (Kadu and Van Leeuwen, IEEE Trans.Comput.Imaging,2019) (one of newest approaches of binary tomography). The significance of our approach is the formulation with a tractable convex program while keeping moderate mathematical rigorousness.

OP11-3 Whole Gamma Imaging 試作機のシミュレーションによる性能予測

○菊地 智也¹, 田久 創大², 菅 幹生¹, 田島 英朗², 錦戸 文彦², 山谷 泰賀²

¹千葉大学, ²量研機構

Whole gamma imaging (WGI) は PET とコンプトンカメラを組み合わせた新しい画像化技術である。コンプトンカメラを利用することで PET ではノイズであったシングルガンマを利用できるようになる。本研究では、これまでの WGI 試作機よりも角度分解能と感度の向上を目指して設計した装置のモンテカルロシミュレーションによる性能予測を目的とした。具体的には、散乱検出器のシンチレータを GSO からエネルギー分解能の高い GAGG とすることで角度分解能の向上を図り、吸収検出器は time-of-flight PET に適する LGSO を用いた。また、リングの内径を小さくして体軸方向に伸ばすことで感度向上を図った。89Zr 点線源を用いて視野中心から半径方向に 1cm 間隔で線源を配置し、角度分解能と感度を評価した。また、デレンゾファントムを対象として画像再構成をした。その結果、従来機と比較して角度分解能と感度が向上し、画質向上により直径 3mm のロッドが識別できることを確認した。

OP11-4 診療放射線技師教育のための考察型教育用ファントムを用いた教育

○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、BBOXの縦横高さ各3個の27か所の位置に対して、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。

解析の正確性と解析の時間をチームや個人で競争する「BBOX コンテスト」を2021年11月に2つの大学をネットで繋いだ遠隔交流大会を開催した。3~4人を1チームとしたチームによる交流戦と個人戦を実施し、アンケート結果からも有用な学習であることが示唆された。特に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が有効であることが確認できた。

一般演題 12

10:30 ~ 11:50

OP12 「微細構造解析 2」

座長：羽石 秀昭 (千葉大学)

本谷 秀堅 (名古屋工業大学)

OP12-1 病理画像のガンらしさと正常らしさを情報量で評価する情報密度可視化法

○金道 敏樹¹, 陸田 駿弥¹, 山田 壮亮²¹金沢工業大学工学部情報工学科, ²金沢医科大学臨床病理学

近年、畳み込みネットワーク (CNN:Convolutional Neural Network) など人工知能を使った病理画像診断技術が盛んに研究され成果を上げる一方、その判断根拠を示すことが課題として浮かび上がっている。

本研究では、逆に、判断根拠から積み上げる病理画像診断技術実現の可能性を提示する。我々は、性質の分かっている画像特徴量のそれぞれが、「ガンである」と「正常である」とを識別する上での情報量をどれほど持っているかに注目する。この情報量の大きさは、そのまま判断根拠の強さに対応する。したがって、病理画像の各小領域毎に含まれる画像特徴量が持つ情報量を全て足し上げれば、その小領域のガンらしさ・正常らしさの判断根拠を定量化できる。情報密度法と名付けたこの可視化方法を人工知能病理診断の国際コンペ CAMELYON16 のデータと我々の保有する症例に適応し、このアプローチの有望さを示す。

OP12-2 Graph Neural Network による悪性リンパ腫のサブタイプ識別と識別根拠となる細胞核の可視化

○田中 寛武¹, 橋本 典明², 横田 達也¹, クグレマウリシオ¹, 大島 孝一³, 三好 寛明³, 永石 美晴³, 竹内 一郎¹, 本谷 秀堅¹¹名古屋工業大学, ²理化学研究所, ³久留米大学 医学部 病理学講座

100 種類以上の病型 (サブタイプ) を持つ悪性リンパ腫は、サブタイプごとに治療方針や症状の進行速度が異なる。そこで、代表的なサブタイプである Reactive, FL, DLBCL の H&E 染色画像を入力としてサブタイプを出力する診断支援システムを構築する。そこで、細胞核を単位とする識別根拠の可視化を行うサブタイプ識別器の構築を目指す。細胞核を単位とするのは、病理医が細胞組織の構造に基づき診断を行うからである。識別に寄与する細胞核を明示するためには画像中の細胞核をノードとする Graph Neural Network(GNN) を構築する。そして、識別根拠の可視化で強調される細胞核が病理学的な知見と整合するかどうかも確認する。結果として、識別率は約 80% となった。識別根拠は、DLBCL はほぼすべての細胞核が識別に寄与していた。これは全体ががん化したサブタイプであるという知見と一致した。

OP12-3 細胞を注視する口腔細胞診画像分類

○武田 啓太¹, 藤原 航平¹, 松尾 和希¹, 見立 英史², 酒井 智弥¹¹長崎大学工学研究科, ²長崎大学医歯薬総合研究科

本研究では口腔擦過細胞の画像を分類する識別器を提案する。口腔がんは死亡率が高いため早期発見が重要であり、非侵襲的で簡便な口腔細胞診が頻用される。しかし定量的診断基準が無く、病理医の負担も大きい。病理医の負担軽減だけでなく、定量的な診断基準の獲得のためにも、口腔細胞診画像を自動で分類する手法が望まれている。

口腔細胞診画像の大部分は背景であり、パパニコロウ染色された細胞が偏在する。しかし、撮像条件により識別的な特徴が背景にも潜在する。注視機構を導入しても、畳み込みニューラルネットは細胞の識別の特徴のみを学習するとは限らない。本研究では、背景の線形従属性と細胞のスパース性に基づき抽出した細胞の画像特徴のみで識別する深層学習モデルを設計した。提案手法は細胞の領域を画素単位でアノテーションする必要があるが、

OP12-4 肺細胞で事前学習された畳み込みニューラルネットワークを用いた尿細胞の自動分類

○道場 彩乃¹, 寺本 篤司², 桐山 諭和^{1,3}, 櫻井 映子¹, 塚本 徹哉¹

¹ 藤田医科大学大学院 医学系研究科, ² 藤田医科大学大学院 保健学研究科, ³ 成田記念病院

【目的】

AI技術の進歩が著しい中で、細胞診断の自動化が採取臓器の変化にどの程度対応できるのかはいまだに不明瞭である。我々は、以前より気管支鏡生検時に採取した肺細胞を用いて良悪性鑑別の自動化を目指してきた。本研究は肺細胞で学習した畳み込みニューラルネットワークを用いた尿細胞の良悪性鑑別の可能性を探ることを目的として実施した。

【方法】

気管支鏡生検材料と自然尿を液状細胞診標本化し、前者は良性1737枚、悪性706枚、後者は良性716枚、悪性664枚のデジタル画像を作成した。肺細胞画像の学習を行ったVGG-16に対し、尿細胞画像を用いてファインチューニングすることで尿細胞画像の分類モデルを構築した。

【結果・考察】

評価の結果、良性正解率が98.2%、悪性正解率が98.8%であった。尿細胞のみならず肺細胞を併用することで分類精度が向上することが確認された。今後、細胞診断における汎用性の高いAIを構築する上で重要な知見を得られた。

OP12-5 ホールスライド画像を用いた特発性間質性肺炎の病型自動分類

○寺本 篤司¹, 道場 彩乃², 桐山 諭和^{2,3}, 櫻井 映子², 塚本 徹哉², 今泉和良^{*2}, 齋藤 邦明¹, 藤田 広志⁴

¹ 藤田医科大学大学院 保健学研究科, ² 藤田医科大学大学院 医学系研究科, ³ 成田記念病院, ⁴ 岐阜大学 工学部

【目的】

原因不明の肺疾患である特発性間質性肺炎は病型によって予後や治療法が大きく異なるため正確な診断が求められている。本研究では、特発性間質性肺炎患者の組織診標本をホールスライドスキャナにて撮影した画像に対し、畳み込みニューラルネットワークによって病型を自動分類する手法を開発した。

【方法】

本研究では、特発性間質性肺炎の中でも予後不良な特発性線維症(IPF)と予後が比較的良好な非特異性間質性肺炎(NSIP)の分類を行う。まず患者の組織標本をホールスライドスキャナ(Carl Zeiss社製 Axio Scan Z1)によってスキャンし、得られた画像を224x224画素のパッチ画素に分割した。画像の分類にはDenseNet 169を用い、パッチ画像の分類結果を平均することで症例ごとの分類結果を導出した。

【結果】

IPF患者8症例31727枚、NSIP患者5症例28919枚の画像を用いて分類性能を評価した。Leave-one-out交差検証法にて分類したところ、IPF症例とNSIP症例の分類正解率は75%、60%となり、総合正解率は69.2%となった。

OP12-6 U-Netを用いた大視野顕微放射光CTの肺3次元マイクロ画像の肺胞壁抽出

○栗田 陽生¹, 河田 佳樹¹, 鈴木 秀宣¹, 梅谷 啓二², 中野 恭幸³, 阪井 宏彰⁴, 岡本 俊宏⁵, 仁木 登⁶

¹ 徳島大学大学院, ² (公財)高輝度光科学研究センター, ³ 滋賀医科大学, ⁴ 兵庫県立尼崎総合医療センター, ⁵ クリーブランドクリニック心臓・血管研究所, ⁶ 株式会社医用科学研究所

肺胞や肺胞囊の3次元マイクロ構造の解明に向けて、肺胞壁セグメンテーションを行うことは重要である。本研究の目的は3D U-Netを用いて肺胞壁セグメンテーションの高精度化に取り組み、肺3次元マイクロ構造解析に貢献することである。3D U-Netを用いた手法の利点は、人によってセグメンテーションの結果に差が生まれない点や、教師データが完成することで正解画像を作成する手間が省ける点である。その実験では、(1)3次元再構成画像を半手動で肺胞壁を抽出して教師データを作成した。(2)3D U-Netを学習して肺胞壁セグメンテーションを行った。(3)3D U-Netの肺胞壁の抽出精度を従来法と比較評価した。評価の結果、再現率は3D U-Netの方が高く、肺胞壁が淡くなっている箇所を高い確率で抽出できていたことが分かった。今後は、教師データ数の増加やアーチファクトを低減する逐次近似画像再構成法の利用によって、さらに肺胞壁のセグメンテーションの高精度化が期待できる。

一般演題 14

14:30 ~ 15:30

OP14 「セグメンテーション 2」

座長：小橋 昌司 (兵庫県立大学)

中村 嘉彦 (苫小牧工業高等専門学校)

OP14-1 U-Net を用いた頭部 MRI からの舌領域自動抽出に関する研究

○手塚 健太¹, 中村 嘉彦², 三上 剛², 米澤 一也³¹ 国立高等専門学校機構苫小牧工業高等専門学校 創造工学専攻, ² 国立高等専門学校機構苫小牧工業高等専門学校 創造工学科, ³ 国立病院機構横浜病院臨床研究部

近年、睡眠時無呼吸症候群の診断方法として舌の形状による診断が検討されているが、頭部 MRI 像から舌の輪郭を医師が手作業で抽出する必要があり、医師に負担がかかる。本研究では、U-Net を用いて 2 次元の頭部 MRI 像から舌領域を自動的に抽出する手法を開発する。医用画像を対象とした学習を行う場合、学習に使う画像の枚数が不足する問題がある。U-Net の構造はエンコーダとデコーダから成り、それらを繋ぐ密なスキップ接続を持つため、学習に必要な画像枚数が少なく、医用画像の学習における問題に対応可能である。U-Net を用いて、52 人分の頭部 MRI から成るデータセットに対し学習を行い、7 枚のテスト画像について本手法を適用し、F 値を用いて評価した結果、平均で 94.8% の精度で舌領域を抽出することができた。今後の課題として、精度向上のためにハイパーパラメータチューニングを行っている。

OP14-2 畳み込みニューラルネットワークを用いた頭部 MRI からの舌の自動輪郭抽出に関する研究

○加藤 優弥¹, 中村 嘉彦², 三上 剛², 米澤 一也³¹ 国立高等専門学校機構苫小牧工業高等専門学校 創造工学専攻, ² 国立高等専門学校機構苫小牧工業高等専門学校 創造工学科, ³ 国立病院機構函館病院臨床研究部

睡眠時無呼吸症候群の診断において頭部 MRI から舌の輪郭を抽出し、その形状から患者の重症度診断を行う手法が検討されている。しかし、そのためには頭部 MRI から抽出した舌の輪郭が必要になり、現状、頭部 MRI から舌領域の輪郭を抽出するには、医師が舌の輪郭を手作業で入力しなければならない。そこで医師の負担軽減を目的とし、畳み込みニューラルネットワークを用いた 2 次元の頭部 MRI からの舌の自動輪郭抽出に関する研究を行った。

学習済みのモデル VGG16 を用いて頭部 MRI のデータについて転移学習を行うことで、舌領域と非舌領域の分類モデルを学習する。学習したモデルを用いて、頭部 MRI からの検出領域を移動させながら舌領域を判定し、検出領域の中心画素を舌領域として抽出することで、舌を輪郭抽出する。

59 人分の頭部 MRI を 2 分割し学習・テストを行い、データ A で約 73.8%、データ B で約 64.8% の抽出精度を達成している。現在、学習条件を変更した上での比較・検証をしている。

OP14-3 3D 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検討

○平岡 大季¹, 西本紘嗣郎², 滝沢 穂高¹, 工藤 博幸¹¹ 筑波大学, ² 埼玉医科大学国際医療センター 泌尿器腫瘍科

本研究では、腹部 CT 画像に 3D U-Net を適用して副腎領域を抽出する手法を提案する。本報告では次の 5 つの実験を実施した。1 つ目の実験では、左右両方の副腎を含む関心領域を 3D U-Net に入力した。副腎の位置は手動で与え、関心領域の大きさは固定した。2 つ目では、左右の副腎それぞれに関心領域を設定し、3D U-Net に入力した。3 つ目は、2 つ目の関心領域を用い、その画素値平均と標準偏差 σ を求め、平均が 127、標準偏差が 2σ になるように画素値変換し、3D U-Net に入力した。4 つ目では、画素値平均を画像データセット全体の画素値平均になるように変換し、3D U-Net に入力した。5 つ目は、4 つ目の値に全体の画素値平均から各画像の画素値平均との差を加えた画素値平均になるように変換し、3D U-Net に入力した。これらの 5 つの手法を造影・非造影画像を含む 49 症例の画像データセットに適用し、その結果を示す。

OP14-4 Expanded tube attention module を用いた tubular structure segmentation

○加藤 聡太¹, 堀田 一弘²

¹名城大学大学院理工学研究科, ²名城大学理工学部

Semantic segmentation of tubular structures, such as blood vessels and cell membranes, is a very difficult task, and it tends to break many predicted regions in the middle. This problem is due to the fact that the tubular teacher labels are very thin, and the number of pixels is extremely unbalanced compared to the background. In this study, we present a novel training method using pseudo labels generated by morphological transformation, in which the detection region is thicker than the original teacher label. Furthermore, we present an attention module using thickened pseudo labels, called expanded tube attention (ETA) module. By using the ETA module, the network learns thickened pseudo labels at first, and then gradually learns thinned labels while transferring information in the thickened regions as an attention map. As a result, we achieve an easy-to-hard learning for tubular structure segmentation. Through experiments conducted on eye image datasets using various evaluation measures, we confirmed that the proposed training method using ETA module improved the accuracy in comparison with the conventional methods.

OP14-5 カラー腹腔鏡符号化画像のセマンティックセグメンテーションにおける評価に関する基礎的検討

○河畑 則文¹, 中口 俊哉²

¹北海道大学数理・データサイエンス教育研究センター, ²千葉大学フロンティア医工学センター

本研究では、画像符号化や分割手法などの複数のパラメータ条件に基づいて医用画像に適したセマンティックセグメンテーションをアルゴリズム設計することにより、カラー腹腔鏡画像のセマンティックセグメンテーションにおける評価についての考察を行った。

7月31日(日)

第2会場 (シンポジオン)

一般演題 16

15:40 ~ 16:40

OP16 「イメージング 4」

座長： 山谷 泰賀 (量子科学技術研究開発機構)

小尾 高史 (東京工業大学)

OP16-1 Encoder-decoderCNN を用いたパッチベース型 MR 画像再構成に関する検討

○佐藤 裕貴¹, 山登 一輝¹, 大内 翔平¹, 伊藤 聡志¹

¹宇都宮大学 大学院 地域創生科学研究科

畳み込みニューラルネットワーク (CNN) による画像空間での MR 画像の再構成において、CNN の層数を変化させると受容野が変化し、画像をパッチ化すると抽出できる特徴の大きさが変化する。

本研究では再構成像の品質を改善するために、Encoder-decoderCNN である U-Net を使用し、受容野やパッチサイズと再構成像の品質との関連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、フルサイズの画像で学習する場合よりも適したパッチサイズの画像で学習すること、および、U-Net の層数をパッチサイズごとの適した受容野に合わせることで再構成像の画質を改善できることが示された。さらに、本知見を応用し、学習中にパッチサイズを切り替える新たな方法を提案し、再構成シミュレーションを行った結果、再構成像の品質をさらに改善できる可能性を示された。

OP16-2 フレネル変換画像のアンサンブル学習による MR 圧縮センシング再構成の性能改善

○阿部 真弥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

近年、深層学習を利用した MR 圧縮センシング再構成法の研究が注目されている。様々な方法が提案されている中に敵対的生成ネットワーク (GAN) を利用した深層学習再構成がある。本研究では、GAN を利用した深層学習再構成に、フレネル変換による画像種を増したアンサンブル学習を導入し、再構成品質の改善を行う新たな方法について検討を行った。フレネル変換は光や音波の回折式を与える変換である。回折に関する係数により画像が変化するので、一種のデータの拡張が可能となる。拡張したデータに対し、それぞれGANによる再構成を行い、アンサンブル学習を行った。再構成シミュレーションの検討の結果、従来の画像のみを学習する方法を顕著に上回る性能が得られた。

OP16-3 インテリア CT 画像再構成の新しい厳密解法と究極の高精度解法の提案

○工藤 博幸

筑波大学システム情報系情報工学科

本研究では、物体内部の小さな関心領域 (ROI) のみに X 線を照射して測定した不完全な投影データから ROI の画像を再構成するインテリア CT の画像再構成を取り扱う。インテリア CT の画像再構成では、不完全投影データであるため通常の再構成法では大きな画質劣化が発生するが、著者らにより物体に関するごくわずかな先験情報があれば数学的に厳密な画像再構成が可能なが知られている (Kudo, Courdurier, Noo, Defrise, Phys.Med.Biol., 2008)。本研究では、先験情報を用いない全く新しい厳密解法を提案する。提案手法は、通常のインテリア CT 投影データに加え、微小な角度範囲 (数学的にはゼロにいくら近くともよい) から物体全体をカバーする完全投影データを少しだけ余分に測定して、インテリア CT 投影データと完全投影データを組み合わせて画像再構成を行うものである。完全投影データを測定する角度範囲は微小で良く、数学的には測度がゼロでない限りいくら小さくとも ROI の厳密でかつ安定な画像再構成が可能であるという驚くべき結論を、数学的に証明することに成功した。更に、本手法で用いる余分な投影データを劇的に削減することを試み、物体の直流成分 (画像濃度値の物体全体の総和) のスカラー値のみを補足情報に用いて高精度で再構成を行う手法を提案する。本手法は、補足情報として物体の直流成分という minimum の情報しか使用せず、実質的に非常に上手く動作し上記の厳密解法と画質性能に違いがなく、究極のインテリア CT 画像再構成法と言える。本研究で提案する手法が実質的に有効に動作することを、シミュレーション実験と実データを用いた実験により示す。

OP16-4 スペクトラルフォトンカウンティング CT の高速な統計的画像再構成法

○金 喜正¹, 賈 澤娜¹, 工藤 博幸²

¹筑波大学 大学院 システム情報工学研究群 情報理工学位プログラム, ²筑波大学 システム情報系情報工学科 教授

近年、フォトンカウンティング検出器を用いて X 線エネルギー毎の投影データを別々に測定し、エネルギー毎の画像を別々に再構成して物質分別を行う、Spectral Photon-Counting CT (SPCCT) の実用化に近づいている。SPCCT の一つの問題点は、物体の高吸収により SN 比が低くなっている低エネルギーの投影データをさらにエネルギー毎に分けることから、各エネルギーの投影データの光子数が少なく低 SN 比になることである。したがって、SPCCT には通常の CT とは異なる新しい画像再構成法を構築する必要がある。1) 統計雑音がポアソン分布であることを利用した投下型 CT モデル、2) Total Variation (TV) などの空間方向の正則化に加え、物体を構成するマテリアルが少数であることを利用したエネルギー方向の正則化項に基づき構成した評価関数を最小化する統計的画像再構成法が有効である。本研究では、SPCCT の統計的画像再構成を高速に行うため、著者らが通常 CT に対して既に提案した Dykstra 型スプリットティングに基づく反復解法 (Kim, Sadakata, Kudo, Proc. ICBIP2021) を SPCCT に拡張して 2 種類の高速に収束する Row-Action 型の画像再構成を構築した。一つ目の手法は、マテリアル特性 (吸収係数エネルギー依存性) を未知として、エネルギー毎の投影データの対数尤度に TV 正則化項を加えた評価関数を最小化することで再構成を行う原理だが、再構成の過程で物質弁別を行いマテリアル数が少数の制約を適用して、低線量でも高画質な画像再構成を可能にしている。二つ目の手法は、マテリアル特性を既知として物質弁別を行ったマテリアル画像を未知数とし、画像再構成問題を定式化して解く原理に基づくものである。シミュレーション実験を行った結果、提案手法は第一と第二のどちらも Row-Action 型であるため非常に高速に収束することが明らかになった。

OP16-5 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

○賈 澤娜¹, 金 喜正¹, 工藤 博幸²

¹筑波大学 大学院 システム情報工学研究群 情報理工学位プログラム, ²筑波大学 システム情報系

著者らは、CT の画像再構成において再構成過程においてサイノグラム上で異常データを検知して除外してアーティファクトを削減した再構成を行う ABD-CT (Abnormal Data Detected CT) の概念を提案した (工藤, 異常データ検知トモグラフィの概念提唱と事例紹介, JAMIT2021)。ABD-CT では L1 ノルムや L0 ノルムから構成される異常データ除外効果があるデータ項とトータルバリエーション (TV) などの正則化項の和から構成される評価関数を反復解法で最小化することで画像再構成を行う。本研究では、Dykstra 型スプリットティングの数学的枠組み (Kim, Sadakata, Kudo, Proc. ICBIP2021) に基づき ABD-CT に用いる高速に収束する画像再構成法を構築して、ABD-CT の典型的な応用であるメタルアーティファクト除去の問題に適用した。画質性能を向上させるため、正則化項としては非局所 TV (Nonlocal TV) を採用した。歯科用 CT 実画像を用いたシミュレーション実験を行い本手法の性能を評価した結果、ABD-CT は非常に優れた画質改善効果を持つことが示され、更に Dykstra 型スプリットティングに基づく反復解法によりほぼ 50 回の反復で十分な画質の再構成画像が得られ実用的なものになった。更には、メタルアーティファクト除去の問題に流行している深層学習と比較した結果、ABD-CT は深層学習より優れた画質性能を持つことが明らかになった。

一般演題 18

16:40 ~ 17:30

OP18「イメージング5」

座長： 銭谷 勉 (弘前大学)

田島 英朗 (量子科学技術研究開発機構)

OP18-1 深層学習を用いたマルチピンホール SPECT システムにおけるオーバーラップ投影データの分離

○山口 恭平¹, 尾川 浩一¹¹法政大学大学院 理工学研究科

SPECTでマルチピンホールコリメータを用いることで検査時間を短縮でき、高い感度が実現できる。しかし、検出器の大きさは限られ、ピンホール数を多くすると重なりが生じ、再構成画像の劣化を招く。そこで、本研究ではマルチピンホールのオーバーラップを深層学習を用いて分離する方法を検討した。シミュレーションでは、モンテカルロ法を用いて光子輸送計算を行い、オーバーラップのある投影データを作成し、これを入力画像とし、一方でオーバーラップのない単独のピンホール投影データを教師画像として与え、ネットワークの学習を行った。この結果、投影データのオーバーラップの除去に成功したので報告する。

OP18-2 静止型マルチピンホール SPECT の空間分解能改善：投影画像上における点拡がり関数の逆畳み込み

○村田 一心¹, 大越 迪², 山田 桃夏², 尾川 浩一³¹国立天文台, ²法政大学大学院 理工学研究科, ³法政大学 理工学部

静止型 SPECT は従来の SPECT と異なり、検出器を回転させないことで、時間情報を取得できる。このシステムでは、角度情報を得るため、複数のピンホールを有するガンマカメラを複数台使用する。しかし、その画質はピンホール径に強く依存し、感度と空間分解能はトレードオフの関係にある。空間分解能を補正する方法として、従来 7-rays 法が用いられてきたが、同手法ではピンホール径が大きい時には近似精度が低い。そこで我々は、投影画像上の点拡がり関数を用いた空間分解能改善手法を開発してきた。本研究では、点拡がり関数の空間依存性を考慮し、ハイパーパラメータの最適化も試みた。同手法を 11 ピンホールシステムに適用したところ、7-rays 法を用いた時の再構成画像と比べ、PSNR, SSIM が共に向上することを確認した。

OP18-3 深層学習を用いたピンホール SPECT システムにおける空間分解能の改善

○島田 良¹, 村田 一心², 尾川 浩一³¹法政大学大学院理工学研究科, ²国立天文台, ³法政大学理工学部

本研究では SPECT でピンホールコリメータを装着して、データ収集を行うピンホール SPECT システムにおいて、従来手法の 7rays 法に代わる新たな空間分解能の補正法を検討しその有用性を実証した。シミュレーションでは脳ファントムを使用し、モンテカルロ法を用いた光子輸送計算を行い、得られた投影データに対し U-net による深層学習を用いて投影データの空間分解能改善を行った。教師データは無限小ピンホールを用いた ray-tracing から作成した。また、この補正を行った投影データに対し ML-EM 法による画像再構成を行い PSNR 値による画質の評価を行った結果、7rays 法と提案手法による PSNR 値はそれぞれ 16.7 と 18.1 であった。このことより、ピンホール SPECT システムにおける本研究の提案手法は有用であることが示された。

OP18-4 順投影モデルを利用した Deep image prior ベース PET 画像再構成

○橋本二三生¹, 大手 希望¹, 大西 佑弥¹, 田島 英朗², 山谷 泰賀²¹浜松ホトニクス株式会社中央研究所, ²量子科学技術研究開発機構量子医科学研究所

計測データから直接断層像を生成する深層学習技術が、新しい画像再構成法として注目されている。しかし、従来の手法は多数の高品質なサイノグラム・再構成画像ペアが必要な教師あり学習であり、装置や PET 薬剤の違いによる汎用性に課題がある。本研究では、学習データセットを必要としない Deep Image Prior(DIP)に順投影モデルを組み込むことで、サイノグラムから PET 画像再構成が可能となる手法を提案する。提案手法では、Fully convolutional neural network(FCN)の出力画像に対し、ラドン変換を行う順投影モデルを組み込むことで推定サイノグラムを計算する。その後、計測サイノグラムとの損失を DIP の枠組みを用いて最適化することで、FCN の出力層から再構成画像を取得する。数値シミュレーションおよび実測データによる評価の結果、我々の画像再構成法は学習データセットなしで再構成画像を取得でき、他の画像再構成法と比べても、高い定量性を維持しつつ灰白質の構造を明瞭に描出できることがわかった。

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：2022 年 7 月 28 日

発行者：第 41 回日本医用画像工学会大会長 森 健策

製作所：トーヨー企画株式会社

位相拡散フーリエ撮像法におけるセグメント信号収集を用いた MR 圧縮センシング

山登 一輝^{*1}, 大水 望^{*1}, 伊藤 聡志^{*1}

^{*1} 宇都宮大学 工学部 情報工学科

Compressed Sensing MRI Using Segmented Signal Under-sampling in Phase Scrambling Fourier Transform Imaging

Kazuki YAMATO, Nozomi Omizu, and Satoshi Ito

^{*1} Department of Information Sciences, School of Engineering, Utsunomiya University

要旨 : 少数の観測信号から元の情報を復元できる圧縮センシングを MRI に利用することで, MRI の撮像時間を短縮できる. しかしながら, 少数の観測信号から再構成された画像の分解能低下が問題である. 先行研究では, フーリエ変換に二次の位相変調を付与した位相拡散フーリエ撮像法 (PSFT) を使用し, 信号の低域のみを収集し事後的に高域の信号を推定することで再構成画像の分解能改善を図った. しかしながら, 再構成画像の中心部分の分解能改善が困難であった. 本稿では, PSFT 信号の収集領域を複数に分割するセグメント収集方式を導入し, 再構成画像の画質と中心部分の分解能改善について取り組んだ. シミュレーション実験の結果, PSFT 信号をセグメント収集した提案手法は, 先行研究よりも PSFT および SSIM が高くなることが確認された. また, 分解能チャートを用いて分解能を評価したところ, 画像中央部分の分解能改善を確認したので報告する.

キーワード : 圧縮センシング, 位相拡散フーリエ撮像法, MRI, セグメント信号収集, 画像再構成

1. はじめに

MRI の撮像時間短縮化と高分解能化を実現するために, 少数の観測信号から画像を再生する方法について研究が活発に行われている. 先行研究[1]では, 汎用のフーリエ変換法に二次の位相変調項を与えた位相拡散フーリエ撮像法(PSFT: Phase Scrambling Fourier Transform imaging)[2]を利用した超解像について検討を行ってきた. この方法は, 信号の低域のみを収集し, 撮像後に信号の外挿に基づいて, 信号の高域成分を推定し, 再構成画像の分解能改善を行うものである. しかし, 先行研究の分解能改善効果は, 再構成画像の中心部ほど低いという課題があった. 本研究では, 信号収集領域をいくつかの領域に分割したセグメント信号収集を導入することで, 再構成画像の画質改善と中央領域の高分解能化を図った. 提案手法の有効性検証のため, 先行研究の手法, および汎用のフーリエ変換法において再構成シミュレーション実験を行い, 再構成画像を比較した.

2. 位相拡散フーリエ撮像法

PSFT は, 位相エンコードに同期して二次関数状の磁界を一定の期間印加するか, あるいは線形勾配磁界を印加のもと周波数変調された RF 励起パルスを照射するなどの方法により, 被写体内のスピンの位相を拡散させ, 読み出し用の勾配磁界によりエコー信号を読み出す方法である. 信号式を式(1)に示す.

$$v(k_x, k_y) = \iint_{-\infty}^{\infty} \{\rho(x, y) e^{jc(x^2+y^2)}\} e^{-j(k_x x + k_y y)} dx dy \quad (1)$$

ここで, $\rho(x, y)$ は xy 平面のスピン密度分布, c は 2 次の位相変調の係数である. ここで c は, 標本化定理を満足する最大の係数 c_{\max} を基準として表現するための係数 h ($h \leq 1$) を導入することで, $c = hc_{\max}$ とする.

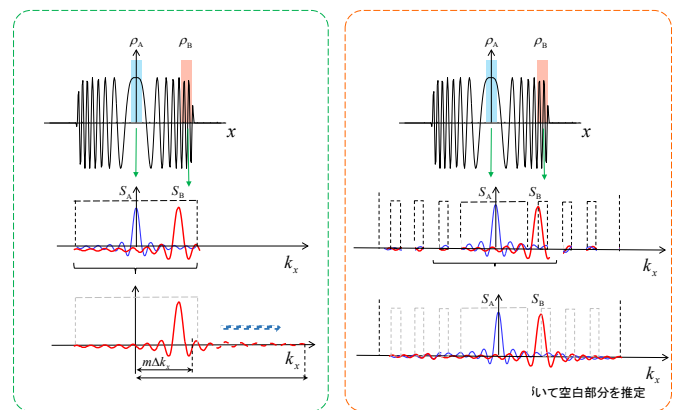


図1 セグメント収集による効果

3. セグメント収集を導入した PSFT 信号の再構成

PSFT 信号の低域収集 (先行研究) と提案するセグメント収集の再構成効果を図 1 に示す. 低域収集では, 図 1(a)の位相変調が付与された画像の断片像 ρ_A , ρ_B についてフーリエ変換したとき, (b)のように ρ_B のスペクトル S_B は変調周波数に依存してシフトする. S_B はピークを中心に対称な形状であり, この対称性を利用し, 未収集である信号の高域成分を外挿に基づいて推定できる. しかしながら, ρ_A のスペクトル S_A の変調周波数は小さく, シフトも短いため, 対称性による高域信号の推定効果は小さい. 一方, 提案するセグメント収集では, スペクトルの対称性を利用した高域信号の推定は, 低域収集手法と同様に, S_A は困難であり, S_B の推定効果は高い. さらに, 図 1(f)のように S_A , S_B ともに, セグメント間の未収集領域を内挿に基づいて推定できる. すなわち, セグメント収集による信号の推定は, 信号の外挿と内挿の両方を有効活用でき, 低域収集手法よりも

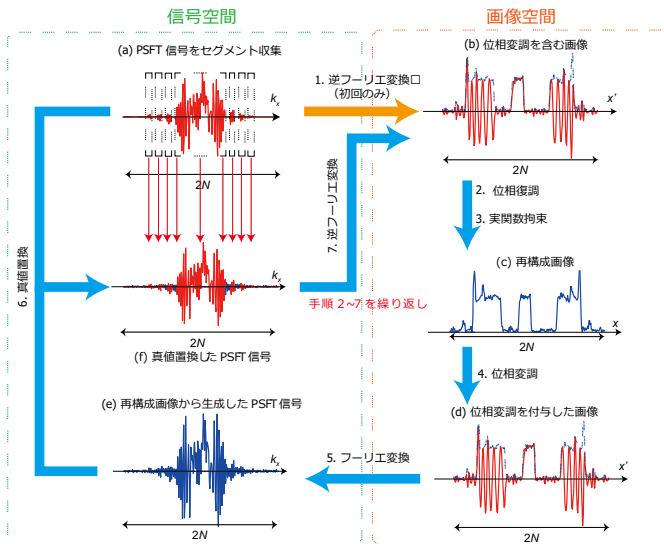


図2 セグメント収集信号の反復再構成アルゴリズム

高性能な画像再構成が期待できる。

図2に、セグメント収集信号の反復再構成アルゴリズムを示す。本アルゴリズムは、Gerchbergの超解像アルゴリズム[3]に基づいた処理である。まず、(a)セグメント収集PSFT信号に逆フーリエ変換して得られる位相変調を含む画像に位相復調および実関数の拘束条件を適用することで、(c)再構成画像が得られる。次に、再構成画像を再びPSFT信号に変換する。最後に、真値である(a)の信号を(e)のPSFT信号に置換し、逆フーリエ変換を適用する。以上の処理を反復することで、高分解能な再構成画像を生成できる。

4. 画像再構成シミュレーション

提案手法の有効性確認のため、提案手法による画像再構成シミュレーションを実施した。使用画像はIXI-Datasetで提供される頭部T1強調像25枚とし、信号収集率は50%とした。比較手法には、圧縮センシングによる再構成法(FT-CS)、2行に1行を収集する等間隔収集PSFT(regular)、低域収集し超解像を行う手法PSFT(noseg)、提案手法(segment)とした。FT-CS以外の手法には、図2に示す反復再構成処理を適用し、反復回数は75回とした。FT-CSにはスパース化関数にカーブレット変換を利用した圧縮センシング[4]を用いた。各手法で使用した信号収集パターンを図4の3行目に示す。なお、segmentの信号収集パターンは、信号収集領域を15分割しており、中央部分は16行、中央以外は8行とし、セグメント間隔は6行とした。再構成画像の定量評価には、Peak-Signal-to-Noise Ratio (PSNR)とStructural Similarity Index Measure (SSIM)を用いた。

図3に示す再構成画像のPSNR・SSIMから、提案手法は $h \leq 0.6$ で他手法よりも高いPSNR・SSIMとなり、最大でPSNR 49.62 dB($h = 0.3$)であった。一方、 $h > 0.6$ では先行研究であるnosegがsegmentを上回った。図4は、解像力チャートに対して画像




図3 再構成画像のPSNRとSSIM




図4 再構成画像と信号収集領域

再構成を適用した結果であり、各手法のパラメータは図3において最良のものを用いた。FT-CSは中央部分にアーティファクトが確認され、regular($h = 0.9$)はエイリアスが発生している。noseg($h = 1.0$)にもエイリアスが生じており、中央部分は分解能改善が確認できない。segment($h = 0.3$)には平滑化やエイリアスは発生しておらず、full-dataに近い画像に再構成されている。提案手法は、PSFT信号の外挿、内挿効果と圧縮センシングを併用した新たな撮像法と考えることができる。

5. おわりに

本稿では、セグメント信号収集法で収集されたPSFT信号からの画像再構成について検討を行った。シミュレーション結果から、提案手法による再構成画像のPSNRは約49 dBであり、視覚的に見ても、平滑化・エイリアス等の発生なく再構成できていることが確認された。今後の課題として、深層学習を利用し、信号収集量が少ない条件下での検討が挙げられる。

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。

文献

- [1] Ito S, Yamada Y.: Improvement of spatial resolution in magnetic resonance imaging using quadratic phase modulation, Proc. IEEE ICIP, pp.2497-2500, 2009.
- [2] Maudsley, A.: Dynamic range improvement in NMR imaging using phase scrambling, J. Mag. Res. Vol.76, no.2, pp.287-305, 1988.
- [3] Gerchberg R.: Super-resolution through error energy reduction, Opt. Act. Vol.21, no.9, pp.709-720, 1974.
- [4] Candes EJ, Donoho DL.: New Tight Frames of Curvelets and Optimal Representations of Objects with piecewise C2 singularities, Commun Pure Appl. Math. Vol.57, pp.219-266, 2004

実関数 CNN を利用した MR 位相画像の深層学習再構成

深津 純奈^{*1}, 山登 一輝^{*1}, 伊藤 聡志^{*1}

^{*1} 宇都宮大学 大学院地域創成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

Deep Learning based Phase-varied MR Image Reconstruction Using Real-valued CNN

Itona FUKATSU^{*1}, Kazuki YAMATO^{*1}, Satoshi ITO^{*1}

^{*1} *Utsunomiya University, Graduate Program in Information, Electrical and Electronic Systems Engineering*

要旨 : MR 撮像の高速化を目的として圧縮センシングの MR 応用が進められ, 一部は実用化されている. 深層学習を利用する再構成法では, これまで実関数型の畳み込みニューラルネットワーク (CNN) を利用する研究報告が多かったが, MR 画像は位相を持つ複素画像であり, 複素数に対応する CNN が必要である. 本研究では, 信号間引きに対称性を与えることにより実関数型の CNN を使用しながら複素数の画像を再構成できる新たな方法を提案する.

キーワード : MRI, 画像再構成法, CNN, 高速化, 深層学習

1. はじめに

磁気共鳴映像法 (Magnetic Resonance Imaging: MRI) は撮影の時間が長いことが課題である. 圧縮センシング (CS) を用いた撮像の高速化 (CS-MRI) が検討[1]されているが, 再構成時間が長いことや最小化問題を解くことで得られる再構成像の不自然さが残ることが課題である. 深層学習を利用する画像再構成法は, 前述の課題を解決する有力な方法として活発に研究が行われている.

深層学習を利用する再構成法では, これまで実関数 CNN を利用する研究報告が多かった. しかし, MR 画像は位相を持つ複素画像であり複素数を扱う必要がある. これまでに複素数に対応した CNN が提案されているが, 畳み込みや活性化関数など課題が残る. そこで, 本研究では, MR 信号の信号収集座標に対称性を与える方法により位相推定実関数 CNN を使用しながら複素画像を再生可能な新たな深層学習再構成法を提案する.

2. 位相画像と信号の関係

MRI で得られる再生像は, 磁化率や装置に起因して一般的に位相を持つ複素画像となる. 観測信号を $s(k)$, 被写体のスピン密度分布を $\rho(x)$, 位相分布を $\phi(x)$ とするとき緩和による減衰を省略した MR 信号式は式(1)で与えられる[2].

$$s(k) = \int \rho(x)e^{-j\phi(x)} e^{-j(k \cdot x)} dx = F[\rho(x)e^{-j\phi(x)}] \quad (1)$$

x と k , F はそれぞれ空間ベクトル, k 空間ベクトル, およびフーリエ変換処理である. 位相を持つ像 $\rho(x)e^{-j\phi(x)}$ の実部のフーリエ変換は, 式(2)となる.

$$\begin{aligned} F\{\text{Re}[\rho(x)e^{-j\phi(x)}]\} &= \frac{1}{2}F\{\rho(x)e^{-j\phi(x)} + \rho(x)e^{j\phi(x)}\} \\ &= \frac{1}{2}\{s(k) + s(-k)^*\} \end{aligned} \quad (2)$$

$$s(-k)^* = \int \rho(x)e^{j\phi(x)} e^{-j(k \cdot x)} dx = F[\rho(x)e^{j\phi(x)}] \quad (3)$$

ここで $s(-k)^*$ は, 式(3)の関係を利用した. 虚部のフーリエ変換も同様に求めることができる. 式(2)は, 原点に関する対称的か




図 1 対称性を与えた信号収集パターン

つ位相共役な信号との加算により位相画像の実部に対応する信号式を与える. この性質を CS-MRI に用いるためには, 図 1 のように収集パターンに対称性を与えた間引き処理を行う. この方法では, 複素画像の実部と虚部のそれぞれの像を実関数用 CNN を利用して独立に再構成することが可能となる.

3. 実関数 CNN 再構成

本研究では, 深層学習再構成に交互方向乗数法 (Alternating Direction Method of Multipliers: ADMM) の反復処理をモデルとする Generic-ADMM-CSNet[3] を利用した. 間引いた MR 信号空間を入力し, 反復処理の各ステップに相当するステージを複数回経ると, 再構成された MR 画像を出力する.

学習において図 2 のように, 実部像と虚部像に対応する MR 信号 100 組を使用して学習を行った. 提案法では実部と虚部と

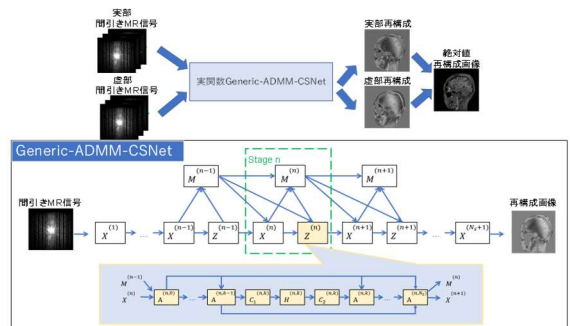


図 2 再構成処理の手順

もに実画像の扱いになるので、同一のネットワークを使用した学習を行うことができる。その結果、データ拡張の効果が期待できる。

4. 画像再構成シミュレーション

提案法、複素数計算を可能とする Generic-ADMM-CSNet, および画像空間のアーティファクト学習法(DnCNN-CS) [4]による画像再構成実験を行い、再構成像を比較した。

4.1 模擬位相付与による再構成実験

位相に対する頑健さを評価するために数値モデルに規則的な位相変化を与え画像再構成を行った。再生像の空間のインデックスを (i_x, i_y) , 位相変化の係数を c , データ数を N とするとき、二次関数状の位相分布を $e^{-jc\{(i_x - N/2)^2 + (i_y - N/2)^2\}}$ として与えた。提案法と Generic-ADMM-CSNet を比較した。信号収集比 40% として再構成した際の、位相変化の係数と再構成像の PSNR の関係を図 3 に示す。 $c=0.01$ とした時の再構成像と位相分布を図 4 示す。図 4 の位相分布において提案法は、複素数 CNN よりも位相の乱れが少ない結果となった。位相の変化が大きい 129 行目の位相の MSE は提案法が 0.028 に対して複素数 CNN は 0.043 となり提案法のほうが、誤差が少なかった。

4.2 取得 MR 画像を使用した再構成実験

MRI で実際に得られた位相画像を再構成する実験を行った。4.1 で使用した方法に DnCNN-CS を加えた 3 通りの方法で比較をした。学習に使用した画像は、被検者の同意を得て MRI (キヤノンメディカル Vantage) で撮像されたボランティア画像 50 枚である。60 エポックの学習を行った。テスト画像は、学習に使用していない複素画像 20 枚を使用した。信号収集比 40% で再構成を行ったときの PSNR を図 5 に示す。提案法は比較した 3 通りの方法の中で最大の PSNR を示した。

5. 考察

MRI で得られた位相を持つ複素数画像での再構成は、提案法と複素数 CNN で同等な PSNR を得ることができた。複素数対応の ADMM-CSNet は実部と虚部で同じ畳み込みフィルタと ReLU を使用しているため、複素数の効果が小さいこと、および提案法は、実部と虚部を同一の畳み込みフィルタを使用して学習を行うことで学習枚数が 2 倍になりデータ拡張の効果があること、実関数の拘束条件の使用などにより複素数 CNN より高い再構成性能となったと考える。

数値モデル位相を与えた複素数画像の再構成では、位相の強さに関わらず提案法が複素数 CNN よりも高い PSNR となった。このことから、提案法は位相分布に頑健であることが示された。MRI では、位相より磁化率や血流の情報を得ることができ、位相を積極的に利用する撮像が行われることがある。位相分布に頑健な提案法は他の優れた実関数 CNN にも応用することができ、実用的かつ有望な方法であると考えられる。




図 3 模擬位相画像の PSNR




図 5 実位相画像の PSNR




図 4 位相付与画像の再構成像比較 : (a) フルデータ画像, (b) 与えた位相分布($c=0.01$), (c), (e) は提案法, 複素数 CNN による再構成像, (d), (f) は(c), (e) の位相分布

6. おわりに

本研究では、位相を持つ MR 画像に対して原点对称な信号間引きを用いることで実関数 CNN での再構成を可能とする新たな深層学習再構成について検討を行った。その結果、画像空間学習、および複素数 CNN のいずれの方法よりも高い PSNR を得ることができた。また、提案法の位相分布への頑健さが示された。今後はさらに学習枚数を増やした検討を行う予定である。

7. 謝辞

本研究の一部は、科研費(19K04423)により実施された。IXI Dataset を提供する Information eXtraction from Images プロジェクトに感謝の意を表す。

文献

- [1] M.Lustig et al: Compressed Sensing MRI, IEEE Signal Processing Magazine, vol.25, no.2: 72-82, 2008
- [2] 伊藤 他: MR 画像の位相ひずみに頑健な圧縮センシング, 信学論 D, Vol. J96-D No.4: 803-804, 2013
- [3] Y.Yang et al: ADMM-CSNet: A Deep Learning Approach for Image Compressive Sensing, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol.42: 512-538, 2018
- [4] S. Ouchi, S. Ito: Efficient Phase-varied Image Reconstruction using Single Deep Convolutional Neural Network without Estimation of Phase Distribution, ISMRM 28th Scientific Meeting, 3608, Paris, France, 2020

Deep image prior を用いたリストモード PET 画像再構成

大手 希望^{*1}, 橋本 二三生^{*1}, 大西 佑弥^{*1}, 磯部 卓志^{*1}

^{*1} 浜松ホトニクス株式会社中央研究所第5研究室

List-mode PET image reconstruction using deep image prior

Kibo OTE^{*1}, Fumio HASHIMOTO^{*1}, Yuya ONISHI^{*1}, Takashi ISOBE^{*1}

^{*1} Hamamatsu Photonics K.K.

要旨 : Deep image prior (DIP) を用いたリストモード positron emission tomography (PET) 画像再構成法を提案する. 提案手法は, 交互方向乗数法の枠組みにより, リストモード逐次近似法と DIP による画像処理を交互に繰り返す. DIP による画像後処理は, ノイズを除去する反面, コントラストが若干犠牲になる. 提案手法はノイズを減らしながら, 同時にコントラストも改善する. 頭部用 PET 装置のモンテカルロシミュレーションデータを用いて, 提案手法の有効性を評価した. 提案手法は従来法に比べて高いピーク信号対雑音比とコントラストリカバリを示した. リストモード PET 画像再構成は, イベント数より検出器対数が多い場合に効率的となる. よって, 提案手法は検出器対数が多く, 飛行時間差, 相互作用位置などの追加情報を備えた PET 装置において特に有用と期待される.

キーワード : 画像再構成, 教師なし学習, 深層ニューラルネットワーク, リストモード, positron emission tomography

1. はじめに

近年, positron emission tomography (PET) 画像再構成などの不良設定逆問題の正則化に深層学習が用いられている. 特に, convolutional neural network (CNN) の構造自体を正則化に用いる deep image prior (DIP) [1] は, 事前の訓練データを必要としないため研究者の注目を集めている. 例えば, Gong らは DIP を PET 画像再構成の正則化に用いている [2]. しかし, これらの深層学習に基づくアプローチは, サイノグラムからの画像再構成に限定されており, リストデータからの画像再構成には広がっていない. これはリストデータがビットコードの集まりであり CNN による処理に適さないことに由来している. リストモード再構成は, イベント数が line-of-response (LOR) 数より少ない場合に効率が良いため, 深層学習を使用したリストモード PET 画像再構成は LOR 数が多く, time-of-flight や depth-of-interaction (DOI) などの追加情報を備えた PET 装置に有用と期待される.

本研究では, DIP を使用したリストモード PET 画像再構成を提案する. 提案手法 (LM-DIPRecon と呼ぶ) は, リストモード PET 画像再構成と DIP による画像処理を, alternating direction method of multipliers (ADMM) の枠組みに従って, 交互に繰り返す. モンテカルロシミュレーションデータを用いて, 提案の LM-DIPRecon 法を評価した. LM-DIPRecon 法は, ノイズを減らしつつ, DIP による後処理に比べて腫瘍のコントラストを維持した.

2. 方法

1) 提案手法

DIP を用いてリストモード PET 画像再構成を正則化するため, 以下の制約付き最適化問題を考える.

$$\begin{aligned} \max \quad & L(U|x), \\ \text{s.t.} \quad & x = f_{\theta}(z), \end{aligned} \quad (1)$$

ここで, $L(U|x)$ は再構成画像 x からリストデータ U を観測する尤度, f は CNN, θ は CNN のパラメータ, z は事前分布画像である.

(1) の制約付き最適化問題を拡張ラグランジュ関数法により以下のように書き換える.

$$\min -L(U|x) + \frac{\rho}{2} \|x - f_{\theta}(z) + \mu\|^2 + \frac{\rho}{2} \|\mu\|^2, \quad (2)$$

ここで, ρ は正の定数, μ は双対変数である.

ADMM は(2)の最適化問題を 2 つの副問題と双対変数の更新の 3 ステップに分割する.

$$x^{(n+1)} = \operatorname{argmax}_x L(U|x) - \frac{\rho}{2} \|x - f_{\theta^{(n)}}(z) + \mu^{(n)}\|^2, \quad (3)$$

$$\theta^{(n+1)} = \operatorname{argmin}_{\theta} \|f_{\theta}(z) - x^{(n+1)} - \mu^{(n)}\|^2, \quad (4)$$

$$\mu^{(n+1)} = \mu^{(n)} + x^{(n+1)} - f_{\theta^{(n+1)}}(z), \quad (5)$$

ここで, n は ADMM の 3 ステップの反復回数である.

副問題(3)は list-mode dynamic row action maximum likelihood algorithm (LM-DRAMA) と下式による正則化の組み合わせで解くことができる.

$$x_j^{(n+1)} = \frac{x_{j,\text{base}}^{(n)} - \frac{S_j}{\rho} + \sqrt{\left(x_{j,\text{base}}^{(n)} - \frac{S_j}{\rho}\right)^2 + 4x_{j,\text{EM}}^{(n+1)} \frac{S_j}{\rho}}}{2}, \quad (6)$$

$$x_{j,\text{base}}^{(n)} = f_{\theta^{(n)}}(z)_j - \mu_j^{(n)}, \quad (7)$$

$$S_j = \sum_i a_{ij}, \quad (8)$$

ここで, x_{EM} は LM-DRAMA によって更新された画像, x_{base} は




図1. 提案手法とその他の手法によって再構成されたシミュレーションデータの画像. 左から, MRI, ファントム画像, LM-DRAMA, MR-DIP, LM-DIPRecon. 画像にPSNRとCRを付記.

正則化のベース画像, S は感度画像, a_{ij} はLOR i の画素 j への寄与を表すシステム行列の要素である.

副問題(4)は $x^{(n+1)} + \mu^{(n)}$ をラベル画像としたDIPによって解くことができる. 本研究では, CNNの構造として3D U-netを使用した. またMRIを事前分布画像としたため, ここではDIPをMR-DIPと呼ぶ.

2) 実験条件

3つの腫瘍領域を含むデジタル脳ファントムを用いてモンテカルロシミュレーションを行った. 検出器配置は4層DOIを備えた頭部用PET装置(Hamamatsu HITS-655000)と同様とした. 定量評価のため, peak signal to noise ratio (PSNR)と腫瘍のcontrast recovery (CR)を以下のように評価した.

$$\text{PSNR} = 10 \log_{10} \frac{\max(x_{j,\text{ref}})^2}{\frac{1}{N_R} \sum_{j \in R} (s_j - x_{j,\text{ref}})^2}, \quad (9)$$

$$\text{CR} = \frac{1}{N_{\text{tumor}}} \sum_{j \in R_{\text{tumor}}} \frac{x_j}{x_{j,\text{ref}}}, \quad (10)$$

ここで, x_{ref} はファントム画像, R は全脳の領域, N_R は全脳内の画素数, R_{tumor} は3つの腫瘍領域の和集合, N_{tumor} は腫瘍領域内の画素数である.

3. 結果と考察

図1に提案手法とその他の手法(LM-DRAMAとMR-DIP)の再構成画像を示す. 画像にPSNRとCRを付記した. MR-DIPはコントラストをやや犠牲にしながらノイズを低減した. LM-DIPReconはコントラストを保ち, MR-DIPよりシャープな画像を提供した.

図2にCR vs. PSNR曲線を示す. MR-DIPはLM-DRAMAに比べてPSNRを改善したが, CRはLM-DRAMAより低かった. LM-DIPReconはLM-DRAMAと同様のCRを維持しながら, PSNRを改善した.

LM-DIPReconはラベル画像ではなくリストデータに忠実であることが可能なため, コントラストが改善したと考えられる.

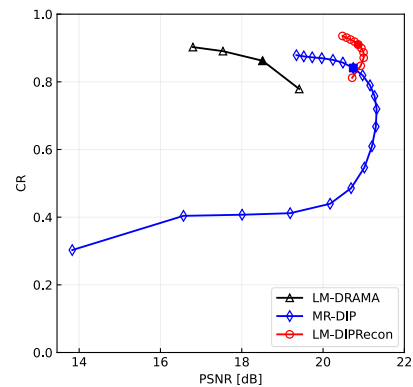


図2. コントラスト(CR)と雑音(PSNR)のトレードオフ曲線. LM-DRAMAのプロットは反復回数1, 2, 3, 4, MR-DIPのプロットは100, 200, ..., 2000エポック, LM-DIPReconのプロットはADMMの繰り返し回数20, 40, ..., 200に対応する. 塗りつぶしマーカーは図1の画像に対応.

4. まとめ

DIPを用いたリストモードPET画像再構成を提案した. ADMMの枠組みに従ってDIPをリストモードPET画像再構成に組み込んだ. 提案手法は, 他の手法よりシャープで, コントラストが高く, 雑音の少ない画像を提供した. これらの結果は, 提案手法が次世代の頭部用PET装置に有望なことを示唆した.

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

- [1] Ulyanov D, Vedaldi V, Lempitsky V: Deep image prior. Int J Comput Vis 128: 1867-1888, 2020.
- [2] Gong K, Catana C, Qi J et al: PET image reconstruction using deep image prior. IEEE Trans Med Imag 38: 1655-1665, 2018.

圧縮センシングを用いたフォトンカウンティング CT のスペクトル歪み補正

村田 一心^{*1}, 尾川 浩一^{*2}

^{*1} 国立天文台

[〒181-8588 東京都三鷹市大沢 2-21-1] e-mail: kazumi.murata@nao.ac.jp

^{*2} 法政大学理工学部

Regularization based spectral distortion correction of a photon-counting CT system

Kazumi MURATA^{*1}, Koichi OGAWA^{*2}

^{*1} National Astronomical Observatory of Japan

^{*2} Faculty of Science and Engineering, Hosei University

要旨: フォトンカウンティング CT は空間情報に加えてエネルギー情報も取得できることから、次世代型 CT として注目されている。しかし、複数の X 線光子が検出器の不感時間内に入射した場合、パルス・パイルアップ効果により、測定スペクトルは歪められてしまう。その影響は、解析モデルを適用することで、原理的には補正できる。しかし、最小二乗法を基にした補正方法では、わずかな雑音も増幅されてしまい、画質を劣化させてしまう。その対応策として圧縮センシングの適用が考えられるが、特にエネルギービンの数が少ない場合にはスペクトル形状を先見情報として扱うことは難しい。そこで本研究では、エネルギー・空間の両方を先見情報として扱う手法を開発した。各エネルギービンの画像に対する全変動正則化、および全データに対する低ランク行列近似を適用することで、スペクトルの歪み補正精度が向上することを確認した。

キーワード: フォトンカウンティング CT, パルス・パイルアップ効果, 圧縮センシング

1. はじめに

フォトンカウンティング CT は、被写体の 3 次元断層画像をエネルギーごとに取得できるため、幅広い応用が可能になり、次世代 CT として着目されている[1]。特に顕著な利点は、エネルギーごとに測定した X 線の減衰量から、媒質分離を行えることである。媒質分離を高精度に行うことができれば、複数の造影剤を用いた断層画像の取得や、臓器の動態解析が可能になる[2]

しかし、フォトンカウンティング CT には、測定スペクトルが歪められてしまうという大きな課題がある。複数の X 線光子が検出器の不感時間内に入射した場合、エネルギーの大きな 1 つの光子として計測されてしまうためである。この現象はパルス・パイルアップ効果と呼ばれており、その影響は X 線強度が高いほど大きい[3]。スペクトルが歪められてしまつては、フォトンカウンティング CT の最大の利点である媒質分離の精度も著しく劣化してしまう[4]。その歪みの程度はモデル化されており[5,6]、原理的には補正可能であるが、歪み補正は逆問題であることから、雑音を増幅してしまいがちという課題もある。

そこで本研究では、正則化を用いたスペクトル歪み補正方法を提案する。逆問題に正則化を適用することで安定した解が得られることは広く知られており、フォトンカウンティング CT の研究にも応用されている[7]。一般的な正則化は空間方向に関する先見情報を用いるが、スペクトルの歪みを補正するには、エネルギー方向の情報も組み合わせることが望ましい。しかし、統計雑音を抑えるためにはエネルギービンを少なくする

必要があり、その場合にはエネルギー方向の先見情報を扱いきれない。そこで本研究では、空間・エネルギーの両方に正則化を適用する。空間方向にも正則化が加わることで、エネルギービンの数が少ない場合でも、安定した解が得られることが期待される。提案手法の評価のため、画像再構成シミュレーションを行ったところ、スペクトルが歪められてしまったデータでも高精度な画像再構成が可能であることを確認した。

2. 提案手法およびシミュレーションによる評価

本研究では、パイルアップ効果によって歪められたスペクトルを復元する問題を、次のように定式化した。

$$\begin{aligned} \operatorname{argmin}_{\mathbf{X}} \|\mathbf{f}(\mathbf{X}) - \mathbf{Y}\|^2 + \lambda \|\mathbf{X}\|_{\text{TV}} \\ \text{s.t. } \mathbf{X} > \mathbf{0}, \operatorname{rank}(\mathbf{X}) = \mathbf{r} \end{aligned} \quad (1)$$

ここで、 \mathbf{X} は本来のスペクトル画像、 \mathbf{Y} は測定データ、 \mathbf{f} はパイルアップによるスペクトルの歪みモデルである。 $\|\cdot\|_{\text{TV}}$ は全変動の L1 ノルム、 λ は正則化パラメータである[5,6]。制約条件として、画素値は正であること、再構成画像のランクは \mathbf{r} であることを加えた。ここで、 \mathbf{r} は小さな値を持つベクトルで要素数は 3 である。この要素数は \mathbf{X} が 3-way テンソルであることに由来する。すなわち、このテンソルを 2 次元行列に広げる方法は 3 パターンあり、それぞれが低ランク行列となるという制約である。低ランクが保証される理由は、異なるエネルギービンの画像であっても、互いに構造は似ているはずだからである[8]。

本手法を評価するため、Shepp ファントムを用いて画像再構

成シミュレーションを行った。スペクトルは、エネルギー範囲を 15-140 keV、ビン幅を 15 keV、管電圧を 100 kV と仮定した。投影画像には、最大カウントの 5%に対応するポアソンノイズを付加し、X 線の強度は不感時間内に入射する平均光子数を 1 として、パイルアップ効果を発生させた。取得した投影画像に対してスペクトルの歪み補正を適用し、フィルター補正逆投影法 (FBP)によって画像再構成を行った。

3. 結果および考察

図 1 に再構成画像を、図 2 に中央の横方向プロファイルを示す。スペクトルの歪みを補正しない場合(図 1b, 図 2 の青線), は画素値を大きく過大評価している。その原因は、スペクトルが歪められることに伴い、測定される X 線強度が過小評価されるためである。一方、正則化を適用せずにスペクトルの歪みを補正した場合には(図 1c, 図 2 の緑線), 画素値の過大評価はなくなったものの、雑音の増幅が目立つ。その原因は、冒頭でも述べた通り、スペクトルの歪み補正が逆問題であるため、安定した解が得にくいことにある。それに対し、提案手法を適用した結果では(図 1d, 図 2 の赤線), 画素値の過大評価もなく、雑音の増幅も抑えられている。それぞれの画像の RMSE は 0.18, 0.040, 0.024 cm^{-1} であり、定量的にも本手法の有効性を確認できる。

4. 結論

本研究では、パイルアップ効果に由来するスペクトルの歪みを補正する手法として、空間・エネルギーの正則化を組み合わせる方法を提案した。その有効性は、シミュレーションにより定量的に確認された。

謝辞

本研究は JSPS 科研費 JP20K20232 の助成を受けたものです。

利益相反の有無

なし

文献

- [1] Ogawa K., Kobayashi T., Kaibuki F. et al.: Development of an energy-binned photon-counting detector for X-ray and gamma-ray imaging, Nuclear Instruments and Methods in Physics Research A, 664: 29-37, 2012
- [2] Cormode D. P., Si-Mohamed S., Bar-Ness D. et al.: Multicolor spectral photon-counting computed tomography: in vivo dual contrast imaging with a high count rate scanner, scientific reports, 7, 4784, 2017
- [3] Taguchi K., Stierstorfer K., Polster C., et al.: Spatio-energetic cross-talk in photon counting detectors: $N \times N$ binning and sub-pixel masking, Proc. Of SPIE, 10573 10574X-1, 2018

- [4] Murata K. and Ogawa K.: Influence of pulse pile-up effects on material decomposition with photon-counting CT, IEEE NSS/MIC, 2020
- [5] Taguchi K., Frey C. E., and Wang X. et al.: An analytical model of the effects of pulse pileup on the energy spectrum recorded by energy resolved photon counting x-ray detectors, Med. Phys., 37, 8: 3957-3969, 2010
- [6] Taguchi K., Zhang M., Frey C. E. et al.: Modeling the performance of a photon counting x-ray detector for CT: Energy response and pulse pileup effects, Med. Phys., 38, 2: 1089-1102, 2011
- [7] Murata K. and Ogawa K.: Ring-artifact correction with total-variation regularization for material images in photon-counting CT, IEEE TRPMS, 5, 4, 2021
- [8] Semerci O., Hao N., Kilmer M. E. et al.: Tensor-based formulation and nuclear norm regularization for multienergy computed tomography, IEEE Transactions on Image Processing, 23, 4, 2014




図 1. 再構成画像の比較。(a) 歪みおよびノイズを含まない画像, (b) 歪み補正を適用していない画像, (c) 正則化を用いずに歪み補正をした画像, (d) 提案手法 (TV+低ランク行列近似)による再構成画像。

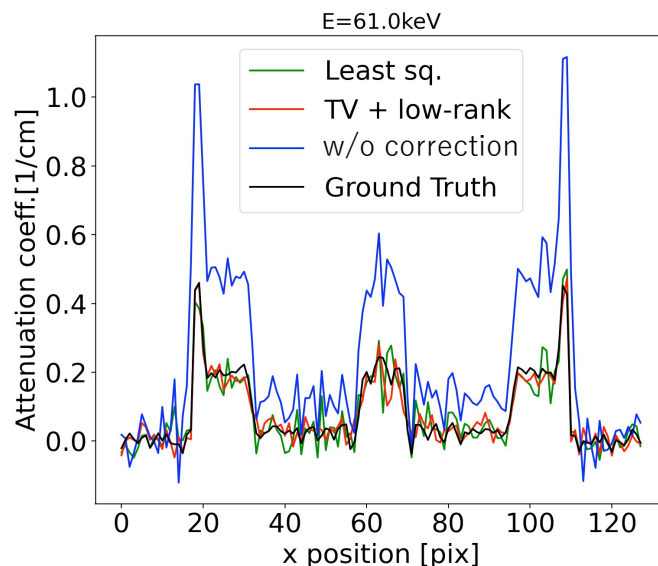


図 2. 再構成画像の中央の横方向プロファイル。歪みおよびノイズなし(黒), 補正なし(青), 正則化なし(緑), 提案手法(赤). 提案手法を用いた時のプロファイルは過大評価もなく、最も安定していることがわかる。

学習データを用いた低線量 CT 逐次近似画像再構成の正則化パラメータ自動決定

工藤 博幸^{*1}

^{*1} 筑波大学システム情報系

Estimation of Regularization Parameter Using Training Data in Low-Dose CT Iterative Reconstruction

Hiroyuki KUDO^{*1}

^{*1} University of Tsukuba

要旨： 本論文では、低線量 CT の TV 正則化を用いた逐次近似画像再構成において、平滑化の度合いを調節する正則化パラメータの値を学習データを用いて自動推定する 2 つの手法を提案する。一つ目はベイズ推定に基づく手法、二つ目は深層学習にヒントを得た手法である。両手法とも上手く動作することを、腹部 CT 実画像を用いたシミュレーション実験により示す。

キーワード： 低線量 CT, 画像再構成, 逐次近似法, TV 正則化

1. はじめに

低線量 CT の画像再構成では、トータルバリエーション(TV)正則化項や非局所平均フィルタを用いた正則化項(文献[1])を用いた逐次近似画像再構成法が有効であり、商用装置にも採用されている。本手法の一番の問題点は正則化の強さや特性を加減する正則化パラメータの決定であり、ほとんどの場合経験的に設定されており自動決定は未検討で難しいとされているのが現状である。

本論文では、撮影対象と同じ部位を撮影した学習データセット(通常線量の正解画像の集合)を用いて、正則化パラメータを自動決定する 2 つの手法を提案して、両者とも有効に動作することを実証する。一つ目の手法は、画像復元など一般の逆問題分野で既に類似手法の提案がある正則化パラメータのベイズ推定に基づく手法で、学習データから正則化パラメータの事前分布を求めておき、それに対数尤度を加えた評価関数を画像再構成の過程で最小化して自動決定する。二つ目の手法は、深層学習にヒントを得た全く新しい手法で、学習データに対して平均 2 乗誤差や SSIM 値を最小にする正則化パラメータ値を学習で事前に求めておき、この事前決定した正則化パラメータで画像再構成を行う。

腹部 CT 実画像データセットを用いたシミュレーション実験を行った結果、どちらの手法も有効に動作して最適に近い正則化パラメータの推定値を与えるが、二つ目の手法が正則化パラメータ推定の反復ループを必要としないため計算量の面で優れることが示された。また、推定するパラメータ空間の次元が低いため、両手法とも必要な学習データの数は非常に少なく済むことも示された。

2. 提案手法

1) 低線量 CT の画像再構成

低線量 CT の画像再構成は、以下の評価関数を逐次近似法を用いて最小化することにより行われる。

$$F(\mathbf{x}) \equiv L(\mathbf{x}) + \beta U(\mathbf{x}) \quad (1)$$

$$L(\mathbf{x}) = \|\mathbf{Ax} - \mathbf{b}\|_W^2/2, \quad U(\mathbf{x}) = \|\mathbf{x}\|_{TV} \quad (2)$$

ただし、 $L(\mathbf{x})$ は重み付き 2 乗誤差から構成されるデータ項、 $U(\mathbf{x})$ は画像を平滑化して雑音を抑制する正則化項で通常トータルバリエーション (TV) が用いられる。また、 β は平滑化の強さを調節する正則化パラメータである。評価関数の最小化は FISTA や Chambolle-Pock アルゴリズムなどの逐次近似法を用いて行われるが、本研究の提案手法はどのような逐次近似法と組み合わせることも可能な一般性があり、本研究では高速に収束する Dykstra 型スプリッティングに基づく Row-Action 型反復法(文献[2])を用いている。

現状では、正則化パラメータ β の値はイメージングの状況や撮影部位に応じて経験的に決定することが行われているが、本研究では撮影対象と同じ部位を撮影した学習データセット(通常線量の正解画像の集合)を用いて β の値を自動決定する手法を 2 つ提案する。

2) 提案手法 1 (ベイズ推定に基づく手法)

[Step 1] 撮影対象と同じ部位を撮影した学習データ \mathbf{x}_n ($n = 1, 2, \dots, N$)の各々を次式の確率モデルに最尤推定で当てはめ N 個の β の値を求め、カーネル密度推定して正則化パラメータ β の事前分布 $P(\beta)$ を求める。

$$P(\mathbf{x}|\beta) = \exp(-\beta U(\mathbf{x})) / \sum_{\mathbf{x}} \exp(-\beta U(\mathbf{x})) \quad (3)$$

[Step 2] 次式の対数事後尤度 $\log P(\beta|\mathbf{b})$ を EM アルゴリズムにより最大化することにより、 β を推定する。

$$\log P(\beta|\mathbf{b}) = \log P(\beta) + \log(\sum_{\mathbf{x}} P(\mathbf{x}|\beta)P(\mathbf{b}|\mathbf{x})) - \log P(\mathbf{b}) \quad (4)$$

$$\log P(\mathbf{b}|\mathbf{x}) = \|\mathbf{Ax} - \mathbf{b}\|_W^2/2 \quad (5)$$

ただし、EM アルゴリズムの反復では、式(4)において $\sum_{\mathbf{x}}$ の部分を鞍点近似して再構成画像 \mathbf{x} の推定と正則化パラメータ β の推定を交互に繰り返す。その処理手順は、以下のようにまとめられる。

(1) β の初期値 $\beta^{(0)}$ を与える。反復回数を $k = 0$ に設定。

(2) β を $\beta^{(k)}$ に固定して式(1)の最小化を行い、再構成画像 $\mathbf{x}^{(k)}$ を求める。

(3) \mathbf{x} を $\mathbf{x}^{(k)}$ に固定して $-\log P(\beta|\mathbf{b})$ の最小化を行い、 $\beta^{(k+1)}$ を求める。

この反復法により、再構成画像 \mathbf{x} と正則化パラメータ β は同時に求まる。ただし、この手法を用いる場合には入力データ毎に EM アルゴリズムの反復計算が必要である。

3) 提案手法 2 (深層学習にヒントを得た手法)

深層学習にヒントを得た手法で、撮影対象と同じ部位を撮影した学習データ $\mathbf{x}_n (n = 1, 2, \dots, N)$ から正則化パラメータ β を推定する学習 Step と推定した β で画像再構成を行う再構成 Step から構成される。

(学習 Step)

[Step 1] 各学習データ $\mathbf{x}_n (n = 1, 2, \dots, N)$ に対して低線量 CT のイメージング過程をシミュレーションして、対応する投影データ $\mathbf{b}_n (n = 1, 2, \dots, N)$ を求める。

[Step 2 (MSE 学習)] 各投影データ $\mathbf{b}_n (n = 1, 2, \dots, N)$ を画像再構成した際の正解 $\mathbf{x}_n (n = 1, 2, \dots, N)$ との平均 2 乗誤差 MSE が最小になるように、 β の値を推定する。式で表現すると、推定の評価関数 MSE は以下のように表される。

$$\text{MSE}(\beta) = \sum_n \|\mathbf{x}_n - \text{Recon}_\beta(\mathbf{b}_n)\|^2 / N \quad (6)$$

ただし、 $\text{Recon}_\beta(\cdot)$ は式(1)を最小化して画像再構成を行う演算である。また、Step 2 のバリエーションとして、SSIM 値の平均値が最大になるに β を推定する手法も合わせて提案する。

[Step 2 (SSIM 学習)]

$$\text{SSIM}(\beta) = \sum_n \text{SSIM}(\mathbf{x}_n, \text{Recon}_\beta(\mathbf{b}_n)) / N \quad (7)$$

(再構成 Step)

入力投影データ \mathbf{b} に対して、学習 Step で推定した β の値で画像再構成を行う。

$$\mathbf{x} = \text{Recon}_\beta(\mathbf{b}) \quad (8)$$

学習 Step では全ての投影データ $\mathbf{b}_n (n = 1, 2, \dots, N)$ の画像再構成を M 個の候補パラメータ $\beta_1, \beta_2, \dots, \beta_M$ で行う必要があるため MN 回の画像再構成が必要になるが、後述するように推定するパラメータ空間の次元は 1 次元で低いため、学習データの個数 N は驚くほど少なく済む。また、提案手法 1 と比較した利点として、全ての入力データに学習で事前に求めておいた β を用いて再構成する手法であるため、反復計算が不要で計算時間が短い点が挙げられる。

3. シミュレーション実験

腹部 CT 実画像を用いたシミュレーション実験を行い、提案手法の有効性を確認した。実験の条件を表 1 にまとめて示す。60 症例の腹部 CT 画像から肝臓のほぼ中心を通る断面を切り出し、40 症例を学習データ、20 症例をテストデータとして用




図 1 推定した β を用いたテストデータの再構成例

いた。表 2 に、提案手法 1 と提案手法 2 で求められた β の値とその β を用いた際の再構成画像の MSE 値 (SSIM 値) を示す。ただし、テストデータに対する MSE が真に最小になる β の値とその β を用いた際の再構成画像の MSE 値も合わせて示す。図 1 に、推定された β の値を用いた場合の提案手法 1, 2 の再構成画像と FBP 法の再構成画像の例を示す。スペースが限られており一つの条件のものしか示していないが、2 種類のノイズレベルと 4 種類の画像データセットの組み合わせについて実験を行い、どの場合にも妥当な β の推定結果が得られ、提案手法 1, 2 は両方とも上手く動作することを確認した。

学習データ数 N	10, 20, 40
テストデータ数 L	20
β の探索刻み	[E-5, E-4], [E-4, E-3], [E-3, E-2] の各区間を各々 20 等分した 58 個の点を探索

表 1 シミュレーション実験の条件

手法	学習データ数	β	MSE (SSIM)
1	10	4.0E-04 ($\sigma=0.0$)	1.553E-03
1	20	4.0E-04 ($\sigma=0.0$)	1.553E-03
2(MSE)	10	4.0E-04	1.553E-03
2(MSE)	20	4.0E-04	1.553E-03
2(SSIM)	10	3.5E-04	0.811
2(SSIM)	20	3.5E-04	0.811
テストデータ MSE が最小になる β とその時の MSE		$\beta=4.0E-04$ MSE=1.553E-03	

表 2 推定された β の値とテストデータ再構成画像の MSE 値

利益相反の有無： なし

文献

- [1] Dong J, Kudo H: Proposal of compressed sensing using nonlinear sparsifying transform for CT image reconstruction. Med Imag Tech. 34: 235-244, 2016
- [2] Kim H, Sadakata K, Kudo H: Unified framework to construct fast row-action-type iterative CT reconstruction methods with total variation using multi proximal splitting. Proc ICBIP2021, 65-71, 2021

Geometric Matching CNN による指骨 CR 画像の位置合わせ手法

小野 輝^{*1}, 神谷 亨^{*1}, 青木 隆敏^{*2}

^{*1} 九州工業大学工学府工学専攻

^{*2} 産業医科大学

Image Registration Method for Phalanges CR Image Based on Geometric Matching CNN

Hikaru ONO^{*1}, Tohru KAMIYA^{*1}, Takatoshi AOKI^{*2}

^{*1} *Kyushu Institute of Technology*

^{*2} *University of Occupational and Environmental Health*

要旨：関節リウマチは、病態が進行すると全身の関節破壊を生じ、患者の QOL を著しく阻害する。関節リウマチの診断は、血液検査や X 線画像診断により総合的に行われている。特に、X 線画像診断は簡便に病態の進行を捉えることができるが、読影医師の負担増加や医師の主観的な評価による再現性の欠如が課題となっている。そこで、コンピュータの解析結果を第二の意見として利用するコンピュータ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・現在画像から関節リウマチの進行を捉える支援診断システムの開発を目的とし、指骨領域の位置合わせ手法を提案する。Geometric Matching CNN を画像ペアごとに最適化することにより、指骨領域の高精度な位置合わせを行う。提案手法を 560 組の合成指骨領域画像に適用した結果、TP が 99.26%、FP が 0.79% という結果を得た。

キーワード：コンピュータ支援診断、画像位置合わせ、経時的差分像、関節リウマチ

1. はじめに

関節リウマチは、関節の腫れや痛み、関節破壊を特徴とする慢性炎症性疾患である[1]。病態早期には手や足の関節に発症することが多いが、病態が進行すると全身の関節破壊を生じ、患者の QOL (Quality of Life) を著しく阻害する。

関節リウマチの診断は、一般に画像診断により行われる。特に、単純 X 線による手指関節の検査は、簡便で複数の関節を短時間に評価することができるため、治療の評価や診断に利用される。しかし、画像診断は読影医師の主観的な評価によるため、客観性に欠け、病変部の見落とし等が発生する可能性がある。

これらの問題を解決するため、コンピュータの解析結果を第二の意見として利用するコンピュータ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・現在画像から関節リウマチの進行を捉える支援診断システムの開発を目的とし、位置合わせ用の深層学習モデルである Geometric Matching CNN[2]による指骨領域の位置合わせ手法を提案する。提案手法を 560 組の合成指骨領域画像と、9 症例の CR 画像に適用し、その結果と考察について述べる。

2. 手法

本章では、CR 画像からの指骨領域のセグメンテーション手法と指骨領域画像の位置合わせ手法について詳細を述べる。

2.1 セグメンテーション



図 1 指骨領域画像とそれに対応するマスク画像

過去・現在画像の各指骨を位置合わせするため、両手を撮影した CR 画像から指骨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である DeepLabv3+[3]により指骨領域を自動抽出する。放射線科技師の指導の下、指骨領域をラベリングし、学習を行った DeepLabv3+により指骨 CR 画像から、マスク画像を生成する。その後、図 1 に示すような各指骨を抽出した指骨領域画像とそれに対応するマスク画像を生成する。

2.2 画像位置合わせ

本論文では、幾何学的変換パラメータの推定を行う深層学習モデル Geometric Matching CNN[2]により指骨領域の位置合わせを行う。本論文では、剛体変換モデルにより画像を変換するため、CNN の出力層の次元数は 3 次元とする。

深層学習により推定された幾何学的変換パラメータは、最適解の単なる近似であると考えられることができる[4]。そのため、最適な変換とのギャップが生じ、位置合わせの精度に影響を及ぼす。そこで、推論時に指骨領域画像に対応するマスク画像の差を参照することで CNN モデルを画像ペア個別に最適化する。手法の概要を図 2 に示す。Geometric Matching CNN は入力された過去・現在画像のペアから剛体変換パラメータを推定し、初

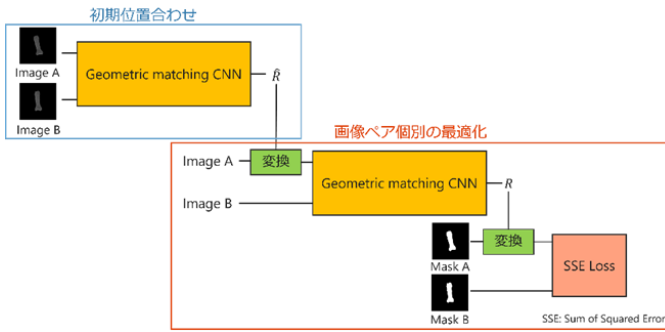


図2 提案手法の概要

期位置合わせを行う。その後、変換した画像ペアを再度モデルに入力する。このとき、出力された剛体変換パラメータを指骨領域画像に対応するマスク画像に適用し、マスク画像の二乗和誤差が最小となるよう、勾配降下法によりモデルを最適化する。

3. 実験と結果

本実験で使用する画像は、産業医科大学病院で収集され、ヘルシンキ宣言の倫理的原則に沿っており、倫理審査委員会の承認を得ている。

本実験では、学習に Pascal VOC 2011[5]データセットを用い、オリジナルの画像に対して、ランダムな剛体変換を適用することで画像ペアを作成した。

また、評価指標は式(1)に示す正解領域に対する予測領域の重なる割合を表す TP と、式(2)に示す正解領域に対する過抽出領域の割合を表す FP を用いる。

$$TP = \frac{A \cap B}{A} \quad (1)$$

$$FP = \frac{B - A \cap B}{A} \quad (2)$$

ここで、正解領域 A とは位置合わせにおける参照画像の指骨領域のことを指し、予測領域 B とは変換画像の指骨領域のことを指す。

本実験では、同一被験者の過去・現在画像のペアで構成される実データと合成データにより評価を行う。過去画像と現在画像のペアで構成される実データでは、骨の変形等により位置合わせの精度を正確に評価することが困難である。そこで、指骨領域画像現に対してランダムな剛体変換を施した合成データにより提案手法の有効性を確認する。合成データは 560 組の指骨領域画像で構成され、実データは 9 症例の過去・現在画像ペアの、親指を除く基節骨および中節骨の指骨領域画像 144 組で構成される。表 1 に実験結果を示す。

3. 考察とまとめ

表 1 より、合成データ、実データともに提案手法が最も良い精度を得た。実データによる評価で、合成データと比較し、提案手法の精度が下がった主な要因として、前処理であるセグメ

表 1 実験結果

手法	合成データ		実データ	
	TP [%]	FP [%]	TP [%]	FP [%]
Genetic Algorithm[6] 世代数: 200	97.86	7.88	92.54	2.69
Geometric Matching CNN	93.23	6.79	93.31	6.39
提案手法 最適化回数: 20	98.46	1.60	97.00	2.06
提案手法 最適化回数: 50	99.26	0.79	97.62	1.44

ンテーションの精度が影響していることが考えられる。

また、処理時間は、古典的な手法である GA による手法では CPU で 16 秒程度かかるが、提案手法は最適化回数 50 回の場合でも GPU で 1 秒程度であり高速化を実現している。

本論文では、経時的差分技術により同一被験者の過去・現在画像から関節リウマチの進行を捉える支援診断システムの開発を目的とし、Geometric Matching CNN による指骨領域の位置合わせ手法を提案した。合成データによる評価により、提案手法は TP が 99.26%、 FP が 0.79% という結果を得た。今後は、セグメンテーション精度の向上により、実データにおいても高精度な位置合わせを行うことが課題である。また、関節リウマチ患者に対し、経時的差分技術を適用し、我々が提案する CAD システムの有効性を確認する予定である。

謝辞

本研究を進めるにあたり、貴重なご助言を賜った純真学園大学の村上誠一教授に深謝いたします。

利益相反の有無

なし

文献

- [1] Aletaha D. et al.: 2010 Rheumatoid Arthritis Classification Criteria: An American College of Rheumatology/European League Against Rheumatism Collaborative Initiative, *Arthritis Rheum*, Vol.62, No.9, pp.2569-2581, 2010
- [2] Rocco I. et al.: Convolutional Neural Network Architecture for Geometric Matching, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.6148-6157, 2017
- [3] Chen L. C. et al.: Encoder-decoder with Atrous Separable Convolution for Semantic Image Segmentation, *Proceedings of the European Conference on Computer Vision*, pp.801-818, 2018
- [4] Balakrishnan G. et al.: A Learning Framework for Deformable Medical Image Registration, *IEEE Transactions on Medical Imaging*, Vol.38, No.8, pp.1788-1800, 2019
- [5] Everingham M. et al.: The PASCAL Visual Object Classes Challenge 2011 (VOC2011), <http://host.robots.ox.ac.uk/pascal/VOC/voc2011/index.html>
- [6] Kawagoe K. et al.: Registration of Phalange Region from CR Images Based on Genetic Algorithm, *The 18th International Conference on Control, Automation and Systems*, pp.1464-1467, 2018

放射線治療における膵臓変位推定の為の 2D 断層画像駆動型複数臓器接触シミュレーション

原 裕貴^{*1}, 角谷 倫之^{*2}, 三目 直登^{*3}, 家永 直人^{*3}, 梅澤 玲^{*2}, 神宮 啓一^{*2},
黒田 嘉宏^{*3}

^{*1} 筑波大学大学院システム情報工学研究群

^{*2} 東北大学医学系研究科

^{*3} 筑波大学システム情報系

2D Tomographic Image-Driven Multi-Organ Contact Simulation for Estimating Pancreatic Displacement in Radiotherapy

Yuki HARA^{*1}, Noriyuki KADOYA^{*2}, Naoto MITSUME^{*3}, Naoto IENAGA^{*3}, Rei UMEZAWA^{*2},
Keiichi JINGU^{*2}, Yoshihiro KURODA^{*3}

^{*1} Degree Programs in Systems and Information Engineering, University of Tsukuba

^{*2} Graduate School of Medicine, Tohoku University

^{*3} Faculty of Engineering, Information and Systems, University of Tsukuba

要旨: 放射線照射中に断層画像を撮影できる MR-Linac は、膵臓などの非周期的な動きをする臓器に対しての効果的な治療につながるとして期待されている。しかし、撮像できるのは一部の断面画像であるため、術前の計画用 3 次元 MR 画像を、膵臓の自発的な変形や周辺臓器との接触を考慮しながら更新するのが困難である。そこで本研究では、2 次元断層画像駆動型 Material Point Method を提案する。2 次元断層画像から得られた対象臓器の位置関係から、該当断面における節点の目標位置を求め、現在位置と目標位置との差に応じた力を加えることで 3 次元ラベルを駆動させる。周辺臓器との接触を考慮した物理シミュレーションにより 3 次元モデルの変位推定を目指す。本提案では、腹部の断層画像を用い、胃を周辺臓器として提案手法の基礎的な検討を行った。その結果、5 例中 4 例で変位の推定精度が改善したことを確認した。

キーワード: Material Point Method, IGRT, pancreas, registration

1. 序論

近年、リアルタイムに MR 画像を撮影しながら放射線治療を行う装置 (MR-Linac) が実用化され、胃や十二指腸などと隣接している膵臓に対して、高い照射線量による治療が期待されている。しかし、撮像できるのは数断面程度のみであり、事前に計画したラベルを、周辺臓器との接触や自発的な変形を考慮しながら臓器の動きに合わせて変更することは困難である。そのため、一部の画像から、モデル全体の変位を推定することが求められる。

MR 画像誘導放射線治療の研究は盛んに行われている。VÁLazquez ら [1] は、多数の患者のデータを同時に学習することで、多様な動きを表現可能なフレームワークを提案した。しかし、複数の周辺臓器により影響を受けた膵臓の変形を適切に扱うためには、膨大な量のデータセットが必要になると考えられる。

本提案では、周辺臓器と隣接している、という点を積極的に利用することで膵臓の高精度な変位推定を目指す。メッシュフリー法の一つであり、異物体の接触を効率よく扱うことができる Material Point Method (MPM) を利用し、断層画像から得られる情報をもとに、膵臓及び周辺臓器を駆動させることで、3

次元変位の推定を行う。

2. 提案手法

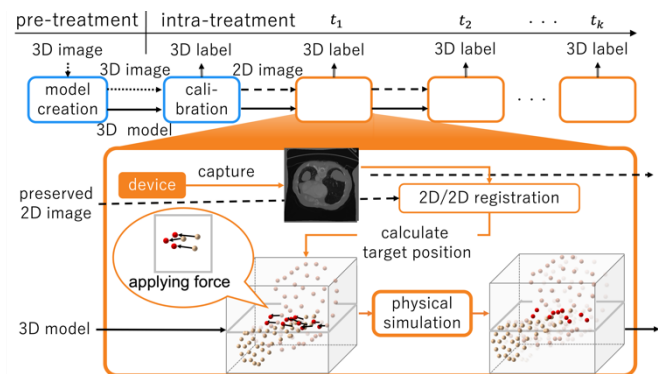


図 1 提案手法の概要図

提案手法の概要を図 1 に示す。提案手法には、大きく分けて 3 つのステップが存在する。

1) 治療前処理

術前に撮像された 3 次元のボリューム画像から、3 次元物理モデルを作る。

2) 治療初期段階でのキャリブレーション

3次元モデルを駆動させるために、装置から得られる断層画像と、それに対応した3次元モデルにおける断層画像を選択する。

3) 治療中処理

治療中に得られた画像と、事前に選択した画像との2D/2D非剛体位置合わせを行うことで、変換行列を求める。

本研究では、`elastix` [2] を用いて位置合わせを行なった。

求めた変換行列を用い、MPMによる臓器の接触シミュレーションを行うことにより膀胱の変位を推定する。本発表では、膀胱に加えて、周辺臓器として胃を線形弾性体としてモデル化した。なお、1画素につき1粒子を割り当てた。

まず、画像と対応した、3次元モデル上の粒子の目標位置を、変換行列を用いて求める。その後、各粒子に対して、現在位置と目標位置の差が閾値を下回るまで、(1)式で表されるような力を加えることで3次元モデルを駆動させる。

$$f = K_p \mathbf{x}_{diff} + K_i \int \mathbf{x}_{diff} dt + K_d \frac{d\mathbf{x}_{diff}}{dt} \quad (1)$$

ここで、 \mathbf{x}_{diff} は目標位置 \mathbf{x}_{tar} と現在位置 \mathbf{x}_{cur} の差 $\mathbf{x}_{tar} - \mathbf{x}_{cur}$ 、 K_p 、 K_i 、 K_d はそれぞれ比例、積分、微分項に対する係数である。このようにして、他臓器との位置関係や動きによる、周期性を持たない変形を表現することを可能とするために、変位の推定の際に周辺臓器との接触を考慮した。

3. 実験及び結果

本発表では、2D/2D位置合わせに使用する断層画像を、臓器が存在するボリューム中央の画像1枚とした。なお、臓器の画像には、Multi-Atlas Labeling Beyond the Cranial Vault segmentation challenge dataset [3] を使用した。画像サイズは $512 \times 512 \times 138$ である。シミュレーションを実行するためのデータ処理にはMATLABを使用した。

物理モデルの各粒子にランダムな平面方向の力を加えて変形させることでGround Truth (GT) を作成し、baselineを`elastix`による3D/3D位置合わせで推定された膀胱の位置誤差とした。なお、本提案で用いた誤差 ε の式は(2)式である。

$$\varepsilon = \frac{1}{n} \sum_{i=1}^n \|\mathbf{x}_{gt,i} - \mathbf{x}_{est,i}\| \quad (2)$$

ここで、 n は物理モデルにおける総粒子数であり、 $\mathbf{x}_{gt,i}$ は*i*番目の粒子のGTにおける位置ベクトル、 $\mathbf{x}_{est,i}$ は*i*番目の粒子の推定された位置ベクトルである。

提案手法による誤差とbaselineを比較することで、断層画像1枚のみの使用で、3次元変位推定においてどの程度の精度を実現できるかを検証した。また、周辺臓器の考慮による精度向上の有無について検証した。

5例のデータに対して提案手法を適用した。5例のシミュレーションにおいて、膀胱の粒子数は16432~52258(個)、胃の粒

子数は58883~327534(個)である。結果の一例を図2に示す。図2を見ると、表面部分に誤差が見受けられるものの精度よく変位を推定できていることが分かる。

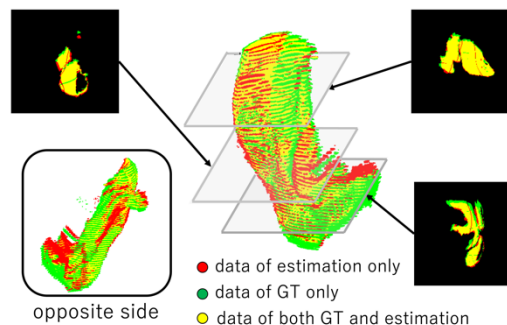


図2 提案手法による結果

提案手法による膀胱の位置誤差は 6.14 ± 2.08 (pixel)、提案手法において、周辺との接触を考慮しなかった場合の膀胱の位置誤差は 8.88 ± 3.82 (pixel)、baselineは 2.49 ± 1.01 (pixel)であった。接触を考慮しない場合に比べて考慮した場合は5例中4例で高精度であったため、周辺臓器との接触を考慮することで精度が向上する傾向が示唆された。

R (ver.4.0.5) を使用して Kruskal-Wallis 検定を行なったところ、有意水準5%で有意差が見られた。その後、Bonferroni調整を行なった Mann-Whitney U test により多重比較を行ったところ、全ての群間で有意差は見られなかった。試行データ数が少ないことが原因だと考えられる。

4. 結論

本研究では、2次元断層画像を用いた放射線治療中の膀胱の変位推定手法を提案した。実験の結果から、周辺臓器との接触を考慮することにより、精度向上の傾向が示唆された。今後は、実測データを用いて、提案手法の有効性を確認する予定である。

利益相反の有無

なし。

文献

- [1] VÁLazquez R L, Mezheritsky T, Kadoury S: Personalized Respiratory Motion Model Using Conditional Generative Networks for MR-Guided Radiotherapy. MICCAI 2021: 24th International Conference, Strasbourg, France, September 27-October 1, 2021, Proceedings, Part IV: 238-248, 2021
- [2] Klein S, Staring M, Murphy K et al: elastix: a toolbox for intensity-based medical image registration. IEEE Trans Med Imaging 29: 196-205, 2010
- [3] Landman B, Xu Z, Igelsias J E et al: Multi-Atlas Labeling beyond the Cranial Vault—Workshop and Challenge, 2015 [online] Available: <https://www.synapse.org/#!/Synapse:syn3193805>

内視鏡動画解析による所見作成支援に向けた臓器判別

藤津 泉梨^{*1}, 藤江 舞^{*2}, 野村 行弘^{*3}, 加藤 順^{*4}, 中口 俊哉^{*3}

^{*1} 千葉大学大学院融合理工学府基幹工学専攻医工学コース

^{*2} 千葉大学医学部附属病院臨床工学センター

^{*3} 千葉大学フロンティア医工学センター

^{*4} 千葉大学医学部附属病院内視鏡センター

Organ discrimination by endoscopic video analysis to support creating of findings

Senri Umetsu^{*1}, Mai Fujie^{*2}, Yukihiko Nomura^{*3}, Jun Kato^{*4}, Toshiya Nakaguchi^{*3}

^{*1} *Department of Medical Engineering, Graduate School of Science and Engineering, Chiba University*

^{*2} *Clinical Engineering Center, Chiba University Hospital*

^{*3} *Center for Frontier Medical Engineering, Chiba University*

^{*4} *Endoscopy Center, Chiba University Hospital*

要旨：内視鏡検査では、医師が検査の記録として診断内容、検査臓器、実施処置などを記入した所見を作成する。しかし、内視鏡操作のため検査中の所見作成は困難であり、医師は検査後の時間を利用して記入する。医師の作業負担軽減のため、所見作成の効率化が求められる。また、所見は医師の記憶に基づくため、記載漏れの発生も課題である。診療報酬点数の申告漏れや医療安全の観点からも、正確な検査記録が求められる。本研究では、内視鏡動画解析による所見作成の効率化と記載漏れ防止を目的とし、第一段階として、検査臓器の判別手法を提案する。提案手法では、CNN と LSTM を組み合わせ、時間情報を利用した臓器分類を行う。さらに、分類結果に対して検査開始時と終了時の双方向から Sliding Window(SW)によって臓器境界を探索し誤分類フレームを除去する。17 症例の内視鏡動画で学習した提案手法を別の 7 症例で評価した結果、LSTM と SW を導入することの有効性が示唆された。

キーワード：内視鏡動画、所見作成、臓器判別、深層学習

1. はじめに

内視鏡検査において、医師は検査記録として診断内容、検査臓器、実施処置などの項目を記録した所見を作成する。検査中はモニターを見ながら両手で内視鏡を操作するため、所見を入力することは困難である。そのため検査後に電子医療記録システムへ入力を行い、所見を作成する必要がある。医師の作業負担軽減のためには、所見作成を効率化することが求められる。また、所見は医師の記憶に基づいて作成されるため、記載漏れの発生も課題となっている。診療報酬点数の申告漏れや医療安全の観点からも、正確な検査の記録は重要である。本研究では、内視鏡動画解析による所見作成の効率化と記載漏れ防止を目的とする。第一段階として、検査記録の中でも重要な情報である検査臓器の判別手法を提案する。

2. 提案手法

提案手法では、はじめにフレーム単位での臓器分類を行い、その結果に対して臓器の境界探索を行う。本研究では、臓器のクラスは上部消化管を対象とし、頭頸部、食道、胃、十二指腸、体外の 5 クラスとする。

フレーム単位での臓器分類では、画像認識に用いられる CNN(Convolutional Neural Network)に、時系列情報を扱う

LSTM(Long Short-Term Memory)を組み合わせることで、時間情報を利用する。先行研究として、Tim Boers らが CNN に RNN(Recurrent Neural Network)を導入することで時間情報を利用した上部消化管の組織分類に取り組み、予測の安定性および精度の向上を達成した[1]。この研究において、各組織クラスは決まった順序で 1 度ずつ観測される。上部消化管内視鏡検査では、臓器間を複数回往復して観察することもある。しかし、Tim Boers らの研究結果からは、クラスの出現順序が一定でない場合における有効性は示されていない。そこで、本研究では時間情報を利用して臓器を分類し、上部消化管内視鏡検査のようなクラスの出現順序が一定でない場合の分類における有効性を検証する。

臓器の境界探索では、フレーム単位での臓器分類結果に対して、臓器の切り替わり部分である境界を探索し、境界を基に予測結果を分割し直すことで、内部の誤分類フレームの除去を目指す。境界探索には SW(Sliding Window)[2]を用いる。SW とは、ウィンドウ内において分類エラーが最小になる点を探索し、クラスの境界を決定する手法である。SW では、フレーム単位での臓器分類結果で誤分類が続いた場合、境界として認識され、誤った臓器にまとめて分割されることが想定される。

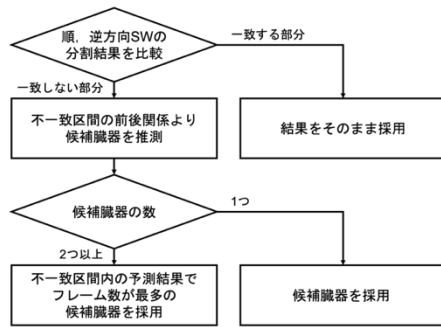


図1 双方向 SW のフロー

そこで本研究では、新たに逆方向 SW と双方向 SW を提案する。通常の SW では、検査開始時から順方向に境界を求めのに対し、逆方向 SW では、検査終了時から逆方向に境界を探索する。また、双方向 SW では、順方向 SW と逆方向 SW の結果および元の臓器分類結果を統合する。双方向 SW のフローを図1に示す。はじめにフレーム単位での臓器分類結果に対して、順方向 SW と逆方向 SW を適用する。この際、臓器の解剖学的位置を考慮して、境界を探索する臓器を設定する。次に2つの SW の分割結果を比較し、一致する部分はその結果を採用する。一致しない部分は不一致区間として、不一致区間前後の臓器から臓器の解剖学的位置を考慮し、候補となる臓器を推測する。候補臓器が1つの場合は、不一致区間のフレームが全てその候補臓器であるとする。候補臓器が2つ以上の場合にはフレーム単位での臓器分類結果を参照し、不一致区間において最もフレーム数の多い候補臓器を採用する。

3. 実験と結果

はじめに CNN 単体のモデルと LSTM を組み合わせたモデルの比較を行った。CNN 単体のモデルには、ResNet34[3]を使用した。また、LSTM を組み合わせたモデルには、ResNet34 の後段に隠れ状態ベクトルが 128 次元の LSTM を 2 層追加した。学習、検証用データには、FUJIFILM 社の内視鏡で撮影された内視鏡動画 17 症例から 10 フレームおきに取得した合計 57094 枚の画像を使用した。これらの画像はフレームの黒枠部分を除去するため、前処理として画像の短辺が 270pixel になるようリサイズした後、画像中央 224×224pixel でクロップした。データ拡張として、学習データに対して 5 度までの回転および剪断と、画像長の 2.5% までの平行移動を適用した。LSTM を用いたモデルにおいては、動画中の連続した 100 枚のフレームを 1 シーケンスとして入力し、10 枚おきに誤差逆伝播を行い、パラメータを更新した。学習において、バッチサイズは 256、損失関数は Cross Entropy Loss、最適化手法は Adam とし、学習率は 0.0001 とした。さらに、10 エポックの間でバリデーション

ロスが改善しなかった場合に学習を打ち切る Early stopping を導入した。

モデルの評価として、学習、検証用データとして使用していない FUJIFILM 社の内視鏡で撮影された内視鏡動画 7 症例に対して臓器分類を行い、Accuracy を算出した。結果として、Accuracy は CNN 単体のモデルで 77.3%、LSTM を組み合わせたモデルで 82.0% であった。これより上部消化管内視鏡検査のようなクラスの出現順序が一定でない場合においても、時間情報を利用した臓器分類の有効性が示された。

次に、CNN と LSTM を組み合わせたモデルの出力に対して、順方向、逆方向、双方向の 3 種類の SW を適用し、モデルの予測結果と Accuracy を比較した。結果として、Accuracy は、SW なしで 82.0%、順方向 SW で 82.2%、逆方向 SW で 83.5%、双方向 SW で 82.8% であり、全ての SW において Accuracy が向上した。本実験において、提案した逆方向 SW の Accuracy が最も高くなった。ただし、今後より多くの症例で検証した場合、順方向と逆方向どちらの SW が有効かは症例により異なる可能性がある。双方向 SW では 1 つの一方方向 SW での Accuracy が低下した場合でも、結果の組み合わせにより補正が可能となる。したがって、2 つの一方方向 SW の平均的な結果が得られる双方向 SW は、分割安定性の向上において有効な可能性がある。

4. まとめ

本研究では、所見作成の効率化と記載漏れ防止に向け、内視鏡動画のみの解析による臓器の判別を行った。フレーム単位の臓器分類では、CNN と LSTM を組み合わせて時間情報を利用することで、CNN 単体のモデルに比べ、分類精度が向上した。さらに、フレーム単位での臓器分類結果に対して SW を用いて臓器の境界を探索することにより、Accuracy が向上した。以上のことより、LSTM と SW を導入することの有効性が示唆された。

利益相反の有無：なし。

文献

- [1] Michal Mackiewicz, Jeff Berens, Mark Fisher: Wireless Capsule Endoscopy Color Video Segmentation. IEEE Transactions on Medical Imaging 27(12): 1769-1781, 2008
- [2] Tim Boers, Joost van der Putten, Maarten Struyvenberg et al.: Improving Temporal Stability and Accuracy for Endoscopic Video Tissue Classification Using Recurrent Neural Networks. Sensors 20(15): 4133, 2020
- [3] Kaiming He, Xiangyu Zhang, Shaoqing Ren et al.: Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition: 770-778, 2016

GNN による血管名自動命名手法における臓器特徴の利用に関する検討

出口 智也^{*1}, 林 雄一郎^{*1}, 北坂 孝幸^{*2}, 小田 昌宏^{*3,1}, 三澤 一成^{*4}, 森 健策^{*1,5,6}

^{*1} 名古屋大学大学院情報学研究科

^{*2} 愛知工業大学情報科学部

^{*3} 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 消化器外科

^{*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 Use of Organ Features in Automated Anatomical Labeling of Abdominal Arteries Based on Graph Neural Networks

Tomoya DEGUCHI^{*1}, Yuichiro HAYASHI^{*1}, Takayuki KITASAKA^{*2},

Masahiro ODA^{*3,1}, Kazunari MISAWA^{*4}, Kensaku Mori^{*1,5,6}

^{*1} Graduate School of Informatics, Nagoya University

^{*2} Faculty of Information, Aichi Institute of Technology

^{*3} Information Strategy Office, Information and Communications, Nagoya University

^{*4} Department of Gastroenterological Surgery, Aichi Cancer Center Hospital

^{*5} Information Technology Center, Nagoya University

^{*6} Research Center for Medical Big Data, National Institute of Informatics

要旨: 本稿では、3次元腹部CT像から抽出した血管領域に対するグラフニューラルネットワーク(GNN)を用いた血管名自動対応付けにおいて、使用する特徴量に関する検討を行ったので報告する。腹部動脈は個人差が大きく複雑であるため、構造の把握は困難である。そこで、外科手術における医師の血管構造把握の負担を軽減するため、血管名自動対応付けが提案されている。これまで、血管構造を木構造と捉え、血管の位置や太さ・自動抽出臓器との位置関係を特徴量としてGNNで血管名を割り当てる血管名自動命名手法が提案されてきた。本稿では、臓器の自動抽出の失敗による自動命名への影響を低減するため、血管に関する特徴のみを用いた自動命名を試みた。実験の結果、全体の精度は89.7%で、臓器情報を用いた場合の92.4%よりも低下した。分岐が単純な部分では精度が上がったが、特に肝動脈で大きな精度の低下がみられ、複雑な構造をとる部分での臓器情報の重要性が確認できた。

キーワード: 血管, グラフニューラルネットワーク, 3次元CT像, 解剖学的名称認識, 血管構造解析

1. はじめに

近年広く行われている腹腔鏡下手術は、得られる視野が狭く高難度である。個人差が大きい血管構造を術中に正確に把握することは難しく、術前に3次元腹部CT像から血管構造を把握することが重要である。このための支援として、これまでに腹部動脈領域に対する血管名自動命名手法がいくつか提案されてきた。手法[1]では血管の分岐木構造をグラフとみなし、GNN(Graph Neural Network)による命名を、手法[2]では2種類の畳み込み範囲を持つGNNによる命名を行った。これらの手法では、入力特徴量の一部に自動抽出[3]された臓器を用いている。そのため、臓器抽出に失敗した場合、命名結果への影響が考えられる。そこで、本稿では臓器特徴を用いず、血管に関する特徴のみに基づいた自動命名を試みた。

2. 手法

本稿ではGNNに対し、2種類の血管特徴を入力とし、命名

結果を比較する。血管木構造は、血管の分岐から分岐までを1つの枝とみなし、1つの枝を1つのノードとみなす。ノードの特徴量は各血管枝に関する特徴とし、血管枝の接続関係と特徴量をGNNの入力として与える。

従来手法[1,2]で用いられた特徴量は、血管に関する特徴、自動抽出臓器[3]に関する特徴の2つに大別される。前者は血管枝の半径・長さ・位置・始点から終点のなす角で与えられる。後者は、肝臓・脾臓・右腎・左腎の4臓器、4臓器に胃・胆のう・膵臓の3臓器を加えた7臓器に関する特徴に分けられる。4臓器に関する特徴は、血管枝とその葉がその臓器領域に含まれるかが与えられる。7臓器に関する特徴には、臓器領域の重心と枝の中心のユークリッド距離と方向が与えられる。

本稿では、従来の特徴から自動抽出臓器に関する特徴を除き、血管に関する特徴、すなわち血管の半径・長さ・位置・なす角を特徴量とし、GNNへの入力として与える。GNNの学習にはノードの正解ラベルデータを用いる。

なし

3. 実験及び結果

自動命名の主要な対象は手法 [2] と同様の 22 種類の腹部動脈とする。GNN は複数の畳み込み範囲を持つ ChebNet [2] を用いる。特徴量は手法 [2] と同様の特徴量と、血管特徴のみの特徴量の 2 種類を試みる。実験は 3 次元腹部 CT 像 100 症例に対し 10 分割交差検定により行い、評価には F 値を用いた。

実験の結果、血管に関する特徴のみを用いた学習では 89.7%、手法 [2] は 92.4% の F 値となり、手法 [2] の特徴量が 2.7 ポイント上回った。各特徴量における血管ごとの F 値の比較を図 1 に示す。多くの血管で臓器に関する特徴量を含む手法 [2] の方が良好な結果となり、特に肝動脈でこの傾向が顕著であった。一方で、5 種類の血管では臓器特徴を除いた結果が手法 [2] を上回った。命名結果の例を図 2 に示す。

4. 考察

手法 [2] に比べ F 値が改善した血管が 5 種類みられたが、多くの血管で臓器特徴を用いた方が良好な結果であった。Ao, CA のように位置や周辺の構造に基づいて分類しやすい血管は血管特徴のみでも高精度に分類できた。しかし、構造が複雑な肝動脈では F 値が大きく低下した。以上から、特に複雑な部分に対しては臓器特徴が有効に作用していたと考えられる。

11 種類の血管について、手法 [2] に対する F 値の差が 3 ポイント以内となり、他の血管に比べて変化が小さかった。このことから、これらの 11 種類については主に血管特徴を分類に用いていたこと、他の F 値が大きく低下した血管の命名では臓器特徴が有用であったことがわかる。F 値が低下した血管の分類に有効な臓器特徴を特定することで、より軽量な特徴量による自動命名を実現できる可能性がある。

5. むすび

本稿では、自動抽出臓器を用いない血管名自動命名を試みた。その結果、命名精度は臓器を用いた手法には及ばず、複雑な血管構造に対する命名における臓器情報の重要性が示された。

一方で、臓器特徴の有無に関わらず F 値が大きく変化しない血管が多くみられたことから、より少ない臓器特徴に基づく軽量な特徴量を用いた自動命名の可能性が示唆された。

謝辞

日頃から熱心に御討論頂く名古屋大学森研究室の諸氏に感謝する。本研究の一部は科研費 17H00867, 21K19898, JST CREST JPMJCR20D5 による。

利益相反の有無

文献

- [1] 日比裕太, 林雄一郎, 北坂孝幸 他: Spectral-based Convolutional Graph Neural Networks を用いた腹部動脈領域の血管名自動命名に関する研究. 信学技報 120:176-181, 2019
- [2] 出口智也, 林雄一郎, 北坂孝幸 他: 複数の畳み込み範囲を持つグラフニューラルネットワークによる血管名自動命名手法の検討. 日本コンピュータ外科学会誌 第 30 回日本コンピュータ外科学会大会特集号 つくば国際会議場, Vol.23, No.4, pp.299-300, 21(12)-2
- [3] H.Roth, H.Oda, Y.Hayashi et al., Hierarchical 3D fully convolutional networks for multi-organ segmentation, arXiv:1704.06382, 2017

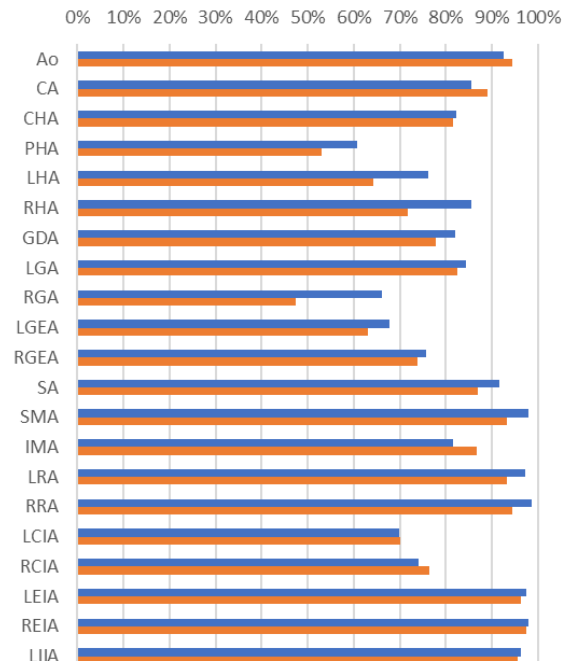


図 1 血管ごとの F 値(%). 青色は手法 [2] を、橙色は血管特徴なしの結果を示す。




図 2 自動命名結果の例. 同じ血管の色は同じ血管名を示す. 赤い丸は誤って分類した血管を示す. 手法 [2] における F 値は 94.7%, 血管特徴のみを用いた実験における F 値は 89.3% であった。

X線透視画像内のデバイスを対象とした深層学習セグメンテーションモデルのための効率的な学習データ作成手法についての検討

鈴木 皓士^{*1}, 菊池 洋平^{*1}, 吉原 陽平^{*1}, 松原 佳亮^{*2,3},
大村 知己^{*2}, 木下 俊文^{*2}, 松山 成男^{*1}

^{*1} 東北大学 工学研究科 量子エネルギー工学専攻

^{*2} 秋田県立循環器・脳脊髄センター 脳血管研究センター放射線医学研究部

^{*3} 秋田県立大学 システム科学技術学部

Research on Effective Training Data Creation of Deep Learning based Segmentation Model for Medical Devices in Fluoroscopic X-ray Image

Koshi SUZUKI^{*1}, Yohei KIKUCHI^{*1}, Yohei Yoshihara^{*1}, Keisuke MATSUBARA^{*2,3},
Tomomi OOMURA^{*2}, Toshibumi KINOSHITA^{*2}, Shigeo MATSUYAMA^{*1}

^{*1} *Department of Quantum Science and Energy Engineering, Graduate School of Engineering, Tohoku University*

^{*2} *Department of Radiology and Nuclear Medicine, Research Institute for Brain and Blood Vessels Akita Cerebrospinal and Cardiovascular Center*

^{*3} *Faculty of System science and Technology, Akita Prefectural University*

要旨：透視画像内のカテーテル等の線状デバイスの視認性を上げる技術は、IVR の手技の多くの作業性向上に貢献すると考えられる。本グループでは機械学習ベースのセグメンテーションにより分割した領域に合わせた視認性向上技術を検討しているが、学習には膨大な学習データが必要となる。本研究では CT 画像とデバイスの形状・構成材料の既知情報からの学習データ作成を提案する。心臓を対象とした臨床 CT 画像（3次元・デバイスなし、22例）において、カテーテル領域を仮想したボクセルの値を構成材料のものに置換し、これを投影処理することで疑似透視画像を作成した。また、カテーテル領域の形状は Bezie 曲線からランダムに決定し、この曲線の投影が教師データとなる。これらを元に準備したデータで学習した PAR-Net でカテーテルセグメンテーションを検証したところ、得られた Dice 係数は 0.910 となった。この学習済みモデルはカテーテル像を含むシネ心画像に対しても良好な性能を示した。

キーワード：Interventional Radiology, セグメンテーション

1. 緒言

Interventional Radiology (IVR)は、X線透視画像やCT画像を動画としてリアルタイムで確認しつつ、カテーテル等を用いて疾患を治療する手術である。低侵襲で低コストでありながら良好な治療成績が得られる IVR は、医療現場において需要が高まっている。本グループでは、IVR に使用されるカテーテルの視認性を向上するべく、機械学習ベースのセグメンテーションモデルによって分割した領域毎に画像処理を行うことを検討している。一方で、多様な手技が想定される IVR においてこの学習には膨大な学習データが必要となる。このため、本研究ではCT画像とデバイスの形状・構成材料に関する既知情報から学習データを作成する手法を提案する。

2. 疑似 IVR データの作成

モデルの学習に必要な学習データは、臨床で撮像された CT 画像を元に作成する。CT 画像のボクセル値 (CT 値) は内部を占める物質の組織・密度を反映しており、撮影時の X 線エ

ネルギーが決まれば当該物質の減弱係数 μ_t は(1)から求められる。

$$\mu_t = \frac{HU \times \mu_w}{1000} + \mu_w \quad (HU: CT 値) \quad (1)$$

μ_w は水の減弱係数であり、データベースから得た離散的な値を線形補完で求められる [1]。本研究では、(1)を用いて3次元CT画像のボクセルの値を減弱係数に変換したものに一方向から直進する X 線を照射すると仮定して投影画像を作成した。この手法により疑似像の画素値には、実際の解剖学的な形状に加えて、X線吸収に係る物性も反映することができる。

始めに、単純な投影処理のみで作成された疑似 IVR 画像と実際の臨床 IVR 画像とを比較して類似度を評価した。疑似画像の作成と比較用の臨床画像には秋田県立循環器センターで過去に撮影された心臓CT画像及び心臓カテーテル透視画像がそれぞれ用いられた。この結果、以下のような点についての相

違が見られた。

i) 疑似画像と臨床画像中での特定の部位(肋骨など)におけるプロファイル形状についての相違

ii) 画像間の画素値分布(ヒストグラム)の傾向における相違

上記 i) は、疑似画像中での皮質骨・海綿骨の間の画素値の差が臨床画像とは異なるなどの特徴に関するものと考えられる。また、ii) は、臨床画像のコントラストが必ずしも物理的な特徴(X線透過)に即していないことが原因であると推測される。これは、i) の要因である可能性もあり、臨床画像の撮像システムでの階調変換処理等によるものとする。

これらの相違を縮小するため、疑似画像作成に含める部位の取舍選択を試みたところ、軟組織・肺・肝臓・皮質骨を用いたことが最適であることが分かった。さらに類似度向上のために、疑似画像に対しても画素値の階調変換処理を加えた。

当該手法によるセグメンテーションモデルの学習のための疑似画像の作成にあたってはTCIA(The Cancer Imaging Archive)で提供されているCT画像のオープンデータを使用した。該当データは、140症例あるが、信頼性の観点から専門家によって作成された教師データがある22症例のみを使用した。これらの画像に対して、カテーテル領域(Bezie曲線からランダムに形状を決定)を仮想したボクセルの値を構成材料のものに置換し、これを投影処理することで疑似透視画像を作成した。カテーテルの材質に多様性を持たせ、モデルのロバスト性増強を図った。また、Bezie曲線の投影をカテーテルの教師データとした。

3.機械学習セグメンテーション

疑似画像から、拡大・回転処理や切り取り位置を変化させた画像群を作成し、モデルの学習用(Training Data)、学習中の検証用(Validation Data)、学習後のテスト用(Test Data)に分けた。学習モデルには、PAR-Net [2]を使用した。

図1より、Training Dataの結果から良好な学習が確認された。また、Validation Dataの結果から、汎用性のあるモデルを得ることができたと考える。また、図2に示す学習済みモデルによるセグメンテーション結果の主観評価において、カテーテルの形状・コントラストの程度によらず精度良くセグメンテーションされている。客観評価であるDice係数も良好で、疑似画像によるカテーテルセグメンテーションの学習は成功したといえる。さらに、目的とする実データへの適用に関して、学習済みモデルに計84症例の血管系IVR透視画像を入力したカテ

ーテルセグメンテーションにおいても一定の結果が得られた(図3)。

4.まとめ

本研究による検討から、提案手法を用いた学習データの拡張が適応できる可能性が示唆された。今後は本手法の臨床画像へのより詳細な評価を行う予定である。




図1 モデルの学習曲線

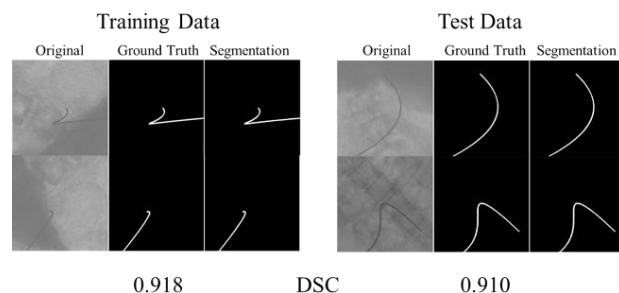


図2 疑似IVR画像のカテーテルセグメンテーション結果




図3 臨床IVR画像のカテーテルセグメンテーション結果

謝辞

本研究はJSPS科研費(19H04478)の助成を受けたものです。

利益相反の有無

なし

文献

- [1] K. He, X. Zhang, S. Ren et al: Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)
- [2] Y. J. Zhou, X. L. Xie, X. H. Zhou et al: Pyramid attention recurrent networks for real-time guidewire segmentation and tracking in intraoperative X-ray fluoroscopy. Computerized Medical Imaging and Graphics, vol83, 2020

気管支内視鏡生検向け処置具 3次元位置認識法における機械学習を用いた精度改善

松崎 和喜^{*1}, 山川 恵介^{*1}, 飯村 隆志^{*1}, 松元 祐司^{*2}, 田中 緑^{*2}

長島 千恵子^{*3}, 麻生 智彦^{*3}

^{*1} 富士フイルムヘルスケア (株), ^{*2} 国立がん研究センター中央病院内視鏡科

^{*3} 国立がん研究センター中央病院放射線技術部

Development of correction method using machine learning in x-ray image guided 3D device positioning for transbronchial biopsy

Kazuki MATSUZAKI^{*1}, Keisuke YAMAKAWA^{*1}, Takashi IIMURA^{*1}, Yuji MATSUMOTO^{*2}

Midori TANAKA^{*2}, Chieko NAGASHIMA^{*3}, Tomohiko ASO^{*3}

^{*1} FUJIFILM Healthcare Corporation, ^{*2} National Cancer Center Hospital Department of Endoscopy

^{*3} National Cancer Center Hospital Radiological Technology Division

要旨：末梢肺病変に対する気管支内視鏡生検手技において、X線装置は腫瘍細胞を採取する処置具の位置を確認する目的で利用されている。X線画像は2次元投影像のため、病変の前後方向の位置把握が困難な場合がある。これまで我々は、X線装置を用いた手技支援をめざし、処置具の位置を把握する3次元位置認識技術を開発してきた。開発手法の位置認識精度を医師が後ろ向きに収集した臨床例で評価したところ、肺解剖構造の領域毎に傾向がある認識誤差が見られた。これらは画像取得時の呼吸相の違いに起因する規則性のある体動が主要因と考えられた。そこで本研究では、臨床データを用い体動を予測する機械学習モデルを構築し、開発手法の認識位置の補正を試みた。その結果、補正前後の位置認識誤差は肺全体平均で27.1mmから14.6mmに改善し、特に体動が大きい肺下葉で補正効果が顕著に見られた。以上から本補正法により、手技支援法の実用性が向上できると考えられる。

キーワード：X線装置、気管支内視鏡生検、処置具3次元位置、体動補正、機械学習

1. はじめに

X線装置を用いた診断・治療の手技は、体内に挿入した処置具の位置や動きを2次元のX線投影画像上に表示しながら行われる。このような手技の一つに、肺がんの確定診断を目的とした気管支内視鏡生検がある[1]。内視鏡を被検者の口から挿入し、内視鏡画像を確認しながら気管、および分岐した気管支を経由して病変まで進むが、分岐数が多くなる末梢では、気管支が内視鏡径よりも細いため、挿入が不可となる。このような場合に、X線透視下で内視鏡先端からガイドシースと呼ばれる管状筒を誘導、病変部に留置し、ガイドシース内に鉗子や細胞診ブラシなどの処置具を挿入して生検を行う。X線画像は、処置具が画像上にリアルタイム表示される長所があるものの、2次元投影像のため、画像奥行方向の情報は失われ、画像上で処置具と病変が重なって見えたとしても、必ずしも処置具が病変部にあるとは限らない。気管支内視鏡生検においても同様で、挿入した処置具と疾患部位との奥行方向の位置関係が不明瞭で、生検が困難な場合がある。このような課題に対し、本研究ではX線画像と診断用に事前撮像した3次元のCT画像を用いる3次元位置認識法を提案、開発（以下、開発法）した[2]。開発法の位置認識精度を医師が後ろ向きに収集した臨床例で評価したところ、開発法で用いる画像取得時の主に呼吸の違いに起因した規則性のある体動と考えられる認識誤差が見られた。そこで本研究では、臨床データを用い体動を予測する機械

学習モデルを構築し、開発法の認識位置の補正を試みた結果を報告する。

2. 方法

処置具の3次元位置認識法は、事前に撮影したCT画像と、生検手技中に取得した複数方向のX線画像に対し、まずCT撮影時の被検者位置と手技中の被検者位置を一致させるために画像位置合せし、次に複数方向X線画像から処置具の先端を把握、その3次元位置を計算して、最後にCT画像上に処置具3次元位置を表示する。これらを後ろ向きに収集した臨床151例に適用し、開発法による処置具の3次元位置を得た。一方、実際に生検を実施した医師が、手技中の画像、および処置具から得られる情報等から、処置具が存在したと考えられる位置をCT画像上で指定し、処置具3次元位置の正解とした。まず開発法による処置具3次元位置と、医師による正解位置とを、臨床例にて比較した。次に表1に示す説明変数を用い、開発法による3次元位置と、正解位置の位置認識誤差を予測する機械学習モデルを構築した。本研究では学習アルゴリズムとして、決定木、線形回帰、ランダムフォレスト、およびAdaBoostを用いた。臨床151例のうち左右上下の各肺葉4領域から2例（計8例）、右中葉1例の計9例を評価用データセットとし、残りを学習データとして評価した。さらにデータセットの症例を変更、同様の学習、評価を10回繰返し、計90例にて評価した。

表 1 位置認識誤差を予測する機械学習の説明変数

変数名	概要
開発法認識位置	CT 画像の中心を原点とする 3 次元位置
病変がある肺葉の分類	右上中下, 左上下の 5 分類
体表マーカ移動量	術中被検者体表に貼付したマーカ位置の前後方向移動量
肺領域の体積	CT 画像から取得
肺領域の Elongation	CT 画像から取得
肺領域の画素値平均	CT 画像から取得
肺領域の画素値ばらつき	CT 画像から取得

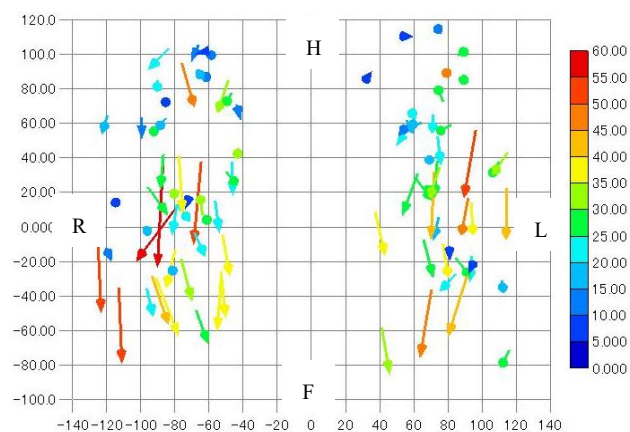
アルゴリズムの予測精度比較には、開発法の認識位置を始点、正解位置または予測位置を終点とする 2 つのベクトルにて、差ベクトルの大きさ、およびなす角を用いた。

3. 結果

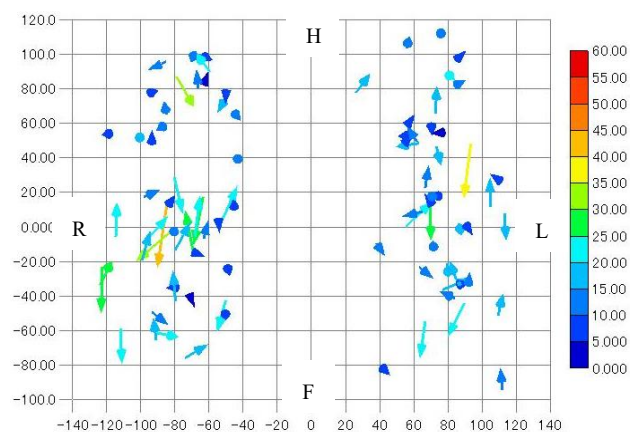
3 次元位置認識法による処置具位置を始点、処置を実施した医師による正解位置を終点とするベクトルについて、評価に用いた 90 症例のベクトルの大きさ（平均値）を表 2 に、またベクトルを Coronal 面に投影した像を図 1(a)に示す。ベクトル向きはほとんどが被検体の頭から足方向であり、また大きさも頭から足に従って大きくなる傾向が見られた。これは被検者が手技中（処置具位置認識時）は自然呼吸下であるのに対し、医師が正解位置を指定した CT 画像は吸気時に撮影されていることから、差の主要因は、被検者で共通する呼吸状態と考えられた。この差を機械学習し、予測するモデルを複数構築、評価した結果を表 2 に、また予測した体動により補正した位置を始点、正解位置を終点とするベクトルを Coronal 面に投影した像を図 1(b)に示す。補正がない場合の差ベクトルの大きさは、平均で 27.1mm、最大 60.9mm に対し、AdaBoost により補正した場合、平均 14.3mm、最大 29.4mm だった。また補正前後のベクトルのなす角は、平均で 23.9°、最大 49.0°であり、予測が逆方向（なす角が 90°以上）となる症例はなかった。また補正効果は、肺上部から肺下部に従って高い傾向が見られた。

表 2 学習別の位置認識誤差予測結果（90 症例平均）

アルゴリズム	差ベクトルの大きさ	なす角
(補正なし)	27.1mm	—
Decision tree	20.3mm	37.6°
Linear	14.3mm	23.1°
Random forest	15.5mm	25.4°
AdaBoost	14.6mm	23.9°



(a) 補正前の差ベクトル



(b) 補正後の差ベクトル（機械学習：AdaBoost）

図 1 機械学習による体動補正効果（評価用 90 例）

4. まとめ

気管支内視鏡生検を支援する処置具 3 次元位置認識において、課題となった呼吸が主要因と考えられる体動に対し、肺解剖構造や術中のマーカ位置情報を用いた機械学習により、3 次元認識位置を正解位置付近へ補正することが可能であった。これにより手技支援法の実用性が向上できると考えられる。

利益相反の有無

本研究の発表者である松崎和喜、山川恵介、飯村隆志は、富士フィルムヘルスケア（株）に属する社員である。

倫理審査の状況

本研究計画は、国立がん研究センター中央病院倫理委員会、および富士フィルム倫理審査委員会承認済みである。

文献

- [1] 荒井保明, 他: 一国立がん研究センター中央病院— 医師・技師・診療放射線技師のための呼吸器内視鏡実践マニュアル. 医療科学社, 東京, 2015

画質改善処理による乳がん腫瘤影の良悪性鑑別 CAD の性能向上

工藤 颯馬^{*1} 安倍 和弥^{*2} 武尾 英哉^{*2} 永井 優一^{*3} 縄野 繁^{*4}

^{*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} 神奈川工科大学 工学部電気電子情報工学科

^{*3} 国立がん研究センター東病院

^{*4} 新松戸中央総合病院

Performance Improvement of CAD for Classification Benign and Malignant Shadows of Breast Cancer Masses by Image Quality Improvement Processing

Soma KUDO^{*1}, Kazuya ABE^{*2}, Hideya TAKEO^{*2}, Yuuichi NAGAI^{*3}, Shigeru NAWANO^{*4}

^{*1} Graduate School of Electronic & Electrical Engineering, Kanagawa Institute of Technology

^{*2} Kanagawa Institute of Technology

^{*3} National Cancer Center Hospital East

^{*4} Shinmatsudo Central General Hospital

要旨: マンモグラフィ(MMG)撮影は検診 MMG と診断 MMG の 2 種類に分かれている。一般的に、検診 MMG は存在診断、診断 MMG は鑑別診断の位置づけで撮影される。しかし、もし検診段階で良悪性鑑別ができれば、より早期の発見に繋がると考えられる。しかし、検診 MMG は診断 MMG と比べて、検診車などで行われることから比較的簡易な撮影装置が使われるため、マンモグラムの画質は若干劣る。そのため、検診 MMG の画像での良悪性鑑別 CAD の性能は診断 MMG の画像の場合と比べて精度が落ちる。そこで本研究では、両者の画質差を補うことを目的として、画像の粒状性とコントラストを同時に改善する画質改善処理を開発し、検診 MMG 画像での良悪性鑑別 CAD の性能向上を図った。その結果、そのままの検診 MMG 画像を使った鑑別精度 85%に対して、画質改善処理を施した場合は鑑別精度が 89%に向上した。診断 MMG 画像の鑑別精度が約 90%であったことから、同等の性能を得ることができた。良悪性鑑別 CAD は CNN を用いており、学習した AI が画像中のどこに着目して判断しているのかも分析したので報告する。

キーワード: 乳がん腫瘤影, CAD, 画質改善処理, 良悪性鑑別, 検診

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].

乳がん検査に必要なマンモグラフィ (mammography : MMG) は検診と診断の 2 つに分かれており、検診 MMG は存在診断、診断 MMG は鑑別診断の位置づけで撮影される。

乳がん良悪性鑑別の領域で CAD 研究の成果は、例えば井上の手法[2]などの CAD システム開発が過去に行われている。

しかし、これらの研究で用いている画像は診断用 MMG 画像のものであり、検診用 MMG 画像で乳がんの良悪性鑑別を行う試みはほとんど無い。

しかし、もし検診段階で良悪性鑑別ができれば、より早期の発見に繋がると考えられる。

乳房腫瘤の良悪性鑑別において最も大きな基準は腫瘤陰影辺縁の不整像の有無である。腫瘤の辺縁が不整のものはがんであり、不整でないものは良性よりである。

また、乳腺が白く映るため、腫瘤と乳腺の重なりが困難であり、腫瘤辺縁形状の読影が難しいという問題がある。

画質改善処理によって良悪性鑑別処理を行う画像を作成するには、検診用 MMG 画像に対し、

1. 輪郭をより強調する処理
2. 腫瘤の濃淡やコントラストの差をはっきりさせる処理
3. 石灰化の存在をわかりやすくする処理

^{*1} 神奈川工科大学 大学院 工学研究科 電気電子工学専攻

[〒243-0292 厚木市下荻野 1030]

e-mail: abex0930@ele.kanagawa-it.ac.jp

^{*2} 神奈川工科大学 工学部電気電子情報工学科

^{*3} 国立がん研究センター東病院

^{*4} 新松戸中央総合病院

を行う必要がある。

そこで本研究では、両者の画質差を補うことを目的として、画像の粒状性とコントラストを同時に改善する画質改善処理を開発し、検診 MMG 画像での良悪性鑑別 CAD を実現した。

X 線撮影領域の画質改善処理の成果としては、川村らの手法[3]などが存在する。

過学習をはじめとして AI の画像認識の判断基準には AI 独自の問題が存在し、人にとってより良い画質改善処理が CAD に最適な画質改善処理とは限らない。

よって、今回の研究では、従来の精細化を目的とした画質改善処理ではなく、画像の構造を抽象化するというアプローチで画質改善処理を開発し、その実用性を実際に画質改善処理した検診用 MMG 画像をデータベースとして CAD 開発を行い検証した。


2. 手法

今回開発した画質改善処理は、腫瘍辺縁の輪郭と石灰化の存在を強調させるための粒状性改善処理としてモルフォロジー処理を採用し、腫瘍の濃淡やコントラストの差をはっきりさせるためのコントラスト改善処理として強調処理を採用した。

この 2 つの処理を同一の画像に対して連続して行うことで、検診用 MMG 画像の粒状性とコントラストの同時改善と画像構造の抽象化による良悪性 CAD の性能向上を図る。

3. 実験結果

図 1 に画像処理における腫瘍部分の変化の例を示す。



原画像 画質改善処理後
図 1 画質改善処理における腫瘍部分の変化

モルフォロジー処理と強調処理の併用により、画像の特徴が抽象的に強調されている。

画質改善処理された検診用 MMG 画像をデータベースとして使用した乳房腫瘍良悪性鑑別処理開発の結果を表 1 に示す。

表 1 画質改善処理された検診用 MMG 画像をデータベースとして使用した乳房腫瘍良悪性鑑別処理の結果

	精度 (%)		
	検診用 MMG 画像	画質改善した検診用 MMG 画像	診断用 MMG 画像
CNN(中間 6 層)	73	<u>89</u>	80
Vgg16	80	85	<u>90</u>
Alexnet	<u>85</u>	82	83

最も高い精度の結果が画質改善処理前と比べて 4%向上した。この性能向上は、診断用 MMG 画像を対象とした良悪性鑑別処理の精度 90%に迫る高い性能に達した。

4. まとめ

AI による乳がん腫瘍影の良悪性鑑別処理の開発に使用する検診用 MMG 画像の画質改善処理の提案と検討を行った。結果から、画質改善処理による乳がん腫瘍影の良悪性鑑別 CAD の性能向上を達成した。

画質改善処理によって、最高精度が得られた AI のネットワーク構成が転移学習から CNN に変わったということは、一般的な画像ではないマンモグラフィの画像のみのデータベースを学習に利用した方が高精度ということであるので、より学習結果の信頼性も向上したものと考えている。

また、今回開発した画質改善処理は CAD のためのものであり、画像の抽象化により鑑別結果の根拠を医師に示すことが可能であるが、細かい画像構造が省略されるという問題点もあるため、医師が読影する画像にはまた別の画質改善処理が必要である。

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),pp427-431，2011
- [2] 井上謙一：畳み込みニューラルネットワークを用いたマンモグラフィの自動読影システムの構築：第 6 回「医療情報学会・人工知能学会 AIM 合同研究会」,2018
- [3] 川村隆浩，内藤慧，岡野佳代，他：新画質改善処理「手法 A(パーチャルグリッド)技術」の開発：X 線検査の画質と作業性の向上：富士フィルム R&D 統括本部技術戦略部：富士フィルム研究報告 (60)：2015,pp21-27

深層学習を用いた肘関節超音波画像における離断性骨軟骨炎診断支援

佐々木 研太^{*1}, 藤田 大輔^{*1}, 高辻 謙太^{*2}, 琴浦 義浩^{*2}, 南 昌孝^{*2},
小林 雄輔^{*2}, 祐成 毅^{*2}, 木田 圭重^{*2}, 高橋 謙治^{*2}, 小橋 昌司^{*1}

^{*1} 兵庫県立大学大学院工学研究科

^{*2} 京都府立医科大学大学院医学研究科

Computer-aided diagnosis of osteochondritis dissecans in ultrasound images of elbow using deep learning

Kenta SASAKI^{*1}, Daisuke FUJITA^{*1}, Kenta TAKATSUJI^{*2}, Yoshihiro KOTOURA^{*2}, Masataka MINAMI^{*2},
Yusuke KOBAYASHI^{*2}, Tsuyoshi SUKENARI^{*2}, Yoshikazu KIDA^{*2}, Kenji TAKAHASHI^{*2}, Syoji KOBASHI^{*1}

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

^{*2} Graduate School of Medical Science, Kyoto Prefectural University of Medicine

要旨：野球肘は投球動作を繰り返すことで引き起こされる肘の障害である。そのうち上腕骨小頭離断性骨軟骨炎(osteochondritis dissecans: OCD)は難治性の骨軟骨損傷であり、初期での早期検出が重要である。本研究では、深層学習による肘超音波画像からのOCD検出法を提案する。提案法をOCD被験者88人、異常なし被験者50人に適用した。対象とした超音波画像は、肘の外側・後方・短軸の撮影方向を用いた。5分割交差検証の結果、検出結果の平均値が正解率82.0%、適合率96.1%、再現率75.2%、F1値0.840、AUC0.944であった。

キーワード：野球肘，離断性骨軟骨炎，深層学習

1. はじめに

野球における投球動作を繰り返すことで引き起こされる肘の障害である野球肘は小中高生の成長期に発症することが多い。この野球肘は離断性骨軟骨炎(osteochondritis dissecans: OCD)、裂離骨折などの様々な投球肘障害の総称である[1]。これらの中でも上腕骨小頭のOCDは初期段階では痛みなどの症状がないことが多く、痛みや肘の可動域制限が出現したときにはすでに進行しており、問診や理学所見などで早期に検出することは難しい[2]。中学・高校生の野球選手において、上腕骨小頭OCDの有病率は1.6-3.4%であると報告されている[3]。

上腕骨小頭OCDの治療法の一つが保存療法である。初期段階では1年ほど安静にすれば、骨が修復し再び野球ができるようになる。しかし、進行すると保存療法では完治せず手術が必要になる場合がある。初期段階では9割の人が完治するが、進行した場合には5割ほどしか修復しなかったと報告されている[4]。従って、上腕骨小頭OCDは初期での検出が重要である。

上腕骨小頭OCDを早期検出するために、一部の病院は年に数回、野球肘検診を行っている。しかし、野球肘検診の実施回数は十分でなく、診断を行える専門医も少ないという問題がある。また痛みを伴いながらも競技が続けられる間は病院を受診しない人が多く、重症化してから初めて外来に訪れる場合がある[3]。超音波検査はOCDの初期像を見つけ出す鋭敏な検査法であり、超音波画像から野球肘の有無を診断するのは有効であることが示されている[5]。従って、簡便かつ誰もが用いられる超音波検査に基づくOCDコンピュータ診断支援システム(CAD)が切望されている。

医療分野において、深層学習が医用画像CADに多く適用されている。一例として、尺骨神経の超音波画像を用い、深層学習に基づいた肘部管症候群診断モデルを構築し、精度がAUCで0.900以上と高い精度を実現している[6]。しかし、超音波画像からのOCD検出に深層学習の適用は未だなされていない。

本研究では、肘OCDのコンピュータ診断支援のために、超音波画像からOCDの有無を判定する深層学習を用いたシステムを提案する。

2. 対象被験者と対象画像

本研究では、野球肘検診を受診した野球児童138人(年齢6~14才)を対象にした。超音波装置により、各被験者の外側・後方・短軸の撮影方向での肘超音波画像を撮影した。超音波画像のサイズは縦横共に400~500画素であった。OCDの有無のアノテーションは野球肘診断に熟練した整形外科医3名が行った。本研究は京都府立医科大学、兵庫県立大学工学研究科それぞれの倫理委員会の承認を得て行った。

3. 提案手法

提案法は、まず超音波画像より上腕骨小頭の骨輪郭を抽出し、それを内包するバウンディングボックスを求める。次に、バウンディングボックスに対して、学習済みモデルを用いてOCDクラスと、Normalクラスの二つに分類することで、OCDを検出する。

OCD検出の2クラス分類は、CNNの構造の一つであるVGG16を用いる。VGG16のfc8を2出力の全結合層に置き換




図1 本研究でのネットワーク構造

える。また最終層の出力層は2つのニューロンで活性化関数はsoftmaxとし、出力値がそれぞれOCDクラス、Normalクラスの確率を示す。図1に用いるネットワーク構造を示す

OCD検出モデルの学習はファインチューニングにより、第1~10層までのネットワークの重みを固定し、本研究の学習データを用いて第11畳み込み層から最終層までを再学習する。学習データはone hot vectorを用いて、出力値をOCDクラスのときは{1,0}を、Normal(正常)クラスのときは{0,1}とする。

4. 実験結果

提案するOCD検出法を外側・後方・短軸の撮影方向画像に適用した。実験では、OCD被験者数を88人、正常被験者数が50人で、被験者1人あたり1枚の画像を用いた。5分割交差検証を適用し、学習条件はエポック数を50、損失関数をbinary_crossentropy、最適化関数をSGD、学習率を0.001とした。また学習用データは明るさ変更、水平移動、垂直移動、拡大・縮小をしてデータの拡張を行った。

提案法によるOCD検出性能を、正解率、適合率、再現率、F1-score、AUC(area under the curve)を用いて評価した。5分割交差検証による評価指標の平均値を表1に示す。表1に示す通り、AUC0.944と高い検出性能が得られたが、学習と評価データの組み合わせの違いにより結果が変動し、正解率では最低78.6%、最高92.6%となった。またOCDをPositiveとした再現率は平均値で75.2%と低い値となった。

5. 考察

学習と評価データの組み合わせの違いによる検出性能が変動した原因の一つは、評価データとなった画像でOCDクラスの画像の骨の状態とNormalクラスの画像の骨の状態との差が少ないために分類が上手くできなかったと考えられる。また再現率が低い結果となったこともこれが原因でNormalクラスに誤分類されたためと考えられる。

また、抽出した上腕骨小頭骨輪郭を内包するバウンディングボックスは正方形ではないものが多く、VGG16への入力の際

表1 OCD検出モデルの性能評価

評価指標	平均値(最小-最大)
正解率	82.0% (78.6%-92.6%)
適合率	96.1% (87.5%-100%)
再現率	75.2% (66.7%-88.2%)
F1-Score	0.840 (0.800-0.938)
AUC	0.944 (0.900-1.0)

に画像サイズを正方形(224x224画素)に変形・拡大縮小したことが精度に影響したと考えている。これを解決するため、今後入力画像の整形方法について検討する。

5. まとめ

本研究ではOCD検出法を提案し、外側・後方・短軸の撮影方向画像に適用した。検出精度は正解率で82.0%、適合率で96.1%、再現率で75.2%、F1-scoreで0.840、AUCで0.944となった。今後の課題として検出精度向上のため学習条件の検討、画像整形方法の検討が必要である。また他の撮影方向画像に対しての検出法も検討する。

利益相反の有無

なし

文献

- [1] 小関祐介, 吉田行宏, 矢野忠ら, "成長期野球選手の肘傷害に関する文献的考察—野球肘に対するスポーツ鍼灸の可能性と役割—", 明治国際医療大学誌, Vol. 10, 2014, pp.1-14
- [2] 堀内俊樹, 西田裕介, 坂本祐太, "野球肘検診の調査結果と今後の展望", 理学療法科学, Vol. 33, No. 6, 2018, pp.969-973
- [3] Y. Kida, T. Morihara, Y. Kotoura, et al, "Prevalence and Clinical Characteristics of Osteochondritis Dissecans of the Humeral Capitellum Among Adolescent Baseball Players", The American Journal of Sports Medicine, Vol. 42, No. 8, 2014, pp.1963-1971
- [4] T. Matsuura, S. Kashiwaguchi, T. Iwase, et al, "Conservative Treatment for Osteochondrosis of the Humeral Capitellum", The American Journal of Sports Medicine, Vol. 36, No. 5, 2008, pp.868-872
- [5] 宇野智洋, 原田幹生, 丸山真博ら, "小学・中学野球選手に対する野球肘検診における超音波検査の有用性", 日本肘関節学会雑誌, Vol. 22, No. 2, 2015, pp.80-82
- [6] I. Shinohara, A. Inui, Y. Mifune, et al, "Diagnosis of Cubital Tunnel Syndrome Using Deep Learning on Ultrasonographic Images", Diagnostics, Vol. 12, No. 632, 2022, pp.1-14

骨シンチグラムの陽性高集積検出システムにおける市販後学習

藤本 啓輔*1, 大崎 洋充*2, 東山 滋明*3, 河邊 譲治*3, 中岡 竜介*4, 清水 昭伸*1

*1 東京農工大学大学院工学研究院

*2 群馬県立県民健康科学大学大学院診療放射線学研究科

*3 大阪公立大学医学部附属病院核医学科

*4 国立医薬品食品衛生研究所医療機器部

Post-market training of a hot-spot detection system of malignant tumor in a bone scintigram

Keisuke FUJIMOTO*1, Hiromitsu DAISAKI*2, Shigeaki HIGASHIYAMA*3, Joji KAWABE*3

Ryusuke NAKAOKA*4, Akinobu SHIMIZU*1

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

*2 Gunma Prefectural College of Health Sciences

*3 Osaka Metropolitan University Hospital

*4 National Institute of Health Sciences

要旨：本報告では、骨シンチグラムを用いた陽性高集積検出システムのための市販後学習の改良法の提案について報告する、特に市販後学習のためのデータが少数の場合に注目する。データが少ない場合、すべての層の重みを対象に再学習を行うと、過学習によって性能が低下する可能性が高くなる。そこで、再学習を行うか否かを適応的に選択する方法について検討をする。具体的には、Policy network を用いて再学習をする層を選択する。本稿では、市販後学習のためのデータの数を変化させて提案法の有効性を評価する。また、再学習の対象になった層の可視化結果などを用いながら提案法の有効性について議論する。

キーワード：骨シンチグラム、高集積検出、再学習、domain shift, Policy network

1. はじめに

骨シンチグラム上の骨転移による高集積の診断は容易ではなく[1]、コンピュータによる検出支援が求められる。これまで著者らは、骨格認識と陽性高集積検出の2つの処理[2][3]からなるシステムを開発した。しかし、開発時(source domain)と市販後(target domain)のデータの特徴の分布が異なるなどのdomain shiftが生じた場合、実運用時に期待される性能が得られないことがある。そのため、市販後のtarget domainのデータを用いて再学習を行うが、市販後の施設で多数のデータを集めることは容易ではなく、データ数が少ない場合には性能が十分に向上しないことがある。原因の一つに、モデルの多数の重みを少数のデータのみを用いて学習させることによる過学習の可能性が挙げられる。

本研究では、これまでのDomain Adaptationの研究の中から文献[4]の手法に注目する。この手法では、再学習の対象となる層を自動的に選択することで重みの内の一部のみを対象とした学習が可能となる。実際の画像データを用いて再学習データ数を変化させながら陽性高集積の検出性能を評価する。また、再学習の対象となった層を可視化しながら考察する。

2. Policy Network を用いた陽性高集積検出システムの再学習

従来の高集積検出システムのResBtrflyNet [3]にPolicy Network [4]を組み合わせる(図1)。まず、市販前のsource domainのデータで事前学習したネットワークの重みをコピーして各層を二重にする。一方は重みを固定し(freeze layer), 他方は市

販後のtarget domainのデータを用いて再学習を行う(fine-tune layer)。Policy Networkは、入力画像ごとに、freeze layerかfine-tune layerかの選択をGumbel-Softmaxを通じて行う。用いた損失関数はClass Weighted Softmax Cross Entropy(式(1))である。

$$p_{ni} = \text{softmax}(y_{ni}) = \frac{e^{y_{ni}}}{\sum_{k=1}^C e^{y_{nk}}}$$

$$w_i = \frac{N - \sum_{n=1}^N t_{ni}}{N}$$

$$L_{WSCE} = -\frac{1}{N} \sum_{n=1}^N \sum_{i=1}^C w_i t_{ni} \log(p_{ni})$$

ここで、Nは全画素数、nは画素のインデックス、t_{ni}は正解ラベル、p_{ni}は出力y_{ni}の確率である。

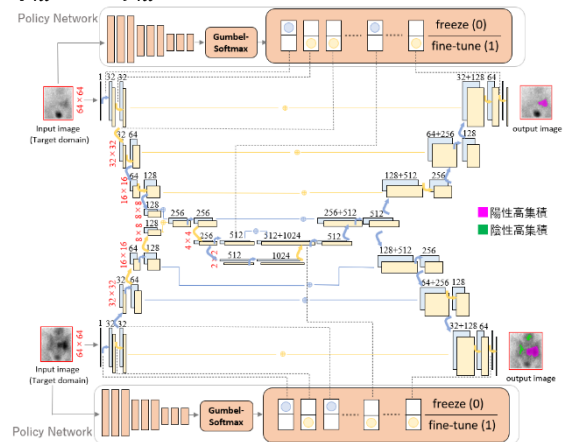


図1 ネットワーク構造

また、図1におけるネットワークのレベルを l , Gumbel-Softmax を経て出力される freeze layer を選択する確率を $I_l(x)$, freeze layer を F_l , fine-tune layer を \tilde{F}_l とすると、ネットワークの出力は式(2)で表される。

$$x_l = I_l(x)F_l(x_{l-1}) + (1 - I_l(x))\tilde{F}_l(x_{l-1}) \quad (2)$$

学習時には、このバイナリ指標 $I_l(x)$ を通じて損失の勾配が伝搬する。なお、前後面の Policy Network の出力が共に存在する場合には2つを平均したものを $I_l(x)$ として用いる。Policy Network の中身には、ResNet[5]を用いた。

3. 実験条件と実験結果

3.1 実験条件

実験試料には6施設から撮影された1,032症例の前後面の骨シンチグラム(512*1024[pixel], 2.8[mm/pixel])と正解の高集積ラベルを使用した(東京農工大学倫理委員会承認番号No.200904-0238)。5施設のデータを市販前の source domain のデータ、1施設のデータを市販後の target domain のデータとした。また、target domain のデータは2/3を再学習用、1/6をバリデーション用、1/6をテスト用に分けた。ここで、2/3の再学習データから $a/10$ ($a=1,5,9$)の割合のデータを10回ランダムに選択し、それぞれで再学習を行った。再学習時のミニバッチサイズは64, Optimizer には Adam($\alpha=0.001$)を使用し、Policy Network に用いる Gumbel-Softmax の温度パラメータは0.5とした。テストには、バリデーションデータで最も FP+FN[pixel] が少ないネットワークを使用した。なお、システムの出力は陽性高集積、陰性高集積、およびその他の3クラスであるが、FP と FN は、陽性高集積かそれ以外かの2クラスとして計算した。

3.2 実験結果

テストデータに対する FP+FN[pixel]を図2に示す。

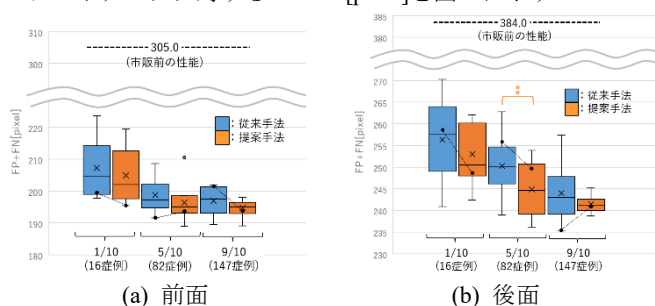


図2 再学習による性能 (FP+FN[pixel])

(** : 有意水準 0.01. Wilcoxon の符号付順位和検定 (H_0 : FP+FN[pixel]の中央値に差がない))

図2には、再学習データ 1/10, 5/10, 9/10 それぞれの性能と合わせて、市販前の性能も示している。図2の平均値(×)や中央値は Policy Network を用いることで減少することが分かる。検定の結果からは、後面で再学習データが 5/10 の場合についてのみ有意水準 1%で帰無仮説が棄却された。また、どの再学習データに対しても市販前のモデルより性能は向上した。なお、全再学習データ(164 症例)を用いて再学習を行った場合、

FP+FN は前面では従来手法で 196.1[pixel], 提案手法で 202.3[pixel], 後面では従来手法で 248.8[pixel], 提案手法で 244.8[pixel]となり、全再学習データが最も性能が改善する訳ではなく、再学習による性能の改善は、再学習データ数よりもデータの特徴に依存することが考えられる。

図3は、再学習データ 10 回の選択中のある回のテストデータに対する推論時の fine-tune layer の選択頻度を可視化したものである。その時の FP+FN[pixel]を図2に●印で示した。




図3 fine-tune layer が選択された頻度

図2, 図3より、入力に近い層で freeze layer が選択された場合に精度(FP+FN)が向上することが分かった。入力に近い Encoder 部の層は出力への影響が大きく、過学習の原因となりやすいが、提案法によってその層の重みを freeze することで、市販前のモデルの特徴が再学習後のモデルにも引き継がれ、性能向上に結びついたと考えられる。一方、Decoder 部は fine-tune layer が選択される傾向にあり、それによって domain shift へ対応できたと予想される。これらの点の検証は今後の課題である。

3. まとめ

本稿では、骨シンチグラムを用いた陽性高集積検出システムのための市販後学習の改良法について実験を行った。実験結果より、freeze layer の適応的な選択が性能の向上に影響を与えていることがうかがえた。今後は、Policy Network の改良をし、更なる認識精度の向上を目指す。

謝辞

日頃から熱心にご指導・ご討論いただいた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

文献

- [1] 小野慈 : 骨シンチによる骨転移診断. 南江堂, 東京, 2002, pp1-30.
- [2] H. Wakabayashi, A. Saito, S. Higashiyama et al: Detection of bone metastasis in a scintigram using U-Net, 2018 Proc. of Computer Assisted Radiology and Surgery(CARS), Berlin, Germany, S260 June 2018.
- [3] A. Shimizu, H. Wakabayashi, T. Kanamori et al: Automated measurement of bone scan index from a whole-body bone scintigram, International Journal of Computer Assisted Radiology and Surgery 15, 389-400, 2020
- [4] I. Zakazov, B. Shirokikh et al: Anatomy of Domain Shift Impact on U-Net Layers in MRI Segmentation, MICCAI 2021, Strasbourg, France, 2021
- [5] He, K., Zang, X., Ren, S., et al: Deep Residual Learning for Image Recognition. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, pp.770, 2016

3D-Alpha-WGAN の正常症例学習モデルを用いた FDG-PET 画像における異常集積の自動検出

内田 卓妙^{*1}, 原 武史^{*2}, 周 向荣^{*2}, 片渕 哲朗^{*3}, 野崎 太希^{*4}, 松迫 正樹^{*4}, 藤田 広志^{*2}

^{*1} 岐阜大学大学院自然科学技術研究科

[〒501-1193 岐阜市柳戸 1-1 e-mail:tuchida@fjt.info.gifu-u.ac.jp]

^{*2} 岐阜大学工学部

^{*3} 岐阜医療科学大学保健科学部

^{*4} 聖路加国際病院放射線科

Malignant tumor detection method in FDG-PET images by normal case training model of 3D-Alpha-WGAN

Takumi UCHIDA^{*1}, Takeshi HARA^{*2}, Xiangrong ZHOU^{*2}, Tetsuro KATAFUCHI^{*3},
Taiki NOZAKI^{*4}, Masaki MATSUSAKO^{*4}, Hiroshi FUJITA^{*2}

^{*1} Graduate School of Natural Science and Technology, Gifu University

^{*2} Faculty of Engineering, Gifu University

^{*3} Gifu University of Medical Science

^{*4} St. Luke's International Hospital

要旨：医用画像における網羅的な異常データの収集コストの高さは問題である。本研究では、医師の負担軽減や見落としを防ぐために、体幹部 FDG-PET 画像における悪性腫瘍の自動検出手法の開発を目的とする。ここでは、データ収集コストの低い正常症例を利用して、教師なし異常検知のアプローチで腫瘍の検出を行う。正常症例の 3 次元 FDG-PET 画像 66 症例を、3 次元画像生成モデルである 3D-Alpha-WGAN に入力して、正常画像生成モデルを得る。このモデルに異常症例を入力し、正常例様に補正された再構成画像を出力する。入出力間の差が大きい領域は、正常症例にない特徴を持つため、その領域を腫瘍候補とする。各候補に対して、体積や周辺画素との差を基に偽陽性の可能性が高い候補を削除し、残った候補を最終出力とする。異常症例 58 症例における検出率は 89.9%、1 症例あたりの平均偽陽性数は 37.9 個となり、正常症例を学習させた 3D-Alpha-WGAN モデルは腫瘍検出に有用である可能性が示唆された。

キーワード：FDG-PET, 教師なし異常検知, GAN, コンピュータ支援診断

1. はじめに

近年、がんの罹患患者数は増加傾向にあり、早期発見と早期治療が重要とされている。PET 検査は、がん腫瘍の位置や大きさの把握、転移状況の調査といった用途で用いられる。

PET 画像は約 300 枚のスライス画像からなる上に、罹患患者数の増加に伴い撮像件数が増えているため、すべての画像を精査することは医師にとって負担が大きい。そこで、計算機による診断の補助を行うコンピュータ支援診断(CAD)システムの開発が期待されている。近年では、深層学習を用いた病変検出に関する研究は数多く報告されている。そのうち、教師あり学習を用いている手法は、幅広い症例を含む大量の学習データとそれに対応した教師ラベルの作成が必要である。網羅的な異常データの収集コストと、3次元データに対する教師ラベルの作成コストの高さは問題として挙げられる。

そこで、本研究では 3 次元の FDG-PET 画像を対象に、教師なし異常検知のアプローチで体幹部全体における異常集積の自動検出を目的とする。正常症例を学習させた画像生成モデル

を用いて、異常集積を含む画像を入力した際の再構成誤差を基にした検出手法を提案する。

2. 方法

2.1 画像生成モデルによる画像生成

画像生成モデルには VAE と GAN を組み合わせ、損失関数に WGAN-GP を適用して 3 次元に拡張した 3D-Alpha-WGAN[1] をベースに、パラメータの調整と Optimizer の変更をしたモデルを用いる。ネットワーク構造を図 1 に示す。学習には正常症例 66 症例の 3 次元 FDG-PET 画像を用いる。首から膀胱までの範囲に切り取り、 $128 \times 128 \times 128$ [voxels]にリサイズしたのち、画素値を $[-1,1]$ に正規化する。

2.2 再構成誤差の出力

正常症例を学習した画像生成モデルに異常集積を含む画像を入力すると、入力画像に類似した正常例様の再構成画像が出力される。入出力間で大きく変化のあった部分には異常集積が含まれる可能性が高い。その部分を検出するため、入力画像から出力画像を引いた差分のうち、正值である画素のみを再構成

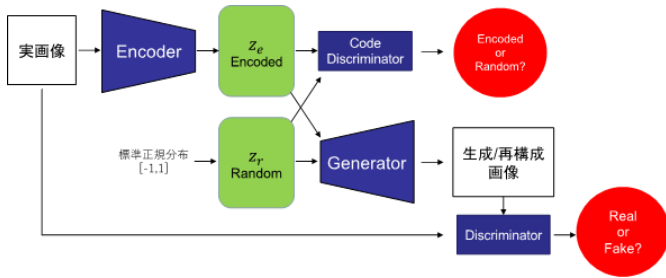


図1 3D-Alpha-WGAN

誤差画像として出力する。

2.3 異常候補の検出

再構成誤差として残った画素に対して、異常集積である可能性の高い領域のみを残すために、誤差の平均と標準偏差を用いて動的閾値処理を行う。

閾値処理後の二値化画像には細切れになったノイズ状の画素が複数含まれる。それらを削除するために、ノイズ除去に用いられるオープニング処理を行う。

2.4 臓器ラベルを利用した偽陽性削除

2.3 での検出結果には、誤って異常と判定されてしまった偽陽性が複数個存在する。中でも、肝臓や膀胱など、正常な細胞であっても画素値が高い部位では偽陽性が多い。そのため、部位ごとに異なる偽陽性削除条件を定めるために、まずCT画像に対する Graph Cut 処理により作成された肺、肝臓、腎臓の臓器ラベルを用いて、検出された異常候補がどの臓器領域に属しているかを特定する。異常候補の画素値の最大値、平均値、周辺画素との差、体積を基に、各臓器の特徴から定めた偽陽性条件と照合し、その条件を満たした場合、その候補を削除する。

3. 結果

肺、肝臓、腹部、その他の体幹部に腫瘍領域を含む異常症例 58 症例を対象に検出を行った。異常症例についても、画像生成モデルの学習に用いた正常症例と同様の範囲への切り取りと正規化を行った。

検出結果の内訳を表1に、FROC 曲線を図2に示す。また、腹部における検出結果の例を図3に示す。橙色が検出結果を、緑色が正解領域を表し、図中の正解領域すべてを検出している。全体の検出率は 89.9%、平均偽陽性数は 37.9 個となった。

4. まとめ

FDG-PET 画像において、教師ラベルなしでの 3 次元画像生成モデルを用いた異常集積の自動検出を行った。検出対象の 58 症例、296 領域に対して、検出率は 89.9%、1 症例あたりの平均偽陽性数は 37.9 個となった。

以上より、正常症例のみで学習した 3D-Alpha-WGAN モデルは、教師なし異常検知のアプローチを用いた、FDG-PET 画像における異常集積の自動検出に有用である可能性が示唆された。

表1 検出結果の内訳

	検出対象数	検出数	検出率
肺	30	27	90.0%
肝臓	25	17	68.0%
腹部	208	194	93.3%
その他	33	28	84.8%
全体	296	266	89.9%





図2 FROC 曲線



(a) スライス画像 (b) 正解領域+検出結果

図3 検出結果の例

謝辞

本研究の遂行にあたり、有益なご助言をいただきました研究室の方々に深く感謝の意を表します。本研究の一部は文部科学省科研費（18K12102）の補助によって行われました。

利益相反の有無

なし

文献

[1] Kwon G, Chihye H, Dae-shik K: "Generation of 3D brain MRI using auto encoding generative adversarial networks." International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer, Cham, 2019

A Novel Centroid-attention based Hybrid Model for Subarachnoid Hemorrhage Classification on Imbalanced Data

Zhongyang LU^{*1}, Masahiro ODA^{*2,1}, Yuichiro HAYASHI^{*1}, Tao Hu¹, Hayato ITOH^{*1},
Takeyuki WATADANI^{*3} Osamu ABE^{*3}, Kensaku MORI^{1,4,5}

^{*1} Graduate School of Informatics, Nagoya University

^{*2} Information Strategy Office, Information and Communications, Nagoya University

^{*3} The University of Tokyo Hospital, Department of Radiology

^{*4} Information Technology Center, Nagoya University

^{*5} Research Center for Medical Bigdata, National Institute of Informatics

Abstract: AI-based diagnosis suffers from the low accuracy, resulting from data imbalance between normal and disease cases. This paper proposes a novel hybrid model to alleviate the data imbalance issue in the subarachnoid hemorrhage classification issue. We present a centroid-attention concept to build up a centroid feature representation of each class dynamically and metric the distance of centroids and features as constraint conditions to enhance the classification performance. In addition, we design a novel loss function to optimize the centroids and the model dynamically. We performed experiments on a highly imbalanced brain CT dataset, including 33 cases with subarachnoid hemorrhage and 2519 normal cases. Our experiments showed that after inducting the memory-attention hybrid model, in contrast to the previous work, the F1 score value was improved around 4.7%, confirming the proposed method's effectiveness in alleviating the classifier bias toward our mission.

Keyword: Imbalanced Classification, Metric learning, Memory-attention, Subarachnoid Hemorrhage

1. Introduction

Subarachnoid Hemorrhage: A Subarachnoid Hemorrhage (SAH) is a subtype of cerebrovascular disease caused by acute hemorrhage in the subarachnoid space [1]. In terms of pathogenesis, it can be divided into the Traumatic subarachnoid hemorrhage (tSAH) and Aneurysmal subarachnoid hemorrhage (aSAH). Especially, with the high lethality and high omission diagnostic rate of aSAH in the emergency department, SAH diagnosis haunts clinical residences for a long time.

Data imbalanced issue: The imbalanced data problem (all called the long-tailed problem) is a common but critical scenario in the real world. In the clinical situation, compared with the number of normal cases, the ones with the disease are rare. And then, it makes a challenge for Computer-Aided Diagnosis (CAD) system to learn an unbiased classifier.

CAD system on cerebral clinical image: Several previous researchers have gained remarkable achievements, Chilamkuthy et al. [2] used a base CNN to detect ICH CT scans and compared the performance of the model to that of radiologists. On the data imbalanced classification, Lu et al. proposed a CB-DenseNet_LSTM framework and its varieties SACB-DenseNet_LSTM [3] to handle the data imbalanced challenge in SAH CT classification on an imbalanced dataset.

In this study, we present a new perspective to deal with the data imbalanced issue on SAH CT classification. The contributions of our work include three highlights. (1) We design a novel model,

DicoriaNet, which dynamically learn centroid feature representation of each class (could be regarded as global information) and metric distances of centroids and features as constraint conditions for performance improvement. (2) We design a loss function to optimize our proposed DicoriaNet, which can optimize the centroids and model dynamically. (3) We conduct experiments on the imbalanced SAH CT dataset and create a new record on our dataset.

2. Methods

In this section, we first demonstrate our proposed method's schematic diagram. And then, we elaborate on critical points in the remaining parts.

DicoriaNet for imbalanced classification: Figure 1 shows the overview of our proposed method, DicoriaNet. Besides the feature extractor (we chose the DenseNet-121 as our backbone model), the model consists of the dynamical class centroid computation and KL divergence-based attention query calculation processing. We input 2D axial CT images and employ the feature extractor to obtain the feature representations of CT images, and utilize the extracted feature vectors to the consequential processing. The purpose of the dynamical class centroid computation is to obtain a global feature representation (class centroid) and dynamically update it in epochs (optimized by center loss). On the other hand, the query calculation is expected to learn an attention weight in order to guide the feature representation to fuse the related centroid wisely. Without loss of the characteristic information, we conduct Hadamard summation on the feature

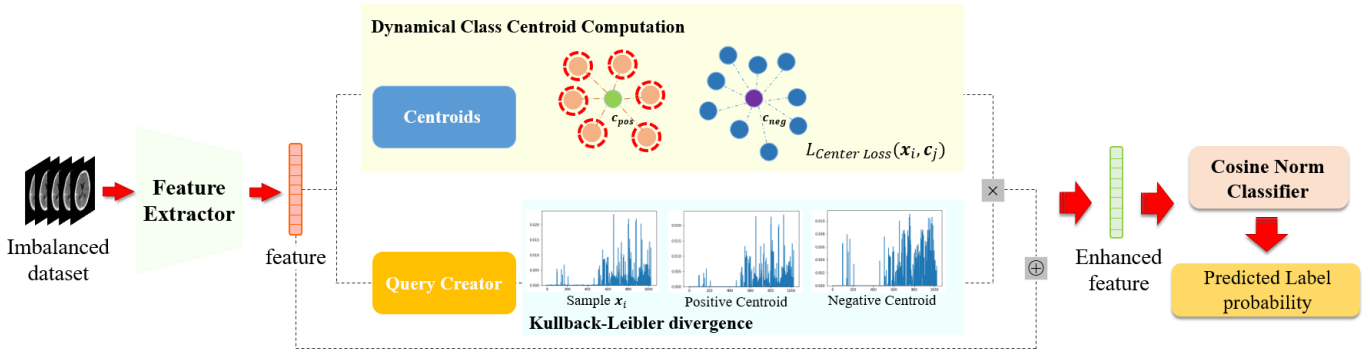


Fig. 1 The workflow of DicoriaNet. The query creator block is a linear layer to enhance model’s learning ability. The center loss is applied to minimize the space of intra-class samples and separate the inter-class samples. The signal \oplus represents the Hadamard summation. The initialization of centroids is calculated by the mean of feature vectors in the same class.

representation and the fusion information (weighted centroids) for the final classification. We refer to Liu et al. [4], adopting cosine norm classifier as the classifier. In inference, as conventional CNNs, we just input 2D CT images and obtain classification results.

Dynamical centroid computation: Instead of the conventional batch-based centroid method (which suffered from lack of global information), the method dynamically update centroid in epoch by its gradient update. And for centroid updating, we design a loss function, which is inspired by the work [5]. We redesign the loss, which the distances of the sample and its non-correspondence centroids are also in consideration. The loss function maximizes the distance of samples and non-correspondence centroids, and minimizes the corresponding one, making model have better discriminative ability.

Attention query calculation. Lu et al: [3] visualized the feature importance vector and proposed the concept of feature importance distribution. We recognized that samples in the same classification results show quite similar distribution. Hence, we vectorize and normalize the centroids (centroids initialization is written in Fig. 1 caption) and samples, and employed KL divergence value of samples and each centroid as metrics to measure their correlation. Considering the nature of KL divergence value, we get its reciprocal as the attention weight of a sample to each centroid.

3. Experiments and Results

Dataset and experimental setting: For verifying effectiveness of our method, we conducted experiments on a heavy imbalanced SAH

CT dataset. It was collected by the National Institute of Informatics (NII), including 2,519 cases of no hemorrhage brain CT and 33 cases brain (607 slices SAH CT and 108,737 no-SAH CT).

Results: For quantitative evaluation, F1 score, precision rate and recall rate were applied to support our experiments. We summarized experimental results in Table 1. By comparing previous works and the state of art method [4] tackling long tailed problem in computer vision, results indicated our method outperform others.

4. Discussion and Conclusions

We discover DicoriaNet alleviates degradation of precision score caused by using LSTM, making intra-class distribution compact, but the recession of minority samples martin at decision boundary should be noticed. For future plans, the generalization of DicoriaNet in other medical CT datasets will be discussed.

Acknowledgement

A part of this research was supported by the Mori laboratory and AMED Grant Numbers JP191k1010036, JP201k1010036, and MEXT/JSPS 26108006, 17H00867 and 21K19898.

Competing interests

None.

References

- [1] Abraham M K, Chang W T, et al.: Subarachnoid hemorrhage. Emergency Medicine Clinics 34(4): 901-916, 2016
- [2] Chilamkurthy S, Ghosh R, et al.: Deep learning algorithms for detection of critical findings in head CT scans: a retrospective study. The Lancet 392: pp.2388-2396, 2018
- [3] Lu Z, Oda M, Hayashi Y, et al.: Self-attention Class Balanced DenseNet_LSTM framework for Subarachnoid Hemorrhage CT image Classification on Extremely Imbalanced Brain CT Dataset, 第 40 回日本医用画像工学会大会予稿集, pp.69-75, 2021
- [4] Liu Z, Miao Z, Zhan X, et al.: Large-scale long-tailed recognition in an open world. IEEE Conference on Computer Vision and Pattern Recognition. 2019, pp.2537-2546.
- [5] Wen Y, Zhang K, Li Z, et al.: A discriminative feature learning approach for deep face recognition. European conference on computer vision, pp.499-515, 2016

Table 1 Quantitative evaluation results of experiments

Experiments	F1 score	Recall	Precision
DenseNet-121	0.638	0.721	0.577
CB_DenseNet_LSTM	0.726	0.936	0.594
SACB_DenseNet_LSTM	0.734	0.927	0.608
OLTR [4]	0.656	0.509	0.923
DicoriaNet	0.781	0.673	0.933

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

大野 真奈^{*1}, 申 忱^{*1}, Holger R. Roth^{*2}, 小田 昌宏^{*3,1}, 林 雄一郎^{*1},
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

A Study on Organ Segmentation from Abdominal CT Volumes Using FCN with a Loss Function Considering Boundary Information

Mana OHNO^{*1}, Chen SHEN^{*1}, Holger R. Roth^{*2}, Masahiro ODA^{*3,1}, Yuichiro HAYASHI^{*1},
Kazunari MISAWA^{*4}, Kensaku MORI^{*1,5}

^{*1} Graduate School of Informatics, Nagoya University

^{*2} NVIDIA Corporation

^{*3} Information Strategy Office, Information and Communications, Nagoya University

^{*4} Aichi Cancer Center

^{*5} Research Center for Medical Bigdata, National Institute of Informatics

要旨：本稿では、境界情報を考慮した損失関数を導入した Fully Convolutional Networks (FCNs) 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。コンピュータによる診断・手術支援システムの開発において、多臓器領域抽出は重要な要素技術であり、これまで多くの研究が報告されている。従来の臓器領域抽出では損失関数として Dice Loss が広く利用されている。しかしながら、Dice Loss は抽出領域と正解領域の重なり部分を考慮するため、学習されたモデルは臓器の境界部分の表現が曖昧になる傾向がある。このような問題を解決するため、提案手法では抽出領域の境界部分における曖昧さを考慮する Boundary Enhancement Loss を Dice Loss と組み合わせた損失関数を用いて、FCN による多臓器領域抽出を行った。そして、境界情報が多臓器領域抽出に与える影響を考察した。本研究では 284 症例の CT 像を用いて多臓器領域抽出を行った。全臓器の Dice 係数の平均は、3D U-Net を用いた手法で 87.24%、V-Net を用いた手法で 87.19%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

近年、コンピュータによる診断や手術の支援の研究が盛んに行われている。腹部 CT 像からの臓器領域抽出はこれらの支援システムの開発のために重要な要素技術であり、これまで多くの手法が提案されている。臓器領域抽出における損失関数として、Dice Loss [1]が広く利用されている。しかし、CT 像はコントラストが低く、境界部分が本質的に曖昧であるにもかかわらず、Dice による評価で境界部分の曖昧性を評価することは難しい。そこで、本稿では境界情報を考慮する損失関数である Boundary Enhancement Loss (BE Loss) [2]を 3D U-Net [3]と V-Net [1]の 2 つの Fully Convolutional Networks (FCNs) の学習に導入し、動脈、門脈、肝臓、脾臓、胃、胆のう、膵臓、左右の腎臓の領域抽出を行った。また、提案手法を Dice Loss を用いた多臓器領域抽出と比較し、境界を考慮する損失関数が抽出精度に与える影響を考察した。

2. 手法

提案手法は学習過程、推定過程、評価過程の 3 つの段階に分けられる。まず、CT 像とその正解ラベルを FCN の入力とし、学習を行う。ここで損失関数として BE Loss が用いられる。次に学習によって作成したモデルにテスト用の CT 像を入力し、ラベルの推定を行う。最後に推定したラベルと正解ラベルを比較してモデルの評価を行う。

提案手法の学習過程において、損失関数として BE Loss が用いられている。BE Loss を用いた学習では、まずモデルによる予測ラベルと正解ラベルにそれぞれラプラシアンフィルタを適用し、その差の L2-norm を導出する。フィルタリングの流れを図 1 に示す。以上の操作を、背景を除くすべての臓器の正解ラベル・予測ラベルについて行う。全臓器の正解ラベルと予測ラベルの差の L2-norm の平均を l_{BE} とする。 l_{BE} はラベルの境界部分のみ考慮し、境界の内部と外部の区別をつけることがで

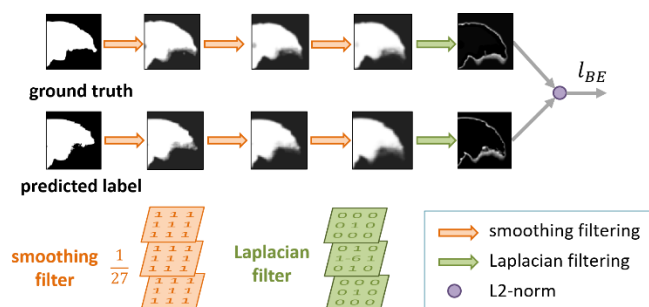


図 1 フィルタリングの流れ. 平滑化フィルタとラプラシアンフィルタを適用後, L2-norm を計算する.

きないため, Dice Loss と組み合わせた値を最終的な損失関数として利用する. 最終的な損失 $l_{overall}$ は

$$l_{overall} = l_{dice} + \frac{1}{1000} l_{BE},$$

のように与えられる. ここで l_{dice} は Dice Loss を表している.

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 $1 \times 1 \times 1$ mm³ の解像度にリサンプリングを行った. また, モデルへの画像の入力サイズは $96 \times 96 \times 96$ pixel とした. Dice による抽出精度評価を表 1 に示す. また, 抽出結果の例を図 2 に示す.

4. 考察

表 1 より 3D U-Net と V-Net のどちらのモデルを用いた場合でも, BE Loss を用いたことで Dice Loss のみ用いたものと比較して精度の改善がみられた. 特に 3D U-Net を用いた手法では胃や肝臓が大きく精度が改善されたが, これは Dice Loss による抽出結果で見られた孤立した過抽出領域が, BE Loss を用いた手法で削減されたことが影響していると考えられる. 一方で血管領域については末端の細い血管が抽出されない傾向があり, 特に門脈の精度が低い結果となっている. このことから, BE Loss が血管のような細い領域では有効でない可能性がある.

4. まとめ

本稿では, 3D U-Net と V-Net の 2 つの FCN に BE Loss を導入し多臓器領域抽出を行った. その結果, 3D U-Net と V-Net のどちらのモデルを用いた場合でも, BE Loss を用いた手法がすべての臓器で最も高い精度となった. 一方, 血管領域については抽出されない領域があり, 特に門脈で低い精度であった. 今

後の課題として, 臓器抽出のモデルの改良や位置情報など新しい特徴量のモデルへの導入を考えている. また, 本実験で精度の低かった血管領域を中心に, さらなる精度の改善を目指す.

謝辞

本研究は JST CREST JPMJCR20D5, JPMJMS2033, 科研費 21K19898 の支援を受けたものである.

利益相反の有無

なし

文献

- [1] Milletari F, Navab N, Ahmadi S: V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation. In Proceedings of Fourth International Conference on 3D Vision (3DV), California, 2016, pp565-571
- [2] Yang D, Roth H, Wang X, et al.: Enhancing Foreground Boundaries for Medical Image Segmentation. In Proceedings of Medical Imaging with Deep Learning, Montréal, 2020, arXiv:2005.14355v1
- [3] Çiçek Ö, Abdulkadir A, Lienkamp S, et al.: 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. Medical Image Computing and Computer-Assisted Intervention (MICCAI), Athens, 2016, pp424-432

表 1 BE Loss と Dice Loss の Dice による評価.

	3D U-Net, Dice + BE	3D U-Net, Dice	V-Net, Dice + BE	V-Net, Dice
動脈	85.90%	82.45%	84.77%	83.74%
門脈	72.74%	70.47%	73.45%	72.07%
肝臓	96.00%	87.93%	96.44%	95.28%
脾臓	96.02%	70.54%	95.66%	94.18%
胃	81.60%	76.08%	83.85%	82.96%
胆のう	83.80%	76.35%	82.14%	82.06%
膵臓	76.63%	72.46%	76.31%	74.50%
右腎臓	96.41%	93.49%	96.24%	96.04%
左腎臓	96.08%	71.46%	95.85%	95.29%
平均	87.24%	77.92%	87.19%	86.24%

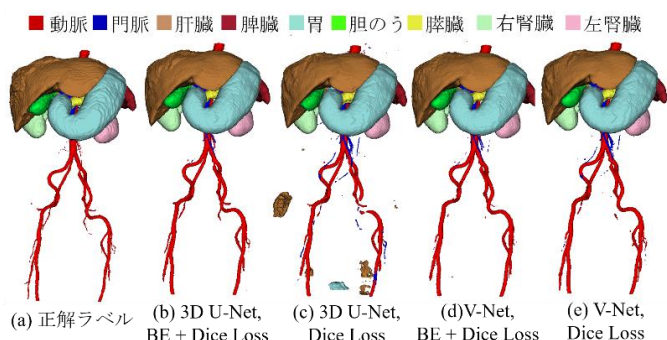


図 2 抽出結果の例.

PET/CT 画像を用いた多臓器自動抽出に関する初期的検討

菅沼雄太^{*1}, 寺本篤司^{*1}, 齋藤邦明^{*1}, 藤田広志^{*2}, 鈴木結紀^{*3}, 富山憲幸^{*4}, 木戸尚治^{*3}

^{*1} 藤田医科大学大学院 保健学研究科

^{*2} 岐阜大学 工学部

^{*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

^{*4} 大阪大学大学院 医学系研究科 放射線医学教室

Initial Investigation of Automated Multi-Organ Extraction Using PET/CT Images

Yuta SUGANUMA^{*1}, Atsushi TERAMOTO^{*1}, Kuniaki SAITO^{*1}, Hiroshi FUJITA^{*2},

Yuuki SUZUKI^{*3}, Noriyuki TOMIYAMA^{*4}, Shouji KIDO^{*3}

^{*1} Graduate School of Health Sciences, Fujita Health University

^{*2} Faculty of engineering, Gifu University

^{*3} Department of Artificial Intelligence Diagnostic Radiology, Graduate School of Medicine, Osaka University

^{*4} Department of Diagnostic and Interventional Radiology, Graduate School of Medicine, Osaka University

要旨 : PET/CT 検査は腫瘍の早期発見に有用であり, 検診目的でも利用されている. しかし, PET 画像は空間分解能が低く, 高集積を呈する臓器の同定が困難な場合がある. そこで本研究は, PET/CT 画像を用いて多臓器を自動抽出する手法を検討した. 本研究では仁泉会 MI クリニックにて収集された 88 症例の全身 PET/CT 画像を対象とした. PET 画像または PET 減弱補正用 CT 画像に対し, U-Net を用いて臓器領域抽出を行った. 抽出対象は, 肝臓・脾臓・膵臓・腎臓とし, それらの抽出精度は Dice 係数にて評価した. 肝臓・脾臓・膵臓・腎臓の Dice 係数はそれぞれ 0.935, 0.912, 0.543, 0.831 となり, 膵臓・腎臓以外は診断用 CT 画像を用いた先行研究と同等の抽出精度が得られた. 診断用 CT 画像よりも解像度が低くノイズレベルの高い PET/CT 画像であっても肝臓・脾臓は十分な精度で抽出が可能であることが確認された.

キーワード : U-Net, セグメンテーション, PET/CT

1. はじめに

国内の疾患別死亡率において, 悪性新生物は 1 位とされ, 年々増加傾向にある[1]. 悪性新生物は進行する病変であり, 治療の開始時期が予後に大きく影響するため, 早期発見が非常に重要である.

悪性新生物の画像検査には, 部位によって様々だが, 核医学検査, 超音波検査, CT, MRI 等が利用される. 特に核医学検査 (PET/CT 検査) は検診目的でも利用されており, 早期発見に貢献している. PET/CT 検査の特徴として, 形態的・動態的情報が得られる点や, 一度に全身の検査を行う点, 目的臓器の

診断の他に転移の有無の診断を行うことができる点が挙げられる. しかし, PET 画像は空間分解能が低く, 高集積を呈する臓器の同定が困難な点や, 読影医は PET 画像, CT 画像, Fusion 画像, それぞれの全身画像を読影する必要があり負担が大きいといった問題点も挙げられる. 上記の問題点により, PET/CT 検査で得られる画像に対し, 読影の補助が求められる.

現在, 人工知能技術を利用した医用画像の定量的な評価やコンピュータ支援診断技術 (CAD) 等の研究が盛んに行われている. 特に人工知能技術の一つであるディープラーニングを利用した, 体幹部の多臓器自動抽出[2][3]は多く存在する. しかし, PET 画像に着目し, ディープラーニングを用いて臓器の自動抽出を行った研究は少ない.

よって本研究は, 人工知能技術の一つである U-Net を用いた PET/CT 画像における多臓器の自動抽出を目的とし, 初期的な検討として, 複数の臓器に対してそれぞれ別の U-Net を用いた臓器の自動抽出を行った.

*1 藤田医科大学大学院保健学研究科 [〒470-1192 豊明市 沓掛町田楽ヶ窪 1 番地 98]

e-mail: teramoto@fujita-hu.ac.jp

*2 岐阜大学工学部

*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

*4 大阪大学大学院 医学系研究科 放射線医学教室

2. 方法

本研究では、畳み込みニューラルネットワークを用いた領域抽出手法である U-Net を用いて臓器領域抽出を行った。抽出対象は肝臓・脾臓・膵臓・腎臓とし、それぞれの臓器に対応した U-Net を用意した。使用データは、仁泉会 MI クリニックで 2006 年から 2019 年に撮影された PET/CT 検査 88 症例を対象とした。ただし、腎臓は 30 症例のみを使用した。入力には PET 減弱補正用 CT 画像、または PET 減弱補正用 CT 画像と PET 画像を重ねた画像のいずれかを使用した。4 種の臓器がすべて入るように、肺底部を基準とし、肺底部から大腿骨頭周辺までの 116 スライスを入力画像とし、臓器領域の正解ラベルは解剖学を修得した学生 17 名によって作成した。臓器抽出の評価指標として正解領域と抽出領域の一致度を表す Dice 係数を用い、交差検証法を用いて全ての症例に対する性能評価を行った。これらの処理には、Tensorflow および Keras を利用した Python プログラムを利用し、学習処理には GPU として NVIDIA Quadro RTX 8000 を搭載した PC を利用した。

3. 結果および考察

臓器別の平均 Dice 係数、標準偏差を算出した結果を表 1 に示す。また図 1 に臓器抽出結果の一例を示す。

表 1 臓器別の平均 Dice 係数と標準偏差

臓器	平均 Dice 係数	標準偏差
肝臓	0.935	0.017
脾臓	0.912	0.033
膵臓	0.543	0.215
腎臓*	0.831	0.138

*腎臓は 30 症例を使用した結果を示す。




図 1 臓器抽出結果の一例

診断用 CT 画像を用いて検討している先行研究[2][3]と比較すると、肝臓・脾臓では、PET/CT 画像を用いた本手法で同等な抽出精度が得られた。また、腎臓は 30 症例のみを使用している影響もあり、先行研究[2][3]に比べ低い結果となった。一方、膵臓は他臓器に比べ大きく低い抽出精度となった。

なお、同一症例にて PET 減弱補正用 CT 画像のみを利用して抽出を行った場合と比較すると、PET 減弱補正用 CT 画像と PET 画像を併用した場合に若干の抽出精度の改善がみられ、2 種類の画像を利用する有効性が確認された。

今後は抽出対象臓器ならびに使用症例数を追加しながら検討を続ける予定である。

4. 結論

本研究では U-Net を用いた PET/CT 画像における多臓器セグメンテーション手法を開発した。検証を行った結果、肝臓・脾臓において、診断用 CT 画像用いた多臓器セグメンテーション同等の精度で行われ本手法の有用性が確認された。

利益相反の有無

なし

文 献

- [1] 令和 2 年(2020)人口動態統計月報年計(概数)の概況：https://www.mhlw.go.jp/toukei/saikin/hw/jinkou/geppo/nengai20/dl/gaikyou_R2.pdf (2022/05/07)
- [2] Holger R. Roth, Hirohisa Oda, Yuichiro Hayashi et al: Hierarchical 3D fully convolutional networks for multi-organ segmentation, arXiv, Vol1704.06382, 2017
- [3] Xiangrong Zhou, Ryosuke Takayama, Song Wang et al: Deep learning of the sectional appearances of 3D CT images for anatomical structure segmentation based on an FCN voting method, Medical Physics, Vol44, Issue10, October2017

U-Net を用いた頸部 X 線動画からの椎体・棘突起の抽出に関する基礎的検討

塩田 紘司^{*1}, 目片 幸二郎^{*2} 滝沢 穂高^{*3}, 工藤 博幸^{*3}

^{*1} 筑波大学大学院情報理工学位プログラム

^{*2} 四条畷学園大学

^{*3} 筑波大学システム情報系

Preliminary study on extraction of vertebral bodies and spinous processes in videofluorography by use of U-Net

Koji Shioda^{*1}, Kojiro Mekata^{*2} Hotaka Takizawa^{*3}, Hiroyuki Kudo^{*3}

^{*1} Master's Program in Computer Science, University of Tsukuba

^{*2} Shijonawate Gakuen University

^{*3} Faculty of Engineering, Information and Systems, University of Tsukuba

要旨：嚥下障害は栄養低下や誤嚥を引き起こし、患者の生活の質を低下させるが、その詳細なメカニズムは未だ明らかになっていない。本研究では嚥下時 X 線動画にデータ拡張、マルチチャンネル化(Multi-channelization, MC)、下顎骨、後頭部、肩部の境界線に基づくキャリブレーションの 3 種類の前処理を行い、U-Net に適用することで椎体・棘突起を抽出する手法を提案する。マルチチャンネル化では、まず線形フィルタや非線形フィルタを用いて特徴画像を生成し、マルチチャンネル化画像 (MC 画像) を生成する。この MC 画像を U-Net に適用し、抽出精度が最大となる特徴画像の組み合わせを求める。データ拡張、MC を行った場合の精度向上を確認した。実際の嚥下時 X 線動画に適用した結果を示す。

キーワード：頸部 X 線動画、椎体、棘突起、U-Net、マルチチャンネル化

1. はじめに

誤嚥性肺炎は 2019 年と 2020 年の日本人の死因 6 位[1]となっている。嚥下障害は誤嚥性肺炎の要因の一つだが、そのメカニズムは未だ解明されていない。本研究では、頸部 X 線動画に Fully Convolutional Network の一種である U-Net を適用し、頸椎を構成する椎体および棘突起をそれぞれ自動で抽出することを試みる。精度向上のために、3 つの抽出手法を提案し、比較実験を行った。

2. 抽出手法

1)アフィン変換に基づくデータ拡張
先行研究[2]に基づき、モルフォロジー演算と RANSAC による放物線あてはめ処理などを適用して求めた基準点を用いて、平行移動と回転による 27 倍のデータ拡張を行う。

2)マルチチャンネル化(MC)[3]
マルチチャンネル化による椎体・棘突起の抽出の流れを図 1 に示す。

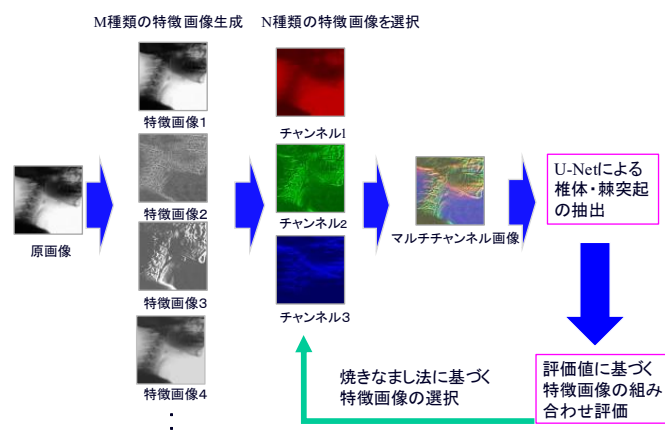


図1 マルチチャンネル化による椎体・棘突起の抽出

8ビットのグレイ画像である嚙下時 X線動画の各フレームから M 種類の特徴画像を生成し、その中から 3 種類の特徴画像を選択し、それぞれを RGB チャンネルに入力したカラー画像を生成する。これをマルチチャンネル化画像と呼ぶ。MC 画像を U-Net に入力し、椎体・棘突起を抽出し、抽出精度の評価値を求める。得られた評価値をもとに焼きなまし法による特徴画像の組み合わせの最適化を行う。

3) 下顎骨、後頭部、肩部の境界線に基づくキャリブレーション

図 2 に示すように頭部放物線、肩部放物線、首中心線を基準として首中心線分と呼ばれる線分を求め、この線分の傾き、位置、大きさをそろえることによってキャリブレーションを行う。

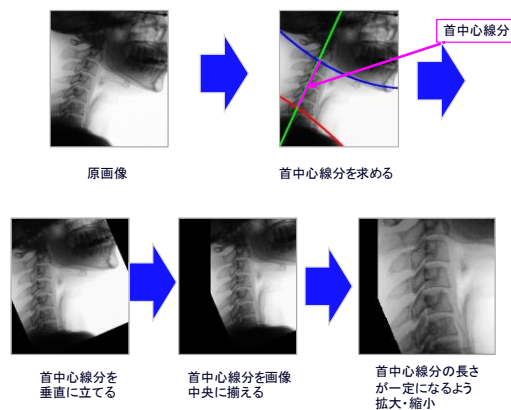


図 2 下顎骨、後頭部、肩部の境界線に基づくキャリブレーション

3. 実験

本研究では、正常被験者の嚙下時 X線動画 39 症例からなるデータセットを実験に用いる。各症例から舌骨最大挙上フレームにおける椎体・棘突起の位置を手動抽出し、正解データとする。MC には学習用、特徴評価用、予測用の 3 つのデータセットを要するため 3-fold 3-phase cross validation による評価を行う。提案した 3 つの抽出手法の性能を評価するために以下のような実験条件にて比較実験を行う。

条件 A : 前処理無し

条件 B : アフィン変換に基づくデータ拡張

条件 C : MC

条件 D : MC+キャリブレーション

U-Net に用いるパラメータはエポック数 100, バッチサイズ 1, 最適化手法には Adam, 損失関数はクロスエントロピーを用いた。

4. 考察とまとめ

評価値を求めた結果、性能はピクセルベースの F 値で、それぞれ 0.919, 0.935, 0.929, 0.765 となり、データ拡張と MC が有効であった。条件 B の結果を図 3 に示す。MC のパラメータの変更や、データ拡張の手法を変更することでさらなる向上が期待できる。この結果から、データ拡張と MC によって性能は向上しており、キャリブレーションによって性能が低下していることがわかる。




図 3 原画像・正解ラベル・予測ラベル

また条件 D では背景領域が小さくなるのが原因で評価値が低くなっており、対策が必要と考える。

利益相反の有無

なし

文献

- [1] 厚生労働省 令和 2 年(2020)人口動態統計(確定数)の概況。
- [2] 八板 駿平, 滝沢 穂高, 目片 幸二郎, 工藤 博幸「Support vector machine を用いた嚙下時 X線サジタル透視動画における舌骨体の追跡 SVM を用いた嚙下時 X線透視画像からの舌骨領域の抽出と追跡」日本医用画像工学会論文誌, Vol. 36, No. 5, pp. 209-216, 2018.
- [3] Ayano Fujinaka, Kojiro Mekata, Hotaka Takizawa, Hiroyuki Kudo, Segmentation of cervical intervertebral disks in videofluorography by CNN, multi channelization and feature selection, International Journal of Computer Assisted Radiology and Surgery, Springer, Vol.15, No.4, pp.1-8, 2020.

体幹部 CT 画像における 2D U-Net を用いた体腔の同時学習による腰方形筋の自動認識

川本 真大^{*1}, 神谷 直希^{*1}, 周 向榮^{*2}, 加藤 博基^{*3}, 原 武史^{*2,4}, 藤田 広志^{*2}

^{*1} 愛知県立大学情報科学部

^{*2} 岐阜大学工学部

^{*3} 岐阜大学大学院医学系研究科放射線医学分野

^{*4} 東海国立大学機構医療健康データ統合研究教育拠点

Automatic Segmentation of Lumbar Quadrate Muscle by Simultaneous Learning of Body Cavity Using 2D U-Net in Torso CT Images

Masahiro KAWAMOTO^{*1}, Naoki KAMIYA^{*1}, Xiangrong ZHOU^{*2}, Hiroki KATO^{*3},
Takeshi HARA^{*2,4}, Hiroshi FUJITA^{*2}

^{*1} School of Information Science and Technology, Aichi Prefectural University

^{*2} Faculty of Engineering, Gifu University

^{*3} Department of Radiology, Graduate School of Medicine, Gifu University

^{*4} Center for Healthcare Information Technology (C-Hit), Tokai National Higher Education and Research System

要旨 : CT 画像を用いた腹部組織の自動解析では、セグメンテーションに基づく骨格筋量の計測が行われている。しかしながら、現状は第三腰椎(L3)断面における二次元の計測にとどまる。さらに、L3 断面内には複数の骨格筋が含まれているが、部位別認識が実現されている対象は限られる。本研究では、姿勢や呼吸機能との関係が示唆されている腰方形筋について、三次元認識手法を提案する。提案手法では、2D U-Net において腰方形筋に隣接する体腔を同時学習し、腰方形筋の自動認識における体腔の同時学習の効果を明らかにする。20 症例の体幹部 CT 画像に対し、4 分割交差検証で提案手法を評価したところ、腰方形筋のみを用いた学習時には、Dice 値が 79.4%であったが、体腔と腰方形筋の同時学習では 85.6%となり、認識精度は 6.2%向上した。今後は、腹腔に隣接し腹壁を構成する他の骨格筋においても腹腔の同時学習の効果の検討を行う。

キーワード : 腰方形筋, 体腔, U-Net, CT 画像, 同時学習

1. はじめに

加齢による骨格筋量の減少や筋力の低下であるサルコペニアの研究において、骨格筋のセグメンテーションに基づく解析は基本的なアプローチである。特に、CT 画像における第三腰椎 (L3) 断面の骨格筋量は全身の骨格筋量と有意な相関があることが示されている [1]。そのため、L3 断面における骨格筋セグメンテーションは多数取り組まれているが、近年では、ディープラーニングによるアプローチが取り入れられている [2]。また、L3 断面には本研究の対象とする腰方形筋をはじめ、多数の骨格筋が描出され、大腰筋の横断面積によるサルコペニアの簡易評価などが報告されている [3]。しかしながら、L3 断面における骨格筋認識は、断面内のセグメンテーションであるため、ボリュームとして骨格筋の評価ができないことが課題である。加えて、L3 断面内の骨格筋のうち、部位別認識が実現されている骨格筋は限られ、腰方形筋の部位別認識は実現できていない。そして、腰方形筋では、横断面積の左右対称性が前額面上の姿勢や呼吸機能との関係が言及されている [4]。

本研究では、体幹部 CT 画像における腰方形筋の自動認識を

目的とする。我々は、これまでに体腔領域の自動認識を提案し、体腔の認識精度は 90%以上と高い Dice 値を示した [5]。さらに、体腔の認識結果を利用し、体腔に隣接する骨格筋である腹斜筋の自動認識を実現した [6]。本研究では、U-Net による学習時に、腰方形筋と体腔を同時に学習することで、体腔に隣接する骨格筋の一つである、腰方形筋の自動認識における体腔の同時学習の効果を明らかにする。

2. 手法

体腔の周りには様々な表層筋が存在するが、腰方形筋も体腔の後方に隣接する骨格筋である。ここでは、2D U-Net の学習画像として、体幹部 CT 画像の横断面における腰方形筋および体腔の領域を利用する。2D U-Net では、オーグメンテーションを適用し、データを 8 倍に拡張する。また、過学習抑制効果を期待し、モデルにおいて、各 Convolution 層の後ろに Batch Normalization を追加する。認識では、学習済みモデルに対し、CT 画像の横断面を入力し、腰方形筋と体腔の同時認識を行い、腰方形筋の 3 次元の部位別認識を実現する。

表1 腰方形筋と体腔の同時学習における腰方形筋と体腔の認識精度と標準偏差(SD) [%]

学習対象領域の 組み合わせ	腰方形筋			体腔		
	Dice	Recall	Precision	Dice	Recall	Precision
腰方形筋のみ	79.4±4.2	82.9±4.1	76.8±7.7	-	-	-
体腔のみ	-	-	-	98.4±0.2	98.4±0.7	98.5±0.5
腰方形筋と体腔 (提案手法)	85.6±4.1	87.1±6.6	85.3±8.6	98.4±0.3	98.1±0.3	98.6±0.6

ハイパーパラメータは、エポック数 50, 学習率 3×10^{-4} , バッチサイズ 4 とし、最適化関数は Adam を用いる。損失関数は、Cross Entropy と Dice を組み合わせた関数である、 $0.5 \times$ Cross Entropy - Dice を用いる。

3. 実験


試料画像には、非造影体幹部 CT 画像 20 症例を用い、4 分割交差検証を行う。正解画像は、手動で作成した腰方形筋領域と体腔領域を用いる。そして、Dice 値、Recall 値および Precision 値により腰方形筋の認識精度を評価する。

4. 結果

腰方形筋と体腔の同時学習における腰方形筋と体腔の認識精度と標準偏差(SD)を表 1 に示す。腰方形筋の認識精度は、腰方形筋と体腔の同時学習では Dice 値が 85.6%となり、腰方形筋のみを学習した場合の Dice 値である 79.4%と比較し、自動認識の精度が 6.2%向上した。このとき、体腔の認識精度は標準偏差が 0.1%増加したものの、Dice 値は 98.4%となり、同時学習による体腔の認識精度は低下していない。

5. 考察

腰方形筋のみの学習、および腰方形筋と体腔の同時学習における腰方形筋の認識結果について、後方から三次元レンダリングしたものと腰椎断面における CT 横断像を図 1 に示す。ここで、緑色は認識結果と正解画像の一致を、赤色は過抽出を、そして黄色は未抽出の領域をそれぞれ示す。表 1 における Precision 値より、腰方形筋と体腔の同時学習により、過抽出が抑制されたことがわかるが、図 1 においても腰方形筋の上部における過抽出が抑制されていることが分かる。また、腰方形筋



(a) 同時学習 (提案手法) (b) 腰方形筋のみ学習
図 1 腰方形筋と体腔の同時学習による腰方形筋の認識結果と腰方形筋のみを学習した場合の比較 (背面の 3 次元画像と腰椎断面における比較)

のみを学習に用いた場合にみられた過抽出は、原画像における脊柱起立筋とその周辺領域であり、濃淡値は腰方形筋と類似している。このような過抽出は体腔の同時学習では大幅に抑制されている。そのため、体腔だけでなく、腰方形筋の後方に隣接する脊柱起立筋と同時学習を検討する必要がある。

6. まとめ

本研究では、体幹部 CT 画像における腰方形筋の部位別認識を目的とし、2D U-Net により体腔領域との同時学習による認識法を提案した。20 症例を用い、4 分割交差検証を行った結果、腰方形筋の認識精度は、提案手法である同時学習では 85.6%となり、腰方形筋のみを学習した場合の 79.4%と比較し、6.2%の精度向上となった。腰方形筋は体腔と隣接するが、腹直筋や腹斜筋などの他の体腔に隣接する筋と比較し、その程度は小さい。そのため、今後は腹壁を構成する他の骨格筋の隣接の程度と体腔の同時学習における認識精度について検討を行う。

謝辞

本研究は JSPS 科研費 21K12731 の助成を受けたものです。

利益相反の有無

なし

文献

- [1] Cruz-Jentoft A, Bahat G, Bauer J et al.: Sarcopenia: revised European consensus on definition and diagnosis. Age and Ageing 48: 16-31, 2019
- [2] Castiglione J, Somasundaram E, Gilligan L et al.: Automated segmentation of abdominal skeletal muscle on pediatric CT scans using deep learning. Radiology Artificial Intelligence 3: 1-9, 2021
- [3] Jones K, Doleman B, Scott S et al.: Simple psoas cross-sectional area measurement is a quick and easy method to assess sarcopenia and predicts major surgical complications. Colorectal Disease 17: O20-O26, 2015
- [4] 本間友貴, 平山哲郎, 茂原亜由美, 他: 強制呼吸での腰方形筋断面面積の左右対称性と前額面上の姿勢, 呼吸機能の関係. 理学療法科学 33: 501-506, 2018
- [5] 前田泰良, 神谷直希, 周 向榮, 他: 体幹部 CT 画像における U-Net アーキテクチャによる体腔の自動認識. 第 39 回日本医用画像工学会大会予稿集 39: 28, 2020
- [6] Kamiya N, Zhou X, Kato H et al.: Automated segmentation of oblique abdominal muscle based on body cavity segmentation in torso CT images using U-Net. In Proceedings of International Workshop on Advanced Imaging Technology (IWAIT), Hong Kong, 2022, 121771

Co-Training for Semi-Supervised CT Segmentation of COVID-19

Kai LIU^{*1}, Masahiro ODA^{*2,1}, Tong ZHENG^{*1}, Yuichiro HAYASHI^{*1}, Yoshito OTAKE^{*3,4},
Masahiro HASHIMOTO^{*5}, Toshiaki AKASHI^{*6}, Shigeki AOKI^{*6}, Kensaku MORI^{*1,2,4}

^{*1} Graduate School of Informatics, Nagoya University

^{*2} Information Strategy Office, Information and Communications, Nagoya University

^{*3} Graduate School of Science and Technology, Nara Institute of Science and Technology

^{*4} Research Center for Medical Bigdata, National Institute of Informatics

^{*5} Department of Radiology, Keio University School of Medicine

^{*6} Department of Radiology, Juntendo University

Abstract: COVID-19 has become a worldwide disease, and some variants of it spread more easily and faster, which causes more affected cases. Segmentation of COVID-19 infected regions from chest CT volumes is helpful for diagnosis, staging, and prognosis of COVID-19 while labeling is time-consuming. In this work, we employ a semi-supervised segmentation method to segment infected regions with few labeled data and a large amount of unlabeled data. To solve the problem of unreliable boundary annotation, we calculate loss without considering boundary pixels. In the experiment using the proposed method, we attained 0.730 of Dice score.

Keywords : Co-training, COVID-19, semantic segmentation, masked loss

1. Introduction

Over the few years, COVID-19 has become a worldwide pandemic, resulting in over 513 million infected cases and over 6 million deaths by May 9, 2022. For diagnosis of COVID-19, CT image-based diagnosis attracts attention for its high sensitivity (about 98%) [1]. However, analyzing CT volumes is tedious and time-consuming because one CT volume usually contains hundreds of CT slices, and some infected regions are small. Segmentation of infected regions helps radiologists analyze CT volumes effectively and provides evidence for the staging and prognosis of COVID-19 [2].

Semi-supervised segmentation methods take advantage of limited labeled data and a large amount of unlabeled data to approach the performance with a large amount of labeled data. Considering data sharing between different clinical data center is challenging, Yang *et al.* [3] combined federated learning with semi-supervised learning. In detail, clients save data invisible to other clients and servers. Clients calculate gradient with local model and share gradient with a server. After that, the server aggregates the received gradient and sends a new model weight to clients. For client saving unlabeled data, the model is optimized by minimizing the difference between pseudo label and prediction of augmented data.

Despite of these successful methods, segmentation of COVID-19 infected regions is still challenging for blurred boundaries. Different radiologists may give different annotations, especially for boundary pixels. We omit boundary pixels of the ground truth and corresponding pixels of prediction when calculating loss to solve this problem. As a result, incorrectly annotated boundary labels do not

worsen the segmentation performance.

2. Method

The overview of the proposed method is shown in Fig. 1, where \mathbf{y}_t , \mathbf{x}_l , \mathbf{x}_u , and \mathbf{B} are the ground truth slice, labeled CT axial slice, unlabeled CT axial slice required for semi-supervised segmentation method, and extracted boundary, respectively. Following cross pseudo supervision [4], we use two U-Nets initialized differently, U-Net 1 and U-Net 2, to segment infected regions of COVID-19. With input \mathbf{x}_l and \mathbf{x}_u , the outputs of U-Net 1 are \mathbf{y}_l^1 and \mathbf{y}_u^1 respectively. The case for U-Net 2 is similar. In the training phase, we first extract the boundary of infected region \mathbf{B} using the ground truth. Then U-Net 1 and U-Net 2 generate a prediction of infected regions from the given input \mathbf{x}_l and \mathbf{x}_u and are optimized then. In the test phase, U-Net 1 generates the prediction result of COVID-19 infected regions from a given test axial CT slice.

In the extraction of the detailed boundary of infected regions, we erode infected regions of the ground truth slice and search pixels with different values between the erosion result and the ground truth slice. To solve the problem of blurred boundary, for labeled CT slice using U-Net 1, we use masked dice loss defined as

$$L_s^1 = 1 - \frac{1}{C} \sum_{c=1}^C \frac{2 \sum_{i=1}^n (1 - \mathbf{B}_i) \mathbf{y}_{t,i,c} \mathbf{y}_{l,i,c}^1 + s}{\sum_{i=1}^n (1 - \mathbf{B}_i) \mathbf{y}_{t,i,c} + \sum_{i=1}^n (1 - \mathbf{B}_i) \mathbf{y}_{l,i,c}^1 + s} \quad (1)$$

where \mathbf{B} , \mathbf{y}_t , \mathbf{y}_l^1 , s , n , and C are boundary mask of ground truth, ground truth, prediction result of labeled axial CT slice generated by U-Net 1, hyperparameter to prevent zero denominators, the number of pixels form \mathbf{B} , and C is the number of classes. The case using U-

Net 2 is similar. Loss for unlabeled axial CT slice is defined as the summation of dice-based loss [5] between prediction results of unlabeled axial CT slice and pseudo label generated by another model.

3. Experiment and Results

We used 15 labeled CT volumes and 86 unlabeled CT volumes for training in this work. We used 5 labeled CT volumes for the test. The initial learning rate was 10^{-4} and decreases 5% every epoch. Batch size was 4, and the optimizer was Adam.

Segmentation results of infected regions are shown in Fig. 2. Quantitative results are shown in Table 1. We attained the larger Dice than U-Net while the proposed method predicted smaller regions than U-Net, and it was easy to omit small objects.

4. Discussion and summary

Our method gave a better Dice score than U-Net, while this method tended to predict smaller regions, and many infected small regions were not correctly segmented. We thought the masked loss function imposes little loss on small objects.

Considering the blurred boundary problem in the COVID-19 segmentation task, we applied masked dice loss to a semi-supervised method. We obtained a dice score of 0.730 in the experiment. Future




Fig. 1 Overall framework of our work, where y_t , x_l , x_u , and B are ground truth slice, labeled axial CT slice, unlabeled axial CT slice, and extracted boundary. In training phase, U-Net 1 and U-Net 2 predict infected regions of x_l and x_u . Masked supervised loss L_s^1 and L_s^2 are used given labeled input CT slice for training and loss L_{cps} is used for given unlabeled input CT slice for training. U-Net 1 and U-Net 2 are optimized by these losses. In test phase, U-Net 1 gives prediction result of test axial CT slices. Black arrows are data transfer. Red arrows represent parameter updates.

work includes developing a better mask to improve the segmentation performance of small infected regions and developing a new evaluation method to show the improvement.

Acknowledgement

Parts of this research were supported by the AMED Grant Numbers 181k1010028s0401, JP191k1010036, JP201k1010036, JP201k10100-25, the NICT Grant Number 222A03, the JST CREST Grant Number JPMJCR20D5, and the MEXT/JSPS KAKENHI Grant Numbers 26108006, 17H00867, 17K20099 and 21K19898. We used the Japan Medical Image Database (J-MID) created by the Japan Radiological Society with support by the AMED Grant Number JP201k1010025.

Competing interests

None

References

- [1] Fang Y, Zhang H, Xie J et al: Sensitivity of Chest CT for COVID-19: Comparison to RT-PCR. *Radiology* 296: E115-E117, 2020
- [2] Chassagnon G, Vakalopoulou M, Battistella E et al: AI-driven quantification, staging and outcome prediction of COVID-19 pneumonia. *Medical Image Analysis* 67: 101860, 2021
- [3] Yang D, Xu Z, Li W et al: Federated Semi-Supervised Learning for COVID Region Segmentation in Chest CT using Multi-National Data from China, Italy, Japan. *Medical Image Analysis* 70: 101992, 2021
- [4] Chen X, Yuan Y, Zeng G et al: Semi-Supervised Semantic Segmentation with Cross Pseudo Supervision. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR): 2613–2622, 2021
- [5] Milletari F, Navab N, Ahmadi S et al: V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation. 2016 Fourth International Conference on 3D Vision (3DV): 565-571, 2016

Table 1 Quantitative comparison with U-Net

	Dice score	Sensitivity	Precision
U-Net	0.716	0.693	0.769
Proposed Method	0.730	0.723	0.755




Fig. 2 Segmentation results, where red regions are infected regions.

光コヒーレンストモグラフィ画像からの3次元血管構造の抽出

岡村 宙輝^{*1}, 岡本 尚之^{*1}, 羽石 秀昭^{*2}^{*1} 千葉大学大学院融合理工学府基幹工学専攻医工学コース^{*2} 千葉大学フロンティア医工学センター

Extraction of 3D vascular structure from optical coherence tomography images.

Hiroki OKAMURA^{*1}, Takayuki OKAMOTO^{*1}, Hideaki HANEISHI^{*2}^{*1} Department of Medical Engineering, Graduate School of Science and Engineering,
Chiba University^{*2} Center for Frontier Medical Engineering, Chiba University.

要旨: 微小循環は $100\ \mu\text{m}$ 以下の血管径を持つ血管から構成され、生命維持に重要な機能を持つ。それゆえ、その3次元構造の可視化は疾患の状態把握に有用である。表層付近の微小血管の血管強調像は、被写体の断層像を取得できる光コヒーレンストモグラフィを用いることで得られる。しかし、血管強調群には体動によるノイズや、実際の血管領域よりも深さ方向に尾を引いたアーチファクトも含まれる。そこで本研究では、血管強調像群から正確な3次元血管構造を抽出することを目標とする。提案手法では、まず3次元血管強調像群の深さ方向の最大値投影図を作成する。次に最大値投影図における血管の連続性に注目してシード点を自動で設定し、領域拡張を行う。結果として、提案手法が体動によるノイズの低減に有用であることを確認した。

キーワード: 微小循環, 光コヒーレンストモグラフィ, 3次元可視化

1. はじめに

微小循環とは細動脈, 毛細管, 細静脈など $100\ \mu\text{m}$ 以下の血管径を持つ血管の総称である。この領域では栄養素や組織からの代謝老廃物, 熱エネルギーなどの交換といった生命維持に重要な活動が行われており, 構造の可視化は疾患の状態把握や機序解明に有用である。被写体の断面を撮影できる光コヒーレンストモグラフィ(OCT: Optical coherence tomography)を用いることで, 微小循環の3次元構造を把握することが可能である。OCTは数 μm 単位の高い空間分解能を持ち, 非侵襲的に撮影を行えることから, 眼科や皮膚科, 歯科などの幅広い分野で臨床応用されている。さらに, 被写体の断面の画像(断層像)を同じ位置で複数フレーム撮影し, 赤血球の移動に起因するフレーム間の画素値変化を定量化することで, 血管領域のコントラストを高めることが可能である。当研究室ではOCT撮影領域の全断面で, Speckle Variance (SV) 法^[1]を適用することで, 3次元の血管強調像群を取得した^[2]。しかし, 血管強調結果には体動によるノイズや, 実際の血管領域よりも深さ方向に尾を引いたノイズ (TA: Tailing Artifact) も含まれる。本研究では血管強調像群に対して, 体動によるノイズを除去する手法を検討した。

2. 使用データ

撮影対象をマウス (C3H, 雄, 10週齢) の背部真皮の微小循

環として, 断層像群を取得した。撮影領域は, $4.0 \times 4.0 \times 2.0\ \text{mm}^3$, 画像サイズは $1024 \times 1024\ \text{pixels}$, フレームレートは $30\ \text{fps}$ である。各断面で時間が異なる断層像を5枚ずつ取得した。撮影領域全体で1024断面を撮影し, 計5120枚の断層像群を取得した。

3. 手法

断層像群の各断面でSV法を適用し, 組織領域のみをマスクすることで血管強調像を作成する(図1)。組織領域を決定する際にはFCN (Fully Convolutional Network) ^[3]を用いて断層像から組織表面の位置を推定し, 組織表面から断層像の縦幅の1/4の深さまでを対象の組織領域とした。図1の処理を断層像群の全断面で行うことで, 血管強調像群を作成した。次に血管強調像群に対してシード点を自動で設定し, 各XZ断面で領域拡張を行うことで体動によるノイズを除去した。処理の流れを次に示す。

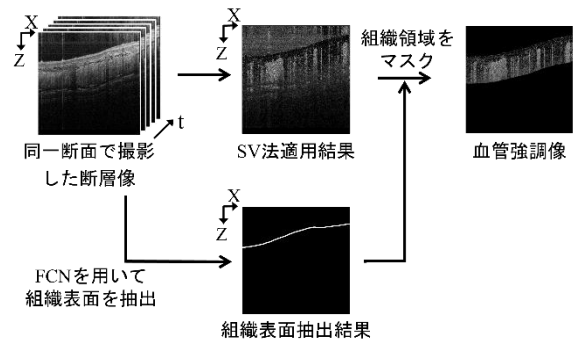


図1 各断面における血管強調処理

*1 〒263-8522 千葉市稲毛区弥生町 1-33

e-mail: h_okamura@chiba-u.jp

- A) 最大値投影図から血管構造の中心線を取得
- B) シード点の設定
- C) 各 XZ 断面で 2 次元の領域拡張を実施

A) ではまず Z 軸方向の最大値投影図を取得する (図 2)。最大値投影図の血管構造を利用することで、深さ方向に伸びた TA の影響を受けずに、XY 軸平面における血管の連続性に注目することが可能である。最大値投影図から血管抽出を行う際には、血管強調フィルタ^[4]を適用したのちにグラフカットを行う。グラフカットとはラベリングの不適合さを表すエネルギー関数が、最小となるラベリングを探索する手法である。グラフカットを用いて血管抽出を行ったのちに、Zhang-Suen の細線化アルゴリズム^[5]によって血管構造の中心線を取得する。

B) では中心線上の全画素でシード点を設定する。シード点の深さ上の位置は、血管強調像群から中心線と垂直な断面 (図 3) を取得し、深さ方向の情報を参照して決定する。具体的には中心線と垂直な断面に対して円形カーネルを設定し、中心線の列を深さ方向に移動しながらカーネル内の画素値の平均を算出する。このとき、画素値の平均が最も大きくなる位置をシード点の深さとする。

C) では全シード点の 3 次元座標を決定したうえで、血管強調像群の全 XZ 断面で 2 次元の領域拡張を行う。




図 2 最大値投影図の取得




図 3 中心線と垂直な断面




図 4 結果の 3 次元表示
(a) 血管強調像群 (b) 領域拡張結果

4. 結果

撮影で取得した断層像の全断面で血管強調処理を適用した結果を図 4 (a) に、血管強調像群に対して提案手法を適用した結果を図 4 (b) に示す。なお、図 4 はどちらもボリュームレンダリングによる 3 次元表示を Z 軸方向の上から見下ろす図である。図 4 (a) では画像全体に体動によるノイズが存在するが、図 4 (b) では除去できたことがわかる。しかし、TA が残存していることも確認した。原因として TA と実際の血管領域が連続しており、画素値が同程度であることが考えられる。

5. まとめ

OCT 断層像に対して血管強調を行った結果から、領域拡張を用いて体動によるノイズを除去する処理を実装した。結果から、提案手法を適用することで体動によるノイズを除去し、血管の連続性を考慮して TA と実際の血管を含む領域をセグメンテーションできるとわかった。正確な 3 次元血管構造を抽出するには、TA を除去する必要がある。よって今後の方針として領域拡張の結果から血管径を推定し、TA を含む領域から正確な血管領域を抽出する処理を検討する。

利益相反の有無

なし

文献

- [1] A. Mariampillai, B. A. Standish, *et al*: Speckle variance detection of microvasculature using swept-source optical coherence tomography. *Opt. Lett.*, 33, 12, 1530-1532, 2008.
- [2] 立川華子, 中野和也 他: SDF-OCT による微小循環観察環境の構築と血管画像解析. *信学技報*, 119, MI2019-18, 3-6, 2019.
- [3] J.Long, E. Shelhamer, and T. Darrell: Fully convolutional networks for semantic segmentation. *IEEE CVPR*. 2015, 3431-3440, 2015.
- [4] A. F. Frangi, W. J. Niessen, *et al*: Multiscale Vessel Enhancement Filtering. *MICCAI*. 1998, 130-137, 1998.
- [5] T. Y. Zhang and C. Y. Suen, A fast parallel algorithm for thinning digital patterns. *Communications of the ACM*, 27, 3, 236-239, 1984.

ヒト胚子の脳の空間的に隣接する複数器官を対象とした統計的形状モデル

近嵐 尚^{*1}, 高桑 徹也^{*2}, 山田 重人^{*2}, 清水昭伸^{*1}^{*1} 東京農工大学大学院工学研究院^{*2} 京都大学 大学院医学研究科

Statistical shape model of multiple neighboring organs of embryonic human brains

Nao CHIKAARASHI^{*1}, Tetsuya TAKAKUWA^{*2}, Shigehito YAMADA^{*2}, Akinobu SHIMIZU^{*1}^{*1} Institute of Engineering, Tokyo University of Agriculture and Technology^{*2} Graduate School of Medicine, Kyoto University

要旨：本報告では、ヒト胚子の脳の空間的に隣接する複数器官を対象とした統計的形状モデルの構築法について報告する。ヒト胚子の脳の5器官（大脳，間脳，中脳，後脳吻側部と小脳，後脳尾側部）は空間的に連続し、隣り合う器官同士は接している。従来の複数器官を対象とした統計的形状モデルでは、器官同士の「重複」や隣接する器官の間に隙間（背景）が存在する「分離」が発生してしまう。そこで、複数の Level Set Function (LSF) の符号の組み合わせ (Multiphase Level Set: Multiphase LS) を利用した器官表現を用い、器官の大きさに関する制約を加えながら器官間の重複、分離を防ぐ方法を提案する。本研究では、提案手法を京都コレクションのヒト胚子・脳の形状ラベルに適用して、従来の手法で構築した統計的形状モデルとの比較により、提案手法の有用性について議論する。

キーワード：ヒト胚子，統計的形状モデル，Multiphase Level Set，Principal Component Analysis

1. はじめに

妊娠3-9週の胚子期は器官形成期であり、先天異常の発生頻度が高く、重要な時期である[1]。新生児の死亡原因の25%が先天奇形によることが知られており[2]、形態異常については出生前に画像を用いて診断できることがある。この診断には正常群を対象とした統計モデルが有用であると考えられ、著者らはこれまで、ヒト胚子の脳の入れ子構造、非重複構造を対象としたモデルを構築した[3,4]。文献[3]では、器官同士の入れ子の位置関係を制約とし対数変換を用いることで内側の器官の外側へのはみだしを防止した (Log Transform-Level Set Function; LT-LSF)。文献[4]では器官が隣接する構造の非重複制約 (LT-LSF with Non-Overlapping Constraint; LT-LSF with NOC) も提案している。しかし、空間的に連続する複数器官に対して適用した場合、不自然な分離や重複を完全に防ぐことができない問題が残されていた。

本研究では、従来の LT-LSF with NOC に加えて Multiphase Level Set (Multiphase LS)[5] による器官表現と LSF の器官の大きさに関する制約を導入し、空間的に連続した複数器官の構造に適した統計的形状モデルの構築法を提案する。

2. 先行研究

2.1 LT-LSF with NOC [4]

領域 $S_i (i = 1, 2)$ の LSF を $\phi_i(\mathbf{r})$ とする。この二つの領域が重ならないのは、式(1)を満たす時である。これを制約条件とすることで二つの LSF 間の非重複が実現できる。

$$\phi_1(\mathbf{r}) + \phi_2(\mathbf{r}) > 0 \quad (1)$$

ここで、この式を満たす LS の組み合わせは 2次元実数平面

^{*1} 東京農工大学大学院工学研究院

〒184-8588 東京都小金井市中町 2-24-16]

e-mail : s226680u@st.go.tuat.ac.jp

^{*2} 京都大学 大学院医学研究科

〒606-8507 京都府京都市左京区聖護院川原町 53]

(\mathbb{R}^2) 全体ではない。そのため、 $\phi_i(\mathbf{r})$ を直接 PCA 等でモデル化しても制約を満たさない組み合わせが発生する。そこで、式(2)を用いて対数変換し、変換後の特徴量 X をモデル化する。この方法であれば、制約空間の領域が実数全体に拡張されベクトル空間となるため、制約を満たさない例は発生しない。

$$X = \log(\phi_1(\mathbf{r}) + \phi_2(\mathbf{r})) \quad (2)$$

しかし、空間的に連続する複数の器官をモデル化した場合、非重複制約 (non-overlap constraint; NOC) は実現できても隙間 (いずれの器官にも属さない背景の領域) が発生する。

2.2 Multiphase LS[5]による領域表現

図1のように n 個の LSF の符号を組み合わせることで、最大で $2n$ 個の領域を表現できる。この方法を用いることで、空間的に連続する複数の器官を隙間なくモデル化することができる。

しかし、一つ離れた LS 同士が重複することがある。




図1 Multiphase LS による領域表現

3. 提案手法：器官表現と制約条件

2.2 の Multiphase LS に 2.1 の NOC と対数変換を導入する。

また、NOC を拡張した体積制約 (Volume Constraint: VC) も導入する。これらにより、空間的に連続する

複数の器官を隙間なくモデル化し、一つ離れた LS 同士の不自然な重複を防止し、かつ、二つの LS が重なる領域の大きさに制約




図2 Multiphase LS による5器官表現

を与える。

今回は図2のように3つの領域のLSF($\phi_1(\mathbf{r})$, $\phi_2(\mathbf{r})$, $\phi_3(\mathbf{r})$)の符号の組み合わせを用いて5器官を表現する。ここで、 V_b, V_d の領域はLSFが重なるときであり、ここにVCを適用する。具体的には、以下の式(3)を用いるが、この ε を適切に設定することで器官が大きくなりすぎないように制約を与える。

$$\phi_1(\mathbf{r}) + \phi_2(\mathbf{r}) + \varepsilon_1 > 0 \quad (3)$$

2つのVCと1つのNOCを適用した場合の対数変換後の特徴量は式(4)で与えられる。

$$\begin{cases} X_1 = \log(\phi_1(\mathbf{r}) + \phi_2(\mathbf{r}) + \varepsilon_1) \\ X_2 = \log(\phi_2(\mathbf{r}) + \phi_3(\mathbf{r}) + \varepsilon_2) \\ X_3 = \log(\phi_1(\mathbf{r}) + \phi_3(\mathbf{r})) \end{cases} \quad (4)$$

4. 実験条件と実験結果

4.1 実験条件

本研究は京都大学大学院医学研究科・医学部及び医学部附属病院・医の倫理委員会(R0316-3, R0347-3)と東京農工大学倫理委員会(No.210503-0307)によって承認された。実験試料は、京都大学が所蔵する京都コレクション[6]から、ヒト胚子17体の大脳、間脳、中脳、後脳吻側部+小脳、後脳尾側部の全5器官のラベル画像を使用した。モデルの評価は、Generalization[7], Specificity[7], Overlap(G/S), 不要成分数(G/S)の4を用い、2-fold Cross Validation法を採用した。Generalizationは未知症例を再現する能力、Specificityは不自然な標本を排除する能力を表し、どちらも高いほど精度が良いことを示す。Overlap(G/S)は隣接器官同士と1つ離れた器官同士の不自然な重なり割合、不要成分数(G/S)はラベルの主要成分以外の成分数を表す評価値であり、どちらも低いほど精度が良いことを示す。GeneralizationとSpecificityを求める過程で生成された形状に対して計算した。また、一つの器官を一つのLSFで表現する従来の手法として、隣り合う器官同士にNOCを4つ適用したモデルNOC(4)、隣り合う器官、一つ離れた器官にNOCを7つ適用したモデルNOC(7)を比較対象とした。なお、Specificity(S), Overlap(S), 不要成分数(S)はNOC(4)のみ比較する。

4.2 実験結果

5器官の平均のGeneralizationとSpecificityを図3に示した。また、各器官間のOverlap(G/S)を平均した結果を図4、不要成分数(G/S)を図5に示した。

図3では、Generalization, Specificityが共に提案手法にお




図3 各手法によるGeneralizationとSpecificity (箱ひげ図上部の数値: 全症例平均値)

いて向上していた。

図4より提案法では器官同士の重なりが全く生じていないが、その一方でNOC(4), NOC(7)では重なりが見られる。また、図5から不要成分数も提案法が最も小さくなっていることが確認できる。これらの結果、GeneralizationとSpecificityが向上したと考えられる。しかし、図6のような不自然な形状が発生した。

5. まとめ

本研究では、Multiphase LSに非重複制約と体積制約を適用し対数変換をすることで空間的に連続した複数器官のモデルの構築を可能とした。今後は不自然な形状の発生しないモデルの構築を検討する。

謝辞

本研究の進行にあたり熱心にご指導・ご議論いただいた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

文献

- [1] R.F.Gasser:ATLAS OF HUMAN EMBRYOS. Haper and Row, New York, 1975.
- [2] B.S. de Bakker, K.H. de Jong, J. Hagoort et al:An interactive three-dimensional digital atlas and quantitative of human development. Science, Vol.354:No.6315, 2016.
- [3] Atsushi Saito, Masaki Tsujikawa, et al:Level set distribution model of nested structures using logarithmic transformation. Medical Image Analysis 56:1–10,2019
- [4] 辻川政樹:ヒト胚子の複数器官を対象とした時空間統計モデル. 東京農工大学大学院修士学位論文, 2019
- [5] Luminita A. Vese, Tony F. Chan:A Multiphase Level Set Framework for Image Segmentation Using the Mumford and Shah Model. International Journal of Computer Vision 50(3):271–293, 2002
- [6] Y. Yamaguchi, S. Yamada:The Kyoto Collection of Human Embryos and Fetuses: History and Recent Advancements in Modern Methods. Cells Tissues Organs: 2018
- [7] M.A. Styner, K.T. Rajamani, L.P. Nolte et al:Evaluation of 3D Correspondence Methods for Model Building. Information Processing in Medical Imaging, Vol.18: pp.63-75, 2003.




図4 各手法によるOverlap(G/S) (箱ひげ図上部の数値: 全症例平均値)




図5 各手法による不要成分数(G/S) (箱ひげ図上部の数値: 全症例平均値)




図6 スライス画像 (左: テストデータ, 右: 提案手法による再構成画像)

白質信号自動解析の再現性に関する評価

高橋 哲彦^{*1}, 大川 竜也^{*1,*2}, 林 則夫^{*1}, 丁嵐 亮^{*1}

^{*1} 群馬県立県民健康科学大学大学院 診療放射線学研究科

^{*2} 脳血管研究所附属美原記念病院 画像診断課

Evaluation of Reproduction on Automated White Matter Signal Intensity Analysis

Tetsuhiko TAKAHASHI^{*1}, Ryuya OKAWA^{*1,*2}, Norio HAYASHI^{*1}, Ryo ATARASHI^{*1}

^{*1} Graduate School of Radiological Technology, Gunma Prefectural Collage of Health Sciences

^{*2} Department of Diagnostic Imaging, Mihara Memorial Hospital

要旨 : FLAIR 画像を用いて白質高信号領域 (WMH) を自動抽出し体積を計算する診断支援アプリケーションの開発が進んでおり従来のグレード判定と比べて詳細な臨床情報が期待されている。一般に WMH の体積は健常例～低グレードでは小さく、高グレードで大きい。臨床では高グレードが重要なため、定量解析の再現性評価にはある程度の WMH 体積の症例が望ましい。そこで、本研究では、検査済み臨床データを活用して再現性を評価した。

共同研究施設にて、2001 年から 2020 年までに頭部 MRI 検査で撮像した FLAIR 画像 900 例に対して、臨床所見が「白質虚血性変化あり」でかつ 2 回以上同一の磁場強度 (3 T) の MRI で検査した患者を抽出した。抽出画像に自動解析を適用し、白質の高信号領域の体積を求め、結果を統計的に解析した。(倫理委員会承認済)

抽出した症例は 34 組 68 例であった。統計解析の結果、抽出体積 1.96 cc～101.6 cc の範囲で、誤差は+14.7 cc, -7.5 cc であった。

キーワード : 白質病変, MRI, FLAIR, 自動解析

1. はじめに

FLAIR (fluid attenuated inversion recovery) 画像を用いて白質高信号領域 (WMH: white matter hyperintensity) を自動的に抽出し体積を計算する診断支援アプリケーションの開発が進んでおり、従来のグレード判定 (Fazekas 分類、脳ドック学会の分類など) と比べて詳細な臨床情報の提供が期待されている[1,2].

一般に WMH の体積は健常例～低グレードでは小さく、高グレードで大きい。また臨床では高グレードの WMH が重要なため、定量解析の再現性評価はある程度の WMH 体積を有する症例を使うことが望ましい。そこで、本研究では、疾患のある検査済み臨床データを活用して再現性の評価を行ったので報告する。

2. 方法

共同研究施設にて、2001 年 1 月から 2020 年 10 月までに頭部 MRI 検査で撮像した FLAIR 画像 900 例に対して、臨床所見が「白質虚血性変化あり」でかつ 2 回以上同一の磁場強度 (3 T) の MRI で検査した画像を抽出した。抽出した画像に白質信号解析ソフトウェアを適用した。解析ソフトウェアは、富士フイルムヘルスケア (株) の研究用ソフトウェアである。ソフトウェアの概要を図 1 に示す。図 2 は解析例で、代表的なスライスの元画像と抽出部位を重ね合わせ表示した結果およびスライス毎の抽出体積を示している。

本ソフトウェアを使って対象とする画像の白質の高信号領

域を自動抽出しその体積を求め、結果を統計的に解析した。

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承認済である。




図 1 自動解析ソフトウェアの概要




図 2 自動解析ソフトウェアを使った解析例

3. 結果と考察

抽出した症例は、男女 17 例計 34 例、2 検査の合計は 68 例であった。検査時の平均年齢は 1 回目 72.8 歳 (分散 11.1 歳)、2 回目 74.9 歳 (分散 9.94 歳)、平均検査間隔は 739 日 (分散 968 日) であった。

自動解析による平均抽出体積は、1 回目検査で 18.3 cc (分散 18.0 cc)、2 回目検査で 22.0 cc (分散 19.5 cc) であった。

1 回目と 2 回目の検査結果に対して Shapiro-Wilk の正規化検定を行い、2 変数差の変数が正規分布していないことから Wilcoxon 検定を行った。その結果、1 回目と比べ 2 回目の体積が若干大きくなる傾向があり、 $p < 0.01$ で有意差があった (図 3)。1 回目と 2 回目の検査結果の相関は良好であった ($R = 0.93$) (図 4)。Bland-Altman プロットでは、抽出体積 1.96 cc ~ 101.6 cc の範囲で、有意差は 3.64cc、誤差は +14.7 cc, -7.50 cc であった (図 5)。有意差は、1.79cc/年に相当し年令に伴う WMH の増加と思われた [3]。誤差の要因として元画像の画質の影響などが考えられた [4]。




図 3 1 回目検査と 2 回目検査の WMH 体積比較
*有意差あり ($p < 0.01$)




図 4 1 回目検査と 2 回目検査の WMH 体積の相関




図 5 1 回目検査と 2 回目検査の WMH 体積の Blend-Altman Plot

4. まとめ

白質病変ありの臨床データを用いて、WMH の抽出体積の再現性を調べた。再現性は良好であった。

謝辞

研究用 FLAIR 信号解析ソフトウェアを貸与いただいた、尾藤良孝氏、岩田吉広氏、仲山貴行氏 (富士フィルムヘルスケア社) に、感謝いたします。

利益相反の有無

なし。

文献

- [1] Park, K, Nemoto, K, Yamakawa, Y et al: Cerebral white matter hyperintensity as a healthcare quotient: J.Clin.Med.8:1823, 2019. doi: 10.3390/jcm8111823.
- [2] 一般社団法人 日本脳ドッグ学会「脳ドッグのガイドライン」改訂・第 5 版, p.34, 38(2019)
- [3] Vangberg, T. R, Eikenes, L, Håberg, A. K: The effect of white matter hyperintensities on regional brain volumes and white matter microstructure, a population-based study in HUNT: NeuroImage, 203, 116158, 2019. Epub 2019 Sep 4. doi: 10.1016/j.neuroimage.2019.116158.
- [4] 丁嵐亮, 高橋哲彦, 林則夫 他. 「白質信号自動解析における FLAIR 画像 SNR の影響」日本放射線技術学会第 78 回総会学術大会 (2022.4, 横浜)

大規模 CT 画像データベースを用いた骨格ランドマークによる 下肢骨格形状の加齢変化解析

下元 悠我^{*1}, 箱谷 知輝^{*1}, 大竹 義人^{*1}, スーフィー マーゼン^{*1}, 政木 勇人^{*1},
上村 圭亮^{*2}, 高尾 正樹^{*3}, 宮本 拓馬^{*4}, 田中 康仁^{*4}, 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} 奈良県立医科大学 〒634-8521 奈良県橿原市四条町 840 番

Analysis of Aging Changes in Lower Limb Skeletal Geometry by Skeletal landmarks Using a Large CT Image Database

Yuga SHIMOMOTO^{*1}, Tomoki HAKOTANI^{*1}, Yoshito OTAKE^{*1}, Mazen SOUFI^{*1},
Yuto MASAKI^{*1}, Keisuke UEMURA^{*2}, Masaki TAKAO^{*3}, Takuma MIYAMOTO^{*4},
Yasuhito TANAKA^{*4}, Nobuhiko SUGANO^{*2}, Yoshinobu SATO^{*1}

^{*1}Nara Institute of Science and Technology 8916-5, Takayama, Ikoma, Nara, 630-0192, Japan

^{*2}Osaka University Graduate School of Medicine 2-2, Yamadaoka, Suita, Osaka 565-0871, Japan

^{*3}Ehime University Graduate School of Medicine 791-0295, Shitsukawa, Toon, Ehime, Japan

^{*4}Nara Medical University 840, Shijomachi, Kashihara, Nara, 634-8521, Japan

要旨: 人体に忠実な全身骨格モデルは、人体の骨格構造解析や動作解析において重要である。現在、骨格の表現方法の一つとして、複数人の臓器の形状データを統計的に解析した統計形状モデル (SSM) が用いられている。しかし、従来研究では一部の骨格形状のみの SSM を構築しており、全身骨格の構築は行われていない。そのため、我々は日本医学放射線学会が収集している J-MID データベースと、共同研究施設で収集する 4 万症例以上の大規模な CT データベースを用いた全身骨格の SSM 構築を目指している。本研究ではその第一歩として、下肢 (骨盤から足部まで) の大規模 CT 画像データベースから骨格上のランドマークを抽出し、そのランドマークを用いて下肢骨格の解析を行った。下肢のランドマークデータを年齢・性別ごとに分け、骨格形状の加齢変化について調査を行ったので報告する。

キーワード: 大規模 CT データベース, 解剖学的ランドマーク, 変形性股関節症

1. はじめに

変形性股関節症は、股関節を形成している関節軟骨や骨が傷んでしまう事によって、股関節痛や機能障害を引き起こす病態である。先行研究では、変形性股関節症の患者における下肢の様々なパラメータを測定しており、その中でも股関節・膝・足首の三点を結んだ線の角度である HKA 角は、変形性股関節症と関連があることが示されている [1]。また、骨盤の傾斜角 (PT) と股関節の病変との関連性も示唆されている [2]。しかし、HKA 角と PT の関係性を年齢・性別ごとに調査する研究は行われていない。

人体の骨格構造解析の方法として、解剖学的特徴点 (ランドマーク) を使用する方法がある。これまでランドマークの自動抽出に関する方法が様々な提案されてきた [3]。そして、我々はこれまでに畳み込みニューラルネットワーク (CNN) を用いた骨盤領域 CT 画像からのランドマークの自動抽出方法を提案した [4]。また、我々は日本医学放射線学会が収集している J-MID データベースと、共同研究施設で収集する 4 万症例以上の大規

模な CT データベースを所有している。そこで、本稿ではランドマークの自動抽出手法を用いて、所有するデータの内、変形性股関節症患者のデータから下肢のランドマークを自動抽出し、年齢・性別ごとの HKA 角と PT を測定する。その結果から変形性股関節症における HKA 角と PT の年齢・性別との関係性について解析することを目的とする。

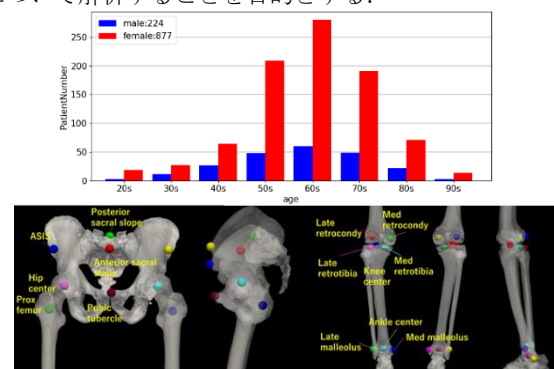


図 1. 使用データの年齢, 性別の内訳 (上) とランドマーク位置 (下)

2. データセット

本研究で用いた CT 画像は、大阪大学病院で撮影された変形性股関節症患者の画像である。患者数は男性 224 例、女性 877 例の計 1101 例である。ランドマークとして左右の大腿骨頭中心、上前腸骨棘、仙骨上面、恥骨結合の 7 点と、下肢大腿骨、膝関節、足関節領域の 18 点の計 25 点を抽出した。使用したデータの内訳とランドマーク位置を図 1 に示す。

3. 実験内容

ランドマークを自動抽出する手法 [3, 4] を用いてランドマークを抽出し、各指標の測定を行った。今回測定した指標は、PT と HKA 角である。PT, HKA 角は各年齢・性別ごとにランドマークを用いて測定し、その平均を求めた。

ランドマークの抽出は骨盤領域と下肢領域でそれぞれ別の手法を用いた。学習データは、骨盤領域では変形性股関節症患者 100 例（男性 26 例、女性 74 例）を使用し、下肢領域では変形性股関節症患者 194 例（男性 44 例、女性 150 例）を使用した。精度検証として 4-fold 交差検証を行った。骨盤領域では [4] の手法で学習し、抽出精度は SDR (4mm) 平均が 83.43% であった。下肢領域では [3] の手法で学習し、抽出精度は SDR (4mm) 平均が 63.97% であった。

4. 実験結果および考察

PT, HKA 角の測定結果を図 2 に示す。PT の測定結果では、男女共に年齢が増すごとに骨盤が後傾する傾向が見られた。また、男性より女性の方がその傾向がより顕著であることが分かった。HKA 角の測定結果では、男女共に年齢が増すごとに内反する傾向が見られた。また、女性より男性の方がその傾向がより顕著であることが分かった。女性の PT と HKA 角の相関については、相関係数が 0.32 であったことから、PT と HKA 角には相関が見られなかった。

男性の PT, HKA 角平均はそれぞれ 2.8 ± 7.2 , -5.4 ± 2.9 であり、女性の PT, HKA 角平均はそれぞれ 4.6 ± 7.7 , -3.4 ± 2.8 であった。この結果は PT と HKA 角について報告している以前の研究結果と類似した結果であった。 [1, 5]

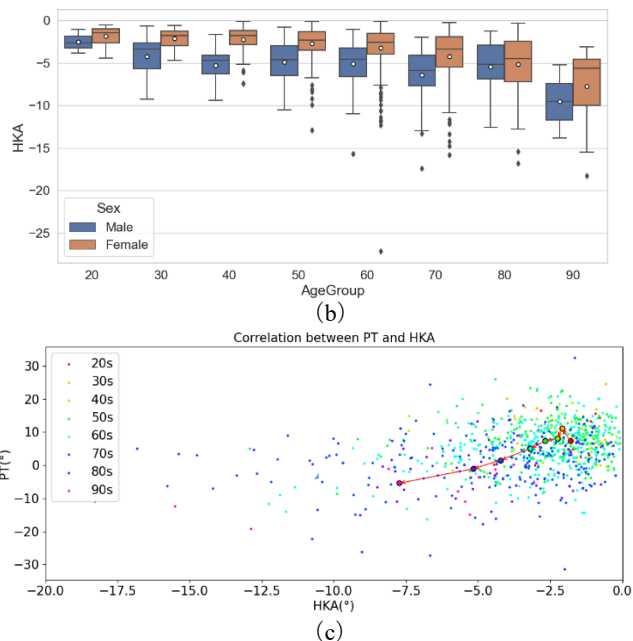



図 2. 男女別の下肢骨格 PT と HKA 角の加齢変化。(a) PT 測定結果。(b) HKA 角測定結果。(c) 女性の PT および HKA 角の散布図。矢印は各年齢の平均値の推移を表す。

5. まとめ

本研究では、自動抽出した解剖学的特徴点を用いて年齢・性別による PT と HKA 角の傾向、関係性について調査を行った。実験結果として、男女間・年齢間で顕著な違いが見られた。

今後はよりデータ数を増強すると共に、体幹部のランドマーク解析も行い、年齢・性別による違い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] Ramazanian T, Yan S, Rouzrokh P et al: Distribution and Correlates of Hip-Knee-Ankle Angle in Early Osteoarthritis and Preoperative Total Knee Arthroplasty Patients. J Arthroplasty 37: 170-175, 2022
- [2] 土井口祐一, 岩崎勝郎, 山田健治 他: X 線学的骨盤腔形態と骨盤傾斜角. 整形外科と災害外科 41: 641-645, 1992
- [3] Xie E, Wan W, Yu Z et al: SegFormer: Simple and efficient design for semantic segmentation with transformers. Advances in Neural Information Processing Systems 34, 2021
- [4] 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
- [5] Blondel B, Parratte S, Tropiano P et al: Pelvic title measurement before and after total hip arthroplasty

テンソル分解を用いた黒質緻密部の 3 次元パターン表現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}, 服部 信考^{*3}, 鎌形 康司^{*3},
青木 茂樹^{*3}, 森 健策^{*1,2,4,5}

^{*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} 順天堂大学 医学部

^{*4} 名古屋大学 情報基盤センター

^{*5} 国立情報学研究所 医療ビッグデータ研究センター

Preliminary Study of Tensor-Decomposition-Based 3D Pattern Representation for Substantia Nigra Analysis

Hayato Itoh^{*1}, Masahiro Oda^{*2,1}, Shinji Saiki^{*3}, Nobutaka Hattori^{*3}, Koji Kamagata^{*3},
Shigeki Aoki^{*3}, Kensaku Mori^{*1,2,4,5}

^{*1} Graduate School of Informatics, Nagoya University

^{*2} Information and Communications, Nagoya University

^{*3} School of Medicine, Juntendo University

^{*4} Information Technology Center, Nagoya University

^{*5} Research Center for Medical Bigdata, National Institute of Informatics

要旨：黒質緻密部の 3 次元パターン表現に関する初期的検討について報告する。黒質緻密部における神経細胞の減少はパーキンソン病疾患において観察される特徴のひとつである。この黒質緻密部の変化は T2 強調画像や神経メラニン強調画像を介して捉えることができ、黒質緻密部の左右差や体積の減少として観察できると報告されている。一方で、得られた画像データを用いて黒質緻密部の 3 次元パターンの変化を計算機上で解析するためには、何らかの特徴表現が必要となる。本稿では黒質緻密部の神経メラニン MRI の信号強度比をテンソルにて表し、これらテンソルの分解に基づいた特徴表現を提案する。提案した特徴表現にて健常者・パーキンソン病患者のパターン分布を調査した結果、2つのクラスで異なる分布を表現できていることを確認した。

キーワード：パーキンソン病, 黒質緻密部, 神経メラニン強調画像, 特徴表現, CP (CANDECOMP/PARAFAC)分解

1. はじめに

人体における 3 次元構造の抽出ならびに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、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はパーキンソン病の診断の一環として知られているが、観察のためには黒質緻密部の精確な抽出が必要となる。黒質緻密部の精確な可視化に向けて神経メラニン強調画像が提案されている一方で、この新しいモダリティに対し、機械学習モデルを用いた黒質緻密部の自動抽出も報告されている[1]。自動抽出に加え、黒質緻密部の経時変化や健常者との差異に関する解析を行うためには、黒質緻密部の形状と信号強度分布から得られるテクスチャの両方を考慮した特徴表現方法が求められる。

本稿では 3 次元パターンのテンソル表現に基づき[2]、黒質緻密部の特徴表現方法について検討する。テンソル表現に基づく分解では、3 次元パターンの形状とテクスチャを同時に取り扱うことが可能である。本稿では神経メラニン強調画像を検討対象とする。

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 $\mathcal{X}_i \in \mathbb{R}^{I \times J \times K}$, $i = 1, 2, \dots, N$ で表す。ここで N_1 と N_2 はそれぞれ健常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 $\mathcal{T} \in \mathbb{R}^{I \times J \times K \times N}$ とする。 $\mathbf{a}_j \in \mathbb{R}^I$, $\mathbf{b}_j \in \mathbb{R}^J$, $\mathbf{c}_j \in \mathbb{R}^K$, $\mathbf{d}_j \in \mathbb{R}^N$ から成る rank-1 テンソルを M 個用いた CP 分解[3,4]は

$$\mathcal{T} = \sum_{j=1}^M \mathbf{a}_j \circ \mathbf{b}_j \circ \mathbf{c}_j \circ \mathbf{d}_j + \mathcal{E} \quad (1)$$

である。 \mathcal{E} と \circ 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 $\mathbf{d}_j = (d_{ji})$ ならびに再構成残差 \mathcal{E}_i を用いて

$$\mathcal{X}_i = \sum_{j=1}^M d_{ji} (\mathbf{a}_j \circ \mathbf{b}_j \circ \mathbf{c}_j) + \mathcal{E}_i \quad (2)$$

と書ける. 式(2)の $d_{ji}, j = 1, 2, \dots, M$ を並べることで \mathbf{x}_i を表す M 次元特徴量ベクトルを得る. 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, 特徴の選択を行う.

各 j に対し, 全ての患者に対する d_{ji} の分散を σ_j とし, 健常者とパーキンソン病疾患者の d_{ji} の平均をそれぞれ, $\mu_{1,j}$ および $\mu_{2,j}$ とすると, クラス間分散は $\sigma_{B,j}^2 = \frac{N_1 N_2}{N^2} (\mu_{1,j} - \mu_{2,j})^2$ であり,

$$\lambda_j = \frac{\sigma_{B,j}^2}{\sigma_j^2 - \sigma_{B,j}^2} \quad (3)$$

は2クラス間の分離度を表す[5]. M 個の d_{ji} のうち分離度 λ_j の大きい L 個を選択して並べ, 特徴量ベクトル $\mathbf{f}_i \in \mathbb{R}^L$ を得る.

3. 数値計算実験

単施設にて収集した73名の健常者と82名のパーキンソン病疾患者の神経メラニンMRIデータを用いた. 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. 各ボリュームデータに対し, 黒質緻密部は信号強度が $[0,1]$ となるように正規化を行い, 黒質緻密部以外のボクセル値を0とした. 抽出した $64 \times 64 \times 64$ ボクセルの神経メラニン強調画像155枚に対して $M = 1000$ として式(1)のCP分解を行い, $L = 100$ として特徴ベクトルを抽出し, L2ノルムによる正規化を行った. 健常者における特徴量ベクトルの平均 \mathbf{f}_μ を求め, \mathbf{f}_μ に対する特徴量それぞれのコサイン類似度[2]を計算した. 図1はコサイン類似度の分布を, 図2はt-SNE[6]を用いた可視化を示す.

4. 考察

図1および2は抽出した特徴量ベクトルが2つのクラスに対して異なる分布を与えることを示す. しかし2つの分布は線形分離不可能である. 2クラス識別において理想的な特徴抽出では, 2クラスの分布に重なりがない, 線形分離可能な分布であることが望まれる. この分布の重なりは, 2つのクラスで共通する特徴が表現されていることに起因する. 大きな分離度を与える d_{ji} を選択してはいるものの, CP分解自体は2つのクラス間のパターンの差を考慮しない分解であるためにこのような特徴表現になると考えられる.

5. まとめ

本稿では黒質緻密部の3次元パターンに関する特徴表現として, CP分解に基づく特徴量ベクトル抽出について初期検討を行った. 従来のCP分解を用いた表現によって3次元パターンの差異を表現できることが判明した. 今後は識別的な特徴量抽出を目的としたテンソル分解法の開発を試みる.




図1 コサイン類似度の分布. HC: 健常者, PD: パーキンソン病疾患者をそれぞれ示す.




図2 特徴量ベクトル分布. 青い●が健常者, 赤い×がパーキンソン病疾患者の特徴量ベクトルの分布を示す.

謝辞

本研究はAMED(No. 21dm0307101h0003)並びに MEXT/JPSP KAKENHI (No. 21K19898)の支援を受けたものである.

利益相反の有無

なし

文献

- [1] Alice L Berre, Koji Kamagata, Yujiro Otsuka, et al.: Convolutional neural network-based segmentation can help in assessing the substantia nigra in neuromelanin MRI. *Neuroradiology* 61: 1387–1395, 2019
- [2] Hayato Itoh, Atsushi Imiya, Tomoya Sakai: Pattern recognition in multilinear space and its applications: mathematics, computational algorithms and numerical validations. *Machine Vision and Applications* 27: 1259–1273, 2016
- [3] Andrzej Cichocki, Rafal Zdunek, Anh Huy Phan, Shunichi Amari: Nonnegative Matrix and Tensor Factorizations: *Applications to Exploratory Multi-way Data Analysis and Blind Source Separation*. Wiley, 2009
- [4] Tamara G Kolda and Brett W. Bader: Tensor decompositions and applications. *SIAM Review* 51(3): 455–500, 2009
- [5] Nobuyuki Otsu: A threshold selection method from gray-level histograms". *IEEE Transactions on Systems, Man, and Cybernetics* 9(1): 62–66, 1979
- [6] Laurens van der Maaten and Geoffrey Hinton: Visualizing Data using t-SNE. *Journal of Machine Learning Research* 9: 2579–2605, 2008

MR マルチスライス撮像におけるパラレルブラインドデノイズングの性能改善

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 Parallel Blind Image Denoising in MR Multi-slice Imaging

Takayuki UEDA ^{*1}, Kazuki YAMATO ^{*1}, Satoshi ITO ^{*1}^{*1} University of Utsunomiya, Graduate Program in Information, Electrical and Electronic Systems Engineering

要旨：MR 画像において構造的特徴の保持と雑音除去性能の両立する雑音除去法が求められている。昨年に隣接するスライス画像間にある密度値の高い相似性と雑音の低い相関性を利用し、重み係数の異なる複数の加算平均画像を作成し、雑音除去後にスライス毎に分離するパラレルデノイズング法を提案した。この方法では加算平均の重み係数は正の値を使用したため、重み係数を変えたことによる雑音分布の変化は僅かであった。本研究では、新たに負の重み係数を使用する。負の重み係数の導入により、1) 一方の雑音の位相が反転するため加算された雑音の分布が大きく変化する、2) 加算平均像は S/N が低下するために深層学習により除去される雑音量が大きくなる、の 2 点により雑音除去効果の改善が期待される。雑音量を未知とするブラインド雑音除去法を適用した結果、画像の鮮鋭さを保ったまま単一画像雑音除去や従来法を顕著に上回る性能を得ることができた。

キーワード：雑音、深層学習、DnCNN

1. はじめに

MRI 装置の高磁界強度化により、信号対雑音比(SNR)の高い画像を取得できるが、高速撮像法・パラレル撮像法のように雑音が多い画像や雑音量が空間的に変化する画像が得られる場合がある。そのため、構造的特徴の保持と高い雑音除去性能を両立する雑音除去法が求められている。MR 画像では、隣接するスライス画像間においてスピン密度分布に相似性があり、一方で雑音は相関が低い。我々はこの性質を利用しスライス画像そのものではなく、スライス画像の重み付き加算画像に対し雑音除去を行う方式を提案した[1]。重み付き加算像は、S/N が高くなっているため、雑音処理による画像の劣化が小さい。また、重み係数を変える操作により雑音の分布が変化するので、非線形の雑音処理法によって雑音の除去程度が変わる。これらの要因から単一画像に雑音除去処理する方法に比べて画像の構造の保存性に優れ、かつ、雑音除去性能を改善できることを明らかにしている[1]。本研究では、加算平均に使用する重み係数に負の値を導入することにより、雑音除去性能のさらなる改善を行うことを目的とする。

2. パラレルデノイズング法の原理

n 枚の隣接スライス画像を使用したパラレルデノイズング




図 1. パラレルデノイズング法の原理図

法は、まず連続スライス画像 $R(r_1, r_2 \dots r_n)$ に、重み係数行列 $A = \{\{a_{11} \dots a_{1n}\}, \{a_{21} \dots a_{2n}\} \dots \{a_{n1} \dots a_{nn}\}\}$ を与えて重み付き加算により、重み付き加算像 $I(i_1, i_2 \dots i_n)$ を得る。

$$I^T = AR^T \quad (1)$$

式(1)で得られた重み付き加算像に、後述する深層学習によるブラインド雑音除去処理 (BDnCNN) を適用し、雑音除去像 $D(d_1, d_2 \dots d_n)$ を得る。

$$D = \text{BDnCNN}(I) \quad (2)$$

式(2)によって取得された雑音除去像を式(1)の逆変換である式(3)によって分離し、スライス位置の画像 P に分離する。

$$P = (A^T A)^{-1} A^T D \quad (3)$$

並列的にブラインド雑音する本手法を ParBlID (Parallel Blind Image Denoising) と称する。本方法の処理の流れを図 1 に示す。

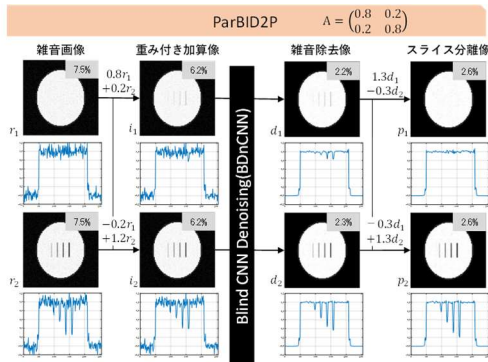
3. DnCNN

DnCNN[2]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、表現の自由度が増す活性化関数、学習効率を高めるための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ことで、雑音除去画像を直接推定する従来法よりも、高い雑音除去性能を持つ[2]。また、学習時に様々な雑音量で学習することで、テスト時に雑音量が未知 (ブラインド) な画像に対しても雑音除去処理をすることができる[2,4]。

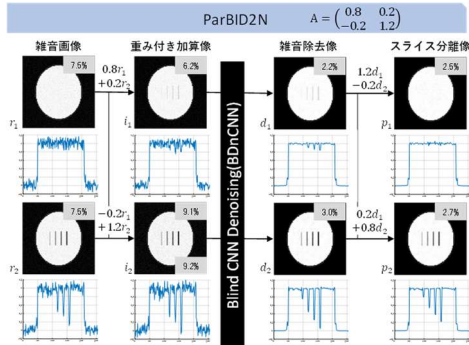
4. 雑音除去シミュレーション実験

4.1 数値ファントムを用いた雑音除去シミュレーション

数値ファントムを用いて雑音除去を行い、雑音量の変化を評



(a) ParBID2P での雑音量の変化



(b) ParBID2N での雑音量の変化

図 2. ParBID における雑音量の変化

価した。重畳雑音は 7.5% のガウス型白色雑音 10 種類とし、2 枚の平行デノイズ法 (ParBID2) において、正の重み係数を使用した ParBID2P と負の重み係数を使用した ParBID2N により雑音除去を行った。使用した重み係数は $A_{2P} = \{ \{0.8 \ 0.2\}, \{0.2 \ 0.8\} \}$ と $A_{2N} = \{ \{0.8 \ 0.2\}, \{-0.2 \ 1.2\} \}$ とした。図 2 に ParBID における 10 種類の平均の雑音量の変化を示す。

負の重み係数を使用して重み付き加算像を得る (図 2-b) と、正の場合 (図 2-a) とは異なり、雑音が増えた形になっている。しかし、BDnCNN による雑音除去処理により正の係数の場合に比べて多くの雑音が除去された結果、スライスに分離された像では残留雑音が減っている。

4.2 MR 画像を用いた雑音除去実験

マルチスライス 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、単一画像雑音除去 (Single), ParBID2, ParBID3P および ParBID3N を比較した。重み係数は、 $A_{2P} = \{ \{0.2 \ 0.8\}, \{0.8 \ 0.2\} \}$, $A_{3P} = \{ \{0.5, 0.3 \ 0.2\}, \{0.2 \ 0.5 \ 0.3\}, \{0.3 \ 0.2 \ 0.5\} \}$, $A_{3N} = \{ \{0.3 \ -0.8 \ 1.0\}, \{0.2 \ 0.6 \ 0.2\}, \{1.0 \ -0.8 \ 0.3\} \}$ を使用した。表 1 に PSNR の評価結果を、図 3 に雑音量 7.5% のときの雑音除去像の例をそれぞれ示す。

表 1 に示すように、評価を行った全ての雑音量に対して ParBID3N が最も高い PSNR を示し、雑音除去性能の改善が示された。図 2-b の実験結果のように、これは負の重み係数を

表 1. PSNR の評価結果[dB]

雑音量	Single	ParBID2	ParBID3P	ParBID3N
雑音量(2.5%)	34.81	34.89	34.94	35.02
雑音量(5.0%)	31.36	31.42	31.41	31.87
雑音量(7.5%)	29.44	29.47	29.40	29.85




図 3. 雑音量 7.5% の像:(a)雑音付加なし, (b)雑音画像, (c)Single, (d)ParBID2, (e)ParBID3P, (f)ParBID3N

使用して得られる低 S/N 画像を、深層学習を利用した高性能な雑音処理の実施により効果的に多くの雑音を除去することが PSNR の改善に寄与したと考える。図 3 を比較すると、詳細構造が保存されていることが確かめられた。低 S/N 画像の雑音処理は一般に構造の劣化が大きくなるが、図 2 の i_2 は一種の差分画像であり、輪郭が強調された画像であるため劣化が抑えられたと考える。

6. まとめ

平行デノイズ法を使用した MR 画像の雑音除去において負の重み係数を使用する場合は、正の重み係数を用いる場合よりも大きな雑音除去性能を持つことが示された。本研究により平行デノイズ法の雑音除去性能を改善する新たな方向性が示された。

謝辞

本研究で用いた MR 画像を提供いただいたキャノンメディカルシステムズ, InformationXtractionfromImages プロジェクトに感謝の意を表します。

利益相反の有無

なし

文献

- [1] T. Sugai et al. : Japanese Society for Magnetic Resonance in Medicine. 10.2463/mrms.mp.2020-0073, 2020
- [2] K. Zhang et al. : IEEE TIP, Vol.26, Issue 7, 2017, 3142-3155
- [3] K. He, X.Zhang et al., IEEE Conference on Computer Vision and Pattern Recognition, 2016, pp770-778
- [4] T. Sugai et al. : Magnetic Resonance in Medical Sciences, Vol.20, No.4, 2021, 410-424

AEは4層構造とし、それぞれはconvolution-ReLu-maxPoolingにより入力画像と同サイズを出力した。フィルターサイズは2×2,初期フィルター数は32チャンネルとした。またU-netは、各4層のエンコーダーとデコーダー対してconvolution-ReLu-maxPoolingを備え、各チャンネルでスキップ接続をした構造とした。フィルターサイズは3×3,初期フィルター数は64チャンネルとした。各学習モデルに対し入力はモーションアーチファクト画像であり、出力画像は入力とペアとなる元画像とした。学習モデルはアーチファクトの出現方向を水平と垂直に分けた画像,および水平と垂直を合わせた画像でそれぞれ学習した。

3) 画質評価指標
 学習データに含まれない642枚のT2強調画像からモーションアーチファクト画像を作成し、補正画像を合成した。補正画像はアーチファクト出現方向と学習モデルとの組み合わせでそれぞれ検証した。補正画像の画質は、体動無しの原画像とのピーク信号対雑音比(Peak signal-to-noise ratio: PSNR)と構造類似性指数(Structural similarity index: SSIM)を計算した[4]。

3. 結果と考察

図2に各学習モデルと学習データのアーチファクト方向に対する補正画像の結果を示す。学習モデルによりアーチファクトは大幅に軽減できている。一方でAEは画像空間分解能が大きく劣化した。U-netとCGANは、解像度を維持しながらアーチファクトが低減された。さらに、トレーニングデータとアーチファクト出現方向が一致しない条件では、画像内に残像が出現しており補正精度が不十分であった。表1および2にSSIMとPSNRの結果を示す。学習モデルとアーチファクトの出現方向が同一であることで、最も高いSSIMおよびPSNRを示したが、水平・垂直データでの学習モデルであってもSSIMは0.9以上となった。水平・垂直データの学習データではU-netおよびCGANでSSIMが約24%および約26%向上し、PSNRが約4.8%および約7.7%向上した。CGANは制約条件とL2ノルム正則化が追加されていることで、モーションアーチファクトを高度に改善でき原画像に違い合成画像を復元できたといえる。

4. 結語

頭部MRI画像のモーションアーチファクトを抑制するため、シミュレーション計算で作成したアーチファクト画像を学習データとしてCGANによるモデルを構築し、その補正効果を他の深層学習モデルと比較評価した。CGANはAEおよびU-netと比較して高い画像再現性が実証され、学習モデルとアーチファクトの出現方向を同一にすることで、最も良好な改善モデルを構築することができた。




図2 各学習モデルによる合成画像の結果。(a) モーションアーチファクトシミュレーション画像と原画像。(b), (c) アーチファクト方向と一致,および不一致した学習モデルの補正画像。(d) 水平と垂直方向のアーチファクト画像を用いた学習モデルによる補正画像。

表1 各学習モデルおよびアーチファクト方向に対するSSIMの結果

	Relationship with training data and motion artifacts direction		
	Consistent	Inconsistent	Both directions
AE	0.848 ± 0.062	0.307* ± 0.044	0.848 ± 0.054
U-net	0.897 ± 0.085	0.396* ± 0.047	0.883 ± 0.079
CGAN	0.925 ± 0.027	0.318* ± 0.056	0.907* ± 0.029

* indicates $p < 0.005$, showing a significant difference to consistent conditions.

表2 各学習モデルおよびアーチファクト方向に対するPSNRの結果

	Relationship with training data and motion artifacts direction		
	Consistent	Inconsistent	Both directions
AE	25.78 ± 1.54 [dB]	22.50* ± 1.17 [dB]	25.63 ± 1.43 [dB]
U-net	29.22 ± 2.26 [dB]	24.00* ± 1.56 [dB]	28.55* ± 2.14 [dB]
CGAN	29.46 ± 2.37 [dB]	22.10* ± 1.30 [dB]	29.02* ± 2.15 [dB]

* indicates $p < 0.005$, showing a significant difference to consistent conditions.

利益相反の有無

なし

文献

- [1] Jose Dolz, et al: 3D fully convolutional networks for subcortical segmentation in MRI: A large-scale study. Neuroimage 170: 456-470, 2018
- [2] P. Isola, et al: Image-to-image translation with conditional adversarial networks. Proc. IEEE Conf. Comput. Vis. Pattern Recognit. 1720-1729, 2017
- [3] 塚本ひかり, 室伊三男: 頭部MRI領域における深層学習のためのモーションアーチファクトジェネレーターの開発. 日放技学誌 77: 463-470, 2021
- [4] Wang Z, Simoncelli EP, Bovik AC. Multi-scale structural similarity for image quality assessment: Conference Record of the Asilomar Conference on Signals, Systems, and Computers. :1398-1402, 2003

教師なし PET 画像ノイズ除去における事前学習済モデルの有用性

大西佑弥^{*1}, 橋本二三生^{*1}, 大手希望^{*1}, 松原佳亮^{*2}, 茨木正信^{*3}

^{*1} 浜松ホトニクス株式会社中央研究所

^{*2} 秋田県立大学システム科学技術学部経営システム工学科

^{*3} 秋田県立循環器・脳脊髄センター研究所脳血管研究センター放射線医学研究部

The usefulness of the pretraining model for unsupervised PET image denoising

Yuya ONISHI^{*1}, Fumio HASHIMOTO^{*1}, Kibo OTE^{*1}, Keisuke MATSUBARA^{*2}, Masanobu IBARAKI^{*3}

^{*1} Central Research Laboratory, Hamamatsu Photonics K. K.

^{*2} Department of Management Science and Engineering, Faculty of System science and Technology, Akita Prefectural University.

^{*3} Department of Radiology and Nuclear Medicine, Research Institute for Brain and Blood Vessels, Akita Cerebrospinal and Cardiovascular Center.

要旨：統計ノイズの多い positron emission tomography (PET) 画像に対し、事前に学習データセットを必要としない deep image prior (DIP) を用いた教師なしノイズ除去やその応用研究が近年数多く行われているが、これらの技術を発展させるためには、根底となる DIP 自体のさらなる性能向上が不可欠である。本研究では、自己教師あり表現学習に注目することで PET 画像のみで汎用的な学習済みモデルを作成し、教師なし学習へ転用することでノイズ除去の性能向上を検討する。数値シミュレーションおよび実測データを用いた評価の結果、学習済モデルを利用することでノイズ除去性能が向上し、先行研究におけるドメイン変換型の学習済モデルと比較して他の PET 薬剤に対する高い汎用性も示された。

キーワード：Positron emission tomography, Unsupervised image denoising, Self-supervised image representation

1. はじめに

陽電子放出断層撮影 (PET) 画像のノイズ除去に畳み込みニューラルネットワーク (CNN) を応用する場合、一般的に高線量または長時間計測および低線量または短時間計測の画像ペアを多数準備する必要があり、多大な労力を要する。さらに、学習セットに含まれていない未知症例や新規 PET 薬剤といった異なるドメインに対する堅牢性が問題となっている。これらの課題を解決するために、事前に学習データセットを必要としない deep image prior (DIP) を用いた教師なしノイズ除去手法が近年数多く提案されている [1, 2]。さらに、その高い汎用性から、画像再構成への応用研究も行われている [3, 4]。これらの技術を発展させるためには、基盤となる DIP 自体のさらなる性能向上が不可欠である。

そこで本研究は転移学習技術を利用し、DIP によるノイズ除去性能の向上を検討する。様々な PET 薬剤に対する汎用性を備えた学習済みモデルを作成するため、我々は自己教師あり表現学習に着目し、その有用性を調査する。自己教師あり学習は教師ラベルを必要としないため DIP アルゴリズムとの相性が良く、様々なドメインに有用な画像表現が獲得可能である。

2. 方法

本手法は二段階の学習ステップによって構成されている。第一段階では PET 画像の破損変換データを復元する自己教師あ

り学習を用いることで学習済みモデルの作成を行う。

$$\theta_0 = \operatorname{argmin}_{\theta} \frac{1}{N_t} \sum_{i \in \mathcal{D}_t} \|x_i^{src} - f_0(\theta | \tilde{x}_i^{src})\|, \quad (1)$$

複数の破損過程によって生成された PET 画像セット \tilde{x}_i^{src} を元の PET 画像セット x_i^{src} に復元するように 3D U-Net f_0 を最適化することで、学習済みのネットワーク重み θ_0 を獲得する。

第二段階では、得られた特徴表現を DIP モデルの初期重みとし、転移学習のような枠組みで教師なしのノイズ除去を行う。

$$\hat{\theta}^{up} = \operatorname{argmin}_{\theta^{up}} \|x_0 - f_1(\theta^{up} | \theta_0^{down}, m)\|, \quad (2)$$

$$\hat{x}_0 = f_1(\hat{\theta}^{up} | \theta_0^{down}, m), \quad (3)$$

3D U-Net f_1 に磁気共鳴 (MR) 画像 m を入力したときの出力画像とノイズを含む PET 画像 x_0 の平均二乗誤差を最小化することで最終的なノイズ除去画像を得る。本手法では、事前学習によって得られたネットワーク重みのエンコーダ部分は固定し、デコーダ部分のみ更新を行った。

3. 結果

モンテカルロシミュレーション及び実測データを用いて提




図 1 模擬腫瘍を挿入したシミュレーションデータによるノイズ除去結果の比較 ([18F]FDG)




図 2 実測データにおけるノイズ除去結果の比較 (上 : [11C]PIB, 下 : [18F]FDG)

案手法の評価を行った。実測データにおけるターゲット画像は、事前学習時の訓練画像とは異なる PET 薬剤を使用した。

シミュレーションデータによる定量評価の結果、学習済モデルを転用することでオリジナルの DIP (Random Init.) と比較し、ピーク信号対雑音比 (PSNR)、構造的類似性 (SSIM)、コントラスト対ノイズ比 (CNR) が向上した (図 1)。さらに、先行研究におけるドメイン変換型の学習済モデル (MR2PET) と比較し、事前学習時に使用していない PET 薬剤に対する高い汎用性も確認できた (図 2)。よって、実臨床における有用性は高く、提案手法を用いることで PET 計測時間の短縮や RI 投与量の削減による被ばく線量の低減が期待される。

4. まとめ

本研究では、自己教師あり表現学習を利用することで汎用的な学習済モデルを作成し、DIP によるノイズ除去性能の向上を検討した。様々な PET 薬剤に対して高いノイズ除去性能と

汎用性が示され、実臨床における有用性が期待される。

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

- [1] Cui J, Gong K, Guo N et al: Populational and individual information based PET image denoising using conditional unsupervised learning. *Phys. Med. Biol.* 66: 155001, 2021
- [2] Onishi Y, Hashimoto F, Ote K et al: Anatomical-guided attention enhances unsupervised PET image denoising performance. *Med. Image. Anal.* 74: 102226, 2021
- [3] Gong K, Catana C, Qi J et al: PET Image Reconstruction Using Deep Image Prior. *IEEE Trans. Med. Imag.* 38: 1655-1665, 2019
- [4] Hashimoto F, Ote K, and Onishi Y: PET Image Reconstruction Incorporating Deep Image Prior and a Forward Projection Model. *IEEE Trans. Med. Imag.*: in press, 2022
- [5] LaMontagne P, Benzinger T, Morris J et al: OASIS-3: Longitudinal neuroimaging, clinical, and cognitive dataset for normal aging and Alzheimer's disease. *Alzheimer's & Dementia: The Journal of the Alzheimer's Association.* 14: 1097, 2018

MR エラストグラフィにおける腹壁運動に伴うモーションアーチファクトの低減法

菅 幹生^{*1,2}, 小賀野 慎^{*2}, 谷口 陽^{*2,3}, 西原 崇^{*3}, 瀧澤 将宏^{*3}

^{*1} 千葉大学 フロンティア医工学センター

^{*2} 千葉大学 大学院融合理工学府

^{*3} 富士フイルムヘルスケア株式会社

Methods for reducing motion artifacts associated with abdominal wall motion in MR elastography

Mikio Suga^{*1,2}, Makoto Ogano^{*2}, Yo Taniguchi^{*2,3}, Takashi Nishihara^{*3}, Masahiro Takizawa^{*3}

^{*1} Center for Frontier Medical Engineering, Chiba University

^{*2} Graduate School of Science and Engineering, Chiba University

^{*3} FUJIFILM Healthcare Corporation

要旨：腫瘍や肝硬変などの病変組織は正常組織と比較して硬くなる。MRI を用いて非侵襲的に生体軟組織の粘弾性分布を評価可能な手法として MR elastography (MRE)がある。自由呼吸条件下では腹壁運動に伴うモーションアーチファクトにより MRE 粘弾性率推定精度が低下するため、息止め条件下で撮像する。本研究では、腹壁運動に伴うモーションアーチファクトの影響を低減可能な MRE 撮像条件を数値シミュレーションにより明らかにすることを目的とした。形態画像に生じるモーションアーチファクトの間隔が呼吸周期と撮像時間に関する知見を元に、MRE 撮像パラメータの1つである repetition time を呼吸周期の3分の1に設定することでモーションアーチファクトを撮像対象から外すことができ、息止め条件下での弾性率推定値との誤差は3%以下となることを確認した。以上の結果より、撮像中に呼吸周期が安定している場合には、自由呼吸条件下での MRE 撮像が可能であることが示唆された。

キーワード：MR エラストグラフィ、モーションアーチファクト、自由呼吸、呼吸周期、repetition time

1. はじめに

Magnetic resonance imaging (MRI) を利用して、生体の粘弾性率を非侵襲的に評価する手法として magnetic resonance elastography (MRE) [1]がある。MRE は撮像中に外部加振装置を用いて対象内部に弾性波を伝播させ、MRI パルスシーケンスに変位エンコード傾斜磁場 (motion encoding gradient : MEG) を付加した 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。得られた弾性波画像から逆問題を解くことで粘弾性率を推定する。MRI では撮像中における被検者の呼吸などの動きによって画像にアーチファクトが生じることがある。このアーチファクトはモーションアーチファクトと呼ばれ、MRI の読影診断に影響する問題がある。MRE では弾性波画像にモーションアーチファクトが生じることで、粘弾性率推定結果に誤差が生じることが懸念される。本研究では、自由呼吸下での MRE 撮像を実現することを目標として、呼吸が弾性率推定値に与える影響の大きさと、モーションアーチファクトを低減可能な撮像条件を数値シミュレーションにより明らかにすることを目的とした。

2. 方法

2.1 数値シミュレーション概要

モーションアーチファクトを再現するために、最初に各 phase encoding step におけるデータ収集のタイミングを MRI の撮像パラメータである信号取得繰り返し時間 (repetition time:

TR) より計算し、あらかじめ取得しておいた呼吸波形から腹部変位を抽出する。腹部数値モデルは腹部体軸断面を模擬した楕円形状で、下半分の背中側は変形せず、呼吸と同期して上半分の腹部側が上下方向に伸び縮みすると仮定した。次に、想定貯蔵弾性率分布と加振周波数、加振点から計算した弾性波変位分布を位相画像に追加する。これらの強度画像と位相画像から実空間での実部画像と虚部画像を作成する。次に、この実部画像と虚部画像をフーリエ変換し、空間周波数 (k) 空間での各 phase-encoding step に対応するデータを1行ずつ充填する。その後、全て充填された k 空間画像を逆フーリエ変換することで得られる実空間のデータから、強度画像と位相画像 (弾性波画像) を出力する。

2.2 シミュレーション設定

本シミュレーションでは、成人男性の腹部 (長軸 : 30 cm, 短軸 : 20 cm) の上面中央が呼吸によって 1.5 cm の振幅で動くとして仮定した。振動子の振動源は1点とした。また、呼吸に伴う振動子の位置変化の有無による影響を確認するために、振動子の配置は右脇腹 (腹部の真横、位置変化なし) と右腹部 (腹部前側のやや右の位置、上下の位置変化あり) の2箇所とした。また、腹部数値モデル内部には肝臓を想定した内包領域 (形状は楕円、長軸 : 19.2 cm, 短軸 : 9.6 cm) を配置した。内包領域は腹部数値モデルの中心から断面像に向かって左に 3.0 cm, 上に 3.6 cm 離れた位置に 15 度傾けて配置し、腹部の動きに合わせて変形させた。各 phase-encoding step での弾性率分布に合わ

せた弾性波画像は波動方程式を用いて計算した。心拍や呼吸などの周期的な動きの場合、アーチファクトの間隔 D (pixel)は、phase encoding step 数 (MR 信号取得回数) N_y (pixel), 信号取得繰り返し時間 T_R (sec), 加算回数 N_{SA} に比例し、動きの周期 T_p (sec) に反比例する[2].

$$D = \frac{N_y \times T_R \times N_{SA}}{T_p} \quad (1)$$

これより、腹部撮像においては、加算回数を1とすると、 TR を呼吸周期の約三分の一、画像収集領域 (field of view: FOV) を腹部短軸長の約3倍に設定することで、アーチファクトの間隔が吸気時の腹部概形よりも大きく、アーチファクトが撮像対象と重ならない条件を満たすことができる。

本実験で利用する 271 周期分の呼吸波形の周波数スペクトルを求め、その最大ピークをガウスフィッティングすることで求めた平均呼吸周期 (3707 ms) を利用して撮像条件を決定した。具体的には、MRE パルスシーケンスはスポイルド GRE - MRE を想定し、 TR : 480 と 1236 ms (平均呼吸周期/3), FOV: $768 \times 768 \text{ mm}^2$, matrix: 256×256 , number of sample averaged: 1, slice number: 15, slice thickness: 3.0 mm, phase encoding 方向: anterior to posterior, vibration frequency: 60.0 Hz とした。腹部背景領域と肝臓領域の貯蔵弾性率はそれぞれ 3.0 kPa と 4.5 kPa とし、いずれの損失弾性率も 0.0 kPa とした。粘弾性率分布の算出には、積分型粘弾性率分布推定手法 (integral type reconstruction formula: ITRF [3]) を用いた。

3. 結果

振動子の位置を右脇腹と右腹部に設定したシミュレーション結果の強度画像, 弾性波画像, 貯蔵弾性率画像を図1に示す。以後、振動子の位置を右脇腹に設定した結果を右脇腹, 振動子の位置を右腹部に設定した結果を右腹部と示す。右脇腹と右腹部のいずれの結果においても、 TR を 1236 ms に設定することで撮像対象外に強いモーションアーチファクトが現れることを確認した。しかし、右腹部の結果では、背景領域と内包領域の両方で弾性率推定値のばらつきが大きくなった。さらに、右腹部の貯蔵弾性率画像において、内包領域の概形が楕円だと判別できないほど弾性率算出誤差が大きかった。

4. 考察

図1で示した各画像に対して、振動子位置と TR の設定が同じで、腹部変位が無い場合の画像との差分によりモーションアーチファクトを確認した。強度画像の差分画像は、右脇腹 ($TR=1236 \text{ ms}$) において差が最も小さく、かつ、モーションアーチファクトが撮像対象外に集中していた。貯蔵弾性率分布の




図1 シミュレーション結果

差分画像では、右脇腹 ($TR=480 \text{ ms}$) と比較して、右脇腹 ($TR=1236 \text{ ms}$) と右腹部 ($TR=1236 \text{ ms}$) での差が小さかった。貯蔵弾性率分布の平均値と変動係数からも、 TR を呼吸周期の三分の一とすることで推定精度が向上することを確認した。また、右腹部 ($TR=1236 \text{ ms}$) での変動係数が右脇腹 ($TR=1236 \text{ ms}$) より大きいことより、振動子が体動に合わせて上下動することは貯蔵弾性率推定の誤差要因となることが示唆された。

5. まとめ

自由呼吸下での肝臓 MRE においては、 TR を呼吸周期の三分の一になるように設定するとともに、振動子を右脇腹に設置することで貯蔵弾性率推定誤差を小さくできることが示唆された。本研究成果により、息留めが困難な被検者に対して MRE が適用可能となることが期待できる。

謝辞

本研究の一部は JSPS 科研費 JP17H02115 の助成を受けたものです。

利益相反の有無

なし

文献

- [1] Muthupillai R, Lomas DJ, Rossman PJ et al: Magnetic resonance elastography by direct visualization of propagating acoustic strain waves. Science 269: 1854-1857, 1995
- [2] Wood ML, Runge VM, Henkelman RM: Overcoming motion in abdominal MR imaging. AJR 150: 513-522, 1988
- [3] Takeda T, Fujiwara H, Suga M: Development of three-dimensional integral-type reconstruction formula for magnetic resonance elastography. Int J Comput Assist Radiol Surg 16: 1947-1956, 2021

Cycle GAN を用いた前立腺癌患者における仮想造影 MR 画像合成

平川 勇也^{*1}, 有村 秀孝^{*2}, 崔 雲昊^{*1}, 高山 幸久^{*3}, 西江 昭弘^{*4}, 石神 康生^{*5}

^{*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} 福岡大学医学部放射線医学教室

^{*4} 琉球大学大学院医学研究科放射線診断治療学講座

^{*5} 九州大学大学院医学研究院臨床放射線科

^{*1} 〒812-8582 福岡市東区馬出 3-1-1

e-mail: hirakawa.yuya.498@s.kyushu-u.ac.jp

Virtual Contrast-Enhanced MR Image Synthesis in Prostate Cancer Patients Using Cycle Generative Adversarial Network

Yuya HIRAKAWA^{*1}, Hidetaka ARIMURA^{*2}, Yunhao CUI^{*1}, Yukihiisa TAKAYAMA^{*3}, Akihiro NISHIE^{*4}, Kousei ISHIGAMI^{*5}

^{*1} Department of Health Sciences, Graduate School of Medical Sciences, Kyushu University

^{*2} Department of Health Sciences, Faculty of Medical Sciences, Kyushu University

^{*3} Department of Radiology, Faculty of Medicine, Fukuoka University

^{*4} Department of Radiology, Graduate School of Medical Sciences, University of the Ryukyus

^{*5} Department of Clinical Radiology, Graduate School of Medical Sciences, Kyushu University

要旨: 高空間分解能の脂肪抑制造影 T1 強調画像は、前立腺外進展、神経血管束浸潤、精嚢浸潤を描出することができる。しかし、腎機能不良や造影剤に対するアレルギー歴のため造影剤の使用が不可能な患者も存在する。そこで、前立腺癌患者の造影 T1 強調画像および T2 強調画像から仮想造影 T1 強調画像を合成する CycleGAN モデルの構築を試みた。本研究では、前立腺癌患者 43 名のガドリニウム造影剤による脂肪抑制造影 T1 強調画像と非造影 T1 強調画像および T2 強調画像を選択し、それらをランダムに 30 名のトレーニングデータセットと 13 名のテストデータセットに分割した。構築された CycleGAN モデルは、非造影画像から仮想造影画像を生成する生成器と、入力画像が実造影画像か仮想造影画像かを判断する識別器で構成されている。モデルによって生成された画像について、PSNR (peak signal to noise ratio) と SSIM (structural similarity) で評価を行った。テストデータセットにおいて平均 PSNR 29.3 ± 2.94 , SSIM 0.780 ± 0.0795 となった。本研究は、CycleGAN モデルが前立腺癌患者の造影 MR 画像を仮想的に生成できることを示唆している。

キーワード: 深層学習, CycleGAN, 前立腺癌, 仮想造影

1. はじめに

我が国における前立腺癌罹患数は 2017 年では 91,215 人と部位別罹患数で男性がんの第 1 位である[1]。また、将来推計では 2035 年-2039 年の年平均罹患数は 180,860 人と予測され今後も急速に増加すると考えられている[2]。前立腺癌の診断において脂肪抑制造影 T1 強調画像は前立腺外進展、神経血管束浸潤、精嚢浸潤を描出することができる。しかし、造影画像を撮像する際に使用されるガドリニウム造影剤は腎機能不良や造影剤に対するアレルギー歴のために使用が制限される場合がある。

そこで、本研究の目的は、非造影 T1 強調画像および T2 強調画像から仮想造影 T1 強調画像を合成することである。画像の合成にはスタイル変換技術の一つである

CycleGAN[3]を用いた。

2. データと手法

1) 使用データ

本研究では九州大学病院で撮像された前立腺癌患者における非造影 T1 強調画像、T2 強調画像および脂肪抑制 T1 強調画像を使用した。30 症例をトレーニングデータセット、13 症例をテストデータセットとして合計 43 症例の MR 画像を用いた。T1 強調画像と T2 強調画像を重ね 2 チャンネルとしたものをドメイン T、脂肪抑制造影 T1 強調画像をドメイン C とした。

2) 前処理

512×512 のマトリクスサイズである原画像の中心

192×192 pixel をクロップして使用した。各シーケンスの最大値と最小値を用いて式(1)により正規化を行い、ピクセル値の範囲が[-1, 1]になるようにリスケールを行った。

$$x_{norm} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (1)$$

ここで、 x_{min}, x_{max} は各シーケンスの最小値および最大値を表し、 x_i は各ピクセル値である。

3) CycleGAN による画像の変換

仮想造影画像の生成にはスタイル変換技術の一つである CycleGAN を用いた。




図1 CycleGAN の構造。T, C はドメイン T, C のデータである。G, F は T→C 変換, C→T 変換を行う、生成器を表し、 D_T, D_C は実画像と生成器によって生成された偽画像を判別する識別器である。

損失関数として、Adversarial loss と Cycle consistency loss の2つを使用して、モデルの最適化を行った。

1つ目の Adversarial loss は識別器の判別結果によって求められ、生成器 G と識別器 D_C に対して式(2)、生成器 F と識別器 D_T に対して式(3)で与えられる。

$$L_{GAN}(G, D_C, T, C) = E_{c \sim p_{data}(c)} [(D_C(c) - 1)^2] + E_{c \sim p_{data}(c)} [(D_C(G(t)))^2] \quad (2)$$

$$L_{GAN}(F, D_T, C, T) = E_{t \sim p_{data}(t)} [(D_T(t) - 1)^2] + E_{t \sim p_{data}(t)} [(D_T(F(c)))^2] \quad (3)$$

2つ目の Cycle consistency loss はインプット画像と再構成画像の L1 ノルムによって計算され、式(4)で表される。

$$L_{cyc}(G, F) = E_{t \sim p_{data}(t)} [\|F(G(t)) - t\|_1] + E_{c \sim p_{data}(c)} [\|G(F(c)) - c\|_1] \quad (4)$$

CycleGAN の最終的な損失関数は式(5)で与えられる。

$$L(G, F, D_T, D_C) = L_{GAN}(G, D_C, T, C) + L_{GAN}(F, D_T, C, T) + \lambda L_{cyc}(G, F) \quad (5)$$

ここで、 λ は Cycle consistency loss の重みである。この損失関数を用いて、生成器 G と生成器 F の最適化を行う。

トレーニングは 200 エポックで、バッチサイズを 1、Optimizer には Adam を使用し、パラメータは $\beta = 0.5$ に設

定し、学習係数は 0.0002、 $\lambda = 10$ で行った。

変換された画像の評価には PSNR (peak signal to noise ratio) と SSIM (structural similarity) を使用した。

2. 結果と考察

テストデータセットから求められた評価指標の結果は PSNR が 29.3 ± 2.94 , SSIM が 0.780 ± 0.0795 となった。また、T1 強調画像と T2 強調画像の 2 チャンネル画像から変換された仮想造影画像の例を図 2 に示す。




図2 Ground truth と仮想造影画像。左図は実際の脂肪抑制 T1 強調画像、右図は 2 チャンネル画像から生成された仮想造影画像である。

図 2 より前立腺組織における造影効果を確認できるが、実画像に比べ淡い表現となっている。図中右下の血管を抽出することができているが、一箇所に限定されており、血管領域は画像に占める割合が小さいため最適化のフィードバックの方法を検討する余地がある。

3. まとめ

本稿では、T1 強調画像と T2 強調画像から仮想造影画像を予測するモデルの構築を試みた。改善の余地はあるものの一定の仮想造影効果は認められた。

謝辞

本研究を進めるにあたり、有益なご助言をいただきました有村研究室の方々に感謝の意を表します。

利益相反の有無

なし

文献

- [1] 国立がん研究センターがん情報サービス「がん登録・統計」(全国がん登録) <https://ganjoho.jp/public/index.html>
- [2] 平成 28 年度科学研究費補助金基盤研究(B)(一般)日本人におけるがんの原因・寄与度：最新推計と将来予測 国立がん研究センターがん情報サービス「がん登録・統計」
- [3] Zhu Jun-Yan, Park Taesung, Isola Phillip et al: Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks. In IEEE International Conference on Computer Vision, 2017, pp.2223-2232

頭部 PET 体動補正のための大きな動きに対応した マーカレスモーショントラッキングシステムの開発

岩男悠真^{*1}, 赤松剛^{*1}, 田島英朗^{*1}, 高橋美和子^{*1}, 山谷泰賀^{*1}

^{*1} 量子科学技術研究開発機構 量子医科学研究所 先進核医学基盤研究部

Development of a marker-less tracking system under large motion for brain dedicated PET motion correction

Yuma IWAO^{*1}, Go AKAMATSU^{*1}, Hideaki TASHIMA^{*1}, Miwako TAKAHASHI^{*1}, Taiga YAMAYA^{*1}

^{*1} National Institutes for Quantum Science and Technology

要旨：頭部の体動は、体動計測ができれば正確に補正することが可能である。そこで、顔表面の立体構造をマーカとすることで、体表装着型マーカが不要な体動補正システムを開発した。しかし、左右の首振りに対する正解値と検出角度の線形性は 30 度を境に大きく乖離する傾向があり、実際にボランティア試験では 30 度を超える大きな動きが問題となった。

そこで本研究では、KinectFusion と呼ばれる 3D スキャンアルゴリズムを改良したトラッキング手法を開発した。マッチングを行うフレーム間の差異を最小とし、形状の類似度を高めるため、対象フレームは直前フレームのモーションによって変換し、リファレンスとなるモデルとのオーバーラップ部分のみを用いる。頭部模型をモータステージにより可動させた実験では、検出角度の線形性が約 60 度まで大幅に向上した。

キーワード：PET, 体動補正, モーショントラッキング, Kinect

1. はじめに

頭部 PET 検査において、高精度な画像を取得するために被験者頭部の固定が実施されるが、これは被験者の負担の増加につながるうえ、完全に体動を抑制することもできない。そこで、撮像中の被験者の体動を再構成時に補正して打ち消すような処理を行う体動補正に関する検討が広く行われている[1]-[3]。特に外部センサを用いる手法は高精度な補正が可能であるが、一方でセンサやマーカの取り付けに手間がかかるため、臨床の場で用いるには不適であった。そこで我々は、被験者の頭部形状をマーカの代わりに活用し、トラッキングや、外部センサと PET 装置間の座標系の統一に用いる手法を開発した[4]。ファントム実験による定量評価や、ボランティア試験により、高い補正効果が実証されている。一方で、リミテーションとしてトラッキングに要する処理時間が撮像時間のおおよそ 5 倍程度必要なこと、首の左右の回転に対し、30 度程度までしか精度が保てないことがあげられる。

そこで本研究では、レンジセンサを用いたリアルタイム 3D スキャン手法である KinectFusion[5]を応用し、トラッキング処理の高速化と、より大きな動きへの対応性を確保する。

モデル実験により性能評価を行い、ボランティア試験への適用を行い、実データでの有用性を評価する。

2. 方法

2.1 提案手法

KinectFusion とは、レンジセンサによって取得されたダイナミックなデプスマップに対し、各フレームにおけるカメラ位置推定を行うことで、測定対象の 3D モデルを更新していくスキャンアルゴリズムである。スケールピラミッドや、GPU 演

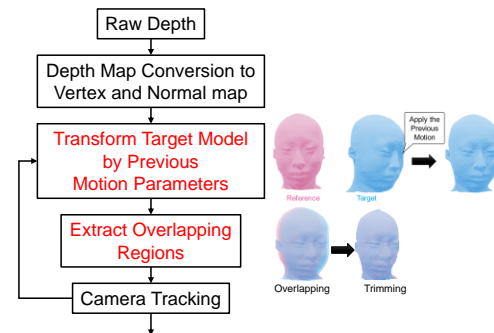


図 1 提案手法の流れ

算による高速化により、リアルタイムな処理が可能となる。カメラを固定することで、逆にオブジェクトの動きをトラッキングすることが可能となるが、位置の基準となるモデルの更新において、フレーム内で生じたトラッキングエラーが蓄積するため、そのままの活用することはできない。

そこで、本研究では KinectFusion のプロセスをもとに、トラッキングアルゴリズムの構築を行った (図 1)。入力であるデプスマップは、3 次元座標点群に変換され、同時に各点の法線ベクトルの計算を行う。最初のフレームから得られたモデルを Reference とする。2 番目以降のフレームでは、ひとつ前のフレームで得られたモーションを用いて対象モデルを座標変換する。この処理には、マッチングの初期位置を Reference モデルと極力近づけることで、処理の安定性を向上させる目的がある。続いて、座標変換された対象モデルと、Reference モデルを Iterative Closest Points (ICP) アルゴリズムによりマッチングし、モーションの計算を行う。この時、前処理として両者が重なった部分のみを抽出し、処理の対象とした。ICP にお

いて、オーバーラップしていない領域は誤った収束を誘発するため、その抑制が目的である。

2.2 実験

マネキンとモータステージを使い、トラッキング精度検証実験を行った。レンジセンサには Azure Kinect (Microsoft) を用いて、マネキンの前方 1.5m のところに配置した。モータステージはマネキン下部に配置されており、首を左右に振る動きを再現する。首の角度は、正面を向いた状態を 0 度として 60 度までとした。シンプルな ICP ベースのトラッキング手法[6] (ICP Base), および本研究で提案する KinectFusion ベースの手法 (KinFu Base) の 2 種類について精度評価を行った。

また、既報[4]にて実施した 8 名のボランティア試験のデータに対し、提案するトラッキング手法を適用し、その性能評価を行った。具体的には、頭部固定状態での 10 分間の静的撮像の再構成像 (Head-Fixed) と、固定無しで 15 分間被験者が頭を動かした状態で撮像を行ったデータに対し、ICP ベースのトラッキングによる体動補正を行った画像 (ICP Base MC) と、提案手法をトラッキングに用いた画像 (KinFu Base MC) にたいし、中脳内部の下丘と呼ばれる微小構造上にプロファイルラインを配置し、Peak-to-valley 比を比較した。

3. 結果と考察

図 2 に、トラッキング精度検証結果を示した。ICP ベースでは、30 度程度を境に大きく精度の低下が生じているのに対し、提案法では 60 度まで安定した精度にてトラッキングができてい。平均誤差は ICP ベースで 3.4 度、提案手法で 0.71 度であった。また、120 秒分のデータに対する処理時間は、ICP ベースが 585 秒、提案手法が 100 秒であった。したがって、提案手法は高精度なトラッキングを 60 度程度まで維持することが可能であり、またその処理時間も従来法に比べて 6 倍程度高速であることがわかる。

図 3 にボランティア測定の結果をまとめた。(a) より、提案手法のトラッキングにより脳内部の微小構造の描出性が灰白質部位などで向上しているように見える。プロファイル (b) のように下丘領域の上にとり、peak-to-valley 比をまとめたものが (c) である。Wilcoxon signed rank test により、Head-Fix よりも優位に値が向上していることが確認できた。

4. まとめ

KinectFusion をベースとした高速かつ広範囲に適用可能なトラッキングシステムの開発を行った。モデル実験とボランティア試験により従来手法と比較しその有効性が示された。

謝辞

本研究の一部は、日本学術振興会科研費 (課題番号 17K18376) の助成を受けたものである。

利益相反の有無

本研究の一部は株式会社 ATOX から資金提供を受けている。

文献

- [1] O. v. Olesen *et al.*, "List-Mode PET Motion Correction Using Markerless Head Tracking: Proof-of-Concept With Scans of Human Subject," *IEEE Transactions on Medical Imaging*, vol. 32, no. 2, pp. 200–209, Feb. 2013
- [2] P. J. Noonan, J. Howard, W. A. Hallett, and R. N. Gunn, "Repurposing the Microsoft Kinect for Windows v2 for external head motion tracking for brain PET," *Phys Med Biol*, vol. 60, no. 22, pp. 8753–8766, 2015
- [3] A. Z. Kyme, J. Maclaren, M. Aksoy, and R. Bammer, "Feasibility of marker-free motion tracking for motion-corrected MRI and PET-MRI," *NSSMIC/RTSD 2016*, vol. 2017-January, Oct. 2017
- [4] Y. Iwao, G. Akamatsu, H. Tashima, M. Takahashi, and T. Yamaya, "Marker-less and calibration-less motion correction method for brain PET," *Radiological Physics and Technology 2022*, pp. 1–10, Mar. 2022
- [5] R. A. Newcombe *et al.*, "KinectFusion: Real-time dense surface mapping and tracking," *2011 10th IEEE International Symposium on Mixed and Augmented Reality, ISMAR 2011*, pp. 127–136, 2011
- [6] Y. Iwao, H. Tashima, E. Yoshida, F. Nishikido, T. Ida, and T. Yamaya, "Seated versus supine: consideration of the optimum measurement posture for brain-dedicated PET," *Physics in Medicine & Biology*, vol. 64, no. 12, p. 125003, Jun. 2019




図 2 ICP Base と提案手法のトラッキング精度比較

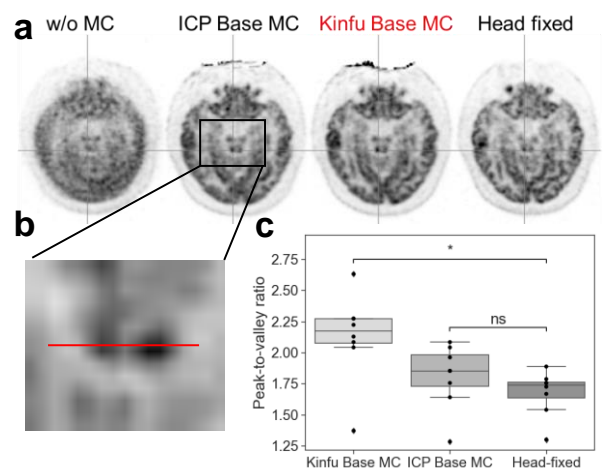


図 3 ボランティア試験まとめ、再構成像 (a), プロファイルラインセッティング (b), 下丘領域上の peak-to-valley (c).

Confocal Laser Scanning Microscope Image Super Resolution for Biomedical Research Based on Two-Stage Generative Adversarial Network

Yunheng WU^{*1}, Masahiro ODA^{*2, 1}, Yuichiro HAYASHI^{*1}, Takanori TAKEBE^{*3, 4, 5},
Shogo NAGATA^{*6}, Shuntaro KAWAMURA^{*3}, Kensaku MORI^{*1, 7, 8}

^{*1} *Graduate School of Informatics, Nagoya University*

^{*2} *Information and Communications, Nagoya University*

^{*3} *Institute of Research, Tokyo Medical and Dental University (TMDU)*

^{*4} *Division of Gastroenterology, Hepatology and Nutrition, Developmental Biology, and Center for Stem Cell and Organoid Medicine (CuSTOM), Cincinnati Children's Hospital Medical Center*

^{*5} *Department of Pediatrics, College of Medicine, University of Cincinnati*

^{*6} *Department of Surgery, Keio University School of Medicine*

^{*7} *Information Technology Center, Nagoya University*

^{*8} *Research Center for Medical Bigdata, National Institute of Informatics*

Abstract : In our work, we propose a two-stage image super-resolution (SR) scheme to improve the resolution of confocal laser scanning microscope (CLSM) images acquired by in vivo imaging for biomedical experiments. The CLSM is a microscope commonly used in vivo imaging for biomedical research. However, CLSM's field of view with high magnification is small. Therefore, to obtain wide-field and high-resolution CLSM images, we use the deep-learning-based SR method to improve the resolution of CLSM images rather than improving complex microscope systems. The experimental results showed that our method can acquire higher quality SR CLSM images than bicubic interpolation in vivo imaging, which can be more conveniently for biomedical researchers to observe sample more conveniently.

Keyword : confocal laser scanning microscope, image super-resolution, generative adversarial network

1. Introduction

The confocal laser scanning microscope (CLSM) is a kind of fluorescent microscope. Because it can capture tiny tissues and cells in vivo imaging, it is often used in drug development and disease research [1]. However, the field of view (FOV) of high-magnification CLSM images is small. Nowadays, many methods are proposed to improve the resolution of CLSM images. However, most of the existing methods improve the complex microscope system to improve the resolution of microscopes.

Image processing is also used to improve the resolution of microscope images. The most common method to improve the image resolution is image interpolation, such as the nearest neighbor and bicubic interpolation. However, the ability of interpolation methods to restore the structure and edge of the image is limited.

In recent years, deep-learning-based methods have achieved many excellent performances in improving image resolution. In our work, we use deep-learning-based image super resolution (SR) to improve CLSM image. SR is an image restoration technology, which can recover a high-resolution (HR) image from a low-resolution (LR) image. Specifically, we propose a two-stage SR generative adversarial network (GAN) using the SRGAN framework [2] to

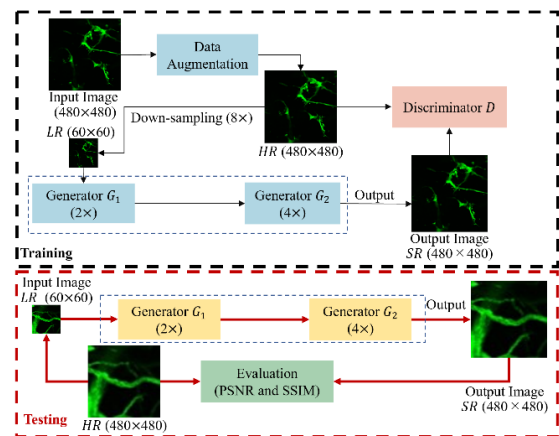


Fig. 1 The workflow of our scheme. The training is showed in the black dashed box. The testing is showed in the red dashed box.

achieve eight-times (8×) SR on CLSM images. In addition, we used data augmentation to solve the small-sample data problem.

2. Method

As shown in Fig. 1, we implemented data augmentation and then input generated data into our two-stage SRGAN network.

1) Data augmentation. For problem of small-sample data, we perform data augmentation. We rotate images in three angles

(90°,180°, 270°) and flip images in horizontal and vertical directions.

2) Two-stage SRGAN for 8× SR. Deep-learning-based SR model not only can expand the size of images, but also can enhance images quality. Two-stage SR method is more conducive to generate high-quality SR images. [3]. Therefore, we propose a two-stage SR scheme based on SRGAN framework [2] to achieve 8× SR on the CLSM images as shown in Fig. 1. Specifically, we divide the 8× SR images generation task into two stages. Firstly, 8× HR images with size of 480×480 are down sampled by the bicubic interpolation to obtain LR images with size of 60×60 pixels. Then, the LR images are used as the input of the 2× generator G_1 . Next, the outputs of generator G_1 are input to the 4× generator G_2 to generate 8× SR images with size of 480×480 pixels. Finally, the generated 8× SR images and the 8× HR images with size of 480×480 pixels are input into the discriminator D to discriminate the generated 8× SR images are real or fake. The parameters of the two generators (G_1 and G_2) are updated according to the results of discriminator D . In addition, we introduce Residual-in-Residual Dense Block (RRDB) and remove the Batch Normalization (BN) layers in Residual Block of SRGAN according to ESRGAN [4]. For training generator, we use a loss function, which is composed of mean squared error loss, content loss, adversarial loss [2] and total variation (TV) loss function [5].

3. Experiments and Results

The data used in our experiment was taken by a professional medical student using a CLSM which is an Olympus FV3000 in biomedical experiment. We extracted four 480×480 images from each of HR images with size of 1024×1024 pixels taken by CLSM with 30× FOV. Because many extracted images are almost all black background, we removed these images and obtained 123 images with a size of 480×480 pixels. Finally, we used 112 images as the training set and 11 images as the test set. Our experiments were implemented by the Pytorch, using a NVIDIA A100 GPU.

For quantitative evaluation, we used the structural similarity index measure (SSIM) and the peak signal to noise ratio (PSNR) as indicators to quantitatively evaluate our experimental results. The proposed two-stage network based on SRGAN framework obtained 32.93 dB of PSNR and 0.84 of SSIM on CLSM images, which was better than 31.85 dB PSNR and 0.76 SSIM of bicubic interpolation. The qualitative results of our experiment were shown in Fig. 2.

4. Discussion and Conclusions

By the deep-learning-based SR method, we achieve a simple, low-




Fig. 2 The qualitative result. (a) is input LR image; (b) is result of bicubic interpolation; (c) is result of proposed method; (d) is Ground Truth.

cost method to improve CLSM image resolution for in vivo imaging in biological experiments, rather than complex and expensive methods like microscope system improvement. The experimental results showed that our scheme achieved 8× SR on the CLSM image, which is conducive to the observation of medical research. As show in Fig. 2, our scheme got better results than bicubic interpolation and blood vessel edges can be more clearly observed.

In the future, we plan to reconstruct SR CLSM images at larger upscaling factors and use HR images and LR images taken by different magnification CLSM as paired data to train network, rather than down sampling HR images generate LR images.

Acknowledgement

Parts of this research were supported by the JST Moonshot R&D Grant Number JPMJMS2033, the JST CREST Grant Number JPMJCR20D5, and the fellowship of the Nagoya University CIBoG program from MEXT WISE program.

Competing interests

None

Reference

- [1] Takebe T, Zhang R, Koike H et al.: Generation of a vascularized and functional human liver from an iPSC-derived organ bud transplant. *Nat Protoc* 9, 396-409, 2014.
- [2] Ledig C, Theis L, Huszár F et al.: Photo-realistic single image super-resolution using a generative adversarial network. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp4681-4690.
- [3] N. Yano and H. Watanabe: Image Quality Enhancement with Machine Learning Based Multi-Step Super-Resolution, *International Conference on Artificial Intelligence in Information and Communication*, 2020, pp141-145.
- [4] Wang X, Yu K, Wu S et al.: ESRGAN: Enhanced super-resolution generative adversarial networks. *Proceedings of the European conference on computer vision (ECCV) workshops*, 2018, pp1-16.
- [5] Johnson J, Alahi A, Fei-Fei L: Perceptual losses for real-time style transfer and super-resolution. In *European conference on computer vision*, 2016 pp694-711.

悪性リンパ腫細胞核画像の低次元表現獲得と 特徴集合に基づくサブタイプ識別器の構築

小出 新悟^{*1}, 橋本典明^{*3}, 横田 達也^{*1}, クグレ マウリシオ^{*1},
大島 孝一^{*2}, 三好 寛明^{*2}, 永石 美晴^{*2}, 竹内 一郎^{*1}, 本谷 秀堅^{*1}

^{*1} 名古屋工業大学

^{*2} 久留米大学 医学部 病理学講座

^{*3} 理化学研究所

Acquisition of low-dimensional representation of cell nucleus images of malignant lymphoma and construction of subtype discriminator based on feature set

Shingo KOIDE^{*1}, Noriaki HASHIMOTO^{*3}, Tatsuya YOKOTA^{*1},
Mauricio KUGLER^{*1}, Koichi OHSHIMA^{*2}, Hiroaki MIYOSHI^{*2},
Miharu NAGAISHI^{*2}, Ichiro TAKEUCHI^{*1}, Hidekata HONTANI^{*1}

^{*1} Nagoya Institute of Technology

^{*2} Kurume University Department of Pathology

^{*3} RIKEN

要旨: 悪性リンパ腫は、細胞核の形態が異型化する病気である。診断では、HE 染色画像が用いられる。悪性リンパ腫のサブタイプの同定は専門医の経験に基づいた定性的な判断によるところが大きく、異型度は定量的に評価されていない。本研究では異型度の定量評価を最終目標とし、まず、細胞核画像の低次元特徴量を獲得し、獲得した特徴集合を用いることで説明可能性を改善したサブタイプ識別器を構築する。異型度の度合いを病理医が説明できる特徴で定量評価するために、細胞核の大きさ、形状の主成分、内部テクスチャのそれぞれを計測し、Contrastive Learning における類似・非類似の判定に利用する。このことにより、細胞核間の類似度を病理医の感覚に沿って計量できる低次元特徴量を各細胞核において求める。その上でサブタイプの同定には、パッチ画像中の細胞核それぞれで求められた低次元特徴量集合を入力とした識別器を構築する。本稿では、その性能を報告する。

キーワード: ニューラルネットワーク, Set Transformer

1. はじめに

悪性リンパ腫は、細胞核の形態が異型化する病気である。正常な細胞核であっても様々な形態が存在するが、がん化に伴い個々の細胞核の形状が変化したり細胞核の形態の多様性のあり方が変わったりする。形態変化の仕方はサブタイプごとに異なり病理医は細胞組織の形態を図 1 のような細胞核を青紫色に染める HE 染色画像で観察することによりサブタイプの診断を行う。ただし、悪性リンパ腫のサブタイプ識別は、病理医の経験に基づいた定性的な判断によるところが大きく、細胞核の異型度は定量的に評価されていない。本研究では、病理画像全体のパッチ画像ではなく、細胞核 1 つ 1 つについて説明可能な指標を用いた低次元特徴量を求め次に、特徴の集合を入力とするサブタイプ識別器の構築を行う。識別性能を確かめたので報告する。

2. 提案法

細胞核形態について病理医とのインタビューにより、面積、形、

内部テクスチャの順に重要な指標であることを確認した。そこで Contrastive Loss を用いる低次元射影を求める際に類似・非類似を面積、形、内部テクスチャそれぞれの形態特徴を測り、この順序で、閾値処理により決定する[1]。学習用の HE 染色画像中の細胞核全てを Hover-Net により抽出し、それぞれについて、類似度が閾値以下の場合に類似、それ以外は非類似のペアを求める。次に、各細胞核の重心を中心とし、細胞核を内に含む程度の小さなパッチ画像の低次元表現を Contrastive Loss の最小化により求める。この際、パッチ画像を回転させたものも類似のペアに含める。このことにより画像の回転に不変な射影を得ることができる。射影先の低次元ベクトルを各細胞核の特徴量とする。Contrastive Loss は、2 つの入力 $\mathbf{X}_1, \mathbf{X}_2$ の類似・非類似により損失を計算する。Y は入力の類似かどうかを表し、2 つの入力が類似のとき 1 をとり、非類似のとき 0 をとる。 G_w は、CNN の出力を表す。

$$L(W, Y, X_1, X_2) = (1 - Y) \frac{1}{2} (D_W)^2 + (Y) \frac{1}{2} \max(0, m - D_W)^2 \quad (1)$$

$$D_W(X_1, X_2) = \|G_W(X_1) - G_W(X_2)\|^2 \quad (2)$$

サブタイプの同定は、細胞核ひとつのみから判断することは困難である。多くの場合がん化に伴い特定の形態を有する細胞核が増えることにより組織を構成する細胞の多様性が減ずる。本提案法では、細胞核ひとつの特徴量ではなく、小領域内に含まれる複数の細胞核をそれぞれから得られる特徴の集合を入力とする識別器を構築する。集合を入力とすることは要素の数や順序に依存しない識別器を構築することである。そのために Set Transformer を用いた識別器を採用する[2]。

3. 実験

細胞核画像の画像サイズは 64×64 とした。画像データは、5000 枚である。学習において、最適化手法は Adam、学習率は、 10^{-7} とした。低次元射影は 5 次元に圧縮した。射影後の結果は、図 2 のようになった。次に細胞核画像の特徴集合を用いて、サブタイプ識別を行った。本研究で識別するサブタイプは、DLBCL、FL、Reactive である。FL は、濾胞性リンパ腫と呼ばれ胚中心の B 細胞由来であり、濾胞と呼ばれる組織内の細胞核が診断において重要である。そのため、入力集合は、濾胞内に存在する細胞核の特徴集合を用いる。識別の際に用いる細胞核画像は、Hover-Net を利用し、細胞核のセグメンテーションを行い、細胞核のマスク画像を生成する[3]。その後、細胞核画像を切り出し、その画像を低次元特徴に射影し、1 つの濾胞内に分布する細胞核集合を入力集合とする。扱ったデータは、学習には 6 症例、評価に 1 症例を用いた。学習データは、DLBCL とそれ以外の識別の時は、それぞれ 300 枚とし、FL と Reactive を識別する際は 150 枚ずつとした。評価データは、各サブタイプで 35 枚ずつを用いた。識別方法は、初めに DLBCL か否かを識別し、DLBCL でないと識別されたデータを FL か Reactive に分ける 2 段階の識別である。結果を混合行列で表すと図 3 のようになった。DLBCL と FL は、8 割程度の識別率となった。

4. まとめ

本研究では、HE 染色画像から細胞核形態の低次元表現を行った。そして、細胞核の特徴集合を入力としたサブタイプ識別器を構築し、識別精度を確認した。今後は、細胞核の形態の測り方を変えることや細胞核特徴について解明していくことを検討する。




図 1 : HE 染色画像




図 2 : 5 次元の内 2 次元をプロット

	dlbcl	fl	reactive
dlbcl	0.88	0.01	0.10
fl	0.00	0.80	0.20
reactive	0.09	0.33	0.58
	dlbcl	fl	reactive

図 3 : 識別結果

利益相反の有無
なし

文献

- [1] Raia Hadsell, Sumit Chopra, Yann LeCun: Dimensionality Reduction by Learning an Invariant Mapping. CVPR, 2006.
- [2] Juho Lee, Yoonho Lee, Jungtaek Kim, et al: Set Transformer: A Framework for Attention-based Permutation-Invariant Neural Networks. 36th International Conference on Machine Learning, Long Beach, California, PMLR 97:3744-3753, 2019
- [3] Simon Graham, Quoc Dang Vu, Shan E Ahmed Raza, et al: Hover-Net: Simultaneous Segmentation and Classification of Nuclei in Multi-Tissue Histology Images. Medical Image Analysis, Vol.58, 2019

X線暗視野法で描出される篩状非浸潤性乳管癌の悪性度に注目した腺腔の解析
吉田 匠^{*1}, 砂口 尚輝^{*2}, 谷口 華奈^{*2}, 黄 卓然^{*2}, 島雄 大介^{*3}, 西村 理恵子^{*4},
岩越 朱里^{*4}, 市原 周^{*4}, 湯浅 哲也^{*5}, 安藤 正海^{*6}

^{*1} 名古屋大学医学部保健学科放射線技術科学専攻

^{*2} 名古屋大学大学院医学系研究科総合保健学専攻

^{*3} 北海道科学大学保健医療学部診療放射線学科

^{*4} 名古屋医療センター病理診断科

^{*5} 山形大学大学院理工学研究科

^{*6} 高エネルギー加速器研究機構

要旨 : X線暗視野法(XDFI)に基づく屈折コントラスト CT は, 生体軟組織内を高コントラスト・高空間分解能で可視化できる. 我々の研究グループでは近年, XDFI を用いて乳癌の初期段階である非浸潤性乳管癌(DCIS)を撮像し, DCIS の篩状構造 (微小なバブル状の腔) と 2次元平面上では見分けが付きにくい通常型乳管過形成の腔に 3次元形状や分布で差異があることを示した. 一方で, DCIS の症例の中でも腔の形状や分布には大きな違いが見られた. 本研究では, DCIS の篩状構造における形状や分布の情報と低中高三段階の病理組織学的悪性度(グレード)との関連を調査した. CT から抽出された腔を 3次元的に観察した結果, 腔の数は低〜中グレードにかけて大きく増加したものの, 中グレードでは腔の大きさに大きなばらつきが見られた. 中〜高グレードにかけては小さな腔が減少し, 高グレードでは大きな腔のみが確認された.

キーワード : X線暗視野法, 屈折コントラスト CT, 非浸潤性乳管癌, 病理組織学的悪性度

1. はじめに

放射光を光源とする X線暗視野法(XDFI)に基づく屈折コントラスト CT は, 生体軟組織内を高コントラスト・高空間分解能で可視化でき, 生体の微小領域の組織形態学的な情報を得るためのツールとして利用されている. 我々の研究グループでは近年, XDFI を用いて乳癌の初期段階である篩状型非浸潤性乳管癌(DCIS)および良性病変である通常型乳管過形成(UDH)の組織ブロックを撮影し, DCIS 内に生じる腺腔 (分泌物による拡張によってできる腔) と UDH 内に生じる腺腔の 3次元形状や分布に差異があることを示した. しかし, 解析に利用された DCIS の症例は, 通常病理学的に理解されている腺腔のサイズよりも大きい腔が数多く検出され, 先行研究で DCIS と UDH の腺腔のみを正しく比較できているのか検証の余地が残っている. 一般的に, 乳管内に確認される腔には, 分泌物によってできる腺腔以外に, 細胞の壊死によってできる腔もある. 細胞の壊死によってできる腔は, 病理学的悪性度 (核グレード) の低グレードではほとんど存在せず, 中グレードから高グレードにかけて増加する. また, 高グレードでは, 広い領域で壊死が起こり, 大きな腔を形成する. XDFI を用いた CT は腔の 3次元構造の描出に有効であるが, 腺腔と壊死による腔の違いを画像のコントラストから判別することは困難である.

本研究では, 病理診断で病理学的悪性度が確定している DCIS の組織を XDFI で撮像し, CT から抽出された腔の 3次元像を作成する. 3次元像から得られる腔の大きさや 3次元配置の情報から腺腔と壊死による腔の違いを判別するための知

見を得る.

2. 手法

1) X線暗視野法による CT 撮像システムおよび乳癌試料

試料の撮像は高エネルギー加速器研究機構 (茨城県つくば市) フォトンファクトリー-BL14B ビームラインに構築された XDFI に基づく屈折コントラスト CT 撮影装置を使用して行った. 撮像装置の概念図を図 1 に示す. 加速器から発生した放射光 X線を 2結晶モノクロリメータによって単色化し, 非対称ブラッグケースモノクロリメータによって回折させて試料に入射させる. 入射した X線は試料内の物理量分布である複素屈折率にしたがって微小に屈折する. 試料で生じた X線ビームの屈折角偏差はラウエケース角度アナライザ結晶によってコントラストに変換される. それを X線カメラで測定する. 表 1 に撮像パラメータを記載する.

なお, 撮像した試料は, 名古屋医療センターで DCIS と診断され, 摘出された乳腺の組織ブロックであり, 病理学的悪性度 (核グレード) が低中高グレードと診断された 1症例ずつを解析対象とした. 本研究で扱うヒト乳腺の画像データの利用については, 名古屋大学医学部保健学科の生命倫理審査で承認されている.

2) 解析手法

CT 画像から腔を抽出する作業は, U-Net を用いた機械学習法により自動化する. まず, 取得した CT ボリュームセットから, DCIS を含む 256×256 pixel の領域をスライス枚数分抜き出し, その中の 5スライスの腔を手動で抽出する. 手動で抽出




図1 XDFIに基づく屈折コントラストCT撮像システム

表1 CT撮像パラメータ

X線エネルギー	19.8keV
ピクセルサイズ	5.5 μm
投影数	2500
スライス厚	5.5 μm




図2 各グレードのCT画像とU-Netによる処理画像の代表スライス

したデータセットを教師データとして、U-Netを学習させる。その後、学習したU-Netを用いてすべてのスライスの腔を自動で抽出する。抽出された腔はボリュームレンダリングにより3次元的に表示される。

3. 結果・考察

XDFIによるCT画像とU-Netにより抽出された腔の例を図2に示す。U-Netによる腔の色は2値ではなく、手動で抽出された腔と近い構造ほど濃い色を示す傾向がある。微小な腔は薄い色で抽出できていることが分かる。

腔のボリュームレンダリング画像を図3に示す。図3では、組織ブロック内に多数存在する腔を見やすくするために、注目する1つの乳管内に含まれる腔に限定して表示している。図3から、腔の数は低～中グレードにかけて大きく増加したものの、中グレードでは腔の大きさに大きなばらつきが見られた。中～高グレードにかけては小さな腔が減少し、高グレードでは大きな腔のみが確認された。これは、中から高グレードにかけて壊死による腔が増加しているためと考えられ、事前に診断された病理学悪性度に基づく組織の状態と矛盾しない。



低グレード 中グレード 高グレード

図3 DCISの各グレードにおける腺腔構造のボリュームレンダリング像

4. まとめ

本研究では、非浸潤性乳管癌の腔構造を3次元化することによって、病理学的悪性度とCTで描出される腔構造の関係を調査した。その結果、腔の大きさや数は各悪性度で大きく異なることが分かった。これは、細胞の壊死と関連している可能性が高く、今後病理切片との比較により詳細に調査する。また、この研究から、DCISの腺腔のみを解析する際は、DCISの症例を壊死による腔が生じにくい低グレードに限定するか、事前に病理切片と対比することで、腺腔の大きさや配置の情報を取得し、後処理で腔を選別するなどの必要があると考えられる。ここで得られた知見はDCISとUDHの腺腔構造の3次元的な差異を解析するために今後活用される。

謝辞

本研究の試料を準備していただいた名古屋医療センター病理診断科の皆様へ感謝申し上げます。本研究はJSPS科研費16K01369, 16K08654, 22591353, 15H01129, 26286079, 18K13765, 24601011, 21K04077の支援を受けています。また、KEK放射光実験課題2008S2002, 2012G562, 2014G589, 2015G597, 2016G0625, 2017G697, 2018G669, 2019G598, 2020G583, 2020G565, 2021G587の支援を受けています。

文献

- [1] Ando M, Maksimenko A, Sugiyama H et al. : Simple X-Ray Dark- and Bright-Field Imaging Using Achromatic Laue Optics. Jpn. J. Appl. Phys. 41, B, L1016-L1018 2002
- [2] Sunaguchi N, Yuasa T, Huo Q et al. : X-ray refraction-contrast computed tomography images using dark-field imaging optics. Appl Phys Lett, 107, 253701, 2015
- [3] O. Ronneberger, P. Fischer, T. Brox : U-Net: Convolutional Networks for Biomedical Image Segmentation. The Medical Image Computing and Computer Assisted Intervention Society (MICCAI), vol.9351, 234-241, 2015
- [4] Taniguchi K, Sunaguchi N, Ichihara S et al. : Three-dimensional visualization of ductal carcinoma in situ and usual ductal hyperplasia using the refraction-contrast X-ray computed tomography. SPIE Proceedings. 11600 : 11600T, 2021

マルチモーダルゲーティングを用いた Mixture of Experts による病理画像分類

橋本 典明¹, 高木 優介², 増田 大輝², 三好 寛明³, 高野 桂³, 永石 美晴³,
佐藤 健作³, 大島 孝一³, 本谷 秀堅², 竹内 一郎^{1,4}¹ 理化学研究所, ² 名古屋工業大学, ³ 久留米大学, ⁴ 名古屋大学

Classification of Histopathological Images Using Multimodal Gated Mixture of Experts

Noriaki HASHIMOTO¹, Yusuke TAKAGI², Hiroki MASUDA², Hiroaki MIYOSHIF³, Kei KOHNO³,
Miharu NAGAISHI³, Kensaku SATO³, Koichi OHSHIMA³, Hidekata HONTANI², Ichiro TAKEUCHI^{1,4}¹ RIKEN, ² Nagoya Institute of Technology, ³ Kurume University, ⁴ Nagoya University

要旨: 近年, 医用分野において画像だけではなくその他の患者情報や検査結果を組み合わせたマルチモーダル解析の研究が行われている. 本研究では mixture of experts の枠組みを利用し, 診断情報を組み合わせることで各入力画像に対してどの expert で特徴抽出を行うかを決定する分類モデルを提案する. 問題設定として巨大画像を対象としたマルチインスタンス学習を扱うが, 提案手法はパッチ画像単位でゲーティングを行うことでより詳細な役割を各 expert に与えることを可能とする. 本稿では画像として病理標本バーチャルスライド, 診断情報としてフローサイトメトリー (FCM) データを使用し, リンパ腫症例の分類実験を行うことで提案手法の有効性を確認する. また各症例に対するゲーティングの重みを解析することで, FCM データから自動的に学習した各 expert の役割を明らかにする.

キーワード: 病理画像, マルチモーダル解析, Mixture of experts, フローサイトメトリー, 悪性リンパ腫

1. はじめに

医用分野において画像だけではなくその他の患者情報や検査結果を組み合わせたマルチモーダル解析の研究が行われている. リンパ腫の病理診断では, 患者から採取した検体のうち特定の抗体に反応する細胞がどの程度存在するかを計測するフローサイトメトリー (FCM) が診断時の補助情報として病理医に提供される. FCM データ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 T 細胞由来の病型であるかといった病型グループの大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なクラス分類手法を提案する. 提案手法では 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 による大分類と画像による細分類を効率的に学習し分類精度の向上を目的とする. 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.

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, 各症例は画像 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 中の異常細胞集団の有無を表す L 次元のマルチラベルベクトルである. T_n の各要素には FCM の対応した抗体に異常集団が認められれば 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画像 X_n および FCM データ T_n が同時に入力されたときの Y_n の予測を行う.

提案するクラス分類モデルを図 1 に示す. モデルは大きく特徴抽出部, ゲーティング部と識別部に分かれる. 本研究で扱う

画像 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画像分類を行うためのマルチインスタンス分類手法として attention-based CNN (AB-CNN) を用いる [2]. AB-CNN では M 枚のパッチ画像の集合であるバッグがモデルの入力として与えられる. このときバッグ内の各パッチに対して, 複数ある特徴抽出器のうちどの出力を重視すべきか, という制御を行う部分がゲーティング部である. ある症例のバッグ b の M 枚のパッチ画像および FCM データは特徴抽出器により特徴量に変換され, FCM 特徴量 $h^{(FCM)}$ はパッチ枚数と同じ数コピーされる. パッチ x_m の特徴量 $h_m^{(lm)}$ と FCM 特徴量 $h^{(FCM)}$ を結合することで各パッチ x_m に対するマルチモーダル特徴量 $h_m^{(cat)}$ が得られ, これをゲーティング NN に入力することで各パッチに対するゲーティング重み w_m を計算する. 重み w_m はパッチ画像 x_m がどの特徴抽出器を重視すべきかを表す. 計算された重み w_m を利用して, C 個の expert により計算される複数の特徴量 $h_m^{(c)}$ ($c = 1, \dots, C$) から重みつき特徴量は,

$$h_m^{(agg)} = \sum_c w_m(c) h_m^{(c)} \quad (1)$$

と計算される. 重みつき特徴量からアテンション機構を通じて得られるバッグ特徴量 $h_b^{(agg)} = \sum_m a_m h_m^{(agg)}$ にさらに FCM 特徴量を結合した特徴量 $h_b^{(cat)}$ を用いて最終的に入力バッグ b のクラス予測を行う. ゲーティング重み w_m はどの特徴抽出器を重視するか, またアテンション重み a_m はどのパッチを分類で重視するか, が各重みに期待される役割となる.

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

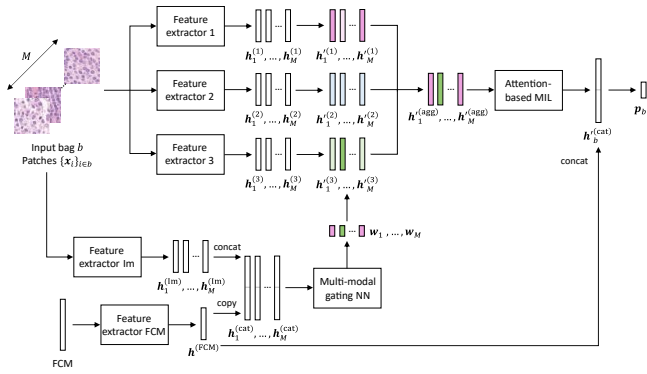


図1 提案手法のモデル構造

た508症例のリンパ腫症例であり、6つの病型からなる。病型の内訳は血管免疫芽球形T細胞リンパ腫(AITL)が59例、成人T細胞白血病/リンパ腫(ATLL)が70例、古典的ホジキンリンパ腫(CHL)が79例、びまん性大細胞型B細胞リンパ腫(DLBCL)が100例、濾胞性リンパ腫(FL)が100例、反応性病変(RL)が100例である。これらのうちDLBCLとFLはB細胞由来リンパ腫、またAITLとATLLはT細胞由来リンパ腫とされており、FCMにより異常細胞が認められた場合には大分類が可能となる。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、FCMデータはある免疫染色マーカーに対して異常細胞が認められたかどうかを二値で表す18次元($L=18$)のベクトルとして扱われる。

モデル中の特徴抽出器として、CNNではResNet50を使用し、NNでは128次元に変換を行う2層NNを使用した。Expertとして用いるCNNはランダムで初期化を行い、ゲーティングCNNではImageNet学習済のパラメータを使用して初期化を行った。また今回は大分類を既知としてexpertの数およびゲーティング重みの次元数は3としている。各バッグに含まれるパッチ画像の数は100枚とし、各症例から最大で50バッグを作成した。全症例の60%を学習データ、20%を検証データ、20%をテストデータに分割し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。

- FCMの18次元ベクトルを入力としたNN(FCM)
- 画像のみから6クラス分類を行うAB-CNN(MIL)
- 上記の特徴量によるマルチモーダル分類(MIL+FCM)

各手法の交差検証における正解率とmacro-F1スコアを表1に示す。提案手法が最もよい分類結果を示し、MoEの機構が正しく学習を行えていることを確認した。

さらにゲーティング重みおよびアテンション重みの可視化を行った。図2および図3はそれぞれDLBCLとFLにおけるexpert1に対するゲーティング重み(中央)と、ゲーティング重みにアテンション重みをかけ合わせたもの(右)である。

表1 5分割交差検証による分類精度の比較

	FCM	MIL	MIL+FCM	MoE
Accuracy	0.593	0.608	0.677	0.685
Macro-F1	0.507	0.597	0.670	0.670




図2 DLBCL症例における重みの可視化結果 (expert 1)




図3 FL症例における重みの可視化結果 (expert 1)

2つの症例は同じB細胞由来の病型群であるため同一のexpertの重みが大きくなっていることが確認できた。FLでは一部のアテンションが小さくなっており、ゲーティング重みとアテンション重みのかけ合わせで値が大きくなっている箇所はモデルがB細胞腫瘍と判断した領域であると予想される。

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、また重みの可視化結果から各expertの役割およびゲーティングの自動学習を確認した。

謝辞

本研究の一部は、科学研究費(20H00601, 16H06538, 18H03262), JST CREST(JPMJCR21D3), 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

- [1] 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.

色素性皮膚病変のハイパースペクトル画像で探索的データ分析

アルポヤニ エレニ^{*1}, 市村 孝也^{*2}, 浜田 芽衣^{*2}, 村上 拓生^{*2}, 佐々木 惇^{*2}, 中村 晃一郎^{*2},
石川 雅浩^{*2}, 小林 直樹^{*2}, 小尾 高史^{*1,3}

^{*1} 東京工業大学

^{*2} 埼玉医科大学

^{*3} 東京工業大学 科学技術創成研究院 未来産業技術研究所

Exploratory Data Analysis on Hyper-spectral Images of Pigmented Skin Lesions

Eleni ALOUPOGIANNI^{*1}, Takaya ICHIMURA^{*2}, Mei HAMADA^{*2}, Takuo MURAKAMI^{*2}, Atsushi SASAKI^{*2}, Koichiro NAKAMURA^{*2}, Masahiro ISHIKAWA^{*2}, Naoki KOBAYASHI^{*2}, Takashi OBI^{*1,3}

^{*1} *Tokyo Institute of Technology, Tokyo, Japan*

^{*2} *Saitama Medical University, Saitama, Japan*

^{*3} *Institute of Innovative Research, Tokyo Institute of Technology, Tokyo, Japan*

要旨 : Amid the global Covid-19 pandemic, the importance of telepathology and computer-assisted diagnosis is prominent. Skin cancer has a high incidence worldwide and early detection is key for successful treatment. Hyper-spectral Imaging (HSI) is an emerging non-invasive modality in the gross pathology of the skin. Spectral signatures of skin tissue samples can help detect valuable pathological features and discriminate malignancies. In this study, we applied exploratory data analysis on a new HSI dataset of 20 ex-vivo skin samples during pathology. Hyper-spectral imaging was performed using a custom imaging system that operates in the range [420,730] nm with step 1nm. We evaluated histology-validated cancer margins against components derived from Principal Component Analysis, Reconstructed Independent Component Analysis and Spectral Angle Mapper. Data insights were evaluated by medical professionals. Preliminary findings show that the first principal components can provide information regarding the condition of the underlying tissue. Such information can be used to determine optical cancer margins.

キーワード : gross pathology, hyperspectral imaging, data analysis, skin cancer, semantic segmentation

1. Introduction

The Covid-19 pandemic highlighted the necessity of telepathology. Computer-assisted diagnosis can facilitate remote diagnosis and relieve some of the burden to the medical personnel. In the past decades, incidence rates of malignant melanoma and other skin cancers increased twofold in Japan. Hyperspectral Imaging (HSI) is an emerging non-invasive, non-ionizing imaging modality that captures spectral signatures of the tissue [1]. Using narrow-band filters, reflectance information is extracted at individual wavelengths, in contrast to the integrated information of common camera filters. Spectral signatures detect chromophore expression of pathological processes, i.e. angiogenesis, that are associated with tumor growths.

HSI was first proposed for remote sensing applications but has since been applied in pathology. Vectors of spectral signatures are hundred points long, which increases the complexity and hinders the effectiveness of standard analysis methods. Feature extraction can reduce the number of features and discard redundancies that are inherent in HSI. Afterwards, the extracted features can be used to detect tumor margins on the tissue. In this study, we investigated three common feature extraction methods and interpreted the features they represent compared to histological findings.

2. Materials and Methods

Twenty ex-vivo samples of pigmented skin lesions were imaged using a custom HSI system [2]. Each data cube has spectral range [420,730] nm with step 1nm and the maximum spatial dimension was 500pixels (corresponding to a sample with length 8cm). Each image required 1-2 minutes for acquisition. The experiments in this study were approved by the Ethical Committee of Saitama Medical University (977) and all participants gave informed consent for the scientific use of their data. The images were histologically evaluated by trained pathologists and dermatologists. A total of 384,014 spectral signatures were captured, 32% of which were within the tumor margin detected by histology.

Three methods were used for feature extraction. Principal Component Analysis (PCA) is a common compression technique, which projects the data in an axis that maximizes data variance. On the other hand, Reconstructed Independent Component Analysis (RICA) unmixes components in the data by optimizing a reconstruction criterion. Spectral Angle Mapper (SAM) is a HSI-specific approach that assigns a small angular value to similar spectral




Figure 1 – The three first transformation coefficient vectors of (a) PCA and (b) RICA. The percentage value is the explained variance for transformation vector.

signatures [3]. PCA and RICA were trained on 17 data cubes and applied on the remaining three. SAM does not require any training. A signature of healthy skin was used as the reference spectrum for SAM. The extracted features and transformation vectors were compared visually and evaluated quantitatively by two trained pathologists.

3. Results

In Figure 1 we observe the results of the three first transformation vectors for PCA and RICA. The first vector of PCA and the third vector of RICA explain more than 80% of data variance and its shape is similar to the base component of skin tissue. For PCA, the second PC resembles the absorbance spectrum of deoxyhemoglobin (HbO₂), a chromophore of the skin, as seen by the critical points at 570nm and 630nm. The third PC has a negative slope at range [500,600] nm, after which it sharply increases. The 600nm point coincides with the

wavelength after which the absorbance of melanin becomes more prominent than HbO₂. The first and second ICs of RICA are noisy. The second IC assigns large coefficients at the area after 600nm. The first IC does not show a clear trend of coefficients.

Extracted features for a Basal Cell Carcinoma sample are presented in Figure 2. The tumor is contained at the central part of the sample. SAM angles detect the highest discrepancy from healthy tissue at blood stains on the edge, instead of the center. The second PC and the second IC provide similar results, for this sample only. Both detect the center of the tissue and the surrounding ring as two areas with different scores. However, evaluation of PCA and RICA components by two pathologists revealed that RICA extracts artifacts and other reflectance features that happen to coincide with the tumor area, instead of extracting actual tumor patterns. This was further corroborated by the noisy transformation vectors of RICA. Therefore, information from PCA is more suitable for tumor margin detection.

4. Conclusion

This study presented features extracted from skin tissue HSI, which were then associated to the properties of skin chromophores. PCA produced interpretable feature coefficients, which is essential for applications in pathology. RICA was severely affected by data noise. Despite being a powerful method, SAM failed to discriminate tumor from healthy tissue in this experiment. The second and third principal components show potential in detect tumor margins, paving the way towards optical biopsy. However, rigorous evaluation with more complex experiments is necessary.

Acknowledgment

This work was supported by JKA and its promotion funds from KEIRIN Race.

Disclosures

The authors disclose no conflicts of interest.

References

- [1] Ortega, S., Halicek, M., Fabelo, H., et al: Hyperspectral and multispectral imaging in digital and computational pathology: a systematic review [Invited]. *Biomedical Optics Express*, 11(6): 3195, 2020
- [2] Aloupogianni, E., Ishikawa, M., Ichimura, T., et al: Design of a Hyper-Spectral Imaging System for Gross Pathology of Pigmented Skin Lesions. *Annu Int Conf IEEE Eng Med Biol Soc.* 2021 Nov: 3605-3608, 2021
- [3] Nagaoka, T., Kiyohara, Y., Koga, H., et al: Modification of a melanoma discrimination index derived from hyperspectral data: A clinical trial conducted in 2 centers between March 2011 and December 2013. *Skin Research and Technology*, 21(3): 278–283, 2015

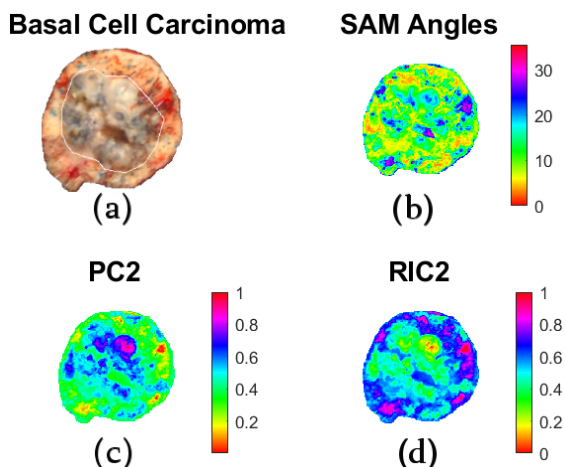


Figure 2 - A sample of Basal Cell Carcinoma where the tumor margin is marked with white. Values of (b) SAM angles, (c) the 2nd principal component and (d) the 2nd independent component are demonstrated.

ICI 治療の NSCLC 患者における肺腫瘍細胞数の経時変化曲線の推定

内野 恭美^{*1}, 有村秀孝^{*1}, 田中謙太郎^{*2}, 藪内英剛^{*1}^{*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呼吸器内科学分野

*1 〒812-8582 福岡県福岡市東区馬出 3-1-1

E-mail: uchino.kyomi.516@s.kyushu-u.ac.jp

Tumor Growth Trajectories for Immune Checkpoint Inhibitor treated Patients with Non-small Cell Lung Cancer

Kyomi UCHINO^{*1}, Hidetaka ARIMURA^{*1}, Kentaro TANAKA^{*2}, Hidetake YABUUCHI^{*1}^{*1} Division of Medical Quantum Science, Department of Health Sciences, Graduate School of Medical Sciences, Kyushu University.^{*2} Research Institute for Diseases of the Chest, Graduate School of Medical Sciences, Kyushu University.

*1 〒812-8582 3-1-1 Maidashi, Higashi-ku, Fukuoka, 812-8582, Japan

E-mail: uchino.kyomi.516@s.kyushu-u.ac.jp

要旨: 本研究では、免疫チェックポイント阻害剤(ICI)により治療された非小細胞肺癌(NSCLC)患者のCT画像を用いて、腫瘍細胞数の経時変化曲線(TGT)を推定する方法を研究した。ICI治療(attezolizumab)を受けたNSCLC患者6人を用い、腫瘍輪郭を抽出し腫瘍細胞数を計算した。腫瘍輪郭は治療前CTとフォローアップCT画像で抽出した。腫瘍細胞はICI感受性、耐性、persister細胞から成ると仮定し、Bertalanffy-Putterモデルを用いてTGTを予測した。焼きなまし法を用いてTGTモデルの14個のパラメータを最適化した。各CT撮影時点における腫瘍細胞数と予測値の関係を、スピアマン順位相関係数を用いて評価した。スピアマン順位相関係数の二乗平均平方根は0.758であった。本手法はICI治療患者のTGTを推定できる可能性がある。

キーワード: 免疫チェックポイント阻害剤, 非小細胞肺癌, 経時変化曲線, 最適化, シミュレーション

1. はじめに

肺癌は悪性腫瘍の中でも生存率が低く、その中でも非小細胞肺癌(NSCLC:non small cell lung cancer)は肺癌の約85%を占めている[1]。PD-1またはPD-L1を標的とする免疫チェックポイント阻害剤(ICI:immune checkpoint inhibitor)は、遺伝子変化を伴わないNSCLC患者の標準治療である[2]。

腫瘍細胞に表面に発現するPD-1/PD-L1シグナル経路が活性化すると、腫瘍細胞は免疫から逃れ増殖につながる。ICI治療薬であるPD-1/PD-L1抗体はこの経路を阻害し、抑制シグナルの伝達を阻止することでT細胞の活性を保持することで抗腫瘍効果を得ることができる。腫瘍におけるPD-L1発現は、PD-1/PD-L1抗体が奏効する確率向上と関連しているが、PD-L1陰性の腫瘍においても低確率ではあるが奏効する可能性がある[3]。したがって、各患者においてICIの治療効果を予測することが重要である。

そこで本研究では、ICIで治療されたNSCLC患者のCT画像を用いて、腫瘍細胞数の経時変化曲線(TGT:tumor growth trajectory)を推定した。

2. 方法

本研究では、九州大学病院においてICI治療を受けたNSCLC患者6人の治療前CT画像と治療中のフォローアップCT画像

(非造影CT画像を除く)を用いた。患者の臨床情報を表1に示す。これらの患者はICIであるatezolizumab,細胞障害性抗癌剤であるCBDCA, pemetrexed,と血管新生阻害剤であるbevacizumabにより同一のレジメンで治療された。これらの治療薬の情報について表2に示す。

腫瘍細胞数の取得方法を図1に示す。治療前と治療後のすべてのCT画像の腫瘍領域を、放射線治療計画用ソフトウェアEclipse(Varian社)を用いて、400のウィンドウ幅、軟部組織用の50のウィンドウレベルで手動により抽出し、ROI(regions of interest)とした。すべての腫瘍領域は、肺癌専門医と放射線科医により監修された。

抽出された腫瘍体積を腫瘍細胞数に変換するため、セグメンテーションで得たROIを二値化した後、等方ボクセル画像に変換した。CT画像における水との相対電子密度(RED:relative electron density for water)は、細胞密度と比例関係を持つと仮定し、式(1)を用いて腫瘍細胞数を計算した。

$$N_t = \sum_{i=1}^{N_v} R_i \quad (1)$$

N_t は腫瘍細胞数、 N_v はROIにおけるボクセル数、 R_i は水の相対電子密度である。また腫瘍細胞はICI感受性、耐性、persister細胞から成ると仮定[4,5]し、Bertalanffy-Putter方程式[6](式(2))とCell lossモデル[5](式(3)), PD-L1抗体応答関数[7](式(4))を元にTGTモデルを構築した。また各パラメータは表3にまと

めた.

$$\frac{dv(t)}{dt} = p \cdot v(t)^a - q \cdot v(t)^b \quad (2)$$

$$\frac{dN(t)}{dt} = -\beta_c C_{max} e^{-\frac{\ln(2)}{T_{1/2}} t} N(t) \quad (3)$$

$$\mathcal{F} = \frac{c_{pd} - 1}{\pi} \left(\tan^{-1} \left((C_I(t) - 1) \cdot k_{pd} \right) + \frac{\pi}{2} \right) + 1 \quad (4)$$

ICI 感受性, 耐性, persister 細胞は式(5)から式(7)のように定義した.

$$\frac{dN_S}{dt} = u_S N_S^j - v_S N_S^k - \mathcal{F} \beta C(t) (u_S N_S^j - v_S N_S^k) \quad (5)$$

$$\frac{dN_P}{dt} = u_P N_P^j - v_P N_P^k - \mu (u_P N_P^j - v_P N_P^k) \quad (6)$$

$$\frac{dN_R}{dt} = u_R N_R^j - v_R N_R^k + \mu (u_R N_R^j - v_R N_R^k) \quad (7)$$

また腫瘍細胞数は式(8)から式(11)のように定義した.

$$N_{total} = N_S + N_P + N_R \quad (8)$$

$$N_P = a N_{total} \quad (9)$$

$$N_R = b N_{total} \quad (10)$$

$$N_S = (1 - a - b) N_{total} \quad (11)$$

最後に, 焼きなまし法を用いて TGT モデルの 14 個のパラメータを最適化し, TGT を得た.

表 1. 患者の臨床情報

Number of patients	6
Age (years)	60 - 79(Average: 70.7)
Sex	
Male	3
Female	3
Stage	
Stage 4A	1
Stage 4B	5
Type	
Adenocarcinoma	4
Not otherwise specified	2
Dose	
Immune Checkpoint Inhibitor	Atezolizumab
Cytotoxic chemotherapeutic agent	CBDCA, Pemetrexed
Anti-angiogenic drug	Bevacizumab
Number of timepoint	2 - 9 (Average: 5.7)
Days of treatment (days)	38 - 424(Average: 233.7)

表 3. TGT モデルのパラメータ

Parameter	Explain
$u_S, u_P, u_R, v_S, v_P, v_R$	Scaling constants
j, k	Growth rates of sensitive, persister, and resistant cells
$\beta \left(\frac{\mu g}{mL} \right)^{-1}$	Cell loss parameter
μ	Compound mutation probability
a, b	Initial fraction value of persister and resistant population
N_{total}, N_S, N_P, N_R	Number of cells of total, sensitive, persister and resistant
c_{pd}	Scales \mathcal{F} , the amount of Anti-PD-L1 to a non-dimensionalized value
k_{pd}	Scaler for switch function, \mathcal{F} , to model effects of Anti-PD-L1
C	Dose concentration of ICI
C_{max}	Maximum concentration at steady state of ICI
$T_{1/2}$	The half life of ICI

表 2. 治療薬情報

Name of Drug	Dose concentration	Dose interbal	Drug Half-life (day)	Maximum Concentration At Steady State ($\mu g/mL$)
			$T_{1/2}$	C_{max}
CBDCA*	AUC = 6	3 week	0.63 ± 0.04 (hr) = 0.0275 (day)	5.89 ± 0.51 ($\mu g/mL$)
Pemetrexed**	500 (mg/m ²) 115 ($\mu g/mL$)	3 week	2.62 ± 3.29 (hr) = 0.109 (day)	115 ± 19.1 ($\mu g/mL$)
Bevacizumab***	15 (mg/kg)	3 week	10.3 ± 2.4 (day)	314.8 ± 40.4 ($\mu g/mL$)
Atezolizumab****	1200 (mg/body)	3 week	13.0 ± 1.32 (day)	536 ± 49.4 ($\mu g/mL$)




図 1. 腫瘍細胞数の計算方法




図 2. TGT の例.

3. 結果

図 2 に本モデルを用いた腫瘍細胞数の TGT の推定結果の例を示す. 本症例において, 各 CT 撮影時点における腫瘍細胞数と予測値の関係を, スピアマン順位相関係数を用いて評価したところ, 0.933 であった. また全症例について, スピアマン順位相関係数の二乗平均平方根は 0.758 であった.

4. まとめ

これらの結果から, 本手法により ICI 治療患者の TGT を推定できる可能性があることが示唆された.

謝辞

本研究の一部は, 科学研究費補助金 (基盤(C) JP20K08084) の助成を受けたものである.

利益相反の有無

なし

文献

- [1] Zappa C, Mousa SA: Non - small cell lung cancer: current treatment and future advances. *Transl Lung Cancer Res* 5(3): 288-300, 2016
- [2] Malhotra J, Jabbour SK, Aisner J: Current state of immunotherapy for non-small cell lung cancer. *Transl Lung Cancer Research* 6(2): 196-211, 2017
- [3] Yu H, Boyle T A, Zhou C et al: PD-L1 Expression in Lung Cancer. *J Thorac Oncol* 11(7), 964-975, 2016
- [4] Sehgal K, Portell A, Ivanova EV et al: Dynamic single-cell RNA sequencing identifies immunotherapy persister cells following PD-1 blockade. *J Clin Invest* 31(2): e135038, 2021
- [5] 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.
- [6] von Bertalanffy L: Quantitative laws in metabolism and growth, *The Quarterly review of biology* 32(3): 217-231, 1957
- [7] Radunskaya A, Kim R, Woods II T: Mathematical Modeling of Tumor Immune Interactions: A Closer Look at the Role of a PD-L1 Inhibitor in Cancer Immunotherapy, Spora: *Journal of Biomathematics* 4(1): 25-41, 2018

胸部 X 線画像および診断構造化ラベルを用いた機械学習による 急性呼吸窮迫症候群(ARDS)患者の早期死亡予測

齊藤 幸喜^{*1}

^{*1} 帝京科学大学生命環境学部生命科学科

Machine Learning with Chest X-Ray Images and Diagnostic Structured Labels for Predicting Early Death in Patients with Acute Respiratory Distress Syndrome (ARDS)

Koki SAITO^{*1}

^{*1} *Teikyo University of Science, Faculty of Life & Environmental Sciences,
Department of Life & Health Sciences*

要旨：急性呼吸窮迫症候群 (ARDS) とは、重症肺炎や敗血症などの様々な疾患が原因となり重度の呼吸不全となる症状の総称である。本研究では、胸部 X 線ビッグデータ(MIMIC-CXR-JPG)を用いて作成した機械学習モデルを用いて ARDS 患者の早期死亡予測について検討した。機械学習には 160 枚の胸部 X 線画像および診断構造化ラベルを用い、DataRobot を利用したマルチモーダルな解析を行った。最適化したモデルで死亡予測を行ったところ、AUC=0.9524 を達成した。このモデルを用いて、学習および評価で使用していない 10 名の ARDS 患者の ICU 初回入室時の画像および構造化ラベルを用いて死亡の早期予測について検討した。さらに、この内の 1 名について時系列で死亡予測を行ったところ、時間とともに死亡確率の上昇が認められ、死亡確率 0.4 程度で重点的な早期介入が必要であることが示唆された。

キーワード：急性呼吸窮迫症候群，早期死亡予測，胸部 X 線ビッグデータ，機械学習，マルチモーダル

1. はじめに

急性呼吸窮迫症候群(ARDS)とは、重症肺炎、敗血症や外傷などの様々な疾患が原因となり重度の呼吸不全となる症状の総称である。疾患により炎症性細胞が活性化され、肺の組織である肺胞や毛細血管に傷害を与える。この結果、肺に水がたまり、重度の呼吸不全が引き起こされる。発症後の死亡率は全体の 30~58%[1]とも言われており、極めて予後が悪い。ARDS を早期に診断する具体的かつ高感度な手段はなく、いったん診断されると急速に進行する傾向がある。

機械学習を用いて ARDS 発症の有無を予測した研究[2,3]は報告されているが、これらの先行研究では、いずれもテーブル形式のデータのみを用いて解析を行っている。本研究では、テーブルデータと画像データを組み合わせたマルチモーダルな解析を行うことにより、予測精度の向上および ARDS 患者の死亡の早期予測を目的とする。

2. 研究方法

本研究で使用した胸部 X 線データは、米国マサチューセッツ州ボストンの三次学術医療センターに入院した患者に関する MIMIC-IV データベース[4]である。MIMIC-IV データベースの 1 つのモジュールである MIMIC-CXR データセットには、

64,588 人の患者を対象とした 377,110 枚の DICOM 形式の胸部 X 線画像と、これらの画像に関連付けられた放射線レポートから派生した構造化ラベルが含まれている。今回の解析には MIMIC-CXR を基に作成された MIMIC-CXR-JPG[5]に含まれる JPG 形式の画像と CSV 形式のテーブルデータを使用した。

テーブルデータには"Atelectasis"などの 13 個の所見に加えて、これらの所見が見られない場合には"No Finding"というラベルが付けられている。各ラベル列に入っている数字は 1, 0, -1 の 3 種類である。1 は放射線レポートで積極的に言及されており、対応する画像に所見が存在することを意味する。一方、0 は放射線レポートで否定的に言及されており、対応する画像に所見が存在しないことを意味する。また、-1 は不確実な言葉で言及されていることを意味する。放射線レポートに記載がない場合は空白となっている。

MIMIC-CXR データセットに含まれる患者の内、ARDS と診断され、かつ対応する X 線画像がある患者数は 98 名であった。これらの患者の画像の内、160 枚(生存:87 枚、死亡:73 枚)を解析に用いた。80%の画像で 5-fold Cross-Validation を行い、20%の画像を Hold Out とした。機械学習には DataRobot[6]を使用し、複数のモデルを同時に探索した。

3. 研究結果および考察

テーブルデータと胸部 X 線画像を共に用いたマルチモーダルな解析を行った結果、最も精度の高いモデルは Elastic-Net Classifier であり、図 1 に示すように、AUC=0.9524, F1 スコア =0.8966 を達成した。

^{*1} 帝京科学大学生命環境学部生命科学科
〒120-0045 東京都足立区千住桜木 2-2-1
e-mail: saito@ntu.ac.jp

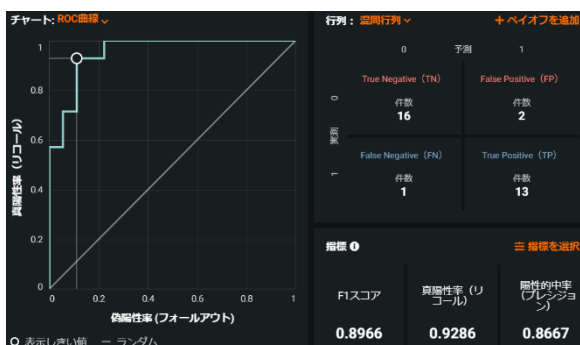


図1 機械学習結果

次に、テーブルデータと胸部 X 線画像を用いて得られたモデルを利用して、これまでの学習および評価で未使用な 10 名（生存 6 名，死亡 4 名）の ARDS 患者の ICU 初回入室時の構造化ラベルおよび胸部 X 線画像を用いて死亡の早期予測について検討した。予測結果を表 1 に示す。

表 1 未使用のデータを用いた死亡予測結果

row_id	hospital_expire_flag	Prediction	PredictedLabel
0	0	0.00569048	0
1	0	0.000582304	0
2	0	0.005645983	0
3	0	0.126366466	0
4	0	0.029576415	0
5	0	0.157584603	0
6	1	0.468173711	0
7	1	0.001504855	0
8	1	0.500738274	1
9	1	0.639865184	1

生存の 6 名については正確に生存と予測できたが，死亡した 4 名の内 2 名については，予測結果は生存となった。これは，初回の ICU 入室時にはまだあまり症状が悪化していなかったためと考えられる。

そこで，さらにこの内の 1 名（表 1 の row_id=7 の患者）について時系列で死亡予測を行った結果を表 2 に示す。

表 2 時系列死亡予測結果

row_id	hospital_expire_flag	Prediction	PredictedLabel	StudyDate
0	1	0.001504855	0	21660524
1	1	0.004248097	0	21660529
2	1	0.011263879	0	21660531
3	1	0.020634747	0	21690601
4	1	0.028554672	0	21690602
5	1	0.049225052	0	21690604
6	1	0.078506466	0	21690605
7	1	0.003121537	0	21690605
8	1	0.022514095	0	21690606
9	1	0.007003632	0	21690607
10	1	0.104977898	0	21690608
11	1	0.414403025	0	21690609
12	1	0.158498019	0	21690610
13	1	0.887654166	1	21690611
14	1	0.312127207	0	21690612
15	1	0.963139228	1	21690614
16	1	0.393967837	0	21690614
17	1	0.617394268	1	21690621
18	1	0.895201012	1	21690622
19	1	0.808762213	1	21690622
20	1	0.579501261	1	21690622

ICU初回入室
 3年後ICU再入室
 再入室から8日後
 再入室から21日後

この患者は，ICU 初回入室後，一旦は退室したが，3 年後に再入室しており，死亡予測確率が上昇していることから症状は悪化していると考えられる。さらに，再入室から 8 日後には死亡確率が 0.4 を超え，その後急激に悪化し，再入室から 21 日後に死亡が確認された。実際の胸部 X 線画像の推移を見ると，死亡確率が 0.4 を超えると，肺に見られるすりガラス様陰影が増加しており，胸水の貯留も認められた。以上の結果から，本研究で開発したモデルを用いた場合，死亡確率 0.4 程度で重点的な早期介入が必要であることが示唆された。ただし，このモデルの一般性を確認するためには，他の機関における検証研究が必要であると考えられる。

3. 結語

胸部 X 線画像および診断構造化ラベルを用いて ARDS 患者の早期死亡予測モデルの開発を行った。最適化したモデルで死亡予測を行ったところ，AUC=0.9524 を達成した。さらに，モデル開発において使用していない 1 名のデータについて時系列で死亡予測を行ったところ，時間とともに死亡確率の上昇が認められ，死亡確率 0.4 程度で重点的な早期介入が必要であることが示唆された。

ただし，今回のモデルはアメリカの 1 つの病院におけるデータを基に開発したものであるため，偏りが生まれる可能性がある。将来的に多施設の症例を取り入れた高精度な機械学習モデルが作成され，ARDS 患者に対する早期介入基準を定める標準的な指標の一つとなることを期待する。

謝辞

本研究の成果は，2021 年度第 3 回 社会変革型医療データサイエンティスト育成 (DHIEP) プログラム (<https://dkgrp.hs.med.kyoto-u.ac.jp>) を通じて得られたものに基づいています。

利益相反の有無

なし。

文献

[1] ARDS 診療ガイドライン 2016. <https://minds.jcqhc.or.jp/n/med/4/med0241/G0000890> (2022 年 5 月 5 日閲覧)

[2] Ding XF, Li JB, Liang HY, et al: Predictive model for acute respiratory distress syndrome events in ICU patients in China using machine learning algorithms: a secondary analysis of a cohort study. J Transl Med. 17: 326-335, 2019

[3] Le S, Pellegrini E, Green-Saxena A, et al: Supervised machine learning for the early prediction of acute respiratory distress syndrome (ARDS). J Critical Care 60: 96-102, 2020

[4] MIMIC-IV. <https://physionet.org/content/mimiciv/1.0/> (2022 年 5 月 5 日閲覧)

[5] MIMIC-CXR-JPG. <https://physionet.org/content/mimic-cxr-jpg/2.0.0/> (2022 年 5 月 5 日閲覧)

[6] DataRobot. <https://www.datarobot.com/jp/> (2022 年 5 月 5 日閲覧)

治療計画 CT 画像のトポロジー解析によるレディオミクスシグネチャを用いた 体幹部定位放射線治療を受けたステージ I 非小細胞肺癌患者の進行予測

児玉 拓巳^{*1}, 有村 秀孝^{*2}, 白川 友子^{*3}, 二宮 健太^{*1},
吉武 忠正^{*2}, 塩山 善之^{*4}

^{*1} 九州大学大学院医学系学府保健学専攻

^{*2} 九州大学医学研究院保健学専攻

^{*3} 九州がんセンター

^{*4} 九州国際重粒子線がん治療センター

Prediction of time to progression of stage I non-small cell lung cancer patients treated with SABR using topology-based radiomics signature on pretreatment planning CT images

Takumi KODAMA^{*1}, Hidetaka ARIMURA^{*2}, Kenta NINOMIYA^{*1}, Yuko SHIRAKAWA^{*3},
Tadamasa YOSHITAKE^{*2}, Yoshiyuki SHIOYAMA^{*4}

^{*1} Department of Health Sciences, Graduate School of Medical Sciences, Kyushu University.

^{*2} Department of Health Sciences, Faculty of Medical Sciences, Kyushu University

^{*3} National Hospital Organization Kyushu Cancer Center

^{*4} Ion Beam Therapy Center, SAGA HIMAT Foundation

要旨：早期非小細胞肺癌(NSCLC)の標準治療は手術と体幹部定位放射線治療(SABR)で、両者の治療効果は同等であり、治療前の再発リスク予測により患者毎の適切な治療法選択を実現する可能性がある。本研究の目的は、SABR の治療前計画 CT 画像のトポロジー解析による画像シグネチャを用いてステージ I 期 NSCLC 患者の治療後の癌進行を予測することである。患者群をレディオミクススコア(Rad-score)により高・低リスク群に分類し、p 値(log-rank test), c-index, 総合指標の nLPC を用いて評価した。Rad-score は、従来ウェーブレット特徴量(WFs)及びトポロジー解析に基づくベッチ数マップから得た特徴量(TFs)を基に Cox-net により構築したシグネチャから計算された。テスト症例の p 値, c-index, nLPC はそれぞれ, TFs で 3.28×10^{-2} , 0.80, 1.19, WFs で 3.13×10^{-2} , 0.72, 1.08 であった。TFs は WFs と比較しより有意な NSCLC の進行との関連性を持つ可能性がある。

キーワード：非小細胞肺癌, 体幹部定位放射線治療, トポロジー, レディオミクス

1. はじめに

早期(ステージ I・II 期)非小細胞肺癌(NSCLC)の標準治療法は、手術可能症例で手術、手術不可症例で根治的放射線治療である[1]。しかし、ステージ I 期 NSCLC 患者の外科的治療と体幹部定位放射線治療(SABR)の治療効果が同等であると報告されている[2]。このため、患者毎の適切な治療法選択のため治療前の術後増悪予測が重要である。

トポロジー解析に基づく輝度不均一性を定量化する画像特徴量は NSCLC の予後と関連を持つ可能性がある。トポロジーとは「繋がり幾何学」と呼ばれ、n 次元の穴を定量化する手法である。n 次元の穴を計数するベッチ数マップ(BN マップ)を開発し、その特徴量から構築されるシグネチャが従来法と比較して高い予後予測能を持つ可能性を示した[3]。

そこで本研究の目的は、SABR の治療前計画 CT 画像のトポロジー解析による画像シグネチャを用いてステージ I

期 NSCLC 患者の治療後の癌進行を予測することである。

2. 方法

1) 使用データ

九州大学病院で SABR を受けたステージ I 期 NSCLC 患者(n = 125; n: 症例数)の治療計画 CT 画像及び臨床情報を用いた。治療後癌進行のあった症例は 44 症例で、無増悪期間(TTP)の中央値は 30 ヶ月であった。進行は、術後の局所再発、領域再発、または遠隔転移と定義し、進行までの期間が TTP である。本研究は、九州大学病院倫理委員会の承認

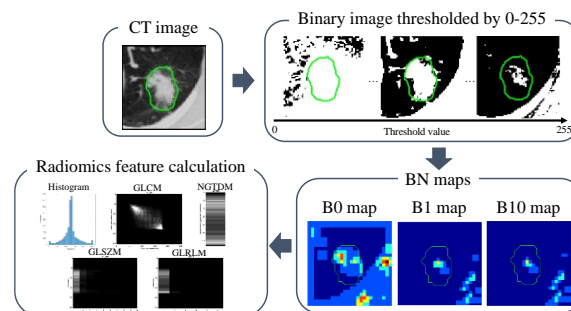


図1 BN マップ計算及び特徴量計算の概念図

^{*1} 九州大学医学系学府保健学専攻

[〒812-8582, 福岡県福岡市東区馬出 3-1-1]

E-mail: kodama.takumi.987@s.kyushu-u.ac.jp

表 1 計算した p 値 (log-rank 検定), c-index, nLPC

	p-value (HR, 95% CI)		c-index (95% CI)		nLPC	
	Training dataset	Test dataset	Training dataset	Test dataset	Training dataset	Test dataset
TFs	1.07×10^{-6} (0.15, 0.07 - 0.31)	3.28×10^{-2} (0.22, 0.08 - 0.67)	0.818 (0.73 - 0.90)	0.798 (0.66 - 0.93)	4.88	1.18
WFs	5.82×10^{-6} (0.18, 0.09 - 0.38)	3.13×10^{-2} (0.30, 0.10 - 0.90)	0.815 (0.75 - 0.88)	0.717 (0.56 - 0.87)	4.27	1.08

HR: Hazard ratio, CI: Confidence interval

を受けて実施した。CT 画像の前処理として、等方ボクセル化と 8 bits 再量子化, Laplacian of Gaussian フィルタを用いたエッジ強調を行った。

2) 提案手法

全患者 125 症例(進行 : n=44, 非進行 : n=81)を 88 の学習症例(進行 : n=31, 非進行 : n=57)と 37 のテスト症例(進行 : n=13, 非進行 : n=24)に分け, 患者群を学習症例のレディオミクススコア(Rad-score)の中央値により高・低リスク群に層別化し, 予後予測性能を評価した。Rad-score は, Cox-net により選択された重要特徴量ベクトルであるシグネチャから計算された。

3) 特徴量抽出

本研究では, トポロジー解析による BN マップから得られる特徴量(TFs)と従来法(WFs)を比較した。TFs は, 原画像及びBNマップからヒストグラムとテクスチャ解析(GLCM, GLRLM, GLSZM, NGTDM)によって計 41,526 個得られた。BN マップは, 前処理した CT 画像から GTV 最大面積のスライスを選択し, 0 から 255 の閾値で二値化して, それぞれの二値画像で 0 次元の穴(連結成分; B0)と 1 次元の穴(穴構造; B1)の数を計数し投影することで得られる(図 1)。B10 マップは B1 マップと B0 マップの除算で求められ, 連結成分と穴構造の分布の比を表す。WFs は, 8 種類の三次元ウェーブレット分解画像及び原画像から, TFs と同様にヒストグラムとテクスチャ解析によって計 486 個得られた。

4) Rad-score と患者のリスク群別層別化

Rad-score は, シグネチャと Cox 比例ハザードモデル(CPHM)に基づく回帰係数の乗算で求められる。シグネチャを構成する 8 つの重要特徴量は Cox-net 正則化により選択された。重要特徴量の数は学習症例数の約 10%に設定するのがよいとされ, 8 つの特徴量を選択した。また, CPHM 回帰係数の絶対値が高い特徴量は, 予後との相関が高いと仮定し, 回帰係数に基づく特徴量選択を行った。

学習症例とテスト症例の患者群は学習症例の Rad-score の中央値を用いて高・低リスク群に層別化され, それぞれ TTP のカプランマイヤー(KM)曲線を作成した。

5) 評価方法

KM 曲線は, log-rank 検定の p 値で統計的有意差(< 0.05)を評価した。また, Concordance index (c-index)で Rad-score

と TTP の相関を評価し, p 値の負の対数(-log₁₀ p)と c-index を乗算し両者を総合的に評価する指標(nLPC)で WFs と TFs の癌進行の予後予測能を総合的に評価した。

3. 結果




図 2 TFs (a)と WFs (b)の TTP の KM 曲線

TFs と WFs について学習症例とテスト症例で計算された p 値, c-index, nLPC を表 1 に示す。テスト症例の p 値より, TFs と WFs 共に TTP の KM 曲線(図 2)で統計的有意差を示した。また, c-index と nLPC はそれぞれ TFs で 0.798, 1.18, WFs で 0.717, 1.08 であった。

4. 考察

今後, 局所領域再発や遠隔転移など再発別リスク分類の可能性を検討する。また, 腫瘍体積や組織型など臨床情報と組み合わせる手法の改善を検討する。

5. まとめ

本稿では, ステージ I 期 NSCLC 患者の治療後の癌進行について, 治療前 CT 画像から得られた TFs と WFs を用いて計算した Rad-score で高・低リスク群に層別化し, TFs が TTP の予後予測能を持つ可能性を示した。

謝辞

本研究の一部は, 科学研究費補助金(基盤(C) JP20K08084)の助成を受けた。本研究を進めるにあたり, 貴重なご意見をいただいた有村研究室の皆様へ感謝いたします。

利益相反の有無

なし

文献

- [1] Lackner RP, Lanuti M, Leal TA, et al. Clinical Practice Guidelines in Oncology NCCN Categories of Evidence and Consensus. JNCCN-Journal Natl Compr Cancer Netw. 15(4):504-535, 2017.
- [2] Onishi H, Shirato H, Nagata Y, et al. Stereotactic body radiotherapy (SBRT) for operable Stage I non-small-cell lung cancer: Can SBRT be comparable to surgery? Int J Radiat Oncol Biol Phys. 81(5):1352-1358, 2011.
- [3] Ninomiya K, Arimura H. Homological radiomics analysis for prognostic prediction in lung cancer patients. Phys Medica. 69:90-100, 2020.

3DCNN を用いた MR 画像における前立腺癌患者の術後尿禁制予測

大羽 史晃^{*1}, 寺本 篤司^{*1}, 住友 誠^{*2}, 中村 渉^{*2}

^{*1} 藤田医科大学大学院保健学研究科

^{*2} 藤田医科大学医学部

Prediction of postoperative urinary continence in prostate cancer patients on MR image using 3DCNN

Fumiaki OBA^{*1}, Atsushi TERAMOTO^{*1}, Makoto SUMITOMO^{*2}, Wataru NAKAMURA^{*2}

^{*1} Graduate School of Health Sciences, Fujita Health University

^{*2} School of Medicine, Fujita Health University

要旨：前立腺癌は他の悪性腫瘍に比べ進行が緩徐であるため適切な治療により根治が期待でき、近年は、治療法の1つである手術療法において低侵襲なロボット手術の普及により、従来の手法に比べ早期の社会復帰が可能となっている。しかし、依然として副作用である尿失禁が生じた場合、患者の日常生活への影響は無視できないため、術後の尿禁制予測は、治療法選択の一助となることが期待される。そこで本研究では、多施設にて診断時に撮影されたMR画像に対し画像信号強度の不均一補正や3次元的なトリミングといった前処理を行った後、3DCNNに入力し、症例ごとに尿禁制良好および不良の分類を行った。尿禁制の程度については、術後6か月の時点における1日の尿パッド交換枚数を基に良好と不良に選別した。結果は、尿禁制良好の正解率が82.5%、尿禁制不良では61.9%となり、Balanced Accuracyが72.2%であった。以上の結果より、本手法が前立腺癌患者の術後尿禁制予測に有効であることが示唆された。

キーワード：3DCNN, 前立腺癌, MR画像, ロボット手術, 尿禁制予測

1. はじめに

前立腺癌は、日本における2018年の悪性新生物の男性罹患数が第1位であり、前立腺を含む泌尿器は排尿機能、性功能に関わるため、男性にとって前立腺癌は重大な問題である[1]。一方、一般的に他の悪性腫瘍に比べ進行が緩徐であるため、適切な治療を行うことにより、根治が期待できる。

前立腺癌の検査に用いられるMRIは、CTやSPECTといった他の画像診断装置に比べ組織コントラストが高いため、前立腺の内部構造や、前立腺癌の浸潤範囲などの把握が可能である。そのため、生検を行う際の癌の位置確認や病期診断など様々な場面において有用であり、臨床現場において広く利用されている。

また、前立腺癌の治療法には、手術療法、放射線療法、薬物療法などがあり、これらは治療後の再発率や予後予測する癌のリスク分類と患者の状態や希望を考慮し、選択されている。特に、手術療法においては低侵襲なロボット手術の普及により、従来の手法に比べ、早期の社会復帰が可能となっている[2]。しかし、依然として副作用である尿失禁が生じた場合、生活の質(QOL)への影響は無視できないため、術後の尿禁制予測は、患者の治療法選択の一助となることが期待される。

近年、人工知能技術の医用画像への応用が進み、コンピュータ支援診断技術(CAD)等の研究が盛んに行われている。特に前立腺癌の分野においては、人工知能技術の1つであるディープラーニングを利用しMR画像から前立腺の領域をセグメンテーションする研究[3]や前立腺癌を検出する研究[4]は多数存在する。しかし、ディープラーニングによりMR画像を解析し、治療成績を予測した研究は少数である。

そこで本研究では、MR画像をボリュームデータとして3次元的に解析するため、3DCNNを用いた前立腺癌ロボット手術症例における術後尿禁制予測を目的とした。

2. 手法

本手法では、図1に示すような多施設にて撮影されたMR画像(T2強調画像)を入力として、3DCNNを用いて尿禁制良好・不良の予測を行った。尿禁制の程度については、術後6か月の時点における1日の尿パッド交換枚数を基に良好と不良に分け、尿禁制良好193症例、不良73症例を処理対象とした。




図1 前立腺癌患者のMR画像(T2強調画像)
前立腺が最大で写る1スライスを掲載

^{*1} 藤田医科大学大学院保健学研究科〔〒470-1192 豊明市杻掛町田楽ヶ窪1番地98〕e-mail: teramoto@fujita-hu.ac.jp

^{*2} 藤田医科大学医学部

まず、撮影施設や装置によって、撮像範囲や画像の信号強度が異なるため、MR 画像に対して前処理を行った。画像信号強度の不均一補正を N4 Bias field correction [5] により行い、撮像範囲に関しては、スライス毎の 2 次元的なトリミングに加え、体軸方向のトリミングも行った。

次に、前処理を行った画像に対して Data Augmentation を行い、尿禁制良好・不良症例間に存在する症例数の差を低減した。Data Augmentation は、図 2 に示すように「左右反転」、「ガウシアンノイズの付加」、「画像の平滑化」、「階調処理による明るさの変更」の 4 種類の画像処理を用いて行った。




図 2 Data Augmentation による学習症例の水増し

- (a) 原画像
- (b) 左右反転
- (c) ガウシアンノイズ付加
- (d) 単純平均フィルタによる平滑化
- (e) 階調処理：原画像における最大画素値の 15%分増加
- (f) 階調処理：原画像における最大画素値の 15%分低下

最後に、MR 画像を $64 \times 64 \times 32$ voxels にリサイズし、3DCNN に入力することで、症例ごとに尿禁制良好および不良の分類を行った。3DCNN のネットワーク構造は、自動最適化フレームワークである Optuna を用いて最適化を行い導出した。

3. 検証

3DCNN の学習処理には CPU に Intel Core i7 7800X、GPU に NVIDIA GeForce RTX 3090 を搭載した PC を利用し、ディープラーニングのフレームワークとして、TensorFlow と Keras を用いた。なお、本研究で使用したプログラムは python により記述した。

また、本手法の分類精度の評価には、混同行列における真陽性 (TP)、真陰性 (TN)、偽陽性 (FP)、偽陰性 (FN) から算出した感度 (尿禁制良好の正解率)、特異度 (尿禁制不良の正解率)、総合正解率、Balanced Accuracy の 4 項目を使用した。各項目は以下の式で表すことができる。

$$\text{感度 Sens} = \frac{TP}{TP+FN} \times 100[\%] \quad (1)$$

$$\text{特異度 Spec} = \frac{TN}{FP+TN} \times 100[\%] \quad (2)$$

$$\text{総合正解率 Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \times 100[\%] \quad (3)$$

$$\text{Balanced Accuracy} = \frac{\text{Sens}+\text{Spec}}{2} \times 100[\%] \quad (4)$$

3. 結果および考察

Hold out 法を用いて検証を行った結果、尿禁制良好の正解率が 82.5%、尿禁制不良では 61.9%となり、Balanced Accuracy が 72.2%であった。前立腺肥大症を伴う症例が尿禁制不良と分類される傾向にあったため、前立腺の大きさが分類に寄与していると考えられる。

4. 結論

本研究では、3DCNN を用いた MR 画像 (T2 強調画像) における前立腺癌ロボット手術症例の術後尿禁制予測手法を開発した。結果より、本手法が前立腺癌患者の術後尿禁制予測に有効であることが示唆された。

利益相反の有無

なし

文献

- [1] 国立がん研究センター がん情報サービス, “最新がん統計”: https://ganjoho.jp/reg_stat/statistics/stat/summary.html (2022/05/11)
- [2] Novara G, Ficarra V, Rosen RC et al.: Systematic review and meta-analysis of perioperative outcomes and complications after robot-assisted radical prostatectomy, *European Urology*, Vol.62, 2012, pp431-452
- [3] Aldo J, Biavati F, Michallek F et al.: Automatic prostate and prostate zones segmentation of magnetic resonance images using DenseNet-like U-net, *Scientific Reports*, 10, 2020, 14315
- [4] Zhenzhen D, Eric C, Chang L et al.: Segmentation of the Prostatic Gland and the Intraprostatic Lesions on Multiparametric Magnetic Resonance Imaging Using Mask Region-Based Convolutional Neural Networks, *Advances in Radiation Oncology*, Vol 5, 2020, pp473-481
- [5] Tustison N, Avants B, Cook P et al.: N4ITK: improved N3 bias correction, *IEEE Trans Med Imaging*, 29, 2010, pp1310-1320

深層学習を用いた小児脳 CT 画像からの脳年齢自動推定と、 Grad-Cam による注目箇所の可視化

森田 蓮^{*1} 安藤 沙耶^{*2} 藤田 大輔^{*1} 石川 翔^{*3}

尾上 宏治^{*3} 安藤 久美子^{*3} 石蔵 礼一^{*3} 小橋 昌司^{*1}

^{*1} 兵庫県立大学大学院工学研究科電子情報工学専攻

^{*2} 兵庫県立尼崎総合医療センター ^{*3} 神戸市立医療センター中央市民病院

Brain Age Estimation from Pediatric Brain CT Images Using Deep Learning and Grad-CAM Visualization

Ren MORITA^{*1}, Saya ANDO^{*2}, Daisuke FUJITA^{*1}, Sho ISHIKAWA^{*3}, Koji ONOUE^{*3},
Kumiko ANDO^{*3}, Reiichi ISHIKURA^{*3}, Syoji KOBASHI

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

^{*2} Hyogo Prefectural Amagasaki General Medical Center ^{*3} Kobe City Medical Center General Hospital

要旨：0 歳から 3 歳の小児期における子供の脳の発育は極めて急速である。小児脳の診断において、この時期における脳の成長を定量的に評価する方法が求められている。本研究では小児の脳 CT 画像に深層学習を適用し、脳の発達年齢を推定する手法を提案する。提案法では、まず CT 画像から頭蓋領域を抽出し、姿勢と位置の校正を行う。本研究では 3 次元畳み込みニューラルネットワーク(3D CNN)を用いて、CT 画像から特徴を抽出し、全結合層で脳の発達年齢を推定する新しいニューラルネットワークモデルを提案する。提案法を 0 から 47 ヶ月(3 歳 11 ヶ月)までの脳神経医学的に異常のない小児 264 人を用いて学習と評価を行った。また、頭蓋の校正方法が年齢推定に与える有効性を検証した。予測年齢と患者の実年齢の間の二乗平均平方根誤差(RMSE)は 6.45 月で相関係数は 0.89 であった。また、勾配加重クラスマッピング(Grad-Cam)を用いてモデルが推定に際して着目した脳領域の可視化を行った結果についても検討した。

キーワード：小児脳 CT, 深層学習, 脳年齢推定, 勾配クラスマッピング

1. はじめに

新生児の発育や早期成長を CT(Computed Tomography)で撮影された脳画像から評価する画像診断が行われている。例えば、脳疾患の一つである自閉症は明確な臨床症状が現れる前の生後 1 ヶ月から 2 歳の間に小脳に過形成が見られる事が特徴である[1]。このように明確な臨床症状がない場合であっても、診断出来る脳疾患がある。しかし、現在の脳画像診断の問題点は脳の成長度合いを定量的に求める方法が明らかでなく、熟練医の経験に基づく定性的な診断方法が行われている事である。小児の脳画像から成長度合いを評価する為には、対象年齢の脳画像を大量に読影する経験が必要であり、これを読影出来る医師が不足している。また、医師の経験に依存した定性的な診断方法も問題になっており、定量的な診断方法が必要とされている。

いくつかの研究で、CNN(Convolutional Neural Network)を用いた脳年齢の推定方法が報告されている[2][3]。文献[2]では、成人 MRI の脳画像から 2D CNN を用いて年齢推定を行っている。文献[3]では、3D 成人 MRI 画像データから 3D CNN を用いて年齢推定を行っている。これらの CNN ベースの手法は、脳実質である白質と灰白質、脳髄液の識別を必要としない。低コントラストであることが理由で、髄質の識別が困難な小児脳 CT 画像への適用が期待されるが、CT 画像から年齢推定を行

った研究は、これまで報告されていない。

本研究では、CNN を用いて小児脳 CT 画像から脳の発達年齢を推定する新しい手法を提案する。小児期の脳の成長の進み具合を定量的に評価することで、成長遅延や未熟児を識別することを目的としている。提案手法は 2 つのステップで構成される。まず、3 次元 CT 画像から頭蓋領域を抽出する。小児脳 CT 画像には、大人の指や治療器具、子供の手が写っているものが散見される。これらの不要領域を取り除くことで、解析領域を頭蓋内に限定する。次に、抽出された頭蓋領域から CNN を用いて脳成長年齢を推定する。そして最後に勾配加重クラスマッピング(Grad-Cam)を用いて、モデルが推定に際して着目した脳領域を可視化する。

2. 使用データ

本研究では、神戸市立医療センター中央市民病院に来院した 0 から 3 歳(47 ヶ月)の小児男女計 264 例で、精神医学的に異常の認められなかった被験者を対象とする。本研究は、同病院の倫理委員会により承認の上実施した。

3. 提案手法

本研究では前処理として頭部領域の抽出、姿勢と位置の校正、

CT 値の正規化を行った CT 画像を入力として、脳年齢を出力とする回帰問題として扱う。図 1 に本研究で用いた 3D CNN のネットワークモデル構造を示す。畳み込み層 2 層、マックスプーリング層 1 層をブロックとしてフィルター数を(4, 8, 16, 32, 64, 128, 256)と増加させながら 7 つのブロックを経て、6 つのニューロンからなる全結合層によって脳年齢を推定する。

4. 実験結果

3D CNN を学習データ 144 例、評価データ 60 例に分割し学習を行った。汎化性能の評価には 4 分割のクロスバリデーションを行った。層化抽出法を用いて各データセット間の被験者の月齢分布の偏りを排除している。図 2 に横軸に実年齢、縦軸に予測年齢とし、各 Fold の評価データにおける予測結果を示した。実年齢と予測年齢の二乗平方根誤差(RMSE)は 6.45 月であり、相関係数は 0.89 であった。図 3 に Grad-Cam を用いて、3D CNN 注目領域の可視化を行った結果を示す。可視化に利用した特徴マップは図 1 における C7*すなわち畳み込みの最終層における特徴マップから作成した。全年齢層において後頭部領域に高い値が見られた。

4. まとめと考察

本研究では、小児脳 CT 画像から脳年齢を推定する手法を提案した。実験の結果、RMSE=6.45 月の精度で推定を行えた。また、モデルの推定に際して、着目した領域を Grad-Cam を用いて可視化を行った結果、後頭部領域で高い値が観察された。人の脳の発達過程においては、まず運動能力をつかさどる後頭部領域が発達する。その後言葉や思想をつかさどる前頭葉の発達に伴い前頭部が発達する。一方、Grad-Cam による顕著性マップでは、後頭部の寄与が大きいことから、本研究で得られたモデルがその成長過程を学習出来たとは言いがたい。そこで、より前頭部で高い重要度となるようなモデル構築を行うことで、推定精度向上が可能であると考えている。

利益相反の有無

なし。

文 献

- [1] Hazlett H C, Poe M, Gerig G et al: Magnetic resonance imaging and head circumference study of brain size in autism: birth through age 2 years. Archives of general psychiatry 62(12): 1366-1376, 2005
- [2] Pan Y, Huang W, Lin Z et al: Brain tumor grading based on neural networks and convolutional neural networks. In 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC): 699-702, 2015
- [3] Cole J H, Poudel R P, Tsagkraloulis D et al: Predicting brain age with deep learning from raw imaging data results in a reliable and heritable biomarker. NeuroImage 163: 115-124, 2017
- [4] Selvaraju R R, Cogswell M, Das A et al: Grad-cam: Visual explanations from deep networks via gradient-based localization. Proceedings of the IEEE international

conference on computer vision: 618-6262017, 2017

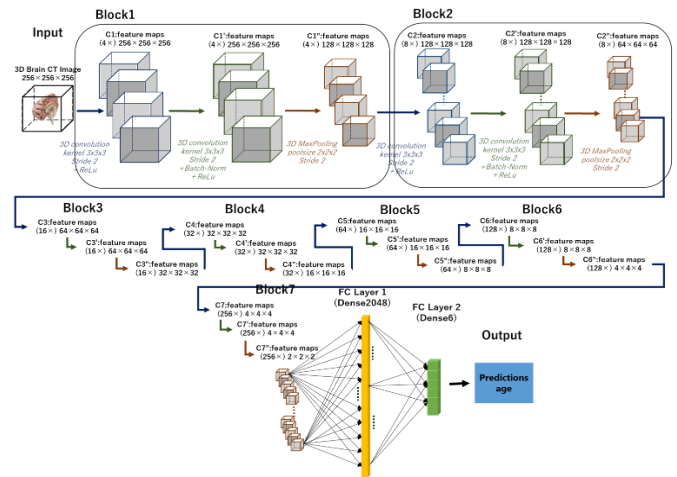


図 1 3D CNN モデル




図 2 年齢予測結果




図 3 Grad-CAM を用いた注目領域の可視化 (A: anterior, P: posterior)

敗血症モデルラットの微小循環動画像に対する血管密度解析

田口 竣也^{*1}, 川崎 真未^{*1}, 羽石 秀昭^{*2}

^{*1} 千葉大学大学院融合理工学府基幹工学専攻医工学コース [〒263-8522 千葉市稲毛区弥生町 1-33]

^{*2} 千葉大学フロンティア医工学センター

e-mail: s_taguchi@chiba-u.jp

Blood vessel density analysis in microcirculation images of septic model rats

Shunya TAGUCHI^{*1}, Mami KAWASAKI^{*1}, Hideaki HANEISHI^{*2}

^{*1} Department of Medical Engineering, Graduate School of Science and Engineering, Chiba University.

^{*2} Center for Frontier Medical Engineering, Chiba University.

要旨：敗血症は感染症に起因して発症し、生命に危機を及ぼす臓器障害である。発症初期には 100 μ m 以下の血管径である微小循環が障害される。そのため敗血症に対する薬効の調査では、微小循環の変化を観察することが重要となる。先行研究では、小動物実験による敗血症モデルラットの微小循環動画像群の収集及び血流速度による経時変化解析が行われた。ここでは血流速度を算出し、敗血症モデルラットでは低下傾向、薬剤を投与したラットは回復傾向が確認された。本研究では、敗血症モデルラットの微小循環動画像群の同一領域の経時変化解析へ向けた、動画像群に対する位置合わせを行った。位置合わせは血管の分岐点を特徴点とした手法を用いた。また、位置合わせ結果を用いて、同一領域での血管密度による経時変化解析を行った。血管密度を算出し、敗血症モデルラットの血管密度は減少した一方、薬剤を投与したラットの血管密度は一部の動画像群で回復傾向が確認された。

キーワード：微小循環，敗血症性ショック，薬効調査，血管密度解析，位置合わせ

1. はじめに

敗血症とは、感染に対する制御不十分な生体反応に起因する、生命に危機を及ぼす臓器障害である [1]。敗血症が進行すると敗血症性ショックに移行し死亡率が増加する。そのため早期診断や治療が重要である。敗血症の初期段階では、100 μ m 以下の血管径である微小循環が障害される [2]。そのため敗血症に対する薬効の調査では、微小循環の変化を観察することが重要となる。先行研究 [3] では、非接触型撮影装置を用いた敗血症モデルラットの微小循環動画像群の収集及び血流速度による経時変化解析が行われた。ここでは血流速度を算出し、敗血症モデルラットでは低下傾向、薬剤を投与したラットは回復傾向が確認された。

先行研究では、ラットに微小循環観察用にチャンバーを固定することにより、経時変化を観察する際におおよそ同じ位置の画像が取得できている。しかし、厳密には画像間で位置ずれがあるため、詳細な分析のためには、画像間の位置合わせが必要となる。これまでに多数の動画像群を取得しており、これらの画像の位置合わせを済ませておくことで、その後の種々の分析が容易になる。そこで本研究では、これら多数の経時画像間での位置合わせを行った。また、そのように得られた画像の解析例として、血管密度による経時変化解析を行った。

2. 使用画像

本研究では雄のラット(Slc:Wistar, 12週齢, n=12)を対象とし、背部真皮微小循環の経時的な変化を観察した。微小循環動画

群の収集は当研究室の前任者によって行われた。敗血症モデルとして Cecal Ligation and Puncture (CLP)[4]モデルが採用された。図1に実験プロトコルを示す。まず毎回同一領域を探索するために、全てのラットに微小循環観察用チャンバーが装着された。その後、健常ラットが属する Sham 群、敗血症モデルラットが属する CLP 群、敗血症モデルラットに TM alfa (Asahi Kasei Pharma Corp.) を投与する CLP+TM 群の3群 (4 rats/group) に無作為に分け、各群に対して処置が施された。CLP 群と CLP+TM 群の処置手順として、まず開腹し盲腸を取り出した。次に盲腸に対して結紮と穿刺を施し、腹腔内に戻した。一方 Sham 群は開腹による侵襲を考慮するために、結紮と穿刺以外の処置が施された。さらに、処置の4時間後に Sham 群と CLP 群には生理食塩水を、CLP+TM 群には TM alfa を 3 mg/kg BW 投与した。微小循環の撮影は、処置直前と処置直後、その後2時間ごとに10時間後まで行われた。取得画像例を図2に示す。Sham 群は血管構造の変化は観察されなかった。それに対して CLP 群では、円で示したような毛細血管が消失していく様子が観察された。一方で、CLP+TM 群では円で示したように、10時間後には回復していることが確認された。また、画像群の撮影の際に、敗血症の診断基準となる乳酸値も併せて計測された。

3. 位置合わせ手法

画像間の特徴点から、位置合わせに必要なアフィンパラメータを、最小二乗法を用いて決定する。本研究では、特徴点として血管の分岐点を採用した。血管の分岐点は、微小循環画




図1 実験プロトコル




図2 取得画像例

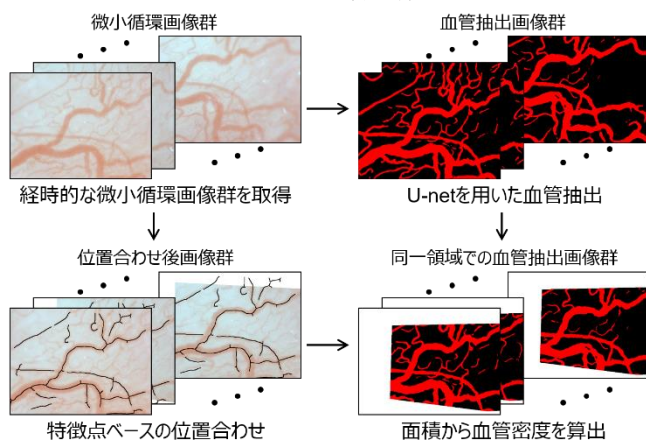


図3 血管密度算出フロー

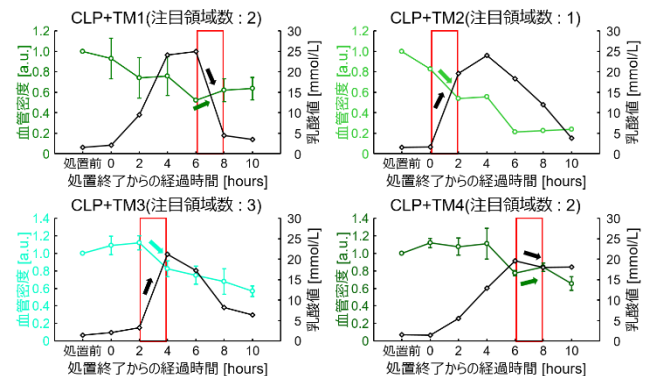


図4 CLP+TM 群の血管密度算出結果

像より U-net[5]を用いて取得した血管抽出画像を細線化[6]した血管細線化画像より手動で選択した。処置前の画像を基準画像とし、これと位置合わせを行う対象画像において、対応する血管の分岐点同士を6点選択した。続いて、選択した分岐点同士の一貫性に注目し、最小二乗法を用いて、一貫度の誤差が最小となるような行列の算出を行い、これをアフィンパラメータとして決定し、基準画像と対象画像の位置合わせを行った。

4. 血管密度解析

同一領域での血管密度を算出した。算出フローを図3に示す。血管抽出画像に位置合わせ手法で算出したアフィンパラメータを適用して同一領域を算出し、面積から密度を算出した。

結果として、Sham群では、全てのラットで変化が少ないことが確認された。CLP群では、4匹中3匹のラットで血管密度の低下が確認された。CLP群の中で変化が少なかったラットは、悪化に伴って上昇する性質の乳酸値が低い状態であったため、敗血症モデルの作成に失敗した可能性が考えられる。CLP+TM群では、2匹のラットで6時間経過後に血管密度が回復傾向であることが確認された。一方で、血管密度が低下し続けるラットも確認された。また、図4の赤枠部分に示す通り、血管密度の低下に伴う乳酸値の上昇、もしくは血管密度の回復に伴う乳酸値の低下が確認された。

5. まとめ

微小循環動画像に対する血管密度の経時変化解析を行った。結果として、Sham群では、全てで変化が少ないこと、CLP群では、3匹のラットで血管密度が低下していくこと、CLP+TM群では、2匹のラットで6時間経過後に血管密度が回復傾向であった一方、血管密度が低下し続けるラットも確認された。

現在の方法では、画像内で太い血管が支配的であるため、微細な血管の密度変化の確認が困難であるという課題がある。そこで今後は血管径別の血管密度解析を行う。

謝辞

本研究の一部は文部科学省科学研究費補助金(課題番号: 16H01855, 19H01172)により行われた。

利益相反の有無

なし

文献

- [1] M Singer, C S Deutschman, C W Seymour, et al.: The third international consensus definitions for sepsis and septic shock (Sepsis-3). *Jama* 315(8): 801-810, 2016
- [2] P E Spronk, D F Zandstra, C Ince: Bench-to-bedside review: sepsis is a disease of the microcirculation. *Critical care* 8(6): 462-468, 2004
- [3] 川崎ら, 微小循環動画像解析システムの構築と敗血症モデルラットに対する薬効調査, メディカルイメージング連合フォーラム 2021, pp. 152-153, 2020.
- [4] K A Wichterman, A E Baue, I H Chaudry: Sepsis and septic shock—a review of laboratory models and a proposal. *Journal of Surgical Research* 29(2): 189-201, 1980
- [5] Ronneberger et al, U-Net: Convolutional Networks for Biomedical Image Segmentation arXiv:1505.04597, 2015.
- [6] Zhang et al, A fast parallel algorithm for thinning digital patterns, *Communications of the ACM*, Vol.27, pp.236-239, 1984.

動画画像解析を用いた脳卒中の病院前診断における顔面麻痺の自動評価

生澤 直樹^{*1}, 吉田 陽一^{*2}, 栗原 聡^{*3}, 中田 孝明^{*2}, 羽石 秀昭^{*4}

^{*1} 千葉大学大学院融合理工学府

^{*2} 千葉大学大学院医学研究院

^{*3} 松戸市総合医療センター

^{*4} 千葉大学フロンティア医工学センター

Video Analysis-based Automatic Evaluation of Facial Palsy in Prehospital Stroke Scale

Naoki IKEZAWA^{*1}, Yoichi YOSHIDA^{*2}, Satoru KURIHARA^{*3},
Taka-aki NAKADA^{*2}, Hideaki HANEISHI^{*4}

^{*1} Graduate School of Science and Engineering, Chiba Univ

^{*2} Graduate School of Medicine, Chiba Univ

^{*3} Matsudo City General Hospital

^{*4} Center for Frontier Medical Engineering, Chiba University

〒263-8522 千葉市稲毛区弥生町 1-33, e-mail: n-ikezawa@chiba-u.jp

要旨：脳卒中の病院前診断において顔面麻痺は重要な項目の一つである。顔面麻痺は顔面神経の障害部位により中枢性と末梢性に分けられ、脳卒中などによって引き起こされる中枢性では顔の下半分に症状が表れるという特徴がある。本研究では、深層学習を用いて顔の特徴点を自動認識した上で、特徴点の動画画像解析によって中枢性顔面麻痺を自動評価する。具体的には入力動画画像から患者の顔の認識・特徴点の検出を行い、口の特徴点を用いて口の動きの対称性・口の動きの量・口の形状などを反映した評価指標を算出する。算出した評価指標に対し有意差検定を実施した結果、多くの評価指標で有意差を確認した。さらに、有意差を確認した評価指標を用いて、機械学習による顔面麻痺患者と健常者の分類を行った結果、良好な精度が得られた。

キーワード：顔面麻痺，脳卒中，プレホスピタルスケール，特徴点検出

1. はじめに

顔面麻痺は、脳卒中の病院前診断(プレホスピタルスケール)における評価項目の1つである。主要なプレホスピタルスケールである Cincinnati Prehospital Stroke Scale や Prehospital Ambulance Stroke Test において、顔面麻痺は脳卒中を予測する上で重要な項目であることが示唆されている[1]。現在、プレホスピタルスケールは救急隊員によって手動で行われているため、隊員による主観的な評価であり、また、入力漏れなど人為的なミスが介入する余地がある。そのため、評価を自動化することで、定量的な評価と人為的なミスの防止が期待できる。

顔面麻痺は顔面神経の障害部位により中枢性と末梢性に分けられ、脳卒中などによって引き起こされる中枢性では顔の下半分に症状が表れ、末梢性は顔全体に症状が表れるという特徴がある。この特徴に着目し、中枢性と末梢性の分類を含めた、動画画像を用いた自動評価を目標としている。今回は、口の評価のみによる中枢性顔面麻痺の分類を検討した。顔の特徴点検出技術を用いた評価指標を提案し、機械学習による患者群と健常群の分類を行った。

2. 手法

まず、撮影した動画画像から Face Boxes[3]という手法を用いて顔面領域を検出する。この手法は、Convolutional Neural Network(CNN)を使用して、顔面を含む矩形領域を検出するものである。次に、Adaptive Wing Loss[4]という手法を用いて顔面の特徴点を検出する。この手法はCNNを使用して、図1に示す96個の特徴点(WFLW)[5]を画像上の顔に回帰するものである。検出した特徴点のうち、口の特徴点を用いて評価指標を算出した。

プレホスピタルスケールにおいて顔面麻痺は、救急隊員が口を横にイーと広げるように指示し、口の動きの左右対称性や口




図1 WFLWの96個の特徴点[5]

の形状の左右差を見て評価される。本研究では、口角の特徴点の動きと口の特徴点で囲まれた領域の時間変化に注目して評価指標を算出する。具体的には、口角の特徴点の x 座標、 y 座標、変位ベクトルの大きさ・方向・ x 成分・ y 成分に対して、式(1)に示す Normalized Cross Correlation(NCC)と式(2)に示す Root Mean Square Error(RMSE)を算出した。変位ベクトルとは、時刻 t から時刻 $t+T$ における特徴点の変位を示すベクトルである。

$$NCC = \frac{\sum_{t=1}^N (x_{R,t} - \bar{x}_R)(x_{L,t} - \bar{x}_L)}{\sqrt{\sum_{t=1}^N (x_{R,t} - \bar{x}_R)^2} \sqrt{\sum_{t=1}^N (x_{L,t} - \bar{x}_L)^2}} \quad (1)$$

ここで $x_{R,t}$ は時刻 t における右口角の特徴点の x 座標、 N は動画のフレーム数、 \bar{x}_R は右口角の x 座標の平均値を示す

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (x_{R,t} - x_{L,t})^2} \quad (2)$$

さらに、図 2 のように口輪郭で囲まれた領域を左右で定義し、一方を左右反転させたときに重なる領域の面積(MOA: Mouth Overlap Area)の時間変化を算出した。MOA の最小値を評価指標とした。

3. 実験

35名(健常者17名、中枢性顔面麻痺患者18名)の口を横にイーと広げた動画像に対して評価指標を算出した。患者データは、千葉大学附属病院及び千葉メディカルセンターの顔面麻痺を伴う脳卒中患者を倫理委員会承認のもとで撮影を行った。また、軽症及び重症が臨床医によって判断された。

まず、算出した評価指標に対し有意差検定を実施した。結果、 x 座標、 y 座標、変位ベクトルの大きさ x 成分・ y 成分の NCC と変位ベクトルの大きさ x 成分・ y 成分の RMSE、MOA で有意な差を確認した。

続いて、有意差を確認した評価指標を用いて、Support Vector Machine(SVM)による分類を行った。検証は、Leave-One-Out Cross Validation を用いて行った。結果を表 1 に示す。全体の精度は 0.88 と高い値となった。このことから、口の評価のみで中枢性顔面麻痺を分類できる可能性が示されたと考えられる。また、健常者の精度は 0.94 と高い値の一方で、患者の精度は 0.78 と比較的低い値となった。健常者と誤分類された患者の重




図 2 MOA で算出する面積

表 1 SVM による分類の結果

	正	誤	精度
健常者	16	1	0.94
患者	14	4	0.78
全体	30	5	0.88

症度は全員軽症であった。健常と軽症は重症と軽症に比べて症状の差が小さいことが原因だと考えられる。

4. まとめと展望

中枢性顔面麻痺を自動評価するための、顔の特徴点を用いた評価指標の提案を行い、SVM による分類を実施した。患者データに適用した結果、複数の評価指標で有意な差を確認した。また、SVM による分類結果は高い精度となり、口の評価のみで中枢性顔面麻痺を分類できる可能性が示された。一方で、患者の精度が比較的低く、健常者に誤分類されたデータは全て軽症であった。

今後は、健常と軽症の誤分類を減少させるために、評価指標の追加・修正を行う。また、脳卒中は緊急性の高い疾患であるため、患者の誤分類を最小に抑える必要がある。したがって、患者の誤分類を抑えるような分類方法の検討も行う。さらに、顔面上部の評価も行い、中枢性と末梢性の判別への応用まで行っていく。

謝辞

本研究の一部は日本医療研究開発機構先進的医療機器・システム等技術開発事業「基盤技術開発プロジェクト」研究開発課題「救急医療予測アルゴリズム研究開発」の支援を受けた。

利益相反の有無

なし

文献

- [1] Karimi S et al: The prehospital ambulance stroke test vs. The Cincinnati prehospital stroke scale: A diagnostic accuracy study. Australasian Journal of Paramedicine 17. 1-7, 2020.
- [2] 天津 睦郎, 木西 實: 顔面神経麻痺の診断. 耳鼻咽喉科臨床 83(10) : 1618-1619, 1990.
- [3] Zhang S et al: FaceBoxes: A CPU real-time face detector with high accuracy. IEEE International Joint Conference on Biometrics 2018-Janua. 1-9, 2018.
- [4] Wang X et al: Adaptive wing loss for robust face alignment via heatmap regression. Proceedings of the IEEE International Conference on Computer Vision 2019-Octob. 6970-6980, 2019.
- [5] Wu W et al: Look at Boundary: A Boundary-Aware Face Alignment Algorithm. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2129-2138, 2018.

ダーモカメラ画像を用いたシワ・キメの特徴解析

浅野 祐太^{*1}, 西澤 巧^{*1}, 梶田 大樹^{*2}, 石井 龍之^{*2}, 貴志 和生^{*2}, 佐藤 いまり^{*1}

^{*1} 国立情報学研究所 コンテンツ科学研究系

^{*2} 慶應義塾大学 医学部

Wrinkle Feature Analysis using Dermo-camera Images

Yuta ASANO^{*1}, Takumi NISHIZAWA^{*1}, Hiroki KAJITA^{*2}, Tatsuyuki ISHII^{*2}, Kazuo KISHI^{*2}, Imari SATO^{*1}

^{*1} National Institute of Informatics, Digital Content and Media Sciences Research Division

^{*2} Keio University, School of Medicine

要旨：人間の皮膚は、外的要因から体内を守り、恒常性を保つ重要な役割を担う器官であるが、一方で美容的な観点からも皮膚の状態評価が重要である。皮膚の評価項目の一つとして、皮膚のシワ・キメと呼ばれる肌の細かい凹凸の形状パターンから皮膚の状態を評価するが、皮膚画像からシワ・キメは判別しづらく、シワ・キメを正確に可視化することは困難である。そこで、ダーモカメラで撮影された通常の画像（「非偏光画像」）、および偏光板を用いて直接反射光成分を除いた画像（「偏光画像」）の二枚の画像を用いたシワ・キメを可視化する画像処理手法を開発した。非偏光画像および偏光画像の差分特徴量を抽出し、皮膚の色による背景輝度のムラを削減することで正確なシワ・キメの可視化を行う。さらに、シワ・キメの可視化画像についての Gabor 特徴量を解析することで、シワ・キメの間隔や方向性などのパターンを定性的および定量的に評価した。

キーワード：シワ・キメ、ダーモカメラ、Gabor 特徴量

1. はじめに

皮膚は医学的には外的要因から体内を守り、恒常性を保つ役割を担う器官であるが、美容的な観点からもその性状の評価が重要視されている。皮膚の性状は、化粧のり、くすみ、透明感など様々な言葉で表現されるが、病的な皮膚所見を診断する一般皮膚科診療と異なり、医学には正常の範疇に含まれるような皮膚の微妙な変化を美容的な観点で定量的に捉えるのは困難であり、未だ実用的な方法が確立されていないのが現状である。皮膚を拡大して観察すると表面には、いわゆる「シワ・キメ」と呼ばれる、細かな紋様の凹凸の形状のパターンが見られる。本研究では、皮膚の健康状態をよりの確に診断することを目指して、画像処理を用いて皮膚のシワ・キメを正確に可視化した上で、シワ・キメのパターンについて検証を行う。

2. 皮膚画像のシワ・キメの可視化

人間の皮膚表面には、格子状の深さ 10~20 μm 程度の溝であるシワ・キメが多数存在する。このシワ・キメの分布を容易に取得するために、従来は目視による確認方法が用いられてきたが、精度やコストの問題から、シワ・キメの分布情報を高精度で、且つ低コストに自動取得可能な手法が必要である。皮膚情報を容易に取得するには、RGB カメラで皮膚表面を撮影することが一般的ではあるが、シワ・キメ箇所は周囲と色が酷似しているため、RGB 画像（図 2 の非偏光画像）のみを用いて正確に可視化することは困難である。

そこで本研究では、一般的な RGB カメラ画像ではなく、偏光画像および非偏光画像を同時に取得可能なダーモカメラを用いて撮影された皮膚の接写画像を処理することで、シワ・キ

メの可視化を試みる。非偏光画像は偏光を考慮しない一般的な RGB 画像であり、偏光画像は偏光させた光を対象に当て、偏光板を透過した光を撮影したもので、皮膚表面での直接反射光を抑え、皮膚内面の情報を取得しやすい画像である。

格子状の溝であるシワ・キメでは、複雑に光の反射が起こり、また微妙に肌色が異なるため、非偏光画像にはシワ・キメとそれ以外の箇所間に微小な輝度差が存在する。一方、偏光画像は主に表面下散乱した光を撮影するため、シワ・キメの情報が画像に含まれにくい。そのため、この二枚の画像の差異は主に皮膚表面での直接反射光の有無で、それはシワ・キメにおける反射光による輝度情報に相当する。また、偏光画像、非偏光画像共に RGB の情報が含まれるが、シワ・キメの微小な溝の形状に起因する光学特性や皮膚色により、G, R チャンネルに比べ、B チャンネル画像にシワ・キメ箇所の輝度差が大きい。そこで、B チャンネル情報のみを可視化処理に活用する。

図 1 にシワ・キメの可視化を行う画像処理のフローチャートを示す。まず、偏光画像および非偏光画像の B チャンネルの各画素の輝度比画像を算出する。シワ・キメ以外の箇所は、偏光

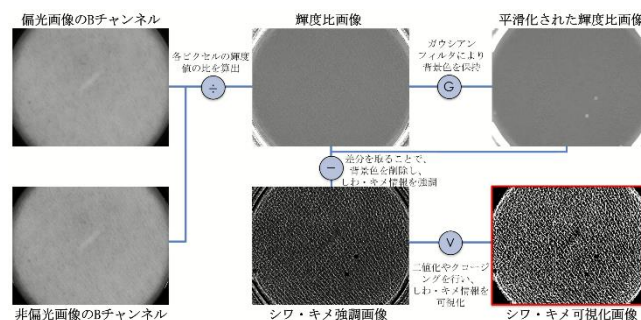


図 1 シワ・キメの可視化処理のフローチャート

画像と非偏光画像が酷似しているため、輝度比は小さいが、シワ・キメ箇所は輝度比が大きくなるため、輝度比画像ではシワ・キメが強調される。次に、輝度比画像に含まれる皮膚の色ムラや入射光の当たり方による陰影を削除するために、輝度比画像と平滑化フィルタのガウシアンフィルタを適用した輝度比画像の差分を取ることで、シワ・キメ箇所のみが顕著に強調された画像を生成する。最後に、二値化処理やクロージング処理を施すことで、シワ・キメの可視化画像を生成する。

図 2 は、本提案手法によりシワ・キメを可視化した例である。偏光画像および非偏光画像の B チャンネルの輝度の差異情報を特徴量として活用することで、皮膚のシワ・キメの可視化に成功していることが分かる。




図 2 皮膚の偏光，非偏光画像および可視化処理画像

3. シワ・キメの間隔・方向性の Gabor 特徴量解析

本提案手法により可視化されたシワ・キメについて、Gabor 特徴量 [1] を用いて評価を行う。Gabor フィルタは、画像処理のテクスチャ解析等に用いられる線形フィルタで、方向毎の特定の周波数成分を抽出する。シワ・キメの可視化画像に対して、任意の方向・周期の Gabor フィルタを適用した際の応答（平均輝度）を算出し、シワ・キメの格子パターンへの歪み方や間隔の定量評価を行う。パターンへの歪み方については、任意の方向の Gabor フィルタを適用した際の応答の強弱に着目し、最大と最小の応答の差異が、パターンへの歪み量に相当する。シワ・キメの間隔については、任意の周期の Gabor フィルタを適用した際の応答の強弱に着目し、最大応答時の Gabor フィルタの周期パラメータ（ピクセル/サイクル）を間隔に相当すると考える。

図 3 に可視化画像に任意の方向・周期の Gabor フィルタを適用した際の応答マトリクス（ヒートマップ表示）の例を示す。これらは画像中の赤枠内の解析結果である。また、表 1 に最大応答時の角度，周期，および応答の差異を示す。ただし、角度は撮影時のカメラの向きに依存する。(b), (c)は縫合後癒痕の例

で、縫合部(c)とその周囲(b)では、シワ・キメの間隔や歪み方が異なることが可視化画像および Gabor 特徴量から確認できる。これらの結果から、シワ・キメの格子パターンへの歪み方や間隔に相当するパラメータから定量評価が可能で、Gabor フィルタを用いたシワ・キメの特徴解析が有用であることが分かる。

表 1 シワ・キメの可視化処理画像の Gabor 特徴量

	(a)	(b)	(c)
最大応答時の角度	117	165	13
最大応答時の周期	70	22	71
最大応答時の周期における任意角度の応答の差異	18.9	32.9	30.7

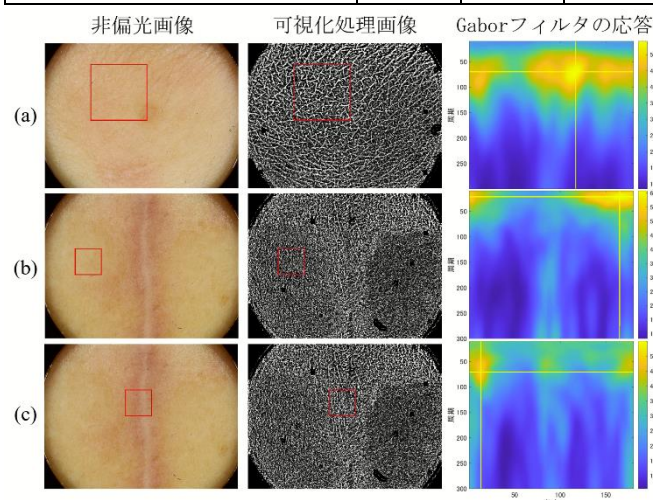


図 3 シワ・キメの可視化処理画像と任意の方向・周期の Gabor フィルタを適用した際の応答マトリクス

4. まとめ

本研究では、ダーモカメラで撮影された皮膚の偏光画像および非偏光画像の B チャンネル情報を用いたシワ・キメの可視化処理手法を提案した。そして、可視化画像についての Gabor 特徴量を用いて、シワ・キメの間隔や方向性を評価した。また、皮膚の疾患箇所の診断において、本提案手法による評価の有用性が示唆された。

謝辞

本研究は、科学研究費補助金 学術変革領域研究 (20H05953) および国立情報学研究所 公募型共同研究 (21FC03) の助成を受けたものです。

利益相反の有無

なし

文献

- [1] Feichtinger, Hans G., and Thomas Strohmer, eds. Gabor analysis and algorithms: Theory and applications. Springer Science & Business Media, 2012.

異なるモダリティによって撮像された医用画像の相同性評価

小林 麟太郎^{*1}, 原 武史^{*2}, 周 向栄^{*2}, 野崎 太希³, 松迫 正樹³, 藤田 広志²^{*1} 岐阜大学大学院自然科学技術研究科知能理工学専攻

[〒501-1193 岐阜市柳戸 1-1 e-mail:rkoba@fjt.info.gifu-u.ac.jp]

^{*2} 岐阜大学工学部^{*3} 聖路加国際病院放射線科

Homology evaluation of medical images taken by different modalities

Rintaro KOBAYASHI^{*1}, Takeshi HARA^{*2}, Xiangrong Zhou^{*2}, Taiki NOZAKI^{*3},
Masaki MATSUSAKO^{*3}, Hiroshi FUJITA^{*2}^{*1} Natural Science and Technology, Gifu Graduate School^{*2} Faculty of Engineering, Gifu University^{*3} St. Luke's International Hospital

要旨 : Ultrashort TE(以降 UTE)画像はエコー時間を短くすることで皮質骨内の水分を検出でき, X線 CT 検査の代わりとして利用できる可能性が示されている. 本研究の目的は, X線 CT 装置で撮像された膝画像と UTE 法によって撮像された MRI 膝画像において, 皮質骨領域の形状の相同性を, 物理評価と主観評価の2つから評価することである. CT 画像, MRI 画像の同患者を含む全ペアに対して, 物理評価では特徴量を用いた L2 ノルムによる類似度評価, 主観評価では専門医による類似度評価を行う. 物理評価と主観評価の相関係数は約 0.360 となり, やや相関係数があることがわかった. 今後の展望は, 主観評価, 物理評価ともに精度向上を目指すとともに, UTE により撮像された MRI 画像が CT 画像の代替となり得るかの判断を, 主観評価と物理評価がどの程度近似したら下すのか, 専門医と検討し決定することである.

キーワード : CT, MR, UTE

1. 背景・目的

近年 Ultrashort TE(以降 UTE 画像)[1]と呼ばれる MRI 検査のエコー時間を短くし撮像を行う技術が注目されている. この UTE 画像はエコー時間を短くすることで皮質骨内の水分を検出できる. その結果, UTE 画像は皮質骨を描出するため, X線 CT 検査の代わりとして利用できる可能性が示唆されている.

本研究の目的は, X線 CT 画像で撮像された膝画像と UTE 法によって撮像された MRI 膝画像の, 皮質骨領域の相同性を評価することである. 物理評価と主観評価の2つから相同性評価を行う.

2. 物理評価手法

CT 画像と MRI 画像から特徴点とする3点を目視で決定, 回転操作による位置合わせを行う. 次に, 皮質骨領域以外の余剰要素となりうる肉組織をグラフカットによって削除する. その後, 一定画素値を閾値として, 皮質骨領域として抽出する. また, この皮質骨領域を, 深度画像生成, 点群データ生成, メッシュ生成の手順で3次元モデルに変換する. 図1に深度画像生成, 点群データ生成, メッシュ生成後の画像例を示す.

ここから3次元モデルの類似度評価を, Absolute Angle Distance(以降 AAD)[2]と呼ばれる特徴量を用いて行う. AAD は, 3次元モデルを生成している点同士の内積と距離から2次

元ヒストグラムを生成し, 特徴量とする. 本手法では, 2次元ヒストグラムの縦軸である距離を64区分, 横軸である内積を4区分とする. このヒストグラムからL2ノルムを計算, 生成点数の組み合わせ数だけ除算する. L2ノルムはモデルAの特徴量 $X=(x_{ij})$, モデルBの特徴量 $Y=(y_{ij})$, 距離区間を I_D , 内積区間を I_P とするとき, 式(1)で求められる. ここでのモデルA, Bとは患者一人のCT, MRIの3次元モデルのことである.

$$D_{L2}(X, Y) = \sum_{i=1}^{I_D} \sqrt{\sum_{j=1}^{I_P} (x_{i,j} - y_{i,j})^2} \quad (1)$$




図1 3次元モデルを生成するまでの過程画像

3. 主観評価手法

物理評価と同様の手法でCT画像, MRI画像に位置合わせを行い, 余剰要素となりうる肉組織等をグラフカットにより削除する. このCT画像とMRI画像を用いて, ボリュームレンダ

リングによる比較を行う。本研究のポリリュームレンダリングには、専用で作成した web ページを用いる。

ポリリュームレンダリングを作成するにあたり、まずグラフィックを行った画像群から、サンプリングを行う。始めに、画像群を用いて作成した 3D テクスチャと、立方体の 3 次元モデルを定義する。その後、画面上からある一定間隔のレイを飛ばし、レイに当たる立方体の座標を 3D テクスチャの座標に見立て、3D テクスチャの座標の RGB 値を取得する。これをレイ方向に一定間隔で繰り返し、取得した RGB 値を全て足し合わせ、画面上のピクセルに出力する。この色計算を全ピクセルで繰り返すことで、ポリリュームレンダリングが生成される。

次にサンプリング回数、透明度、閾値の 3 つのパラメータを、web 上で調整可能にする。また、光源の追加による影の再現を行う。影の再現には平行光源と、レンダリングしている頂点座標の法線ベクトルの内積を用いる。最後に、RGB 値が 0.1 から 0.4 である出力色を、G 値、B 値を 0、R 値を 0.000~0.122 までの範囲として、色変換する。パラメータ調整後、光源追加後、色変換後のポリリュームレンダリング例を図 2 に示す。

作成したポリリュームレンダリングを用いて、全患者の CT、MRI の総当たりペアに対して類似度評価を行う。全ペアに対して 0~1 までの値で主観的な評価を行い、それぞれのペアに対して評価した人数による平均値を求める。その平均値をそのペアの類似度とする。



図 2 ポリリュームレンダリング例

4. 実験

本研究では、20 歳から 41 歳の男性 4 症例、女性 1 症例の合計 5 症例の CT 膝画像と MRI 膝画像を用いる。全ての症例に対し、2、3 で述べた手法により類似度評価を行う。なお、主観評価は学生 8 名、専門医 1 名で行った。また、主観評価と物理評価の一致度を評価するため、2 つの類似度を散布図にし、相関係数を求める。

5. 結果


表 1 に物理評価、表 2 に主観評価、図 3 に物理評価と主観評価の散布図と相関係数を示す。

表 1 物理評価による類似度(平均値)

CT・MRI 同患者ペア	0.140
CT・MRI 異患者ペア	0.191

表 2 主観評価による類似度(平均値)

CT・MRI 同患者ペア	0.355
CT・MRI 異患者ペア	0.711



● CT・MRI 同患者ペア ● CT・MRI 異患者ペア

図 3 物理評価と主観評価の散布図と相関係数

6. 考察

物理評価と主観評価の全体の相関係数は、 $r = 0.360$ となり、やや相関係数があることがわかる。また、同患者ペアは異患者ペアに対して物理評価、主観評価ともに値が高い場所に位置しており、ある程度異患者ペアとの差別化ができていていると考える。今回の手法では CT 画像と MRI 画像の切り出し方が違うため、切り出し方を揃えれば、評価精度が向上すると考える。

7. 結論・展望

本研究では、CT 骨画像と UTE を用いた MRI 骨画像の相同性評価を行った。CT 画像と MRI 画像の物理評価、主観評価の一連の流れを定めることができた。今後の展望は、主観評価、物理評価ともに精度向上を目指すこと。また、UTE により撮像された MRI 画像が CT 画像の代替となり得るのかの判断を、主観評価と物理評価がどの程度近似したら下すのか、専門医と検討し決定することである。

謝辞

研究の遂行にあたり多くの実験試料をご提供いただきました岐阜医療科学大学保健科学部の方々から謝意を表します。本研究の一部は、文部科学省科研費補助金 (17K10455) によって行われました。

利益相反の有無

なし

文 献

- [1] Du, J., & Bydder, G. M, Qualitative and quantitative ultrashort-TE MRI of cortical bone. NMR in biomedicine, 26(5), pp.489-506, 2013.
- [2] 南谷 高宏, 武井 毅, 大淵 竜太郎, 点群の向きと距離の統計を用いた 3 次元モデルの形状類似比較, 画像電子学会年次大会予稿集, Visual Computing グラフィクスと CAD 合同シンポジウム 2003, pp.25-30

Deep Auto Encoder を用いた眼底画像からの糖尿病性網膜症の判別

安倍 和弥^{*1}, 武尾 英哉^{*1}, 永井 優一^{*2}, 高橋 嘉晴^{*3}

^{*1} 神奈川県立工科大学工学部電気電子情報工学科

^{*2} 国立がん研究センター東病院

^{*3} たかはし眼科クリニック

Discrimination of Diabetic Retinopathy from fundus images using Deep Auto Encoder

Kazuya ABE^{*1}, Hideya TAKEO^{*1}, Yuuichi NAGAI^{*2}, Yoshiharu TAKAHASHI^{*3}

^{*1} Kanagawa Institute of Technology

^{*2} National Cancer Center Hospital East

^{*3} Takahashi Eye Clinic

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の研究・開発が行われている。糖尿病性網膜症とは, 糖尿病の三大合併症の一つであり, 日本における中途失明の代表的な原因であるとされる。従来の糖尿病性網膜症の診断は, 眼科医が経時的に撮影した複数の眼底画像を比較読影することで診断しており, 診断能は眼科医の技能によるところが大きく, 病変を客観的かつ正確に把握することがやや困難であった。本研究では, 深層学習技術を用いたオートエンコーダによる異常検知により, 糖尿病性網膜症を判別する手法について研究を行う。オートエンコーダはあらかじめ正常な眼底画像だけで学習を行う。学習済みのオートエンコーダに疾患のある眼底画像が入力された場合, 異常部位が復元されないため, 原画像との差分をとることで異常陰影の検出が可能となる。平均二乗誤差に基づく一致判定結果において, 健常者と網膜症患者で有意差があることを t 検定で確認した。

キーワード: 糖尿病性網膜症, Deep Auto Encoder, 眼底画像, 異常分類, 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 Network) は積極的に用いられるようになった[2]。

健康診断や人間ドックにおいて, 広く用いられている検査の一つに眼底カメラを用いた眼底画像検査がある。また, 失明の原因となる糖尿病性網膜症の早期発見の為に, この検査を受診する人数が増加している。糖尿病性網膜症は糖尿病の三大合併症のひとつで, 糖尿病の発症後 10 年以内に合併症を引き起こす可能性が高いとされている[3]。

従来は, 糖尿病性網膜症の患者の診断は, 眼科医が経時的に撮影した複数の眼底画像を 1 枚 1 枚比較読影することで診断しており, 所見の微妙な変化出血, 浮腫, 細小血管閉塞等の病変を客観的かつ正確に把握することは難しく, 診断精度の低下を引き起こす可能性がある。そのため様々な CAD システムの開発が行われている。

本研究では, オートエンコーダを用いた異常検知により糖尿病性網膜症患者の判別を行う手法について検討を行う。健常者の画像を用いて構築したオートエンコーダを用いてエンコー

ド・デコードを行うことで, 異常領域が再構成されないためその差分から異常領域を検出できる。

オートエンコーダとは, 次元圧縮と再構築からなる入力画像と一致するような出力画像を生成する手法である。これを健常者の画像を基に学習を行い, 健常者のデータを入力すると似通った画像が再構築される。一方, 白斑などの異常のあるデータを入力すると, 学習されていない異常部位は再構築されず, 血管等だけが再構築された画像となる。

本論文では, 異常検知手法の一種である Skip-GANomaly[4] を眼底画像に合わせて拡張した手法を用いて, 糖尿病性網膜症の異常検知を行い, 入出力画像の平均二乗誤差 (Mean Squared Error: MSE) にて判別性能の検討を行う。これにより眼底画像の異常度を数値化して評価を行うことが可能となる。

本論文で使用する眼底画像データは, Messidor のデータセット[5]を用いている。

2. 手法

1) 前処理

カラー眼底画像においては緑成分のみの濃淡画像を作成すると血管領域とそれ以外の領域とのコントラストが高くなることから, カラー眼底画像を緑成分のみで構成した濃淡画像に変換し, 以降の処理ではこの画像を用いる。また学習の処理の関係上, 画像サイズを均一化している。

2) Skip-GANomaly を基にした異常検知

本研究で構築したオートエンコーダは, Akçay らの Skip-GANomaly を基とし, エンコーダ・デコーダともに 5 層構造に

拡張, 原著の論文では全層で用いられていたスキップ結合を中間層である第4層のみへと変更を加えた. スキップ結合とは, 同階層のエンコーダとデコーダを接続することで, 画像再構成時にパラメータの一部を補完する手法である. スキップ結合を複雑にするほど再構成の精度に向上が見られるが, 過学習の危険性が高まることや, 学習していない病変部のパラメータも画像から取り入れてしまうことにより異常検知が行えなくなるなどの問題も発生する.

3) 糖尿病性網膜症の判別法

糖尿病性網膜症の判別は, 入力画像と異常検知による再構成画像から MSE により一致度を算出し判定を行う. 再構成画像との一致度が高いほど MSE は低くなり, 逆に異常な部分が多いほど再構成がされず, 結果 MSE は上昇する. これにより異常検知による糖尿病性網膜症の判別が可能となる.


3. 実験と評価

1) オートエンコーダの学習

オートエンコーダの学習では, 健常者の眼底画像データ 476 例で学習を行った. 学習の設定としては, エポック数が 5000, バッチサイズが 64, 潜在変数が 100 次元となっている.


2) 未知データでの評価

本実験で未知データとして用いる画像データは健常者の画像 52 枚, 糖尿病性網膜症患者の画像 98 枚の計 150 枚にて評価を行った. オートエンコーダによる再構成画像の例と入出力の差分画像を図 1, 図 2 に示す. なお, 差分値は表示用にコントラストを 5 倍にしている.



(a) 入力画像 (b) 再構成画像 (c) 差分画像

図 1 健常者の再構成画像



(a) 入力画像 (b) 再構成画像 (c) 差分画像

図 2 糖尿病性網膜症の再構成画像

未知データでの評価結果を表 1 に示す. 健常者の MSE の平方根(Root Mean Squared Error : RMSE)は平均して 9.7, 対して糖尿病性網膜症患者の RMSE は平均して 13.4 となった. また, T 検定にてこの MSE 間の有意差を検証したところ, 両側 t 境界値 1.978 に対して t 値は -4.745 と範囲外であり, P 値も

0.000005 となり有意差があることが確認できた.

表 1 糖尿病性網膜症の判別

	健常者	網膜症患者
RMSE	2.53~21.4	6.21~33.4
平均	9.71	13.40
標準偏差	3.95	5.47
T 検定		
t 値	-4.745	
t 境界値	1.978	
P 値	0.000005 (<0.05)	

4. 考察

3章の図 1 より, 未知データにおいても健常者はほぼ再構成ができていたことが確認できる. 逆に, 図 2 より糖尿病性網膜症患者では白斑部や出血部が再現しきれないことにより入力画像と再構成画像との差分が大きくなった. また, 健常者と糖尿病性網膜症患者の RMSE を比較しても, 平均して 9.71 対 13.40 となり差異が得られた. T 検定においてもこの MSE 間の有意差が確認できた.

5. まとめ

本論では, Skip-GANomaly を医用画像に合わせて拡大した手法を用いて, 糖尿病性網膜症の異常検知を行い, MSE を基にした糖尿病性網膜症の判別について研究を行った. 異常検知による再構成とその差分により, 白斑部や出血部の検出が可能となり, MSE を基にした t 検定の結果より, 有意差ありとの結果が得られた. これにより, 本手法での糖尿病性網膜症の判別への有効性が示唆された.

謝辞

本研究で使用した眼底画像は, Messidor プログラムパートナーから提供されました.

Kindly provided by the Messidor program partners.

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] 田野保雄, 樋田哲夫, 根木昭他: 眼底アトラス. 文光堂, 東京, 2006
- [4] Akçay S, Atapour-Abarghouei A, Breckon T.P: Skip-GANomaly: Skip Connected and Adversarially Trained Encoder-Decoder Anomaly Detection. 2019 International Joint Conference on Neural Networks (IJCNN), doi: 10.1109/ijcnn.2019.8851808, 2019
- [5] Decencière E, Zhang X, Cazuguel G et al: Feedback on a publicly distributed database: the Messidor database. Image Analysis & Stereology, v.33, n.3, p.231-234, 2014

機械学習による白色上皮領域検出におけるコルポスコープ画像の実験的検討

篠原 寿広^{*1}, 小林 陽輝^{*1}, 藤井 一輝^{*1}, 村上 幸祐^{*2}, 中迫 昇^{*1}, 松村 謙臣^{*2}

^{*1} 近畿大学生物理工学部生命情報工学科

^{*2} 近畿大学医学部産科婦人科学教室

Experimental investigation of colposcope image for detecting acetowhite epithelium region by machine learning

Toshihiro SHINOHARA^{*1}, Haruki KOBAYASHI^{*1}, Kazuki FUJII^{*1}, Kosuke MURAKAMI^{*2},
Noboru NAKASAKO^{*1}, Noriomi MATSUMURA^{*2}

^{*1} *Department of Computational Systems Biology, Faculty of Biology-Oriented Science & Technology, Kindai University*

^{*2} *Department of Obstetrics & Gynecology, Faculty of Medicine, Kindai University*

要旨：子宮頸がん診断において、コルポスコープとよばれる拡大鏡を用いて子宮頸部の目視による検査が行われている。本検査はコルポスコピーとよばれ、子宮頸がんの確定診断を行う組織診のための組織を採取する部位を決定する非常に重要な検査であるが、コルポスコピーには豊富な知識と経験が必要とされる。本研究では、コルポスコープ画像を用いて機械学習による診断支援を行ってきた。これまで初期検討として、撮影条件などを考慮せずに撮影したコルポスコープ画像を試行的に使用していたが、撮影条件や個人差などにより、子宮頸部の色合いが大きく異なっていた。そこで、当該研究では、畳み込みニューラルネットワークを用いた、子宮頸部の代表的な病変の一つである白色上皮の判別において、子宮頸部の色合いに着目し、撮影条件や画像選択が判別に与える影響について実験的に検討した。

キーワード：コルポスコープ画像、子宮頸癌、白色上皮、診断支援、機械学習

1. はじめに

子宮頸癌はヒトパピローマウイルスの持続的な感染が原因となって発症する癌で、全世界では、年間約 570,000 人が罹患し、約 311,000 人が死亡しており、女性の癌による死亡原因の第 4 位となっている [1]。日本においては、年間約 10,000 人が子宮頸癌に罹患し、約 3,000 人が死亡している [2, 3]。

子宮頸癌の診断において、コルポスコープとよばれる拡大鏡を用いて、酢酸で加工した子宮頸部を目視により観察する検査が行われている。本検査はコルポスコピーとよばれ、子宮頸癌の診断において重要な役割を担っている。しかしながら、コルポスコピーは検査者の知識と経験に強く依存する [4]。そこで、われわれは機械学習によるコルポスコピー支援を検討している。初期検討として、子宮頸部の代表的な前癌病変の一つである白色上皮を対象に、コルポスコープ画像に対し、Convolutional Neural Network (CNN) を用いて白色上皮の判別を行ったが、精度よく判別することができなかった [5]。本初期検討では、撮影条件を考慮せずに撮影したコルポスコープ画像を使用していたが、症例によっては子宮頸部の色合いが大きく異なっており、そのことが判別性能を低下させた大きな原因の一つであると考えられる。

そこで本研究では、撮影条件をそろえることで、判別性能が向上するかどうかを実験的に検討した。また、初期検討において用いた画像のうち、子宮頸部の色合いの似た画像を選択して学習させ判別することを試みた。

2. 機械学習による白色上皮の判別 [5]

本研究では、はじめに、医師による診断データを基にコルポスコープ画像の各画素にラベル付けを行う。ラベルは白色上皮と白色上皮以外の 2 つのラベルであり、2 クラス分類問題を考える。つぎに、コルポスコープ画像を小領域に分割し、それらを学習用画像として、CNN により学習を行う。判別対象のコルポスコープ画像 (以下、テスト用画像とよぶ) も同様に分割し、それらを学習させた CNN により判別する。

4. 白色上皮判別実験

本実験では、コルポスコピーを実施した 20~50 代の患者 12 症例を対象に実験を行った。本研究は近畿大学医学部倫理委員会および同生物理工学部生命倫理委員会によって承認され、コルポスコープ画像の使用はすべての患者より書面による同意を得ている。また、使用したコルポスコープ画像は 1 名の医師がデジタルカメラ (E-PL5, OLYMPUS) により撮影条件をそろえて撮影した 4,608×3,456 pixels の RGB 画像である。図 1 にコルポスコープ画像の 1 例を示す。

*1 〒649-6493 和歌山県紀の川市西三谷 930
e-mail: sinohara@waka.kindai.ac.jp



図1 使用したコルポスコブ画像の1例

また、実験に使用した計算機環境を表1に示す。本研究で用いた CNN のネットワーク構造は VGG (Visual Geometry Group)16 [6] に基づく。CNN の学習パラメータなどの実験条件を表2に示す。画像の分割サイズは 128×128 pixels とし、64 pixel のストライドで画像を分割した。使用した分割画像のうち、白色上皮は 1,421 枚、正常上皮は 1,868 枚である。1 症例を判別対象とし、残りの 11 症例を学習用に使用し、各症例の判別性能の平均を全体の判別性能とした。

表1 計算機環境

CPU	Intel Core i7-8700
メインメモリ	32GB
GPU	NVIDIA Geforce RTX 2080 Ti
OS	Ubuntu 18.04 LTS
ソフトウェア	Chainer

表2 CNN の学習パラメータ

エポック数	500
バッチサイズ	128
最適化手法	慣性項付き確率的勾配降下法
学習率	0.001
慣性項	0.9

実験結果を表3に示す。比較として、初期検討において得られた結果[5]を「初期検討」として示す。初期検討においては、撮影条件を考慮せず、複数の医師が撮影したコルポスコブ画像を用いており、子宮頸部の色合いが異なっていたのに対し、本実験の画像は、色合いがほぼ同様であった。結果を比較すると、明らかに感度、適合率ともに向上しており、使用した画像は異なるものの、撮影条件をそろえることが判別性能の向上に効果があることが示唆された。

表3 白色上皮の平均判別性能

	精度	感度	適合率	F 値
本実験	0.742	0.705	0.705	0.668
初期検討	0.656	0.417	0.318	0.414

また、初期検討において用いた画像のうち、子宮頸部の色合いの似ている画像を7症例選択し、同様の判別実験を行った結果を「画像選択」として、表4に示す。なお、色合いの選択は、主観的に目視により行った。比較のため、初期検討の結果も表4に再掲している。結果を比較すると、やはり画像選択の方が明らかに判別性能が向上していることがわかる。

以上より、子宮頸部の色合いが判別性能に影響を与えることが実験的に示された。

表4 画像選択による白色上皮の平均判別性能

	精度	感度	適合率	F 値
画像選択	0.884	0.892	0.550	0.680
初期検討	0.656	0.417	0.318	0.414

5. まとめ

本研究では、機械学習を用いた、コルポスコブ画像における白色上皮の判別において、判別精度向上のため、コルポスコブ画像の撮影条件を考慮して判別実験を行った。その結果、初期検討して撮影条件を考慮せず、複数の医師が撮影したコルポスコブ画像を使用したときよりも判別性能が大幅に向上した。また、初期検討で使用した画像から子宮頸部の色合いの似た画像を選択して判別実験を行ったところ、やはり判別性能が向上した。今回、学習に用いた症例数が少なかったため、撮影条件や画像選択が白色上皮領域判別に顕著に影響を与えたものと思われる。

利益相反の有無

なし。

文献

- [1] Bray F, Ferlay J, Soerjomataram I, et al.: Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. CA Cancer J Clin. 68(6): 394-424, 2018.
- [2] 厚生労働省: 平成29年全国がん登録 罹患数・率報告, 2017.
- [3] 国立がん研究センターがん情報サービス: がん登録・統計(人口動態統計), 2018.
- [4] Xue P, Ng M.T.A and Qiao Y: The challenges of colposcopy for cervical cancer screening in LMICs and solutions by artificial intelligence. BMC Med 18, 169 2020.
- [5] 篠原 寿広, 藤井 一輝, 村上 幸祐, 他: 機械学習によるコルポスコブ画像における白色上皮領域検出精度向上のための検討. 第40回日本医用画像工学会大会予稿集, オンライン, P2-04, 2021.
- [6] Karen S and Andrew Z: Very Deep Convolutional Networks for Large-Scale Image Recognition. Proceedings of International Conference on Learning Representations, 2015.

正例とラベル無し画像からの学習による子宮頸部病変の識別

マナロ マーガレット ディー^{*1}, 青木 工太^{*1}, 武 淑瓊^{*1}, 新堂 真利子^{*2}, 上田 豊^{*2},
八木 康史^{*1}

^{*1} 大阪大学産業科学研究所複合知能メディア研究分野

^{*2} 大阪大学大学院医学系研究科産科学婦人科学教室

Cervical Lesion Classification via Positive-Unlabeled Learning

Margaret Dy MANALO^{*1}, Kota AOKI^{*1}, Shuqiong WU^{*1}, Mariko SHINDO^{*2}, Yutaka UEDA^{*2},
Yasushi YAGI^{*1}

^{*1} *Department of Intelligent Media, Institute of Scientific and Industrial Research, Osaka University*

^{*2} *Department of Obstetrics and Gynecology, Graduate School of Medicine, Osaka University*

要旨：子宮頸部前がん病変（異形成）および子宮頸がんの画像識別は緩和療法や外科治療において重要である。多くの機械学習手法は単一かつ完全にラベル付けされた画像を対象としているが、臨床現場における子宮頸がんのステージに対して、そのようなラベル付けは必ずしも適切とは言えない。本研究では、部分的あるいは複数のラベルが付与された子宮頸部画像を対象として、正例とラベル無し画像からの学習による識別手法を提案する。識別モデルと同時に、病変のラベル付けにおけるバイアスを反映する、正例性向モデルを学習させる。教師あり学習モデルと比べて、いくつかの評価尺度において性能が向上した。また、勾配で重み付けされた活性化マップは、より適切な領域を重視していた。

キーワード：正例とラベル無し画像からの学習、マルチラベル、子宮頸がん、前がん病変、子宮頸部画像

1. Introduction

Visual inspection has been recommended by the World Health Organization as an alternative cervical screening procedure due to its economic and expeditious advantages [1]. It, however, is subjective and dependent on expertise; thus, multiple machine learning works have attempted to automate it by training models on colposcopy-taken cervical images, or cervigrams.

However, acquiring a sufficient cervigram dataset for machine learning remains a challenge. As a result, most datasets in the field are limited to single-label annotations, with only a few made public, so previous works have focused on binary and multi-class approaches. This ignores the medical nature of the problem where lesions of different types can concurrently manifest.

In this study, we present a partially labeled multi-label cervigram dataset and perform cervical lesion classification through semi-supervised learning. Our contributions are threefold: (i) we introduce a cervigram dataset with partial multi-labels that closely resembles a clinical setting, (ii) we consider the partial-label nature of the dataset by treating it as positive-unlabeled and extending a semi-supervised deep learning algorithm, (iii) we perform multi-label classification, a rare setting due to the limitations of most cervigram datasets.

2. Materials and Methods

2.1 Multi-label Cervigram Dataset

We introduce a multi-label cervigram dataset, approved by the




図 1 酢酸の塗布によって白く浮き上がった病変と対応する画素単位のアノテーション。

institutional review board of Osaka University Hospital, which consists of 7,099 cervigrams of size 480×640 . Acetic acid was used to enhance the visibility of lesions as shown in Fig. 1, after which multi-label annotations were added after biopsy. Severe lesions were prioritized, leading to some cervigrams with partial labels.

2.2 Expectation-Maximization for Propensity Estimation

We consider the dataset as positive-unlabeled (PU), where unlabeled samples can either be positive or negative, and its labeled samples were selected under a bias, or *Selected At Random* (SAR) by PU definition [2]. In [3], the authors proposed to simultaneously train a classification and a labeling mechanism, or *propensity*, model through expectation-maximization (EM). The latent variable to be estimated is the expected probability of the positive class \hat{y} of instance x with label s estimated by

$$\begin{aligned} \hat{y} &= P(y = 1 | s, x, \hat{f}, \hat{\epsilon}) \\ &= s + (1 - s) \frac{\hat{f}(x)(1 - \hat{\epsilon}(x))}{1 - \hat{f}(x)\hat{\epsilon}(x)}. \end{aligned} \quad (1)$$

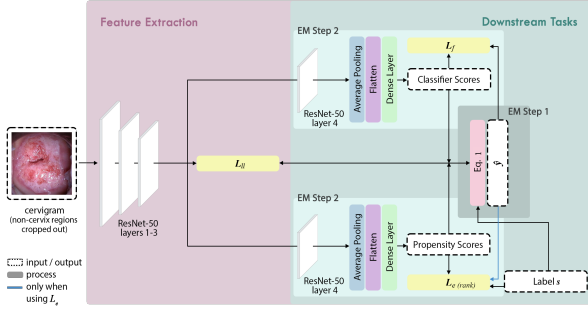


図 2 識別モデル f と正例性向モデル e の処理の流れとネットワーク構造. 処理の下流 (緑色で囲まれた部分) では, 正例確率 \hat{y} の推定 (ステップ 1), \hat{y} による f と e の学習 (ステップ 2) を反復する. 特徴抽出 (赤色で囲まれた部分) では, 下流の層のパラメータを固定し, その出力と特徴から L_{ll} を最小化する.

2.2.1 SAR-PU with Deep Learning

Our proposed approach extends [3] to multi-label image classification by estimating \hat{y} on M classes for each instance x . We trained the classification and propensity models using the estimated \hat{y} across M classes by minimizing the negative logistic loss for each instance as

$$L_f = -\frac{1}{M} \sum_{i \in M} [\hat{y}_i \ln f(x) + (1 - \hat{y}_i) \ln(1 - f(x))] \quad (2)$$

$$L_e = -\frac{1}{M} \sum_{i \in M} \hat{y}_i [s_i \ln e(x) + (1 - s_i) \ln(1 - e(x))] \quad (3)$$

2.2.2 SAR-PU Ranked Propensity

The assumption for Eq. 3 points to a strict hierarchical propensity based on the true class. Such an assumption cannot be directly applied to our cervigram dataset due to the presence of completely negative or normal samples which appear diseased yet proven otherwise during biopsy. Therefore, we modify Eq. 3 as

$$L_{e\text{rank}} = -\frac{1}{M} \sum_{i \in M} \sum_{j \in M: j \neq i} \max(0, -z(e_i(x) - e_j(x))), \quad (4)$$

$$z = s_i - s_j.$$

2.3 Implementation

The data was divided in ratios of 8:1:1 for training, validation, and test respectively. The classes of CIN1, CIN2,3, and cancer were used for multi-label classification. The network backbone of choice was a ResNet-50. As seen in Fig. 2, the network architecture consists of a feature extractor and separate downstream tasks for the classifier and propensity scores. Training was done in a two-step process where: (1) the classifier and propensity were trained on the same extracted features, backpropagating along the down-stream layers, and (2) the

表 1 マルチラベルデータセットに対する実験結果. 最も高い値を青字, 次に高い値を太字で示す.

Loss	BCE	SAR-PU	SAR-PU Rank
CIN1			
ROC	0.7607	0.7492	0.8209
AP	0.5561	0.5809	0.6348
Sensitivity	0.8030	0.7109	0.7197
Specificity	0.6130	0.6781	0.7979
CIN2,3			
ROC	0.7284	0.7596	0.7585
AP	0.7648	0.8056	0.7778
Sensitivity	0.8360	0.6800	0.7800
Specificity	0.5172	0.7678	0.6437
Cancer			
ROC	0.9220	0.9295	0.9330
AP	0.8478	0.8569	0.8781
Sensitivity	0.8352	0.8003	0.8132
Specificity	0.9039	0.9147	0.9520




図 3 テストデータに対して生成した活性化マップ.

feature extractor was trained using the output from the updated downstream layers, backpropagating its loss only along its own layers.

3. Results and Discussion

We compared our method with a straightforward supervised multi-label classification with binary cross entropy (BCE), that assumes a fully labeled dataset. We evaluated the effect of applying a rank loss for training the propensity model over that of the original in [3]. A quantitative comparison for each method on the test set is presented in Table 1. Results showed an improvement in overall performance with the SAR-PU methods, particularly with the rank loss. However, as specificity increased, sensitivity scores decreased for both CIN1 and CIN2,3 which indicates more false-negatives. Upon inspection, the activation maps show a wider focus with the SAR-PU methods, making them more inclusive of concurrent lesions.

4. Conclusion

In this study, we consider a clinical and realistic cervigram dataset setting and adapted a deep learning algorithm to accommodate it. In the process, it highlights the untapped potential of unlabeled cervical lesions as additional sources of training data for better overall classification.

References

[1] WHO guideline for screening and treatment of cervical pre-cancer lesions for cervical cancer prevention, 2nd ed. World Health Organization, 2021

[2] Bekker J, Davis J: Learning from positive and unlabeled data: a survey. Machine Learning 109: 719-760, 2020

[3] Bekker J, Davis J: Beyond the selected completely at random assumption for learning from positive and unlabeled data. Joint European Conference on Machine Learning and Knowledge Discovery in Data-bases, 2019

補綴物検出を用いた歯科パノラマ画像の歯牙認識性能の向上

岡 和範^{*1}, 新居 学^{*1}, 藤田 大輔^{*1}, 小橋 昌司^{*1}

^{*1} 兵庫県立大学大学院工学研究科電子情報工学専攻

Improvement of Tooth Recognition Performance of Dental Panoramic Images Using Prosthetic Detection

Kazunori OKA ^{*1}, Manabu NII^{*1}, Daisuke FUJITA^{*1}, Syoji KOBASHI^{*1}

^{*1} University of Hyogo

要旨：現在の歯科診療の現場では口腔領域をレントゲン撮影した歯科パノラマ画像が広く用いられている。歯科パノラマ画像を基に医師や歯科助手がカルテを作成するが、治療に直接関係しない歯牙を含む全ての歯牙を一つずつ確認し、治療痕の有無等を記述する必要がある。これらの負担によって誤記入などの医療の質の低下につながる可能性がある。そのため、診療に際して歯科パノラマ画像の自動解析が望まれている。CNNを用いた歯牙自動認識の研究があるが、口腔内に類似した歯牙が複数存在するため十分な精度が得られていない。本研究ではYOLOv5を用いた歯牙検出に加え、4種の補綴物を含む歯牙の検出を行い、それらに対して事前知識モデルを用いた組み合わせ最適化によって歯牙認識を行う手法を提案する。提案手法の実験結果として認識精度最大97.17%を達成した。また、補綴物を用いた歯牙検出を併用し、事前知識モデルを用いた最適化の有用性を示した。

キーワード：歯科パノラマ画像, 物体検出, 組み合わせ最適化, CNN, YOLOv5

1. はじめに

歯科パノラマ画像は歯科医院の診療で広く使われており、治療痕や喪失歯牙、疾病などの情報を1枚の画像として獲得し、視覚的に確認することができる。日本での歯科パノラマ画像の撮影枚数は2014年には1,200万枚、2019年には1,750万枚[1]と増加傾向にある。それに伴い、医師や歯科助手らの負担は増大し、誤記入などの医療の質の低下を招く危険性がある。ゆえに、歯科パノラマ画像の自動解析は喫緊の課題となっている。

先行研究として、Linらは画像100枚に対してDeep Convolutional Neural Network(CNN)を用いた歯牙検出の手法を提案したが、精度90.2%と不十分であった[2]。また、藤田らはSSDベースの深層学習を用いて75症例に対して歯牙認識を行ったが精度は92%程度であった[3]。また、藤田らはGoogLeNETを用いた関心領域の検出と歯種認識、治療痕認識を行ったが、精度は歯種認識が93.2%であった[4]。MahdiらはCNNの一種であるFaster R-CNNを用いた歯牙検出手法を報告したが、適合率は94.2%であった[5]。また、CNNから得られる結果が重複を許す複数物体検出である点に着目し、その検出結果に組み合わせ最適化を行うことで精度向上が可能であることを検証した[6]。

本研究では他ネットワークによる精度向上が可能かを検討するため2020年に開発されたCNNの一種であるYOLOv5[7]を用いた歯牙検出をベースとした歯牙自動認識を行う。先行研究[4]では、補綴物を含む歯牙に対して精度が低下することが問題であった。そのため、通常の歯牙検出に加えて補綴物を含む歯牙を検出する必要がある。同ネットワークにて補綴物を含む歯牙の候補を検出する。これらの情報をもとに、事前知識モデルを用いた組み合わせ最適化を行い、CNNの直接的な歯牙認識よりも高い精度での歯牙自動認識を目指す。

2. 提案手法

本研究では深層学習を用いた歯科パノラマ画像からの歯牙自動認識の手法を提案する。提案手法は以下の3つのステップで構成される。

1) YOLOv5を用いた歯牙候補検出

ここでは各歯牙を異なる物体と考え32クラスの物体検出を行う。1枚の歯科パノラマ画像を入力画像とし、学習済みのYOLOv5による歯牙の検出を行う。検出された候補はバウンディングボックスとして出力される。

2) 補綴物を含む歯牙候補の検出

ステップ1の歯牙候補検出では、補綴物を含む歯牙と通常の歯牙を共通の番号の歯牙として学習を行うため、検出精度が低くなる。しかし、補綴物の種類と歯牙の種類に関して同時に学習、検出を行うと類似するクラス数が増大し、認識が困難になる。そこで、ステップ2では補綴物を含む歯牙について、YOLOv5を用いてインレー、クラウン、インプラント、ブリッジの4クラスの物体検出を行う。ここで、歯牙認識のためにステップ2で得られた候補に歯牙番号の紐づけを行うが、各候補に全ての歯牙番号を紐づけすることは現実的ではない。そこで、ステップ1で得られたデータを基に咬合曲線を求め、歯牙番号の推測を行う。

3) 事前知識モデルによる組み合わせ最適化

ステップ1, 2で各歯牙番号に対して0個から複数個の候補が検出される。そこで、各歯牙番号に対して喪失を含む1つの歯牙候補を選択する組み合わせ最適化問題として取り扱う。この時、得られた候補に対して事前知識モデルを適用する。与えられた歯牙候補の組み合わせ \mathbf{P} を評価する目的関数 $f(\mathbf{P})$ を式(1)で提案する。ここで、 $f_p(\mathbf{P})$ は歯牙候補間の相対位置に基づく目的関数、 $f_c(\mathbf{P})$ はYOLOv5により算出された各候補の信




図 1 歯牙候補検出成功例




図 2 歯牙候補検出失敗例




図 3 補綴物を含む歯牙候補検出の成功例



図 4 補綴物を含む歯牙候補検出の失敗例

表 1 各補綴物における歯牙の検出結果

	インレー 2569 例	クラウン 1197 例	ブリッジ 218 例	インプラント 118 例
Precision	93.39%	64.97%	99.06%	88.62%
Recall	97.31%	97.39%	96.77%	99.09%
F1 score	95.31%	77.94%	97.90%	93.56%
Accuracy	91.03%	63.86%	95.89%	87.90%

頼度に基づく目的関数である。この評価関数 f を最大化する組み合わせ \mathbf{P} を求めることで歯牙認識が行われる。

$$f(\mathbf{P}) = \omega_p f_p(\mathbf{P}) + \omega_c f_c(\mathbf{P}) \quad (1)$$

3. 実験結果

YOLOv5 による歯牙候補検出の結果について、成功例を図 1 に、失敗例を図 2 に示す。成功例では全ての候補を正常に検出することができた。失敗例では、補綴物を含む歯牙である 30 番の歯牙の検出に失敗している。補綴物を含む歯牙の検出には失敗するケースが多く、特にインプラントは検出できない。なお、YOLOv5 による歯牙検出の評価としては、Recall が 97.73%、Precision が 92.98%、F1 Score が 95.30%、Accuracy が 91.94% であった。

補綴物を含む歯牙の検出結果の成功例を図 3 に、失敗例を図 4 に示す。図 3 では全ての歯牙に対する補綴物の検出に成功している。図 4 においては画像右下部の歯牙に対して同一の歯牙に対してクラウンとインレーの両方を検出してしまっている。各補綴物における歯牙の検出結果を表 1 に示す。

次に組み合わせ最適化を行った。成功例を図 5 に、失敗例を図 6 に示す。図 5、6 では各歯牙を対象歯牙の中心座標を示す点によって結んでいる。図 5 では、複数の補綴物付の候補を持つ歯牙のうち、正しい結果を選択することができた。失敗例として、図 6 では前歯が密集する部分にて歯牙認識に失敗してい




図 5 組み合わせ最適化の成功例




図 6 組み合わせ最適化の失敗例

る。複数の歯が重なり合い、ステップ 1 での検出に失敗し、組み合わせ最適化においても位置座標評価が困難になっている。歯牙認識の結果は、Recall が 97.70%、Precision が 95.31%、F1 Score が 96.80%、Accuracy が 94.73% であった。

4. まとめ

本研究では、補綴物を含む歯牙の検出と事前知識モデルに基づく組み合わせ最適化によって歯牙自動認識の精度を向上する手法を提案した。本研究により、深層学習を用いた歯科パノラマ画像からの歯牙自動認識手法の有効性を確認した。

謝辞

本研究の実施にあたり、終始適切な助言を賜り、また丁寧に指導して下さった小橋昌司教授、新居学准教授、藤田大輔助教に深く感謝いたします。

本研究で使用した歯科パノラマ画像を提供いただきました株式会社ナルコム代表取締役猪俣吾郎様に深謝いたします。

利益相反の有無

なし

文献

- [1] 勝又明敏：歯科画像情報の現状と将来展望。日本歯科保存学雑誌，第 62 巻 5 号，pp238-242, 2019
- [2] Lin N, Lin T, Wang X et al.: Teeth detection algorithm and teeth condition classification based on convolutional neural networks for dental panoramic radiographs. Journal of Medical Imaging and Health Informatics, Vol. 8, No. 3, pp507-515. 2018
- [3] 藤田広志, 村松千佐子, 林達郎 他：歯牙的個人識別のための relation networks for object detection を用いた歯科用 cone-beam CT における歯牙の検出。第 38 回日本医用画像工学会大会予稿集，pp514-517, 2019
- [4] Muramatstu C, Morishita T, Takahashi R et al.: Tooth detection and classification on panoramic radiographs for automatic dental chart filing: improved classification by multi- sized input data. Oral Radiology 2021, pp13-19, 2021
- [5] Mahdi F, Yagi N, Kobashi S: Automatic teeth recognition in dental X-Ray images using transfer learning based faster R-CNN. 50th IEEE International Symposium on Multiple-Valued Logic, 2020
- [6] Motoki K, Mahdi F, Yagi N et al.: Automatic Teeth Recognition Method from Dental Panoramic Images Using Faster R-CNN and Prior Knowledge model, SCIS-ISIS, 2020
- [7] Thuan D: Evolution of YOLO Algorithm and YOLOv5: The State-of-The-Art Object Detection Algorithm. Oulun Ammattikorkeakoulu, 2021

多施設からの眼底画像における緑内障の重症度推定

村尾 晃平^{*1}, 佐藤 真一^{*1}, 大本 貴士^{*1*4}, 柏木 賢治^{*2}, 三宅 正裕^{*3}, 二宮 洋一郎^{*1}

^{*1} 国立情報学研究所 医療ビッグデータ研究センター

^{*2} 山梨大学 大学院 総合研究部 医学部 眼科学

^{*3} 京都大学 大学院 医学研究科 眼科学

^{*4} 東京大学 大学院 医学研究科 眼科学教室

Estimation of glaucoma severity in fundus images from multiple hospitals

Kohei MURAO^{*1}, Shin'ichi SATOH^{*1}, Takashi OMOTO^{*1*4}, Kenji KASHIWAGI^{*2}, Masahiro MIYAKE^{*3}, Youichirou NINOMIYA^{*1}

^{*1} Research Center for Medical Bigdata, National Institute of Informatics

^{*2} Department of Ophthalmology, Yamanashi University

^{*3} Department of Ophthalmology, Graduate School of Medicine, Kyoto University

^{*4} Department of Ophthalmology, Graduate School of Medicine, The University of Tokyo

要旨: 日本眼科学会が全国 14 施設から収集した眼底画像について、正常および 11 種類の疾患に分類した約 1 万 3 千の画像がある。これをもとに緑内障のクラスを重症度別に 3 クラスに分割した 14 クラスの識別器を作成したところ緑内障の識別率は 93%、重症度の識別率は 43%であった。なお、施設によって画像サイズ・縦横比やスケールが異なるため、スケールを合わせるような規格化の前処理を考案し、規格化した画像を用いて学習・識別を行った。

一般に、分類すべきクラスが多いとエントロピーが大きくなり推定が困難になる。そこで、緑内障の有無の識別とは別に、緑内障の重症度を専門に判定する識別器を作成して組合せることで精度向上を考えた。前段で作成した識別器を緑内障有無の判定に使い、緑内障有と推定された症例に重症度判定の識別器を使うようにしたところ、緑内障の識別率はそのまま、重症度の識別率を 64%に向上させることができた。

キーワード: 眼底画像, 多施設データ, 規格化, 緑内障, 重症度判定

1. はじめに

眼底画像に対する日本眼科学会から次のような要望を承っていた:「健診にて異常を拾い上げるのを支援すると共に、統計的に頻度の高い疾患については有無を提示したい。中でも緑内障については、重症度を推定できることが望ましい。」

そこで日本眼科学会から提供されていた 13,452 枚の画像を用いて識別器を開発し、追加で提供された 120 枚の画像を使ってテストを行った。これらの画像は国内 14 施設から収集した画像であり、画質の差異は目視で見られないものの、後述するように画像サイズ・縦横比や画像マスクのサイズが多種類にわたる。そこで、画像コンテンツがほぼ同様のスケールになるような規格化の前処理を考案した。

識別器の作成に当たっては、疾患種別と緑内障の重症度を同列に扱ったモデルと、緑内障の有無を推定する識別器と重症度を推定する識別器を組み合わせたモデルを試した。後者の方が個々の識別器で分類すべきクラスが少なく、識別性能は良くなることを実際のデータで示す。

2. 画像の規格化

国内 14 施設から提供された眼底画像のデータを見ると、施設間だけでなく施設内でも画像サイズ・縦横比などの異なる画像がある。代表的なものを整理して図 1 の上段に列挙した。図からわかることは、実質画像（眼底として意味のある部分を指す）の上下はトリミングされている場合があるが、左右についてはトリミングされている例はない。そこで、実質画像の左右を辺の長さとする正方形になるように画像にマスク画像の付加やトリミングを行う方針とした。具体的には、下記のような手順で規格化を行った。

1) 画像全体が正方形でない場合には、短い方に黒のマスク画像を付加して正方形にする。




図 1 上段：元画像，下段：規格化後の画像

2) 眼底画像外の黒い領域にスパイク状のノイズが存在する場合がありトリミングの障害になるため、9x9のMedianフィルタでぼかした作業者の画像を作り、実質画像が含まれる正方形の領域を抽出する。

3) 上記で求めた正方形の領域の座標を元画像から切り抜き、所定のサイズ(512x512)にリサイズする。

なお、元画像のフォーマットにはbmp, png, tiffが混在しているので、全てjpgに変換する。

3. 識別器の作成

識別器にはVGG19[1]をベースとし、学習率を変化させるCLR(Cyclical Learning Rates)[2]を併用して多クラスの識別器を作成する。

最初に多種の疾患と緑内障の重症度を同時に振り分ける識別器を作って性能を調べる。次に、緑内障の重症度のみを振り分ける専用の識別器を作って、上記の識別器を前処理とする多段階の識別器を作る(図2)。重症度識別専用の識別器の学習には、緑内障のデータのみを使って学習させる。




図2 多段階の識別器。

4. 実験データ

学習用のデータは、日本眼科学会が収集した眼底画像の正常および11疾患について、疾患ごとおよび施設ごとの分布に応じて8000例をランダムに選び出した。このうち、緑内障の重症度については3クラスに分けた。各々のクラスに対する症例数を表1に示す。

表1 各クラスの症例数

クラス	症例数	クラス	症例数
00 (正常)	932	07 (緑内障早期)	406
01 (加齢黄斑変性)	787	08 (緑内障中等度)	326
02 (中心性漿液性脈絡網膜症)	587	09 (緑内障重度)	502
03 (網膜静脈閉塞症)	966	10 (近視性黄斑症)	631
04 (黄斑円孔)	350	11 (乳頭浮腫)	269
05 (黄斑上膜)	626	12 (網膜色素変性)	405
06 (糖尿病網膜症)	1,067	13 (非緑内障性視神経委縮)	146

バリデーション用データについても、上記と同様にデータ分布に従って2000例をランダムに選んだ。

	推定													合計	
	00	01	02	03	04	05	06	07	08	09	10	11	12		13
00	13	4	3	1	1	3	1	2	1	0	0	0	0	1	30
01	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
02	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
03	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
04	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
05	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
06	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
07	2	1	0	1	0	1	15	9	0	0	0	1	0	30	
08	0	0	0	0	0	0	3	20	7	0	0	0	0	30	
09	0	0	0	0	0	0	1	6	23	0	0	0	0	30	
10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
12	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	

図3 多段階の識別器による Confusion Matrix

テスト用のデータは、緑内障の重症度ごとの3クラスについて各々30例、正常および緑内障以外の疾患を含む例(コントロール症例と呼ぶ)について30例、合計120例を使った。

5. 結果

多疾患と緑内障の重症度を同時に振り分ける識別器の結果、緑内障の識別率は93%、重症度の識別率は43%であった。緑内障として拾いすぎた例は3例(10%)であった。

図2のような構成の識別器を使った場合の結果、緑内障の識別率は93%のままで、重症度の識別率は64%であった。拾いすぎは10%のままである。Confusion Matrixを図3に示す。ここで、コントロール症例を全て00のクラスに設定した。識別器を通すと00以外のクラスにも振り分けられた。

3. まとめ

多施設の眼底画像を解析する際、画像の規格化が必要であることがわかった。疾患の有無と重症度判定を行う際、単一の識別器を使うよりも多段階の識別器を組み合わせる方が性能が良い。これは、分類すべきクラス数が少ない方が、各クラスのデータ量に大きな差異が発生しないなら、エントロピーを小さくでき、推定が容易になるからだと考えられる。

謝辞

本研究はAMEDのJP201k1010036により構築された医療ビッグデータクラウド基盤を利用しております。

利益相反の有無

なし

文献

[1] Simonyan K, Zisserman A: Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv:1409.1556, 2015
 [2] Smith L N: Cyclical Learning Rates for Training Neural Networks. arXiv:1506.01186, 2017

臨床情報を加えた改良型 ResNet による

CT 画像からの結節状陰影の識別

本田 直也*¹ 神谷 亨*¹ 木戸 尚治*²

要旨

近年、肺がんの検査方法として CT 検査が多く用いられているが、得られる CT 画像の枚数は膨大であり、読影医師の大きな負担となっている。そこで、この問題を軽減するためにコンピュータ支援診断システムの開発が行われている。一般に医師が診断を行う際、画像情報以外に患者情報も加味していることから、これを機械で模倣することにより、診断精度を向上させる新しい取り組みが行われている。そこで本論文では、画像以外にカルテ情報を追加することによる診断精度の向上を目的とした肺結節の識別法を提案する。機械学習における画像特徴から誤認識の一因とされる血管影の分岐情報や血管影、結節状陰影などを教師ラベルとして付与し、未知データからの分類を行う。実験では 159 枚の結節画像を含む計 636 枚に対し、臨床情報を追加した場合の識別結果は、画像情報のみを用いた場合と比較して真陽性率と正解率は 1% 向上し、臨床情報の追加による精度向上が確認できた。

キーワード：CT, コンピュータ支援診断, 臨床情報, マルチモーダル, 深層学習

1. 序論

2019 年における日本のがんによる死亡者数は約 37 万人である^[1]。通常、肺がんの検査方法として CT 検査が行われるが、1 回の撮影で得られる CT 画像の枚数は膨大で、CT 画像の読影を行う読影医師への負担が大きく、それに伴って小さな病変部の未検出などが発生する可能性がある。

そこで近年、読影医師の負担を軽減すべく、画像診断の分野ではコンピュータ支援診断 CAD (computer aided diagnosis) システムの開発が推し進められている。現在 CAD システムは、CT 画像を用いた画像診断支援が主である。そ

で本論文では、患者情報と画像診断の結果を含めた診断を行う CAD システムの開発を目的としている。手法としては、画像情報と患者情報を用いた深層学習による結節の識別を行う。実験では画像情報のみの場合と性能比較を行い、提案手法の有用性と考察を述べる。

2. 手法

2.1 画像特徴

画像特徴を抽出するモデルとして画像分類の分野において高性能な成果を得ている ResNet^[2]を用いる。本論文では、ResNet34 に対して改良を行ったモデルを提案する。モデルの詳細は Residual Block の直前に畳み込みオートエンコーダを追加する。また、Residual Block の内部に SE-Block^[3]を導入する。そして、画像特徴量を抽出するため全結合層を除外し、512 次元の特徴ベクトルを取得する。

2.2 臨床情報特徴

本稿では臨床情報として、性別、年齢、既往歴、そして疾患率を用いる。前処理として、性別に関しては男女で、既往歴に関しては、疾患

*1 九州工業大学

〔〒804-8550 福岡県北九州市戸畑区仙水町 1-1〕

e-mail: kamiya@cntl.kyutech.ac.jp

*2 大阪大学

〔〒565-0871 大阪府吹田市山田丘 2-2〕

の有無を one-hot ベクトル化を行う。そして全ての説明変数に対して標準化の処理を行う。

臨床情報の特徴量を抽出するモデルとして、3層からなる多層パーセプトロンによって 256次元の特徴ベクトルを取得する。

2.3 マルチモーダル

画像と臨床情報から得られた特徴ベクトルを統合し、768次元の特徴ベクトルを4層の多層パーセプトロンによって結節の識別を行う。

3. 実験と結果

3.1 入力画像

入力画像として、結節、分岐した血管、細い血管、丸い血管の4種類のマスク画像を用いた。陽性画像として75症例159枚の結節画像を用いた。また、陰性画像として分岐した血管、細い血管、丸い血管をそれぞれ159枚用いた。回転処理によりデータの水増しを行っている。

3.2 評価指標

評価指標としては、正解率(Accuracy)、真陽性率 TPR(True Positive Rate)、そして、FPR(False Positive Rate)を用いる。

3.3 実験結果と考察

画像情報のみを用いて分類を行った際の精度と画像情報以外に文章情報を追加した際の結果を表1に示す。また、表2に画像のみの場合、そして表3に臨床情報を追加した場合の混同行列を示す。表1より画像に臨床情報を追加することで1%の精度向上がみられた。実際は結節であるが丸い血管であると予測した数が多く、その理由としては、関心領域のみをマスク加工したため、得られる情報が限られていることから、結節に対する精度向上は難しいのではないかと考える。また、画像情報のみで分類した場合より、臨床情報を追加した場合の方が結節を正しく分類できた数がいずれの場合も少なくなった。その理由として正常組織に対し、文章情報はそのクラス分類に関連性が少なく、精度向上に至らなかったと考えられる。

4. 結論

本論文では、胸部CT画像からカルテに含まれる患者情報を加え、結節、分岐した血管、細い血管、そして丸い血管の4クラス分類を行い、

表1 精度比較

Data	Acc.	TPR	FPR
Image only	0.91	0.91	0.03
Image+text	0.92	0.92	0.03

表2 混同行列(image only)

	結節	分岐	細い	丸い
結節	138	3	0	18
分岐	0	147	12	0
細い	0	4	155	0
丸い	16	0	0	143

表3 混同行列(image+text)

	結節	分岐	細い	丸い
結節	136	2	0	21
分岐	0	147	12	0
細い	0	4	155	0
丸い	10	0	0	149

わずかではあるが画像情報に文章情報を追加したことにより精度が向上した。今後の課題としては、それぞれのネットワークに対してさらなる改良が必要である。

謝辞

本研究は、文部科学省科学研究費補助金(21H03840)、栢森情報科学振興財団(K33研XXVI第579号)の助成を受けて遂行された。

利益相反の有無

なし

参考文献

- [1] [https://ganjoho.jp/reg_stat/statistics/stat/cancer/12_lung.html#anchor1\(2022/01/07access\)](https://ganjoho.jp/reg_stat/statistics/stat/cancer/12_lung.html#anchor1(2022/01/07access))
- [2] K. He et al., "Deep residual learning for image recognition", IEEE Conference on Computer Vision and Pattern Recognition, pp. 770-778, 2016.
- [3] J. Hu et al., "Squeeze-and-excitation networks", IEEE Conference on Computer Vision and Pattern Recognition, pp. 7132-7141, 2018

Vision Transformer を用いた胸部 X 線画像の画像分類による COVID-19 の診断

伴 凌輔^{*1}, 原田 恵雨^{*1}, 中村 嘉彦^{*1}, 三上 剛^{*1}

^{*1} 苫小牧工業高等専門学校

Diagnosis of COVID-19 by Image Classification of Chest X-Ray Images Using Vision Transformer

Ryosuke BAN^{*1}, Keiu HARADA^{*1}, Yoshihiko NAKAMURA^{*1}, Tsuyoshi MIKAMI^{*1}

^{*1} National Institute of Technology, Tomakomai College

要旨 : COVID-19 は様々な診断方法が提案されている。PCR 検査は最も一般的だが、結果の判明に時間を要するなどの問題があった。そのため高速な診断のために機械学習による研究が行われている。また、自然言語処理で利用される Transformer を画像処理に転用した Vision Transformer (ViT) は、一般的な画像分類で用いられる CNN を用いずに CNN と同等以上の精度になることなどがわかっている。本研究では ViT を用いて COVID-19 患者の胸部 X 線画像の画像分類による迅速な診断を目的とする。ハイパーパラメータ最適化に Optuna を使用し、選択されたオプティマイザ RAdam 及び学習率によって学習を行った。また、正解率や適合率などの指標で評価した結果、各指標で約 90% の精度を出すことが分かった。また、課題として誤分類の解消が必要である。今後は軽症患者と正常者の判別が困難なために誤分類が起こると仮定し重症度分析を行う。

キーワード : COVID-19, 医用画像処理, Vision Transformer

1. はじめに

COVID-19 とは 2019 年に発生した感染症であり、全世界で感染拡大している。2019 年に中国武漢市で発見されてから 2021 年 9 月までに世界で感染が確認されたのは 2 億 2 千万人で死者は 455 万人も及ぶ。COVID-19 の感染を確かめる手段はいくつか存在し、最も一般的に用いられているのは PCR 検査である。しかし欠点としては検査結果が判明するのに時間を要する点などがある。医師や医療機器、病床などの数は限られており、より迅速な診断が求められる。そのような点から CT 画像やレントゲン画像などを用いた画像処理や機械学習による診断方法が複数提案されている。本研究では深層学習モデル Vision Transformer (ViT) を用いて胸部 X 線画像から Normal, Pneumonia, COVID-19 の 3 クラス分類を行う。

2. 関連研究

Linda Wang ら[1]によって、オープンソースで公開されている胸部 X 線画像から COVID-19 の感染を検出するための深層学習モデル COVID-Net を提案し、COVID-19, Pneumonia, Normal の 3 クラスについて分類を行っている[1]。分類精度は、Normal クラスは 90.5%, Pneumonia クラスは 91.3%, COVID-19 は 98.9%であり VGG19 や ResNet50 と比較しどのクラスでも高い精度を達成している。

3. 基本事項

3-1. Vision Transformer

Transformer は 2017 年に発表された主に自然言語処理タスクに用いられる深層学習モデルである。自然言語を含む時系列データを取り扱うタスクで用いられるリカレントニューラルネットワーク(RNN)と異なる点は、逐次処理が必要なく、並列化

が可能になったことから訓練時間が短縮されたという特徴がある。2020 年に Google の研究チームが発表した Vision Transformer は Transformer を画像認識の分野に適用することで CNN と同等以上の精度が得られたことから様々な分野で応用されている。Alexey らの研究[2]では CNN と組み合わせることなく Transformer 単体で画像分類を行い、畳み込みを用いたモデルと同等以上の精度が確認されており、Vision Transformer (ViT) として提案されている。

4. 実験方法

4-1. データセット

本研究では Linda Wang らの研究と同様に COVIDx を使用した。COVIDx は 5 つのオープンソースデータセットを組み合わせできたデータセットであり、Normal, Pneumonia, COVID-19 の 3 つのクラスに分かれたラベルがある。表 1 に各クラスとその訓練、検証、テストにそれぞれ使用した枚数を示す。

4-2. モデルの構築

モデルの学習には keras ライブラリ「vit-keras」を使用している。「vit-keras」は ImageNet21K データセットで事前学習済みのモデルである。vit-keras を 3 クラス用分類モデルとして適用するために全結合層を追加した。また、活性化関数には Softmax を使用した。

4-3. モデルの学習と評価方法

モデルの学習に最適なハイパーパラメータを決定するために Optuna を用いてハイパーパラメータ最適化を行った。最適化を行ったのは最適化アルゴリズムと学習率である。モデルの学習に用いた学習パラメータを表 1 に示す。また、学習結果の

評価方法としてテストデータについては正解率, 適合率, 再現率, 混同行列で評価する. また, 分類モデルの注目領域を見るために LIME を使用する.

表 1 分類クラスにおけるデータの枚数

	Train	validation	test
Normal	7170	796	100
Pneumonia	4931	544	100
COVID-19	1950	208	200

表 2 学習パラメータ

項目	名称
評価関数	Accuracy
損失関数	Categorical Cross Entropy Loss
最適化アルゴリズム	Adam
学習率	3.9×10^{-5}

5. 実験結果

5-1. 評価関数

本研究では正解率, 適合率, 再現率について評価し, Bhowal らの研究[3]と比較している. Bhowal らの研究は胸部 X 線画像による COVID-19 分類において SoTA レベルを達成している. また, COVIDx による実験も行っているため提案手法の結果との比較を行う. 各評価指標の計算式は式(1)~(3)に示す. また, 各評価指標の比較結果を表 3, 混同行列を表 4 に示す.

$$\text{正解率} = \frac{TP+TN}{TP+FP+TN+FN} \quad (1)$$

$$\text{適合率} = \frac{TP}{FP+TP} \quad (2)$$

$$\text{再現率} = \frac{TP}{FN+TP} \quad (3)$$

表 3 評価指標の結果

評価項目	Bhowal ら[3]	提案手法
正解率[%]	93.8	94.9
適合率	Normal[%]	87.8
	Pneumonia[%]	96.3
	COVID-19[%]	98.0
再現率	Normal[%]	96.0
	Pneumonia[%]	88.0
	COVID-19[%]	97.8

表 4 混同行列

		Predict		
		Normal	Pneumonia	COVID-19
True	Normal	0.96	0.02	0.02
	Pneumonia	0.1	0.88	0.02
	COVID-19	0.02	0.01	0.98

5-2. 可視化

LIME による可視化の例を図 1 に示す. 緑色の領域は分類クラスに肯定的な領域であり, 赤色の領域は否定的な領域である.




図 1 LIME の可視化例

(左:Normal, 中央:Pneumonia, 右:COVID-19)

6. 考察

6-1. 評価関数

学習精度は約 90%を達成し, 高精度であると言える. しかし, 混同行列より誤分類ケースが一定数あるために COVID-19 患者の発見を見落としてしまう可能性などの恐れがあるため, 原因の調査が必要である. また, COVIDx は症状の経過日数や重症度が不明なため症状が軽微な場合に誤分類する可能性を考える必要がある.

6-2. 可視化

肺領域を捉えている画像もあったが, 背景や肺以外の部位に注目しているケースが多い. このような場合が多いと, 例え正解率等が高くても肺以外の領域で分類を判断しているということなので診断において信頼性のあるモデルであるとは言えない. したがって注目する必要がない領域で判断する機会を減らすために ROI 抽出などの処理を行うことが必要と考えられる.

7. まとめ

本研究では Transformer を画像認識用に適用したモデル Vision Transformer を用いて胸部 X 線画像による画像分類から COVID-19 の診断を行った. 正解率等について約 90%の精度を達成できた. しかし, 誤分類の発生やモデルの注目領域の違いなどが問題であり, 今後はより信頼性を高めるために重症度分析や ROI 抽出などが必要である.

利益相反の有無

なし

文献

- [1] Linda Wang, Alexander Wong: COVID-Net: A Tailored Deep Convolutional Neural Network Design for Detection of COVID-19 Cases from Chest X-Ray Images, Scientific Reports, 2020 arXiv preprint arXiv:2003.11055.
- [2] Alexey Dosovitskiy et al. : An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale, ICLR 2021, 2021
- [3] Pratik Bhowal et al. : Choquet Integral and Coalition Game-Based Ensemble of Deep Learning Models for COVID-19 Screening From Chest X-Ray Images, IEEE J Biomed Health Inform, 2021

LPC と HPSS を用いた呼吸音の自動分類

田端 愛美^{*1}, 陸 慧敏^{*1} 神谷 亨^{*1}
 間普 真吾^{*2} 木戸 尚治^{*3}

^{*1} 九州工業大学

^{*2} 山口大学

^{*4} 大阪大学

Automatic Classification of Respiratory Sounds Using LPC and HPSS

Manami TABATA^{*1}, Huimin LU^{*1}, Tohoru KAMIYA^{*1}, Shingo MABU^{*2}, Shoji KIDO^{*3}

^{*1} *Kyushu Institute of Technology*

^{*2} *Yamaguchi University*

^{*3} *Osaka University*

要旨：呼吸器疾患の多くは世界の死因上位に上げられており、年間 800 万人近い死者が出ている。呼吸器疾患の主な診断方法は聴診器を用いた聴診である。しかし、定量的な基準がなく、経験豊富な医師が不足する発展途上国や、災害現場では診断が困難になる場合がある。この問題を解決するため、呼吸音を定量的に分析・分類し、「第二の意見」として出力するコンピュータ支援診断(CAD: Computer Aided Diagnosis)システムが必要である。本論文では、呼吸音データを調波打楽器音分離(HPSS: Harmonic / Percussive Sound Separation)によって異常呼吸音特徴を強調分離し、分離前を含む 3 種類の音声データを、それぞれ線形予測分析(LPC: Linear Predictive Coefficient)によって得られたスペクトル包絡から画像生成を行う。3 種類の画像を CNN(Convolutional Neural Network)と LightGBM(Light Gradient Boosting Machine)を用いて分類する。提案手法を ICBHI(International Conference on Biomedical and Health Informatic) 2017 Challenge で使用されたデータセットに適用した結果、Sensitivity は 58.8%, Specificity は 87.0%, Average Score は 72.9%, Harmonic Score は 70.2%, Area Under the Curve は 86.8%, 偽陰性率は 29.4%を得た。

キーワード：呼吸音、畳み込みニューラルネットワーク、コンピュータ支援診断システム、線形予測分析、調波打楽器音分離

1. 序論

呼吸器疾患は 2019 年の WHO(World Health Organization)による調査によると、世界の死因原因の上位に上げられている^[1]。呼吸器疾患の主な診断方法である、聴診器を用いた聴診は、訓練を受けた医師が必要になる。そのため「第二の意見」として結果を出力する、CAD システムの開発が必要である^[2]。呼吸音の自動分類に関する研究では、線形予測測ケプストラム係数の特徴によって 2 クラス(異常・正常)分類手法^[3]や、HPSS によって異常呼吸音特徴を強調分離したスペクトログラムを用いた、4 クラス(Crackle, Wheeze, Both(Crackle and Wheeze), Normal)分類手法が提案されている^[4]。CAD システムの実用化には 4 クラス分類でさらなる精度の向上が必要である。

本論文では、HPSS を用いて異常呼吸音特徴を強調分離し、LPC を用いてモデル化する手法を提案する。

2. 手法

2.1 前処理

呼吸音データのサンプリング周波数を 4000Hz に統一、音量の正規化、呼吸周期ごとで分割する。短時間フーリエ変換(STFT: Short-Time Fourier Transform)^[5]によってスペクトログラムを生成、スペクトログラムに HPSS^[4]、逆短時間フーリエ変換^[5]を行い 2 種類の呼吸音データが得る。本論文では、時間長

N 256, フレームシフト S なし、2 種類のフィルタ長はともに 31, ウィナーフィルタのパワー 2.0 とする。

2.2 信号変換

元の呼吸音データを含む 3 種類の呼吸音データに対して、フレーム処理、窓関数処理、LPC^[6]を行い、伝達関数 $H(z)$ からゲインを得る。ゲインをパワースペクトルとして、2 次元平面(時間 - 周波数)上で表現する。本論文では、窓関数をハミング窓、予測次数 24, ゲイン 513, 画像サイズ 224×224 (pixels)として画像を生成する(図 1)。

2.3 CNN と機械学習による分類

浅谷らの提案モデル^[7]を改良した CNN モデルを採用する(図 2)。各畳み込み層の活性化関数を ReLU 関数、各出力結果に Batch Normalization(BN)を行う。時間軸方向と周波数方向の情報を保つため、カーネルサイズを縦長(A)、横長(B)とし、出力結果を Concatenate する。3 種類の画像に対して行い、出力結果




図 1 LPC による画像

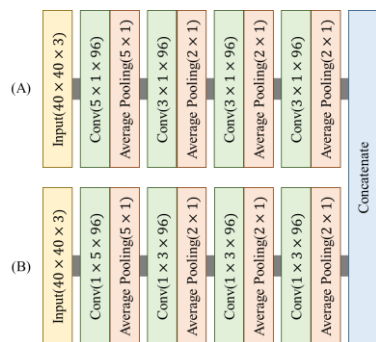


図2 提案モデルの構成

を Concatenate, Global Average Pooling(GAP)し, 分類器へ入力する. 分類器は LightGBM を用いる.

3. 実験と結果

ICBHI 2017 Challenge で使用されたデータセットを使用する. 5 分割交差検証を行い, 4 クラス分類における Sensitivity(SE), Specificity(SP), Accuracy, 偽陰性率(FNR), および 2 クラス分類における AUC(Area Under the Curve)より評価する^[8](表 1). HPSS で生成するスペクトログラムを入力とする手法と, 分類器に SVM(Support Vector Machine)を用いた手法と, CNN 最終層に softmax 層を用いた手法と比較する.

4. 考察

本論文では, 呼吸音データに HPSS を用いて, 強調分離し, 分類前を含む 3 種類の呼吸音データに, LPC を用いて画像生成, CNN を用いて特徴抽出, LightGBM を用いて自動分類した. RNN を用いた手法を除く SP, AS, Accuracy, AUC において提案手法が最も高い結果を示す.

LPC によって, 異常呼吸音特徴に似た形として出現されたノイズが抑制され, 正常呼吸音の精度が向上した. 異常呼吸音特徴も抑制されたことによる誤分類例や, 話し声など強く出現するノイズが, 除去されなかったことによる誤分類例がある.

提案 CNN モデルは VGG16^[4]の結果を比較すると, 特徴の維持しながら畳み込むことができた考える.

分類器においては, 分類する際に大きな役割を持つ情報を優

先して決定木として生成しているため, 高い精度が得られたと考える. しかし, 各ラベルのデータ数には偏りがあり, 一番多い Normal は高い精度を得たが, 他のラベルは誤分類が多い.

異常呼吸音特徴を維持するため, 画像生成方法の改良, データ数の偏りによる, 各ラベル間の分類精度差を軽減, 特徴抽出に RNN の導入により, さらなる精度向上を図る必要がある.

4. 結論

本論文では, 呼吸音を 4 クラスに自動分類するための CAD システムの開発を行った. SE58.8%, SP87.0%, AS72.9%, HS70.2%, Accuracy73.7%, AUC86.8%, 偽陰性率 29.4%を得た. 今後さらなる分類性能の向上のため, 画像生成方法の改良, データセットの偏りの改善, RNN の導入が必要となる.

謝辞

本研究は, ICBHI 2017 Challenge Dataset (https://bhichallenge.med.auth.gr/ICBHI_2017_Challenge) を使用している. 文部科学省科学研究費補助金(21H03840)の補助を受けている.

利益相反の有無

なし

文献

- [1] World Health Organization the Top 10 Causes of Death, <https://www.who.int/en/news-room/fact-sheets/detail/the-top-10-causes-of-death>
- [2] K.Do, "Computer-Aided Diagnosis in Medical Imaging: Historical Review, Current Status and Future Potential", Computerized Medical Imaging and Graphics, Vol.31, No.4-5, pp.198-211, 2007.
- [3] H. Mukherjee et al., "Automatic Lung Health Screening Using Respiratory Sounds", Journal of Medical Systems, Vol.45, No.19, 2021.
- [4] 丸橋他, "HPSS を用いた呼吸音の自動分類", 医用画像情報学会雑誌, Vol.38, No.2, pp.95-100, 2021.
- [5] 小野, "短時間フーリエ変換の基礎と応用", 日本音響学会誌, Vol.72, No.12, pp.764-769, 2016.
- [6] H.Mukherjee et al., "MISNA : A Musical Instrument Segregation System from Noisy Audio with LPCC-S Features and Extreme Learning", Multimedia Tools and Applications, Vol.77, pp.27997-28022, 2018.
- [7] N.Asatani et al., "Classification of Respiratory Sounds Using Improved Convolutional Recurrent Neural Network", Computers and Electrical Engineering, Vol.94, No.107367,pp.1-10, 2021.
- [8] B. M. Rocha et al., "An Open Access Dataset for the Evaluation of Respiratory Sound Classification Algorithms", Physiological Measurement, Vol. 40, No.3, 2019.

表 1 精度評価

	SE[%]	SP[%]	AS[%]	HS[%]	Accuracy[%]	AUC[%]	FNR[%]
HPSS(LPC)+proposed CNN&LightGBM	58.8	87.0	72.9	70.2	73.7	86.8	29.4
HPSS(LPC)+proposed CNN&SVM	59.8	81.9	70.8	69.1	71.5	85.0	27.6
HPSS(LPC)+proposed CNN&softmax	63.5	81.2	72.4	71.2	72.8	86.2	22.6
HPSS(STFT)+proposed CNN&LightGBM	53.0	85.6	69.3	65.5	70.2	83.9	35.0
HPSS(STFT)+proposed CNN&SVM	54.2	81.7	67.9	65.1	68.7	82.7	31.8
HPSS(STFT)+proposed CNN&softmax	53.7	83.0	68.3	65.0	69.2	83.5	31.5
HPSS(STFT)+VGG16&SVM ^[4]	51.3	82.5	66.9	63.3	67.9	-	34.6
STFT+CRNN ^[7]	63	83	73	72	-	-	-

悪性・良性腎腫瘍鑑別のための多時相造影 CT 画像データベース作成

西岡 大^{*1}, 西平 健斗^{*1}, 鈴木 秀宣^{*2}, 松廣 幹雄^{*3}, 河田 佳樹^{*2}, 小針 悠希^{*4}
池田 篤史^{*5}, 仁木 登^{*6}

^{*1} 徳島大学大学院創成科学研究科理工学専攻

^{*2} 徳島大学ポスト LED フォトニクス研究所

^{*3} 鈴鹿医療科学大学放射線技術科学科

^{*4} 東京女子医科大学病院

^{*5} 筑波大学附属病院

^{*6} 徳島大学発ベンチャー企業医用科学研究所

Creation of a database of multi-temporal contrast-enhanced CT images for differentiation of malignant and benign renal tumors

Dai NISHIOKA^{*1}, Kento NISHIHARA^{*1}, Hidenobu SUZUKI^{*2}, Mikio MATSUHIRO^{*3}

Yoshiki KAWATA^{*2}, Yuki KOBARI^{*4}, Atsushi IKEDA^{*5}, Noboru NIKI^{*6}

^{*1} Program of Science and Technology, Graduate School of Creative Science, Tokushima University

^{*2} Institute of Post-LED Photonics, Tokushima University

^{*3} Department of Radiation Technology Science, Suzuka University of Medical Science

^{*4} Tokyo Women's Medical University Hospital

^{*5} University of Tsukuba Hospital

^{*6} The University of Tokushima Venture Company, Institute of Medical Science

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する。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, 性別, 年齢, 腎腫瘍の体積・形, 種類, 非造影・動脈相・門脈相・平衡相画像を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

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(4cm 以下)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 の撮影条件, 手法

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 41 症例からマニュアル抽出で腎臓, 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を 2D U-Net を用いて学習データを作成(3) 学習データ作成過程を損失関数, Dice 係数から確かめる。

(1) 淡明細胞型腎細胞がん症例 10 症例, 乳頭状腎細胞がん症例 10 症例, 嫌色素性腎細胞がん症例 8 症例, 血管筋

脂肪腫症例 6 症例, オンコサイトーマ症例 7 症例からマニュアル抽出を, 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動脈相の造影 CT 画像を教師データ 25 症例, 検証データ 5 症例, 学習回数を 70 回行って作成した.
- (3) 損失関数は正解値とモデルにより出力された予測値のずれの大きさを計算する関数である. 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.

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. トレーニングを行う際に損失関数及び Dice 係数を計測しグラフに表した. 学習データのトレーニングの(a)損失関数, (b)Dice 係数のグラフを図 2 に示す.




図 2 トレーニングの結果

作成した学習データを用いてテストデータ 1 症例の腎臓・腎腫瘍の自動抽出を行った. 図 3 に抽出結果を示す.




図 3 2D U-Net を用いた腎臓・腎腫瘍の自動抽出結果

自動抽出した腎臓・腎腫瘍のスライス画像と, その画像に対応するマニュアル抽出した腎臓・腎腫瘍のスライス画像を, Dice 係数を用いて比較した. Dice 係数の平均値と標準偏差を下の表に示す.

表 Dice 係数の平均値と標準偏差

平均値	0.911
標準偏差	0.025

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・腎腫瘍の自動抽出を行い, 今回作成した学習データの抽出精度が高いことを確認した. しかし抽出した腎臓・腎腫瘍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

文献

- [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, 増訂第 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.マティニーニ, 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, Michelle S. Ginsberg: Intra- and Interobserver Variability in CT Measurements in Oncology, Radiology 2007, Volume: 242 Issue: 3pp. 769-776
- [8] Olaf Ronneberger: U-Net: Convolutional Networks for Biomedical Image Segmentation, MICCA2015
- [9] 西平 健斗ほか: 3 時相腹部造影 CT 画像を用いた腎癌解析, 信学技報, vol. 121, no.98, MI2021-13, pp. 20-22, 2021 年 7 月
- [10] Kento NISHIHARA et al: Renal tumor analysis using multi-phase abdominal CT images, Proc. SPIE 12033, SPIE Medical Imaging 2022, Computer-Aided Diagnosis, 120330Q, 4 April 2022

3次元CT画像によるじん肺の重症度別粒状影解析

橋本 悠雅^{*1}, 松廣 幹雄^{*2}, 鈴木 秀宣^{*3}, 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

Yuga HASHIMOTO^{*1}, Mikio MATSUHIRO^{*2}, Hidenobu SUZUKI^{*1}, Yoshiki KAWATA^{*1}

Yoshinori OHTSUKA^{*3}, Takumi KISHIMOTO^{*4}, Kazuto ASHIZAWA^{*5}, Noboru NIKI^{*6}

^{*1} Tokushima University, ^{*2} Suzuka University of Medical Science, ^{*3} Hokkaido Chuo Rosai Hospital

^{*4} Okayama Rosai Hospital, ^{*5} Nagasaki University, ^{*6} 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。我国において毎年 24 万人前後の粉じん労働者がじん肺健康診断を受診している。じん肺の診断では単純 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、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。

キーワード: CT, CAD, 医用画像処理

1. はじめに

じん肺は、粉じんを肺に吸入することによって生じる職業性呼吸器疾患である。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. 撮影条件と手法

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。^{[5][6]} 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。^[7] 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、重症度ごとの肺葉別粒状影数と分布の割合によって評価する。ボンフェローニ補正 t 検定を用いて、粒状影数、分布の割合に有意差があるか調べ、重症度と肺葉別粒状影数や割合に関係性があるか確認した。

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 重症度と肺葉別の粒状影数

図 2 に重症度ごとに 1cm³あたりの肺葉別平均粒状影数を示しており、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。全肺葉で重症度が高いほど粒状影数が多くなり、特に上葉で顕著である。




図 2 重症度と肺葉別の粒状影数

図 3 に全肺野と肺葉別の 1cm³あたりの粒状影数の比を示しており、右上葉が 1 を大きく上回っていることが分かる。また、中葉と両下葉は似た値になった。このことから、右上葉の粒状影が多いことや重症度間で各肺葉の粒状影数の割合に

変化はなく、粒状影は一樣に増えていることが分かる。




図 3 重症度と肺葉別の粒状影数の割合

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樣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

文献

- [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-Assisted Intervention—MICCAI 2016; 424-432.

Faster-R-CNN を用いた胸部 X 線像における肺結節の検出

韓 磊^{*1}, 平野 靖^{*2}

^{*1} 山口大学大学院創成科学研究科

^{*2} 山口大学医学部附属病院

Detection of pulmonary nodules on chest X-ray images using Faster-R-CNN

Lei HAN^{*1}, Yasushi HIRANO^{*2}

^{*1} Graduate School of Sciences and Technology for Innovation, Yamaguchi University

^{*2} Yamaguchi University Hospital

要旨：肺結節の検出に対する深層畳み込みニューラルネットワークモデルの有効性を向上させるために、3 段階の転移学習手法を提案した。事前学習に大量の自然画像や X 線画像を用いることで、少ないデータ量での学習性能を向上させることができた。さらに、モデル性能の向上を目的として、Attention 機構を導入された肺結節検出アルゴリズムを提案した。空間方向とチャンネル方向という 2 つの異なる種類の Attention 機構によって、特徴抽出ネットワークが生成する特徴マップの品質を向上させた。日本放射線技術学会(JSRT)データベースを用いて大量な実験を行い、モデルの有効性を検証した。

キーワード：肺結節, X 線像, Attention 機構, 物体検出

1. はじめに

日本において、肺がんは悪性腫瘍の中で死亡率が第 1 位となっている[1]。肺がんは早期発見により、早期に治療が開始できれば生存率の上昇が期待される。そのため、集団検診においては胸部 X 線検査によるスクリーニングが行われ、悪性の可能性がある肺結節が発見されれば、CT 画像などによる精密検査が行われる。一方、集団検診で撮影される胸部 X 線像の数は膨大であり、読影医の負担が大きい。また、肺結節は様々な濃度や形状を持つうえ、肋骨や心臓などと重なって撮影された場合には発見が難しい。そこで本研究では、医師の負担の軽減と肺結節の見落としの削減を目的として、Attention 機構を導入した Faster-R-CNN を用いて肺結節の検出手法の構築を行い、日本放射線技術学会(JSRT)データベースを用いて提案手法の学習と評価を行った。その結果、提案手法が肺結節の検出精度を向上させ、誤検出率を低減できることを示した。

2. 提案手法

本研究では肺結節を検出する手法の開発を行った。提案方法は、事前学習とネットワーク構造の設計に分けられる。

1) 事前学習

本研究で使用した JSRT データベースでは、学習に使用可能な医用画像の数が少ないため、モデルを十分に学習させることが困難である。このようにデータ数が少ない場合は、転移学習と呼ばれる手法が併用されることが多い。転移学習では、あるドメイン(一般的には自然画像)での学習結果を別のドメインでの学習に適用させる技術である。しかし、X 線画像は自然画像との類似度が低く[2]、JSRT データベース中の X 線画像の数も 100 枚と少ないため、従来の転移学習を利用しても結果は良

くなかった。そこで、本研究では三段階の転移学習を考案した。具体的には、一段階目は PASCAL VOC2007, および 2012 データセットの自然画像を用い、基本的な画像特徴を学習させ、パラメータの初期化を行った。二段階目に、肺結節を含まない X 線画像を用い、X 線画像の画像特徴を学習させた。それによって、三段階目では肺結節のある X 線画像のみで、肺結節を高精度に検出できるように学習ができた。

2) ネットワークの構造

物体検出のアルゴリズムである Faster RCNN[3]をメインフレームワークとして用い、より細かい特徴の抽出のため、特徴抽出ネットワークとして ResNet50[4]を用いた。そして、抽出された特徴マップに Attention 機構処理を加えた。詳細を図 1 に示す。

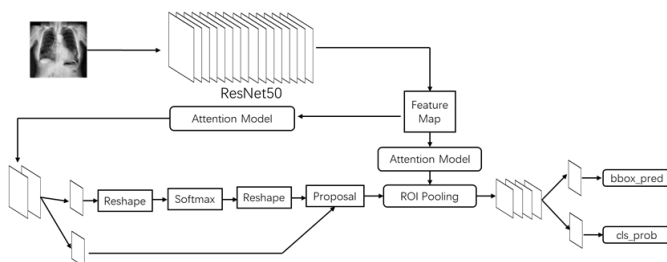


図 1 使用したネットワークの構造

入力画像は ResNet50 の入力層に合わせるために $600 \times 600 \times 3$ に調整した。特徴抽出ネットワークの計算後、 $38 \times 38 \times 1024$ の feature map が得られる。注目領域への集中、検出精度の向上、および誤報率の低減を可能にするため、feature map を Region Proposal Network(RPN)に入力する前に Attention 機構演算を加え、関連性の高い特徴点にはより大きな重みを持たせた

[5]. 本研究は, Woo が提案した CBAM[6]を用いて, チャンネル方向と空間方向の Attention 強化を行う. チャンネル方向と空間方向の Attention をそれぞれ式(1)(2)で示す. ここで, σ は sigmoid 関数, F は feature map, MLP は多層パーセプトロン, $f^{7 \times 7}$ は 7×7 の畳み込み層を表す. また, 式(2)の ; は, AvgPool と MaxPool の結果を結合させ 2 チャンネルの feature map にすることを表す.

$$M_c = \sigma \left(MLP(AvgPool(F)) + MLP(MaxPool(F)) \right) \quad (1)$$

$$M_s = \sigma \left(f^{7 \times 7}(AvgPool(M_c)); (MaxPool(M_c)) \right) \quad (2)$$

RPN では, 候補領域とラベルの IoU が 0.5 より大きい場合, 候補領域は結節と分類される. 候補領域の分類損失関数を, 式(3)で示す. ここで, p は正解ラベル (背景は 0, 結節は 1), \hat{p} は候補領域が結節である確率を表す.

$$L_{cls} = p \log(\hat{p}) + (1 - p) \log(1 - \hat{p}) \quad (3)$$

この後, feature map から, 結節と判定された候補領域を適切に「固定サイズの feature map」として抽出する. 最後に, 分類層と帰層を通して, 分類結果と領域座標を得る.

3. 実験結果

1) 使用したデータセット

本研究では, JSRT のデータセット[7]を使用した. このデータセットには, 放射線科医が注釈をつけた合計 150 枚の胸部 X 線写真が含まれており, 肺結節の位置と直径の大きさに関する情報が記録されている. また, 胸部 X 線写真は, 医師による検出のしやすさに応じて 5 つのレベルに分類されている.

また, 事前学習の第二段階には, kaggle で公開されているデータセット[8]を使った. このデータセットには 1500 枚の胸部 X 線写真が含まれている.

2) パラメータ設定

学習では確率的勾配降下法 (Adam) を使用した. バッチサイズを 4 とした. 初期の学習率は 0.0001 であり, 各 Epoch の後に学習率は 0.96 倍ずつ減衰する. モデルが結節であると判断する閾値を 0.5 とした. モデルの学習には 5-分割交差検証を用い, 各段階で 140 epoch の学習を行った. 5-分割交差検証は, JSRT のデータセット中の胸部 X 線写真を 5 分割して, そのうち 3 つをトレーニングセット, 1 つを検証セット, 残りの 1 つをテストセットとして, 学習を 5 回繰り返し, すべての結果を平均化することで, モデルを評価した.

3) 実験指標と結果

肺結節の検出精度について, 真陽性率(True Positive Rate: TPR)と 1 症例あたりの偽陽性陰影数(False Positive per Image: FPI)より評価を行った. ここで, True Positive (TP) とは, 正解領域の中心座標が検出領域に含まれている症例数である. また, False Positive (FP) とは, 正解領域の中心座標が検出領域に含ま

れていない検出領域の数である. 表 1 に難易度別の識別結果を示す.

表 1 検出が非常に困難・極めて困難識別結果

subset	検出容易・比較的容易・困難		検出非常に困難・極めて困難	
	TPR[%]	FPI[個/症例]	TPR[%]	FPI[個/症例]
1	87.50	0.88	65.00	0.75
2	90.00	0.80	35.00	0.85
3	80.00	0.85	35.00	0.93
4	82.50	0.75	55.00	0.95
5	80.00	0.73	30.00	0.35
平均	84.00	0.80	44.00	0.77

平均 TPR は難易度別でそれぞれ 84.00%, 44.00%となった. また, 平均 FPI はそれぞれ 0.80[個/症例], 0.77[個/症例]となった.

4. まとめ

本研究では, Attention 機構を用いた肺結節検出方法を提案し, JSRT データセットでその有効性を検証した. 5-分割交差検証の結果, 検出容易・比較的容易・困難とされた症例では TPR は 84.00[%], FPI は 0.80[個/症例]となった. 一方, 検出が非常に困難・極めて困難とされた症例では, それぞれ 44.00[%]および 0.77[個/症例]となった. TPR は, オリジナルの Faster-R-CNN よりそれぞれ 2.6%, 4.4%向上した. 今後の課題として, マルチスケール処理の導入による肺結節の検出精度向上が挙げられる.

利益相反の有無

なし.

文献

- [1] https://ganjoho.jp/reg_stat/statistics/data/dl/index.html (2022年5月2日閲覧)
- [2] Wang B, Zhao Hai, Zhu H, et al: Pulmonary nodules detection based on 3D features from CT images. Journal of Northeastern University Natural Science 39:181-185, 2018
- [3] Ren S, He K, Girshick R et al: Faster r-cnn: Towards real-time object detection with region proposal networks. Advances in Neural Information Processing Systems: 91-99, 2015
- [4] He K, Zhang X, Ren S et al. Deep Residual Learning for Image Recognition. Proc. of Computer Vision and Pattern Recognition (CVPR): 770-778, 2016
- [5] Li W, Wang P, Qiao H. A survey of visual attention based methods for object tracking. Acta Automatica Sinica 40: 561-576, 2014
- [6] Woo S, Park J, Lee J et al. CBAM:Convolutional Block Attention Module. Proc. of European Conf. on Computer Vision (ECCV): 3-7, 2018
- [7] <http://imgcom.jsrt.or.jp/download/> (2022年5月2日閲覧)
- [8] <https://www.kaggle.com/datasets/zhangjin4415/chestxray-nodule-detection> (2022年5月2日閲覧)

Supervised Contrastive Learning を用いた胸部 CT 画像における びまん性肺疾患の陰影識別

森崎 幹也^{*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

Opacity Classification of Diffuse Lung Diseases in Chest CT Images Using Supervised Contrastive Learning

Mikiya MORISAKI^{*1}, Shingo MABU^{*1}, Shoji KIDO^{*2}

^{*1} Yamaguchi University

^{*2} Osaka University

要旨: 識別問題では, Cross-Entropy Loss を用いることで, 特徴量空間において特徴量を分離できる. 一方 Contrastive Learning では, 同じクラスに属するデータの特徴量は近く, 異なるクラスに属するデータの特徴量は遠くなるように学習を行うことで, 識別性の高い, 所属するクラスに本質的な特徴量の抽出が可能となる. 本研究では, 教師あり学習の枠組みの中で, ラベル情報を利用してより適切な特徴の埋め込みを行う Supervised Contrastive Learning(SCL)に着目し, 胸部 CT 画像の陰影識別タスクに適用した. 2つの異なるドメイン (大阪大学病院症例, 山口大学病院症例) 各々への適応, およびドメインを超えた適応の観点から行った 4つの検証パターン全てにおいて SCLによる Accuracyの向上が確認できた. また, t-SNE を用いた特徴量の可視化により, クラス毎のより明確なグループの形成を確認した.

キーワード: 深層学習, 対照学習, 胸部 CT, びまん性肺疾患, 識別

1. はじめに

機械学習におけるマルチクラス識別モデルで用いられる代表的な Loss 関数として, Cross-Entropy Loss(CE Loss)が挙げられる. CE Loss を用いることで, 特に深層学習では, 特徴量空間において, 識別可能な特徴量と識別境界を得ることができる. しかし, その特徴量空間におけるデータの分布は考慮されない. ゆえに, 同クラス内のデータであっても特徴量に大きな差が生じたり, 異なるクラスのデータ同士が近い特徴量に埋め込まれたりする可能性が高くなる.

この問題を解消する手法として, Contrastive Learning(CL)と呼ばれる, データ間の距離を元に Loss の計算を行う手法がある [1]. CL では, 同じクラスに属するデータの特徴量は近く, 異なるクラスに属するデータの特徴量は遠くなるように学習を行うことができる. これにより, 識別性の高い, 所属するクラスに本質的な特徴量の抽出が可能となる.

本論文では, 胸部 CT 画像の陰影識別タスクに対して Supervised Contrastive Learning (SCL) [2] を適用し, 陰影の識別性能が向上することを明らかにする.

2. 手法

2.1 胸部 CT 画像への SCL の適用

SCL モデルのネットワーク構成を図 1 に示す. 大きく分けて, Encoder 部(ResNet50), Projector 部(2層の全結合層), Classifier 部(3層の全結合層)からなる. SCL では, Encoder と Projector からなるネットワークを Supervised Contrastive Loss(SupCon Loss)

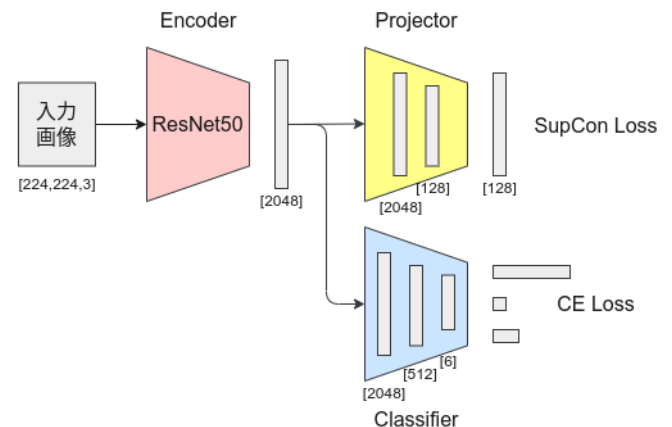


図 1 SCL のネットワーク構成

を用いて学習し識別性の高い 2048 次元の特徴ベクトルを抽出した後, 得られた特徴ベクトルを Classifier により識させる.

Encoder と Classifier を用い, その全体をはじめから学習させる, いわゆる通常の CNN モデルとの性能比較を行い, 胸部 CT 画像の陰影識別タスクにおける SCL の有用性を検証する.

2.2 マルチチャンネル化

文献 [3, 4] において有用性が報告されている入力画像のマルチチャンネル化を本研究でも適用する. $\gamma=0.5$ および $\gamma=2.0$ としてガンマ変換を行った 2 枚の画像を元画像に重ね合わせ, 3 チャンネル化した画像をモデルへの入力とすることで, SCL においても性能向上が見られるかを検証する.

表 1 実験結果一覧 (Accuracy の 5 回平均および標準偏差)

		山大基本検証	阪大基本検証	山大応用検証	阪大応用検証
CNN	加工なし	0.59±0.22	0.69±0.15	0.48±0.10	0.44±0.17
	ガンマ変換	0.67±0.12	0.77±0.09	0.44±0.07	0.50±0.09
SCL	加工なし	0.74±0.05	0.87±0.05	0.56±0.07	0.62±0.03
	ガンマ変換	0.72±0.02	0.89±0.03	0.49±0.08	0.62±0.02

3. 実験

3.1 実験概要

山口大学医学部附属病院で撮影された胸部 CT 画像（山大データ）と大阪大学医学部附属病院で撮影された胸部 CT 画像（阪大データ）を用い、以下の条件で検証を行う。

- ・ 山大データ 8 割で学習 → 山大データ残りの 2 割でテスト（山大基本検証）
- ・ 阪大データ 8 割で学習 → 阪大データ残りの 2 割でテスト（阪大基本検証）
- ・ 山大データで学習 → 阪大データでテスト（山大応用検証）
- ・ 阪大データで学習 → 山大データでテスト（阪大応用検証）

3.2 実験結果

「胸部 CT 画像への SCL の適用」の結果を表 1 の「加工なし」の行に示す。全ての検証パターンにおいて、SCL の方が高い性能を示した。また、山大データで学習させたモデルに阪大データを入力した時の、Encoder の出力である 2048 次元の特徴ベクトルを t-SNE により可視化した結果を図 2 に示す。図 2 より、CNN では各クラスの陰影が広範囲に分布し混在しているのに対し、SCL では各クラスの陰影がそれぞれ密集しており、またクラスごとに分離している。ゆえに、SCL は胸部 CT 画像の陰影識別タスクに対し有用であると言える。

「マルチチャネル化」の結果を表 1 の「ガンマ変換」の行に示す。加工なしの場合と比較すると、CNN では山大応用検証を除いて性能の向上が見られたが、SCL では性能の向上が見られなかった。このことから、SCL は人間による特徴抽出のサポートなしに潜在空間における特徴量の明確な分離が可能であると考えられる。

4. まとめと今後の課題

胸部 CT 画像の陰影識別タスクへの SCL の適用により、識別性能の向上と、人間による特徴抽出のサポートなしに潜在空間における特徴量の明確な分離が可能であることから、有用性が高い学習方式であることを明らかにした。

今後の課題として、学習とテストに異なるドメインのデータ

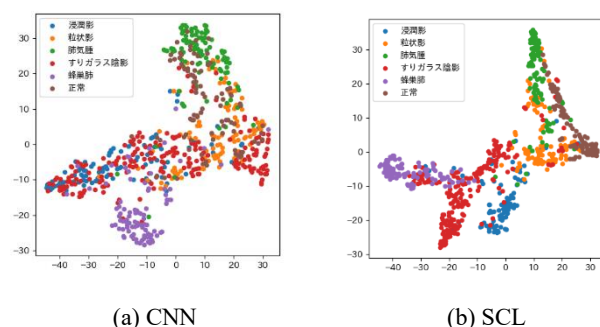


図 2 t-SNE による特徴ベクトルの可視化

を用いる山大応用検証や阪大応用検証では性能の低下が見られたことから、より本質的な特徴量の獲得により第 3 のドメインのデータに対しても有用なモデルとする必要がある。

謝辞

本研究は JSPS 科研費 JP19K12120, 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] Raia Hadsell, Sumit Chopra and Yann LeCun: Dimensionality Reduction by Learning an Invariant Mapping. In: 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Vol. 2, 2006, pp1735-1742
- [2] Prannay Khosla, Piotr Teterwak, Chen Wang et al: Supervised Contrastive Learning. In: H. Larochelle, M. Ranzato, R. Hadsell, M. F. Balcan and H. Lin eds. Advances in Neural Information Processing Systems Vol. 33, 2020, pp18661-18673
- [3] Shingo Mabu, Shoji Kido, Noriaki Hashimoto et al: Opacity annotation of diffuse lung diseases using deep convolutional neural network with multi-channel information. In: Nicholas Petrick and Kensaku Mori eds. Medical Imaging 2018: Computer-Aided Diagnosis Vol. 10575, 2018, pp692-697
- [4] Shingo Mabu, Yoshiaki Nakayama, and Takashi Kuremoto: Landslide Classification from Synthetic Aperture Radar Images Using Convolutional Neural Network with Multichannel Information. Journal of Signal Processing 24: 61-73, 2020

Contrastive Learning による次元削減による胸部 CT 画像に対する異常検知

飛世 裕貴^{*1}, クグレマウリシオ^{*1}, 横田 達也^{*1}, 橋本 正弘^{*2},

大竹 義人^{*3}, 明石 敏昭^{*4}, 清水 昭伸^{*5}, 本谷 秀堅^{*1}

^{*1} 名古屋工業大学 〒466-8555 名古屋市昭和区御器所町

^{*2} 慶應義塾大学 ^{*3} 奈良先端科学技術大学院大学 ^{*4} 順天堂大学 ^{*5} 東京農工大学

Anomaly Detection for Chest CT Images by Dimensionality Reduction

Based on Contrastive Learning

Hiroki TOBISE^{*1}, Kugler MAURICIO^{*1}, Tatsuya YOKOTA^{*1}, Masahiro HASHIMOTO^{*2},

Yoshito Otake^{*3}, Toshiaki AKASHI^{*4}, Akinobu SHIMIZU^{*5}, Hidekata HONTANI^{*1}

^{*1} Nagoya Institute of Technology, ^{*2} Keio University, ^{*3} Nara Institute of Science and Technology,

^{*4} Juntendo University, ^{*5} Tokyo University of Agriculture and Technology

要旨 : Covid-19 の診断支援を目的として, 胸部 CT 画像中の異常部位検知手法を提案する. 正常・異常を分類する 2 クラス識別器を学習する際, 正常データと異常データの学習データ数に不均衡が存在すると識別器の学習が困難となることが知られている. 本研究では, 正常なパッチ画像の確率密度分布に基づく 1 クラス識別器の考え方を採用することにより, 学習データ数のクラス間の不均衡を緩和する. 確率密度分布はパッチ画像空間で直接求めるのではなく, 画像間の異同がユークリッド距離で表現されるような低次元空間で求める. そこで Contrastive Loss に基づく学習による次元圧縮法を採用する. Contrastive Loss は利用者が定める変換に対する不変性を獲得する上で有用であり, 提案法では並進や回転といった変換に対して不変な射影を学習する. 本稿では提案法による胸部 CT 画像中の異常部位の検出結果について報告する.

キーワード : 胸部 CT 画像, Covid-19, 異常検知, ニューラルネットワーク

1. はじめに

本項では Covid-19 の診断支援を目的として, 胸部 CT 画像中の異常部位検知を試みたので報告する. Covid-19 では通常の肺炎などと同様に肺野にすりガラス陰影を含む, 正常症例では観察されない異常パターンが観察される. そこで胸部 CT 画像を入力として各部位のパッチ画像に対して異常度を求める手法を提案する. 異常検知は 1 クラス行き別の考え方を採用している. Covid-19 は流行開始から時間経過が浅く, 正常症例や Covid-19 以外の肺炎などと比べて症例数が少ない. このため, 正常症例と Covid-19 や肺炎などを識別する多クラス識別器を構築するときには学習症例数の偏りが問題となる. しかし, 異常検知は正常症例の画像パターンを基準として構築できるため, クラスごとの学習データ数の偏りに影響されることがない.

2. 提案法

正常症例中のパッチ画像 \mathbf{x} の確率密度分布を $P(\mathbf{x})$ と表す時, 異常度は負の対数尤度 $-\log P(\mathbf{x})$ で評価することが一般的である. しかし, 確率密度分布 $P(\mathbf{x})$ の推定には多数の学習データが必要であり, また確率密度分布 $P(\mathbf{x})$ のみに基づいた異常検知は容易ではないことが知られている [1]. 容易ではないことの原因として, \mathbf{x} が高次元であり, 正常パッチ画像群が構成する多様体が複雑な構造を持っているため, \mathbf{x} の空間におけるユークリッド距離が必ずしも医学的な基準下でのパッチ画像間の異

同を反映しないことが挙げられる. そこで提案法では, パッチ画像 \mathbf{x} をユークリッド距離が医学的な基準下でのパッチ画像間の異同に対応するような低次元空間に射影し, 射影先の低次元空間 \mathbf{y} における確率密度分布 $P(\mathbf{y})$ に基づき異常度 $-\log P(\mathbf{y})$ を評価する. 確率密度分布 $P(\mathbf{y})$ の推定には Normalizing flow [2] を用い, 低次元空間への射影の学習には Contrastive Loss [3] を用いる. Contrastive Loss に基づく自己教師あり学習は, 並進や回転など病態の変化とは無関係な画像変換に対して不変な射影を実現し, 射影先のユークリッド距離により異同の評価を可能とする上で有用である. Contrastive Loss は式(1),(2)で定義される.

$$L(\mathbf{x}_i, \mathbf{x}_j, \mathbf{y}, w) = \frac{1-y}{2} (D_w)^2 + \frac{y}{2} \{\max(0, m - D_w)\}^2 \quad (1)$$


$$D_w(\mathbf{x}_i, \mathbf{x}_j) = \|G_w(\mathbf{x}_i) - G_w(\mathbf{x}_j)\|^2 \quad (2)$$

$\mathbf{x}_i, \mathbf{x}_j$ はパッチ画像, G_w は w をパラメータとする射影関数, m は閾値パラメータ, $\mathbf{y} \in \{0, 1\}$ は各画像のペア $(\mathbf{x}_i, \mathbf{x}_j)$ が類似画像と見なせるかを表す. この Contrastive Loss の最小かによって最適化された射影関数 G_w は類似画像を近づけ, 非類似画像を遠くに射影する. 病態の変化に無関係な変換を加えた画像を類似画像, 意味のある変換を加えた画像を非類似画像として扱うことによって変換に対する感度を有する射影を実現することができる. 類似画像の生成については並進と回転, 肺野条件の変更を採用し, 非類似画像の生成については CutPaste を採用し

ている。ここで CutPaste はパッチ画像中からランダムな位置・大きさの領域を抽出し、別の位置へ貼り付ける変換で、局所的なテクスチャへの感度を高くすることが知られている [4]。射影関数の実現には ResNet [5] を採用している。正常症例中のパッチ画像のみで射影先を求めると異常パッチ画像が正常パッチ画像と異なる射影先となることが保証されない。そのため、病態の有無を問わずに全ての症例から抽出したパッチ画像に基づいて低次元射影を求める。そして求めた低次元射影を用いて、正常症例から抽出したパッチ画像のみを射影し、確率密度分布を推定する。

3. 実験結果

パッチ画像は連続する複数枚のスライスの肺野領域内の同一領域から抽出し、抽出したパッチ画像群を3次元パッチ画像として扱う。異常検知結果を図1に示す。ここでは肺野内部の各ピクセルを中心として $32 \times 32 \times 3$ のパッチ画像を抽出し、算出された異常度は各データの中心ピクセルの異常度として扱い、可視化を行っている。異常検知は Covid-19 の典型症例（経時データ）、Covid-19 の典型症例だが非特異的な症例、Covid-19 の非典型症例に対して行った。Covid-19 の典型症例ではすりガラス陰影を表す領域が抽出出来ている事がわかる。また時間経過によって、典型症例中の異常領域の範囲・異常度が変化している様子が観察できる。Covid-19 の非典型症例では浸潤影のような異常所見を表す領域が抽出出来ている。



謝辞

[本研究は日本医学放射線学会のナショナルデータベース J-

MID (臨床研究等 ICT 基盤構築・人工知能実装研究事業/画像診断ナショナルデータベース実現のための開発研究(AMEDの課題番号: JP201k1010025)) を利用しました。データベース構築に関わっていただいた先生方に感謝いたします。また、本研究の一部は、AMED の医療ビッグデータ利活用を促進するクラウド基盤・AI 画像解析に関する研究 (AMED の課題番号: JP201k1010036) の支援を受けました。

利益相反の有無

なし

文献

- [1] NALISNICK, Eric, et al. Do deep generative models know what they don't know?. arXiv preprint arXiv:1810.09136, 2018.
- [2] DINH, Laurent; SOHL-DICKSTEIN, Jascha; BENGIO, Samy. Density estimation using real nvp. arXiv preprint arXiv:1605.08803, 2016.
- [3] HADSELL, Raia; CHOPRA, Sumit; LECUN, Yann. Dimensionality reduction by learning an invariant mapping. In: 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06). IEEE, 2006. p. 1735-1742.
- [4] LI, Chun-Liang, et al. CutPaste: Self-Supervised Learning for Anomaly Detection and Localization. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021. p. 9664-9674.
- [5] HE, Kaiming, et al. Deep residual learning for image recognition. In: Proceedings of the IEEE conference on computer vision and pattern recognition. 2016. p. 770-778.

アノテーションが不完全な教師データを用いた腹部超音波画像からの肝腫瘍検出

池田 裕亮^{*1}, 道満 恵介^{*1}, 目加田 慶人^{*1}, 西田 直生志^{*2}, 工藤 正俊^{*2}

^{*1} 中京大学 大学院工学研究科

^{*2} 近畿大学 医学部

Detection of Liver Tumors from Abdominal Ultrasound Images with Incompletely Annotated Training Data

Yusuke IKEDA^{*1}, Keisuke DOMAN^{*1}, Yoshito MEKADA^{*1},
Naoshi NISHIDA^{*2}, Masatoshi KUDO^{*2}

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

^{*2} Faculty of Medicine, Kindai University

要旨：腹部超音波検査の支援を目的として、機械学習を用いた超音波画像からの肝腫瘍検出に関する研究がおこなわれている。中島らの研究では YOLOv3 を用いて検出を行っていた。しかし、学習データには画像 1 枚に 1 つの腫瘍のアノテーションしか付与されていなかった。転移性肝がんは 1 枚の超音波画像に複数箇所写っている場合があり、アノテーションのない腫瘍は学習に悪影響を与えている。そのため、アノテーションの不完全性を考慮した肝腫瘍検出手法が必要であった。これに対して本研究では、YOLOv3 の損失関数に腫瘍の種類に応じた重みを加えることで、アノテーションがない腫瘍に対する検出および検出精度の改善を試みた。実験の結果、転移性肝がんに対する再現率の向上が確認された。また、適合率は低下したものの、転移性肝がんにおいてはアノテーションが入力されていない腫瘍部分を検出できていることが確認でき、提案手法の有効性が示唆された。

キーワード：超音波画像，肝腫瘍検出，深層学習

1. はじめに

超音波検査は超音波診断装置から超音波を生体に送信し、その反射波を受信して生体内軟部組織の断層像を得ることで臓器の構造や動きを評価する検査方法である [1]。モニタに映される断層像は CT 画像などと比べて描画される範囲が狭く、またプローブの操作をしながら画像の確認を行うため正確な検査には一定の技量が求められる。そのため超音波検査を支援するシステムの研究が行われている [2]。

機械学習を用いた腹部超音波検査支援の研究として、中島らの肝腫瘍検出の研究がある [3]。中島らの研究では、腹部超音波画像から深層学習手法の一つである YOLOv3 [4] を用いて肝腫瘍の検出を行っている。YOLOv3 の学習には国立研究開発法人日本医療研究機構 (AMED) から提供されたデータセットを使用している。このデータセットは匿名化 ID、超音波画像、診断名、腫瘍位置情報 (アノテーション)、患者情報の 5 つで構成されている。アノテーションは画像 1 枚につき 1 つ与えられているが実際に画像内に写っている腫瘍は 1 つとは限らない。特に転移性肝がんは他の腫瘍と比べて複数の腫瘍が一枚の画像に写っている場合がある。その場合、本来転移性肝がんである領域を腫瘍のない領域として学習してしまい腫瘍の検出に悪影響を与えている。医療分野のような専門的な知識が必要な分野において大量の画像に正確なアノテーションを与えることは困難である。そのためアノテーションの不完全性を考慮した腫瘍の検出手法が必要とされている。

そこで本研究では YOLOv3 の学習時、各腫瘍の種類に応じて損失に重みを加えることでアノテーションが不完全なデータからの肝腫瘍検出の精度が改善するかを検証する。

2. 提案手法

アノテーションのない腫瘍の検出と検出精度の改善または維持するため YOLOv3 の損失関数を変更する。1 枚に複数腫瘍が写っている割合は腫瘍の種類によって異なる。そのため YOLOv3 学習時の損失値に腫瘍の種類ごとの重みを加える。損失値を腫瘍ごとに操作することで、アノテーションのないものが多い腫瘍では小さい損失値で、他の腫瘍では従来通りの損失値を用いることで学習ができる。小さい損失値での学習は腫瘍を過検出しやすくなるが、その反面、アノテーションのない腫瘍も検出しやすくなる。YOLOv3 の損失関数は検出窓の大きさの項、クラスの項、オブジェクトが正解領域に存在する場合の項、オブジェクトが正解領域に存在しない場合の項の 4 つからなっている。アノテーションのない腫瘍を検出するためオブジェクトが正解領域にない場合の項に腫瘍ごとの重みを加える。

3. 実験

提案手法が実際に有効であるか調査した。提案手法の重みは転移性肝がんの場合 0.5、その他の腫瘍の場合 1.0 とした。学習データは従来研究と同じ AMED から提供されたデータを用いた。学習データの構成を表 1 に示す。従来手法では YOLOv3

の畳み込み層の重みの初期値に ImageNet [5] で学習した重みを使用した。提案手法も同様に同じ重みを初期値とした。学習回数は全結合層の重みのみの学習 100 回とすべての重みの学習 100 回の合計 200 回行った。YOLOv3 は検出した領域ごとに信頼度を出力する。その信頼度が 0.3 以上であるものを採用し、その検出領域と正解領域との IoU が 0.3 以上であったとき検出成功として適合率と再現率を計算した。IoU のしきい値はアノテーションが画像に写っている腫瘍よりも非常に大きく囲っているデータが多いため低く設定した。また、YOLOv3 の検出窓の統合のしきい値は 0.3 とした。アノテーションのない腫瘍に関しては目視で確認を行った。

4. 結果

検出結果を表 2 に示す。提案手法では転移性肝がんの損失の値を追加した重みによって小さくしているため転移性肝がんが過検出しやすくなっている。そのため転移性肝がんの再現率は従来手法よりも高くなり、適合率は低くなる傾向がある。実際に表 2 の転移性肝がんの数値は期待した通りの傾向を示している。転移性肝がんを除いた他の腫瘍では提案手法は従来手法と比べて 1~4%ほどの低下がみられる。これは腫瘍の種類ごとに重みを与えたとしても学習時のミニバッチごとに個々の損失の値の平均がモデルの更新に用いられるため、他の腫瘍の検出にも転移性肝がんの重みが影響した結果であると考えられる。検出した結果の例を図 1, 2 に示す。図 1 と図 2 は同じ画像に対して提案手法と従来手法で検出した結果である。赤枠が検出結果、水色が正解領域を示している。図 1 の正解領域の右にある検出窓の中には転移性肝がんと同じ特徴を持った領域があり、図 2 にはその領域を囲む検出窓がないため、アノテーションのない腫瘍が検出できている可能性が高い。今後、実際に検出した領域が腫瘍であるかの確認を医師の協力の下行う必要があるものの、アノテーションが不完全なデータに対する提案手法の有効性が示唆された。

5. まとめ

機械学習において、アノテーションが不足したデータを用いて教師あり学習をする場合に精度が低下することが知られている。本稿ではアノテーションの不完全性を考慮するため YOLOv3 の損失関数に腫瘍の種類ごとの重みを加える手法を提案した。転移性肝がんは他の腫瘍と比較して複数写っていることが多いため、損失関数において転移性肝がんの重みを他の腫瘍の半分に設定して学習を行った結果、アノテーションがされていない転移性肝がんが検出されていることを確認した。今後、検出領域が腫瘍であるかについて医師の確認が必要である。

表 1 学習データの構成

腫瘍	Train	Validation	Test
肝細胞がん	10,082	1,261	1,259
転移性肝がん	7,758	970	969
血管腫	22,678	2,835	2,834
嚢胞	23,068	2,884	2,882
その他	4,273	535	533
合計	67,859	8,485	8,477

表 2 検出結果

腫瘍	従来手法		提案手法	
	適合率	再現率	適合率	再現率
肝細胞がん	0.90	0.85	0.87	0.85
転移性肝がん	0.84	0.81	0.69	0.85
血管腫	0.91	0.90	0.90	0.87
嚢胞	0.92	0.90	0.90	0.87
その他	0.85	0.82	0.81	0.79
合計	0.90	0.88	0.86	0.86




図 1 提案手法の検出結果

図 2 従来手法の検出結果

謝辞

本研究は日本学術振興会研究費補助金と日本医療研究開発機構の援助によってなされた。

利益相反の有無

無し

文献

- [1] 森秀明, 平井都始子: レジデント・臨床検査技師のための初めての超音波検査第 2 版. 文光堂, 2019
- [2] Naoshi N, Makoto Y, Tsuyoshi S et al: Artificial intelligence (AI) models for the ultrasonographic diagnosis of liver tumors and comparison of diagnostic accuracies between AI and human experts. Journal of Gastroenterology, <https://doi.org/10.1007/s00535-022-01849-9>, 2022
- [3] Nakashima T, Tsutsumi I, Takami H et al: A Study on Liver Tumor Detection from an Ultrasound Image using Deep Learning. SPIE 11515, International Workshop on Advanced Image Technology 2020, 115151V, 2020, <https://doi.org/10.1117/12.2566913>
- [4] Redmon J and Farhadi A: YOLOv3: An Incremental Improvement. arXiv: 1804.02767, <https://doi.org/10.48550/arXiv.1804.02767>, 2018
- [5] Deng J, Dong W, Socher R et al: Imagenet: A large-scale hierarchical image database. 2009 IEEE Conference on Computer Vision and Pattern Recognition: pp.248-255, 2009

MR 深層学習再構成における MR 画像特徴を利用した学習時とテスト時のデータ拡張の有効性に関する検討

大内 翔平^{*1*2}, 伊藤 聡志^{*1}

^{*1} 宇都宮大学大学院 工学研究科 システム創成工学専攻

^{*2} 日本学術振興会特別研究員 DC

Study on the Effectiveness of Data Augmentation and Test Time Augmentation Using the Feature of MR Images in MR Deep Learning-based Image Reconstruction

Shohei OUCHI^{*1*2}, Satoshi ITO^{*1}

^{*1} Graduate School of Engineering Utsunomiya University

^{*2} JSPS Research Fellow

要旨 : CNN を用いた MR 画像の深層学習再構成法は数多く提案されているが, なかでも画像空間型学習の手法では, 既存の画像解析手法と CNN の併用法が注目されている. 我々は多重解像度解析手法の eFREBAS 変換と CNN を併用し, 異なる周波数成分から構成される複数枚の変換像を, グループごとに別個の CNN で学習する方法により, 高周波成分の復元性能の向上を図った. 本研究では eFREBAS 変換が複素変換である性質を利用した, さらなる画質改善法を提案する. 位相を有する複素画像の実部と虚部は, 一般に正と負の値をもつ. そこで, オリジナルの輝度を持つ画像と輝度反転画像を併用することで, 学習時には Data Augmentation を, テスト時には Test Time Augmentation を行ったときと同等の効果を得られる手法を導入した. 再構成シミュレーションの結果, 提案手法の導入により, 従来法よりもアーチファクトの除去性能が向上し, PSNR と SSIM を改善させることができた.

キーワード : 深層学習, 圧縮センシング再構成, eFREBAS 変換

1. はじめに

MRI(Magnetic Resonance Imaging)の撮像時間の短縮化法として圧縮センシング(Compressed Sensing : CS)[1][2]を応用する方法(CS-MRI)[3]が提案されている. 近年では CS の画像再構成に CNN(convolutional neural network)を導入した CNN-CS[4]の研究が活発であり, CS-MRI を上回る性能が報告されている. しかし, CNN-CS では MR 信号の間引きに起因する折り返しアーチファクトの除去性能や, 失われた被写体細部の情報の復元性能には依然として改善の余地がある. 我々は, これらの課題の解決を目的として eFREBAS-CNN を提案し, 昨年度の JAMIT 大会で報告した[5]. 本手法は, Image Domain Learning 型の CNN と多重解像度解析手法である eFREBAS 変換(enhanced Fresnel band-split transform)[6]を融合した手法であり, 図 1 のように eFREBAS 変換で展開された画像群を複数のマルチチャンネル型 CNN で再構成することで, 周波数帯域ごとに再構成を行う手法である. これまでの検討の結果, eFREBAS-CNN では比較を行った他手法と比べて, 被写体細部のコントラストの変化が微小な部分において高い復元性能を示したものの, 目標画像と比較すると鮮鋭さにおいては依然として課題が残る結果となった.

一般に MR 画像は位相を有する複素画像であり, 複素画像の実部と虚部は一般に正と負の値を持つ. 撮像時のエコー信号が現れる座標を $-x$ 軸にする, あるいは, 位相を反転させた場合には実部や虚部の輝度値を反転した MR 画像が

得られる. 本研究では, この点に着目し, オリジナルの輝度を持つ画像と, その輝度を反転した画像を併用することで, 学習時とテスト時にデータ拡張を行ったときと同等の効果を得られる手法を提案し, eFREBAS-CNN に導入して有効性を検討した.

2. eFREBAS-CNN

1) eFREBAS 変換

eFREBAS 変換は, 入力画像を任意数かつ任意のサイズの画像群 (サブ画像) に展開できる多重解像度解析手法である. 各

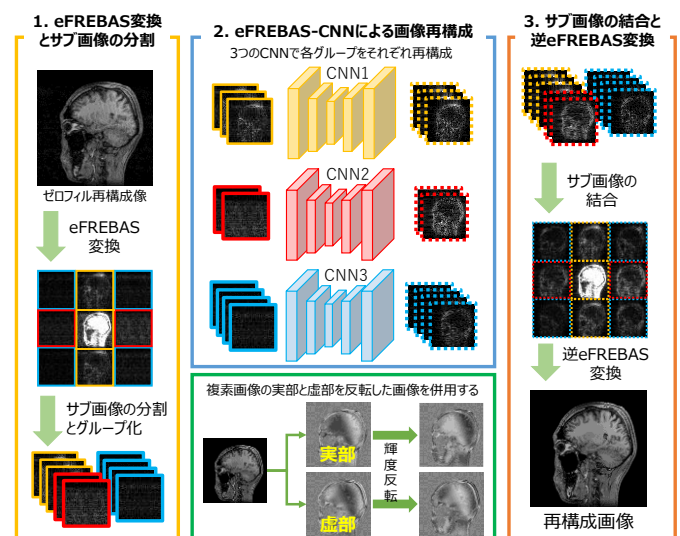


図 1. eFREBAS-CNN と輝度反転画像の概要図

サブ画像によってフィルタバンクが構成されており、展開像のサブ画像の位置と信号空間 (k-space) の領域には対応関係がある。本研究では、eFREBAS 変換の展開数を決定するパラメータを 3 に設定し、3² 枚のサブ画像を生成した。

2) eFREBAS-CNN

eFREBAS-CNN では、フルデータ像と間引きにより折り返しアーチファクトが発生したゼロフィル再構成像の eFREBAS 空間上での関係を CNN で学習する。各サブ画像は異なる周波数帯域を有するため、ゼロフィル再構成像のサブ画像には、被写体構造の消失やアーチファクトの重量に特徴の差が存在する。そこで、9 枚のサブ画像を構造の保存度合いに応じて 3 グループに分割し、それぞれを Lee ら提案の U-Net[7]を基本とする 3 つの CNN で再構成することで、情報の消失程度に応じた画像復元を行った。U-Net は、各グループのサブ画像の枚数に応じてマルチチャンネルの入出力を持つように改良している。

3) 輝度反転画像の併用

本研究では学習とテストの際に、図 1 のように複素 MR 画像の実部と虚部それぞれの輝度を反転した画像を生成して、オリジナルの輝度を持つ画像と併用する手法を導入した。これにより、学習時には画像枚数が倍増するため Data Augmentation と同等の効果を、テスト時にはオリジナルの輝度の再構成像と輝度を反転した再構成像の 2 枚から最終的な再構成像を生成できるため Test Time Augmentation と同等の効果が期待できる。

3. 画像再構成シミュレーション

1) 学習およびテスト画像

キャノンメディカルシステムズ社製の MRI で撮像された位相を含む複素 MR 画像を計 183 枚使用した。このうち、122 枚を学習用、61 枚をテスト用としている。

2) 学習条件

eFREBAS-CNN は、MATLAB と MatConvNet[8]を使用して 300 エポックの学習を行った。また、本研究では収集信号量が 20, 30, 40%となるパターンを用いて信号間引き処理を行った。

3) 再構成シミュレーション結果と考察

提案法による信号量 30%での再構成像を図 2 に、各信号量による再構成像の平均 PSNR を表 1 に示す。輝度反転画像の併用なしの eFREBAS-CNN では、小脳付近のコントラストの変化が微細な領域で靄状のアーチファクトの残存が見られたが、輝度反転画像の併用により、再構成像がより鮮鋭化した。これは、輝度反転画像の併用により学習枚数が増加したこと、輝度反転という新たな特徴が付加されたことで CNN が被写体構造を捕捉する能力が向上したことが要因と考える。以上より、輝度反転画像の併用は複素 MR 画像に固有かつ容易に導入可能な手法であり、その有効性が示された。




図 2. 信号量 30%による再構成像 (a)フルデータ像, (b)ゼロフィル再構成像, (c)eFREBAS-CNN 輝度反転併用なし, (d)eFREBAS-CNN 輝度反転併用あり

表 1. 各信号量による再構成像の平均 PSNR

PSNR[dB]	20%	30%	40%
輝度反転なし	27.63	29.78	31.09
輝度反転あり	28.11	30.36	31.48

3. まとめ

CNN-CS における、複素 MR 画像の特徴を利用した学習時とテスト時の新たなデータ拡張法の有効性を示した。今後は提案法に適した間引きパターンの検討などを行う予定である。

謝辞

本研究の一部は、科学研究費補助金(19K04423,21J14120)の助成により実施されました。また、本研究に使用した MR 画像をご提供いただいた、キャノンメディカルシステムズに感謝の意を表します。

利益相反の有無

なし

文献

- [1] Donoho DL, IEEE Transactions on Information Theory 52 : 1289-1306, 2006
- [2] Candès EJ, Wakin MB, IEEE Signal Processing Magazine 25 : 21-30, 2008
- [3] Lustig M, Donoho DL, Pauly JM, Magn Reson Med 58 : 1182-1195, 2007
- [4] Wang S, Su Z, Ying L, et al. : ISBI2016, Prague, Czech Republic 2016, 514-517
- [5] 大内 翔平, 伊藤 聡志, JAMIT2021, P4-16, 2021, 410-417
- [6] Ito S, Yamada Y, ICIP2003, Barcelona, Spain 2003, Map8.7.
- [7] Lee D, Yoo J, Tak S, et al., IEEE Transaction on Biomedical Engineering 65 : 1985-1995, 2018
- [8] Vedaldi A, Lenc K, Proceedings of the 23rd ACM international conference on Multimedia, Brisbane, Australia 2015, 689-692

WGIによる ^{89}Zr 撮像において909keVコンプトンイメージングがPETの空間分解能を超える可能性

田島 英朗^{*1}, 田久 創大^{*1}, 錦戸 文彦^{*1}, 菅 幹生^{*2},
赤松 剛^{*1}, 高橋 美和子^{*1}, 山谷 泰賀^{*1}

^{*1} 量子科学技術研究開発機構

^{*2} 千葉大学

Potential of 909 keV Compton imaging beyond PET spatial resolution for ^{89}Zr measurement with Whole Gamma Imaging

Hideaki TASHIMA^{*1}, Sodai TAKYU^{*1}, Fumihiko NISHIKIDO^{*1}, Mikio SUGA^{*2},

Go AKAMATSU^{*1}, Miwako TAKAHASHI^{*1}, Taiga YAMAYA^{*1}

^{*1} National Institutes for Quantum Science and Technology

^{*2} Chiba University

要旨：PETは陽電子飛程と角度揺動によって理論的に空間分解能が制限される。一方、コンプトンイメージングはそれらの制限を受けない。本研究では、WGI (Whole Gamma Imaging) によるコンプトンイメージングがPETの空間分解能を超えられる可能性を検証するためにモンテカルロシミュレーションを実施した。具体的には、PETリング (LGSO, 厚さ計20mm, 直径320mm, ピクセル $1.5 \times 1.5 \times 6.67\text{mm}^3$) に散乱検出器リング (Si, 厚さ計20mm, 直径86mm, ピクセル $0.25 \times 0.25 \times 0.5\text{mm}^3$, エネルギー分解能 $0.3\% @ 511\text{keV}$) が挿入されたWGIをGeant4でモデル化した。陽電子と909keVのシングルガンマ線を両方放出する ^{89}Zr を充填した分解能評価用ロッドファントムを、視野中心及び端に置いた場合それぞれの測定を模擬した。エネルギーウィンドウにより、PETイベント及び、909keVのコンプトンイベントを抽出し、それぞれリストモードOSEM法により画像再構成を行った。その結果、中心に置いた場合にはPETより1mmロッドの分解がやや不鮮明であったが、端に置いた場合にはPETより鮮明に分解することができた。WGIにおいてコンプトンイメージングがPETより高い空間分解能を得られる可能性が示された。

キーワード：コンプトンイメージング, PET, ^{89}Zr , 空間分解能

1. はじめに

WGI (Whole Gamma Imaging) は、Positron Emission Tomography (PET) のリング内に、散乱検出器リングを挿入し、PETとコンプトンイメージングを組み合わせることで、検出可能な全てのガンマ線をイメージングに利用する我々のコンセプトである [1]。我々はこれまでに、シンチレータ素材を用いて開発した試作機で ^{89}Zr 投与マウスを測定し、PETに迫る空間分解能が909 keVガンマ線のコンプトンイメージング (以下909keVコンプトン) によって得られることを示した [2]。本研究では、PETの空間分解能に陽電子飛程と角度揺動による理論的な限界 [3] がある一方で、コンプトンイメージングはこれらの影響を受けず、PETの空間分解能を超えられる可能性があることに着目した。コンプトンイメージングでは、各検出イベントの線源位置をコンプトンコーンと呼ばれる円錐面上に限定することができ、その頂点は散乱検出器での検出位置、中心軸は吸収検出器での検出器位置を通る直線、半頂角はエネルギー情報から求まる散乱角度となる。そして、コンプトンイメージングの空間分解能は、検出器サイズの他に、エネルギー分解能やドップラーブロードニングの影響を受け、円錐を決定する際の不確かさである角度分解能により決まる。今回、エネルギー分解能に優れ、ドップラーブロードニングの影響の少ないSiを散

乱検出器に用いたWGIにおいて、コンプトンイメージングがPETの空間分解能を超えられるかシミュレーションにより検討した。

2. 方法

Si散乱検出器リングとLGSOシンチレータの吸収検出器リングで構成したWGIをモンテカルロシミュレーションのツ

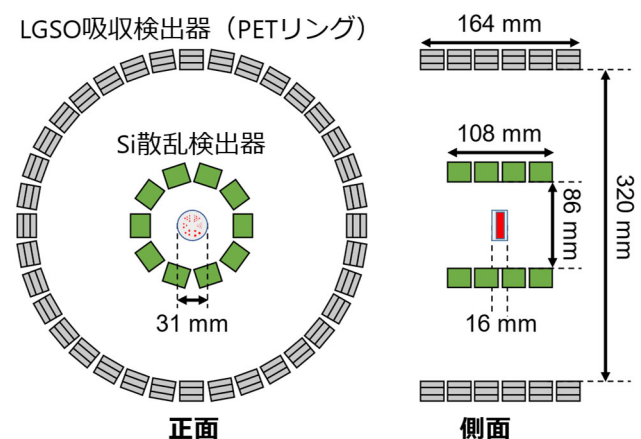


図1.モデル化したWGIのジオメトリ

ルキットである Geant4 によってモデル化した (図 1). ピクセルサイズは Si 散乱検出器が $0.25 \times 0.25 \times 0.5 \text{mm}^3$ (ピクセル数 $96 \times 96 \times 40$), LGSO 吸収検出器が $1.5 \times 1.5 \times 6.67 \text{mm}^3$ (ピクセル数 $16 \times 16 \times 3$) とした. Si のエネルギー分解能は, エネルギー依存とし, 文献 [4] のモデルを用いた. 例えば 511keV では 0.3% となる. また, 909keV のガンマ線点線源に対する角度分解能は半値幅で 1.5° であった. 空間分解能評価のため, ^{89}Zr を充填したロッドサイズが $2.4, 2.0, 1.7, 1.4, 1.0, 0.8 \text{mm}$ のデレンゾファントムを視野中心に置いた場合と, 上方向に 20mm のオフセットを与えた場合の測定をシミュレーションした. その際, 陽電子飛程の影響を模擬するため, 平均運動エネルギーとして 396keV を発生する陽電子に与えた. ファントムの放射能は計 1MBq , 測定時間は 10 分とした. そして, 同時計数イベントに対して, エネルギーウィンドウを適用することで, 909keV コンプトンイベント (散乱検出器 $30\text{-}300 \text{keV}$, 吸収検出器 $820\text{-}100 \text{keV}$) と, PET イベント ($400\text{-}600 \text{keV}$) をそれぞれ抽出した. なお, 511keV コンプトンイベントも抽出し, ペアとなるシングルイベントまたは 511keV コンプトンイベントが同時計数されている場合も PET イベントとして抽出した. そして, PET 画像と 909keV コンプトン画像をそれぞれ 3D リストモード Ordered Subset Expectation Maximization 法 [2] によって再構成した. サブセット数は 8 , 反復回数は別のファントムの測定により実験的に最適化し, コンプトンイメージングの場合 20 回, PET の場合 10 回とした. 定量評価として, 1mm ロッドのピークバレー比を比較した.

3. 結果

図 2 に再構成画像, 図 3 に 1mm ロッドのプロファイルを示す. すべての画像で 1mm ロッドは分解されていた. なお, PET イベントのうち, Si 散乱検出器を含んだものは 20% で, そのうちの 93% は 511keV コンプトンイベントを含んだものであった. 表 1 に図 3 のプロファイルにおけるピークバレー比を示す. 視野中心の場合には PET の方が高い値を示したが, オフセット 20mm の 909keV コンプトンが最も高い値となった.

4. まとめ

PET では ^{89}Zr から放出される陽電子飛程と角度揺動の影響を受けるが, 1mm のロッドを位置によらず同程度分解することができた. 一方で, 909keV コンプトンは, 視野中心よりもオフセット 20mm で, 散乱検出器に近づけた方がより鮮明に分解できた. また, その時のピークバレー比は PET よりも高くなった. よって, 散乱検出器に近い領域では PET よりも高い空間分解能を得られる可能性が示唆された.

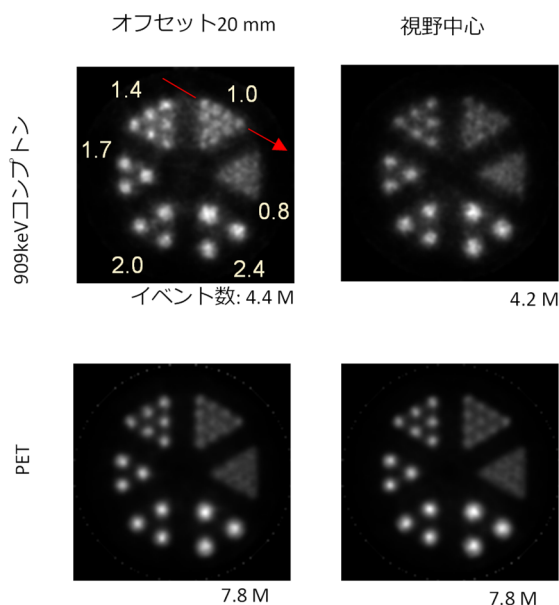


図 2. 再構成画像. 数字はロッドサイズ (mm). 矢印線は比較のためのプロファイル位置を示す.




図 3. 図 2 の矢印で示した線上のプロファイル比較.

表 1. ピークバレー比

位置	909keVコンプトン	PET
オフセット20 mm	1.48	1.44
視野中心	1.37	1.42

謝辞

本研究は JSPS 科研費 20H05667, 20K12683 の助成を受けたものです.

利益相反の有無

本研究の一部は, 中谷医工計測技術振興財団の研究助成を得て実施された.

文献

- [1] Yoshida E, Tashima H, Nagatsu K et al: Whole gamma imaging: a new concept of PET combined with Compton imaging. Phys Med Biol 65: 125013, 2020
- [2] Tashima H, Yoshida E, Wakizaka H et al: 3D Compton imaging reconstruction method for whole gamma imaging. Phys Med Biol 65: 225038, 2020
- [3] Moses W W: Fundamental limits of spatial resolution in PET. Nucl Instr Meth Phys Res Sect A 648: S236-S240, 2011
- [4] Yabu G, Yoneda H, Orita T et al: Tomographic imaging by a Si/CdTe Compton camera for ^{111}In and ^{131}I radionuclides. IEEE Trans Rad Plas Med Sci 6: 592-600, 2022

Deep Image Prior を用いた SPECT 画像再構成における EM-TV アルゴリズムの検討

矢部 暁登*¹, 松原 佳亮*², 越野 一博*³, 渡部 浩司*⁴, 湯浅 哲也*⁵, 銭谷 勉*¹

*¹ 弘前大学大学院理工学研究科

*² 秋田県立大学システム科学技術学部経営システム工学科

*³ 北海道情報大学経営情報学部システム情報学科

*⁴ 東北大学サイクロトロン・ラジオアイソトープセンター

*⁵ 山形大学大学院理工学研究科

EM-TV Algorithm for SPECT Image Reconstruction by Using Deep Image Prior

Akito YABE*¹, Keisuke MATSUBARA*², Kazuhiro KOSHINO*³, Hiroshi WATABE*⁴, Tetsuya YUASA*⁵,
Tsutomu ZENIYA*¹

*¹ Graduate School of Science and Technology, Hirosaki University

*² Faculty of Systems Science and Technology, Akita Prefectural University

*³ Faculty of Business Administration and Information Science, Hokkaido Information University

*⁴ Cyclotron and Radioisotope Center, Tohoku University

*⁵ Graduate School of Science and Engineering, Yamagata University

要旨：我々のグループでは高解像度 SPECT 装置を開発しているが、十分なカウントが得られない場合、画質が劣化してしまう。我々は事前学習が不要で、ターゲット画像のみで画像を復元できる DIP(Deep Image Prior)を利用することで画質改善に成功した。本研究では更なる画質改善を目指して、DIP 処理に加えて、トータルバリエーション (TV) を正則化項として組み込んだ EM-TV アルゴリズムを用いた再構成法を検討した。数値ファントムを用いたシミュレーション実験を行い、DIP 無 TV 無, TV のみ, DIP のみ, DIP 有 TV 有で再構成した画像を比較、それぞれの PSNR(dB)は 32.09, 40.77, 41.64, 41.72, SSIM は 0.8590, 0.9390, 0.9462, 0.9467 と DIP と TV の組み合わせが最も良かった。また、実測データによる再構成画像も、DIP 有 TV 有によってノイズが低減され、ファントムの構造が鮮明になった。DIP と EM-TV による SPECT 画像の画質改善効果が示された。

キーワード：SPECT, Deep Image Prior, EM-TV

1. はじめに

SPECT(Single Photon Emission Computed Tomography) 装置は、目的臓器に集積した放射性薬剤から放出されるガンマ線を検出し、体内の薬剤の分布を画像化することで、体の機能が可視化できる。我々のグループでは、解像度が 3.5 mm 程度の高解像度の SPECT 装置を開発しており、通常の SPECT 装置よりも高解像度で薬剤の三次元分布を得ることができる[1]。しかし、高解像度化に伴い検出効率が低下し、十分なカウントが得られない場合、画像が劣化してしまう。近年ディープラーニングを用いた医用画像のノイズ除去の研究が盛んにおこなわれている[2]。その中で DIP(Deep Image Prior) という CNN(Convolutional Neural Network) を用いた画像処理法がある。DIP は画像の自然な成分とノイズ成分の学習の早さの違いを利用して画像のノイズ除去ができ、ネットワークの事前学習や大量のデータセットが必要ないという利点がある[3]。我々は DIP を用いて、ノイズ成分が多い画像のノイズ除去を行い、高解像度 SPECT 画像の画質改善に成功した。また、圧縮センシングのひとつに、トータルバリエーション(Total Variation : TV)と ML-EM(Maximum Likelihood Expectation Maximization)法

を組み合わせた EM-TV アルゴリズムという画像再構成法があり、エッジの保持とノイズ抑制の効果がある[4]。本研究では、高解像度 SPECT の画質の向上のため、DIP 処理に加え EM-TV アルゴリズムを用いた再構成法を検討した。

2. 方法

1) Deep Image Prior

ターゲット画像を x_0 、入力として与えるノイズ画像を z 、ネットワークのパラメータを θ 、ニューラルネットワークを f_θ とすると、以下の式からネットワークパラメータを更新する。

$$\theta^* = \underset{\theta}{\operatorname{argmin}} E(f_\theta(z); x_0) \quad (1)$$

ロス関数 E にはターゲット画像と出力画像の MSE(平均二乗誤差, Mean Square Error)を用いている。このネットワークは、ノイズ画像よりも、規則的な構造を持つ画像が早く復元されるため、ノイズ成分が復元される前にパラメータの更新を止めることで、ノイズ除去を行うことができる。

2) EM-TV 法

EM-TV 法は EM アルゴリズムを行う EM step と TV 正則化を行う TV step を組み合わせた手法であり、各アルゴリズムを組み合わせることで再構成画像を得ることができる。TV ノル

μは画素値λとすると

$$TV(\lambda) = \iiint \sqrt{\left(\frac{\partial \lambda}{\partial x}\right)^2 + \left(\frac{\partial \lambda}{\partial y}\right)^2 + \left(\frac{\partial \lambda}{\partial z}\right)^2} dx dy dz \quad (2)$$

と表すことができ、EM アルゴリズムで推定したλに対するTV ノルムの重み付け係数αを用いて、EM step, TV step の最小化問題を求めることで再構成画像を得ることができる。

3) SPECT 画像再構成への応用

SPECT の投影データをターゲット画像として、1 投影毎にDIP 処理を行う。DIP の optimizer には SGD を使用する。DIP 処理した投影画像は、EM-TV 法を用いて画像再構成する。

3. 実験

1) シミュレーション実験

脳ファントムの数値ファントム画像を用いた[6]。数値ファントム画像からプログラムを用いて、180 方向からの投影データを抽出し、統計ノイズを付加した。この投影データをターゲット画像として、DIP の処理を epoch 数 2000 で行い、DIP の処理をした投影データを EM-TV 法で iteration=50 で画像再構成を行い、視覚的評価および、作成された再構成画像と数値ファントムとの PSNR(Peak Signal-to-Noise Ratio), SSIM(Structural Similarity)の値を計算し、画質を評価した。

2) 実測データによる評価実験

高解像度 SPECT 装置でパラレルホールコリメータを使用し、447 MBq の Tc-99m 溶液で満たされた物理脳ファントムを撮像し得られた画素サイズ 0.81 mm×0.81 mm, 画素数 256 × 256, 180 方向の投影データを用いた。この投影データ画像をターゲット画像として DIP の処理を行い、DIP の処理を行った投影データを EM-TV 法で iteration を 50 で再構成し、画素サイズ 0.81 mm×0.81 mm×0.81 mm, 画素数 256 × 256 × 256 の再構成画像を作成し比較した。

4. 結果

1) シミュレーション実験

表 1 は再構成画像と数値ファントムとの PSNR, SSIM を示している。表 1 から DIP と EM-TV を用いた再構成画像が最も PSNR, SSIM の値が向上した。図 1 に原画像, DIP 無 EM-TV 無の再構成画像, EM-TV 処理のみの再構成画像, DIP 処理のみの再構成画像, DIP と EM-TV 処理をした再構成画像を示す。図 1 から DIP と EM-TV を用いた処理は再構成画像のエッジを保持しつつ、ノイズを抑制していることが確認できた。

表 1 再構成画像の PSNR と SSIM

	DIP 無 EM-TV 無	DIP 無 EM-TV 有	DIP 有 EM-TV 無	DIP 有 EM-TV 有
PSNR[dB]	32.09	40.77	41.64	41.72
SSIM	0.8590	0.9390	0.9462	0.9467




図 1 再構成画像の比較 (a)原画像 (b)処理なし (c)EM-TV 処理(α = 4.9) (d)DIP 処理 (e)DIP + EM-TV 処理 (α = 0.28)

2) 実測データによる評価実験

図 2 に DIP 無 EM-TV 無の再構成画像, EM-TV 処理のみの再構成画像, DIP 処理のみの再構成画像, DIP と EM-TV 処理をした再構成画像を示す。図 2 から DIP と EM-TV により構造が鮮明になり、ノイズが抑制された。




図 2 実測データの再構成画像 (a)処理なし (b)EM-TV 処理(α = 4.9) (c)DIP 処理 (d)DIP+EM-TV 処理(α = 0.28)

5. まとめ

本研究では、ノイズの抑制と画質の向上に有用である DIP と EM-TV 法を組み合わせた手法を検討した。実験により、DIP と EM-TV 法を組み合わせた手法は PSNR, SSIM, 視覚的評価から効果的であることが分かった。

謝辞

本研究は JSPS 科研費 JP17H04116 の助成を受けて実施された。

利益相反の有無

無し

文献

- [1] Zeniya T, Gaku K, Hori Y, et al.: Development of high-resolution brain SPECT system using full-digital gamma camera with multiple position-sensitive PMTs. In Conference Record of 2015 IEEE Nuclear Science Symposium and Medical Imaging Conference, San Diego, 2016
- [2] Matsubara K, Ibaraki M, Nemoto M, et al.: A review on AI in PET imaging. Ann Nucl Med 36: 133-143, 2022
- [3] Ulyanov D, Vedaldi A, Lempitsky V: Deep Image Prior. [Online]. Available: <https://arxiv.org/abs/1711.10925>
- [4] Sawatzky A, Brune C, Wbbeling F, et al.: Accurate EM-TV algorithm in PET with low SNR. In 2008 IEEE Nuclear Science Symposium Conference Record, Dresden, 2008, pp. 5133-5137
- [5] Iida H, Hori Y, Ishida K, et al.: Three-dimensional brain phantom containing bone and grey matter structures with a realistic head contour. Ann Nucl Med 27: 25-36, 2013

Dual Energy 散乱線補正と高感度マルチピンホールによる蛍光 X 線 CT の画質改善

對馬 結太^{*1}, 松岡 将宏^{*2}, 笹谷 典太^{*2}, 砂口 尚輝^{*3}, 河嶋 秀和^{*4}, 兵藤 一行^{*5},
湯浅 哲也^{*2}, 銭谷 勉^{*1}

^{*1} 弘前大学 大学院理工学研究科 ^{*2} 山形大学 大学院理工学研究科

^{*3} 名古屋大学 大学院医学系研究科 ^{*4} 京都薬科大学 放射性同意元素研究センター

^{*5} 高エネルギー加速器研究機構 物質構造科学研究所

Image improvement of X-ray fluorescence computed tomography by dual-energy scatter correction and highly sensitive multiple pinholes

Yuta TSUSHIMA^{*1}, Masahiro MATSUOKA^{*2}, Tenta SASAYA^{*2}, Naoki SUNAGUCHI^{*3},
Hidekazu KAWASHIMA^{*4}, Kazuyuki HYODO^{*5}, Tetsuya YUASA^{*2}, Tsutomu ZENIYA^{*1}

^{*1} Graduate School of Science and Technology, Hirosaki University

^{*2} Graduate School of Science and Engineering, Yamagata University

^{*3} Nagoya University Graduate School of Medicine

^{*4} Radioisotope Research Center, Kyoto Pharmaceutical University

^{*5} Institute of Materials Structure Science, High Energy Accelerator Research Organization (KEK)

要旨: 我々は非放射性ヨウ素化合物を用いて生体機能画像の取得を可能とするピンホール蛍光 X 線 CT 装置の開発をしているが、被写体からの散乱線の影響により画像コントラストが低くなる。また、シングルピンホールは感度が低いため統計ノイズが大きくなる。本研究では dual energy 散乱線補正法と高感度マルチピンホールを組み合わせた新しい手法によって、蛍光 X 線 CT 画像のコントラストノイズ比 (CNR) の改善を試みた。放射光単色 X 線を利用した物理ファントム実験の結果、再構成画像の CNR は濃度 0.3mg/ml のヨウ素にて、シングルピンホール・散乱線補正無しに比べ、散乱線補正により 11 倍に、マルチピンホール化により 3.4 倍に、両方適用で 22 倍に改善された。dual energy 散乱線補正法とマルチピンホールの相乗効果により画質が大きく改善された。

キーワード: 蛍光 X 線 CT, ピンホールコリメータ, 散乱線補正

1. はじめに

我々は放射光 X 線で励起した特定の物質から発する蛍光を利用した蛍光 X 線 CT を開発してきた[1]。蛍光 X 線 CT は生体内の微量な特定物質を描出でき、蛍光を発する物質を標識薬剤として利用すると positron emission tomography (PET) や single photon emission computed tomography (SPECT) と同様の機能画像が放射線同位元素を使用せずに得られる。しかし、被写体からの散乱線によって再構成画像のバックグラウンド領域で偽像が発生し、画質の劣化する。Sasaya らはシングルピンホールコリメータを用いた蛍光 X 線 CT において dual energy 散乱線補正法を提案し、画質を改善させた[2]。そこで、マルチピンホールコリメータを使用して高感度化された蛍光 X 線 CT[3]に応用することで更なる画質改善が可能ではないかと考えた。

本研究は、dual energy 散乱線補正法をマルチピンホール蛍光 X 線 CT に適応させ、シングル・補正無しでの再構成画像と比較することで、画質の改善を確認することを目的とする。

2. 方法

1) マルチピンホール蛍光 X 線 CT

造影元素に X 線が照射されると、光電効果による励起によ

って蛍光が放出される。ボクセルから発生した蛍光は、入射 X 線に垂直な方向に配置された複数のピンホールを通り検出器で検出され、投影画像データを得る (図 1)。本研究では、高エネルギー加速器研究機構 PF-AR のビームライン AR-NE7A に蛍光 X 線 CT システムを構築し、放射光単色 X 線を利用した。




図 1 マルチピンホール蛍光 X 線 CT システム

投影画像データは次式の ordered subsets expectation maximization (OS-EM) 逐次近似画像再構成法で再構成される。

$$V_j^{(k+1)} = \frac{V_j^{(k)}}{\sum_{i \in S_n} c_{ij}} \sum_{i \in S_n} \frac{p_i c_{ij}}{\sum_{j=1}^N c_{ij} V_j^{(k)}} \quad (1)$$

ここで j は再構成画素の通し番号 ($1 \leq j \leq N$), i は検出器画素の通し番号 ($1 \leq i \leq M$), c_{ij} は画素 j から放出されたガンマ線が検出器 i で検出される確率, p_i は計測により得た投影データ, V_j は再構成画像, k は繰り返し回数, S_n はサブセットである.

2) Dual energy 散乱線補正

再構成領域の画素数を N 個, 検出器の個数を M 個とする. p_i^E, c_{ij}^E を, それぞれ i 番目の検出器に入射する全光子数, 係数行列とする. また, 上付きの添え字 E は K 吸収端エネルギーの直上 (AB)・直下 (BL) を区別するものである. ($n+1$) 回目の更新における j 番目の画素値の推定値 $v_j^{(n+1)}$ および i 番目の検出器に入射する散乱光子数の推定値 $\sigma_i^{(n+1)}$ は以下ようになる.

$$v_j^{(n+1)} = \frac{v_j^{(n)}}{\sum_i^M (c_{ij}^{AB} + c_{ij}^{BL})} \sum_i^M P_{ij}^{(n)} \quad (2)$$

$$\left(P_{ij}^{(n)} = \frac{c_{ij}^{AB} v_j^{(n)}}{\sum_j^N c_{ij}^{AB} v_j^{(n)} + \sigma_i^{(n)}} + \frac{c_{ij}^{BL} v_j^{(n)}}{\sum_j^N c_{ij}^{BL} v_j^{(n)} + \sigma_i^{(n)}} \right)$$

$$\sigma_i^{(k+1)} = \frac{\sigma_i^{(k)}}{2} \times B_i^{(n)}$$

$$\left(B_i^{(n)} = \frac{p_i^{AB}}{\sum_j^N c_{ij}^{AB} v_j^{(n)} + \sigma_i^{(n)}} + \frac{p_i^{BL}}{\sum_j^N c_{ij}^{BL} v_j^{(n)} + \sigma_i^{(n)}} \right)$$

投影, 逆投影, 散乱線成分の更新は, ピンホール毎に計算した後, 次の計算に移る. 造影元素の K 吸収端の直上・直下のエネルギーで 2 種類の投影データを得て, (3)式を利用して散乱線補正された再構成画像が得られる.

3. 撮像実験

本実験では図 2 に示すように直径 2 mm の穴を 6 つ開けた直径 10 mm の PMMA 製円筒に, 濃度の異なるヨウ素溶液を満たした物理ファントムを被写体とした. K 吸収端の直上の 33.3 keV と直下の 32.4 keV のエネルギーで 2 種類の投影画像データを得た. シングルおよびマルチピンホールの投影画像データを散乱線補正無しと, 有りの画像再構成法を用いて再構成した.




図 2 物理円柱ファントムの概要

コントラストノイズ比 (CNR) で画質を評価した.

$$CNR = \frac{m_s - m_N}{\sigma_N} \quad (3)$$

m_s, m_N, σ_N は造影剤領域の画素値の平均, バックグラウンド領域の画素値の平均, バックグラウンドの画素値の標準偏差である.

4. 結果

図 3 に各条件における物理ファントムの再構成画像を示す. 画質評価のために (3) 式を用いてヨウ素溶液の 0.3, 0.2, 0.1 mg/ml 部分の CNR を計算した (図 4). 0.3 mg/ml ヨウ素濃度領域では, シングルピンホール・散乱線補正なしに比べてマルチピンホール化で 3.4 倍 CNR が向上していることが確認できた. また, 散乱線補正により約 11 倍向上した. 両方を適用することで, 約 22 倍も改善された.




図 3 再構成画像

(a) シングル・散乱線補正なし (b) マルチ・散乱線補正なし
(c) シングル・散乱線補正あり (d) マルチ・散乱線補正あり




図 4 濃度別の CNR

5. まとめ

Dual energy 散乱線補正法とマルチピンホールの相乗効果により蛍光 X 線 CT 画像の画質が大きく改善された.

謝辞

本研究は JSPS 科研費 JP17H04116 の助成を受けたものです.

利益相反の有無

なし

文献

- [1] 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, Thet-Thet-Lwin et al: Dual-energy fluorescent x-ray computed tomography system with a pinhole design: use of K-edge discontinuity for scatter correction. Sci Rep 7: Article Number 44143, 2017
- [3] 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

データ・カルテシステム (SAKAS) の構築とマイクロ・位相 X 線 CT への適用

米山明男^{1,3}、河本正秀¹、馬場理香^{1,2}、廣沢一郎¹、妹尾与志木¹、兵藤一行³、平野馨一³

¹九州シンクロトロン光研究センター

²(株) 日立製作所研究開発グループ

³高エネルギー加速器研究機構物質構造科学研究所

Development of SAKAS (SAGA light source data KArte System)

Akio YONEYAMA^{1,3}, Masahide KAWAMOTO¹, Rika BABA^{1,2}, Ichiro HiroSawa¹, Yoshiki SENO¹,
Kazyuki HYODO³, Keiichi HIRANO³

¹ SAGA Light Souce

² Research and Development Group, Hitachi Ltd

³ Institute of Materials Structure Science, High Energy Accelerator Research Organization

要旨：九州シンクロトロン光研究センター (SAGA Light Source(SAGALS)) では、マイクロ CT や位相 CT 等の放射光イメージングにより取得した画像データについて、サンプルの名前や状態に加え、X 線カメラやビームラインの計測条件から、再構成の画像処理に至る全ての条件を統合的に取り扱い、保存するデータ・カルテシステム (SAKAS : SAGA-LS data KArte System) の構築を進めている。本システムでは、テキスト形式 (windows の ini ファイル形式) で 1 個のカルテ・ファイルとして管理するため、どのような処理がどのような条件で行われたか容易に確認することが出来る。現在、初版の仕様策定と制御及び処理ソフトの製作を終え、SAGA-LS の BL 07 や PF の BL-14C で試験的な運用を行っている。SAKAS の仕様と、マイクロ CT への適用結果等について紹介する。

キーワード：データ、カルテシステム、放射光 CT (5 語以内)

1. はじめに

大量試料の計測 (ビッグデータ) や DX への対応として、SAGA LS では、放射光を利用したマイクロ X 線 CT や位相 X 線 CT 等のイメージングにおいて、画像データ (RAW データ) とは別に、

- サンプルの名前、部位、状態
- 計測条件 (使用した X 線カメラの仕様、露光条件)
- ビームラインの状況 (蓄積電流、分光器)

等の計測条件に加えて、

- フィルター関数など再構成の画像処理条件

に至る全ての実験・計算条件を統合的に取り扱い、自動で保存するデータ・カルテシステム (SAKAS : SAGA-LS data KArte System) の構築を進めている。SAKAS では、計測制御ソフトや処理ソフトが個別に保存していた計測・計算条件を、テキスト形式 (windows の ini ファイルと同じ構造) で 1 個のカルテファイル (Tag ファイル) として管理するため、どのような処理がどのような条件で行われたか容易に確認することが出来る。さらに、連続自動処理 (バッチ処理) も行うことができる。

2. SAKAS の書式

画像データの生成 (計測) と各データ処理の条件は、1 個の「tag ファイル」(画像データファイル名 + '.tag' を推奨) に追記の形で順に記録していく。Tag ファイルのフォーマットは、

Windows の ini ファイルに準拠し、

[セクション]

パラメータ=***

;コメント

とし、テキストの記録ルールは

- 大文字・小文字の区別はしない。
- パラメータの順番は問わない。
- 独自のセクション、及びパラメータがあっても良い。
- 独自のパラメータは、処理側で任意に設定できる。

とする。計測における主なセクションは Sample、BL_Cond、Imager、Method とし、撮像条件は Proc_1 に記録する。その後のデータ処理はセッション名「Proc_*」として、パラメータに各計算条件や ROI 等を記録する。表 1 に SAKAS の Tag ファイルの項目 (メタデータ) 一覧を示す。

4. 処理ソフトウェア群 (SAKAS-**)

データ処理の流れと対応する開発ソフトウェア群 (CTRL7 と SAKAS-**) を図 1 に示す。いずれのソフトも同じインターフェイスを備え、画像データと同じファイル名の Tag ファイルを選択するだけで、画像データの各情報が自動的に入力されるようになっている。また、CT の中心や位相アンラップの手法など画像処理の各パラメータは 2. の規約にしたがって自動で Tag ファイルに追記される。

表 1 SAKAS の Tag ファイルの項目 (メタデータ) 一覧

SECTION	Param	Format	SECTION	Param	Format
Sample	Name	string	Method	Method	string
	Part	string		Pro_Number	Integer
	Status	string		Pro_angle	Integer
	Temp	string		Step_Mode	Integer
	Memo	string		FS_Numer	Integer
BL_Cond	Date	string	Proc_1	File_Name	string
	Time	string		Width	integer
	SR_Facility	string		Height	integer
	Energy	Float		Image_Number	integer
	Mono	Float		Format	integer
	TC1W	Float		BK_Interval	Float
	TC1H	float		BK1_File_Name	float
	Name	string	Proc_2	BK2_File_Name	string
	Mag	Float		BK_Image_Num.	Float
	Exp_T	Float		Off_Image_Num.	Float
	Camera_Width	Integer		Method	
	Camera_Height	Integer		File_Name	string
	Image_Width	Integer		Width	integer
	Image_Height	Integer		Height	integer
	Image_Offset_X	Integer		Image_Number	integer
				Format	integer
				BK_Interval	Float




図 2 SAKAS を用いた画像処理結果。

い、自動で保存するデータ・カルテシステム SAKAS を構築し、SAGA LS BL07、KEK PF BL-14C、及び SPring-8 BL16B2 に導入した。今後は、DICOM 変換機能を備えた Viewer の整備に加えて、利用ユーザーのフィードバックに基づいた修正・機能追加等を行っていく予定である。

利益相反の有無

なし

文 献

[1] Yoneyama, A., Takeya, S., Lwin, T. T., Takamatsu, D., Baba, R., Konishi, K., Fujita, R., Kobayashi, K., Shima, A., Kawamoto, M., Setoyama, H., Ishiji, K. & Seno, Y. (2021). J Synchrotron Radiat 28, 1966-1977.

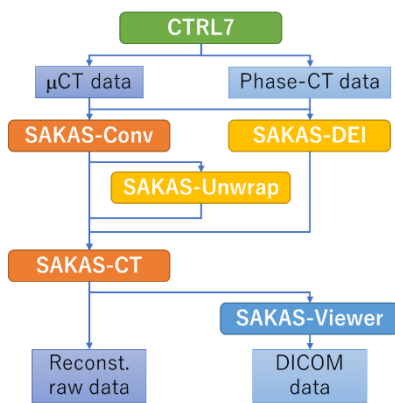


図 1 画像データの流れと SAKAS の各画像処

なお、同ソフトウェア群は SAGAL-LS のホームページ

<http://www.saga-ls.jp/main/3092.html#gsc.tab=0>

及び GitHub (SAGALS-IMG/BL07) で公開している。

5. 導入事例

これまでに SAGA LS BL07、KEK PF BL-14C、及び SPring-8 BL16B2 に導入を進めており、マイクロ X 線 CT では図 2 のような高精細な 3 次元データの取得と処理を短時間で出来るようになってきている [1]。

3. まとめ

放射光を利用したマイクロ X 線 CT や位相 X 線 CT 等のイメージングにおいて、全ての実験・計算条件を統合的に取り扱

A reconstruction method for binary limited-data tomography using a dictionary-based sparse shape recovery

Haytham A. Ali^{*1}, Katsuya Fujii^{*} and Hiroyuki Kudo^{*}

^{*} *Information and Systems, University of Tsukuba, Tsukuba, Ibaraki 305-8573, Japan*

¹ *Department of Mathematics, Faculty of Science, Sohag University, Sohag 82524, Egypt*

Abstract : Binary tomography is concerned with reconstructing a binary image from a very small number or other limited CT projection data. This problem itself not only possesses several medical imaging applications but also can be considered a model of general inverse problems to recover the object shape from limited measured data. Several approaches such as the Mumford-Shah method and various level-set methods have been investigated, but most of them lead to a non-convex optimization due to the difficulty to handle the binary constraint. We propose a new method based on a convex optimization inspired by dictionary-based shape recovery. In the proposed method, the object boundary of the binary image is represented by a level set of linear combinations of basis vectors in the dictionary. Using the dictionary, the object boundary is reconstructed by finding weights of the linear combination that best match the measured data. We create the dictionary by using the Gaussian radial basis function (GRBF). More concretely, we use Gaussian functions as a basis function placed at sparse grid points to represent the parametric level-set function and provide more flexibility in the binary representation of the reconstructed image. The simulation results of CT image reconstruction from only four projection data demonstrate that the proposed method can recover the object boundary more accurately compared with other competitive methods. The significance of our approach is the formulation with a tractable convex program while keeping moderate mathematical rigorosity.

Keywords: Binary tomography; Parametric level-set method; Shape recovery; Convex optimization.

1. Introduction

Tomography imaging is known as a method for displaying precise details inside the scanned object, i.e., it visualizes the internal structures of objects and thus has a wide range of applications such as medicine, science, industry, and electron tomography [1-3]. In all these applications that deal with reconstructing images from a given set of projection data, it is highly desirable to decrease the number of rays penetrating through the unknown object. Mathematically, this object can be represented as a function with a domain that can be discrete or continuous. Discrete Tomography (DT) deals with reconstructing discrete images consisting of a few different materials by using a limited number of projections. Recently, Batenburg and Sijbers have developed an algorithm called Discrete Algebraic Reconstruction Technique (DART) for DT, which provides high-quality reconstructions [3]. Even though this technique has its advantages, it requires more computation time, which limits its use in practical applications.

2. Problem Formulation

For binary image reconstruction, we can use the following linear system of equations

$$b = Au, \quad (1)$$

where $A \in \mathbb{R}^{M \times N}$ is the measurement matrix, $b \in \mathbb{R}^M$ is a measurement and the image $u \in \mathbb{R}^N$.

To solve (1), we used a regularized least-squares problem

$$\min f(u) = \|Au - b\|_2^2 + \mathcal{L}(u) \quad , \quad (2)$$

where $\mathcal{L}(u)$ is the regularization term. Based on the properties of the problem we can choose \mathcal{L} . This regularization term is used to enforce smoothness and boundedness of u . In our proposed the number of parameters involved in the problem is very small. As a result, the underdetermined problem can be made overdetermined, and the problem becomes better posed. According to this the parametrization idea is empirically found to be well-posed enough that no necessary regularization terms need to be added to the cost function. So, Eq. (2) can be written as

$$\min f(u) = \|Au - b\|_2^2 \quad , \quad (3)$$

This optimization problem (3) will solve by using a Newton like algorithm [4] as

$$u_{k+1} = u_k - \lambda_k \mathcal{H}_k^{-1} \nabla f(u_k),$$

where λ_k denotes the step-size parameter, \mathcal{H}_k denotes an approximation of the Hessian matrix of f calculated at $u = u_k$, and $\nabla f(u_k)$ is the gradient of f at u_k .

3. Level-set methods

By using the parametric level-set function $f(x, \alpha)$, we can express the image u as [5]

$$u(x, \alpha) = u_{in}(x) H(f(x, \alpha)) + u_{ex}(x) (1 - H(f(x, \alpha))), \quad (4)$$

where α is the parameter of the level set function, H is the Heaviside function.

The evolution of the level set function f is performed through updating the unknown parameter α . As a result, the level-set

function $f(x)$ can be represented parametrically by using set of basis functions and unknown weights as follows:

$$f(x, \alpha) = \sum_{i=1}^n \alpha_i \mu_i(x) \quad (5)$$

where $\mu = [\mu_1, \mu_2, \dots, \mu_n]$ denotes our dictionary or basis vector of basis functions. Here, we used the GRBF as a basis function and it is expressed as

$$\mu_i(x) = \exp(-\beta \|x - x_i\|^2), \quad (6)$$

where $\beta = (\sqrt{2} \sigma)^{-1}$, σ is the width of Gaussian, x_i is the center of GRBF, and $\|\cdot\|$ is the Euclidean norm.

4. Experimental results

To prove the efficacy and superiority of the proposed method in image reconstruction, we present experimental results for image reconstruction in sparse-view CT and limited-angle CT by using synthetic images and real X-ray CT projection data of a carved cheese slice [6].






Fig. 1. These two synthetic images are used to evaluate the performance of the proposed approach.



(a)TV (b)DART (c)DP (d) our method

Fig. 2. Reconstructed of synthetic image from only 4 projection distributed over the angular range $[0, \pi)$ compared to the other three methods.



(a) $5\pi/6$ (b) $2\pi/3$ (c) $7\pi/12$ (d) $\pi/2$

Fig. 3. Reconstructed images in the limited-angle CT case.





Fig. 4. Sinogram and a reconstructed image of the real data. with 180 angles over the angular range $[0, 2\pi)$.



(a)FBP (b)TV (c)Our method

Fig. 5. Reconstructed images for real data from only 8 projection data uniformly distributed over the angular range $[0, \pi)$.



(a)FBP (b)TV (c)Our method

Fig. 6. Reconstructed image for the real data in the limited-angle case, where the angular range was limited to $[0, \pi/2)$.

Conclusions

In this work, we proposed a new approach using a parametric level-set method for binary image reconstruction. We represent the object shape by using a level-set function, which in turn is represented using a linear combinations of basis vectors in the dictionary. Furthermore, the problem to be solved for image reconstruction becomes a tractable convex optimization.

Acknowledgments

I would like to express my deep gratitude to my supervisor for his support and valuable advice in carrying out the research. This research was supported by JST-CREST Grant Number JPMJCR1765.

Conflicts of Interest

The authors declare that they have no conflicts of interest to report regarding the present study.

References

- [1] Buzug T. M: Computed Tomography. In Springer-Verlag, Berlin, 2008.
- [2] Midgley P. A., Dunin-Borkowski R. E.: Electron tomography and holography in materials science. Nature Materials 8: 271-280, 2009.
- [3] Batenburg K. J., Sijbers J.: DART: a practical reconstruction algorithm for discrete tomography. IEEE Transactions on Image Processing 20: 2542-2553, 2011.
- [4] Pratt R. G., Shin C., Hick J. G.: Gauss-Newton and full Newton methods in frequency-space seismic waveform inversion. Geophysical Journal International 133: 341-362, 1998.
- [5] Ali H. A., Kudo H.: New Level-Set-Based Shape Recovery Method and its application to sparse-view shape tomography. In 2021 4th International Conference on Digital Medicine and Image Processing 24-29, 2021.
- [6] Bubba T. A. et al.: Tomographic X-ray data of carved cheese. arXiv preprint arXiv:1705.05732, 2017.

Whole Gamma Imaging 試作機のシミュレーションによる性能予測

菊地 智也^{*1}, 田久 創大^{*2}, 菅 幹生^{*1}, 田島 英朗^{*2},
錦戸 文彦^{*2}, 山谷 泰賀^{*2}

^{*1} 千葉大学, ^{*2} 量子科学技術研究開発機構

Performance Prediction of Whole Gamma Imaging Prototype by Simulation

Tomoya Kikuchi^{*1}, Sodai Takyu^{*2}, Mikio Suga^{*1}, Hideaki Tashima^{*2},
Fumihiko Nishikido^{*2}, Taiga Yamaya^{*2}

^{*1} Chiba University, ^{*2} National Institutes for Quantum Science and Technology

要旨 : Whole gamma imaging (WGI) は PET とコンプトンカメラを組み合わせた新しい画像化技術である。コンプトンカメラを利用することで PET ではノイズであったシングルガンマを利用できるようになる。本研究では、これまでの WGI 試作機よりも角度分解能と感度の向上を目指して設計した装置のモンテカルロシミュレーションによる性能予測を目的とした。具体的には、散乱検出器のシンチレータを GSO からエネルギー分解能の高い GAGG にすることで角度分解能の向上を図り、吸収検出器は time-of-flight PET に適する LGSO を用いた。また、リングの内径を小さくして体軸方向に伸ばすことで感度向上を図った。⁸⁹Zr 点線源を用いて視野中心から半径方向に 1 cm 間隔で線源を配置し、角度分解能と感度を評価した。また、デレンゾファントムを対象として画像再構成をした。その結果、従来機と比較して角度分解能と感度が向上し、画質向上により直径 3 mm のロッドが識別できることを確認した。

キーワード : PET, コンプトンカメラ, シミュレーション, 画像再構成

1. はじめに

量子科学技術研究開発機構では positron emission tomography (PET) とコンプトンカメラを組み合わせた whole gamma imaging (WGI) の開発を進めている。PET は体内に投与された放射性薬剤の体内分布を画像化する核医学診断装置である。このときの標識薬剤は陽電子放出核種を用い、陽電子の対消滅による一対の対消滅放射線を検出し、エネルギーが検出された二つの検出器を結んだ線分上に線源の位置を推定する。次に、コンプトンカメラは散乱検出器と吸収検出器の二層の検出器で構成されるガンマ線検出器の一種でシングルガンマ線の検出が可能である、吸収検出器として利用する既存の PET 検出器リングの内側に、WGI は散乱検出器として利用する追加の検出器リングを挿入し、コンプトンイメージングの手法を用いることで、PET イメージングだけでなくシングルガンマ線も検出できる。そのため、従来の PET 核種以外の核種も撮像可能となる[1]。

半減期が約 78 時間の ⁸⁹Zr は、比較的時間を要する抗体反応に着目したイメージングに適した PET 核種の一つとして知られている。しかし、陽電子放出に比べ 4 倍ほど多く放出される 909 keV のシングルガンマ線が、従来の ⁸⁹Zr-PET では画質低下の要因となっている[2]。WGI ではこのシングルガンマ線もコンプトンイメージングにより有効利用できるため、画質低下を抑えるのみならず、感度そのものの向上も期待できる[3]。これまで量研機構は三機の WGI の開発を行ってきた。本研究では最後に開発された WGI (WGI-3) から感度と角度分解能の向上を目指して設計した WGI (WGI-4) のシミュレーションによる

性能予測を行った。

2. 方法

1) シミュレーションジオメトリ

シミュレーションには素粒子が物質中で起こす振舞や反応をモンテカルロ法によりシミュレートする GEANT4 を用いた。

概形図と主なパラメータを図 1 と表 1 に示す。散乱検出器のシンチレータにエネルギー分解能の高い HR-GAGG を用い、結晶サイズの小さいものを用いることで角度分解能の向上を図った。吸収検出器のシンチレータは時間分解能と密度の高い LGSO を用い、リング数を 6 リングにすることで感度の向上を図った。また、散乱検出器は深さ情報を用いないものと深さ情報を用いるもの (2-layer DOI, 3-layer DOI) の 3 種類を比較した。線源は ⁸⁹Zr 点線源を視野中心から半径方向に 1 cm おきに 4 cm までの 5 か所に配置した。




図 1 シミュレーションジオメトリ

表1 WGI-4 ジオメトリの主なパラメータ

	散乱検出器			吸収検出器
素材	HR-GAGG			LGSO
エネルギー分解能 @511 keV	4.6 %			13.7 %
素子サイズ [mm ³]	1.5×1.5×15	1.5×1.5×7.5	1.5×1.5×5.0	3.0×3.0×20
結晶数	16×16×1	16×16×2	16×16×3	8×8×1
検出器数	10×4 ring			36×6 ring
リング径 [mm]	86			320

2) 評価方法

感度評価はコンプトンイベント数を核種の崩壊数とコンプトンイベントを起こした放射線の分岐比の積で割ったものをコンプトン感度として使用した。

角度分解能は angular resolution measure (ARM)を用いて評価した。ARM は散乱検出器や吸収検出器で測定されたエネルギーから計算した、ガンマ線の入射角度と実際の入射角度の差により求められ、その半値全幅を求めた。

空間分解能評価には図2に示した直径72 mmのデレンゾファントムを用いて評価した。線源は²²Naを用い、ロッドの直径は3, 4, 5, 8, 10 mm, 体軸長は5 mmとした。またイメージングパラメータを表2に示す。




図2 デレンゾファントム

表2 イメージングパラメータ

反復回数	20
サブセット数	8
ボクセルサイズ [mm ³]	1.0×1.0×1.0
FOV [mm]	Radius : 40 Axial length : 15

3. 結果

1) 感度評価

感度評価結果を図3(a)に示す。WGI-4の感度は、積層数により変化しなかった。視野中心で約1.3%が得られ、視野端に進むと約1.5%に向上した。WGI-3に比べ、視野中心で約3倍の感度が得られた。

2) 角度分解能評価結果

角度分解能評価結果を図3(b)に示す。1層の角度分解能はすべての点においてWGI-3より劣った。2層DOIのWGI-4は、視野中心で4.2度、視野端に向かうと6.4度まで劣化した。3層DOIのWGI-4では、視野中心で4.0度、視野端に向かうと5.7度まで劣化した。端に行くにつれて角度分解能が劣化する割合は2層より3層DOIの方が小さい。

3) 空間分解能評価結果

逐次近似型画像再構成法であるLM-OSEM法を用いて再構成された画像からロッド部の体軸長にあたるスライスを加算した結果を図3(c)に示す。3層DOIのWGI-4では3 mmのロッドまで識別が可能であった。角度分解能の向上に伴い視野内全域で画質が改善された。

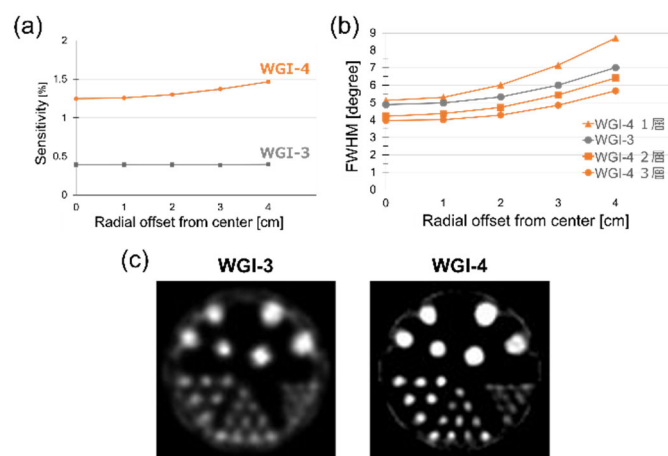


図3 (a) 感度評価結果 (b) 角度分解能評価結果
(c) 空間分解能評価結果

4. まとめ

散乱検出器のエネルギー分解能と素子サイズの改善をしたWGI4号機のシミュレーションによる性能予測を行った。その結果、WGI3号機より感度は3倍向上し、再構成画像では全体の画質が向上し、直径3 mmのロッドまで識別が可能であることを確認した。

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

文献

- [1] Yoshida E et al: Phys Med Biol 65: 125013, 2020
- [2] Deri MA et al: Nucl Med Biol 40: 3-14, 2013
- [3] Tashima H et al: Phys Med Biol 65: 225038, 2020

診療放射線技師教育のための考察型教育用ファントムを用いた教育

近藤 啓介^{*1}

^{*1} 駒澤大学医療健康科学部

Education of Radiologic Technologists Using a Considerable Educational Phantom

Keisuke KONDO^{*1}

^{*1} Faculty of Health Sciences, Komazawa University

要旨：社会から大学での教育に「自ら考え行動できる」能力の育成が求められている。本研究は診療放射線分野の専門的知識・技術を活用した問題解決型の教育コンテンツの開発が目的である。提案する教育コンテンツに利用する教育用ファントムを開発した。X線吸収率の異なる3種類の立方体ファントム（黄色・青色・橙色）とそれを縦横高さ各3個の計27個が入るブラックボックスである。最初に3種類の立方体ファントム各9個をブラックボックスに入れ外から見えないように封印する。次にブラックボックスをX線撮影装置で撮影し画像を解析することで27ヶ所のどの位置に黄色・青色・橙色の立方体ファントムが配置されたかを当てる。解析の速さと正確性を得点化し対戦形式のゲーム方式である。教育コンテンツとしての有効性を確認するために、2つの大学の学生による交流大会を開催した。参加者のアンケート結果より、専門知識を利用した考察型の教育コンテンツとして十分な効果が期待でき、チームでのディスカッションも盛んであったことからチーム力を育てるコンテンツとしても期待ができる。

キーワード：教育、画像解析、ファントム、問題解決能力

1. はじめに

文部科学省の2020年度の学習指導要領では、「知識及び技能」「思考力・判断力・表現力など」「学びに向かう力、人間性など」の3つの柱からなる「資質・能力」を総合的にバランスよく育てていくことを目指すとしている。大学の教育においても「主体的・対話的で深い学び（アクティブ・ラーニング）」の視点からの授業改善が求められている。同様に社会から大学での教育に「自ら考え行動できる」能力の育成が求められている。学生の自由な発想で独創的なアイデアを出しながら専門知識を学ぶ教育コンテンツの代表的な例が「ロボットコンテスト」である。しかし工学系の学生にとっては非常に興味深い内容であっても、診療放射線技師の教育内容と分野があまりに異なり「ロボットコンテスト」を診療放射線技師の教育現場で利用することは困難である。そこで、本研究では診療放射線分野の専門的知識・技術を活用した問題解決型の教育コンテンツ^[1]の開発が目的である。教育コンテンツとしての有効性を確認するために、開発した教育用ファントムと教育コンテンツを用いて、2つの大学対抗の交流大会を開催し、参加した7チームによるアンケート結果を報告する。

2. 教育用ファントム

開発したのは、X線吸収率の異なる3種類の立方体ファントムと立方体ファントムを縦横高さ各3個入れることが可能なブラックボックスである。立方体ファントムとブラックボックスの写真を図1に示す。図1の左側の黒い箱は蓋であり、右側の黒い箱にかぶせると立方体のブラックボックスとなる。立方体ファントムは種類ごとに色をつけ、X線吸収率の高い順に黄色・青色・橙色であり、1辺の長さが20mmである。ブラック

ボックスは黒いアクリルで、蓋をすると中の立方体ファントムを視認することが出来ない。内寸の1辺が60.5mmである。また、各面にアルファベットのAからEを印字し、底面は無印である。



図1 立方体ファントムとブラックボックスの写真




図2 立方体ファントム3個の組合せとX線画像

ブラックボックスに立方体ファントムを入れた状態で上面や正面、側面から X 線撮影をすると、立方体ファントムが 3 個重なった状態の投影像となる。3 種類の 3 個の組み合わせは 10 パターンあるため、10 パターン全てを撮影した時の写真と X 線画像を図 2 に示す。時計回りに白くなるように配置したが、すべて異なる画素値（輝度）にならず、異なる 3 個の組み合わせでも同じ画素値（輝度）が存在するように立方体ファントムの X 線吸収率を調整した。

3. 教育コンテンツ（交流大会ルール）

ブラックボックスに入れられた立方体ファントム縦横高さ各 3 個の 27 か所の位置に対して、3 種類（黄色・青色・橙色）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。予選では、教員がブラックボックスに入れる立方体ファントムの配置パターンを決めて封印し、そのブラックボックスを撮影した 5 枚の画像（全チーム共通）を配布し、解析の正確性と速さを競争した。決勝戦では各大学の優秀チームで対戦形式とし、ブラックボックスに入れる立方体ファントムの配置パターンもチームで相談して考えさせる。封印したブラックボックスを交換し、X 線撮影も各チームで行い、時間内であれば追加の撮影を可能とした。決勝戦の時間を利用し、優秀チーム以外の学生による個人戦を行った。個人戦では最初に 3 枚の画像を配布し希望に応じて追加の画像を配布した。個人戦で利用した写真と X 線画像の一部を図 3 と図 4 に示す。

評価方法は、予選では 27 か所の立方体ファントムの色を 1 つ正解すると 1 点とし、最大 27 点とした。決勝戦と個人戦では、27 か所の立方体ファントムの色を 1 つ正解すると 1 点に加え撮影枚数に応じて 3 枚は 13 点、4 枚は 11 点、5 枚は 8 点、6 枚は 4 点、7 枚は 0 点とし患者の被ばくを意識させる配点とした。全てにおいて同点の場合は解析の早いチームの勝ちとした。

4. 結果

予選の 7 チームの得点は、27 点、27 点、19 点、17 点、15 点、14 点、13 点であった。決勝戦では、27 個正解で撮影枚数 4 枚の 38 点と 23 個正解で撮影枚数 3 枚の 36 点であった。個人戦では、27 個正解で撮影枚数 4 枚の 38 点が 2 名おり、解析の早かった学生の優勝となった。

アンケートでは、画像の解析の学習「考える力の学習」「チーム力」「コミュニケーション力」について役立ったかを問うた。どれも約 80% の学生が「非常に役に立った」「役に立った」と回答しており学習教材としての効果が期待できる。今回 4 名の教員が指導にあたったが、どの教員からも問題解決型の教育コンテンツとして有用であるとの評価を得ることができた。




図 3 上部から撮影時の写真と X 線画像




図 4 斜めから撮影時の写真と X 線画像

5. まとめ

開発した教育用ファントムを利用して大学対抗の交流大会を開催した結果、学生アンケートから診療放射線技師に必要な専門知識を利用した考察型の教育コンテンツとして十分な効果が期待できる。チーム戦にしたことにより、コミュニケーション能力の育成にも効果が期待できる。今後は参加者数や参加大学を増やして効果の検証を進める予定である。

謝辞

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

病理画像のガンらしさと正常らしさを情報量で評価する情報密度法

金道 敏樹^{*1}, 陸田 駿弥¹, 山田 壮亮^{*2}

^{*1} 金沢工業大学工学部情報工学科

^{*2} 金沢医科大学臨床病理学

Information Density Method to Evaluate the Cancer-likeness and Normality-likeness of Pathological Images with the Amount of Information

Toshiki KINDO^{*1}, Shunya MUTSUDA^{*1}, Sohsuke YAMADA^{*2}

^{*1} Department of Information and Computer Science, Kanazawa Institute of Technology

^{*2} Department of Pathology and Laboratory Medicine, Kanazawa Medical University.

要旨：近年，畳み込みネットワークなど人工知能を使った病理画像診断技術が盛んに研究され成果を上げる一方，その判断根拠を示すことが課題として浮かび上がっている．本研究では，逆に，判断根拠から積み上げる病理画像診断技術実現の可能性を提示する．我々は，性質の分かっている画像特徴量のそれぞれが，「がんである」と「正常である」とを識別する上での情報量をどれほど持っているかに注目する．我々が提案するカルバック・ライブラー情報量の第2項の符号を反転させて得られる識別情報量の大きさは，そのまま判断根拠の強さに対応する．したがって，病理画像の各小領域毎に含まれる画像特徴量が持つ情報量を全て足し上げれば，その小領域のがんらしさ・正常らしさの判断根拠を定量化できる．情報密度法と名付けたこの可視化方法を人工知能病理診断の国際コンペ CAMELYON16 のデータに適用し，臨床的判断と合わせてこのアプローチの有望さを示す．

キーワード：画像特徴量，カルバック・ライブラー情報量，情報量密度，判断根拠，可視化

1. はじめに

近年，畳み込みネットワーク(CNN)など人工知能を使った病理画像診断技術が盛んに研究され成果を上げる一方，その判断根拠を示すことが課題として浮かび上がっている[1,2,3].

この論文では，逆に，判断根拠から積み上げる病理画像診断技術実現の可能性を提示する．我々は，性質の分かっている画像特徴量のそれぞれが，「がんである」と「正常である」とを識別する上での情報量をどれほど持っているかに注目してきた[4,5]. この情報量の大きさは，そのまま判断根拠の強さに対応する．したがって，病理画像の各小領域に含まれる画像特徴量が持つ情報量を全て足し上げれば，その小領域のがんらしさ・正常らしさの判断根拠を定量化できる．情報密度法(Visualization Of Information Density: VOID)と名付けたこの可視化方法の詳細を示すとともに，人工知能病理診断の国際コンペ CAMELYON16 のデータ[1]に適用し，臨床的判断と合わせてこのアプローチの有望さを示す．

2. 判断根拠と識別情報量

病理画像診断の前提は，病変領域の特徴と正常領域の特徴には違いがあること，さらに病変領域と正常領域を区別できるほど特徴が高密度に分布していることである．そして，診断の対象の画像中に病変領域特有の特徴があれば，それが診断の判断根拠となる．

現実には，一例一例のパターンは多様で異なっており，典型的な特徴を全て兼ね備えているものはほとんどなく，いくつかの特徴の組み合わせから総合的に判断せざるを得ない．そこに，

病理画像診断の困難さがある．

こうした特徴がどの程度判断の根拠足り得るかは，情報理論から説明，定量化できる．情報理論によれば病変領域と正常領域とで出現確率に偏りがある特徴が判断の根拠足り得る．そして，その根拠の強度は，特徴 f^0 を病変領域にも正常領域にも均等に現れる特徴としたとき，カルバック・ライブラー情報量

$$D(f|f^0) = P_p(f) \log \frac{P_p(f)}{P_p(f^0)} + P_n(f) \log \frac{P_n(f)}{P_n(f^0)} \quad (1)$$

で定量化できる．ここで， $P_p(f)$ は特徴 f が病変領域に現れる確率であり， $P_n(f) = 1 - P_p(f)$ は特徴 f が正常領域に現れる確率である．ただ，カルバック・ライブラー情報量は，病変領域に偏って現れる特徴だけでなく，正常領域に偏って現れる特徴にも同様に正の大きな値となる．この不便さを解消するために，第2項の符号を反転させた次の量

$$C(f, f^0) = P_p(f) \log \frac{P_p(f)}{P_p(f^0)} - P_n(f) \log \frac{P_n(f)}{P_n(f^0)} \quad (2)$$

を識別情報量として採用する[6]. この識別情報量は，

- ・病変領域によく現れる特徴 f^+ には，正の値
- ・正常領域によく現れる特徴 f^- には，負の値
- ・いずれにもよく現れる特徴 f^0 には，ほぼ0

という便利な性質を持つので，病変判断の根拠足りえる根拠特徴集合 F^+ と，正常判断の根拠足りえる根拠特徴集合 F^- とを，

$$F^+ = \{f^+ | C(f^+) > \theta^+\}, F^- = \{f^- | C(f^-) < \theta^-\}$$

と求めることができる．ここで，閾値 $\theta^+ > 0, \theta^- < 0$ は，根拠水準を決めるパラメータである．




図1 診断対象画像の病変部を可視化する処理の概念図。

情報密度法 VOID は、根拠特徴集合を使って次の手続きで診断画像を処理し、病変領域と正常領域を塗り分ける（図1）：

- 1) 診断対象画像を複数の画像小片に分割する、
- 2) 各画像小片から複数の特徴 $\{f_a\}$ を取り出す、
- 3) 取り出した特徴が根拠特徴集合の要素のいずれかとの距離が閾値以下となるかを調べる、
- 4) 距離が閾値以下となる根拠特徴集合の要素があった場合、その要素の識別情報量を取り出した特徴の識別情報量とする、
- 5) 画像小片の特徴の識別情報量の積算値を画像小片の識別情報密度 $\sum_a C(f_a, f^0)$ とする、
- 6) 画像小片の識別情報密度の値を、大なら色濃く小なら薄くと、色の濃さへ変換して、画像小片を塗りつぶす。

3. 実験結果

情報密度法 VOID を CAMELYON16 の画像に適用した結果を、図2に示す。左上が CAMELYON16 の元画像であり、画像中の線は CAMELYON16 が定めた病変領域と正常領域の境界線の真値である。右上が、色の濃さで画像小片の識別情報量を示したブロック画像である。左下は、色の濃さで式(2)の第1項の値を示したブロック画像である。この二つは色の濃さが病変の疑わしさを示している。これに対して、右下は色の濃さで式(2)の第2項の値を示したブロック画像であり、色の濃さが正常らしさを表している。

この結果から、情報密度法が病変領域をよく抽出していることが分かる。特に、CAMELYON16 では正常領域とされているものの臨床的には病変領域と判断すべき領域である中央上部に、情報密度法は病変情報ありと妥当な結果を与えている。

現状の情報密度法には、右上、左下の脂肪領域に対して病変領域と評価する傾向があるなどの課題もあるものの、判断根拠の積み上げることによって病変領域の抽出が可能という結果は、CNN 活用とは違うアプローチによる、信頼できる医用画像診断技術実現の可能性を期待させる。

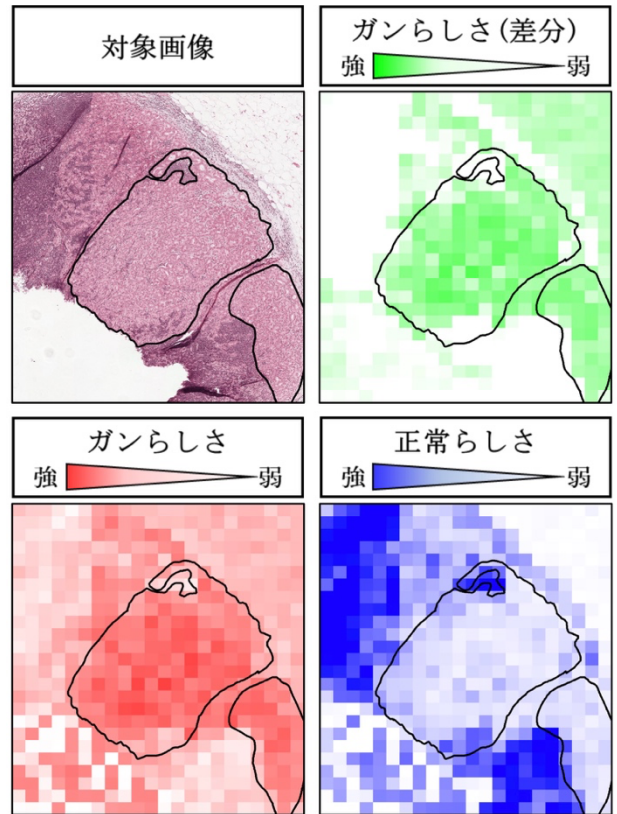


図2 情報密度法による CAMELYON16 画像の処理結果

4. まとめ

診断画像の各画像特徴が持つ判断根拠を情報量によって定量評価し、病変領域を抽出・可視化する情報密度法を提案した。SIFT 特徴量を採用した提案手法を CAMELYON16 の画像に適用して抽出された領域は臨床的にがん領域と判断された。

判断根拠の定量化に基礎を置く提案方法は、AI 応用手法の「判断根拠が分からない」という問題を本質的に解決している。

利益相反の有無

なし。

文献

- [1] CAMELYON16, <https://camelyon16.grand-challenge.org/>
- [2] Suzuki K.: Survey of Deep Learning Applications to Medical Image Analysis, MEDICAL IMAGING TECHNOLOGY Vol.34, pp212-26, 2017
- [3] S 上原和樹, 坂無英徳: 病理診断支援における説明可能 AI, MEDICAL IMAGING TECHNOLOGY, Vol.39, pp105-109, 2021.
- [4] 田村一希, 田島和征, 金道敏樹: 情報量を用いた画像特徴量解析とそのガン診断画像への応用, 情報処理学会第83回全国大会, Vol2, pp203-204, 2021.
- [5] 陸田駿弥, 鎌田千晶, 佐藤大紀, 他: 情報理論を用いたガン画像診断-特徴量の特性解析による性能向上の検討-, 情報処理学会第84回全国大会, 7U-06, 2022.
- [6] Kindo T., Yoshida H., Morimoto et al.: Adaptive Information Filtering System that Organizes Personal Profiles Automatically, Proceeding of the Fifteenth International Joint Conference on Artificial Intelligence(IJCAI-97), pp716-721, 1997.

Graph Neural Network による悪性リンパ腫のサブタイプ識別と 識別根拠となる細胞核の可視化

田中 寛武^{*1}, 橋本 典明^{*2}, 横田 達也^{*1}, クグレ マウリシオ^{*1},
大島 孝一^{*3}, 三好 寛明^{*3}, 永石 美晴^{*3}, 竹内 一郎^{*4}, 本谷 秀堅^{*1}

^{*1} 名古屋工業大学

^{*2} 理化学研究所

^{*3} 久留米大学 医学部 病理学講座

^{*4} 名古屋大学

Graph Neural Network for identification of malignant lymphoma subtypes and visualization of cell nuclei as a basis for identification

Hiromu TANAKA^{*1}, Noriaki HASHIMOTO^{*2}, Tatsuya YOKOTA^{*1},
Mauricio KUGLER^{*1}, Koichi OHSHIMA^{*3}, Hiroaki MIYOSHI^{*3},
Miharu NAGAISHI^{*3}, Ichiro TAKEUCHI^{*4}, Hidekata HONTANI^{*3}

^{*1} Nagoya Institute of Technology

^{*2} Institute of Physical and Chemical Research

^{*3} Kurume University Department of Pathology

^{*4} Nagoya University

要旨：H&E 染色病理顕微鏡画像より悪性リンパ腫のサブタイプ同定をおこなう機械を、識別根拠となる細胞核を明示するために、細胞核をノードとする Graph Neural Network(GNN)により構築する。100 種類以上の病型(サブタイプ)を持つ悪性リンパ腫は、サブタイプごとに治療方針や症状の進行速度が異なる。そこで、代表的なサブタイプである Reactive, FL, DLBCL の H&E 染色画像を入力としてサブタイプを出力する診断支援システムを構築する。そこで、説明可能性として、細胞核を単位とする識別根拠の可視化を行うサブタイプ識別器の構築を目指す。細胞核を単位とするのは、病理医が細胞組織の構造に基づき診断を行うからである。識別に寄与する細胞核を明示するためには画像中の細胞核をノードとする GNN を構築する。そして、識別根拠の可視化で強調される細胞核が病理学的な知見と整合するかどうかを確認する。結果として、識別率は約 83%となった。識別根拠は、Reactive はマンテル帯、FL は濾胞の外縁部、そして DLBCL はほぼすべての細胞核が識別に寄与していた。これらは病理学的知見と矛盾しない。

キーワード：悪性リンパ腫, 説明可能性, Neural Network, Graph Neural Network

1. はじめに

悪性リンパ腫は血液に含まれるリンパ球ががん化する病気であり、100 種類以上の病型(サブタイプ)に分類され、がん化したリンパ球は異型化する。サブタイプごとに治療方針や症状の進行速度が異なるため、正しいサブタイプを診断することは重要である。サブタイプの診断ではまず H&E 染色画像によりサブタイプの候補を推定する。説明可能性として H&E 染色画像を入力として識別根拠を明示する診断支援システムを構築する。識別根拠の代表的な明示法は Grad-CAM である。Grad-CAM は識別根拠をピクセル単位で表示する。しかし、病理医は細胞組織の構造に基づき診断を行うため、どの識別根拠を細胞核単位で明示する必要がある。そこで Graph Grad-CAM[1]を使用する。実験結果として識別結果と識別根拠を報告する。

2. 提案法

H&E 染色画像より細胞核をセグメンテーションし、細胞核をノードとするグラフを構築する。識別器には、Graph Neural Network(GNN)[2]を使用する。識別根拠は Graph Grad-CAM で明示する。Graph Grad-CAM は識別根拠をグラフのノード単位、即ち細胞核単位で評価する。また、セグメンテーションには細胞核の重心からの水平距離、垂直距離を回帰する HoVer-Net[3]を参考とした。グラフの構築では、まず同じ大きさの矩形領域を




図 1：ネットワーク構造




図 2 : 濾胞の構造

切り出す. 次に, 辺の生成ではボロノイ図の隣接した母点同士を接続した. なお, ノード間の距離が閾値以下の場合のみ辺を生成する. さらに, 各ノードに付与する細胞核の特徴量は細胞核を中心とする局所的なパッチ画像の固有空間表現ならびに細胞核の座標を使用した. なお, 固有空間表現では自己相関行列の主成分分析によって寄与率が約 99%になる 200 次元に削減した. 識別器には GNN のアーキテクチャである Graph Isomorphism Network(GIN)[4]を使用する. ネットワーク構造を図 1 に示す. Graph Grad-CAM は以下の式(1), (2)で計算される. ノード n の GNN の l 層の特徴 $F_{k,n}^l$ についてクラス c の出力 y^c に対する勾配を求め全ノードで平均を取ったものを $\alpha_k^{l,c}$ とする. そして, $\alpha_k^{l,c}$ を重みとして $L_{\text{GradCAM}}^c[n]$ を計算する. なお, GNN の全ての層について平均をとっている. 勾配を重みとするのは全特徴について勾配が大きいほど識別に寄与すると考えられるためである.

$$L_{\text{GradCAM}}^c[n] = \frac{1}{L} \sum_{l=1}^L \text{ReLU} \left(\sum_{k=1}^K \alpha_k^{l,c} F_{k,n}^l(X, A) \right) \quad (1)$$

$$\alpha_k^{l,c} = \frac{1}{N} \sum_{n=1}^N \frac{\partial y^c}{\partial F_{k,n}^l} \quad (2)$$

グラフの各ノードの勾配を計算する. 識別の対象は代表的なサブタイプである Reactive, Follicular lymphoma(FL), Diffuse large B-cell lymphoma(DLBCL) の 3 つとする. 悪性リンパ腫はリンパ節ががん化する病気である. 図 2 のようにリンパ節は濾胞と呼ばれるリンパ球が集まる構造体を持つ. 濾胞は中心部にある胚中心と縁にあるマントル帯から構成される. Reactive はがん化していない正常なリンパ節である. 一方で, FL は濾胞の内部でがん化が進行しており, マントル帯を持たない. さらに, DLBCL は全体でがん化が進んだサブタイプであり, 濾胞の構造が崩れている.

4. 実験結果

識別結果を図 3 に示す. Reactive を FL と誤識別しているが, Reactive と FL の識別は容易でないことが知られている. 細胞核単位での識別根拠を図 4 に示す. 識別に寄与しているほど細胞核が赤色になり, 寄与していないほど青色で表示され




図 3 : 混合行列




図 4 : 識別根拠

(左 : Reactive, 中央 : FL, 右 : DLBCL)

る. Reactive では, マントル帯の部分が強調されている. また, FL は濾胞の外縁部に識別に寄与した細胞核が多い. また, DLBCL は全体が識別にした細胞核である. これは, Reactive は FL, DLBCL と異なりがん化しておらず, マントル帯を持つためであると考えられる. FL は濾胞の外縁部が強調されたことは, FL の濾胞の外縁部にマントル帯がないことに起因すると考えられる. DLBCL の識別根拠として全体が赤くなることは全体ががん化しているためであると言える. 識別根拠は病理学的知見と矛盾しない.

5. まとめ

悪性リンパ腫の 3 つのサブタイプ(Reactive, FL, DLBCL)について識別を行い, 識別根拠を示した. 識別根拠は悪性リンパ腫の病理学的な知見と矛盾しなかった. ただしより詳細な調査が必要である. また, 注目する領域の大きさによって可視化の結果が変化することがあり, これは今後の課題である.

利益相反の有無

無し

文献

- [1] P. E. Pope, S. Kolouri, and M. Rostami Explainability methods for graph convolutional neural networks. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, pages 10764–10773, 2019.
- [2] F. Scarselli, M. Gori, A. C. Tsoi, and M. Hagenbuchner. The graph neural network model. IEEE Transactions on Neural Networks, p. 61–80, 2009
- [3] S. Graham, Q. D. Vu, and S. A. Raza. Hover-Net: Simultaneous segmentation and classification of nuclei in multi-tissue histology images. Medical Image Analysis, 58, 2019.
- [4] K. Xu, W. Hu, J. Leskovec, and S. Jegelka. How Powerful are Graph Neural Networks? In International Conference on Learning Representations, 2018.

細胞を注視する口腔細胞診画像分類

武田 啓太^{*1}, 藤原 航平^{*1}, 松尾 和季^{*1}, 見立 英史^{*2}, 酒井 智弥^{*1}^{*1} 長崎大学工学研究科^{*2} 長崎大学医歯薬総合研究科

Image Classification for Oral Cytology with Attention to Sparse Cells

Keita TAKEDA^{*1}, Kohei FUJIWARA^{*1}, Kazuki MATSUO^{*1}, Eiji MITATE^{*2}, Tomoya SAKAI^{*1}^{*1} Graduate school of engineering, Nagasaki University^{*2} Graduate School of Biomedical Sciences, Nagasaki University

要旨：本研究では口腔擦過細胞の画像を分類する識別器を設計する。口腔がんは死亡率が高いため早期発見が重要であり、非侵襲的で簡便な口腔細胞診が頻用される。しかし定量的診断基準が無く、病理医の負担も大きい。病理医の負担軽減だけでなく、定量的な診断基準の獲得のためにも、口腔細胞診画像を自動で分類する手法が望まれている。口腔細胞診画像の大部分は背景であり、パピニコロウ染色された細胞が偏在する。しかし、撮像条件により識別的な特徴が背景にも潜在する。注視機構を導入しても、畳み込みニューラルネットは細胞の識別的特徴のみを学習するとは限らない。本研究では、背景の線形従属性と細胞のスパース性にに基づき抽出した細胞の画像特徴のみで識別する深層学習モデルを設計した。提案手法は細胞領域を検出し、CAMは口腔細胞診の定量的な基準となる細胞核に注視した。識別性能に関して汎化できず、モデル構造の更なる改良が求められる。

キーワード：U-Net, Segmentation, 教師なし学習 (5語以内)

1. はじめに

本研究は口腔擦過細胞の画像（口腔細胞診画像）を自動で分類する識別器を提案する。近年、口腔がんの罹患者数は増加している[1]。がん患者の生存率を高めるためには早期発見および早期治療が非常に重要である。

口腔細胞診はがん患者の早期発見に有用であるとされる。口腔細胞診とは、口腔内の上皮細胞の良悪性を診断する検査である。口腔粘膜の病変を専用のブラシで擦ることで細胞を採取し、採取した細胞を染色した後に顕微鏡で観察することで検査する。細胞の良悪性の判定にはPapanicolaou分類[2]が用いられる。病理医は細胞の形状や細胞核の状態といった画像特徴により細胞診画像を分類する。口腔細胞診は従来の組織診と比較し、検査が簡便かつ非侵襲的である。被検者の負担の軽減という観点からも、口腔細胞診は重要である。

一方で、口腔細胞診画像の診断には定量的な基準が存在せず、病理医に大きな負担を強いる。深層学習による口腔細胞診の自動化は、病理医の負担軽減だけでなく、定量的な診断基準を獲得することも狙える。従って、本研究は口腔擦過細胞の画像を自動で分類する識別器の設計を目指す。

ここで、口腔細胞診画像は大部分が背景である。また、1人の被検者から複数の口腔細胞診画像が得られるため、同一の被検者から取得された口腔細胞診画像は共通した背景成分を持つ傾向にある。これは背景が識別的な特徴となりえることを意味する。口腔細胞診は細胞の特徴に従って診断するものであり、背景の特徴を抑制することは重要である。

以上より、本研究は細胞領域の特徴量のみから口腔細胞診画像を分類する識別器を提案する。細胞診画像の持つ数学的な性

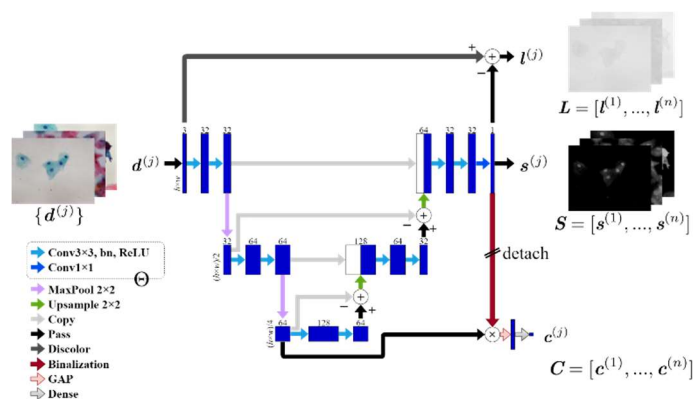


図1 細胞領域を検出し、細胞診画像を識別するモデル構造。

質を損失関数に導入し、細胞領域を検出する。細胞領域の検出に利用される特徴マップを流用し、検出された細胞領域を用いて特徴を抑制することで、口腔細胞診画像の分類を目指す。

2. 細胞診画像の持つ数学的な性質と前景分離

口腔細胞診画像は共通した背景を大部分に持つ。これは即ち、複数の口腔細胞診画像を集め、画像1枚を列ベクトルとした画像行列において、背景成分が共通する冗長な性質（低ランク性）や、細胞領域は画像行列全体と比較すると局所的に値が存在する（スパース性）性質を持つといえる。低ランク性とスパース性を持つ行列を各成分に分離する手法としてRPCA[3]が存在する。RPCAは行列を対象とした最適化の手法であり、1枚の細胞診画像から細胞の領域を検出できない。そこで、本研究はRPCAの最適化式をDual frame U-Net[4]の損失関数に導入することで、細胞領域を検出し、特徴量の抑制に利用する。

2. 細胞の注視と識別器の設計

細胞領域の検出と識別を同時に達成する識別器を設計する。提案手法のモデル構造を図 1 に示す。細胞の検出には Dual frame U-Net[4]を利用した。モデルは画素値 m の細胞診カラー画像 $\mathbf{d} \in \mathbb{R}^{3 \times m}$ を入力し、スパースな前景である細胞領域 $\mathbf{s} \in \mathbb{R}^m$ と、良悪性それぞれの確率 $\mathbf{c} \in \mathbb{R}^2$ を出力する。モデルの深さや中間層のチャンネル数はモデル設計のハイパーパラメータである。本研究では計算機資源の規模から図 1 のように決定した。

識別には U-Net の中間層で生成された特徴マップを利用する。特徴マップの選択はモデル設計のハイパーパラメータである。本研究では 2 段目の Pooling 層の出力を利用する。また、識別に利用する特徴マップは \mathbf{S} を 2 値化したマスク画像を乗算することで背景の特徴を抑制する。 \mathbf{S} の 2 値化について、本研究では \mathbf{S} のヒストグラムを観察し、 \mathbf{S} の絶対値が 0.1 より大きい値を取った画素値を 1、それ以外を 0 とした。マスク後の特徴マップを GAP 層に通し、細胞診画像の良悪性を識別する。

学習時には、バッチサイズ n 枚の画像 $\mathbf{D} \in \mathbb{R}^{n \times 3 \times m}$ を入力する。入力 \mathbf{D} を濃淡画像化した $\mathbf{D}' \in \mathbb{R}^{n \times m}$ と、 N 枚の出力 $\mathbf{S} \in \mathbb{R}^{n \times m}$ を用いて、RPCA の最適化に倣い、以下の式で損失を求める。

$$I_{loss} = \|\mathbf{D}' - \mathbf{S}\|_* + \lambda_s \|\mathbf{S}\|_1 + \lambda_c I_{CE} \quad (1)$$

ここで、 I_{CE} はモデルの出力 $\mathbf{C} \in \mathbb{R}^{n \times 2}$ と正解ラベルとの交差エントロピー損失である。 λ は各損失のバランスをとるハイパーパラメータである。

3. 提案手法による識別実験

実験に用いるデータセットは liquid based cytology[5]により取得された、画像サイズ (1280×1024) の被検者 27 人分の口腔細胞診画像 5762 枚である。実験時は被検者単位で訓練データ 21 名分、検証データ 16 名分、テストデータ 5 名分に分割して利用した。本研究では Papanicolaou 分類[2]のうち、良性と、擬陽性・悪性の 2 クラスの分類とする。画像は (320×256) への縮小と正規化を前処理とする。データセットの規模が大きいため、学習時にはデータ拡張を施していない。データはバッチサイズ 32 のミニバッチ形式で読み出す。訓練回数は 300 回とし、式(1)で損失を計上、Adam[6]によって最適化した。学習率は 10^{-5} とした。 λ_s は RPCA の論文[3]において推奨される、自動的に決まる値を利用した ($\lambda_s = 1/\sqrt{320 \times 256}$)。 λ_c は 10^3 とした。 λ_c は 10^{20} まで最適化に大きな影響がないことを確認した。

学習曲線を図 2 に示す。Accuracy において、提案手法は汎化できなかった。また、検証データにおける入力画像と、検出された細胞領域 \mathbf{S} 、CAM[7]を図 3 に示す。図 3(b)において、モデルは非ゼロの領域を示す赤色で細胞の領域を検出した。図 3(c)において、悪性の特徴分布を示す CAM は、口腔細胞診の定性的な診断基準のひとつである細胞核への注視を達成した。また、細胞の辺縁への注視が確認できる。




図 2 学習曲線。横軸が epoch 数、縦軸が各要素の値を示す。青が訓練データ、赤が検証データに対応する。




図 3 モデルが検出した細胞領域と CAM。(b)、(c)は白が 0、赤がマイナス、青がプラスの値を示す。

4. おわりに

本研究は口腔細胞診画像を自動で分類するために、教師なしで細胞を検出し、細胞検出モデルの内部で生成される特徴マップを用いて口腔細胞診画像を識別した。

細胞領域の検出について、図 3(b)より、RPCA の最適化式を用いた教師なしの細胞領域検出は有効であると考えられる。

細胞診画像の識別において、提案手法は汎化しなかった。要因として、細胞領域に背景の特徴量を保存し、識別器が利用できた可能性がある。入力やモデル設計の検討が改善案として考えられる。

謝辞

本研究は JSPS 科研費 JP19H04177, JP20K10163 の助成を受けています。本研究は長崎大学病院倫理審査委員会 No20190513 の承認を得ています。

利益相反の有無

なし

文献

- [1] 厚生労働省. 人口動態統計 (厚生労働省大臣官房統計情報部編), 2022.
- [2] 石橋浩晃, 秀島克巳, 関根浄治. 細胞診による口腔がんの早期診断 (総説). 日本口腔腫瘍学会誌, 25(3):54-71, 2013.
- [3] Candès, Emmanuel J., Xiaodong Li, Yi Ma, and John Wright. "Robust principal component analysis?" Journal of the ACM (JACM) 58, no. 3 (2011): 1-37.
- [4] Han, Y. and Ye, J. C.: Framing U-Net via deep convolutional framelets: Application to sparse-view CT, IEEE transactions on medical imaging, Vol. 37, No. 6, pp. 1418-1429 (2018).
- [5] 松坂賢一. 口腔細胞診の現状. 歯科学報, 117(2):87-92, 2017.
- [6] Kingma, D. P. and Ba, J.: Adam: A Method for Stochastic Optimization, 3rd International Conference on Learning Representations, ICLR 2015, San Diego, CA, USA, May 7-9, 2015, Conference Track Proceedings (Bengio, Y. and LeCun, Y., eds.) (2015).
- [7] Zhou, Bolei, et al. "Learning deep features for discriminative localization." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.

肺細胞で事前学習された畳み込みニューラルネットワークを用いた尿細胞の自動分類 道場彩乃^{*1}, 寺本篤司^{*2}, 桐山諭和^{*1,3}, 櫻井映子^{*1}, 塚本徹哉^{*1}

^{*1} 藤田医科大学大学院 医学系研究科

^{*2} 藤田医科大学大学院 保健学研究科

^{*3} 成田記念病院

Automatic Classification of Urinary Cells Using Convolutional Neural Networks Pre-trained on Lung Cells.

Ayano MICHIBA^{*1}, Atsushi TERAMOTO^{*2}, Yuka KIRIYAMA^{*1,3}

Eiko SAKURAI^{*1}, Tetsuya TSUKAMOTO^{*1}

^{*1} Graduate School of Medicine, Fujita Health University

^{*2} Graduate School of Health Sciences, Fujita Health University

^{*3} Narita Memorial Hospital

要旨: AI 技術の進歩が著しい中で, 細胞診断の自動化が採取臓器の変化にどの程度対応できるのかははまだ不明瞭である. 我々は, 以前より気管支鏡生検時に採取した肺細胞を用いて良悪性鑑別の自動化を目指してきた. 本研究では肺細胞で学習した畳み込みニューラルネットワークを用いた尿細胞の良悪性鑑別の可能性を探ることを目的として実施した. 気管支鏡生検材料と自然尿を液状化細胞診標準化し, 前者は良性 2249 枚, 悪性 888 枚, 後者は良性 716 枚, 悪性 664 枚のデジタル画像を作成した. 肺細胞画像で学習, 尿細胞画像で Fine-Tuning し, 尿細胞画像を評価した. 結果は良性正解率が 98.2%, 悪性正解率が 98.8% だった. 尿細胞画像のみならず肺細胞画像を併用することで尿細胞画像の分類精度が向上することが判明した. また, Grad CAM (Gradient-weighted Class Activation Mapping) により, AI はヒトによる細胞診での注目箇所と類似の箇所に注目して判定していることが判明した. 今後, 細胞診断における汎用性の高い AI を構築する上で重要な知見を得られた.

キーワード: 尿細胞診, 肺細胞診, 畳み込みニューラルネットワーク

1. はじめに

近年, 尿路上皮癌の罹患率は少しずつ増加している. 尿細胞診は尿中に剥がれ落ちた癌細胞の有無を検査する. しかし, 尿細胞は自然尿中に剥離した細胞であるため, 変性が起こりやすく, 尿細胞診の良悪性鑑別精度が低いことが問題視されている. そのため臨床現場では, 尿細胞を精度よく検査できる診断支援技術の開発が求められている.

われわれは以前より, 肺細胞診に関する診断支援技術を開発しており, 畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) によって細胞の良悪性鑑別処理を行う技術を開発した[1,2]. 尿細胞診に関して, 対象となる細胞画像を収集して CNN モデルの学習を行う研究がすでに行われている[3,4]. しかし, 希少疾患やアンバランスなデータセットしか得られない場合 (例えば悪性が良性に対して極めて少ない), 良好な結果が得られない. そのため, 異なる部位の細胞画像も利用して CNN を学習させることができれば, 多くのバリエーションを学習させることができ, 高い性能を有する CNN モデルを構築できる可能性がある.

CNN の学習方法において, 転移学習・Fine-Tuning がある. インターネット上の膨大な数の自然画像を学習させた AlexNet や GoogLeNet, VGG ネットなどの優れた分類性能を持つ CNN

を応用し, 処理対象である医用画像の分類のために一部作り替え, モデルを微調整 (Fine-Tuning) することで高いパフォーマンスを得ることができる. この場合, 医用画像の枚数はオリジナルのディープラーニングモデルを学習した際の自然画像の枚数よりもはるかに少ない数であっても良好な性能が得られる.

肺細胞と尿細胞においては共通した形態学的特徴が存在する. そこで本研究では, 肺細胞画像を学習した CNN を用いた尿細胞画像の自動分類手法を提案する.

2. 材料と方法

藤田医科大学病院で気管支鏡生検時に鉗子洗浄液から採取された肺細胞および自然尿を用いて液状化細胞診パバニコロウ染色標本 (Beckton Dickinson, Durham, NC, USA) を作成した. 肺細胞は良性 175 例, 悪性 116 例, 尿細胞は良性 64 例, 悪性 59 例を使用した. 次に, 肺細胞は良性 2249 枚, 悪性 888 枚, 尿細胞は 716 枚, 悪性 664 枚のバッチ画像 (296×296 画素) を作製した. 画像分類を行う CNN のネットワークアーキテクチャとして, VGG-16 を選出し, 以下に示す 3 種類の方法 (Method 1-3) で尿細胞の分類精度を評価した. Method 1: 肺細胞画像を利用して CNN の学習をし, 尿細胞画像の予測を行

う。Method 2：尿細胞画像のみを利用して CNN の学習をし、尿細胞画像の予測を行う。Method 3：肺細胞画像で事前学習した CNN を尿細胞画像で Fine-Tuning し、尿細胞画像の予測を行う。Method 3 が上述した提案法である。

加えて、予測値に対する勾配を重み付けすることで、重要なピクセルをヒートマップ (Activation Map) の形式で出力できる Grad CAM (Gradient-weighted Class Activation Mapping) により分類根拠の可視化を行った。

3. 結果

3つの手法で測定した結果、良性正解率はMethod 1で60.2%、Method 2で92.6%、Method 3で98.2%だった。悪性正解率はMethod 1で81.2%、Method 2で95.6%、Method 3で98.8%だった。すべての手法の中で、Method 3 が最も正解率が高かった。次に、Method 3 によって分類された代表的な画像と Grad CAM によって得られた Activation Map を示す (Fig.1)。




Fig. 1 Method3 による分類結果と Grad CAM による可視化

Grad CAM により、VGG-16 が画像のどの部位に注目して判断しているのかを明確にした。今回使用した VGG-16 は細胞質が淡く、細胞辺縁が不明瞭な場合、細胞を認識することが困難で良性と判定する傾向があることが判明した。また、細胞を認識した場合は、核 (核クロマチンの増量や核異型の有無) に注目していた。

4. 考察

尿細胞診は実臨床において核クロマチンの増量、核形不整、N/C 比の増大、核偏在、核腫大の 5 所見で判定する (泌尿器細胞診報告様式 2015)。この特徴は肺細胞診にも当てはまることが多い。尿細胞画像のみの学習と比較して、肺細胞画像で学習し、尿細胞画像で Fine-Tuning する方法で正解率が高いことは、新しい発見だった。

細胞質が淡く、細胞辺縁が不明瞭な場合に細胞を認識するこ

とが困難なことが多かったことから、今後、染色性の低下した標本を使用する際に色調補正ができるシステムの構築が必須となる。

尿細胞は変性が起こりやすく、新鮮な肺細胞と比較して悪性細胞との鑑別は容易ではない。そのため、Method 1 では良性細胞の正解率が 60.2%と極めて低い結果になったと推測できた。

尿細胞に限らず細胞診標本上では細胞が集塊状に出現することは多いが、重積性が強く、観察しづらいため、集塊辺縁の細胞で判断することも少なくない。Grad CAM により、Method 2, 3 も同様に細胞集塊の辺縁に注目しており、ヒトによる細胞診での着眼点と類似していた。さらに、Method 3 においては良性正解率が 98.2%、悪性正解率が 98.8%と高い正解率を得た。これは Grad CAM によりある一定の核異型や核クロマチンの増量などにも注目しており、すべての手法の中で実臨床における判定基準に最も近いためと考えられた。

5. 結論

尿細胞診の自動鑑別には、尿細胞画像のみで学習する CNN よりも、肺細胞画像で学習し、尿細胞画像で Fine-Tuning する CNN を使用するとより精度が高い結果を得られることが判明した。

この結果から、異なる臓器から採取した細胞画像を学習に用いることで、画像データ収集が困難な稀少疾患細胞診にも応用できる汎用性の高い手法を構築できる可能性を生み出した。

利益相反の有無

なし

文献

- [1] Teramoto A, Kiriya Y, Tsukamoto T et al: Weakly supervised learning for classification of lung cytological images using attention-based multiple instance learning. Sci Rep. 11; 20317, doi:10.1038/s41593-021-99246-4 2021
- [2] Teramoto A, Tsukamoto T, Yamada A, et al: Deep learning approach to classification of lung cytological images: Two-step training using actual and synthesized images by progressive growing of generative adversarial networks. PLoS One 15, e0229951, 2021
- [3] Vaickus LJ, Suriawinata AA, Wei JW et al: Automating the Paris System for urine cytopathology-A hybrid deep-learning and morphometric approach. Cancer Cytopathol. 127(2):98-115. doi:10.1002/cncy.22099, 2019
- [4] Awan R, Benes K, Azam A, et al. Deep learning based digital cell profiles for risk stratification of urine cytology images. Cytometry A. 99(7):732-742. doi:10.1002/cyto.a.24313, 2021

ホールスライド画像を用いた特発性間質性肺炎の病型自動分類

寺本篤司^{*1}, 道場彩乃^{*2}, 桐山諭和^{*2*3}, 櫻井映子^{*2}, 塚本徹哉^{*2},
今泉和良^{*2}, 齋藤邦明^{*1}, 藤田広志^{*4}

^{*1} 藤田医科大学大学院 保健学研究科

^{*2} 藤田医科大学大学院 医学系研究科

^{*3} 成田記念病院

^{*4} 岐阜大学 工学部

Tissue Type Classification of Idiopathic Interstitial Pneumonia Using Whole Slide Images

Atsushi Teramoto^{*1}, Ayano Michiba^{*2}, Yuka Kiriyama^{*2*3}, Eiko Sakurai^{*2}, Tetsuya Tsukamoto^{*2},
Kazuyoshi Imaizumi^{*2}, Kuniaki Saito^{*1}, Hiroshi Fujita^{*4}

^{*1} Graduate School of Health Sciences, Fujita Health University

^{*2} Graduate School of Medicine, Fujita Health University

^{*3} Narita Memorial Hospital

^{*4} Faculty of Engineering, Gifu University

要旨：原因不明の肺疾患である特発性間質性肺炎は病型によって予後や治療法が大きく異なるため正確な診断が求められている。本研究では、特発性間質性肺炎患者の組織診標本をホールスライドスキャナにて撮影した画像に対し、畳み込みニューラルネットワークによって病型を自動分類する手法を開発した。本研究では特発性間質性肺炎の中でも予後不良な特発性線維症(IPF)と予後が比較的良好な非特異性間質性肺炎(NSIP)の分類を試みた。まず、患者の組織標本をホールスライドスキャナ(Carl Zeiss 社製 Axio Scan Z1)によってスキャンし、得られた画像を 224×224 画素のパッチ画像に分割した。画像の分類には DenseNet 169 を用い、パッチ画像の分類結果を平均することで症例ごとの分類結果を導出した。IPF 患者 8 症例 31727 枚、NSIP 患者 5 症例 28919 枚の画像を用いて Leave-one case-out 交差検証法にて分類したところ、IPF 症例と NSIP 症例の分類正解率は 75%ならびに 60%となり、総合正解率は 69.2%となった。

キーワード：特発性間質性肺炎，病理画像，分類，畳み込みニューラルネットワーク

1. はじめに

肺の間質に炎症や肥厚が生じて呼吸障害が生じる間質性肺炎には 100 種類以上の原因の異なるものが含まれ[1]，その中でも原因不明の特発性間質性肺炎は国の難病にも指定されている。特発性間質性肺炎にもいくつかの病型が存在し，それぞれ適切な治療法が異なるため，早期かつ正確に診断を行う必要がある[2]。診断には CT 検査や肺生検による病理検査が行われるが，それらの検査には豊富な経験を要する。もしこれらの検査で得られた画像を解析することで正確に病型を把握できれば，より正確かつ迅速に安定した診断や治療が可能となる。

ここで，近年注目を集めているディープラーニング技術の中でも畳み込みニューラルネットワーク(Convolutional neural network: CNN)は画像認識処理に高い性能を有することが様々な分野にて確かめられており，間質性肺炎の診断支援技術についても，CNN を応用した方法が多数報告されている。我々はセマンティックセグメンテーション技術の一つである 3D U-Net を用いて特発性間質性肺炎領域の自動抽出と病型の鑑別を行う手法を開発し，75.7%の鑑別精度を得た[3]。

特発性間質性肺炎の鑑別が胸部 CT 検査では困難な場合，生

検によって肺組織を取り出して標本を作製し病理検査を行う。最近では標本全体をスキャンできるホールスライドスキャナが登場し，デジタル画像を用いたソフトコピー診断も行われつつある。

しかし特発性間質性肺炎の病理標本には様々なパターンが含まれるため診断が極めて困難であり，国内でも診断できる病理医に限られているのが現状である。また，特発性間質性肺炎を自動鑑別する技術もまだ研究途上の段階にある。そこで本研究では，ホールスライドスキャナによって撮影された病理画像を対象とした，CNN による特発性間質性肺炎の病型分類手法を提案する。

2. 方法

本研究では特発性間質性肺炎の中でも予後不良な特発性線維症(IPF)と予後が比較的良好な非特異性間質性肺炎(NSIP)の分類手法の検討を行う。本研究の処理フローを図 1 に示す。

本研究で対象とした患者は藤田医科大学病院を受診し，特発性間質性肺炎と診断された 13 名の患者データであり，病型の内訳は IPF が 8 症例，NSIP が 5 症例である。まず，対象患者




図1 本手法の概要図

のガラス標本をホールスライドスキャナ (Axio Scan Z1, Carl Zeiss 社製) にてスキャンし、1 標本につき 1 枚の画像を得た。水平および垂直方向のマトリクス数は数万ピクセルと膨大であるため、組織の存在する部分のみを 224×224 画素のパッチ画像に分割した。その結果、IPF 症例は 31714 枚、NSIP 症例は 28914 枚のパッチ画像が得られた。

それらの画像を分類する CNN には DenseNet169 の事前学習モデルを利用し、フル結合層を 1024-256-2 ユニットの構造に置き換え、IPF と NSIP の 2 分類が可能なモデルを利用した。モデルの評価においては、5 分割交差検証法を用いてすべての画像について分類結果を算出し、画像単位で集計した分類精度と症例単位で分類した精度をもとに評価を行った。なお、これらの処理には、Tensorflow および Keras を利用した Python プログラムを利用し、学習処理には GPU として NVIDIA Quadro RTX 8000 を搭載した PC を利用した。

3. 結果および考察

図 2 に正しく分類された症例と誤って分類された症例の標本全体像を示す。画像単位で評価した結果、IPF の分類正解率は 80.4%、NSIP の分類正解率は 14.6%、総合正解率は 49%であった。一方、症例単位で評価した結果、IPF の分類正解率は 75.0%、NSIP の分類正解率は 60.0%、総合正解率は 69.2%であった。これらの結果より、特発性間質性肺炎の病理画像の分類は局所領域での分類ではなく総合的に判断することが重要であることが示唆された。

4. 結論

本研究では特発性間質性肺炎患者のホールスライド画像において、CNN による病型分類を試みた。評価の結果 70%の鑑別正解率が得られ、本手法の有効性が確認された。

利益相反の有無


なし

文 献


[1] Travis WD, Costabel U, Hansell DM et al. : An Official American Thoracic Society/European Respiratory Society Statement : Update of the International Multidisciplinary Classification of the Idiopathic Interstitial Pneumonias., Am. J. Respir. Crit. Care Med , 188 , 733-748, 2013.

[2] Raghu G, Rochwerg B, Zhang Y et al. : An Official ATS /ERS/JRS/ALAT Clinical Practice Guideline : Treatment of Idiopathic Pulmonary Fibrosis., An Update of the 2011 Clinical Practice Guideline. Am. J. Respir. Crit. Care Med, 192 , 505-509, 2018.


[3] N.Takeuchi, A.Teramoto, K.Imaizumi, K.Saito, H.Fujita, "Analysis of Idiopathic Interstitial Pneumonia in CT Images Using 3D U-Net," Medical Image and Information Sciences, No.38, Vol.3, pp.126-131, 2021.




(a) 正しく判定された IPF 症例



(b) 正しく判定された NSIP 症例



(c) 誤判定された IPF 症例



(d) 誤判定された NSIP 症例

図2 分類正解例と分類失敗例

U-Net を用いた大視野顕微放射光 CT の肺 3 次元マイクロ画像の肺胞壁抽出

栗田 陽生^{*1}, 河田 佳樹^{*1}, 鈴木 秀宣^{*1}, 梅谷 啓二^{*2},
中野 恭幸^{*3}, 阪井 宏彰^{*4}, 岡本 俊宏^{*5}, 仁木 登^{*6}

^{*1} 徳島大学大学院

^{*2} (公財)高輝度光科学研究センター

^{*3} 滋賀医科大学

^{*4} 兵庫県立尼崎総合医療センター

^{*5} クリーブランドクリニック心臓・血管研究所

^{*6} 株式会社医用化学研究所

Extraction of alveolar walls in 3-D lung micro images from large-field microscopic synchrotron radiation CT using U-Net

Haruki KURITA^{*1}, Yoshiki KAWATA^{*1}, Hidenobu SUZUKI^{*1}, Keiji UMETANI^{*2},
Yasutaka NAKANO^{*3}, Hiroaki SAKAI^{*4}, Toshihiro OKAMOTO^{*5}, Noboru NIKI^{*6}

^{*1} *University of Tokushima Graduate School*

^{*2} *Registered Institution for Facilities Use Promotion*

Japan Synchrotron Radiation Research Institute

^{*3} *Shiga University of Medical Science*

^{*4} *Hyogo Prefectural Amagasaki General Medical Center*

^{*5} *Cleveland Clinic Heart and Vascular Institute*

^{*6} *Medical Engineering Institute, Inc*

要旨：肺胞管や肺胞囊の 3 次元マイクロ構造の解明に向けて、肺胞壁抽出を行うことは重要である。本研究の目的は U-Net を用いて肺胞壁抽出の高精度化に取り組み、肺 3 次元マイクロ構造解析に貢献することである。実験では、(1)手動で肺胞壁抽出をして学習データを作成し、(2)これを用いて 2D U-Net^[1]による肺胞壁抽出を行った。(3)2D U-Net による axial, coronal, sagittal の 3 方向の抽出結果を用いて 3 次元学習データを作成し、(4)これを用いて 3D U-Net^[2]による肺胞壁抽出を行った。(5)従来法と U-Net による肺胞壁の抽出精度を比較評価した。この結果、従来法の適合率は 0.868、再現率は 0.903 となった。2D U-Net の再現率は 0.983 となり、従来法と比べて肺胞壁が淡くなっている箇所を高い確率で抽出できた。3D U-Net の適合率は 0.964 となり、アーチファクトの誤抽出が少なくなった。3 次元学習データ数の増加や 3D U-Net の改良により肺胞壁抽出の高精度化がさらに期待できる。

キーワード：U-Net, 肺胞壁, 抽出, CT

1. 背景・目的

本研究の目的は肺胞壁の 1 次中隔と 2 次中隔の分類を行い、肺胞管や肺胞囊の 3 次元構造を解明することである。これを達成するために、本研究室では薄面化処理が施された肺胞壁のラベルデータから、連結成分による交差線、端点、分岐点の解析を行い、1 次中隔と 2 次中隔を分類する方法を示した^[3]。

本報告では、従来の肺胞壁抽出法の精度を上回る手法を述べる。これは 2D U-Net や 3D U-Net を用いた高精度な肺胞壁抽出を開発する。この結果に薄面化処理を施したラベルデータから交差線、端点、分岐点の高精度な分類が可能となると肺胞壁の 1 次中隔と 2 次中隔の分類が高精度かつ簡便に達成することができる。

2. 実験手順

本研究では 3D U-Net に用いる 3 次元学習データの効率的な作成が重要な課題である。本実験では、2D U-Net の axial, coronal, sagittal の 3 方向の抽出結果を用いて 3 次元学習データを作成する。具体的には以下の手順で行った。

- (1) 手塗りで肺胞壁を抽出した 2 次元の画像データを 500 枚 (1 枚のサイズ 256×256pixel)作成し、2D U-Net 用の学習モデルを作成した。
- (2) 3 次元肺マイクロ画像の axial, coronal, sagittal の 3 方向に対し、作成した学習モデルを用いてそれぞれテストを行った。
- (3) (2)で得た 3 つの抽出結果を入力として and, 多数決, or 演算をして出力を得た。

- (4) (3)で得た3つの結果を目視で確認し、3D U-Netに用いる学習データとして or 画像が適切なデータであると判断した。
- (5) 256×256×256pixel サイズに切り出して 3D U-Net の学習データおよびバリデーションデータとした。
- (6) (1)で作成した 500 枚のデータセットの中から 3D U-Net のテストデータとして用いるデータを選び、そのデータが含まれるように 256×256×256pixel サイズで切り出した。
- なお、WL は-850、WW は 400 に固定した。

3. 評価方法

U-Net による肺胞壁抽出を行った後、従来法による肺胞壁の抽出結果、2D U-Net のテスト結果、3D U-Net のテスト結果を比較評価した。手動で作成した正解ラベル画像 500 枚のうち 10 枚を正解画像として、評価指標である正解率、適合率、再現率、F 値を算出した。TP、FP、FN を色分けした画像を図 1 に示す。評価指標だけでなく視覚的評価も示した。




図 1 TP、FP、FN を表示させた画像の例

4. 評価結果

各評価指標の結果を表 1 に示した。

2D U-Net の結果に関して、学習データ数が 256 枚から 490 枚に増加することで正解率、再現率、F 値が向上した。この結果より、肺胞壁抽出の精度が全体的に向上したと判断できる。従来法と学習データ 490 枚の結果を比較すると、再現率は 2D U-Net が高く、肺胞壁が淡くなっている箇所を高精度に抽出できた。

3D U-Net の結果に関して、従来法と 3D U-Net を比較すると、適合率は 3D U-Net が高く、アーチファクトの誤抽出が少なくなった。

2D U-Net と 3D U-Net の結果を比較すると、正解率は 3D U-Net の方が高かった。

表 1 手法ごとの各評価指標の計算結果

	学習データ数	正解率	適合率	再現率	F 値
従来法		0.975	0.868	0.903	0.885
2D	256 枚	0.964	0.983	0.682	0.805
	490 枚	0.966	0.766	0.983	0.861
3D	10	0.968	0.964	0.727	0.829

5. まとめ

学習データ 500 枚の 2D U-Net の学習モデルを用いて、axial, coronal, sagittal の 3 方向に対してテストを行った。これらの結果の論理和を取り、3D U-Net の学習データを作成した。この結果、従来法と比べて再現率は 2D U-Net が高かった。適合率は 3D U-Net が高かった。

肺胞抽出精度向上のための大規模データベースの構築

- (1) 2D U-Net の正解画像の作成
- (2) 3D U-Net の学習データの多数化が課題である。

利益相反の有無

無し

文献

- [1] Olaf Ronneberger, Philipp Fischer, and Thomas Brox: U-Net: Convolutional Networks for Biomedical Image Segmentation, Proc. International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015.
- [2] Ö. Çiçek, A. Abdulkadir, S. S. Lienkamp, T. Brox, and O. Ronneberger: 3D U-Net: learning dense volumetric segmentation from sparse annotation, in International conference on medical image computing and computer-assisted intervention, Springer, pp. 424-432 (2016).
- [3] K. Saito, K. Fukuda, Y. Kawata, K. Umetani, H. Sakai, Y. Nakano, T. Okamoto, N. Niki: Pulmonary alveoli cluster analysis of 3D human lung microstructure using synchrotron radiation micro-CT, Proc. SPIE Medical Imaging, Vol.12036, 127-131, San Diego, Feb.2022.

U-Net を用いた頭部 MRI からの舌領域自動抽出に関する研究

手塚 健太^{*1}, 中村 嘉彦^{*2}, 三上 剛^{*2}, 米澤 一也^{*3}

^{*1} 苫小牧工業高等専門学校 創造工学専攻 専攻科

^{*2} 苫小牧工業高等専門学校 創造工学科

^{*3} 国立病院機構函館病院臨床研究部

Development of automated segmentation method for tongue region from head MRI using U-Net architecture

Kenta TEZUKA^{*1}, Yoshihiko NAKAMURA^{*2}, Tsuyoshi MIKAMI^{*2}, Kazuya YONEZAWA^{*3}

^{*1} Tomakomai College Advanced Engineering Courses

^{*2} Tomakomai College Dept. of Engineering for Innovation

^{*3} National Hospital Organization Hakodate Hospital

要旨：近年、睡眠時無呼吸症候群の診断方法として舌の形状による診断が検討されているが、頭部 MRI から舌の輪郭を医師が手作業で抽出する必要があり、医師の負担が大きい。本研究では、U-Net を用いて 2 次元の頭部 MRI 像から舌領域を自動的に抽出する手法を開発する。医用画像を対象とした学習を行う場合、学習に使う画像の枚数が不足する問題がある。U-Net の構造はエンコーダとデコーダから成り、それらを繋ぐ密なスキップ接続を持つため、学習に必要な画像枚数が少なく、医用画像の学習における問題に対応可能である。U-Net を用いて、52 人分の頭部 MRI から成るデータセットに対し学習を行い、7 枚のテスト画像について本手法を適用し、F 値を用いて評価した結果、平均で 95.1%の精度で舌領域を抽出することができた。現在、U-Net の派生である U-Net++や Ladder-Net の導入を検討している。

キーワード：U-Net, セマンティックセグメンテーション, 睡眠時無呼吸症候群, 頭部 MRI

1. はじめに

現在、睡眠時無呼吸症候群(Sleep Apnea Syndrome: SAS)の診断方法として舌の形状による診断が検討されているが、医師が頭部 MRI から舌の輪郭を手作業で抽出する必要があり、医師にかかる負担が大きい。そこで、畳み込みニューラルネットワーク(Convolutional Neural Network: CNN)を用いた舌領域の自動抽出[1]など、舌領域の抽出を自動化する様々な手法が提案されている。本研究では、医用画像のセグメンテーションに特化したアーキテクチャである U-Net を用いた新たな手法を検討し、舌領域の自動抽出精度を向上することを目的とする。

2. U-Net

本研究では、医用画像の物体検出やセグメンテーションに特化した U-Net[2]を用いて、舌領域の自動抽出を検討する。U-Net のアーキテクチャを図 1 に示す。




図 1. U-Net アーキテクチャ[2]

U-Net の概要について説明する。まず、畳み込み層と全結合層から成り、画像分類を目的として用いられるアーキテクチャである CNN がある。これに対し、CNN の全結合層を畳み込み層に置き換え、すべての層を畳み込み層のみで構成し、セグメンテーションを目的として用いることを可能としたアーキテクチャである完全畳み込みネットワーク(Fully Convolutional Network :FCN)がある。U-Net は、この FCN を医用画像に特化したアーキテクチャである。医用画像を対象とした学習を行う場合、学習に使う画像の枚数が足りないという問題があるが、U-Net は学習に必要な画像枚数が少ないので、この問題点を解決できる。

次に、U-Net は次のような特徴を持つ。

①Encoder – Decoder 構造

②スキップ接続

特徴①の Encoder - Decoder 構造は、アーキテクチャ全体を、入力画像から特徴を抽出する Encoder と、特徴マップの解像度を復元する Decoder に区別した構造である。Encoder では特徴を抽出するとき、プーリングにより特徴マップのサイズが縮小するため、Decoder で特徴マップを拡大する。②のスキップ接続は、Encoder で畳み込みをする前の特徴マップを保持し、Decoder にコピーすることで、解像度復元の精度を上げることを目的とした接続である。U-Net は、Encoder と Decoder の密なスキップ接続により、Encoder で失われた位置情報を補完し、

解像度復元の精度を向上させる。しかし、不完全な特徴マップのスキップ接続により、ノイズが発生する可能性があるという欠点もある。

3. 結果と評価

本研究では、52 人分の頭部 MRI 画像をデータ拡張し、320 枚の学習用データセットと、7 枚のテスト用データセットを用意した。このデータセットに対し、エポック数 100、最適化関数に Adam、損失関数に MSE を用いて学習を行った。更に、optuna を用いてハイパーパラメータチューニングを行い、活性化関数、損失関数、最適化関数を最適化した。

畳み込み層のカーネルサイズを縦横 3, 5, 7 ピクセルとしたときの学習結果をそれぞれ比較した。テスト用データセット 7 枚の内 1 枚の入力画像を図 3、出力画像(正解ラベル, それぞれのカーネルサイズがそれぞれ縦横 3, 5, 7 の時の出力計 4 枚)の例を図 4 に示す。



図 3. 入力画像



(a)正解ラベル (b)3*3 (c)5*5 (d)7*7

図 4. カーネルサイズによるセグメンテーション結果比較

F 値を用いてセグメンテーション制度を評価した。それぞれの評価は次の通りである。

表 1. F 値を用いた精度比較

カーネルサイズ	3*3	5*5	7*7
F 値(平均)	94.8%±0.4	93.2%±2.4	89.7%±0.2

最適化関数を Adam、損失関数を MSE、活性化関数を ReLU、畳み込み層のカーネルサイズを縦横 5 ピクセルとする設定を基準とし、ハイパーパラメータチューニングを行った結果、最適なパラメータとして選択した関数を表 2 に示す。最適化の対象とするパラメータの F 値を比較した結果を表 3 に示す。

表 2. ハイパーパラメータチューニング結果

関数	損失関数	最適化関数	活性化関数
関数名	BinaryCrossentropy	RMSprop	ReLU

表 3. 最適化項目の比較

最適化項目		F 値(平均)	
最適化関数	Adam	94.4%	
	RMSprop	94.8%	
	Adamax	94.7%	
	Nadam	92.5%	
損失関数・活性化関数	ReLU	BinaryCrossentropy	95.2%
		MSE	93.7%
	softmax	BinaryCrossentropy	0.00%
		MSE	0.00%

更に、最適化後のセグメンテーション結果を比較した。最適化前のセグメンテーション結果と最適化後のセグメンテーション結果を図 5、F 値の比較を表 4 に示す。



(a)正解ラベル (b)最適化前 (c)最適化後

図 5. 最適化後のセグメンテーション結果比較
(入力画像：図 3)

表 4. ハイパーパラメータチューニング結果

	最適化前	最適化後
F 値(平均)	93.2%±2.4	95.1%±0.2

結果として、5*5 の畳み込みフィルタを用いる場合、最適化関数に RMSprop、損失関数に BinaryCrossentropy、活性化関数に ReLU を用いると最も精度が高くなることが分かった。

4. まとめ

U-Net を用いて頭部 MRI から舌領域を自動抽出する手法を開発した。その結果、平均で 94.1%の精度で舌領域を抽出することができた。

利益相反の有無

なし

文献

- [1] 櫻田 峻也：畳み込みニューラルネットワークを用いた MRI 画像からの舌領域自動抽出に関する研究，苫小牧工業高等専門学校 特別研究論文，2021 年
- [2] Olaf R, Philipp F, and Thomas B : U-Net : Convolutional Networks for Biomedical Image Segmentation, <https://arxiv.org/abs/1505.04597>, 2015

畳み込みニューラルネットワークを用いた頭部 MRI からの舌の自動輪郭抽出に関する研究

加藤 優弥^{*1} 中村 嘉彦^{*2} 三上 剛^{*2} 米澤 一也^{*3}

^{*1} 国立高等専門学校機構苫小牧工業高等専門学校 創造工学専攻

^{*2} 国立高等専門学校機構苫小牧工業高等専門学校 創造工学科

^{*3} 国立病院機構函館病院臨床研究部

A Study on Automatic Tongue Contour Extraction from Head MRI Using Convolutional Neural Network

Yuya KATO^{*1}, Yoshihiko NAKAMURA^{*2}, Tsuyoshi MIKAMI^{*2}, Kazuya YONEZAWA^{*3}

^{*1} National Institute of Technology, Tomakomai College Advanced Engineering Courses

^{*2} National Institute of Technology, Tomakomai College Dept. of Engineering for Innovation

^{*3} National Hospital Organization Hakodate Hospital

要旨：睡眠時無呼吸症候群の診断において頭部 MRI から舌の輪郭を抽出し、その形状から患者の重症度診断を行う手法が検討されている。しかし、そのためには頭部 MRI から抽出した舌の輪郭が必要になり、現状、頭部 MRI から舌領域の輪郭を抽出するには、医師が舌の輪郭を手作業で入力しなければならない。そこで医師の負担軽減を目的とし、畳み込みニューラルネットワークを用いた 2 次元の頭部 MRI からの舌の自動輪郭抽出に関する研究を行った。学習済みのモデル VGG16 を用いて頭部 MRI のデータについて転移学習を行うことで、舌領域と非舌領域の分類モデルを学習する。学習したモデルを用いて、頭部 MRI からの検出領域を移動させながら舌領域を判定し、検出領域の中心画素を舌領域として抽出することで、舌を輪郭抽出する。

キーワード：畳み込みニューラルネットワーク、転移学習

1. はじめに

睡眠時無呼吸症候群(Sleep apnea syndrome, SAS)とは、睡眠時に低呼吸または無呼吸になる疾患である。SAS の症状になると、睡眠中に酸素を取り込む量が減少する為、人体に悪影響を及ぼす可能性がある。SAS の診断方法に、頭部 MRI から舌の輪郭を抽出しその形状から SAS 患者の重症度の診断を行う方法が検討されている[1]。しかし、この方法で診断を行うには頭部 MRI から抽出した舌の輪郭が必要になる。現在、頭部 MRI から舌領域を切り出すには、医師が舌の輪郭を手作業で入力しなければならないため、SAS の診断を行う医師の負担を軽減させるには自動的に輪郭を抽出する方法が必要である。

医師の負担を軽減し、かつ、SAS の診断を容易に行うためには高い精度で MRI 画像中から舌領域を自動的に抽出する必要がある。CNN を用いたランダムな位置の検出領域で舌領域を抽出する手法では、舌領域の判別率は 75%であった[2]。

本研究では畳み込みニューラルネットワーク (Convolutional neural network, 以下 CNN) を用いた画像分類による頭部 MRI からの舌領域の自動輪郭抽出手法の研究を行った。

2. 原理

2.1. 畳み込みニューラルネットワーク

CNN は、画像分析を行うための学習手法の 1 つで、画像の一部が見えにくくなっているような画像でも解析することが出来る。

このネットワークは、「畳み込み層」や「プーリング層」などの特徴的な機能を持った層を積み重ねて構成されている。

畳み込み層では、画像に対してフィルタを適用していき、画像の特徴量を抽出することが可能である。最適化が必要な重みパラメータの数は、画像のサイズではなくフィルタのサイズに依存するため、画像のサイズが大きくなってもパラメータ数は増大しない。

また、プーリング層では、画像サイズを縮小し計算コストを軽減させることや、各領域内の位置の違いを無視することで、小さな位置変化に対して頑健なモデルを構築することが可能である[3]。

また、畳み込みニューラルネットワークは画像の分類にも用いられており、MRI の医用画像処理に応用されている例も存在する[4]。

2.2. 転移学習[5]

本研究で対象とする頭部 MRI のようなグレースケール画像は、カラー画像に比べ表現できる情報量が少ない他、医療データは個人情報であるため、畳み込みニューラルネットワークにより学習させるための画像を大量に準備することが困難である。そこで、本研究では転移学習を用いる。

転移学習は、学習済みモデルの出力部に全結合層を追加して出力部のみを再学習する手法である。タスクの仮説立てを行う上で、別のタスクですでに学習された知識を転用し、仮説立てを行わせることができる。

大量のデータと学習にかかる時間を大幅に削減できる他、分類したい画像のデータセットが小さくても画像認識を行うことができるという特徴がある。

3. 研究手法

3.1. 学習・テストデータの作成

本研究では、59人分の頭部MRIを2つに分割しセットA・Bとし、学習とテストを交互に行い、抽出に使用するしきい値の評価を行った。

まず、分類精度向上のため、前処理として頭部MRIの画素を正規化した。また、舌に近い部分の抽出のため特徴部位(鼻、後頭部、顎)を検出した。

その後、舌領域を示すマスクング画像を元に、頭部MRIから224×224[pixels]で舌領域・非舌領域をトリミングし、それらを1人分の頭部MRIにつき舌領域10枚・非舌領域30枚となるように繰り返し、学習・テストデータを作成した。データ例を図1に示す。左図(A)が舌領域、右図(B)が非舌領域のデータである。




図1(A)(B) 切り出した舌領域、非舌領域の例

3.2. 転移学習・モデルの生成

本研究では、ImageNetというデータセットを学習済みのモデルであるVGG16を用いて転移学習を行う。ImageNetは1400万枚以上からなる一般画像認識用のデータセットで、2万カテゴリの画像がある[4]。

学習の繰り返し回数(エポック数)を20に設定して頭部MRIの学習を行い、舌領域判定用の学習モデルを生成した。

3.3. 舌領域の抽出

テストデータである頭部MRIに対して、検出領域を8[pixels]ずつ移動させながら舌領域か非舌領域かを判定する。イメージを図2に示す。各検出領域において、舌領域と判定された場合、検出領域の中心画素を舌領域として抽出する。



図2 検出領域を移動させるイメージ

なお、本研究では舌領域かどうかを判定するしきい値を0(最も舌と認識しやすい)~1(最も舌と認識しにくい)の範囲で100分割し、徐々に数値を上昇させていくことで画像とマスクング画像の比較をする。また、各しきい値について比較結果をF値として出力する。

4. 結果

セットA・Bそれぞれにおける、F値がもっとも高かったし

きい値での、抽出画像とマスクデータの比較結果を図3(A)(B)に示す。ここで、左図(A)は学習をA・テストをBで行った場合、右図(B)は学習をB・テストをAで行った結果である。

ここで、画素の各色は白がマスクデータ上での舌領域の画素、黒が非舌領域の画素、赤が抽出結果の画素をそれぞれ示している。



図3(A)(B) 抽出画像とマスクデータの比較結果

図3(A)においては、しきい値を0.01に設定した場合のF値が最も高く、0.738であった。

また、図3(B)においては、しきい値を0.2に設定した場合のF値が最も高く、0.648であった。

5. 考察

図3(A)と図3(B)を比較した際、F値が一番高い場合のしきい値が(A)では0.01、(B)では0.2と異なっている。このことから、特に舌領域において、2つのデータ間で学習にばらつきがあったと考えられる。

また、特に図3(A)において、輪郭付近が抽出できていないことがわかる。このことから、輪郭付近の学習データが不足していると考えられる。

6. まとめ

本研究では、舌領域の自動輪郭抽出手法の研究を行った。現状、舌領域の抽出までは完了しているが、特に輪郭付近の精度において課題がある。

今後の課題としては、学習の際に舌領域の輪郭を多く学習していく必要がある他、現段階では舌の輪郭抽出まで及んでいないため、輪郭を抽出した上で、結果を考察する必要があると考えている。

利益相反の有無

なし

文献

- [1] 三上 剛, 他: "重度の閉塞型睡眠時無呼吸症候群の鑑別を目的とした上気道MRIの画像解析とその有用性", 医用画像情報学会雑誌 31(1), 13-18, 2014
- [2] 櫻田 峻也, 他: "畳み込みニューラルネットワークを用いたMRI画像からの舌領域自動抽出に関する研究", 苫小牧高専専攻科特別研究, 2020
- [3] 太田 満久, 他: 現場で使える!Tensorflow 開発入門 Keras による深層学習モデル構築手法, 翔泳社, pp.107-110, pp.123, pp.135-144, 2018
- [4] Z. Cui, et al.: "Brain MRI Segmentation with Patch-based CNN Approach", 2016 35th Chinese Control Conference (CCC), pp. 7026-7031, 2016
- [5] S. J. Pan, et al.: "A Survey on Transfer Learning", IEEE Transactions on Knowledge and Data Engineering, vol. 22, no. 10, pp. 1345-1359, 2010
- [6] 木村 優志: 現場で使える!Python 深層学習入門 Python の基本から深層学習の実践手法まで, 翔泳社, pp.308, 2019

3D 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

^{*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 U-Net

Daiki HIRAOKA^{*1}, Koshiro NISHIMOTO^{*2}, Hotaka TAKIZAWA^{*3}, Hiroyuki KUDO^{*3}

^{*1} *Master's Program in Computer Science, University of Tsukuba*

^{*2} *Saitama Medical University International Medical Center*

^{*3} *Faculty of Engineering, Information and Systems, 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や、成功率が低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 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、学習時には回転や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、3D 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、手技の難易度が高い。また、検査に時間がかかるため、多数検査を行うことも難しい。そのため、副腎静脈サンプリングを補完する方法として、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。本報告では 3D U-Net[2]を用いて半自動的に領域抽出する手法を提案する。

2. 方法

1) 学習段階

学習に用いる画像中の副腎領域を手動でラベル付けし、その画素から両方の副腎と片方の副腎それぞれの重心を算出し、その重心を用いて2種類の関心領域の画像を作成する。

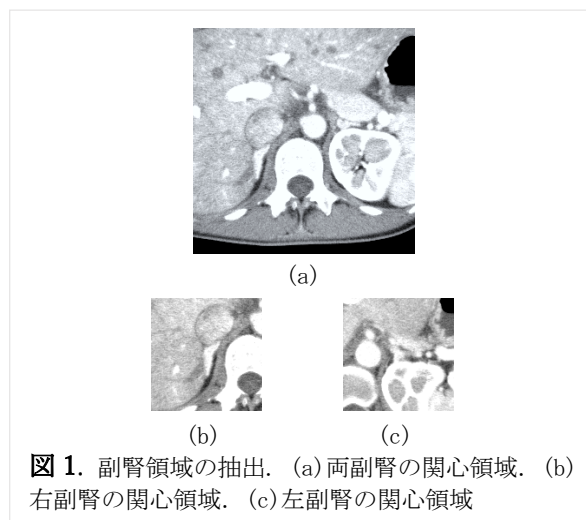


図 1. 副腎領域の抽出。(a)両副腎の関心領域。(b)右副腎の関心領域。(c)左副腎の関心領域

1つ目は両方の副腎の重心を中心として $256 \times 256 \times 16$ の画像を作成する(図 1 (a)参照)。2つ目は左右別で求めた重心を中心として $128 \times 128 \times 16$ の画像をそれぞれ作成する(同図(b)と(c)参照)。

次に学習画像の前処理として以下の3つの正規化を行う(図 2 参照)。

(i) $\mu=127$, $\sigma=2 \times$ (各画像の画素値分布の標準偏差)

で正規化.

(ii) μ =すべての画像の画素値の平均, σ = (i)と同じで正規化.

(iii) $\mu = 2 \times (\text{全体平均}) - \text{各症例の平均画素値}$, $\sigma = (i)$ と同じで正規化.

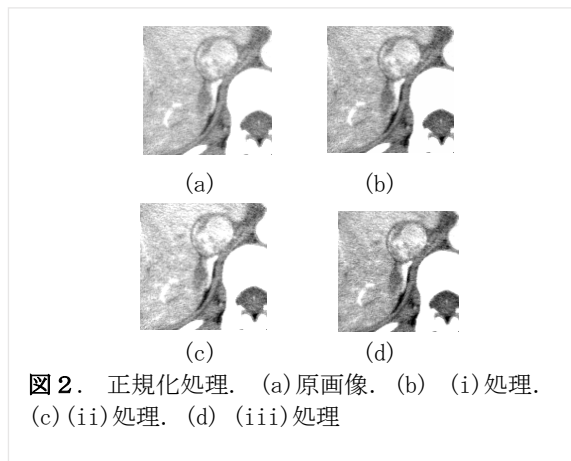


図2. 正規化処理. (a)原画像. (b) (i)処理. (c) (ii)処理. (d) (iii)処理

2) テスト段階

1)で作成した画像を学習データとして 3D U-Net で学習を行い, テスト画像を入力することで副腎領域を抽出する.

3. 実験

本研究では, 腹部 CT 画像 49 症例に 10-fold cross validation を適用した. 精度評価に IoU を用いた. 3D U-Net に用いるパラメータはエポック数を 100, バッチサイズを 1 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

表 1 に実験結果を示す. 関心領域のサイズを変更する実験では, 右副腎は片方だけ, 左副腎は両方学習した場合の精度が高かった. また, 正規化に関しては, 右副腎では (i), 左副腎では (ii) の手法が最も高い精度を示した. また, 図 3 に関心領域別の IoU の評価の 1 例を示している. この実験例に関しては, 右副腎では, 片方だけで学習を行った手法の精度が高いのに対し, 左副腎に関しては, 精度が下がった.

今後の課題はマルチチャンネル化[3]を用いた臓器領域抽出の精度向上などがある.

表 1: 評価結果

	右副腎	左副腎
両副腎関心領域	0.402	0.442
片副腎関心領域	0.478	0.411
正規化 (i)	0.364	0.452
正規化 (ii)	0.366	0.482
正規化 (iii)	0.523	0.407

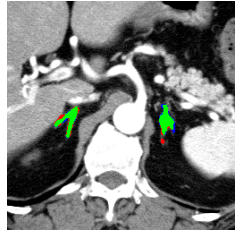
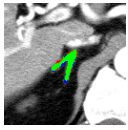
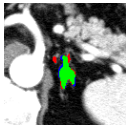
両副腎	右副腎	左副腎
		
右:0.4024, 左:0.4426	0.4784	0.4113

図 3 関心領域を変更した実験結果の比較

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] Ozgun Cicek, Ahmed Abdulkadir, Soeren S. Lienkamp, Thomas Brox, and Olaf Ronneberger 「3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation」 MICCAI, p424-432, 2016.
- [3] Ayano Fujinaka, Kojiro Mekata, Hotaka Takizawa, Hiroyuki Kudo 「Segmentation of cervical intervertebral disks in videofluorography by CNN, multi channelization and feature selection」 IJCARS, Vol.16, No.4, pp.1-8. 2020.

Expanded tube attention module を用いた tubular structure segmentation

加藤 聡太^{*1}, 堀田 一弘^{*2}

^{*1} 名城大学大学院 理工学研究科 電気・情報・材料・物質工学専攻

^{*2} 名城大学 理工学部 電気電子工学科

Expanded Tube Attention for Tubular Structure Segmentation

Sota KATO^{*1}, Kazuhiro HOTTA^{*2}

^{*1} Graduate School of Science and Engineering, Meijo University

^{*2} Faculty of Engineering, Meijo University

要旨: 血管や細胞膜などの検出を行う際、管状ネットワーク構造を持つセマンティックセグメンテーションは難易度が高く、予測が途切れる箇所が発生しやすい。これは教師ラベルが非常に細く、背景と比較して画素数が極端に少ないことが原因の一つであると考えられる。そこで本研究では、元の教師ラベルよりも太い領域を持った擬似教師ラベルを用いた新しい学習方法を提案する。擬似教師ラベルを応用した Expanded Tube Attention module (ETA module)を用いることにより、予測の初期段階は擬似ラベルに基づいた太い領域を学習し、太い領域の情報を Attention map として伝達しながら、徐々にオリジナルの予測領域を学習する。その結果、ネットワーク状構造のセグメンテーションにおいて、Easy-to-Hard learning を実現することが可能となる。眼球画像のセグメンテーションデータセットを用いた実験から、様々な評価指標において提案手法は従来手法と比較して精度が改善することを確認した。

キーワード: 深層学習, セマンティックセグメンテーション, クラス不均衡, 注意機構, モルフォロジー変換

1. はじめに

画像の各画素にクラスラベルを割り当てるセマンティックセグメンテーションは、医療や細胞生物学分野の画像解析において重要な課題である。その中でも、細い管状ネットワーク構造をもつ画像に対するセグメンテーションは非常に難しい課題であり、線が途切れてしまう箇所が多く発生する傾向にある。予測が途切れてしまうと物体としての意味をなさず、解析が非常に困難になる。そこで本研究では、このような細い管状ネットワーク構造のセグメンテーション精度の改善を目的とする。提案手法では、検出領域と背景領域の画素数の不均衡さに着目し、古典的なモルフォロジー変換を用いた教師ラベルの拡張法を提案する。さらに、この擬似教師ラベルの情報を応用した Attention module を用いた学習法を提案する。これにより、初期段階では元の教師ラベルよりも簡単な領域を学習し、徐々に予測領域を狭めていくことにより学習の難易度を上げていく Easy-to-Hard learning が可能となる。また Attention module により簡単な領域から獲得できる情報を伝達しながら学習することにより予測の途切れを抑えることが可能となる。

2. 関連研究

上述した問題点に対し、モデル構造を改良して精度を改善する研究[1]が進められてきた。しかし、これらは計算コストが増加する傾向がある上、十分な精度は達成していない。近年では、トポロジーの概念を用いた学習手法が提案されている [2]。しかしこれらは学習方法が非常に難しく、学習の安定化や手法の簡素化が課題として挙げられる。これに対し、本研究で提




図1 モルフォロジー変換の例

案する Attention module は通常のネットワークと同様の学習が可能であり、また既存のネットワークモデルへの応用も容易であるため、汎化性に優れた手法である。

3. 提案手法

識別領域に対する教師ラベルは非常に細く、背景領域と比較してラベルの画素数が極端に少ないクラス不均衡の状態にある。そこで本研究では、モルフォロジー変換により細い領域の面積を膨張させた膨張教師ラベル画像を新たに作成する。図1に示すように、モルフォロジー変換は領域の細さを自由に調整することが可能であり、様々な細さの領域を持つ疑似教師ラベル画像を作成することが可能である。この疑似教師ラベル画像を学習に用いることにより、ネットワークはオリジナルの教師ラベルよりも太い領域を学習することができ、学習時のクラス不均衡を緩和することが可能である。

表 1 定量評価結果

	DRIVE				
	Accuracy	Sensitivity	DSC	cDice	AUC
従来手法	96.27±0.09	74.78±1.92	77.83±0.85	78.33±1.34	97.64±0.27
提案手法	96.42±0.06	79.04±1.72	79.47±0.10	80.98±0.39	97.77±0.04




図 3 定性評価結果

ことが分かり, ETA module の有効性を確認することができた. 特に DSC や cDice などの, 血管領域の精度に対して厳しく働く評価指標において, DSC では平均 1.64%, cDice では平均 2.65%精度が改善していることが分かる.

図 3 に定性評価の結果を示す. 図 3 から, 従来手法では検出できていない血管領域や途中で途切れてしまった予測領域が存在しているが, 提案手法を用いることにより予測の途切れを改善することができている. これは, ETA module により太い予測領域の繋がった情報が, 細い領域の予測に対して有効に働いている結果であると考えられる.

5. おわりに

本研究では, 管状ネットワーク構造を持つセマンティックセグメンテーションにおいて有効な学習方法を提案し, その有効性を確認した. 今後は細胞画像からの細胞膜検出や, 航空画像からの道路検出など, 管状ネットワーク構造をもつ他分野のデータセット等でも同等の結果を得ることができると確認したいと考えている.

文 献

- [1] Sun, J, et al: Saunet: Shape attentive u-net for interpretable medical image segmentation. In International Conference on Medical Image Computing and Computer-Assisted Intervention, Springer, Cham, 2020, pp. 797-806
- [2] Wang, F, et al: Topogan: A topology-aware generative adversarial network. In European Conference on Computer Vision, Springer, Cham, 2020, pp. 118-136
- [3] Shit, S, et al: cDice-a novel topology-preserving loss function for tubular structure segmentation. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021, pp. 16560-16569.

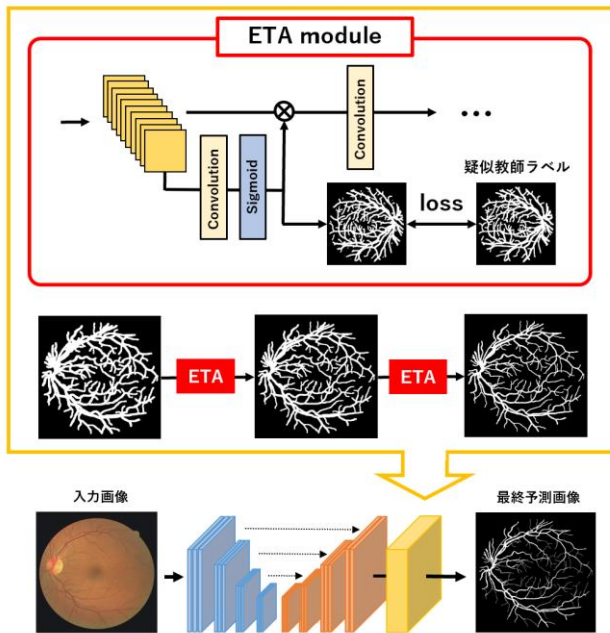


図 2 ETA module を用いた提案手法の概要図

しかし予測領域は太い状態であるため, ここで新たに図 2 に示すような Expanded Tube Attention (ETA) module を提案する. 細さの異なる疑似教師ラベル画像を用いた学習を複数回繰り返す, 徐々に予測領域をオリジナルの教師ラベルの細さに近づけていく. この時, 太い予測領域を Sigmoid 関数で正規化し, Attention map として特徴マップに重みづけした後, 次の段階の予測領域の学習に使用する. これにより太い予測領域から獲得できる途切れない情報を次の予測で利用できるため, 最終的な予測領域の途切れ箇所を減少させることが可能である.

4. 評価実験

実験では Digital Retinal Images for Vessel Extraction (DRIVE) データセットを用いた. これは血管領域のクラスとそれ以外の領域のクラスを識別する 2 クラスのセグメンテーションであり, 学習画像が 20 枚, テスト画像が 20 枚存在する. オリジナルの画素数は 584×565 であるが, 本研究では扱いやすくなるため 592×592 にリサイズして使用した. 学習では, 画像増強として画素数 256×256 のランダムクロップ, 水平・垂直方向の反転, 画像回転を使用した. 学習回数は 300 回であり, 最適化手法には Adam を用いた. 学習率は 0.001 である. ネットワークには U-Net を使用し, ETA module がある場合とない場合を比較した. また評価指標には[3]を参考に Accuracy, Sensitivity, DSC, cDice, AUC を用いた. 乱数の初期値を 3 回入れ替えて実験を行い, 3 回の平均で評価した.

表 1 に検証実験の定性評価の結果を示す. 表 1 から, 全ての評価指標において従来手法よりも提案手法の方が精度が高い

カラー腹腔鏡符号化画像のセマンティックセグメンテーションにおける評価に関する基礎的検討

河畑 則文^{*1*}, 中口 俊哉^{*3}

^{*1} 北海道大学数理・データサイエンス教育研究センター

^{*2} コンピュータイメージングラボ

^{*3} 千葉大学フロンティア医工学センター

Evaluation on Semantic Segmentation of Color Laparoscopic HEVC Images

Norifumi KAWABATA^{*1*}, Toshiya NAKAGUCHI^{*3}

^{*1} Education and Research Center for Mathematical and Data Science, Hokkaido University

^{*2} Computational Imaging Lab

^{*3} Center for Frontier Medical Engineering, Chiba University

要旨：医用画像診断支援を行う上で、医用画像の認識・理解・評価を行う前処理として、効率の良いかつ精度の高い領域分割を行うことは重要である。領域分割の一つとして、深層畳込みニューラルネットワークを用いたセマンティックセグメンテーションがある。先行研究では、セマンティックセグメンテーションの設計や性能に関する研究が行われてきた。これらの多くは、ニューラルネットワークや領域分割に関するパラメータを変化させたものが多く、それらが必ずしも医用画像の特徴量や画像品質といった環境・使用条件に適しているとはいえなかった。そのため、医用画像における画像品質とセマンティックセグメンテーションとの関係は明らかではない。本研究では、画像符号化や分割手法などの複数の条件に基づいて医用画像に適したセマンティックセグメンテーションを設計することで、カラー腹腔鏡画像のセマンティックセグメンテーションにおける評価についての考察を行った。
キーワード：HEVC 符号化, セマンティックセグメンテーション, ラベリング, 精度, 損失関数

1. まえがき

2010年代以降の医用画像工学分野においては、人工知能を積極的に活用した医用画像処理に関する研究が進められており、特に、深層畳込みニューラルネットワークを用いて効率の良いかつ精度の高い領域分割に関して議論されてきた。しかしながら、医用画像を扱う環境や条件が異なれば、領域分割の精度が必ずしも高くなるとは限らず、適切なアルゴリズム設計を行うことが重要である。筆者は先行研究として3DCG画像のセマンティックセグメンテーションのためのスキーム [1]や、カラー腹腔鏡画像の診断支援を目的とした領域分割に関する検討 [2]を行ってきた。しかしながら、多次元情報を含む画像においては、領域分割の精度が十分ではなく、特に、医用画像の画像品質とセマンティックセグメンテーションとの関係は明らかではなかったので検証する必要がある。

本稿では、カラー腹腔鏡符号化画像に適したセマンティックセグメンテーションについて設計を行い、最終的に、テストセットと訓練セットの評価を行うことで、考察を行った。

2. 関連研究

関連研究として、画像劣化を考慮したセマンティックセグメンテーション [3]や U-Net を用いた領域分割手法 [4]が見られる。本研究では、カラー腹腔鏡画像における画像符号化とセマンティックセグメンテーションの関係性を明らかにしていく。

3. セマンティックセグメンテーション

3.1. 本研究で使った医用画像

本研究で使った医用画像は、図1に示すように、内視鏡に




図1：本研究で使った医用画像

より取得した、肝臓と胃の周辺を撮影した腹腔鏡下手術動画像(約15秒間)をフレーム画像として切り出したものである。

なお、使った動画像は特定の治療行為は行っていない。

3.2. 実験手順

実験手順を以下に示す。

- (a). まず、腹腔鏡下手術動画像(以下、腹腔鏡静止画像または動画像)をフレーム静止画像として切り出し処理を行う。

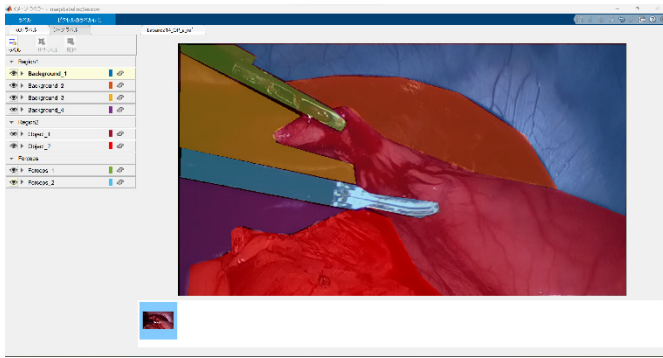


図 3 : 領域分割のためのラベルの作成

本研究では、全部で 426 枚を切り出した。

- (b). 次に、フレーム静止画像として切り出した 426 枚の腹腔鏡画像 (1280 × 720 (pixels)) に対して、本研究では、1 フレーム目のフレーム静止画像を選択する。
- (c). 1 枚(214 フレーム)の画像に対して、画像全体に、HEVC 符号化を行う。ここで、量子化パラメータ (Quantization Parameter: $Q = ref, 20, 25, 30, 35, 40, 51$) を 7 通り設定して符号化処理を行う。H.265/HEVC 符号化させた画像セットをテスト画像として準備する。
- (d). 腹腔鏡画像データにラベルを付ける。本研究では、図 2 に示すように、MATLAB R2022a の Computer Vision Toolbox に搭載されているイメージラベラー (Image Labeler)を用いてラベリング処理を行う。
- (e). テスト (テスト画像とラベル画像)、訓練 (訓練画像とラベル画像) のセットを読み込み、バッチサイズにする。
- (f). セマンティックセグメンテーションの一種である U-Net を用いてネットワークを学習させ、訓練を 10 回行う。
- (g). 最後に、ネットワークの精度を評価する。本研究では、モデルの精度と損失関数を用いて評価を行う。

3.3. 実験方法と評価方法

MATLAB R2022a を用いて領域のラベル付けを行い、Anaconda 2022.05 の Python 3.7.13 によりプログラムを作成し、U-Net によるネットワーク学習により、実験及び評価を行った。

4. 実験結果と考察

実験結果を図 3 (accuracy), 4 (loss)に示す。実験結果から、エポック数が上がるほど、accuracy は上昇し、10 回を終える頃には 100%近くまで達しており、学習効果が見られた。また、損失関数については、エポック数が上がるほど、loss は減少し、10 回を終える頃には 0.5 付近まで減少が見られた。このことから、領域分割に適用可能だと示唆された。

5. まとめ

本研究から、U-Net を用いた領域分割がカラー腹腔鏡画像の符号化セットにも対応可能で有効性が示された。今後の展望と




図 2 : 実験結果 (model accuracy)




図 4 : 実験結果 (model loss)

して、より詳細な医用画像解析を進めていく。

謝辞

本研究の一部は、千葉大学フロンティア医工学センターの協力の下で実施されたので、感謝します。

利益相反の有無

本研究を行うにあたっての利益相反は無い。

文献

- [1]. N. Kawabata: "Data Set Production and Evaluation for Semantic Segmentation of 3D CG Images by H.265/HEVC," *Proc. of The Eleventh International Workshop on Image Media Quality and its Applications (IMQA2022)*, SO-4, pp.107–113, Kyoto, Japan, Mar. 2022.
- [2]. N. Kawabata and T. Nakaguchi: "Laparoscopic Image Region Segmentation Based on Texture Analysis by Regions," *Proc. of The Tenth International Workshop on Image Media Quality and its Applications (IMQA2020)*, PS2-4, 6 pages, Taiwan, Mar. 2020.
- [3]. D. Guo et al., "Degraded Image Semantic Segmentation With Dense-Gram Networks," *IEEE Trans. on Image Processing*, Vol.29, pp.782–795, 2020.
- [4]. E. Thomas et al., "Multi-Res-Attention UNet : A CNN Model for the Segmentation of Focal Cortical Dysplasia Lesions from Magnetic Resonance Images," *IEEE Journal of Biomedical and Health Informatics*, Vol.25, No.5, pp.1724–1734, May 2021.

Encoder-decoderCNN を用いたパッチベース型 MR 画像再構成に関する検討

佐藤 裕貴^{*1}, 山登 一輝^{*1}, 大内 翔平^{*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

Study on Patch-based MR Image Reconstruction Using Encoder-decoder CNN

Yuki SATO^{*1}, Kazuki YAMATO^{*1}, Shohei OUCHI^{*1}, Satoshi ITO^{*1}

^{*1} *Utsunomiya University Graduate School of Regional Development and Creativity*

要旨：畳み込みニューラルネットワーク(CNN)による画像空間での MR 画像の再構成において、CNN の層数を変化させると受容野が変化し、画像をパッチ化すると抽出できる特徴の大きさが変化する。本研究では再構成像の品質を改善するために、Encoder-decoderCNN である U-Net を使用し、受容野やパッチサイズと再構成像の品質との関連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、フルサイズの画像で学習する場合よりも適したパッチサイズの画像で学習すること、および、U-Net の層数をパッチサイズごとの適した受容野に合わせることで再構成像の画質を改善できることが示された。さらに、本知見を応用し、学習中にパッチサイズを切り替える新たな方法を提案し、再構成シミュレーションを行った。その結果、再構成像の品質をさらに改善できる可能性が示された。

キーワード：深層学習, 受容野, パッチベース, MRI

1. はじめに

MRI の課題は撮像時間の長さである。医療現場では高画質な画像が必要になるが、高画質な画像を得るためには撮像を長時間行わなければならない。MRI の撮像時間を短縮する方法として、圧縮センシングや深層学習を利用して少数の信号から MR 画像を再構成する研究が行われている。これにより収集する信号を削減でき撮像時間を短縮することができるが、不自然な画像になる場合があることや反復的な再構成は再構成に時間を要する課題などがある。畳み込みニューラルネットワーク(CNN:Convolutional Neural Network)による画像空間での MR 画像の再構成は、CNN の構造が単純である点や CNN のパラメータの最適化が容易なため多数の手法が提案されている[1]。しかし、CNN の受容野に関する検討は少なく、受容野と再構成性能との関係は明らかではない。本研究では Encoder-decoderCNN である U-Net[2]を用いて、MR 画像の再構成を行った。学習画像のパッチサイズや受容野ごとで再構成結果の比較を行い、パッチ化や受容野についての検討を行った。

2. CNN の受容野とステージ数

受容野とは感覚器官を通じて刺激の情報に対する信号が伝達するとき、ニューロンが信号に対して反応することができる範囲のことを呼ぶ。CNN では最小サイズの出データに、影響を与える入力範囲を受容野といえる。

ステージ数 4 の U-Net を図 1 に示す。本研究では U-Net の内部で同じサイズの特徴マップを扱う層を一つのステージと考える。ステージ数により U-Net の内部の特徴マップのサイズの変化が決まるため、入力データのサイズに制限がある。

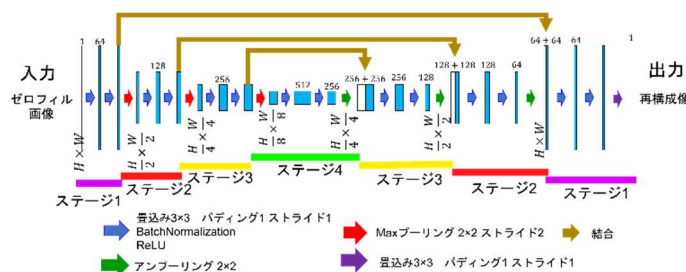


図 1 ステージ数 4 の U-Net

4. シミュレーション条件

使用した MR 画像は、IXI-dataset[3]に含まれる、Philips 社製 MRI (1.5T) によって撮像された 256×256 の頭部プロトン密度強調像である。学習、検証、テスト用にそれぞれ 100 枚、40 枚、40 枚を使用した。パラメータ更新手法に Adam, 損失関数に平均二乗誤差, 学習係数は 1×10^{-3} に設定した。表 1, 2 に学習条件を示す。CNN の学習および画像再構成に MATLAB2021a を使用した。また CPU に IntelCorei7-7700, GPU に GTX1050Ti を用いて学習及びテストを行った。再構成像を評価するために、PSNR(Peak Signal-to-Noise Ratio)と SSIM(Structural SIMilarity index)を使用した。信号空間のデータサイズは、256×256 とし、信号収集はカルテシアン軌道とし、信号空間の中心 50 行を連続収集するものを使用した。また、使用した信号間引きパターンの信号収集率と信号収集分布を図 2 に示す。

表 1 CNN のステージ数とパッチサイズの関係

ステージ数	2	3	4	5	6
パッチサイズ	10	8	5	2	

表2 パッチサイズ, パッチ化ストライド, エポック数の関係

パッチサイズ	16	32	64	128	256
パッチ化ストライド	5	11	23	43	—
エポック数	100				200




図2 使用したサンプリングパターン(信号収集率 40%)

5. 学習時にパッチサイズを変更する学習方法

表3に学習時にパッチサイズを変更する場合のパッチサイズとストライドとパッチサイズの関係を示す。フルサイズは10エポック学習し、5エポックごとにフルサイズからパッチサイズを16ずつ小さくする。パッチサイズが16まで小さくなら、またフルサイズから徐々にパッチサイズを小さしていく。これを170エポックまで行った。このシミュレーションはCPUにIntelCore i7-11700k, GPUにRTX3080を用いて学習及びテストを行った。

表3 パッチサイズとストライドとパッチサイズの関係

パッチサイズ	16	32	48	64	80	96,112	128~240	256
パッチ化ストライド	5	11	17	23	29	31	43	-
パッチサイズ	4900	700	169	324	100	50	25	10

6.再構成シミュレーション結果

図3に再構成結果のPSNR, SSIM, 図4に再構成像を示す。パッチサイズが大きいほど最も高いPSNR, SSIMを示すステージ数が大きくなった。パッチサイズを切り替えた場合(256~16)が最もPSNR, SSIMが高く、単一のパッチサイズでは64x64の条件で最もPSNR, SSIMが高くなった。

7. 考察

パッチサイズが大きくなるにつれてPSNR, SSIMが最も高くなるステージ数が大きくなる傾向がある。これは入力する画像のサイズに適した受容野があり、適した受容野からずれるにつれて特徴を抽出しにくくなるためだと考える。学習中




図3 パッチサイズ, ステージ数とPSNR, SSIMの関係




図4 再構成像比較

(a)目標画像, (b)再構成像(パッチサイズ256, ステージ数5), (c)再構成像(パッチサイズ64ステージ数4),

(d)再構成像(パッチサイズ切り替え)

にパッチサイズを切り替えた場合のPSNR, SSIMが最も高く、次にパッチサイズが32と64の場合のPSNR, SSIMが高くなった。これはパッチサイズを切り替えることで異なる特徴を抽出しやすくなるためだと考える。フルサイズが256の場合にパッチサイズ32や64の大きさが特徴を抽出しやすいと考える。

8.まとめ

U-Netを用いたMR画像の再構成を行った結果、フルサイズの画像で学習を行うよりも、適したパッチサイズでパッチ化を行うこと、ステージ数をパッチサイズごとの適した受容野に合わせることで、および、エポックごとにパッチサイズを調整することの3点により再構成画像の品質を改善できることが示された。

謝辞

本研究の一部は、科学研究費助成金(19K04423)により実施された。また、本研究を遂行する際に利用したIXIDatasetを提供するInformationeXtractionfromImagesプロジェクトに感謝の意を表します。

利益相反の有無

なし

文献

- [1] S.Ouchi et al.,Magn Reson Med Sci 20: 190-203, 2021
- [2] Olaf Ronneberger, P.Fischer, T.Brox, Medical Image Computing and Computer-Assisted Intervention 9351:234-241, 2015
- [3] "IXIdataset,"<https://brain-development.org/ixidataset/>

フレネル変換画像のアンサンブル学習による MR 圧縮センシング再構成の性能改善

阿部 真弥^{*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

Improvement of MR Compressed Sensing Reconstruction
Using Ensemble Learning of GANs with Fresnel Transformed Images

Shinya ABE^{*1}, Kazuki YAMATO^{*1}, Satoshi ITO^{*1}

^{*1} Utsunomiya University, Graduate School of Regional Development and Creativity

要旨：近年，深層学習を利用した MR 圧縮センシング再構成法の研究が注目されている．様々な方法が提案されている中に敵対的生成ネットワーク(GAN)を利用した深層学習再構成がある．本研究では，GAN を利用した深層学習再構成に，フレネル変換による画像種を増したアンサンブル学習を導入し，再構成品質の改善を行う新たな方法について検討を行った．フレネル変換は光や音波の回折式を与える変換である．回折に係数により画像が変化するので，一種のデータの拡張が可能となる．拡張したデータに対し，それぞれ GAN による再構成を行い，アンサンブル学習を行った．再構成シミュレーションの検討の結果，従来の画像のみを学習する方法を顕著に上回る性能が得られた．

キーワード：深層学習，GAN，フレネル変換

1. はじめに

圧縮センシング[1]の応用により MRI の撮像時間を短縮することが可能となるが，再構成時間と再構成像の品質の点で課題が残る．これらの問題を解決する方法として深層学習を利用する研究が行われている．なかでも，敵対的生成ネットワーク(GAN: Generative Adversarial Network)[2]を CS-MRI に応用した DAGAN(Deep De-Aliasing Generative Adversarial Network)[3]は良質な画像を再構成することで知られている．

アンサンブル学習 [4]は，多数の CNN を使用して画像再構成を行うことで画質を向上することができる．光や音波の回折として知られるフレネル変換は画像を情報劣化させることなく分布を変化させることができる．本研究ではこの点に着目し，MR 信号からフレネル変換信号を作成し，フレネル変換画像を推定する CNN を追加し，複数の CNN により画像推定を行うアンサンブル学習を考えた．

フレネル変換画像を DAGAN により推定するために DAGAN のネットワークを 2 チャンネル入力にし，通常の画像推定の CNN の他にフレネル変換信号をネットワークの入力とする CNN を用意した．提案法の有効性を検証するために画像再構成実験を行い再構成像の品質比較を行った．

2. 画像のフレネル変換

$\rho(x)$ を被写体関数， b を回折に関する係数， x' をフレネル回折面の座標とすると，フレネル変換信号は式(1)で示すことができる．

$$u(x') = \int \rho(x)e^{-jb(x'-x)^2} dx \quad (1)$$

式(1)の x' についてフーリエ変換を行うと，次式が得られる．

$$F[u(x')] = \sqrt{\frac{\pi}{b}} e^{-j\frac{\pi}{4}} e^{j\frac{k_x^2}{4b}} R(k_x) \quad (2)$$

ここで，式(2)における $F[\cdot]$ はフーリエ変換， $R(k_x)$ は $\rho(x)$ のフーリエ変換関数であり，収集される信号に相当する．式(2)から MR 信号 $R(k_x)$ に 2 次の位相変調を与えるだけで容易にフレネル変換信号を求めることができる．また，標本化定理を満足する b の最大値を \bar{b} とし，回折の程度を与える位相拡散係数 h を用いて式(3)のように表すことにする．

$$b = h\bar{b} \quad (3)$$

3. DAGAN によるフレネル変換画像の推定

DAGAN (Deep De-Aliasing Generative Adversarial Networks) [3]は，Yang らによって提案された画像再構成ネットワークである．GAN は生成器と識別器という二つのネットワークを使用するが [2]，DAGAN では生成器への入力をゼロフィル再構成像とし，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ように学習させる．また，識別器はフルデータ再構成像と生成画像を識別するように学習する．

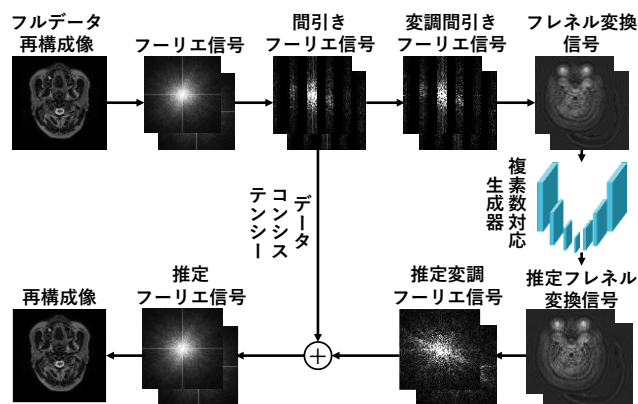


図1 フレネル変換画像推定 CNN

フレネル変換信号を使用するにあたり、複素数に対応した2チャンネル入力の生成器の開発を行った。複素数対応生成器は、DAGAN のもともとの生成器である U-Net[5]を参考に、複素数畳み込み[6]を組み込んだものとなっている。入出力は実部と虚部を持つ2チャンネルとなっている。

フレネル変換を使用した画像再構成処理の流れを図1に示す。まず、撮像の高速化を想定して信号の間引きを行う。フレネル変換信号は、ゼロフィル信号に位相変調項を乗じることで得ることができ、ネットワークはゼロフィル信号によるフレネル変換信号から、フルデータ信号によるフレネル変換信号を推定するように学習する。ネットワークが推定したフレネル変換信号をフーリエ変換し、逆位相を乗じてから逆フーリエ変換することで再構成画像を得る。なお、推定フーリエ信号には、真の信号で値を置き換える処理であるデータコンシステンシーを行っている。

5. 画像再構成シミュレーション

学習とテストに使用する MR 画像は、IXI dataset[7]に含まれる T2 強調頭部 MR 画像の中から 2,500 枚を学習用に、1,297 枚を検証用に、50 枚をテスト画像用に選出した。撮像は 2 次元とし、臨床でよく使用されるカルテシアン座標系による信号収集とした。間引きパターンは 1 次元ポアソン・ディスク間引きとし、信号データサイズは 256×256 、信号収集率は 40%、中心取得列数は 30 列、中心以外の列は 3 列に 1 列取得するものとし、収集列が隣接しないという制約を与えた。

実験では、2 パターンにおける再構成シミュレーションを行った。1 つ目が従来法である生成器を変更していない DAGAN、2 つ目は複素数対応の生成器を使用した DAGAN により $h = 0, 25, 50, 75$ の場合の再構成画像の加算平均をとる方法である。再構成画像の画質評価には PSNR と SSIM[8]を使用した。

図2に示す結果では、提案法は従来法に比べ高い PSNR, SSIM を示し、図3の再構成画像では、提案法は従来法に比べアーチファクトの除去性能に優れ、画像の細部構造の再現性も高いことがわかる。フレネル変換信号において h が小さい場合は、虚部画像にアーチファクトに似た様相を呈する構造が出




図2 PSNR と SSIM

現する傾向がある。この性質により、位相拡散係数 h の値ごとに CNN それぞれが、対応する h のフレネル変換信号のアーチファクトを学習するため、それらの推定画像の加算平均をとることで、アーチファクト除去性能と画質向上に寄与したものとする。

6. おわりに

MRI の圧縮センシング再構成法の性能向上を目的として DAGAN の生成器の改良を行い、さらに、フレネル変換信号を推定するアンサンブル学習を導入した。その結果、従来法に比べ高い再構成性能を示すことが確認された。今後はネットワークの構造の改良を中心に、DAGAN の更なる性能向上を行う予定である。

謝辞

本研究の一部は、科学研究費助成金(19K04423)により実施されました。

利益相反の有無

なし

文献

[1] D.Donoho: IEEE 52: 1289-1306, 2006
 [2] I.J.Goodfellow, J.Pouget-Abadie, M.Mirza, et al: NIPS: 2672-2680, 2014
 [3] G.Yang, S.Yu, H.Dong, et al: IEEE 37: 1310-1321, 2018
 [4] L.Hansen, P.Salamon: IEEE 12: pp.993-1001, 1990
 [5] O.Ronneberger, P.Fischer, T.Brox: MICCAI 3: 234-241, 2015
 [6] C.Trabelsi, O.Bilaniuk, Y.Zhang, et al: ICLR: arXiv:1705.09792v4, 2018
 [7] Biomedical Image Analysis Group, "IXI Dataset": <https://brain-development.org/ixi-dataset/>(参照 2020-10-14)
 [8] Z.Wang, A.Bovik, H.Sheikh, et al: IEEE 13: 600-612, 2004

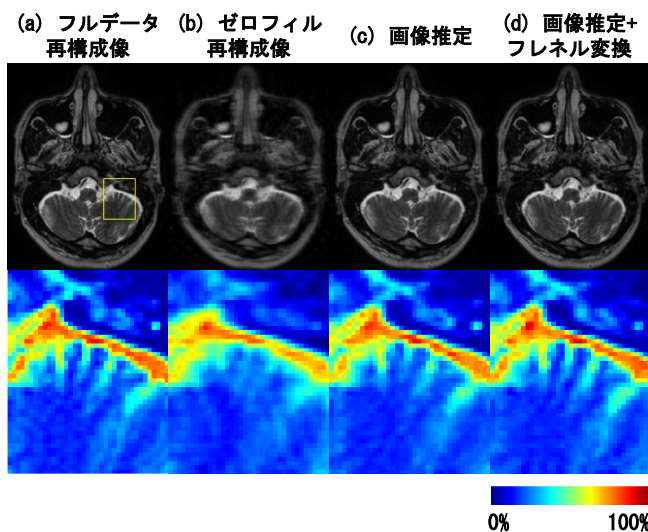


図3 再構成画像比較

インテリア CT 画像再構成の新しい厳密解法と究極の高精度解法の提案

工藤 博幸^{*1}

^{*1} 筑波大学システム情報系

New Exact Approach to Interior CT Reconstruction and Ultimate Accurate Reconstruction Method

Hiroyuki KUDO^{*1}

^{*1} University of Tsukuba

要旨：本論文ではインテリア CT の画像再構成を取り扱い，物体に関する先験情報を全く用いない新しい厳密解法と従来よりはるかに少ない先験情報で実質的に厳密解法と同等の高精度で画像再構成が可能な究極の解法を提案する。

キーワード：インテリア CT，画像再構成，トランケーション，関心領域

1. はじめに

本論文では，物体内部の小さな関心領域 (ROI) のみに X 線を照射して測定した不完全な投影データから ROI の画像を再構成するインテリア CT の画像再構成を取り扱う。インテリア CT の画像再構成では，不完全投影データであるため通常の再構成法では大きな画質劣化が発生するが，著者らにより物体に関するごくわずかな先験情報があれば数学的に厳密な画像再構成が可能であることが示されている (文献[1])。本論文では，先験情報を用いない全く新しい厳密解法を提案する。提案手法は，通常のインテリア CT 投影データに加え，微小な角度範囲 (数学的にはゼロにいくら近くともよい) から物体全体をカバーする完全投影データを少しだけ余分に測定して，インテリア CT 投影データと完全投影データを組み合わせて画像再構成を行うものである。完全投影データを測定する角度範囲は微小で良く，数学的には測度がゼロでない限りいくら小さくとも ROI の厳密でかつ安定な画像再構成が可能であるという驚くべき結論を，数学的に証明することに成功した。更に，本手法で用いる余分な投影データを劇的に削減することを試み，物体の直流成分 (画像濃度値の物体全体の総和) のスカラー値のみを補足情報に用いて高精度で再構成を行う手法を提案する。本手法は，補足情報として物体の直流成分という *minimum* の先験情報しか使用せず，実質的に非常に上手く動作し上記の厳密解法と画質性能に違いがなく，究極のインテリア CT 画像再構成法と言える。本論文で提案する手法が実質的に有効に動作することを，シミュレーション実験と実データを用いた実験により示す。

2. 提案手法

1) インテリア CT の画像再構成

インテリア CT の原理を図 1 に示す。X 線吸収係数の分布を $f(x,y)$ ，物体内部にある (心臓や乳房など) 見たい検査の関心領域 (ROI) を S で表す。平行ビーム方式の場合，X 線を ROI のみに照射して 180 度角度範囲の投影データ $p(r,\theta)$ を測定する。ファンビーム方式の場合，X 線を ROI のみに照射して 360 度角度範囲の投影データ $g(u,\beta)$ を測定する。この投影データから ROI

S の画像を再構成するのが，インテリア CT の画像再構成問題である。インテリア CT の画像再構成問題は，測定した投影データの情報のみでは解が一意に定まらないことが知られ CT 分野における長年の未解決問題であったが，2007 年以降文献[1] などによりごくわずかな物体に関する先験情報があれば，厳密な画像再構成が可能であることが示された。本論文では，1) 物体に関する先験情報の代わりに通常のインテリア CT で測定しない補足投影データを余分に測定して厳密な画像再構成を行う新しい厳密解法，2) 従来よりはるかに少ない先験情報で実質的に厳密解法と同等な高精度の画像再構成が可能な究極の高精度解法，の 2 つを提案する。




図 1 インテリア CT の原理を示す概念図

2) 先験情報を用いない厳密解法 (文献[2]) (提案手法 1)

提案手法では，図 1 に示すインテリア CT 投影データに加えて，図 2 に示すようにある角度範囲 E から物体全体をカバーする完全投影データ (平行ビームの場合 $p_c(r,\theta)$ ，ファンビームの場合 $g_c(u,\beta)$ で表す) を補足的に測定して，図 1 と図 2 の投影データを組み合わせて画像再構成を行う。本手法において数学的に最も興味があるのは，数学的に厳密で安定な画像再構成が可能のためには，完全投影データを測定する角度範囲 E はどの程度必要かという問題である。この問題を数学的に考察して，以下の驚きの事実を証明した (文献[2])。

[解の一意性と安定性] 図 1 の投影データ $p(r,\theta)$ (または $g(u,\beta)$) に加え，測度がゼロでない角度範囲 E から図 2 の投影データ

$p_c(r, \theta)$ (または $g_c(u, \beta)$) を測定する。このとき、図1と図2の投影データから $f(x, y)$ は ROI S 全体で一意に定まり、逆変換は安定である。なお、角度範囲 E は、数学的には測度がゼロでない限りいくら小さくともよい。

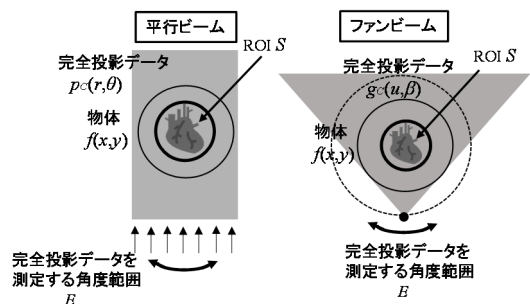


図2 厳密なインテリア CT を可能にする補足測定

3) 究極の高精度解法 (文献[3]) (提案手法2)

次に、2)の厳密解法で必要になる補足投影データを更に削減することを検討して、(数学的に厳密性が証明できる手法ではないが)従来の厳密解法で用いる物体に関する先験情報よりはるかに少ない先験情報で実質的に厳密解法と同等な高精度の画像再構成が可能な新手法を発見した。新手法の原理を図3に示すが、図1に示すインテリア CT 投影データに加えて、次式で表される $f(x, y)$ の物体断面全体での合計値 (直流成分) C の値を先験情報として用いる。

$$C = \iint_{\Omega} f(x, y) dx dy \quad (1)$$

ただし、 Ω は物体サポート ($f(x, y) \neq 0$ である (x, y) の範囲) を表す。即ち、ROI S のみではなく画像全体における $f(x, y)$ の合計値を先験情報に用いるのが本手法で、これにより劇的にインテリア CT で発生する直流成分や低周波成分のアーティファクトは劇的に削減される。式(1)の先験情報を獲得する方法としては多くのバリエーションが考えられるが、以下の3つを挙げておく。




図3 高精度なインテリア CT を可能にする先験情報

[方法1] 事前に低線量や低分解能の条件で画像撮影を行い、画像値を合計して C を予想する。

[方法2] 事前に低線量や低分解能の条件で一方向だけから投影データ測定を行い、投影データの値を合計して C を予想する (一方向投影データの合計値 = 画像の合計値)。

[方法3] 同一患者の同一部位の撮影であれば時間が変わって

も C の値はほぼ同じであり、以前に撮影した同一患者の画像から予想する。

3. シミュレーション実験

コントラストの要求が厳しくインテリア CT のアーティファクトが問題になりやすい頭部 CT 実画像を用いて、シミュレーション実験を行った。提案手法1と提案手法2に加え、比較のため以下の2手法を実装した。

[ローカル FBP 法] 商用器で用いられる簡便な手法で、投影データの欠損部分を滑らかな関数で外挿した後 FBP 法で画像再構成を行う。

[Kudo (2008) の厳密解法] ROI S の内部にある任意小領域 B における $f(x, y)$ の値が既知という先験情報を用いて、厳密な画像再構成を行う。本実験では、先験情報領域 B として ROI S の縁に位置するリング状の領域を用いている。

再構成画像を図4にまとめて示す。赤の点線で示す領域が X 線を照射する ROI S を表している。ローカル FBP 法では、直流成分のシフトとシェーディングアーティファクトが強く発生しているのに対して、他の3つの手法は ROI 内部は高精度で上手く画像再構成されている。




図4 シミュレーション実験の再構成画像

利益相反の有無： なし

文献

[1] Kudo H, Courdurier M, Noo F, Defrise M: Tiny a priori knowledge solves the interior problem in computed tomography. Phys Med Biol 53: 2207-2231, 2008
 [2] 工藤博幸, インテリア CT 画像生成方法, 特許願 2017-061390, PCT 出願 WO/2018/179905A1, US, EP, CN, JP 出願中, 2017
 [3] 工藤博幸, 特許出願手続中, May 2022

スペクトラルフォトンカウンティング CT の高速な統計的画像再構成法

金 喜正^{*1}, 賈 澤娜^{*1}, 工藤 博幸^{*1}

^{*1} 筑波大学大学院システム情報工学研究群情報理工学位プログラム専攻

Fast Statistical Image Reconstruction Method for Spectral Photon-Counting CT

Heejeong KIM^{*1}, Zena JIA^{*1}, Hiroyuki KUDO^{*1}

^{*1} University of Tsukuba

要旨: 本研究では, スペクトラルフォトンカウンティング CT (SPCCT) に用いる統計的画像再構成を提案する. 提案手法は, エネルギー画像を変数として画像再構成を定式化する提案手法 1 と, マテリアル画像を変数として定式化する提案手法 2 の 2 つである. 両手法とも, 1) 統計雑音ポアソン分布であることを考慮した重み付き最小 2 乗法 (WLS) のデータ項を利用, 2) 空間方向の TV 正則化項に加え物体を構成するマテリアルが少数であることを利用したエネルギー方向の正則化項, 3) 文献[1]の Dykstra 型スプリッティングによる高速に収束する反復法で計算時間を削減, の工夫が施されている. 特に, Dykstra 型スプリッティングで極めて高速に収束する反復法を構築して計算量の問題を克服したのは, 大きな成果と考える.

キーワード: スペクトラルフォトンカウンティング CT, 統計的画像再構成, 物質弁別, TV 正則化

1. はじめに

近年, 造影剤などの物質弁別が可能な CT が実用に至っており, 特にデュアルエネルギー CT の次の装置として Spectral Photon-Counting CT (SPCCT) が注目されている. この装置は Photon-Counting 検出器 (PCD) を用いた CT 装置であり, PCD を用いて X 線エネルギー毎の投影データを別々に測定し, エネルギー毎の画像を別々に再構成した後物質弁別を行うことが可能な装置となっている. SPPCT は, 通常の CT と同じ一回のスキャンで物質弁別を行うことができる利点がある. しかし, エネルギー毎に投影データを分けるため各エネルギーの光子数が少なくなり, 特に吸収が大きい低エネルギー帯の画像再構成が統計雑音の影響で難しくなる問題点がある. そこで, 本研究では, 通常 CT の統計的画像再構成法を SPCCT に拡張した新しい画像再構成法を構築した. 特に, SPCCT のための画像再構成に拡張する際に工夫した点は, 1) 統計雑音ポアソン分布であることを考慮した重み付き最小 2 乗法 (WLS) のデータ項を利用, 2) 空間方向の TV 正則化項に加え物体を構成するマテリアルが少数であることを利用したエネルギー方向の正則化項, 3) 文献[1]の Dykstra 型スプリッティングによる高速に収束する反復法で計算時間を削減, の 3 点である. 1) と 2) は他研究でも組み込まれているものであるが, 3) は本論文の独創性が高いものと位置づけられる.

2. 提案手法

統計的画像再構成では, 測定データと再構成画像の整合性を評価するデータ項と画像のモデルから定義される正則化項の和から構成される評価関数を定義し, 逐次近似法により最小化することで画像再構成を行う手法である. 本論文では, 提案手法 1 と提案手法 2 の 2 つの異なる定式化に基づく画像再構成法を提案する.

1) 提案手法 1 (エネルギー画像を変数とする定式化)

まず, SPCCT における再構成画像は, 行列 X を用いて次式で表される.

$$X = [\vec{x}_1 \vec{x}_2 \cdots \vec{x}_E] = [\vec{m}_1 \vec{m}_2 \cdots \vec{m}_M] \begin{bmatrix} \vec{e}_1^T \\ \vec{e}_2^T \\ \vdots \\ \vec{e}_M^T \end{bmatrix} \quad (1)$$

ただし, $\vec{x}_1 \vec{x}_2 \cdots \vec{x}_E$ はエネルギーを分割数 E で分割した各エネルギービンの画像, $\vec{m}_1 \vec{m}_2 \cdots \vec{m}_M$ は対象に含まれる M 個の基本物質に分解したマテリアル画像, $\vec{e}_1 \vec{e}_2 \cdots \vec{e}_M$ は各基本物質の吸収係数の基底ベクトルを表している. SPCCT の画像再構成は, E 個のエネルギービンの投影データから各エネルギービンの再構成画像 $\vec{x}_1 \vec{x}_2 \cdots \vec{x}_E$ と物質弁別を行った各マテリアル画像 $\vec{m}_1 \vec{m}_2 \cdots \vec{m}_M$ を求める問題である. 提案手法 1 では, $\vec{x}_1 \vec{x}_2 \cdots \vec{x}_E$ を変数として, 次式の評価関数を最小化することで画像再構成を行う.

$$\min_X f(X) = \frac{1}{2} \sum_{l=1}^E \|A \vec{x}_l - \vec{b}_l\|_{W_l}^2 + \sum_{l=1}^E \beta \|\vec{x}_l\|_{TV} \quad (2)$$

subject to Rank (X) $\leq M$

ただし, 第 1 項目は各エネルギービンの投影データに対する重み付き 2 乗誤差の和を表し, 第 2 項目は各エネルギービンの画像に平滑化を行う TV 正則化項を表す. また, 制約条件はマテリアル数が少数の M 個であることを表し, これにより実質的にエネルギー方向の正則化を行っている.

この方法の利点としては, 必要な先験情報はマテリアル数 M の値 (エネルギー数 E より小さい) のみで, 基底ベクトル $\vec{e}_1 \vec{e}_2 \cdots \vec{e}_M$ の情報は不要で画像再構成の過程で同時に求まることが挙げられる. 即ち, 組成が事前に未知の物体が含まれているような場合にも有効な方法である.

2) 提案手法 2 (マテリアル画像を変数とする定式化)

医療用 CT では, 対象に含まれる物質は事前に既知であるた

め、基底ベクトル $\vec{e}_1 \vec{e}_2 \dots \vec{e}_M$ は既知である。この場合、式(1)のデータを項に代入することで、マテリアル画像を変数として画像再構成を行うことができる。この場合の画像再構成問題は、次のように定式化される。

$$\min_{\vec{m}_1 \vec{m}_2 \dots \vec{m}_M} f(\vec{m}_1 \vec{m}_2 \dots \vec{m}_M) \quad (3)$$

$$= \frac{1}{2} \sum_{l=1}^E \|A \left(\sum_{i=1}^M e_{li} \vec{m}_i \right) - \vec{b}_l\|_{W_l}^2 + \sum_{i=1}^M \beta \|\vec{m}_i\|_{TV}$$

ただし、この定式化では、TV 正則化はエネルギー画像ではなくマテリアル画像に適用する。

3) Dykstra 型スプリッティングによる反復法

提案手法 1 と提案手法 2 のように定式化された最小化問題を、文献[1]で通常の CT に対して提案された Dykstra 型スプリッティングによる高速な反復法を用いて解く。提案手法 1 と提案手法 2 のどちらの問題も解くことが可能だが、提案手法 1 に適用した場合のアルゴリズムを表 1 に示す。ただし、提案手法 1 における行列の Rank 拘束条件は、エネルギー画像を表す行列 X を特異値分解して Rank を M まで落とす Hard Thresholding により適用している。

$\vec{x}^{(0)}(l) = 0, \mu_i^{(0)}(l) = 0 (i=1,2,\dots,I), \vec{y}_{i+1}^{(0)}(l) = 0, \vec{z}^{(0)}(l) = 0 (l=1,2,\dots,E)$	
$k = 0, 1, 2, \dots$ Main Loop	
$l = 1, 2, \dots, E$ エネルギー-bin番号のloop 各エネルギーの画像は別々に処理	
$\vec{x}^{(k,1)}(l) = \vec{x}^{(k)}(l) + \vec{z}^{(k)}(l)$	
$i = 1, 2, \dots, I$	
$\vec{i} = \alpha \frac{\sqrt{w_{li}} [b_l - \vec{a}_l^T \vec{x}^{(k,i)}(l)] + \mu_i^{(k)}(l) / \alpha}{1 + \alpha w_{li} \ \vec{a}_i\ ^2}$	データ項の処理
$\vec{x}^{(k,j+1)}(l) = \vec{x}^{(k,j)}(l) + \sqrt{w_{li}} \vec{i} \vec{a}_i$ $\mu_i^{(k+1)}(l) = \mu_i^{(k)}(l) - \vec{i}$	
$\vec{x}^{(k,j+2)}(l) = \text{prox}_{\alpha\beta\ \vec{x}\ _{TV}}(\vec{x}^{(k,j+1)}(l) + \vec{y}_{i+1}^{(k)}(l))$	TV項の処理
$\vec{y}_{i+1}^{(k+1)}(l) = \vec{y}_{i+1}^{(k)}(l) + \vec{x}^{(k,j+1)}(l) - \vec{x}^{(k,j+2)}(l)$	
$X^{(k,j+3)} = \text{Rank}(X^{(k,j+2)})$	Rank M 拘束条件の処理
$\vec{x}^{(k+1)}(l) = \vec{x}^{(k,j+3)}(l)$	ここだけ行列で記載(異なるエネルギーの画像が関係する)
$l = 1, 2, \dots, E$	
$\vec{z}^{(k+1)}(l) = \vec{z}^{(k)}(l) + \vec{x}^{(k,j+3)}(l) - \vec{x}^{(k,1)}(l)$	Proximal Minimization の処理

表 1 提案手法 1 に対する Dykstra 型スプリッティングの反復法

3. シミュレーション実験

提案手法 1 と提案手法 2 の両方に対応する Dykstra スプリッティングの反復法を実装した。画像再構成の設定は、マテリアルの個数 M を 4 個として物質弁別を行う対象のマテリアルは水・骨・ヨウ素造影剤・ガドリニウム造影剤の 4 個とした。これらは医療用 CT においてよく使われるため、これらの物質に設定した。数値ファントムのマテリアル画像を図 1 に示す。投影データに雑音がない場合の提案手法 1 による再構成画像(マテリアル画像)を図 2 に示すが、物質弁別は上手く行われている。また、図 3 に Dykstra 型スプリッティングの収束の様子を

示すが、極めて高速に 4 回の反復で収束しその有効性が確認された。次に、図 4 に、放射光子数 1.0×10^7 (counts/bin) のポアソン雑音を投影データに付加した場合の再構成画像(マテリアル画像)を示す。雑音の影響で完全ではないが、概ね物質弁別はできている。




図 1 数値ファントム (マテリアル画像)





図 2 雑音がない場合の再構成画像 (上段: エネルギー画像, 下段: マテリアル画像)




図 3 Dykstra 型スプリッティングの収束の様子




図 4 雑音がある場合の再構成画像 (マテリアル画像)

利益相反の有無: なし

文 献

[1] Kim H, Sadakata K, Kudo H: Unified framework to construct fast row-action-type iterative CT reconstruction method with total variation using multi proximal splitting. Proc. Int. Conf. on Biomedical Signal and Image Processing (ICBIP2021), pp.66-71, 2021

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

賈 澤娜^{*1}, 金 喜正^{*1}, 工藤 博幸^{*1}

^{*1} 筑波大学大学院システム情報工学研究群 情報理工学位プログラム

Fast Iterative Reconstruction Method for ABD-CT (Abnormal Data Detected CT) and Application to Metal Artifact Reduction

Zena JIA^{*1}, Heejeong KIM^{*1}, Hiroyuki KUDO^{*1}

^{*1} University of Tsukuba

要旨: CT の画像再構成において、再構成過程においてサイノグラム上で異常データを検知して除外してアーティファクトを削減した再構成を行う ABD-CT (Abnormal Data Detected CT) の概念が提案されている [1]。ABD-CT では、L1 ノルムや L0 ノルムから構成される異常データ除外効果があるデータ項とトータルバリエーション (TV) などの正則化項の和から構成される評価関数を反復解法で最小化して画像再構成を行う。本研究では、Dykstra 型スプリッティングの数学的枠組み [2] に基づき ABD-CT に用いる高速に収束する画像再構成法を構築して、ABD-CT の典型的な応用であるメタルアーティファクト除去(MAR)の問題に適用した。画質性能を向上させるため、正則化項としては非局所 TV (Nonlocal TV) を採用した。歯科用 CT 実画像を用いたシミュレーション実験を行い本手法の性能を評価した結果、ABD-CT は優れた画質改善効果を持つことが示された。更には、MAR の問題に流行している深層学習と比較した結果、ABD-CT は深層学習より優れた画質性能を持つことが明らかになった。

キーワード: CT, メタルアーティファクト, Abnormal Data Detected CT, 画像再構成

1. はじめに

コンピュータ断層撮影(Computed Tomography: CT) は対象物断面を非破壊で画像化できる技術である。医療現場では人体に X 線を照射し、人体を透過した X 線を検出器で測定して、得られたデータに画像再構成のデータ処理を施して断面像を得る。医療用 X 線 CT 画像再構成には、これまで解析的手法であるフィルタ補正逆投影(Filtered Back Projection: FBP)法が用いられてきた。しかし、患者は治療により、歯牙充填、人工股関節置換術など金属が含まれている場合が多い。この場合、金属を通る X 線は、連続 X 線が物質を透過する際、高エネルギーに比べ低エネルギーの方がより多く吸収され、結果的にエネルギーピークが高い側に移動 (シフト) してしまう。このような投影データに対して FBP 法で画像再構成を行うと、画像に筋状のアーティファクトやビームハードニングが発生する問題点がある。この現象をメタルアーティファクトと呼ぶ。メタルアーティファクトは医師の診断に大きな支障をきたし、正確な診断や検査が行えなくなる。そのため様々なメタルアーティファクト除去の手法が提案されている。[1, 2]

2. 提案手法

本研究では、Dykstra 型スプリッティングの数学的枠組 [2, 3] に基づき L1 ノルムから構成される異常データ除外効果があるデータ項と非局所 TV(Nonlocal TV)の正則化項の和から構成される評価関数を、反復解法で最小化することで画像再構成を行う。

最適化問題の対象となる評価関数を式(1)に示す。

$$f_{\beta}(\vec{x}) = \|\mathbf{Ax} - \mathbf{b}\|_1^2 + \beta \text{NLTV}(\vec{x}) \quad (1)$$

ここで、データ項には L1 ノルムを用いており、異常値のみを適切に除外することができる。正則化項としては非局所 TV(Nonlocal TV)を用いている [3]。

この最適化問題を Dykstra 型スプリッティングに基づく反復解法 [2] を用いて解く、そのアルゴリズムをテーブル 1 で示す。

```

[step0] 初期化
 $\vec{x}^{(0)} = \mathbf{0}, \mu_i^{(0)} = 0 (i = 1, 2, \dots, I), \vec{y}_{I+1}^{(0)} = \mathbf{0}, \vec{z}^{(0)} = \mathbf{0}$ 
for k in range(1, n):
     $\vec{x}^{(k,1)} = \vec{x}^{(k)} + \vec{z}^{(k)}$ 
    [step1]各投影方向に対するソフト閾値処理
    for i in range(1, I):
         $q = -\frac{b_i - \vec{a}_i^T \vec{x}^{(k,i)} - \|\vec{a}_i\|^2 \mu_i^{(k)}}{\alpha \|\vec{a}_i\|^2} \quad \lambda = \begin{cases} -1 & (q < -1) \\ q & (-1 \leq q \leq 1) \\ 1 & (q > 1) \end{cases}$ 
    [step2] 解の更新
     $\vec{x}^{(k,i+1)} = \vec{x}^{(k,i)} + (\mu_i^{(k)} - \lambda \alpha) \vec{a}_i \quad \mu_i^{(k+1)} = \lambda \alpha \quad \alpha > 0$ 
    [step3]正則化に関する最適化問題を解き、解の更新
     $\vec{x}^{(k,I+2)} = \text{prox}_{\alpha \beta \text{NLTV}(\cdot)}(\vec{x}^{(k,I+1)} + \vec{y}_{I+1}^{(k)})$ 
     $\vec{y}_{I+1}^{(k+1)} = \vec{y}_{I+1}^{(k)} + \vec{x}^{(k,I+1)} - \vec{x}^{(k,I+2)}$ 
     $\vec{z}^{(k+1)} = \vec{z}^{(k)} + \vec{x}^{(k,I+1)} - \vec{x}^{(k,1)}$ 
Return  $\vec{x}^{(n,1)}$ 

```

テーブル 1: アルゴリズム

3. シミュレーション実験

臨床歯科用 CT 画像を用いてシミュレーション研究を行う

た. 原画像は 512×512 (ピクセル) であり, 歯に金属の被せ物, 詰め物, 両者を含むものを 2~4 箇所ランダムに追加した. ただし, シミュレーションでは金属は鉄と仮定している. 金属を挿入後に, X線が多色であること及びビームハードニングシミュレーションとポアソンノイズを考慮して, 投影データを作成した. また, この実験は, 金属の影響で発生する散乱線の影響が取り除かれた状態で行った. 以下の4種類の再構成法を実装して比較した (図1).

[FBP] シミュレーションした投影データに直接 FBP 法を適用

[DLSP-L2-NLTV] L2- Nonlocal TV による再構成手法

[FBP+CNN] FBP 法で再構成画像した画像にディープラーニングを適用 (学習用画像は 90 枚, テスト用画像は 10 枚) の結果

[DLSP-L1-NLTV] 提案手法

メタルアーティファクト除去後の画質の評価指標として, 平均二乗誤差(MSE), 画像構造の類似度(SSIM)を用いて評価を行った (表1).

4. まとめ

ABD-CT を用いたメタルアーティファクト除去の有効性が確認され, かつ Dykstra 型スプリッティングに基づく高速に収束する反復解法により, 短時間で十分な画質の再構成画像が得られる実用的なものとなった. 今後は, 本手法と深層学習を組み合わせた方法を構築して, 更なる画質性能の改善を行いたい.

謝辞

本研究は, JST-CREST (JPMJCR1765) の助成を受けた.

	MSE	SSIM
FBP	0.018	0.61
DLSP2-NLTV	0.021	0.73
FBP+CNN	0.008	0.77
DLSP2-NLTV	0.009	0.75

表1: MAR 画像における数値比較

利益相反の有無

なし

文献

- [1] 工藤博幸: 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. JAMIT2021 P4-07, 2021
- [2] Kim H, Sadakata K, Kudo H: Unified framework to construct fast row-action-type iterative CT reconstruction methods with total variation using multi proximal splitting. Proceedings of 2021 6th International Conference on Biomedical Signal and Image Processing (ICBIP 2021), pp.65-71, 2021
- [3] Combettes PL and Pesquet JC: Proximal splitting methods in signal processing. In Bauschke H.H, Burachik R.S, Combettes P.L et al. eds. Fixed-Point Algorithm for Inverse Problems in Science and Engineering, 2011, pp.185-212, 2011

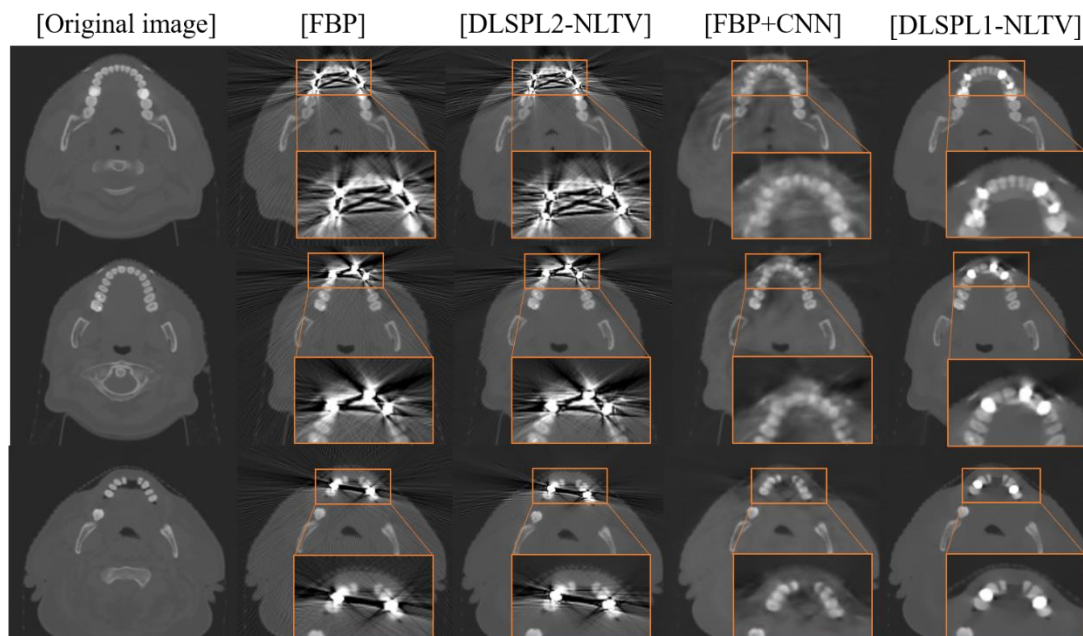


図1: 原画像と各手法における4, 3, 2個のメタルを挿入した場合の再構成画像

深層学習を用いたマルチピンホール SPECT システムにおけるオーバーラップ投影データの分離

山口 恭平^{*1}, 村田 一心^{*2}, 尾川浩一^{*3}

^{*1}法政大学大学院理工学研究科応用情報工学専攻

^{*2}国立天文台

^{*3}法政大学理工学部

Separation of overlapped projection data with a neural network in multi-pinhole SPECT system

Kyohei YAMAGUCHI^{*1}, Kazumi MURATA^{*2}, Koichi OGAWA^{*1}

^{*1} Graduate School of Science and Engineering, Hosei University

^{*2} National Astronomical Observatory of Japan

^{*3} Faculty of Science and Engineering, Hosei University

要旨：マルチピンホール SPECT はガンマカメラを回転させずにデータを取得できるため、PET 検査のようなダイナミックな臓器検査が可能である。しかし、ピンホールの数を増やしてデータ取得効率を上げると、ピンホールからの投影画像が互いに重なり合い、再構成画像に深刻なアーチファクトが発生する。そこで我々は、重なり合った投影画像を分離するために、ニューラルネットワークを用いた新しい手法を提案する。提案するニューラルネットワークは、全結合の 8 層から構成されている。入力データとして、各投影角度で重なったサイノグラムを用い、重ならない状態で測定したサイノグラムでニューラルネットワークを学習させた。提案手法の実現可能性を 2 ピンホールコリメータシステムで検討した。シミュレーション結果から、提案手法は重なった投影画像を個々の画像に分離できることを確認した。

キーワード：マルチピンホールコリメータ, SPECT, 深層学習

1. はじめに

SPECT (Single Photon Emission CT) は、患者の体内で放射性医薬品から放出されるガンマ線を検出し、臓器の機能を調べる断層撮影法である。一般に SPECT 装置では、平行多孔コリメータやファンビームコリメータが使用される。そして、これらのコリメータでガンマカメラを回転させながらデータ取得を行う。そのため、データ収集に長時間を要する。また、患者の動きはアーチファクトの原因となるため、データ収集をしている間、患者は姿勢を維持する必要がある、長時間のデータ収集は大きな負担となる。一方、様々な方向からの光子を検出するマルチピンコリメータを使用することで、SPECT 装置でのデータ取得時間の短縮になる。ピンホールコリメータの欠点は、感度が低いことであるが、ピンホールの数を増やすことで感度は改善可能である。しかし、投影像が重なるとアーチファクトが発生するため、増設できるピンホールの数にも限度がある。逆に言えば、重なった投影画像の再構成でアーチファクトが発生しなければ、ピンホール数の増設が可能でさらなるデータ取得時間の短縮や感度の向上が見込まれる。このよう

な投影画像の重なりによるアーチファクトを低減する方法がいくつか報告されている [1][2]。しかし、それらの反復処理には長い計算時間がかかる。ネットワークならば長い時間をかけずに分離後の投影画像を出力できる。しかし、これまで、深層学習を用いた投影画像の分離の研究はされてこなかった。そこで本研究では、分離した投影画像の作成に全結合のニューラルネットワークを使用した。

2. 方法

A. ネットワークの構造

図 1 は、投影画像の分離に使用するニューラルネットワークである。ネットワークは全結合で、入力には重なった投影画像 (256[pixel]×1[angle]) 出力には、異なるピンホールで取得した 2 種類の投影画像を重ならないように再配置した投影画像 (256[pixel]×1[angle]) を用いた。各層で使用するノードの数を図に示す。モデルは 1800 の投影画像を用い、学習用に 90%、検証用に 10% とし、10000 エポックの学習を行った。損失関数は平均二乗誤差であり、学習率を 10^{-3} とした Adam アルゴリズムにより最適化した。




図 1. ネットワーク構造

B. シミュレーション方法

図 2 に本シミュレーションで使用した SPECT システムのジ

*1 法政大学大学院理工学研究科

[〒184-8584 東京都小金井市梶野町 3-7-2]

e-mail: kyohei.yamaguchi.5z@stu.hosei.ac.jp

*2 国立天文台

*3 法政大学理工学部

オメトリを示す. 重なりを持つ2ピンホール SPECT システムを想定した. 検出器のサイズは 256×60 [pixel] (ピクセルサイズ: $0.8 \text{ cm} \times 0.8 \text{ cm}$), 投影方向は 180 とした. コリメータと検出器の距離は 7.6 cm , ターゲットの中心からコリメータまでの距離は 25 cm とした. ピンホールは中央に水平に配置され, ピンホールの間隔は 2 cm に配置した. シミュレーションには脳ファントムを用い, 投影画像は光線追跡法で計算した. ガンマ線の吸収と散乱は無視した. 分離された投影データを用いて, ML-EM 法により画像再構成を行った. 反復回数は各ピンホール投影画像に対して 50 回とした.




図 2. 2 ピンホールのデータ収集ジオメトリ




図 3. 学習に用いた投影画像. (a) ピンホール番号 1 の投影画像, (b) ピンホール番号 2 の投影画像, (c) オーバーラップした投影画像, (d) 学習で教師画像として用いたオーバーラップのない投影画像.




図 4. 図 3(c) (d) に対応するサイノグラム. (a) 入力データ (重なっているデータ), (b) 訓練データ (重なりのないデータ).

3. 結果と考察

図 5 (a) は分離した投影画像の出力, (b) はニューラルネットワークの平均二乗誤差 (MSE) である. MSE が徐々に下がっていることが確認できる. また, (a) の画像から重なりが除去されているのが確認できた. 図 6 は再構成された画像とそのプロファイルを示したものである. (a) は投影画像が重なっていない再構成画像, (b) はニューラルネットワークで分離後の

再構成画像である. (c) は (a) で示したライン上の再構成画像のプロファイルを示す. (a) と比べて (b) の画像にはアーチファクトが見られるものの, 両者のプロファイルはよく一致していることがわかる.




図 5. 出力画像, (a) 学習により分離されたサイノグラム (b) 出力画像の損失グラフ.




図 6. 再構成された画像とプロファイル. (a) 投影画像の重なりのない場合の再構成画像, (b) 投影画像を分離した場合の再構成画像, (c) 赤線上の再構成画像のプロファイル.

4. まとめ

本研究では, マルチピンホール SPECT 装置において, ニューラルネットワークを用いて, 重なり合った投影画像を分離する方法を提案した. シミュレーションの結果, 重なり合った投影画像を分離できることを確認した.

謝辞

本研究の一部は科学研究費基盤研究(C)22K12874 の補助を受けた.

利益相反

なし

文献

[1] Schramm N U, Ebel G, Engeland U, et al: High-resolution SPECT using multipinhole collimation. IEEE Transactions on Nuclear Science, vol. 50, no. 3, pp. 315-320, June 2003.

[2] Moore S C, Cervo M, Metzler S D et al: An iterative method for eliminating artifacts from multiplexed data in pinhole SPECT. The 13th international meeting on fully three-dimensional image reconstruction in radiology and nuclear medicine, 515-517, 2015.

静止型マルチピンホール SPECT の空間分解能改善: 投影画像上における点広がり関数の逆畳み込み

村田 一心^{*1}, 大越 迪^{*2}, 山田 桃夏^{*2}, 尾川 浩一^{*3}

^{*1} 国立天文台

[〒181-8588 東京都三鷹市大沢 2-21-1] e-mail: kazumi.murata@nao.ac.jp

^{*2} 法政大学理工学研究科

^{*3} 法政大学理工学部

Improving the spatial resolution of a static multi-pinhole SPECT system via PSF deconvolution on projection domain

Kazumi MURATA^{*1}, Michi OKOSHI^{*2}, Momoka YAMADA^{*2}, Koichi OGAWA^{*3}

^{*1} National Astronomical Observatory of Japan

^{*2} Graduate School of Science and Engineering, Hosei University

^{*3} Faculty of Science and Engineering, Hosei University

要旨: 静止型SPECTは従来のSPECTと異なり, 検出器を回転させないことで, 時間情報を取得できる. このシステムでは, 角度情報を得るため, 複数のピンホールを有するガンマカメラを複数台使用する. しかし, その画質はピンホール径に強く依存し, 感度と空間分解能はトレードオフの関係にある. 空間分解能を補正する方法として, 従来7-rays法が用いられてきたが, 同手法ではピンホール径が大きい時には近似精度が低い. そこで我々は, 投影画像上の点広がり関数を用いた空間分解能改善手法を開発してきた. 本研究では同手法を, 11ピンホールを有し, その点広がり関数は空間依存性を持つSPECTシステムに適用した. 画像再構成シミュレーションを行った結果, 7-rays法を用いた時の再構成画像と比べ, PSNR, SSIMが共に向上することを確認した.

キーワード: 静止型 SPECT, マルチピンホールコリメータ, 空間分解能, 逆畳み込み

1. はじめに

静止型 SPECT システムは, 従来の SPECT と異なり, 臓器の動態解析に必要な時間情報を取得できる[1]. なぜなら, データを収集する際, 検出器の回転ではなく, 複数のピンホールを有するコリメータによって投影方向数を確保するためである. しかし, このマルチピンホールコリメータを用いたデータ収集には, 大きな課題が存在する. ピンホール径が大きいほどより多くの光子を検出できる一方, 空間分解能は劣化してしまうのである. 特に劣化が顕著な場合には, 従来の 7-rays 法[2]では補正が難しいのが現状である.

この問題に取り組むため, 我々は従来の方法とは異なる手段での空間分解能改善方法を開発した[3]. 本手法では, ピンホール径の大きさに由来する画像のボケを点広がり関数 (Point Spread Function; PSF)として取り扱う. これにより, 投影画像に対して PSF の逆畳み込みを行った画像を, 無限小ピンホールによって投影された画像と近似できる. 本手法の有効性はシミュレーション研究によって確認している. しかし, これまでの検証では, わずか3つのピンホールだけしか用いておらず, PSF の空間依存性も考慮していなかった.

そこで本研究では, より現実的な条件で提案手法の有効性を検証する. ピンホール径は先行研究[4]に合わせて 11 個とし, PSF の空間依存性も計算に取り入れた. 得られる再構成画像

の画質を評価した結果, 提案手法は従来の 7-rays 法よりも優れた精度で空間分解能を改善できることが確かめられた.

2. 提案手法の理論的枠組み

本手法の最大の特徴は, 光子の検出確率を表すシステム行列 \mathbf{A} を 2 つの要素に分解して近似することである. 一般的に, ピンホールを用いた場合のシステム行列は扱うことが難しいほどに巨大になってしまう. 従来の 7-rays 法では, ピンホール径を通過する光子の経路を 7 本の光線で近似する. それに対し我々の手法では, システム行列を無限小ピンホールによる投影と PSF の畳み込みで近似する. すなわち, 投影画像 \mathbf{Y} を次のように定式化する.

$$\mathbf{Y} = \mathbf{A}\mathbf{X} \sim \mathbf{A}_{\text{PSF}}\mathbf{A}_{1\text{ray}}\mathbf{X} = \mathbf{A}_{\text{PSF}}\mathbf{Y}', \quad (1)$$

ここで, \mathbf{A}_{PSF} と $\mathbf{A}_{1\text{ray}}$ は PSF と無限小ピンホールのシステム行列, \mathbf{X} は線源の分布を表す. 最後の等式では $\mathbf{Y}' = \mathbf{A}_{1\text{ray}}\mathbf{X}$ と定義した. このように定式化した上で, 本手法では 2 段階の最適化によって再構成画像を得る. まず, 取得した投影画像に対し, PSF の逆畳み込みを行う.

$$\mathbf{Y}' = \operatorname{argmax} P(\mathbf{Y}' | \mathbf{Y}, \mathbf{A}_{\text{PSF}}), \quad (2)$$

ここで, P は尤度関数である. 次に, \mathbf{Y}' を無限小ピンホールによる投影画像とみなし, 次のように画像再構成を行う.

$$\mathbf{X} = \operatorname{argmax} P(\mathbf{X} | \mathbf{Y}', \mathbf{A}_{1\text{ray}}) \quad (3)$$

3. シミュレーションによる評価

本研究では、提案手法を評価するため、モンテカルロ法による光子輸送計算を用いた画像再構成シミュレーションを行った。より現実的な条件にするため、ピンホール数は11個とし、PSFの空間依存性も計算に含めた。ピンホール径は5mmを仮定し、6台の検出器でデータを収集した。シミュレーションの具体的なジオメトリは図1(a)に示した。図1(b)に示した脳ファントムを使い、白および灰色領域からそれぞれ1000万、3000万個の光子を放出させ、投影画像を取得した(図2b)。この投影画像に対してRichardson-Lucyアルゴリズム[5]を適用し、PSFの




図1. 投影画像の比較. (a) シミュレーションジオメトリ. ファントムの周囲には6台の検出器を設置した. (b) 用いた脳ファントム.






図2. 投影画像の比較. (a) 無限小ピンホールによる投影画像. (b) モンテカルロ法で得た投影画像. (c) PSFの逆畳み込みを適用した投影画像.




図3. 再構成画像の比較. (a) 光線追跡, (b) 7-rays法, (c) 提案手法による再構成画像.

逆畳み込みを行った(図2c). 画像のボケが取れ、光線追跡による画像(図2a)に近づいたことがわかる. 最後にML-EM法を用いて画像再構成を行った.

図3に再構成画像の比較を示す. 7-rays法による再構成画像(図3b)と比べ、詳細な構造を再現できていることがわかる. 数値的な評価をしてみると、本手法による再構成画像のPSNRは16.9dB、SSIMは9.35となり、7-rays法による15.8dB、0.904を上回っている. これらの結果は、本手法によって空間分解能が改善されたことを明示している.

4. 結論

本研究では、我々が提案してきた空間分解能改善手法の有効性を示した. より現実的な条件で評価するため、11ピンホールシステム、空間依存性をPSFでシミュレーションを行った. 得られた再構成画像は、従来法と比べて詳細な構造を再現し、数値的にもより優れた画質を示した.

謝辞

本研究の一部は科研費基盤研究(C)22K12874の助成を受けたものです.

利益相反の有無

なし

文献

- [1] Ogawa K. and Ichimura Y.: Simulation study on a stationary data acquisition SPECT system with multi-pinhole collimators attached to a triple-head gamma camera system, *Ann. Nucl. Med.*, 28:716-724, 2014
- [2] Andreyev A., Defrise M., and Vanhove C.: Pinhole SPECT Reconstruction Using Blobs and Resolution Recovery, *IEEE Transaction on Nuclear Science*, 53, 5: 2719-2728, 2006.
- [3] Okoshi M., Murata K., Ogawa K.: Improvement of the Spatial Resolution With a Deconvolution Method for a Multi-pinhole SPECT System, *IEEE nuclear sciences symposium and medical imaging conference (NSS/MIC)*, 2021
- [4] Fujishiro Y., Murata K., Motomura N. et al.: Comparison of a Multi-pinhole Stationary SPECT System and a Parallel-hole High Speed Rotational SPECT system, *IEEE Nuclear Science Symposium and Medical Imaging Conference (NSS/MIC)*, 2019
- [5] Richardson W. H.: Bayesian-Based Iterative Method of Image Restoration, *Journal of the optical society of America*, 62,1: 55-59, 1972

深層学習を用いたピンホール SPECT システムにおける空間分解能の改善

島田 良^{*1}, 村田 一心^{*2}, 尾川 浩一^{*3}

^{*1} 法政大学大学院理工学研究科

^{*2} 国立天文台

^{*3} 法政大学理工学部

Improving Resolution in Pinhole SPECT Systems Using Deep Learning

Ryo SHIMADA^{*1}, Kazumi MURATA^{*2}, Koichi OGAWA^{*3}

^{*1} *Graduate School of Science and Engineering, Hosei University*

^{*2} *National Astronomical Observatory of Japan*

^{*3} *Faculty of Science and Engineering, Hosei University*

要旨：静止型マルチピンホール SPECT システムで得られる再構成画像の空間分解能を向上させる方法を提案する。静止型 SPECT 装置は、従来の SPECT 装置では不可能であった臓器の動的機能の計測が可能であるという利点がある。しかし、ピンホールの大きさが再構成画像に大きな影響を与えてしまうという欠点がある。従来では空間分解能の補正法に 7-rays 法が広く用いられてきた。しかし、この方法はピンホールが大きい場合に空間分解能が大きく低下してしまう。そこで本研究では、ディープラーニングを用いて無限小のピンホールに相当する投影データを推定し再構成を行うことで空間分解能を向上させる新たな画質改善手法を提案した。本研究ではモンテカルロシミュレーションによりデータセットとなる投影データを作成し検証を行った。その結果、提案手法による再構成画像は 7-rays 法よりも複雑な構造を再現することができ、正確な画像を取得できることが明らかとなった。

キーワード：静止型 SPECT システム, マルチピンホールコリメータ, 深層学習

1. はじめに

静止型 SPECT 装置は、時間情報や臓器の動的機能の計測を目的として近年研究が進んでいる。この装置のコリメータにマルチピンホールコリメータを採用しデータ取得を行うことで様々な角度から検出器に入射する光子を検出できる。これにより、検出器の投影方向を減らし、大幅な計測時間の短縮が可能になる [1-2]。しかし、再構成画像の空間分解能はコリメータのピンホールサイズに大きな影響を受ける。特に、ピンホール径が 3mm を超える場合では診断画像は大きく劣化してしまう。従来、空間分解能を改善するために 7-rays 法 [3] が広く適用されているが、ピンホールが大きい場合には十分な効果が得られない。そこで我々は、投影領域での空間分解能を大幅に向上させるデコンボリューションに基づく手法を開発した [2]。しかし、この方法は検出器ごとに正確な PSF を求める必要があることや、デコンボリューション処理に膨大な計算量がかかることなどの欠点がある。近年、深層畳み込みニューラルネットワーク (CNN) が小さな計算コストで画像再構成や雑音除去などの多くの画像処理で優れた結果を示している。そこで本論文では、比較的小さなデータセットで学習可能な U-net [4]

を用いて空間分解能を向上させる新たな画質改善手法を提案し、マルチピンホール SPECT 装置での画像再構成シミュレーションにより提案手法の性能評価を行った。

2. シミュレーション方法

本手法の実現性を評価するため、静止型マルチピンホール SPECT システムを用いたシミュレーションを行った。検出器のサイズを 512×256 pixel (ピクセルサイズ: 0.8 mm×0.8 mm)、検出器の有効面積は 400 mm×200 mm とした。コリメータプレートの厚さは 10 mm、ピンホールの直径は 5 mm、ピンホールの数は 11 個であり、各ピンホールはコリメータプレートの半分の深さにナイフエッジを持つ。ピンホールの開口角は 48 度とした。この 11 個のピンホールは、対象物の投影像が重ならないように配置した。対象物の中心からコリメータまでの距離は 25 cm、コリメータから検出器までの距離は 7.6 cm であった [1]。本シミュレーションでは、脳ファントムを使用した。再構成領域は 128×128×128 voxel、ボクセルサイズは 2.0 mm×2.0 mm×2.0 mm とした。ファントム内の光子の輸送にはモンテカルロ法を用いた。簡単のため散乱光子を無視し、エネルギー分解能は考慮しなかった。得られた投影に対し U-net を用いて空間分解能を補正し ML-EM 法で画像を再構成した。この時の反復回数は 50 回であった。また、比較のため 7-rays 法による画像再構成を行った。

*1 法政大学大学院理工学研究科

[〒184-8584 東京都小金井市梶野町 3 丁目 7-2]

e-mail: ryo.shimada.7z@stu.hosei.ac.jp

*2 国立天文台

*3 法政大学理工学部

3. ニューラルネットワーク

1) 学習データ

上記のシミュレーション条件により得られた脳ファントムの投影データを入力データとした。最大値で正規化された720枚の画像からなり、脳ファントムをランダムに回転させることでデータ拡張を行った。教師データは、無限小のピンホールで得られた理想的な投影データとした。

2) ネットワークの構成

U-netは縮小パス(左側)と拡張パス(右側)で構成されている。左側では 3×3 の畳み込み層にReLU関数が続き、 2×2 の最大プーリング層で2回の畳み込み演算ごとに半分ずつダウンサンプリングしている。合計3回のダウンサンプリングで入力データは 512×256 [pixel]から 64×32 [pixel]に縮小され、各ダウンサンプリングにおいて、特徴チャンネル数は2倍になり、最初の層では32チャンネル、最深部の層では256チャンネルになる。拡張パスでは、縮小パスと同じ畳み込み演算を行いアップサンプリングによりデータを拡張している。中央の青い矢印は、特徴マップを結合するためのものである。浅い層の特徴量と高い層の特徴量を結合し、局所の特徴を保持したまま全体的位置情報の復元を可能としている。最後の層は 1×1 畳み込みで、32チャンネルの層から2次元画像の出力に対応させるために用いた。図1に本研究で使用したU-netの構成を示す。




図1 ネットワークの構成

3) 学習方法

損失関数に平均二乗誤差を、最適化手法にAdamを採用した。結果は、バッチサイズ64、エポック数2000の学習パラメータに基づき得られた。

4. 結果と考察

再構成画像を図2に示す。無限小のピンホールで得られた理想的な画像(a)に比べ、7-rays法で補正した画像(b)は、ピンホール径の影響を受けかなりぼやけていることが分かる。一方、U-netで補正した画像(c)は、より細部の構造を再現しており、理想的な画像に近いことが確認できる。PSNR値は7-rays法が16.7dBであるのに対し、本提案手法は18.7dBであった。再構成画像のプロファイルを図3に示す。U-netを用いた際の再構成画像のプロファイルは理想的な画像とかなり一致している。これらの結果から、提案手法は従来の7-rays法よりもより正確な画像を取得できると考えられる。




図2 無限小ピンホールで得られた再構成画像(a)、7-rays法で得られた再構成画像(b)、提案手法で得られた再構成画像(c)。プロファイルは脳ファントムの中心に沿って設定した。




図3 再構成画像のプロファイル

5. まとめ

本論文では、静止型マルチピンホールSPECTシステムにおいて深層学習に基づく新たな画質改善手法の検討を行った。その結果、従来法と比べて空間分解能は有意に改善され、より詳細な構造を再構成できることが分かった。

謝辞

本研究の一部は科学研究費基盤研究(C) 22K12874による補助を受けた。

利益相反の有無

なし

文献

- [1] Fufushiro Y, Murata K, Motomura N et al: Comparison of a multi-pinhole stationary SPECT system and a parallel-hole high speed rotational SPECT system. *IEEE Nucl. Sci. Symp. Conf. Record (NSS/MIC)* 2019
- [2] Okoshi M, Murata K, Ogawa K et al: Improvement of the spatial resolution with a deconvolution method for a multi-pinhole SPECT system. *IEEE Nucl. Sci. Symp. Conf. Record (NSS/MIC)* 2021.
- [3] Andreyev A, Defrise M, Vanhove C et al: Pinhole SPECT reconstruction using blobs and resolution recovery. *IEEE Trans. Nucl. Sci.*, vol. 53, no. 5, pp. 2719-2728, 2006.
- [4] Ronneberger O, Fischer P, Brox T et al: U-net: Convolutional networks for biomedical image segmentation. *Lecture Notes in Computer Science*, vol. 9351, pp. 234-241, 2015.

順投影モデルを利用した Deep image prior ベース PET 画像再構成

橋本二三生^{*1}, 大手希望^{*1}, 大西佑弥^{*1}, 田島英朗^{*2}, 山谷泰賀^{*2}

^{*1} 浜松ホトニクス株式会社 中央研究所

^{*2} 量子科学技術研究開発機構 量子医科学研究所

Deep image prior-based PET image reconstruction using a forward projection model

Fumio HASHIMOTO^{*1}, Kibo OTE^{*1}, Yuya ONISHI^{*1}, Hideaki TASHIMA^{*2}, Taiga YAMAYA^{*2}

^{*1} *Central Research Laboratory, Hamamatsu Photonics K. K.*

^{*2} *Institute for Quantum Medical Science, National Institutes for Quantum Science and Technology*

要旨 : 計測データから直接断層像を生成する深層学習技術が, 新しい画像再構成法として注目されている. しかし, 従来の手法は多数の高品質なサイノグラム・再構成画像ペアが必要な教師あり学習であり, 装置や PET 薬剤の違いによる汎用性に課題がある. 本研究では, 学習データセットを必要としない Deep Image Prior(DIP)に順投影モデルを組み込むことで, サイノグラムから PET 画像再構成が可能となる手法を提案する. 提案手法では, Fully convolutional neural network(FCN)の出力画像に対し, ラドン変換を行う順投影モデルを組み込むことで推定サイノグラムを計算する. その後, 計測サイノグラムとの損失を DIP の枠組みを用いて最適化することで, FCN の出力層から再構成画像を取得する. 数値シミュレーションおよび実測データによる評価の結果, 我々の画像再構成法は学習データセットなしで再構成画像を取得でき, 他の画像再構成法と比べても, 高い定量性を維持しつつ灰白質の構造を明瞭に描出できることがわかった.

キーワード : Deep image prior, Positron emission tomography (PET), 3D PET image reconstruction, End-to-end learning

1. はじめに

深層学習は今や, Positron emission tomography (PET)画像のノイズ除去や画像再構成タスクの性能向上に欠かせないものとなっている. 特に, サイノグラムを Convolutional neural network (CNN)に入力し, 再構成画像を直接出力する End-to-end PET 画像再構成は, アーチファクトやノイズの少ない高品質な画像を提供できる可能性が示されている [1]. 一方で, これら深層学習ベースの画像再構成技術は, 一般的に高品質な再構成画像を含む学習データペアを大量に用意する必要がある.

最近, 大量の学習データセットを利用せず, CNN 構造そのものがノイズ除去の正則化として機能する Deep image prior (DIP)とよばれる深層学習技術が注目されている [2]. Gong らは従来の PET 画像再構成法である最尤推定法と, 画像空間上での DIP 処理を組み合わせた教師なし PET 画像再構成法を提案している [3]. 一方我々は, Gong らとは異なるアルゴリズムとして, DIP に順投影モデルを組み込んだ End-to-end PET 画像再構成を提案している [4]. しかし Graphics processing unit (GPU) のメモリサイズの制限により, End-to-end PET 画像再構成は 2 次元 PET データへの適用に留まっていた.

そこで本研究では, DIP の枠組みを利用した教師なし End-to-end PET 画像再構成を 3 次元 PET に拡張する方法を提案する. 提案する教師なし 3 次元 PET 画像再構成は, ブロック反復アルゴリズムを用いた単一の最適化問題として定式化されるため, 従来手法において調整が煩雑であったハイパーパラメータを削減することが可能である.

2. 方法

提案手法の概要を図 1 に示す. 本研究では, CNN 出力画像に対し Point spread function (PSF) 処理を行った後, 3 次元順投影モデルを組み込んでいる.

提案手法では, GPU のメモリ使用量を削減するため, 3 次元サイノグラムを複数のブロックに分割し, 以下のように各ブロックを順次更新する.

$$\theta^* = \underset{\theta}{\operatorname{argmin}} \sum_{m \in D} L(y_0^m | P^m \operatorname{PSF}(f(\theta|z))), \quad (1)$$

$$x^* = f(\theta^*|z), \quad (2)$$

ここで, $L(\cdot)$ は負の対数尤度関数, f は 3D U-net [3], θ は学習可能パラメータ, y_0 は計測サイノグラム, P は 3 次元システム行列, D は, 3 次元サイノグラムを M 個に分割したサブセットのアクセス順である. 再構成画像 x^* は 3D U-net の出力として表現される. 本研究では, 更なる画質向上のため Magnetic resonance 画像を解剖学的情報として用いた.

3. 結果

頭部用 PET 装置を想定し, モンテカルロシミュレーションを用いて 3 次元 PET データを生成した. 比較手法として, Maximum Likelihood Expectation Maximization (MLEM) 法, および Gong らの方法を用いた [3]. 3 次元サイノグラムおよび再構成画像のサイズはそれぞれ, 128 bin \times 128 angle \times 64 slice \times 19 oblique angle, 128 \times 128 \times 64 voxel である. 図 2 にシミュレ




図1 提案手法の概要図. 本手法では, 順投影計算を含めた end-to-end 学習により PET 画像再構成を行う. まず, MR 画像を CNN に入力し, 再構成画像を出力させる. 次に, 再構成画像を PSF 処理した後, 投影行列 P によりサイノグラムを計算する. 最後に, 前述サイノグラムと計測サイノグラムを用いて, 負の対数尤度を算出し, CNN の最適化を行う.




図2 再構成画像結果. 従来手法と比較し, 提案手法は CSF などの低放射能の構造をより明瞭に再現することができた.

ーション実験結果を示す. 提案手法は MLEM 法よりも鮮明な画像が得られた. また, Gong らの手法と比較すると, 提案手法は CSF などの低放射能の構造をより明瞭に再現することができた.

上記のことから, 提案した教師なし End-to-end 3 次元 PET 画像再構成法は, 学習データセットを一切利用することなく, 高品質な再構成画像を取得することが可能であった. また, 提案手法は調整が煩雑なハイパーパラメータを必要とせず, CNN の最適化処理のみを 1 ステップで実行する, より実用的な 3 次元 PET 画像再構成法であるといえる.

4. まとめ

本研究では, DIP と順投影モデルによる End-to-end 学習を利用した教師なし 3 次元 PET 画像再構成法を提案した. モンテカルロシミュレーションによる評価の結果, 本手法は他の手法と比較し, より明瞭な再構成画像を取得することができた. これらの結果は, 提案手法が高品質な学習データセットを一切利

用せず, 高品質な再構成画像が取得できる 3 次元 PET 画像再構成法であることが示された.

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

- [1] Häggström I, Schmidlein CR, 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
- [2] Ulyanov D, Vedaldi A and Lempitsky V: Deep image prior. Int J Comput Vis 128: 1867-1888 2020
- [3] Gong K, Catana C, Qi J et al.: PET image reconstruction using deep image prior. IEEE Trans Med Imaging 38: 1655-1665 2019
- [4] Hashimoto F, Ote K and Onishi Y: PET Image Reconstruction Incorporating Deep Image Prior and a Forward Projection Model. IEEE Trans Radiat Plasma Med Sci : 2022 in press

第 41 回日本医用画像工学会大会 (JAMIT2022)

大会役員委員会名簿

五十音順・敬称略

大会役員		
大会長		
	森 健策	名古屋大学
大会長補佐		
	北坂 孝幸	愛知工業大学
業務委員長		
	湯澤 史佳	キャノンメディカルシステムズ株式会社
プログラム委員会		
委員長		
	小田 昌宏	名古屋大学
委員		
	明石 敏昭	順天堂大学
	有村 秀孝	九州大学
	伊藤 聡志	宇都宮大学
	上村 幸司	国立循環器病研究センター
	内山 良一	熊本大学
	小尾 高史	東京工業大学
	河田 佳樹	徳島大学
	北村 圭司	株式会社 島津製作所
	木戸 尚治	大阪大学
	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
	椎名 毅	芝浦工業大学
	清水 昭伸	東京農工大学
	周 向榮	岐阜大学
	庄野 逸	電気通信大学
	陣崎 雅弘	慶応義塾大学
	菅 幹生	千葉大学
	杉本 直三	京都大学
	滝沢 穂高	筑波大学
	田中 利恵	金沢大学
	陳 延偉	立命館大学
	中尾 恵	京都大学
	中口 俊哉	千葉大学
	根本 充貴	近畿大学
	野村 行弘	千葉大学
	橋本 正弘	慶応義塾大学
	畑中 裕司	大分大学
	花岡 昇平	東京大学
	羽石 秀昭	千葉大学
	原 武史	岐阜大学
	原口 亮	兵庫県立大学
	平野 靖	山口大学
	本谷 秀堅	名古屋工業大学
	増谷 佳孝	広島市立大学
	宮崎 靖	富士フイルムメディカル株式会社
	目加田慶人	中京大学
	山谷 泰賀	量子科学技術研究開発機構
	湯浅 哲也	山形大学
現地実行委員会		
委員長		
	林 雄一郎	名古屋大学
委員		
	伊東 隼人	名古屋大学
	砂口 尚輝	名古屋大学
	目加田慶人	中京大学

日本医用画像工学会 (JAMIT)
 役員名簿
 (令和4年6月9日現在)

五十音順・敬称略

	氏名	所属	
会 長	工藤 博幸	筑波大学	
副 会 長	佐藤 嘉伸	奈良先端科学技術大学院大学	
	原 武史	岐阜大学	
	森 健策	名古屋大学	
理 事	伊藤 聡志	宇都宮大学	
	北坂 孝幸	愛知工業大学	
	滝沢 穂高	筑波大学	
	中田 典生	東京慈恵会医科大学	
	畑中 裕司	大分大学	
	花岡 昇平	東京大学	
	増谷 佳孝	広島市立大学	
	宮崎 靖	日立製作所	
	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	
	代議員	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	
陣崎 雅弘		慶応義塾大学	
杉本 直三		京都大学	
銭谷 勉		弘前大学	
高橋 哲彦		群馬県立県民健康科学大学	
武田 徹		青柳病院	
健山 智子		藤田医科大学	
田中 利恵		金沢大学	
陳 延偉		立命館大学	
寺本 篤司		藤田医科大学	
土居 篤博		富士フイルム	
縄野 繁		新松戸中央総合病院	
根本 充貴		近畿大学	
野崎 太希		聖路加国際病院	
野村 行弘		千葉大学	
長谷川純一		中京大学	
羽石 秀昭		千葉大学	
平野 靖		山口大学	
本谷 秀堅		名古屋工業大学	
山谷 泰賀		量子科学技術研究開発機構 放射線医学総合研究所	
吉川 悦次		浜松ホトニクス	
監 事		森田 尚孝	島津製作所
		清水 昭伸	東京農工大学