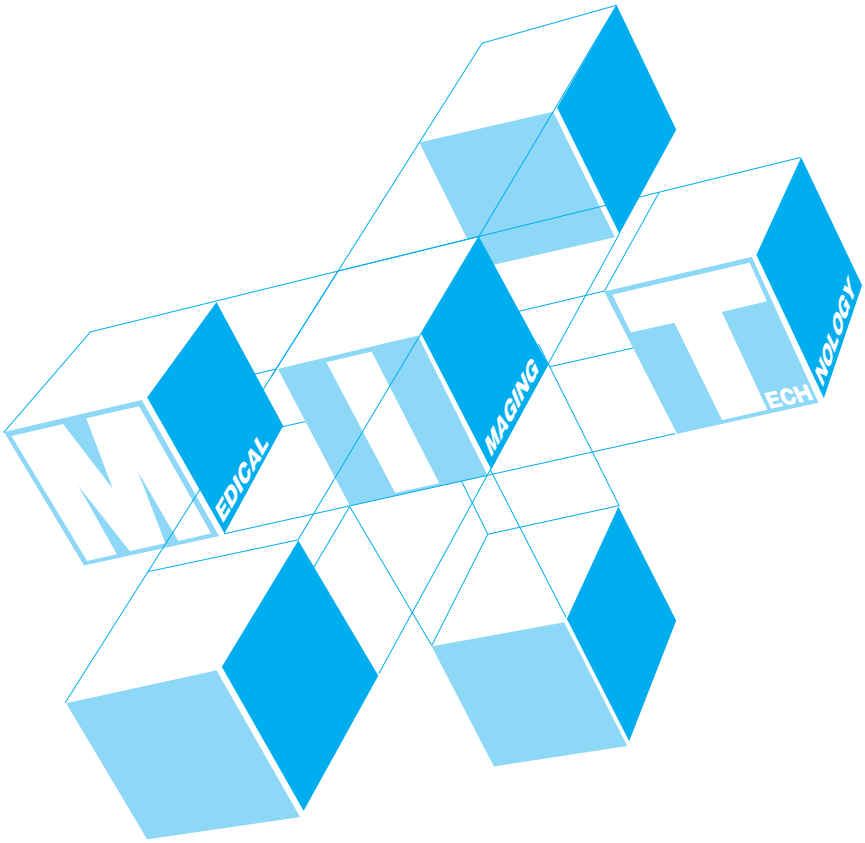
JAMIT Annual Meeting 2024
第43回日本医用画像工学会大会

会　期：2024 年 8 月 5 日(月)～ 7 日(水)
会　場：一橋講堂(一橋大学 学術総合センター内)
大会長：清水 昭伸(東京農工大学)



主 催:　一般社団法人 日本医用画像工学会
後 援:　一般社団法人 電子情報技術産業協会
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

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 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 日本応用数理学会
一般社団法人 日本核医学会
一般社団法人 日本コンピュータ外科学会
一般社団法人 日本写真学会
公益社団法人 日本超音波医学会
一般社団法人 日本メディカルAI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
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
日本画像医学会
一般社団法人 日本磁気共鳴医学会
公益社団法人 日本生体医工学会
公益社団法人 日本放射線技術学会

学会長ご挨拶

第 43 回日本医用画像工学会大会（JAMIT 2024）を，会期 8/5(月) ～ 8/7(水) にわたって，一橋大学千代田キャンパス（学術総合センター内）の一橋講堂にて清水昭伸先生（東京農工大学）大会長のもと開催させていただくことになりました．JAMIT2024 のテーマは，清水昭伸先生に「AI 時代のレギュラトリーサイエンス」と決定していただきましたが，その意図を以下に述べさせていただきます．2010 年代中盤までの医用画像技術の最大の悩みは，多くの優れた研究成果や論文があってもなかなか実用化に至らない点にありました．これに対して，2010 年代中盤に始まった AI や深層学習に基づく医用画像技術はその問題点をほぼ克服して，直近の 10 年間で産官学が一体となり世界的に医用画像技術の実用化が急速に進んでいる状況にあります．JAMIT 大会もこの革新的な進歩とともに歩んできた歴史があり，以下は過去の JAMIT 大会のテーマですが，基礎から応用へ・工学から医学応用へ・医学応用から実用化へ，の流れで医用画像分野が発展している様子が感じられます．

JAMIT2018「イメージング技術の新潮流と AI が結合した近未来の医用画像工学を探る」
JAMIT2019「AI 時代の医用画像工学」
JAMIT2020「AI 画像：診断から治療へ」
JAMIT2021「新たな潮流を目指して」
JAMIT2022「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」
JAMIT2023「臨床サイドからみた医療 AI ～あらたなる飛躍をめざして～」

一方で，実用化を達成するためには，技術の良さだけでは不十分で，研究サイドは医薬品医療機器総合機構などによる承認をどのように得るか，行政サイドでは安全性を確保する方法や規制をどのように構築するかなど，科学的知見と規制などの行政施策・措置との間の橋渡しのための科学，が必要になります．これらを統合した新分野が「レギュラトリーサイエンス」で，JAMIT 会員の方の多くがまだよく知らない新鮮な分野といえると思います．そこで，医用画像解析技術の実用化や行政への参画などを通してレギュラトリーサイエンスをよく知る清水昭伸先生に大会長をお願いして，皆でレギュラトリーサイエンスについて学ぶ大会にしたいと考えました．

既に清水先生を中心に考えていただいた企画物は魅力的なものが準備できており，一般演題も COVID-19 流行前を超える約 110 件の発表申し込みがありました．以下に全体像を紹介させていただきます．特別講演は，AI 分野の著名研究者である東京大学の原田達也先生に，画像と言語の基盤モデルの現状とこれからに関するご講演をいただけることになり，私自身も非常に楽しみにしています．チュートリアルは，JAMIT が 2012 年に出版した「医用画像工学ハンドブック」以降の技術進歩を増補するため現在発刊を進めている「医用画像工学ハンドブック増補版」（2024 年度中に発刊予定）の紹介を，執筆者の先生方にしていただくセッションを企画しました．シンポジウムは，レギュラトリーサイエンスに関する PMDA・厚労省・医療 AI 推進機構の方と医療機器の開発に携わった経験をお持ちの著名な臨床研究医の先生方をお呼びしてのセッション「AI 時代のレギュラトリーサイエンスについて」，JAMIT のお家芸である医用イメージングの話題をモダリティごとに紹介するセッション「医用イメージングの新潮流」，JAMIT2022 から新たに開始して第 3 回目になる「JAMIT の未来をつくろう」，の 3 つを企画しました．「JAMIT の未来をつくろう」について詳しく紹介させてください．このシンポジウムで取り扱う内容は若手研究者を意識したもので，「研究の方法論や様式が目まぐるしく変化する現代において，若手研究者が元気に活躍して成功を納め JAMIT の未来を作るにはどうすればよいか」という大変難しいながら重要な問題です．元気のよい若手研究者に思いや本音を述べてもらう，年配研究者から若手研究者に問いかけ，のようなスタイルのシンポジウム．過去の 2 回の成果が実を結び，「医用画像若手シンポジウム（SAMIT）」の新設（毎年秋に開催）や JAMIT 若手委員会の新設，などの形で成果になり，若手が活動しやすい学会に JAMIT が変遷してきている様子が感じられます．その他，ハンズオンセミナー・ランチョンセミナー・企業展示に関しては，例年通りの魅力あるものを準備しています．最後に，COVID-19 の流行以降 4 年間実施できなかった懇親会を今回から再開することになり，各々の医用画像技術に関する議論や交流のみならず共同研究先や友人の開拓に是非ご活用ください．会員集会では，例年と同様に功績賞の表彰式を実施します．

また，今回の JAMIT2024 から，6 つの学会（日本放射線技術学会，日本医学物理学会，医用画像情報学会，日本応用数理学会，日本コンピュータ外科学会，日本メディカル AI 学会）との大会参加費優遇制度が始まります．上記の関連学会の会員の方は JAMIT 会員と同じ参加費で大会に出席できる制度です．JAMIT の声がけで関連学会にご賛同いただき実現したもので，関連学会の方にも参加しやすい大会になっています．また，JAMIT の学生会員の方には JAMIT2023 から参加費と入会金を値下げして，参加しやすくなっています．

JAMIT 大会を都心で開催するのは第 33 回大会（福田国彦先生大会長：東京慈恵会医科大学にて開催）以来 10 年ぶりになります．今回の会場の一橋大学はアクセスがよく，COVID-19 の流行も治まりアフターファイブの時間帯で交流を深めることも可能であり，JAMIT2024 に多くの方が参加されることを期待しています．COVID-19 が治まるまでかなりの年月がかかり毎年苦労して大会を実施してきましたが，今回の大会から COVID-19 前にほぼ完全に戻ると思います．是非 JAMIT 大会を覗いてみてください．

日本医用画像工学会（JAMIT）
会長　工藤 博幸

大会長ご挨拶

第 43 回日本医用画像工学会大会（The 43rd JAMIT Annual Meeting (JAMIT2024)）は，2024 年 8 月 5 ～ 7 日の日程で，一橋大学 千代田キャンパス（学術総合センター内）の一橋講堂にて開催する運びとなりました．テーマは,「AI 時代のレギュラトリーサイエンス」です．現在，診断支援や治療支援のためのさまざまな医療機器プログラム（Software as a Medical Device：SaMD）が，実用化のフェーズを迎えています．このテーマは，AI の特性を踏まえた最近のレギュラトリーサイエンス（規制科学）に注目して設定しました．本大会では，このテーマを中心に，下記の多彩な企画を用意しました．

まず，大会初日の 8/5（月）の午前と午後には，現在 JAMIT が発刊準備をしている医用画像工学ハンドブック増補分冊「Part Ⅰ：映像化技術編」と「Part Ⅱ：画像処理と解析編」のそれぞれから，重要なトピックを取り上げて，著者みずからが分かりやすく解説するチュートリアルを実施します．続いて，午後には，シンポジウム「医用イメージングの新潮流」を開催します．4 名の気鋭の研究者による最新の医用イメージング技術に関するシンポジウムです．

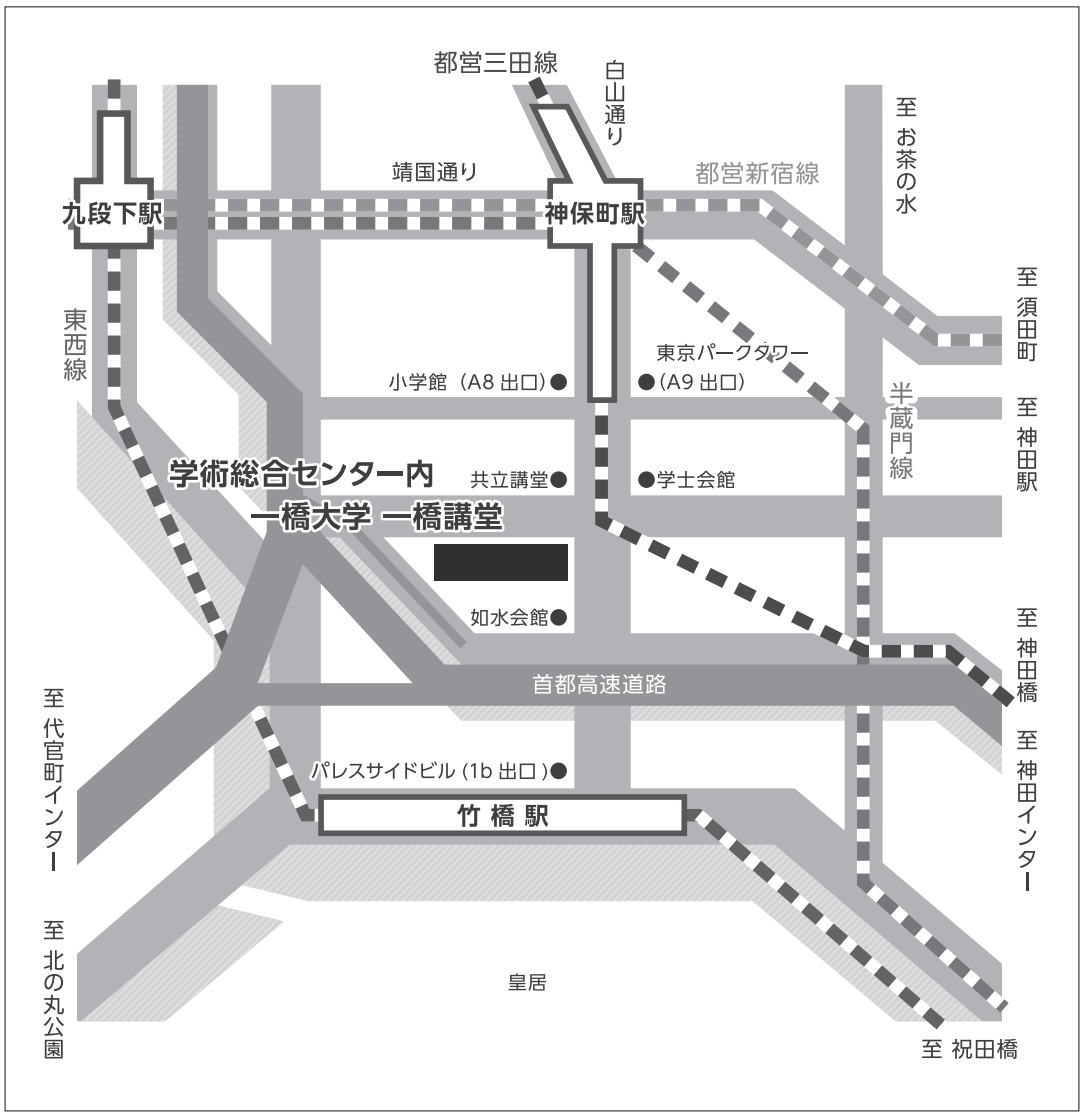
二日目の 8/6（火）の午前には,最新の AI についての理解を深めていただく機会として,国際的にご活躍されている東京大学の原田達也先生から，画像と言語の基盤モデルの現状とこれからについて，お話をしていただきます．続いて午後には，本大会のテーマに関連するシンポジウム「AI 時代のレギュラトリーサイエンス」を開催します．演者には，この分野の第一線でご活躍の東京慈恵会医科大学の村山雄一先生に続いて，医薬品医療機器総合機構（PMDA），厚生労働省，産業界，学術界からエキスパートの方々をお迎えして，SaMD を実用化する際の種々の問題に関して，パネル討論を含むシンポジウムを開催します．

最終日の 8/7（水）の午前には，JAMIT2022 より始まった，若手研究者によるシンポジウム「JAMIT の未来を作ろう！」を今年も開催します．若手のみずみずしい力によってこの分野を未来に向けて力強く牽引することを目指し，今年も若手研究者を中心に魅力ある企画を用意します．

その他，大会二日目（8/6）と三日目（8/7）には，毎年ご好評をいただいている深層学習のハンズオンセミナーを実施します．また，今年は，例年を大きく上回る約 110 件の一般演題の申し込みをいただいており，これらの演題の発表も楽しんでいただければと思います．　加えて，今回の JAMIT2024 から，6 つの学会（日本放射線技術学会，日本医学物理学会，医用画像情報学会，日本応用数理学会，日本コンピュータ外科学会，日本メディカル AI 学会）との大会参加費優遇制度が始まります．大会当日は,さまざまな学会の方々との交流も楽しんでいただければ幸いに存じます．多数の皆様のご参加をお待ちしております．

第 43 回日本医用画像工学会大会
大会長　清水　昭伸（東京農工大学）

交通案内



一橋大学 一橋講堂

〒101-8439　東京都千代田区一ツ橋2-1-2　学術総合センター内

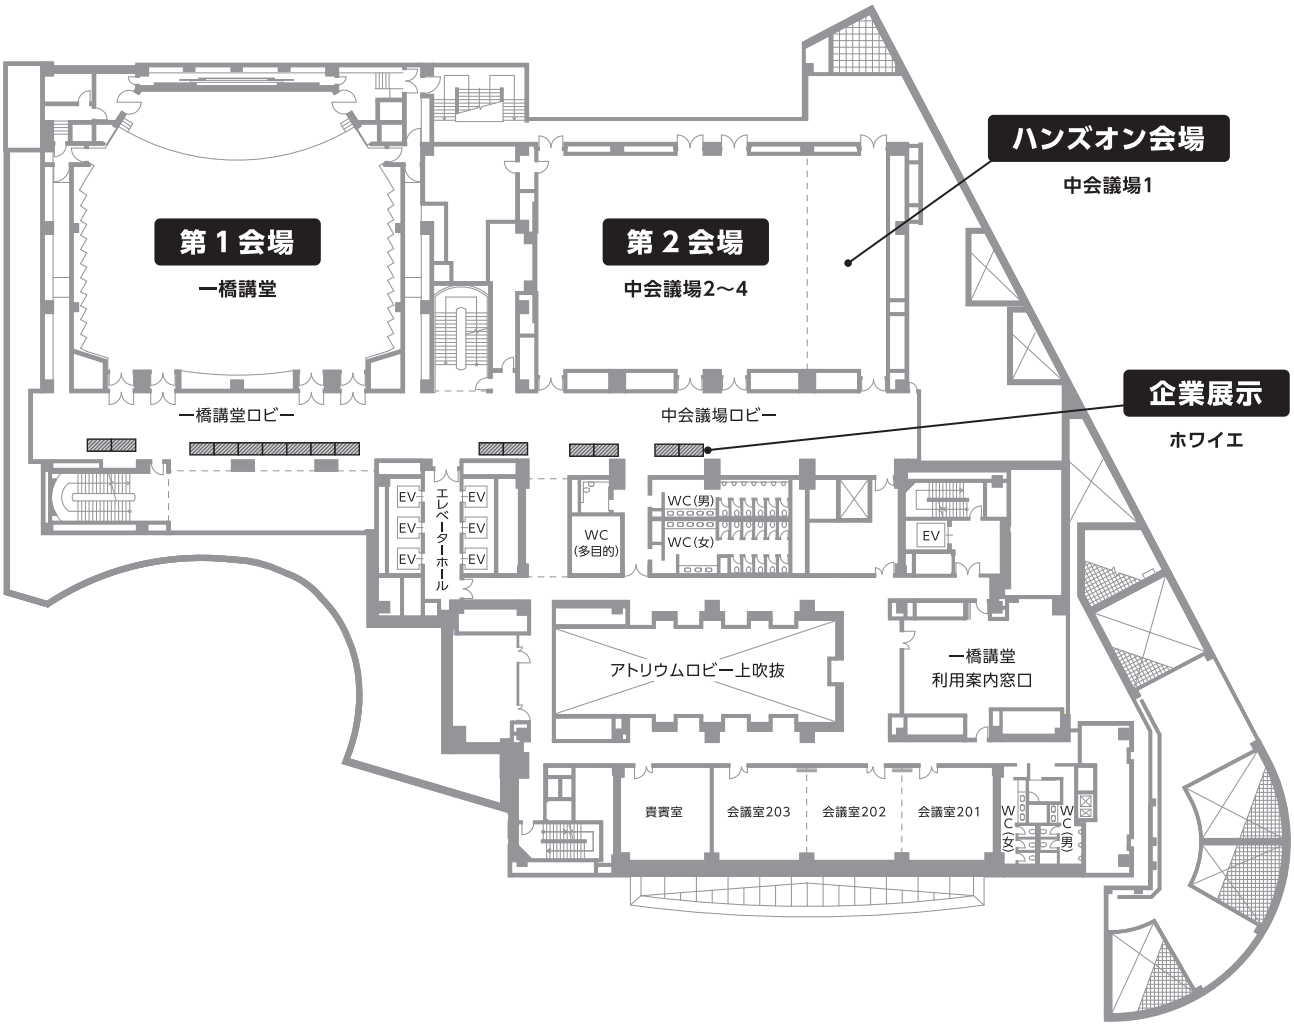
■ アクセス

東京メトロ半蔵門線、都営三田線、都営新宿線　　神保町駅（A8・A9出口）徒歩4分

東京メトロ東西線　　竹橋駅（1b出口）徒歩4分

会場案内図

一橋講堂 2F



参加者へのご案内

1. 会 期：2024 年 8 月 5 日（月）～ 8 月 7 日（水）

2. 会 場：一橋講堂

〒101-8439 東京都千代田区一ツ橋 2 丁目 1 － 2 学術総合センター 2F
一橋大学 千代田キャンパス
https://www.hit-u.ac.jp/hall/

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．当日は，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://jamit2024.jamit.jp/registration.html

1） 登録期間：4 月 30 日（火） ～ 8 月 7 日（水）
2） 参加費：正会員（賛助会員含む）：13,000 円
学生会員：2,000 円
関連学会会員：13,000 円
関連学会学生会員：2,000 円
非会員一般：20,000 円
非会員学生：4,000 円
3）関連学会：下記 7 学会の会員の方は正会員と同価格でご参加いただけます。
応用物理学会，日本医学物理学会，医用画像情報学会，日本放射線技術学会，
日本コンピュータ外科学会，日本応用数理学会，日本メディカル AI 学会
4）現地受付開設時間
8 月 5 日（月） 10:00 ～ 18:00
8 月 6 日（火） 9:15 ～ 18:00
8 月 7 日（水） 9:15 ～ 15:30

4. 会員集会

日時：8 月 6 日（火） 13:20 ～ 14:20 会場：第 1 会場（一橋講堂）

5. 予稿集について

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

6. 発表者へのご案内

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

7. 座長へのご案内

担当セッションが始まる 10 分前までに，会場の前方の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 28 日までに入会のお申込みをいただき，7 月 12 日(金)までに会費を納入してください.

9. 入会手続き及びお問い合わせ

日本医用画像工学会事務局（http://www.jamit.jp/）

〒1043-0013 東京都中央区日本橋人形町 2-24-4

にほんばしコスモ 15 ビル （株）メイプロジェクト内

TEL: 03-6667-0922　FAX: 03-6661-1490　E-mail: taikai@jamit.jp

10. 利益相反（COI）について

筆頭発表者が，　日本医用画像工学会における「利益相反の取扱いに関する規程」（http://www.jamit.jp/outline/agreement/rules_riekisohan.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 14 回 JAMIT チュートリアル講演会（教育委員会企画）
JAMIT ハンドブック増補版（発刊予定）チュートリアル

第 43 回日本医用画像工学会大会のプログラムの一環として「医用画像工学ハンドブック増補版（発刊予定）チュートリアル」を第 1 日目に開催いたします。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。

JAMIT ハンドブック増補版（発刊予定）チュートリアル Part I
「映像化技術論」
日　時：8 月 5 日（月）　10:40～12:10
座　長：橋本　二三生（浜松ホトニクス株式会社）
　　野崎　太希（慶応義塾大学）
TU1-1　最新の医用イメージングにおける画像再構成法の紹介
　　工藤　博幸　（筑波大学）
TU1-2　MRI の最近の技術的発展
　　寺田　康彦　（筑波大学　数理物質系　物理工学域）
TU1-3　核医学装置ー10 年間の進歩
　　田島　英朗　（量子科学技術研究開発機構）
TU1-4　X 線イメージングと放射線治療用イメージングの概要
　　臼井　桂介　（順天堂大学保健医療学部診療放射線学科）

JAMIT ハンドブック増補版（発刊予定）チュートリアル Part II
「画像処理と解析編」
日　時：8 月 5 日（月）　13:30～15:00
座　長：中田　典生　先生（東京慈恵会医科大学）
　　滝沢　穂高　先生（筑波大学）
TU2-1　深層学習の 10 年間の進歩概要と今
　　本谷　秀堅　（名古屋工業大学）
TU2-2　深層学習におけるドメイン適応
　　庄野　　逸　（電気通信大学）
TU2-3　教師データの不足を補う: 少数データに対する機械学習手法概要
　　備瀬　竜馬　（九州大学）

12. ジーデップ・アドバンス　JAMIT ハンズオンセミナー
（教育委員会企画）

ハンズオンセミナーは，資料に基づいて参加者の PC に環境を構築し，すぐにでも実験ができる環境を提供します．2024 年度は，PyTorch の利用を中心として，DICOM 画像（CT，MR 画像）や病理画像（バーチャルスライド画像）の取り扱い，ROC 解析などの統計的な手法を用いた評価も取り扱います．いずれも入門から中級程度の課題を用意し，深層学習を利用した実験の流れを実践的に習得します．セミナーでは課題 1 から課題 4 を用意します（各回 90 分）．ご興味ある課題を自由に受講ください．それぞれ受講人数を 24 名程度に制限します．なお，ハンズオンの参加には JAMIT2024 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：深層学習超入門
　　「画像の分類と領域分割：転移学習と Fine-Tuning」
課題 2：ハンズオンセミナー・コンテスト
　　「胸部 X 線画像の分類と ROC 解析」
課題 3：深層学習のための前処理と後処理
　　「DICOM 画像・バーチャルスライド画像の読み込み／ROC などの統計処理」
課題 4：幅広い深層学習
　　「言語処理や音声認識における深層学習技術」
※内容は変更となる場合があります

ハンズオンセミナー・コンテスト

これまでのハンズオンセミナーは，画像分類や回帰，領域分割を 2017 年から取り上げてきました．2024 年度はそれらの小規模チャレンジとして，胸部 X 線画像から性別を推定する精度をみなさんで比較する「ハンズオンセミナー・コンテスト」を企画しました．参加対象は，最近深層学習の研究や実験を始めた初学者／初級者の個人／グループです．サンプルプログラムとデータ，実行環境はハンズオンセミナーのウェブページで配布します．期間中に実施する「JAMIT2024 ハンズオンセミナー・コンテスト」では，主催者がもつ画像データを公開し，その性別を回答していただきます．優秀な結果となった個人／グループを表彰します．奮ってご参加ください．詳細はハンズオンセミナーのウェブサイトをご覧ください．

開催形態・会場

ハンズオンセミナーは，会場内の 1 部屋を利用して対面形式で実施します．事前に公開するセットアップ資料と題材に基づいて，セミナー開催までにご自身の PC に環境を構築して，その PC をご持参ください．もしくは会場に持参した PC から環境構築済みの PC 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 JAMIT2024 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，JAMIT2024 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 14 日　セットアップ資料の公開／コンテストサンプルプログラム・データの公開
7 月 28 日　セミナー資料の公開
8 月 6〜7 日 ハンズオンセミナー開催（大会 2 日目と 3 日目）
8 月 6 日　　9:20〜　課題 1,　　16:30〜　課題 2
8 月 7 日　　9:10〜　課題 3,　　14:00〜　課題 4
（各回の予定：90 分）

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

運営スタッフ

原　武史（岐阜大学）／滝沢　穂高（筑波大学）／中田　典生（東京慈恵医科大学）／
小田　昌宏（名古屋大学）／近藤　世範（新潟大学）

協力

本セミナーは，株式会社ジーデップ・アドバンスの支援を得て実施しています。また，岐阜大学人工知能研究推進センター，東海国立大学機構健康医療ライフデザイン統合研究教育拠点の協力で実施します．

ハンズオンのウェブサイト

http://micv.sakura.ne.jp/jamitho/

ご 協 力 団 体

本大会は下記企業及び団体にご協力いただきました．心より感謝申し上げます．

イーグロース株式会社
医歯薬出版株式会社
株式会社医用工学研究所
HPC システムズ株式会社
株式会社 HPC テック
霞クリニック
カリスト株式会社
キヤノンメディカルシステムズ株式会社
GE ヘルスケア・ジャパン株式会社
株式会社ジーデップ・アドバンス
シーメンスヘルスケア株式会社
シスメックス株式会社
テガラ株式会社
日本メジフィジックス株式会社
バイエル薬品株式会社
浜松ホトニクス株式会社
PDR ファーマ株式会社
富士フイルム株式会社
富士フイルムソフトウエア株式会社
菱洋エレクトロ株式会社

（五十音順／2024 年 6 月 12 日 現在）

後 援： 一般社団法人 電子情報技術産業協会
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

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
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 日本応用数理学会
特定非営利活動法人 日本核医学技術学会
一般社団法人 日本核医学会
日本画像医学会
一般社団法人 日本コンピュータ外科学会
一般社団法人 日本磁気共鳴医学会
一般社団法人 日本写真学会
公益社団法人 日本生体医工学会
公益社団法人 日本超音波医学会
公益社団法人 日本放射線技術学会
一般社団法人 日本メディカル AI 学会

助 成： 公益財団法人 村田学術振興・教育財団

第1日目／8月5日(月)

	第1会場 2F　一橋講堂	第2会場 2F　中会議室2～4	ハンズオン会場 2F　中会議室1
9:00			
10:00			
11:00	10:30～10:40 開会式 10:40～12:10 JAMIT ハンドブック増補分冊（発刊予定） チュートリアル Part I 映像化技術編 座長：橋本 二三生、野崎 太希 演者：工藤 博幸、寺田 康彦、田島 英朗、臼井 桂介		
12:00			
13:00			
14:00	13:30～15:00 JAMIT ハンドブック増補分冊（発刊予定） チュートリアル Part II 画像処理と解析編 座長：中田 典生、滝沢 穂高 演者：本谷 秀堅、庄野 逸、備瀬 竜馬		
15:00	15:10～16:40 シンポジウム 1 医用イメージングの新潮流 座長：工藤 博幸 演者：戸田 尚宏、橋本 雄幸、伊藤 聡志、木村 裕一	15:00～16:00 一般演題 2 画像生成 OP2-1～OP2-6 座長：中山 良平、花岡 昇平	
16:00		16:10～17:00 一般演題 3 セグメンテーション 1 OP3-1～OP3-5 座長：有村 秀孝、野村 行弘	
17:00	16:50～18:00 一般演題 1 放射線画像再構成 1 OP1-1～OP1-7 座長：湯浅 哲也、尾崎 翔	17:10～18:00 一般演題 4 臓器モデリング OP4-1～OP4-5 座長：大竹 義人、伊東 隼人	
18:00			
19:00			

第２日目 ／ 8月6日(火)

	第１会場 ２Ｆ　一橋講堂	第２会場 ２Ｆ　中会議室２～４	ハンズオン会場 ２Ｆ　中会議室１
9:00			
			9:20 ～ 10:50 **ハンズオンセミナー１** 深層学習超入門
10:00	9:40 ～ 10:50 **一般演題５** 推定・予測１ OP5-1 ～ OP5-7 座長：畑中 裕司、目加田 慶人	9:40 ～ 10:40 **一般演題８** MR 画像再構成 OP8-1 ～ OP8-6	
11:00	11:00 ～ 12:00 **特別講演** 画像と言語の基盤モデルの現状とこれから 座長：清水 昭伸 演者：原田 達也		
12:00		12:10 ～ 13:10 **ランチョンセミナー** 共催：株式会社ジーデップ・アドバンス	
13:00	13:20 ～ 14:20 **会員集会**		
14:00			
15:00	14:30 ～ 16:30 **シンポジウム２** AI 時代のレギュラトリーサイエンス 座長：中岡 竜介 演者：村山 雄一、江面 崇智、水谷 玲子、島原 佑基、三澤 将史	14:30 ～ 15:30 **一般演題９** 微細構造解析 OP9-1 ～ OP9-6 座長：橋本 典明、彌冨 仁	
16:00			
17:00	16:40 ～ 17:30 **一般演題６** 基盤モデル・連合学習 OP6-1 ～ OP6-5 座長：本谷 秀堅、黒瀬 優介		16:30 ～ 18:00 **ハンズオンセミナー２** ハンズオンセミナー・コンテスト
18:00	17:30 ～ 18:20 **一般演題７** CAD1 OP7-1 ～ OP7-5 座長：滝沢 穂高、佐藤 嘉伸		
19:00		18:30 ～ 20:00 **懇親会**	

第３日目／８月７日（水）

	第１会場	第２会場	ハンズオン会場
	２Ｆ　一橋講堂	２Ｆ　中会議室２～４	２Ｆ　中会議室１
9:00			
			9:10～10:40 **ハンズオンセミナー３** 深層学習のための前処理と後処理
10:00	9:30～10:30 **一般演題 10** CAD2 OP10-1～OP10-6 座長：庄野 逸、橘 理恵	9:30～10:20 **一般演題 14** 放射線画像再構成２・画像変換 OP14-1～OP14-5 座長：橋本 二三生、花岡 昇平	
		10:30～11:20 **一般演題 15** 推定・予測２ OP15-1～OP15-5 座長：根本 充貴、小橋 昌司	
11:00	10:40～12:10 **シンポジウム３** JAMITの未来を作ろう！ 座長：岡本 尚之、伊東 隼人 パネリスト：皆川 智哉、大村 眞朗、関川 祐矢、武山 彩織、渕辺 章太郎	11:20～12:10 **一般演題 16** MRイメージング OP16-1～OP16-5 座長：増谷 佳孝、伊藤 聡志	
12:00			
13:00			
	13:30～14:30 **一般演題 11** CAD3 OP11-1～OP11-6 座長：河田 佳樹、砂口 尚輝	13:30～14:30 **一般演題 17** 核医学イメージング OP17-1～OP17-6 座長：羽石 秀昭、小尾 高史	
14:00			14:00～15:30 **ハンズオンセミナー４** 幅広い深層学習
15:00	14:40～15:30 **一般演題 12** セグメンテーション２ OP12-1～OP12-5 座長：滝沢 穂高、杉本 直三	14:40～15:30 **一般演題 18** 内視鏡・手術映像等 OP18-1～OP18-5 座長：中口 俊哉、林 雄一郎	
	15:40～16:30 **一般演題 13** セグメンテーション３ OP13-1～OP13-5 座長：小田 紘久、神谷 亨	15:30～16:30 **一般演題 19** 医療情報・教育 OP19-1～OP19-6 座長：北坂 孝幸、田中 利恵	
16:00	16:30～16:40　**閉会式**		
17:00			
18:00			
19:00			

特別講演

8月6日（火）

第1会場（一橋講堂）

特別講演

11:00 ～ 12:00　**SL「画像と言語の基盤モデルの現状とこれから」**

座長：清水　昭伸（東京農工大学）

SL

原田　達也
東京大学，理化学研究所，国立情報学研究所

シンポジウム

8月5日（月）

第1会場（一橋講堂）

シンポジウム1

15:10 ～ 16:40　**SY1「医用イメージングの新潮流」**

座長：工藤　博幸（筑波大学）

SY1-1　散乱を用いたX線CT
戸田　尚宏
愛知県立大学　情報科学部　情報科学科

SY1-2　画像再構成の最新の話題
橋本　雄幸
杏林大学　保健学部　診療放射線技術学科

SY1-3　深層学習を利用したMR画像再構成の新展開
伊藤　聡志
宇都宮大学 大学院工学研究科 地域創成科学専攻 情報電子オプティクスコース

SY1-4　PETの現状 － 装置開発及び臨床応用
木村　裕一
近畿大学情報学部情報学科，近畿大学情報学研究所

8月6日（火）

第1会場（一橋講堂）

シンポジウム2

14:30 ～ 16:30　**SY2「AI時代のレギュラトリーサイエンス」**

座長：中岡　竜介（国立医薬品食品衛生研究所）

SY2-1　医療ICTシステムの課題と将来展望
村山　雄一
東京慈恵会医科大学　脳神経外科

SY2-2　国内におけるプログラム医療機器の審査について
江面　崇智
独立行政法人医薬品医療機器総合機構 プログラム医療機器審査室

SY2-3　プログラム医療機器に関する最近の規制動向
水谷　玲子
厚生労働省 医薬局 医療機器審査管理課 プログラム医療機器審査管理室

SY2-4　日本が医療AI先進国になるためにできること
島原　佑基
医療AI推進機構

SY2-5　大腸内視鏡 AI の開発から保険償還獲得の経験

三澤　将史
昭和大学横浜市北部病院　消化器センター

8 月 7 日（水）

第 1 会場（一橋講堂）

シンポジウム 3

10:40 ～ 12:10　**SY3「JAMIT の未来を作ろう！ 2024」**

座長：岡本　尚之（千葉大学フロンティア医工学センター）
伊東　隼人（福岡大学理学部応用数学科）

（パネリスト）

皆川　智哉
東邦大学医療センター大橋病院 放射線部
大村　眞朗
富山大学学術研究部工学系
関川　祐矢
帝京大学大学院保健学研究科
武山　彩織
東京工業大学工学院情報通信系
渕辺章太郎
GE ヘルスケア・ジャパン株式会社

JAMIT ハンドブック増補分冊（発刊予定）チュートリアル

8 月 5 日（月）

第 1 会場（一橋講堂）

JAMIT ハンドブック増補分冊（発刊予定）チュートリアル Part I

10:40 ～ 12:10　**TU1「映像化技術編」**

座長：橋本二三生（浜松ホトニクス株式会社）
野崎　太希（慶應義塾大学医学部　放射線科学教室）

TU1-1　最新の医用イメージングにおける画像再構成法の紹介
工藤　博幸
筑波大学システム情報系情報工学域，東北大学国際放射光イノベーション・スマート研究センター（SRIS）

TU1-2　MRI の最近の技術的発展
寺田　康彦
筑波大学　数理物質系　物理工学域

TU1-3　核医学装置 － 10 年間の進歩
田島　英朗
量子科学技術研究開発機構

TU1-4　X 線イメージングと放射線治療用イメージングの概要
臼井　桂介
順天堂大学保健医療学部診療放射線学科，順天堂大学大学院保健医療学研究科診療放射線学専攻，順天堂大学医学部放射線治療学講座

JAMIT ハンドブック増補分冊（発刊予定）チュートリアル Part II

13:30 ～ 15:00　**TU2「画像処理と解析編」**

座長：中田　典生（東京慈恵会医科大学）
滝沢　穂高（筑波大学）

TU2-1　深層学習の 10 年間の進歩概要と今
本谷　秀堅
名古屋工業大学

TU2-2　深層学習におけるドメイン適応
庄野　　逸
電気通信大学 大学院情報理工学研究科

TU2-3　教師データの不足を補う : 少数データに対する機械学習手法概要
備瀬　竜馬
九州大学大学院システム情報科学研究院情報知能工学部門

ハンズオンセミナー

8月6日（火）

ハンズオン会場（中会議室 1）

ハンズオンセミナー 1

9:20 ～ 10:50　**課題 1　深層学習超入門**

「画像の分類と領域分割：転移学習と Fine-Tuning」

ハンズオンセミナー 2

16:30 ～ 18:00　**課題 2　ハンズオンセミナー・コンテスト**

「胸部 X 線画像の分類と ROC 解析」

8月7日（水）

ハンズオン会場（中会議室 1）

ハンズオンセミナー 3

9:10 ～ 10:40　**課題 3　深層学習のための前処理と後処理**

「DICOM 画像・バーチャルスライド画像の読み込み／ ROC などの統計処理」

ハンズオンセミナー 4

14:00 ～ 15:30　**課題 4　幅広い深層学習**

「言語処理や音声認識における深層学習技術」

8月5日（月）

第1会場（一橋講堂）

開会式

10:30 ～ 10:40

JAMIT ハンドブック増補分冊（発刊予定）チュートリアル Part I

10:40 ～ 12:10　**TU1「映像化技術編」**

座長：橋本二三生（浜松ホトニクス株式会社）
野崎　太希（慶應義塾大学医学部　放射線科学教室）

TU1-1　最新の医用イメージングにおける画像再構成法の紹介
工藤　博幸
筑波大学システム情報系情報工学域，東北大学国際放射光イノベーション・スマート研究センター（SRIS）

TU1-2　MRI の最近の技術的発展
寺田　康彦
筑波大学　数理物質系　物理工学域

TU1-3　核医学装置 － 10 年間の進歩
田島　英朗
量子科学技術研究開発機構

TU1-4　X 線イメージングと放射線治療用イメージングの概要
臼井　桂介
順天堂大学保健医療学部診療放射線学科，順天堂大学大学院保健医療学研究科診療放射線学専攻，順天堂大学医学部放射線治療学講座

JAMIT ハンドブック増補分冊（発刊予定）チュートリアル Part II

13:30 ～ 15:00　**TU2「画像処理と解析編」**

座長：中田　典生（東京慈恵会医科大学）
滝沢　穂高（筑波大学）

TU2-1　深層学習の 10 年間の進歩概要と今
本谷　秀堅
名古屋工業大学

TU2-2　深層学習におけるドメイン適応
庄野　　逸
電気通信大学 大学院情報理工学研究科

TU2-3　教師データの不足を補う : 少数データに対する機械学習手法概要
備瀬　竜馬
九州大学大学院システム情報科学研究院情報知能工学部門

シンポジウム 1

15:10 ～ 16:40　**SY1「医用イメージングの新潮流」**

座長：工藤　博幸（筑波大学）

SY1-1　散乱を用いた X 線 CT
戸田　尚宏
愛知県立大学　情報科学部　情報科学科

SY1-2　画像再構成の最新の話題
橋本　雄幸
杏林大学　保健学部　診療放射線技術学科

SY1-3　深層学習を利用した MR 画像再構成の新展開
伊藤　聡志
宇都宮大学 大学院工学研究科 地域創成科学専攻 情報電子オプティクスコース

SY1-4　PET の現状 － 装置開発及び臨床応用
木村　裕一
近畿大学情報学部情報学科，近畿大学情報学研究所

一般演題 1

16:50 ～ 18:00　**OP1「放射線画像再構成 1」**

座長：湯浅　哲也（山形大学大学院理工学研究科）
尾崎　　翔（弘前大学大学院理工学研究科）

OP1-1　SPECT における被写体構造を考慮した係数自動制御機構付き正則化画像再構成法
皆川　智哉[1]，堀　　拳輔[3]，橋本　雄幸[2]
[1] 東邦大学医療センター大橋病院 放射線部，[2] 杏林大学大学院保健学研究科，[3] 順天堂大学保健医療学部

OP1-2　ダイクストラ型スプリッティング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]，尾内　康臣[2]
[1] 浜松ホトニクス株式会社 中央研究所，[2] 浜松医科大学 光尖端医学教育研究センター

OP1-3　Dykstra 型 Splitting を用いた統計的 PET 画像再構成法のリストモードデータへの拡張とオンライン PET 再構成の提案
工藤　博幸
筑波大学システム情報系

OP1-4　主双対ブロック反復勾配法の理論構築と統計的画像再構成への応用
工藤　博幸
筑波大学システム情報系

OP1-5　Variance Reduction 確率的勾配法を用いたブロック反復型逐次近似画像再構成法の構築
朝戸　天翔[1]，工藤　博幸[2]
[1] 筑波大学 理工情報情報生命学術院 システム情報工学研究群 情報理工学位プログラム 博士前期課程，[2] 筑波大学システム情報系

OP1-6　不完全投影データからの位相 CT 画像再構成における解の一意性
藤井　克哉[1]，工藤　博幸[2]
[1] 畿央大学　教育学部，[2] 筑波大学システム情報系情報工学域

OP1-7　X 線回折波 2 重撮影法のスパース性を利用した CT 投影削減手法
砂口　尚輝[1]，湯浅　哲也[2]，島雄　大介[3]，黄　　卓然[1]，市原　　周[4]，西村理恵子[4]，岩越　朱里[4]，KimJong-Ki[5]，GuptaRajiv[6]，安藤　正海[7]
[1] 名古屋大学，[2] 山形大学，[3] 大阪物療大学，[4] 名古屋医療センター，[5] 大邱カトリック大学，[6] マサチューセッツ総合病院，[7] 高エネルギー加速器研究機構

8 月 5 日（月）

第２会場（中会議室 2-4）

一般演題 2

15:00 ～ 16:00　**OP2「画像生成」**

座長：中山　良平（立命館大学）
花岡　昇平（東京大学）

OP2-1　膨張畳み込みを導入した 3D ResNet-18 による心臓 CT-Perfusion 画像の左室短軸像の自動作成
岩井　星澄[1]，中山　良平[1]，檜作　彰良[1]，中村　哲士[2]，佐久間　肇[2]
[1] 立命館大学大学院　理工学研究科，[2] 三重大学医学部放射線科

OP2-2 拡散モデルを用いた皮膚疾患画像の合成と画像分類におけるクラス不均衡の改善

高倉　俊[1]，志藤　光介[2]，藤澤　康弘[3]，山崎　研志[2]，坂井　浩志[4]，藤本　学[4]，清水　昭伸[1]
[1]東京農工大学大学院工学研究院，[2]東北大学大学院医学系研究科皮膚科学分野，[3]愛媛大学大学院医学系研究科皮膚科学，[4]大阪大学大学院医学系研究科皮膚科学

OP2-3 光干渉断層血管撮影画像からのフルオレセイン蛍光眼底造影様画像の生成手法

溝部　秀謙[1]，鳥羽　修平[1]，平野　隆雄[2]，村田　敏規[2]
[1]キヤノン株式会社，[2]信州大学 医学部 眼科学教室

OP2-4 腹部単純 X 線画像からのガス領域抽出における疑似 X 線画像を用いた U-Net 事前学習法の検討

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

OP2-5 細胞核画像の形とテクスチャへの特徴分離と生成モデルの構築

村上　和真[1]，田口　慶[1]，横田　達也[1]，大島　孝一[2]，三好　寛明[2]，永石　美晴[2]，橋本　典明[3]，竹内　一郎[3]，本谷　秀堅[1]
[1]名古屋工業大学，[2]久留米大学，[3]名古屋大学

OP2-6 Textual Inversion を用いた FDG PET 画像の text-to-image 生成の試み

松原　佳亮[1]，村上　貴也[1]，木下富美子[2]，篠原　祐樹[2]，茨木　正信[2]，木下　俊文[2]
[1]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，[2]秋田県立循環器・脳脊髄センター放射線医学研究部

一般演題 3

16:10 ～ 17:00　**OP3「セグメンテーション 1」**

座長：有村　秀孝（九州大学）
野村　行弘（千葉大学）

OP3-1 Evaluation of Intestine Segmentation Methods Towards Path Tracking

安　芹[1]，小田　紘久[2]，林　雄一郎[1]，北坂　孝幸[3]，滝本愛太朗[4]，檜　顕成[4]，内田　広夫[4]，鈴木耕次郎[5]，小田　昌宏[6,1]，森　健策[1,6,7]
[1]名古屋大学大学院情報学研究科，[2]静岡県立大学経営情報学部，[3]愛知工業大学情報科学部，[4]名古屋大学大学院医学系研究科，[5]愛知医科大学医学部放射線科，[6]名古屋大学情報基盤センター，[7]国立情報学研究所医療ビッグデータ研究センター

OP3-2 Enhancing Kidney Tumor Segmentation using Multi-Modal Medical Images with Transformer Networks

SrisopitsawatPavarut[1]，小尾　高史[1]，李　中淳[2]，小林　正貴[3]，田中　一[3]，石岡淳一郎[3]，松岡陽[3]，藤井　靖久[3]
[1]東京工業大学　工学院　情報通信系，[2]科学技術創成研究院 東京工業大学，[3]東京医科歯科大学 腎泌尿器外科学

OP3-3 密な残差接続を持つ Dense Residual UNet を用いた頭部死後 CT 画像の脳内出血セグメンテーション

中本　将彦[1]，八代　正彦[2]，林　敬人[2]
[1]株式会社エクセル・クリエイツ，[2]鹿児島大学大学院医歯学総合研究科 法医学分野

OP3-4 大規模データセットの活用に向けた基礎的検討と応用事例

杉下　友麻[1]，原　武史[2]，尾碕　公美[3]，周　向栄[2]，藤田　広志[2]
[1]岐阜大学大学院自然科学技術研究科，[2]浜松医科大学放射線診断学講座，[3]岐阜大学工学部

OP3-5　3時相腹部造影CT画像を用いた腎臓・腎腫瘍・嚢胞の自動抽出

西村　一馬[1]，越野　魁都[1]，河田　佳樹[2]，小針　悠希[3]，池田　篤史[4]，仁木　　登[5]

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

一般演題4

17:10 ～ 18:00　**OP4「臓器モデリング」**

座長：大竹　義人（奈良先端科学技術大学院大学）
伊東　隼人（福岡大学 理学部応用数学科）

OP4-1　咀嚼嚥下に関連する臓器を対象とした複数臓器統計形状モデルの構築

三浦　皓大[1]，中谷　亮太[1]，政木　勇人[1,2]，大竹　義人[1]，崇風まあぜん[1]，谷　　懿[1]，井尻　　敬[3]，重田　優子[4]，井川　知子[4]，小川　　匠[4]，稲本　陽子[5]，菊池　貴博[6]，道脇　幸博[7]，佐藤　嘉伸[1]

[1]奈良先端科学技術大学院大学，[2]PSP株式会社，[3]芝浦工業大学，[4]鶴見大学，[5]藤田医科大学，[6]株式会社明治，[7]みちわき研究所

OP4-2　CT･MRIに基づく筋骨格モデリングと簡易動作計測を統合した患者個別バイオメカニクスシミュレーション

伊藤　善久[1]，大竹　義人[1]，崇風まあぜん[1]，李　　贛萍[1]，谷口　匡史[2]，八木　優英[2]，田原　大輔[3]，高尾　正樹[4]，岩佐　　諦[5]，上村　圭亮[5]，市橋　則明[2]，佐藤　嘉伸[1]

[1]奈良先端科学技術大学院大学，[2]京都大学，[3]龍谷大学，[4]愛媛大学，[5]大阪大学

OP4-3　大規模データベースにおける体幹部CT画像の自動筋骨格系セグメンテーションと解析

ゴリンサナー アミナ[1]，崇風まあぜん[1]，大竹　義人[1]，政木　勇人[1,2]，村上　陽子[3]，永谷　幸裕[3]，渡邉　嘉之[3]，上村　圭亮[4]，高尾　正樹[5]，菅野　伸彦[4]

[1]奈良先端科学技術大学院大学，[2]PSP株式会社，[3]滋賀医科大学，[4]大阪大学，[5]愛媛大学

OP4-4　八分木キューブ構造の臓器変形モデルにおける反力提示の実装

宮﨑琳太郎[1]，林　雄一郎[1]，小田　昌宏[2,1]，森　　健策[1,2,3]

[1]名古屋大学大学院情報学研究科，[2]名古屋大学情報基盤センター，[3]国立情報学研究所医療ビッグデータ研究センター

OP4-5　X線位相CTを用いた高精細マウス3次元アトラスの構築

米山　明男[1,2,3]，LwinThet Thet[2]，馬場　理香[4]，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]北里大学医療衛生学部，[3]高エネルギー加速器研究機構物質構造科学研究所，[4]（株）日立製作所研究開発グループ

一般演題 5

9:40 ～ 10:50　**OP5「推定・予測 1」**

座長：畑中　裕司（大分大学）
目加田慶人（中京大学）

OP5-1　吸気・呼気 CT 画像を用いた慢性閉塞性肺疾患における身体活動性予測

近藤　芽生[1]，間普　真吾[1]，平野　綱彦[2]，村田　順之[2]，土居　恵子[2]，深津愛祐美[2]，楊　　鯤昊[1]，松永　和人[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呼吸器・感染症内科

OP5-2　マルチモーダル学習を用いた CEA 患者の循環器病発症予測

石田　修也[1]，盛田　健人[1,2]，畠山　金太[2]，蓮　　乃駿[2]，渡辺　翔吾[2]，小橋　昌司[2,3]，飯原　弘二[2]，若林　哲史[1]

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

OP5-3　拡散モデルによる人体頭部の未来予測と脳室容積の予測精度検証

柴田　寿一[1]，花岡　昇平[1]，野村　行弘[2,3]，吉川　健啓[2]，阿部　　修[1]

[1]東京大学医学部附属病院放射線科，[2]東京大学医学部附属病院コンピュータ画像診断学／予防医学講座，[3]千葉大学フロンティア医工学センター

OP5-4　体幹部定位放射線治療を受けた早期非小細胞肺癌患者における腫瘍成長モデルの開発

光島　千稀[1]，有村　秀孝[2]，白川　友子[3]，吉武　忠正[4]

[1]九州大学大学院医学系学府保健学専攻医用量子線科学分野，[2]九州大学大学院医学研究院保健学部門，[3]独立行政法人国立病院機構九州がんセンター放射線治療科，[4]九州大学病院放射線科

OP5-5　早期非小細胞肺癌に対する体幹部定位放射線治療における治療計画 CT 画像を用いた放射線肺炎予測

江田　惇哉[1]，有村　秀孝[2]，兒玉　拓巳[1]，吉武　忠正[3]，廣瀬　貴章[4]，YagizYedekci[5]

[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臨床放射線科学分野，[4]九州大学病院医療技術部放射線部門，[5]Department of Radiation Oncology, Faculty of Medicine, Hacettepe University

OP5-6　体外衝撃波結石破砕術結果予測の性能改善に向けたハイブリッド Mixup の初期検討

望月　嘉恋[1]，根本　充貴[1,2]，中前有香子[1]，木村　裕一[3]，出口　龍良[4]，山下　真平[4]，柑本　康夫[4]，原　　勲[4]

[1]近畿大学生物理工学研究科，[2]近畿大学生物理工学部，[3]近畿大学情報学部・情報学研究科，[4]和歌山県立医科大学泌尿器科

OP5-7　ESWL アウトカム予測における CT・X 線画像からの特徴量抽出法の検討

小林　壯哉[1]，藤田　大輔[1]，澁谷　浩伸[2]，郷原　真輔[2]，小橋　昌司[1]

[1]兵庫県立大学，[2]石川病院

特別講演

11:00 ～ 12:00　**SL「画像と言語の基盤モデルの現状とこれから」**

座長：清水　昭伸（東京農工大学）

SL

原田　達也
東京大学，理化学研究所，国立情報学研究所

会員集会

13:20 ～ 14:20

シンポジウム 2

14:30 ～ 16:30　**SY2「AI 時代のレギュラトリーサイエンス」**

座長：中岡　竜介（国立医薬品食品衛生研究所）

SY2-1　医療 ICT システムの課題と将来展望
村山　雄一
東京慈恵会医科大学　脳神経外科

SY2-2　国内におけるプログラム医療機器の審査について
江面　崇智
独立行政法人医薬品医療機器総合機構 プログラム医療機器審査室

SY2-3　プログラム医療機器に関する最近の規制動向
水谷　玲子
厚生労働省 医薬局 医療機器審査管理課 プログラム医療機器審査管理室

SY2-4　日本が医療 AI 先進国になるためにできること
島原　佑基
医療 AI 推進機構

SY2-5　大腸内視鏡 AI の開発から保険償還獲得の経験
三澤　将史
昭和大学横浜市北部病院　消化器センター

一般演題 6

16:40 ～ 17:30　**OP6「基盤モデル・連合学習」**

座長：本谷　秀堅（名古屋工業大学）
黒瀬　優介（東京大学　先端科学技術研究センター）

OP6-1　WSI を表現する基盤モデルの構築に向けた自己教師学習の検討

田口　慶[1]，横田　達也[1]，大島　孝一[2]，三好　寛明[2]，永石　美晴[2]，橋本　典明[3]，竹内　一郎[3]，本谷　秀堅[1]
[1]名古屋工業大学，[2]久留米大学，[3]名古屋大学

OP6-2　基盤モデルを用いた皮膚疾患画像からの皮膚領域の認識

佐藤　優斗[1]，志藤　光介[2]，藤澤　康弘[3]，山﨑　研志[2]，坂井　浩志[4]，藤本　　学[4]，清水　昭伸[1]
[1]東京農工大学大学院工学研究院，[2]東北大学大学院医学系研究科皮膚科学分野，[3]愛媛大学大学院医学系研究科皮膚科学，[4]大阪大学大学院医学系研究科皮膚科学

OP6-3　数値特徴量による不均衡な医用画像良悪性分類の改善

吉次　研二[1]，岸本　和昌[2]，竹村　匡正[1]
[1]兵庫県立大学大学院情報科学研究科，[2]京都大学医学部付属病院

OP6-4　連合学習を用いた胸部 CT 画像におけるびまん性肺疾患の陰影識別と異常検知

岩瀬　実莉[1]，間普　真吾[1]，楊　　鯤昊[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

OP6-5　パーソナライズド連合学習を用いた EOB-MR 画像の肝結節性病変分類における施設毎の性能改善の検討

山田　藍樹[1,2]，花岡　昇平[2]，竹永　智美[2]，吉川　健啓[3]，野村　行弘[3,4]
[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]東京大学医学部附属病院放射線科，[3]東京大学医学部附属病院コンピュータ画像診断学／予防医学講座，[4]千葉大学フロンティア医工学センター

一般演題 7

17:30 ～ 18:20　**OP7「CAD1」**

座長：滝沢　穂高（筑波大学）
佐藤　嘉伸（奈良先端科学技術大学院大学）

OP7-1　骨シンチグラム診断支援システムの市販後再学習時のテストデータ再利用による性能バイアスとその補正

山中　陽大[1]，東山　滋明[2]，河邉　譲治[2]，中岡　竜介[3]，清水　昭伸[1]
[1]東京農工大学　大学院　工学研究院，[2]大阪公立大学医学部附属病院核医学科，[3]国立医薬品食品衛生研究所医療機器部

OP7-2　皮膚疾患画像分類における Underspecification の評価

殿村　理久[1]，志藤　光介[2]，藤澤　康弘[3]，山﨑　研志[2]，坂井　浩志[4]，藤本　　学[4]，清水　昭伸[1]
[1]東京農工大学大学院工学研究院，[2]東北大学大学院医学系研究科皮膚科学分野，[3]愛媛大学大学院医学系研究科皮膚科学，[4]大阪大学大学院医学系研究科皮膚科学

OP7-3　皮膚疾患分類のためのマルチモーダル学習

飯嶋　杏奈[1]，坂井　浩志[2]，藤本　　学[2]，志藤　光介[3]，山﨑　研志[3]，藤澤　康弘[4]，清水　昭伸[1]

[1]東京農工大学大学院工学研究院，[2]大阪大学大学院医学系研究科皮膚科学，[3]東北大学大学院医学系研究科皮膚科学分野，[4]愛媛大学大学院医学系研究科皮膚科学

OP7-4　胸部 CT 画像におけるびまん性肺疾患の識別のための Voxel データの効果的な活用方法の提案

森崎　幹也[1]，間普　真吾[1]，楊　　鯤昊[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

OP7-5　呼吸器内視鏡迅速細胞診における AI 診断支援 – 第 2 報 埋め込み表現空間における距離を考慮した対照学習

尾見　康夫[1]，桐田　圭輔[2,3]，酒井　徹也[2]，高橋　真理[4,5]，後藤　功一[2]

[1]ＮＥＣ　ヘルスケア・ライフサイエンス事業部門　医療機器ソフトウェア統括部，[2]国立がん研究センター東病院　呼吸器内科，[3]上尾中央総合病院　呼吸器内科，[4]国立がん研究センター東病院　TR 検体管理室，[5]国立がん研究センター東病院　内視鏡センター

第２会場（中会議室 2-4）

一般演題 8

9:40 ～ 10:50　**OP8「MR 画像再構成」**

座長：菅　　幹生（千葉大学）
岡本　尚之（千葉大学フロンティア医工学センター）

OP8-1　拡散モデルを使用したマルチタスク MRI 再構成モデルの検討

藤田　直人[1]，寺田　康彦[1]

[1]筑波大学　理工情報生命学術院　数理物質科学研究群

OP8-2　Swin Transformer を利用した MR 深層学習再構成における学習スケジュールと画質の関連

中鉢　史也[1]，佐藤　裕貴[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 情報電気電子システム工学プログラム

OP8-3　等間隔な信号間引き収集を可能とする MR 撮像法と再構成法

足立虎太郎[1]，伊藤　聡志[1]

[1]宇都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム

OP8-4　低周波数帯域から順に推定を行う多段接続型 CNN を基本とした MR 画像再構成法の画質改善法の検討

大内　翔平[1]，伊藤　聡志[2]

[1]小山工業高等専門学校　電気電子創造工学科，[2]宇都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム

OP8-5　位相拡散フーリエ変換法と多空間型 ADMM-CSNet よる CS-MRI 再構成の性能改善

山登　一輝[1]，伊藤　聡志[1]

[1]宇都宮大学工学部基盤工学科

OP8-6　位相拡散フーリエ変換法を使用した CS-MRI と超解像の併用による深層学習再構成像の高画質化

松浦　毅弥[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

一般演題 9

14:30 ～ 15:30　**OP9「微細構造解析」**

座長：橋本　典明（理化学研究所）
　　彌冨　　仁（法政大学理工学部応用情報工学科）

OP9-1　**血流を阻害したラット皮弁の分光画像解析**

高宮　桃香[1]，恵藤　　陸[1]，秋田　新介[2]，三川　信之[2]，岡本　尚之[3]，羽石　秀昭[3]
[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]千葉大学フロンティア医工学センター

OP9-2　**大視野顕微放射光 CT による肺 3 次元ミクロ画像の肺胞壁解析**

小野　龍輝[1]，河田　佳樹[2]，梅谷　啓二[3]，中野　恭幸[4]，小熊　　毅[5]，阪井　宏彰[6]，岡本　俊宏[7]，仁木　　登[8]
[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]（公財）高輝度光科学研究センター，[4]滋賀医科大学，[5]京都市立病院，[6]兵庫県立尼崎総合医療センター，[7]クリーブランドクリニック心臓・血管研究所，[8]株式会社医用科学研究所

OP9-3　**X 線暗視野法を用いた膵管内乳頭粘液性腫瘍における乳頭様構造の 3 次元解析 − 追加 2 症例による比較検討 −**

天野　遥菜[1]，砂口　尚輝[1]，岩越　朱里[2]，末永　雅也[2]，西村理恵子[2]，島雄　大介[3]，湯浅　哲也[4]，安藤　正海[5]，市原　　周[2]
[1]東海国立大学機構名古屋大学医学部保健学科放射線技術科学専攻，[2]国立病院機構名古屋医療センター病理診断科　外科，[3]大阪物療大学 保健医療学部 診療放射線技術学科，[4]山形大学大学院理工学研究科，[5]高エネルギー加速器研究機構

OP9-4　**悪性リンパ腫における細胞核の種類識別器構築のためのラベル遷移を考慮した弱教師学習**

古賀　諒一[1]，小出　新悟[1]，横田　達也[1]，大島　孝一[2,3]，三好　寛明[2,3]，永石　美晴[2]，橋本　典明[4]，竹内　一郎[5]，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]日本病理学会，[4]理化学研究所，[5]名古屋大学

OP9-5　**深層学習を用いたイメージング FCM 画像における尿中マルベリー小体のスクリーニング**

今久保桃子[1]，眞砂　明典[1]，浅井　千春[2]，坪井　一哉[3]
[1]シスメックス株式会社，[2]社会医療法人宏潤会大同病院，[3]名古屋セントラル病院

OP9-6　**3D U-Net を用いた肺マイクロ CT 画像中の肺胞壁領域抽出**

矢田　遥大[1]，中村　彰太[2]，林　雄一郎[1]，小田　昌宏[3,1]，森　　健策[1,3,4]
[1]名古屋大学大学院情報学研究科，[2]名古屋大学大学院医学系研究科，[3]名古屋大学情報基盤センター，[4]国立情報学研究所医療ビッグデータ研究センター

ハンズオンセミナー 1

9:20 ～ 10:50　**課題 1　深層学習超入門**

「画像の分類と領域分割：転移学習と Fine-Tuning」

ハンズオンセミナー 2

16:30 ～ 18:00　**課題 2　ハンズオンセミナー・コンテスト**

「胸部 X 線画像の分類と ROC 解析」

8 月 7 日（水）

一般演題 10

9:30 ～ 10:30　**OP10「CAD2」**

座長：庄野　　逸（電気通信大学）
橘　　理恵（室蘭工業大学 大学院工学研究科）

OP10-1　FDG-PET/CT 像上の副腎転移病変検出に関する検討 - 上腹部臓器領域抽出とのマルチタスク学習の実験的検証 -

吉田　昂平[1]，根本　充貴[1,2]，甲斐田勇人[3]，木村　裕一[4]，永岡　　隆[1,2]，三上　勝大[2]，山田　誉大[3]，花岡　宏平[3]，槌谷　達也[5]，北島　一宏[5]，石井　一成[3]
[1] 近畿大学 生物理工学研究科，[2] 近畿大学生物理工学部，[3] 近畿大学病院，[4] 近畿大学情報学部，[5] 兵庫医科大学病院

OP10-2　深層学習による CT 画像での乳癌腫瘤影検出における過去画像の有用性に関する検討

守田　裕一[1]，花岡　昇平[1]，野村　行弘[2,3]，中尾　貴祐[2]，吉川　健啓[2]，阿部　　修[1]
[1] 東京大学医学部附属病院放射線科，[2] 東京大学医学部附属病院コンピュータ画像診断学／予防医学講座，[3] 千葉大学フロンティア医工学センター

OP10-3　Masked Autoencoder の自己教師あり学習に基づく頭部 CT 画像からのくも膜下出血の検知

大野未来矢[1]，黒瀬　優介[2,3]，渡谷　岳行[4]，原田　達也[2,3,5]
[1] 東京大学　情報理工学系研究科　知能機械情報学専攻　原田・長・黒瀬・椋田研究室，[2] 東京大学先端科学技術研究センター，[3] 理化学研究所　革新知能統合研究センター，[4] 東京大学医学部附属病院放射線科，[5] 国立情報学研究所　医療ビッグデータ研究センター

OP10-4　胸部 X 線画像における緊急性疾患向け異常検出

福島　祥之[1]，吉田　皓文[2]，笠井　　聡[2]，近藤　敏志[1]
[1] 室蘭工業大学，[2] 新潟医療福祉大学

OP10-5　Masked Autoencoder と注意機構を用いた 12 誘導心電図の異常検知

今村　健太[1]，原田　達也[2,3,4]，黒瀬　優介[2,3]

[1] 東京大学　工学部，[2] 東京大学　先端科学技術研究センター，[3] 理化学研究所　革新知能統合研究センター，[4] 国立情報学研究所　医療ビッグデータ研究センター

OP10-6　Gray Wolf アルゴリズムベースのハイパーパラメータ調整を使用した白血病サブタイプ検出のための YOLOv8 の最適化

タンジラルムスタキム[1], タンジラルムスタキム[1], 中淳　　李[3], 小尾　高史[2], チャスティンファティチャ[1], ナニックスチアティ[1]

[1] インドネシア、スラバヤのセプル・ノーペンバー工科大学情報学部，[2] 東京工業大学 未来科学技術研究チーム，[3] 東京工業大学科学技術創成研究院

シンポジウム 3

10:40 ～ 12:10　**SY3「JAMIT の未来を作ろう！ 2024」**

座長：岡本　尚之（千葉大学フロンティア医工学センター）
伊東　隼人（福岡大学理学部応用数学科）

（パネリスト）

皆川　智哉
　東邦大学医療センター大橋病院 放射線部
大村　眞朗
　富山大学学術研究部工学系
関川　祐矢
　帝京大学大学院保健学研究科
武山　彩織
　東京工業大学工学院情報通信系
渕辺章太郎
　GE ヘルスケア・ジャパン株式会社

一般演題 11

13:30 ～ 14:30　**OP11「CAD3」**

座長：河田　佳樹（徳島大学ポスト LED フォトニクス研究所）
砂口　尚輝（東海国立大学機構名古屋大学大学院医学系研究科総合保健学専攻）

OP11-1　神経血管束温存に関するロボット支援根治的前立腺摘除術画像のコンピュータ支援分類

デルアギラモラガディエゴアンドレス[1]，王　　慧涛[1]，安東　　聡[2]，保科　勇斗[2]，川平　　洋[3]，野村　行弘[4]，中口　俊哉[4]

[1] 千葉大学大学院融合理工学府，[2] 自治医科大学腎泌尿器外科学講座，[3] 自治医科大学メディカルシミュレーションセンター，[4] 千葉大学フロンティア医工学センター

OP11-2　気管支超音波画像に基くマルチブランチと投票メカニズムを用いた肺末梢病変分類

王　　慧涛[1]，鹿野　幸平[2]，中島　崇裕[3]，李　ジャオ[4]，野村　行弘[5]，中口　俊哉[5]

[1] 千葉大学 融合理工学府基幹工学，[2] 千葉大学大学院医学研究院 呼吸器内科学，[3] 獨協医科大学　呼吸器外科学，[4] 同済大学附属東方医院，[5] 千葉大学フロンティア医工学センター

OP11-3　SE-Block を導入した 3D ResNet による大動脈弁狭窄症の重症度自動分類

佐橋　拓哉[1]，中山　良平[1]，檜作　彰良[1]，岡本　寛樹[2]

[1] 立命館大学大学院 理工学研究科，[2] 滋賀医科大学循環器内科

OP11-4　深層学習を用いた骨盤 CT 画像による各脚の下肢リンパ浮腫スクリーニング手法の検討

辻　　美里[1]，秋田　新介[2]，長西　裕樹[3,4]，松岡　　歩[5]，甲賀かをり[6]，三川　信之[2]，野村　行弘[7]

[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形成・美容外科，[3]NACS クリニックリンパ浮腫センター北横浜，[4] 済生会横浜市南部病院形成外科，[5] 千葉大学医学部附属病院婦人科，[6] 千葉大学大学院医学研究院産婦人科学，[7] 千葉大学フロンティア医工学センター

OP11-5　脳 MR 画像における Multi-input CNN を用いた特発性正常圧水頭症の鑑別診断支援

澤　　風吹[1]，藤田　大輔[1]，嶋田　兼一[2]，石井　一成[2,3]，小橋　昌司[1]

[1] 兵庫県立大学，[2] 兵庫県立はりま姫路総合医療センター，[3] 近畿大学

OP11-6　ESRGAN による超解像処理を利用した乳がん石灰化良悪性鑑別 CAD 精度向上の検討

大坂　亮二[1]，安倍　和弥[1]，高取　祐介[1]

[1] 神奈川工科大学 工学部 電気電子情報工学科

一般演題 12

14:40 ～ 15:30　**OP12「セグメンテーション 2」**

座長：滝沢　穂高（筑波大学）
杉本　直三（京都大学大学院医学研究科 人間健康科学系専攻）

OP12-1　3D U-Net による非造影 CT 画像の大動脈・冠動脈石灰化の検出

庄野未彩季[1]，赤塚　真人[1]，河田　佳樹[2]，杉浦　寿彦[3]，田邊　信宏[3]，丸茂　一義[4]，金子　昌弘[4]，仁木　　登[5]

[1] 徳島大学大学院創成科学研究科理工学専攻，[2] 徳島大学ポストフォトニクス研究所，[3] 千葉大学，[4] 東京都予防医学協会，[5](株) 医用科学研究所

OP12-2　CT 画像と存在確率マップを用いた CNN に基づく全自動僧帽弁形状抽出

益田　幸輝[1]，石川　　亮[1]，田中　　亨[1]，青山　岳人[2]，川島圭太郎[2]，ChapmanJames V.[3]，阿佐美匡彦[4]，PhamMichael Huy Cuong[5]，KofoedKlaus Fuglsang[5]，坂口　卓弥[2]，佐藤　清秀[1]

[1] キヤノン株式会社，[2] キヤノンメディカルシステムズ株式会社，[3]Canon Medical Informatics,Inc.，[4] 三井記念病院　循環器内科，[5]Department of Cardiology and Radiology, Copenhagen University Hospital - Rigshospitalet

OP12-3　ラジオ波焼灼療法のための腹部 CT 画像における肝臓腫瘍の自動識別

オウヤンガンシン[1]，杉下　友麻[1]，原　　武史[1]，周　　向栄[1]，尾﨑　公美[2]

[1] 岐阜大学大学院自然科学技術研究科，[2] 浜松医科大学放射線診断学講座

OP12-4　Ensemble Multiscale Attention UNet による胸部 CT 画像からの肺腫瘍領域の自動抽出

高橋　礼生[1]，神谷　　亨[1]，寺澤　　岳[2]，青木　隆敏[2]

[1] 九州工業大学，[2] 産業医科大学

OP12-5　Semi-supervised Tubular Structure Segmentation with Hausdorff Distance Consistency

朱　　芮昀[1]，小田　昌宏[2,1]，林　雄一郎[1]，北坂　孝幸[4]，森　　健策[1,2,3]

[1] 名古屋大学情報学研究科，[2] 名古屋大学　学術情報開発研究部門，[3] 名古屋大学　情報基盤センター，[4] 愛知工業大学　情報科学科

一般演題 13

15:40 ～ 16:30　**OP13「セグメンテーション 3」**

座長：小田　紘久（静岡県立大学経営情報学部経営情報学科）
神谷　　亨（九州工業大学）

OP13-1　3 次元医用画像の自己教師ありセグメンテーションに関する初期検討
鈴木　敦志[1]，小林　和馬[1,2]，浜本　隆二[1,2]
[1] 理化学研究所革新知能統合研究センター，[2] 国立がん研究センター研究所

OP13-2　MRI 単体での肩関節画像診断に向けた深層学習を用いた軟部組織除去手法の初期検討
杉本　裕汰[1]，野崎　太希[2]，寺田　康彦[1]
[1] 筑波大学　理工情報生命学術院　数理物質科学研究群，[2] 慶應義塾大学医学部　放射線科学教室（診断）

OP13-3　マルチチャンネル化，画像の線形結合，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
滝沢　穂高[1]，塩田　紘司[2]，目片幸二郎[3]，工藤　博幸[1]
[1] 筑波大学システム情報系，[2] 筑波大学大学院情報理工学位プログラム，[3] 四条畷学園大学作業療法学専攻

OP13-4　Optical coherence tomography angiography における血管中心線深度の推定手法の検討
岡本　尚之[1]，岡村　宙輝[2]，羽石　秀昭[1]
[1] 千葉大学フロンティア医工学センター，[2] 千葉大学融合理工学府

OP13-5　超広角眼底画像における無灌流領域の自動抽出
中野　勝太[1]，畑中　裕司[2]，慶野　　博[3]
[1] 大分大学大学院工学研究科，[2] 大分大学理工学部，[3] 杏林大学医学部

第２会場（中会議室 2-4）

一般演題 14

9:30 ～ 10:20　**OP14「放射線画像再構成 2・画像変換」**

座長：橋本二三生（浜松ホトニクス株式会社）
花岡　昇平（東京大学）

OP14-1　デノイジング拡散確率モデルを用いた CT 画像再構成
尾崎　　翔[1,3]，鍛治　静雄[2]，名和　要武[3]，今江　禄一[3]，中川　恵一[3]
[1] 弘前大学大学院理工学研究科，[2] 九州大学　マス・フォア・インダストリ研究所，[3] 東京大学医学部附属病院放射線科

OP14-2　マイクロ CT による小動物イメージングのための動態アーチファクト低減手法の構築
福島まひる[1]，岡本　尚之[2]，羽石　秀昭[2]
[1] 千葉大学大学院融合理工学府，[2] 千葉大学フロンティア医工学センター

OP14-3　多重解像度展開像の相似性を利用した単一画像超解像
正田　優大[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 情報電気電子システム工学プログラム

OP14-4　条件付き敵対生成ネットワークを用いた頭部 MRI 画像におけるモーションアーチファクト成分の低減

有田　晃大[1]，臼井　桂介[1]，京極　伸介[1]，坂野　康昌[1]，坂本　肇[1]，代田　浩之[1]
[1] 順天堂大学大学院保健医療学研究科

OP14-5　脳腫瘍病変の有無におけるコンディショナル GAN による頭部 CT-MRI 画像変換精度の比較

土屋　諒真[1]，臼井　桂介[1]，坂本　肇[1]，坂野　康昌[1]，京極　伸介[1]，代田　浩之[1]
[1] 順天堂大学大学院保健医療学研究科診療放射線学専攻

一般演題 15

10:30 ～ 11:20　**OP15「推定・予測 2」**

座長：根本　充貴（近畿大学）
小橋　昌司（兵庫県立大学先端医療工学研究所）

OP15-1　低線量胸部 CT 画像から深層学習を用いた年齢推定モデルの開発

菊野　遥翔[1]，田中　利恵[2]，松永　哲夫[3]，小林　聡[4]，南　哲弥[5]，白石　順二[6]
[1] 金沢大学大学院　医薬保健学総合研究科，[2] 金沢大学　医薬保健研究域附属 AI ホスピタル・マクロシグナルダイナミクス研究開発センター，[3] 石川県予防医学協会，[4] 金沢大学　医薬保健研究域医学系，[5] 金沢医科大学　放射線科，[6] 福岡国際医療福祉大学

OP15-2　前眼部 OCT 画像のテクスチャ特徴を用いたぶどう膜炎の前房細胞グレードの推定

清水　悠多[1]，畑中　裕司[2]，慶野　博[3]
[1] 大分大学大学院工学研究科，[2] 大分大学理工学部，[3] 杏林大学医学部眼科学教室

OP15-3　深層学習を用いた超音波 RF 信号再構成による転移リンパ節診断予測モデルの開発

前田　一伎[1]，大村　眞朗[3]，小玉　哲也[1,2]
[1] 東北大学大学院　医工学研究科，[2] 東北大学大学院　医工学研究科　がん医工学研究センター，[3] 富山大学　学術研究部工学系

OP15-4　対照学習を用いた画像特徴抽出モデルの事前学習の有効性の検証

渡辺　翔吾[1]，連　乃駿[1]，今岡　幸弘[1]，和久　景子[1]，盛田　健人[1,2]，小橋　昌司[1,3]，西村　邦宏[1]，飯原　弘二[1]
[1] 国立循環器病研究センター，[2] 三重大学，[3] 兵庫県立大学

OP15-5　TMS コイルによる脳内誘導電場の回帰精度改善に向けた頭部 MRI の自己教師あり学習

牧　豊大[1]，横田　達也[1]，平田　晃正[2]，本谷　秀堅[1]
[1] 名古屋工業大学情報工学専攻，[2] 名古屋工業大学電気機械工学専攻

一般演題 16

11:20 ～ 12:10　**OP16「MR イメージング」**

座長：増谷　佳孝（東北大学 大学院医学系研究科 保健学専攻）
伊藤　聡志（宇都宮大学）

OP16-1　画像分離に深層学習を利用する新たな MR マルチスライス撮像法の提案
遠藤　尚哉[1]，佐藤　裕貴[1]，大内　翔平[2]，伊藤　聡志[1]
[1] 宇都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム，[2] 小山工業高等専門学校

OP16-2　生成型 X-Q 空間学習による拡散尖度イメージングパラメタの推定
増谷　佳孝[1]，一関　雄輝[1]，紺谷　昂生[1]
[1] 東北大学大学院医学系研究科・医学部

OP16-3　MRI を用いたラット肝臓の定量的磁化率マッピングにおける手法検討
中村　浩也[1]，寺田　康彦[1]，山口　雅之[2]
[1] 筑波大学 理工情報生命学術院 数理物質科学研究群，[2] 国立がん研究センター　先端医療開発センター　機能診断開発分野

OP16-4　勾配加重クラス活性化マッピング (Grad-cam) を用いた MRI モーションアーチファクト分類の位相方向による影響
赤沼　優文[1]，臼井　桂介[1]，有田　晃大[1]，坂本　肇[1]，坂野　康昌[1]，京極　伸介[1]，代田　浩之[1]
[1] 順天堂大学大学院保健医療学研究科　診療放射線学専攻

OP16-5　弾性波画像の振幅対ノイズ比を利用した MR エラストグラフィ解析手法の改良
玉田　綾[1]，菅　幹生[1,2]
[1] 千葉大学　融合理工学府　医工学コース，[2] 千葉大学　フロンティア医工学センター

一般演題 17

13:30 ～ 14:30　**OP17「核医学イメージング」**

座長：羽石　秀昭（千葉大学）
小尾　高史（東京工業大学科学技術創成研究院）

OP17-1　Noise2Void による脳 SPECT 画像の画質改善
草刈　颯太[1]，成田　和陽[2]，松岡　将宏[3]，松原　佳亮[4]，越野　一博[5]，渡部　浩司[6]，湯浅　哲也[3]，銭谷　勉[1]
[1] 弘前大学大学院理工学研究科，[2] 弘前大学理工学部，[3] 山形大学大学院理工学研究科，[4] 秋田県立大学システム科学技術学部，[5] 北海道情報大学経営情報学部，[6] 東北大学先端量子ビーム科学研究センター

OP17-2　ピンホール SPECT イメージングによる検出確率の近似手法の比較
縄野　勇大[1]，尾川　浩一[2]
[1] 法政大学大学院理工学研究科，[2] 法政大学理工学部応用情報工学科

OP17-3　臨床用 Whole Gamma Imaging 装置のシミュレーション設計
菊地　智也[1]，田久　創大[2]，菅　幹生[1,3]，田島　英朗[2]，赤松　剛[2]，錦戸　文彦[2]，山谷　泰賀[2]
[1] 千葉大学 融合理工学府 医工学コース，[2] 量子科学技術研究開発機構，[3] 千葉大学 フロンティア医工学センター

OP17-4　対向パネル型 PET のシミュレーション：TOF 分解能と感度が画質に及ぼす影響

石川　大洋[1]，赤松　　剛[1]，田島　英朗[1]，錦戸　文彦[1]，高橋美和子[1]，橋本二三生[1,2,3]，大田　良亮[3]，山谷　泰賀[1,2]

[1]量子科学技術研究開発機構，[2]千葉大学，[3]浜松ホトニクス株式会社

OP17-5　TOF-DOI 検出器を用いた半球型頭部 PET 装置 1 リング試作機の開発

○成田　胡桃[1,2]，赤松　　剛[1]，吉田 英治[1]，田島 英朗[1]，岩男 悠真[1]，高橋美和子[1]，山谷　泰賀[1,3]

[1]量子科学技術研究開発機構，[2]千葉大学大学院融合理工学府，[3]千葉大学フロンティア医工学センター

OP17-6　OpenPET 初の重粒子線がん治療臨床応用

田島　英朗[1]，寅松　千枝[1]，浜戸アクラム[1]，岩男　悠真[1]，赤松　　剛[1]，カンハンギュ[1]，錦戸　文彦[1]，田尻　　稔[1]，水野　秀之[1]，小藤　昌志[1]，山谷　泰賀[1]

[1]量子科学技術研究開発機構

一般演題 18

14:40 ～ 15:30　**OP18「内視鏡・手術映像等」**

座長：中口　俊哉（千葉大学フロンティア医工学センター）
林　雄一郎（名古屋大学）

OP18-1　股関節鏡視下手術における術中動画のセグメンテーション画像と仮想股関節鏡シミュレータによる仮想股関節画像との連携による最適ポータル位置の推定

川上申之介[1]，福田　紀生[2]，西井　　孝[3]，大竹　義人[4]，佐藤　嘉伸[4]

[1]関西女子短期大学医療秘書学科，[2]脳情報通信融合研究センター，[3]大阪急性期・総合医療センター整形外科，[4]奈良先端科学技術大学院大学情報科学領域

OP18-2　Segment Anything Model を用いて生成されたマスクの分類による腹腔鏡映像からの血管・膵臓領域自動抽出の検討

髙見　一慧[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[1,3,5]

[1]名古屋大学大学院情報学研究科，[2]愛知工業大学情報科学部，[3]名古屋大学情報基盤センター，[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

OP18-3　改良を加えた YOLO モデルに基づく内視鏡下手術画像からの術具先端検出

劉　　育彰[1]，林　雄一郎[1]，小田　昌宏[2,1]，森　　健策[1,2,3]

[1]名古屋大学　情報学研究科，[2]名古屋大学　情報基盤センター，[3]国立情報学研究所　医療ビッグデータ研究センター

OP18-4　色彩の分離に基づいた 3 次元点群顔データからの口唇領域の抽出

木原　成海[1]，神谷　　亨[1]

[1]九州工業大学

OP18-5　大腸内視鏡動画像を用いた 3 次元復元に関する初期的検討

小野坂　捺[1]，伊東　隼人[2,1]，小田　昌宏[3,1]，三澤　将史[4]，森　　悠一[5,4]，工藤　進英[4]，森　　健策[1,3,6]

[1]名古屋大学大学院情報学研究科，[2]福岡大学理学部応用数学科，[3]名古屋大学情報基盤センター，[4]昭和大学横浜市北部病院消化器センター，[5]オスロー大学臨床効果研究グループ，[6]国立情報学研究所医療ビッグデータ研究センター

一般演題 19

15:30 ～ 16:30　**OP19「医療情報・教育」**

座長：北坂　孝幸（愛知工業大学）
田中　利恵（金沢大学医薬保健研究域）

OP19-1　Transformer と画像強調分析を使用した放射線レポート生成ツール

イスメットヒリヤツァニヤ[1], イスメットヒリヤツァニヤ[1], 李　　中淳[3], 小尾　高史[2], スシアティナニック[1], ファティチャチャスティン[1]
[1] セプル ノーペンバー工科大学, [2] 東京工業大学 未来産業技術研究所, [3] 東京工業大学 科学技術創成研究院

OP19-2　PET-CT 画像所見文における部位および正常 / 異常識別のための深層学習モデルの構成に関する検討

山中唯歩生[1], 成田　紗弥[1], 間普　真吾[1], 楊　　鯤昊[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

OP19-3　ChatGPT は整形外科専門医試験に合格可能か？～医療画像認識能力を含めた成績の検討～

中嶋　　望[1], 藤森　孝人[2]
[1] 堺市立総合医療センター　整形外科, [2] 大阪大学大学院　整形外科

OP19-4　紙ベースで取得された患者報告型アウトカムを画像化して、自動読み取りする AI の開発

藤森　孝人[1], 喜多　洸介[1,2], 鈴木　裕紀[2], 蟹江　祐哉[1], 古家　雅之[1], 武中　章太[3], 海渡　貴司[4], 岡田　誠司[1], 木戸　尚治[2]
[1] 大阪大学整形外科, [2] 大阪大学人工知能画像診断学, [3]JCHO 大阪病院, [4] 大阪労災病院

OP19-5　カスタマイズ可能なクエリに基づく Human-in-the-Loop 型医用画像検索

小林　和馬
国立がん研究センター研究所

OP19-6　没入型 VR を用いた放射性医薬品投与訓練における緊張度の計測

垣本　晃宏[1,2], 藤瀬　大助[3], 長谷川　慎[3], 奥田　保男[3], 太田　悠斗[4], 谷　　碧翔[4], 船橋　正夫[1]
[1] 森ノ宮医療大学　医療技術学部　診療放射線学科, [2] 浜松医科大学　光尖端医学教育研究センター　フォトニクス医学研究部　生体機能イメージング研究室, [3] 量子科学技術研究開発機構　本部　情報基盤部　IT 企画課, [4] 森ノ宮医療大学　保健医療学部　診療放射線学科

ハンズオン会場（中会議室 1）

ハンズオンセミナー 3

9:10 ～ 10:40　**課題 3　深層学習のための前処理と後処理**

「DICOM 画像・バーチャルスライド画像の読み込み／ ROC などの統計処理」

ハンズオンセミナー 4

14:00 ～ 15:30　**課題 4　幅広い深層学習「言語処理や音声認識における深層学習技術」**

第 1 会場（一橋講堂）

閉会式

16:30 ～ 16:40

第1会場（一橋講堂）

JAMIT ハンドブック増補分冊（発刊予定）チュートリアル Part I

10:40 ～ 12:10　**TU1「映像化技術編」**

座長：橋本二三生（浜松ホトニクス株式会社）
野崎　太希（慶應義塾大学医学部　放射線科学教室）

TU1-1　最新の医用イメージングにおける画像再構成法の紹介

○工藤　博幸
筑波大学システム情報系情報工学域，東北大学国際放射光イノベーション・スマート研究センター（SRIS）

医用画像ハンドブック増補版の「画像再構成」部分を伊藤聡志先生（宇都宮大学），橋本二三生氏（浜松ホトニクス），工藤の3名で分担して執筆した．その構成は大きく，1) ハンドブック 2012 年版への増補項目（順投影の計算方法，デュアルエナジー CT・フォトンカウンティング CT の画像再構成，CT アーティファクトの補正，PET・SPECT アーティファクトの補正），2) 圧縮センシング画像再構成法（CT, MRI），3) 深層学習画像再構成法（CT, MRI, PET）のようになっており，魅力的なものに仕上がったと考えている．本発表では，3名を代表して工藤がその内容の一旦を紹介する．

TU1-2　MRI の最近の技術的発展

○寺田　康彦
筑波大学　数理物質系　物理工学域

MRI（核磁気共鳴イメージング）は，核磁気共鳴現象を利用して，物体内部の構造を計測する方法で，1973 年に Lauterbur によって提案されて以来，人体用 MRI 装置を中心に目覚ましい技術的発展を遂げている．本稿では，本学会（JAMIT）出版予定の「医用画像工学ハンドブック増補版」において，MRI に関して新しく追加した内容を中心に，MRI の最近の技術的発展に関して紹介する．

まず，MRI は他のモダリティと比べて撮像時間が長いことが課題の一つであるが，MRI の撮像を高速化する方法として，パラレルイメージングや non-Cartesian イメージングについて紹介する．また，対象の物体や組織に由来する物性値を直接画像化する，定量画像法を紹介する．定量画像は，画像診断の標準化や精密医療に不可欠な定量バイオイメージングマーカーとして期待されている．その他のコントラストとして，骨中などの固体状態に近いプロトンを画像化する手法などを紹介する．また，MRI 特有のアーチファクトに関しても紹介する．

TU1-3　核医学装置 － 10 年間の進歩

○田島　英朗
量子科学技術研究開発機構

PET，SPECT に代表される核医学装置はこの 10 年で大きく進歩した．SPECT では，直接変換型の半導体検出器を用いた全身装置が登場し，エネルギー分解能を始めとして様々な性能が向上した．PET では，シンチレーション検出器の受光素子が SiPM に置き換えられていき，大幅な時間分解能向上がなされた．SiPM は小型かつ磁場中での動作が可能であるため，PET-MR 装置の開発も活発に行われた．臨床用 PET としては，1 メートルを超える体軸視野の装置が登場し超高感度全身同時撮像を実現する一方で，半球状の検出器配置を持つヘルメット PET のように，特定部位に特化することで原理的に高感度のみならず高分解能達成可能な部位別 PET 装置が実用化された．また，対向型 PET 装置のように特定用途に特化したものも乳房専用装置として商品化されている．そして，多様化する装置に対応するため，性能評価法も現状に合わせてアップデートされてきた．本講演では，これらの技術，装置の進歩を包括的に紹介する．

TU1-4　X 線イメージングと放射線治療用イメージングの概要

○臼井　桂介

順天堂大学保健医療学部診療放射線学科，順天堂大学大学院保健医療学研究科診療放射線学専攻，順天堂大学医学部放射線治療学講座

本シンポジウムでは，X 線イメージング（フォトンカウンティング検出器，X 線撮影装置，X 線 CT 装置）および放射線治療用イメージングの項での掲載内容を概説する．フォトンカウンティング検出器は林裕晃先生がご執筆され，その原理と課題および物質弁別の可能性に関して解説している．X 線撮影装置は五味勉先生，水上慎也先生がご執筆され，仮想グリッド，X 線動態撮影およびフォトンカウンティングを含むデジタルトモシンセシス（主に乳腺検査領域）を概説している．X 線 CT 装置は田口克行先生がご執筆され，デュアルエナジーとフォトンカウンティング CT 技術に関する原理と臨床応用を示されている．放射線治療用イメージングは講演者が執筆担当し，画像誘導放射線治療法で実用されているイメージング機器の概要と臨床利用を説明している．

8 月 5 日（月）

第 1 会場（一橋講堂）

JAMIT ハンドブック増補分冊（発刊予定）チュートリアル Part II

13:30 ～ 15:00　**TU2「画像処理と解析編」**

座長：中田　典生（東京慈恵会医科大学）
滝沢　穂高（筑波大学）

TU2-1　深層学習の 10 年間の進歩概要と今

○本谷　秀堅

名古屋工業大学

深層学習に関わる技術の近年の進展は目覚ましい．本講演では，まず過去 10 年間の深層技術の進歩を振り返る．具体的には，畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) や回帰型ニューラルネットワーク (RNN: Recurrent Neural Network) やトランスフォーマー (Transformer) の要点を，画像データや言語データが持つ性質と併せて述べてみたい．画像データや言語データは，データを構成する各要素間に複雑な統計的依存関係がある．データが構成する低次元多様体は，この統計的依存関係の表れである．画像データや言語データの性質を復習したあと，トランスフォーマーにおける注意プーリングがこの複雑な統計的依存関係を表現する手続きを概観する．ついで，自己教師学習により生成されるベクトル表現について，その効力を確認する．最期に，本チュートリアルで言及される技術の位置づけを紹介する．

TU2-2　深層学習におけるドメイン適応

○庄野　　逸

電気通信大学 大学院情報理工学研究科

深層学習におけるドメイン適応は，転移学習や敵対的学習といった手法を活用して異なるドメイン間での知識転移を実現する技術として重要である．本講演では，これらの技術が発展してきた説明するとともに，様々なドメイン適応の課題とその解決策を概観する．特に，ソースドメインとターゲットドメイン間のデータ分布の違いが引き起こすパフォーマンスの低下という課題に焦点を当てる．転移学習はターゲットドメインが少数データしかないようなケースで顕在化する不確実性を担保するために有効な手法である．一方，敵対的学習は，モデルの堅牢性を向上させる手法でドメイン間の差異を最小化するといった応用が提案されている．本講演は，これらのアプローチの理論的背景と実践的な応用例を紹介し，それぞれの手法がどのようにしてドメイン間のギャップを縮め，モデルの汎用性を向上させるかを解説する予定である．

TU2-3　教師データの不足を補う : 少数データに対する機械学習手法概要

○備瀬　竜馬
九州大学大学院システム情報科学研究院情報知能工学部門

一般的に，機械学習において，高い汎化性を持つモデルを実現するためには，大量の教師ありデータが必要となる．しかし，医療分野においては，アノテーションに専門的な知識が必要である点や個人情報保護の観点からクラウドソーシングを用いることができず，多忙な医師が様々な症例ごとに正解データを大量にアノテーションすることには限界がある．また，個人情報保護の観点から公開データセットも不十分である．

本発表では，以上の十分な数の教師データ収集の困難性へ対応するためのアプローチとして，①少数の教師データと多数の教師なしデータから学習する半教師あり学習，②データ自体を加工して，機械的にラベルを生成し表現学習を行う自己教師あり学習，③最初に与えられた教師データに加えて，学習に効果的な教師データを手法自ら選択する能動学習について，クラス分類タスクを軸に説明し，具体例として著者らが提案した手法を紹介する．

8月5日（月）

第１会場（一橋講堂）

シンポジウム１

15:10 ～ 16:40　**SY1「医用イメージングの新潮流」**

座長：工藤　博幸（筑波大学）

SY1-1　散乱を用いた X 線 CT

○戸田　尚宏
愛知県立大学　情報科学部　情報科学科

X 線 CT は 1970 年代に実用化され，現在までに医療診断において不可欠な診断装置となっている．近年ではフォトンカウンティング方式やエネルギ分析による組織同定，さらには検出器の高感度化，高密度化による高精細・高速化が進行中である．また，コーンビーム化に伴い散乱線が増加するため，その除去のためのグリッドの精度も極めて高度化してきた．しかし，散乱線は対象物の存在により発生するため，対象物の情報を含む．この事から直接線と合わせて散乱線を利用する事で，CT 再構成精度が向上し，被爆削減に繋げられるのではないかと期待される．本報告では散乱線を擾乱要素としてではなく，情報源として捉える観点からこれまでの研究を概観し，著者らによるモンテカルロシミュレーションによる逐次近似法を用いる方法や，ニューラルネットワークを用いた方法，及び理論的な根拠の構築に関する取り組みを紹介する．

SY1-2　画像再構成の最新の話題

○橋本　雄幸
杏林大学　保健学部　診療放射線技術学科

画像再構成は，アルゴリズムとコンピュータの性能との両輪で進化してきました．Hounsfield によって開発された最初の CT では，2 次元の再構成に 9 日間を要しました．1970 年代後半に浮動小数点演算が自由に使えるようになると，フーリエ変換を使った FBP 法が主流になります．その後，徐々にコンピュータの性能が高くなり，逐次近似的な計算に耐えうるようになりました．逐次近似法に正則化などの技術を取り入れることで，ノイズ耐性などが向上し，逐次近似法は画像再構成の中心に躍り出ました．さらに，コンピュータ性能の向上により深層学習が登場し，現在ではその深層学習を利用した画像再構成が話題の中心になっています．その深層学習を用いた画像再構成法については詳しく解説したいと思います．近年，コンピュータの分野では量子コンピュータが大きな注目を浴びています．今後は，画像再構成の分野も量子コンピュータへの応用が重要な課題となるでしょう．

SY1-3　深層学習を利用した MR 画像再構成の新展開

○伊藤　聡志

宇都宮大学 大学院工学研究科 地域創成科学専攻 情報電子オプティクスコース

圧縮センシング（CS）と，それに関連する画像科学は MRI の高速化 (CS-MRI) において新たな展開をもたらしたが，CS-MRI は比較的長い再構成時間を必要とすること，再構成パラメータやスパース化関数は，経験的に選択されることが多いことなどの課題があった．

深層学習画像再構成 (DLR) は，前述の解決に有望な方法として登場し，すでに十有余年が経過している．様々な方法が提案されてきたが，DRL は大別すると再構成のフレームワークとその入出力信号に基づきデータ駆動型 End-to-end 学習と物理・モデル Unrolling 型学習の 2 種類に分類される．それぞれの方法は，解に至る方法の違いから得られる再構成像，学習に要する画像枚数，学習時間などが異なる特徴がある．本シンポジウムでは，DRL の再構成法を体系的に分類しつつ，各方法の特徴を説明する．

SY1-4　PET の現状 − 装置開発及び臨床応用

○木村　裕一

近畿大学情報学部情報学科，近畿大学情報学研究所

PET は，定量値が得られるが故に，様々な生体機能の画像化が可能であるという特徴を有するモダリティーである．一方で，その測定原理上，他のモダリティーと比較して空間分解能が劣るという欠点がある．そこで本講演では，PET の装置開発の現状の説明を通して，空間分解能が向上した PET 画像をご覧頂く．又，生体機能の画像化が可能であるという特徴故に，PET は臨床に様々に応用されているが，その現状についても説明する．

8 月 5 日（月）

第 1 会場（一橋講堂）

一般演題 1

16:50 ～ 18:00　**OP1「放射線画像再構成 1」**

座長：湯浅　哲也（山形大学大学院理工学研究科）

尾崎　　翔（弘前大学大学院理工学研究科）

OP1-1　SPECT における被写体構造を考慮した係数自動制御機構付き正則化画像再構成法

○皆川　智哉[1]，堀　　拳輔[3]，橋本　雄幸[2]

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

正則化付き画像再構成法の係数値は経験的に決定する必要があるが，SPECT は対象の部位によって撮像条件が大きく変化するため，全ての検査で最適な係数値を決定するのは煩雑で難しい．そこで我々は先行研究において，収集条件および正則化項のとり得る値を考慮し係数値を自動制御する正則化付き画像再構成法である RAREM 法を提案した．しかし，被写体の構造的複雑さについては考慮されていないため適応は限定的であった．本研究では，RAREM 法の係数値自動制御機構に新たに被写体の構造的複雑さを考慮する項を組み込んだ画像再構成法を提案する．実験では収集カウント数および投影数を変化させ，単純な構造のファントムと頭部ファントム 2 種類を使用した．画像再構成法には TV-EM 法，modified-BSREM 法および提案法を用い，有効性を検討した．最適なパラメータを経験的に選択した従来法と比較して，提案法の NRMSE は同等以上の結果を示し，臨床応用の容易さおよび有用性が示唆された．

OP1-2　ダイクストラ型スプリッティング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]，尾内　康臣[2]
[1]浜松ホトニクス株式会社 中央研究所，[2]浜松医科大学 光尖端医学教育研究センター

PET のブロック反復法を収束させるには，緩和パラメータの制御が必要となる．しかし，リストモード PET 再構成のための緩和パラメータの自動決定法は明らかとなっておらず, 別の枠組みが必要とされている．本研究では, ダイクストラ型スプリッティングを用いたリストモード最尤 PET 再構成（LM-MLDS）を提案する．LM-MLDS は，初期画像からの距離をペナルティ項として目的関数に追加することにより，リストモードのブロック反復法を収束させる．LM-MLDS は，シミュレーションにおいて他のブロック反復法より良好なノイズとコントラストのトレードオフ曲線を与え，臨床データにおいては体軸視野の端にある偽のホットスポットを抑制した．これらの結果は，近接スプリッティングが，微分不可能な関数を最適化するためだけではなく，リストモード PET 再構成のブロック反復法を構築するためにも有用な枠組みであることを示唆した．

OP1-3　Dykstra 型 Splitting を用いた統計的 PET 画像再構成法のリストモードデータへの拡張とオンライン PET 再構成の提案

○工藤　博幸
筑波大学システム情報系

PET の画像再構成では，計算量を削減するため OSEM 法などの対数尤度を部分評価関数の和に分解して部分評価関数ごとに画像更新を行うブロック反復型（ローアクション型）再構成法が用いられる．しかし，評価関数の厳密な最小解に収束せず雑音特性が悪い Limit Cycle に収束する問題点がある．この問題点を解決する方法として，1) 画像更新量のステップサイズをゼロに近づけながら反復を行うステップサイズ制御（Tanaka,Kudo,2003, Dong,Kudo,2017），2) 主双対問題の形に再定式化して双対空間の座標降下法で解く手法（李 , 工藤 ,2004，Chambolle et al,2018）が存在する．後者は発表者らが 2004 年に初めて提案したが（李 , 工藤 ,2004）近年この方向性の研究が世界的によく行われており（Chambolle et al,2018），筆者らも後者の中でも有効な Dykstra 型 Splitting と呼ばれる数学的枠組みを用いた PET 再構成法を既に提案している（Sadakata et al,2020, Kim et al,2021）．PET の測定データは，LOR ごとの計数値を記録するヒストグラムモードと各光子が測定された LOR を記録するリストモードの 2 つの表現方法が知られ，光子数と比較して LOR 数が多い 3D 収集・TOF 収集・Dynamic 収集などの場合にはリストモードが効率的であり，リストモードデータから直接対数尤度を最小化するリストモード再構成法が研究されている．本発表では，ヒストグラムモードに対して提案された Dykstra 型 Splitting を用いた再構成法をリストモードに拡張することを行った．拡張は数学的に自明ではなく，幾つかのキーアイデアが必要であった．従来の主問題を直接解く再構成法では，ステップサイズ制御や雑音のバランスを取る部分評価関数への分割（Nakayama,Kudo,2005）がないと上手く動作しないが，Dykstra 型 Splitting に基づく再構成法ではこれらが不要で従来のリストモード再構成法と比較して上手く収束することが明らかになった．更に，画像平滑化を行う Relative Difference Prior を正則化項に用いた場合への拡張を行った．類似研究の Chambolle らの方法では一反復内でサブセット数回の正則化項の近接写像が必要で計算量が多いが，正則化項を一つのサブセットと考える Dykstra 型 Splitting では一反復内で一回の近接写像しか必要なく計算量の点で大きな優位性がある．最後に，Dykstra 型 Splitting の高収束性を活かして，データ収集と同時に並行して画像再構成を行いデータ収集後直ちに再構成画像を提示できる新しい考え方の「PET オンライン再構成」を提案して，その数値実験による検討を行い有望な見通しを得た．

OP1-4　主双対ブロック反復勾配法の理論構築と統計的画像再構成への応用

○工藤　博幸
筑波大学システム情報系

PET や X 線 CT の統計的画像再構成は，対数尤度からなるデータ項と TV など画像平滑化を行う正則化項の和を反復法で最小化することにより行われる．反復法の収束が遅い問題点を解決するために，評価関数を部分評価関数の和の形に分解して部分評価関数毎に画像更新を行う構造のブロック反復型（ローアクション型）反復法がよく用いられるが，真の評価関数の最小解と異なる雑音伝搬が悪い Limit Cycle に収束する問題点がある．この問題点を解決するため，1) 画像更新量のステップサイズをゼロに近づけながら反復を行うステップサイズ制御，2) 主双対問題の形に定式化して双対問空間の座標降下法で解く方法（李 , 工藤 ,2004, Chambolle et al,2018），の 2 つが存在する．特に，後者は固定ステップサイズで Limit Cycle 問題を回避でき有効である．発表者らは，既に後者の中でも有効な Dykstra 型 Splitting を用いた再構成法（Sadakata et al,2020, Kim et al,2021）を提案しているが，問題点として部分評価関数の近接写像計算が必要なことがあげられる．近接写像計算は勾配法の計算より複雑であり，1) PET 対数尤度では近接写像が複雑な形になりアルゴリズムの見通しが悪い，2) 透過型 CT 対数尤度では近接写像は陽な形で計算できない，などの問題点がある．本研究では，主双対問題を解く Dykstra 型 Splitting と類似した構造の反復法で部分評価関数の（前処理なし・ありの）勾配計算のみで済む新手法の「主双対ブロック反復（ローアクション型）勾配法」を提案し , その数学的導出を行った．そして，この枠組みを PET（ヒストグラムモード・リストモード）及び X 線 CT に適用した具体的なアルゴリズムを示し，勾配法の計算が基本であるため従来の再構成法と類似した外観で見通しがよく実装しやすく，Dykstra 型 Splitting と同様に高速に収束し Limit Cycle 問題を回避できることを示した．更に，JAMIT2023 で発表した部分評価関数の選択をランダムに行う手法を組み込んだ「確率的主双対ブロック反復勾配法」では，数学的に概収束（almost sure convergence）することを示した．実用的に非常に上手く動作し Limit Cycle 問題がない, 理論的収束性, 実装が勾配法ベースで簡単で実用的など，欠点がないといえる手法である．

OP1-5　Variance Reduction 確率的勾配法を用いたブロック反復型逐次近似画像再構成法の構築

○朝戸　天翔[1]，工藤　博幸[2]

[1]筑波大学 理工情報情報生命学術院 システム情報工学研究群 情報理工学位プログラム 博士前期課程，[2]筑波大学システム情報系

PET や CT の画像再構成は，対数尤度や 2 乗誤差などからなるデータ項と，TV などの平滑化を行う正則化項からなる評価関数を逐次近似法で最小化することにより行われる．逐次近似法の収束を高速化させるためには，評価関数を部分評価関数の和の形に分解し，部分評価関数毎に画像更新を行うブロック反復型 (Row-Action 型) 反復法が有効であるが，評価関数の真の最小解と異なる Limit Cycle に収束し，雑音特性が悪くなるという問題点がある．この問題点を解決する方法として，Dykstra 型 Splitting を用いた画像再構成法である DLPM 法 (Sadakata et al, 2020, Kim et al, 2021) が提案され，DLPM 法を数学的に概収束 (almost sure convergence) するように改良した確率的 Dykstra 型 Splitting(Kudo et al, 2023) が提案された．確率的 Dykstra 型 Splitting では部分評価関数の選択をランダムに行い，選んだ部分評価関数に近接写像を作用させて画像更新を行う，高速に収束し，かつ数学的に厳密な収束性を持つ方法である．しかし，近接写像の計算が必要であることから，1) PET の対数尤度では近接写像の計算が複雑になってアルゴリズムの見通しが悪くなる，2) 透過型 CT の対数尤度では近接写像が解析的に計算できない，などの問題点が挙げられる．本研究では，高速に収束する逐次近似画像再構成法として，Variance Reduction Method を用い，部分評価関数の勾配を使った Variance Reduction Method の更新式によって逐次近似画像再構成を行う手法を提案する．Variance Reduction Method では，確率的 Dykstra 型 Splitting と同様に，ランダムにサブセットを選ぶことが収束性を保証するキーとなっており，提案手法のアルゴリズムは，確率的 Dykstra 型 Splitting における近接写像を適用させる部分を，データ項の勾配を使った更新式に置き換えた形になっている．そのため，緩和係数制御が不要などといった DLPM 法の利点を併せ持っている点が特徴である．また，提案手法では近接写像を使わないためデータ項の勾配が計算できればよく，近接写像の計算が複雑になるものや，近接写像の計算が解析的に計算できないものについても簡単に実装できる点が利点として挙げられる．提案手法に基づき，PET の対数尤度を用いた画像再構成法を実装し，Limit Cycle 問題を回避して，従来の逐次近似画像再構成法よりも高速に収束することを実証した．

OP1-6　不完全投影データからの位相 CT 画像再構成における解の一意性

○藤井　克哉[1]，工藤　博幸[2]

[1]畿央大学　教育学部，[2]筑波大学システム情報系情報工学域

X 線位相 CT は，吸収係数の小さい物質に対して十分なコントラストが得られる画像再構成として期待されている X 線 CT 手法である．本研究では，工藤らの先行研究であるインテリア CT の手法を位相 CT へ拡張する．インテリア CT とは関心領域のみを通る投影データから再構成する手法であり，X 線被ばく量軽減のためにも期待されている．工藤らはインテリア CT の解の一意性が成立する条件は，再構成領域の任意の先見情報領域が存在することを示した．本研究における位相 CT の場合も同じ条件を用いる．また位相 CT の場合，取得可能な投影データは元の投影データを微分したものであるため，解の一意性を示すときに用いる数式モデルは Cormack 型再生公式を採用することにより，簡便でより広範な不完全投影データからの再構成理論を構成することが可能となった．さらに本理論の正しさを実証するために不完全投影データからの位相 CT 画像再構成のシミュレーション実験を行い，理論と整合性のとれた実験結果を得た．

OP1-7　X 線回折波 2 重撮影法のスパース性を利用した CT 投影削減手法

○砂口　尚輝[1]，湯浅　哲也[2]，島雄　大介[3]，黄　　卓然[1]，市原　　周[4]，西村理恵子[4]，岩越　朱里[4]，KimJong-Ki[5]，GuptaRajiv[6]，安藤　正海[7]

[1]名古屋大学，[2]山形大学，[3]大阪物療大学，[4]名古屋医療センター，[5]大邱カトリック大学，[6]マサチューセッツ総合病院，[7]高エネルギー加速器研究機構

放射光 X 線を利用する位相コントラスト撮影法 (PCI) は軽元素からなる被写体に高いコントラストを生成できる．近年，光源の高品質化や検出器の性能向上が進み，広視野かつ高空間分解能の撮像が可能になっている．それに伴い，CT の再構成に必要な投影数も増加しており，撮像時間の増加に繋がっている．我々は以前 PCI の 1 つである X 線暗視野法を用いて，微分型 CT に基づく投影削減手法を提案し，CT の画素値が疎であるほど投影数を削減できることを示した．しかし，この方式は取得される 1 階微分投影に差分処理を適用し 2 階微分投影を生成する必要があり，処理の過程でノイズが増幅する問題があった．それに対して，近年我々が考案した新しい PCI である X 線回折波 2 重撮影法は高い空間分解能とコントラストで 2 階微分投影が直接得られるという特徴を持つ．本研究ではこの撮影法が有するスパース性を利用した CT の投影削減について検討する．

第２会場（中会議室 2-4）

一般演題 2

15:00 ～ 16:00　**OP2「画像生成」**

座長：中山　良平（立命館大学）
花岡　昇平（東京大学）

OP2-1　膨張畳み込みを導入した 3D ResNet-18 による心臓 CT-Perfusion 画像の左室短軸像の自動作成

○岩井　星澄[1]，中山　良平[1]，檜作　彰良[1]，中村　哲士[2]，佐久間　肇[2]
[1] 立命館大学大学院　理工学研究科，[2] 三重大学医学部放射線科

左室の形態や機能の評価に用いられる心臓 CT-Perfusion 画像の左室短軸像は，撮影された画像を読影医が手動で回転を行い，作成する必要がある．そこで本研究では，読影医の負担を軽減するため，心臓 CT-Perfusion 画像から左室短軸像を自動作成する手法を提案する．実験試料は，心臓 CT-Perfusion 画像 100 症例である．本研究では，3D ResNet-18 の受容野を広げるために，畳み込み層を膨張畳み込み層に置き換えた Dilated 3D ResNet-18 を構築する．そして，Dilated 3D ResNet-18 により体軸水平断像から左室短軸像へ変換するオイラー角を予測し，オイラー角に基づく回転行列を適用することで左室短軸像を作成する．提案手法の各オイラー角に対する RMSE は ψ：9.60，θ：5.61，φ：6.15 で，従来手法の 3D ResNet-18（ψ：13.49，θ：5.82，φ：6.22）より小さく，その有用性が示唆された．

OP2-2　拡散モデルを用いた皮膚疾患画像の合成と画像分類におけるクラス不均衡の改善

○高倉　　俊[1]，志藤　光介[2]，藤澤　康弘[3]，山崎　研志[2]，坂井　浩志[4]，藤本　　学[4]，清水　昭伸[1]
[1] 東京農工大学大学院工学研究院，[2] 東北大学大学院医学系研究科皮膚科学分野，[3] 愛媛大学大学院医学系研究科皮膚科学，[4] 大阪大学大学院医学系研究科皮膚科学

著者らはこれまで，光学カメラで撮影された 172 クラスの皮膚疾患の臨床画像を対象とした皮膚疾患分類モデルを開発してきた．しかし，クラス数が増えるにつれて，クラス間の学習データの不均衡が著しくなり，分類モデルがデータ数の多い多数派クラスに注目して，少数派クラスの分類精度が低下する問題が明らかになった．本研究では，精度の低い少数派クラスを対象に，拡散モデルを用いて人工的にデータを合成する方法を提案する．具体的には，Stable Diffusion を textual inversion という手法でファインチューニングすることで，疾患を表す 68 個の疑似単語から，疾患画像を合成するモデルを作成した．また，172 疾患の中から精度の低い少数派の 43 クラスに提案手法を適用し，実画像と合成画像を用いて分類モデルを学習させることで精度が改善することを示す．

OP2-3　光干渉断層血管撮影画像からのフルオレセイン蛍光眼底造影様画像の生成手法

○溝部　秀謙[1]，鳥羽　修平[1]，平野　隆雄[2]，村田　敏規[2]
[1] キヤノン株式会社，[2] 信州大学 医学部 眼科学教室

蛍光眼底造影検査は，網膜 - 脈絡膜疾患の診断を補助する一般的な検査であるが，造影剤の利用に起因する副作用等の課題がある．そこで本研究では，造影剤を用いない光干渉断層計 (OCT) 検査によって取得される，ある一時点の OCT Angiography(OCTA) 画像に基づいて，フルオレセイン蛍光眼底造影 (FA) 検査画像を模した，造影剤の経時的な漏出の様子を描出する動画像を生成するモデルを構築した．このモデルの訓練には，糖尿病網膜症患者を対象とした OCT 検査で取得された OCTA 画像，非撮像時間帯への合成画像挿入処理と位置合わせ処理を施した FA 検査画像，および FA 検査画像の造影時間情報とによって構成されたデータセットを用いた．そして，有効画素領域のみを損失計算の対象として訓練を実施した．生成した動画像は，実際の FA 検査画像に対して平均 SSIM 0.91 (SD 0.08) という高い類似性を示した．

OP2-4　腹部単純 X 線画像からのガス領域抽出における疑似 X 線画像を用いた U-Net 事前学習法の検討

○高島　直也[1]，藤田　大輔[1]，佐貫　　毅[2]，木下　芳一[2]，小橋　昌司[1]

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

慢性便秘は世界人口の 15% に影響を与える慢性疾患であり，生活の質を著しく低下させている．便秘は多様な症状や病態を示し，その原因に応じた治療が必要である．適切な治療法の選択には，腹部単純 X 線画像中のガスや便の量と位置の定量化が重要である．本研究では，便秘の画像診断支援法として，U-Net を用いたガスと便領域の自動抽出法を提案している．本稿では，CT 画像から生成された疑似 X 線画像を用いた事前学習法を提案し，その有効性を検証する．実験では，U-Net の初期ネットワーク重みにランダム，ImageNet での事前学習，疑似 X 線画像を用いた大腸領域抽出での事前学習を 95 例の被験者に交差検証により適用し，DICE 係数がそれぞれ 0.520，0.676，0656 となり，事前学習の有効性が確認できた．また，疑似 X 線画像を用いた事前学習は ImageNet と同等であり，今後の精度向上には他領域の抽出問題での事前学習，疑似 X 線画像生成法についての検討が必要である．

OP2-5　細胞核画像の形とテクスチャへの特徴分離と生成モデルの構築

○村上　和真[1]，田口　　慶[1]，横田　達也[1]，大島　孝一[2]，三好　寛明[2]，永石　美晴[2]，橋本　典明[3]，竹内　一郎[3]，本谷　秀堅[1]

[1] 名古屋工業大学，[2] 久留米大学，[3] 名古屋大学

悪性リンパ腫は多くのサブタイプに分かれており，サブタイプによって治療法が大きく異なるため正確な診断が必要となる．しかし，現在細胞核の形態によりその種別を識別するための定量的な基準が統一されておらず，細胞核の分類をすると病理医ごとにその結果が変化しうるという課題がある．本研究では細胞の種別ごとの違いを病理医に理解可能な形式で明示することを目指す．まず，細胞核の画像より形とテクスチャの特徴を分離表現するために機械学習を行う．これにより得られる特徴ごとの潜在空間を利用し，細胞の種別識別器を並用することにより種別の違いによる細胞核の違いを形とテクスチャの要因を分けて解析することを可能にする．また，細胞核画像の生成モデルを潜在空間で実現することで種別の異なる細胞核間の系列画像を生成し，それらを種別識別することで種別間の識別境界に近い細胞核画像を系列として明示する．本稿ではその結果を報告する．

OP2-6　Textual Inversion を用いた FDG PET 画像の text-to-image 生成の試み

○松原　佳亮[1]，村上　貴也[1]，木下富美子[2]，篠原　祐樹[2]，茨木　正信[2]，木下　俊文[2]

[1] 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，[2] 秋田県立循環器・脳脊髄センター放射線医学研究部

近年拡散モデルを用いた text-to-image 画像生成が台頭してきている．本研究では画像の特徴を一つの単語 (“S*”) に圧縮することで画像生成を制御する Textual Inversion を用い，FDG PET 画像の text-to-image 生成を試みた．

23 例の肝臓 FDG PET 画像を用い，事前学習済み Stable Diffusion v1.5 を Textual Inversion により fine-tuning した．当該モデルを用いて ”S*” 及びそれに肝臓における集積という条件を加えたプロンプトによる生成を試みた．

Fine-tuning したモデルにより，実際の PET 画像にごく近い画像の生成に成功した．一方で，集積を条件に加えたプロンプトを用いた時と ”S* image” のみの時とで差異がなく，集積の制御はできなかった．集積の制御には健常画像による学習等が必要である．

第２会場（中会議室 2-4）

一般演題 3

16:10 ～ 17:00　**OP3「セグメンテーション 1」**

座長：有村　秀孝（九州大学）
野村　行弘（千葉大学）

OP3-1　Evaluation of Intestine Segmentation Methods Towards Path Tracking

○安　　芹[1]，小田　紘久[2]，林　雄一郎[1]，北坂　孝幸[3]，滝本愛太朗[4]，檜　　顕成[4]，内田　広夫[4]，鈴木耕次郎[5]，小田　昌宏[6,1]，森　　健策[1,6,7]

[1]名古屋大学大学院情報学研究科，[2]静岡県立大学経営情報学部，[3]愛知工業大学情報科学部，[4]名古屋大学大学院医学系研究科，[5]愛知医科大学医学部放射線科，[6]名古屋大学情報基盤センター，[7]国立情報学研究所医療ビッグデータ研究センター

In this paper, we compare the results of intestine path tracking based on different segmentation methods. We also analyze the influence of intestine segmentation accuracy on path tracking. We employed the different trained segmentation models (3D U-Net, TotalSegmentator, MVSNet, and CPS) to achieve the segmentation results and then achieved the distance maps based on the segmentation. The distance maps were used to narrow the segmentation results, which helped to eliminate the overlapping parts between the intestinal walls reducing the shortcut of the intestine and extracting the correct intestinal path. In the experiment, we used CT volumes labeled by clinicians for training different segmentation models and then achieved path tracking. We evaluated the influence of segmentation on path tracking using 15 CT volumes and the results show that good segmentation helps with path tracking.

OP3-2　Enhancing Kidney Tumor Segmentation using Multi-Modal Medical Images with Transformer Networks

○ SrisopitsawatPavarut[1]，小尾　高史[1]，李　　中淳[2]，小林　正貴[3]，田中　　一[3]，石岡淳一郎[3]，松岡陽[3]，藤井　靖久[3]

[1]東京工業大学　工学院　情報通信系，[2]科学技術創成研究院 東京工業大学，[3]東京医科歯科大学 腎泌尿器外科学

Detecting and segmenting kidney tumors presents a significant challenge due to their small size and complex characteristics. Typically, medical professionals rely on various diagnostic techniques, including multi-modal medical imaging, to reach a conclusive diagnosis. However, existing Convolutional Neural Network (CNN) methodologies face limitations in handling multi-modal data of varying sizes and missing information.

In this study, our primary objective is to enhance segmentation accuracy, surpassing current methods. To achieve this, we propose a multi-modal fusion framework leveraging transformer model, capitalizing on the remarkable success transformers have demonstrated in image recognition tasks. Our methodology utilizes the extensive data provided by Contrast-Enhanced Computed Tomography (CECT) and Magnetic Resonance Imaging (MRI), including their respective subtypes, to enrich our medical analysis. This comprehensive approach aims to advance the state-of-the-art in kidney tumor segmentation, offering promising prospects for improved medical diagnosis and treatment planning. Our work also introduces a thorough analysis of different multi-modal fusion techniques. Furthermore, we propose the integration of a multi-modal attention mechanism to ensure the model attends to the most contributory modalities. This innovation enhances the interpretability and effectiveness of our approach in accurately detecting and segmenting kidney tumors.

OP3-3　密な残差接続を持つ Dense Residual UNet を用いた頭部死後 CT 画像の脳内出血セグメンテーション

○中本　将彦[1]，八代　正彦[2]，林　　敬人[2]

[1]株式会社エクセル・クリエイツ，[2]鹿児島大学大学院医歯学総合研究科 法医学分野

死後画像診断は解剖前に体内の異変を把握できるため，より正確かつ短時間で解剖を行うために有用である．一方で，画像撮影から解剖までの短時間で読影が求められたり，死後画像に精通した読影医が少ないことから画像解析による支援が期待されている．著者らは，頭部死後 CT 画像の脳内出血の種類，位置，出血量を把握するために機械学習による脳内出血セグメンテーションモデルの開発を行っている．本研究では密な残差接続を持つ Dense Residual UNet を提案し，残差接続を持つ Residual UNet，レイヤー間接続を持つ Dense UNet と比較する．実験結果ではレイヤー間の接続が最も密な提案法で最も Dice 係数が高くなり，脳内出血セグメンテーションの性能向上に有効であることを確認した．

OP3-4　大規模データセットの活用に向けた基礎的検討と応用事例

○杉下　友麻[1]，原　　武史[2]，尾碕　公美[3]，周　　向栄[2]，藤田　広志[2]

[1]岐阜大学大学院自然科学技術研究科，[2]浜松医科大学放射線診断学講座，[3]岐阜大学工学部

医用画像分野において，大規模なパブリックデータセットの構築が進んでいる．Wasserthal らによって発表された TotalSegmentator は 1204 件の CT 画像を用いて 104 の解剖学的構造のセグメンテーションを可能とし，医用画像 AI の発展に貢献している．そして様々なモダリティ，撮像部位を統一的に扱うことができるモデルの登場により，我々が扱うデータは増大している．DICOM や nifti は医用画像を統一的に扱うための画像形式であるが，放射線科と脳神経科では画像の座標系が異なるように，分野によりデータの扱いに違いがある．これは医用画像を統一的に扱う際の課題になる．そこで本研究では TotalSegmentator データセットの活用に向けた基礎的検討を行う．また応用事例として肝腫瘍の RFA 前後の臓器セグメンテーションと位置合わせを行い，治療効果を推定する研究の展望を示す．

OP3-5　3 時相腹部造影 CT 画像を用いた腎臓・腎腫瘍・嚢胞の自動抽出

○西村　一馬[1]，越野　魁都[1]，河田　佳樹[2]，小針　悠希[3]，池田　篤史[4]，仁木　　登[5]

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

腎臓がん患者の死亡者数は年々増加傾向にある．本研究の最終目標は，腎臓・腎腫瘍を精密に解析して良性・悪性腫瘍の高精度な鑑別法を開発することである．そのためにまず 3 時相腹部造影 CT 画像から腎臓・腎腫瘍・嚢胞の抽出を行う必要がある．解析には数百～数千の抽出した症例が必要であるため，より高速に抽出することが求められる．本研究では 3 時相腹部造影 CT 画像からの 3D U-Net を用いた腎臓・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) ・嚢胞の高速かつ高精度な抽出方法を開発し，従来法との比較評価を行った．評価結果より，新手法は従来法より高速かつ高精度な抽出を可能にしたことが分かった．今後も，学習データ数の増大により，自動抽出の更なる高精度化が期待できる．

第２会場（中会議室 2-4）

一般演題 4

17:10 ～ 18:00　**OP4「臓器モデリング」**

座長：大竹　義人（奈良先端科学技術大学院大学）
伊東　隼人（福岡大学 理学部応用数学科）

OP4-1　咀嚼嚥下に関連する臓器を対象とした複数臓器統計形状モデルの構築

○三浦　皓大[1]，中谷　亮太[1]，政木　勇人[1,2]，大竹　義人[1]，崇風まあぜん[1]，谷　　懿[1]，井尻　　敬[3]，重田　優子[4]，井川　知子[4]，小川　　匠[4]，稲本　陽子[5]，菊池　貴博[6]，道脇　幸博[7]，佐藤　嘉伸[1]
[1]奈良先端科学技術大学院大学，[2]PSP 株式会社，[3]芝浦工業大学，[4]鶴見大学，[5]藤田医科大学，[6]株式会社明治，[7]みちわき研究所

食物を口腔内に咀嚼し，飲み込む一連動作を嚥下と呼ぶ．嚥下機能は我々が生まれ持った時から持つ機能であるが，年齢を重ねるごとに低下し，誤嚥から誤嚥性肺炎といった症状を起こすことがある．そのため，このような事故を防ぐためにも咀嚼嚥下機能の原理を解明することは重要である．嚥下機能の低下は，舌骨の位置との関連があると言われ，舌骨の上昇量が減少しているヒトは嚥下障害が発生しやすいと報告されている．また，咀嚼機能の低下と嚥下機能の低下には関連性があり，咀嚼機能の低下は口腔周辺の機能の低下と関連があると言われている．そこで本研究では，舌骨および咀嚼嚥下に関連する臓器を対象とした複数臓器統計形状モデルの構築を行い，咀嚼嚥下に関連する臓器を解析することにより，咀嚼嚥下動作の原理の解明を目指す．

OP4-2　CT･MRIに基づく筋骨格モデリングと簡易動作計測を統合した患者個別バイオメカニクスシミュレーション

○伊藤　善久[1]，大竹　義人[1]，崇風まあぜん[1]，李　　贛萍[1]，谷口　匡史[2]，八木　優英[2]，田原　大輔[3]，高尾　正樹[4]，岩佐　　諦[5]，上村　圭亮[5]，市橋　則明[2]，佐藤　嘉伸[1]
[1]奈良先端科学技術大学院大学，[2]京都大学，[3]龍谷大学，[4]愛媛大学，[5]大阪大学

現在行われているバイオメカニクスシミュレーションでは，Vicon などの光学式モーションキャプチャシステムを用いてモーションデータを取得し，そのモーションデータと対象の身長・体重データから標準筋骨格モデルをスケーリングしたモデルを用いてシミュレーションを行う．しかしこの方法には，光学式モーションキャプチャシステムの導入にかなりコストがかかること，標準筋骨格モデルをスケーリングしただけでは筋骨格の個人差などが反映されないこと，といった問題がある．これらの問題を改善するために，導入が容易な OpenCap を用いてモーションデータを取得し，MRI 画像から推定した骨格形状と筋肉体積データを反映させた患者個別筋骨格モデルでシミュレーションを行う．従来のバイオメカニクスシミュレーションと，患者個別バイオメカニクスシミュレーションの両方を実施し，比較した結果を報告する．

OP4-3　大規模データベースにおける体幹部 CT 画像の自動筋骨格系セグメンテーションと解析

○ゴリンサナー アミナ[1]，崇風まあぜん[1]，大竹　義人[1]，政木　勇人[1,2]，村上　陽子[3]，永谷　幸裕[3]，渡邉　嘉之[3]，上村　圭亮[4]，高尾　正樹[5]，菅野　伸彦[4]
[1]奈良先端科学技術大学院大学，[2]PSP 株式会社，[3]滋賀医科大学，[4]大阪大学，[5]愛媛大学

This study aims to develop an automated approach for segmentation and analysis of the entire torso's musculoskeletal (MSK) structures in CT images. In addition, we aimed at investigating the feasibility of the predictive uncertainty for assessing the segmentation accuracy in unlabeled CT images in large-scale database. Previous research has mainly focused on segmenting 2D slices of the abdomen or a limited number of structures in 3D CT images. Our approach involves using an active learning strategy with Monte Carlo dropout sampling (MCDS) to efficiently prepare fully annotated datasets of 20 CT images, covering 20 structures consisting of 18 muscles with visceral and subcutaneous fat. Two models based on convolutional neural networks (CNNs), i.e., a 2D Bayesian UNet and a 3D patch-based nnUNet, were tested. The segmentation accuracy was validated in a 5-fold cross-validation experiment on the 20 labeled CT images using Dice coefficient, average symmetric surface distance, average intensity error, and average volume error. The correlation between the predictive uncertainty and the segmentation accuracy was assessed and additionally tested on two external databases. A model trained on the whole annotated datasets was used to segment and analyze the volume and density of the muscle and fat in a large-scale database of CT images. The relationships between those features and the demographic characteristics including patient's age and sex will be reported.

OP4-4　八分木キューブ構造の臓器変形モデルにおける反力提示の実装

○宮﨑琳太郎[1]，林　雄一郎[1]，小田　昌宏[2,1]，森　　健策[1,2,3]

[1]名古屋大学大学院情報学研究科，[2]名古屋大学情報基盤センター，[3]国立情報学研究所医療ビッグデータ研究センター

本研究では八分木構造および Position Based Dynamics 法に基づく臓器変形モデルに対し，腹腔鏡鉗子の把持操作に伴う反力提示を実装した．近年のコンピュータやコンピュータグラフィックの進歩により，腹腔鏡手術の訓練環境としてシミュレーションが利用されている．製品化されたシミュレータの多くは，モニタに写された臓器モデルをインタラクティブに操作できる．既存のシミュレータ内の臓器モデルは，シミュレーションのリアルタイム性のために低解像度になり，視覚的品質に悪影響を与えている．レンダリングに高解像度の臓器モデル，変形計算のためにラフなキューブ構造を用いる手法が提案されているが，シミュレータとして重要な役割を担う反力提示は実装されていない．本研究ではこのモデルに対し，鉗子にかかる反力を，反力提示装置を通じて操作者に提示する手法を提案する．本手法をゲームエンジンである Unity に実装し，臓器モデルの変形に伴う反力提示を実現した．

OP4-5　X 線位相 CT を用いた高精細マウス 3 次元アトラスの構築

○米山　明男[1,2,3]，LwinThet Thet[2]，馬場　理香[4]，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]北里大学医療衛生学部，[3]高エネルギー加速器研究機構物質構造科学研究所，[4]（株）日立製作所研究開発グループ

X 線が被写体を透過する際に生じる位相の変化（位相シフト）を画像化する位相コントラスト X 線 CT（X 線位相 CT）は，従来の吸収による強度変化を画像化する吸収コントラスト X 線 CT に比べて，軽元素に対して 1000 倍以上感度が高い．このため，無造影，低被曝，かつ高精細に生体の軟部組織を観察することができる．この特徴を活かして，心臓，腎臓，脳をはじめとするマウスの各種臓器の高精細な 3 次元アトラスの構築を，高エネルギー加速器研究機構の放射光施設に常設されている位相 CT 撮像システムを用いて 2 年前より進めている．本発表では，本撮像システムの概要，撮像の条件，及びこれまでに取得した各種臓器の 3 次元像等について発表する．

一般演題 5

9:40 ～ 10:50　**OP5「推定・予測 1」**

座長：畑中　裕司（大分大学）
目加田慶人（中京大学）

OP5-1　吸気・呼気 CT 画像を用いた慢性閉塞性肺疾患における身体活動性予測

○近藤　芽生[1]，間普　真吾[1]，平野　綱彦[2]，村田　順之[2]，土居　恵子[2]，深津愛祐美[2]，楊　　鯤昊[1]，松永　和人[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呼吸器・感染症内科

慢性閉塞性肺疾患（COPD）は，タバコ煙などの有害粒子を長期に吸入することで生じる肺 の慢性炎症性疾患である．COPD に罹患すると，患者は身体活動性が低下し日常生活が制限される．このことを身体活動性障害と呼び，これがさらに COPD の悪化に繋がり悪循環に陥ってしまう．したがって，身体活動性障害を正しく診断するために身体活動性の低下を予測することが重要である．身体活動性を予測するために様々な研究が行われてきたが，患者の胸部 CT 画像を用いた身体活動性予測の研究はほとんど存在しない．そこで本研究では，吸気及び呼気の CT 値ヒストグラムから身体活動性を予測するモデルを構築することを目的とする．具体的には，5 層で構成されたニューラルネットワーク（5-layer NN），自己符号化器付きニューラルネットワーク（AENN），畳み込みニューラルネットワーク（CNN）を構築し，身体活動性の 2 クラス分類を行い，各モデルの身体活動性の予測性能を評価する．

OP5-2　マルチモーダル学習を用いた CEA 患者の循環器病発症予測

○石田　修也[1]，盛田　健人[1,2]，畠山　金太[2]，蓮　　乃駿[2]，渡辺　翔吾[2]，小橋　昌司[2,3]，飯原　弘二[2]，若林　哲史[1]

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

頸動脈内膜剥離術（CEA）は頚動脈狭窄に対する脳梗塞予防を目的とした外科的治療である．強度のプラーク狭窄を有する患者に対して CEA を施行することの有効性が示されているが，術後の長期予後を予測することは依然として困難である．これまでも CEA 患者の臨床情報を用いた予後予測の研究は行われてきているが，病理画像を用いた研究は存在しない．そこで，本研究では頚動脈プラーク病理画像と患者の臨床情報および病理医の所見の 3 つを組み合わせたマルチモーダル学習により，CEA 患者の術後 1 年以内の循環器病の発生の有無を予測した．異常検知モデルによって得られた病理学的リスクスコアと臨床情報および自然言語処理によって得られたテキスト特徴量を組み合わせ，XGBoost による分類を行った結果，ROC-AUC は 0.865，F 値は 0.803 を得た．これらの値はそれぞれの特徴量を単体で用いた時よりも良い分類性能を示した．

OP5-3　拡散モデルによる人体頭部の未来予測と脳室容積の予測精度検証

○柴田　寿一[1]，花岡　昇平[1]，野村　行弘[2,3]，吉川　健啓[2]，阿部　　修[1]

[1] 東京大学医学部附属病院放射線科，[2] 東京大学医学部附属病院コンピュータ画像診断学／予防医学講座，[3] 千葉大学フロンティア医工学センター

近年，機械学習手法の一種である，深層生成モデルが飛躍的に発展しており，これを採用して MR 画像から人体の経時変化をモデル化（＝老化予測）する研究も増えている．ここに，本研究では，深層生成モデルの一種である，拡散モデルを採用して，異なる複数の時期（約 1 年間隔で 7 回）において撮像された過去の成人人体を映した 3 次元頭部 MR 画像から，相対的に未来の成人人体を映した 3 次元頭部 MR 画像を予測し生成できるデジタルツインを構築する．このデジタルツインによる老化予測の精度を検証するため，我々は，脳室容積の変化に注目する．具体的には，過去の頭部 MR 画像から予測された相対的に未来の頭部 MR 画像，及び本物の相対的に未来の頭部 MR 画像から脳室容積を計算し，それらを経時データとしてプロットして，比較検討する．

OP5-4　体幹部定位放射線治療を受けた早期非小細胞肺癌患者における腫瘍成長モデルの開発

○光島　千稀[1]，有村　秀孝[2]，白川　友子[3]，吉武　忠正[4]

[1]九州大学大学院医学系学府保健学専攻医用量子線科学分野，[2]九州大学大学院医学研究院保健学部門，[3]独立行政法人国立病院機構九州がんセンター放射線治療科，[4]九州大学病院放射線科

体幹部定位放射線治療（SBRT）を受けた早期非小細胞肺癌（NSCLC）患者では腫瘍が進行することがある．したがって，本研究では腫瘍の進行予測を目的とし，SBRT を受けた早期 NSCLC 患者の腫瘍成長モデルの開発を行った．SBRT を施行した NSCLC 患者 17 名を選択し，治療前後の CT 画像から輪郭描出した肉眼的腫瘍体積（GTV）をもとに腫瘍細胞数を算出し，それらを参照値とした．一方，放射線に対して 3 つの異なる反応を示す細胞集団（感受性細胞，persister 細胞，抵抗性細胞）が存在すると仮定し，Gompertz モデルに基づいた腫瘍成長モデルを構築した．腫瘍成長モデルに含まれる 9 つのパラメータを焼きなまし法によって最適化し，腫瘍細胞数の経時変化曲線を推定した．SBRT を受けた早期 NSCLC 患者において，腫瘍細胞数の予測可能性を示したが，進行予測のためには腫瘍成長モデルの更なる改良が必要である．

OP5-5　早期非小細胞肺癌に対する体幹部定位放射線治療における治療計画 CT 画像を用いた放射線肺炎予測

○江田　惇哉[1]，有村　秀孝[2]，兒玉　拓巳[1]，吉武　忠正[3]，廣瀬　貴章[4]，YagizYedekci[5]

[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臨床放射線科学分野，[4]九州大学病院医療技術部放射線部門，[5]Department of Radiation Oncology, Faculty of Medicine, Hacettepe University

肺癌に対する体幹部定位放射線治療（SBRT）後に，放射線肺炎（RP）が発症する場合がある．多くの患者では無症状 Grade 1 の RP（RP −）が発症し，一部の患者では有症状 Grade 2 以上の RP（RP+）が発症する．本研究の目的は，SBRT の治療計画 CT 画像を用いて RP+ の予測モデルを開発することである．本研究では 272 症例の SBRT を受けた早期非小細胞肺癌症例を用いた．治療計画 CT 画像に対する Betti 数（BN）に基づく位相幾何学的解析により，BN マップを得た．肉眼的腫瘍体積を除いた肺野を ROI とし，BN マップに対して特徴量計算を行った．特徴量選択を行い，RP+ 予測モデルを構築した．比較のため，ウェーブレット分解画像特徴量によるモデルも構築した．本研究は BN マップ特徴量が従来特徴量より高い RP + 予測能がある可能性を示した．

OP5-6　体外衝撃波結石破砕術結果予測の性能改善に向けたハイブリッド Mixup の初期検討

○望月　嘉恋[1]，根本　充貴[1,2]，中前有香子[1]，木村　裕一[3]，出口　龍良[4]，山下　真平[4]，柑本　康夫[4]，原　　勲[4]

[1]近畿大学生物理工学研究科，[2]近畿大学生物理工学部，[3]近畿大学情報学部・情報学研究科，[4]和歌山県立医科大学泌尿器科

本研究では，体外衝撃波結石破砕術 (ESWL) の治療結果予測システムの性能改善に向け，様々な学習データの人工的加増法を実験的に検討する．本研究で用いる ESWL 治療結果予測 AI システムは，術前手術計画用 CT 像から計測される結石テクスチャ特徴と結石体積に加え，年齢等の患者メタデータ特徴から得られる計 15 特徴量を入力とした全結合層 5 層からなるニューラルネットワークを基盤とする．実験では単純な input mixup，manifold mixup に加え，入力特徴量空間や潜在変数空間上でのクラス境界付近データを用いた mixup，外れ値を除いた mixup など多様な加増データを用いてネットワークを学習し，それぞれの性能改善への効果について網羅的に検証する．術前 CT の撮像後 ESWL を行った単発尿管結石を有する 171 例を用いた 5-fold 交差検証の結果，最大で 16% の ROC 下面積の向上を見た．

OP5-7　ESWL アウトカム予測における CT・X 線画像からの特徴量抽出法の検討

○小林　壯哉[1]，藤田　大輔[1]，澁谷　浩伸[2]，郷原　真輔[2]，小橋　昌司[1]

[1]兵庫県立大学，[2]石川病院

尿管結石に対する治療方法の 1 つである体外衝撃波結石破砕術 (ESWL：Extracorporeal Shock Wave Lithotripsy) は，侵襲性は低いが成功確率が 7 割程度と低い．そのため，治療が失敗すると患者の身体的・金銭的負担が増大につながり，治療前に成功可否を予測することが求められている．本研究では，初期治療として ESWL を選択した 162 名の患者の X 線・CT 画像から特徴量を抽出し，ESWL の成否をアウトカムとした分析を行う．各 CT・X 線画像からそれぞれ深層学習及びラジオミクスにより特徴量抽出を行う．深層学習からの特徴量については，各画像から定めた関心領域を入力として VGG16 を用いた ESWL のアウトカム予測を行い，その出力層を特徴量とする．ラジオミクス特徴量として texture 特徴量，CT 画像からは shape 特徴量も抽出する．抽出した特徴量について，ROC 解析によって各特徴量のアウトカム予測能を評価した．また，相関および多変量解析によって特徴量の独立した予測能を評価した．

第1会場（一橋講堂）

特別講演

11:00 ～ 12:00　**SL「画像と言語の基盤モデルの現状とこれから」**

座長：清水　昭伸（東京農工大学）

SL

○原田　達也
東京大学，理化学研究所，国立情報学研究所

画像認識の技術は，近年，大規模な言語モデルと統合することでさらなる進化を遂げている．この画像認識モデルと言語モデルや異なる特性を持つセンサ情報処理などを統合したモデルは，マルチモーダルモデルとして知られている．このマルチモーダルモデルは，大規模言語モデルの次世代モデルと見なされ，医療応用を含む熾烈な研究開発が行われている．本講演では，画像認識とマルチモーダルモデルの最新動向を紹介し，医療応用の可能性について議論する．

第1会場（一橋講堂）

シンポジウム 2

14:30 ～ 16:30　**SY2「AI 時代のレギュラトリーサイエンス」**

座長：中岡　竜介（国立医薬品食品衛生研究所）

SY2-1　医療 ICT システムの課題と将来展望

○村山　雄一
東京慈恵会医科大学　脳神経外科

2014 年「国民が受ける医療の質の向上の ための医療機器の研究開発及び普及の促進に関する「基本計画」が策定され，医療機器開発の方向性が示された．近年は，IT AI 技術を活用したプログラム医療機器，いわゆる Software as a Medical Device(SaMD) への期待は大きい．例えば脳卒中治療では早期治療トリアージを進めることで寝たきり患者を減らし，患者の社会復帰を促進する様な医療 ICT システムに適切な保険点数を付与することで，最終的には医療費の削減，日本の生産性を高めることにつながる可能性がある．しかしながら保険償還の適正化と個人情報保護の問題が課題となっている．本講演では脳卒中領域を中心に SaMD の現状と将来展望について報告する．

SY2-2　国内におけるプログラム医療機器の審査について

○江面　崇智
独立行政法人医薬品医療機器総合機構 プログラム医療機器審査室

医薬品，医療機器等の品質，有効性及び安全性の確保等に関する法律（以下「薬機法」という．）における医療機器とは，「人若しくは動物の疾病の診断，治療若しくは予防に使用されること，又は人若しくは動物の身体の構造若しくは機能に影響を及ぼすことが目的とされている機械器具等であって，政令で定めるもの（第 2 条第 4 項）」に該当するものであり，その製品が医療機器の定義に該当する場合，薬機法の規制を受けることになる．また，その中でも実質的にソフトウェアの形態で流通されるものをプログラム医療機器といい，平成 26 年の薬事法改正以降，薬機法の規制対象として取り扱われている．

本講演では，国内におけるプログラム医療機器の規制の概要及び審査の現状を説明するとともに，今後更にプログラム医療機器の開発が活発になることが予想される中で，規制側から見て開発者に留意していただきたいポイントについて，実例を踏まえて概説する．また，新しいプログラム医療機器を早く現場に届けるために設けられている行政の様々な施策についても概説する．

SY2-3　プログラム医療機器に関する最近の規制動向

○水谷　玲子

厚生労働省 医薬局 医療機器審査管理課 プログラム医療機器審査管理室

医療機器は，「医薬品，医療機器等の品質，有効性及び安全性の確保等に関する法律」によりその製造・販売等が規制されている．平成 26 年からは，疾病の診断・治療等を目的とした単体プログラム（ソフトウェア）についても医療機器としての規制対象となり，多くのプログラム医療機器が開発，製造販売承認等されている．

厚生労働省では，プログラム医療機器の更なる実用化促進及び日本発プログラム医療機器の研究開発の加速と国際展開の推進を図るため，令和５年９月に経済産業省と連名で「プログラム医療機器実用化促進パッケージ戦略２（通称：「DASH for SaMD ２」）」を公表．萌芽的シーズの早期把握と審査の考え方の公表，プログラム医療機器の特性を踏まえた実用化促進，早期実用化のための体制強化等，様々な取組を行っている．

本講演では，プログラム医療機器に関する最近の規制動向について紹介する．

SY2-4　日本が医療 AI 先進国になるためにできること

○島原　佑基

医療 AI 推進機構

この 10 年間で AI は日常生活に不可欠な存在となり，医療分野も例外ではない．2019 年には我が国で初めて深層学習を用いた医療機器が承認されて以降，医療 AI の臨床利用が進んでいる．特に医療画像関連の AI は，黎明期を超え普及期に入っている．我が国は医用画像の多さと専門医の不足があり，AI 開発に適した環境だが，韓国や米国に比べて遅れがある．この遅れの一因はデータの利活用であり，韓国では国が主導してデータ整備を行い，ガイドラインを整備してスタートアップへ提供していることからも明らかである．当機構では，データ利活用促進を柱に様々な取り組みを行っており，本講演では我が国のマクロな課題とその解決策について，当機構のミクロな取り組みを含めて説明する．

SY2-5　大腸内視鏡 AI の開発から保険償還獲得の経験

○三澤　将史

昭和大学横浜市北部病院　消化器センター

大腸内視鏡支援プログラム医療機器 EndoBRAIN は，昭和大学・名古屋大学・サイバネットシステム株式会社との医工産連携研究の成果として本邦初の AI を活用した SaMD として薬機法承認を取得した．現時点では CADe，CADx の５製品が薬機法承認を取得済みで，オリンパス株式会社の販売チャネルで市販されている．EndoBRAIN のような CAD はその臨床有用性から早期に普及し，診療レベルの均てん化が期待されたが，普及率は期待ほど高くなかった．そこで，EndoBRAIN を使用することに対するインセンティブとして診療報酬加算を付与することができないか，2020 年より日本消化器内視鏡学会とも協力し活動を続けてきた．2024 年度の診療報酬改定において，EndoBRAIN-EYE という CADe 製品の使用に対する診療報酬加算が設定されるに至り，今後の普及と診療レベルの均てん化が期待される．本発表では診療報酬加算設定までの過程と経験した課題について共有したい．

第1会場（一橋講堂）

一般演題 6

16:40 ～ 17:30　**OP6「基盤モデル・連合学習」**

座長：本谷　秀堅（名古屋工業大学）
黒瀬　優介（東京大学　先端科学技術研究センター）

OP6-1　WSI を表現する基盤モデルの構築に向けた自己教師学習の検討

○田口　慶[1]，横田　達也[1]，大島　孝一[2]，三好　寛明[2]，永石　美晴[2]，橋本　典明[3]，竹内　一郎[3]，本谷　秀堅[1]

[1] 名古屋工業大学，[2] 久留米大学，[3] 名古屋大学

昨今，深層学習の分野では基盤モデルの研究が盛んにおこなわれている．基盤モデルとは，大量のデータを用いて事前学習を行ったモデルであり，ファインチューニングすることで多様な下流タスクに適応可能なモデルである．基盤モデルは，画像分野でも多く研究が行われており，自然画像では大きな功績を残している．しかし，我々が扱う病理顕微鏡画像は自然画像とは異なる特性を持ち，そのままの枠組みではうまく機能しない．そこで，細胞核と組織，ホールスライド全体，サブタイプなどそれぞれの構成要素を関連付ける自己監視タスクを生成することで病理顕微鏡画像の基盤モデルを構築することを目指す．今回はその先駆けとして，Masked AutoEncoder を用いて画像をマスクして再構成しながら，細胞核のサイズに対応するトークンに対して対照学習を適応する．これにより，ミクロな特徴を失うことなく，細胞核の形態を自己監視するタスクを生成可能か検討する．

OP6-2　基盤モデルを用いた皮膚疾患画像からの皮膚領域の認識

○佐藤　優斗[1]，志藤　光介[2]，藤澤　康弘[3]，山﨑　研志[2]，坂井　浩志[4]，藤本　　学[4]，清水　昭伸[1]

[1] 東京農工大学大学院工学研究院，[2] 東北大学大学院医学系研究科皮膚科学分野，[3] 愛媛大学大学院医学系研究科皮膚科学，[4] 大阪大学大学院医学系研究科皮膚科学

本報告では，基盤モデルを用いた皮膚疾患画像からの皮膚領域の認識について述べる．著者らはこれまで，光学カメラで撮影した，倍率，撮影角度，照明条件，背景の異なる多様な臨床画像を入力として，172 クラスの皮膚疾患を分類するシステムを構築した．しかし，一部の画像では，皮膚以外の場所に注目をして誤診断している例が見られた．そこで本研究では分類システムを皮膚領域に注目させるために，画像から皮膚領域を認識する処理を開発した．今回は，認識処理のための深層モデルとして基盤モデルの一つである Segment Anything Model を用いた．本研究では，各疾患クラスからサンプリングした 5 枚の画像に対して皮膚領域のアノテーションを作成し，計 860 枚の教師ありの少数データを用いて Segment Anything Model のファインチューニングを行った．また，未知のテスト画像を用いて性能を評価したところ，皮膚疾患画像における皮膚領域の認識性能の向上を確認したので，それらの結果も併せて報告する．

OP6-3　数値特徴量による不均衡な医用画像良悪性分類の改善

○吉次　研二[1]，岸本　和昌[2]，竹村　匡正[1]

[1] 兵庫県立大学大学院情報科学研究科，[2] 京都大学医学部付属病院

深層学習を用いた画像分類が近年，医療に応用されているが，医用画像の多くは良性と悪性のような所見の違いで不均衡なデータ構成になっていることが珍しくない．機械学習による不均衡なデータ構成を持つ画像の分類は，数の多いデータの影響で数の少ない所見の画像の検出が困難な場合が多い．多くの研究はこの問題を深層学習で解決しようとしているが，本研究ではレディオミクス特徴量という数値特徴量に基づく分類に置き換えて，少ないデータを多いデータと同じ数にアップサンプリングすることで，定量的に良悪性の分類を改善できるのではないかと考えた．画像から算出したレディオミクス特徴量を SMOTE，Borderline SMOTE，SVMSMOTE，ADASYN の 4 つ方法でアップサンプリングしてランダムフォレストアルゴリズムで分類した結果，深層学習による画像分類に比べて高い汎化性と堅牢性が示唆された．

OP6-4　連合学習を用いた胸部 CT 画像におけるびまん性肺疾患の陰影識別と異常検知

○岩瀬　実莉[1]，間普　真吾[1]，楊　　鯤昊[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

これまで，胸部 CT 画像におけるびまん性肺疾患の陰影識別を行うモデルが多数提案されてきた．深層学習を用いた識別モデルの構築では，学習に十分な量の教師データが用意できる場合，良い識別性能を示すことができる．しかし，医療分野においては個人情報等の問題から，データを広く公開することができず，十分な教師データを用意することを困難にしている．このような問題を解決するために，データを集約せずに分散した状態での機械学習が可能な連合学習（Federated Learning）という考え方が提唱されている．そこで，胸部 CT 画像におけるびまん性肺疾患の陰影識別，陰影異常検知を目的とした学習に連合学習を適用したところ，識別タスクではデータを集約して学習を行う場合と同程度の性能，異常検知タスクでは 1 つの施設で学習を行う場合よりも良い性能を示した．さらに，連合学習を行った後，各施設のデータで再学習を行ったとき，両方のタスクで連合学習のみを行った場合と比較して，性能が向上することを明らかにした．

OP6-5　パーソナライズド連合学習を用いた EOB-MR 画像の肝結節性病変分類における施設毎の性能改善の検討

○山田　藍樹[1,2]，花岡　昇平[2]，竹永　智美[2]，吉川　健啓[3]，野村　行弘[3,4]

[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] 東京大学医学部附属病院放射線科，[3] 東京大学医学部附属病院コンピュータ画像診断学／予防医学講座，[4] 千葉大学フロンティア医工学センター

コンピュータ支援診断（computer-aided diagnosis, CAD）の開発において，従来の開発施設に各施設のデータを集約した学習（データ集約型）の代替として，分散学習手法の連合学習（federated learning, FL）が注目されている．しかし，FL では各施設で最適な単一のモデルを得ることは困難である．この課題に対して施設毎に最適なモデルを学習する personalized FL（pFL）が提案されている．本研究では，pFL を用いた EOB-MR 画像の肝結節性病変分類における施設毎の性能改善について検討した．深層学習モデルには Attention 構造を付加した 3D ResNet-18 を使用し，pFL には Ditto を用いた．テスト症例による正解率の平均は，データ集約型で 59.7%，FL で 64.0%，Ditto で 67.4% となり，pFL の適用が施設毎の性能改善に寄与することが示された．

8 月 6 日（火）

第 1 会場（一橋講堂）

一般演題 7

17:30 ～ 18:20　**OP7「CAD1」**

座長：滝沢　穂高（筑波大学）
佐藤　嘉伸（奈良先端科学技術大学院大学）

OP7-1　骨シンチグラム診断支援システムの市販後再学習時のテストデータ再利用による性能バイアスとその補正

○山中　陽大[1]，東山　滋明[2]，河邉　譲治[2]，中岡　竜介[3]，清水　昭伸[1]

[1] 東京農工大学　大学院　工学研究院，[2] 大阪公立大学医学部附属病院核医学科，[3] 国立医薬品食品衛生研究所医療機器部

本報告では，骨シンチグラムの診断支援システムを市販後に再学習する際に，同一テストデータを繰り返し利用することによって生じる性能のバイアスをシミュレーションし，そのバイアスに補正法を適用した結果について報告する．まず，撮影施設を市販前と市販後にランダムに分割し，市販前の複数施設の骨シンチグラムを用いて陽性高集積検出モデルを学習する．次に，市販後の複数施設ごとにその学習済みモデルの再学習を行って，市販後施設数分のモデルを構築する．さらに，AUC が大きくなるように逐次的にモデルを選択してアンサンブルモデルを構築するが，その際に，同一テストデータを繰り返し利用しながら求めた AUC に基づいて実行する．最後に，再利用したテストデータとフレッシュなテストデータによる性能差（バイアス）を求め，統計的検定を行う．また，差分プライバシーに基づくバイアス補正アルゴリズムを適用した結果に対しても検定を実施し，有効性について考察する．

OP7-2　皮膚疾患画像分類における Underspecification の評価

○殿村　理久[1]，志藤　光介[2]，藤澤　康弘[3]，山﨑　研志[2]，坂井　浩志[4]，藤本　　学[4]，清水　昭伸[1]

[1]東京農工大学大学院工学研究院，[2]東北大学大学院医学系研究科皮膚科学分野，[3]愛媛大学大学院医学系研究科皮膚科学，[4]大阪大学大学院医学系研究科皮膚科学

最近の深層学習に基づくモデルは多数の未知パラメータを持ち，その自由度は非常に大きい．そのため，手元にある学習やテストデータでは性能が同じであるにもかかわらず，実世界のデータでは性能が異なることがある．この問題は underspecification（仕様不足）と呼ばれ，手元のデータでは高い汎化性能を持つモデルが特定できず，実世界にモデルを導入した際に性能が予想外に低下する原因となり得る．本報告では，光学カメラで撮影された 59 クラスの皮膚疾患画像の分類モデルに対して，Stress Test によって underspecification を評価する方法について述べる．特に，皮膚疾患画像に人工的な摂動を与える Stress Test に注目して，実世界データとの類似性を考慮しながら摂動の適切な範囲を決定する方法を提案する．また，提案方法を用いて underspecification を評価することで，未知の施設に対する性能を予測する可能性についても議論をする．

OP7-3　皮膚疾患分類のためのマルチモーダル学習

○飯嶋　杏奈[1]，坂井　浩志[2]，藤本　　学[2]，志藤　光介[3]，山﨑　研志[3]，藤澤　康弘[4]，清水　昭伸[1]

[1]東京農工大学大学院工学研究院，[2]大阪大学大学院医学系研究科皮膚科学，[3]東北大学大学院医学系研究科皮膚科学分野，[4]愛媛大学大学院医学系研究科皮膚科学

著者らはこれまで，光学カメラで撮影された皮膚の臨床画像を対象とした診断支援システムを開発してきた．実際の臨床における皮膚疾患の診断の際には，ダーモスコピー画像や被検者の年齢や性別などの臨床情報も併せて用いられる．しかし，従来のシステムでは臨床画像以外の情報を考慮していないために，分類精度に限界があった．本研究では，臨床画像とダーモスコピー画像に年齢などの臨床データを加えたマルチモーダルデータによる皮膚疾患の分類手法を提案する．また，実画像を用いて性能を評価することで，入力情報の種類や数，マルチモーダルデータの融合方法の違いによる分類精度の比較を行った．その結果，すべての情報を用いた場合の Accuracy が最も高いことなどが確認できた．

OP7-4　胸部 CT 画像におけるびまん性肺疾患の識別のための Voxel データの効果的な活用方法の提案

○森崎　幹也[1]，間普　真吾[1]，楊　　鯤昊[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

近年，GPU の性能の向上により，Voxel データを対象とした深層学習モデルの構築が可能となりつつある．しかし，一般に胸部 CT 画像データは 1 症例あたり (200-300) × 512 × 512 ほどの解像度で記録されており，この規模のデータの処理には膨大な GPU メモリや学習時間を要する．そこで本研究では，胸部 CT 画像において，Voxel データを効果的に扱うための手法を提案する．1 つ目は，環状軸方向，矢状軸方向，垂直軸方向の 3 つの軸を基準としてスライスをサンプリングしたデータを用いる手法である．2 つ目は，画像から輝度情報とテクスチャ情報を抽出し，これらを組合せたデータをモデルへの入力とする手法である．クラス不均衡なデータセットに対して有用な PR-AUC で少数派クラスの陰影識別性能を評価した結果，1 つ目の方法は，学習データと同じドメインのテストデータにおいて高い識別性能を示した．2 つ目の方法は，学習データと同じドメインおよび異なるドメインのテストデータに対しても高い識別性能を達成した．

OP7-5　呼吸器内視鏡迅速細胞診における AI 診断支援 – 第 2 報 埋め込み表現空間における距離を考慮した対照学習

○尾見　康夫[1]，桐田　圭輔[2,3]，酒井　徹也[2]，高橋　真理[4,5]，後藤　功一[2]

[1]ＮＥＣ　ヘルスケア・ライフサイエンス事業部門　医療機器ソフトウェア統括部，[2]国立がん研究センター東病院　呼吸器内科，[3]上尾中央総合病院　呼吸器内科，[4]国立がん研究センター東病院　TR 検体管理室，[5]国立がん研究センター東病院　内視鏡センター

Rapid on-site cytologic evaluation (ROSE) for samples taken during endobronchial ultrasound guided transbronchial needle aspiration (EBUS-TBNA) is effective to improve the diagnostic yield and to avoid repeated puncture procedures. However, ROSE is not widely used due to limited human resources, especially limited availability of staff who performs benign and malignant classification. Thus, we developed an artificial intelligence system to assist in ROSE diagnoses. We had used in-house dataset consists of about 750 cells cropped from 26 pathological slides for training and testing. In the last annual meeting, we had reported the effectiveness of the contrastive learning with categorizing of hard and easy negative samples based on supervised coarse and fine labels (Old proposal method). To enhance the classification performance, we came up with a new method (New proposal method) which selects semi-hard negative samples considering distance metric in embedding spaces in addition to the hard and easy negative samples categorization. We compared the following three methods, 1. General contrastive learning, 2. Old proposal method and 3. New proposal method to investigate the pretext task which suits for our AI-assisted diagnose system. Classification accuracy using the three methods were found to be 0.922/0.931/0.938, respectively. Since the new proposal method can define adaptively a threshold distance to select the semi-hard negative samples, we strongly think that it could be a big advantage to the existing methods giving the threshold distance as a constant hyper-parameter.

第２会場（中会議室 2-4）

一般演題 8

9:40 ～ 10:50　**OP8「MR 画像再構成」**

座長：菅　　幹生（千葉大学）
岡本　尚之（千葉大学フロンティア医工学センター）

OP8-1　拡散モデルを使用したマルチタスク MRI 再構成モデルの検討

○藤田　直人[1]，寺田　康彦[1]
[1] 筑波大学　理工情報生命学術院　数理物質科学研究群

MRI における深層学習を用いた画像復元は，ノイズ除去，MRI 画像再構成，超解像など幅広い領域で応用が進んできた．しかし，各タスクに特化した深層学習モデルを別々に用意するのは，非効率な上，ドメインシフトによる性能低下，すなわち，サンプリング条件などのタスク由来の条件により，テスト時の性能が低下する懸念がある．近年，MRI 画像再構成における拡散モデルの性能の高さが報告された．拡散モデルでは，学習時にタスク由来の情報を入れず，推論時に計測データとの整合を取りながらノイズ除去を繰り返し，目的画像の生成を行う．これまで報告された MRI 再構成拡散モデルは，ほとんどがシングルタスク向けであるが，マルチタスク問題にも応用可能であることが期待される．そこで本研究では，生成時のデータ整合の強度を変え，各タスクへ応用できるか検討した．本手法は，MRI 画像再構成，超解像，ノイズ除去の面で再構成された画像の数値評価の向上が確認できた．

OP8-2　Swin Transformer を利用した MR 深層学習再構成における学習スケジュールと画質の関連

○中鉢　史也[1]，佐藤　裕貴[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 情報電気電子システム工学プログラム

画像処理分野ではこれまで畳み込みニューラルネットワーク (Convolutional Neural Network ; CNN) が深層学習の標準的な方法として使用されてきた．一方，Attention と呼ばれる新しい情報処理機構を備えた Transformer が自然言語処理 (NLP) において成功を収め，画像処理分野でも応用されている． MRI の圧縮センシング再構成向けには Swin Transformer が提案されている．Swin Transformer は，学習の特徴が CNN と異なり，その性能と学習パラメータの関係が明確でない．そこで，本研究では，学習スケジュールをさまざまに変化させて，再構成性能との関連を調べた．その結果，CosineLR に Warmup を導入する方法により高い性能が得られることが示されたので報告する．

OP8-3　等間隔な信号間引き収集を可能とする MR 撮像法と再構成法

○足立虎太郎[1]，伊藤　聡志[1]
[1] 宇都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム

圧縮センシングの MRI 応用では，一般に信号空間をランダムに間引く方法が取られる．ランダム間引きに比べて等間隔間引きは画像のぼけが少ない利点があるが，折り返しアーティファクトに周期性が現れるため画像再構成は困難であった．深層学習の利用により，等間隔サンプリングによる画像再構成が可能となってきているが，信号エネルギーの大きい信号空間の原点付近を連続収集する方式が一般的である．本研究では，被写体が実関数のときであっても等間隔な規則的な信号間引きによっても画像再構成が可能な新たな撮像法を提案する．本法によれば，高分解能な画像をより少数の信号で再構成できる可能性がある．信号取得時に振幅変調を与え，深層学習を利用する方式により，4 倍速まで画像再構成に成功したので報告する．

OP8-4　低周波数帯域から順に推定を行う多段接続型 CNN を基本とした MR 画像再構成法の画質改善法の検討

○大内　翔平[1]，伊藤　聡志[2]

[1] 小山工業高等専門学校　電気電子創造工学科，[2] 宇都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム

MRI の撮像時間を短縮する目的で，少数の信号から画像を再構成する方法が提案されている．再構成法として，近年では深層学習を用いる方法が数多く提案されており，これらの多くは MR 信号の低周波数帯域を良好に復元できるものの，画像の鮮鋭さを担う高周波数帯域の推定に関しては改善の余地がある．上記の課題を解決するため，我々は，推定対象とする周波数帯域を数段階に分割して，複数の CNN を用いて低周波数帯域から順に推定を行う方法を提案し，昨年度の SAMIT で報告した．本研究では，提案手法における周波数帯域の分割数や，使用する CNN について検討を行い，さらなる画質改善を図った．再構成シミュレーションの結果，PSNR の向上が確認できたので結果を報告する．

OP8-5　位相拡散フーリエ変換法と多空間型 ADMM-CSNet よる CS-MRI 再構成の性能改善

○山登　一輝[1]，伊藤　聡志[1]

[1] 宇都宮大学工学部基盤工学科

圧縮センシング MRI(CS-MRI) は MRI の高速化手法の一つである．近年，深層学習を用いた CS-MRI が主流となり，再構成画像の品質が著しく向上している．先行研究では，等間隔に間引き収集された位相拡散フーリエ変換法 (PSFT) の信号を，ADMM-CSNet を用いて再構成を行った．しかし，特に位相を含む複素数画像において再構成画像に平滑化や残留アーチファクトが生じる問題があった．本研究では，PSFT 信号を用いた多空間学習を導入した ADMM-CSNet を提案する．提案手法は，ADMM-CSNet に k 空間畳み込み層の追加，および k 空間と画像空間の畳み込み層の増設を行う．複素数画像を用いた実験を行ったところ，提案手法による再構成画像の PSNR が，既存の ADMM-CSNet よりも 1dB 向上し，再構成画像は，平滑化や残留アーチファクトが低減され，詳細構造の再構成性能も改善した．

OP8-6　位相拡散フーリエ変換法を使用した CS-MRI と超解像の併用による深層学習再構成像の高画質化

○松浦　毅弥[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

MRI の撮像時間を短縮するために圧縮センシング MRI(CS-MRI) が提案されている．近年，深層学習を用いた CS-MRI が提案され，反復再構成に比べて再構成像の高画質化が報告されている．再構成像の品質改善法の一つに，位相拡散フーリエ変換法 (PSFT) の利用がある．PSFT は汎用 MRI で使用されるフーリエ変換法よりも，高品質な再構成像を得る特徴がある．先行研究では PSFT を利用した超解像として，低域の PSFT 信号を収集し，信号外挿により高域信号を外装することで，再構成像の高分解能化を行った．低域信号を間引き収集し，先行研究の超解像を適用する手法により，CS-MRI と信号外挿を同時に実現できる可能性がある．本研究では深層学習を用いた CS-MRI と超解像の併用による高画質化を提案する．提案法の有効性を検証するため，提案法と従来の CS-MRI を比較したところ，PSNR，SSIM の向上が確認された．

第２会場（中会議室 2-4）

一般演題 9

14:30 ～ 15:30　**OP9「微細構造解析」**

座長：橋本　典明（理化学研究所）
　　彌冨　　仁（法政大学理工学部応用情報工学科）

OP9-1　血流を阻害したラット皮弁の分光画像解析

○高宮　桃香[1]，恵藤　　陸[1]，秋田　新介[2]，三川　信之[2]，岡本　尚之[3]，羽石　秀昭[3]
[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]千葉大学フロンティア医工学センター

皮弁移植手術とは，皮膚欠損を皮弁と呼ばれる健常領域の皮膚で補う手術である．皮弁移植手術では血管閉塞による術後の壊死が重大な合併症のひとつとして挙げられる．これを避けるために造影剤蛍光像や組織酸素飽和度計測により血流状態を把握する検討がなされているが，標準的な方法は確立されていない．本研究は，静脈または動脈を結紮することで血液の循環を制御した状態を作製し，皮弁組織に生じる変化を観察することで，壊死の機序を解明することを目的とする．本発表では，ラットの腹部に血行を温存した皮弁のモデルを作製し，皮弁への栄養血管である動脈・静脈を結紮することで，結紮後の分光反射率の経時変化を観察した．実験により，結紮側の分光反射率が一部低下する様子が確認された．結紮に伴って血流の変化が生じたと考えられ，血流悪化の把握に有効である可能性が示唆された．

OP9-2　大視野顕微放射光 CT による肺 3 次元ミクロ画像の肺胞壁解析

○小野　龍輝[1]，河田　佳樹[2]，梅谷　啓二[3]，中野　恭幸[4]，小熊　　毅[5]，阪井　宏彰[6]，岡本　俊宏[7]，仁木　　登[8]
[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]（公財）高輝度光科学研究センター，[4]滋賀医科大学，[5]京都市立病院，[6]兵庫県立尼崎総合医療センター，[7]クリープランドクリニック心臓・血管研究所，[8]株式会社医用科学研究所

和文：

肺の 3 次元ミクロ構造の解明に向けて，肺胞壁の抽出を行うことは重要である．本研究の目的は SwinUNTER を用いて肺胞壁の抽出の高精度化に取り組み，肺の 3 次元ミクロ構造解析に貢献することである．実験では，(1) 肺標本のミクロ CT 画像から肺胞壁を抽出し対話的に修正することで教師データを作成した．(2) この教師データを SwinUNTER で学習させ，肺胞壁の抽出精度を評価した．(3) 元画像と抽出結果から線強調フィルタをかけることで毛細血管の候補領域を抽出した．(4) パーシステントホモロジーを元画像や線強調後の画像に適用することで肺胞壁や毛細血管の孔の特徴を定量的に評価した．評価の結果，SwinUNTER を用いることでアーチファクトの誤抽出がほとんどなくなり，CT 値が低い箇所も抽出できるようになった．また，パーシステントホモロジーを成人肺だけでなく小児肺や気腫肺にも適用することで定量的に比較することができた．

英文：

Extraction of the alveolar wall is important to elucidate the three-dimensional microstructure of the lung. The purpose of this study is to improve the accuracy of alveolar wall extraction using SwinUNTER and to contribute to the analysis of the three-dimensional lung microstructure. In our experiments, we (1) created teacher data by extracting alveolar walls from micro-CT images of lung specimens and interactively modifying them, and (2) used this data for the analysis of lung microstructure. (2) We trained SwinUNTER on this teacher data and evaluated the accuracy of alveolar wall extraction. (3) Candidate regions of capillaries were extracted from the original image and the extraction results by applying a line enhancement filter. (4) Percistent homology was applied to the original and line-enhanced images to quantitatively evaluate the characteristics of alveolar walls and capillary pores. The evaluation results showed that the use of SwinUNTER almost eliminated artifact mis-extraction and enabled the extraction of areas with low CT values. In addition, quantitative comparison was possible by applying persistent homology not only to adult lungs but also to pediatric lungs and emphysema lungs.

OP9-3　X 線暗視野法を用いた膵管内乳頭粘液性腫瘍における乳頭様構造の 3 次元解析 − 追加 2 症例による比較検討 −

○天野　遥菜[1]，砂口　尚輝[1]，岩越　朱里[2]，末永　雅也[2]，西村理恵子[2]，島雄　大介[3]，湯浅　哲也[4]，安藤　正海[5]，市原　　周[2]

[1] 東海国立大学機構名古屋大学医学部保健学科放射線技術科学専攻，[2] 国立病院機構名古屋医療センター　病理診断科外科，[3] 大阪物療大学 保健医療学部 診療放射線技術学科，[4] 山形大学大学院理工学研究科，[5] 高エネルギー加速器研究機構

X 線暗視野法 (XDFI: X-ray Dark field imaging) を用いる屈折コントラスト CT（XDFI-CT）は，染色した病理組織像に匹敵するコントラストと数 μm の空間分解能を有しており，生体軟組織の詳細な 3 次元像を提供する．JAMIT2023 で我々は，XDFI-CT によりヒトから切除された膵管内乳頭粘液性腫瘍 (IPMN) の 3 次元微細構造を可視化し，3 次元像の観察から，拡張した膵管内に増殖する乳頭様の腫瘍構造が独立した凸の構造ではなく，膵管の管軸方向にて波状・山脈状に繋がっていく一症例を報告した．この構造がこの症例に特異的なものなのかを検証する事を目的として，本研究では新たに IPMN の症例を 2 例追加し，同様の 3 次元構造が観察されるかどうか評価した．また，術前検査で得られた X 線 CT，MRI，MRCP の各画像と XDFI 像の見え方を対応付け，実臨床における画像所見の理解に寄与するような情報を収集した．

OP9-4　悪性リンパ腫における細胞核の種類識別器構築のためのラベル遷移を考慮した弱教師学習

○古賀　諒一[1]，小出　新悟[1]，横田　達也[1]，大島　孝一[2,3]，三好　寛明[2,3]，永石　美晴[2]，橋本　典明[4]，竹内　一郎[5]，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] 日本病理学会，[4] 理化学研究所，[5] 名古屋大学

本研究では，悪性リンパ腫における細胞核の種類識別器を構築するための弱教師あり学習の手法を提案する．細胞種のラベル付けは専門の病理医にとっても容易ではなく，ラベルデータに多くのノイズが含まれうる．病理医との打ち合わせを通じて，細胞種のラベル付けは特に 2 種類の間で迷う場合が多いことを見出した．そこで，ラベルデータの作成時には，最終的な判断結果だけではなく，2 種類の間で迷った後に棄却された種類名も記録することとした．本研究では，迷った末に棄却されたラベルも含めた弱い教師信号に基づいて，クラス間での判断の迷いをラベル遷移行列として表現することを提案する．そして，得られたラベル遷移行列を用いて，細胞の種類識別器の弱教師学習を行う．クラス間の迷いを考慮しない方法との比較実験により，提案法が識別性能の改善をもたらしたことが確認されたので，その結果を報告する．

OP9-5　深層学習を用いたイメージング FCM 画像における尿中マルベリー小体のスクリーニング

○今久保桃子[1]，眞砂　明典[1]，浅井　千春[2]，坪井　一哉[3]

[1] シスメックス株式会社，[2] 社会医療法人宏潤会大同病院，[3] 名古屋セントラル病院

マルベリー小体は，ファブリー病患者の尿中に特異的に出現する渦巻き状の脂肪成分である．尿沈査検査では，標本中に多種多様な有形成分が含まれるため，少量の MB を目視で検出することは困難かつ多大な労力を要する．そこで我々は，大量の細胞を高速で撮像可能な分子イメージングフローサイトメトリー（MI-FCM）を用いて，MB を自動検出するシステムを開発している．

本研究では，尿中有形成分から MB 以外の成分を除外し，MB 候補成分をスクリーニングすることを目的とする．MI-FCM により撮像した有形成分画像を用い，成分サイズなどの画像特徴を用いたゲーティング法と CNN ベースの明視野像分類モデルを構築した．本手法をファブリー病患者 16 例のデータに適用した結果，全有形成分に対する MB 数の割合が約 0.01% から少なくとも 10%以上に改善し，MB 検出における検査者の負担を大幅に軽減できることが示唆された．本発表では主に，CNN ベースの画像分類モデルの開発について報告する．

OP9-6　3D U-Net を用いた肺マイクロ CT 画像中の肺胞壁領域抽出

○矢田　遥大[1]，中村　彰太[2]，林　雄一郎[1]，小田　昌宏[3,1]，森　　健策[1,3,4]

[1] 名古屋大学大学院情報学研究科，[2] 名古屋大学大学院医学系研究科，[3] 名古屋大学情報基盤センター，[4] 国立情報学研究所医療ビッグデータ研究センター

本研究では，人工画像を用いることで肺マイクロ CT 画像から 3D U-Net によって肺胞壁領域を抽出するモデルの構築を行なった． 医用画像処理の分野において，深層学習を用いた領域抽出手法は次々と提案されており，病態理解や，人体機能のさらなる知見獲得，診断支援等に有効な手段であると期待されている． 一方で，肺マイクロ CT 画像と深層学習を組み合わせた研究はまだ少ない．その要因として学習用のデータ量確保の困難さ，教師データの作成の困難さ等が考えられる． 本研究ではデータ拡張を行うことによってデータ量の確保を行う．また，2 値化をベースとした手法で肺胞壁領域の 3 次元の正解データを自動的に生成する． 本手法を用いることによって肺マイクロ CT 画像に対して 3 次元の深層学習を可能にし，肺胞壁領域を自動的に抽出することを実現した．Dice 係数による評価は 0.911 となった．

第1会場（一橋講堂）

一般演題 10

9:30 ～ 10:30　**OP10「CAD2」**

座長：庄野　逸（電気通信大学）
橘　理恵（室蘭工業大学 大学院工学研究科）

OP10-1　FDG-PET/CT 像上の副腎転移病変検出に関する検討 - 上腹部臓器領域抽出とのマルチタスク学習の実験的検証 -

○吉田　昂平[1]，根本　充貴[1,2]，甲斐田勇人[3]，木村　裕一[4]，永岡　隆[1,2]，三上　勝大[2]，山田　誉大[3]，花岡　宏平[3]，槌谷　達也[5]，北島　一宏[5]，石井　一成[3]

[1] 近畿大学 生物理工学研究科，[2] 近畿大学生物理工学部，[3] 近畿大学病院，[4] 近畿大学情報学部，[5] 兵庫医科大学病院

悪性腫瘍の転移先になりやすくサイズの小さい副腎に注目し，FDG-PET/CT 像 Axial スライス上の副腎転移病変の有無の判定と肝・腎領域抽出のマルチタスク学習について実験的に検証する．用いるモデルは上腹部 Axial スライス像を入力とし，肝・腎領域を同時抽出する U-Net ベース領域抽出ブロックと，U-Net 中間出力特徴量マップをエンコードすることでスライス像上の副腎転移病変の有無を判定する識別ブロックからなる．学習手順は，まず領域抽出ブロックのみ肝・腎領域抽出タスクで事前学習し，そこに識別ブロックを加えてマルチタスク学習によるファインチューニングを行う．識別に有効な特徴量マップの選択利用や特徴量マップのエンコード方法などを多角的に検証し，副腎転移症例 7 例を含む計 14 例の FDG-PET/CT 像を用いた実験では病変有無の識別のみ学習時より約 27%の副腎転移スライス的中率の改善を確認した．

OP10-2　深層学習による CT 画像での乳癌腫瘤影検出における過去画像の有用性に関する検討

○守田　裕一[1]，花岡　昇平[1]，野村　行弘[2,3]，中尾　貴祐[2]，吉川　健啓[2]，阿部　修[1]

[1] 東京大学医学部附属病院放射線科，[2] 東京大学医学部附属病院コンピュータ画像診断学／予防医学講座，[3] 千葉大学フロンティア医工学センター

CT 検査では偶発的に乳癌は 1~3%ほど発見され，年々増加する CT 検査において偶発的乳癌検出の重要性は高まっている．マンモグラフィーでは過去画像との比較が放射線科医の乳癌検出感度を上昇させる研究があることから，本研究では深層学習に過去画像のある乳癌患者の体幹部 CT 画像を入力し，乳癌を検出するモデルの構築と評価を行った．

被検者は 31 名の病理学的に乳癌と診断された女性（平均年齢 69.8 ± 10.7 歳）で，2005 年 3 月～ 2021 年 11 月までに東京大学医学部附属病院で撮影された体幹部 CT 画像を用いた．3D U-Net に過去画像と現在画像をデータオーグメンテーションの上，2ch で入力し，訓練 12 例，検証 12 例，評価 7 例として学習を行った．free response receiver operating 解析にて評価した．結果は 0.4 false positives/case で感度 14.3% となった．

OP10-3　Masked Autoencoder の自己教師あり学習に基づく頭部 CT 画像からのくも膜下出血の検知

○大野未来矢[1]，黒瀬　優介[2,3]，渡谷　岳行[4]，原田　達也[2,3,5]

[1] 東京大学　情報理工学系研究科　知能機械情報学専攻　原田・長・黒瀬・椋田研究室，[2] 東京大学先端科学技術研究センター，[3] 理化学研究所　革新知能統合研究センター，[4] 東京大学医学部附属病院放射線科，[5] 国立情報学研究所　医療ビッグデータ研究センター

くも膜下出血は発症後に緊急の治療を要する疾患であり，診断支援システムの開発は重要である．くも膜下出血の微小で多様な出血を網羅する CT 画像データセットの構築はアノテーションコストの観点から困難であるため，本研究では Masked Autoencoder(MAE) をモデルとして用いて，正常な頭部 CT 画像のみをモデルの学習に使用した異常検知の手法を提案する．MAE では分割されたパッチをランダムにマスクして，マスクされたパッチの再構成を行う自己教師あり学習により，画像全体の大局的な特徴の抽出を学習する．くも膜下出血罹患者の CT 画像は正常な頭部 CT 画像よりも再構成誤差が大きくなるという仮定のもと異常度を算出する．より鮮明な再構成を行うために，入力画像かパッチごとに再構成されたものかを識別する敵対的損失を計算し学習時の損失として加える．実験により，提案手法において ROC AUC 値の向上を確認した．

OP10-4　胸部 X 線画像における緊急性疾患向け異常検出

○福島　祥之[1]，吉田　皓文[2]，笠井　　聡[2]，近藤　敏志[1]

[1] 室蘭工業大学，[2] 新潟医療福祉大学

胸部X線画像は健康診断において広く使用され , 症例数も多いことから , 放射線科医や放射線技師にとって読影にかかる負担は大きい . そのため , 詳細な検査が必要な症例とそうではない症例を機械学習によって用いて区別することによって膨大な読影の負担を軽減し , 医師や技師がより緊急性の高い画像の読影に注力できるような機能が求められている . 本研究では , 健康診断において早く治療しなければ重篤な疾患になる緊急性疾患に関して , 異常検出手法を用いて早期に発見することを目的とする .

本研究では ,DDAD,PaDiM の 2 種類の異常検出手法を用いる .DDAD はオートエンコーダをベースとした胸部 X 線画像向け異常検出モデルであり ,PaDiM は正常な画像のみで再学習を行うことなく異常検出が可能な機械学習モデルである . これらの手法を用いて , 胸部X線画像データセットの緊急性疾患異常検出に適した機械学習モデルを提案する .

OP10-5　Masked Autoencoder と注意機構を用いた 12 誘導心電図の異常検知

○今村　健太[1]，原田　達也[2,3,4]，黒瀬　優介[2,3]

[1] 東京大学　工学部，[2] 東京大学　先端科学技術研究センター，[3] 理化学研究所　革新知能統合研究センター，[4] 国立情報学研究所　医療ビッグデータ研究センター

迅速な対応が必要である心疾患に有効である心電図に対して，近年深層学習による診断支援システムの研究が行われている．本研究の目的は 12 誘導心電図に対し，正常な心電図のみを用いて教師なし学習による高精度な異常検知を行うことである．教師なし学習による異常検知手法においては，正常な心電図の特徴を捕捉することが重要であるが，従来の研究では正常な心電図の特徴として時間変化のみを考慮していた．そこで本研究では，学習時にマスクされた誘導心電図を再構築することにより，12 誘導間の関係性を捕捉するモデルを提案した．また，モデルの学習に既知の誘導関係性を制約条件として課すことでより再構築精度の高いモデルの実現を目指した．推論時には罹患者の 12 誘導心電図は正常な 12 誘導心電図よりも再構成誤差が大きくなると仮定し異常度を算出する．また，モデルが誘導ごとでの不確実性を出力することで誘導ごとに正確な異常度を算出可能な方式を実現した．約 20,000 人の 12 誘導心電図が記録されたデータセットを使用して，実験を行い，従来手法と比較し ROCAUC が 0.04 向上することを確認した.

OP10-6　Gray Wolf アルゴリズムベースのハイパーパラメータ調整を使用した白血病サブタイプ検出のための YOLOv8 の最適化

○タンジラルムスタキム[1]，タンジラルムスタキム[1]，中淳　　李[3]，小尾　高史[2]，チャスティンファティチャ[1]，ナニックスチアティ[1]

[1] インドネシア、スラバヤのセプル・ノーペンバー工科大学情報学部，[2] 東京工業大学 未来科学技術研究チーム，[3] 東京工業大学科学技術創成研究院

The accurate identification of Acute Lymphoblastic Leukemia (ALL) subtypes is critical for developing effective treatment plans. Traditional manual diagnosis procedures are time-consuming, subjective, and prone to error, necessitating the development of automated and reliable diagnostic methods. This study aims to improve the diagnostic accuracy and efficiency of ALL subtype detection by optimizing the hyperparameters of the You Only Look Once version 8 (YOLOv8) algorithm with the Grey Wolf Optimizer (GWO), a nature-inspired optimization method. The YOLOv8 algorithm has advantages from speed and accuracy in object detection tasks especially medical image domain. However, its efficiency is strongly reliant on the correct selection of hyperparameters, which is a challenging task due to the algorithm's complexity and the enormous dimensionality of the search space. The proposed method leverages the GWO algorithm for hyperparameter tuning, which is inspired by grey wolves' social hierarchy and hunting. This approach aims to systematically explore the hyperparameter space in order to identify the optimal configuration that maximizes the algorithm's effectiveness in detecting ALL subtypes. Our methodology involves a quantitative analysis using a dataset of annotated medical images of distinct ALL subtypes, with the aim of achieving superior model performance metrics compared to baseline YOLOv8 models.

第1会場（一橋講堂）

シンポジウム3

10:40 ～ 12:10　**SY3「JAMITの未来を作ろう！ 2024」**

座長：岡本　尚之（千葉大学フロンティア医工学センター）
伊東　隼人（福岡大学理学部応用数学科）

パネリスト

皆川　智哉（東邦大学医療センター大橋病院 放射線部）
大村　眞朗（富山大学学術研究部工学系）
関川　祐矢（帝京大学大学院保健学研究科）
武山　彩織（東京工業大学工学院情報通信系）
渕辺章太郎（GEヘルスケア・ジャパン株式会社）

第1会場（一橋講堂）

一般演題 11

13:30 ～ 14:30　**OP11「CAD3」**

座長：河田　佳樹（徳島大学ポスト LED フォトニクス研究所）
砂口　尚輝（東海国立大学機構名古屋大学大学院
医学系研究科総合保健学専攻）

OP11-1　神経血管束温存に関するロボット支援根治的前立腺摘除術画像のコンピュータ支援分類

○デルアギラモラガディエゴアンドレス[1]，王　慧涛[1]，安東　聡[2]，保科　勇斗[2]，川平　洋[3]，野村行弘[4]，中口　俊哉[4]

[1]千葉大学大学院融合理工学府，[2]自治医科大学腎泌尿器外科学講座，[3]自治医科大学メディカルシミュレーションセンター，[4]千葉大学フロンティア医工学センター

RARP is a laparoscopic surgery for prostate cancer. The surgeon removes the gland while minimizing damage to closed structures. The goal is to remove the tumor and preserve healthy tissue. The prostate is found just beneath the bladder and surrounds the upper portion of the urethra. Adjacent to this gland is a cluster of nerves and blood vessels known as "neurovascular bundles" (NVB).

After RARP, patients may experience urinary incontinence or erectile dysfunction. Research shows that damage to the NVB during surgery commonly causes these symptoms, which can significantly impact a patient's quality of life.

Therefore, the following research has been proposed: detecting whether the NVB was preserved after RARP surgery using deep learning.

The use of deep learning classifier models has been proposed. These models were trained using techniques such as fine-tuning, oversampling, and Youden Index to find the optimal threshold. The ideal parameters were found through experimentation.

Specifically, we used four different models: ResNet-50, ResNet-18, MobileNet-V2, and EfficientNetV2. To classify the preservation of the NVB

After the training, a fusion ensemble was created, combining the outputs of multiple classifier models to improve classification accuracy. The ensemble's output averaged the NVB conservation probabilities of the best-trained models. The same RARP image was used for each model as input.

During the experiments, the classifier models and the ensemble were evaluated using 5-Folds cross-validation.

Jichi Medical University Hospital provided 418 RARP images. 174 were labeled "NVB," and 244 were labeled "NOT_NVB."

ResNet-50 outperformed the models used in this study, with an average accuracy of 0.86, precision of 0.90, recall of 0.84, F1-score of 0.86, and AUROC of 0.91 across 5-fold.

The ensemble's best results after experimentations were 0.82, 0.92, 0.76, 0.81, and 0.92, respectively.

The proposed models can classify RARP images to detect the preservation of NVB.

OP11-2　気管支超音波画像に基くマルチブランチと投票メカニズムを用いた肺末梢病変分類

○王　慧涛[1]，鹿野　幸平[2]，中島　崇裕[3]，李　ジャオ[4]，野村　行弘[5]，中口　俊哉[5]

[1]千葉大学 融合理工学府基幹工学，[2]千葉大学大学院医学研究院 呼吸器内科学，[3]獨協医科大学　呼吸器外科学，[4]同済大学附属東方医院，[5]千葉大学フロンティア医工学センター

Background: Lung cancer stands as a significant contributor to cancer-related fatalities worldwide. Endobronchial ultrasonography (EBUS) plays a crucial role in the early diagnosis of lung cancer. A challenge is that even highly experienced physicians cannot directly determine the benign or malignant peripheral pulmonary lesions (PPLs) through EBUS images. This study develops a computer-aided diagnosis (CAD) system capable of accurately predicting the benign or malignant nature of PPLs directly from EBUS images. This advancement aims to afford patients more treatment time and significantly reduce physicians' diagnostic time.

Methods: We propose an innovative multi-branch framework with multiple convolutional neural network (CNN) models. Each CNN model is trained independently. The ensemble of predictions from multiple branches' CNN models is integrated using a majority voting method to form the final prediction result of the model. Also, the Bayesian optimization algorithm is employed to integrate the distinct CNN models. Furthermore, we explored a coordinate system transformation approach, wherein the original EBUS images are converted from polar coordinates to Cartesian coordinates. This innovative image-processing method aims to optimize the representation of images, enhancing the effectiveness of subsequent analyses. The CAD system was evaluated on a set of 2760 EBUS images consisting of 95 lung cancer cases consisting of 82 malignant cases and 13 benign cases.

Results: The proposed multi-branch CAD diagnostic system utilizing transformed EBUS images achieved a level of 0.80 in terms of area under the curve, with an accuracy of 0.78, F1-score of 0.80, positive predictive value of 0.77, negative predictive value of 0.83, sensitivity of 0.85, and specificity of 0.72.

Conclusions: According to experimental findings, our proposed framework achieves excellent results. Our framework can accurately predict benign or malignant PPLs directly from EBUS images.

OP11-3　SE-Block を導入した 3D ResNet による大動脈弁狭窄症の重症度自動分類

○佐橋　拓哉[1]，中山　良平[1]，檜作　彰良[1]，岡本　寛樹[2]

[1]立命館大学大学院 理工学研究科，[2]滋賀医科大学循環器内科

大動脈弁狭窄症（AS：Aortic Stenosis）は，左心室からの大動脈における石灰化面積や最大血流速度など複数の要素から重症度が決定される．そこで本研究では，AS 重症度診断の簡便化のため，心臓 CT 画像を用いた AS の重症／中等症の自動分類手法を提案する．実験試料は，心臓 CT 画像 142 症例（重症：99 症例，中等症：43 症例）である．本研究では，AS の重症／中等症の分類に有用な特徴マップチャネルに重み付けする SE-Block を既存分類モデル 3D ResNet に導入した SE-3DResNet を構築する．そして，4-fold cross validation test により，SE-3DResNet の学習と評価を行った．提案手法による AUROC は 0.76 で，従来手法である 3D ResNet（0.73）より高い結果が得られ，その有用性が示唆された．

OP11-4　深層学習を用いた骨盤 CT 画像による各脚の下肢リンパ浮腫スクリーニング手法の検討

○辻　美里[1]，秋田　新介[2]，長西　裕樹[3,4]，松岡　歩[5]，甲賀かをり[6]，三川　信之[2]，野村　行弘[7]

[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形成･美容外科，[3]NACS クリニックリンパ浮腫センター北横浜，[4]済生会横浜市南部病院形成外科，[5]千葉大学医学部附属病院婦人科，[6]千葉大学大学院医学研究院産婦人科学，[7]千葉大学フロンティア医工学センター

下肢リンパ浮腫は婦人科系がん治療後によくみられる合併症であり，患者の生活の質を著しく低下させる．早期の診断・治療が重篤な合併症予防につながるため，スクリーニング手法の確立が重要となる．我々の研究グループはこれまでに，深層学習を用いた骨盤 CT 画像による下肢リンパ浮腫スクリーニング診断手法を提案した．しかし，この手法ではリンパ浮腫が左右どちらの脚に有するのかまでは診断できない．本研究では，深層学習を用いた骨盤CT画像による各脚の下肢リンパ浮腫スクリーニング手法を提案する．大転子スライスより各脚の部分画像を切り出した上で，脂肪領域強調処理を施した画像を深層学習に入力した．複数の深層学習モデルで比較した結果，ResNet-34 で AUC が 0.918，正解率が 87.1% となり，提案手法による各脚の下肢リンパ浮腫のスクリーニング診断の実現可能性が示唆された．

OP11-5　脳 MR 画像における Multi-input CNN を用いた特発性正常圧水頭症の鑑別診断支援

○澤　風吹[1]，藤田　大輔[1]，嶋田　兼一[2]，石井　一成[2,3]，小橋　昌司[1]

[1]兵庫県立大学，[2]兵庫県立はりま姫路総合医療センター，[3]近畿大学

特発性正常圧水頭症 (idiopathic normal pressure hydrocephalus: iNPH) は脳脊髄液が過剰に蓄積し，歩行障害，認知障害，尿失禁の 3 徴症を引き起こす．シャント術により症状の改善が見込める．一方，進行性核上性麻痺 (progressive supranuclear palsy: PSP) も類似の症状を有するが，現在根治治療法はなく，iNPH と PSP の正確な鑑別診断が重要である．通常臨床では脳 MR 画像におけるいくつかの脳画像所見を基に視覚評価により鑑別するが，画像に詳しい医師でないと正確な診断が困難である．そこで本研究では，脳 MR 画像から深層学習による iNPH と PSP の分類モデルを作成し，自動で鑑別診断支援を行う手法を提案する．本提案法では，脳 MR 画像の灰白質，白質の分離，形状の標準化を行なったものを直接の入力として CNN による分類を行う．入力として灰白質，白質の Multi-input，およびそれぞれ単体入力の場合の比較を行う．また，GradCAM による注目領域の可視化も行う．実験結果より，Multi-input による提案手法において Accuracy は 0.945，AUC は 0.968 であった．

OP11-6　ESRGAN による超解像処理を利用した乳がん石灰化良悪性鑑別 CAD 精度向上の検討

○大坂　亮二[1]，安倍　和弥[1]，高取　祐介[1]

[1] 神奈川工科大学 工学部 電気電子情報工学科

乳がん石灰化良悪性鑑別を行うコンピュータ支援診断 (CAD) は石灰化部分が微小であることから鑑別性能が低くなる . そこで本研究では撮影画像に ESRGAN を利用した超解像処理を適応し , 乳がん石灰化良悪性鑑別 CAD の精度向上の検討を行った .

ESRGAN による超解像処理の学習は教師あり学習で行う . 利用する画像は石灰化が認められる部分を切り取った 256 × 256 サイズの画像を 128 × 128 サイズに一度縮小し元に戻す過程の学習を行わせた .CAD は単純な鑑別を行うものとし , 利用する画像は元画像である 256 × 256 サイズと生成画像である 448 × 448 サイズの 2 パターンで行った .

CAD の学習は各画像群で 5 回ずつ行い，元画像における鑑別精度が 73.3% であったのに対し，生成画像における精度は 75.3% となり精度の向上が見られた．また t 検定における p 値は 0.0352 となった .

この結果より，乳がん石灰化において超解像処理を行うことによる鑑別精度の向上が確認できたため更に Yolo を用いた CAD の精度向上への寄与を確認していく .

8 月 7 日（水）

第 1 会場（一橋講堂）

一般演題 12

14:40 ～ 15:30　**OP12「セグメンテーション 2」**

座長：滝沢　穂高（筑波大学）
杉本　直三（京都大学大学院医学研究科人間健康科学系専攻）

OP12-1　3 D U-Net による非造影 CT 画像の大動脈・冠動脈石灰化の検出

○庄野未彩季[1]，赤塚　真人[1]，河田　佳樹[2]，杉浦　寿彦[3]，田邊　信宏[3]，丸茂　一義[4]，金子　昌弘[4]，仁木　登[5]

[1] 徳島大学大学院創成科学研究科理工学専攻，[2] 徳島大学ポストフォトニクス研究所，[3] 千葉大学，[4] 東京都予防医学協会，[5](株) 医用科学研究所

画像診断において , 専門医は大量の画像を読影することを要求されており，診断する上で大きな負担となっている . そこで , 近年これらの読影を支援するコンピュータによる臓器の自動抽出や異常部位の自動検出などについての研究開発が行われている . 大動脈・冠動脈の石灰化によって引き起こされる心疾患の死亡率は悪性新生物に続き第 2 位を占めている . 心疾患は日本において主な死因の 1 つとされる疾患であり , 早期発見・早期治療を受けることが必要とされている . 本報告では , 正常 100 例と慢性血栓塞栓性肺高血圧症の 22 例の非造影 CT 画像を用いて 3D U-Net による大動脈・冠動脈石灰化を抽出する . その結果を用いて , 心房・心室 , 大動脈・肺動脈の情報をもとに大動脈・冠動脈石灰化の自動抽出・分類結果を示す .

OP12-2　CT 画像と存在確率マップを用いた CNN に基づく全自動僧帽弁形状抽出

○益田　幸輝[1]，石川　　亮[1]，田中　　亨[1]，青山　岳人[2]，川島圭太郎[2]，ChapmanJames V.[3]，阿佐美匡彦[4]，PhamMichael Huy Cuong[5]，KofoedKlaus Fuglsang[5]，坂口　卓弥[2]，佐藤　清秀[1]

[1] キヤノン株式会社，[2] キヤノンメディカルシステムズ株式会社，[3]Canon Medical Informatics,Inc.，[4] 三井記念病院　循環器内科，[5]Department of Cardiology and Radiology, Copenhagen University Hospital - Rigshospitalet

コンピュータ断層撮影（CT）や経食道心エコー図（TEE）などによって得られた臨床画像から，僧帽弁形状を正確に抽出することは僧帽弁治療計画において有用である．しかしながら僧帽弁形状の手動抽出は手間がかかり，既存の自動抽出法は精度面での課題や，精度向上のために別途ランドマークの入力を必要とするなどの課題がある．本発表では，心周期の全位相に対する CT 画像から僧帽弁形状を完全自動かつ高精度で抽出する手法を提案する．本手法は元の CT 画像と，U-Net により推論した僧帽弁領域の存在確率マップの両方を入力として，DenceNet によって僧帽弁形状メッシュを抽出する．提案手法における僧帽弁形状抽出の平均誤差は 0.88mm であり，存在確率マップを用いない方法と比較して 0.32mm 改善された.

以上の結果により，本手法では存在確率マップを入力に加えることで，僧帽弁の抽出精度が向上することを示す.

OP12-3　ラジオ波焼灼療法のための腹部 CT 画像における肝臓腫瘍の自動識別

○オウヤンガンシン[1]，杉下　友麻[1]，原　　武史[1]，周　　向栄[1]，尾﨑　公美[2]

[1] 岐阜大学大学院自然科学技術研究科，[2] 浜松医科大学放射線診断学講座

Radiofrequency Ablation (RFA) is one of the important treatment approach for focal liver tumors. To determine the effectiveness of this treatment, it is necessary to verify whether the tumor area has been appropriately ablated. For this purpose, comparing the ablated areas before and after RFA treatment is crucial. The aim of this study was to evaluate the accuracy of an automatic extraction method for tumor and ablated areas before and after RFA treatment. The experiment utilized 92 tumors of before and after RFA treatment. The automatic extraction method was compared between U-Net++ and U-Net. The extraction results were evaluated using the Intersection over Union (IoU). The mean/SD IoU results of the automatic extraction were 31.6/32.8 for tumors before RFA treatment and 56.3/34.2 for areas after treatment.

OP12-4　Ensemble Multiscale Attention UNet による胸部 CT 画像からの肺腫瘍領域の自動抽出

○高橋　礼生[1]，神谷　　亨[1]，寺澤　　岳[2]，青木　隆敏[2]

[1] 九州工業大学，[2] 産業医科大学

現在，日本での肺がんによる死亡者数は男女計で 1 位を記録しており，肺がんの早期発見・早期治療が最重要課題となっている．肺がんの検査は治療方針を選択するための手段であり，特に，遺伝子検査はがん細胞の増殖・湿潤・転移に関わるドライバー遺伝子変異の有無を確認することができる．ドライバー遺伝子変異の有無を確認する過程では，医師と協力して手作業で肺がん領域を抽出する必要があり，読影医師への負担が懸念される．そこで本論文では，医師の負担軽減のため，アテンション構造，複数スケールの特徴抽出と広範囲受容野の獲得に加え，異なる層数を持つ 2 つのモデルのアンサンブル学習による，肺腫瘍領域の検出を行うため，EMA-UNet を用いた画像解析手法を提案する．実験の結果，EMA-UNet は U-Net と比較して良好な抽出精度が得られた．

OP12-5　Semi-supervised Tubular Structure Segmentation with Hausdorff Distance Consistency

○朱　　芮昀[1]，小田　昌宏[2,1]，林　雄一郎[1]，北坂　孝幸[4]，森　　健策[1,2,3]

[1] 名古屋大学情報学研究科，[2] 名古屋大学　学術情報開発研究部門，[3] 名古屋大学　情報基盤センター，[4] 愛知工業大学情報科学科

This study introduces an innovative semi-supervised methodology for the 3D segmentation of tubular structures, a notable challenge in medical imaging due to the complexity of these structures. Traditional supervised deep learning requires extensive annotated datasets, which are expensive and challenging. To mitigate this, we propose a semi-supervised model utilizing task-level consistency learning with Hausdorff distance consistency. This approach leverages the geometric properties of both labeled and unlabeled data to enhance segmentation accuracy. Our model generates a segmentation and a distance transform map, with Hausdorff distance consistency ensuring geometric shape alignment, thus improving tubular structure segmentation performance. Tested on 3D CT scan airway segmentation, our method exceeded recent advanced methods, achieving an 84.0% tree length detection rate, 74.4% branch detection rate, and 89.7% precision rate, demonstrating its effectiveness in medical imaging segmentation.

第1会場（一橋講堂）

一般演題 13

15:40 ～ 16:30　**OP13「セグメンテーション 3」**

座長：小田　紘久（静岡県立大学経営情報学部経営情報学科）
神谷　　亨（九州工業大学）

OP13-1　3次元医用画像の自己教師ありセグメンテーションに関する初期検討

○鈴木　敦志[1]，小林　和馬[1,2]，浜本　隆二[1,2]
[1]理化学研究所革新知能統合研究センター，[2]国立がん研究センター研究所

患者のプライバシーやアノテーション･コストの観点から，大規模な医用画像データセットを構築することは時に困難である．そのため，下流タスクに転移可能な特徴をデータそれ自体から学習するための事前学習が注目されている．我々は，3次元医用画像の解剖学的構造に応じたセグメンテーションを獲得するための自己教師あり手法を提案する．具体的には，ランダムな幾何学的・光学的変換に対して，埋め込み表現が不変となるような制約を加えてボクセル単位でのクラスタリングを行う．予め設定したクラスタ数へと画像が分割されることによって，セグメンテーションが得られる．本手法は，U-Net などの様々なセグメンテーション・ネットワークに対して，モデル非依存に適用可能である．原発性脳腫瘍を含む頭部 MRI からなるデータセットにおいて実装し，下流タスクとしての腫瘍セグメンテーションの性能向上に寄与するかについての初期検討を報告する．

OP13-2　MRI 単体での肩関節画像診断に向けた深層学習を用いた軟部組織除去手法の初期検討

○杉本　裕汰[1]，野崎　太希[2]，寺田　康彦[1]
[1]筑波大学　理工情報生命学術院　数理物質科学研究群，[2]慶應義塾大学医学部　放射線科学教室（診断）

肩関節部などの骨軟部領域の画像診断では，一般的に軟部組織，骨性構造の評価のために MRI と CT の2つの画像機器を用いる必要がある．しかし，2つの検査を受けることはコストがかかるため，MRI のみでの評価の完結（All in one MRI）が望まれている．そこで近年，MRI での骨性構造の描出が可能な Zero echo time（ZTE）シーケンスが注目されている．しかし，ZTE シーケンスで得られた画像には，骨性構造だけでなく軟部組織も描出されてしまう．それら軟部組織は，診断時のボリュームレンダリング像を得るときに除去が必要となる．そこで本研究では，ZTE シーケンスで撮像された肩関節 MRI 画像から深層学習を用いて軟部組織を除去する手法を提案する．その結果，CT との一致度に対しての数値評価において，出力画像は処理前の ZTE と比べ改善がみられた．また，作成したボリュームレンダリング像からも軟部組織の除去が視覚的に確認された．

OP13-3　マルチチャンネル化，画像の線形結合，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

○滝沢　穂高[1]，塩田　紘司[2]，目片幸二郎[3]，工藤　博幸[1]
[1]筑波大学システム情報系，[2]筑波大学大学院情報理工学位プログラム，[3]四条畷学園大学作業療法学専攻

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．本報告では頸部 X 線動画にマルチチャンネル化を適用して特徴画像を生成し，その特徴画像を線形結合した画像を U-Net に入力することで，頸部椎体と棘突起を抽出する手法を提案する．線形結合の係数は Dice 係数をエネルギー値とする焼きなまし法を使って最適化する．実際の頸部 X 線動画に適用した結果を示す．

OP13-4　Optical coherence tomography angiography における血管中心線深度の推定手法の検討

○岡本　尚之[1]，岡村　宙輝[2]，羽石　秀昭[1]
[1]千葉大学フロンティア医工学センター，[2]千葉大学融合理工学府

光干渉撮影計 (OCT) を応用した OCT Angiography(OCTA) は，血管構造を3次元に描出可能な画像化技術である．OCTA は，眼科領域や生体機能計測など，幅広い領域で応用されている．しかし，OCTA の主な課題として，抽出した血管構造下に伸びるテーリングアーチファクトが発生し，3次元血管構造の詳細観察を阻害していることが挙げられる．本研究は，OCTA の2次元投影像で観察できる血管中心線の深さ情報を推定し，これらの推定結果を統合することで3次元血管グラフを構築することを目的とする．提案手法では，まず OCTA に対して血管形状を模擬したテンプレートを設計し，テンプレートマッチングにより血管中心を強調する．さらに，血管走行に沿った断面に対して，動的輪郭モデルを応用した最適化手法により血管中心線の深さ情報を推定する．シミュレーションおよび実データ実験の結果，妥当な深さ情報推定結果が得られた．

OP13-5　超広角眼底画像における無灌流領域の自動抽出

○中野　勝太[1]，畑中　裕司[2]，慶野　　博[3]

[1]大分大学大学院工学研究科，[2]大分大学理工学部，[3]杏林大学医学部

ぶどう膜炎は，眼球のぶどう膜に炎症が起こる疾患群で，視力の低下や失明の原因になる疾病である．網膜で血液が流れていない無灌流領域は，ぶどう膜炎の所見の一つであり，蛍光眼底造影撮影での検査が必要とされている．

医師の定量的な診断の補助を目的として，超広角眼底画像を対象とした，無灌流領域の自動抽出システムの開発を目指した．

無灌流領域と灌流領域に注目し，画像全体より灌流領域を削除することで，無灌流領域を抽出することが可能であると考え，U-Net を用いて灌流領域の自動抽出を試みた．40 枚の超広角眼底造影画像を対象として U-Net で抽出した灌流領域と医師の手動抽出した領域と比較したとき，IoU の平均値は 0.731 であった．

本研究で提案する手法は無灌流領域を特定することが可能であると示唆された．

Uveitis is a group of diseases in which inflammation occurs in the uvea of the eye, causing loss　of vision and blindness.

An area of no perfusion in the retina is one of the findings of uveitis and should be examined with fluorescence fundus angiography.

To assist physicians in quantitative diagnosis, we aimed to develop an automatic extraction system for the no-perfusion area in ultra-wide-angle fundus images.

We focused on no-perfusion and perfusion areas and considered that it would be possible to extract no-perfusion areas by removing perfusion areas from the entire image and attempted automatic extraction of perfusion areas using U-Net. The average value of IoU is 0.731.

This suggests that the method proposed in this study can identify areas of no perfusion.

8 月 7 日（水）

第２会場（中会議室 2-4）

一般演題 14

9:30 ～ 10:20　**OP14「放射線画像再構成 2・画像変換」**

座長：橋本二三生（浜松ホトニクス株式会社）

花岡　昇平（東京大学）

OP14-1　デノイジング拡散確率モデルを用いた CT 画像再構成

○尾崎　　翔[1,3]，鍛治　静雄[2]，名和　要武[3]，今江　禄一[3]，中川　恵一[3]

[1]弘前大学大学院理工学研究科，[2]九州大学　マス・フォア・インダストリ研究所，[3]東京大学医学部附属病院放射線科

近年，画像生成 AI 研究は急速に発展しており，高画質で多様性に富んだ画像の生成を可能にしている．本研究では，デノイジング拡散確率モデルと呼ばれる画像生成 AI を用いて CT 画像の画質改善を行う．画像生成 AI が高画質な画像を生成することは画質改善にとって望ましい性質だが，一方で多様性を生み出す性質は，患者の解剖学的な構造変化を伴うため抑制したい．そこで本研究では，デノイジング拡散確率モデルと逐次近似画像再構成法を組み合わせた新しい CT 画像再構成法を提案する．CT 画像再構成に用いられる投影データは患者の解剖学的な構造の情報を含むため，CT 画像再構成法と拡散モデルを組み合わせることによって，患者の解剖学的な構造を保存した医用画像に特化した画像生成モデルが構築可能となる．我々の手法と既存の画像再構成法を，1) 視覚的な定性評価と，2) SSIM や PSNR などの指標を使った定量的な評価を用いて比較する．

OP14-2　マイクロ CT による小動物イメージングのための動態アーチファクト低減手法の構築

○福島まひる[1]，岡本　尚之[2]，羽石　秀昭[2]

[1]千葉大学大学院融合理工学府，[2]千葉大学フロンティア医工学センター

マイクロ CT による小動物イメージングは，創薬研究などの前臨床研究で頻繁に用いられている．しかし，撮影中の呼吸や心拍による体動はモーションアーチファクトの原因となる．従来の解決策として，同期処理と呼ばれる特定位相の投影データのみを再構成に利用することでアーチファクトを低減する手法が提案されている．同期処理に関する研究は数多く検討されているが，そのほとんどで安定した呼吸が前提となっている．そこで本研究では異常呼吸や様々な呼吸周期に適用可能なロバストな同期処理手法を提案する．具体的には透視画像の横隔膜付近に関心領域を設定し平均輝度値を算出することで呼吸や心拍のパターンを表す波形を生成する．その後，移動平均を閾値として特定位相の投影データを選定する．実データを用いて本手法の有効性検証を実施した結果，実機のマイクロ CT に搭載されている同期処理手法と比較してアーチファクトが低減された画像を取得した．

OP14-3　多重解像度展開像の相似性を利用した単一画像超解像

○正田　優大[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 情報電気電子システム工学プログラム

超解像の MR 画像応用は実質的に撮像時間を短縮することに繋がり，受ける恩恵は大きいものがある．本研究では，多重解像度解析の一種である eFREBAS 変換によって得られる展開像の相似性を利用し，単一画像利用の超解像法について検討を行った．従来法では，画像を補間拡大する際に eFREBAS 信号が平滑化されていた．本研究では，eFREBAS 信号の補間時に鮮鋭化を実施した．画像評価法に PSNR，SSIM，LPIPS を使用し，他の超解像法との比較を行った．その結果，提案法は，他の超解像法よりも良好な LPIPS を取りつつ，比較的高い PSNR が得られることがわかった．また，画像比較による評価では提案法の構造は鮮鋭さを保ちつつ，ジャギーが取り除かれていた．本研究より，eFREBAS 展開像の相似性を利用した本法は，非学習型の単一画像超解像法であるが，学習型の超解像法に比肩する性能が得られる可能性が示された．

OP14-4　条件付き敵対生成ネットワークを用いた頭部 MRI 画像におけるモーションアーチファクト成分の低減

○有田　晃大[1]，臼井　桂介[1]，京極　伸介[1]，坂野　康昌[1]，坂本　　肇[1]，代田　浩之[1]

[1]順天堂大学大学院保健医療学研究科

磁気共鳴画像撮影（MRI）中の患者の頭部の動きは，モーションアーチファクトを引き起こし，診断精度を低下させる可能性がある．近年，深層学習を用いた補正法の有効性が示されているが，アーチファクト補正後の空間分解能等の低下や膨大な数の学習データの確保が課題となっている．本研究では，シミュレーションによりモーションアーチファクト画像を生成し，条件付き敵対生成ネットワーク (CGAN) に模擬モーションアーチファクト画像とその原画像の 10,000 枚ペアにして学習させ，モーションアーチファクトを低減させる学習モデルを作成し，動き低減効果を評価した．Validation データに評価画像 1000 枚，Test データにボランティア画像 300 枚を学習済み CGAN モデルで補正し，動き低減後の画像について，アーチファクト画像で正規化した平均絶対値誤差（NMAE）を算出した．その結果，Validation データの補正画像の NMAE は約 26% の減少が確認された．また，Test データの補正画像も改善傾向を示した．

OP14-5　脳腫瘍病変の有無におけるコンディショナル GAN による頭部 CT-MRI 画像変換精度の比較

○土屋　諒真[1]，臼井　桂介[1]，坂本　　肇[1]，坂野　康昌[1]，京極　伸介[1]，代田　浩之[1]

[1]順天堂大学大学院保健医療学研究科診療放射線学専攻

深層学習による CT-MRI 画像変換は，CT のみから位置ずれがなく組織コントラストに優れた MRI を迅速に生成することが可能であり，放射線治療計画の輪郭描出精度の向上が期待できる．関連する先行研究では，多くの場合は病変のない正常画像を用いた学習モデルである．そこで，脳腫瘍病変の有無による各学習データを用いて，コンディショナル GAN による画像変換精度を評価した．本研究では，病変無しおよび有りの各 100 例の頭部 CT 画像および FLAIR 画像に対して剛体レジストレーションを行い，病変無画像 3322 枚，病変有画像 2987 枚で CT-MRI のペア画像を教師として学習を行った．90 症例を学習，残りの 10 症例を検証に使用した．評価は MRI の原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，病変無画像の SSIM 平均値が 0.62，PSNR 平均値が 19.3 dB となり，病変有画像の SSIM 平均値が 0.57，PSNR 平均値が 17.5 となったことから病変領域は学習精度を低下させることが示唆された．

第2会場（中会議室 2-4）

一般演題 15

10:30 ～ 11:20　**OP15「推定・予測 2」**

座長：根本　充貴（近畿大学）
小橋　昌司（兵庫県立大学先端医療工学研究所）

OP15-1　低線量胸部 CT 画像から深層学習を用いた年齢推定モデルの開発

○菊野　遥翔[1]，田中　利恵[2]，松永　哲夫[3]，小林　　聡[4]，南　　哲弥[5]，白石　順二[6]

[1] 金沢大学大学院　医薬保健学総合研究科，[2] 金沢大学　医薬保健研究域附属 AI ホスピタル・マクロシグナルダイナミクス研究開発センター，[3] 石川県予防医学協会，[4] 金沢大学　医薬保健研究域医学系，[5] 金沢医科大学　放射線科，[6] 福岡国際医療福祉大学

肺がん CT 検診は，肺がんの早期発見に有効である．しかし，受診者の約 95％に相当する正常者は一括りに「異常なし」と診断される．深層学習を用いて肺の僅かな経年変化から加齢変化を推定できれば，受診者の生活改善の機会になり得る．本研究の目的は，低線量胸部 CT 画像から年齢推定をする深層学習モデルを開発することである．石川県予防医学協会で過去 11 年間に人間ドックで撮影された低線量胸部 CT 画像約 2.8 万件のうち，異常なし症例について，1 秒量と身長から算出した肺年齢ならびに実年齢と低線量胸部 CT 画像の関係を畳み込みニューラルネットワークに学習させた．学習したモデルを検証したところ，肺年齢は ± 11.18 歳，実年齢は ± 4.02 歳の誤差で推定され，喫煙歴が長いほど推定年齢が高くなることが確認された．加齢や喫煙による肺の変化を，開発したモデルが捉えていると考えられる．胸部 CT 画像から推定した年齢と実年齢の差を新しい健康指標として期待できる．

OP15-2　前眼部 OCT 画像のテクスチャ特徴を用いたぶどう膜炎の前房細胞グレードの推定

○清水　悠多[1]，畑中　裕司[2]，慶野　　博[3]

[1] 大分大学大学院工学研究科，[2] 大分大学理工学部，[3] 杏林大学医学部眼科学教室

ぶどう膜炎の前房細胞の評価は，現在 SUN Working Group の評価案に従って行われているが，主観的評価であり再現性などが課題となっている．本研究は，テクスチャ解析を用いて，前眼部 OCT 画像からぶどう膜炎における前房細胞グレードの自動推定手法の開発を目的とする．本研究では，OCT 画像中の前房領域を特定し，その領域内を正方形で関心領域に設定しテクスチャ解析を行った．ここでは，画素値の度数分布に基づく統計量，同時生起行列 (GLCM)，ランレングス行列 (GLRLM)，サイズゾーン行列 (GLSZM)，ディペンデンス行列 (GLDM)，近傍濃度差行列 (NGTDM) への変換から得られる合計９３種類の特徴量を抽出した．抽出した特徴量に対して主成分分析を行い，上位 7 要素を使用してニューラルネットワークによる重回帰分析を行った．その結果，利用する特徴量を増やすことにより推定精度が改善したことを確認した．

OP15-3　深層学習を用いた超音波 RF 信号再構成による転移リンパ節診断予測モデルの開発

○前田　一伎[1]，大村　眞朗[3]，小玉　哲也[1,2]

[1] 東北大学大学院　医工学研究科，[2] 東北大学大学院　医工学研究科　がん医工学研究センター，[3] 富山大学　学術研究部工学系

転移リンパ節は，重要な予後因子である．われわれの先行研究では，ヒトと同等の大きさのリンパ節を有するモデルマウスを用いた非臨床試験で，転移リンパ節内で血管が欠損する灌流欠損が造影高周波超音波で可視化され，灌流欠損が転移リンパ節の初期段階を判定する重要な指標になることを明らかにした．しかし，造影剤投与は手間やコスト，ならびに一部のアレルギー患者には適用不可といった課題がある．本研究では，造影剤を必要としない転移リンパ節判定システムを開発することを目的とする．学習に使用するデータセットは，リンパ節の超音波 RF 信号再構成情報である．これらのデータを学習用と検証用に分割して深層学習を実行した．造影前データを入力としたモデル予測データと検証用の造影後データを比較すると，ほぼ一致することを確認した．本研究は，超音波 RF 信号に基づく深層学習モデルの有用性を示すものである．

OP15-4　対照学習を用いた画像特徴抽出モデルの事前学習の有効性の検証

○渡辺　翔吾[1]，連　　乃駿[1]，今岡　幸弘[1]，和久　景子[1]，盛田　健人[1,2]，小橋　昌司[1,3]，西村　邦宏[1]，飯原　弘二[1]

[1]国立循環器病研究センター，[2]三重大学，[3]兵庫県立大学

医用画像は臨床診断において重要な位置を占めており，疾患や予後に関わる情報を含んでいる．画像からより重要な情報を抽出することは，疾患分類や予後予測に繋がると考えられるが，そのためには汎用的な画像特徴抽出モデルが必要となる．

そこで本研究では，画像情報と構造化された臨床情報を用いて対照学習を行い，より汎用的な画像特徴抽出モデルの事前学習を目指した．対象とする画像は，脳梗塞を発症した患者の MR 画像とし，FLAIR，T2*，DWI を使用した．

下流タスクとして脳梗塞再発予測を扱い，臨床情報のみの再発予測と，臨床情報に画像特徴抽出モデルで得られた画像特徴量を加えたものとの比較を行った．

その結果，臨床情報のみでの再発予測の精度 ROC AUC 0.66 であったのに対し，対照学習を用いて抽出した画像特徴量を加えることで ROC AUC 0.74 への向上が見られた．これにより，画像データと構造化データの対照学習に基づく事前学習の可能性が示唆された．

OP15-5　TMS コイルによる脳内誘導電場の回帰精度改善に向けた頭部 MRI の自己教師あり学習

○牧　　豊大[1]，横田　達也[1]，平田　晃正[2]，本谷　秀堅[1]

[1]名古屋工業大学情報工学専攻，[2]名古屋工業大学電気機械工学専攻

経頭蓋磁気刺激法 (Transcranial Magnetical Stimulation: TMS) は，頭部に置いたコイルによって誘導される電場を用いた非侵襲的な刺激手法である . コイルによって刺激されている部位を求めること，また反対にある部位を刺激する上での最適なコイルの位置を求めることは TMS にとって重要である．これらを達成するためには，正確に誘導電場を計算する必要がある . 誘導電場は頭部 MRI 画像から電磁シミュレーションを用いて計算される . 電磁シミュレーションは，MRI 画像から導電率の空間的な分布を構築すること及びその分布から電場を計算する二つの工程で構成される . しかし，いずれの工程も実時間で行うことはできない . 近年，CNN を用いた電場を実時間で推定する手法が提案されている . 本研究では，Transformer 及びその事前学習を用いて，誘導電場の回帰精度の改善を検討する．

8 月 7 日（水）

第２会場（中会議室 2-4）

一般演題 16

11:20 ～ 12:10　**OP16「MR イメージング」**

座長：増谷　佳孝（東北大学 大学院医学系研究科 保健学専攻）
伊藤　聡志（宇都宮大学）

OP16-1　画像分離に深層学習を利用する新たな MR マルチスライス撮像法の提案

○遠藤　尚哉[1]，佐藤　裕貴[1]，大内　翔平[2]，伊藤　聡志[1]

[1]宇都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム，[2]小山工業高等専門学校

研究室ではホログラフィの 3 次元情報エンコード様式を MRI に応用し，2 次元的に収集した MR 信号から任意の断面に焦点を合わせた画像を再構成する研究を行ってきた．この方法の問題点は，焦点外の映像が重畳し焦点面の像が不鮮明になることであった．本研究では，焦点面の映像抽出に深層学習を利用する新たな方法について行った．汎用 MRI への応用を想定し，マルチスライス撮像を模擬したシミュレーション実験を行った．スライス

像毎に異なる振幅変調を与えることにより，U-Net により各断面を良好に分離することができた．MR 同時マルチスライス撮像 (SMS) は近接したスライス位置における受信コイルの感度差が小さい場合はスライス画像の分離が困難になる問題があるが，本法は受信コイルの感度分布を使用しないので応用可能性の拡がりが期待される．本研究により，ホログラフィの見地に立ち深層学習の新たな応用とみなせる新方式 SMS の可能性が示された．

OP16-2　生成型 X-Q 空間学習による拡散尖度イメージングパラメタの推定

○増谷　佳孝[1]，一関　雄輝[1]，紺谷　昂生[1]

[1] 東北大学大学院医学系研究科・医学部

拡散尖度イメージングを含め，拡散 MRI の信号値モデルパラメタの推定は voxel-by-voxel で行われる．各種のフィッティングによる推定手法では，誤差関数に空間正則化項を導入することで，推定されたパラメタマップの空間的滑らかさを向上させる試みが行われる．本研究では，合成データを用いた機械学習によるパラメタ推定に空間正則化を導入した生成型 X-Q 空間学習の手法を提案する．具体的には，パラメタ推定対象位置の Q 空間の信号群に加え，近傍の信号群を入力に追加することでパラメタ推定の頑健性を向上させる．学習データとして生成される X-Q 空間の信号の元となるパラメタの局所空間分布は，２次までの多項式近似による変動成分により生成する．拡散尖度イメージングのパラメタ推定を例として，パラメタマップおよび信号分布の合成，合成データおよび実データにおけるパラメタ推定の性能評価を本研究の目的とする．

OP16-3　MRI を用いたラット肝臓の定量的磁化率マッピングにおける手法検討

○中村　浩也[1]，寺田　康彦[1]，山口　雅之[2]

[1] 筑波大学 理工情報生命学術院 数理物質科学研究群，[2] 国立がん研究センター　先端医療開発センター　機能診断開発分野

MRI を用いた肝臓の造影検査に用いられる SPIO は，正常な肝臓とがん化した肝臓での蓄積度が異なる．そこで，この蓄積度の推定を行うことができれば，がん化の定量評価につながると期待される．しかし，この肝臓内の SPIO の定量化手法はいまだ確立されていない．そこで，近年注目されているのが MRI 撮像によって得られた位相画像から磁化率の分布を画像化する手法である定量的磁化率マッピング（QSM）である．しかし，現状，造影剤投与下での QSM の研究は少なく，特に SPIO を投与した肝臓内での検討はほとんどない．一般に QSM は，一つの静磁場角度で撮像する MEDI 法と，異なる複数の静磁場角度で撮像する COSMOS 法などが採用される場合が多い．本研究では，SPIO 投与下のラット肝臓を対象とした QSM の各再構成手法の有効性の検証を目的とした．その結果，肝臓内の SPIO の微小な位相変化に対しては MEDI 法が有効であることが示された．本研究により，QSM による肝臓内の SPIO 定量化の可能性が示された．

OP16-4　勾配加重クラス活性化マッピング (Grad-cam) を用いた MRI モーションアーチファクト分類の位相方向による影響

○赤沼　優文[1]，臼井　桂介[1]，有田　晃大[1]，坂本　肇[1]，坂野　康昌[1]，京極　伸介[1]，代田　浩之[1]

[1] 順天堂大学大学院保健医療学研究科　診療放射線学専攻

MRI のモーションアーチファクトは強度や発生方向が異なり，画像診断の妨げとなる．一方で転移学習にて分類モデルを作成し Grad-CAM を用いることでその分類理由を明らかにできる．先行研究では，アーチファクトが強いほど強く反応したが位相方向への影響は不明であった．本研究では，位相方向毎にモデルを作成し Grad-CAM の結果に及ぼす影響を検討した．

11 例の頭部 MRI 画像の T2 強調像を用い，アーチファクト有りの画像をシミュレーションにより 10000 枚作成した．70%を学習データ，20%を検証データ，10% をテストデータとし，GoogLeNet を使用した転移学習を行った．位相方向が縦横モデルのテスト精度は 96.94%，縦モデルは 96.25%，横モデルは 96.67%であり，縦横モデルが最も高かった．Grad-CAM の結果にはモデルの特徴が現れており，縦横モデルにおいては位相方向による影響が見られなかった．

OP16-5　弾性波画像の振幅対ノイズ比を利用した MR エラストグラフィ解析手法の改良

○玉田　綾[1]，菅　幹生[1,2]

[1] 千葉大学　融合理工学府　医工学コース，[2] 千葉大学　フロンティア医工学センター

MR エラストグラフィは，定量的に粘弾性を測定可能な手法である．測定では，外部加振装置により対象内に発生させた弾性波を MRI で画像化し，解析手法を適用することで弾性率画像を生成する．解析手法には弾性波画像の振幅対ノイズ比（ANR）が低い領域では推定誤差が生じやすい課題がある．本研究では，弾性率画像の定量性改善のため，ANR を利用した解析手法を開発することを目的とした．粘弾性体伝播過程で反射や減衰することを想定した 3 次元弾性波画像を数値シミュレーションにより生成し，ガウスノイズを 5 段階の強度で加えた．誤差低減手法として ANR の閾値を設定し，低 ANR 領域を除いて弾性率を推定した．ANR の閾値を設定しない場合に対して閾値を 3.0 に設定した場合では弾性率画像に生じる誤差と変動係数が共に小さくなった．以上の結果より，ANR 閾値を利用した解析手法により定量性が向上することが示唆された．

第２会場（中会議室 2-4）

一般演題 17

13:30 ～ 14:30　**OP17「核医学イメージング」**

座長：羽石　秀昭（千葉大学）
小尾　高史（東京工業大学科学技術創成研究院）

OP17-1　Noise2Void による脳 SPECT 画像の画質改善

○草刈　颯太[1]，成田　和陽[2]，松岡　将宏[3]，松原　佳亮[4]，越野　一博[5]，渡部　浩司[6]，湯浅　哲也[3]，銭谷　勉[1]

[1]弘前大学大学院理工学研究科，[2]弘前大学理工学部，[3]山形大学大学院理工学研究科，[4]秋田県立大学システム科学技術学部，[5]北海道情報大学経営情報学部，[6]東北大学先端量子ビーム科学研究センター

SPECT 装置における空間分解能と検出効率はトレードオフの関係にあり，高解像度化に伴って検出効率が低下し，画像に生じるノイズ量は増加する．本研究では，ブラインドスポットネットワークによる自己教師あり学習を用いたノイズ低減手法である Noise2Void により SPECT 画像の画質改善を試みた．180 方向の投影画像で学習した Noise2Void ネットワークを用いて投影画像のノイズ低減を行い，処理後の投影画像を OS-EM 法により再構成した．シミュレーションによる脳数値ファントムの再構成画像では，エッジを保持しつつノイズが低減され，PSNR は 6.69 dB から 20.04 dB へ，SSIM は 0.443 から 0.836 へ大幅に向上した．開発中の高解像度 SPECT 装置を用いて撮像した脳物理ファントムの再構成画像においても，ノイズが大きく低減され，ファントムの構造が明瞭に描出された．

OP17-2　ピンホール SPECT イメージングによる検出確率の近似手法の比較

○縄野　勇大[1]，尾川　浩一[2]

[1]法政大学大学院理工学研究科，[2]法政大学理工学部応用情報工学科

SPECT において，ML-EM 等の逐次的画像再構成法を用いる場合，画素と投影データの bin で決まる検出確率が重要となる．ジオメトリが複雑になると検出確率の計算が困難になるため，この値を近似的に求める方法が採用されるが，誤差が大きくなることが予想される．本研究では近似的に検出確率を求める方法と厳密に検出確率を求める方法を比較した．近似的に検出確率を求める方法として pixel を横切る ray の長さで近似する ray-driven 法 (Siddon の方法，Joseph の方法), および検出器と画素との位置関係を計算に用いる distance-driven 法を用いた．本研究では，ピンホールジオメトリにおけるそれぞれの計算手法の検出確率を用いて，ML-EM 法による画像再構成を行い，シミュレーション結果から異なる検出確率の計算手法における再構成画像の違いを考察した．

OP17-3　臨床用 Whole Gamma Imaging 装置のシミュレーション設計

○菊地　智也[1]，田久　創大[2]，菅　幹生[1,3]，田島　英朗[2]，赤松　剛[2]，錦戸　文彦[2]，山谷　泰賀[2]

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

Whole gamma imaging (WGI) 装置は，PET 検出器リングの内側に散乱検出器リングを挿入し，PET とコンプトンカメラの２つの画像化手法を１つの装置で実現する．今まで QST では小動物用 WGI の開発を進めてきた．本研究では小動物用 WGI の開発を通して得られた知見をもとにヒト用 WGI をシミュレーションによって設計した．散乱検出器にはピッチが 1.5 mm で 5.0 mm 厚の HR-GAGG3 層 DOI 検出器を，吸収検出器にはピッチが 3.0 mm で 20 mm 厚の LGSO 検出器を用いた．一般的にコンプトンイメージングの精度は，散乱検出器が撮像対象に近い方が良いとされる．よって散乱検出器のみを体に近づけて楕円状に配置した場合と，通常の円形に配置した場合を比較した．89Zr 点線源を用いたシミュレーションを行い，視野中心における PET 感度，コンプトン感度，コンプトンの角度分解能を評価した．その結果，検出器の配置の違いによる大きな性能の変化が無いことが分かった．そのため，汎用性が高く製造が容易な円形の形状が適当であると結論した．

OP17-4　対向パネル型 PET のシミュレーション：TOF 分解能と感度が画質に及ぼす影響

○石川　大洋[1]，赤松　　剛[1]，田島　英朗[1]，錦戸　文彦[1]，高橋美和子[1]，橋本二三生[1,2,3]，大田　良亮[3]，山谷　泰賀[1,2]

[1]量子科学技術研究開発機構，[2]千葉大学，[3]浜松ホトニクス株式会社

30ps の time-of-flight (TOF) 分解能を持つチェレンコフ放射体一体型マイクロチャンネルプレート光電子増倍管 (CRI-MCP-PMT) により，非リング型 PET でも断層像が取得できる可能性が示された．しかし，TOF 分解能と検出効率の両立が課題となっており，これらのパラメータの変動が画質に与える影響は明らかにはなっていない．そこで本研究では，チェレンコフ放射体としてBGOを搭載した開発中のCRI-MCP-PMTを用いた対向パネル型PETをGeant4シミュレーションによりモデル化し，システム感度と TOF 分解能を変化させた場合の空間分解能と画像ノイズの推移を調査した．従来のリング型 PET（TOF 分解能 210ps）と比較した結果，システム感度が 10% に低下しても，30ps の TOF 分解能を維持できれば，提案装置は従来装置に近い空間分解能と画像ノイズを達成できることが明らかになった．

OP17-5　TOF-DOI 検出器を用いた半球型頭部 PET 装置 1 リング試作機の開発

○成田　胡桃[1,2]，赤松　　剛[1]，吉田 英治[1]，田島 英朗[1]，岩男 悠真[1]，高橋美和子[1]，山谷　泰賀[1,3]

[1]量子科学技術研究開発機構，[2]千葉大学大学院融合理工学府，[3]千葉大学フロンティア医工学センター

PET は脳機能を画像化できることから，神経変性疾患の病態解明に有用である．PET 装置の空間分解能が高いほど，より早期の微細な変化を検出できる可能性がある．そこで量研では，空間分解能の向上を目的に検出器を頭部に近接させた半球型頭部 PET 装置の開発を進めている．検出器には，1.45 mm 幅の微細なシンチレータを用いて製作した，ガンマ線の飛行時間差（time-of-flight: TOF）と検出器の深さ方向の検出位置（depth-of-interaction: DOI）の両方を計測できる TOF-DOI 検出器を応用する．本研究では，TOF-DOI 検出器 36 個を使用して直径 30 cm の 1 リング PET 試作機を開発し，ロッドファントムを用いて空間分解能を評価した．画像再構成には OSEM を用いた．予備的に実施したモンテカルロシミュレーションと同様に，1 mm ロッドが明瞭に識別できた. 撮像視野辺縁においてはDOI情報による空間分解能の向上が認められた. TOF-DOI検出器（1.45 mm 幅シンチレータ）を用いた 1 リング PET 試作機を開発し，1 mm 空間分解能が実現できることを示した．

OP17-6　OpenPET 初の重粒子線がん治療臨床応用

○田島　英朗[1]，寅松　千枝[1]，浜戸アクラム[1]，岩男　悠真[1]，赤松　　剛[1]，カンハンギュ[1]，錦戸　文彦[1]，田尻　　稔[1]，水野　秀之[1]，小藤　昌志[1]，山谷　泰賀[1]

[1]量子科学技術研究開発機構

開放空間を持つ OpenPET は重粒子線照射中に PET 測定が可能である．照射によって生体内で副次的に生成される陽電子放出核種をその場でイメージングすることで，患者体内での治療ビームの飛程検証や，治療効果予測ができるようになると期待されている．昨年の報告では, OpenPET 装置を HIMAC（Heavy Ion Medical Accelerator in Chiba）の治療室へ設置し, 頭部ファントムへの照射と OpenPET 測定を行った結果を示した．本発表では，頭頚部がん患者を対象とした臨床試験を開始し，初の OpenPET 臨床測定を実施した結果を報告する．実際の治療では垂直と水平の 2 つ照射ポートを用い，照射は片方ずつ行われるが，OpenPET 装置は水平照射のみに対応しているため，先に垂直照射を行い，その後 OpenPET 装置を測定位置に移動し，水平照射に合わせて測定を開始した．測定は照射後 10 分間継続した．その結果，患者体内にて重粒子線が照射された領域に生成された陽電子放出核種を捉えることに成功した．

第２会場（中会議室 2-4）

一般演題 18

14:40 ～ 15:30　**OP18「内視鏡・手術映像等」**

座長：中口　俊哉（千葉大学フロンティア医工学センター）
林　雄一郎（名古屋大学）

OP18-1　股関節鏡視下手術における術中動画のセグメンテーション画像と仮想股関節鏡シミュレータによる仮想股関節画像との連携による最適ポータル位置の推定

○川上申之介[1]，福田　紀生[2]，西井　　孝[3]，大竹　義人[4]，佐藤　嘉伸[4]

[1]関西女子短期大学医療秘書学科，[2]脳情報通信融合研究センター，[3]大阪急性期・総合医療センター整形外科，[4]奈良先端科学技術大学院大学情報科学領域

前回我々は股関節鏡視下手術における術中動画から切り出した静止画像にたいして Unet によるセグメンテーションの精度検証を行った．我々が開発している仮想股関節鏡シミュレータによりポータル位置をシフトしながら網羅的に捜査撮影した仮想股関節鏡画像に対して，Unet により生成したモデルにより選定された術中動画から切り出した静止画像のうち，我々の定義する視認性の指標の最も高い画像に最も近い仮想股関節鏡画像を選ぶことにより，その画像を得る場合のシフトしたポータル位置を推定したので報告する．

OP18-2　Segment Anything Model を用いて生成されたマスクの分類による腹腔鏡映像からの血管・膵臓領域自動抽出の検討

○髙見　一慧[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[1,3,5]

[1]名古屋大学大学院情報学研究科，[2]愛知工業大学情報科学部，[3]名古屋大学情報基盤センター，[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

本稿では，Segment Anything Model（SAM）で生成したマスクを分類し，腹腔鏡映像の血管領域と膵臓領域を自動抽出する手法について述べる．腹腔鏡手術は患者にとって負担が小さい手術である一方，術者にとって手術難易度が高く，負担が大きい手術である．そのため，術者を支援するシステム開発が必要とされている．SAM は汎用セグメンテーションモデルの１つで，画像の一部分を点やボックスなどのプロンプトで指定し，それに対するマスクを生成し，セグメンテーションを行う．SAM は強力なゼロショット性能を持つ一方で，生成されたマスクがクラス情報を持たないという問題がある．そのため本研究では，SAM が腹腔鏡画像から生成したマスクを基に深層学習モデルを用いてクラス分類を行い，血管領域，膵臓領域の自動抽出を行う手法を提案する．実験の結果，従来手法では抽出が難しい血管領域の抽出が可能であった．

OP18-3　改良を加えた YOLO モデルに基づく内視鏡下手術画像からの術具先端検出

○劉　　育彰[1]，林　雄一郎[1]，小田　昌宏[2,1]，森　　健策[1,2,3]

[1]名古屋大学　情報学研究科，[2]名古屋大学　情報基盤センター，[3]国立情報学研究所　医療ビッグデータ研究センター

Laparoscopic tool detection plays a crucial role in assisting minimally invasive surgeries, facilitating tasks such as tool pose estimation and surgical phase recognition. However, current detection techniques for laparoscopic surgical tools mainly focus on the detection of the entire tool, while in practical applications, the tips of surgical tools contain the most critical information. During surgery, operations such as tissue grasping, excision, and vascular sealing are performed by the tips of various surgical tools. Thus, detecting the tips of surgical tools holds applicative value in assisting laparoscopic surgery.

This study aims to address the detection of laparoscopic tool tips. We selected laparoscopic frames and annotated the tips of the laparoscopic tool instances contained in the frames, thereby creating a dataset specifically for detecting laparoscopic tool tips. An improved YOLOv8 model, tailored for the task of laparoscopic tool detection, was then trained on this dataset. In surgical scenarios within the training videos, which featured relatively simple environments and fewer categories of instruments, our approach demonstrated the capability to detect the tooltips with relatively high accuracy.

OP18-4　色彩の分離に基づいた3次元点群顔データからの口唇領域の抽出

○木原　成海[1]，神谷　　亨[1]

[1]九州工業大学

頭蓋・顔面部は形成の過程が極めて複雑であるため，同部には多くの先天異常が発生する．口唇裂は，その中で最も頻度が高い先天異常の一つである．口唇裂の外科手術は複数回に渡って行われることが一般的であるが，顔の左右対称性に関する基準が曖昧なことから，手術方針が医師の主観的な判断に依存することが懸念されている．そこで，顔の左右対称性を定量的に示す指標の開発が期待されている．本論文では，口唇裂の症状が現れる口唇部に注目した解析を行う準備段階として，顔を撮影した3次元点群データから口唇領域を抽出する手法を提案する．抽出処理では，口唇の候補領域をHSV変換し，H（色相）に対し判別分析法を適用することにより，色彩の分離に基づいた抽出を図る．実験の結果，提案手法によって効果的に口唇領域を抽出できることを確認した．

OP18-5　大腸内視鏡動画像を用いた3次元復元に関する初期的検討

○小野坂　捺[1]，伊東　隼人[2,1]，小田　昌宏[3,1]，三澤　将史[4]，森　　悠一[5,4]，工藤　進英[4]，森　　健策[1,3,6]

[1]名古屋大学大学院情報学研究科，[2]福岡大学理学部応用数学科，[3]名古屋大学情報基盤センター，[4]昭和大学横浜市北部病院消化器センター，[5]オスロー大学臨床効果研究グループ，[6]国立情報学研究所医療ビッグデータ研究センター

大腸内視鏡検査中のポリープ見落とし防止を目的に，検査中の未観測領域を内視鏡医へ提示する計算機支援診断技術が求められている．内視鏡検査中に記録された内視鏡画像を用いた精確な3次元復元により，未復元部分を未観測領域として推定可能である．教師なし深層学習手法による3次元復元では，深度推定とポーズ推定の両方の推定精度向上により高精度な3次元復元を達成する．大腸の弾性変形は，ポーズ推定の精度に悪影響を与えると考えられるが，動画像中の近いフレーム間のポーズ推定のみを考えれば，弾性変形は小さいと仮定できる．本稿では非ランバート反射の影響を抑えた深度推定手法の訓練済みモデルを教師なし深層学習による3次元復元手法へ組み込み，内視鏡動画像から得られる様々な内視鏡画像集合から3次元復元を行う．復元結果の定性的な評価より，3次元復元に対するサンプリング間隔の影響について調査を行う．

8月7日（水）

第2会場（中会議室 2-4）

一般演題 19

15:30 ～ 16:30　**OP19「医療情報・教育」**

座長：北坂　孝幸（愛知工業大学）
田中　利恵（金沢大学医薬保健研究域）

OP19-1　Transformerと画像強調分析を使用した放射線レポート生成ツール

○イスメットヒリヤツァニヤ[1]，イスメットヒリヤツァニヤ[1]，李　　中淳[3]，小尾　高史[2]，スシアティナニック[1]，ファティチャチャスティン[1]

[1]セプル ノーペンバー工科大学，[2]東京工業大学 未来産業技術研究所，[3]東京工業大学 科学技術創成研究院

It takes a lot of time and requires the involvement of skilled radiologists to compose a radiology report. Therefore, it would be beneficial to have technology that can produce a report automatically. Developing a coherent predictive text is the main challenge in automatic report generation. It is necessary to develop methods that can increase the relevance of features in producing predictive text. To leverage the visual and semantic features, the transformers method is used. An enhancement method was also used to improve the noise-prone nature of the medical image. Therefore, this study constructed a medical report generator model using the transformer approach and image enhancement implementation. The proposed model is an encoder-decoder with text feature embedding using the Transformer method and visual feature extraction utilizing a pre-trained ChexNet that is also used for multi-label classification for abnormalities tags with a Multi-Head Attention (MHA) mechanism. The image data quality was also improved by applying the gamma correction method. The use of gamma correction produces medical images with a more scattered histogram representation. The comparison of the report-generated performance is evaluated using a Bilingual Assessment Understudy (BLEU). The MHA model with a gamma correction obtains 5% better using BLEU with a 4 n-gram evaluation value than the model without gamma correction implementation. The MHA model also produces 15% better results than the baseline model. This method is able to outperform the baseline model and other previous works. It can be concluded that the use of a transformer is effective in leveraging visual and text features for generating medical reports. The addition of an image enhancement approach has also been found to have an impact to the model's performance.

OP19-2　PET-CT 画像所見文における部位および正常 / 異常識別のための深層学習モデルの構成に関する検討

○山中唯歩生[1]，成田　紗弥[1]，間普　真吾[1]，楊　　鯤昊[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

本研究では，大量に蓄積された PET-CT 画像所見文を解析し，機械学習に適した教師ラベル付きデータセットを構築することを目的としている．先行研究では，自然言語処理ニューラルネットワークの一つである UTH-BERT で画像所見文を解析し，全身，頭部，頭頚部，胸部，腹部，その他の文章に分割するモデルを提案してきた．入力に識別対象文だけでなくアテンションが付与された前文も利用することで，前文をそのまま入力として使う場合より識別性能が向上した．一方，コンピュータ支援診断における一般的な目標として正常と異常の識別がある．したがって，本研究ではこれまで開発してきたモデルを拡張し，部位識別に加えて正常 / 異常のクラス識別も行うモデルの構築を目指す．具体的には，前文と識別対象文を利用したモデルにおいて，部位および正常異常識別の 2 つのタスクを効果的に実行するための最適なモデルの構成について検討する．

OP19-3　ChatGPT は整形外科専門医試験に合格可能か？～医療画像認識能力を含めた成績の検討～

○中嶋　　望[1]，藤森　孝人[2]

[1] 堺市立総合医療センター　整形外科，[2] 大阪大学大学院　整形外科

【目的】今後, 医師を含む士業の仕事に人工知能が活用されるのは間違いない．現時点における大規模言語モデル（ChatGPT）の性能を，整形外科専門医試験を用いて評価する．

【方法】過去３年分（２０２１－２０２３年）の試験問題を使用して正答率を調べた．ChatGPT のモデルは GPT-3.5 と GPT-4 を使用した．画像を含む問題について，GPT-3.5 に対しては画像なしでの出題としたが，GPT-4 については画像なしの場合と画像を含めた場合の双方での成績を比較した．

【結果】GPT-3.5 と GPT-4 の正答率はそれぞれ 30%（28-32%）と 58%（55-60%）であった．GPT-4 は合格点を上回っていたが，GPT-3.5 は合格レベルに達しなかった．画像問題では，画像の有無で成績に差を認めなかった．

【結論】知識としては整形外科専門医試験に合格可能なレベルにあるが，hallucination（幻覚）などの問題があり実臨床への応用にはまだ課題がある．医療画像の認識能力についてはまだ不十分であるが，学習を重ねることで改善の余地がある．

OP19-4　紙ベースで取得された患者報告型アウトカムを画像化して、自動読み取りする AI の開発

○藤森　孝人[1]，喜多　洸介[1,2]，鈴木　裕紀[2]，蟹江　祐哉[1]，古家　雅之[1]，武中　章太[3]，海渡　貴司[4]，岡田　誠司[1]，木戸　尚治[2]

[1] 大阪大学整形外科，[2] 大阪大学人工知能画像診断学，[3]JCHO 大阪病院，[4] 大阪労災病院

【目的】深層学習を用いて，患者報告型アウトカムの一つである日本整形外科学会腰痛評価質問票用紙を読み取り，自動集計する人工知能を開発すること .

【方法】大学病院で収集したアウトカム用紙 (1305 セット) を訓練データ，関連病院で収集した用紙 (483 枚) をテストデータとした . 用紙は ,1, 2 ページ目は選択肢問題で ,3 ページ目は Visual analog scale (VAS) を有する．用紙を JPG に変換し，各ページを画像として認識させた． 各質問毎に全結合層を設けて，読み取り結果を求めた．評価指標として , 選択肢問題は Accuracy を ,VAS は相関係数及び絶対誤差を算出した． Python (3.9.7), Pytorch (1.11.0), EfficientNetB0 をモデルとして使用した .

【結果】選択肢問題の Accuracy は ,2 択問題で 99.9%, 5 択問題で，99.2%，全体で 99.7% であった . VAS の相関係数は 0.989, 絶対誤差は最大値 4.2, 平均 0.34, 中央値 0.25 であった .1 セットの用紙の読み取るにかかる時間は 1.62 秒であった.

【結論】アンケート用紙からの自動読み取り AI は , 高い精度の結果を示し , 実用的なツールになると考えらえた.

OP19-5　カスタマイズ可能なクエリに基づく Human-in-the-Loop 型医用画像検索

○小林　和馬

国立がん研究センター研究所

現代の病院では膨大な放射線画像がデータベースに蓄積されている．こうしたデータベースから，手元の放射線画像に対して類似する画像や，あるいは，特定の所見に関して異なる画像を自在に取得し，比較読影できれば，診断や教育に有用となることが期待される．そこで，医用画像の特徴分解を応用することで，例示画像から抽出したクエリ情報をユーザが必要に応じてカスタマイズすることを可能にする，Human-in-the-Loop 型の医用画像検索システムを構築した．原発性脳腫瘍を含む頭部 MRI からなるデータセットを用いて実装し，検索結果に対する臨床的観点からの評価を専門医により行った．結果，例示画像に対して，カスタマイズを行わない場合には類似した画像が，カスタマイズを行った場合には，その内容を反映した画像が適切に取得できることが認められた．本研究によって，柔軟かつ実用性の高い医用画像検索が実現された．

OP19-6　没入型 VR を用いた放射性医薬品投与訓練における緊張度の計測

○垣本　晃宏[1,2]，藤瀬　大助[3]，長谷川　慎[3]，奥田　保男[3]，太田　悠斗[4]，谷　　碧翔[4]，船橋　正夫[1]

[1]森ノ宮医療大学　医療技術学部　診療放射線学科，[2]浜松医科大学　光尖端医学教育研究センター　フォトニクス医学研究部　生体機能イメージング研究室，[3]量子科学技術研究開発機構　本部　情報基盤部　IT 企画課，[4]森ノ宮医療大学　保健医療学部　診療放射線学科

[目的] 診療放射線技師へのタスクシフトにより，放射性医薬品投与における静脈路確保などの業務拡大が認められた．そこで我々は，診療放射線技師養成校において非侵襲かつ被ばくゼロで当該業務訓練を実施可能な没入型 VR システムの開発を進めている．今回，VR 操作中の緊張度の計測を試みた．

[方法] 同意が得られた 20 ～ 21 歳の学生 10 名（男性 6 名，女性 4 名）を対象とした．VR 操作時における緊張度を数種類の方法で計測し，没入度の違いによる各計測値を比較した．

[結果] 交感神経活動の指標値となる唾液アミラーゼでは，没入度による緊張度の際は見られなかった．また，主観的な気分評価尺度として知られる POMS2 および TDMS-ST では，没入度の高い方がポジティブな感情が維持される傾向であった．脳波計測では，没入度の高い方が緊張度を示す β 波成分は高値を示した．今後は，緊張度と医療技術トレーニング効果の関連性を検証する予定である．

以降の予稿は，著者から提出された原稿を査読なしで，
そのまま掲載しています．

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

発行日：2024 年 7 月 25 日
発行者：第 43 回日本医用画像工学会
大会長　清水　昭伸
製作所：トーヨー企画株式会社

SPECT における被写体構造を考慮した係数自動制御機構付き正則化画像再構成法

皆川　智哉[*1,2]，堀　拳輔[*3]，橋本　雄幸[*2]
[*1] 東邦大学医療センター大橋病院放射線部
[*2] 杏林大学大学院保健学研究科
[*3] 順天堂大学保健医療学部

Regularization reconstruction method incorporated with hyperparameters control system based on the object structure in SPECT

Tomoya MINAGAWA[*1,2]，Kensuke HORI[*3]，Takeyuki HASHIMOTO[*2]
[*1] *Toho University Ohashi Medical Center*
[*2] *Kyorin University Graduate School of HealthSciences*
[*3] *Juntendo University*

要旨：正則化付き画像再構成法の係数値は経験的に決定する必要があるが，SPECT は対象の部位によって撮像条件が大きく変化するため，全ての検査で最適な係数値を決定するのは煩雑で難しい．そこで我々は先行研究において，収集条件および正則化項のとり得る値を考慮し係数値を自動制御する正則化付き画像再構成法である RAREM 法を提案した．しかし，被写体の構造的複雑さについては考慮されていないため適応は限定的であった．本研究では，RAREM 法の係数値自動制御機構に新たに被写体の構造的複雑さを考慮する項を組み込んだ画像再構成法を提案する．実験では収集カウント数および投影数を変化させ，単純な構造のファントムと頭部ファントム 2 種類を使用した．画像再構成法には TV-EM 法，modified-BSREM 法および提案法を用い，有効性を検討した．最適なパラメータを経験的に選択した従来法と比較して，提案法の NRMSE は同等以上の結果を示し，臨床応用の容易さおよび有用性が示唆された．

キーワード：係数自動制御，SPECT 画像再構成，TV 正則化，被写体の構造的複雑さ

1. はじめに

2014 年に PET (Positron emission tomography) 商用機に初めて正則化付き画像再構成法である BSREM (block sequential regularized expectation maximization) 法が搭載され，最適な正則化の係数値を検討する研究が盛んに行われている［1,2］．SPECT (Single photon emission computed tomography) では，2022 年に BSREM 法が商用機に搭載され，今後同様な研究が盛んになると予測される．しかし臨床において，PET と比較して SPECT では対象の部位や検査によって投影数やカウント数，マトリクスサイズ等の撮像条件が大きく変化するため，全ての検査で最適な係数値を決定するのは煩雑で難しい．そこで我々は先行研究において，収集条件および正則化項のとり得る値を考慮し係数値を自動制御する正則化付き画像再構成法である RAREM (row-action type regularized expectation maximization) 法を提案した［3］．しかし，被写体の構造的複雑さについては考慮されていないため適応は限定的であった．本研究では，RAREM 法の係数値自動制御機構に新たに被写体の構造的複雑さを考慮する項を組み込んだ画像再構成法を提案する．

2. 方法

本研究で提案する cRAREM (complexity-RAREM) 法は，Sobel filter により更新画像のエッジを抽出した後，処理前後の画素値の総和の割合によって複雑さを評価した項を正則化項の係数値に組み込んだ画像再構成法である．cRAREM 法の逐次式を以下に示す．

$$x_j^{k,q+1} = x_j^{k,q} + \lambda_{k,q} x_j^{k,q} \left\{ \sum_{i \in S_q} C_{ij} \left(\frac{y_i}{\sum_{n=1}^{N^2} C_{in} x_n^{k,q}} - 1 \right) - \eta_k \frac{\partial}{\partial x_j} U(\boldsymbol{x}) \right\} \quad (1)$$

$$\lambda_{k,q} = \frac{1}{1 + \log_{10} \frac{M_{Nq}}{M}} \times \frac{\beta_0}{\beta_0 + q + \gamma k M} \times \frac{1}{1 + \eta_k V_{max}} \quad (2)$$

$$\eta_k = \frac{1}{E_k} \times \left\{ 0.01 \times \left(1 + \log_{10} \frac{M_{Nq}}{M} \right) + 0.0625 \times \log_{10} \left(\frac{N \times 10^5}{T} \right) \right\} \quad (3)$$

$$E_k = 100 \times \frac{\sigma_{x_f^k}}{\sigma_{x^k}} \quad (4)$$

ここで，x は放射能濃度，k は main iteration 数，q は sub iteration 数，λ は緩和係数，C は検出確率，N はマトリクスを正方としたときの一辺の数，y は投影データ，S_q は q 回目の sub iteration に含まれる全ての要素であり subset 数は最大に設定した．β_0 は λ の下げ幅を決めるパラメータであり収集条件によって近似することができる［4］．η は正則化の係数値，$U(x)$ は正則化項であり，正則化項には TV (total variation) を用いた．また，TV における $\partial U(\boldsymbol{x})/\partial x_j$ のとり得る最大値 V_{max} は $2+\sqrt{2}$ と求められ，V_{max} の項により RAREM 法と同様に負値の発生を回避できる［3］．M_{Nq} は再構成画像のナイキスト周波数を満たす最小の総投影数，T は総カウント数である．ただ

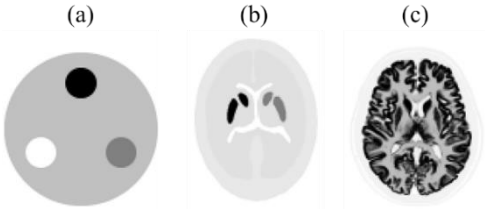


図 1 各ファントムの概略図．(a) 3D-MAC phantom, (b) IB-20 Advanced, (c) BrainWeb (https://brainweb.bic.mni.mcgill.ca/brainweb/) より作成した数値ファントム．

し，$N \times 10^5 < T$ のとき $N \times 10^5/T = 1$，$M_{Nq} < M$ のとき $M_{Nq}/M = 1$ とする．E_k は被写体の構造的複雑さを考慮する項であり，k 回目の更新画像の画素値の総和 σ_{x^k} と，更新画像に Gaussian filter をかけた後に Sobel filter をかけた画像 $\boldsymbol{x}_f^k$ の画素値の絶対値の総和 $\sigma_{x_f^k}$ の割合で計算される．

3 種類の数値ファントム (図 1) から，マトリクスサイズ 128 ×128，総投影数 12~120 で投影データを作成し，1 投影あたりのカウント数を 2.5×10^3~5.0×10^4 count/view でポアソンノイズを付加した．画像再構成法の比較には TV-EM 法, modified-BSREM 法を用い，どちらも最良の NRMSE (normalized root mean square error) を示す係数値を用いて再構成した［5,6］．

3. 結果と考察

総投影数 60, 10^4 count/view における再構成画像および main iteration 毎の E_k をそれぞれ図 2，3 に示す．ほぼすべての撮像条件において，cRAREM 法は従来の再構成法と同等の NRMSE を示した．また E_k は，4 つの円のみで構成されている 3D-MAC phantom において最小値を示した一方で，多数の様々な形状をした領域によって構成される BrainWeb phantom では最大値を示した．そのため，cRAREM 法の正則化項の係数値 η_k は構造が単純なほど大きく，構造が複雑なほど小さくなるように制御し，異なる被写体においても良好な再構成画像を得ることができた．しかし，IB-20 Advanced ではざらつきが見られ，BrainWeb phantom では一部不明瞭な領域があり，両者の E_k に大きな差がなかった． E_k の評価方法を改良することでさらに良好な結果を得ることができると考えられる．

4. まとめ

被写体の構造的複雑さを考慮した項を組み込むことで正則化項の係数値を自動調節し，最適な係数値探索なしに様々な撮像条件および構造物への適用の可能性が示された．

謝辞

本研究に際し，東邦大学医療センター大橋病院放射線部の皆様のご協力に深く感謝いたします．

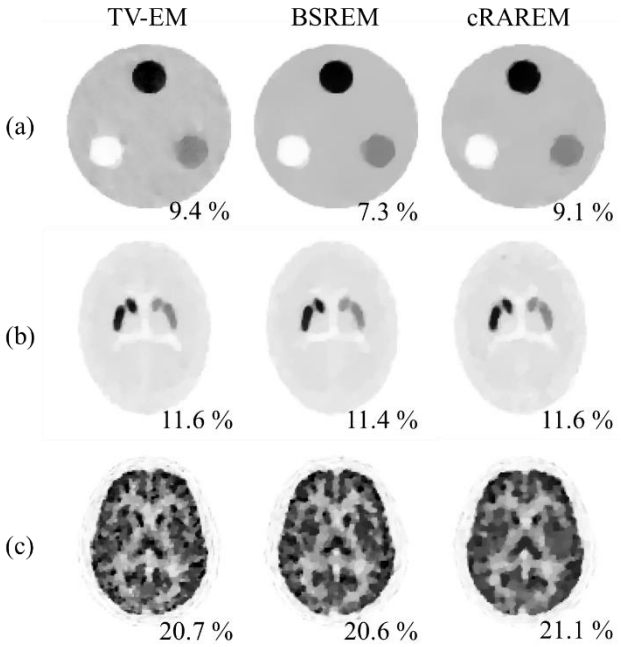


図 2 総投影数 60, 10^4 count/view における再構成画像．それぞれの再構成画像の右下に NRMSE [%]を示す．

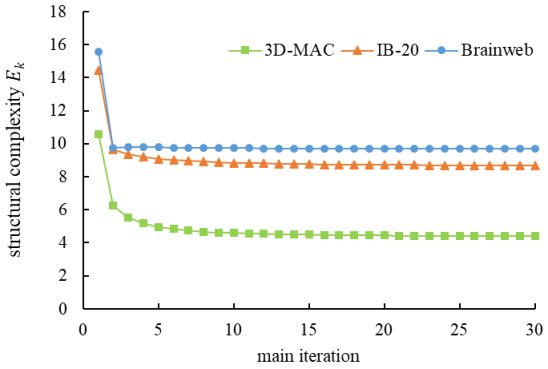


図 3 総投影数 60, 10^4 count/view における構造的複雑さの項 E_k の繰り返しに対する変化．

利益相反の有無

筆頭著者および共著者全員が利益相反はない．

文　献

［1］ Ross S : Q.Clear, white paper. GE Health care, 1-9, 2014

［2］ 三輪建太，宮司典司，山尾天翔，他：教育講座-核医学装置と画像再構成法の進歩- PET 編 5.PET における Bayesian penalized likelihood 画像再構成法に関する研究．日放技学誌 79 (5): 477-487, 2023

［3］ 皆川智哉，堀拳輔，橋本雄幸：少数投影 SPECT における正則化付き係数自動制御 Row-action 型逐次近似画像再構成法． JAMIT 若手医用画像工学シンポジウム (SAMIT2023) 抄録集 18-19, 2023

［4］ 北村圭司，高橋重和：DRAMA を応用した PET トランスミッション画像再構成． 第 23 回日本医用画像工学会大会抄録集．1-10, 2004

［5］ V Y Panin, G L Zeng, G T Gullberg : Total variation regularized EM algorithm. IEEE Trans Nucl Sci. 46: 2202-2210, 1999

［6］ S Ahn, J Fessler : Globally convergent image reconstruction for emission tomography using relaxed ordered subsets algorithms. IEEE Trans Med Imag. 22: 613-626, 2003

ダイクストラ型スプリッティング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]，尾内　康臣[*2]
[*1] 浜松ホトニクス株式会社中央研究所
[*2] 浜松医科大学光医学総合研究所

List Mode PET Image Reconstruction Using Dykstra-Like Splitting

Kibo OTE[*1]，Fumio HASHIMOTO[*1], Yuya ONISHI[*1], Yasuomi OUCHI[*2]
[*1] *Hamamatsu Photonics K.K.*
[*2] *Hamamatsu University School of Medicine*

要旨：Positron emission tomography（PET）のブロック反復法を収束させるには，緩和パラメータの制御が必要となる．しかし，リストモード PET 再構成のための緩和パラメータの自動決定法は明らかとなっておらず，別の枠組みが必要とされている．本研究では，ダイクストラ型スプリッティングを用いたリストモード最尤 PET 再構成（LM-MLDS）を提案する．LM-MLDS は，初期画像からの距離をペナルティ項として目的関数に追加することにより，リストモードのブロック反復法を収束させる．LM-MLDS は，シミュレーションにおいて他のブロック反復法より良好なノイズとコントラストのトレードオフ曲線を与え，臨床データにおいては体軸視野の端にある偽のホットスポットを抑制した．これらの結果は，近接スプリッティングが，微分不可能な関数を最適化するためだけではなく，リストモード PET 再構成のブロック反復法を構築するためにも有用な枠組みであることを示唆した．
キーワード：ダイクストラ型スプリッティング，画像再構成，リストモード，positron emission tomography (PET)

1. はじめに

Ordered subset expectation maximization (OSEM)などのブロック反復法は，PET の画像再構成に広く用いられている．OSEM はデータに統計雑音が含まれる場合，収束しないため，Row action maximum likelihood algorithm (RAMLA) や dynamic RAMLA (DRAMA)が開発された[1]．RAMLA や DRAMA は緩和係数を制御することで OSEM を収束させるが，高速な収束には最適な緩和係数制御が必須となる．サイノグラムベースの DRAMA では，各サブセットからの雑音の伝搬を均衡させるという直観から最適な緩和係数制御が導かれた[1]．一方，リストデータから画像を再構成する list-mode DRAMA（LM-DRAMA）では，最適な緩和係数制御はいまだ解明されていない．最先端の PET 装置では Line-of-response（LOR）の数がイベント数より多くなる傾向があり，リストモード再構成がよく用いられる．よって，緩和係数の制御を必要としない収束性を持ったリストモードのブロック反復法が求められている．

近年，信号，画像処理の分野において，近接スプリッティングと呼ばれる枠組みが広く用いられている[2]．近接スプリッティングは，主に total variation（TV）などの微分できない関数を最適化するために用いられるが，収束性を持ったブロック反復法の構築にも用いることが可能である．

本研究では，ダイクストラ型スプリッティングを用いたリストモード最尤 PET 再構成（LM-MLDS）を提案する．LM-MLDS は初期画像からの距離を罰則項として目的関数に追加することで，緩和係数の制御なしに，リストモードのブロック反復法を収束させる．

2. 方法

1）提案手法

LM-MLDS は，参照画像rからの距離を罰則項としてブロック最適化問題に追加する．

$$\min_{x\in\mathbb{R}_+^J} \frac{1}{2\alpha}\|x-r\|^2 + \sum_q -L_q(D|x), \tag{1}$$

ここで，xは被写体の画像，αはステップサイズ，$L_q(D|x)$はリストデータDのq番目のサブセットに対するリストモード対数尤度関数である．

LM-MLDS は，上記の最適化問題を以下のように解く．

$$x^{(0,0)} = r,\quad y_0^{(0)} = y_1^{(0)} = \cdots = y_{M-1}^{(0)} = 0, \tag{2}$$

$$x^{(k,q+1)} = \mathrm{prox}_{-\alpha L_q}\left(x^{(k,q)} + y_q^{(k)}\right)$$

$$= \underset{x\in\mathbb{R}_+^J}{\mathrm{argmin}}\left\{-L_q(D|x) + \frac{1}{2\alpha}\left\|x - \left(x^{(k.q)} + y_q^{(k)}\right)\right\|^2\right\}, \tag{3}$$

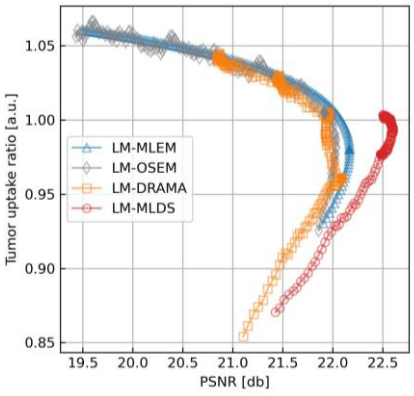


図 1　シミュレーションデータにおける腫瘍取り込み比（TR）と PSNR のトレードオフ曲線．

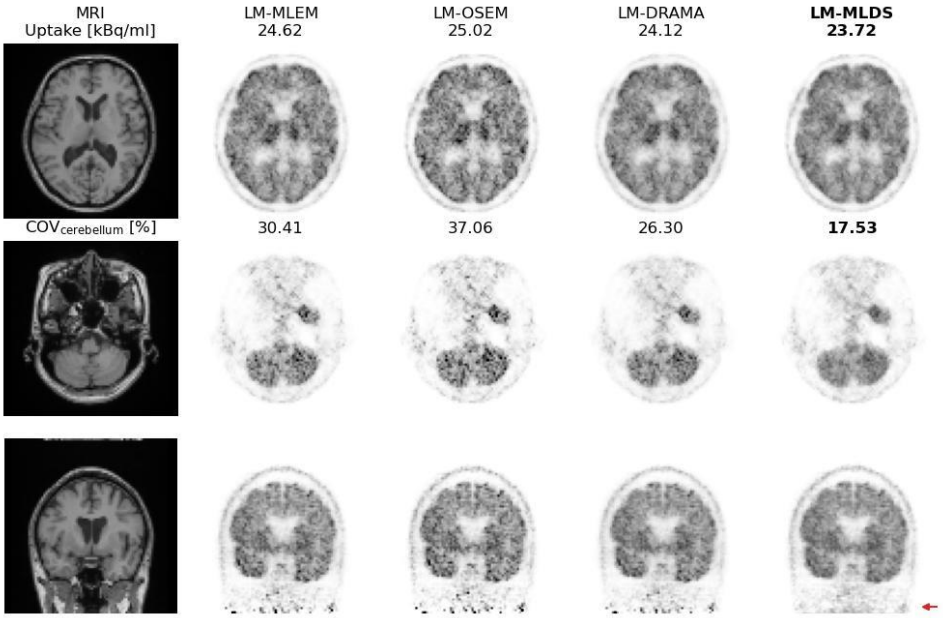


図 2　臨床データにおいて提案手法とその他の手法を用いて再構成された画像．左から，MRI，LM-MLEM，LM-OSEM，LM-DRAMA と LM-MLDS．視床への取り込みと小脳内の COV を示す．

$$y_q^{(k+1)} = x^{(k.q)} + y_q^{(k)} - x^{(k,q+1)}, \qquad (4)$$

ここで，$\mathrm{prox}_{-\alpha L_q}$は近接作用素，$y_q$は$q$番目のサブセットに対する双対変数である．(2) 式に示すように，参照画像rは初期画像$x^{(0,0)}$となる．LM-MLDS の性能は，初期画像の質に依存するため，2 段階のアプローチをとる．1 段階目は，均一な画像を初期画像として用い，2 段階目は 1 主反復後の画像を初期画像として用いる．

2）実験条件

4 層の depth-of-interaction（DOI）を持つ頭部用 PET 装置（Hamamatsu HITS-655000）をシミュレーションと臨床研究の両方に用いた．

シミュレーションデータは，腫瘍領域を 3 つ埋め込んだ数値脳ファントムを用いてモンテカルロシミュレーションにより生成された．Peak signal to noise ratio（PSNR），再構成画像とファントム画像の腫瘍内の平均画素値の比（Tumor uptake ratio: TR）を指標として算出した．

臨床データは，浜松医科大学の倫理委員会の承認のもと，視床に多く存在する$\alpha 7$ ニコチンアセチルコリン受容体のトレーサーである ^{11}C-MeQAA を用いて計測された．視床への取り込みと小脳内の変動係数（$\mathrm{COV_{cerebellum}}$）を指標として算出した．

3. 結果

図 1 にシミュレーションデータにおける list-mode maximum likelihood expectation maximization（LM-MLEM），LM-OSEM，LM-DRAMA と LM-MLDS の PSNR と TR のトレードオフ曲線を示す．LM-MLDS は他の手法より高い PSNR を与え，腫瘍取り込み比のオーバーシュートを抑制した，

図 2 に臨床データの再構成画像を示す．LM-MLDS は小脳を含む断層面（**図 2，2 行目**）において，他の手法より雑音の少ない画像を与えた．コロナル像に注目すると，LM-MLDS は体軸視野の端の偽のホットスポットを抑制した（**図 2, 赤矢印**）．これは，近接作用素に誘導されたガウシアンデノイジングによって，MLEM における雑音レベルの画素値への依存性が緩和されたためと考えられる．

4. まとめ

ダイクストラ型スプリッティングを用いたリストモード PET 再構成のためのブロック反復法である LM-MLDS を提案した．LM-MLDS は，シミュレーションにおいてより良い PSNR と TR のトレードオフ曲線を与え，臨床において体軸視野端の偽のホットスポットを抑制した．これらの結果は，LM-MLDS が最先端の PET 装置のリストモードブロック反復法として，LM-OSEM や LM-DRAMA を置き換えられることを示唆した．

謝辞

本研究は JSPS 科研費 JP22K07762 の助成を受けたものです．

利益相反の有無　なし

文　献

［1］Tanaka E., Kudo H.: Subset-dependent relaxation in block iterative algorithms for image reconstruction in emission tomography. Phys Med Biol 10: 1405–1422, 2003

［2］Combettes P. L., Pesquet J.-C.: Proximal splitting methods in signal processing. In Fixed-Point Algorithms for Inverse Problems in Science and Engineering. Bauschke H. H. et al. eds. Springer Optimization and Its Application Vol. 49. Springer, New York NY 2011, pp. 185–212

Dykstra 型 Splitting を用いた統計的 PET 画像再構成法のリストモードデータへの拡張とオンライン PET 再構成の提案

工藤 博幸[*1,*2], [*1] 筑波大学システム情報系, [*2] 東北大学国際放射光 SRIS

Extension of Statistical PET Image Reconstruction Method Using Dykstra-Like Splitting to List-Mode Data and Proposal of Online PET Reconstruction

Hiroyuki Kudo[*1,*2], [*1] *University of Tsukuba*, [*2] *Tohoku University*

要旨： 本論文では，筆者らが既に構築したヒストグラムモード PET データに対する Dykstra 型 Splitting を用いた画像再構成法 [4),5)] をリストモードデータに拡張する．また，PET 画像再構成の新しい考え方として，「オンライン再構成」の概念と手法を提案する．
キーワード： PET，画像再構成，リストモード，Dykstra 型 Splitting，オンライン再構成

1. はじめに

PETの画像再構成では, 計算量を削減するためOSEM法などの対数尤度を部分評価関数の和に分解して部分評価関数ごとに画像更新を行うブロック反復（Row-Action）型再構成法が用いられる．しかし，評価関数の厳密な最小解に収束せず雑音特性が悪いLimit Cycleに収束する問題点がある．この問題点を解決する方法として，1) 画像更新量のステップサイズをゼロに近づけながら反復を行うステップサイズ制御[1),2)]，2) 主双対問題の形に再定式化して双対空間の座標降下法で解く手法[3)-6)]が存在する．後者は筆者らが2004年に初めて提案したが[3)]近年この方向性の研究が世界的によく行われており[6)]，筆者らも後者の中で有効なDykstra型Splittingと呼ばれる数学的枠組みを用いたPET再構成法を既に提案している[4),5)]．PETの測定データは，LORごとの計数値を記録するヒストグラムモードと各光子が測定されたLORを記録するリストモードの2つの表現方法が知られ，光子数と比較してLOR数が多い3D収集・TOF収集・Dynamic収集などの場合にはリストモードが効率的であり，リストモードデータから直接対数尤度を最小化する再構成法が研究されている．本論文では，ヒストグラムモードに対して構築されたDykstra型Splittingを用いた再構成法をリストモードに拡張することを行った．拡張は数学的に自明ではなく，幾つかのキーアイデアが必要であった. 従来の主問題を直接解く再構成法では, ステップサイズ制御や雑音のバランスを取る部分評価関数への分割がないと上手く動作しないが，Dykstra型Splittingに基づく再構成法ではこれらが不要で従来のリストモード再構成法と比較して上手く収束することが明らかになった．また，画像平滑化を行う正則化項に用いた場合への拡張を行った．更に，Dykstra型Splittingの高収束性を活かして，データ収集と同時に並行して再構成処理を行いデータ収集後直ちに画像を提示できる新しい考え方の「PETオンライン再構成」を提案して，数値実験で有望な見通しを得た．

2. 提案手法

PETリストモード画像再構成の評価関数は次式で表される．

$$f(\mathbf{x}) = \sum_{i=1}^{I} \mathbf{a}_i^{\mathrm{T}}\boldsymbol{x} - \sum_{t=1}^{T} \log(\mathbf{a}_{i(t)}^{\mathrm{T}}\boldsymbol{x}) + \beta R(\boldsymbol{x}) \quad (1)$$

ただし，$\mathbf{x} = (x_1, \cdots, x_J)^{\mathrm{T}}$は画像ベクトル，$i(t)$は$t$番目のイベントが検出されたLOR，$\mathbf{a}_i$は$i$番目のLORに対応するシステム行列の行，$R(\mathbf{x})$は画像平滑化を行う正則化項である．本研究ではブロック反復型再構成法を用いるため，式(1)を部分評価関数の和の形に分解しておく．

$$\begin{aligned} &f(\mathbf{x}) = \textstyle\sum_{l=1}^{L+1} f_l(\mathbf{x}) \\ &f_l(\mathbf{x}) = (\textstyle\sum_{i=1}^{I} \mathbf{a}_i^{\mathrm{T}}\boldsymbol{x})/L - \sum_{t\in S_l} \log(\mathbf{a}_{i(t)}^{\mathrm{T}}\boldsymbol{x}) \ (l = 1,2,\cdots,L) \\ &f_{L+1}(\mathbf{x}) = \beta R(\mathbf{x}) \end{aligned} \quad (2)$$

ただし, サブセット分割は次式のように単純に時間方向にイベントをT/L個ずつ区切ることで行う．

$$S_l = \{(l-1)T/L + 1, \cdots, lT/L\} \ (l = 1,2,\cdots,L) \quad (3)$$

式(2)を最小化する反復法を構成するため，筆者らが既にヒストグラムモードに対して提案したDykstra型Splittingの数学的枠組みを用いる[4),5)]．この手法は，元々は式(2)に摂動項を加えた次式を最小化する問題を解く主双対反復法である．

$$f(\mathbf{x}) \equiv ||\mathbf{x} - \mathbf{m}||/(2\alpha) + \textstyle\sum_{l=1}^{L+1} f_l(\mathbf{x}) \quad (4)$$

しかし, 摂動項は真の評価関数に含まれず画質や収束性に悪影響を及ぼし抜く必要があり, それを実現する外挿（Extrapolation）の処理を組み込んだ手法を提案してDLPM法（Dykstra-Like Splitting with Proximal Minimization）と名付けた[4),5),7)]．本論文でもDLPM法を用いるが，そのアルゴリズムをAlgorithm 1にまとめて示す．Algorithm 1においてD_l は部分評価関数$\alpha f_l(\boldsymbol{x})$に対応する双対変数の定義域で次式から定まる．

$$D_l \equiv \left\{\mathbf{y}_l \middle| \max_{\mathbf{x}} F(\mathbf{x}, \mathbf{y}_l) \equiv \mathbf{y}_l^{\mathrm{T}}\mathbf{x} - \alpha f_l(\mathbf{x}) < \infty\right\} \ (l = 1,2,\cdots,L) \quad (5)$$

双対変数$\mathbf{y}_l$は見かけ上画像次元であるが, 式(5)から次式で表される低次元ベクトル$\boldsymbol{\mu}_l = (\mu_{(l-1)T/L+1}, \cdots, \mu_{lT/L})^{\mathrm{T}}$（$T/L$次元）である[4),5)]．

$$\begin{aligned} &\mathbf{y}_l = \mathbf{c} + \alpha A_l^{\mathrm{T}}\boldsymbol{\mu}_l = \mathbf{c} + \alpha \textstyle\sum_{t\in S_l} \mathbf{a}_{i(t)}\,\mu_t, \ \mu_t < 0 \ (t \in S_l) \\ &\mathbf{c} = ((\alpha \textstyle\sum_{i=1}^{I} a_{i1})/L, \cdots, \alpha(\textstyle\sum_{i=1}^{I} a_{iJ})/L)^{\mathrm{T}} \end{aligned} \quad (6)$$

上記の双対変数の低次元化を行いAlgorithm 1を式(2)の評価関数に適用すると，Algorithm 2が得られる．Algorithm 2は（※マークされた）近接写像とそれに続く双対変数更新の計算が陽な形でないため実装可能でなく, 以降ではその具体的な計算式を導出する．まず，※部分の計算はMoreau Identityから主変数$\mathbf{x}$と

双対変数$\boldsymbol{\mu}_l$の更新順番を交換した次式と等価である．

$$\boldsymbol{\mu}_l^{(k+1)} = \mathrm{argmin}_{\boldsymbol{\mu}_l} Q(\boldsymbol{\mu}_l)$$
$$Q(\boldsymbol{\mu}_l) = -\alpha \textstyle\sum_{t\in S_l} \log(-\mu_t) + ||\alpha A_l^{\mathrm{T}} \boldsymbol{\mu}_l - (\mathbf{x}^{(k,l)} + \alpha A_l^{\mathrm{T}} \boldsymbol{\mu}_l^{(k)})||^2/2$$
$$\mathbf{x}^{(k,l+1)} = [\mathbf{x}^{(k,l)} + \alpha A_l^{\mathrm{T}}(\boldsymbol{\mu}_l^{(k)} - \boldsymbol{\mu}_l^{(k+1)}) + \mathbf{z}^{(k,l+1)}]^+ \quad (7)$$

式(7)は行列A_l^{T}が含まれ簡単に最小化できないので，$Q(\boldsymbol{\mu}_l)$の最後の2乗項にMajorization Minimization（MM）を適用してseparableな代理関数$Q(\boldsymbol{\mu}_l; \boldsymbol{\mu}_l^{(k)})$に置き換えて最小化する．最終的な更新式は次式であり，ヒストグラムモードの場合[5]とほとんど同じ計算式である（イベントtごとに別々に計算可能）．

$$\mu_t^{(k+1)} = \left(\bar{p} - \sqrt{\bar{p}^2 + \bar{q}}\right)/(2\alpha d_t),\ (t \in S_l)$$
$$\bar{p} = \mathbf{a}_{i(t)}^{\mathrm{T}} \mathbf{x}^{(k,l)} + \alpha d_t \mu_t^{(k)}, \bar{q} = 4\alpha d_t$$
$$\mathbf{x}^{(k,l+1)} = [\mathbf{x}^{(k,l)} + \alpha \textstyle\sum_{t\in S_l} \mathbf{a}_{i(t)} \left(\mu_t^{(k)} - \mu_t^{(k+1)}\right) + \mathbf{z}^{(k,l+1)}]^+$$
$$= [\mathbf{x}^{(k,l)} + \alpha A_l^{\mathrm{T}}(\boldsymbol{\mu}_l^{(k)} - \boldsymbol{\mu}_l^{(k+1)}) + \mathbf{z}^{(k,l+1)}]^+ \quad (8)$$

ただし，d_tはMMで決まる2乗項の係数である．Algorithm 2の※部分を式(8)で置き換えたものが提案手法である．双対空間でMMを適用することで，双対関数が必ず増えるように更新されるDykstra型Splittingの収束性に必要な性質は保持される．

本論文のもう一つの新規性として，「オンライン再構成」と命名したPET再構成の新しい考え方を提案する．現在のPET装置では，画像再構成の計算は測定が終了してから開始される．これに対して，リストモードデータを利用して，データ収集と並行して再構成の計算を行い，全リストモードデータの収集が終了した時点で直ちに画像を提示するのがオンライン再構成である．具体的には，再構成の計算は以下の手順で行う．

[Step 1] サブセットS_1のデータが揃ったら，$\{S_1\}$のデータで一反復の計算を行い画像$\mathbf{x}$の更新．□

[Step 2] サブセットS_2のデータが揃ったら，$\{S_1, S_2\}$のデータで一反復の計算を行い画像$\mathbf{x}$の更新．□

……

[Step L] サブセットS_Lのデータが揃ったら，$\{S_1, S_2, \cdots, S_L\}$のデータで一反復の計算を行い画像$\mathbf{x}$の更新．画像を提示．□

オンライン再構成を実現するには高収束性の再構成法が必要であり，Dykstra型Splittingを用いた反復法を用いる．特に注意すべき点として以下がある．雑音のバランスが取れた再構成画像を得るには，上記各Stepの終了時に収集が済んでいる過去のサブセットは同じ回数だけ用いて画像修正が行われている必要がある．例えば，[Step l]の計算の終了時には過去の全ステップ[Step 1] ～[Step l]において$S_1, S_2, \cdots, S_l$の各データが使用された回数は等しくなくてはならない．この条件をSubset balanceと呼ぶ．Subset balanceが成り立つデータアクセス順序は自明でないが，以下のものを提案する．また，各Stepでサブセットの選択を行う際には，順番は工藤らがDykstra型Splittingに対して提案したpermutation型のランダムアクセスを用いる[7]．

[Step 1] 画像修正の回数を1回として，S_1のデータを1回選び画像更新．□

[Step 2] 画像修正の回数を3回として，S_1のデータを1回，S_2のデータを2回選び画像更新．□

……

[Step L] 画像修正の回数を$2L-1$回として，$S_1, S_2, \cdots, S_{L-1}$の各データを1回選び更新，$S_L$のデータを$L$回選び画像更新．□

数値実験の結果は発表で紹介する．**利益相反の有無**：なし

文　献

[1] Dong J, Kudo H: Accelerated algorithm for compressed sensing using nonlinear sparsifying transform in CT image reconstruction. Med Imag Tech 35, 63-73, 2017

[2] Tanaka E, Kudo H: Subset-dependent relaxation in block-iterative algorithms for image reconstruction in emission tomography. Phys Med Biol 48: 1405-1422, 2003

[3] 李，工藤: 非線形計画問題の双対性を用いた統計的PET画像再構成.電子情報通信学会論文誌 J87-D-II: 62-70, 2004

[4] Kim H, Sadakata K, Kudo H: Unified framework to construct fast row-action-type iterative CT reconstruction methods with total variation using multi proximal splitting. Proc ICBIP2021, 65-71, 2021

[5] Sadakata K, Kim H, Kudo H: Unified approach to fast convergent row-action-type iterative methods for PET image reconstruction using multi proximal splitting. Journal of Image and Graphics 10: 82-87, 2022

[6] Chambolle A, Ehrhardt MJ, Richtárik P, Schönlieb C-B: Stochastic primal-dual hybrid gradient algorithm with arbitrary sampling and imaging applications. SIAM J Opt 28: 2783-2808, 2018

[7] 工藤，金，藤井: 確率的Dykstra型スプリッティングによる統一的なブロック反復型画像再構成法の構成：CTとPETへの応用, JAMIT2023. 2023

Algorithm 1 (DLPMアルゴリズム)

$\vec{x}^{(0,1)} \geq 0,\ \vec{y}_l^{(0)} \in D_l\ (l = 1,2,\cdots,L),\ \vec{y}_{L+1}^{(0)} \in \mathrm{R}^J,\ \vec{z}^{(0,1)} = -(\sum_{l=1}^{L+1} \vec{y}_l^{(0)})/(L+1)$

$k = 0,1,2,\cdots$ Main iteration

$l = 1,2,\cdots,L+1$ Sub iteration

$\bar{\vec{x}} = \mathrm{prox}_{\alpha f_l(\vec{x})}(\vec{x}^{(k,l)} + \vec{y}_l^{(k)}) \equiv \min_{\vec{x}}(\frac{1}{2\alpha}\left\|\vec{x} - (\vec{x}^{(k,l)} + \vec{y}_l^{(k)})\right\|^2 + f_l(\vec{x}))$

$\vec{y}_l^{(k+1)} = \vec{y}_l^{(k)} + \vec{x}^{(k,l)} - \bar{\vec{x}}$ 双対変数update　主変数update

$\vec{z}^{(k,l+1)} = \vec{z}^{(k,l)} + (\bar{\vec{x}} - \vec{x}^{(k,l)})/(L+1)\quad \vec{x}^{(k,l+1)} = [\bar{\vec{x}} + \vec{z}^{(k,l+1)}]^+$

$\vec{x}^{(k+1,1)} = \vec{x}^{(k,L+2)}\quad \vec{z}^{(k+1,1)} = \vec{z}^{(k,L+2)}$　外挿（摂動項を抜く）

Algorithm 2 (リストモードDLPMアルゴリズム)

$\vec{x}^{(0,1)} \geq 0,\ \vec{\mu}_l^{(0)} = (\underbrace{\gamma,\cdots,\gamma}_{T/L})^{\mathrm{T}}\ (l = 1,\cdots,L),\ \vec{y}^{(0)} = 0,\ \vec{z}^{(0)} = -\sum_{l=1}^{L}(\vec{c} + \alpha A_l^{\mathrm{T}} \vec{\mu}_l^{(0)})/(L+1)$　$\gamma < 0$

$k = 0,1,2,\cdots$

$l = 1,2,\cdots,L$　データ項の処理

$\bar{\vec{x}} = \mathrm{prox}_{\alpha f_l(\vec{x})}(\vec{x}^{(k,l)} + \alpha A_l^{\mathrm{T}} \vec{\mu}_l^{(k)})$　主変数update　（※）本文に具体的な更新式

$= \min_{\vec{x}}[\frac{1}{2\alpha}\left\|\vec{x} - (\vec{x}^{(k,l)} + \vec{c} + \alpha A_l^{\mathrm{T}} \vec{\mu}_l^{(k)})\right\|^2 + \vec{c}^{\mathrm{T}}\vec{x}/\alpha - \sum_{t\in S_l} \log(\vec{a}_{i(t)}^{\mathrm{T}}\vec{x})]$

$\alpha A_l^{\mathrm{T}} \vec{\mu}_l^{(k+1)} = \alpha A_l^{\mathrm{T}} \vec{\mu}_l^{(k)} + \vec{x}^{(k,l)} - \bar{\vec{x}}$ 双対変数update

$\vec{z}^{(k,l+1)} = \vec{z}^{(k,l)} + (\bar{\vec{x}} - \vec{x}^{(k,l)})/(L+1)\quad \vec{x}^{(k,l+1)} = [\bar{\vec{x}} + \vec{z}^{(k,l+1)}]^+$ 外挿

$\bar{\vec{x}} = \mathrm{prox}_{\alpha\beta R(\vec{x})}(\vec{x}^{(k,L+1)} + \vec{y}^{(k)}) \equiv \min_{\vec{x}}(\frac{1}{2\alpha}\left\|\vec{x} - (\vec{x}^{(k,L+1)} + \vec{y}^{(k)})\right\|^2 + \beta R(\vec{x}))$

$\vec{y}^{(k+1)} = \vec{y}^{(k)} + \vec{x}^{(k,L+1)} - \bar{\vec{x}}$　正則化項の処理

$\vec{z}^{(k,L+2)} = \vec{z}^{(k,L+1)} + (\bar{\vec{x}} - \vec{x}^{(k,L+1)})/(L+1)\quad \vec{x}^{(k,L+2)} = [\bar{\vec{x}} + \vec{z}^{(k,L+2)}]^+$

$\vec{x}^{(k+1,1)} = \vec{x}^{(k,L+2)}\quad \vec{z}^{(k+1,1)} = \vec{z}^{(k,L+2)}$

主双対ブロック反復勾配法の理論構築と統計的画像再構成への応用

工藤 博幸[*1,*2], [*1] 筑波大学システム情報系, [*2] 東北大学国際放射光 SRIS

Development of Theory of Primal-Dual Block-Iterative Gradient Method and its Applications to Statistical Image Reconstruction

Hiroyuki Kudo[*1,*2], [*1] *University of Tsukuba*, [*2] *Tohoku University*

要旨： 本論文では，Dykstra 型 Splitting[1),2)]と類似した構造の反復法で部分評価関数の勾配計算のみで済む新しい数学的枠組みの「主双対ブロック反復勾配法」を提案する．その数学的導出を行い，PET と CT の統計的画像再構成への応用について述べる．

キーワード： CT，PET，画像再構成，ブロック反復，勾配法，Dykstra 型 Splitting,

1. はじめに

PETやCTの統計的画像再構成は, 対数尤度からなるデータ項とTVなど画像平滑化を行う正則化項の和を反復法で最小化することにより行われる. 反復法の収束が遅い問題点を解決するために, 評価関数を部分評価関数の和に分解して部分評価関数ごとに画像更新を行う構造のブロック反復（Row-Action）型反復法がよく用いられるが, 真の評価関数の最小解と異なる雑音伝搬が悪いLimit Cycleに収束する問題点がある．この問題点を解決するため，1) 画像更新量のステップサイズをゼロに近づけながら反復を行うステップサイズ制御，2) 主双対問題の形に定式化して双対空間の座標降下法で解く方法[1),2)]，の2つが存在する．特に，後者は固定ステップサイズでLimit Cycle問題を回避でき有効である．発表者らは，既に後者の中でも有効なDykstra型Splittingを用いた再構成法[1),2)]を提案しているが, 問題点として部分評価関数の近接写像計算が必要なことがあげられる．近接写像計算は勾配法の計算より複雑であり，1) 放射型CT対数尤度では近接写像が複雑な形になりアルゴリズムの見通しが悪い，2) 透過型CT対数尤度では近接写像が陽な形で計算できない，などの問題点がある．本論文では，主双対問題を解くDykstra型Splittingと類似した構造の反復法で部分評価関数の（前処理なし・ありの）勾配計算のみで済む新手法の「主双対ブロック反復勾配法」を提案し,その数学的導出を行った. そして, この枠組みをPET及びCTに適用した具体的なアルゴリズムを示し, 勾配法の計算が基本であるため従来の再構成法と類似した外観で見通しがよく実装しやすく，Dykstra型Splittingと同様に高速に収束しLimit Cycle問題を回避できることを示した．非常に上手く動作しLimit Cycle問題がない，理論的収束性，実装が勾配法ベースで簡単など，欠点がない手法である．

2. 提案手法

PETやCTの統計的画像再構成では, 以下の評価関数を最小化することで再構成を行う．

$$f(\mathbf{x}) = \sum_{i=1}^{I} h_i(\mathbf{a}_i^{\mathrm{T}}\mathbf{x}) + \beta R(\mathbf{x}) \quad (1)$$

ただし，$\mathbf{x} = (x_1, \cdots, x_J)^{\mathrm{T}}$は画像ベクトル，$h_i(\cdot)(i = 1,2,\cdots,I)$は雑音の統計的性質から決まる非線形関数，$\mathbf{a}_i$はシステム行列の$i$番目の行，$R(\mathbf{x})$は画像平滑化を行う正則化項である．表1に様々なノイズモデルに対する$h_i(\cdot)$の式をまとめて示す. 本論文ではRow-Action型再構成法を用いるため，式(1)を部分評価関数の和の形に分解しておく．

$$f(\mathbf{x}) = \sum_{i=1}^{I+1} f_i(\mathbf{x})$$
$$f_i(\mathbf{x}) = h_i(\mathbf{a}_i^{\mathrm{T}}\mathbf{x})\ (i = 1,2,\cdots,I), f_{I+1}(\mathbf{x}) = \beta R(\mathbf{x}) \quad (2)$$

式(2)を最小化する反復法を構成する数学的枠組みとして，筆者らはDykstra型Splittingを提案した[1),2)]．元々は，本手法は式(2)に摂動項を加えた次式を最小化する問題を解く主双対反復法である．

$$f(\mathbf{x}) = ||\mathbf{x} - \mathbf{m}||/(2\alpha) + \sum_{i=1}^{I+1} f_i(\mathbf{x}) \quad (3)$$

しかし, 摂動項は真の評価関数に含まれず画質や収束性に悪影響を及ぼし抜く必要があり, それを実現する外挿（Extrapolation）を組み込んだ手法を提案してDLPM法（Dykstra-Like Splitting with Proximal Minimization）と名付けた[1),2)]．DLPM法を式(2)の最小化に適用した際のアルゴリズムをAlgorithm 1にまとめて示す．ただし，Algorithm 1においてD_i は部分評価関数$\alpha f_i(\boldsymbol{x})$に対応する双対変数の定義域で次式から定まる．

$$D_i \equiv \left\{\mathbf{y}_i \middle| \max_{\mathbf{x}} F(\mathbf{x}, \mathbf{y}_i) \equiv \mathbf{y}_i^{\mathrm{T}}\mathbf{x} - \alpha f_i(\mathbf{x}) < \infty\right\}(i = 1,2,\cdots,I) \quad (4)$$

Dykstra型Splittingは実質的に非常に上手く動作しLimit Cycleを回避して最適解に高速に収束するが，問題点として（※でマークした箇所）でデータ項の部分評価関数$f_i(\cdot)(i = 1,2,-,I)$の近接写像計算が必要なことがあげられる．表1に様々な再構成問題に対する近接写像を計算した結果を示すが，透過型CT対数尤度では近接写像が解析的に計算不可能で，放射型CT対数尤度では複雑な見通しが悪い式になり通常の再構成法との乖離が大きい．もし，近接写像計算を勾配法の画像更新に置き換えることができれば，この問題は解決されより多くの場面でDykstra型Splittingが簡便に使用可能になる．本論文では，Algorithm 1から出発してこの問題に応える新しい数学的枠組みを構築して，「主双対ブロック反復勾配法」と呼ぶ．その導出を以下で述べる．まず，（※でマークした）主変数$\mathbf{x}$の近接写像とそれに続く双対変数$\mathbf{y}_i$の更新を，Moreau Identityを用いて順番を次式のように交換する．

$$\mathbf{y}_i^{(k+1)} = \mathrm{argmin}_{\mathbf{y}}\left[q(\mathbf{y}) - \mathbf{y}^{\mathrm{T}}\mathbf{x}^{(k,i)} + ||\mathbf{y} - \mathbf{y}_i^{(k)}||^2/2\right]$$
$$q(\mathbf{y}) = \alpha f_i^*(\mathbf{y}/\alpha) \quad (5)$$

$\mathbf{x}^{(k,i+1)} = \mathrm{argmin}_{\mathbf{x}}[(\mathbf{y}_i^{(k+1)} - \mathbf{y}_i^{(k)} - \mathbf{z}^{(k,i+1)})^{\mathrm{T}}\mathbf{x} + ||\mathbf{x} - \mathbf{x}^{(k,i)}||^2/2$

ただし，$f_i^*(\cdot)$は$f_i(\cdot)$の共役関数である．式(5)の上式と下式は各々双対変数と主変数の近接写像計算であるが，近接項の距離を双対変数側は$q(\mathbf{y})$のBregman Divergence $D_q(\mathbf{y}, \mathbf{y}_i^{(k)})$ [3]に主変数側は重みつき距離に，次式のように置き換える．

$$\mathbf{y}_i^{(k+1)} = \mathrm{argmin}_{\mathbf{y}}\,[q(\mathbf{y}) - \left(\mathbf{y} - \mathbf{y}_i^{(k)}\right)^{\mathrm{T}}\mathbf{x}^{(k,i)} + \sigma D_q(\mathbf{y}, \mathbf{y}_i^{(k)})]$$
$$D_q\left(\mathbf{y}, \mathbf{y}_i^{(k)}\right) = q(\mathbf{y}) - q\left(\mathbf{y}_i^{(k)}\right) - \nabla q(\mathbf{y}_i^{(k)})^{\mathrm{T}}(\mathbf{y} - \mathbf{y}_i^{(k)}) \qquad (6)$$
$$\mathbf{x}^{(k,i+1)} = \mathrm{argmin}_{\mathbf{x}}[(\mathbf{y}_i^{(k+1)} - \mathbf{y}_i^{(k)} - \mathbf{z}^{(k,i+1)})^{\mathrm{T}}\mathbf{x} + ||\mathbf{x} - \mathbf{x}^{(k,i)}||_{\mathrm{P}}^2/2]$$

距離を変更する意図は，双対変数側は双対変数の更新を勾配計算にする目的であり，主変数側は主変数の更新を正定値対称行列P^{-1}で前処理可能にする目的である．式(6)の最小化は「Lanの Lemma」（文献3）p.70）を用いると解析的に計算でき，次式の結果が得られる．

$$\mathbf{y}_i^{(k+1)} = \alpha\nabla f_i(\mathbf{w}),\ \mathbf{w} = [\mathbf{x}^{(k,i)} + \sigma\nabla f_i^*(\mathbf{y}_i^{(k)})]/(1+\sigma)$$
$$\mathbf{x}^{(k,i+1)} = \mathbf{x}^{(k,i)} + \mathrm{P}^{-1}(\mathbf{y}_i^{(k)} - \mathbf{y}_i^{(k+1)} + \mathbf{z}^{(k,i+1)}) \qquad (7)$$

式(7)の上式の意味は双対変数$\mathbf{y}_i$が画像$\mathbf{x}^{(k,i)}$に摂動を加えた点$\mathbf{w}$で計算された勾配と解釈でき，これにより$\mathbf{y}_i$の更新は勾配計算のみで済むようになる．また，式(7)の下式は画像を前処理付き勾配方向に更新する式である．よって，Algorithm 1の（※でマークした箇所の）計算を式(7)で置き換えることで，近接写像計算が不要なアルゴリズムが得られる．更に，Dykstra型Splittingでは見かけ上データ項の部分評価関数に対応する双対変数$\mathbf{y}_i\ (i = 1,2,\cdots,I)$の次元は画像次元であるが，共役関数$f_i^*(\cdot)\ (i = 1,2,\cdots,I)$の定義域は式(4)であり，以下のように各$\mathbf{y}_i$をスカラー（1次元領域$D_i^{(\mu)}$）に低次元化できる[1),2)].

$$\mathbf{y}_i = \alpha\mathbf{a}_i\mu_i,\ \max_z F(z,\mu_i) \equiv \mu_i z - \alpha h_i(z) < \infty\ (i = 1,2,\cdots,I) \quad (8)$$

上述の近接写像から勾配への移行と双対変数の低次元化をAlgorithm 1に組み込んだ手法をAlgorithm 2にまとめて示す．

表1において近接写像では不都合な放射型CT対数尤度と透過型CT対数尤度の場合に，式(7)に対応する画像$\mathbf{x}$と双対変数μ_iの更新の具体的な式は以下のようになる．

[放射型CT対数尤度の場合]

$$\mathbf{x}^{(k,i+1)} = [\mathbf{x}^{(k,i)} - \alpha\mathrm{P}^{-1}\mathbf{a}_i(1 - \frac{b_i(1+\sigma)}{\mathbf{a}_i^{\mathrm{T}}\mathbf{x}^{(k,i)} + \frac{\sigma b_i}{1-\mu_i^{(k)}} + \epsilon} - \mu_i^{(k)}) + \mathbf{z}^{(k,i+1)}]^+$$

$$\mu_i^{(k+1)} = \mu_i^{(k)} + (1 - \frac{b_i(1+\sigma)}{\mathbf{a}_i^{\mathrm{T}}\mathbf{x}^{(k,i)} + \frac{\sigma b_i}{1-\mu_i^{(k)}} + \epsilon} - \mu_i^{(k)}) \qquad (9)$$

[透過型CT対数尤度の場合]

$$\mathbf{x}^{(k,i+1)} = [\mathbf{x}^{(k,i)} - \alpha\mathrm{P}^{-1}\mathbf{a}_i(b_i - d_i\exp[-(\mathbf{a}_i^{\mathrm{T}}\mathbf{x}^{(k,i)} + \sigma\log\frac{d_i}{b_i - \mu_i^{(k)}})/(1+\sigma)] - \mu_i^{(k)}) + \mathbf{z}^{(k,i+1)}]^+ \qquad (10)$$
$$\mu_i^{(k+1)} = \mu_i^{(k)} + (b_i - d_i\exp[-(\mathbf{a}_i^{\mathrm{T}}\mathbf{x}^{(k,i)} + \sigma\log\frac{d_i}{b_i - \mu_i^{(k)}})/(1+\sigma)] - \mu_i^{(k)})$$

いずれも部分評価関数$f_i(\cdot)$の勾配（に双対変数μ_iの寄与を加味した）反復式であり，従来手法との構造の類似性が高く実装が容易である．式(9),(10)から双対変数を除外すると通常のRow-Action型反復法になるがLimit Cycleは回避できず，勾配計算に正しく双対変数を含むことが真の解に収束するキーである．また，勾配計算に基づくため各部分評価関数に複数方向の投影データが含まれるOrdered-Subsetsへの拡張も容易である．

数値実験の結果は発表で紹介する．**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 methods with total variation using multi proximal splitting. Proc ICBIP2021, 65-71, 2021

[2] Sadakata K, Kim H, Kudo H: Unified approach to fast convergent row-action-type iterative methods for PET image reconstruction using multi proximal splitting. Journal of Image and Graphics 10: 82-87, 2022

[3] Lan G: First-order and stochastic optimization methods for machine learning. Springer, 2020

表 1 様々なノイズモデルの再構成に対する近接写像

	$h_i(y_i)$	$\mathrm{prox}_{\alpha f_i}(\vec{x})$	
最小2乗法	$\frac{1}{2}(y_i - b_i)^2$	$\vec{x} + \alpha\frac{b_i - \vec{a}_i^{\mathrm{T}}\vec{x}}{1+\alpha\|\vec{a}_i\|^2}\vec{a}_i$	○
放射型CT対数尤度	$y_i - b_i\log y_i$	$\vec{x} + t\vec{a}_i\ \ t = -\frac{\bar{p} - \sqrt{\bar{p}^2 + \bar{q}}}{2\|\vec{a}_i\|^2}$ $\bar{p} = \vec{a}_i^{\mathrm{T}}\vec{x} + \alpha\|\vec{a}_i\|^2,\ \bar{q} = 4\alpha\|\vec{a}_i\|^2(b_i - \vec{a}_i^{\mathrm{T}}\vec{x})$	△ 複雑過ぎる
透過型CT対数尤度	$d_i\exp(-y_i) + b_i y_i$		× 計算不可能
異常データ検知CT	$\|y_i - b_i\|$	$\vec{x} - \lambda\alpha\vec{a}_i\ \ \lambda = \begin{cases} -1 & (q < -1) \\ q & (-1 \le q \le 1),\ q = -\frac{b_i - \vec{a}_i^{\mathrm{T}}\vec{x}}{\alpha\|\vec{a}_i\|^2} \\ 1 & (q > 1) \end{cases}$	○

Algorithm 1 (DLPMアルゴリズム)

$\vec{x}^{(0,1)} \ge 0,\ \vec{y}_i^{(0)} \in D_i\ (i = 1,2,\cdots,I),\ \vec{y}_{I+1}^{(0)} \in \mathrm{R}^J,\ \vec{z}^{(0,1)} = -(\sum_{i=1}^{I+1}\vec{y}_i^{(0)})/(I+1)$

$k = 0,1,2,\cdots$ Main iteration

$i = 1,2,\cdots,I+1$ Sub iteration

主変数update

$$\bar{\vec{x}} = \mathrm{prox}_{\alpha f_i(\vec{x})}(\vec{x}^{(k,i)} + \vec{y}_i^{(k)}) \equiv \min_{\vec{x}}(\frac{1}{2\alpha}\left\|\vec{x} - (\vec{x}^{(k,i)} + \vec{y}_i^{(k)})\right\|^2 + f_i(\vec{x}))$$
$$\vec{y}_i^{(k+1)} = \vec{y}_i^{(k)} + \vec{x}^{(k,i)} - \bar{\vec{x}} \quad \text{双対変数update}$$
$$\vec{z}^{(k,i+1)} = \vec{z}^{(k,i)} + (\bar{\vec{x}} - \vec{x}^{(k,i)})/(I+1) \quad \vec{x}^{(k,i+1)} = [\bar{\vec{x}} + \vec{z}^{(k,i+1)}]^+ \quad (※)$$

$\vec{x}^{(k+1,1)} = \vec{x}^{(k,I+2)}$　$\vec{z}^{(k+1,1)} = \vec{z}^{(k,I+2)}$　外挿（摂動項を抜く）

Algorithm 2 (主双対ブロック反復勾配法)

$\vec{x}^{(0,1)} \ge 0,\ \mu_i^{(0)} \in D_i^{(\mu)}\ (i = 1,2,\cdots,I),\ \vec{y}^{(0)} = 0,\ \vec{z}^{(0,1)} = -(\alpha\sum_{i=1}^{I}\mu_i^{(0)}\vec{a}_i)/(I+1)$

$k = 0,1,2,\cdots$

（※）本文に放射型CTと透過型CTの更新式

$i = 1,2,\cdots,I$ データ項の処理

$$\bar{\vec{x}} = \vec{x}^{(k,i)} - \alpha\mathrm{P}^{-1}\vec{a}_i[h_i'(\frac{\vec{a}_i^{T}\vec{x}^{(k,i)} + \sigma h_i^{*\prime}(\mu_i^{(k)})}{1+\sigma}) - \mu_i^{(k)}] \text{ 主変数update}$$
$$\mu_i^{(k+1)} = \mu_i^{(k)} + [h_i'(\frac{\vec{a}_i^{T}\vec{x}^{(k,i)} + \sigma h_i^{*\prime}(\mu_i^{(k)})}{1+\sigma}) - \mu_i^{(k)}] \text{ 双対変数update}$$
$$\vec{z}^{(k,i+1)} = \vec{z}^{(k,i)} + (\bar{\vec{x}} - \vec{x}^{(k,i)})/(I+1) \quad \vec{x}^{(k,i+1)} = [\bar{\vec{x}} + \vec{z}^{(k,i+1)}]^+ \text{ 外挿}$$

$$\bar{\vec{x}} = \mathrm{prox}_{\alpha\beta R(\vec{x})}(\vec{x}^{(k,I+1)} + \vec{y}^{(k)}) \equiv \min_{\vec{x}}(\frac{1}{2\alpha}\left\|\vec{x} - (\vec{x}^{(k,I+1)} + \vec{y}^{(k)})\right\|_{\mathrm{P}}^2 + \beta R(\vec{x}))$$
$$\vec{y}^{(k+1)} = \vec{y}^{(k)} + \vec{x}^{(k,I+1)} - \bar{\vec{x}} \quad \text{正則化項の処理}$$
$$\vec{z}^{(k,I+2)} = \vec{z}^{(k,I+1)} + (\bar{\vec{x}} - \vec{x}^{(k,I+1)})/(I+1) \quad \vec{x}^{(k,I+2)} = [\bar{\vec{x}} + \vec{z}^{(k,I+2)}]^+$$

$\vec{x}^{(k+1,1)} = \vec{x}^{(k,I+2)}$　$\vec{z}^{(k+1,1)} = \vec{z}^{(k,I+2)}$

Variance Reduction 確率的勾配法を用いたブロック反復型逐次近似画像再構成法の構築

朝戸　天翔[*1]，工藤　博幸[*2]
[*1] 筑波大学 理工情報生命学術院 システム情報工学研究群 情報理工学位プログラム 博士前期課程
[*2] 筑波大学システム情報系

Block-Iterative Sequential Approximation Image Reconstruction Using Variance Reduction Stochastic Gradient Method

Sho ASATO[*1]，Hiroyuki KUDO[*2]
[*1] *Master's Program in Computer Science, University of Tsukuba*
[*2] *Faculty of Engineering, Information and Systems, University of Tsukuba*

要旨：本論文では，新たなブロック反復型逐次近似画像再構成法として確率的分散削減法のアルゴリズムを用いた，勾配法ベースの画像再構成法を提案する。提案手法を用いて，PET の対数尤度を対象とした画像再構成法を実装して提案手法の高収束性を実証した。提案手法は固定ステップサイズのみで Limit Cycle 問題を回避でき，勾配法がベースであることから複雑な近接写像の計算が必要なく実装が簡単であり，評価関数を変えることで PET にも CT にも統一的に適用が可能である。
キーワード：PET，画像再構成，逐次近似法，確率的勾配法，Variance Reduction

1. はじめに

PET や CT の画像再構成では，2 乗誤差や対数尤度からなるデータ項と，Total Variation (TV)などの平滑化を行う正則化項からなる評価関数を逐次近似法によって最小化することにより行われる。高速に最小化を行うには，評価関数を部分評価関数の和の形に分解し，部分評価関数毎に画像更新を行うブロック反復型(Row-Action 型)反復法が有効であるが，Limit Cycle と呼ばれる評価関数の真の最小解と異なる周期解に収束し，雑音特性が悪い画像になる問題を抱えている。Limit Cycle の問題を回避する方法として，緩和係数を用いて画像更新のステップサイズを制御しながら反復計算を行う方法[1]があるが，緩和係数の制御に経験的なパラメータ設定が必要であることが問題となっていた。工藤らによって提案された DLPM 法[2],[3]ではこの問題が解決され，部分評価関数に近接写像を作用させて画像の更新を行うことにより，緩和係数の制御が必要なく，固定ステップサイズで Limit Cycle 問題を回避しつつ高速に収束することが可能となった。また，部分評価関数をランダムに選ぶことで DLPM 法が数学的に概収束(almost sure convergence)することが示された[4]。このように，DLPM 法は非常に有効な方法であるが，問題点として近接写像の計算が必要なことが挙げられる。PET の対数尤度では近接写像の計算が複雑になってアルゴリズムの見通しが悪くなる，透過型 CT の対数尤度では近接写像が解析的に計算できず DLPM 法の適用ができない，などの問題点がある。

本研究では，新たなブロック反復型逐次近似画像再構成法として，Variance Reduction 確率的勾配法に基づく勾配法ベースの画像再構成法を提案する。この方法は，部分評価関数の勾配が計算できればよく，近接写像の計算が複雑になるものや計算できないものについても適用可能で，簡単に実装できるメリットを持つ。加えて，DLPM 法と同様に固定ステップサイズのみで Limit Cycle 問題を回避できる特徴を持つ。提案手法を PET の非負制約付き対数尤度に適用し，DLPM 法の場合との性能比較を行った。

2. 提案手法

本研究で提案する手法は，確率的分散削減法(Stochastic Variance Reduction)のアルゴリズムに基づいている。確率的分散削減法は式(1)で示されるような部分関数の有限和に分解できる関数を最小化するアルゴリズムである。

$$f(x) = \frac{1}{n}\sum_{i=1}^{n} f_i(x) \qquad (1)$$

Variance Reduction のアルゴリズムでは，各ステップkにおいて，式(2)に示す更新式でxを更新する。

$$x_i^{k+1} = x_i^k - \gamma\left\{\nabla f_i\left(x_i^k\right) - \nabla f_i\left(x_i^{k-1}\right) + \frac{1}{n}\sum_{j=1}^{n}\nabla f_j(\bar{x}_j)\right\} \qquad (2)$$

ここで，$\bar{x}_j$は部分関数の勾配$\nabla f_j(\bar{x}_j)$を計算した時の変数である。部分関数の勾配$\nabla f_i\left(x_i^k\right)$から 1 ステップ前の部分関数の勾配$\nabla f_i\left(x_i^{k-1}\right)$を引き，関数全体の勾配$1/n\ \sum_{j=1}^{n}\nabla f_j(\bar{x}_j)$を足したものをステップサイズ$\gamma$でフィードバックする形になっている。$f(x)$を評価関数，$f_i(x)$を部分評価関数，$i(1,2\ldots n)$をサブセットの番号と見ると，(2)式はあるサブセットiを使って画像xを更新する式と見ることができる。このとき，部分関数の勾配の項$\nabla f_i\left(x_i^k\right) - \nabla f_i\left(x_i^{k-1}\right)$によって関数の解の方向に修正を行っているが，$i$以外の別のサブセットから見ると必ずしも解の方向に修正しているとは限らない。部分関数の勾配の項に関数全体の勾配を足すことで方向を修正し，xを関数全体の解の方向へ更新できる。このように，部分関数の勾配の項と関数全体の勾配を足したものをステップサイズでフィードバックするという(2)式の形によって，Limit Cycle 問題を回避して真の解に到

達することができる。

本研究では確率的分散削減法のアルゴリズムの 1 つである SAGA[5]，SVRG[6]を用いて，PET の対数尤度を対象とした画像再構成アルゴリズムを構築した。用いる評価関数は，式(3)の通りである。

$$f(\vec{x}) \equiv L(\vec{x}) + \beta U(\vec{x}),\ L(\vec{x}) = \boldsymbol{A}\vec{x} - \vec{b}\ln \boldsymbol{A}\vec{x} \qquad (3)$$

ここで，$\vec{x}$は画像ベクトル，$\vec{b}$は投影データベクトル，$\boldsymbol{A}$は PET のシステム行列，$L(\vec{x})$はデータ項，$U(\vec{x})$は正則化項である。今回は正則化項を使用せず，データ項のみで画像再構成を行った。確率的分散削減法では，部分関数の勾配を使って関数の最小化を行う。式(3)の PET の対数尤度を用いる場合，全体勾配$\nabla f(\vec{x})$および部分勾配$\nabla f_i(\vec{x})$は式(4)のようになる。

$$\nabla f(\vec{x}) = \frac{1}{n}\sum_{i=1}^{n} \nabla f_i(\vec{x})$$

$$\nabla f_i(\vec{x}) = \boldsymbol{A}_i^T\{\vec{1} - (\vec{b}_i \oslash \boldsymbol{A}_i\vec{x})\} \qquad (4)$$

ここで，$\oslash$はアダマール除算であり，ベクトルの要素ごとの割り算を表す。また，$\vec{1}$はすべての要素が 1 のベクトルで，$\vec{b}_i$と同じサイズである。

構築したアルゴリズムを Algorithm 1~2 に示す。nはサブセットの数である。$[\,]^+$は非負制約であり，負の値を 0 に置き換える処理を表す。また，勾配を計算するときに$\boldsymbol{A}_i\vec{x}$の値によって 0 除算が発生する可能性があるため，0 ではない小さな定数ベクトル$\vec{\varepsilon}$を足すことで 0 除算を回避している。Algorithm 1 は SAGA をベースにした画像再構成アルゴリズムである。SAGA では，完全な全体勾配を計算せず，部分勾配$\vec{v}_s^k$と 1 ステップ前の部分勾配$\vec{v}_{old}$を計算し，$\vec{v}_s^k$と$\vec{v}_{old}$で全体勾配$\vec{g}_s$を更新しながら$\vec{x}$の更新を行う。このとき，部分勾配の$\boldsymbol{A}_i^T$の係数を保存し，次のステップでの$\vec{v}_{old}$の計算に使用する。保存するデータ量は全体で投影データベクトル$\vec{b}$のサイズとなる。Algorithm 1 では，

Algorithm 1 ~ SAGA- Reconstruction

$\vec{x}_1^1 = (\text{arbitrary}),\ \vec{v}_n^0 = \vec{0}\ (i = 1,2,\dots,n),\ \vec{g}_0 = \vec{0},\ \vec{\varepsilon} \ll 1$

$\delta\ (0 < \delta < 1)$

$k = 1,2,\dots,\text{iter}$

　$s = 1,2,\dots,n$

　　$i = \text{randperm}\{1,2,\dots n\}$ ：ランダムな順序でiを選択

　　$\vec{v}_{old} = \boldsymbol{A}_i^T\left[\vec{1} - \left\{\vec{b}_i \oslash (\boldsymbol{A}_i\vec{x}_s^{k-1} + \vec{\varepsilon})\right\}\right]$

　　$\vec{v}_s^k = \boldsymbol{A}_i^T\left[\vec{1} - \left\{\vec{b}_i \oslash (\boldsymbol{A}_i\vec{x}_s^k + \vec{\varepsilon})\right\}\right]$ ：部分勾配の計算

　　Store: $\vec{1} - \left\{\vec{b}_i \oslash (\boldsymbol{A}_i\vec{x}_s^k + \vec{\varepsilon})\right\}$

　　$\vec{x}_{s+1}^k = [\vec{x}_s^k - \gamma\{\delta(\vec{v}_s^k - \vec{v}_{old}) + \vec{g}_s\}]^+$ ：画像の更新

　　$\vec{g}_s = \vec{g}_{s-1} + \frac{1}{n}\cdot\delta(\vec{v}_s^k - \vec{v}_{old})$ ：全体勾配の更新

　$\vec{x}_1^{k+1} = \vec{x}_{n+1}^k,\ \vec{g}_0 = \vec{g}_n$

部分勾配の項に$0 < \delta < 1$の定数δをかけて，全体勾配に対して部分勾配の影響を小さくし，オリジナルの SAGA に変更を加えて使用している。

Algorithm 2 は SVRG をベースにした画像再構成アルゴリズムである。SAGA との違いは，各ステップの最初に完全な全体勾配$\vec{g}$を計算して$\vec{x}$の更新を行う点である。1 ステップ前の部分勾配$\vec{v}_{old}$の計算に$\vec{x}_g$を使用するため，画像次元の$\vec{x}_g$を保存すればよく，SAGA より保存量が少なくて済むメリットを持つ。しかし，各ステップの最初に全体勾配を計算するため，この分の計算時間がかかり，SAGA と比べてアルゴリズムの実行時間が増大するデメリットがある。

3. まとめ

確率的分散削減法のアルゴリズムに基づいた，新たな再構成アルゴリズムを提案し，PET の対数尤度について提案手法を実装し高収束性を実証した。今後の課題としては，正則化項の導入，リストモード画像再構成への拡張が挙げられる。

利益相反の有無：なし

文　献

[1] Tanaka E, Kudo H: Tanaka E, Kudo H: Subset-dependent relaxation in block-iterative algorithms for image reconstruction in emission tomography. Phys Med Biol 48: 1405-1422, 2003

[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

[3] Sadakata K, Kim H, Kudo H: Unified approach to fast convergent row-action-type iterative methods for PET image reconstruction using multi proximal splitting. Journal of Image and Graphics 10: 82-87, 2022

[4] 工藤博幸，金喜正，藤井克哉: 確率的 Dykstra 型スプリッティングによる統一的なブロック反復型画像再構成法の構成 : CT と PET への応用，第 42 回日本医用画像工学会(JAMIT)大会，2023

[5] Defazio A, Bach F, Julien SL: SAGA: A Fast Incremental Gradient Method With Support for Non-Strongly Convex Composite Objectives. Neural Information Processing Systems, 2014

[6] Johnson R, Zhan T: Accelerating Stochastic Gradient Descent using Predictive Variance Reduction, Neural Information Processing Systems, 2013

Algorithm 2 ~ SVRG Reconstruction

$\vec{x}_1^1 = (\text{arbitrary}),\ \vec{\varepsilon} \ll 1$

$k = 1,2,\dots,\text{iter}$

　$\vec{x}_g = \vec{x}_1^k,\ \text{Store: } \vec{x}_g$

　$\vec{g} = \frac{1}{n}\sum_{i=1}^{n} \boldsymbol{A}_i^T\left[\vec{1} - \left\{\vec{b}_i \oslash \left(\boldsymbol{A}_i\vec{x}_g + \vec{\varepsilon}\right)\right\}\right]$

　$s = 1,2,\dots,n$

　　$i = \text{randperm}\{1,2,\dots n\}$ ：ランダムな順序でiを選択

　　$\vec{v}_{old} = \boldsymbol{A}_i^T\left[\vec{1} - \left\{\vec{b}_i \oslash \left(\boldsymbol{A}_i\vec{x}_g + \vec{\varepsilon}\right)\right\}\right]$

　　$\vec{v}_s^k = \boldsymbol{A}_i^T\left[\vec{1} - \left\{\vec{b}_i \oslash (\boldsymbol{A}_i\vec{x}_s^k + \vec{\varepsilon})\right\}\right]$ ：部分勾配の計算

　　$\vec{x}_{s+1}^k = [\vec{x}_s^k - \gamma(\vec{v}_s^k - \vec{v}_{old} + \vec{g})]^+$ ：画像の更新

　$\vec{x}_1^{k+1} = \vec{x}_{n+1}^k$

不完全投影データからの位相 CT 画像再構成における解の一意性

藤井　克哉[*1]，　工藤博幸[*2]
[*1] 畿央大学教育学部，[*2] 筑波大学システム情報系

Uniqueness in phase CT image reconstruction from incomplete projection

Katsuya Fujii[*1], Hiroyuki Kudo[*2]
[*1] *Kio University,* [*2] *University of Tsukuba*

要旨： X 線位相 CT は，吸収係数の小さい物質に対して十分なコントラストが得られる画像再構成として期待されている X 線 CT 手法である．本研究では，工藤らの先行研究であるインテリア CT の手法を位相 CT へ拡張する．インテリア CT とは関心領域のみを通る投影データから再構成する手法であり，X 線被ばく量軽減のためにも期待されている．工藤らはインテリア CT の解の一意性が成立する条件は，再構成領域の任意の先見情報領域が存在することを示した．本研究における位相 CT の場合も同じ条件を用いる．また位相 CT の場合，取得可能な投影データは元の投影データを微分したものであるため，解の一意性を示すときに用いる数式モデルは Cormack 型再生公式を採用することにより，簡便でより広範な不完全投影データからの再構成理論を構成することが可能となった．

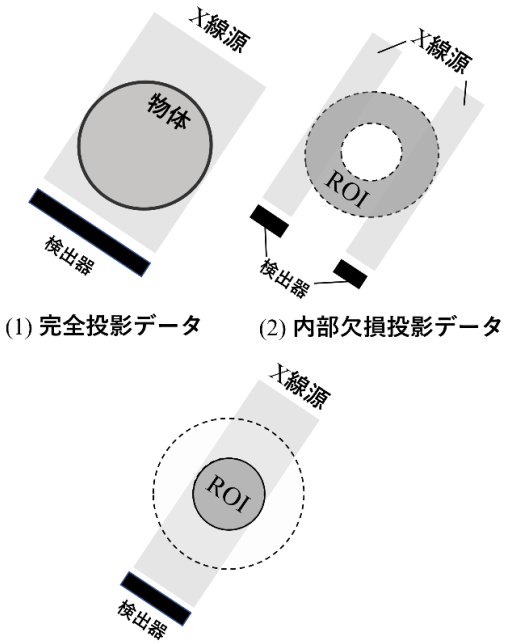
キーワード： CT，位相 CT，画像再構成，解の一意性

1. はじめに

近年，CT 画像再構成では，様々な社会的，科学的な要請から X 線量の低下, またはビーム幅の削減を必要とされており，スパースビューCT，インテリア CT などの新たな CT 画像再構成法の研究が多方向の分野から進められている[1]．これらの CT 画像再構成は，得られる投影データが従来の完全 CT よりも不完全な形で実現する必要があるため，例えば FBP (Filtered Back Projection)といった従来の数学的枠組みではなく，新しい数学的理論が求められる. 本論文で扱う不完全投影データからの CT 画像再構成はインテリア CT，エクステリア CT とよばれるもので，互いに完全な投影データに対して，外側，内側の欠損がある状況下での再構成法である(図 1 参照)．これらの具体的な再構成に関して簡単に説明する. まず外部欠損投影データからの再構成を担う再構成法をインテリア CT 再構成法と呼ばれ，2008 年頃の工藤，Ye らによる仕事が大きく寄与している[2, 3]．実は F. Natterer により，インテリア CT は，再構成解が一意にならないことが証明されていたが[4]，彼らの発見した再構成のための十分条件は「関心領域（Region of Interest, ROI）上に面積が0ではない先験領域が存在すること」であり，インテリア CT の実用化へ向けて大きく貢献した．内部欠損データからの再構成を担うエクステリア CT は，A Cormack による解析的逆変換公式によって厳密に解を記述できることが知られている[5].

上記のような不完全投影データからの再構成以外の従来 CT の問題点として, X 線吸収係数が小さい物質を再構成したい場合，十分なコントラストが得られないことがある．例えば，軽元素からなる物質が多くの割合を占めている場合，従来の CT では困難な問題であった．上記の困難を克服するために，X 線位相コントラストを利用した再構成法が提案されている[6]．X 線位相 CT における投影データは，通常の投影データの動径方向に関して微分されたものとなることが知られている. つまり，従来の CT 画像再構成をそのまま適用することは難しく，さらに不完全な投影からの位相 CT は一部で困難であった．

本論文では，工藤らによって得られた再構成のための十分条件を位相 CT へ拡張する. その際の重要なキーが Cormack の解析的逆変換公式であり，不完全位相 CT における解の一意性が，この公式のもとで成立することを見る．



(1) 完全投影データ　(2) 内部欠損投影データ

(3) 外部欠損投影データ

図 1: 完全投影データ(1)と不完全投影データ(2), (3)の撮影．(1)は通常の CT，(2),(3)はそれぞれ ROI のみを照射する．

2. 提案手法

本論文で扱う CT 画像再構成の数理を説明する．復元したい対象物体の密度関数を$f(x)$で表すとき，Cormack の公式は次で与えられる．

$$f_\ell(r) = -\frac{1}{\pi}\int_r^1 \frac{T_\ell\left(\frac{s}{r}\right)}{\sqrt{s^2-r^2}} g'_\ell(s)ds \qquad (1)$$

ここで，T_ℓは第 1 種 Chebyshev 多項式であり，Cormack の公式(1)は，密度関数$f(x)$，投影データ$p(s,\theta)$ を以下の(2)，(3)のようにそれぞれ円調和展開し，各 Fourier 係数の比較から得られる公式である[4].

$$f(x) = f\big(r(\cos\theta, \sin\theta)\big) = \sum_{\ell=-\infty}^{\infty} f_\ell(r)e^{i\ell\theta} \qquad (2)$$

$$p(s,\theta) = \sum_{\ell=-\infty}^{\infty} g_\ell(s)e^{i\ell\theta} \qquad (3)$$

数式(1)から(3)を用いて，不完全投影データからの CT 画像再構成の逆問題は「各(r,θ)に対し，不十分な投影データ$p(r,\theta)$から再構成解$f(x)$を一意に決定すること」と解釈される．例えばインテリア CT の場合，$0 < a < 1$に対して，

$$p^I = \{p(s,\theta);\ |s| < a, -\pi \le \theta < \pi\} \qquad (4)$$

からの再構成法を与えることになる．位相 CT において，与えられるデータは微分された投影データ，つまり

$$p'(s,\theta) = \sum_{\ell=-\infty}^{\infty} g'_\ell(s)e^{i\ell\theta} \qquad (5)$$

の形である．これらを基に，外部欠損のある不完全投影データからの位相 CT 画像再構成の手順を示す．ここで重要な Step が，インテリア CT の逆問題のブレークスルーとなった「面積 0 でない先験領域の存在」である．また，工藤らの研究で扱った数学的枠組みは DBP (Differential Back Projection)法であり，FBP 法を modified したものであるが，本稿で Cormack の公式を利用した背景は，直ちにエクステリア CT にも応用可能であるところにある．

[Step1: 微分投影データの分解]

式(1)に着目すると，すべての微分投影データが必要であることがわかる．まず測定可能な微分投影データと，そうでないデータに Cormack の公式を分解する．

$$f_\ell(r) = -\frac{1}{\pi}\int_r^a \frac{T_\ell\left(\frac{s}{r}\right)}{\sqrt{s^2-r^2}} g'_\ell(s)ds - \frac{1}{\pi}\int_a^1 \frac{T_\ell\left(\frac{s}{r}\right)}{\sqrt{s^2-r^2}} g'_\ell(s)ds \qquad (6)$$

式(6)において，第 2 項は測定データが存在しないため，計算が不可能であることに注意する．

[Step2: 先験領域の利用]

密度関数$f(x)$は中心が原点であり，半径がεの円上で既知であるとする．つまり，円調和展開した際の Fourier 係数（動径方向成分）$f_\ell(r)$が$(-\varepsilon,\varepsilon)$上で既知である（図 2 参照）．$(-\varepsilon,\varepsilon)$上で，式(6)は，

$$-\frac{1}{\pi}\int_a^1 \frac{T_\ell\left(\frac{s}{r}\right)}{\sqrt{s^2-r^2}} g'_\ell(s)ds = f_\ell(r) + \frac{1}{\pi}\int_r^a \frac{T_\ell\left(\frac{s}{r}\right)}{\sqrt{s^2-r^2}} g'_\ell(s)ds \qquad (7)$$

と変形した時，右辺の$f_\ell(r)$は既知であり，積分表示された第 2 項は計算可能である．ゆえに式(7)の左辺は一意に決まり，取得可能な関数である．

[Step3: 解析接続(定義域の拡大)]

再度，式(7)の左辺に着目すると，微分投影データ取得可能領域まで解析接続可能であることが，次のようにしてわかる．微分投影データ$g'_\ell(s)$は式(4)より，$s \in (0,a)$で取得可能であり，ある程度の連続性を持つとする（[2]と同様の仮定）．このとき，実数rを複素数zに形式的に置き換えた式：

$$F(z) = -\frac{1}{\pi}\int_a^1 \frac{T_\ell\left(\frac{s}{z}\right)}{\sqrt{s^2-z^2}} g'_\ell(s)ds \qquad (8)$$

は，第 1 種 Chebyshev 多項式の解析性と，投影データ取得不可能領域$s \in (a,1)$を除いて解析関数となる．したがって，先験領域の利用と$(0,a)$まで解析関数であることから，$F(z)$は式(7)の左辺の解析接続を与えることになり，微分投影データ可能取得領域まで一意に定まる．この結果と，式(6)から$f_\ell(r)$ は一意に決まる．各 Fourier 係数が一意に定まることから式(2)より，$f(r)$の再構成は一意であることがわかる．

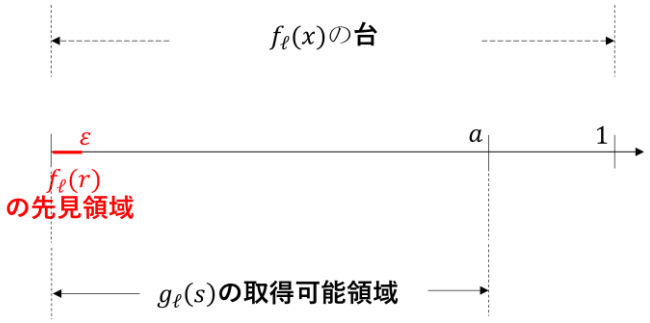


図 2: 先験領域と投影データ取得領域

3. まとめ

本論文では，位相 CT における不完全投影データからの再構成の数理を扱った．現在までの位相 CT の再構成法との主な違いは，Cormack の公式を用いたことにより，位相 CT が取得可能な微分投影データを公式に適用可能なところにある．また本稿では述べていないが，エクステリア CT，さらに，内部と外部の微分投影データが欠損している複合型の不完全投影データからの CT 画像再構成の解の一意性も検討することが可能になる[7].

利益相反の有無： なし

文　献

[1] 工藤博幸：第 2 章　投影からの画像再構成．日本医用画像工学会編：医用画像工学ハンドブック．国際文献社，東京, pp39-84, 2012

[2] Kudo H, Courdurier M, Noo F, et el.: Tiny a priori knowledge solves the interior problem in computed tomography. Phys Med Biol 53: 2207-2231, 2008

[3] Y. Ye, H. Yu, et al: A general local reconstruction approach based on a truncated Hilbert transform. Int.J.Biomed.Imaging. 2007:Article ID 63634, 2007

[4] Natterer F: The Mathematics of Computerized Tomography. John Wiley & Sons, Stuttgart, 1986

[5] Cormack AM: Representations of a function by its line integrals, with some radiological applications. J Appl Phys 34: 2722-7, 1963

[6] 百瀬敦：X 線位相イメージングと X 線位相 CT. 精密工学会誌 82, No.6: 513-517, 2016

[7] 藤井克哉，金鎔采，工藤博幸：CT 画像再構成における混合インテリアエクステリア問題の 解の一意性，第 39 回日本医用画像工学会大会（JAMIT 2020）予稿集, Paper No P3-14, 2020

X 線回折波 2 重撮影法のスパース性を利用した CT 投影削減手法

砂口　尚輝[*1]，湯浅　哲也[*2]，島雄　大介[*3]，黄　卓然[*1]，市原　周[*4]，西村　理恵子[*4]，岩越　朱里[*4]
Jong-Ki Kim[*5]，Rajiv Gupta[*6]，安藤　正海[*7]
[*1] 名古屋大学大学院医学系研究科，[*2] 山形大学，[*3] 大阪物療大学，[*4] 名古屋医療センター，
[*5] 大邱カトリック大学，[*6] マサチューセッツ総合病院，[*7] 高エネルギー加速器研究機構

Projection reduction method using high sparsity of superimposed wavefront imaging of diffraction-enhanced x-rays (SWIDeX)

Naoki SUNAGUCHI[*1]，Tetsuya YUASA[*2]，Daisuke SHIMAO[*3]，Zhuoran HUANG[*1]，
Shu ICHIHARA[*4]，Rieko NISHIMURA[*4]，Akari IWAKOSHI[*4], Jong-Ki Kim[*5], Rajiv GUPTA[*6], Masami ANDO[*7]
[*1] *Nagoya University,* [*2] *Yamagata University,* [*3] *Butsuryo College of Osaka,*
[*4] *Nagoya Medical Center,* [*5] *Daegu Catholic University,*
[*6] *Massachusetts General Hospital,* [*7] *High Energy Accelerator Research Organization*

要旨：放射光 X 線を利用する位相コントラスト撮影法(PCI)は軽元素からなる被写体に高いコントラストを生成できる．近年，光源の高品質化や検出器の性能向上が進み，広視野かつ高空間分解能の撮像が可能になっている．それに伴い，CT の再構成に必要な投影数も増加しており，撮像時間の増加に繋がっている．我々は以前 PCI の 1 つである X 線暗視野法を用いて，微分型 CT に基づく投影削減手法を提案し，CT の画素値が疎であるほど投影数を削減できることを示した．しかし，この方式は取得される 1 階微分投影に差分処理を適用し 2 階微分投影を生成する必要があり，処理の過程でノイズが増幅する問題があった．それに対して，近年我々が考案した新しい PCI である X 線回折波 2 重撮影法は高い空間分解能とコントラストで 2 階微分投影が直接得られるという特徴を持つ．本研究ではこの撮影法が有するスパース性を利用した CT の投影削減について検討する．
キーワード：X 線回折波 2 重撮影法，SWIDeX，投影数削減，CT 再構成，放射光

1. はじめに

X 線と物体の相互作用を利用して，様々な X 線イメージングが開発されている．一般的に，被写体内の物理量は複素屈折率$n = 1 - \delta + i\beta$の形で表現され，実部δは X 線の位相シフト，虚部βは吸収の相互作用に関わる．δのイメージングは位相コントラストイメージング(PCI)と呼ばれ，特に硬 X 線領域における軽元素のδはβと比べて約 1000 倍大きいため，生体軟組織等の構造を高いコントラストで可視化できる[1]．これまでに開発された PCI の撮像方式には，インライン法，干渉法，回折格子法，アナライザー法などがあり，目的や用途に合わせて実用化のための研究が現在も続けられている．

我々の研究グループでは近年，これまでのアナライザー法よりも高い空間分解能を期待できる新しい PCI，X 線回折波 2 重撮影法(SWIDeX: Superimposed Wavefront Imaging of Diffraction-enhanced X-rays)を提案し[2]，生体軟組織の 3 次元構造を 1 μm の空間分解能で可視化するための開発を進めている．一方で，光源性能をそのままに高空間分解能化を進めると，CT 画像の画素数や露光時間が増加するという問題が生じる．一般的に，CT の再構成に必要な投影数は，サンプリング理論から CT 画像の一辺の画素数の約 1.5 倍以上とされており，画素数の増加は投影数の増加を伴う．これに，1 投影当たりの露光時間の増加を含めると CT の撮影は実用上困難になることが多く，実験の拠点を高い光源性能を持つ放射光施設に移すか，投影数や露光時間を妥協して許容できる範囲で画質を落とすかの判断に迫られる．実際はどちらも容易ではないため，画質低下が生じない投影数削減手法の開発が必要であり，本研究では SWIDeX の投影数削減に焦点を当てる．

画質低下を防ぎつつ CT で必要な投影数を削減するためのアプローチとして，再構成時に CT に関する既知の情報を組み込むことが考えられる．SWIDeX で投影数削減に有効な既知情報としては，SWIDeX のスパース性が考えられる．SWIDeX で得られる投影は被写体のδ分布の 2 階微分を線積分したものであり，再構成を行うことで高いスパース性を持つδ分布のラプラシアン像が直接得られるという特徴を持つ．スパース性を利用する再構成法としては，全変動（TV）正則化を用いる代数的再構成法(ART+TV)が知られており，SWIDeX の再構成にも有効に働く可能性を持つ．

本研究では，シミュレーションおよび実際のヒト生体組織の SWIDeX-CT 撮像実験により得た 2 階微分投影セットに ART+TV 法を適用し，投影数削減に有効であるか評価する。この予稿では生体組織を用いた CT 画像結果のみを示す．

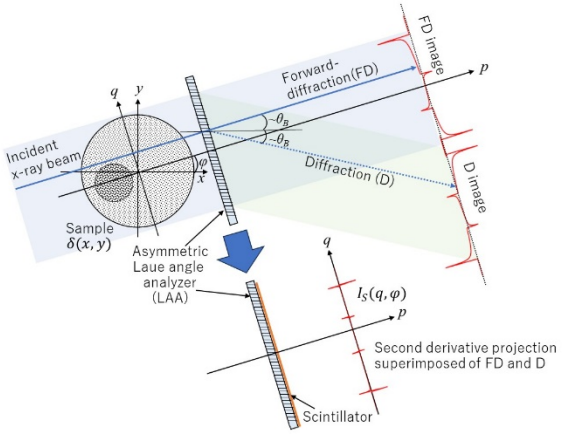


図 1 SWIDeX-CT 撮像ジオメトリ

2. SWIDeX 撮像原理および CT 再構成方法

図 1 は SWIDeX 撮像系の概要図である．被写体$\delta(x,y)$には xy 座標系とそれをφ回転した pq 座標系が設定されている．入射 X 線ビームは p 軸に平行に被写体上を伝搬し，$\delta(x,y)$に従って屈折する．X 線の屈折による微小な角度偏差は入射 X 線とブラッグ角θ_Bを成すように設置された Laue 型角度アナライザー(LAA: Laue-case Angle Analyzer)で強度情報（屈折コントラスト）に変換され，LAA の背面で前方回折(FD: Forward-diffraction)と回折(D: Diffraction)方向に X 線が分離する．ここで，FD と D の強度は足すとほぼ入射 X 線強度になり，互いのコントラストは反転した関係を持つ．SWIDeX では，LAA の直後に検出器を配置して，FD 像と D 像が重なった状態で撮像する．この像の詳細な導出過程については省略するが，SWIDeX の投影像と$\delta(x,y)$の関係（ラドン変換）は次のように得られる．

$$M(q) = C\Delta q \int_{-\infty}^{\infty} \frac{\partial^2 \delta(p,q)}{\partial q^2} dp + I_0 \qquad (1)$$

ここで，C は回折強度勾配，Δqは FD 像と D 像のずれ量，I_0 は入射 X 線強度である．SWIDeX の投影は$\delta(x,y)$の 2 階微分の線積分である．また，ラプラシアン像のラドン変換は 2 階微分投影になることが知られている．

$$\int_{-\infty}^{\infty} \Delta\delta(p\cos\varphi - q\sin\varphi, p\sin\varphi + q\cos\varphi)\, dp = \int_{-\infty}^{\infty} \frac{\partial^2 \delta}{\partial q^2} dp \quad (2)$$

通常，SWIDeX の投影セットに Filtered Backprojection (FBP) を適用することで，ラプラシアン画像$\Delta\delta(x,y)$を再構成でき，その後 Successive over-relaxed 法などを利用することで$\delta(x,y)$を求めることができる．

この研究では，FBP の代わりに ART+TV を適用する．ART+TV についてはすでに広く知られている技術であるため詳細は省くが，SWIDeX への適用に際し，まず (1)から$(M(q) - I_0)/C\Delta q$を計算し(2)の右辺を得る．次にこれを ART ステップに入力し，ART と TV 最小化ステップを交互に繰り返すことにより$\Delta\delta$を得る．

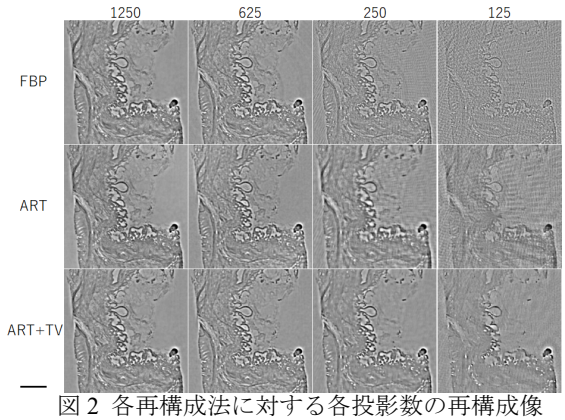


図 2 各再構成法に対する各投影数の再構成像

3. 生体組織の SWIDeX-CT 投影数削減実験および結果

実験は高エネルギー加速器研究機構フォトンファクトリー BL14B で実施された．撮像条件のうち，X 線エネルギーは 19.8 keV，投影数は 125，250，625，1250 の 4 セット，検出器の画素数は 4608×2592，CT 再構成像の画素数は 4608×4608，画素サイズは 5.5μm，1 投影当たりの露光時間は 4 秒とした．サンプルには複雑な構造を有す膵管内乳頭粘液性腫瘍(IPMN)組織が選択された．投影削減効果を評価するために，各セットの投影に FBP，ART，ART+TV を適用した CT 像が再構成された．

図 2 は，再構成法と投影数を変えて再構成された IPMN 組織の CT 画像である．全体的に 650 投影までは目立ったアーチファクトなく再構成できている．しかし，FBP と ART では，250 投影になるとストリーク状のアーチファクトが発生している．また ART では投影数が少なくなると画像にボケが生じている．ART+TV では 125 投影までアーチファクトなく再構成できているが，125 投影では若干細かい構造が失われている．

4. まとめ

高いスパース性を持つ SWIDeX の投影に ART+TV 法を適用することである程度の投影削減効果を得た．当日の発表では，シミュレーション実験や定量性の評価結果なども報告する．

謝辞

2023 年 5 月 1 日にご逝去された高エネ研安藤正海名誉教授には，本研究を含めて放射光 X 線イメージングの開発に多大なる貢献をしていただきました．ここで深くご冥福をお祈りいたします．本研究は科研費 21K04077 の支援を受けています．

利益相反の有無

なし

文　献

［1］ Ando M, Sunaguchi N, Shimao D et al: Dark-field imaging: recent developments and potential clinical applications. Phys Med. 32(12): 1801-1812, 2016

［2］ Sunaguchi N, Yuasa T, Shimao D et al: Superimposed wavefront imaging of diffraction-enhanced x-rays: A method to achieve higher resolution in crystal analyzer-based x-ray phase-contrast imaging. Appl Phys Lett. 122(12): 123702, 2023

膨張畳み込みを導入した 3D ResNet-18 による心臓 CT-Perfusion 画像の左室短軸像の自動作成

岩井　星澄[*1]，中山　良平[*1]，檜作　彰良[*1]，中村　哲士，[*2]佐久間　肇[*2]
[*1] 立命館大学大学院　理工学研究科
[*2] 三重大学医学部放射線科

Automatic Reorientation to Generate Left Ventricular Short-Axis Images for Cardiac Perfusion CT Images Using 3D ResNet-18 with Dilated Convolution

Seito IWAI[*1]，Ryohei NAKAYAMA[*1]，Akiyoshi HIZUKURI[*1]，Satoshi NAKAMURA[*2]，Hajime SAKUMA[*2]
[*1] *Graduate School of Science and Engineering, Ritsumeikan University*
[*2] *Department of Radiology, Mie University School of Medicine*

要旨：心筋虚血評価手法の一つに心臓 CT-Perfusion 検査がある．左室の形態や機能を評価する際，左室短軸像が用いられるが，撮影された心臓 CT-Perfusion 画像を読影医が手動で回転させて左室短軸像を作成する必要がある．そこで本研究では，読影医の負担を軽減するため，心臓 CT-Perfusion 画像から左室短軸像を自動作成する手法を提案する．実験試料は，心臓 CT-Perfusion 画像 100 症例である．本研究では，3D ResNet-18 の受容野を広げるために，畳み込み層を膨張畳み込み層に置き換えた Dilated 3D ResNet-18 を構築する．そして，Dilated 3D ResNet-18 により体軸水平断像から左室短軸像へ変換するオイラー角を予測し，オイラー角に基づく回転行列を適用することで左室短軸像を作成する．提案手法の各オイラー角に対する Root Mean Squared Error は$\psi = 10.12, \theta = 2.91, \phi = 6.78$で，従来の 3D ResNet-18（$\psi = 14.08$，$\theta = 4.88$，$\phi = 12.69$）より小さく，その有用性が示唆された．
キーワード：心疾患，心臓 CT-Perfusion 画像，3D ResNet-18，Dilation Convolution

1. はじめに

心筋虚血評価手法の一つに心臓 CT-Perfusion 検査がある．左室の形態や機能を評価する際には左室短軸像が用いられるが，撮影された心臓 CT-Perfusion 画像を読影医が手動で回転して左室短軸像を作成する必要があり，検査数の増加に伴い負担が増大している．したがって，心臓 CT-Perfusion 画像から左室短軸像を自動作成する手法が望まれている．

近年，畳み込みニューラルネットワーク（CNN：Convolutional Neural Network）を活用したコンピュータ支援診断手法が多く報告されており[1-2]，特に深層学習の問題の一つである深いネットワーク構成における学習の停滞を残差接続によって解決した 3D-ResNet は，様々な研究で利用されている[3-4]．

心臓 CT-Perfusion 画像から左室短軸像を自動作成するためには，局所的な特徴ではなく大局的な特徴に着目した解析が重要である．CNN を用いて大局的な特徴を抽出する方法としては，ネットワークを深くすることが一般的であるが，パラメータ数が増大する問題がある．そこで本研究では，既存の 3D ResNet-18 の受容野を広げるために，畳み込み層を膨張畳み込み層に置換した Dilated 3D ResNet-18 を構築する．そして，Dilated 3D ResNet-18 により体軸水平断像から左室短軸像への変換に必要なオイラー角を予測し，そのオイラー角に基づく回転行列を適用することで左室短軸像を作成する．

2. 実験試料

実験試料は，三重大学医学部附属病院で撮影された体軸水平断像の心臓 CT-Perfusion 画像 100 症例である．各症例は 512×512×102 画素で構成される．本研究では，心臓 CT-Perfusion 画像から 3 段階の手動回転（θ_1，θ_2，θ_3）を用いて短軸像を作成するソフトウェアを開発し，回転角から算出したオイラー角を学習時の教師データ，評価時の正解データとして用いた．また，実験試料をランダムに学習用 60 症例，検証用 10 症例，評価用 30 症例に分割し，提案手法の学習および評価に使用した．

本研究では，心臓 CT-Perfusion 画像を等方ボクセル化し，画像サイズが 512×512×512 画素となるよう体軸方向にゼロパディングを行った．そして，224×224×224 画素にリサイズし，実験に用いた．

3. 方法

1）膨張畳み込み

通常の畳み込みではフィルタを連続する画素に適用するが，膨張畳み込みでは，フィルタのカーネル間に間隔を設けることにより，パラメータを増やさずに受容野を広げることが可能である．本研究では，膨張率を 3 と設定した．

2）提案ネットワーク構造

図 1 に提案ネットワーク構造を示す．提案ネットワークのベースモデルである ResNet-18 の Residual Block では，畳み込みを経た特徴マップに対して，その前段の特徴マップを Skip Connection を通して加算する．これにより，誤差逆伝播の際，勾配を減衰させることなく次の層に伝播され，勾配消失を回避できる．本研究では，ResNet-18 を 3 次元に拡張し，畳み込み層を膨張畳み込み層に置換することにより，Dilated 3D ResNet-18 を構築した．

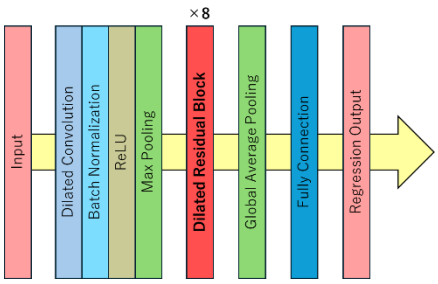


図 1：提案ネットワーク構造

3）損失関数

本研究では損失関数として，下式の Huber Loss を用いた．

$$\text{Loss} = \frac{1}{3N}\sum_{i=1}^{N}\sum_{k=1}^{3}\begin{cases}\frac{1}{2}\left(\hat{\lambda}_{ik}-\lambda_{ik}\right)^2 & \left|\hat{\lambda}_{ik}-\lambda_{ik}\right| \le \delta \\ \delta\left|\hat{\lambda}_{ik}-\lambda_{ik}\right| - \frac{1}{2}\delta^2 & otherwise\end{cases}$$

Nはミニバッチ数，$\lambda_{i1},\lambda_{i2},\lambda_{i3}$は正解のオイラー角$\psi,\theta,\phi$，$\hat{\lambda}_{ik}$は予測したオイラー角を示す．

4）評価指標

予測したオイラー角と正解のオイラー角の誤差を平均二乗平方根誤差（RMSE：Root Mean Squared Error）で評価した．

$$Angle\ Error_k = \sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(\hat{\lambda}_{ik}-\lambda_{ik}\right)^2}$$

Nは評価データ数を示す．

5）左室短軸像の作成

予測したオイラー角に基づく回転行列は下式で定義される．

$$Rotation\ Matrix = \begin{pmatrix} c_\psi c_\theta & c_\psi s_\theta s_\phi - s_\psi c_\phi & s_\psi s_\phi + c_\psi s_\theta c_\phi \\ s_\psi c_\theta & c_\psi c_\phi + s_\psi s_\theta s_\phi & s_\psi s_\theta c_\phi - c_\psi s_\phi \\ -s_\theta & c_\theta s_\phi & c_\theta c_\phi \end{pmatrix}$$

ここで，cはcos，sはsinを表す．この回転行列を心臓 CT-Perfusion 画像に適用し，左室短軸像を作成した．

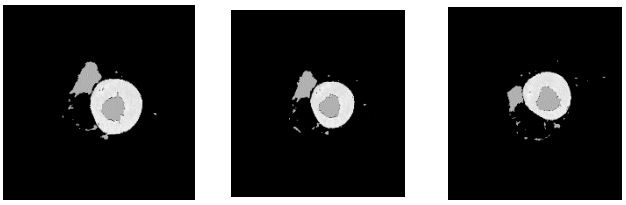
4. 結果と考察

表 1 に提案手法と 3D ResNet-18 による予測オイラー角の誤差を示す．提案手法の各オイラー角に対する RMSE は$\psi = 10.12$，$\theta = 2.91$，$\phi = 6.78$で，従来手法の 3D ResNet-18（$\psi = 14.08$，$\theta = 4.88$，$\phi = 12.69$）より小さい結果が得られた．また，図 2 に提案手法と 3D ResNet-18 で予測されたオイラー角に基づく回転行列を心臓 CT-Perfusion 画像に適用した左室短軸像の作成結果画像を示す．提案手法による予測画像がより正解画像に近い左室短軸像であることが確認された．

3D ResNet-18 では，畳み込み層の受容野が小さく大局的な特徴を得ることが出来ない．しかし，畳み込み層の受容野を広げるとパラメータ数が増大し学習が安定しないため，高い精度で予測することが困難である．一方，膨張畳み込み層ではパラメータ数を変えずに受容野を広げることが可能であるため，より大局的な特徴を抽出し，オイラー角の予測ができたと考える．

表 1：予測オイラー角の誤差の比較

Angle	提案手法	従来手法
ψ	**10.12**	14.08
θ	**2.91**	4.88
ϕ	**6.78**	12.69



正解画像　　提案手法　　従来手法

図 2：左室短軸像の作成結果

5. まとめ

本研究では，3D ResNet-18 の畳み込み層を膨張畳み込み層に置き換えることで，より大局的な特徴を捉える Dilated 3D ResNet-18 を構築し，心臓 CT-Perfusion 画像を左室短軸像に回転させるオイラー角の予測を行った．提案手法は 3D ResNet-18 より予測精度が高く，左室短軸像を作成できることが確認でき，その有用性が示唆された．

利益相反の有無

なし

文　献

［1］ Huseyin Polat, and Homay Danaei Mehr, “Classification of Pulmonary CT Images by Using Hybrid 3D-Deep Convolutional Neural Network Architecture,” Applied Sciences, vol.9, no.5, Multidisciplinary Digital Publishing Institute, 2019

［2］ Shilpa Rani, Sandeep Kumar, Deepika Ghai, et al, “Automatic Detection of Brain Tumor from CT and MRI Images using Wireframe model and 3D Alex-Net,” 2022 International Conference on Decision Aid Sciences and Applications, Chiangrai, Thailand, Mar.2022.

［3］ Robert, T., et al. “Using a 3D ResNet for Detecting the Presence and Severity of COVID-19 from CT Scans”, Proceedings of the European Conference on Computer Vision(ECCV) 2022 Workshops, 2022, pp663-676

［4］ Aimr Ebrahimi, Suhuai Luo, and Raymond Chiong, “Introducing Transfer Learning to 3D ResNet-18 for Alzheimer’s Disease Detection on MRI Images,” 35th International Conference on Image and Vision Computing New Zealand, Wellington, New Zealand, Dec.2020.

拡散モデルを用いた皮膚疾患画像の合成と画像分類におけるクラス不均衡の改善

高倉　俊[*1]，藤澤　康弘[*2]，藤本　学[*3]，坂井　浩志[*3]，志藤　光介[*4]，山崎　研志[*4]，清水　昭伸[*1]

[*1] 東京農工大学大学院工学研究院

[*2] 愛媛大学大学院医学系研究科皮膚科学

[*3] 大阪大学大学院医学系研究科皮膚科学

[*4] 東北大学大学院医学系研究科皮膚科学分野

Synthesis of skin disease images using a diffusion model to improve class imbalance in image classification

Shun TAKAKURA[*1], Yasuhiro FUJISAWA[*2], Manabu FUJIMOTO[*3], Hiroshi SAKAI[*3], Kosuke SHIDO[*4], Kenshi YAMASAKI[*4], Akinobu SHIMIZU[*1]

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

[*2] *Department of Dermatology, Osaka University Graduate School of Medicine*

[*3] *Department of Dermatology, Ehime University Graduate School of Medicine*

[*4] *Department of Dermatology, Tohoku University Graduate School of Medicine*

要旨：著者らはこれまで，光学カメラで撮影された 162 クラスの皮膚疾患の臨床写真を対象とした皮膚疾患分類モデルを開発してきた．しかし，クラス数が増えるにつれて，クラス間の学習データの不均衡が著しくなり，分類モデルがデータ数の多い多数派クラスに注目して，少数派クラスの分類精度が低下する問題が明らかになった．本研究では，精度の低い少数派クラスを対象に，拡散モデルを用いて人工的にデータを合成する方法を提案する．具体的には，Stable Diffusion を textual inversion を用いて fine-tuning することで，疾患を表す 68 個の疑似単語から，疾患画像を合成するモデルを作成した．また，162 疾患の中から精度の低い少数派の 41 クラスに提案手法を適用し，実画像と合成画像を用いて分類モデルを学習させることで精度が改善することを示す．

キーワード：画像合成，stable diffusion，textual inversion，クラス不均衡，皮膚疾患

1. まえがき

皮膚疾患は種類が多く外観も多様である．診断では，疾患の形態や色などの特徴を正しく理解して観察することが求められ，非専門医による診断は容易ではない[1]．そこで，多種多様な皮膚疾患の写真を対象とした診断支援システムの開発が進められてきた[2-3]．

これらの診断支援システムの課題の一つに，学習データのクラス不均衡問題がある．図 1 に示すように，皮膚疾患の画像数の分布はロングテールであり，クラスによって学習データ数は大きく異なり（不均衡率（データ数の最大値と最小値の比率）＝116），少数クラスの分類性能が大きく低下する [4]．対策としては Data Augmentation があり，学習データの幾何学的変換や濃度変換によって画像を増加させたり，生成モデルにより新しい画像を生成する方法がある．後者の方が多様な画像を生成することができるため，本研究では生成モデルに注目する．

本研究では，生成モデルの一つである Diffusion Model[5]を用いて少数クラスの皮膚疾患画像を生成する．また，これらの画像を学習データとすることで，クラス不均衡により低下した分類精度の向上を目指す．ここで拡散モデルに注目したのは，従来主流であった GAN と比較して，FID score などの観点から優れているという報告があるためである[6]．

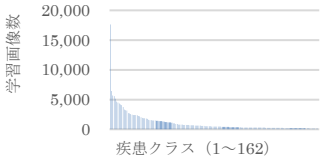


図1　クラスごとのデータ数

2. 関連研究

拡散モデルの生成データを皮膚疾患分類器の学習に使った過去の研究例について述べる．まず，文献[7]では，Stable Diffusion[8]によって皮膚疾患画像を生成し，キュレーション後に基底細胞がんやメラノーマを含む 6 クラスの分類器の学習に使用して，生成画像が有益であることを示した．また，文献[9]も Stable Diffusion に注目して 9 クラスの皮膚疾患を生成し，分類器の学習に利用している．様々な条件下で実験をした結果，データ数が限られている環境下では，生成画像は分類器の性能向上に寄与することを明らかにした．

上記の研究の課題としては，クラス数が一桁であり，大規模なクラス数での検討がなされてない点がある．また，ロングテール分布で不均衡率が 100 を超える例では検討されていない．具体的には，不均衡率は，文献[7]は 1.0，文献[9]は最大で 8.0 である．これらに対して本研究では，

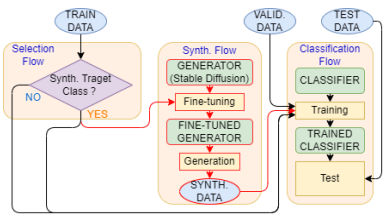


図 2　処理フロー

162 の皮膚疾患の分類器を対象に，データの不均衡率が 116 のデータベースを用いる．

3. 提案する皮膚疾患画像生成処理

処理フローを図 2 に示した．まず，分類精度が低く，データ数が少数のクラスに注目して画像を生成した．次に，生成画像と実画像を合わせて分類器を学習することで精度向上を目指した．以下では対象クラスと画像生成手順について説明する．

3.1 対象クラス

画像生成の対象とするクラスは，精度下位 25%かつデータ数が全クラスの平均以下の 41 クラスとした．

3.2 画像生成[7]

事前学習済みのテキスト条件付画像生成モデルである Stable Diffusion v1-5[8]を使用した．また，このモデルの Fine-tuning には textual inversion[10]用いた．Stable Diffusion に入力されたテキストプロンプトはトークンに分割され，各トークンはさらに埋め込みベクトルに変換される．ここで，Textual inversion は，予測ノイズと付与ノイズの差を損失とする拡散モデルの学習を通じて，この変換プロセスを最適化（fine-tuning）する．今回は，特に，テキストプロンプト中の擬似単語の数を増やすことで，より精細で多様な特徴を表現した画像を生成可能とした．具体的には，Stable Diffusion v1-5 では最大で 68 個まで増やすことができるため，本研究では，クラスごとに疾患名の後に 0～67 の番号を付与した 68 個の疑似単語を作成した．

4. 実験条件

実験では日本皮膚科学会が保有する National Skin Disease Database の 162 疾患，42,435 症例，241,816 画像を使用した．このうち 61,982 枚 8,783 症例をテスト，179,834 枚 33,652 症例を学習と validation（学習回数の最適化）に使用した．

画像生成のための提案手法の textual inversion による fine-tuning では，一部のパラメータを除いて文献[7]に従った．変更点は，擬似単語数（1→68），バッチサイズ（16→10），学習イテレーション（約 3～32epoch→5epoch）の三つである．また，生成対象クラスにおいて生成する画像数は，対象クラスの学習データの中央値である 210 枚とした．分類器は，文献[3]の距離学習を適用した ResNet18 を使用した．

5. 実験結果と考察

まず生成画像の質の評価を行ったが，これには，実画像と合成画像の類似度として，事前学習済みモデル facebook/dino-vits16 [11]の特徴量空間での cos 類似度に基づいて定義された最大 DINO 類似度を使った [12]．この評価値は，j番目の生成画像s_jの質を，同クラスの実画像r_i（n枚）から下式で計算した．

$$\text{最大 DINO 類似度} = \frac{\sum_{j=1}^{n} \max_{r_i} \left(\frac{r_i \cdot s_j}{\|r_i\| \, \|s_j\|} \right)}{n} \quad (1)$$

図 3 は，生成画像に対して最大の DINO 類似度を示す実画像を並べた．これから，いずれの画像も実画像に良く類似していることが分かった．

次に，生成画像と実画像を用いて 162 クラスの分類器を学習したところ，生成画像を用いない場合と比較して，用いた場合の macro-sensitivity は 0.2220 から 0.2223 に上がったが，その差はわずかであった．次に，生成画像を追加した生成対象クラスのみに注目した場合の macro- sensitivity を図 4 に示す．縦軸は，実画像のみで学習した場合と生成画像を追加して学習したときの生成対象 41 クラスの macro-sensitivity の 5-fold CV の平均である．ウィルコクソンの符号付順位検定で帰無仮説（両者の間の性能に差がない）は棄却（p<0.01）された．

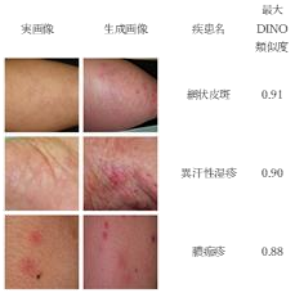


図 3 生成画像の例

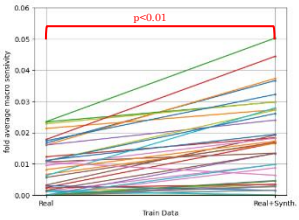


図 4 生成対象クラスの分類結果

6. むすび

本研究では，162 クラスの皮膚疾患の分類精度向上を目的として，拡散モデルを用いて少数クラスの皮膚疾患画像を生成し，これらの画像を用いた学習した．その結果，少数クラスにおいて，性能の向上が確認された（p<0.01）．今後は，残りのクラスにもこの手法を適用し，全体的な精度向上を目指す．

謝辞

本研究では，日本皮膚科学会の National Skin Disease Database を利用しました．データベース構築・維持に関係されている先生方に感謝いたします．

利益相反の有無

なし．

文　献

[1]Burns T, Breathnach S, Cox N et al: Rook's textbook of dermatology. John Wiley & Sons, 2008

[2]Fujisawa Y, Otomo Y, Ogata Y et al: Deeplearning-based, computer-aided classifer developed with a small dataset of clinical images surpasses board-certifed dermatologists in skin tumour diagnosis. Br J Dermatol 180(2): pp.373–381, 2019

[3]Tanaka M., Saito A., Shido K. et al: Classification of large-scale image database of various skin diseases using deep learning. Int J CARS 16: pp.1875–1887, 2021

[4] Mateusz B, Atsuto M, Maciej A. M et al: A systematic study of the class imbalance problem in convolutional neural networks. Neural networks 106: pp.249-259, 2018

[5] Jascha S., Eric A. W., Niru M et al: Deep Unsupervised Learning using Nonequilibrium Thermodynamics. ICML:pp.2256-2265. 2015

[6] Prafulla D, Alex N: Diffusion models beat gans on image synthesis. Advances in neural information processing systems, 34: pp.8780-8794, 2021

[7] Mohamed A, Bálint G, Péter H et al: Diffusion-based Data Augmentation for Skin Disease Classification: Impact Across Original Medical Datasets to Fully Synthetic Images. Deep Generative Models. DGM4 workshop in conjunction with MICCAI 2023, LNCS 14533:pp.99-109, 2023

[8] Robin R, Andreas B, Dominik L et al: High-resolution image synthesis with latent diffusion models. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, pp.10684-10695, 2022

[9] Luke W. S, James A. D, Luke M et al: Augmenting medical image classifiers with synthetic data from latent diffusion models. arXiv e-prints, arXiv: 2308.12453, 2023

[10] Rinon G, Yuval A, Yuval A et al: An Image is Worth One Word: Personalizing Text-to-Image Generation using Textual Inversion. The Eleventh International Conference on Learning Representations, 2022.

[11] Mathilde C, Hugo T, Ishan M et al: Emerging Properties in Self-Supervised Vision Transformers. CVPR:pp.9650-9660, 2021

[12] Nataniel R, Yuanzhen L, Varun J et al:DreamBooth: Fine Tuning Text-to-Image Diffusion Models for Subject-Driven Generation. CVPR:pp.22500-22510, 2013

光干渉断層血管撮影画像からのフルオレセイン蛍光眼底造影様画像の生成手法

溝部 秀謙[*1]，鳥羽 修平[*1]，平野 隆雄[*2]，村田 敏規[*2]
[*1] キヤノン株式会社
[*2] 信州大学 医学部 眼科学教室

Generation method of Fluorescein Angiography-like images from OCT Angiography images

Hideaki MIZOBE[*1]，Shuhei TOBA[*1]，Takao HIRANO[*2]，Toshinori MURATA[*2]
[*1] *Canon Inc.*
[*2] *Department of Ophthalmology, School of Medicine, Shinshu University*

要旨：蛍光眼底造影検査は網膜－脈絡膜疾患の診断を補助する一般的な検査であるが，造影剤の利用に起因する副作用等の課題がある．本研究では，造影剤を用いない光干渉断層計（OCT）検査によって取得される，ある一時点の OCT Angiography（OCTA）画像に基づいて，フルオレセイン蛍光眼底造影（FA）検査画像を模した，造影剤の経時的な漏出の様子を描出する画像（FA 検査様画像）を動画像で生成するモデルを構築した．モデルの訓練には，糖尿病網膜症患者を対象とした OCT 検査で取得された OCTA 画像，非撮像時間帯への合成画像挿入処理と位置合わせ処理を施した FA 検査画像，および FA 検査画像の造影時間情報とによって構成されたデータセットを用いた．そして，有効画素領域のみを損失計算の対象として訓練を実施した．生成した動画像は，実際の FA 検査画像に対して平均 SSIM0.91（SD0.08）という高い類似性を示した．
キーワード：画像生成，ドメイン変換，人工知能，光干渉断層計，蛍光眼底造影検査

1. はじめに

フルオレセイン蛍光眼底造影（FA）検査は網膜血管とその病理を描写するための標準的な検査であるが，造影剤を投与する必要があるため，アナフィラキシーショックを含むアレルギー反応に注意する必要がある．一方で光干渉断層計（OCT）検査によって取得される OCT Angiography（OCTA）画像は，造影剤を使用せずに網膜血管を描出できる．また，OCTA 画像は，毛細血管レベルで新生血管や血管の閉塞，赤血球の動態を観察できることや，一度に広視野を撮影できる機種もあることなどから，近年では利用機会が増加している．

しかし，OCTA 画像が従来の FA 検査画像を完全に代替する検査画像として採用されていない理由の一つに，血管や毛細血管瘤における血液成分の漏出を描出できないということがある．例えば，糖尿病網膜症において発症しやすい糖尿病黄斑浮腫（DME）では上述の漏出を特定することが重要であるため，治療アプローチの決定には OCTA 検査画像よりも FA 検査画像の方が有用である[1].

本研究では，造影剤を使用せずに漏出部位を特定することを目的として，OCTA 画像に基づいて FA 検査様画像を生成する画像生成モデルを開発した．

2. 提案手法

1）訓練用データセット

2019 年から 2022 年の間に信州大学眼科外来を受診した糖尿病網膜症患者から取得された 43 眼の，広視野 OCTA 画像（23mm×20mm, Canon, Xephilio OCT-S1） 43 画像と，経時的に撮影された FA 検査画像（55°，Heidelberg Engineering, SPECTRALIS） 1,532 画像に基づいて，画像生成モデルを訓練するためのデータセットを構築した．具体的には，FA 検査画像には後述の非撮像時間帯への合成画像の挿入処理と位置合わせ処理を実施し，血管構造の位置が同期された 19,648 ペアの OCTA 画像と FA 検査画像を含むデータセットを構築した．

2）非撮像時間帯への合成画像の挿入処理

FA 検査では左右の眼を撮影対象としているものの，通常は同時に両眼を撮影しない．つまり，一方の眼が撮影されている間は，他方を撮影しないため，眼毎に FA 画像が存在しない非撮像時間帯が存在する．時間経過による造影効果の傾向を学習するための FA 画像が存在しない非撮像時間帯は，画像生成モデルが出力する画像の品質が悪化するため，非撮像時間帯に対して，撮像時間帯からサンプリングした FA 画像によって作成した合成画像群を追加挿入した．

3）OCTA 画像と FA 検査画像の位置合わせ

同じ日に取得された同じ患者の OCTA 画像と FA 画像の血管構造が一致するように位置合わせ処理を実施した．具体的には，血管抽出処理を実施した二値 OCTA 画像と，同様に血管抽出処理を実施した二値 FA 画像の，対応する画素間の画素値の差の二乗和を最小化するような非剛体の変形を自動推定した．

4）画像生成モデルのネットワーク構造

本研究では，画像生成モデルの画像生成部として，OCTA 画像と造影時間を入力データとして位置合わせされた FA 画像を正解データとして訓練可能な U-Net [2]をベースとした畳み込みニューラルネットワーク（CNN）を採用した（図 1）．

この CNN への入力データは，具体的には，OCTA 画像のテンソルに対して，造影時間 （ミリ秒） のスカラー値に基づく

テンソルをチャンネル軸に結合したテンソルである.

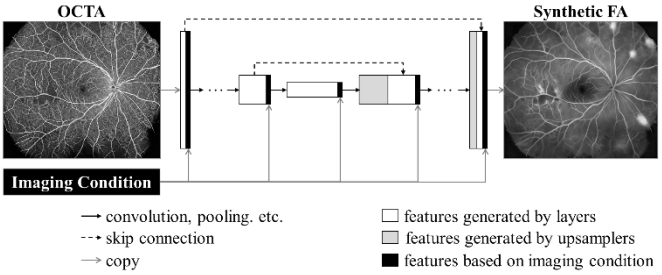


図 1: 画像生成モデルのネットワーク構造

5）損失関数

FA 検査画像の周辺部にはマスク領域が存在する. そのため, 一般的な手法と同様に, OCTA 画像を入力データとし, FA 検査画像を正解データとして画像生成ネットワークモデルを訓練すると, 生成画像にマスク領域様の領域が描出されてしまい, OCTA 画像の撮像領域全体に対する漏出様態を観察できなくなってしまう. そこで, 構成した有効画素領域のみを損失計算の対象として画像生成モデルの訓練を実施した.

6）生成画像の動画化

FA 検査画像では, 造影剤投与後の経過時間に応じて, 漏出の程度が変化する様子が描出される. 本研究の画像生成モデルにおいても, この変化を再現するため, OCTA 画像は変えずに, 入力する造影時間データを変化させて動画フレーム画像に相当する画像を生成した.

3. 評価

1）評価用データセット

画像生成モデルの評価のために, 訓練用データセットに含まれない糖尿病網膜症患者から取得された 5 眼の OCTA 画像（5 画像）と, FA 検査画像（540 画像）に基づいてデータセットを構築した. なお, 評価用データセットの FA 検査画像は上述の位置合わせ処理のみを実施し, 非撮像時間帯への合成画像の挿入処理は実施していない.

2）評価方法と結果

評価用データセットに含まれる FA 検査画像と同じ造影時間をターゲットに FA 検査様画像を生成し, 当該 FA 検査画像と同じ領域のマスク処理を行ったうえで, 構造的類似性（SSIM）を計測した. その結果, 平均 SSIM は 0.91（標準偏差 0.08） であった. なお, 上述の撮像時間帯への合成画像の挿入処理を実施していない別の訓練用データセットによって訓練された画像生成モデルの結果は, 平均 SSIM は 0.86（標準偏差 0.18） であった.

3）画像生成モデルの出力例

図 2（a）は FA 検査画像（正解データ）, 図 2（b）は画像生成モデルの出力画像（1 つの動画フレーム画像に相当）, 図 2（c）は画像生成モデルに入力した OCTA 画像である.

図 2（b）に示す生成画像では, 図 2（a）に示す FA 検査画像の全体的な明るさや血管構造を, ある程度再現できている. また, 図 2（a）に示す FA 検査画像で確認される微小な漏出の一部が, 図 2（b）に示す生成画像で描出されている. しかし, FA 検査画像で確認されるすべての微小な漏出を描出できているわけではない.

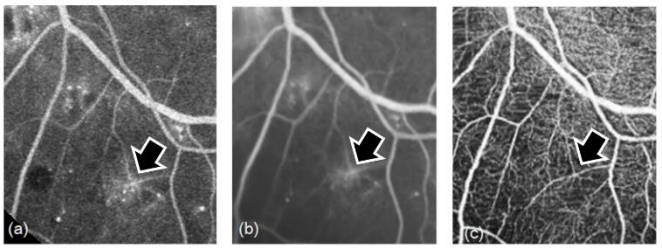


図 2: 画像生成モデルの出力例

4. まとめ

本研究では, 実際の FA 検査画像と似た造影効果を示す画像を OCTA 画像から生成する手法を提案した. FA 検査様画像を生成する処理は, 従来の FA 検査と比較して, 造影剤を使用しない点, 撮影時間が短い点などの優位な特徴があるため, 将来的には FA 検査の代替検査としての活用が期待される.

しかしながら, 開発および評価に用いたデータセットは糖尿病網膜症に由来するものに限定されているため, 本研究の画像生成モデルはその他の疾患・様態を含む OCTA 画像の処理に適しているとはいえない.

今後は, データセットの拡充および画像生成モデルの改良を実施し, 臨床での運用に耐える技術となりうるか, 慎重に評価する必要がある.

また, その他の展望として, 今回提案した非造影画像から造影画像（静止画や動画）を生成する手法は, インドシアニングリーン（ICG）などの他の造影剤を用いた検査や, CT や MRI などの他の撮像装置における造影検査に対しても応用が可能であると考えられる.

利益相反の有無

無し

文　献

［1］E. A. Novais et al.: Optical Coherence Tomography Angiography of Chorioretinal Diseases, Ophthalmic Surg Lasers Imaging Retina: 47, 848-861, 2016

［2］O. Ronneberger et al.: U-Net: Convolutional Networks for Biomedical Image Segmentation, Springer International Publishing: 234–241, 2015

腹部単純 X 線画像からのガス領域抽出における 疑似 X 線画像を用いた U-Net 事前学習法の検討

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

Pre-training Method Using Pseudo-X-Ray Images for Gas Region Segmentation in Abdominal X-ray Images

Naoya TAKASHIMA[*1], Daisuke FUJITA[*1], Tsuyoshi SANUKI[*2],
Yoshikazu KINOSHITA[*2], Syoji KOBASHI[*1]
[*1] *University of Hyogo*
[*2] *Hyogo Prefectural Harima-Himeji General Medical Center*

要旨：慢性便秘症は世界人口の 15%に影響を与える慢性疾患であり，生活の質を著しく低下させている．便秘は多様な症状や病態を示し，その原因に応じた治療が必要である．適切な治療法の選択には，腹部単純 X 線画像中のガスや便の量と位置の定量化が重要である．本研究では，便秘の画像診断支援法として，U-Net を用いたガスと便領域の自動抽出法を提案している．本稿では，CT 画像から生成された疑似 X 線画像を用いた事前学習法を提案し，その有効性を検証する．実験では，U-Net の初期ネットワーク重みにランダム，ImageNet での事前学習，疑似 X 線画像を用いた大腸領域抽出での事前学習を 95 例の被験者に交差検証により適用し，DICE 係数がそれぞれ 0.520，0.676，0656 となり，事前学習の有効性が確認できた．また，疑似 X 線画像を用いた事前学習は ImageNet と同等であり，今後の精度向上には他領域の抽出問題での事前学習，疑似 X 線画像生成法についての検討が必要である．
キーワード：セマンティックセグメンテーション，腹部 X 線画像，便秘，DRR

1. はじめに

慢性便秘症の有訴率は世界的に 15%[1]に達し，多様な症状や病態があるため, 原因の特定と適切な治療法の選択が重要である．便とガスの量と便秘症状，および大腸の各領域の便の特徴と間に関係があることがわかっているため, ガスと便の量と所在が分かれば，便秘の重症度や分類の手掛かりとなる[2].

そこで，熟練の消化器内科医らは，腹部 X 線画像の読影により，便秘の重症度やタイプを判断し，治療法，治療薬を選定して治療を行っている．しかし，経験の少ない医師や消化器内科医以外の専門医では，腹部 X 線画像の読影による診断は困難である．このような背景から，腹部 X 線画像からガスや便の量および位置を自動抽出する技術が求められており, 我々は便秘の画像診断支援法として，U-Net[3]を用いたガスと便領域の自動抽出法を提案している．

深層学習，特に畳み込みニューラルネットワーク（CNN）の性能は，大量のラベル付き訓練データに大きく依存しており，医療分野のようにデータ数が限られている状況でこれらのモデルを適用することは困難である. この課題を克服するために，大規模データセット（例 : ImageNet[4]）に基づく転移学習が用いられている．医療分野においてその手法の有効性は，呼吸器疾患の分類[5]，細胞のセグメンテーション[3]などの研究で示されている．しかし，自然画像と医療画像では視覚情報やモダリティが大きく異なっており, 医療画像に基づく事前学習を用いた方が転移学習の際に学習がうまく進むことが予想されるが，なぜ最近の研究の多くが ImageNet などの自然画像データセットでの事前学習に依存しているのか疑問である．さらに，ImageNet を用いた事前学習が最良の選択ではあるが，画像のモダリティがより近い医用画像を用いた事前学習の有効性が示されている研究がある[6].

そこで本研究では，腹部単純 X 線画像からのガス領域抽出における，CT 画像から生成された疑似 X 線画像を用いた事前学習法を提案し，その有効性を検証する．

[*1] 〒671-2280 兵庫県姫路市書写 2167
e-mail: kobashi@eng.u-hyogo.ac.jp

2. 使用データ・提案手法

2.1 事前学習

Kaggle の RSNA 2023 Abdominal Trauma Detection コンペティションで使用された腹部 CT 画像の公開データセット[7]から 781 名を収集し, TotalSegmentator[8]を適用して大腸領域のマスク画像を作成する．その後，CT 画像および CT マスクに DRR(Digitally Reconstructed Radiograph)法を適用することにより，疑似 X 線画像および大腸領域マスクを生成し，U-Net を用いて大腸領域を学習する．これを事前学習済み重みとする．

2.2 ガス領域抽出

（旧）製鉄記念広畑病院に来院し，腹部単純 X 線画像を撮影し，画像上に顕著な病変を有しない患者を無作為に抽出した 95 名（男性 48 名，女性 47 名）を対象とした．平均年齢は 62.3 歳で，標準偏差は 16.6 歳である．各画像に対して，熟練の消化器内科医が，手動でガス領域を抽出し，これをアノテーションデータとする．

本研究では，U-Net の初期ネットワーク重みにランダム，ImageNet での事前学習済み重み，疑似 X 線画像を用いた大腸領域抽出での事前学習済みの 3 条件を用いたときのガス領域抽出精度の結果を比較する．図 1 に提案手法の流れを示す．

2.3 実験条件

全データを 5 分割交差検証により分割し，それぞれの実験で訓練データが全体の 60%，検証データが 20%，評価データが 20%とする．全データセットを一度だけ評価データとして用いるように分割する．バッチサイズは 32，初期学習率を10^{-3}に設定しコサインスケジューラを用いてスケジューリングする．

2.4 評価方法

ネットワークモデルより求められる各画素の対象領域に属する確率が 0.5 以上のとき 1 に，0.5 未満のとき 0 とすることで，本手法の出力結果として 2 値画像を得る．

領域抽出結果の精度評価指標として DICE 係数を用いる．各画像において対象領域の面積が異なり，画素数と DICE 係数の乖離があるため，全画像を合算して求めた DICE 係数を評価指標として用いる．

3. 実験結果・考察

U-Net の初期ネットワーク重みに（モデル 1）ランダム，（モデル 2）ImageNet での事前学習済み重み，（モデル 3）疑似 X 線画像を用いた大腸領域抽出での事前学習済みの 3 条件において，提案手法によるガス領域の抽出領域と医師が手動で抽出した領域を比較した結果，DICE 係数がそれぞれ 0.520, 0.676, 0656 となった．結果より，モデル 1 による抽出精度と比較して，モデル 2 とモデル 3 の抽出精度の方が優れており，事前学習の有効性が確認できた．また，モデル 3 はモデル 2 と比較して，大きな差はないが抽出精度が良く，ImageNet での事前学習による抽出精度が最良ではあるものの，疑似 X 線画像を用いた事前学習は ImageNet と同等の結果を示し，画像の視覚情報やモダリティがより近い医療画像を事前学習に用いる有効性を確認できた．モデル 2 の抽出精度がモデル 3 と比較して劣った原因としては，今回事前学習として用いた疑似 X 線画像は単一の CT 画像データセットから収集しており，形態学的情報が限られていたことなどが考えられる．

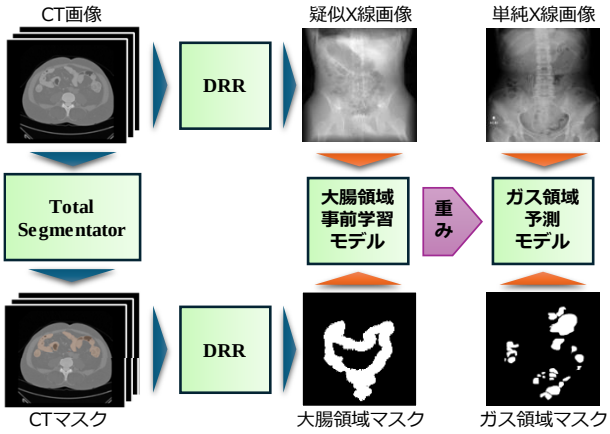


図 1 腹部単純 X 線画像からのガス領域抽出における疑似 X 線画像を用いた事前学習法のフローチャート

4. まとめ

本研究では，U-Net を用いた腹部 X 線画像からガスと便領域の抽出において，CT 画像から生成された疑似 X 線画像を用いた事前学習法を提案し，その有効性を検証した．U-Net の初期ネットワーク重みにランダム，ImageNet での事前学習，疑似 X 線画像を用いた大腸領域抽出での事前学習を 95 例の被験者に交差検証により適用したところ，DICE 係数がそれぞれ 0.520, 0.676, 0656 となり，事前学習の有効性が確認できた．また，疑似 X 線画像を用いた事前学習は ImageNet と同等の結果を示し，今後の精度向上には他領域の抽出問題での事前学習，疑似 X 線画像生成法についての検討が必要である．

利益相反の有無

なし

文　献

[1] Aziz I, Whitehead WE, Palsson OS et al: An approach to the diagnosis and management of Rome IV functional disorders of chronic constipation. Expert Rev Gastroenterol Hepatol 14(1): 39-46, 2020

[2] Haraikawa M, Takeda T, Oki S et al: Correlation between Constipation Symptoms and Abdominal CT Imaging: A Cross-Sectional Pilot Study. Journal of Clinical Medicine 12(1): 341, 2023

[3] Ronneberger O, Fischer P, Brox T: U-Net: Convolutional Networks for Biomedical Image Segmentation. International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015, pp234-241

[4] Krizhevsky A, Sutskever I, Hinton GE: ImageNet Classification with Deep convolutional neural Networks. Communications of the ACM 60(6): 84-90, 2017

[5] Kermany DS, Goldbaum M, Cai W et al: Identifying medical diagnoses and treatable diseases by image-based deep learning. Cell 172(5): 1122-1131, 2018

[6] Wen Y, Chen L, Deng Y et al: Rethinking pre-training on medical imaging. Journal of Visual Communication and Image Representation, 2021, p78

[7] https://www.kaggle.com/competitions/rsna-2023-abdominal-trauma-detection/data

[8] Wasserthal J, Breit HC, Meyer MT et al: TotalSegmentator: Robust segmentation of 104 anatomic structures in ct images. Radiology: Artificial Intelligence 5(5) 2023

細胞核画像の形とテクスチャへの特徴分離と生成モデルの構築

村上 和真[*1], 田口 慶[*1], 横田 達也[*1], 大島 孝一[*2],
三好 寛明[*2], 永石 美晴[*2], 橋本 典明[*3], 竹内 一郎[*3], 本谷 秀堅[*1]
[*1] 名古屋工業大学, [*2] 久留米大学, [*3] 名古屋大学

Disentanglement of features into shapes and textures of cell nuclear images and construction of generative models

Kazuma MURAKAMI[*1], Kei TAGUCHI[*1], Tatsuya YOKOTA[*1],
Koichi OHSHIMA[*2], Hiroaki MIYOSHI[*2], Miharu NAGAISHI[*2],
Noriaki HASHIMOTO [*3], Ichiro TAKEUCHI[*3], Hidekata HONTANI[*1]
[*1]*Nagoya Institute of Technology*, [*2]*Kurume University*, [*3]*Nagoya University*

要旨： 悪性リンパ腫を構成する細胞を客観的に分類する基準を構築する準備として，その H&E 染色画像の自己符号器により獲得する内部表現を形態と内部テクスチャに分離したうえで拡散モデルを応用する手法を提案する．リンパ節は様々な種別の細胞により構成されている．そしてがん化にともない各種別の細胞は病型に応じて変化する．これら細胞の種別や変化による細胞の違いは H&E 染色画像中の細胞核により観察できるが，その違いを病理医に理解可能な特徴量により定量評価する基準は存在しない．本研究においてこの基準構築に向けた初期検討をおこなう．まず細胞核画像の自己符号器を組み合わせることにより，細胞核輪郭の形態と核内部テクスチャの表現へと分離する．ついで内部表現の拡散モデルを構築し，種別やがん化の度合いの異なる二つの細胞核を内挿する系列画像を生成する．この系列画像はリンパ節の細胞核の空間において，形態や内部テクスチャの内挿を実現したものであり，例えば異なる種別間の識別境界を明示することができる．提案法と実験結果を得たので報告する．
キーワード：悪性リンパ腫, 説明可能性, 拡散モデル

1. はじめに

悪性リンパ腫においてがん化した細胞は正常な細胞とは異なる形態が観察され，形態変化の仕方は病型ごとに異なる．病理医は H&E 染色画像の観察を通して個々の細胞核の種別や形態変化を評価している．しかし，現在細胞核を，病理医に理解可能な特徴量により定量評価する基準は存在しない．本研究ではまず，細胞核画像より形態特徴とテクスチャ特徴を分離表現する．これにより，細胞核の変化について二つの理解可能な特徴量を分けて解析することを可能にする．次に特徴量の持つ潜在空間を拡散モデルを用いて構築する．種別や病態の異なる二つの細胞核から得られる特徴量を内挿して生成される系列画像は，異なる種別の細胞核の識別境界明示や，病態の変化に伴う細胞核の変化予測に応用可能である．実験結果として細胞核画像からの特徴分離の結果と，種別の異なる細胞核の間をつなぐ系列画像の生成，その識別結果を報告する．

2. 提案法

提案法ではまず，自己符号器である DRIT[1]を用いて細胞核を形・大きさを表す輪郭特徴と色や細胞内の核を表すテクスチャ特徴へ分離する．学習データには悪性リンパ腫診断に用いられた H&E 染色画像のうち Reactive もしくは Follicular Lymphoma と診断されたものより切り出した細胞核画像を約 20 万枚用いた．細胞核画像は個々の細胞核の重心を中心とする画像で，細胞核セグメンテーションには Hover-Net[2]を用いた．

細胞核の形態特徴の抽出には核の内外を示す二値画像を用いる．自己符号器は形態特徴のみから二値画像を復元し，形態特徴とテクスチャ特徴から RGB の元画像を復元するだけではなく，二つの異なる細胞核それぞれより得られる形態特徴とテクスチャ特徴を入れ替えることにより形やテクスチャを相互に交換できるように学習する[1].

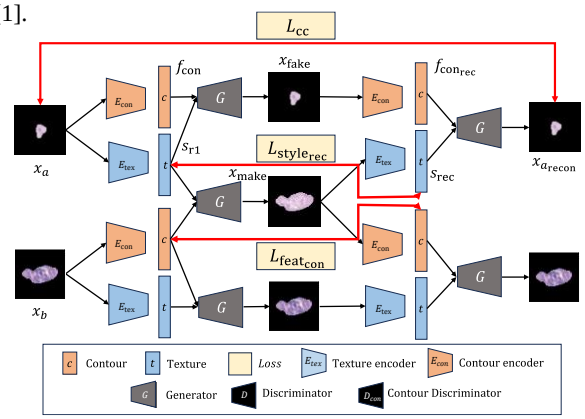


図 1：細胞核画像の特徴分離

次に形態特徴とテクスチャ特徴の分離された潜在空間

において拡散モデルを構築する．この潜在空間には，長軸の向きを正規化した細胞核の画像より分離された特徴が持つ空間を使用する．拡散モデルの学習には DDPM[3]を用いる．この拡散モデルにより生成した二つの特徴量と，前述した自己符号器を併用することにより，RGB の細胞核画像を生成できるだけではなく，形態を固定してテクスチャを入れ替えたり，テクスチャを固定して形態を入れ替えたりと任意の特徴を持つ細胞核画像を生成することが可能である．

本発表では異なる二つの細胞核画像間を内挿する系列画像を生成し，種別ラベルが付された細胞核画像約 1500 枚により学習した種別識別器の予測を用いて系列画像の評価を行う (図 2)．がん化の度合いの異なる細胞核を内挿すればがん化に伴う細胞核の変化を可視化し，種別の異なる細胞核を内挿すれば識別境界付近の画像を可視化できることを期待できる．

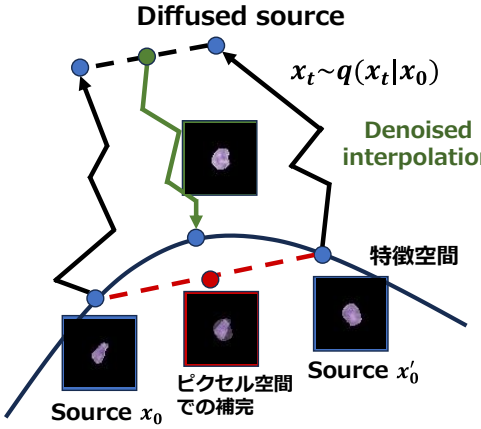


図 2：拡散モデルを用いた画像間の内挿による系列画像の生成

3. 実験結果

細胞核画像から分離されたテクスチャ特徴量の分布を t-SNE により可視化した結果と，各テクスチャ特徴を用いて生成した細胞核画像を図 3 に示す．細胞核のテクスチャは大きく二つのカテゴリに分離されていることがわかる．図 4 に，それぞれ実細胞核画像二枚を内挿した系列画像と，系列中の核細胞核画像の種別を識別した結果を示す．最初に示した系列はガンの進行の指標となる Centroblast を内挿する系列であり，系列両端の形態は実画像のものである．系列中に Centroblast 以外が表れないことなどを確認できる．図中下に示す系列は種別が Round-Medium と Centrocyte で異なる二つの細胞核を内挿した系列であり，識別境界付近の画像を明示できている．このような系列画像は細胞種別の識別基準を考えるうえで有用である．

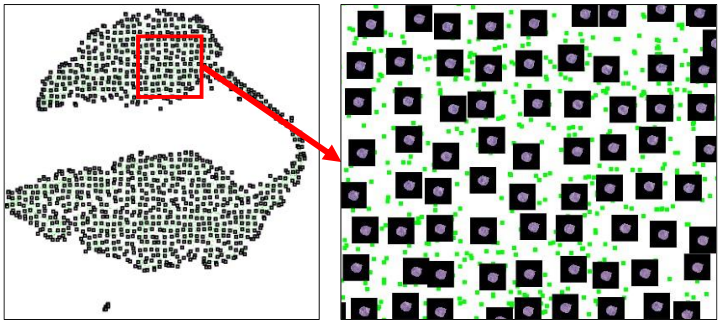


図 3：輪郭特徴の正規化による特徴分離の確認

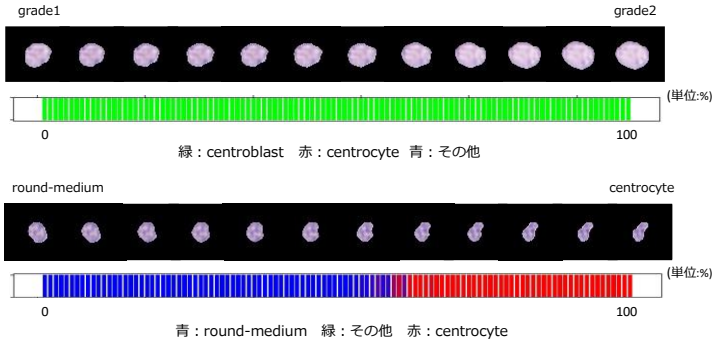


図 4：系列画像と種別識別結果

4. まとめ

細胞核画像を輪郭形状と内部テクスチャの表現へ分離し，異なる二つの細胞核を内挿する系列画像の生成を輪郭形状の系列特徴を用いて行った．テクスチャ特徴量の可視化結果から二つの集合が繋がっている特徴的な分布が確認できた．今後はガンの進行度や種別の識別に有用な定量基準の構築を検討する．

利益相反の有無

なし

文 献

[1] Hsin-Ying Lee, Hung-Yu Tseng, Jia-Bin Huang *et al* : Diverse Image-to-Image Translation via Disentangled Representations, ECCV, Aug 2018

[2] Simon Graham, Quoc Dang Vu, Shan E AhmedRaza *et al* :HoVer-Net: Simultaneous Segmentation and Classification of Nuciel in Multi-Tissue Histology Images, arXiv:1812.06499 [cs.CV], Dec 2018

[3] Jonathan Ho, Ajay Jain, Pieter Abbee: Denoising Diffusion Probabilistic Models, arXiv:2006.11239v2 [cs.LG], Dec 2020

Textual Inversion を用いた FDG PET 画像の text-to-image 生成の試み

松原　佳亮[*1]，村上　貴也[*1]，木下　富美子[*2]，篠原　祐樹[*2]，茨木　正信[*2]，木下　俊文[*2]
[*1] 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
[*2] 秋田県立循環器・脳脊髄センター放射線医学研究部

Text-to-image generation of FDG PET images by Textual Inversion

Keisuke MATSUBARA[*1]，Takaya MURAKAMI[*1]，Fumiko KINOSHITA[*2]，Yuki SHINOHARA[*2]，Masanobu IBARAKI[*2]，Toshibumi KINOSHITA[*2]
[*1] *Akita Prefectural University*
[*2] *Akita Cerebrospinal Cardiovascular Center*

要旨：近年拡散モデルを用いた text-to-image 画像生成が台頭してきている。本研究では画像の特徴を一つの単語(“S*”)に圧縮することで画像生成を制御する Textual Inversion を用い、FDG PET 画像の text-to-image 生成を試みた。

23 例の肝臓 FDG PET 画像を用い、事前学習済み Stable Diffusion v1.5 を Textual Inversion により fine-tuning した。当該モデルを用いて”S*”及びそれに肝臓における集積という条件を加えたプロンプトによる生成を試みた。

Fine-tuning したモデルにより、実際の PET 画像にごく近い画像の生成に成功した。一方で、集積を条件に加えたプロンプトを用いた時と”S* image”のみの時とで差異がなく、集積の制御はできなかった。集積の制御には健常画像による学習等が必要である。

キーワード：PET，深層学習，画像生成

1. はじめに

深いニューラルネットワークモデルによる機械学習, 深層学習 (deep learning)の登場により，多くの画像認識タスクが高い精度で遂行できるようになった. 医用画像分野においても幅広く応用されており，MR 画像から CT 画像の生成［1］等，従来困難であった画像の復元, 変換, 生成も可能にしている［2, 3］. また近年は Transformer［4］や拡散モデル［5］といった技術の登場により，テキストからそれに沿った画像を生成する text-to-image 画像生成が高い精度でできるようになってきており［6］, アートやエンターテイメントの分野で普及が始まっている.

一方, 高精度な深層学習モデルを構築するには大規模なデータセットによる学習が必要となる. 医用画像はその特性から大規模なデータセットの収集・用意が困難であり，この欠点が特に相対的に検査数が少ない PET (positron emission tomography) 検査等での深層学習の応用・普及の妨げとなっている．この問題に対して, 手持ちの画像データに回転等の変換を加えて学習データを増やすデータ拡張がよく行われている．また，自然画像のデータベースを用いて事前に学習したモデルを手持ちの医用画像データで再学習する fine-tuning もデータ数不足の問題の解決策になり得る．実際に Chambon らはデータ拡張を目的とした X 線画像の text-to-image 画像生成を事前学習済みの StableDiffusion モデルを用いて実現している［7］．しかし，PET 画像は X 線画像や MR 画像のような解剖学的画像とは異なり，生体機能を反映した画像であるため, また空間分解能が低いため，text-to-image 画像生成を行う場合にそれに合わせた工夫が必要と考えられる.

Fine-tuning の方法の 1 つとして画像のスタイル・テクスチャの情報を”S*”という単語に圧縮し埋め込む textual inversion という方法が提案されている［8］．本研究では事前学習済みモデルを用いた textual inversion を用いることで，PET 画像特有の画像特徴を捉え，text-to-image 画像生成を実現できると考え，本法による FDG (fluorodeoxyglucose) PET 画像の text-to-image 画像生成を試みた.

2. 方法

2.1. 対象

本研究では肝臓に集積がみられた 23 例の肝臓近傍における FDG PET 画像を学習データとして用いた．この際，読影医が読影レポートへの添付を目的に抽出した PET-CT フュージョン画像を用いた．用いた画像の colormap は rainbow であった．画像の例を図 1 に示す.

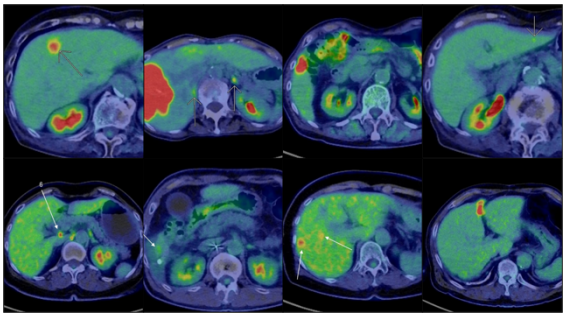


図 1 fine-tuning に用いた PET-CT フュージョン画像例

本研究は秋田県立循環器・脳脊髄センター倫理委員会の承認を得た上で，その指示に従って実施した．

2.2. Textual inversion による fine-tuning

本研究では事前学習済みの Stable Diffusion ver.1.5 モデル (https://huggingface.co/runwayml/stable-diffusion-v1-5)を用いて，textual inversion による fine-tuning を実施した．初期学習率を 0.0005，num_vectors_per_token を 8 に設定した．また画像の特徴を指定する initializer word には[“liver”, “tomography”, “colormap”, “positron emission tomography”, “hyperaccumulation”]を指定した．特徴を埋め込む単語には”S*”を用いた．Textual inversion の実行には原著論文著者のコード(https://github.com/rinongal/textual_inversion)を実行環境に合わせて改変したものを用いた．

2.3. 画像生成

2.2.で学習したモデルにテキスト（プロンプト）を与え，PET 画像の生成を試みた．その際，プロンプトによる集積の制御が可能かを検証するために，”S*”（プロンプト 1），“S* images, Hyperaccumulation on the upper side of the liver”（プロンプト 2）の 2 種のプロンプトによる画像生成を行い，視覚による比較評価を実施した．Scale（プロンプトに従う度合い）は 10, ddim_eta は 0，サンプリングステップ数(ddim_steps)は 50 に設定した．

3. 結果

2.2.で学習したモデルにプロンプト 1，プロンプト 2 をそれぞれ与えて生成した画像を図 2，3 に示す．双方のプロンプトとも，学習データとして用いた PET-CT フュージョン画像の特徴（臓器の形状，集積の程度，バラつき，色など）を良く捉えた画像が生成された．一方で，生成された画像にプロンプトによる違いはみられなかった．

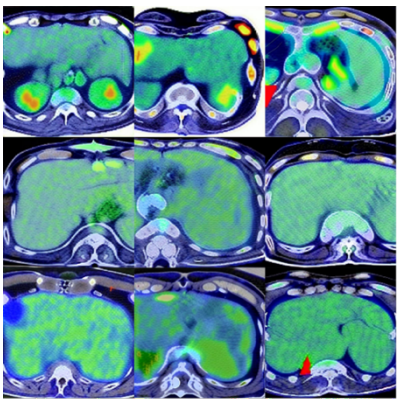


図 2 プロンプト 1 で生成した画像

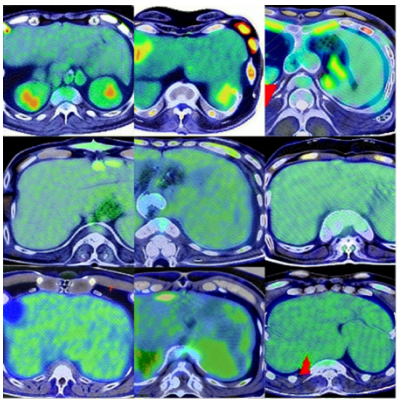


図 3 プロンプト 2 で生成した画像

4. 考察・まとめ

本研究の結果から事前学習済み Stable Diffusion モデルと textual inversion を用いた fine-tuning により，PET 画像を生成することが可能であることが示唆された．一方で，プロンプトにより集積を制御するまでには至らず，データ拡張に用いるには健常画像を用いた fine-tuning などの改善が必要である．また今回はキャプチャ画像を用いたため，PET 画像の特徴である定量性が担保されていない．今後，本法を実用で用いるためには定量性を担保できるための工夫が必要である．

謝辞

本研究は JSPS 科研費 JP23K07087 の助成を受けたものです．

利益相反の有無

なし

文　献

[1] Lei Y, Harms J, Wang T, et al. MRI-only based synthetic CT generation using dense cycle consistent generative adversarial networks. Med Phys 46: 3565-3581, 2019

[2] Wang T, Lei Y, Fu Y, et al. A review on medical imaging synthesis using deep learning and its clinical applications. J Appl Clin Med Phys 22: 11-38, 2021

[3] Arabi H, AkhavanAllaf A, Sanaat A, et al. The promise of artificial intelligence and deep learning in PET and SPECT imaging. Phys Med 83: 122-137, 2021

[4] Vaswani A, Shazeer N, Parmar N et al. Attention is all you need. In proceedings of the 31st international conference on Neural Information Processing Systems (NIPS ’17), Long Beach, 2017, pp6000-6010

[5] Ho J, Jain A, Abbeel P, Denoising diffusion probabilistic models. In proceedings of the 34th Conference on Neural Information Processing Systems (NeurIPS 2020), Vancouver, 2020

[6] Rombach R, Blattmann A, Lorenz D, et al. High-resolution image synthesis with latent diffusion models. In proceedings of the IEEE/CVF Computer Vision and Pattern Recognition Conference (CVPR 2022), New Orleans, 2022

[7] Chambon P, Bluethgen C, Langlotx CP, et al. Adapting pretrained vision-language foundational models to medical imaging diagnosis. arXiv: 2210.04133, 2022

[8] Gal R, Alaluf Y, Atzmon Y, et al. An image is worth one word: personalizing text-to-image generation using textual inversion. arXiv: 2208.01618, 2022

Evaluation of intestine segmentation methods for path tracking

Qin AN[*1], Hirohisa ODA[*2], Yuichiro HAYASHI[*1], Takayuki KITASAKA[*3],
Aitaro TAKIMOTO[*4], Akinari HINOKI[*4], Hiroo UCHIDA[*4], Kojiro SUZUKI[*5],
Masahiro ODA[*6, 1], and Kensaku MORI[*1, 6, 7]

[*1] *Graduate School of Informatics, Nagoya University, Nagoya, Japan*
[*2] *School of Management and Informatics, University of Shizuoka, Shizuoka, Japan*
[*3] *School of Information Science, Aichi Institute of Technology, Toyota, Japan*
[*4] *Graduate School of Medicine, Nagoya University, Nagoya, Japan*
[*5] *Department of Radiology, Aichi Medical University, Nagoya, Japan*
[*6] *Information Technology Center, Nagoya University, Nagoya, Japan*
[*7] *Research Center for Medical Bigdata, National Institute of Informatics, Tokyo, Japan*

Abstract : In this paper, we compare the results of intestine path tracking based on different segmentation methods. We also analyze the influence of intestine segmentation accuracy on path tracking. We employed the different trained segmentation models (3D U-Net, TotalSegmentator, MVSNet, and CPS) to achieve the segmentation results and then the distance maps based on the segmentation. The distance maps were used to narrow the segmentation results, which helped to eliminate incorrectly connected parts between the intestinal walls. This strategy reduces shortcuts of the intestine and extracts the correct intestinal path. In the experiment, we used CT volumes labeled by clinicians for training different segmentation models and then achieved path tracking. We evaluated the influence of intestine area segmentation on intestine path tracking using 15 CT volumes and the results show that good segmentation helps with path tracking.
Keywords: Intestine segmentation, Path tracking, Deep learning, Ileus.

1. Introduction

Intestinal diseases may seriously affect human health. Intestinal obstruction [1] is one of the severe diseases, and that includes both mechanical and functional blockages of the intestine. Accurate localization of the intestinal region is critical for obtaining detailed disease information and making preoperative diagnoses. Therefore, intestine path tracking can help physicians accurately diagnose intestinal disease. However, intestine segmentation can help identify the correct intestinal path and assist clinicians in diagnosing intestine diseases.

There are various segmentation networks based on the U-Net are the main methods for medical segmentation, for example, 3D U-Net [2], cross pseudo supervision [3] (CPS), multi-view symmetrical network (MVSNet) [4], and TotalSegmentator [5]. Different segmentation methods can obtain different intestine segmentation results, and the intestine path obtained based on these segmentation results varies. We analyze the influence of segmentation results on the intestine path tracking task by comparing intestine paths from different segmentation results.

2. Method

We perform two steps to obtain intestinal paths from a CT volume. The first step is to segment the intestinal regions. The second step is to obtain intestine path tracking results from the segmentation results. We qualitatively analyze the second step's quality regarding the choice of the first step's segmentation method.

Firstly, we train different intestine segmentation models (3D U-Net, CPS, MVSNet, and TotalSegmentator) and then use the trained segmentation models to infer the testing dataset. Secondly, we extract distance maps from the segmentation results by Euclidean Distance Transform (EDT) and narrow the distance maps by erosion operation. Then we obtain the internal regions by watershed algorithm according to the narrowed distance map, which can effectively eliminate the shortcut due to overlapping between the intestinal walls. Finally, we divide the segmented regions into small blocks and perform the graphical analysis [6] to find the paths running along the narrowed intestine segmentation results. Figure 1 shows the flowchart of the method.

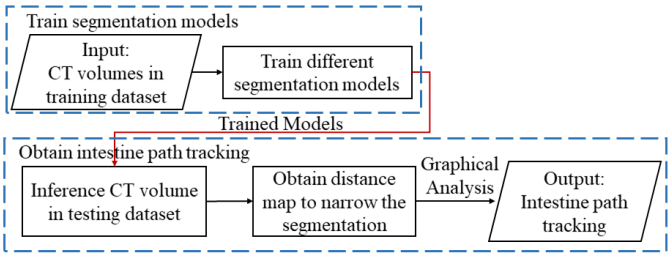


Fig. 1 Flowchart of obtaining intestine path based on results and intestine path tracking results.

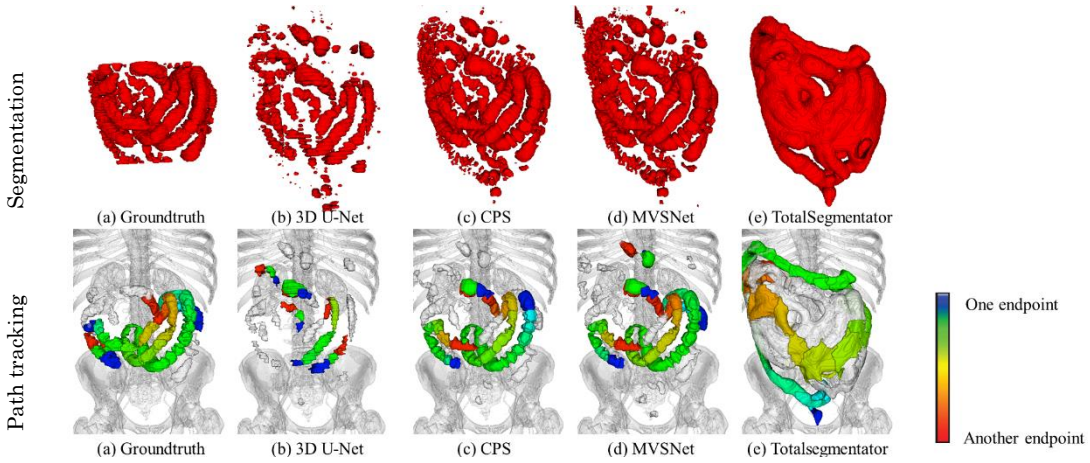


Fig. 2 Intestine segmentation results and intestine path results. The first line is the segmentation results from different segmentation methods. The second line is the path tracking results. The color means the direction of the intestine is blue to red.

Table 1 Accuracies of different segmentation methods

Method	Dice	Recall	Precision
3D U-Net [2]	0.468	0.808	0.378
TotalSegmentator [4]	0.566	0.500	**0.786**
CPS [3]	0.760	**0.846**	0.718
MVSNet [5]	**0.789**	0.845	0.759

3. Experiments and Results

We used a dataset to train different segmentation methods and obtained segmentation results in a testing dataset. Our dataset consists of 171 cases of ileus patients' CT volumes. We interpolated them into 1mm isotropic resolution as preprocessing. To verify the effectiveness of the segmentation methods, we calculated the Dice score, recall, and precision. Table 1 shows the segmentation performance of different segmentation methods on our dataset, and we bold the best result. Figure 2 shows the intestine segmentation results and intestine path results.

4. Discussion and Summary

In this study, we focused on exploring the effect of intestine segmentation on intestine path tracking. Figure 2 shows the segmentation results of the intestinal region by different segmentation methods and the intestine path tracking obtained from the different segmentation results. We can see that the intestine path tracking results from CPS and MVSNet' segmentation results are better than 3D U-Net and TotalSegmentator' segmentation results. The quantitative result of different segmentation methods is shown in Table 1. We can see that CPS method and MVSNet method have higher Dice values than 3D U-Net and TotalSegmentator. From the above results we can conclude that higher accuracy of the intestine segmentation helps us to find more correct intestine paths from CT volumes. Although we have obtained the preliminary results, there is still space for improvement. For example, finding the optimal threshold to handle distance maps better to eliminate the shortcut problem. Future work includes development of quantitative evaluation method for the path tracking.

5. Acknowledgements

Thanks for the help and advice from Mori laboratory. Parts of this work were supported by Hori Sciences and Arts Foundation, MEXT/JSPS KAKENHI (24H00720, 22H03703), the JSPS Bilateral International Collaboration Grants, and the JST CREST (JPMJCR20D5).

Conflict of Interests

There is no conflict of interests in this paper.

Reference

[1] Gore R M, Silvers R I, Thakrar K H et al: Bowel obstruction. Radiologic Clinics, Vol. 53(6), pp 1225-1240, 2015

[2] Cicek O, Abdulkadir A, Lienkamp SS et al: 3D U-Net: learning dense volumetric segmentation from sparse annotation. MICCAI 2016, LNCS 9901, Vol. 2106.01226, pp 424–432, 2016

[3] Chen X, Yuan Y, Zeng G et al: Semi-supervised semantic segmentation with cross pseudo supervision. IEEE/CVF CVPR, pp 2613–2622, 2021

[4] An Q, Oda H, Hayashi Y et al: Intestine segmentation from CT volume based on bidirectional teaching. SPIE Med Imag 2024, Vol. 12926, pp 238-243, 2024

[5] Wasserthal J, Breit H C, Meyer M T Pradella et al: TotalSegmentator: Robust Segmentation of 104 Anatomic Structures in CT Images. Radiology: Artificial Intelligence, Vol. 5(5), pp e230024, 2023

[6] Oda H, Hayashi Y, Kitasaka T et al: Intestinal region reconstruction of ileus cases from 3D CT images based on graphical representation and its visualization, SPIE Med Imag 2021, Vol. 115971N, pp 388-395, 2021

Enhancing Kidney Tumor Segmentation using Multi-Modal Medical Images with Transformer Networks

Pavarut SRISOPITSAWAT[*1], Takashi OBI[*1], Joong-sun LEE[*2], Masaki KOBAYASHI[*3], Hajime TANAKA[*3], Junichiro ISHIOKA[*3], Yoh MATSUOKA[*3]

[*1] *Department of Information and Comunnications Engineering, Tokyo Institute of Technology*
[*2] *Institute of Innovative Research, Tokyo Institute of Technology*
[*3] *Department of Urology, Tokyo Medical and Dental University*

Abstract：Detecting and segmenting kidney tumors presents a significant challenge due to their small size and complex characteristics. Typically, medical professionals rely on various diagnostic techniques, including multi-modal medical imaging, to reach a conclusive diagnosis. However, existing Convolutional Neural Network (CNN) methodologies face limitations in handling multi-modal data of varying sizes and missing information. In this study, our primary objective is to enhance segmentation accuracy, surpassing current methods. To achieve this, we propose a multi-modal fusion framework leveraging the transformer model, capitalizing on the remarkable success transformers have demonstrated in image recognition tasks. Our methodology utilizes the extensive data provided by Contrast-Enhanced Computed Tomography (CECT) and Magnetic Resonance Imaging (MRI), including their respective subtypes, to enrich our medical analysis. This comprehensive approach aims to advance the state-of-the-art in kidney tumor segmentation, offering promising prospects for improved medical diagnosis and treatment planning. Our work also introduces a thorough analysis of different multi-modal fusion techniques. Furthermore, we propose the integration of a multi-modal attention mechanism to ensure the model attends to the most contributory modalities. This innovation enhances the interpretability and effectiveness of our approach in accurately detecting and segmenting kidney tumors.

Keywords：Kidney tumor, Medical image segmentation, Multi-modal, Missing modalities, Deep learning

1. Introduction

Kidney tumors pose a significant health threat worldwide. Imaging tests capable of visualizing kidney tumors are crucial for diagnosis, but they encounter limitations in detecting small solid renal masses.

In this work, we propose an approach that leverages multi-modal diagnostic imaging, including Contrast-Enhanced Computed Tomography (CECT) and Magnetic Resonance Imaging (MRI), addressing the issue of missing modalities. Additionally, we aim to evaluate the contribution of each modality to the output segmentation map using a transformer-based network.

2. Related works

In recent publications, numerous works propose multi-modal fusion techniques by mapping different modalities into a shared feature representation. For instance, SFusion [1] aims to achieve N-to-One multi-modal mapping by computing feature correlations among multi-modal data using a self-attention mechanism, followed by applying softmax to normalize the contribution of each modality. A2FSeg and HeMIS, on the other hand, present an alternative approach that utilizes arithmetic functions such as averaging, A2FSeg also performs adaptive fusion based on attention mechanisms.

3. Proposed method

Figure 1 illustrates our proposed method. We adopt SegFormer [2] as our base model for kidney tumor segmentation due to its success in semantic segmentation with a lightweight decoder. Instead of using the traditional patch embedding followed by Vision Transformer, SegFormer utilizes Overlapped Patch Merging to merge adjacent patches and extend them to obtain hierarchical feature maps. During processing, these patch images are encoded by the SegFormer encoder, resulting in multiscale features. At each level, a joint feature representation is derived by concatenating feature representations from all available modalities. This yields $V^i = V_1^i \circ V_2^i \circ \cdots \circ V_N^i$ where i and N denote the layer and number of available modalities, respectively. Given the potential absence of certain modalities, we implement Modal Attention at each level within the multiscale features. Since we assume that feature representations from each modality are already weighted at the voxel level by the self-attention mechanism in SegFormer, our Modal Attention evaluates the voxel-level contribution of each available modality by normalizing only the present modalities, achieved through a softmax function.

$$W_m^i = \frac{\exp\left(V_m^i\right)}{\sum \exp(V^i)}$$

Following this step, we conduct an element-wise multiplication of the feature representation V^i with the corresponding weight map W_m^i to derive the weighted feature representations of each modality at every multiscale level. Subsequently, we sum all the modalities at each multiscale level to generate a fused weighted multiscale feature.

$$\hat{V}^i = \sum_m V_m^i \cdot W_m^i$$

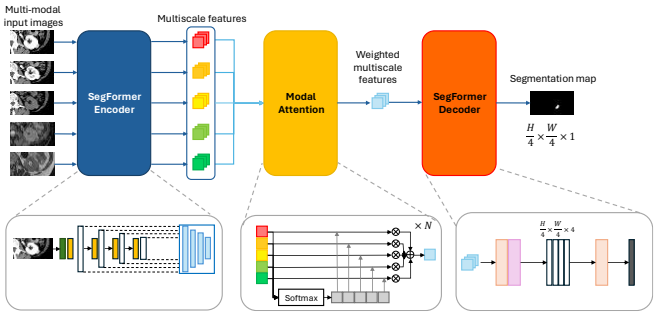


Figure 1 Proposed framework for multi-modal kidney tumor segmentation using SegFormer and Modal Attention. (Left) Hierarchical encoder using the SegFormer Transformer. (Middle) Modal Attention module weighing the contribution of each modality. (Right) Lightweight decoder from SegFormer.

After obtaining the fused weighted multiscale feature, it is passed through a lightweight decoder of SegFormer to produce the final segmentation map.

Table 1 Quantitative analysis of ADC MRI (am) and T2W MRI (tm) in tumor segmentation, including average Dice score, Precision, and Recall.

	Modality	Dice	Precision	Recall
SegFormer	am	0.399	0.417	0.417
	tm	0.607	0.575	0.661
SegFormer with SFusion	am	0.425	0.531	0.380
	tm	0.634	0.691	0.608
Our proposed method	am	**0.531**	**0.622**	**0.506**
	tm	0.622	0.680	0.594

4. Experiments and Evaluation

Our research utilizes a kidney tumor dataset obtained from Tokyo Medical and Dental University. This dataset includes both CECT and MRI modalities.

The CECT component comprises non-enhanced CT (NECT), Early Arterial Phase (EC), and Delayed Phase (DC) acquisitions. NECT is a plain CT scan (PC) performed without the injection of contrast material. In contrast, both the Early Arterial Phase and Delayed Phase involve the injection of contrast material, with images acquired at distinct time intervals following the injection.

The MRI component includes Apparent Diffusion Coefficient MRI (ADC MRI) and T2-weighted MRI (T2W MRI). ADC-MRI reflects the degree of water diffusion through different tissues by analyzing changes in signal magnitude with varying levels of diffusion weighting. Conversely, T2W-MRI highlights differences in the T2 relaxation time of tissues, resulting in varying levels of brightness across different tissues in the images.

We preprocess this dataset by resizing the images to 224×448 pixels and splitting it by patient ID into 80% training images, 10% validation images, and 10% testing images. The testing set includes all patients with a complete record of every modality.

Our experimental framework involves evaluating each modality combination to improve the diagnostic accuracy of that modality. In each experiment, one modality is selected as the primary modality, while the remaining four modalities serve as support modalities, providing complementary information. Given that our dataset has missing modalities, the support modalities vary dynamically with each iteration, allowing our proposal network to adapt to handling incomplete multi-modal data. The loss function is a simple Dice loss function.

Our research is evaluated using the Dice score, Precision, and Recall metrics. We compare our results with those obtained from existing multi-modal fusion methods, specifically SFusion, as well as single-modal approaches using SegFormer.

5. Results

Table 1 presents a quantitative analysis of our approach compared with a single-modal network using SegFormer and a multi-modal approach using SFusion. Our proposed method significantly improves Dice scores, Precision, and Recall for ADC MRI while maintaining similar performance for T2W MRI as SFusion. This demonstrates the effectiveness of our method in multi-modal integration.

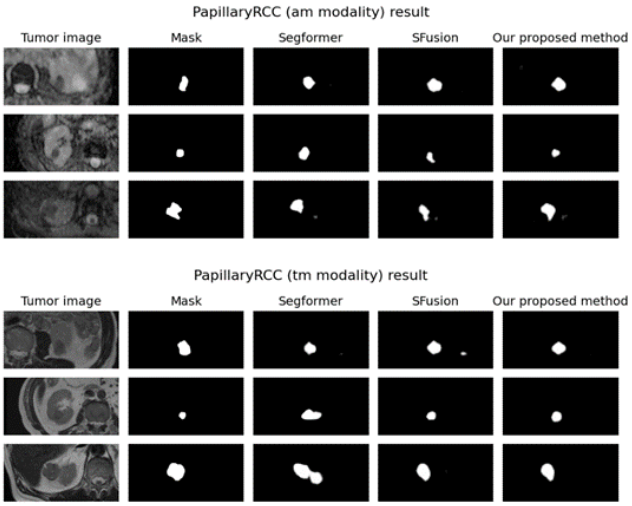


Figure 2 Qualitative comparison for SegFormer, SFusion, and our proposed method from the testing kidney tumor images from ADC MRI (am) and T2W MRI (tm) modality in Papillary RCC.

Figure 2 illustrates a qualitative comparison between SegFormer, SFusion, and our approach. SegFormer and SFusion exhibit the possibilities of false positive tumors, with SegFormer also missing some segmentations. Our proposed method reduces the false positive tumors and enhances the accuracy of tumor segmentation.

To ensure that no single modality dominates the analysis, we examine the average weighted feature representation and the weight map of each modality at each multiscale level. This ensures that no single modality overwhelmingly contributes, with each modality contributing uniquely at different multiscale levels.

6. Summary

We propose an approach that leverages multi-modal data with a Modal Attention module to weigh the contribution of multiscale feature representations from each modality. This approach leads to improved performance in terms of Dice score, Precision, and Recall, particularly for ADC MRI that previously exhibited poor performance.

References

[1] Liu, Z., Wei, J., Li, R., Zhou, J. (2023). SFusion: Self-attention Based N-to-One Multimodal Fusion Block. In: Greenspan, H., et al. Medical Image Computing and Computer Assisted Intervention – MICCAI 2023. MICCAI 2023. Lecture Notes in Computer Science, vol 14221. Springer, Cham. https://doi.org/10.1007/978-3-031-43895-0_15

[2] Xie, E., Wang, W., Yu, Z., Anandkumar, A., Alvarez, J. M., & Luo, P. (2021). SegFormer: Simple and Efficient Design for Semantic Segmentation with Transformers. In M. Ranzato, A. Beygelzimer, Y. Dauphin, P. S. Liang, & J. W. Vaughan (Eds.), Advances in Neural Information Processing Systems (Vol. 34, pp. 12077–12090). Retrieved from https://proceedings.neurips.cc/paper_files/paper/2021/file/64f1f27bf1b4ec22924fd0acb550c235-Paper.pdf

密なスキップ接続と残差接続を持つ U-Net を用いた頭部死後 CT 画像の脳内出血セグメンテーション

中本　将彦[*1]，八代　正彦[*2]，林　敬人[*2]
[*1] 株式会社エクセル・クリエイツ
[*2] 鹿児島大学大学院医歯学総合研究科法医学分野

Segmentation of intracranial hemorrhages in post-mortem head CT images using Dense Residual U-Net

Masahiko Nakamoto[*1], Masahiko Yatsushiro[*2], Takahito Hayashi[*2]
[*1] *Excel Creates Inc.*
[*2] *Department of Legal Medicine, Graduate School of Medical and Dental Sciences, Kagoshima University*

要旨：死後画像診断は解剖前に体内の異変を把握できるため，より正確かつ短時間で解剖を行うために有用である．一方で，画像撮影から解剖までの短時間で読影が求められる，死後画像に精通した読影医が少ないといったことから画像解析による支援が期待されている．著者らは，頭部死後 CT 画像の脳内出血の種類，位置，出血量を把握するために機械学習による脳内出血セグメンテーションモデルの開発を行っている．本研究では密なスキップ接続と残差接続を持つ Dense Residual U-Net を提案し，残差接続を持つ Residual U-Net，スキップ接続を持つ Dense U-Net と比較する．実験結果ではスキップ接続が最も密な提案法で最も Dice 係数が高くなり，脳内出血セグメンテーションの性能向上に有効であることを確認した．
キーワード：死後画像診断，脳内出血，セグメンテーション，U-Net，残差接続

1. はじめに

死後画像診断は解剖前に体内の異変を把握できるため, 解剖の要否判断やより正確かつ効率的な解剖を行うために有用である．死後画像診断が広まりつつある一方で，死後画像に精通した読影医が不足しているため, 画像解析技術による支援が期待されている．

著者らのグループでは頭部 CT 画像を対象として死因究明の手掛かりとなる脳内出血のセグメンテーションに取り組んでいる [1]．生前の頭部 CT 画像における脳内出血をセグメンテーションする研究はすでに行われており, 商用化されたソフトウェアも存在するが，死後画像を対象にしたものは少ない．死後画像では死後変化によりガスの発生や軟組織の腐敗, 血液の貯留等が見られる点が生前画像と異なっているため, そのような画像に対しても精度よくセグメンテーションできる方法の開発を目指している．

CT 画像のセグメンテーションには U-Net が広く用いられており, さらにそこから派生したネットワークが多数提案されている．脳内出血セグメンテーションにおいては，出血領域が不定形かつ発生する位置も一定していないため概念獲得が難しく，学習時に勾配消失が起こりやすい．そこで本研究では勾配消失を防ぐために多数のレイヤー間に残差接続および密なスキップ接続を配置した Dense Residual U-Net を提案する．残差接続のみを持つ Residual U-Net やスキップ接続のみを持つ Dense U-Net との比較を行い，提案法の有用性を示す．

2. 方法

Residual U-Net は各層において残差接続を行った U-Net である. 入力から出力へ恒等写像で行うことで入力した情報の劣化を防ぐねらいがある．Dense U-Net は，層内の全てのレイヤーに対してスキップ接続を行った U-Net である. レイヤー間の接続を密にすることで各層の出力を最後の層に伝達することができる．提案法の Dense Residual U-Net は，層内の全てのレイヤーに対するスキップ接続と各レイヤーに対する残差接続の両方を行った U-Net である．Dense U-Net よりもさらに接続が密になっており, 深いネットワークで起こり得る勾配消失を防いで概念伝達を強化する．

3. 実験

脳内出血のセグメンテーションでは 5 種類の出血領域（脳内出血，脳室内出血，くも膜下出血，硬膜下血腫，硬膜外血腫）を対象とし，それぞれの領域抽出および識別を行う．データセットは鹿児島大学で撮影された頭部死後 CT 画像 131 症例, 研究用に公開されている生前の頭部 CT 画像として ct-ich [1] , CQ500 [2] 191 症例， BHSD [3] 66 症例の計 388 症例を用いた．これらを学習用データセット 363 症例，評価用データセット 25 症例に分割し，それぞれ学習と評価に用いる．前述の出血領域にはそれぞれのラベルを用手的に付与し, 医師により確認を行った．ただし，BHSD は公開データに含まれているラベル

を分類が一致するように変換して用いた．Residual U-Net, Dense U-Net, Dense Residual U-Net のそれぞれで学習を行い，領域抽出精度を 5 種類の出血領域の平均 Dice 係数で評価した．また，学習データ数が 131 症例と 363 症例のデータセット（それぞれ学習データ 1,2 と呼ぶ）を作成し，学習データ数の違いによる領域抽出精度を比較した．

4. 結果と考察

それぞれの学習データセットおよびネットワークにおける平均 Dice 係数を表 1 に示す．ネットワーク間の比較では，提案法の Dense Residual U-Net が最も高い値を示した．学習データ数を増やした場合はどのネットワークでも平均 Dice 係数が向上し，提案法が最も高い 0.639 を示した．学習データ数を増やしたことによる平均 Dice 係数の改善率においても提案法が最も高い 9.2%を示した．

図 1 にセグメンテーション結果を示す．図 1(a)はくも膜下出血の症例である．くも膜下出血は他の 4 種の出血と比較して形状と位置のバリエーションが多く抽出が難しい．学習データ 1 では一部しか抽出できていないが，学習データ 2 を使ったネットワークでは複雑な領域を細部まで抽出できており，Dense Residual U-Net は最も細部まで抽出できた．図 1(b)は硬膜外血腫を除く 4 種の出血が生じている症例である．学習データ 1 ではくも膜下出血（青）を脳内出血（黄）と誤分類されたが，学習データ 2 では正しく分類された．また点在する細かな出血領域は Dense Residual U-Net で最も良く抽出された．

これらの実験結果は Dense Residual U-Net は他の 2 つよりも細部の領域抽出に優れていることを示しており，密なスキップ接続と残差接続による概念伝達の強化が細部概念獲得に寄与し，性能向上に至ったと考えられる．

5. まとめ

本研究では，頭部死後 CT 画像における脳内出血のセグメンテーションを目的として密なスキップ接続と残差接続を持つ Dense Residual U-Net を提案した．提案法は Residual U-Net や Dense U-Net と比較して学習データ数の増加による性能向上の幅が大きく，細部の抽出能の向上が見られた．今後の課題として，データの拡張とパラメータの最適化，およびアノテーション精度の向上が求められる．

謝辞

本研究は JSPS 科研費 基盤研究(C) 23K09767 の助成を受けたものです．

利益相反の有無

なし

文　献

［1］ 八代他: AI を用いた死後 CT における頭蓋内出血の検出についての予備検討（第 3 報）．第 73 回日本法医学会学術九州地方集会講演要旨集, 2023, p7

［2］ He K et al: Deep Residual Learning for Image Recognition. arXive: 1512.03385, 2015

［3］ Huang G et al: Densely Connected Convolutional Networks. arXive: 1608.06993v5, 2018

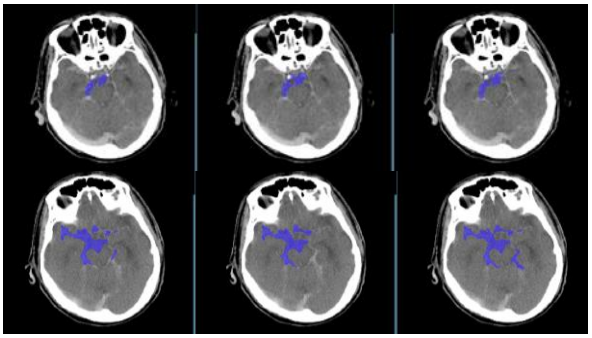
［4］ Hssayeni M: Computed Tomography Images for Intracranial Hemorrhage Detection and Segmentation (version 1.3.1). PhysioNet, 2020

［5］ Chilamkurthy S et al: Development and Validation of Deep Learning Algorithms for Detection of Critical Findings in Head CT Scans. arXiv: 1803.05854v2, 2018

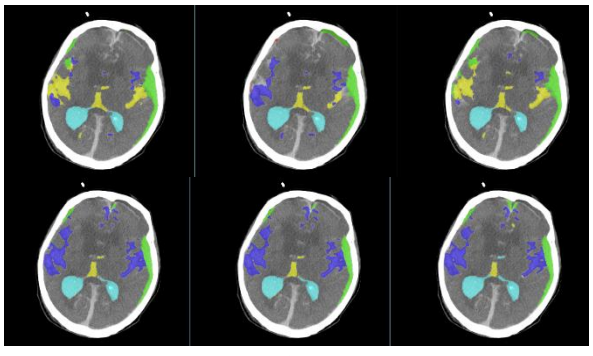
［6］ Wu B et al: BHSD: A 3D Multi-class Brain Hemorrhage Segmentation Dataset. International Workshop on Machine Learning in Medical Imaging: 147-156, 2023

表 1 Dice 係数による評価.

ネットワーク	平均 Dice 係数		改善率
	学習データ 1 (N=131)	学習データ 2 (N=363)	
Residual U-Net	0.574	0.601	4.7%
Dense U-Net	0.584	0.591	1.2%
Dense Residual U-Net	0.585	0.639	9.2%



(a)



(b)

図 1 セグメンテーション結果．左から Residual U-Net, Dense U-Net, Dense Residual U-Net ． 上段：学習データ 1，下段：学習データ 2.

大規模データセットの活用に向けた基礎的検討と応用事例

杉下　友麻[*1]，原　武史[*2],尾﨑　公美[*3]，周　向栄[*2]，藤田　広志[*2]
[*1] 岐阜大学大学院自然科学技術研究科
[*2] 岐阜大学工学部
[*3] 浜松医科大学放射線診断学講座

Fundamental considerations and applications for utilization of large datasets

Yuma SUGISHITA[*1]，Takeshi HARA[*2]，Kumi OZAKI[*3]，Xiangrong ZHOU[*2]，Hiroshi FUJITA[*2]
[*1] *Graduate School of Natural Science and Technology, Gifu University*
[*2] *Faculty of Engineering, Gifu University*
[*3] *Department of Radiology, Hamamatsu University School of Medicine.*

要旨：医用画像分野においても大規模なパブリックデータセットの構築が進んでおり，TotalSegmentator などの基盤モデルが登場している．しかし実際の研究開発に基盤モデルを活用する際，研究を目的として収集したデータであれば，スムーズに利活用できるが臨床用に収集されたデータではさまざまな問題が発生する．そこで本研究の目的は，臨床用に収集されたデータを基盤モデルに適用する際のデータの統一に関する問題を明らかにすることである．そして，肝腫瘍のラジオ波焼灼法（Radiofrequency ablation: RFA）治療の CT データにおける TotalSegemntaor を用いた肝臓の 3 次元セグメンテーションを実施し，データ変換手順の妥当性を検証したところ，基盤モデルの入力データとして機能する変換を実現できた．しかし，撮像されたデータのスライス枚数が極めて少ないため，セグメンテーション精度は不十分であった．

キーワード：基盤モデル，肝臓腫瘍，3 次元セグメンテーション

1.　はじめに

医用画像分野においても大規模なパブリックデータセットの構築が進んでおり，TotalSegmentator[1]や SAM-Med 3D[2]などの基盤モデルが登場している．これらを活用することで医療 AI 開発の高速化・高性能化が期待できる．しかし実際の研究開発に基盤モデルを活用する際には，データフォーマットやドメインの違いから入力データを作成する前処理に苦労する．特に撮像モダリティの違い，画素値分布，スライス数などは精度に影響を与える．そのため研究を目的として収集したデータであれば，スムーズに利活用できる．しかし臨床用に収集されたデータに基盤モデルを活用する際には，上記の問題や病変領域以外撮像されていないことによるデータの不足，記録の形式が統一されていないなどの問題が発生する．本研究の目的は，臨床用に収集されたデータを基盤モデルに適用する際のデータの統一に関する問題を明らかにすることである．

そして，肝腫瘍のラジオ波焼灼法（Radiofrequency ablation: RFA）治療の CT データに適用し，TotalSegemntaor を用いた肝臓の 3 次元セグメンテーションを実施し，手順の妥当性を報告する．

2.　手法

2.1 試料画像

同一患者の RFA 治療の前後で撮像された 184 症例（総スライス枚数 1,211 枚）の CT 画像を用いる．これを RFA データセットとする．

2.2 3 次元ボリュームデータに変換

DICOM 形式の 2 次元スライス CT データを 3 次元ボリュームデータに変換するため，3D Slicer（以下，Slicer）を用いた．Slicer は医用画像の可視化・分析に用いられるオープンソースソフトウェアである．変換の手順を図 1 に示す．Slicer に DICOM 形式で保存されている各患者の 2 次元スライス CT データを入力した．Slicer 内で Series, Description, Count が異なるデータを区別し，それぞれのデータを 3 次元ボリュームデータとして，nii.gz 形式で書き出した．一連の処理は Slicer を Python で操作し自動化された．

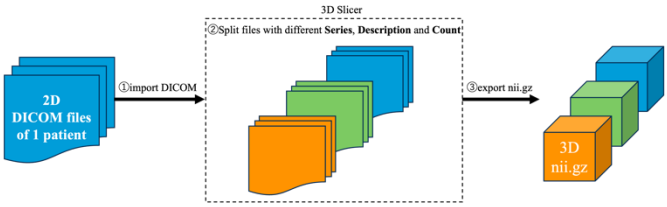


図 1 Slicer を用いた変換の手順

2.3 3 次元セグメンテーション

3 次元セグメンテーションには TotalSegmentator を用いた．TotalSegmentator は 1228 症例の CT 画像を用いて，117 個の解剖学的構造をラベル付けした TotalSegmentator データセットで学習された uuU-Net[3]である．RFA データセットには肝臓のラ

ベルが含まれていないため，セグメンテーション結果は目視で確認した．

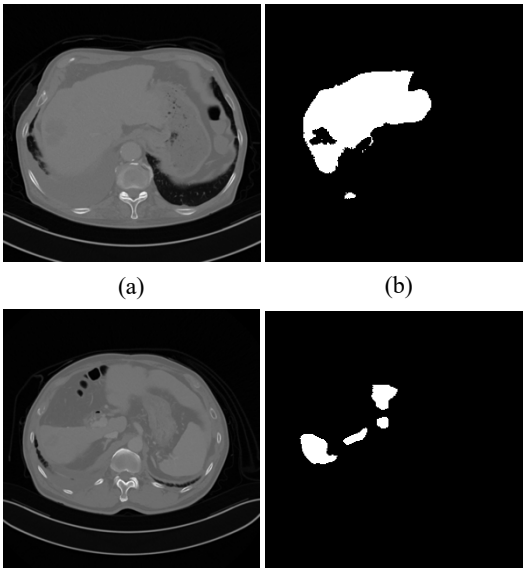
3. 結果・考察

3.1 データの変換

TotalSegmentator への入力データとして要求される nii.gz 形式の 3 次元ボリュームデータに変換でき，入力データとして機能すると確認できた．しかし Series，Description，Count を区別しても重複するデータが混在してしまった．これは Slicer 内部での区別に DICOM タグ（0020，000E）SeriesInstaceUID を使用しているためであった．

3.2 3 次元セグメンテーション

入力画像例と対応する出力画像例を図 2 に示す．



(a)　(b)

(c)　(d)

図 2 入力画像例(a,c)と出力画像例(b,d)

図 2(d)のように 3 次元セグメンテーションの結果として活用できない症例が一定数含まれており肝臓の抽出精度は不十分であったと考える．

RFA データセットと TotalSegmentator データセットと比較したところ，画素値の分布は同様であった．画素値分布のヒストグラムを図 3 に示す．撮像範囲について，TotalSegmentator データセットでは肝臓全体が撮像されているのに対し，RFA データセットの 1 症例あたりの平均スライス数は 6.58 であり，肝臓全体が撮像されていない症例が大半であった．TotalSegmentator データセットのサンプルデータから肝臓を含む 7 スライスを抽出し TotalSegmentator で推論したところ，全スライスを用いた場合に比べ精度の低下が見られた．したがって，スライス枚数が不足し対象臓器全体が撮像されていないことが精度低下の大きな要因であると考える．スライス枚数による抽出結果の比較例を図 4 に示す．

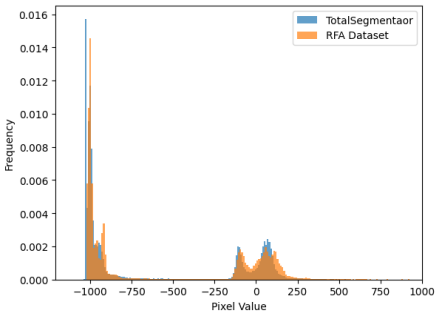
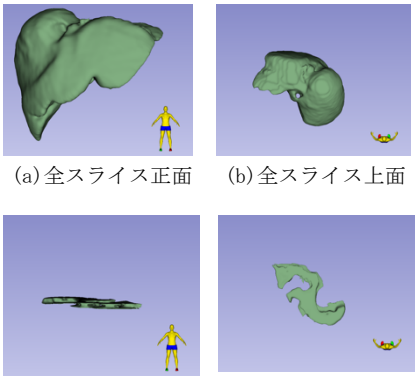


図 3 画素値分布の比較



(a) 全スライス正面　(b) 全スライス上面

(c) 7 スライス正面　(d) 7 スライス上面

図 4 スライス枚数による抽出精度の比較例

4. 結論

基盤モデルの入力として臨床用に撮像された画像を使用する際には画像データ形式や記録方法の不統一がデータ活用の容易さに影響を与えることがわかった．この問題は，基盤モデルのサンプルデータに沿った形式にデータを変換する作業を自動化し解決できた．

基盤モデルに 3 次元 CT データを入力する際はスライス枚数の不足がセグメンテーション精度に悪影響を与えることが示された．

利益相反の有無

なし

文　献

［1］ J. Wasserthal, et al., "TotalSegmentator: Robust Segmentation of 104 Anatomic Structures in CT Images," Radiology: Artificial Intelligence, vol. 5, no. 5, 2023.

［2］ WANG, Haoyu, et al. Sam-med3d. arXiv preprint arXiv:2310.15161, 2023.

［3］Isensee, F., Jaeger, P.F., Kohl, S.A.A. et al. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. Nat Methods 18, 203–211 (2021)

3 時相腹部造影 CT 画像を用いた腎臓・腎腫瘍・嚢胞の自動抽出

西村　一馬[*1]，越野　魁都[*1]，河田　佳樹[*2]
小針　悠希[*3]，池田　篤史[*4]，仁木　登[*5]
[*1] 徳島大学大学院創成科学研究科理工学専攻
[*2] 徳島大学ポスト LED フォトニクス研究所 [*3] 東京女子医科大学
[*4] 筑波大学医学医療系 [*5] 株式会社医用科学研究所

Automatic extraction of kidneys, renal tumors and cysts using 3-time-phase abdominal contrast-enhanced CT images.

Kazuma NISHIMURA[*1], Kaito KOSHINO [*1], Yoshiki KAWATA[*2]
Yuuki KOBARI[*3], Atsushi IKEDA[*4] Noboru NIKI[*5]
[*1] *Graduate School of Science and Technology for Innovation, Tokushima University*
[*2] *Institute of Post-LED Photonics, Tokushima University* [*3]*Tokyo Women's Medical University*
[*4] *Faculty of Medicine, Tsukuba of University* [*5] *Medical Science Institute*

要旨：腎臓がん患者の死亡者数は年々増加傾向にある．本研究の最終目標は，3 時相腹部造影 CT 画像から腎臓・腎腫瘍・嚢胞を精密に解析し，良性・悪性腫瘍の高精度な鑑別法を開発することである．解析を行うためには，まず腎臓・腎腫瘍・嚢胞を抽出することが必要で，数百~数千の症例数が必要なので高速に抽出することが求められる．本研究では，3D U-Net を用いた 3 時相腹部造影 CT 画像からの腎臓・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)・嚢胞の高速かつ高精度な抽出法の開発を行い，腎臓・腎腫瘍・嚢胞の抽出を行った．
キーワード：腎臓・腎腫瘍・嚢胞，自動抽出，U-Net，3 時相腹部造影 CT 画像

1. 背景・目的

腎がん患者の年間死亡者数は 1 万人を超え，年々増加傾向にある．腎術前に腎がんと診断して手術を行っても，手術後に良性腫瘍であったと判明した患者は約 10%であると報告されている．特に腫瘍径が小さい場合(2.5cm 以下)は良性腫瘍の頻度が高く，注意が必要である．マルチスライス CT 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，3 時相腹部造影 CT 画像から腎臓・腎腫瘍・嚢胞を精密に解析し，良性・悪性腫瘍の高精度な鑑別法を開発することを目指している．そのために 3D U-Net を用いて 3 時相腹部造影 CT 画像から腎臓・腎腫瘍・嚢胞の自動抽出を行い，それをもとに修正した症例を学習させることで，自動抽出の更なる高精度化を目指す．

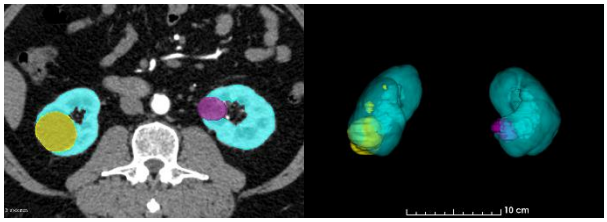
2. CT 画像の撮影条件

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

3. 手法

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腎腫瘍 5 種類を対象に研究を行った．本手法は(1) 3 時相造影 CT 画像から 2 人の観測者によるマニュアル抽出，3D U-Net を用いた自動抽出で腎臓・腎腫瘍・嚢胞を抽出しデータベースを作成(2)腎臓+腎腫瘍+嚢胞を抽出し作成したデータベースから 3 時相 246 症例を 3D U-Net を用いて学習(3)自動抽出の抽出精度を，テストデータ 25 症例を用いた Dice 係数，Jaccard 係数,から確かめる．

(1)淡明細胞型腎細胞がん症例，乳頭状腎細胞がん症例，嫌色素性腎細胞がん症例，血管筋脂肪腫症例，オンコサイトーマ症例から抽出を行い，データベースを作成した．抽出した症例の抽出結果画像を図 1 に示す．



(a)Axial 面　　(b)3D 表示
図 1(a)(b) 腎臓・腎腫瘍・嚢胞の抽出結果画像

(2)U-Net は入力された画像に対しセグメンテーションを行う CNN アーキテクチャである．本研究に作成・使用する学習データは腎臓+腎腫瘍+嚢胞の 3 時相の造影 CT 画像をトレーニングデータ 176 症例，バリデーションデータ 45 症例， 学習回数を 100 回として作成した．

(3)テストデータは淡明細胞型腎細胞がん症例，乳頭状腎細胞がん症例，嫌色素性腎細胞がん症例，血管筋脂肪腫症例，オンコサイトーマ症例から計 25 症例を用いて作成した．Dice 係数は 2 つの集合の平均要素数と共通要素数の割合を表した指標．Jaccard 係数は 2 つの集合に含まれている要素の内，共通要素が占める割合を表した指標である．

4. 結果

学習データの作成を行い，3D U-Net を用いて学習を行った．作成した学習モデル(トレーニングデータ 176 症例・バリデーションデータ 45 症例・テストデータ 25 症例)を用いて腎臓+腎腫瘍+嚢胞の自動抽出を行った．図 2 に腎臓・腎腫瘍・嚢胞の自動抽出結果を示す．



図 2　腎臓・腎腫瘍・嚢胞の自動抽出結果

3D U-Net を用いた自動抽出の抽出精度を，テストデータ 25 症例から Dice 係数と Jaccard 係数を算出することで評価した．自動抽出ラベルと正解ラベルを比較したときの Dice 係数，Jaccard 係数の平均値を下の表 1 に示す．

表 1　Dice 係数, Jaccard 係数の平均値

評価指標:Dice
（テストデータ　25症例）

	動脈相	門脈相	平衡相
平均値	0.966	0.970	0.970

評価指標:Jaccard
（テストデータ　25症例）

	動脈相	門脈相	平衡相
平均値	0.936	0.943	0.943

この結果から， 今回作成した学習モデルによる自動抽出の精度は高いといえる．

5. まとめ

3 時相造影 CT 画像より腎臓・腎腫瘍・嚢胞をマニュアル抽出し，腎臓・腎腫瘍・嚢胞の学習データを作成した．作成した学習データを用いて 3D U-Net により学習を行い，作成した学習モデルを用いて腎臓+腎腫瘍+嚢胞の自動抽出を行い，自動抽出の精度を確認した．表 1 で示した評価結果より，自動抽出した腎臓+腎腫瘍+嚢胞は高精度ではあるが多少の誤抽出があるので，誤抽出を手動で修正し，修正した症例は学習データデータベースに追加して症例数を増やす．そして新たなデータベースから質の高い学習モデルを作成し，腎臓・腎腫瘍・嚢胞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] 日本泌尿器科学会：腎癌取扱い規約，第 4 版，金原出版，2011

[2] Olaf Ronneberger: U-Net: Convolutional Networks for Biomedical Image Segmentation, MICCA2015

[3] 西平健斗，西岡大，鈴木秀宣，河田佳樹，池田篤史，小針悠希，仁木登：3 時相腹部造影 CT 画像を用いた小径腎腫瘍解析，電子情報通信学会技術研究報告医用画像 vol.122, no.265, MI2022-71, pp.43-44, 2022.11

[4] 西岡大，西平健斗，越野魁都，鈴木秀宣，河田佳樹，小針悠希，池田篤史，仁木登：多時相造影 CT 画像データベースの腎臓・腎腫瘍の抽出，電子情報通信学会技術研究報告医用画像 vol.122，no.417，MI2022-125，pp.210-211，2023.3

[5] Kaito KOSHINO, Dai NISHIOKA, Yoshiki KAWATA, Atsushi IKEDA, Yuki KOBARI, Noboru NIKI, “Renal tumor analysis using multi-phase abdominal CT images”, SPIE Medical Imaging, 2024

咀嚼嚥下に関連する臓器を対象とした複数臓器統計形状モデルの構築

三浦皓大[*1]，中谷亮太[*1]，政木勇人[*1, 2]，大竹義人[*1]，崇風まあぜん[*1]，谷懿[*1]，井尻敬[*3]，
重田優子[*4]，井川知子[*4]，小川匠[*4]，稲本陽子[*5]，菊池貴博[*6]，道脇幸博[*7]，佐藤嘉伸[*2]
[*1] 奈良先端科学技術大学院大学，[*2] PSP 株式会社，[*3] 芝浦工業大学，[*4] 鶴見大学，
[*5] 藤田医科大学，[*6] 株式会社明治，[*7] みちわき研究所

Development of a multi-organ statistical shape model for organs related to mastication and swallowing

Akihiro Miura[*1], Ryota Nakatani[*1], Yuto Masaki[*1, 2] , Yoshito Otake[*1], Soufi Mazen[*1], Yi Gu[*1], Takashi Ijiri[*3], Yuko Shigeta[*4], Tomoko Ikawa[*4], Takumi Ogawa[*4], Yoko Inamoto[*5], Takahiro Kikuchi[*6], Yukihiro Michiwaki[*7], Yoshinobu Sato[*1]
*[*1] Nara Institute of Science and Technology, [*2] PSP Corporation, [*3] Shibaura Institute of Technology, [*4] Tsurumi University, [*5] Fujita Health University, [*6] Meiji Co., Ltd., [*7] Michiwaki Kenkyusho Co., Ltd.*

要旨：食物を口腔内に咀嚼し，飲み込む一連動作を嚥下と呼ぶ．嚥下機能は我々が生まれ持った時から持つ機能であるが，年齢を重ねるごとに低下し，誤嚥から誤嚥性肺炎といった症状を起こすことがある．そのため，このような事故を防ぐために咀嚼嚥下機能の原理を解明することは重要である．嚥下機能の低下は，舌骨の動きとの関連があると言われている．また，咀嚼機能と嚥下機能の低下には関連性があり，咀嚼機能の低下は口腔周辺の機能の低下と関連があると言われている．そこで本研究では，舌骨および咀嚼嚥下に関連する臓器を対象とした多構造統計形状モデルの構築を行い，咀嚼嚥下に関連する臓器を解析することにより，形状変化の把握を行う．さらに，非侵襲での嚥下解析を目指すために体表面からの内部筋骨格予測を試みたのでその結果を報告する．
キーワード：統計形状モデル，嚥下咀嚼，医用画像

1. はじめに

ヒトが食物を咀嚼し，口腔から胃まで運搬する一連の動作を嚥下運動と呼び，嚥下機能は加齢とともに機能が低下するため，超高齢化社会を迎えている日本において，嚥下機能を解明することは重要である．嚥下機能の低下は舌骨の動きと関係があるといわれている．咀嚼機能の低下と嚥下機能の低下には関連性があり，咀嚼機能の低下は口腔周辺の機能の低下と関連があると言われている．統計形状モデル(Statistical shape model, SSM)[1]は，形状の変動を抽出する特徴があり，医療イメージングやバイオメカニクスの分野などで活用されている．本研究では，舌骨および咀嚼嚥下に関連する臓器を対象とした SSM の構築を行い，咀嚼嚥下動作の原理の解明を目指すために、静止 CT 画像での嚥下構造の統計形状解析により形状変化の傾向を把握する．しかし，CT 画像での撮影は撮影機関や侵襲的な計測方法といった問題点が生じる．そのため，近年体表面を非侵襲に取得できる技術があり[2]，体表面から内部筋骨格を復元することで嚥下構造の非侵襲な解析を目指す．

2. データセット

口腔領域が撮像範囲の鶴見大学で撮影された 178 症例の CT 画像を使用した．データセットの詳細を表 1 に示す．SSM を構築する解剖学構造は体表面を含めて 11 構造とした．筋骨格構造について，左右それぞれに存在する構造は左右を分離している．

表 1：データセット詳細

項目	内容
撮影機関	鶴見大学
症例数	178症例
画像サイズ	(512×512×512～512×512×751)
ピクセルサイズ	(0.411, 0.411, 0.3125)
スライス厚	0.3125

3. 手法

CT 画像からの頭部全体の筋骨格自動抽出手法[3]を適用し，自動抽出ラベルが得られている．

3.1. 実験

多構造 SSM 構築を行った．その後，体表面から内部筋骨格を予測するために，SSM 当てはめを利用する．SSM 当てはめは形状ベクトルを適切に選定することで，SSM の体表面が目的形状に近似し．モデル内部の筋骨格形状も推定することである．最適な形状ベクトルを選択手法には CMA-ES[4]を使用した．学習データは，10～150(10，30，50，150)症例，テストデータは，27 症例を使用した．主成分はそれぞれすべて使用した．

4. 結果

4.1. 多構造 SSM の結果

頭部の SSM の平均形状と主成分変形の結果を図 1 に示す．これは第 3 主成分を示しているが，舌骨が頸椎の C2～C4 周辺に位置関係を示した変動である．

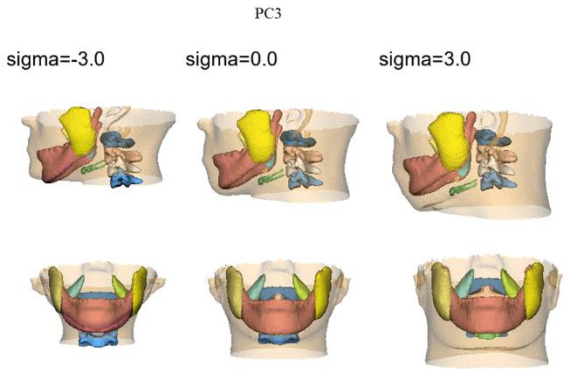


図 1：SSM の主成分変形（第 3 主成分）

4.2. SSM 当てはめの予測精度結果

SSM 当てはめを行った結果を図 2 に示す．学習データ数を 10，30，50，150 のときの各構造の平均の予測精度ついて記載しており，評価指標は ASSD(Average Symmetric Surface Distance)を用いた．

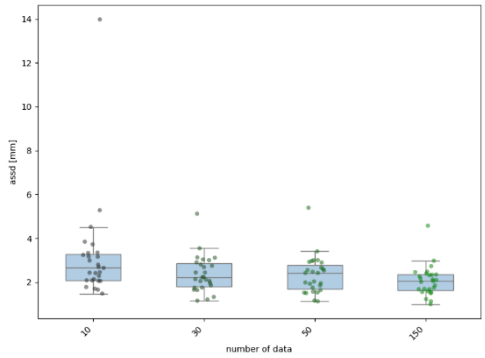


図 2：各学習データ数による構造の平均予測精度

学習データ数による予測程度の定性的な比較のために学習データ数が 10 と 150 のときの ASSD 下位 25%，中央値，上位 25%の症例の ASSD 誤差マップを図 3 に記載する．図 3 は下顎骨と頸椎の可視化削除している．

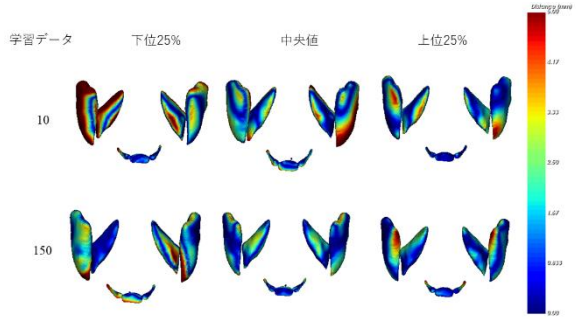


図 3：ASSD の誤差マップ

5. 考察

実験 1 より，第 3 主成分から舌骨の位置と頸椎の位置関係が示され，舌骨の位置が頸椎の C2 から C4 周辺に分布していることが分かった．

図 2 より，学習データ数を増加させると体表面から内部骨格の予測精度が向上していることが分かった．また，図 3 の ASSD の誤差マップより，学習データ数が増加していくにつれて構造全体の予測精度が向上してきた．

6. まとめ

本研究では，CT 画像を用いて，自動抽出ラベルを利用して SSM 構築および体表面からの内部筋骨格の予測を行った．その結果，SSM の主成分変形のモデルから舌骨と頸椎の位置関係が分かった．また、学習データ数を変更した内部筋骨格を行い．学習データ数と予測精度には関係性があること分かった．今後は，嚥下 4 次元 CT を用いて，嚥下動作の形状と動きのバリエーションの統計モデル化を目指していく．

本報告では，咀嚼嚥下に関わる一部臓器の多構造 SSM しか構築していない．そのため今後は，頭蓋骨や周辺の筋肉などの追加を行い SSM の再構築を行いたい．また，頭蓋骨や周辺筋肉などは CT の撮像範囲や金属アーチファクトなどの影響により途切れている症例もある．そのため，それらの構造も SSM を作成し，SSM 当てはめを行うことで咀嚼嚥下に関連する臓器の SSM 構築のための学習データ数を増やすことも考えられる．

謝辞

本研究は JSPS 科研費 23H03790 の助成を受けたものである．

利益相反の有無

なし．

文　献

［1］ Tobias Heimann and Hans-Peter Meinzer. Statistical shape models for 3d medical image segmentation: A review. Medical Image Analysis, Vol. 13, No. 4, pp. 543–563, 2009.

［2］ Shunsuke Saito, , Zeng Huang, Ryota Natsume, Shigeo Morishima, Angjoo Kanazawa, and Hao Li. Pifu: Pixel-aligned implicit function for highresolution clothed human digitization. arXiv preprint arXiv:1905.05172, 2019.

［3］Nakatani R, et al., “Automatic segmentation of 4DCT images for analysis of subject-specific swallowing motion”,JSCAS,2023

［4］ Hansen, N., Arnold, D. V., Auger, A.,”Evolution strategies; Handbook of Computational Intelligence”, J. Kacprzyk and W. Pedrycz, editors, pp.871–898, Springer 2015

CT・MRI に基づく筋骨格モデリングと簡易動作計測を統合した患者個別バイオメカニクスシミュレーション

伊藤　善久[*1]，大竹　義人[*1]，崇風　まあぜん[*1]，李　贛萍[*1]，谷口　匡史[*2]，八木　優英[*2]，
田原　大輔[*3]，高尾　正樹[*4]，岩佐　諦[*5]，上村　圭亮[*5]，市橋　則明[*2]，佐藤　嘉伸[*1]
[*1] 奈良先端科学技術大学院大学先端科学技術研究科情報科学領域
[*2] 京都大学大学院医学研究科人間健康科学系専攻　[*3] 龍谷大学先端理工学部機械工学・ロボティクス課程
[*4] 愛媛大学整形外科　[*5] 大阪大学大学院医学系研究科

Individual patient biomechanics simulation integrating CT and MRI-based musculoskeletal modelling and simple motion measurement

Yoshihisa Ito[*1], Yoshito Otake[*1], Mazen Soufi[*1], Ganping Li[*1], Masashi Taniguchi[*2], Yagi Masahide [*2], Daisuke Tawara[*3], Masaki Takao[*4], Makoto Iwasa[*5], Keisuke Uemura[*5], Noriaki Ichihashi [*2], Yoshinobu Sato[*1]
[*1] *Nara Institute of Science and Technology*　[*2] *Kyoto University*
[*3] *Ryukoku University*　[*4] *Ehime University*　[*5] *Osaka University*

要旨：現在行われているバイオメカニクスシミュレーションでは，Vicon などの光学式モーションキャプチャシステムを用いてモーションデータを取得し，そのモーションデータと対象の身長・体重データから汎用モデルをスケーリングしたモデルを用いてシミュレーションを行う. しかしこの方法には，光学式モーションキャプチャシステムの導入にかなりコストがかかること，汎用モデルをスケーリングしただけでは筋骨格の個人差が反映されないことといった問題がある. これらの問題を改善するために，導入が容易な OpenCap を用いてモーションデータを取得し，MR 画像から推定した骨格形状と筋肉体積データを反映させた患者個別筋骨格モデルでシミュレーションを行った. 汎用モデルをスケーリングした筋骨格モデルと患者個別筋骨格モデルのそれぞれでシミュレーションを行い，比較した結果を報告する.
キーワード：医用画像，セグメンテーション，筋骨格モデル，バイオメカニクスシミュレーション

1. はじめに

バイオメカニクスシミュレーションを行うためのシステムとして AnyBody[1] などが開発されている. このようなシステムで利用される筋骨格モデルは, 少数の遺体を参考に作成された汎用モデルが一般的である[2]. Vicon などの光学式モーションキャプチャシステムを用いて取得したモーションデータと解析対象の身長や体重データを用いて, 汎用モデルをスケーリングした筋骨格モデルがシミュレーションに用いられる[3]. しかしこの方法には光学式モーションキャプチャシステムの導入にかなりコストがかかることや, 汎用モデルをスケーリングした筋骨格モデルでは筋骨格の個人差が反映されないといった問題がある.

この問題を改善するために, 本研究では光学式モーションキャプチャシステムに比べると導入コストが低い OpenCap[4]という 2 台以上の iOS デバイスで撮影してモーションデータを取得するモーションキャプチャシステムを用いて動作計測を行った. また被験者の下肢 MR 画像から筋肉体積値と骨格形状を求め, AnyBody の筋骨格モデルに反映させた. 計測して得られたモーションデータを用いてシミュレーションを行い, 汎用モデルをスケーリングした筋骨格モデルを用いた場合とシミュレーション結果を比較した.

2. 手法

被験者の下肢 MR 画像を撮影し, OpenCap で動作計測を行う. そして下肢 MR 画像に対して Li らの筋骨格セグメンテーションモデル[5]を用い, 得られた筋骨格構造のラベルから筋肉体積値と骨格形状を求め, 患者個別筋骨格モデルを作成する. AnyBody の筋肉において, Li らのモデルでは 1 つの筋肉としてセグメンテーションされるが AnyBody では複数に分かれている筋肉がいくつかある. その筋肉体積値の計算方法を式(1)に示す. 式(1)において, xは求めたい筋肉の AnyBody における初期体積値, x_iは同じ筋肉としてセグメンテーションされた筋肉の初期体積値, V_{seg}がセグメンテーションラベルから求めた筋肉全体の体積値を表す.

$$V = V_{seg}\,\frac{x}{\sum_{i=1}^{n} x_i} \tag{1}$$

また AnyBody には, Li らのモデルではセグメンテーションされない筋肉もあり, その筋肉体積値の計算方法を式(2)に示す. 式(2)において, xが求めたい筋肉の初期体積値, V_iが求めたい筋肉周辺の, Li らのモデルで求まった筋肉体積値, y_iがV_iの筋肉における初期体積値を表す.

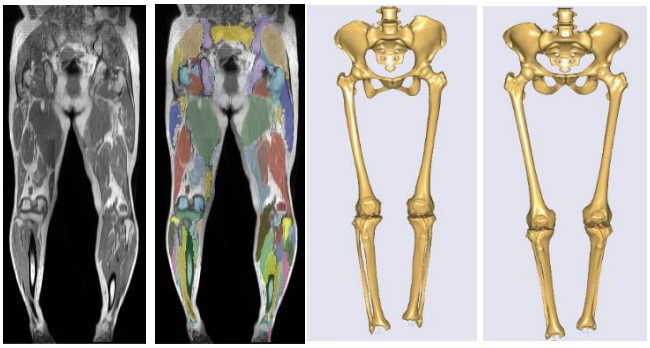
$$V = x\,\frac{\sum_{i=1}^{n} V_i}{\sum_{i=1}^{n} y_i} \tag{2}$$

3. 実験

京都大学大学院医学研究科臨床バイオメカニクス研究室で被験者(女性, 年齢 74 歳, 体重 54.5kg, 身長 148cm)の下肢 MR 画像の撮影を行った. また, iPad を 3 台使用し OpenCap を用いて被験者の歩行動作の計測を行った.

4. 結果

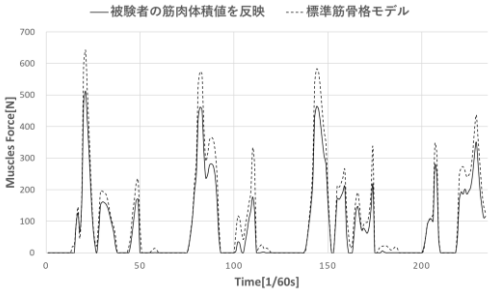
図 1 に撮影した下肢 MR 画像とセグメンテーション結果, 筋骨格モデルの下肢骨格形状を示す. AnyBody 上の表示では, 図 1(c)における右大腿骨の長さは 34.2cm, 図 1(d)における右大腿骨の長さは 36.8cm だった.



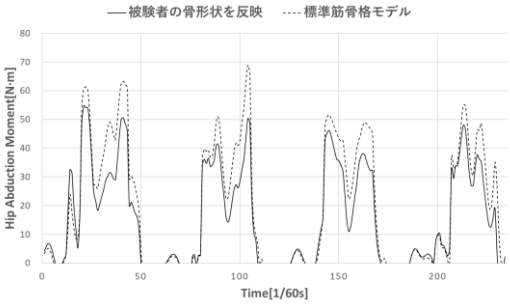
(a) (b) (c) (d)

図 1 (a)撮影された下肢 MR 画像, (b)セグメンテーション結果, (c)下肢 MR 画像から得られた骨格形状(骨盤, 仙骨, 大腿骨, 脛骨, 腓骨, 膝蓋骨)を反映させた筋骨格モデルの骨格, (d)汎用モデルをスケーリングした筋骨格モデルの骨格

下肢 MR 画像から求めた被験者の筋肉体積値を反映させた筋骨格モデル, 下肢 MR 画像から得られた骨格形状を反映させた筋骨格モデル, 汎用モデルをスケーリングした標準筋骨格モデルにおけるシミュレーション結果の例を図 2 に示す. 図 2(a)では結果の例として歩行動作における右足外側広筋の筋張力を示し, 図 2(b)では歩行動作における右足の Hip Abduction Moment を示している. 図 2(a)の結果において, 被験者の筋肉体積値を反映した方が標準筋骨格モデルより筋張力が全体的に小さくなっている. これは AnyBody 上の表示で標準筋骨格モデルにおける外側広筋の体積値が 479.8ml, 被験者の筋肉体積値を反映した筋骨格モデルにおける外側広筋の体積値が 259.2ml であったことから, 被験者の筋肉体積値を反映させたことにより, 筋張力が全体的に小さくなったと考えられる. 図 2(b)では, 被験者の骨形状を反映した方が全体的にモーメントが小さくなっている. これは標準筋骨格モデルの右大腿骨の長さが 36.8cm であったのに対し, 被験者の骨形状を反映した筋骨格モデルの右大腿骨の長さは 34.2cm と短く, この大腿骨の長さの違いによってモーメントが小さくなったと考えられる.



(a)歩行動作における右足外側広筋の筋張力



(b)歩行動作における右足の Hip Abduction Moment

図 2 シミュレーション結果の例

6. まとめ

OpenCap を用いて被験者の歩行動作の計測を行い, また被験者の下肢 MR 画像から下肢筋肉体積値, 下肢骨形状を求め, それを反映した筋骨格モデルと, 動作計測で得られたモーションデータを用いて AnyBody でシミュレーションを行い, 標準筋骨格モデルを用いた場合と比較した. その結果, 標準筋骨格モデルを用いた場合より, 被験者の筋肉体積値や骨形状が反映された結果が得られた.

今後の予定としては 200 例規模のデータで実験を行い, 患者個別筋骨格モデルを用いたバイオメカニクスシミュレーションの意義・限界等を明らかにすることを目指す.

利益相反の有無

なし

文 献

[1] Damsgaard M, Rasmussen J, Christensen ST et al: Analysis of musculoskeletal systems in the anybody modeling system. Simulation Modelling Practice and Theory, Vol. 14, No. 8, pp. 1100–1111, 2006.

[2] Carbone VI, Fluit R, Pellikaan P et al: Tlem 2.0 - a comprehensive musculoskeletal geometry dataset for subject-specific modeling of lower extremity. Journal of biomechanics, Vol. 48 5, pp. 734–41, 2015.

[3] Lund ME, Andersen MS, Zee MD et al: Scaling of musculoskeletal models from static and dynamic trials. International Biomechanics, Vol. 2, No. 1, pp. 1–11, 2015.

[4] Uhlrich SD, Falisse A, Kidziński Ł et al: OpenCap: Human movement dynamics from smartphone videos. PLoS Comput Biol 19(10): e1011462, 2023.

[5] Li G, Otake Y, Soufi M et al: Hybrid representation-enhanced sampling for Bayesian active learning in musculoskeletal segmentation of lower extremities. Int J CARS, 2024.

大規模データベースにおける体幹部 CT 画像の自動筋骨格系セグメンテーションと解析

ゴリン サナー アミナ [*1]，崇風 まあぜん[*1]，大竹 義人[*1]，政木 勇人[*1,2]，村上 陽子[*3]，永谷 幸裕[*3]，渡邉 嘉之[*3]，上村 圭亮[*4]，高尾 正樹[*5]，菅野 伸彦[*4]，藤森 孝人[*4]，佐藤 嘉伸[*1]

[*1] 奈良先端科学技術大学院大学 情報科学領域, [*2] PSP 株式会社, [*3] 滋賀医科大学 放射線医学講座, [*4] 大阪大学大学院 医学系研究科, [*5] 愛媛大学大学院医学系研究科 整形外科

Automated musculoskeletal segmentation and analysis of torso CT images in a large-scale database

Sanaa Amina Gourine [*1], Mazen Soufi [*1], Yoshito Otake[*1], Yuto Masaki[*1,2], Yoko Murakami[*3], Yukihiro Nagatani[*3], Watanabe Yoshiyuki[*3], Keisuke Uemura[*4], Masaki Takao[*5], Nobuhiko Sugano[*4], Takahito Fujimori[*4], Yoshinobu Sato[*1]

*[*1] Nara Institute of Science and Technology, Division of Information Science, [*2] PSP Corporation, [*3] Shiga University of Medical Science, Department of Radiology, [*4] Osaka University Graduate School of Medicine Department of Orthopaedic Surgery, [*5] Ehime University, Department of Bone and Joint Surgery*

Abstract：本研究は、大規模データベース内の多様な体幹部構造のセグメンテーションを目的とし、さらに，正解ラベルなし CT 画像のセグメンテーション精度を評価するための予測不確実性の実現可能性を調査することを目指している。従来研究では、16 の構造を含めたラベル付きの 10 例を用いた 2D Bayesian UNet を学習させたが、筋肉体積や筋肉密度（平均ＨＵ値）などの特徴解析に有効なセグメンテーション検出に加えて、モデルのセグメンテーションは大規模データセットで検証されていなかった。本研究では、学習済みモデルを使用して CT 画像の大規模データベースのセグメンテーションを行い、予測不確実性に基づいて、筋肉の体積、平均 HU 値、脂肪抜き筋肉量、脂肪率を分析するために，信頼性の高いセグメンテーション結果を持った症例を検出し，解析対象にした。これらの特徴と患者の年齢や性別などの関係を報告する。

Keywords: Automated musculoskeletal segmentation, Torso CT images, Large-scale database, 2D Bayesian UNet, Features analysis

1. Introduction

Large-scale databases of torso CT images are gradually constructed, which are valuable for validating segmentation models and analyzing body features. In our previous work [1], we validated a Bayesian 2D UNet model on torso structure segmentation but didn't validate it to large databases. Given the variations in imaging conditions and patients' characteristics, selecting reliable segmentations to analyze variations in muscle features, such as volume and density, is challenging. Therefore, this study aims to reliably analyze the torso CT segmentations and muscle features across multiple structures in a large-scale CT database.

2. Materials and Methods

1) CT Images

In this study, we have used a large-scale database collected at multiple departments at Osaka University Hospital that included 1302 unlabeled cases of torso CT scans without contrast enhancement and acquired by various scanners with a voxel size of ~0.7×0.7×4.0 mm^3. The target segmentations included 14 muscles with two subcutaneous and visceral fat structures, as shown in Fig. 1.

2) Methods

In this study, we have employed a convolutional neural network (CNN)-based segmentation model: the 2D Bayesian UNet [2]. The model predicts segmentation accuracy by quantifying voxel-wise uncertainty using Monte Carlo dropout sampling. Reliable cases for feature analysis were selected based on the average uncertainty, where cases having a value smaller than 95% of the maximum average uncertainty were selected. The muscles were assessed using multiple metrics, i.e., muscle density (mean Hounsfield Units), volume, lean muscle mass [3], and fat ratio [4]. Statistical significance between age males and females was assessed using Mann Whitney U-Test with Bonferroni correction.

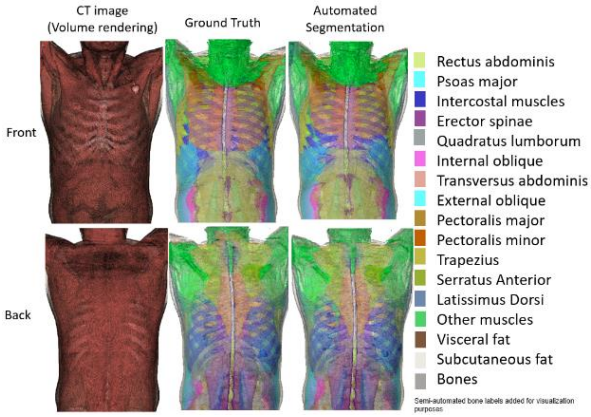


Figure 1 Representative CT image (left) with ground truth (middle) and automated segmentation labels (right). Target labels included 14 muscles and 2 fat structures.

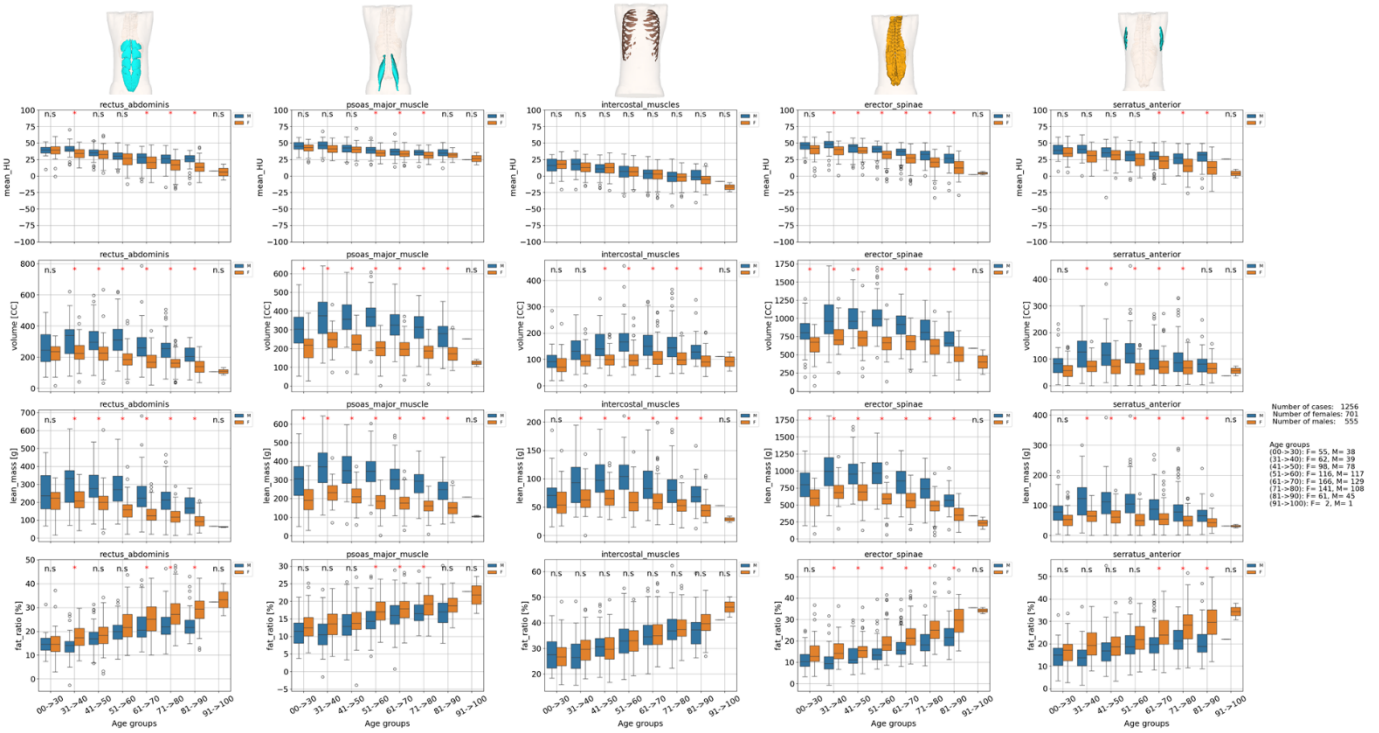


Figure 2: Quantitative assessment of human body features with regards to age/sex for several torso structures

3. Experiments and Results

In our previous work [1], we validated a 2D Bayesian UNet and evaluated it using a 5-fold cross-validation experiment. Segmentation accuracy (average DC) was 0.84±0.14, average symmetric surface distance (ASD) was 2.56±4.66 mm, average volume error (AVE) was 11.02±15.86 % and average intensity error (AIE) was 3.20±1.94 HU. Representative segmentation results are shown in Fig. 1. In this work, we have tested this trained model on a large-scale database and selected the valid segmentations based on the average uncertainty. Figure 2 presents boxplots of various evaluation metrics across age and gender in five major torso muscles.

We observed a decrease in mean HU values with age for all structures, with females showing lower muscle intensity than males. As for the muscle volume, it increases to a peak median value between 30 and 40 years old, then decreases until 90-100 year-old group across all structures. Females consistently have lower muscle volume compared to males. In addition, muscle mass follows a similar pattern, increasing from 30-40 years old before declining until 100 years old. Males exhibited higher lean muscle mass than females. We also noticed that the fat ratio increases with age in all structures, with females showing a slightly higher value than males. Significant differences were found between males and females in volume and lean muscle mass for almost all structures.

4. Discussion and Conclusion

This study aimed to reliably apply the segmentation to multiple structures and analyze the relationship between the muscle characteristics in the torso and age/sex in a large CT database.

Our segmentation model and uncertainty evaluation provided acceptable results in segmenting torso muscles and tracking changes in muscle mass, volume, and fat ratio with aging. However, the study had a limitation of using only 10 labeled cases for training the segmentation model. The target labels collected rotator cuff with neck muscles in a single label. Moreover, significant differences in mean HU were observed in contrast-enhanced CTs, which led to their exclusion from the current study. Future work will focus on expanding the training data to improve the segmentation accuracy, increase the structures to cover the rotator cuff muscles, and validate the models on large-scale databases, with investigation of the impact of contrast-enhancement on muscle assessment.

References

[1] Gourine S, et al. Automated musculoskeletal segmentation of torso CT images. Medical Imaging Conference, IEICE, 2024

[2] Yuta H, et al. Automated muscle segmentation from clinical CT using Bayesian U-Net for personalized musculoskeletal modeling. IEEE Transactions on Medical Imaging 39.4, 2019, pp. 1030-1040

[3] Gu Y, et al. MSKdeX: Musculoskeletal (MSK) decomposition from an X-ray image for fine-grained estimation of lean muscle mass and muscle volume. International Conference on Medical Image Computing and Computer-Assisted Intervention, Charm Springer Nature Switzerland, 2023, pp. 497-507

[4] Faron A, et al. Body composition analysis using CT and MRI: intra-individual intermodal comparison of muscle mass and myosteatosis. Scientific reports, 10.1, 2020, 11765

八分木キューブ構造の臓器変形モデルにおける反力提示の実装

宮﨑　琳太郎[*1]，林　雄一郎[*1]，小田　昌宏[*2, 1]，森　健策[*1, 2, 3]
[*1] 名古屋大学大学院情報学研究科
[*2] 名古屋大学情報基盤センター
[*3] 国立情報学研究所医療ビッグデータ研究センター

Implementation of Haptic Feedback for Deformable Organ Models based on Octree Cube Structure

Rintaro MIYAZAKI[*1]，Yuichiro HAYASHI[*1]，Masahiro ODA[*2, 1]，Kensaku MORI[*1, 2, 3]
[*1] *Graduate School of Informatics, Nagoya University*
[*2] *Information Technology Center, Nagoya University*
[*3] *Research Center for Medical Bigdata, National Institute of Informatics*

要旨：本研究では，八分木構造および Position Based Dynamics 法に基づく臓器変形モデルに対し，腹腔鏡鉗子の把持操作に伴う反力提示を実装した．近年のコンピュータやコンピュータグラフィックの進歩により，腹腔鏡手術の訓練環境としてシミュレーションが利用されている．製品化されたシミュレータの多くは，モニタに映された臓器モデルをインタラクティブに操作できる．しかし，リアルタイム動作のために臓器モデルの解像度が制限されていることが多く，視覚的品質が十分でない．レンダリングに高解像度の臓器モデル，変形計算にラフなキューブ構造を用いる手法が提案されているが，シミュレータの重要な役割である反力提示は実装されていない．本研究ではこのキューブ構造の変形モデルに対し，鉗子にかかる反力を，反力提示装置を通じて操作者に提示する手法を提案する．本手法をゲームエンジンである Unity に実装し，臓器モデルの変形に伴う反力提示を実現した．
キーワード：腹腔鏡手術シミュレーション，変形モデル，局所細分化，反力提示

1. はじめに

手術シミュレーションは医師や医学生が外科技術を習得するための有効な訓練環境の一つとしてその活用が期待されている．中でも，腹腔鏡手術シミュレータは既に製品化され、いくつかの研究調査によって手術手技の訓練環境としての有効性が評価されている[1, 2].

手術シミュレーションの開発では, 変形可能な臓器モデルが重要な役割を持つ. 臓器モデルは仮想環境上に配置され，手術器具による変形操作と操作者への反力提示が行われる. 臓器のような柔軟物体の変形シミュレーションは計算コストが高いため，リアルタイム性を確保するための工夫が必要である．臓器モデルのポリゴン数を削減することが解決策の一つであるが，見た目の品質に悪影響を及ぼすため，レンダリングのための高解像度サーフェスモデルと変形計算のための格子構造を分けて扱う手法が提案されている．

例えば，Pan J et al. は変形格子に 4 面体構造を利用し，Position Based Dynamics (PBD)法[3]による臓器モデルの変形・切断と反力提示を実現している[4]. 一方, 宮﨑らは空間分割手法の一つである八分木を利用し, 変形格子に階層的なキューブ構造を用いている[5]. また, より精密なマニピュレーションを実現するために, 鉗子モデルの接近によるキューブ要素の動的な局所細分化も実装している[6]. しかし，宮﨑らの手法では腹腔鏡手術シミュレーションにおいて重要な反力提示は実装されていない. 本研究では鉗子にかかる反力を各キューブ要素の形状制約から導出し, 反力提示装置を通じて操作者に提示する.

2. 手法

ここでは，先行研究[5, 6]の変形手法について簡単にまとめ，反力提示装置を通じて操作者に提示する手法について述べる．

1) 先行研究[5, 6]の変形手法

先行研究では, 高解像度の臓器サーフェスモデルを八分木階層構造のキューブ群で近似する. 臓器の変形運動の生成は PBD 法を用いて, 各キューブの変形がその元形状の立方体に復元する制約条件を与えることにより実現する．すなわち，時刻tにおける変形キューブのi番目の頂点の位置を$\boldsymbol{r}_i(t)$，その復元先の立方体の頂点位置を$\boldsymbol{R}_i(t)$とすると, 頂点の制約条件$\boldsymbol{C}_i(t)$は,

$$\boldsymbol{C}_i(t) = \boldsymbol{r}_i(t) - \boldsymbol{R}_i(t), \tag{1}$$

で定義される. なお, $\boldsymbol{R}_i(t)$はキューブの変形に含まれる剛体回転成分を考慮して求める必要がある. シミュレーションにおける離散時刻の更新間隔をΔtとし，$\boldsymbol{r}_i(t)$および$\boldsymbol{R}_i(t)$の座標系の原点を$\boldsymbol{r}_i(t)$の重心とする．$\boldsymbol{R}_i(t-\Delta t)$を回転行列$\boldsymbol{M}$で変換して$\boldsymbol{R}_i(t)$を求めるなら,

$$\boldsymbol{R}_i(t) = \boldsymbol{M}\boldsymbol{R}_i(t-\Delta t), \tag{2}$$

である．その回転角度は微小であり，近似的解法により$\boldsymbol{M}$は回転軸$\boldsymbol{u} = (u_x, u_y, u_z)$および回転角$\theta$を用いて,

$$\boldsymbol{M} = \begin{pmatrix} 1 & -u_z\theta & u_y\theta \\ u_z\theta & 1 & -u_x\theta \\ -u_y\theta & u_x\theta & 1 \end{pmatrix}, \tag{3}$$

で表すことができ，解析解を得ることが可能となる．

レンダリングにおけるシェーダ処理において, 変形後のキュ

ーブ 8 頂点からトリリニア補間により臓器サーフェスモデルの頂点がマッピングされる. この処理は計算量がサーフェスモデルの頂点数に対して線形的に増加するが, 頂点シェーダを用いることで高速化することが可能である[7].

2) 反力提示

本研究で利用する反力提示装置の Touch (3D Systems, USA) は，Unity や Unreal Engine などの主要なゲームエンジンでの開発を可能にするプラグインが用意されている．また，スタイラス（ペン形の入力装置）による 6 自由度の位置入力と，3 自由度の力覚フィードバックを最大 3.3N，1kHz の更新レートで受け取ることが可能である．

図 1 は反力提示のフローチャートを示している. スタイラス先端の位置$\boldsymbol{P}_s$および姿勢角$\boldsymbol{\theta}_s$はシミュレーションにおける鉗子モデルの先端部の位置および姿勢と連動する. スタイラスのボタンを押下する際に鉗子モデル先端部の位置とキューブ構造との接触判定を行い，位置$\boldsymbol{P}_s$とキューブ重心位置$\boldsymbol{G}$の距離が最も近い場合に，そのキューブを操作キューブとする．キューブ構造は操作キューブが動かされることによって変形が生じる．その後，反力計算が行われ，反力提示装置にフィードバックされる．反力$\boldsymbol{F}$は各シミュレーションステップにおいて操作キューブのもつ 8 頂点の位置$\boldsymbol{P}_i$と目標位置$\boldsymbol{P}_i'$を用いて計算される. i はキューブ頂点のインデックスを示す. 目標位置$\boldsymbol{P}_i'$は，キューブ構造の各要素に与えられる 1)の形状制約や重力条件に基づいて PBD 法によって反復的に求まる安定状態の位置である. 各キューブ要素の 8 頂点は位置$\boldsymbol{P}_i$からそれぞれの目標位置$\boldsymbol{P}_i'$に向かって復元力が与えられる．反力$\boldsymbol{F}$を，操作キューブの 8 頂点にかかる復元力の合力とすると，反力$\boldsymbol{F}$は，

$$\boldsymbol{F} = \alpha \sum_{i=0}^{7} k(\boldsymbol{P}_i' - \boldsymbol{P}_i), \tag{4}$$

で表される. αは反力調整のための係数, kはばね定数である.

3. 実験

本研究では，八分木キューブ構造の胆のうモデルに対し，鉗子モデルによる把持操作にともなう反力提示のシミュレーションを行った. 胆のうモデルは患者 CT 像から生成され, 19580 個の三角形パッチと 9792 個の頂点を持つ．キューブ構造の細分化階層数は 4 レベルとした．パラメータは$\alpha = 30, k = 0.004$とした．PC は AMD Ryzen 7 3700X 8-Core CPU および NVIDIA GeForce RTX 3060 GPU，反力提示装置は Touch (3D Systems, USA)，環境構築にはゲームエンジン Unity を用いた.

4. 結果と考察

図 2 は臓器の把持変形のシミュレーション結果を示している．反力$\boldsymbol{F}$の大きさとその各成分の値が表示されている．描画フレームレートは 44.2 fps であった．現段階では生成した反力

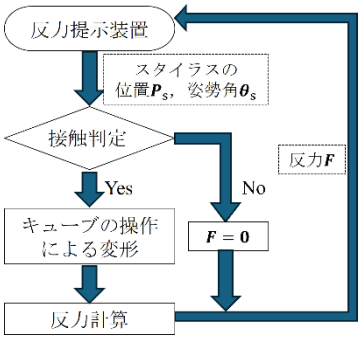


図 1 反力提示のフローチャート

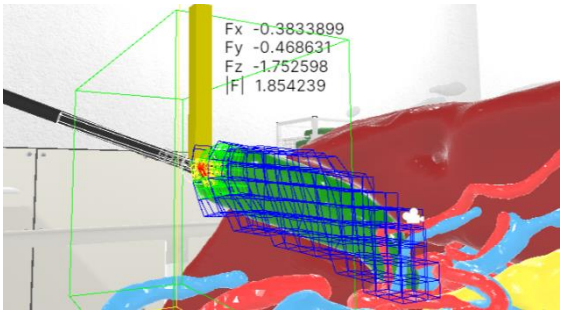


図 2 胆のうモデルの変形と反力提示

の値の妥当性については検討できていない．また，複数本の手術器具を用いた変形・反力提示の実装も重要課題である.

5. むすび

本研究では八分木キューブ構造を用いた臓器変形モデルの把持操作に対し，反力提示を実装した.

謝辞

本研究は JSPS 科研費 (21K19898, 24H00720)，JST CREST JPMJCR20D5，ムーンショット JPMJMS2033　JPMJMS2214, JST SPRING JPMJSP2125 の支援を受けた.

利益相反の有無　なし

文　献

[1] Badash I, Burtt K, Solorzano C et al: Innovations in surgery simulation: a review of past, current and future techniques. Ann Transl Med 4(23): 453, 2016

[2] Juan U González-Tova, Pallikonda S Madhulik: Systematic Review of Laparoscopic Surgery and Simulation-based Training. World J Lap Surg 10(3): 117-128, 2017

[3] Muller M, Heidelberger B, Hennix M et al: Position Based Dynamics, J Vis Comun 18(2), 109-118, 2007

[4] Pan J, Bai J, Zhao X et al: Real-time haptic manipulation and cutting of hybrid soft tissue models by extended position-based dynamics. Comp Anim Virtual Worlds 26: 321-335, 2015

[5] Miyazaki R, Hayashi Y, Oda M et al: Octree cube constraints in PBD method for high resolution surgical simulation, Proc. SPIE 12464, MI, 124642N, 2023

[6] Miyazaki R, Hayashi Y, Oda M et al: Adaptive octree cube refinement depending on grasping position for deformable organ models, Proc. SPIE 12927, MI, 1292826, 2024

[7] 宮崎琳太郎，林雄一郎，小田昌宏，他: 頂点シェーダを用いた八分木キューブ構造の局所細分化におけるマッピング処理の高速化，日本コンピュータ外科学会誌，23(6)-6, 2023

X 線位相 CT を用いた高精細マウス 3 次元アトラスの構築

米山明男[*1,2,3], Thet Thet Lwin[2], 馬場理香[4],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] 北里大学医療衛生学部
[3] 高エネルギー加速器研究機構物質構科学造研究所
[4]㈱日立製作所研究開発グループ

High-resolution 3D mouse atlas using phase-contrast X-ray CT

Akio YONEYAMA[*1,2,3], Thet Thet LWIN[2], Rika BABA[4], Kazuyuki HYODO[3], Keiichi HIRANO[3]
[*1] *SAGA Light Source*
[2] *School of Allied Health Sciences, Kitasato University*
[3] *Institute of Materials Structure Science, High Energy Accelerator Research Organization*
[4] *Research and Development Group, Hitachi Ltd.*

要旨：X 線が被写体を透過する際に生じる位相の変化（位相シフト）を画像化する位相コントラスト X 線 CT（X 線位相 CT）は，従来の吸収による強度変化を画像化する吸収コントラスト X 線 CT に比べて，軽元素に対して 1000 倍以上感度が高い．このため，無造影，低被曝，かつ高精細に生体の軟部組織を観察することができる．この特徴を活かして，心臓，腎臓，脳をはじめとするマウスの各種臓器の高精細な 3 次元アトラスの構築を，高エネルギー加速器研究機構の放射光施設に常設されている結晶 X 線干渉計型の位相 CT 撮像システムを用いて 2 年前より進めている．以下，本撮像システムの概要，撮像の条件，及びこれまでに取得した各種臓器の 3 次元像等について紹介する．
キーワード：位相 X 線 CT，アトラス

1. はじめに

高エネルギー加速器研究機構放射光実験施設（KEK PF）のビームライン BL-14C には，結晶 X 線干渉計型の大視野位相 CT 撮像システムが常設されている[1]．これまでに，同法の高感度な特性を活用して，肝臓や腎臓内の各種腫瘍と正常組織の無造影識別[2]，脳内に蓄積したアルツハイマー病βアミロイドの可視化と加齢に伴う定量解析[3]，表在ガンに対する抗がん剤投与効果の経時観察[4]，肝臓の血流動態解析[5]，ヒト胚子の非破壊観察[6]など，様々な観察が行われてきた．

バイオメディカル分野において，各種疾患の病態観察，加齢に伴う臓器変化，薬剤投与効果の定量可視化などに同撮像システムを幅広く活用していくためには，評価の基準となるマウスの正常臓器の三次元画像コレクション（アトラス）が不可欠である．しかし，これまでに取得した CT データは撮像条件や X 線画像検出器が大きく異なるために，同データ群から統一した像質のアトラスを作成することは困難である．そこで，同一環境下で育成した複数の正常マウスから同じプロトコルで摘出した各種の臓器を対象として，最高の空間及び密度分解能となる計測条件で撮像した，評価の基準に資する「位相ＣＴの画像アトラス」の作成を 2 年前より進めている．

2. 結晶 X 線干渉計型位相 CT 撮像システムと条件

BL-14C に常設されている撮像システムの模式図を図 1 に，主な仕様を表 1 に示す．今回，空気による X 線の吸収を低減するために真空パスを上流に設置し，さらに縞走査法における位相板駆動デバイスをステッピングモータから圧電素子へ変更して駆動時間の大幅な短縮（1 秒→0.1 秒以下）を行った後に，マウス腎臓を対象として露光時間や投影数について密度分解能などの検討を行った．

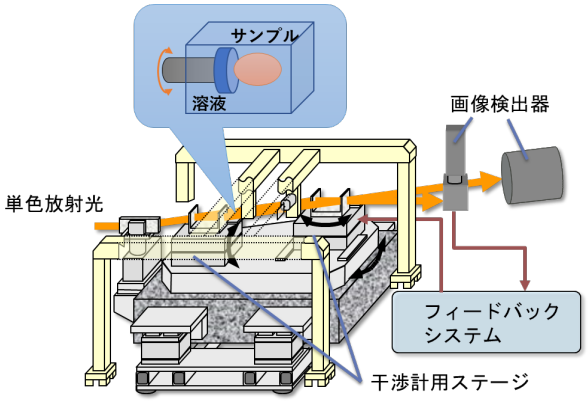


図 1　結晶 X 線干渉計型位相 CT 撮像システム

表 1　撮像システムの主な仕様

X 線エネルギー	17.8 ～35 keV
観察視野	16×13 mm^2
画素数	2560×2160
画素サイズ	6.5 ミクロン

3. 結果

1）撮像条件

検討の結果，表 2 に示す撮像条件を採用することにした．なお，本条件における密度分解能は 0.3 mg/cm^3，空間分解能は 20~30 ミクロンである．

表 2　アトラスの計測条件

X 線エネルギー	17.8 keV
露光時間	4 秒/干渉像
縞走査数	5
投影数	1000 投影/360 度

2）アトラスの作成

最終的には各臓器について 5 個の計測を予定しており，これまでに表 3 の計測を終了している．図 2 に一部の計測結果を示す．今後 2〜3 年で全データを取得し，SAKAS[7]に対応した CT データとしてクラウドで一般に公開する予定である．

表 3　アトラス構築の進捗状況

部位	進捗状況
脳	1 サンプル計測済み
肺	固定方法検討中
心臓	1 サンプル計測済み
肝臓	1 サンプル計測済み
脾臓	固定方法検討中
腎臓	2 サンプル計測済み

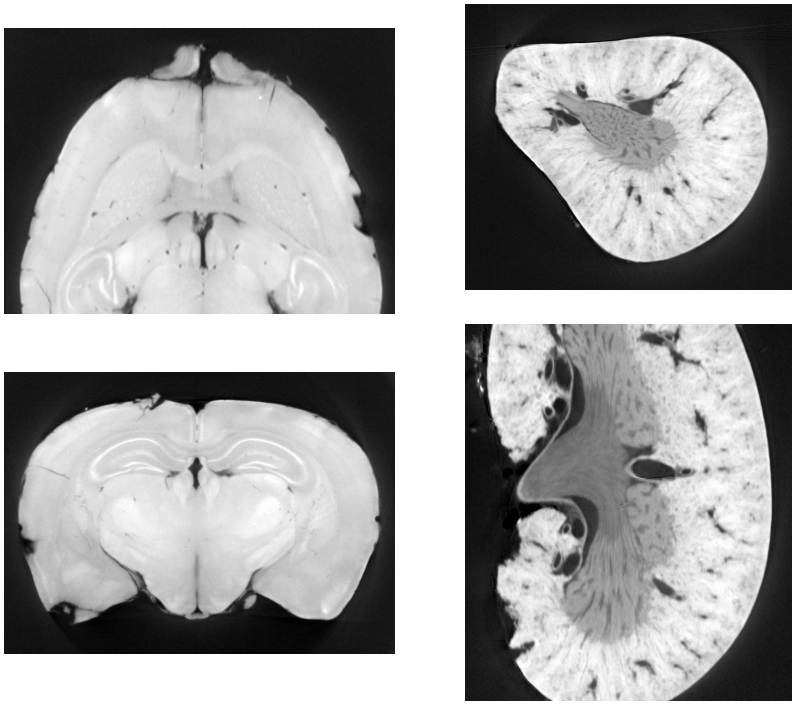


図 2　マウスアトラスの例（左：脳，右：腎臓）

4. まとめ

KEK PF に常設されている結晶 X 線干渉計型の位相 CT 撮像システムを用いてマウスアトラスの構築を進めている．今後２〜３年で全データを取得し，クラウドで一般に公開する予定である．なお，データ公開に関してご協力頂ける機関を募集中です．

謝辞

放射光を用いた計測は KEK PF の G 型課題「2022G611」で行った．本動物実験は北里大学医療衛生学部動物実験委員会の承認（承認番号 23-13-1）を得て実施した．

利益相反の有無

利益相反　無し

文　献

［1］ Yoneyama A, et al., J. of Phys.: Conference Series 425: 192007, 2013
［2］ Takeda T, et al., Radiology 214: 298, 2000
［3］ Noda-Saita K, et al., Neuroscience 138 (4): 1205-1213, 2006
［4］ Yoneyama A, et al, Jap. J. Appl. Phys. 4: 1864-1868, 2006.
［5］ Takeda T, et al., J. Sync. Radia. 19: 252-256, 2012
［6］ Kanahashi T, et al., The Anatomical Record 302: 1968, 2019
［7］ Yoneyama A, et al., ECR 2023:C-13563, 2023

吸気・呼気 CT 画像を用いた慢性閉塞性肺疾患における身体活動性予測

近藤　芽生[*1]，間普　真吾[*1]，平野　綱彦[*2]，村田　順之[*2]，土居　恵子[*2]，深津　愛裕美[*2]，
楊 鯤昊[*1]，松永　和人[*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呼吸器・感染症内科

Prediction of Physical Activity in Chronic Obstructive Pulmonary Disease Using Inspiratory and Expiratory CT Images

Kai KONDO[*1]，Shingo MABU[*1]，Tsunahiko HIRANO[*2]，Yoriyuki MURATA[*2]，Keiko DOI[*2]，
Ayumi FUKATSU-CHIKUMOTO[*2]，Kunhao YANG[*1]，Kazuto MATSUNAGA[*2]
[*1] *Graduate School of Sciences and Technology for Innovation, Yamaguchi University*
[*2] *Department of Respiratory Medicine and Infectious Disease, Yamaguchi University Hospital*

要旨：慢性閉塞性肺疾患（COPD）は，タバコ煙などの有害粒子を長期に吸入することで生じる肺 の慢性炎症性疾患である．COPD に罹患すると，患者は身体活動性が低下し日常生活が制限される．このことを身体活動性障害と呼び， これがさらに COPD の悪化に繋がる悪循環に陥ってしまう．したがって，身体活動性障害を正しく診断するために身体活動性の低下を予測することが重要である．身体活動性を予測する研究は，様々あり，吸気および呼気の胸部 CT 画像から予測できる可能性が示唆されているが，胸部 CT 画像と深層学習を組合せた予測モデルへの展開はまだ行われていない．そこで，吸気及び呼気の CT 値ヒストグラムから身体活動性を予測するモデルを構築する．具体的には，5 層で構成されたニューラルネットワーク（5-layer NN），自己符号化器付き NN（AENN），畳み込みニューラルネットワーク（CNN）を構築し，身体活動性の 正常および異常の 2 クラス分類を行い，各モデルの予測性能を評価する．

キーワード：COPD，身体活動性，CT，ヒストグラム

1. はじめに

慢性閉塞性肺疾患（COPD）は，タバコ煙などの有害粒子を長期に吸入することで生じる肺の炎症である．COPD に罹患すると，身体活動性が低下し，日常生活が制限される身体活動性障害を引き起こす原因となる．これがさらに，COPD の悪化につながり悪循環に陥ってしまう．したがって、身体活動性障害を正しく診断するために身体活動性の低下を予測することが重要である．先行研究より患者の検査項目からニューラルネットワークを用いて身体活動性を予測する研究 [1] や吸気及び呼気の胸部 Computed Tomography（CT）画像における CT 値と身体活動性との関連性を統計学的手法で明らかにする研究 [2] が行われてきたが，深層学習と吸気・呼気の胸部 CT 画像を併用して身体活動性予測を行っている研究は著者らの知る限り存在しない．

そこで本研究では，先行研究 [2] の知見にもとづき，吸気および呼気の CT 値ヒストグラムから身体活動性を予測するモデルを構築する．

2. 提案手法

まず胸部 CT 画像から肺野抽出を行い，肺野領域の CT 値から CT 値ヒストグラムを作成する．作成したヒストグラムに前処理を施し，さらに前処理済みデータを 3 つの予測モデルにそれぞれ入力し，Accuracy を評価する．

本研究では，身体活動性を表す指標（Total Exercise，T-Ex）が 3 以上で正常，3 未満で異常とし，2 クラス分類を行った．

2.1. 肺野抽出

本研究では，CT 値ヒストグラムを作成するにあたり，肺野領域の CT 値が必要となるため，胸部 CT 画像から肺野領域を抽出する必要がある．そのため，肺野領域のセグメンテーションを行う学習済みモデルである lungmask [3] を用いた．

2.2. CT 値ヒストグラムの作成

ヒストグラムを作成する CT 値の範囲は，先行研究 [2] にもとづき，-1000 から-300 の範囲とした．作成した吸気および呼気ヒストグラムの例を図 1 と図 2 に示した．図 1 は吸気を用いた作成例，図 2 は呼気を用いた作成例である．図 1，図 2 から，呼気に比べて吸気のほうが空気を多く含むため，より低い CT 値の範囲にヒストグラムが寄っていることがわかる．

本研究では，最も良い性能を示した階級幅 10 のヒストグラムを作成した．

2.3. CT 値ヒストグラムの前処理

各予測モデルに CT 値ヒストグラムを入力する前に，正規

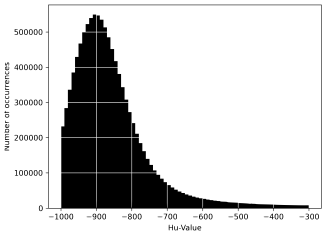


図 1 吸気ヒストグラム作成例

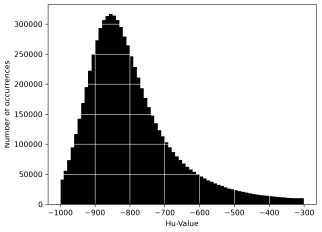


図 2 呼気ヒストグラム作成例

化・標準化・同じ階級のビンごとの標準化（ビン標準化）の 3 つの前処理のいずれかを適用し，それぞれ性能比較を行う．

2.4. 身体活動性予測モデル

1) 5 層で構成されたニューラルネットワーク（5-layer NN）

入力層，3 層の全結合層，出力層の 5 層で構成されたコンパクトなモデルである．

2) 自己符号化器付きニューラルネットワーク（AENN）

自己符号化器による事前学習により，入力データの圧縮・復元を通じて入力データの特徴をよく表した特徴量を抽出することができ，その特徴量を全結合層への入力としてファインチューニングを行うモデルである．本研究では使用する症例数は 138 であり，深層学習を行うには少ないデータ数であるため，事前学習による特徴抽出の改善を図った．

3) 畳み込みニューラルネットワーク（CNN）

ヒストグラムが表す 1 次元ベクトルを入力層，畳み込み層，プーリング層，畳み込み層，プーリング層，3 層の全結合層，出力層で構成された CNN によって特徴抽出と予測を行うモデルである．1×3 のフィルタを有する 1 次元畳み込みを用いた．

3. 実験結果

使用データは，山口大学医学部附属病院呼吸器・感染症内科から提供された COPD，非 COPD，健常の 138 症例である．1 症例ごとに吸気及び呼気の胸部 CT 画像が存在する．

身体活動性予測（5 分割交差検証）を行い，Accuracy による評価を行ったところ表 1 の結果となった．表 1 より，CT 値ヒストグラムの前処理には標準化を行い，5-layer NN で学習行ったケースが最も良い結果となった．

次に，機械学習手法の 1 つである Support Vector Machine（SVM）と 5-layer NN（前処理は標準化）の比較を行い，その結果を表 2 に示した．本比較は，データ数が少ないため深層学習を使用する効果を検証するためである．表 2 より，SVM に比べ 5-layer NN のほうが高い Accuracy を示した．

表 1 各モデルの身体活動性予測結果

モデル	前処理	Accuracy
5-layer NN	正規化	0.645
AENN		0.608
CNN		0.637
5-layer NN	標準化	**0.652**
AENN		0.601
CNN		0.638
5-layer NN	ビン標準化	0.558
AENN		0.579
CNN		0.565

表 2 SVM と提案モデルの比較結果

モデル	Accuracy
SVM	0.550
提案モデル	**0.652**

4. まとめ

吸気および呼気の胸部 CT 画像を用いて身体活動性の予測を行うモデルを複数構築した．その結果，5-layer NN が構築したモデルの中で最も高い Accuracy を示し，加えて SVM より高い Accuracy を示した．

しかし Accuracy にはまだ改善の余地があるため，ヒストグラムの作成方法の改善やデータ拡張，少量のデータからでも有用な特徴量を抽出するためのアルゴリズムの改善を行っていきたい．

謝辞

本研究は JSPS 科研費 JP21H03840，JP22K12152 の助成を受けたものです．

利益相反の有無

なし

文　献

［1］ Yoshiki Nakahara, Shingo Mabu, Tsunahiko Hirano, et al. Neural network approach to investigating the importance of test items for predicting physical activity in chronic obstructive pulmonary disease. Journal of Clinical Medicine, Vol. 12, No. 13, p. 4297, 2023.

［2］ Yoriyuki Murata, Tsunahiko Hirano, Keiko Doi, et al. Computed tomography lung density analysis: An imaging biomarker predicting physical inactivity in chronic obstructive pulmonary disease: A pilot study. Journal of Clinical Medicine, Vol. 12, No. 8, p. 2959, 2023.

［3］ Johannes Hofmanninger, Forian Prayer, Jeanny Pan, et al. Automatic lung segmentation in routine imaging is primarily a data diversity problem, not a methodology problem. European Radiology Experimental, Vol. 4, No. 1, pp. 1–13, 2020.

マルチモーダル学習を用いた CEA 患者の循環器病発症予測

石田　修也[*1]，盛田　健人[*1,2]，畠山　金太[*2]，蓮　乃駿[*2]，
渡辺　翔吾[*2]，小橋　昌司[*2,3]，飯原　弘二[*2]，若林　哲史[*1]
[*1] 三重大学大学院工学研究科情報工学専攻
[*2] 国立循環器病研究センター
[*3] 兵庫県立大学大学院工学研究科電子情報工学専攻

Multimodal Learning for the Prognostic Prediction of CEA Patients

Shuya ISHIDA[*1]，Kento MORITA[*1,2]，Nice REN[*2]，Kinta HATAKEYAMA[*2]，
Syoji KOBASHI[*2,3]，Shogo WATANABE[*2]，Koji IIHARA[*2]，Tetsushi WAKABAYASHI[*1]
[1] *Graduate School of Engineering, Mie University*
[*2] *National Cerebral and Cardiovascular Center*
[*3] *Graduate School of Engineering, University of Hyogo*

要旨：頸動脈内膜剥離術（CEA）は頚動脈狭窄に対する脳梗塞予防を目的とした外科的治療である．強度のプラーク狭窄を有する患者に対して CEA を施行することの有効性が示されているが，術後の長期予後を予測することは依然として困難である．これまでも CEA 患者の臨床情報を用いた予後予測の研究は行われてきているが，病理画像を用いた研究は存在しない．そこで，本研究では頚動脈プラーク病理画像と患者の臨床情報および病理医の所見の 3 つを組み合わせたマルチモーダル学習により，CEA 患者の術後 1 年以内の循環器病の発生の有無を予測した．異常検知モデルによって得られた病理学的リスクスコアと臨床情報および TF-IDF によって得られた病理医の所見特徴量を組み合わせ，XGBoost による分類を行った結果，ROC-AUC は 0.875，F 値は 0.811 を得た．これらの値はそれぞれの特徴量を単体で用いた時よりも良い予測性能を示した．
キーワード：マルチモーダル学習，病理画像，予後予測，頸動脈内膜剥離術，深層学習

1. はじめに

循環器疾患は日本人の死因の中で，癌に次いで 2 番目に多い疾患である．頸動脈内膜剥離術（Carotid Endarterectomy，CEA）は頚動脈狭窄に対する脳梗塞予防を目的とした外科的治療である[1]．近年の報告では，CEA 患者の臨床情報を用いて循環器病の発症の有無を予測できることが示されているが[2,3]，頸動脈プラークにおける病理画像と脳卒中を含む循環器病の発生を検討した報告はない．本研究では頚動脈プラーク病理画像と患者の臨床情報および病理医の所見の 3 つを組み合わせたマルチモーダル学習により，CEA 患者の術後 1 年以内の循環器病の発生の有無を推定し，病理学的および臨床的因子の特定を目指す．

2. データセット

本研究では国立循環器病研究センターから提供された 141 名の病理画像及び臨床データを用いる．CEA 術後 1 年以内の脳卒中及び心筋梗塞のイベント（術直後の脳梗塞を示す DWI 高信号、退院後の脳梗塞及び心筋梗塞の発生）の有無に対して，表 1 に示すとおりイベントが発生しなかった 120 例を正常データと定義し，イベントが発生した 21 例を異常データとする．臨床情報には患者の年齢や既往症の有無・薬の投与歴などの計 16 種類のパラメータを用いる．病理医の所見は日本語から英語に翻訳したものを用い，語彙は 457 語，文の長さは最大 83 語である．なお，本研究の実施は国立循環器病研究センター倫理委員会にて承認済みである．

表 1:　データ数

長期予後	患者(名)	WSI(枚)
正常	120	197
異常(DWI)	10	16
異常(心筋梗塞)	7	11
異常(脳梗塞)	4	4

3. 提案手法

提案手法は主に 2 つのステップからなる．まず，正常患者の画像のみを用い，異常検知モデルとしてオートエンコーダを学習し，各患者の病理学的リスクスコアを算出する．その後，得られた病理学的リスクスコアと患者の臨床情報及び病理医の所見から抽出した特徴量の 3 つを組み合わせ，XGBoost を用いて循環器病の発症の有無を推定する．

3-1. 異常検知による病理学的リスクスコアの算出

異常検知とは，大多数のデータとは振る舞いの異なるデータを検出する技術であり，正常データでのみ学習を行うため，異常データが少ない場合に有用である．異常検知には画像分野で広く用いられている畳み込みオートエンコーダを用いる．異常

スコア$A(x)$は各パッチ画像について計算され，入力画像と出力画像の MSE であり，式(1)によって求める．

$$A(x) = \frac{1}{n}\left|x - D\left(E(x)\right)\right|^2 \quad (1)$$

なお，xはテスト画像，$D(E(x))$は生成画像，nは総画素数である．

患者ごとの病理学的リスクスコアA_pは異常スコア算出対象パッチ群Xと異常スコア$A(x)$を用いた式(2)によって求める．

$$A_P = \frac{\Sigma_{x\epsilon X} A(x)}{|X|} \quad (2)$$

3-2. マルチモーダル学習による循環器病発症予測

ここでは，オートエンコーダによって得られた病理学的リスクスコアA_pと 16 種類の臨床情報及び TF-IDF[4]によって抽出された病理医の所見特徴量を組み合わせ，XGBoost を用いて循環器病を発症するか否かの二値分類を行う．

4. 実験

オートエンコーダの学習には正常患者 70 名分を用い，残りのすべての患者について病理学的リスクスコアA_pを算出した．XGBoost を用いた分類にはオートエンコーダで学習した患者を除く正常患者 50 名と異常患者 21 名を学習と評価に用いる．被験者の組み合わせ方を変え，4 分割交差検証を 100 回繰り返し，その平均値を評価値に用いる．なお，TF-IDF 値は病理所見から[atheroma, covered, narrowed, observed, ruptured, thrombus, vitrified]といった特定の 7 つの単語を指定して求めた．

4-1. 実験結果

表 2 は循環器病を発症するか否かの二値分類において，組み合わせを変えた以下の 6 つの方法を比較したものである．

#1 病理学的リスクスコアのみ
#2 臨床情報のみ
#3 病理所見(TF-IDF)のみ
#4 病理学的リスクスコア＋臨床情報
#5 臨床情報＋病理所見(TF-IDF)
#6 病理学的リスクスコア＋臨床情報＋病理所見(TF-IDF)

病理画像(#1)，臨床情報(#2)，病理所見(#3)の ROC-AUC を比較すると，病理画像から得られる病理学的リスクスコアの分類性能が最も高く，次いで臨床情報，病理所見となった．また，この 3 つを組み合わせた方法(#6)は ROC-AUC が 0.875，F 値が 0.811 と最も優れた予測性能を示した．図 1 に実験方法#6 の XGBoost の特徴量重要度を示す．異常検知によって算出された病理学的リスクスコアの重要度は，臨床データや 7 単語の TF-IDF 値よりも高く，病理学的リスクスコアが循環器病発症予測に有用な因子であることを示している．

表 2：実験結果

#	ROC-AUC	PR-AUC	感度	特異度	F 値
1	0.776	0.737	0.714	0.800	0.652
2	0.764	0.617	0.818	0.746	0.683
3	0.669	0.669	0.638	0.826	0.618
4	0.839	0.800	0.801	**0.911**	0.793
5	0.808	0.664	**0.891**	0.754	0.724
6	**0.875**	**0.828**	0.842	0.899	**0.811**

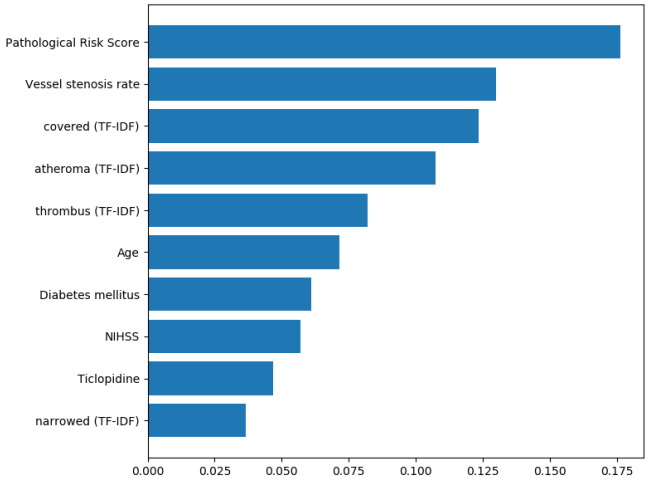


図 1：特徴量重要度

5. 結論と今後の予定

本研究では，病理画像，臨床情報及び病理医の所見を組み合わせたマルチモーダル学習によって CEA 術後 1 年以内の循環器病の発症の有無を推定した．結果として，提案手法の ROC-AUC は 0.875，F 値は 0.811 となり，それぞれ単体で予測するよりも高い性能を示した．

今後は，病理学的リスクスコアの算出方法を検討し，単語の選択が予測精度に与える影響を調査する．また，Word2vec や他の自然言語処理手法を用いた実験を行う予定である．

利益相反の有無

本研究の一部は㈱イドルシア ファーマシューティカルズジャパンの研究助成金を得て実施した．

文　献

[1] Rothwell PM, Slattery J, Warlow CP et al: A Systematic Comparison of the Risks of Stroke and Death Due to Carotid Endarterectomy for Symptomatic and Asymptomatic Stenosis. *Stroke*, 27:266-269, 1996

[2] Matsuo K, Fujita A, Hosoda K et al: Potential of machine learning to predict early ischemic events after carotid endarterectomy or stenting: a comparison with surgeon predictions. *Neurosurg Rev* 45(1):607-616, 2022

[3] Li B, Beaton D, Eisenberg N et al: Using machine learning to predict outcomes following carotid endarterectomy. *J Vasc Surg*78(4):973-987.e6, 2023

[4] Salton G: Automatic Text Processing, *Addison-Wesley Publishing Company*, 1989.

拡散モデルによる人体頭部の未来予測と脳室容積の予測精度検証

柴田　寿一[*1]，花岡　昇平[*1]，野村　行弘[*2, 3]，吉川　健啓[*2]，阿部　修[*1]
[*1] 東京大学医学部附属病院放射線科
[*2] 東京大学医学部附属病院コンピュータ画像診断学／予防医学講座
[*3] 千葉大学フロンティア医工学センター

Aging Prediction of Human Head with a Diffusion Model and Evaluation with Ventricular Volume

Hisaichi SHIBATA[*1]，Shouhei HANAOKA[*1]，Yukihiro NOMURA[*2, 3]，
Takeharu YOSHIKAWA[*3]，and Osamu ABE[*1]
[*1] *Department of Radiology, The University of Tokyo Hospital*
[*2] *Department of Computational Diagnostic Radiology and Preventive Medicine, The University of Tokyo Hospital*
[*3] *Center for Frontier Medical Engineering, Chiba University*

要旨：我々は驚くほど普遍的な老化を経験する．デジタル領域で老化を統計的に予測できれば，それは病変やその発生の兆候を超早期に発見できる可能性がある．さらに，これらを基に介入することで，究極的には患者の生活の質を向上できる可能性もある．これらを受けた本研究では，成人人体頭部のデジタルツインを構築する．このデジタルツインは，長期にわたる頭部磁気共鳴画像を採用して学習される．このデジタルツインは，多点予測，不確実性評価，および予測性能の多点評価の 3 点を特徴とし，従来のデジタルツインと異なる．これらの特徴により，未来の頭部 MRI スキャンのより正確な予測が可能になると考えられる．我々は，3 次元条件付き拡散モデルを採用することで，このデジタルツインを実現し，その未来予測精度を脳室容積で評価する．

キーワード：老化予測，頭部 MRI，拡散モデル，条件付きサンプリング，不確実性評価

1. はじめに

誕生から死に至るまで，我々は皆，加齢による普遍的な変化（老化）を経験する．本研究では，老化は個別の軌跡を取るが，統計的にモデル化できると仮定し，デジタル領域で老化を予測するモデル（人体デジタルツイン）を構築する．人体デジタルツインは予防医学を革新し，病理学的変化を初期段階で検出し，究極的には，病変が現れる前に介入することで，生活の質を向上させ，同時に寿命も延長できる可能性がある．

深層生成モデル（Deep Generative Model: DGM）は，複雑なデータのパターンをモデル化できるので，離散的かつ確率的な変化を包括する老化を扱う人体デジタルツインの基盤技術として適切である．したがって，本研究では，DGM を採用する．既に，いくつかの研究者が，医用画像を DGM で処理して未来の人体を予測するための人体デジタルツインを開発している[1]．しかし，成人人体のデジタルツインに関する先行研究では，　経時的な 3 次元医用画像を採用した研究はまだない．この制限は，長期にわたって同一患者を追跡した，成人人体を写した医用画像の公開データセットがほぼないことから生じた可能性がある．一方，我々は，東京大学医学部附属病院の検診部門にて撮像された長期的な医用画像を採用することで，この制限を克服する．

以上を受けた本研究では，成人人体の頭部を扱えるデジタルツインを構築し評価することを目標とする．特に，過去複数点の長期的な 3 次元頭部磁気共鳴画像（MRI）を事前知識とし，現在の頭部 MRI スキャンを推定し生成する規則を学習することで，現在までのスキャンに基づいて，未来の頭部 MRI スキャンを予測するデジタルツインを構成できることを示す．

2. 方法

確率的デノイジング拡散モデル（DDPM: Denoising Diffusion Probabilistic Models）[2]を拡張したモデルを新規に構築し，条件付き確率分布$p(\boldsymbol{x}, \boldsymbol{y})$を学習する．具体的には，3 次元の条件付きモデルである点で，本モデルは新しい．ここに，$\boldsymbol{x}$は 7 年前から 1 年前までの計 7 ボリュームの MRI 体積画像を積層したデータを表し，$\boldsymbol{y}$は現在の MRI 画像を表す．過去のデータから現在のデータを予測する過程（未来予測）はサンプリングによる画像生成で実現する．つまり，$\boldsymbol{y} \sim p(\boldsymbol{x}, \boldsymbol{y})$である．これは，疑似乱数により生成されたガウシアンノイズ$\boldsymbol{y}_0$からのデノイジングを学習済みモデルによって逐次的に行い，画像$\boldsymbol{y}$を生成することに対応する．加え，統計的性質を維持したまま$\boldsymbol{y}_0$を変更することで，あり得るが相異なる未来の人体頭部を予測し生成することが可能になると考えられる．$\boldsymbol{y}_0$を変えるためには，乱数シードを変えればよい．これにより，予測さ

れた画像からセグメンテーション・ツール等により計算された脳室容積や全脳容積などの量について，形式的には平均や分散などの量を計算できる．本研究でのエラーバーは，この手法で計算された量を示している．DDPM の詳細については，紙面の都合から詳細を解説できないので，[2]を参照のこと．

東京大学医学部附属病院で撮像された 621 症例の頭部 MRI スキャンを 128x128x128 の画像サイズにダウン・サンプリングして採用した．撮像方法などについては，紙面の都合から説明を略す．これをトレーニング 599 症例（それぞれ 8 回分の体積画像を含む），テスト 22 症例（それぞれ 13 回分の体積画像を含む）に分割した．トレーニング損失のみで学習の進行を監視するため，バリデーション症例は設定しない．スキャンがない年は，ブランク画像を入力としたが，予測対象となる画像には，ブランク画像が混入しないように設定した．頭部 MRI スキャンを[0, 8192]の値域にクリップした後，それを[-1, 1]に変換して用いた．DDPM のアーキテクチャは，UNet3D を基本とし，注意機構と 3 次元畳み込みニューラル・ネットワークを組み合わせたものである．デノイジング・ステップ数は，標準的な 1,000 に設定した．メモリ要求量を抑えるため，fp16 演算と Flash Attention を採用した．学習率は 8e-5 に設定した．加え，指数移動平均（EMA）を採用し，減衰率は 0.995 と設定した．計算は，DGX-A100 サーバー上の GPU 8 基で実施した．バッチ・サイズは 1 GPU あたり 1 に設定し，勾配アキュムレーションは 2 に設定したので，全体ではバッチ・サイズは 16 となる．この学習を，42 epochs にわたって進めた．

推論時（老化予測時）には，過去 7 年分の頭部 MRI スキャンを学習済みモデルに入力し，未来の頭部 MRI スキャンを 1 つ得る．これを再帰的に繰り返すことにより，より遠い未来の頭部 MRI スキャンも得る．加え，乱数シードを変えることにより，あり得るが相異なる未来の頭部 MRI スキャンも得る．本研究では，10 個の異なる乱数シードを採用した．

脳室容積などを頭部 MRI から自動的に計算するため，セグメンテーション・ツールとして，LOD-Brain [3]を採用した．これは，脳室，脳脊髄液，小脳，灰白質，白質，脳幹を空間的に分類して表示することができる．本研究では，その結果から，ボクセル数をカウントし，経時変化として，プロットする．

3. 結果

図 1 に予測した未来の頭部 MRI スキャンから脳室容積を計算し，時系列データとしてプロットする．7 症例において，6 年先までの脳室容積を全脳容積で規格化した量の MAE: Mean Absolute Error は 0.3875 [%]であった．一方，線形回帰では，0.3750 [%]であった．一方，全脳容積についての MAE は，27.39 [cc]であった．一方，線形回帰では，38.40 [cc]であり，提案デジタルツインよりも予測精度は低い．

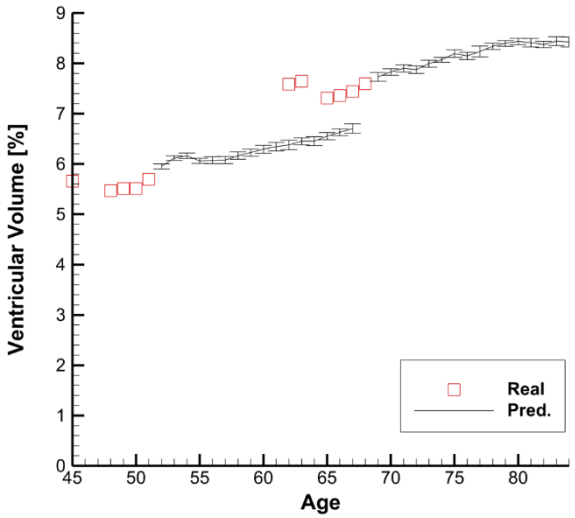


図 1 提案する人体デジタルツインによる脳室容積の 16 年先までの予測結果（2 症例をチェリー・ピック）．脳室容積は全脳容積で規格化されている．エラーバーは 95%信頼区間（t 分布を仮定）を表す．

4. まとめ

本研究では，未来の人体頭部を予測し生成できるデジタルツインを構築した．このデジタルツインは，6 年先までの脳室容積の予測については，線形回帰と同等の性能ではあるが，全脳容積の予測については，線形回帰よりも高い精度で予測できることが判明した．このデジタルツインの学習は，健常成人のコホートからの頭部 MRI スキャンに基づくものである．本研究は後ろ向き研究であるが，将来的には，年齢，性別，認知機能の状態などに基づく条件付きモデルを取り入れる可能性がある．また，人体の異なる部位でデジタルツインを構成することも検討しており，多様なデジタルツインの基盤を築くことを目指している．

謝辞

本研究は JSPS 科研費 21K18073 の助成を受けたものです．東京大学医学部附属病院・コンピュータ画像診断学／予防医学講座は，株式会社ハイメディック／シーメンス・ジャパン株式会社の寄附講座です．

利益相反の有無

なし

文　献

［1］ Ravi, D., *et al.* “Degenerative adversarial neuroimage nets for brain scan simulations: Application in ageing and dementia.” Medical Image Analysis **75** (2022): 102257.

［2］ Ho, J., *et al.* “Denoising diffusion probabilistic models.” Advances in Neural Information Processing Systems **33** (2020): 6840-6851.

［3］ Svanera, M., *et al.* “Fighting the scanner effect in brain MRI segmentation with a progressive level-of-detail network trained on multi-site data.” Medical Image Analysis **93** (2024): 103090.

体幹部定位放射線治療を受けた早期非小細胞肺癌患者における腫瘍成長モデルの開発

光島　千稀[*1]，有村　秀孝[*2]，白川　友子[*3]，　吉武　忠正[*4]
[*1] 九州大学大学院医学系学府保健学専攻医用量子線科学分野
[*2] 九州大学大学院医学研究院保健学部門
[*3] 独立行政法人国立病院機構九州がんセンター放射線治療科
[*4] 九州大学病院放射線科

Development of a tumor growth model in early-stage non-small cell lung cancer patients who underwent stereotactic body radiation therapy

Kazuki MITSUSHIMA[*1]，Hidetaka ARIMURA[*2]，　Yuko SHIRAKAWA[*3]，Tadamasa TOSHITAKE[*4]
[*1] *Division of Radiological Science, Department of Health Sciences, Faculty of Medicine, Kyushu University*
[*2] *Division of Medical Quantum Science, Department of Health Sciences, Academy of Medicine, Graduate school of Kyushu University*
[*3] *Department of Radiation Oncology, National Hospital Organization Kyushu Cancer Center*
[*4] *Department of Radiology, Kyushu University Hospital*

要旨：体幹部定位放射線治療（SBRT）を受けた早期非小細胞肺癌（NSCLC）患者では腫瘍が進行することがある．したがって，本研究では腫瘍の進行予測を目的とし，SBRT を受けた早期 NSCLC 患者の腫瘍成長モデルの開発を行った．SBRT を施行した NSCLC 患者 17 名を選択し，治療前後の CT 画像から輪郭描出した肉眼的腫瘍体積（GTV）をもとに腫瘍細胞数を算出し，それらを参照値とした．一方，放射線に対して 3 つの異なる反応を示す細胞集団（感受性細胞，persister 細胞，抵抗性細胞）が存在すると仮定し，Gompertz モデルに基づいた腫瘍成長モデルを構築した．腫瘍成長モデルに含まれる 9 つのパラメータを焼きなまし法によって最適化し，腫瘍細胞数の経時変化曲線を推定した．SBRT を受けた早期 NSCLC 患者において，腫瘍細胞数の予測可能性を示したが，進行予測のためには腫瘍成長モデルの更なる改良が必要である．

キーワード：腫瘍成長モデル，腫瘍細胞数，体幹部定位放射線治療，非小細胞肺癌

1. はじめに

肺癌は小細胞肺癌と非小細胞肺癌（NSCLC）の大きく 2 つに分類され, そのうち NSCLC は全肺癌の 85%~90%を占める．NSCLC は複数の組織型を有し，主に腺癌，扁平上皮癌，大細胞癌の 3 つが挙げられる．I~II期の NSCLC 患者の標準治療は手術である[1]．しかしながら，医学的に切除不能な腫瘍や手術を拒否した患者といった手術不可症例に対しては体幹部定位放射線治療（SBRT）が施行されている[1]．SBRT とは体幹部の腫瘍に対して，多方向から腫瘍の形状に沿って，大線量を短期間に寡分割照射する治療法である．SBRT は手術に比べて，患者への侵襲度が低く, 外来通院も可能であるという利点がある． 2021 年に，アメリカ・テキサス大学 MD アンダーソンがんセンターで行われた，手術可能な I 期 NSCLC 患者に用いる SBRT と手術の長期転帰を比較した STARS Revised 試験において，3 年生存率は SBRT，手術ともに 91%，3 年無増悪生存率は SBRT が 80%，手術が 88%と同等の治療成績を収めたことが報告されている[2]．しかしながら，SBRT においても腫瘍が進行することがあるのも現状である．

本研究では、腫瘍の進行予測を目的とし，SBRT を受けた早期 NSCLC 患者の腫瘍成長モデルを開発した．

2. 対象と方法

1）対象症例

本研究は九州大学医系地区部局臨床研究倫理委員会の許可を受けて行った．九州大学病院にて，2004 年から 2016 年において SBRT を行ったI期 NSCLC 患者 131 人のうち, 放射線腫瘍医の確認のもと，GTV（肉眼的腫瘍体積）の輪郭抽出が可能であったフォローアップ CT 画像を 2 つ以上含む 17 症例を本研究の対象とした．腫瘍のサブタイプの内訳は扁平上皮癌 7 症例，腺癌 8 症例，大細胞癌 1 症例，不明 1 症例であった．また，17 症例の全てが 48Gy / 4Fraction で処方されていた．

2）使用した CT 画像と腫瘍細胞数の計算

各患者の治療計画用 CT 画像およびフォローアップ CT 画像において，前述のとおり，GTV の輪郭描出を行った．次に，等方ボクセル化を行った上でボクセル数をカウントし, ボクセルサイズを乗じて GTV の体積を算出した．最後に，腫瘍細胞密

度を乗じることで腫瘍細胞数を算出し，それらを参照数とした[3]．これらの過程において，MATLAB2018a, 3Dslicer ver.4.10.2, ImageJ を使用した．

3）Gompertz モデルによる腫瘍細胞数の予測

本研究では腫瘍成長モデルとして Gompertz モデルを採用し、CT 画像から求めた腫瘍細胞数にフィットする腫瘍成長モデルを構築した．NSCLC 患者の腫瘍細胞は放射線抵抗性細胞，persister 細胞，放射線感受性細胞の 3 種類に分けられると仮定し，3 種類の細胞数の合計が腫瘍細胞数となる[4][5]．放射線治療開始前における放射線抵抗性細胞，persister 細胞，放射線感受性細胞に対する腫瘍成長モデルはそれぞれ次のように定義した．

$$\frac{dN_r(t)}{dt} = \lambda_r N_r(t) - log\left(\frac{K}{N(t)}\right) \quad (1)$$

$$\frac{dN_p(t)}{dt} = \lambda_p N_p(t) - log\left(\frac{K}{N(t)}\right) \quad (2)$$

$$\frac{dN_s(t)}{dt} = \lambda_s N_s(t) - log\left(\frac{K}{N(t)}\right) \quad (3)$$

同様に，放射線治療開始後においては，それぞれ次のように定義した．

$$\frac{dN_r(t)}{dt} = \lambda_r N_r(t) - log\left(\frac{K}{N(t)}\right) + \mu\lambda_r N_r(t)\, log\left(\frac{K}{N(t)}\right) \quad (4)$$

$$\frac{dN_p(t)}{dt} = \lambda_p N_p(t) - log\left(\frac{K}{N(t)}\right) - \mu\lambda_p N_p(t)\, log\left(\frac{K}{N(t)}\right) \quad (5)$$

$$\frac{dN_s(t)}{dt} = \lambda_s N_s(t) - \log\left(\frac{K}{N(t)}\right) - n\lambda_s N_s(t)\log\left(\frac{K}{N(t)}\right) \quad (6)$$

ただ，照射中の放射線感受性細胞に対する腫瘍成長モデルについては次のように定義した．

$$\frac{dN_s(t)}{dt} = \lambda_s N_s(t) - \log\left(\frac{K}{N(t)}\right) - (\alpha d + \beta d^2)N_s(t) \quad (7)$$

tは放射線治療開始時を 0 とした経過日数であり，時間 t における全腫瘍細胞数を $N(t)$，放射線抵抗性細胞および persister 細胞の初期比率をそれぞれ a, b と定義した．放射線抵抗性細胞，persister 細胞，放射線感受性細胞において，$N_r(t)$，$N_p(t)$および$N_s(t)$はそれぞれ時間tにおける細胞数であり，λ_r，λ_pおよびλ_sはそれぞれ腫瘍細胞の成長率である．μは persister 細胞から放射線抵抗性細胞への変異確率，αとβはα/β値に基づき，dは 1 回線量 (Gy) ，nは細胞損失パラメータ，Kは carrying capacity である．焼きなまし法を用いて、腫瘍成長モデルに含まれる 9 個のパラメータ（λ_r, λ_p, λ_s, μ, a, b, n, α, α/β）を最適化することで，腫瘍細胞数の経時変化曲線を推定した．

4) 腫瘍成長モデルの評価

本研究で開発した腫瘍成長モデルの評価として，MAPE（平均絶対誤差率）とスピアマンの相関係数を用いた．MAPE は次の式で定義された．

$$MAPE = \frac{1}{n}\sum_{i=1}^{n}\frac{|N_p(i)-N_m(i)|}{N_m(i)} \times 100 \quad (8)$$

N_m は CT 画像から求めた腫瘍細胞数の参照数，N_p は数学的モデルによって求めた腫瘍細胞数の予測値である．

3. 結果

推定した腫瘍細胞数の経時変化曲線の 1 例を図 1 に示す．この症例では、治療の影響で放射線感受性細胞は急激に減少するが，抵抗性細胞は少し増加し，persister 細胞はほとんど変化しないと推定された．全 17 症例における MAPE とスピアマンの相関係数の平均値はそれぞれ 15.9，0.872 であった．

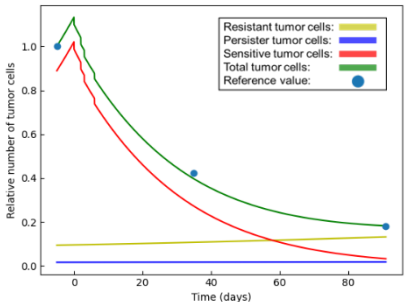


図 1　srt129 における腫瘍細胞数の経時変化曲線

4. 結論

SBRT を受けた早期 NSCLC 患者において，腫瘍細胞数の予測可能性を示したが，進行予測のためには腫瘍成長モデルの更なる改良が必要である．

謝辞

本研究は JSPS 科研費 JP24K10840 の助成を受けたものです．

利益相反の有無

なし．

文　献

［1］David Planchard, Silvia Novello, Solange Peters et al: Non-Small Cell Lung Cancer. Guide for Patients: 8-10, 23-24, 2019

［2］Chang JY, Mehran RJ, Feng L et al: STARS Lung Cancer Trials Group. Stereotactic ablative radiotherapy for operable stage I non-small-cell lung cancer (revised STARS): long-term results of a single-arm, prospective trial with prespecified comparison to surgery. Lancet Oncol 22(10): 1448-1457, 2021

［3］Katsurada N, Tachihara M, Jimbo N et al: Yield of tumor samples with a large guide-sheath in endobronchial ultrasound transbronchial biopsy for non-small cell lung cancer: A prospective study. PLoS One 16(10): e0259236, 2021

［4］Geng C, Paganetti H, Grassberger C: Prediction of Treatment Response for Combined Chemo- and Radiation Therapy for Non-Small Cell Lung Cancer Patients Using a Bio-Mathematical Model. Sci Rep 7(1): 13542, 2017

［5］Zhao Y, Song Y, Zhao R et al: Gene Panel of Persister Cells as a Prognostic Indicator for Tumor Repopulation After Radiation. Front Oncol 10: 607727, 2020

早期非小細胞肺癌に対する体幹部定位放射線治療における治療計画 CT 画像を用いた放射線肺炎予測

江田　惇哉[*1]，有村　秀孝[*2]，兒玉　拓巳[*1]，吉武　忠正[*3]，廣瀬　貴章[*4]，Yagiz YEDEKCI [*5]

[*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臨床放射線科学分野

[*4] 九州大学病院医療技術部放射線部門

[*5] *Department of Radiation Oncology, Faculty of Medicine, Hacettepe University*

Prediction of Radiation Pneumonitis Using Planning CT Images in Stereotactic Body Radiation Therapy for Early-Stage Non-Small Cell Lung Cancer

Junya EDA[*1]，Hidetaka ARIMURA[*2]，Takumi KODAMA[*1]，Tadamasa YOSHITAKE[*3]，Taka-aki HIROSE[*4]，Yagiz YEDEKCI[*5]

[*1] *Department of Health Sciences, Graduate School of Medical Sciences, Kyushu University*

[*2] *Division of Medical Quantum Science, Department of Health Sciences, Faculty of Medical Sciences, Kyushu University*

[*3] *Department of Clinical Radiology, Graduate School of Medical Sciences, Kyushu University*

[*4] *Department of Radiology, Medical Technology, Kyushu University Hospital*

[*5] *Department of Radiation Oncology, Faculty of Medicine, Hacettepe University*

要旨：肺癌に対する体幹部定位放射線治療（SBRT）後に，放射線肺炎（RP）が発症する場合がある．多くの患者では無症状 Grade 1 の RP（RP−）が発症し，一部の患者では有症状 Grade 2 以上の RP（RP+）が発症する．本研究の目的は，SBRT の治療計画コンピュータ断層撮影（CT）画像を用いて RP+の予測モデルを開発することである．本研究では 272 症例［RP+30 症例，RP−（グレード 1 以下）242 症例］の SBRT を受けた早期非小細胞肺癌症例を用いた．治療計画 CT 画像に対する Betti 数（BN）に基づく位相幾何学的解析により，BN マップを得た．肉眼的腫瘍体積を除いた肺野を ROI とし，BN マップ特徴量（BF）を計算した．特徴量選択を行い，RP+予測モデルを構築した．比較のため，ウェーブレット分解画像特徴量（WF）によるモデルも構築した．モデルの性能評価は ROC 解析における AUC(area under the receiver operating characteristic curve)，正確度，感度，特異度を用いて行った．BF モデルは従来(WF)モデルよりも高い test AUC (0.703 vs 0.568) を示した．本研究は BN マップ特徴量が従来特徴量より高い RP＋予測能がある可能性を示した．

キーワード：レディオミクス，放射線肺炎，体幹部定位放射線治療，非小細胞肺癌，治療計画 CT 画像

１．はじめに

体幹部定位放射線治療（SBRT）は外科手術と比較して非侵襲的であり，治療期間が短いことにより患者にかかる身体的，精神的負担が少ないという特徴がある．先行研究では早期非小細胞肺癌（NSCLC）の治療において SBRT と肺葉切除術は同等の全生存期間，無増悪生存期間を示すと報告されている[1]．しかし，SBRT では放射線によって正常組織が傷害されることにより様々な障害が発生することがある．SBRT において発生する最も一般的な放射線障害は放射線肺炎（RP）である．早期の非小細胞肺癌に対する SBRT においては 9% - 28%の患者が有症状（グレード 2 以上）の放射線肺炎を発症すると報告されている[2]．RP+の正確な予測によって，医師が患者ごとに SBRT の最適化や，予後がより良くなる別の治療法の適用を検討できる可能性がある．

２．対象と方法

２．１．対象

本研究では早期 NSCLC に対して SBRT を行った患者 272 名が後ろ向きに登録された．270 名の治療計画 CT 画像は，九州大学病院において，2003 年 8 月から 2018 年 3 月に得られた．2 名の治療計画 CT 画像はハジェテペ大学病院（トルコ）において 2021 年 2 月と同年 6 月に得られた. RP グレードは Common Terminology Criteria for Adverse Events version 4.0（CTCAE v.4.0）を用いて評価された．

２．２．方法

２．２．１．画像の前処理と特徴量抽出

治療計画 CT 画像は異なる 3 つのウィンドウ幅（−1000-1500

HU，－150-250 HU，－1350-150 HU）を用いて，8 bits（0～255）画像に変換された．関心領域（ROI）は治療計画 CT 画像の肺野から gross tumor volume（GTV）を除いた領域の内，線量が 5 Gy より大きい領域（> 5 Gy）を用いた．

本研究では，肺野の不均一なテクスチャーやキャビテーションを強調するために，位相幾何学的解析を行った．位相幾何学における Betti 数（BN）は，連続変形下の物体の性質を示す位相不変量である．3 次元画像における BN は，連結成分数（b0），穴の数（b1），空洞の数（b2）の 3 つが定義される．これら 3 種類の BN を，元画像に対する閾値処理によって得られた 256 種類の二値画像に対してキュービックカーネルを用いて計算，マッピングすることで BN マップが得られた．BN マップ計算において，キュービックカーネルの一辺の長さ（px）（KS），カーネルが移動する幅（px）（SP）の 2 種類のパラメーターを用いた．KS は 7，9，11，SP は 3，4，5 が検証された．比較のために，従来手法のウェーブレット分解（WD）画像の作成も行われた．3 軸方向にローパスフィルター，ハイパスフィルターをそれぞれ適用することで 8 種類の WD 画像を求めた．

1 つの 3 次元画像当たり 93 個の特徴量（ヒストグラム特徴量 18 個，テクスチャー特徴量 75 個）を計算した．その結果，BF は 71,424 個，WF は 744 個の特徴量を求めた．

２．２．２．特徴量選択

モデルの構築に用いる特徴量を LASSO (least absolute shrinkage and selection operator) を用いて選択した．LASSO における係数の絶対値が大きい特徴量から順に選択し、モデルの構築に用いた．また，選択された特徴量において，ある２つの特徴量のピアソンの相関係数の絶対値が 0.8 を超えるとき，LASSO における係数の絶対値が小さい方の特徴量を削減した．モデル構築において上位５つの特徴量をシグネチャーの候補として検討した．

２．２．３．モデルの構築と評価

272 症例のデータセットを，それぞれ 252 症例のトレーニングデータセット［RP+20 症例，RP−（グレード 1 以下）232 症例］，20 症例のテストデータセット［RP+10 症例，RP−（グレード 1 以下）10 症例］に分割した．RP+と RP−の症例数の違いの均衡をとるために，トレーニングデータセットを 11 個のサブセット（RP+症例は同じもので，RP−症例は無作為に抽出）に分割した．それぞれのサブセットにおいて特徴量選択およびベースモデルの構築が行われた．ベースモデルの構築はサポートベクターマシン（SVM），ランダムフォレスト（RF），勾配ブースティング決定木（GBDT）の３種類のモデルで行われた．画像処理におけるパラメーター，シグネチャー，およびベースモデルのハイパーパラメーターの最適化は robustness index（RI）に基づいて行われた．RI は以下の式で定義される．

$$RI = \frac{AUC_{va}}{1+|AUC_{tr}-AUC_{va}|},$$

ここでAUC_{tr}，AUC_{va}は Training AUC と Validation AUC である．それぞれのサブセットにおいて，ベースモデルは一つ抜き交差検証によって検証された．それぞれのサブセットで構築された最適なベースモデルが出力した予測値を用いて、ロジスティック回帰（LR）モデルのメタモデルを構築した．

構築されたベースモデル，メタモデルを用いてモデルの性能評価を行った．評価指標としてテストにおける AUC（Test AUC），正確度，感度，特異度を用いた．一連のワークフローは 4 回繰り返され，4 回の評価の平均値を最終的な評価値として用いた．

３．結果

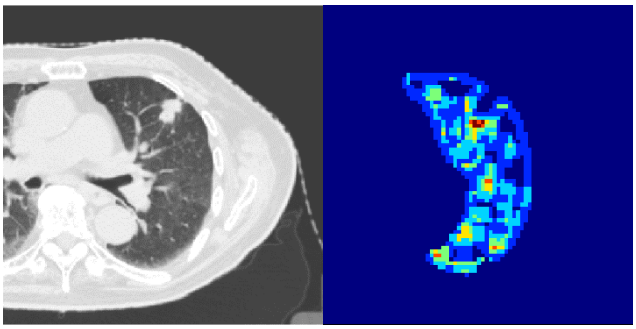


図１．治療計画 CT 画像と BN マップの一例（KS: 11，SP: 3，ウィンドウ幅: −1350 -150 HU，二値化閾値: 150）

図１に BN マップの一例を示す．図に示す BN マップは GTV の重心を通るアキシャル面において計算された b0 マップである．色が青に近いほど連結成分が少なく，赤に近いほど連結成分が多いことを意味する．

WF によるモデルの Test AUC，正確度，感度，特異度はそれぞれ 0.568，0.600，0.675，0.525 であった．BF によるモデルにおいては，それぞれ 0.703，0.750，0.550，0.950 であった．

４．結論

BN マップ特徴量は従来特徴量より高い RP＋予測能がある可能性を示した．

謝辞

本研究は JSPS 科研費 JP24K10840 の助成を受けたものです．

利益相反の有無

なし

文献

[1] Tomita N, Okuda K, Osaga S, et al. Surgery versus stereotactic body radiotherapy for clinical stage I non-small-cell lung cancer: propensity score-matching analysis including the ratio of ground glass nodules. Clin Transl Oncol. 2021; 23: 638–647.

[2]Yamashita H. Radiation pneumonitis after stereotactic radiation therapy for lung cancer. World J Radiol.2014; 6: 708.

体外衝撃波結石破砕術結果予測の性能改善に向けたハイブリッド Mixup の初期検討

望月　嘉恋[*1]，根本　充貴[*1,2]，中前　有香子[*1]，木村　裕一[*3]，
出口　龍良[*4]，山下　真平[*4]，柑本　康夫[*4]，原　勲[*4]
[*1] 近畿大学大学院生物理工学研究科
[*2] 近畿大学生物理工学部
[*3] 近畿大学情報学部・情報学研究科
[*4] 和歌山県立医科大学泌尿器科

Preliminary study of hybrid mixup to improve performance of extracorporeal shock wave lithotripsy outcome prediction

Karen MOCHIZUKI[*1]，Mitsutaka NEMOTO[*1,2]，Yukako NAKAMAE[*1]，Yuichi KIMURA[*3]，
Ryusuke DEGUCHI[*4]，Shinpei YAMASHITA[*4]，Yasuo KOUJIMOTO[*4]，Isao HARA[*4]
[*1] *Kindai University Graduate School of Biology-Oriented Science and Technology*
[*2] *Kindai University Faculty of Biology-Oriented Science and Technology*
[*3] *Kindai University Faculty of Informatics / Graduate School of Informatics*
[*4] *Department of Urology Wakayama Medical University*

要旨：本研究では，体外衝撃波結石破砕術（ESWL）の治療結果予測システムの性能改善に向けた学習データの人工的加増法について実験的に検討する．本研究で用いる ESWL 治療結果予測 AI システムは，術前治療計画用 CT 像から計測される結石テクスチャ特徴と結石体積に加え，年齢等の患者メタデータ特徴から得られる計 15 特徴量を入力とした全結合層 5 層からなるニューラルネットワークを基盤とする．実験では単純な Manifold Mixup に加え，入力特徴量空間での識別境界付近データを用いた Mixup の 1 種である Borderline-SMOTE，Manifold Mixup と Borderline-SMOTE を組み合わせた手法など多様な加増法で得た人工データを用いてネットワークを学習し，それぞれの性能改善への効果について網羅的に検証する．術前 CT の撮像後 ESWL を行った単発尿管結石を有する 171 例を用いた 5-fold 交差検証の結果，Manifold Mixup と Borderline-SMOTE の組み合わせ法適用時が最も性能が良く，加増なしの場合と比べ平均 0.12，最大 0.25 の ROC 下面積の向上を確認した．
キーワード：ESWL，CNN，Mixup

1. 背景・目的

尿管結石は高罹患率の泌尿器疾患の一つである．近年，尿路結石に対する経皮的結石破砕術（PNL: percutaneous nephro-uretero lithotripsy），経尿道的結石破砕術（TUL: trans-urethral lithotripsy）といった内視鏡手術の進歩が目覚ましいが，低侵襲かつ患者を選択すれば高い治療効果が得られることから体外衝撃波結石破砕術（ESWL: extracorporeal shock wave lithotripsy）も重要な治療選択肢の 1 つである．しかし，ESWL の治療成功率は約 50~80%と低い[1]．ESWL の失敗は結石治療の遅れに繋がり，尿路感染症や腎機能障害のリスクが高まることから，AI による ESWL 治療結果予測などの研究がなされている．

機械学習による高性能 AI システムの開発には良質な学習データが大量に必要とされる[2]．しかし，データの仕様等の統一や，正確な教師データの作成のコストなどから，医療データの収集・整備は非常に困難である．そこで，学習データの人工的加増法である Mixup に着目した．中でも Manifold Mixup と Borderline-SMOTE を組み合せたハイブリッド Mixup 手法（Manifold-Borderline-SMOTE）による加増データの学習効果を実験的に検証する．

2. 手法

本研究で用いる ESWL 治療結果予測 AI システムは，術前治療計画用 CT 画像，結石体積，患者メタデータから得られる計 15 種類の特徴量データ[3]を全結合層 5 層（ユニット数は 1 層目から順に 15，10，6，6，1）からなるニューラルネットワークで解析し，予測治療結果を出力する．

ニューラルネットワークの学習には，収集データおよび収集データに Mixup を適用して得た人工的な加増データを用いる．Mixup とは，二つの実データから重み付き平均を算出し，それを新たな人工データとする手法である．この手法を入力特徴量に行うものを Input Mixup，ネットワークの中間層で得られる中間特徴量に行うものを Manifold Mixup と呼ぶ[4]．また，同じく重み付き平均を取る加増法として，特徴量空間上のクラス間境界付近に位置する少数クラスのみ加増を行い，クラスインバランスを解消する Borderline-SMOTE がある[5]．本実験では，

①：収集データのみの学習，②：Manifold Mixup データ利用学習，③：Borderline-SMOTE データ利用学習，④：②と③組み合わせ（中間特徴量での Borderline-SMOTE＝Manifold-Borderline-SMOTE）適用学習の 4 種の AI システムの性能比較を行う．

本実験では，ESWL 治療を適用した単発尿管結石症例 171 例のデータを用いる．うち，術後 3 か月以内の CT 検査で 4mm 以上の結石がなかった除石成功例は 97 例，失敗は 74 例である．性能評価には ROC 曲線とその下面積（AUC）を用いる．検証方法には 5-fold 交差検証を用いる．そのため，全データ中 137 例を学習用，34 例を検証用とする．

Mixup 適用に関して，②Manifold Mixup で生成する人工データ数は 500（データ加増で用いる重み λ は $\alpha = 5.0$ の γ 分布に従う），③Borderline-SMOTE および④Manifold-Borderline-SMOTE での生成データ数は数の少ない失敗クラスが成功クラスと同数になるようにする．また，②Manifold Mixup および④Manifold-Borderline-SMOTE を適用する中間特徴量は，ネットワーク 3 層目出力（6 次元）とする．

3. 結果

5-fold 交差検証による ROC 曲線を図 1 に示す．①収集データのみの学習で平均 AUC＝0.61，②Manifold Mixup データ利用学習で平均 AUC＝0.70，③Borderline-SMOTE データ利用学習で平均 AUC＝0.71，④Manifold-Borederline-SMOTE 適用学習で平均 AUC＝0.73 であった．①収集データのみの学習と④Manifold-Borderline-SMOTE 適用学習の fold ごとの AUC を比べると，最大 0.25 の向上を見た．ネットワーク出力値に対する Wilcoxon 符号順位検定を実施したところ，①収集データのみの学習と④Manifold-Borderline-SMOTE 適用学習の間には統計的な有意差があった（$p < 0.05$）．

また，FPR=0.27 の時の各学習法の感度を表 1 に示す．表 1 より，④Manifold-Borderline-SMOTE 適用学習での感度が最も高いことが分かった．

4. 考察・まとめ

様々な Mixup で得られる人工データの ESWL 治療結果予測 AI システム学習への効果を実験的に検証することで，Mixup の有用性を確認した．また複数の Mixup 手法の組合せ（今回は Manifold-Borderline-SMOTE）でより良い性能を実現可能であることを示唆した．今回は Manifold Mixup と Borderline-SMOTE の組合せのみ検討したが，他の組合せも可能なため，別の組合せについての検討が今後の課題である．

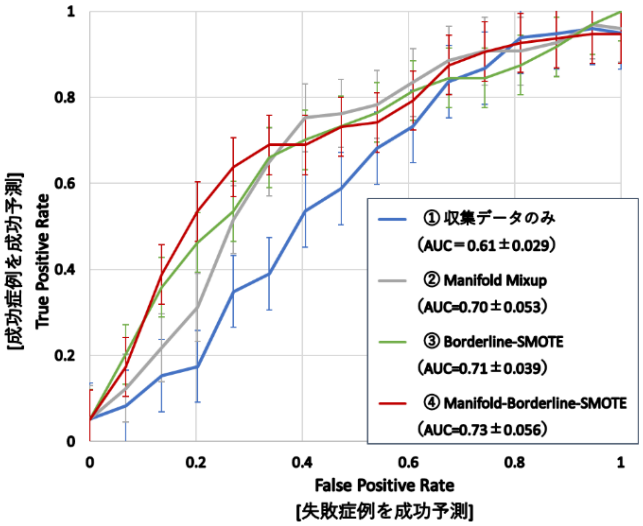


図 1　学習済モデル ROC 曲線

表 1　学習済モデル感度（FPR=0.27 のとき）

データ加増法	平均	標準偏差
①なし（収集データのみ）	0.51	0.048
②Manifold Mixup	0.61	0.077
③Borderline-SMOTE	0.62	0.048
④Manifold-Borderline-SMOTE	0.68	0.032

謝辞

研究遂行にあたり貴重な臨床データを提供いただいた和歌山県立医科大学泌尿器科学講座に御礼申し上げます．また貴重なご助言を賜った永岡隆 近畿大学准教授，篠原寿広 近畿大学准教授，三上勝大 近畿大学講師に深謝いたします．本研究は JSPS 科研費 JP20K11944 の助成を受けたものです．

利益相反の有無

なし

文　献

［1］松田健二，池田英夫，栗栖弘明，他：ESWL 単独療法の適応と治療回数の検討．Japanese Journal of Endourology and Robotics 36.1: 107-112, 2023

［2］Hofmanninger J, Prayer F, Pan J, et al: Automatic lung segmentation in routine imaging is primarily a data diversity problem, not a methodology problem. European Radiology Experimental 4: 1-13, 2020

［3］Nakamae Y, Deguchi R, Nemoto M, et al: AI prediction of extracorporeal shock wave lithotripsy outcomes for ureteral stones by machine learning-based analysis with a variety of stone and patient characteristics. Urolithiasis 52.1: 9, 2023

［4］Verma V, Lamb A, Beckham C, et al: Manifold mixup: Better representations by interpolating hidden states. International conference on machine learning. PMLR, 2019

［5］Han H, Wang WY, and Mao BH: Borderline-SMOTE: a new over-sampling method in imbalanced data sets learning. International conference on intelligent computing. Berlin, Heidelberg: Springer Berlin Heidelberg, 2005.

ESWL アウトカム予測における CT・X 線画像からの特徴量抽出法の検討

小林　壯哉[*1]，藤田　大輔[*1]，澁谷　浩伸[*2]，郷原　真輔[*2]，小橋　昌司[*1]
[*1] 兵庫県立大学大学院工学研究科
[*2] 石川病院

Analysis of Features from CT and X-Ray Images for ESWL Outcome Prediction

Soya KOBAYASHI[*1]，Daisuke FUJITA[*1]，Hironobu SHIBUTANI[*2]，Shinsuke GOHARA[*2]，
Syoji KOBASHI[*1]
[*1] *Graduate School of Engineering, University of Hyogo*
[*2] *Ishikawa Hospital*

要旨：尿管結石に対する治療方法の 1 つである体外衝撃波結石破砕術(ESWL：Extracorporeal Shock Wave Lithotripsy)は，侵襲性は低いが成功確率が 7 割程度と低い．そのため，治療が失敗すると患者の身体的・金銭的負担の増大につながり，治療前に成功可否を予測することが求められている．本研究では，初期治療として ESWL を選択した 139 名の患者の X 線・CT 画像から特徴量を抽出し，ESWL の成否をアウトカムとした分析を行う．各 CT・X 線画像からそれぞれラジオミクスにより特徴量抽出を行う．ラジオミクス特徴量として texture 特徴量，CT 画像からは shape 特徴量も抽出する．抽出した特徴量と臨床所見について，ROC 解析によってアウトカム予測能を評価した．また，相関および多変量解析の係数によって特徴量の独立した予測能を評価した．
キーワード：尿管結石，ESWL，機械学習，ラジオミクス

1. はじめに

尿管結石は，腎臓から膀胱へ尿を運ぶ尿管内に存在する結石である[1]．尿管結石に対する治療法である体外衝撃波結石破砕術(ESWL: Extracorporeal Shock Wave Lithotripsy)は，侵襲性が低い治療方法であるが，成功確率が 7 割程度と低く，治療失敗による追加治療のリスクが考えられる．

そのため，臨床現場において適切な治療法を選択することは重要であり，その支援のために ESWL の治療結果を事前に予測する技術が求められている．文献[2]では，結石の体積，位置，長さ，CT 値など 15 の特徴量を用いた決定木分析により，Accuracy が 0.951，AUC が 0.923 の予測精度を達成している．

しかし，先行研究[2]のような予測モデルはブラックボックスになりがちであり，また予測に寄与しない特徴量は，精度と解釈性を低下させる原因となり得る．そのため，予測モデルの特徴量それぞれの予測能力を評価することは重要である．

本研究では，CT・X 線画像から抽出した特徴量と臨床所見について，ROC 解析によって各特徴量のアウトカム予測能を評価する．また，相関および多変量解析によって特徴量の独立した予測能についても評価する．

2. データ

本研究では，医療法人仁寿会石川病院泌尿器科に来院した尿路結石症患者で ESWL が適用された被験者 139 症例を対象とし，各被験者の CT 画像，X 線画像及び臨床所見を使用する．本研究のデータ使用にあたり、医療法人仁寿会石川病院倫理委員会にて事前に承認を受けた(承認番号：仁倫 2021-4)．臨床所見には年齢，右尿管結石か左尿管結石か，性別，結石の位置(U1/U2/U3)，治療回数，照射時間，照射強度，結石の長径，CT 値の 9 個の特徴量と，ESWL の成功・失敗(アウトカム)が含まれている．ESWL のアウトカムについては，1 回目の ESWL 治療後の残石 4mm 以下を成功とする．

3. 提案法

提案法は，CT・X 線画像から抽出した特徴量と臨床所見を特徴量とし，各特徴量について予測能の評価を行う．

3.1 CT・X 線画像からの特徴量抽出

X 線画像の照準内 75×75pixel を関心領域(ROI)として切り出し，ROI から 18 種類のラジオミクス特徴量(texture 特徴量)18 種類を抽出する．

CT 画像は結石の中心から上下左右 16pixel ずつ計 33×33pixel を切り出し，X 線画像と同様に texture 特徴量 18 種類を抽出する．また，切り出した画像から 2 値化処理によってマスク画像を生成し，マスク画像を用いて shape 特徴量 10 種類を抽出する．解析には Python3.6.13 を用い，ライブラリとして numpy1.19.2，radiomics0.1，SimpleITK2.1.1 を用いた．

3.2 ROC 解析による各特徴量の予測能評価

3.1 で抽出した特徴量と臨床所見を本手法における特徴量と

*1 兵庫県立大学大学院工学研究科電子情報工学専攻
〔〒671-2280 兵庫県姫路市書写 2167 姫路工学キャンパス
e-mail：souyakobayashi@gmail.com

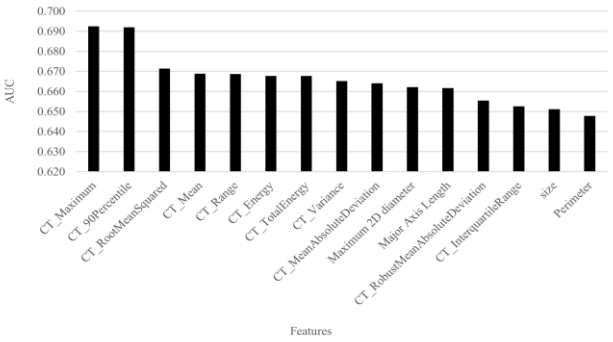


図 1. 各特徴量のアウトカムに対する AUC

し，各特徴量とアウトカムに対し ROC 解析を行い，各特徴量の独立した予測能を評価する．

また，予測に寄与する特徴量を選択するために，P 値と相関係数を算出する．ここで，特徴量は連続値とカテゴリカルデータが混在しており，アウトカムは 2 値のデータである．P 値については，連続値の特徴量に対してはマンホイットニーの U 検定，カテゴリカルな特徴量に対してはカイ二乗検定を用いて算出する．相関係数については，連続値の特徴量に対してはスピアマンの順位相関係数，カテゴリカルな特徴量に対してはクラメールの V を用いて算出する．

3.3 Logistic Lasso 回帰による特徴量選択

3.2 で算出した P 値と相関係数から，P 値が 0.05 以下且つ相関係数 0.2 以上の特徴量を有効特徴量として選択する．選択された有効特徴量に対して，Logistic Lasso 回帰による正則化を行い，さらに特徴量選択を行う．

4. 実験結果

4.1 ROC 解析による各特徴量の予測能評価結果

CT・X 線画像から抽出した特徴量と臨床所見の計 59 種類の特徴量とアウトカムデータのそれぞれについて，ROC 解析により AUC を算出した． AUC 算出結果の一部を図 1 に示す．図 1 より，AUC は高いものでも 0.7 程度であり，これらの特徴量単独でのアウトカム予測は難しいと考えられる．

4.2 抽出した特徴量に対する特徴量選択結果

各特徴量とアウトカムデータに対して，3.2 の手法により P 値と相関係数を算出した．そして，P 値が 0.05 以下且つ相関係数 0.2 以上の特徴量を選択した結果，23 個の特徴量が選択された．

次に，得られた 23 個の特徴量に対して，Logistic Lasso による正則化を行い，モデルの解釈性を考慮して，
最終的に特徴量数が 10 個になるように正則化パラメータを調整した．最終的に得られた 10 種類の特徴量を表 1 に示す．表 1 の成功列は，＋であれば条件列を満たす場合に治療が成功しやすいことを示している．

表 1. 選択された特徴量とアウトカムの関係

特徴量	条件	成功
Female	女性	＋
U1	結石位置が U1（上部尿管）	－
Minimum(CT)	CT 値の最低値が大きい	－
Pixel Surface	結石領域の表面積が大きい	＋
Mesh Surface	結石領域のポリゴンメッシュ表面積が大きい	＋
Major Axis Length	結石領域の長径が長い	－
Variance(CT)	CT 値の分散が大きい	－
Energy(CT)	CT 値の集中度が高い	－
Total Energy(CT)	Energy 値をボクセル体積で標準化した値が大きい	－
10 Percentile	最小値から数えて 10%の画素値が大きい	－

以上より，各特徴量の予測能を評価することによって，予測に寄与する 10 個の特徴量を選択することができた．選択された特徴量の内訳は，臨床所見が 3 種類，CT 画像の shape 特徴量が 3 種類，CT 画像の texture 特徴量が 4 種類であった．これらの特徴量を用いたアウトカム予測モデルは，Accuracy が 0.829 を示した．

5. まとめ

本研究では，ESWL アウトカム予測に用いる特徴量について，アウトカム予測能を評価した．各特徴量に対して，P 値と相関係数を算出し予測能を評価することで，特徴量選択を行い，選択された特徴量に対して Logistic Lasso 回帰による正則化を行うことで，多数の特徴量の中から，各々が独立して予測能を持った 10 個の特徴量を選択することができ，Accuracy が 0.829 の予測精度を示した．

利益相反の有無

なし

文　献

［1］A. P. Evan, "Physiopathology and etiology of stone formation in the kidney and the Urinary tract", Pediatric Nephrology, Vol. 25, No. 5, pp. 831-841, 2010.

［2］M. S. Choo, S. Uhmn, J. K. Kim, J. H. Han, D-H. Kim, J. Kim, and S. H. Lee, "A prediction model using machine learning algorithm for assessing stone-free status after single session shock wave lithotripsy to treat ureteral stones", Journal of Urology, Vol. 200, No. 6, pp. 1371-1377, 2018.

細胞核を起点とした病理顕微鏡画像の表現学習

田口　慶[*1]，横田　達也[*1]，大島　孝一[*2]，三好　寛明[*2]，　永石　美晴[*2]，
橋本　典明[*3]，　竹内　一郎[*3]，　本谷　秀堅[*1]
[*1] 名古屋工業大学
[*2] 久留米大学
[*3] 名古屋大学

Nuclei centric representation learning for digital pathology

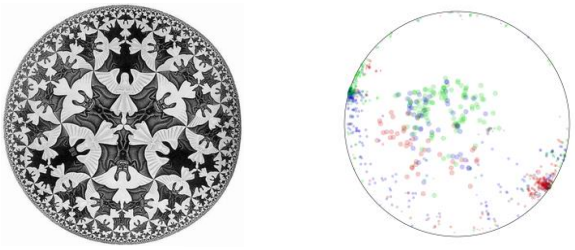
Kei TAGUCHI[*1]，Tatsuya YOKOTA[*1]，Kouichi OHSHIMA[*2]，Hiroaki MIYOSHI[*2]，Miharu NAGAISHI[*2]，Noriaki HASHIMOTO[*3]，Ichiro TAKEUCHI[*3]，Hidekata HONTANI[*1]
[*1] *Nagoya Institute of Technology*
[*2] *Kurume University*
[*3] *Nagoya University*

要旨：悪性リンパ腫の細胞組織を，個々の細胞核から多数の細胞が構成する組織に至る広範なスケールにまたがり，同一の潜在空間に表現する手法を提案する．リンパ節は多種多様な細胞により構成されており，がん化に伴い個々の細胞核の形態が病型に応じて変化するだけではなく，組織の構造も変化する．これら各スケールにおける細胞組織の構造変化は，互いに強い相関を持っている．本研究では，細胞核から組織像までスケールの異なる画像を単一の双曲面上で表現する．双曲面は辺縁に近づくほど多量のデータを埋め込むことが可能であり，スケールの異なる画像間の包含関係の表現に適している．双曲面上の表現獲得に対照学習を適用することで，個々の細胞核の表現の異同の表現と細胞群の組織の異同の表現を相互に影響を与えつつ学習する．これにより，がん化に伴う形態変化を細胞核と細胞組織の双方で同時に表現する．本稿では，その学習手法と表現空間について報告する．
キーワード：Hyperbolic Space, Contrastive Learning, Representation Learning, Digital Computational Pathology

1. はじめに

悪性リンパ腫[1]は，血液の癌であり白血球のうちリンパ球ががん化する病である．悪性リンパ腫には 100 種類以上のサブタイプがあり，診断，病型確定のために生検が行われる．病型を確定させるプロセスにおいて，初めに H&E 染色による組織形態の観察が行われる．本研究では，この H&E 染色によって染色された組織片を光学顕微鏡で撮影した画像を取り扱う．

本研究では，悪性リンパ腫の細胞組織を，個々の細胞核から多数の細胞が構成する組織に至る広範なスケールにまたがり，同一の潜在空間に表現する手法を提案する．リンパ節は多種多様な細胞により構成されており，がん化に伴い，個々の細胞核の形態が病型に応じて変化するだけではなく，多数の細胞が構成する組織の構造も変化する．これら各スケールにおける細胞組織の構造変化は，互いに強い相関を持っている．病理顕微鏡画像を処理する従来法には，個々の細胞核レベルの画像と複数の細胞が構成する組織像の双方を処理する手法が多数存在するが，それら手法の多くはスケールの異なる画像を異なる潜在空間で表現する．本研究では，細胞核から組織像まで互いにスケールの異なる画像を単一の双曲面上で表現する．双曲面は辺縁に近づくほど多量のデータを埋め込むことが可能（図 1（a））であり，スケールの異なる画像間の包含関係の表現に適している．双曲面上の表現獲得に対照学習[2, 3]を適用することにより，個々の細胞核の表現の異同の表現と細胞群の組織の異同の表現を相互に影響を与えつつ学習する．細胞核・組織間で相互に監視することで，組織表現は組織の画像間のみの表現学習では失われてしまう重要であるミクロな特徴を損なうことなく学習が可能になることが期待できる．また，細胞核表現は細胞核の画像間のみの表現学習では獲得することができないマクロな情報を参照して表現が学習されることが期待できる．本稿



(a)　(b)

図 1：
(a) エッシャーの絵「Circle Limit Ⅳ」：この作品は，双曲面上の計量を表している
(b) 提案法により獲得した病理画像の分布：円の大きさが視野の大きさ（大きいほど視野が狭い）を表し，色が病態の違いを表す．

では，双曲対照学習の学習手法と表現空間について報告する．

2. 提案法

双曲対照学習[3]におけるオブジェクトを細胞核，シーンを組織と読みかえることで病理顕微鏡画像にこれに適用する．

本研究では，双曲空間のうち，ポワンカレ球を用いる．ポワンカレ球は$\mathbb{D}^n := \{p \in \mathbb{R}^n \mid \|p\|^2 < r^2\}$で定義される．ここで$r > 0$は球の半径であり，$c = \frac{1}{r^2}$とおくことにする．このとき，ポワンカレ球上の点$p \in \mathbb{D}^n$，ユークリッド距離を$g_{\mathbb{E}}$とするとリーマン計量は$g_{\mathbb{D}}(p) = \frac{4}{(1-c\|p\|^2)^2} g_{\mathbb{E}}$と書くことができる．よって$p, q \in \mathbb{D}^n$のポワンカレ球上でのリーマン距離は以下のように求められる．

$$d(p,q) = \frac{2}{\sqrt{c}} \operatorname{arctanh}\left(\sqrt{c}\|(-p) \oplus_c q\|\right) \quad (1)$$

$\oplus_c$はメビウス和を表しており，以下のように求められる．

$$x \oplus_c y = \frac{(1 + 2c\langle x,y\rangle + c\|y\|^2)x + (1 - c\|x\|^2)y}{1 + 2c\langle x,y\rangle + c^2\|x\|^2\|y\|^2} \quad (2)$$

また，ポワンカレ球の原点oの接空間中の点$u \in T_o\mathbb{D}^n \approx \mathbb{R}^n$をポワンカレ球に写像する際には，以下で定義される指数写像を用いる．

$$\exp_o^c(u) = \tanh\left(\sqrt{c}\|u\|\right)\frac{u}{\sqrt{c}\|u\|} \quad (3)$$

病理顕微鏡画像をハイパボリック空間を導入した対照学習[3]の枠組みに適用する（図 2）．細胞核表現と組織表現を獲得するために 2 つの損失を最小化する．

まずは，細胞核表現を獲得するために，通常の InfoNCE 損失を用いる．図 2 の上のブランチに示すように細胞核を含む領域を正のペアとして切り出し，背景をぼかし，エンコーダとモメンタムエンコーダに入力し細胞核表現を出力する．ここで正規化後の出力をz^1_{euc}，z^2_{euc}とする．また，MoCo[2]と同様にメモリバンクに負例z^n_{euc}を格納する．

このとき損失を以下のように定義する．

$$L_{euc} = -\log \frac{\exp\left(\frac{z^1_{euc} \cdot z^2_{euc}}{\tau}\right)}{\exp\left(\frac{z^1_{euc} \cdot z^2_{euc}}{\tau}\right) + \sum_n \exp\left(\frac{z^1_{euc} \cdot z^n_{euc}}{\tau}\right)} \quad (4)$$

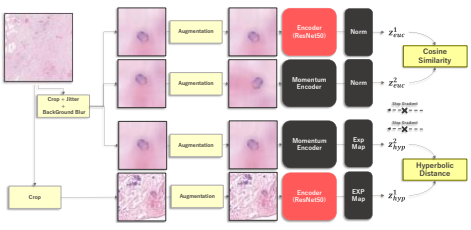


図 2：双曲対照学習のフレームワーク

ここで，τは温度パラメータである．

つぎに，図 2 の下のブランチに示すように組織表現を獲得するために，細胞核画像とそれを含む組織の画像のペアをエンコーダとモメンタムエンコーダに入力する．エンコーダの出力を正規化する代わりに式 2 で定義される指数写像を行う．指数写像後の出力をz^1_{hyp}，z^2_{hyp}とする．式 4 のexpの中の内積を式 1 で定義されるハイパボリック距離を負にしたもので置き換えて，損失を以下のように定義する．

$$L_{euc} = -\log \frac{\exp\left(\frac{-d(z^1_{hyp},\ z^2_{hyp})}{\tau}\right)}{\exp\left(\frac{-d(z^1_{hyp},\ z^2_{hyp})}{\tau}\right) + \sum_n \exp\exp\left(\frac{-d(z^1_{hyp},\ z^n_{hyp})}{\tau}\right)} \quad (5)$$

よって，学習全体の損失は以下の通りである．

$$L = L_{euc} + \lambda L_{hyp} \quad (6)$$

ここでλは 2 つの損失を重みづけるハイパーパラメータである．

3. 表現空間の可視化

双曲対照学習によって獲得した表現空間を[4]を用いて可視化したものを図 1(b)に示す．B 細胞型リンパ腫のうち進行度順に，Reactive（青），FL（緑），DLBCL（赤）という病型の画像を用いた．円の大きさはスケールを表しており，円が小さくなるほどスケールは大きい．中心には細胞核の表現，辺縁には組織の表現が分布していることが観察できる．辺縁では，各病型ごとにクラスタが形成されている．この組織の表現によって細胞核の共存のしやすさが，表現空間に反映されていることが期待できる．

4. まとめ

本稿では[3]で提案された双曲対照学習を病理顕微鏡画像に適用して，細胞核と組織の関係を獲得できるか試みた．今後は下流タスクへ適用し，本手法の実用性について検討していく．

利益相反の有無

なし

文　献

［1］悪性リンパ腫：[国立がん研究センター　がん情報サービス　一般の方へ] (ganjoho.jp)

［2］HE, Kaiming, et al. Momentum contrast for unsupervised visual representation learning. In: *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. 2020. p. 9729-9738.

［3］GE, Songwei, et al. Hyperbolic contrastive learning for visual representations beyond objects. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2023. p. 6840-6849

［4］GUO, Yunhui; GUO, Haoran; YU, Stella X. Co-sne: Dimensionality reduction and visualization for hyperbolic data. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2022. p. 21-30

基盤モデルを用いた皮膚疾患画像からの皮膚領域の認識

佐藤　優斗[*1]，藤澤　康弘[*2]，藤本　学[*3]，坂井　浩志[*3]，志藤　光介[*4]，山崎　研志[*4]，
清水　昭伸[*1]

[*1] 東京農工大学大学院工学研究院
[*2] 愛媛大学大学院医学系研究科皮膚科学
[*3] 大阪大学大学院医学系研究科皮膚科学
[*4] 東北大学大学院医学系研究科皮膚科学分野

Segmentation of skin areas from skin disease images using a foundation model

Yuto SATO[*1]，Yasuhiro FUJISAWA[*2]，Manabu FUJIMOTO[*3]，Hiroshi SAKAI[*3]，Kosuke SHIDO[*4]，Kenshi YAMAZAKI[*4]，Akinobu SHIMIZU[*1]

[*1] *Institute of Engineering, Tokyo University of Agriculture and Technology*
[*2] *Department of Dermatology, Ehime University Graduate School of Medicine*
[*3] *Department of Dermatology, Osaka University Graduate School of Medicine*
[*4] *Department of Dermatology, Tohoku University Graduate School of Medicine*

要旨：本報告では，基盤モデルを用いた皮膚疾患画像からの皮膚領域の認識について述べる．著者らはこれまで，光学カメラで撮影した，倍率，撮影角度，照明条件，背景の異なる多様な臨床写真を入力として，162 クラスの皮膚疾患を分類するシステムを構築した．しかし，一部の画像では，皮膚以外の場所に注目をして誤診断している例が見られた．そこで本研究では分類システムを皮膚領域に注目させるために，画像から皮膚領域を認識する処理を開発した．今回は，認識処理のための深層モデルとして基盤モデルの一つである Segment Anything Model を用いた．本研究では，各疾患クラスからサンプリングした 5 枚の画像に対して皮膚領域のアノテーションを作成し，計 810 枚の教師データを用いて Segment Anything Model の fine-tuning を行った．学習後のモデルの性能を未知のテスト画像を用いて評価した結果について報告する．

キーワード：皮膚疾患，臨床写真，皮膚領域，基盤モデル，セグメンテーション

1. はじめに

皮膚は人体最大の臓器であり，保護作用，分泌作用，体温調整作用などの重要な機能を持つ[1]．皮膚疾患の種類は 2,000 を超えており[2]，多様な外観を示す．同じ疾患でも進行度により患部の大きさ，形，色が大きく変化し，また異なる疾患であっても外観が類似している場合もある．これらの多様な疾患の正確な分類は専門医であっても容易ではない[3]．そこで，コンピュータ支援診断が求められている．

皮膚疾患分類の研究は多く行われており，近年では深層畳み込みニューラルネットワークを用いた手法が成果を上げている[4]．Fujisawa ら[5]は，皮膚腫瘍と診断された 1,842 人の患者から得た 4,867 枚の臨床写真を用いて GoogLeNet を学習し，皮膚科医と比較して優れた性能を示すことを明らかにした．また，Tanaka ら[6]は ResNet-18 を用いた分類をロバストにするために距離学習を導入し，臨床写真のクラス分類に有効であることを示した．その一方で，一部の臨床写真では，皮膚以外の場所に注目をして誤分類している例が見られた．

本研究では，分類システムを皮膚領域に注目させるために，画像から皮膚領域を認識する処理を開発する．本稿では，基盤モデルの一つである Segment Anything Model (SAM)[7]を fine-tuning することで皮膚領域の認識処理を開発し，性能を評価したので，その結果について報告する．

2. SAM による皮膚領域の認識処理

SAM は，イメージエンコーダ，プロンプトエンコーダ，マスクデコーダの 3 つにより構成される．イメージエンコーダには Vision Transformer[8]が用いられており，画像の特徴量の抽出を行う．プロンプトエンコーダではプロンプト（点やバウンディングボックス）の座標のベクトル化[9]を行う．マスクデコーダでは，イメージエンコーダによって得られた特徴量とプロンプトエンコーダによってベクトル化された座標を用いた cross attention によりマスクを生成する．1,100 万枚の画像と 11 億枚のマスクによって学習されたモデルが公開されており，本研究では初期値としてそれを用いる．

本研究における SAM の fine-tuning を図 1 に示す．まず，アノテーションツール[10]を利用して，臨床写真とその皮膚領域の正解マスク画像を作成した．また，プロンプトにはバウンディングボックスを用いたが，学習時には皮膚領域を囲む最小の矩形領域に対して，辺長にノイズを加えた領域を使用し，検証・テスト時には物体検出モデル Grounding DINO[11]により，単語“skin”をテキストプロンプトとして得られるバウンディ

ングボックスを使用した． fine-tuning は，イメージエンコーダとプロンプトエンコーダによる 2 種類の特徴量からマスクデコーダが予測したマスク画像と，正解マスク画像との間で計算される損失（DICE Loss と Cross Entropy Loss の和）を最小化した．このとき，fine-tuning の対象を，i)イメージエンコーダ， ii)マスクデコーダ， iii)イメージエンコーダとマスクデコーダの両方，の 3 通りで実験を行った．

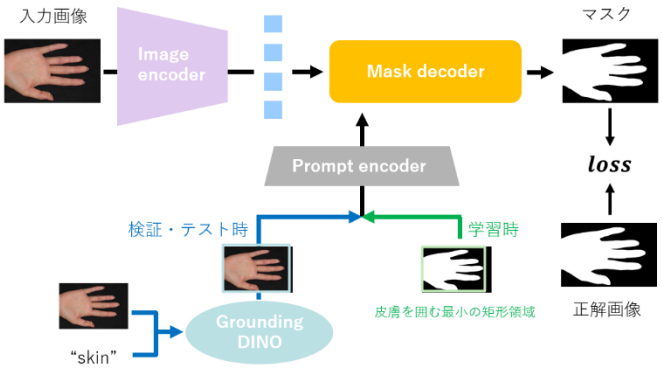


図 1　SAM の学習過程．学習時（緑矢印）には正解マスク画像の皮膚を囲む最小の矩形領域，検証・テスト時（青矢印）には Grounding DINO を用いたバウンディングボックスをプロンプトとして入力．

3. 実験

実験試料には， 日本皮膚科学会の National Skin Disease Database から 162 疾患クラスの画像を使用した．学習と検証に各疾患から 5 症例ずつサンプリングした 810 画像，テストにも各疾患から 5 症例ずつサンプリングされた 810 画像を使用した．5-fold CV により性能を評価し，評価指標には False Positive (pixel)， False Negative (pixel)， DICE score を用いた．

表 1 に学習させたモジュールごとの実験結果を示す．まず，fine-tuning により性能が大きく向上したことが分かる．次に，イメージエンコーダとマスクデコーダの同時学習の場合が，全ての評価指標において最も良い性能であることが確認された．Fine-tuning 後の 3 通りについて，Wilcoxon の符号順位検定（H_0: 2 つのモデルの評価値間に差がない．Bonferroni 補正）を行ったところ，マスクデコーダのみの学習とイメージエンコーダとマスクデコーダの同時学習と間では，全ての評価指標で帰無仮説が棄却された．このことから，イメージエンコーダを含めた同時学習が皮膚領域の認識に重要であることが分かった．

表 1　実験結果．各値は 5-fold の平均値．

** $p \times 5 < 0.01$， * $p \times 5 < 0.05$

学習モジュール	DICE	FN	FP
(事前学習済みモデル[7])	0.862	44,104	16,153
マスクデコーダ	0.968	6,375	8,971
イメージエンコーダ	0.978	3,787	5,764
マスクデコーダ+イメージエンコーダ	0.983	2,651	4,690

しかし，課題も残されている．図 2(a)に示す通り，同時学習の場合に疾患部位の見落としが 1 症例確認された．また，衣類などの拾いすぎ（同図 2(b)）も今後の課題である．

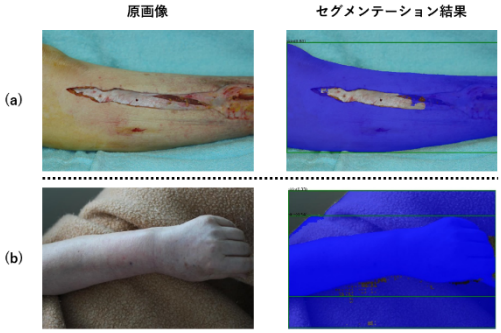


図 2　皮膚領域の認識結果（青色領域）の例

4. まとめ

本研究では，皮膚疾患の臨床写真から皮膚領域を認識する処理の開発に，基盤モデルを用いて取り組んだ．実際の臨床写真を用いた実験からは，皮膚領域の認識性能の向上を確認したが，疾患部位の見落としや衣類などの拾いすぎも確認されている．今後は，これらの課題の解決や，皮膚領域の認識結果を用いた皮膚疾患分類システムの精度向上にも取り組む．

謝辞

本研究では，日本皮膚科学会の National Skin Disease Database を利用しました．データベース構築・維持に関係されている先生方に感謝いたします．

利益相反の有無

なし

文　献

[1] Graham‐Brown R, Burns T. Dermatology (9th ed.). Oxford: Blackwell, 2007

[2] Grifths C, Barker J, Bleiker T, et al: Rook’s textbook of dermatology. Wiley-Blackwell, 2016

[3] Heal C F, Raasch B A, Buettner P G, et al: Accuracy of clinical diagnosis of skin lesions,Br J Dermatol 159(3):661-668, 2008

[4] Hasan K, Ahamad A, Yap C H, et al: A survey, review, and future trends of skin lesion segmentation and classification. Computers in Biology and Medicine, 155, 106624, 2023

[5] Fujisawa Y, Otomo Y, Ogata Y et al: Deeplearning-based, computer-aided classifer developed with a small dataset of clinical images surpasses board-certifed dermatologists in skin tumour diagnosis. Br J Dermatol 180(2):373–381, 2019

[6] Tanaka M, Saito A, Shido K et al: Classification of large-scale image database of various skin diseases using deep learning. Int J CARS 16, 1875–1887, 2021

[7] Kirillov A, Mintun E, Ravi N, et al: Segment Anything, ICCV, 2023

[8] Dosovitskiy A, Beyer L, Kolesnikov A, et al: An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale, ICLR, 2021

[9] Tancik M, Srinivasan P, Mildenhall B, et al: Fourier Features Let Networks Learn High Frequency Functions in Low Dimensional Domains, NeurIPS, 2020

[10] Hao Y, Liu Y, Wu Z, et al: EdgeFlow: Achieving Practical Interactive Segmentation with Edge-Guided Flow, ICCV, 2021

[11] Liu S, Zeng Z, Ren T, et al: Grounding DINO: Marrying DINO with Grounded Pre-Training for Open-Set Object Detection, arXiv preprint arXiv:2303.05499, 2023

数値特徴量による不均衡な医用画像良悪性分類の改善

吉次　研二[*1]，岸本　和昌[*2]，竹村　匡正[*1]
[*1] 兵庫県立大学大学院情報科学研究科
[*2] 京都大学医学部付属病院

Improvement of Imbalanced Medical Image Benign and Malignant Classification by Numerical Features

Kenji YOSHITSUGU[*1]，Kazumasa KISHIMOTO[*2]，Tadamasa TAKEMURA[*1]
[*1] *Graduate School of Information Science. University of Hyogo.*
[*2] *Kyoto University Hospital.*

要旨：深層学習を用いた画像分類が近年，医療に応用されているが，医用画像の多くは良性と悪性のような所見の違いで不均衡なデータ構成になっていることが珍しくない。機械学習による不均衡なデータ構成を持つ画像の分類は，数の多いデータの影響で数の少ない所見の画像の検出が困難な場合が多い。多くの研究はこの問題を深層学習で解決しようとしているが，本研究ではレディオミクス特徴量という数値特徴量に基づく分類に置き換えて，少ないデータを多いデータと同じ数にアップサンプリングすることで，定量的に良悪性の分類を改善できるのではないかと考えた。画像から算出したレディオミクス特徴量を SMOTE，Borderline SMOTE，SVMSMOTE，ADASYN の４つ方法でアップサンプリングしてランダムフォレストアルゴリズムで分類した結果，深層学習による画像分類に比べて高い汎化性と堅牢性が示唆された．
キーワード：画像分類，数値特徴量，レディオミクス，SMOTE，マンモグラフィ

1. はじめに

執深層学習を用いた画像分類が近年, 医療に応用されている．[1,2]

しかし, 診断のために撮影された医用画像の多くは良性所見が多かったり悪性所見が多かったりと, 不均衡なデータ構成になっていることが珍しくない. 機械学習を用いてこのような不均衡なデータ構成を持つ医用画像を分類しようとすると, 数で優る所見のデータの影響で, 数の少ない所見の画像の検出は困難な場合が多い. 多くの研究がこの問題を解決しようとしているが，多くがその提案手法に深層学習を使っている[3-5].

本研究ではデータ構成が不均衡な画像分類をレディオミクス特徴量という数値特徴量に基づく分類に置き換えて, 少ない所見のデータを所見の多いデータと同じ数にアップサンプリングすることで定量的に良悪性の分類を改善できるのではないかと考えた．

データ構成が不均衡な画像分類を数値特徴量による分類とすることで分類結果を改善することができれば, 専門医の読影効率を向上させることで, 昨今社会問題になっている医師の働き方改革の一助になる可能性がある．

2. 材料と方法

本研究では，マンモグラフィの三種類の公開データセット，VinDr（悪性 988，良性 5606）[6]，CMMD（悪性 4174，良性 1416）[7]，INbreast（悪性 100，良性 243）[8]を利用した．

前処理として，画像はいずれも dicom 形式から jpeg 形式に変換した後，CLAHE[9]でコントラストを調整した．

画像から得る数値特徴量としては，レディオミクス特徴量[10]を使用した．本来，レディオミクス特徴量は，放射線画像のアノテーションされた腫瘤から算出するが, 本研究では腫瘤のない画像も対象とするため，乳房全体から算出した．

レディオミクス特徴量は，pyrdiomics（v3.0.1）[11]を使い、ひとつの画像から，信号強度，形状，テクスチャに基づく 104 のレディオミクス特徴量を得た．

良悪性のデータ構成の不均衡を解消するためのオーバーサンプリング手法として SMOTE[12]，Borderline SMOTE[13]，SVMSMOTE[14]，ADASYN[15]を使用した．

オーバーサンプリングしたレディオミクス特徴量の良悪性分類アルゴリズムには，ランダムフォレストを利用した．

良悪性分類結果の比較のために，深層学習モデルとして，EfficientNetV2(CNN)[16]と VisionTransformer(ViT)[17]を使用した．

検証環境には，Windows11（CPU:Intel Corei7-11700KF，メモリ:128GB），GPU（RTX4070）を使用した．

3. 結果と考察

三種類の公開データセットにおいて, 感度と特異度のバランスを考慮した F 値で結果を見ると，アップサンプリングした数値特徴量であるレディオミクス特徴量によるランダムフォレスト分類が，CNN と ViT といった深層学習による分類よりも高い結果が得られた．

本研究にはふたつの新規性があると考える．ひとつは，本来は関心領域（Region of Interest：ROI）である腫瘤から算出する

レディオミクス特徴量を, 腫瘤のない画像からも算出するために，乳房全体を ROI として算出したことである.

この方法は乱暴に見えるが、VinDr データセットにおける ROI の矩形アノテーションをビュー毎に加算合成したもの見ると、マンモグラフィの ROI は特定の場所ではなく乳房全体に広がっていることがわかる．このことから，乳房全体を ROI とすることが乱暴ではないと考える.

ふたつめは，良性と悪性が不均衡なデータセットに対して，画像からレディオミクス特徴量という数値特徴量を算出して，SMOTE 等でオーバーサンプリングすることで不均衡を解消して良悪性分類の結果を改善したことである.

画像をオーバーサンプリングすることは生成することを除けば, 深層学習時のデータ拡張が一般的だがこれは教師データの総数が増えるだけで不均衡を解消できるわけではない.

ただし，SMOTE 等のオーバーサンプリング手法はふたつの数値特徴量から新たにひとつの特徴量を生成するため, もっと多くの数値特徴量から凸結合等で新たに特徴量を生成するという新しい手法も検討課題であると考える.

加えて, 本研究では不均衡解消のために少ない方のデータをオーバーサンプリングすることで多い方と同じにしたが, 少ない方のデータのオーバーサンプリングするだけでなく, 多い方もオーバーサンプリングすることで教師データ全体を増やした場合の検証も課題と考える.

4. 結論

マンモグラフィから算出した数値特徴量であるレディオミクス特徴量をオーバーサンプリングすることで, 良悪性の不均衡を解消して良悪性分類の改善が確認できた. 三種類の公開データセットに対する, 四種類のアップサンプリング手法による検証で，本研究の主張の汎化性と堅牢性が示唆された.

利益相反の有無

なし

文　献

［1］ Litjens, G., Kooi, T., Bejnordi, B., et al., A survey on deep learning in medical image analysis. Medical image analysis, 42, 60-88.(2017)

［2］ Shen, D., Wu, G., & Suk, H., Deep Learning in Medical Image Analysis., Annual review of biomedical engineering, 19, 221-248.(2017)

［3］ Rezaei, M., Yang, H., & Meinel, C. Recurrent generative adversarial network for learning imbalanced medical image semantic segmentation. Multimedia Tools and Applications, 79, 15329 - 15348.(2019)

［4］ Khan, N., Abraham, N., & Guan, L. Machine Learning on Biomedical Images: Interactive Learning, Transfer Learning, Class Imbalance, and Beyond. 2019 IEEE Conference on Multimedia Information Processing and Retrieval (MIPR), 85-90.(2019)

［5］ Banik, D., & Bhattacharjee, D. Mitigating Data Imbalance Issues in Medical Image Analysis. , 66-89.(2021)

［6］ VinDr-Mammo: A large-scale benchmark dataset for computer-aided diagnosis in full-field digital mammography, https://vindr.ai/datasets/mammo

［7］ The Chinese Mammography Database (CMMD), https://wiki.cancerimagingarchive.net/pages/viewpage.action?pageId=70230508

［8］ Moreira, I. C., Amaral, I., Domingues, I., Cardoso, A., Cardoso, M. J., & Cardoso, J. S. (2012). INbreast: toward a full-field digital mammographic database. Academic radiology, 19(2), 236–248.

［9］ K. Zuiderveld: “Contrast limited adaptive histogram equalization”, In:Academic PressGraphics Gems Series: Graphics Gems, Vol.IV, pp.474-485 (1994)

［10］ They are Data Gillies RJ et al., Radiomics: Images Are More than Pictures, Radiology 2016, Vol. 278, 563-577

［11］ pyradiomics, https://pyradiomics.readthedocs.io/en/latest/

［12］ Nitesh V. Chawla, Kevin W. Bowyer, Lawrence O. Hall, et al., SMOTE: Synthetic Minority Over-sampling Technique, Journal of Artificial Intelligence Research 16 (2002) 321–357

［13］ Hui Han, Wen-Yuan Wang and Bing-Huan Mao, Borderline-SMOTE: A New Over-Sampling Method in Imbalanced Data Sets Learning, Vol. 3644, pp. 878–887

［14］ Nguyen Hien M., Cooper Eric W., Kamei Katsuari, Borderline Over-sampling for Imbalanced Data Classification, 5th International Workshop on Computational Intelligence & Applications Proceedings : IWCIA 2009 p.24-29, 2009-11

［15］ Haibo He, Yang Bai, E. A. Garcia and Shutao Li, "ADASYN: Adaptive synthetic sampling approach for imbalanced learning," 2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence), Hong Kong, 2008, pp. 1322-1328

［16］ Tan, Mingxing & Le, Quoc., EfficientNetV2: Smaller Models and Faster Training. (2021)

［17］ A. Vaswani, N. Shazeer, N. Parmar, et al., Attention is all you need, Advances in neural information processing systems, page 5998--6008. (2017)

連合学習を用いた胸部 CT 画像におけるびまん性肺疾患の陰影識別と異常検知

岩瀬　実莉[*1]，間普　真吾[*1]，楊　鯤昊[*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 and Anomaly Detection of Diffuse Lung Diseases in Chest CT Using Federated Learning

Minori IWASE[*1], Shingo MABU[*1], Kunhao YANG[*1], Shoji KIDO[*2]
[*1] *Graduate School of Sciences and Technology for Innovation, Yamaguchi University*
[*2] *Graduate School of Medicine, Osaka University*

要旨：これまで，胸部 CT 画像におけるびまん性肺疾患の陰影識別を行うモデルが多数提案されてきた．深層学習を用いた識別モデルの構築には，学習に十分な量の教師データが必要である．しかし，医療分野においては個人情報等の問題から，十分な教師データを用意することが困難である．このような問題を解決するために，データを分散した状態での機械学習が可能な連合学習（Federated Learning）という考え方がある．そこで，胸部 CT 画像におけるびまん性肺疾患の陰影識別，陰影異常検知を目的とした学習に連合学習を適用したところ， 識別タスクではデータ公開し集約して学習を行う場合と同程度の性能，異常検知タスクでは単独の施設で学習を行う場合と同程度の性能であった．さらに，連合学習を事前学習と考え，連合学習後に各施設のデータで再学習を行うと，両タスクで，連合学習のみを行った場合より性能が向上することが明らかになった．
キーワード：連合学習，胸部 CT，識別，異常検知，びまん性肺疾患

1. はじめに

深層学習を用いた識別モデルの構築では，学習に十分な量の教師データが必要であるが，医療分野においては個人情報等の問題から，データを広く公開することができず，データが不十分であるケースも多い．

このような問題を解決するために，Google 社によって連合学習（Federated Learning）の考え方が提唱されている［1］．これは，データを集約する必要がなく，分散した状態で機械学習を行う手法である．

本研究では，第一に連合学習を胸部 CT 画像におけるびまん性肺疾患の陰影識別に適用した．一方，教師データ収集において，比較的収集しやすい正常データに対して，異常データの収集が難しいことを想定し，正常データのみで学習が可能な異常陰影検知モデルの研究も行い，連合学習の効果の検証と，改善を目指した．

2. 手法

2.1　手法 1（連合学習を用いる手法）

手法 1 では，複数施設の胸部 CT 画像に対して連合学習を適用し，性能を評価する．識別タスクでは，VGG16 ベースの CNN を，異常検知タスクでは，畳み込み自己符号化器（Convolutional Autoencoder, CAE）を共有モデルとする．なお，異常検知には，CAE の特徴量を入力とする One-class SVM を用いた．

2.1.1　連合学習の構成

図 1 に，連合学習の概観を示す．連合学習は，以下の 5 つの手順で学習を行う．

① 各クライアントは自身が持つデータを用いてモデルを学習
② 各クライアントが学習したモデルをサーバに送信
③ サーバはモデルを集約し，共有モデルを構築
④ サーバが共有モデルを各クライアントに転送
⑤ ①～④を 1 ラウンドとし，ラウンドを繰り返すことで，共有モデルを更新していく

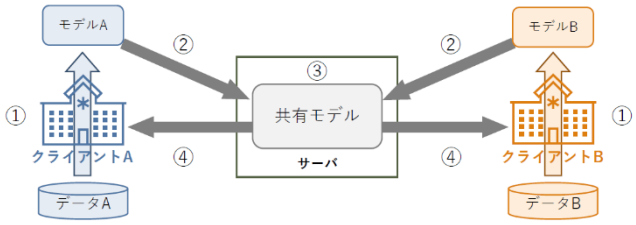


図 1：連合学習の概観

2.2　手法 2（連合学習後，再学習を行う手法）

手法 2 では，手法 1 の連合学習によって構築された共有モデルを，各クライアントで自身が持つデータを用いて再学習を行い，それぞれ新たなモデルを構築する．

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 2790 枚(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 1756 枚(阪大データ)を用い，3 パターンの検証を行う．手法 1 では，以下の通りである．

① 連合検証（手法 1）
山大，阪大で連合学習→山大データでテスト
山大，阪大で連合学習→阪大データでテスト
② 混合検証（データを公開できる場合を想定した比較検証）
山大，阪大データで学習→山大データでテスト
山大，阪大データで学習→阪大データでテスト
③ 基本検証（各施設において単独で学習する場合を想定した比較検証）
山大データで学習→山大データでテスト
阪大データで学習→阪大データでテスト

手法 2 では，連合検証が以下の通りとなる．
① 連合検証（手法 2）
連合学習後，山大で再学習→山大でテスト
連合学習後，阪大で再学習→阪大でテスト

3.2 実験結果

3.2.1 手法 1（連合学習を用いる手法）

表 1 に，識別タスクでの Accuracy を示す．t 検定は，すべての実験で連合検証と比較検証の間で行っている．表 1 より，連合検証は，基本検証で 1 施設のみの改善であったが，データの公開を仮定する混合検証と同程度の性能を示した．表 2 は異常検知タスクでの結果を示しており，連合検証は，比較検証と同程度の AUC であった．

3.2.2 手法 2（連合学習後，再学習を行う手法）

表 3 に，識別タスクでの結果，表 4 に，異常検知タスクでの結果を示す．両タスクにおいて，手法 1 の連合検証より手法 2 の連合検証のほうが高い性能であるため，連合学習を事前学習とし，各施設での再学習により，各施設に適したモデルにすることが有用であるといえる．表 4 より，異常検知タスクでは阪大基本検証より改善が見られたが，山大基本検証とは同程度であった．したがって，各施設の画像特徴の違いによって連合学習の効果に差があることも明らかとなった．

4. まとめ

連合学習を陰影識別と異常検知に適用した．その結果，データの秘匿性を保ったまま効果的な学習が可能であることを示した．また，連合学習後，再学習を行うことで，各施設に適したモデルとなり，連合学習のみの場合より性能が向上した．

今後の課題として，連合学習の汎用的な活用のために，共有モデルを胸部 CT 画像に関する汎用的な特徴抽出器として活用し，様々な異なるタスクに適用することが挙げられる．

表 1：識別タスクにおいて手法 1 と比較検証で得られた Accuracy と t 検定の結果

		連合検証	混合検証	基本検証
山大	Accuracy	0.8202	0.8264	0.7783
	p 値	-	0.3902	0.0446
阪大	Accuracy	0.8947	0.8993	0.9226
	p 値	-	0.3610	0.0063

表 2：異常検知タスクにおいて手法 1 と比較検証で得られた AUC と t 検定の結果

		連合検証	混合検証	基本検証
山大	AUC	0.7576	0.7683	0.7525
	p 値	-	0.1282	0.3185
阪大	AUC	0.8586	0.8624	0.8555
	p 値	-	0.6005	0.8546

表 3：識別タスクにおいて手法 2 と比較検証で得られた Accuracy と t 検定の結果

		連合検証	混合検証	基本検証
山大	Accuracy	0.8434	0.8264	0.7783
	p 値	-	0.2032	0.0053
阪大	Accuracy	0.9412	0.8993	0.9226
	p 値	-	0.0046	0.0290

表 4：異常検知タスクにおいて手法 2 と比較検証で得られた AUC と t 検定の結果

		連合検証	混合検証	基本検証
山大	AUC	0.7592	0.7683	0.7525
	p 値	-	0.3348	0.1650
阪大	AUC	0.8874	0.8624	0.8555
	p 値	-	0.0871	0.0350

謝辞

本研究は JSPS 科研費 JP21H03840、JP22K12152 の助成を受けたものです．

利益相反の有無

大阪大学大学院医学系研究科人工知能画像診断学共同研究講座は，富士フイルム株式会社との共同研究講座です．

文　献

［1］ Google Research, Federated Learning: Collaborative Machine Learning without Centralized Training Data, 2017, https://ai.googleblog.com/2017/04/federated-learning-collaborative.html

パーソナライズド連合学習を用いた EOB-MR 画像の肝結節性病変分類における施設毎の性能改善の検討

山田　藍樹[*1,2]，花岡　昇平[*2]，竹永　智美[*2]，吉川　健啓[*3]，野村　行弘[*3,4]
[*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] 東京大学医学部附属病院放射線科
[*3] 東京大学医学部附属病院コンピュータ画像診断学／予防医学講座
[*4] 千葉大学フロンティア医工学センター

Performance improvement for each site of classification of focal liver lesion in EOB-MR images using personalized federated learning

Aiki YAMADA[*1,2], Shouhei HANAOKA[*2], Tomomi TAKENAGA[*2],
Takeharu YOSHIKAWA[*3], Yukihiro NOMURA[*3,4]
[*1] *Department of Medical Engineering, Graduate School of Science and Engineering, Chiba University*
[*2] *Department of Radiology, The University of Tokyo Hospital*
[*3] *Department of Computational Diagnostic Radiology and Preventive Medicine, The University of Tokyo Hospital*
[*4] *Center for Frontier Medical Engineering, Chiba Universityl*

要旨：コンピュータ支援診断（computer-aided diagnosis, CAD）の開発において，開発施設に各施設のデータを集約した学習（データ集約型）の代替として，分散学習手法の連合学習（federated learning, FL）が注目されている．しかし，FL では各施設で最適な単一のモデルを得ることは困難である. この課題に対して施設毎に最適なモデルを学習する personalized FL（pFL）が提案されている．本研究では，pFL を用いた EOB-MR 画像の肝結節性病変分類における施設毎の性能改善について検討した．深層学習モデルには Attention 構造を付加した 3D ResNet-18 使用し, pFL には Ditto を用いた. テスト症例による正解率の平均は, データ集約型で 59.7%, FL で 64.0%，Ditto で 67.4%となり，pFL の適用が施設毎の性能改善に寄与することが示された.
キーワード：コンピュータ支援診断，連合学習，パーソナライズド連合学習，肝結節性病変，Gd-EOB-DTPA 造影 MR 画像

1. はじめに

汎用性の高いコンピュータ支援診断（computer-aided diagnosis, CAD）の開発には，複数施設のデータを用いた開発が望ましい[1,2]．しかし，複数施設より画像データを収集して開発施設に集約する形態（以下，データ集約型）には，データ共有に関する課題が存在する．近年，データを共有する代わりに各施設で学習した機械学習モデル（以下，モデル）の重みを統合して全体のモデルを学習する連合学習（Federated learning, FL）[3]が注目を集めている．連合学習の課題の 1 つとして，データ分布が学習施設（以下，クライアント）ごとに異なることにより，FL で得られるモデルが各クライアントで性能が最大とはならない点が挙げられる. この課題に対して施設毎に最適なモデルを学習するパーソナライズド連合学習（personalized FL, pFL）が提案されている[4]．本研究では，gadolinium-ethoxybenzyl-diethylene-triaminepentaacetic acid (Gd-EOB-DTPA) 造影 MR 画像の肝結節性病変分類における施設毎の性能改善について検討した.

2. データセット

装置ベンダーおよび静磁場強度の異なる MR 装置で撮像した 3 種類の GD-EOB-DTPA 造影 MR 画像 185 症例を使用した．Gd-EOB-DTPA 造影 MR 画像は，非造影，動脈相（造影剤注入後 20–35 秒），門脈相（造影剤注入後 60–90 秒），平衡相（造影剤注入後 3–5 分），肝細胞相（造影剤注入後 15–40 分）の 5 時相で構成されている. 各症例には少なくとも肝細胞癌, 肝転移, 肝血管腫のいずれかを含まれる. 対象病変はこれら 3 種類の病変に肝嚢胞を加えた 4 種類とした． 185 症例のうち，125 症例を training set，31 症例を validation set，29 症例を test set とし，装置ベンダーおよび静磁場強度毎に 3 種類のサブセット(GE 1.5 Tesla(T), GE 3T, Siemens 3T) に分割した.

3. 肝結節性病変分類

前処理として, まず肝細胞相をターゲット画像として残りの 4 時相を group-wise registration[5]を用いて動きの補正を行った後に，各辺 1.0mm の等方ボクセルへの等方化処理，ならびに画素値の正規化を行った．病変毎に重心を中心とした 5×32×32×32 の関心領域（voxel of interest, VOI）を時相毎に切り出し，学習済みの深層学習モデルに入力し分類結果を得た. 本研究では，深層学習モデルとして attention 機構である convolutional block attention module[6]を付加した 3D ResNet-18 を使用した.

モデルの学習では，各病変に対して L 個の拡張データを作成した．拡張に用いた変換は，各方向±4 ボクセルの範囲内でのシフト，各断面での 90 度単位の回転，およびγが[0.5, 1.5]の範囲のガンマ補正である．なお，拡張画像は epoch 毎に変更した．

4. 連合学習(FL)

FL は図 1 に示すように，グローバルモデルの更新を行うサーバ，ならびにモデルの学習を行う複数のクライアントから構成される．本研究では，クライアント数は 3 とし，グローバルモデルの更新に FedAvg[3]を用いた．FedAvg は各クライアントのモデルの重みの更新量と各クライアントのデータ数による重み付け平均で得られた更新量を用いて，グローバルモデルの更新を行う．pFL には Ditto[6]を用いた．Ditto はサーバのグローバルモデルだけではなく，各クライアント用のモデルも学習する手法である．各クライアント用のモデルの更新にはグローバルモデルの重みの情報も用いられる．

5. 実験および結果

施設毎および全体の分類性能を(a)データ集約型，(b)各施設のデータのみで学習した場合（以下，施設毎），(c) FL，(d) pFL（Ditto）の 4 種類の手法で比較した．データ集約型においてランダムサーチ 40 回の試行にハイパーパラメータ探索を行い，各試行で validation set の正解率が最良なモデルを test set に適用した．探索対象のハイパーパラメータはデータ拡張数 L，学習率，およびバッチサイズの 3 種類である．固定パラメータは，学習 epoch 数を 100 とし，最適化手法として stochastic gradient descent (SGD) を使用した．データ集約型以外の各手法の学習条件は，データ集約型と共通するパラメータは同一とした．連合学習および Ditto では，1 round あたりの各クライアントの学習 epoch 数を 1，最大 round 数は 100 とした．また，Ditto のパラメータのλは経験的に 1 とした．

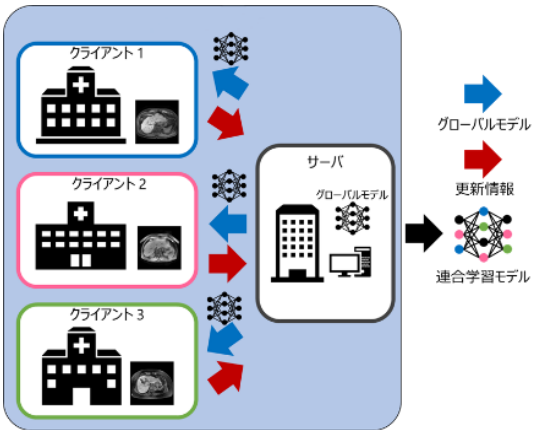


図 1　連合学習の構成

表 1 に各学習手法における正解率を示す．平均正解率はデータ集約型で 59.7%，施設毎で 54.4%，FL で 64.0%，Ditto で 67.4%であった．pFL では Siemens 3.0T での性能が他の手法に比べて大幅に上昇したため，平均正解率が最良になったと考えられる．

表 1　各学習手法の正解率[%]

手法	GE 1.5T	GE 3.0T	Siemens 3.0T	平均
データ集約型	63.9	56.8	58.3	59.7
施設毎	58.3	49.4	55.6	54.4
FL	**72.2**	**64.2**	55.6	64.0
pFL	66.7	60.5	**75.0**	**67.4**

6. まとめ

本研究では，pFL を用いた Gd-EOB-DTPA 造影 MR 画像の肝結節性病変分類における施設毎の性能改善について検討した．結果より，pFL の適用は施設毎の性能改善に有効であることが示された．今後，さらなる性能改善を図るために，pFL のパラメータ調整を行うなどのさらなる検討を行う予定である．

謝辞

本研究は JST，CREST，JPMJCR21M2 の支援を受けたものである．

利益相反の有無

吉川健啓，野村行弘の所属施設（東京大学医学部附属病院コンピュータ画像診断学／予防医学講座）は株式会社ハイメディック，シーメンスヘルスケア株式会社の寄附講座である．

文　献

[1] Park SH, Han K: Methodologic guide for evaluation clinical performance and effect of artificial intelligence technology for medical diagnosis and prediction. Radiology 286(3): 800-809, 2018

[2] Nomura Y, Hanaoka S, Nakao T et al: Performance changes due to differences in training data for cerebral aneurysm detection in head MR angiography images. Jpn J Radiol 39: 1039-1048, 2021

[3] McMahan HB, Moore E, Ramage D et al: Communication-efficient learning of deep networks from decentralized data. PMLR: 1273-1282, 2017

[4] Li T, Hu S, Beirami A, et al: Ditto: Fair and robust federated learning through personalization. PMLR: 6357-6368, 2021

[5] Jansen MJA, Kuijf HJ, Veldhuis WB, et al: Evaluation of motion correction for clinical dynamic contrast enhanced MRI of the liver. Phys Med Biol 62(19): 7556–7568, 2017

[6] Woo S, Park J, Lee JY, et al: Cbam: convolutional block attention module. In: Proc of the ECCV, pp. 3-19, 2018

骨シンチグラム診断支援システムの市販後再学習時のテストデータ再利用による性能バイアスとその補正

山中　陽大[*1]，東山　滋明[*2]，河邉　譲治[*2]，中岡　竜介[*3]，清水　昭伸[*1]

[*1] 東京農工大学大学院工学研究院

[*2] 大阪公立大学医学部附属病院核医学科

[*3] 国立医薬品食品衛生研究所医療機器部

Performance bias by test data reuse in post-market training a hot spot detection support system of bone scintigram and the bias correction

Haruto YAMANAKA[*1], Shigeaki HIGASHIYAMA[*2], Joji KAWABE[*2], Ryusuke NAKAOKA[*3], Akinobu SHIMIZU[*1]

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

[*2] *Department of Nuclear Medicine, Graduate School of Medicine, Osaka Metropolitan University*

[*3] *Division of Medical Devices, National Institute of Health Sciences*

要旨：本稿では，骨シンチグラムの診断支援システムを市販後に再学習する際に，同一テストデータを繰り返し利用することによって生じる性能のバイアスをシミュレーションし，バイアスの補正法を適用した結果について報告する．具体的には，連合学習の枠組みを利用して市販後の施設ごとに再学習したシステムをアンサンブルすることを想定し，アンサンブルに用いるモデルを同一のテストデータによる評価結果を用いて逐次的に選択する．また，再利用したテストデータとフレッシュなテストデータによる性能差（バイアス）を求め，統計的検定を行う．また，差分プライバシーに基づくバイアス補正アルゴリズムを適用した結果に対しても検定を実施し，有効性について考察する．

キーワード：テストデータ再利用，再学習，アンサンブル学習，検出支援システム，骨シンチグラム

1. 背景と目的

深層モデルを用いたコンピュータ支援診断システムでは，性能評価を繰り返しながらシステムを設計する場合がある．例えば，モデルのハイパーパラメータチューニングや，複数モデルのアンサンブルを行う場合などである[1,2]．また，市販後においても，使用する施設での性能向上を目的として，モデルの再学習と性能評価を繰り返すことがある[3]．この性能評価には，新鮮なテストデータの利用が理想的であるが，医用画像はアノテーションコストが高く，ラベル付き正解データの収集は困難であるため，同一のテストデータを繰り返し使用することが想定される．その場合に，テストデータに過剰適合するバイアスの問題が指摘されている[4,5,6]．

本稿では，骨シンチグラムの陽性高集積検出支援システム[7]を対象に，市販後の複数施設で独立に再学習をしたモデルを，連合学習[8]の枠組みで組み合わせる場合に注目して上記の問題について調べる．具体的には，アンサンブルに使用する再学習モデルを，同一テストデータを繰り返し利用しながら選択し，その際に評価値に混入するバイアスをシミュレーションにより確認する．また，バイアスを低減する補正法[5,6]を適用した結果についても示し，考察する．

2. 関連研究と問題点

Gossmann ら[5]は，Dwork ら[6]の手法を拡張したバイアスを補正するアルゴリズム（$Thresholdout_{AUC}$）を提案した．そこでは，同一テストデータによる ROC 下面積の AUC を利用して分類器を設計する際，式(1)に従って補正を行う．

$$\widehat{AUC}_{S_h}[\phi] = \begin{cases} \widehat{AUC}_{S_h}[\phi] + \xi, & if \left|\widehat{AUC}_{S_h}[\phi] - \widehat{AUC}_{S_t}[\phi]\right| + \eta > T \\ \widehat{AUC}_{S_t}[\phi], & else \end{cases} \quad (1)$$

ここで，S_t は学習データ，S_hは public データの集合を表す．この public データは，繰り返し利用するテストデータに対応する．この式は，学習データと public データによる AUC の差にノイズを加えた値が閾値を超えた場合には public データの AUC にノイズを加え，それ以外の場合には学習データの AUC を用いることを意味する．このように，public データへのアクセスを制限したりノイズを加えることで，バイアス混入を防ぐ．

上記の先行研究[5,6]では，public データによる評価値を分類に用いる特徴量選択に繰り返し利用している．しかし，最近の深層ネットワークでは，特徴量は学習の中で自動獲得される．また，個人情報保護の観点から最近利用されることの多い連合学習[8]の場合について，先行研究[5,6]の結論が同様に当てはまるか否かは不明である．

3. 市販後再学習におけるテストデータ再利用によるバイアスの検証

本節では，市販後再学習の方法，連合学習の枠組みによりテストデータを再利用しながらアンサンブルモデルを構築する方法，その構築時に生じるバイアスの検証法について説明する．

まず，市販後再学習では，11 施設で撮影された骨シンチグラムの中から 3 施設を市販前データとして深層モデルを学習し，

残りの 8 施設ごとに市販前学習済みモデルの再学習を行い，8 個の市販後モデルを構築する．

次に，アンサンブルのためのモデル選択では，まず，市販前テストデータを public データと private データ（フレッシュなテストデータに相当）に分割し，これらのデータに市販後モデルを適用して陽性高集積を予測する．次に，市販前学習モデルに再学習モデルを一つ追加した場合について，平均予測値の public データに対する AUC が最大の組合せを探索する．これをすべての再学習モデルが選択されるまで逐次的に行う（図 1）．

最後に，構築したアンサンブルモデルを public と private のそれぞれのデータに適用して求めた AUC の差をバイアスとして定義し，そのバイアスに対する統計的検定を行う．また，public データに対する AUC が最大の組合せを探索する際に，$Thresholdout_{AUC}$により AUC を補正した場合の実験も行う．

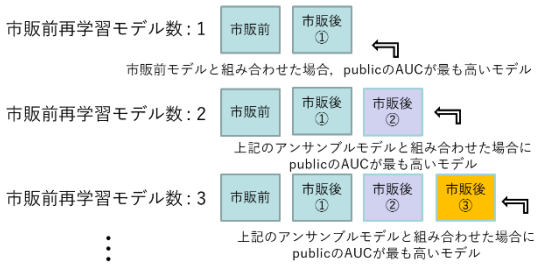


図 1 アンサンブルのためのモデル選択

4. 実験条件

実験試料には，11 施設から撮影された 1,430 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．市販前と市販後の学習では，3/5 を学習，1/5 をバリデーション，1/5 をテストデータとした．市販前テストデータはさらに 2 分割し，public と private のデータとした．public と private の分割は，乱数を用いて 20 通り用意し，統計的に評価した．深層ネットワークには ResBtrflyNet [7]を用い，学習回数は 100,000iteration，ミニバッチサイズは 64，Optimizer には Adam(α=0.001，β_1=0.9，β_1=0.999)，損失関数は Softmax Cross Entropy を用いた．また，$Thresholdout_{AUC}$のパラメータは，$T = 0.03, \sigma = 0.02, \eta = N(0, 4\sigma), \xi = N(0, \sigma)$とした．

5. 実験結果・考察

20 通りのテストデータに対するアンサンブル結果を図 2 に，$Thresholdout_{AUC}$を適用した結果を図 3 に示す．横軸はアンサンブルする再学習モデル数（0 は市販前モデル），縦軸は 20 通りのテストデータの平均 AUC とその標準偏差を表す．

図 2 よりアンサンブルモデル数 2 の場合に帰無仮説（両者の性能は等しい）が棄却され，public と private の AUC の間に有意差を確認した．このことはテストデータ再利用によってアンサンブルモデルの AUC にバイアスが含まれていることを示唆している．一方，$Thresholdout_{AUC}$を適用した図 3 の場合には，モデル数 2 における帰無仮説が保留となった．このことは，テストデータ再利用によるバイアスが，$Thresholdout_{AUC}$によって補正された可能性を示唆している．

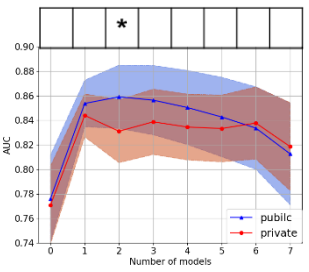


図 2 $Thresholdout_{AUC}$無アンサンブルモデルの AUC

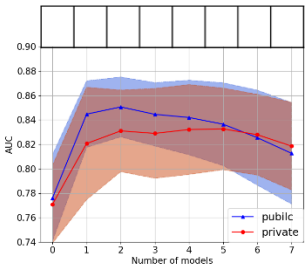


図 3 $Thresholdout_{AUC}$有アンサンブルモデルの AUC

（*：有意水準 0.05．Wilcoxon の符号付順位和検定
H_0：public と private の AUC に差は無い）

6. まとめ

本稿では，骨シンチグラムの陽性高集積検出支援システムに注目し，アンサンブルモデルに追加する市販後再学習モデルを，同一のテストデータで繰り返し評価しながら選択する実験を行った．実画像を用いた実験からは，テストデータ再利用によるバイアスが確認され，$Thresholdout_{AUC}$によってそのバイアスが補正できる可能性も示唆された．今後は，他のアンサンブル手法による検証実験や，市販後テストデータによる評価などを予定している．

謝辞

日頃から熱心にご指導・ご討論いただく東京農工大学清水昭伸研究室の各位に感謝いたします．なお本研究は，AMED の「AI を利用した医療機器プログラムの市販後学習時の性能評価に資する研究」（JP23mk0101240）の支援を受けています．

利益相反の有無

なし

文　献

[1] P. Probst, A. Boulesteix, B.Bischl, “Tunability: Importance of Hyperparameters of Machine Learning Algorithms”, JMLR, Vol.20, pp.1-32, 2019

[2] M. A. Ganaie, M. Hu, A.K. Malik, et al. “Ensemble deep learning: A review”, EAAI, Vol. 115,101515, 2022

[3] F. Takanashi, “The development of policy measures on medical devices using AI technology in Japan”, IMDRF, 2019

[4] R. Roelofs, V. Shankar, B. Recht, et al. “A Meta-Analysis of Overfitting in Machine Learning”, NeurIPS, 2019

[5] A. Gossmann, A. Pezeshk, Y. Wang, et al. “Test Data Reuse for the Evaluation of Continuously Evolving Classification Algorithms Using the Area under the Receiver Operating Characteristic Curve”, SIAM Journal on Mathematics of Data Science, Vol. 3, No. 2, pp.692-714, 2021

[6] C. Dwork, V. Feldman, M. Hardt, et al. “The reusable holdout: Preserving validity in adaptive data analysis”, Science, Vol. 349, No. 6248, pp.636-638, 2015

[7] A. Shimizu, H Wakabayashi, T Kanamori, et al., “Automated measurement of bone scan index from a whole-body scintigram”, International Journal of Computer Assisted Radiology and Surgery Vol. 15, pp.389-400, 2019

[8] H. guan, P. Yap, A. Bozoki, et al. “Federated learning for medical image analysis: A survey”, Pattern Recognition, Vol. 151, 2024

皮膚疾患画像分類における Underspecification の評価

殿村　理久[*1]，藤澤　康弘[*2]，藤本　学[*3]，坂井　浩志[*3]，志藤　光介[*4]，山崎　研志[*4]，
中岡　竜介[*5]，清水　昭伸[*1]

[*1] 東京農工大学大学院工学研究院

[*2] 愛媛大学大学院医学系研究科皮膚科学

[*3] 大阪大学大学院医学系研究科皮膚科学

[*4] 東北大学大学院医学系研究科皮膚科学分野

[*5] 国立医薬品食品衛生研究所

Evaluation of Underspecification in Skin Disease Image Classification

Riku TONOMURA[*1], Yasuhiro FUJISAWA[*2], Manabu FUJIMOTO[*3], Hiroshi SAKAI[*3],
Kosuke SHIDO[*4], Kenshi YAMASAKI[*4], Ryusuke NAKAOKA[*5], Akinobu SHIMIZU[*1]

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

[*2] *Department of Dermatology, Ehime University Graduate School of Medicine*

[*3] *Department of Dermatology, Osaka University Graduate School of Medicine*

[*4] *Department of Dermatology, Tohoku University Graduate School of Medicine*

[*5] *National Institute of Health Sciences*

要旨：本稿では，皮膚疾患画像の分類モデルにおける underspecification の影響を評価した結果について報告する．まず，学習時のネットワークの重みの初期値などの乱数に従う処理を変えたモデルを 10 個作成した．次に，学習データと独立同分布のテストデータ，そのデータに人工的な摂動（画像変換）を加えたストレステスト用のテストデータ，および，学習データとは異なる分布に従うテストデータを用いて，モデルの性能を評価した．また，ストレステストを用いた，未知データに対するモデルの性能の予測について検討した．

キーワード：underspecification，ストレステスト，深層学習，分類モデル，皮膚疾患

1. はじめに

皮膚疾患の種類は多く, 限局性やびまん性の病変までさまざまである．その病変の特徴は多様，かつ，異なる疾患でも類似した特徴を示すことがある. そのため専門医でも判断が難しく, 皮膚疾患の診断支援システムの開発が求められている. 著者らはこれまでに, 深層モデルによる皮膚疾患の臨床写真の分類システムを提案した[1].

こうした機械学習モデルを用いたとき, 手元の学習と独立同分布(independent and identically distributed; iid)のデータによるテストでは同程度の性能を示すが，実世界(real-world; RW)のデータに適用した際に性能が異なる複数のモデルが存在する underspecification[2]と呼ばれる問題が存在することが知られている. 実世界にモデルを導入した際に性能が予想外に低下する原因となる可能性があるため, モデルの設計の際にこの問題を評価することが重要である.

2. 関連研究と目的

D'Amour ら[2]は, underspecification が機械学習の様々な応用分野で存在することを，事例研究を用いて示した．例えば，自然画像の分類問題において，ImageNet[3]で学習させた複数のモデルに対して, 低解像度化や輝度変換などの画像変換を適用し作成された ImageNet-C [4]を用いて性能を評価するストレステストを行った．その結果，ストレステストに対するモデル性能のばらつきが ImageNet のテストに対するものと比べて大きくなることを示し，underspecification によって未知データに対する性能の安定性が保証されないことを示した．

Eche ら[5]は，D'Amour らの研究を踏まえて AI の放射線医学への応用に取り組み，underspecification 克服のためのストレステストの設計について議論した．彼らは CT 画像を用いた脂肪肝の分類モデルに対し，肥満患者の S/N 比が低いことに注目して，テストデータの S/N 比をランダムに変化させ，変化前後のモデルの性能を比較するストレステストを提案している．

以上の研究成果は, 皮膚疾患の臨床写真の分類システムに適用できるか否かは不明である．そこで，本研究では，著者らが開発した 59 クラスの皮膚疾患の臨床写真の分類システム[1]を対象に，ストレステストや RW データによる underspecification の評価を行い, この問題に関する知見を得ることを目的とする.

3. 実験方法

本研究では，従来の 59 クラスの皮膚疾患分類システム[1]を

学習させる際の，オーグメンテーション，ミニバッチ選択，距離損失用画像選択で用いる一様乱数，および，全結合層の重みの初期値の正規乱数の初期値を変えて，評価用の 10 個のモデルを作成した．また，それらに対して，テスト用画像，ストレステスト用の画像変換とノイズ付与後のテスト画像，および，他施設で撮影された RW テストデータを用いて性能を評価した（図 1 参照）．

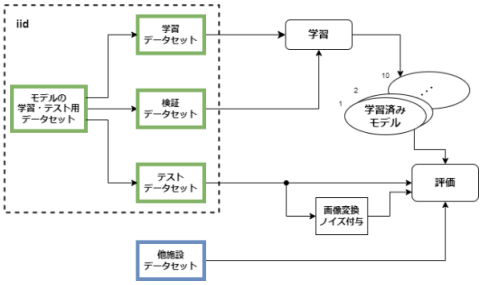


図 1　underspecification 評価フロー

まず，日本皮膚科学会の National Skin Disease Database の中の 12 施設 12,066 症例の画像のうち，10 施設 11,846 症例を手元の学習，検証，テストデータとした．また，残り 2 施設 220 症例を RW データとして使用した．次にテストデータに対して，画像変換やノイズの付与を行った．そこでは，ImageNet-C [4]を参考に，輝度変換，コントラスト変換，ガウスノイズ，ぼかしの 4 種類×強度 5 段階の計 20 種類の画像を用意した．ただし，不自然な画像は評価に適さないと考え，学習画像との類似度（DINO Vision Transformer [6]による画像特徴ベクトル間の cos 類似度）が高い変換のみを評価に用いた．

4. 実験結果と考察

10 個のモデルに対して得られた性能を平均値で割って正規化した後の Relative Accuracy を図 2 に示す．ここでは，手元のテストデータ（iid）と比較して，強度が中程度（2）以上のコントラスト変換，および，RW と表示した他施設のデータに対していずれもばらつきが増加していた．F 検定を用いて iid の性能の分散と等しいという帰無仮説を検定したところ，強度 2 と 3 では $p<0.05$ で棄却され，underspecification の問題の可能性が示唆された．紙数の制限により詳細は割愛するが，輝度変換，カウスノイズ，ぼかしを加えた画像によるストレステスト（DINO の類似度で評価に適するとされたテスト）においては，強度が最小のぼかしを除いてばらつきが増加し，等分散性の検定は，輝度変換の強度 3 とぼかしの強度 2 では $p<0.05$ で棄却され，輝度変換の強度 4 と 5 では $p<0.01$ で棄却され，ここでも underspecification の問題の可能性が示唆された．

次に，テスト間のスピアマンの順位相関係数を求めたところ，コントラスト変換 2 と RW データの間で正の高い相関(0.571)がみられたことから，コントラスト変換を用いて，RW データに対して性能の高いモデルを選択できる可能性があることが分かった．しかし，相関係数が 0 という帰無仮説は保留されたことから，さらなる検討が必要である．

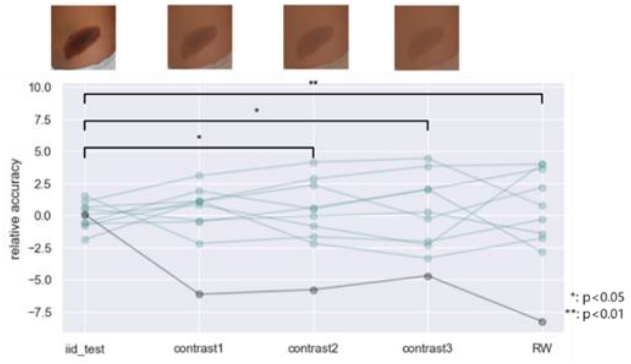


図 2　モデルの性能の変化（相対 Accuracy）

5. まとめ

本稿では，59 クラスの皮膚疾患分類システムに対して，人工的に摂動を与えたストレステスト用データや RW データによるテストを実施した．その結果，モデル性能の分散の増加が確認され，underspecification の可能性が示唆された．また，ストレステストを用いて RW データに対して性能の高いモデルを予想できる可能性について検討した．今後は，他のストレステストによる underspecification の評価や，ストレステストを用いた RW データにおける性能の予想法について検討する．

謝辞

本研究では，日本皮膚科学会の National Skin Disease Database を利用しました．データベース構築・維持に関係されている先生方に感謝いたします．また，本研究は，AMED「AI を利用した医療機器プログラムの市販後学習時の性能評価に資する研究」(JP23mk0101240)による支援を受けて実施しました．

利益相反の有無

なし

文　献

［1］Tanaka M, Saito A, Shido K et al: Classification of large-scale image database of various skin diseases using deep learning. International Journal of Computer Assisted Radiology and Surgery 16:1875–1887, 2021

［2］D'Amour A, Heller K, Moldovan D et al: Underspecification Presents Challenges for Credibility in Modern Machine Learning. Journal of Machine Learning Research, 23(226): 1-61, 2022

［3］Deng J, Dong W. Socher R et al: ImageNet: A large-scale hierarchical image database, IEEE Conference on CVPR, 248-255, 2009

［4］Hendrycks D, Dietterich T: Benchmarking Neural Network Robustness to Common Corruptions and Perturbations, ICLR, 2019

［5］Eche T, Schwartz LH, Mokrane FZ et al: Toward Generalizability in the Deployment of Artificial Intelligence in Radiology: Role of Computation Stress Testing to Overcome Underspecification. Radiology: Artificial Intelligence, Oct 27;3(6):e210097, 2021

［6］Caron M, Touvron H, Misra I et al: Emerging properties in self-supervised vision transformers. Proceedings of the IEEE/CVF ICCV: 9650-9660, 2021

皮膚疾患分類のためのマルチモーダル学習

飯嶋　杏奈[*1]，藤澤　康弘[*2]，藤本　学[*3]，坂井　浩志[*3]，
志藤　光介[*4]，山﨑　研志[*4]，清水　昭伸[*1]
[*1] 東京農工大学大学院工学研究院
[*2] 愛媛大学大学院医学系研究科皮膚科学
[*3] 大阪大学大学院医学系研究科皮膚科学
[*4] 東北大学大学院医学系研究科皮膚科学分野

Multimodal learning for skin disease classification

Anna IIJIMA[*1]，Yasuhiro FUJISAWA[*2]，Manabu FUJIMOTO[*3]，Hiroshi SAKAI[*3]，
Kosuke SHIDO[*4]，Kenshi YAMAZAKI[*4]，Akinobu SHIMIZU[*1]
[*1] *Institute of Engineering, Tokyo University of Agriculture and Technology*
[*2] *Department of Dermatology, Ehime University Graduate School of Medicine*
[*3] *Department of Dermatology, Osaka University Graduate School of Medicine*
[*4] *Department of Dermatology, Tohoku University Graduate School of Medicine*

要旨：皮膚疾患は種類が多く，病変の種類や進行度によって多様な外観を示す．これまでに皮膚疾患の臨床写真かダーモスコピー画像のいずれかを対象とした分類の研究が行われてきたが，実際の医師による皮膚疾患の診断には，臨床写真やダーモスコピー画像，患者の年齢や性別などの臨床情報が併せて用いられる．そのため，従来のシステムでは二種類の画像が持つ相補的情報を考慮しておらず，分類精度に限界があった．本報告では，臨床写真とダーモスコピー画像に年齢などの臨床情報を加えたマルチモーダルデータによる皮膚疾患の分類手法を提案する．また，実画像を用いて性能を評価することで，入力情報の種類や数，マルチモーダルデータの融合方法の違いによる分類精度の比較を行った．その結果，すべての情報を用いた場合の精度が最も高いことなどが確認できた．

キーワード：CAD，皮膚疾患分類，マルチモーダル学習，Transformer

1. はじめに

皮膚疾患は 2,000 を超える種類が存在し，外観はさまざまである．また，同一疾患においても発症部位や進行度によって外観は大きく変化する．そのため，診断には疾患の形態や色の特徴を正しく理解しながら適切に観察を行うことが求められ，非専門医による診断は容易ではない［1］．そこで，多種多様な皮膚疾患を対象とした，診断支援システムの開発が求められている．

2. 先行研究と本研究の目的

Tanaka［2］らは，ResNet ベースのモデルを提案し，大規模かつ多様な皮膚疾患の臨床写真の分類に取り組んだ．また，Vision Transformer（ViT）［3］の登場以来，ViT ベースのモデルが提案されている．例えば Cai［4］らは，皮膚病分類のために，臨床写真かダーモスコピー画像のいずれか一種類の画像とメタデータに対応する 2 つのエンコーダと，マルチモーダル情報を融合する Mutual Attention（MA）ブロックを用いたデコーダから構成される Transformer ベースのモデルを提案した．各データの特徴抽出において，画像には ViT モデル，メタデータにはソフトラベルエンコーダが利用される．これらの特徴は，Multi-head Cross Attention の手法に触発されて設計された MA ブロックにより融合され，高い分類性能が報告されている．

上記の先行研究［2,4］の問題点として，分類に用いる画像データがいずれも一種類であることが挙げられる．基底細胞癌などの一部の皮膚疾患の臨床診断時に臨床像，ダーモスコピー画像，被検者の年齢、部位などの複数の臨床情報が用いられる．しかし，先行研究では二種類の画像と臨床情報が持つ相補的情報を利用していないため，精度に限界がある．

本研究では，臨床写真とダーモスコピー画像の二種類のデータおよび被検者の臨床情報のマルチモーダルデータを用いた皮膚疾患の分類手法を提案する．また，入力情報の種類と数や融合方法の違いによる分類精度の差異を明らかにし，優れた融合法を明らかにする．

3. 提案手法

3.1 入力情報の種類と数

本研究では，臨床写真，ダーモスコピー画像，臨床情報の三種類の入力情報に注目し，入力数の異なる複数の条件下で実験を行った．具体的には，二種類の画像と臨床情報の 3 入力の場合以外に，一種類の画像と臨床情報または二種類の画像の 2 入

力，一種類の画像の 1 入力についてモデルを構築し，性能を比較した．ここでモデルは，先行研究［4］を参考に一種類の画像と臨床情報の 2 入力モデルを作成し，その後で 3 入力への拡張と 1 入力への縮小を行った．3 入力のモデルを図 1 に示したが，二種類の画像特徴を連結結合と多層パーセプトロンにより融合し，1 つの画像特徴として抽出する．その後，画像と臨床情報（メタデータ）の特徴を MA ブロックで融合した．

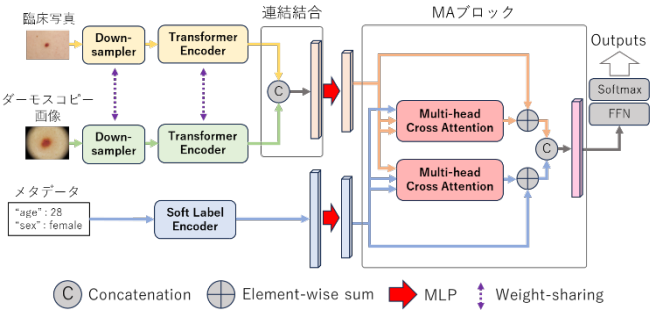


図 1　3 入力モデルの構造

3.2 入力情報の融合方法

図 1 に示した通り，3 入力モデルの入力情報の融合箇所は，二種類の画像情報の融合と，画像と臨床情報の特徴融合の 2 箇所である．本研究では，このモデルの融合方法の違いに注目して，2 つの融合箇所に連結結合または MA ブロックを利用し，計 4 つのモデルについて比較を行った．

4. 実験

4.1 実験条件

実験では，日本皮膚科学会が保有する National Skin Disease Database から，皮膚科専門医が選んだダーモスコピー画像を診断に利用する 24 疾患，4,595 症例を対象とした．前処理として画像を短辺 512［pixel］になるようアスペクト比固定でリサイズした．学習時にはオーグメンテーションとして，画像内から 448×448［pixel］をランダムクロップ，左右上下独立に 0.5 の確率で反転，0.5 の確率で転置を適用した．テストデータは，画像の中央から 448×448［pixel］でクロップした．損失関数は交差エントロピー損失 L_{CE} を用い，パラメータの最適化には Adam($\alpha = 10^{-5}, \beta_1 = 0.9, \beta_2 = 0.999$)を使用した．入力情報の種類と数の違い注目した実験では 6 通り，入力情報の融合方法の違いに注目した実験では 4 通りのモデルを使用した．

4.2 実験結果と考察

表 1 に入力情報の種類と数の違いに注目した実験の正解率，表 2 に入力情報の融合方法の違いに注目した実験の正解率を示す．また，Accuracy に対しては，2 つのモデルの正解率には差は無いという帰無仮説に対してマクネマー検定（Bonferroni 補正あり）を行った．

まず表 1 より，入力情報が 3 つの場合が最も分類精度が高くなることが確認できた．特に，Accuracy の画像単位の結果からは，二種類の画像を入力した場合に正解率が高くなることがわかる．次に表 2 からは，二種類の画像特徴の融合に連結結合，画像とメタデータの特徴融合に MA ブロックを使用した時に Accuracy が高くなることが確認できた．しかし，どのモデル間においても検定結果は保留となった．

表 1　入力情報の種類と数の違いに注目した実験

入力数	入力情報	Accuracy 画像単位	Accuracy 症例単位	Macro-sensitivity 画像単位	Macro-sensitivity 症例単位
3入力	臨床写真 ダーモスコピー メタデータ	**0.567**	**0.588**	**0.371**	**0.400**
2入力	臨床写真 ダーモスコピー	0.531	0.551	0.343	0.362
	臨床写真 メタデータ	0.461	0.505	0.297	0.323
	ダーモスコピー メタデータ	0.484	0.537	0.333	0.366
1入力	臨床写真	0.419	0.455	0.274	0.305
	ダーモスコピー	0.449	0.472	0.310	0.340

（** p × 4 < 0.01，* p × 4 < 0.05）

表 2　入力情報の融合方法の違いに注目した実験

二種の画像情報の融合方法	画像とメタデータの特徴の融合方法	Accuracy 画像単位	Accuracy 症例単位	Macro-sensitivity 画像単位	Macro-sensitivity 症例単位
MAブロック	MAブロック	0.545	0.574	**0.388**	0.398
MAブロック	連結結合	0.562	0.582	0.373	0.394
連結結合	MAブロック	**0.567**	**0.588**	0.371	**0.400**
連結結合	連結結合	0.550	0.568	0.342	0.358

5. まとめ

本研究では，皮膚疾患の分類を目的として，臨床写真，ダーモスコピー画像，臨床情報の三種類を組み合わせたマルチモーダル学習に取り組んだ．実画像を用いた実験結果から，すべてを入力した際に最も性能が高くなることが分かった．また，融合方法を変えて性能を評価したが，有意な違いは確認できなかった．今後は，その他の融合法も含めて検討を行う予定である．

謝辞

本研究では，日本皮膚科学会の National Skin Disease Database を利用しました．データベース構築・維持に関係されている先生方に感謝いたします．

利益相反の有無

なし

文　献

［1］ Griffiths C, Barker J, Bleiker T et al: Rook's Textbook of Dermatology, 9th ed. John Wiley & Sons, 2016

［2］ Tanaka M, Saito A, Shido K et al: Classification of large-scale image database of various skin diseases using deep learning. IJCARS, 2021

［3］ Dosovitskiy A, Beyer L, Kolesnikov A, et al: An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. ICLR, 2021

［4］ Cai G, Zhu Y, Wu Y et al: A multimodal transformer to fuse images and metadata for skin disease classification. The Visual Computer, 2023

胸部 CT 画像におけるびまん性肺疾患の識別のための Voxel データの効果的な活用方法の提案

森崎　幹也[*1]　間普　真吾[*1]　木戸　尚治[*2]
[*1] 山口大学
[*2] 大阪大学

Proposal for the Effective Utilization of Voxel Data for the Classification of Diffuse Lung Diseases in Chest CT Images

Mikiya MORISAKI[*1], Shingo MABU[*1], Shoji KIDO[*2]
**1 Yamaguchi University*
**2 Osaka University*

要旨：近年，GPU の性能の向上により，Voxel データを対象とした深層学習モデルの構築が可能となりつつある．しかし，一般に胸部 CT 画像データは 1 症例あたり 2-300×512×512 ほどの解像度で記録されており，この規模のデータの処理には膨大な GPU メモリや学習時間を要する．そこで本研究では，胸部 CT 画像において，Voxel データを効果的に扱うための手法を提案する．1 つ目は，環状軸方向，矢状軸方向，垂直軸方向の 3 つの軸を基準としてスライスをサンプリングしたデータを用いる手法である．少数派クラスの識別性能を Precision-Recall Area Under the Curve (PR-AUC)で評価した結果，学習データと同じドメインのデータに対し非常に高い識別性能を示した．2 つ目は，画像から輝度情報とテクスチャ情報を抽出し，これらを組合せたデータをモデルへの入力とする手法である．学習データと同じドメインのデータに対し高い識別性能を保ったまま，異なるドメインのデータに対しても高い識別性能を達成した．
キーワード：深層学習，Voxel データ，胸部 CT，びまん性肺疾患，識別

1. はじめに

近年，GPU の性能の向上により，以前は困難であった Voxel データを対象とした深層学習モデルの構築が可能となりつつある．しかし，一般に胸部 CT 画像データは，1 症例あたり 2-300×512×512 ほどの解像度で記録されており，そのままの入力は依然として難しい．そこで本研究では，胸部 CT 画像において，Voxel データを効果的に扱うための 2 つの手法を提案する．

2. 手法

2.1 3 つの軸を基準としたスライスのサンプリング

本先行研究である Multichannel 2D Convolu-tional Neural Network (M2D)[1]の考え方をもとに，環状軸方向，矢状軸方向，垂直軸方向の 3 方向を基準にスライスをサンプリングしたデータをそれぞれ独立に畳み込み処理し，それらの結果を統合することで，医師による胸部 CT 画像の読影を模倣した識別手法を提案する．モデル構造を図 1 に示す．3 つの軸を基準として一定間隔ごとにスライスのサンプリングを行い，4 層の 3 次元畳み込み層，Global Average Pooling (GAP)，64 次元から 1 次元への全結合層を繋げたモデルにそれぞれ入力する。各出力の平均を取り，最終的な出力値とする．これを、垂直軸方向にサンプリングしたデータのみを用いた場合（ベースライン手法）と比較する．

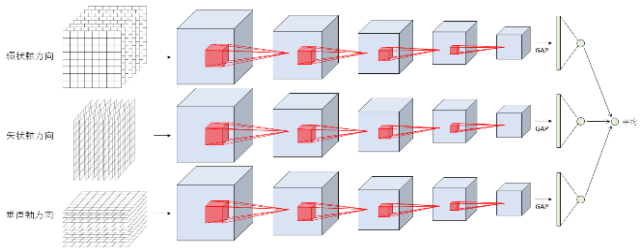


図 1 提案手法 1 のモデル構造

2.2 3 つの軸を基準としたスライスのサンプリング

先行研究であるカラー特徴量とテクスチャ特徴量の組合せによる画像の特徴を生かした圧縮[2]の考え方をもとに，輝度ヒストグラムとテクスチャヒストグラムを連結したデータを入力するモデルを提案する．輝度ヒストグラムには，数千階調の解像度を持つ胸部 CT 画像から肺野領域の識別に有用な 1500 階調ほどの範囲を用いる．テクスチャヒストグラムには，画素値の局所的な変化を捉えるために，Local Binary Pattern (LBP)値をヒストグラム化したものを用いる．入力データの作成手順を図 2 に示す．環状軸方向，矢状軸方向，垂直軸方向の 3 方向を基準に、スライスごとに輝度ヒストグラムとテクスチャヒストグラムの作成を行い，これらを連結することで 2 次元データを得る．これを，ResNet18，GAP，512 次元から 128 次元を経由して 1 次元となる 2 層の全結合層を繋げたモデルに入力する．

表 1 学習結果（5-CV の平均および標準偏差）

	入力データサイズ	ROC-AUC		PR-AUC	
		基本検証	応用検証	基本検証	応用検証
ベースライン手法	16×512×512×1	0.9866±0.2225	0.6899±0.0526	0.8901±0.1929	0.2667±0.0506
提案手法 1	環状軸方向：32×256×512×1 矢状軸方向：32×256×512×1 垂直軸方向：16×512×512×1	**0.9991±0.0018**	0.8302±0.0800	**0.9948±0.0103**	0.5177±0.1320
提案手法 2	1280×1756×1	0.9815±0.0202	**0.9684±0.0082**	0.9071±0.1008	**0.8174±0.0546**

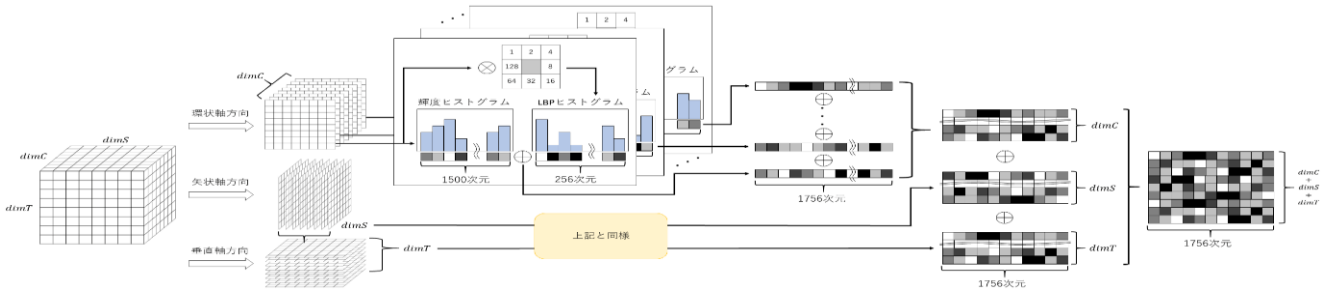


図 2 提案手法 2 のモデルへの入力データの作成手順

3. 実験

3.1 データセット

実験には，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)および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)を用いる．阪大データの 5 分割交差検証(基本検証)および同じ学習モデルに対する山大データでのテスト(応用検証)について、正常/異常の識別性能を検証する．

3.2 実験結果

結果を表 1 に示す。ベースライン手法と比較して，提案手法 1 は，特に応用検証に対する汎化性能が大きく向上した．この要因として，提案手法 1 では，Voxel データを多角的に見ることができたことが考えられる．提案手法 1 と比較して，提案手法 2 は，基本検証に対する性能は低下したが，応用検証に対する性能がさらに大きく向上した. 輝度ヒストグラムとテクスチャヒストグラムの両方を組合せることで，胸部 CT 画像から多様な特徴を抽出することができ, 識別性能の向上に繋がったと考えられる．

4. まとめと今後の課題

環状軸方向，矢状軸方向，垂直軸方向の 3 方向からスライスをサンプリングすることで, 異なるドメインのデータに対する汎化性能が向上した．また，輝度情報とテクスチャ情報組合せることで, 異なるドメインのデータに対しても非常に高い識別性能を達成した．

今後の課題として，胸部 CT 画像の前処理，およびヒストグラムデータの組合せ方に関する改善の余地が挙げられる. 特に、提案手法 2 におけるヒストグラムデータの連結では，LBP 値のヒストグラムに対する畳み込み演算や，連結したデータの境界を無視した畳み込み演算に不自然さがあるため，さらなる改良を行いたい．

謝辞

本研究は JSPS 科研費 JP21H03840，JP22K12152 の助成を受けたものです．

利益相反の有無

大阪大学大学院医学系研究科人工知能画像診断学共同研究講座は，富士フイルム株式会社との共同研究講座です．

文　献

［1］ Jinlong Hu, Yuezhen Kuang, Bin Liao, Lijie Cao, Shoubin Dong, and Ping Li. A Multichannel 2D Convolutional Neural Network Model for Task-Evoked fMRI Data Classification. Computational Intelligence and Neuroscience, 2019.

［2］ Saikat Chakraborty. A Graph-based Ranking Approach to Extract Key-frames for Static Video Summarization. CoRR, Vol. abs/1911.13279, 2019.

呼吸器内視鏡迅速細胞診における AI 診断支援 - 第２報 埋め込み表現空間における距離を考慮した対照学習

尾見康夫*1、桐田圭輔*2,*3、酒井徹也*2、高橋真理*4,*5、後藤功一*2
*1 NEC ヘルスケア・ライフサイエンス事業部門 ライフスタイルサポート統括部 Incubation G
*2 国立がん研究センター東病院 呼吸器内科
*3 上尾中央総合病院 呼吸器内科
*4 国立がん研究センター東病院 トランスレーショナルリサーチ検体管理室
*5 国立がん研究センター東病院 内視鏡センター

AI-assisted benign and malignant classification for Rapid On-Site cytologic Evaluation on lung cancer. A follow up report, contrastive learning based on distance metric in embedding spaces.

Yasuo Omi1, Keisuke Kirita2,3, Tetsuya Sakai2, Mari Takahashi4,5, and Koichi Goto2
1 Healthcare and life sciences, Lifestyle support, Incubation group, NEC Corporation
2 Department of Thoracic Oncology, National Cancer Center Hospital East
3 Department of Thoracic Oncology, Ageo Central General Hospital
4 TR Sample Management Office, National Cancer Center Hospital East
5 Endoscopy Ctr., National Cancer Center Hospital East

要旨：呼吸器内視鏡検査における迅速細胞診（ROSE）は診断率の向上や穿刺回数の減少などの有効性が報告されているが検体の良悪性分類を担う人的資源の確保等の理由から導入施設が限られている。この課題を解決するため ROSE の診断支援を目的とした AI 診断システムの開発を進めている。我々は昨年度の本学会において、細胞の種類における大分類と小分類に基づいて対照学習における負例を hard negative と easy negative に分けて学習する手法（旧提案法）を提案し、従来法（SimCLR）に比べて分類精度が向上することを報告した。更なる精度改善を目的として、hard negative と easy negative に分配した後に埋め込み表現空間における距離に基づいて Semi-hard negative を抽出する手法を考案し、旧提案法を上回る分類精度を実現した。
キーワード：迅速細胞診, 対照学習, 良悪性分類

1. Introduction

The studies of Oki and Trisolini showed that Rapid on-site cytologic evaluation (ROSE) resulted in a lower puncture number compared with a non-ROSE group and less complications, and it could also prevent a repeat bronchoscopy [1-2]. However, ROSE is not widely used routinely due to limited availability of a cytopathologic technician skilled in ROSE diagnosis. To solve the availability issue, we aim to develop an AI-assisted benign and malignant classifier for ROSE. The goal of this research is to devise an effective pretext task to achieve sufficient classification accuracy.

2. Materials and Methods

Twenty-six pathological slides were obtained from routine examinations for lung cancer or suspected cases in National Cancer Center East (NCCE) hospital in which bronchoscopy with ROSE was performed using Diff-Quick staining method. 741 cells were selected and labeled by a pulmonologist and cytotechnologist, and cell images were obtained by cropping a 128x128 pixel region around the cell center at 40X magnification from digital scanned slide. 394 cells were categorized as benign, and 347 cells were categorized as malignant. The cells were also categorized into 9 cell types, endothelial cells, inflammatory endothelial cells, macrophages, lymph cell, white blood cell, small cell carcinoma, adenocarcinoma, squamous cell carcinoma, and other non-small cell lung cancers. Since our obtained images were an imbalanced dataset among subclasses, we applied augmentation to have a consistent number of images, i.e. every 1000 images per subclass. The cell images were randomly partitioned into five equal sized subsamples to perform 5-folds cross validation.

In general supervised contrastive learning [3], the images belong to same class with an anchor are assigned as positive samples and the images belong to different class with an anchor are assigned as negative samples, respectively. When an image with Adenocarcinoma is choose as an anchor image, both the following group A and the group B are assigned as negative samples. Group 1: The cells with other malignant class (Squamous cell carcinoma etc.) that could have some level of similar features because they belong to same class in terms of coarse classification despite different class in terms of fine classification. Group 2: The cells with benign class (Endothelial cell

etc.) that should have few similar features because they belong to different class even coarse classification. The figure 1 illustrates an example of the group 1 and the group 2 definition based on coarse and fine labels. Since the group A samples are expected to locate relatively close to the anchor in embedding spaces compared with the group 2 samples, it's reasonable to assign larger weight the group 1 samples during training than the group 2 samples. Based on the consideration, we had proposed the method using the loss function that is designed to be more sensitive to the hard negative samples that are typically seen in the group A than the easy negative samples that are typically seen in the group B (We call it as 'old proposal method').

Coarse	Fine
Benign cell	Endothelial cell (EC)
	Inflammatory endothelial cell (IEC)
	Macrophage (M)
	Lymph cell (LC)
	White blood cell (WBC)
Malignant cell	Small cell carcinoma (S)
	Adenocarcinoma (Ad)
	Squamous cell carcinoma (Sq)
	Other non-small cell carcinoma (NS)

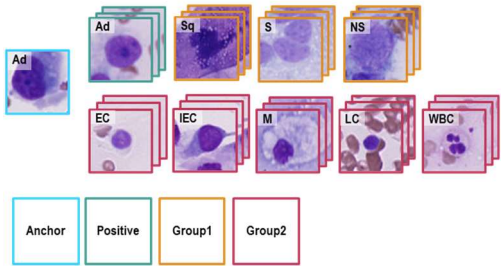


図 1　ラベル情報に基づいたグループ A と B の選択

The figure 2 illustrates an example of distribution of each sample in an embedding space and following semi-hard negative mining. The 2 dotted circles in the figure 1 shows the lower and upper of the confidential interval from the anchor to the group1 samples. Despite the group1 samples, some samples could have shorter distance from the anchor than the confidential interval lower or could have longer distance from the anchor than the confidential interval upper. And there are a few chances that it locates within the confidential intervals despite the group2 samples. The old proposal method has a potential risk that it doesn't necessarily work fine for the dataset containing such outliers. To mitigate the potential risk, we introduced a method that the samples locating within the confidential intervals are assigned as semi-hard negative samples which are main target of our training strategy (We call it as 'new proposal method'). In the new proposal method, the samples which have shorter distance from the anchor than the confidential interval lower are assigned as hard negative samples and the samples which have longer distance from the anchor than the confidential interval upper are assigned as easy negative samples. The loss function in the new proposal method is designed to be much sensitive to the semi-hard negative samples and to be less sensitive to the hard negative samples and the easy negative samples.

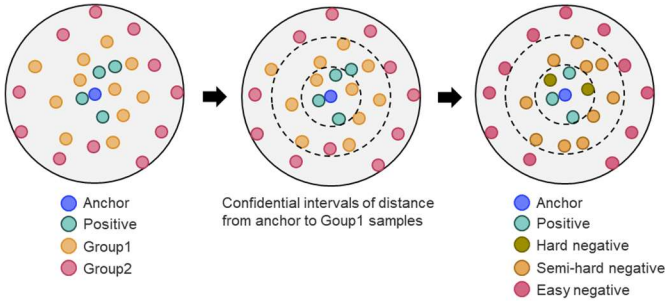


図 2　セミハードネガティブの抽出方法

3. Results and Discussion

We compared the following three methods, 1. General contrastive learning (SimCLR), 2. Old proposal method and 3. New proposal method to investigate the pretext task which suits for our AI-assisted diagnose system. Classification accuracy using the three methods were found to be 0.922/0.931/0.938, respectively. The concept of semi-hard negative mining is inspired by the existing method like Triplet loss [4]. Since the new proposal method can define adaptively a threshold distance to select the semi-hard negative samples, we strongly think that it could be a big advantage to the existing methods giving the threshold distance as a constant hyper-parameter.

4. Conclusion

We devised a novel pretext task using contrastive learning based on distance metric in embedding spaces, and our proposal method was effective to improve classification accuracy for lung cancer ROSE.

Conflict of Interest

The author is an employee of NEC corporation.

References

[1] M. Oki et al.: Rapid on-site cytologic evaluation during endobronchial ultrasound-guided transbronchial needle aspiration for diagnosing lung cancer: a randomized study, Respiration, 2013;85(6):486-92

[2] R. Trisolini et al.: Rapid on-site evaluation of transbronchial aspirates in the diagnosis of hilar and mediastinal adenopathy: a randomized trial, Chest. 2011 Feb;139(2):395-401

[3] P. Khosla et al., Supervised Contrastive Learning, NeurIPS 2020

[4] J. Wang et al., Learning Fine-grained Image Similarity with Deep Ranking, CVPR 2014.

拡散モデルを使用したマルチタスク MRI 再構成モデルの検討

藤田 直人[*1]，寺田 康彦[*1]

[*1] 筑波大学大学院　理工情報生命学術院　数理物質科学研究群

応用理工学学位プログラム電子・物理工学サブプログラム

Multitask MRI reconstruction models using diffusion models

Naoto Fujita[1], Yasuhiko Terada[1]

[1]Institute of Applied Physics, University of Tsukuba, Tsukuba, Japan

要旨：MRI における深層学習を用いた画像復元は，ノイズ除去，画像再構成，超解像など幅広い領域で応用が進んできた．しかし，各タスクに特化した深層学習モデルを別々に用意するのは，非効率かつ，サンプリング条件などのタスク由来の条件によって，テスト時の性能が低下する懸念がある．近年では，MRI の画像復元タスクでも拡散モデルの性能が高いことが報告されている．例えば画像再構成用の生成モデルは，学習時にタスク由来の情報を入れず，推論時に計測データとの整合を取りながらノイズ除去を繰り返し，目的画像の生成を行う．これまで報告された MRI 再構成拡散モデルは，ほとんどがシングルタスク向けであるが，マルチタスク問題にも応用可能であることが期待される．そこで本研究では，この生成時のデータ整合の強度を変更することで，マルチタスクに拡張できるかどうかを検証した．結果，MR 画像再構成，超解像のタスクにおいてモデルが有効に働くことを確認した．

キーワード：Deep Learning, Multitask MRI, 拡散モデル

1. はじめに

これまでに高速撮像下における MR 画像再構成を初めとして，ノイズ除去や超解像などの様々なタスクで深層学習（Deep Learning; DL）モデルの性能の高さが報告されてきた．しかし，現在使用される DL モデルの多くは，学習時に設定したタスクやサンプリング条件でのみしか適用することができず，ドメインシフトによる性能低下の危険性も報告されている[1, 2].

このような中，近年，生成 AI の一種である拡散モデルの性能と汎用性の高さが報告されている[3]．拡散モデルは MRI の様々な画像復元タスクにも使われている．拡散ベースの画像再構成モデルでは[4, 5]，拡散モデルを事前情報（prior knowledge）として使用し，学習時にはタスク由来の情報を入れず，生成時に計測データとの整合を取りながらノイズ除去を繰り返し，目的画像の生成が行われる．このため，追加学習なしに生成時に様々なタスクに対して応用できる可能性がある．しかし，これまで報告された MRI の画像復元問題における拡散モデルのほとんどはシングルタスク向けである．

そこで本研究では，拡散ベースの MRI 再構成モデルを，超解像やノイズ除去のタスクに拡張した，マルチタスク MRI 再構成モデルを提唱し，それぞれのタスクでモデルが有効に働くことを示すことを目的とした．

2. 理論

2.1 画像復元問題

一般に，multi-coil MRI の観測は以下のように定式化できる．

$$y = A_\Omega x + n \tag{1}$$

ここで，yは undersampled (US) k-space data，xは目的画像，$A_\Omega = FCM_\Omega$はエンコード演算子，nはノイズである．F は離散フーリエ演算子，C はコイル感度分布，M_Ωはサンプリング演算子（k 空間内のサンプリング領域をΩとし，Ω以外の領域は 0 で充填する）である．画像復元タスクは，yからxを推測するタスクである．ノイズ除去においてはΩを k-space の全体とした．

2.2 拡散モデルの生成過程とその制御

本研究では，マルチタスク拡散モデルの学習法として，学習時にサンプリング条件などを入れてモデルを学習させない，条件なし学習法を採用した．条件なしで学習された拡散モデルは，学習したデータドメインに属する画像を生成する生成器として機能する．このような条件なし生成の場合の生成過程は以下の式であらわされる．

$$x_t \leftarrow f_\theta(x_t, t) \tag{2}$$

この時，tは時刻，x_tは t における生成画像，f_θは θ をパラメタにもつ学習済みのノイズ除去モデルである．生成過程では，時刻 T から，t = 0 まで繰り返しノイズ除去を繰り返す．ただしx_Tは，標準正規分布に従って生成される乱数である．

目的画像の生成のためには，観測データ等によって生成制御（ガイダンス）を加える必要がある．Song ら[4]はこの生成過程に，計測データとの整合（Data Consistency; DC）の勾配（以下，勾配型ガイダンス）を加えることで CT 画像の再構成を行った．この条件付き生成過程を以下に示す．

$$x_t \leftarrow f_\theta(x_t, t) + \lambda A_\Omega^H(y - A_\Omega x_t) \tag{3}$$

ここで，λは，ガイダンス強度で，大きいほど生成画像が観測条件に強く束縛される．

更に，Chung ら[5]は，MRI の画像再構成に応用し，推測データの一部を計測データで置換するタイプの DC（以下置換型ガ

イダンス）（式 5）を併用した．

$$z_t \leftarrow f_\theta(x_t, t) + \lambda A_\Omega^H(y - Ax_t) \quad (4)$$

$$x_t \leftarrow A_\Omega^H(y + A_\Omega^H z_t) \quad (5)$$

このように，条件なし拡散生成モデルでは，生成時にタスクに特化したガイダンス戦略を適用させることが可能である．

2.3 マルチタスクへの応用のためのガイダンス戦略

本研究では，前節の拡散モデルの条件なし学習―条件付き生成法を，超解像およびノイズ除去タスクに拡張した．そのためには，(4)式および(5)式で示される勾配型ガイダンスと置換型ガイダンスの強度を調整する必要がある．そこで，本研究では，(4), (5)式を一般化した以下の式を導入した．

$$z_t \leftarrow f_\theta(x_t, t) + \lambda_1(t) A_\Omega^H(y - Ax_t) \quad (6)$$

$$x_t \leftarrow A_\Omega^H(\lambda_2(t) y + (1 - \lambda_2(t)) A_\Omega^H z_t + A_\Omega^H z_t) \quad (7)$$

ここで，$\lambda_1(t)$，$\lambda_2(t)$は，時刻 t におけるガイダンス強度である．

3. 実験方法

3.1 実施タスク

本研究では，提案手法に対し，６種類のタスクを実施した．

1. 高速撮像下の画像再構成（AF4）
2. 高速撮像下の画像再構成（AF8）
3. 超解像（x2）
4. 超解像（x3）
5. ノイズ除去（S.D. 5%）
6. ノイズ除去（S.D. 10%）

ここで AF は加速率，超解像における倍率は拡大率を示す．ノイズ除去における，S.D.は標準偏差で目的画像の最大強度の 5%あるいは 10%のノイズを加えた．1–4 では，$\lambda_1(t)$を 1 から 0.2 まで時刻ごとに線形に減衰させ，$\lambda_2(t) = 1$で一定とした．5, 6 のノイズ除去では，計測データ自体にノイズが乗っているため，5 では，$\lambda_1(t)$を 1 から 0.8，6 では 1 から 0.6 まで時刻ごとに線形に減衰させ，$\lambda_2(t) = 0$に設定した．

3.2 学習・評価条件

学習モデルは，Chang らの fastMRI データセット[6]による学習済みモデル（https://github.com/HJ-harry/score-MRI/tree/main）を使用した．学習条件の詳細については文献[5]を参照されたい．再構成性能の評価には，fastMRI データセットの学習に使用していないデータ 1 症例の中央 10 スライスを使用した．ガイダンスの設定のために，学習，テストともに使用していない 1 症例 1 スライスによるパラメタチューニングを行った．ネットワークの出力は，Peak signal-to-noise ratio (PSNR)によって，正解画像と比較することで評価した．

4 結果・考察

図 1 に各タスクの拡散モデルの再構成画像を示す．各画像再構成，超解像，ノイズ除去のタスクにおいて数値指標が高いことが確認できた．

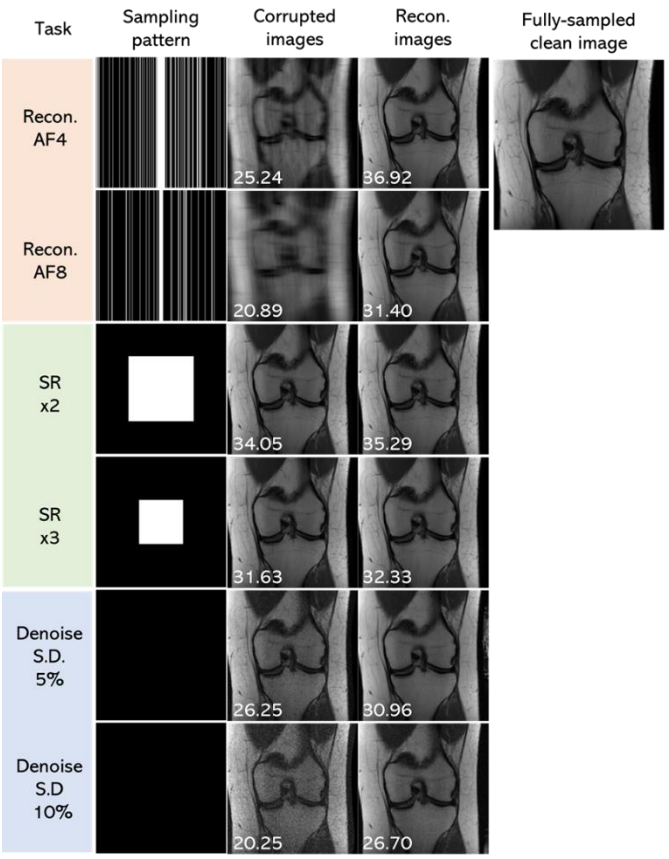


図 1 各タスクにおける拡散モデルの結果．左が使用したサンプリング領域，中央画像が入力画像，左が再構成画像．各画像左下に PSNR である．Recon.: Reconstruction, SR: SuperResolution.

5. まとめ

本研究により，拡散モデルが複数のタスクを同時に扱うことのできる可能性が示唆された．今後，DL を使用した手法を含めた各タスクにおけるモデルとの比較を行っていく．

利益相反の有無

本研究は富士フイルム株式会社の助成を受け実施された．

文　献

1. Hammernik K, Schlemper J, Qin C, et al (2021) Systematic evaluation of iterative deep neural networks for fast parallel MRI reconstruction with sensitivity-weighted coil combination. Magn Reson Med 86:1859–1872
2. Fujita N, Yokosawa S, Shirai T, Terada Y (2023) Numerical and Clinical Evaluation of the Robustness of Open-source Networks for Parallel MR Imaging Reconstruction. Magn Reson Med Sci.
3. Dhariwal P, Nichol A (2021) Diffusion models beat gans on image synthesis. Adv Neural Inf Process Syst 34:8780–8794
4. Song Y, Shen L, Xing L, Ermon S (2022) Solving Inverse Problems in Medical Imaging with Score-Based Generative Models. In: International Conference on Learning Representations
5. Chung H, Ye JC (2022) Score-based diffusion models for accelerated MRI. Med Image Anal 102479
6. Knoll F, Zbontar J, Sriram A, et al (2020) fastMRI: A publicly available raw k-space and DICOM dataset of knee images for accelerated MR image reconstruction using machine learning. Radiol Artif Intell 2:e190007

Swin Transformer を利用した MR 深層学習再構成における学習スケジュールと画質の関連

中鉢 史也[*1]，佐藤 裕貴[*2]，山登 一輝[*3]，伊藤 聡志[*4]

[*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

Relationship between Training Schedule and Obtained Image Quality in MR Deep Learning-based Reconstruction Using Swin Transformer

Fumiya CHUBACHI[*1]，Yuki SATO[*2]，Kazuki YAMATO[*1] ，Satoshi ITO[*1]

[*1] *Graduate Program in Information, Electrical and Electronic Systems Engineering, Utsunomiya University*

要旨：これまで画像処理分野では畳み込みニューラルネットワーク(Convolutional Neural Network ; CNN) が深層学習の標準的な方法として使用されてきた．一方，Attention と呼ばれる新しい情報処理機構を備えた Transformer が自然言語処理(NLP) において成功を収め，画像処理でも応用されている． MRI の圧縮センシング再構成に対しては Swin Transformer が提案されている．Swin Transformer は，学習の特徴が CNN と異なり，その性能と学習パラメータの関係が明らかになっていない．そこで，本研究では，学習スケジュールを変更することで，再構成性能との関連を調査した．その結果，CosineLR への Warmup 導入手法により高い性能が取得されたので報告する．また，ネットワーク構造の変更によりさらなる再構成性能を得たので報告する．

キーワード：MRI，深層学習，画像再構成，学習スケジュール，Swin Transformer

1. はじめに

MRI の撮像高速化法として圧縮センシングの応用が実用化され, データ駆動型の画像再構成法として深層学習が注目されている．画像処理分野の深層学習では，これまで畳み込みニューラルネットワーク(Convolutional Neural Network: CNN)が多く使用されてきた．一方，画像の近傍領域との畳み込みを基本とせず, Attention と呼ばれる新しい情報処理機構のみによって構成される Transformer[1]が画像処理分野で大きな注目を集めている. 画像処理向けには Vision Transformer[2]が知られており，その改良版である Swin Transformer[3]も開発されている．Transformer は CNN 等と比較して，その構造やパラメータが一般に煩雑であり, 最適な学習率や学習スケジュールは未だ明確にされていない．そこで，Swin Transformer を用いた MR 画像再構成における学習スケジュールと再構成画質の関係を明らかとするために学習率スケジューラの比較を行った. その結果, 良質な画像が得られるスケジューラを得ることができた. また, ネットワーク構造の改良により性能向上の可能性が示された.

2. SwinMR

本研究では MR 画像用 Swin Transformer である SwinMR[4]を使用し, 学習スケジュールと再構成画質の関係を明らかにする．図 1(a)に示す SwinMR は Residual Swin Transformer Block(RSTB)と畳み込み層(Conv2d)で構成される．RSTB の内部構造を図 2 に示す．RSTB は主に Swin Transformer Layer(STL) の積み重ねで構成され, 入力特徴マップをパッチごとにベクトルに埋め込んだパッチ特徴量が STL に入力される．STL は Layer Normalization，(S)W-MSA，MLP，そして 2 つの残差接続を含む層である．(S)W-MSA は(Shifted) Window based Multihead Self Attention を指し，Window 単位に分割された画像に対してデータ内の照応関係を表す Attention の計算を行う．その際，通常の W-MSA と Window の位置をシフトされた SW-MSA を交互に行うことで効率的に画像全体を学習する．その後，ベクトルの逆変換と畳み込み層，残差接続を経て RSTB の最終的な出力を得る．RSTB を経た後は特徴の調整を行う畳み込み層と残差接続, アップサンプリングを通じて再構成画像が出力される．

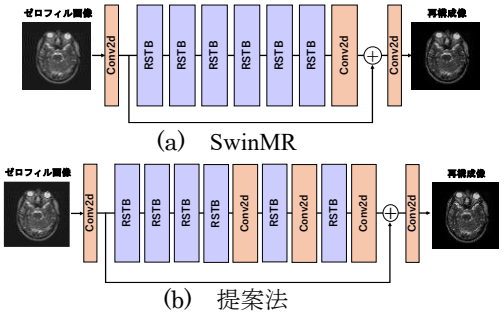


図 1 ネットワーク構成

また, 提案法として, もとの SwinMR のネットワーク後半部に対し，図 1(b)のように RSTB と 2 層の畳み込み層を交互に配置したネットワークも使用した.

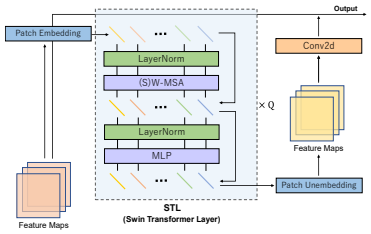


図 2 RSTB の内部構造

3. 学習スケジューラ

使用スケジューラは MultiStepLR(MSLR), CosineLR(CosLR), CosineAnnealingLR(CosALR)の 3 種類であり，その推移グラフを図 4 に示す．MultiStepLR と CosineLR には学習の初期段階で小さな学習率から徐々に学習率を上昇させる Warmup も適用する．Warmup 無の場合を 1，有の場合を 2 とした．

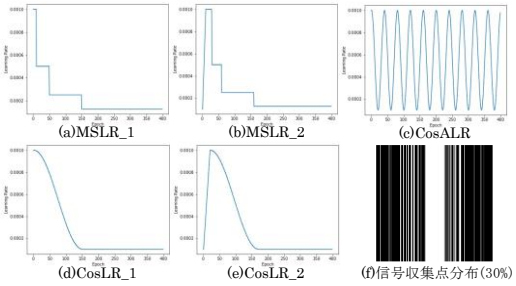


図 3　学習率スケジューラと信号収集点分布

表 1　学習時間

MSLR_2	CosLR_2
1d 6h 44m(233 エポック)	18h 57m(142 エポック)

4. 再構成実験

本研究では，IXI Dataset [5]に含まれる健常ボランティアの T2 強調像を学習用に 500 枚，検証用に 100 枚，テスト用に 100 枚使用した．また，信号の間引き処理は図 3(f)に示した信号収集率 30%，中心連続行数 40 行の信号集収集点分布に従って行った．再構成画像の定量的評価には PSNR を使用した．本実験では Early Stopping を実装しており，学習時に測定する PSNR が 15 エポック向上しない場合，学習を終了する仕様とした．PSNR の結果を図 5 に，再構成画像とその拡大像を図 6 に示す．また，Warmup を適用した場合の学習時間とベストモデルを記録したエポック数を表 1 に示す．

図 5 より，MSLR_2 と CosLR_2 の PSNR が 32dB 以上となり， CosLR_2 が最高値を記録した．図 6 に示すように，再構成画像を Warmup の有無で比較すると，Warmup 無ではアーティファクトの残留が確認されるが，Warmup 有の (c)，(f)は高品質な再構成画像が得られている．(c), (f)の拡大像である(i), (l)を比較すると，赤枠で示した箇所において CosLR_2 がより高精度で構造を復元していることを確認した．Warmup を導入したスケジューラを用いることで再構成性能が向上したことから，SwinMR は学習初期において小さな学習率が適していることが分かる．これは，Transformer が他のネットワークと比較してパラメータの数が多く，局所最適解を多数持つため，学習の初期段階を小さな学習率から開始することによって早期に学習が収束することを防ぎ，最適な解へ収束したと考える．また，Warmup は学習の安定性を必要とする Early Stopping とも相性が良いことが考えられる．さらに，表 1 の学習時間より，高画質となった 2 つのスケジューラの比較において，CosLR_2 の方が学習の収束が早いことが確認できた．よって，SwinMR には急激に学習率が減少する MultiStepLR より滑らかに学習率を減少させる CosineLR が適していると言える．これは，学習率の変化が緩やかであることによって学習に安定性がもたらされ，最適な解への収束が早まったためであると考える．また，図 1(b)に示す提案法にスケジューラ CosLR_2 を使用して再構成を行ったところ，図 5 より，PSNR は 0.12dB 上昇しており，再構成性能が向上していることが確認できる．これは，異なる特徴抽出方法の組み合わせによってより効果的に画像情報を捉え，学習能力が向上したためと考えられる．

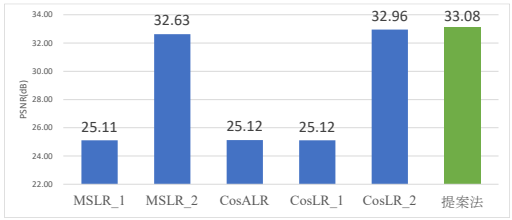


図 4　PSNR の平均値［dB］

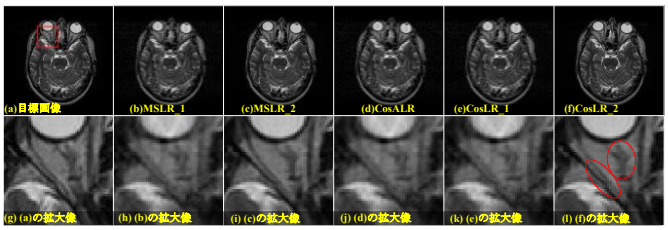


図 5　再構成画像

5. まとめ

本研究では，MR 画像再構成において学習スケジューラと Swin Transoformer の関係を明らかにすることを目的に複数のスケジューラの比較を行った．実験結果から，Warmup を適用した CosineLR が最も高画質なった．また，ネットワーク後半部において畳み込み層を RSTB の間に入れ込むことで性能が向上する可能性が示された．

謝辞

本研究の一部は，科研費(23K03864)，医科学応用財団，萩原科学技術財団の助成を受けて行われた．MR 画像を提供いただいた Information eXtraction from Images に感謝の意を表します．

利益相反の有無

なし

文　献

［1］ A.Vaswani, N.Shazeer et al.: Attention is all you need. Advances in neural information processing systems, pp.5998 – 6008, 2017.

［2］ A.DosoViTskiy, L.Beyer et al.: An image is worth 16x16 words: Transformers for image recognition at scale. In International Conference on Learning Representations, 2021.

［3］ Z.Liu, Y.Lin et al.: Swin Transformer: Hierarchical vision Transformer using shifted windows. Proceedings of the IEEE/CVF international conference on computer vision, pp.10012-10022, 2021.

［4］ J.Huang, Y.Fang et al.: Swin transformer for fast MRI. Neurocomputing vol.493, pp.281-304, 2022.

［5］ IXI Dataset, https://brain-development.org/ixi-dataset/

等間隔な信号間引き収集を可能とする MR 撮像法と再構成法

足立 虎太郎[*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

MR Imaging and Reconstruction Methods Using Equally Spaced Under-sampled Signal

Kotaro ADACHI[*1]，Satoshi ITO[*1]

[*1] *Utsunomiya University, Graduate Program in Information, Electrical and Electronic Systems Engineering*

要旨：圧縮センシングの MRI 応用では，一般に信号空間をランダムに間引く方法が取られる．ランダム間引きに比べて等間隔間引きは画像の“ぼけ”が少ない利点があるが，折り返しアーチファクトに周期性が強く現れることから画像再構成は困難であった．深層学習の利用により等間隔サンプリングによる画像再構成が可能となってきているが，折り返し像の分離目的と信号エネルギーの集中度から信号空間の原点付近は連続収集する方式が一般的である．本研究では，被写体が実関数のときであっても等間隔間引き収集による画像再構成を可能にする新たな撮像法と再構成法を提案する．本法によれば，高分解能な画像をより少数の信号で再構成できる可能性がある．信号取得時に振幅変調を与え，画像再構成に深層学習を利用する方式により，実関数画像の場合に 4 倍速まで画像再構成に成功した．

キーワード： 圧縮センシング MRI，等間隔間引き法，位相変調，深層学習，画像再構成法

1. はじめに

圧縮センシング (Compressed Sensing : CS) を MRI に応用し，撮像を高速化する研究が進められている [1]．一般に CS-MRI を応用する場合に，信号はランダム収集が採用され，規則的な間引き収集を行う場合でも中央付近を連続で収集する方法が採用されてきた [2]．実関数画像の場合に等間隔に信号を間引くと再生像に折り返しアーチファクトが発生するので，単一の受信コイルでは折り返し像の分離は理論的に困難であった．一方で，等間隔間引きでは再生される像に“ぼけ”が生じないため高い品質の画像再構成が期待できる．本研究では，再生像の位相を変調するパルスと深層学習の利用により，等間隔間引き収集の場合でも画像再構成が可能な方法を提案し，再構成性能の改善効果を明らかにすることを目的とする．

2. 位相変調を与えた等間隔サンプリング

汎用のフーリエ変換映像のパルスシーケンスの位相エンコード勾配磁界の前に y 方向の磁界G_{y1}を印加し，位相変調を与える．この時のパルスシーケンスを図 1 に示す．この場合に緩和項を省略した MR 信号は式(1)で表される．ここで，$\rho(x,y)$ はスピン密度分布，k_x，k_yは空間周波数である．

$$v(k_x,k_y)=\iint_{-\infty}^{\infty}\{\rho(x,y)e^{-jk_m y}\}e^{-j(k_x x+k_y y)}dxdy \qquad (1)$$

k_mはG_{y1}により与えられる位相変調の係数であり，画像のデータ数 n で正規化すると $k_m=\pi d/n$ $(-n\le d\le n)$ となる．式(1)を逆フーリエ変換し，位相復調処理を行うことにより式(2)の再構成像が得られる．

$$\rho(x,y)=e^{jk_m y}\mathrm{IFT}\left[v(k_x,k_y)\right] \qquad (2)$$

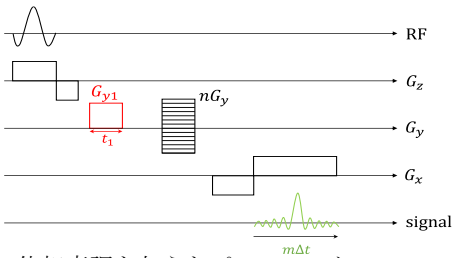


図 1. 位相変調を与えたパルスシーケンス

ここで，信号空間において位相エンコード方向にs点毎に収集する信号間引きを考える．この場合に連続式を用いて式(2)を表現すると式(3)のようになる．

$$\rho(m,n)+\rho\left(m,\left(n\mp 1\frac{N}{s}\right)\right)e^{\pm j\left(\frac{d}{s}\right)\pi}+\rho\left(m,\left(n\mp 2\frac{N}{s}\right)\right)e^{\pm j\left(2\frac{d}{s}\right)\pi}+\cdots$$

$$+\rho\left(m,\left(n\mp p\frac{N}{s}\right)\right)e^{\pm j\left(p\frac{d}{s}\right)\pi}+\cdots \qquad (3)$$

式(3)において，p は自然数であり，第 2 項目以降は折り返し像を表している．このとき再生像の折り返し像には，$\pi d/s$（$s=2,3,4,5$）の位相が与えられる．この時の折り返し像の位置と位相を図 2 に示す．図 2 より，d/s が整数の場合，虚部の信号は 0 となり，実部のみの表現となるため画像の分離は不可能である．一方，d/s が整数でない場合は実部と虚部で表現され画像の重なりが部分的に解消されるため画像の分離可能性が生じる．得られた画像を CNN に入力し，フルデータ再構成画像を教師画像として学習を行う．ネットワークの学習には

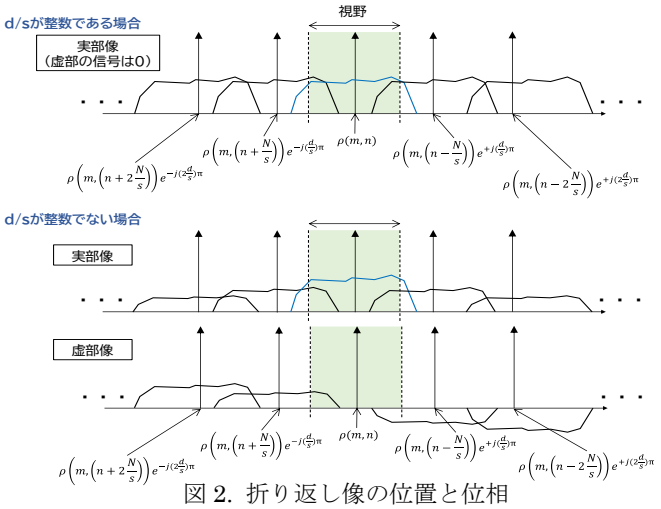


図 2. 折り返し像の位置と位相

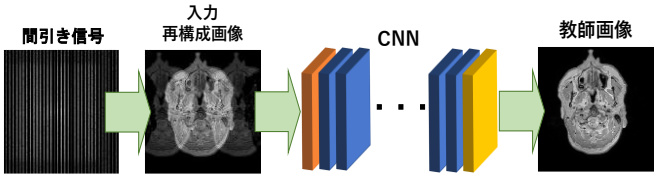


図 3. U-Net を使用した学習と再構成

U-Net を基本構造とした CNN を用いた．処理の流れを図 3 に示す．

4. 再構成実験

本研究では U-Net の学習に IXI データセット[3] のプロトン密度強調画像（256×256）を使用した．学習画像は 250 枚，検証画像は 50 枚，テスト画像は 100 枚を使用し，信号収集点分布は信号収集率 20%, 25%, 33%, 50%の等間隔間引き収集分布を使用した．それぞれの信号収集率において位相変調係数 d を 0 から 15 まで 0.5 ずつ変化させた．位相変調係数 d と PSNR の関係を図 4 に，各信号収集率において PSNR 最大値と最大値を与える d の値を表 1 に示す．また，信号収集率 33%における FT 再構成像の実部と虚部を図 5 に，再構成結果を図 6 に示す．図 6(d) は (a) と (b) の誤差画像，(h) は (a) と (f) の誤差画像である．各信号収集率で $d = 0$ の 場合は，本法を使用しない一般の撮像の場合（従来法）である．図 4 より，すべての収集率において PSNR は周期的な変化をしている．これは位相変調により実部像と虚部像の割合が周期的に変化するためである．信号の間引き率 s が大きい場合，すなわち信号収集率が小さい場合に, PSNR の周期が長くなる傾向がある．また，位相変調を導入しない従来法に比べて顕著に PSNR を改善することができた．

5. おわりに

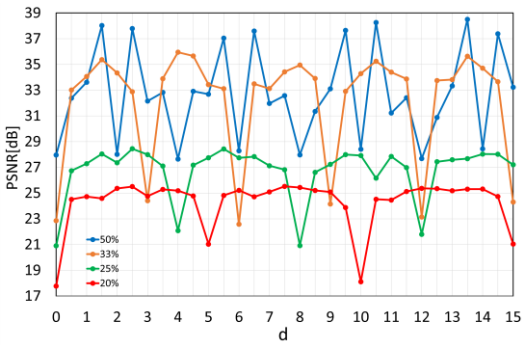


図 4. 位相変調係数 d と PSNR の関係

表 1. PSNR 最大値/d 値

	20%	25%	33%	50%
提案法	25.52 / 7.5	28.45 / 9.5	35.95 / 4	38.5 / 13.5
従来法	17.78 / 0	20.91 / 0	22.86 / 0	27.96 / 0

圧縮センシング MRI において等間隔な信号収集点分布による画像再構成法の可能性について検討した．その結果，撮像時に位相変調を与えるパルスの導入により画像再構成の可能性と画質改善の可能性が示された．今後は，さらに位相を含んだ画像について検討を行う予定である．

謝辞

本研究の一部は，科研費(23K03864)，萩原学術振興財団，医科学応用財団の研究助成を受けて行われた． 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., IEEE Signal Processing Magazine, Vol.25, pp.72-82, 2008.
[2] CM. Hyun et al., Phys Med Biol, Vol.63, 135007, 2018.
[3] IXIdataset, https://brain-development.org/ixi-dataset/

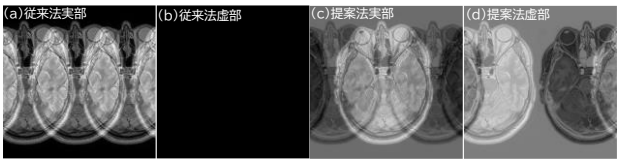


図 5. FT 再構成像の実部と虚部（CNN 入力像）

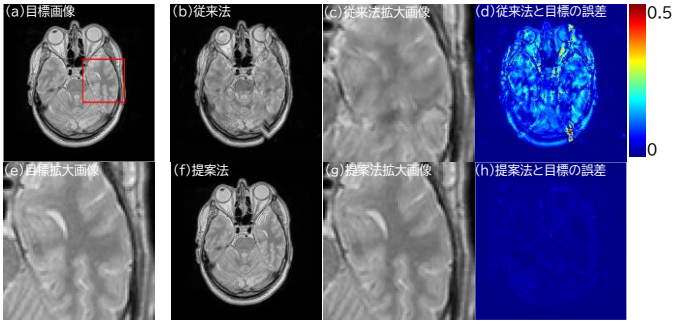


図 6. 収集率 33%における再構成画像と誤差画像

低周波数帯域から順に推定を行う 多段接続型 CNN による MR 画像再構成法の構造に関する検討

大内　翔平[*1]，伊藤　聡志[*2]
[*1] 小山工業高等専門学校　電気電子創造工学科
[*2] 宇都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム

Study on MR image reconstruction using cascaded CNNs with sequential expansion of the estimated frequency bandwidth

Shohei OUCHI[*1]，Satoshi ITO[*2]
[*1] *National Institute of Technology, Oyama College*
[*2] *Graduate Program in Information, Electrical and Electronic Systems Engineering, Utsunomiya University*

要旨：MRI の撮像時間を短縮する目的で，少数の信号から画像を再構成する方法が提案されている．再構成法として，近年では深層学習を用いる方法が数多く提案されており，これらの多くは MR 信号の低周波数帯域を良好に推定できるものの，画像の鮮鋭さを担う高周波数帯域の推定に改善の余地がある．上記の課題を解決するため，我々は，推定対象とする周波数帯域を数段階に分割して，複数の CNN を用いて低周波数帯域から順に推定を行う方法を提案し，昨年度の SAMIT で報告した．本研究では，提案手法における周波数帯域の分割数や，使用する CNN 等の基本構造について検討を行い，さらなる画質改善を図った．再構成シミュレーションの結果，PSNR の向上が確認できたので結果を報告する．
キーワード：画像再構成，深層学習，圧縮センシング

1. はじめに

MRI(Magnetic Resonance Imaging)では，撮像に多くの時間を要するため，MR 信号の収集量を削減して，少数の信号から画像を再構成する方法が提案されている．再構成法として，信号回復理論である圧縮センシング(Compressed Sensing:CS)[1][2]を応用した反復的な再構成法[3]が提案されているが，近年では CNN を導入した再構成法である CNN-CS に主流が置き換わりつつある．CNN-CS では，従来の反復的再構成法と比較して，多様な間引きパターンに頑健かつ高品質な再構成を高速に行える利点を持つが，再構成像の鮮鋭さを担う MR 信号の高周波数成分の復元性能においては，改良の余地がある．我々は，CNN-CS における上記課題の解決に向け，多段接続型の CNN を使用して推定対象の周波数帯域を段階的に拡大する新たな再構成法を提案し，その初期段階の成果を昨年度の SAMIT2023 にて報告した[4]．通常の U-Net[5]による再構成法と比較して，提案手法では明瞭な再構成が行えたが，細部構造の復元性能においては課題が残る結果となった．本研究では，さらなる画質改善を図るため，推定する周波数帯域の分割数の検討および，Unrolling 型 CNN-CS への提案手法の導入について検討したので，これらの結果を報告する．

2. 多段接続型 CNN-CS による再構成法の概要

本研究で基本とする多段接続型 CNN による再構成法（以下，提案手法とする）では，MR 信号空間を任意の大きさで切り出し，切り出した信号の逆フーリエ変換像を利用して再構成を行う．提案手法の概要図を図 1 に示す．切り出し処理は，MR 信号空間の中心部のみが対象となる小領域から始めて，次第に外周部を含む大領域へと拡大する．切り出した信号空間の数と多段接続する CNN の段数は一致しており，それぞれの大きさの MR 信号空間から得た画像を，対応する CNN で再構成することで，前段に近い CNN は主に低周波数成分を対象とした再構成を，後段に近い CNN は高周波数成分を含んだ領域を対象とした再構成を行う．MR 信号空間の間引き収集を行う際は，低周波数成分を間引かず連続に，高周波数成分をランダムに間引くことが一般的である．そのため，低周波数成分に近い領域の方が CNN による再構成が比較的容易に行える．また，２段目以降の CNN に画像を入力する際は，図 1 のように前段で復元済みの信号を代入するため，各 CNN は未復元の周波数帯域の推定に集中できる．提案手法では，CNN の多段接続数とそれに応じた周波数帯域の分割数を任意に変更可能である．また，提案手法自体を適用する CNN も任意に選択可能である．

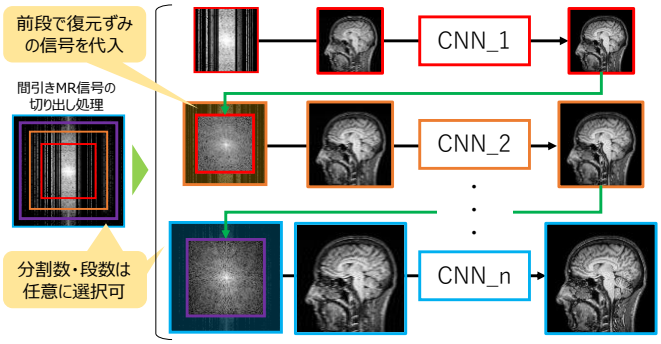


図 1. 多段接続型 CNN-CS の概要図

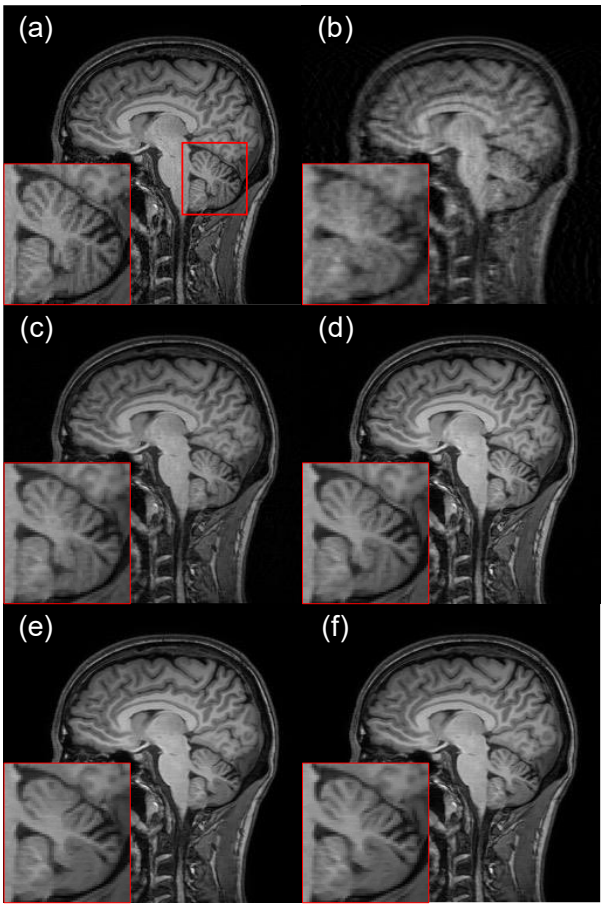


図 2. 信号量 30%による再構成像 (a)フルデータ像，(b)間引き再生像，(c)Single U-Net, (d)Cascade U-Net 3, (e)Single ISTA, (f)Cascade ISTA 3，各図の左下は拡大画像

表 1. 信号量 30%における再構成像の平均 PSNR[dB]

Single U-Net	Cascade U-Net 2	Cascade U-Net 3
30.45	30.85	30.86
Cascade U-Net 4	Single ISTA	Cascade ISTA 3
31.03	30.58	30.80

これまでの検討では，分割数は低・中・高周波数領域を想定した 3 分割を，CNN は U-Net を基本とした画像空間で再構成が完結する End-to-end 型を採用していた．本研究では，分割数の変更，および Unrolling 型 CNN として ISTA-Net+[6]に提案手法を導入した場合について，再構成シミュレーションを行った．

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

本研究では，SIMON dataset[7][8]に含まれる T1 強調像を，学習用に 1000 枚，テスト用に 50 枚使用した．

2) 使用した手法について

本研究では，提案手法による再構成像の品質を検討するため，単一の U-Net, ISTA-Net+で全周波数帯域を一度に再構成する CNN-CS（以下，Single U-Net および Single ISTA）を比較手法として使用した．また，提案手法を採用した U-Net による手法を Cascade U-Net, 提案手法を採用した ISTA-Net+による手法を Cascade ISTA とする．分割数については，それぞれの名称につづけて数字で表記する．

3) 再構成シミュレーションの結果と考察

信号収集量 30%における各手法での再構成像を図 2 に，再構成像の平均 PSNR を表 1 に示す．図 2 より，間引き再生像に生じたアーチファクトは，いずれの手法でも除去できた．また，(c)と(e)の Single よりも，(d)と(f)の Cascade の方が小脳をはじめとした細部の構造を鮮鋭に復元できた．表 1 に示す各手法の平均 PSNR からは，Cascade の方が高い PSNR を示すこと，特に U-Net においてその傾向が顕著であることが確認できる．また，分割数の変更により，PSNR の向上が確認できた．分割数の調整により，各周波数帯域を細かく分割して再構成することで，復元性能が向上したと考える．

4. まとめ

多段接続した CNN を利用して低周波数帯域から順に推定を行う CNN-CS について，周波数帯域の分割数の検討により画像品質が向上すること，Unrolling 型の CNN にも本手法が適用可能であることが明らかとなった．

謝辞

本研究の一部は令和 5 年度小山工業高等専門学校萌芽的研究支援，JSPS 科研費 23K20013, 23K03864 の助成により実施されました．

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］大内翔平，SAMIT2023, OP4-6, 63-64, 2023
［5］Ronneberger O, Fischer P, Brox T, Medical Image Computing and Computer-Assisted Intervention, Munich, Germany, 2015, 234-241
［6］Zhang J, Ghanem B, IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2018, pp.1828‐1837
［7］Duchesne S, Chouinard I, Potvin O et al., J Magn Reson Imaging 49: 456-465, 2019
［8］SIMON Dataset. https://fcon_1000.projects.nitrc.org/indi/retro/SIMON.html

位相拡散フーリエ変換法と多空間型 ADMM-CSNet による CS-MRI 再構成の性能改善

山登　一輝[*1]，伊藤　聡志[*2]
[*1] 宇都宮大学 工学部 基盤工学科
[*2] 宇都宮大学大学院 地域創生科学研究科 情報電気電子システム工学プログラム

Improvement of CS-MRI reconstruction using phase-scrambling Fourier transform and multi-domain ADMM-CSNet

Kazuki Yamato and Satoshi Ito
[*1] *Department of Fundamental Engineering, School of Engineering, Utsunomiya University*
[*2] *Graduate Program in Information, Electrical and Electronic System Engineering, Utsunomiya university*

要旨：圧縮センシング MRI(CS-MRI)は MRI の高速化手法の一つである．近年，深層学習を用いた CS-MRI が主流となり，再構成画像の品質が著しく向上している．先行研究では，等間隔に間引き収集された位相拡散フーリエ変換法(PSFT)の信号を，ADMM-CSNet を用いて再構成を行った．しかし，特に位相を含む複素数画像において再構成画像に平滑化や残留アーティファクトが生じる問題があった．本研究では，PSFT 信号を用いた多空間学習を導入した ADMM-CSNet を提案する．提案手法は，ADMM-CSNet に k 空間畳み込み層の追加，および k 空間と画像空間の畳み込み層の増設を行う．複素数画像を用いた実験を行ったところ，提案手法による再構成画像の PSNR が，既存の ADMM-CSNet よりも 1dB 向上し，再構成画像は，平滑化や残留アーティファクトが低減され，詳細構造の再構成性能も改善した．

キーワード：圧縮センシング，MRI，画像再構成，深層学習

1. はじめに

MRI は，同様の生体断面撮像装置である X 線 CT と比較し，コントラストに優れるが，撮像に長時間を要する．そのため，MRI の撮像高速化は重要課題である．少数の観測信号から元データを復元できる圧縮センシング(Compressed Sensing: CS)[1]を MRI に応用した CS-MRI は，CS の原理に従って収集した間引き信号から画像再構成を可能とする[2]. CS-MRI の高画質化手法として，MRI で汎用的に使用されるフーリエ変換法(Fourier Transform imaging: FT)に 2 次の位相変調を付与した位相拡散フーリエ変換法(Phase-Scrambling Fourier Transform imaging: PSFT)の利用がある[3]. PSFT の信号式に含まれる 2 次の位相変調項は画像再構成の際に誤差を拡散する効果があり，FT に CS を応用するよりも高画質な再構成像が得られることが報告されている．また，PSFT 信号に深層学習再構成法を適用する研究も行われ，さらなる高画質化が示唆されている．しかしながら，位相変化を含む複素数画像の再構成については検討が不十分であった．本研究では，PSFT を用いた深層学習再構成法を複素数画像に適用し，再構成像に生じるアーティファクトの軽減，および高画質化を図る．本稿では，CS 最適化アルゴリズムの一手法である交互方向乗数法(Alternating Direction Method of Multipliers: ADMM)を深層学習として構成した ADMM-CSNet[4]に対して信号空間の畳み込み演算を加えた Dual Domain(DD)-ADMM-Net を提案した．DD-ADMM-Net の有効性を確認するための実験を行ったところ，ADMM-CSNet を使用した再構成結果を上回ることが確認されたので，報告する．

2. 位相拡散フーリエ変換法

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．

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

ここで，$\rho(x,y)$は xy 平面のスピン密度分布，c は二次の位相変調の係数である．式(1)に示すように，二次の位相変調を付与したスピン密度関数のフーリエ変換として表せる．PSFT 信号 $v(k_x,k_y)$からの画像再構成は，$v(k_x,k_y)$に逆フーリエ変換F^{-1}を適用し，二次の位相変調の複素共役を付与することで，以下のように実現できる．

$$\rho(x,y)=e^{jc(x^2+y^2)}F^{-1}[v(k_x,k_y)] \quad (2)$$

3. DD-ADMM-Net

本研究では，近接分離に基づく凸最適化手法の一種である ADMM の演算ステップを深層学習ネットワークとして構成した ADMM-CSNet に対して，PSFT 信号を入力できるように再構成層を改善し．雑音除去層に信号空間畳み込みの追加と畳み込み層の増設を行った．図 1 に DD-ADMM-Net のネットワーク構成を，各層の処理を以下に示す．

$$X^{(n)}:\rho^{(n)}=S^*F^T\frac{P^Ty+rFS(z^{(n-1)}-\beta^{(n-1)})}{P^TP+rI} \quad (3)$$

$$Z^{(n)}:z^{(n)}=\mu_1\{(\rho^{(n)}+\beta^{(n-1)})-D_{ICNN}(\rho^{(n)}+\beta^{(n-1)})\}+\mu_2D_{kCNN}(\rho^{(n)}) \quad (4)$$

$$M^{(n)}:\beta^{(n)}=\beta^{(n-1)}+\eta(\rho^{(n)}-z^{(n)}) \quad (5)$$

ここで，$S=e^{-jc(x^2+y^2)}$は二次の位相変調，S^*はSの複素共役，Fはフーリエ変換，Pはサンプリングマスク，yは観測信号，D_{ICNN}，D_{kCNN}は画像空間および信号空間の畳み込みに演算である．r，μ_1，μ_2，ηは DD-ADMM-Net によって学習される重み

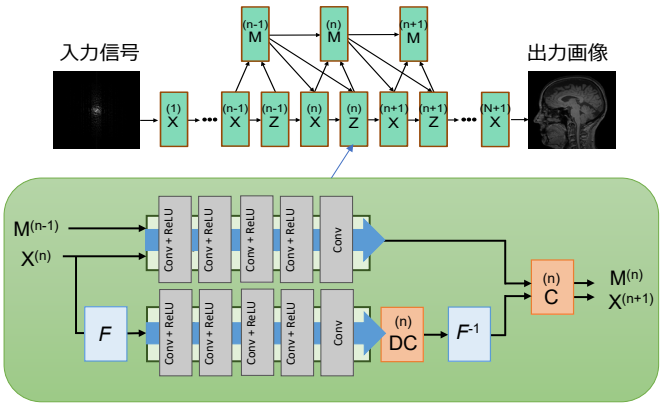


図 1 DD-ADMM-Net のネットワーク構成

表 1 学習時間と再構成時間

	DD-ADMM-Net	ADMM-CSNet
学習時間[min]	20.69	23.49
再構成時間[ms]	59.6 ± 2.7	36.3 ± 0.8

パラメータである．図 1 において，n番目の各層は ADMM によるn回目の反復処理に相当し，$X^{(n)}$は再構成層，$Z^{(n)}$は雑音除去層，$M^{(n)}$は乗数更新層である．また，$Z^{(n)}$は画像空間および信号空間の複数回の畳み込み層，信号空間のデータコンシステンシー層$DC^{(n)}$，特徴結合層$C^{(n)}$から成る．図 1 に示す DD-ADMM-Net へ，信号空間上で間引いた PSFT 信号を入力することで，各層の処理を繰り返し，最後の再構成層$X^{(n+1)}$により再構成像が得られる．

4. 画像再構成シミュレーション

Canon Medical Systems 社製 MRI(3T)により撮像された，位相変化を含む頭部 T2 強調像(256×256 pixel)70 枚を，学習に 50 枚使用し，残りをテスト用とした．本実験において PSFT 信号の生成は，計算機内で使用画像に二次の位相変調を付与し，フーリエ変換することで行った．本実験では，FT 信号の収集にはランダム収集(図 2(k))，PSFT 信号の収集には等間隔収集(図 2(l))を行い，信号収集率は 33%とした．再構成像の画質評価には Peak Signal-to-Noise Ratio (PSNR)と Structural Similarity Index Measure (SSIM)[5]を用いた．計算機環境は，Intel(R) Core(TM) i7-12700(2.1GHz)，32GB RAM，NVIDIA GeForce RTX 3080 GPU であり，使用ソフトウェアには，Python 3.9.5，PyTorch 2.1.1，CUDA Toolkit 12.1 を用いた．以上の環境で学習および再構成に要した時間を表 1 に示す．

間引き FT 信号から ADMM-CSNet および DD-ADMM-Net による再構成像を比較すると，図 2(g)，(h)のから，DD-ADMM-Net による再構成像 ADMM-CSNet よりも詳細構造を復元できている．間引き PSFT 信号から再構成した像を比較すると，図 2(i)，(j)より，PSFT 信号を用いた場合も DD-ADMM-Net は ADMM-CSNet よりも詳細構造を復元されている．以上より，DD-ADMM-Net は信号の種類にかかわらず画像再構成に有効である．また，表 2 に示す定量評価結果から，間引き PSFT 信号を DD-ADMM-Net で再構成した画像の PSNR，SSIM が最大となった．

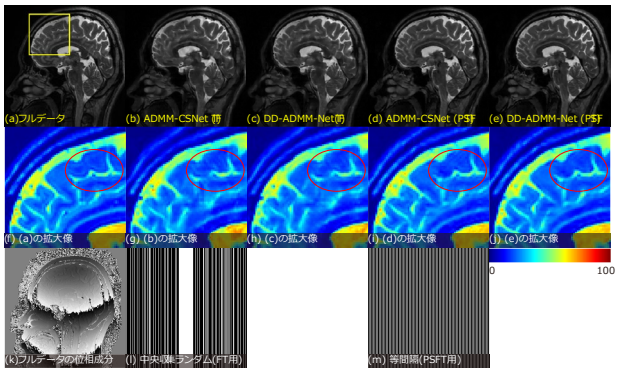


図 2 再構成像とサンプリングパターン

表 2 再構成像の PSNR と SSIM

	PSNR[dB]	SSIM
ADMM-CSNet(FT)	30.16 ± 0.99	0.953 ± 0.005
DD-ADMM-Net(FT)	30.65 ± 1.06	0.955 ± 0.006
ADMM-CSNet (PSFT)	34.14 ± 0.74	0.978 ± 0.003
DD-ADMM-Net(PSFT)	$\mathbf{34.79 \pm 0.73}$	$\mathbf{0.981 \pm 0.002}$

以上の結果から，DD-ADMM-Net は信号の種類によらず ADMM-CSNet よりも高い再構成性能を示した．本稿では，位相成分を含む複素数画像を使用したため，信号空間での畳み込みによる特徴抽出に効果があったと考える．また，PSFT 信号の場合，CS の条件であるインコヒーレント性を満たさない等間隔収集でも画像再構成が行えた．これは，PSFT 信号が二次位相変調により信号空間上で広域に分布するため，信号のインコヒーレント性が増加するためであると考える．さらに,等間隔収集は信号の高域成分も収集できるため，詳細構造の復元に寄与できたと考える．

6. おわりに

本稿では，Generic-ADMM-Net に信号空間畳み込みを加えた DD-ADMM-Net を提案した．シミュレーション実験から，DD-ADMM-Net は FT 信号，PSFT 信号の両方に有効であることが確認された．特に，PSFT 信号に適用した場合は FT 信号からの再構成よりも詳細構造の再現性に優れた再構成像を得ることができた．

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] Donoho D.: Compressed sensing. IEEE TIT, vol.52, no.4, pp.1289-1306, 2006.

[2] Lustig M., et al.: Compressed sensing mri. IEEE Signal Process Mag. Vol.25, issue 2, pp.72-82, 2008.

[3] Maudsley A.: Dynamic range improvement in NMR imaging using phase scrambling, J. Mag. Res., vol.76, no.2, pp.287-305, 1988.

[4] Yang Y., et al.: Admm-csnet: a deep learning approach for image compressive sensing. IEEE TPAMI, vol.42, issue 3, pp.521-538, 2020.

[5] Wang Z. et al.: Image quality assessment: from error visibility to structural similarity, IEEE TIP, vol.13, no.4, pp.600-612, 2004.

位相拡散フーリエ変換法を使用した CS-MRI と超解像の併用による深層学習再構成像の高画質化

松浦 毅弥[*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 工農総合科学専攻 情報電気電子システム工学

Improvement of Deep Learning-based Image Reconstruction by Combining CS-MRI and Super-resolution in Phase-scrambling Fourier Transform Imaging

Takaya MATTSUURA [*1]，Kazuki YAMATO[*1]，Satoshi ITO[*1]

[*1] *Graduate Program in Information, Electrical and Electronic Systems Engineering, Utsunomiya University*

要旨：MRI の撮像時間を短縮するための圧縮センシング応用 MRI(CS-MRI)では，再構成法からの品質改善法として深層学習再構成が注目されている．撮像法からの品質改善法として位相拡散フーリエ変換法（PSFT）の利用がある．PSFT は 2 次の位相拡散係数の導入が再構成誤差の拡散効果を与え良質な再構成像が期待できる．先行研究では PSFT を利用した超解像として，信号外挿により再構成像の高分解能化を行った．本研究では CS に超解像効果を導入し，深層学習再構成により CS-MRI による再構成像の構造的損失を抑える方法の検討を行った．数値シミュレーションの結果，2 倍の収集信号から得られるフーリエ変換再構成像よりも平均的に高い PSNR，SSIM が得られた．また，分解能の劣化が抑えられた画像が得られた．

キーワード： 超解像，圧縮センシング，深層学習，高速撮像法

1. はじめに

少数の観測信号から元信号を復元する圧縮センシング(compressed sensing: CS)を MRI 撮像に応用する CS-MRI は，撮像時間を短縮する有望な方法である．CS-MRI における画質改善には再構成法と撮像法の 2 つの側面から提案されている. 再構成法の側面では, 深層学習再構成を用いると反復再構成法に比べて高品質な再構成像が得られることが報告されている. 撮像法に関しては，位相拡散フーリエ変換法（Phase Scrambling Fourier Transform imaging: PSFT）[1]を導入する方法が報告されている[2]．フーリエ変換映像法に 2 次関数状の位相変調パルスを導入する PSFT は, MRI 撮像においてさまざまな利点があり，画像折り返し防止[2]や圧縮センシング応用時の画質改善[3]，エコープラナー法における画像歪み低減などがある[4]. 先行研究では，PSFT 信号の外挿による再構成像の高分解能化を図った[5]. 本研究ではさらなる撮像高速化を目指し，より少数の観測信号に対し信号の内挿と外挿を同時に実現しながら画像再構成を行う方法を提案する．深層学習再構成を利用し，従来のフーリエ変換法を基本とする CS-MRI，および先行研究である信号間引きを行わない PSFT 法と比較し，画質の評価などから提案法の有効性を示すことを目的とする．

2. PSFT

PSFT は汎用のフーリエ変換法に二次の位相変調項を加えた方法であり, 被写体関数が実関数である拘束条件下で信号の事後的な超解像が可能となる特徴がある． PSFT 信号は緩和項を省略すると式(1)で表される．

$$v(k_x,k_y)=\iint_{-\infty}^{\infty}\rho(x,y)e^{-j\gamma b\tau(x^2+y^2)}e^{-j(k_xx+k_yy)}dxdy \quad (1)$$

ここで，$\rho(x,y)$ はxy平面のスピン密度，b は二次関数状磁界の係数，τは印加時間，γ は磁気回転比，k_x，k_yは空間周波数である．Nをデータ長，Δxを画素幅とするとき視野全域で標本化定理を満足するには，$\gamma b\tau$ は $\gamma b\tau \le \pi/(N\Delta x^2)$ $(=\overline{\gamma b\tau})$ の関係を満足する必要がある．以降，$\gamma b\tau$ は位相拡散係数 hを導入し，$h\overline{\gamma b\tau}$と表すことにする．PSFT 信号は h が大きいと信号の拡散効果が大きくなり，k空間の広い領域に分布する形となる．また，$h=0$の場合は，二次の位相変調が与えられないので，汎用法であるフーリエ変換法に相当する．

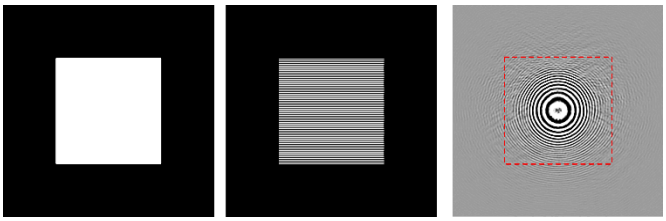
3. 信号収集法と深層学習再構成

PSFT 信号は被写体が実関数との拘束条件を使用すると図 1(a)の白色領域の収集信号から黒色領域に信号を外挿することができ，事後的な高分解能化が可能となる（PSFT-SR と称する）[5]. 本研究では中央の連続的な信号収集領域に間引き処理を行い，信号収集点数が 1/2 の図 2(b)に示す信号収集パターンにより画像の再構成を目指す（PSFT-CS-SR と称する）．なお，図 2 の垂直方向が位相エンコード方向である．

画像再構成は, 信号空間と画像空間との間で位相変調とフーリエ変換を行うことにより信号外挿が行われることを踏まえ，反復的再構成をネットワーク化した ADMM-CSNet [6] を基本とし，PSFT 用のネットワークを構築した．学習に使用した画像は，IXI-Dataset の頭部プロトン密度強調画像(256×256 pixel)[7]であり, テスト用に 25 枚, 学習用に 50 枚を使用した．

5. 再構成シミュレーション実験

位相拡散係数を $h=0.0$ から 1.0 までの範囲で学習と再構成を行った．分解能評価では，画像上に設けた細いスリット周囲の



(a)信号収集パターン A　(b)信号収集パターン B　(c)信号外挿後の PSFT 信号

図 1. 使用した信号収集パターンと外挿された PSFT 信号

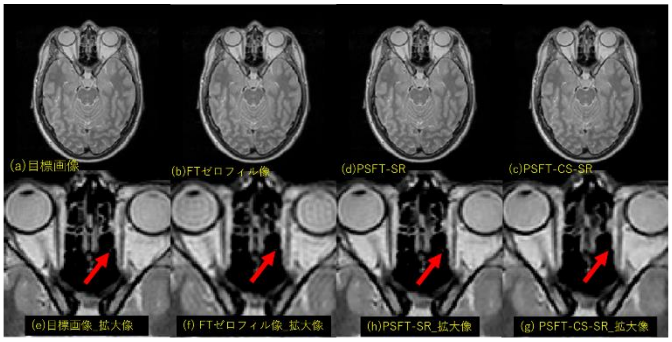


図 2. 再構成像と拡大像比較

分布から判定した．3 つのスリット（slit 1，slit 2，slit 3）は，再構成像上で画像空間の中心から 22，52，82 画素の位置に設けた．PSFT-SR で使用する信号収集パターンは図 1(a)に示すように 256×256 の空間で中央の 128×128 の信号を収集する．PSFT-CR-SR 信号収集は，図 1(b)に示す 128×128 の領域の信号を 1 行おきに間引き収集した．PSFT では，汎用のフーリエ変換法と異なり，信号空間の原点付近を連続的に信号収集する必要は無く，また等間隔間引きによる画像再構成を可能とする特徴がある．図 2 に再構成像とその拡大像を示し，図 3 に PSNR と SSIM を，図 4 に位相拡散係数に対する分解能改善度の変化を示す．PSFT-SR では一般に h の値が大きいほど信号の外挿効果が大きくなり高い PSNR が得られる．特に，視野の周辺部ほど外挿効果が大きくなるので分解能改善効果が大きくなる性質がある．PSFT-CS-SR では，h が 0.5 までは同様な傾向がみられた．h が 0.1 以上のときフーリエ変換法で 2 倍の信号収集を行ったフーリエ変換法のゼロフィル再構成像より PSFT-CS-SR の方が高い PSNR と SSIM が得られた．図 1(c)に提案法において h=1.0 のときに外挿された信号を示す．赤枠の収集信号を越えて信号が外挿されている．

図 4 の分解能評価では，図 1(b)の場合も(a)と同様に h が大きいほど分解能の改善度も大きくなる傾向があり，h が 0.9 の場合を除き 0.4 以上では全てのスリット位置においてフーリエ変換法のゼロフィル像より高分解能となった．PSFT-CS-SR において分解能特性に変動があるのは，わずかに残留する折り返しアーティファクトが分解能評価に影響を与えたものと考える．図 2 より，図(f)，(g)，(h)の赤矢印部に注目するとフーリエ変換法のゼロフィル像よりも PSFT-CS-SR の構造は明瞭であり，

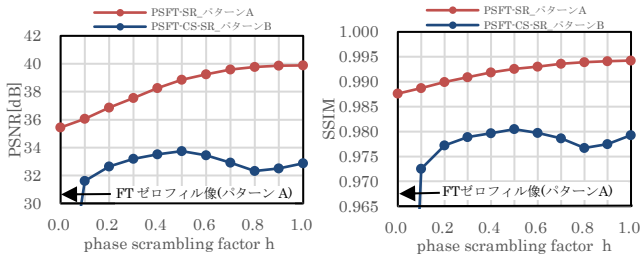


図 3.位相拡散係数 h と PSNR と SSIM

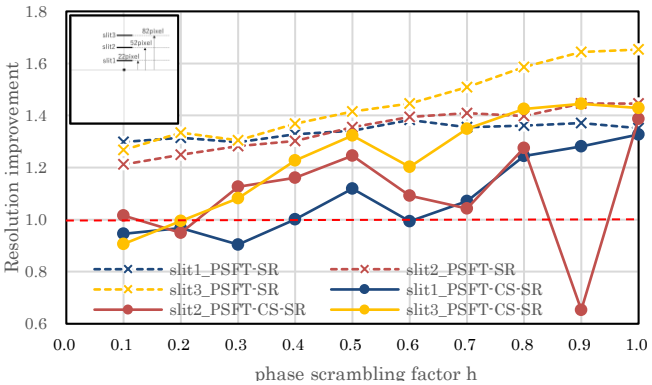


図 4. スリット位置ごとの分解能改善度

（フーリエ変換法のゼロフィル再構成像の分解能を 1.0 とする）

輪郭がはっきりしている．また，信号収集数が 2 倍の PSFT-CS-SR に近い像が得られた．

PSFT の有する超解像と CS 応用における良質な画像再生の特性を組合せ，CS 応用で失われる傾向のある詳細構造の保存性を高める方法の検討を行った．その結果，超解像効果を有した CS の可能性が示された．今後は分解能の変動を抑えること，位相画像に対する応用が課題である．

6. おわりに

PSFT 信号の圧縮センシングに超解像を組み合わせ深層学習により再構成する MRI 高速撮像法を提案した．シミュレーション実験により位相拡散係数の選択により信号収集数が 2 倍のフーリエ変換法で得られる再構成像を超える PSNR と分解能が得られる可能性が示された．

謝辞

本研究の一部は，科研費(23K03864)の助成を受けて行われた．MR 画像の使用に際し，IXI プロジェクトに感謝の意を表す．

文　献

[1] A. A. Maudsley, Journal of Magnetic Resonance, vol.76, pp.287-305, 1988

[2] S. Ito et al., Magnetic Resonance in Medicine, vol.60, pp.422-430, 2008

[3] Y. Wiaux et al., IEEE ISBI: From Nano to Macro, 2010, pp. 756–759

[4] R. Schmidt, Magnetic Resonance in Medicine vol. 71, pp.711–722, 2014

[5] K. Yamato et al., 2022 IEEE ICIP, 2022, pp. 2551-2555.

[6] Y. Yang et al., IEEE PAMI, vol. 42, pp. 521-538, 2020.

[7] IXI dataset. https://brain-development.org/ixi-dataset/ (2023/9/13)

血流を阻害したラット皮弁の分光画像解析

高宮　桃香[*1]，恵藤　陸[*1]，秋田　新介[*2]，三川　信之[*2]，岡本　尚之[*3]，羽石　秀昭[*3]
[*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] 千葉大学フロンティア医工学センター

Multispectral Image Analysis of Skin Flap of Rats with Impaired Blood Flow

Momoka TAKAMIYA[*1]，Riku ETO[*1]，Shinsuke AKITA[*2]，Nobuyuki MITSUKAWA[*2]，
Takayuki OKAMOTO[*3]，Hideaki HANEISHI[*3]
[*1] *Graduate School of Science and Engineering, Chiba University*
[*2] *Graduate School of Medicine, Chiba University*
[*3] *Center for Frontier Medical Engineering, Chiba University*
〒263-8522 千葉市稲毛区弥生町 1-33　e-mail:m_takamiya@chiba-u.jp

要旨：皮弁移植手術とは，皮膚欠損を皮弁と呼ばれる健常領域の皮膚で補う手術である．皮弁移植手術では血管閉塞による術後の壊死が重大な合併症として挙げられる．本研究は，ラット腹部に作製した血行を温存した皮弁モデルへの栄養血管である動脈や静脈を結紮し，虚血または鬱血状態で皮弁表皮の分光反射率の変化を経時的に観察することで，壊死の機序の解明や，壊死初期段階での血流悪化の早期発見に向けた技術の開発を目的とする．動物実験により血管結紮前後の皮弁表皮の分光反射画像を撮影し，皮弁画像の各画素において分散を用いて撮影時刻間での分光反射率の変動を調査した結果，動脈結紮，静脈結紮両モデルともに，結紮側において分光反射率の変動が大きいことが確認された．結紮に伴う血流の変化が反映されていると考えられ，血流悪化の把握や，動脈閉塞，静脈閉塞の判別に有効である可能性が示唆された．
キーワード：皮弁壊死，分光反射率，ハイパースペクトルカメラ，血管閉塞

1. はじめに

皮弁移植手術は, 皮膚欠損を皮弁と呼ばれる健常領域の皮膚で補う手術であり, 血管閉塞による術後の壊死が重大な合併症として挙げられる. 皮弁壊死を避けるために造影剤蛍光像や組織酸素飽和度計測により血流状態を把握する検討[1]がなされているが，標準的な方法は確立されていない.

当研究室では, 壊死の発生機序の解明や血流悪化の早期発見のための技術開発に向け，皮弁壊死モデルラット[2]を用いた研究を進めてきた．皮弁壊死モデルラットを用いることで，動脈閉塞と静脈閉塞を区別した状態での皮弁の観察が可能となる．今回は皮弁表皮の分光計測による血流状態の把握に着目した．術後の血流に問題がある場合には，皮弁の変色が見られ，臨床では目視での経過観察が行われている．しかし目視での観察は定性的であり信頼度が低いという問題がある．

そこで, ハイパースペクトルカメラを用いて結紮前後の皮弁表皮を撮影することで血流の変化を捉えることが可能か検討した．具体的には，血管結紮前後の皮弁表皮の分光反射画像を撮影し分散を用いて撮影時刻間での分光反射率の変動を可視化した. さらに変動の大きい領域に着目し分光反射率スペクトルの変動を観察した.

2. 使用データ

ラット(Slc:Wistar，13 週齢，オス，2 体)を対象とし，血管結紮前後の腹部皮弁表皮の経時変化を観察した. 本実験は千葉大学動物実験委員会の承認を受けている(動 5–268)．図 1 に動物実験プロトコルを示す．まず，図 2 に示すように，ラット腹部の皮膚を挙上してチャンバー(固定具)を装着する．右下腹壁動脈を結紮することで, 皮弁への血液流入が阻害され虚血状態を引き起こす虚血モデル 1 体, また右下腹壁静脈を結紮することで, 皮弁からの血液排出が阻害され鬱血状態を引き起こす鬱血モデル 1 体を作製する.

皮弁表皮を対象に，ハイパースペクトルカメラ(NH-4-HC, エバジャパン，波長域:450–1000nm，波長間隔:5nm)を用いて結紮前と結紮から 3 時間後までを経時的に撮影する. 経時撮影時にはチャンバーを用いることで, 撮影系と皮弁の位置関係を再現できる．また，白色板の分光反射画像も同時に撮影し，分散画像の作成，分光反射率の算出に使用する.

3. 手法

1）分散画像作成

皮弁表皮の分光反射画像を取得する. ここで特定の波長の各画素において分散を用いて撮影時刻間での分光反射率の変動を算出し，分散画像として可視化する．具体的には，まず各画

素における分光反射率を式(1)より算出する．ここで，R は分光反射率，x,y は座標，λ は波長，t_k（$t = 1, \ldots, 11$）は撮影時刻，I_{ref} は反射光強度(皮弁表皮画像)，I_{in} は入射光強度(白色板画像)を示す．

$$R(x, y, \lambda, t_k) = \frac{I_{ref}(x, y, \lambda, t_k)}{I_{in}(x, y, \lambda)} \tag{1}$$

次に，同一座標にある画素の分光反射率が撮影時刻間でどれだけ変動しているかを調べるために，各画素における分光反射率の，計 11 回の撮影時刻間での分散を算出し，画素値 0–255 のグレースケールで画像化する．

2）分光反射率の算出

分散画像による観察のみでは，どの撮影時刻間に変動があったのかが不明であり，さらに，分散画像はある 1 波長に対して作成されるため，連続的に波長間の比較を行うことが難しいという問題点がある．そこで，分散画像中の変動の大きい領域に着目して関心領域(ROI)を設定し，ROI 内の分光反射率スペクトルを観察することで，空間的に分光反射率の変動を把握しながら変動のタイミングの調査と波長間の比較を行う．ROI(30×30[pixels])は分散画像をもとに変動の大きい領域から目視で設定する．続いて，ROI 内における分光反射率を式(2)より算出する．ここで，r は ROI 内平均分光反射率，I_{ref_mean} は ROI 内平均反射光強度(皮弁表皮画像)，I_{in_mean} は ROI 内平均入射光強度(白色板画像)，λ は波長，t_k は撮影時刻を示す．

$$r(\lambda, t_k) = \frac{I_{ref_mean}(\lambda, t_k)}{I_{in_mean}(\lambda)}, \qquad t_k = 1, \ldots, 11 \tag{2}$$

4. 結果

図 3 に，(a)虚血モデル，(b)鬱血モデルにおいて作成した分散画像(500nm)と ROI の位置，ROI における分光反射率スペクトルの算出結果を示す．分散画像から，虚血モデル，鬱血モデルともに，健常側と比較し結紮側において分散値が高い傾向にあることが確認された．また ROI ごとの解析では，虚血モデル，鬱血モデルともに，時間経過に伴い分光反射率が全波長域において大きく変動していた．モデル別に見ると，虚血モデルでは主に 750nm 以降の波長域において，図中矢印で示すように，結紮直後に分光反射率が上昇し，その後徐々に減少する傾向があることが認められた．鬱血モデルにおいても類似の現象が見られたが，減少の仕方がやや異なり，一度大きく減少し，その後は概ね一定，またはやや上昇する傾向が見られた．

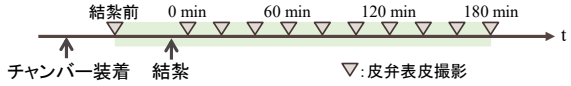


図 1 実験プロトコル

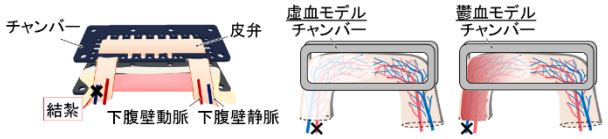


図 2 皮弁モデルラット概要図

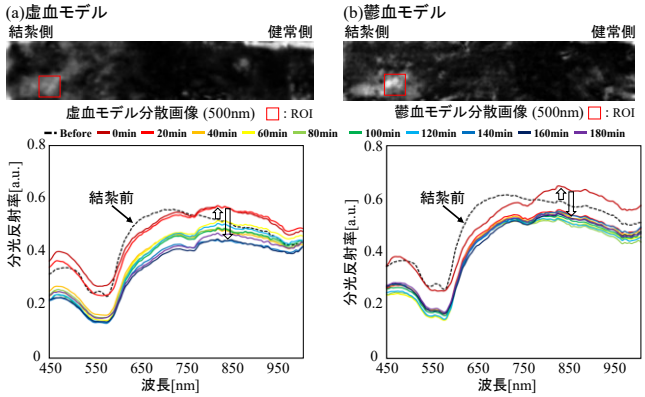


図 3 分散画像，分光反射率スペクトル結果

5. まとめと今後の展望

皮弁壊死モデルに対する表皮分光反射率の経時変化解析を行った．虚血，鬱血モデルともに分光反射率の変動は結紮側で大きい傾向があることが確認された．また，変動の大きい領域の分光反射率のスペクトルを調査した結果，両モデルともに 750nm 以降の波長域において結紮直後に増加，その後減少する傾向が確認された．しかし，減少の程度や傾向がモデル間で異なるため，動脈閉塞，静脈閉塞の違いが反映された可能性があると考える．今後は，個体数を増やして実験を行うとともに，特定の波長域に見られる分光反射率変動の要因解明を行う．

謝辞

この研究の一部は JSPS 科研費 21KK0196 および 24K03300 の支援により行われた．

利益相反の有無

なし

文　献

［1］ Akita S et al.: Regional Oxygen Saturation Index: A Novel Criterion for Free Flap Assessment Using Tissue Oximetry. Plastic and Reconstructive Surgery 138, 510e–518e, 2016

［2］ Eto R et al.: Hemodynamic Analysis of Congestive and Ischemic Skin Flap of Rat, International Forum on Medical Imaging in Asia 2023 61, 2023

大視野顕微放射光 CT による肺３次元ミクロ画像の肺胞壁解析

小野　龍輝[*1]，河田　佳樹[*2]，梅谷　啓二[*3]，中野　恭幸[*4]，
小熊　毅[*5]，阪井　宏彰[*6]，岡本　俊宏[*7]，仁木　登[*8]
[*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] （公財）高輝度光科学研究センター
[*4] 滋賀医科大学
[*5] 京都市立病院
[*6] 兵庫県立尼崎総合医療センター
[*7] クリーブランドクリニック心臓・血管研究所
[*8] 株式会社医用科学研究所

Analysis of alveolar walls in 3D lung micro images from large-field synchrotron radiation CT

Ryuki ONO[*1]，Yoshiki KAWATA[*2] ，Keiji UMETANI[*3]，Yasutaka NAKANO[*4] ，
Tsuyoshi OGUMA[*5]，Hiroaki SAKAI[*6] ，Toshihiro OKAMOTO[*7]，Noboru NIKI[*8]
[*1] *Program of Science and Technology, Graduate School of Creative Science, Tokushima University*
[*2] *Institute of Post-LED Photonics, Tokushima University*
[*3] *Registered Institution for Facilities Use Promotion Japan Synchrotron Radiation Research Institute*
[*4] *Shiga University of Medical Science*
[*5] *Kyoto City Hospital*
[*6] *Hyogo Prefectural Amagasaki General Medical Center*
[*7] *Cleveland Clinic Heart and Vascular Institute*
[*8] *Medical Engineering Institute*

要旨：肺の 3 次元ミクロ構造の解明に向けて，肺胞壁の抽出を行うことは重要である．本研究の目的は SwinUNTER を用いて肺胞壁の抽出の高精度化に取り組み，肺の 3 次元ミクロ構造解析に貢献することである．実験では，(1)肺標本のミクロ CT 画像から肺胞壁を抽出し対話的に修正することで教師データを作成した．(2)この教師データを SwinUNTER で学習させ，肺胞壁の抽出精度を評価した．(3)元画像と抽出結果から線強調フィルタをかけることで毛細血管の候補領域を抽出した．(4)パーシステントホモロジーを元画像や線強調後の画像に適用することで肺胞壁や毛細血管の孔の特徴を定量的に評価した．評価の結果，SwinUNTER を用いることでアーチファクトの誤抽出がほとんどなくなり，CT 値が低い箇所も抽出できるようになった．また，パーシステントホモロジーを成人肺だけでなく小児肺や気腫肺にも適用することで定量的に比較することができた．
キーワード：放射光

1. 背景・目的

肺の気管支系・血管系を厳密に可視化した文献は少なく，特に肺胞領域や毛細血管領域などの肺ミクロ構造は十分に解明されていない．次世代の画像診断に向けて，肺ミクロ形態を観察し疾患の極初期段階を診断することは極めて重要な問題である．この問題の解決のため，肺の正常形態・極早期の疾患構造のミクロレベルでの画像化と定量的な解析が必要である．

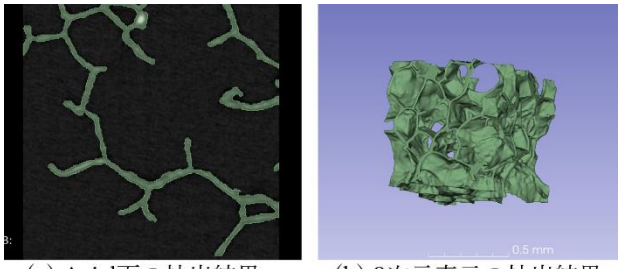
本論文では，肺の正常形態・極早期の疾患構造の３次元ミクロ構造の解明を目指している．そのために造影肺標本を大視野顕微放射光 CT で撮影し再構成画像を作成した．その後，Swin UNTER を用いて高精度な肺胞壁の抽出結果を得て，線強調処理とパーシステントホモロジーの２つの手法を用いて抽出結果から肺 3 次元ミクロ構造を解析した結果を示す．

2. 撮影条件

今回使用した造影肺標本は，岡本俊宏先生により Heitzman の方法に準じて作製された伸展固定肺である．また，この肺標本は Spring-8 の BL20B2 を用いて撮影された．

3. 肺胞壁の抽出法と結果

Swin UNTER による肺胞壁の抽出を行うために３つのフェーズに分けて学習モデルを作成した．フェーズ１では，教師データを再構成画像からツールを用いて抽出し作成した．フェーズ２では，修正が必要なくなるまで教師データの修正と学習を繰り返した．フェーズ３では新たな再構成画像から自動で肺胞壁を抽出した（256×256×256 pixel の抽出にかかる時間は 20 秒程度）．図１に Swin UNTER による肺胞壁の抽出結果を示す．



(a) Axial面の抽出結果　(b) 3次元表示の抽出結果

図１．Swin UNTER による肺胞壁抽出結果

肺胞壁の抽出結果は，正解率・再現率・適合率・Dice 係数の４つの評価指標を用いて精度評価を行った．表１に各評価指標の計算結果を示す．従来法に比べて全ての評価指標で精度が上回っているため肺胞壁の抽出精度が向上したことが確認できる．

表１．各評価指標の計算結果

	正解率	適合率	再現率	Dice
従来法	0.975	0.868	0.903	0.885
Swin UNTER	0.983	0.940	0.968	0.950

4. 肺胞壁の解析法と結果

肺胞壁の解析は線強調とパーシステントホモロジーの２つの手法を用いて，小児肺・成人肺・気腫肺に対して行った．

線強調はヘッセ行列を利用した処理で，ヘッセ行列の固有値の関係から線構造を判別して抽出するものである．この処理により，再構成画像から毛細血管の候補領域を抽出することができる．

パーシステントホモロジーはホモロジーの一種で位相空間の大域的な性質を抽出することができる．１次解析では輪の発生と消滅の結果をパーシステント図にプロットする．この手法を用いて毛細血管の候補領域から毛細血管の網目構造の孔数を数える．図２に小児肺・成人肺・気腫肺の毛細血管の候補領域の３次元表示画像とその孔のプロット数を示す．入力画像が３次元二値画像のためマンハッタン距離を用いているため，パラメータが負の値を取っている．

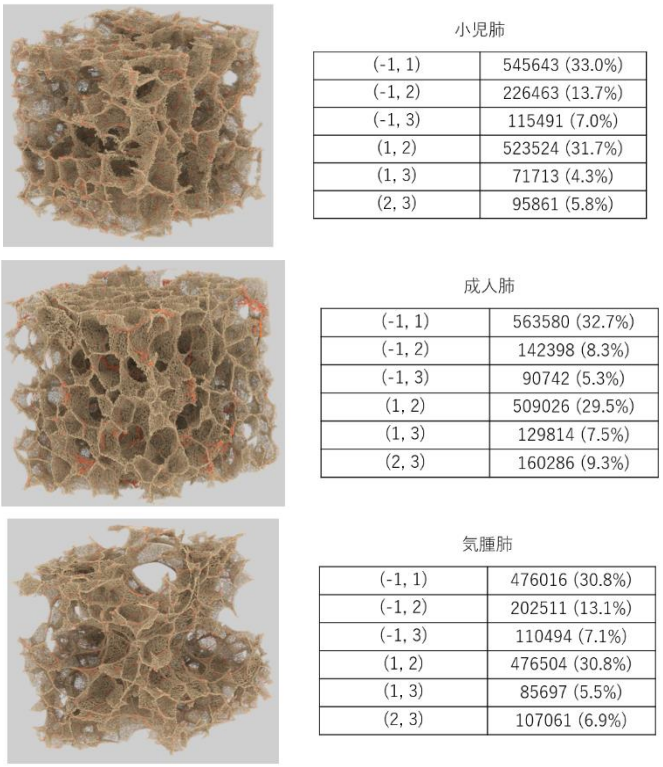


図２．小児肺・成人肺・気腫肺の毛細血管の候補領域の３次元表示画像とその孔のプロット数

5. まとめ

再構成画像からツールを用いて肺胞壁の抽出を行い，Swin UNTER の学習モデルを作成した．精度は全ての評価指標で従来法を上回っており，抽出にかかる時間は大幅に短縮することができたので，肺標本全体の肺胞壁を自動で抽出することができた．そして，この抽出結果を用いて血管系３次元視覚化や肺胞壁の位相的解析を行うことで，小児肺・成人肺・気腫肺から成長と病態進行について肺胞壁と毛細血管の面積や孔数から評価した．

利益相反の有無

なし

文　献

[1] 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, 2022. [Oral presentation] (in press)

[2] Y. Sato, S. Nakajima, N. Shiraga, H. Atsumi, S. Yoshida, T. Koller, G. Gerig and R. Kikinis: Three-dimensional multi-scale line filter for segmentation and visualization of curvilinear structures in medical images. Medical Image Analysis, Vol. 2, No. 2, pp 143–168, 1998

[3] I. Obayashi, Y. Hiraoka, “Persistence Diagrams with Linear Machine Learning Models”, Journal of Applied and Computational Topology, 1(3):421-449, 2018

X 線暗視野法を用いた膵管内乳頭粘液性腫瘍における乳頭様構造の 3 次元解析 －追加 2 症例による比較検討－

天野　遥菜[*1]，砂口　尚輝[*1]，岩越　朱里[*2]，末永　雅也[*2]，
西村　理恵子[*2]，島雄　大介[*3]，湯浅　哲也[*4]，市原　周[*2]
[*1] 東海国立大学機構名古屋大学医学部保健学科放射線技術科学専攻
[*2] 国立病院機構名古屋医療センター
[*3] 大阪物療大学保健医療学部診療放射線技術学科
[*4] 山形大学大学院理工学研究科

Three-dimensional papillary-like structures of intraductal papillary mucinous neoplasm tissue visualized by X-ray Dark Field Imaging: Comparison with two additional cases

Haruna AMANO[*1], Naoki SUNAGUCHI[*1], Akari IWAKOSHI[*2], Masaya SUENAGA[*2],
Rieko NISHIMURA[*2], Daisuke SHIMAO[*3], Tetsuya YUASA[*4], Shu ICHIHARA[*2]
[*1] *Nagoya University*
[*2] *Nagoya Medical Center*
[*3] *Osaka University of Material treatment*
[*4] *Yamagata University*

要旨：X 線暗視野法(XDFI:X-ray Dark Field Imaging)を用いる屈折コントラスト CT(XDFI-CT)は，染色した病理組織像に匹敵するコントラストと数 μm の空間分解能を有しており，生体軟組織の詳細な 3 次元像を提供する．JAMIT2023 では，ヒトから切除された膵管内乳頭粘液性腫瘍(IPMN: Intraductal Papillary Mucinous Neoplasm)の 3 次元微細構造を XDFI-CT で可視化し，拡張した膵管内に増殖する乳頭様の腫瘍構造が独立した凸の構造ではなく，膵管の管軸方向に向かって波状・山脈状に繋がっていることを報告した．この構造がこの症例に特異的なものなのかを検証する事を目的として，本研究では新たに IPMN の症例を 2 例追加し，同様の 3 次元構造が観察されるかどうか評価した．また，術前検査で得られた X 線 CT，MRI，MRCP (Magnetic Resonance Cholangio Pancreatography)の各画像と高解像度である XDFI-CT 像を対比し，臨床における画像所見の理解に寄与するような情報を収集した．

キーワード：X 線暗視野法，屈折コントラスト CT，膵管内乳頭粘液性腫瘍，放射光イメージング

1. はじめに

X 線暗視野法(XDFI: X-ray Dark Field Imaging)に基づく屈折コントラスト CT (XDFI-CT)は，病理画像に匹敵する組織コントラストで生体軟組織内の詳細な 3 次元構造を再構成できる．我々は XDFI を用いて様々な生体試料の 3 次元構築に関する形態学的情報を集めてきた［1,2］．膵臓腫瘍の一つである膵管内乳頭粘液性腫瘍(IPMN: Intraductal Papillary Mucinous Neoplasm)は，拡張した膵管内に種々の程度に隆起性病変を形成する腫瘍であり，良性～悪性までを含む疾患である．腫瘍の分布と進行度に応じた適切な手術が必要となるが，従来のモダリティでは正確な範囲・悪性度の術前判定は十分とはいえない［3］．

JAMIT2023 で我々はヒトから切除された IPMN を XDFI-CT によって 3 次元的に可視化し，拡張した膵管内に増殖する乳頭様の腫瘍構造が独立した凸の構造ではなく，膵管の管軸方向にて波状・山脈状に繋がっていくことを報告した．この構造が特異的なものではなく一般的にみられ，新規性を有する IPMN の知見を検証する事を目的として，本研究では新たに IPMN の症例を 2 例追加し，同様の 3 次元構造が観察されるかどうか評価した．また，術前検査目的で得られた X 線 CT，MRI，MRCP の各画像と，切除検体の高解像度 XDFI-CT 像を対比し，実臨床における画像所見の理解に寄与するような情報を収集した．

2. 方法

図 1 は XDFI-CT の概要図である．XDFI は，モノクロメーターコリメータ(MC: Monochromator-Collimator)(非対称 Bragg 型 Si 単結晶)，アクリル製円筒フィルタ，XY スリット，試料回転ステージ，Laue 角度アナライザ(LAA: Laue-case angle analyzer)(非対称 Laue 型 Si 単結晶)，X 線カメラから構成される．X 線光源には，高輝度・高指向性な放射光を利用した．シンクロトロンから発生した放射光 X 線は，まず 2 結晶分光器により単色化された後，MC の非対称回折により，ビームの幅を拡大した．アクリル製円筒フィルタと XY スリットを通ったビームは試料に入射し，試料内の屈折率分布に従って微小に屈折しながら伝搬する．アクリル円筒フィルタは，円筒状試料容器の表面の屈折を打ち消す目的で利用した．試料を透過したビームは後

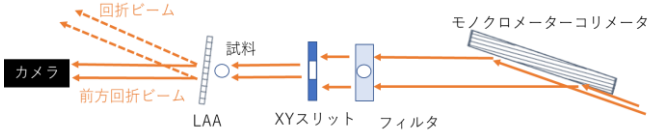


図 1　屈折コントラスト CT 撮影システムを上から見た図

所属：名古屋大学
連絡先住所：〒461-8673　愛知県名古屋市東区大幸南1－1－20
e-mail：kb.55c.9782@s.thers.ac.jp

方の LAA によって前方回折ビームと回折ビームに分割されるが，ビームの角度偏差に従ってそれぞれの回折強度は変化する．その変化量が屈折コントラストであり，前方回折方向に設置した X 線カメラにより屈折コントラスト像を得ることができる．また，試料の回転毎に投影撮影を行うことで XDFI-CT の再構成に必要な投影セットを得ることができる．

撮像装置は，高エネルギー加速器研究機構フォトンファクトリーの BL14B ビームラインに構築された．単色 X 線エネルギーは 19.8 keV，MC の回折面は Si(111)，非対称角は 5.4 度である．LAA の回折面は Si(111)，厚さは 166 μm，非対称角は 5.0 度である．回転ステップ角は 0.144 度，投影数は 2500 枚である．X 線カメラのピクセルサイズは 5.5 μm，画素数は 4608×2592 である．1 投影の露光時間は 4 秒である．XDFI-CT は Filtered Backprojection 法により再構成される．撮影試料は，IPMN と病理診断された膵臓手術検体の残余組織ブロックである．この試料は，病理診断に適した大きさ(約 20×30×5 mm^3)に切り分けられており，ホルマリン固定されている．今回は先行症例を含む 3 症例について腫瘍領域を含む連続した組織ブロックを撮影対象としており，各試料を内径 20 mm のアクリル製円筒容器に挿入し，アガロースゲルで埋めた．

撮影された XDFI-CT 像から Maximum Intensity Projection (MIP)像とボリュームレンダリング像が作成された後，3 次元観察および XDFI-CT 像と術前検査で得られた X 線 CT，MRI，MRCP の各画像の比較を実施した．本研究で扱うヒト膵臓の画像データの研究利用は，名古屋大学医学部保健学科および名古屋医療センターの生命倫理審査で承認されている．

3. 結果と考察

図 2 は IPMN によって分泌される粘液によって拡張した膵管を画像処理で半月切りにし，内腔から膵管壁面の構造を観察したものである．症例 1 は先行研究で使用されたもの，症例 2，3 は今回追加した 2 症例である．2 次元平面観察では乳頭様の隆起が膵管の内面に並んでいるように見えたが，3 次元像では各隆起が独立した凸の構造ではなく，波状・山脈状の 3 次元構築になっていることが，先行研究の 1 例だけではなく追加 2 例でも認められたことから，前回報告した 3 次元構築は IPMN で一般的にみられる可能性が高いことが示され，「乳頭」という用語が適切でない可能性も示した．

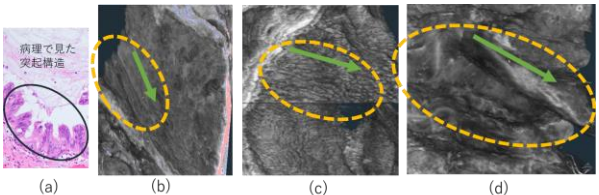


図 2　病理組織 HE の乳頭様構造(a)，症例 1 (b)，症例 2 (c)，症例 3 (d)のすべての症例において観察された山脈状の隆起

図 3(a)は症例 1 において術前検査で得られた MRCP 像，図 3 (b)~(e)は図 3 (a)の点線の断面であり，左から MRI-T1 強調画像，MRCP 像，造影 X 線 CT 像，XDFI-CT 像 を表す．図中の水色の線で囲まれた領域は拡張が少なく腫瘍の進展のある主膵管，黄色の点線で囲まれた部分は病変主座の分枝膵管である．従来のモダリティによる画像は空間分解能が低く混合型 IPMN と術前診断していたものの，主膵管への進展は認識困難であった．また，拡張した分枝膵管内の病変性状も確認できなかった．一方，(e)では主膵管内のわずかな隆起までを含めて，腫瘍の性状・進展範囲を組織レベルで描出できた．また，拡張はみられるがその原因が腫瘍の進展なのか，IPMN によって分泌される粘液貯留によるものか判別が不可能で，手術適応ないし切除範囲の決定が困難となっていた．そのため XDFI-CT 像と術前に撮影された画像を比較し，レトロに再評価することで，腫瘍と粘液は従来のモダリティでも区別できる可能性があることがわかった．

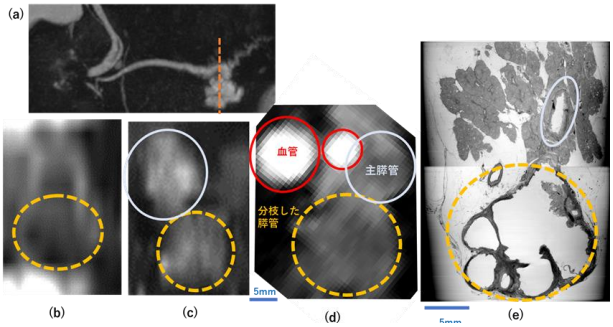


図 3　MRCP 像(a)，(a)の点線における断面 MRI-T1 強調画像(b)，MRCP 像(c)，造影 X 線 CT 像(d)，XDFI-CT 再構成断面(e)と主膵管と拡張した分枝膵管

4. まとめ

高精細に試料を可視化できる XDFI-CT を用いると IPMN の真の形態は波状・山脈状であった．また，従来モダリティとの比較では実臨床の画像解釈に貢献できる可能性が示唆された．今後症例を増やし多くの知見を収集していく予定である．

利益相反の有無

なし

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,L1016-L1018,2002.

［2］ Sunaguchi N,Shimao D,Yuasa T,et al.: Three-dimensional microanatomy of human nipple visualized by X-ray dark-field computed tomography. Breast Cancer Res Treat 180,397-405,2020.

［3］ N. Sata,K. Kurihara,M. Koizumi,M. Tsukahara,K. Yoshizawa & H. Nagai : CT virtual pancreatoscopy: a new method for diagnosing intraductal papillary mucinous neoplasm (IPMN) of the pancreas.

悪性リンパ腫における細胞核の種類識別器構築のための ラベル遷移を考慮した弱教師学習

古賀　諒一[*1]，小出　新悟[*1]，横田　達也[*1]，大島　孝一[*2]，三好　寛明[*2]
永石　美晴[*2]，橋本　典明[*3]，竹内　一郎[*3,4]，本谷　秀堅[*1]
[*1] 名古屋工業大学 〒466-8555 愛知県名古屋市昭和区御器所町
[*2] 久留米大学医学部病理学講座　〒830-0011 福岡県久留米市旭町 67
[*3] 理化学研究所　〒103-0027 東京都中央区日本橋 1-4-1
[*4] 名古屋大学　〒464-8601 愛知県名古屋市千種区不老町

Construction of a Cell Type Classifier for Malignant Lymphoma using Weakly-Supervised Learning with Label Transition

Ryoichi Koga[*1], Shingo Koide[*1], Tatsuya Yokota[*1], Kouchi Ohshima[*2], Hiroaki Miyoshi[*2]
Miharu Nagaishi[*2], Noriaki Hashimoto[*3], Ichiro Takeuchi[*3,4], Hidekata Hontani[*1]
[*1] *Nagoya Institute of Technology*
[*2] *Kurume University Department of Pathology*
[*3] *RIKEN*
[*4] *Nagoya University*

要旨：本研究では，悪性リンパ腫における細胞核の種類識別器を構築するための弱教師あり学習の手法を提案する．細胞の種類のラベル付けは専門の病理医にとっても容易ではなく，ラベルデータには多くのノイズが含まれうる．病理医との打ち合わせを通じて，細胞の種類のラベル付けは特に 2 種類の間で迷う場合が多いことを見出した．そこで，ラベルデータの作成時には，最終的な判断結果だけではなく，2 種類の間で迷った後に棄却された種類名も記録することとした．本研究では，迷った末に棄却されたラベルも含めた弱い教師ラベルにより，ラベル遷移行列を近似する．さらに，識別器がラベルノイズに適合してしまうことを防ぐために，学習過程の損失値に基づくサンプル選択を利用する．これら 2 つの手法を組み合わせることにより，細胞の種類の識別性能を向上させることが確認できたため，その結果を報告する．

キーワード：ラベルノイズ，遷移行列，サンプル選択，弱教師あり学習，悪性リンパ腫

1. はじめに

悪性リンパ腫は血液細胞中のリンパ球ががん化した病気であり，70 を超える多種類のサブタイプに分類される［1］．病理診断においては，検体の薄切切片から作製される組織スライドを観察することにより，サブタイプが同定される．サブタイプ診断では，組織切片中のすべての細胞核を観察するのではなく，ある特定の種類の細胞に注目して観察が行われる．特定の種類の細胞には，centrocyte，centroblast などが存在し，これらの細胞の個数や構成に基づいてサブタイプ診断がなされる．本研究では，病理画像解析に基づくサブタイプ予測の実現を目指して，悪性リンパ腫の細胞核の種類識別器を構築する．

細胞核の種類識別器を構築するためには，各細胞核に対するラベル付けが必要となる．しかしながら，そのラベル付けは専門の病理医にとっても容易ではなく，ラベルデータにはノイズが含まれうる．このようなデータをそのまま学習に用いると，識別器は誤ったラベルにも適合してしまうため，識別性能が低くなる．そのため，ラベルノイズ対策は必要不可欠である．本研究では，ラベルノイズ対策手法として遷移行列［2］を採用する．遷移行列は特定のクラス間でのラベルの誤り方を損失値の計算に反映させる方法であるが，遷移行列の推定は一般に容易ではない．本研究では，ラベル付けにおける迷いも含めて記録した弱い教師ラベル（図 1）により，ラベル遷移行列を近似する．さらに，識別器がラベルノイズに適合してしまうことを防ぐために，学習過程の損失値に基づくサンプル選択［3］を利用する．これら 2 つの手法を組み合わせる弱教師あり学習の手法を提案する．

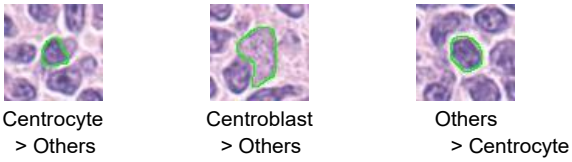


図 1　細胞核画像の例．各画像には，2 つのクラスでラベル付けに迷ったことを不等号により示す弱い教師ラベルが与えられている．画像中の緑色の線は識別対象の細胞核の輪郭を示している．

2. 提案法

細胞の種類のラベル付けは専門の病理医にとっても容易ではなく，時にはラベルの誤りが発生する．このようなラベルはラベルノイズと呼ばれ，特定のクラス間で頻繁に混同する場合もある．特定のクラス間での混同によるラベルの誤り方を損失値の計算に反映させることで，ラベルノイズによる影響を抑制する手法が提案されている［2］．多クラス識別器を構築するための損失関数 $l(\cdot)$ は Cross Entropy を用いて式 (1) で表せる．

$$l(\boldsymbol{f}(\boldsymbol{x};\theta),\boldsymbol{y}) = -\sum_{k=1}^{K} y_k \log f_k(\boldsymbol{x};\theta) \tag{1}$$

ただし，$\boldsymbol{x}$ は入力画像，$\boldsymbol{y} \in \mathbb{R}^K$ は教師ラベル，K はクラス数，$\boldsymbol{f}(\boldsymbol{x};\theta) \in \mathbb{R}^K$ は識別器の出力とする．ラベルノイズ対策法［2］では，識別器が出力する各クラスの予測確率に対して，式 (2) のように遷移行列をかけることでラベルノイズに遷移させてから，損失関数 $L(\cdot)$ を計算する．

$$\begin{aligned} L(\boldsymbol{f}(\boldsymbol{x};\theta),\hat{\boldsymbol{y}}) &= l(\langle \hat{\boldsymbol{p}}(\hat{\boldsymbol{y}}|1),\dots,\hat{\boldsymbol{p}}(\hat{\boldsymbol{y}}|K)\rangle \boldsymbol{f}(\boldsymbol{x};\theta),\hat{\boldsymbol{y}}) \\ &= l(\boldsymbol{T}^{\mathrm{T}}\boldsymbol{f}(\boldsymbol{x};\theta),\hat{\boldsymbol{y}}) \end{aligned} \tag{2}$$

ただし，$\hat{\boldsymbol{y}}$ はノイズを含むラベルであり，$\boldsymbol{T} \in \mathbb{R}^{K\times K}$ は真のラベルからノイズを含むラベルへの遷移確率を示す行列である．遷移行列 $\boldsymbol{T}$ とノイズを含むラベル $\hat{\boldsymbol{y}}$ を用いて識別器を学習させることにより，識別器は真のラベル $\boldsymbol{y}$ を推定できるように学習される．遷移行列 $\boldsymbol{T}$ の推定は，ラベル付けを 2 回行う必要があるなど人的資源の観点で容易ではない場合が多い．本研究では，ラベル付けにおける 2 つのクラス間での迷いを含めて記録した弱い教師ラベルから遷移行列 $\boldsymbol{T}$ を近似する．

さらに本研究では，識別器がラベルノイズに適合することで識別性能が低下してしまうことを防ぐために，学習過程の損失値に基づくサンプル選択の手法 JoCoR［3］を併せて利用する．学習が容易なサンプルについては，学習過程における損失値の減少が早いことが知られており［4］，JoCoR ではこれを利用する．この手法では，異なる初期値で初期化された 2 つのニューラルネットワークに対して同じミニバッチを入力し，損失値が小さくなったサンプルを優先的に選択して，選択されたサンプルだけを用いて学習を行う．選択されるサンプルの個数は，ネットワークが学習初期に学習しやすいサンプルに適合した後で，学習後期に学習が困難なノイズを含みうるサンプルにも適合してしまうことから，学習の進行とともに少数にしていく戦略を採用する［3］．初期値の異なる 2 つのネットワークを利用することで，双方のネットワークにとって学習が容易なサンプルを選択しやすいようにしており，1 つのネットワークを用いる場合に比べて，ラベルノイズの混入を防ぐことができる．本研究では，遷移行列とサンプル選択の手法を組み合わせるラベルノイズ対策のための弱教師あり学習の手法を提案する．

表 1　手法ごとの細胞核分類の正答率と Macro-F1 スコア

手法	正答率	Macro-F1
従来法	60.4 % ± 6.4 %	0.543 ± 0.074
遷移行列のみ	63.7 % ± 7.1 %	0.587 ± 0.061
JoCoR のみ	66.1 % ± 5.5 %	0.612 ± 0.059
提案法	**68.0 %** ± **4.1 %**	**0.642** ± **0.060**

3. 実験結果および結論

細胞核の種類識別器は CNN により構築し，入力画像は図 1 に示す細胞核画像に対して 4 チャネル目に識別対象の細胞核の領域を示すマスクを追加したものである．これにより，識別器が画像中央の細胞核にのみ注目して分類を行うことを期待する．学習データは 10 症例の病理画像から 64 ピクセル四方で切り出したパッチ画像 1,473 枚について，9 症例から得られる画像を学習用，残り 1 症例中の画像をテスト用に分割する．識別器の学習はテスト症例を 1 つずつ取り替えることで 10 回行い，そのすべてでミニバッチサイズを 64 として AdamW により 2.0×10^{-3} の学習率を用いて 200 エポックの学習を行った．比較のために，ラベルノイズ対策を行わない従来法，遷移行列のみを用いた学習，JoCoR のみによる学習，遷移行列と JoCoR の両方を用いた提案手法で実験を行った．各手法における 10 回の実験に対する正答率と Macro-F1 スコアの平均値と標準偏差を表 1 に示す．遷移行列や JoCoR によるラベルノイズ対策を導入することで，識別性能の改善が示された．

今後の課題としては，JoCoR に基づくサンプル選択の個数が識別器の学習にどのような影響を及ぼしていくかの検証などが挙げられる．

謝辞

本研究は JSPS 科研費 JP22H03613 及び JP23KJ1141 の助成を受けたものです．

利益相反の有無

なし

文　献

［1］ Swerdlow SH, Campo E, H.N., Jaffe ES et al: “World Health Organization classification of tumours of haematopoietic and lymphoid tissues”. Revised 4th ed., Lyon, IARC Press, 2017.

［2］ G. Patrini, A. Rozza, A. Krishna Menon et al. “Making Deep Neural Networks Robust to Label Noise: A Loss Correction Approach”. In: Proc. CVPR, 2017, pp. 1944-1952.

［3］ H. Wei, L. Feng, X. Chen et al. “Combating Noisy Labels by Agreement: A Joint Training Method with Co-Regularization”. In: Proc. CVPR, 2020, pp.13726-13735.

［4］ Bo Han, Q. Yao, X.Yu, X. Chen et al. “Robust Training of Deep Neural Networks with Extremely Noisy Labels”. In: Proc. NeurIPS, 2018.

深層学習を用いたイメージング FCM 画像における尿中マルベリー小体のスクリーニング

今久保　桃子[*1]，眞砂　明典[*1]，浅井　千春[*2]，坪井　一哉[*3]
[*1] シスメックス株式会社
[*2] 社会医療法人宏潤会大同病院
[*3] 名古屋セントラル病院

Deep Learning-based Screening of Urinary Mulberry Bodies using Imaging Flow Cytometry

Momoko IMAKUBO[*1], Akinori MASAGO[*1], Chiharu ASAI[*2], Kazuya TSUBOI[*3]
[*1] *Sysmex Corporation*
[*2] *Daido Hospital, Kojunkai Social Medical Corporation*
[*3] *Nagoya Central Hospital*

要旨：マルベリー小体（Mulberry Body, MB）は，ファブリー病患者の尿中に特異的に出現する渦巻き状の微細な粒子である．尿沈渣検査では，標本中に多種多様な有形成分が含まれるため，少量の MB を目視で検出することは困難である．そこで我々は，大量の有形成分を高速で撮像可能な分子イメージングフローサイトメトリー（MI-FCM）を用いて，MB を自動検出するシステムを開発している．
MI-FCM により撮像した有形成分から，MB 候補成分をスクリーニングするため，画像特徴を用いたゲーティング法と明視野画像を分類する深層学習モデルを構築した．ファブリー病患者 12 例のデータに適用した結果，MB 候補成分中の MB の数の割合が 1.3×10^{-2} %から 2.0×10 %に増加した．さらに，検体ごとの MB の定性判定結果では，尿沈渣で MB が検出されなかったファブリー病患者由来の 4 検体から MB が検出された．本稿では主に，MB 候補成分のスクリーニングおよび MI-FCM による MB 定性判定の性能について報告する．
キーワード：深層学習，畳み込みニューラルネットワーク，画像分類，イメージングフローサイトメトリー，尿沈渣

1. 背景・目的

ファブリー病は，細胞のライソゾーム内の酵素の欠損または低下によって引き起こされる先天性代謝異常症である[1,2]．近年，ファブリー病の特異マーカーとして尿中にごく少量出現するマルベリー小体（Mulberry Body, MB）が着目されている[3,4]．既存の尿沈渣検査では，標本中に MB 類似の他の有形成分が大量に含まれるため，顕微鏡下で，目視で見落としなく希少な MB を検出することは困難である．そこで我々は，大量の有形成分を重なりなく高速で撮像可能な分子イメージングフローサイトメトリー（MI-FCM）を用いて，MB を高感度に検出するためのシステムを開発している．本システムでは，1 測定で数十万オーダーの有形成分の画像を取得することが可能であるが，この中から希少な MB を目視で検出することは多大な労力がかかり現実的でない．そこで本研究では，MI-FCM により取得した有形成分の画像から MB 以外の成分を除外し，MB 候補成分をスクリーニングすることで，MB 候補成分中の MB の数の割合，すなわち MB 出現頻度を向上させることを目的とする．さらに，MI-FCM を用いた MB 定性判定の性能について尿沈渣との比較により評価する．

2. 手法

1）使用データおよび MB 定性判定方法

名古屋セントラル病院通院中のファブリー病患者 24 名・非患者 3 名の尿検体を用いた．そのうち，ファブリー病患者 8 名のデータを学習用に用い，残りのファブリー病患者 16 名・非患者 3 名のデータを評価用に用いた．

濃縮した尿検体を，イメージングフローサイトメーター（Sysmex, MI-1000）で撮像した．まず，成分サイズなどの形態情報を用いて画像特徴ゲーティングを行った．次に，除外し切れなかった MB 以外の成分を除外しさらに MB 候補成分を絞り込むため，MB かそれ以外かを分類する Convolutional Neural Network （CNN）ベースの深層学習モデルを構築し，MB と判定された成分を MB 候補成分として抽出した．最後に，残った MB 候補成分のうち，目視判定により MB が 2 個以上検出された場合に MB(+)，1 個以下のときに MB(-)と判定した(図 1)．参照法となる尿沈渣では，顕微鏡下で 10 視野から MB の数を目視で確認し，同様に MB(+)または MB(-)と判定した．

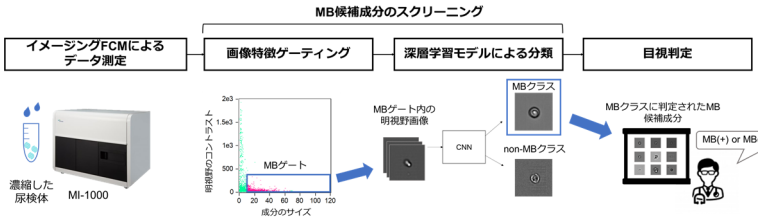


図 1 MI-FCM を用いた MB 定性判定方法の概要

2）MB/non-MB 画像分類のための深層学習モデルの構築

ファブリー病患者由来の 8 検体のデータを用いて，目視判定により判定された MB 1,925 枚，MB 以外の non-MB 17,985 枚からなる 64×64 画素の明視野画像データセットを作成した．MB と non-MB の画像数を均等にし，かつ画像数を増やすために，両クラスの画像数を non-MB クラスの画像数の 10 倍になるまでオーバーサンプリングした．データ拡張のため，回転，シアー変換，拡大縮小，明るさ調整，コントラスト調整，上下左右反転をランダムに適用した．ImageNet で事前学習された VGG16[5]を用いて，80 %を学習データ，20 %を検証データに分割し 5-fold 交差検証により評価した．学習時のパラメータは，バッチサイズ 64，エポック数 100，学習率 0.001 とした．

3. 結果

深層学習モデルの 5fold の検証データでの MB 検出性能は，感度 96.7±1.2 %，特異度 89.7±1.6 %，F1 スコア 93.1±0.8 %となった．

MB 候補成分のスクリーニングについて評価するため，ファブリー病患者 16 名・非患者 3 名の評価用データに対して，画像特徴ゲーティングおよび深層学習モデルによる分類を適用した．測定時・画像特徴ゲーティング後・深層学習モデルによる分類後における MB 出現頻度を比較するため，目視判定によってラベリングされた MB と non-MB の数をそれぞれの場合で比較した(図 2)．その結果，MB を含む患者検体（n=12）では，MB 出現頻度が測定時には $1.3\times10^{-2}\pm1.4\times10^{-2}$ %であったのに対して，画像特徴ゲーティングおよび深層学習モデルによる分類後には 2.0×10±9.6 %まで向上した．また，画像特徴ゲーティングおよび深層学習モデルによる分類の MB 検出感度は 83.4±14.9 %となった．MB を含まない患者検体（n=4）および非患者検体（n=3）では，測定時の総有形成分数に対して，画像特徴ゲーティングおよび深層学習モデルによる分類後の MB 候補成分数は $3.6\times10^{-5}\pm4.6\times10^{-5}$ 倍となった．

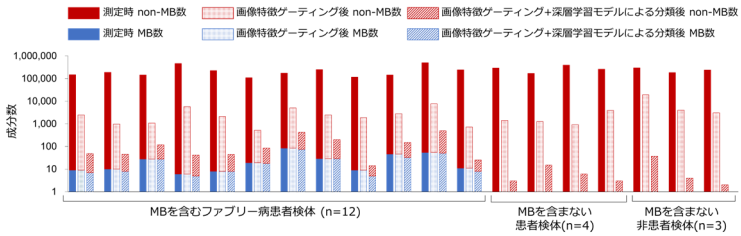


図 2 測定時・画像特徴ゲーティング後・画像特徴ゲーティング＋深層学習モデルによる分類後の MB と non-MB の数

MI-FCM を用いた MB の定性判定性能について評価するため，参照法の尿沈渣との結果を比較した（表 1）．ファブリー病患者由来 16 例のデータのうち 8 例は両手法とも MB(+)となり，4 例は MI-FCM 法でのみ MB(+)となり，残りの 4 例では両手法とも MB(-)となった．非患者由来 3 例のデータでは，両手法とも MB(-)と判定された．

表 1 MI-FCM 法と尿沈渣の MB 定性判定結果の比較

		MI-FCM 法		
		MB(+)	MB(-)	Total
尿沈渣	MB(+)	8 (患者 8 例)	0	8
	MB(-)	4 (患者 4 例)	7 (患者 4 例・非患者 3 例)	11
	Total	12	7	19

4. 結論

本研究では，MI-FCM で測定した尿検体データを用いて，MB 候補成分をスクリーニングするため，有形成分の形態情報を用いた画像特徴ゲーティングと明視野画像を分類するための深層学習モデルを構築した．これらを用いた MB 候補成分のスクリーニングにより，MB を含む検体（n=12）での MB 出現頻度は 1.3×10^{-2} から 2.0×10 へと 1,000 倍オーダーで向上した．また，MB を含まない検体（n=7）における MB 候補成分の数は 3.6×10^{-5} 倍に削減できた．この結果から，本研究で開発した MB 候補成分のスクリーニングにより，MI-FCM を用いて MB を検出する際の検査者の負担を大幅に軽減できることが示唆された．

MI-FCM を用いた MB 定性判定により，尿沈渣で MB が見つからなかったファブリー病患者由来の 4 検体から MB が検出された．MI-FCM によって大量の成分を対象に自動的に MB 候補成分をスクリーニングしたことにより，MB の見落としが解消されたことが示唆された．

今後は，MI-FCM を用いた MB 定性判定の自動化のため，MB 候補成分のスクリーニング性能を改善し，人の目を介さない検査系の確立を目指す．

利益相反の有無

なし

文　献

［1］Brady RO, Gal AE, Bradley RM, et al: Enzymatic defect in Fabry's disease. Ceramidetrihexosidase deficiency. N Engl J Med 276: 1163-1167, 1967

［2］Kint JA: Fabry's Disease: Alpha-Galactosidase Deficiency. Science 167: 1268-1269, 1970

［3］Shimohata H, Maruyama H, Miyamoto Y, et al: Urinary mulberry cells and mulberry bodies are useful tool to detect late-onset Fabry disease. CEN Case Rep 6: 148-151, 2017

［4］Yonishi H, Namba-Hamano T, Hamano T, et al: Urinary mulberry bodies as a potential biomarker for early diagnosis and efficacy assessment of enzyme replacement therapy in Fabry nephropathy. Nephrol Dial Transplant 37: 53-62, 2021

［5］Simonyan K, Zisserman A Very deep convolutional networks for large-scale image recognition, In ICLR 2015

3D U-Net を用いた肺マイクロ CT 画像中の肺胞壁領域抽出

矢田　遥大[*1]，林　雄一郎[*1]，中村　彰太[*2]，小田　昌宏[*3,1]，森　健策[*1,3,4]
[*1] 名古屋大学大学院情報学研究科
[*2] 名古屋大学大学院医学系研究科
[*3] 名古屋大学情報基盤センター
[*4] 国立情報学研究所医療ビッグデータ研究センター

Alveolar Wall Region Extraction from Lung Micro-CT Volume using 3D U-Net

Haruto YADA[*1], Yuichiro HAYASHI[*1], Shota NAKAMURA[*2],
Masahiro ODA[*3,1], Kensaku MORI[*1,3,4]
[*1] *Graduate School of Information Science, Nagoya University*
[*2] *Nagoya University Graduate School of Medicine*
[*3] *Information Technology Center, Nagoya University*
[*4] *Research Center for Medical Bigdata, National Institute of Informatics*

要旨：本研究では，3D U-Net を用いて肺マイクロ CT 画像から肺胞壁領域の抽出を行なう手法を提案する．医用画像処理の分野において，深層学習を用いた領域抽出手法が次々と提案されており，病態理解や，人体機能のさらなる知見獲得，診断支援等に有効な手段であると期待されている．一方で，肺マイクロ CT 画像と深層学習を組み合わせた研究はまだ少ない．その要因として学習用のデータ数確保の困難さ，教師データの作成の困難さ等が考えられる．この問題に対処するため，本研究ではデータ拡張を行いデータ数の確保を行う他，2 値化をベースとした手法で肺胞壁領域の 3 次元の正解データを自動的に作成して深層学習を行い，肺胞壁領域の抽出を行った．学習のモデルには 3D U-Net を用いた．Dice 係数による評価は 0.911 となった．
キーワード：マイクロ CT，肺微細構造，3D U-Net

1. はじめに

本稿では, 肺マイクロ CT 画像からの肺胞壁領域抽出について述べる．末梢肺には，細気管支や小葉間隔壁，肺胞といった微細な構造が 3 次元的に分布する．これらの構造は，マイクロ CT 画像と呼ばれる μm 単位の解像度の CT 画像を撮影することで観察することが可能である. 肺微細構造の 3 次元的分布の詳細は明らかにされておらず，マイクロ CT 画像を用いて構造解析を行うことは病態や生体機能の解明につながると期待される．

末梢肺には, 肺胞と呼ばれる小胞がもっとも普遍的にみられる．肺胞は直径が 100μm から 200μm とされている非常に微細な構造である[1]. この 3 次元的分布は複雑であるうえ, 肺胞嚢との接続や, 肺胞同士が孔で接続していることから完全に閉じた立体構造でなく，CT 画像中では壁が途切れて映る．そのため，単純な塗りつぶし手法で肺胞，肺胞壁領域抽出を行うことは困難である．

肺マイクロ CT 画像からの構造抽出に関する研究としては，椎名ら[2]による距離マップを利用した肺胞抽出や，深井ら[3]による 2D U-Net による肺胞抽出がある. 深井らはマイクロ CT 画像をスライスごとに取り出し, 肺胞壁からの距離画像を生成して学習を行うことで, 個々の肺胞領域を抽出する手法を提案している．この手法では，距離画像が明瞭な部分での抽出精度が高い一方, スライスごとに学習しているため 3 次元的な特徴量が失われている可能性がある．また，現状ではマイクロ CT 画像の撮影が可能な肺標本を多数用意することができず, 多数の画像を確保することが難しい．そのため，深層学習を用いた研究はまだ少ない.

本稿では, 3D U-Net[4]を用いた肺胞壁領域の抽出手法を提案する．本手法では 3D U-Net の学習データ数確保のためデータ拡張法を用いる．拡張されたデータを元に学習を行い，肺マイクロ CT 画像から 3 次元の肺胞壁領域ラベル画像を出力する．

2. 手法

本手法では，深層学習を用いて 3 次元の肺マイクロ CT 画像を入力とし，肺胞壁領域を示すラベル画像を出力する．深層学習を行う際のモデルは 3D U-Net[4]を用いる．

撮影されたマイクロ CT 画像にはノイズが含まれるため，標準偏差が 2 画素のガウシアンフィルタを用いてノイズ除去を行う．肺胞壁は面状構造と考えられるため，ノイズ除去後にヘッセ行列の固有値の大小比較による面状構造強調手法[5]を用いて強調処理を行う. これらの処理を行った画像を前処理後画像とする．

深層学習を行うにあたり, 教師データを手動で用意することは非常に労力が大きいため，前処理後画像にしきい値 17 で 2

値化を行い, 過抽出抑制のため連結成分のうち 3 画素以上からなる成分を肺胞壁領域として正解ラベルに用いる.

また十分な精度での抽出を行うには, 学習において多数のデータが必要であるが, 前述の通り肺マイクロ CT 画像を多数用意することは難しく, データが不足しがちである. そこでデータ拡張を行い, データ数を補う. 本手法では, 前処理後画像から, $M \times M \times M$ 画素の領域をクロップしてデータ拡張を行う. データ拡張は反転処理と非剛体変形処理を行う. 反転処理では, 画像を x, y, z 軸方向へ反転することで新しい画像を作成する. 本手法では, 前処理後画像を x, y, z 各軸方向に 2 等分して 8 つのブロックを作成し, 各ブロックをランダムな方向に反転する. その後, 再び結合して新しい画像とする. 非剛体変形では, 各画素に対して移動方向と大きさを決定して移動を行い, 画像を変形して新しい画像を作成する. 本手法では前処理後画像に N 画素間隔で等間隔に制御点を配置して各制御点を移動させた後, B スプライン補間を行い得られる図形に合わせて画像の変形を行う. 尚, 移動の方向は各軸まわりに d_{min} 度から d_{max} 度の間の向き, 移動の大きさは $-m$ 画素から m 画素の間でランダムに定める. この 2 つの拡張法を組み合わせてデータ拡張を行い, 生成した画像を拡張後画像とする.

上記手順で作成した画像を 3D U-Net に入力して学習を行う. 学習後のモデルで前処理後画像から肺胞壁領域の抽出を行う.

3. 実験および結果

肺がん患者の切除肺標本のうち肺がんに浸潤されていない部分のマイクロ CT 画像を撮影した. 撮影装置には SKYSCAN 1272（Bruker, USA）を用いた. 標本数は 3, それぞれ解像度は $25 \times 25 \times 25\ \mu m^3$, 画素数は $806 \times 806 \times 462$ 画素である. 3 つの標本のうち 2 つを学習用, 1 つを評価用に用いた. 前述の手法により前処理後画像及び正解ラベルを作成した. データ拡張のためのパラメータは表 1 の通りであり, 前処理後画像からクロップした画像 432 枚から拡張後画像 1728 枚を作成した. 学習はバッチサイズ 4 で行い, 学習係数の値は 0.001, エポック数 600 とした. 損失関数には交差エントロピー誤差を用いた. これらの条件で, 肺胞壁領域を抽出した. 抽出精度の評価は Dice 係数を用いた.

評価用の標本から 108 枚のクロップ画像を用意して, 抽出を行った. Dice 係数による評価は表 2 に示すように 0.911 となった. 入力画像と抽出された肺胞壁領域のスライス画像の例を図 1 に示す. また, データ拡張を行わずに学習, 抽出を行うと Dice 係数の評価は 0.904 であった.

4. 考察およびむすび

図 1 のように肺胞壁領域が連続的に抽出できていることが観察できる. また, 表 2 のように Dice 係数の値はデータ拡張を行ったほうが高いことから, データ不足を改善できているといえる. 今後の課題として肺胞壁と小葉間隔壁等他の構造との区別や, 肺胞領域抽出への応用が考えられる. さらに, 肺がんに浸潤された領域への応用を行うことで健常領域との差異を分析し, 医学的知見獲得へと繋げていきたい.

謝辞

研究遂行にあたり, 日頃より熱心に指導, 協力いただく森研究室の諸氏に感謝する. 本研究の一部は JSPS 科研費（21K19898, 17K20099）による.

利益相反の有無

なし

文　献

［1］伊藤隆：解剖学講義.　株式会社　南山堂, 2012

［2］椎名健, 小田紘久, 鄭通 他：距離マップを利用した肺マイクロ CT 像からの肺胞抽出. 第 40 回日本医用画像工学会大会予稿集: 374-377, 2021

［3］深井大輔, 小田紘久, 林雄一郎　他：面状構造強調に基づく 2D U-Net を用いた肺マイクロ CT 像からの肺胞セグメンテーション. 信学技報 123(411): 145-148, 2024

［4］Cicek O, Abdulkadir A, Lienkamp S et al: 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. MICCAI, 9901: 424-432, 2016

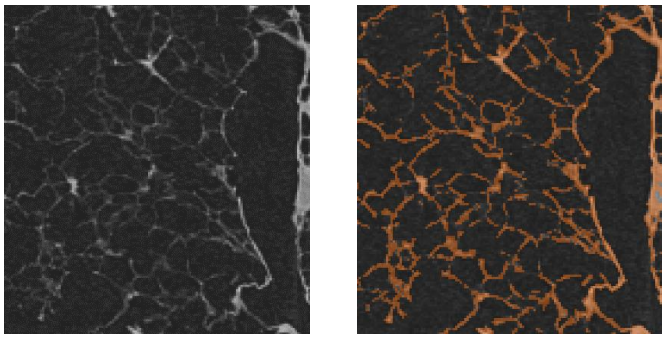
［5］Sato Y, Nakajima S, Shiraga N et al: Three-dimensional multi-scale line filter for segmentation and visualization of curvilinear structures in medical images. Med Imag Anal 2(2): 143-168, 1998

表 1　データ拡張のパラメータ

M	N	d_{min}	d_{max}	m
96 画素	19.2 画素	-5 度	5 度	20 画素

表 2　抽出精度の評価結果比較

評価指標	データ拡張有	データ拡張無
Dice 係数	0.911	0.904



（a）　（b）

図 1　肺胞壁抽出結果.（a）入力画像のスライス例.（b）肺胞壁抽出結果のラベル画像スライス例. 橙色の部分が抽出された肺胞壁領域を示す.

FDG-PET/CT 像上の副腎転移病変検出に関する検討
-上腹部臓器領域抽出とのマルチタスク学習の実験的検証-

吉田昂平[*1]，根本充貴[*1 *2]，甲斐田勇人[*3]，木村裕一[*4]，永岡隆[*1 *2]，三上勝大[*2]，山田誉大[*3]，
花岡宏平[*3]，槌谷達也[*5]，北島一宏[*5]，石井一成[*3]
[*1] 近畿大学生物理工学研究科　[*2] 近畿大学生物理工学部　[*3] 近畿大学病院
[*4] 近畿大学情報学部　[*5] 兵庫医科大学病院

Study on the detection of adrenal metastatic lesions on FDG-PET/CT images
-Experimental validation of multitask learning with upper abdominal organ region extraction-

Kohei YOSHIDA[*1], Mitutaka NEMOTO[*1*2], Hayato KAIDA[*3],
Yuichi KIMURA[*4], Takashi NAGAOKA[*1*2], Katsuhiro MIKAMI[*2], Takahiro YAMADA[*3],
Kohei HANAOKA[*3], Tatsuya TSUCHITANI[*5], Kazuhiro KITAJIMA[*5] and Kazunari ISHII[*3]
[*1] *Graduate School of BOST, Kindai University*　[*2] *Faculty of BOST, Kindai University*
[*3] *Kindai University Hospital*　[*4] *Faculty of Informatics, Kindai University*
[*5] *Hyogo Medical University Hospital*

要旨：悪性腫瘍の転移先になりやすい副腎に注目し，FDG-PET/CT 像上の副腎転移病変検出に向けた病変の存在判定と肝・腎領域抽出のマルチタスク学習について検討する．用いるモデルは上腹部 Axial スライス像を入力とし，肝・腎領域を同時抽出する U-Net ベース領域抽出ブロックと，U-Net 中間出力特徴量マップをエンコードすることでスライス像上の副腎転移病変の有無を判定する識別ブロックからなる．その学習は，まず領域抽出ブロックのみ肝・腎領域抽出タスクで事前学習し,次に識別ブロックを加えてマルチタスク学習によるファインチューニングを行う．副腎転移症例 7 例を含む計 14 例の FDG-PET/CT 像を用いた実験では，病変有無の識別のみ学習時より AUC 約 0.14 の改善を確認した．
キーワード：マルチタスク学習，FDG-PET/CT 像，副腎転移

1. 背景・目的

副腎は血流が豊富であるためがん転移のリスクが高いが, その初期症状は乏しいため，早期発見が重要となる．全身の癌の早期診断に FDG-PET/CT 検査は有用[1]だが，FDG の自然集積が病変読影の妨げとなるため，画像診断支援（CAD）システムへの期待が高まっている[2]. 医用画像処理や CAD の研究において, 病変領域と臓器領域マルチタスク学習が病変領域の抽出精度向上に効果があるという報告[3]があることから，本研究では副腎腫瘍の高精度検出に向け, 肝臓および腎臓のセグメンテーションと副腎転移スライス識別のマルチタスク学習について検証する．

2. 手法

本研究で提案するマルチタスクモデルは, 上腹部 Axial FDG-PET/CT スライス像を対象とし，肝臓と腎臓の領域抽出を行う U-Net ブロックと，U-Net による処理過程で得られる特徴量マップから副腎転移の存在を識別する識別ブロックからなる. 前処理により CT 像および PET 像の体幹領域外除去および空間等方化（スライスサイズ 192×192 pixels, 2.00 mm 等方画素サイズ）が施された画像を入力とする．各ブロックの詳細を図 1 に示す．U-Net ブロックは 3×3 畳み込み層 4 層による特徴抽出を行ったあと圧縮または拡大を行う処理を繰り返し行う. 識別ブロック（図 1）は，U-Net の Encode 処理により得られた各層の特徴量マップ（図 1 内，① 96×96 pixels, ② 48×48 pixels, ③ 24×24pixels）を解析する．それぞれの特徴量マップを 3×3 畳み込み層 6 層，1×1 畳み込み層 4 層，2 層の Max Pooling 層，1 層の Average Pooing 層で圧縮したのち，FC 層でスライスの識別を行う．

このモデルは 2 段階で学習する. まず U-Net ブロックのみを学習したのち, 識別ブロックを追加し臓器抽出とスライス識別のマルチタスク学習によるファインチューニングを実施する．抽出タスクにおける損失関数には Dice loss, 識別タスクにおける損失関数には Categorical-cross-entropy を用いる．

検証実験では近畿大学病院および兵庫医科大学病院にて撮像された FDG-PET/CT 画像計 14 症例を使用する．全症例が原発性肺癌症例であり，内 7 症例は副腎転移症例である．これらを用いて Case-based leave-one-out 交差検証を行う．領域抽出の結果は Dice Index を用いて評価し，識別結果には ROC 曲線および AUC を用いて評価を行う．また識別ブロックで用いる特徴量マップの妥当性を検証するため，図 1 のマップ②+③のみ用いた場合，③のみ用いた場合の性能も検証する．

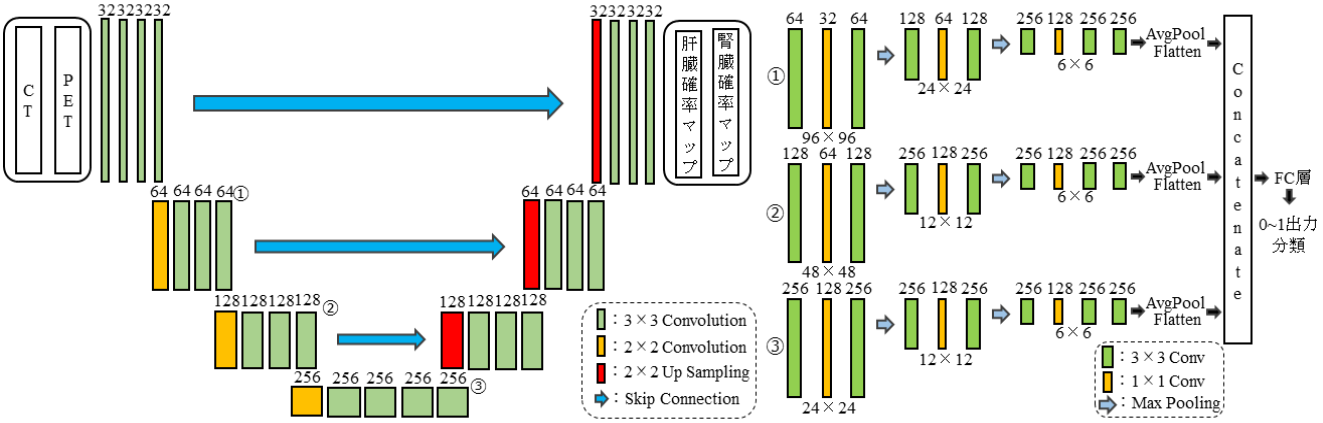


図 1　マルチタスクネットワーク（左：U-Net Block、右：識別 Block）

3. 結果

図 2 に副腎病変スライス識別結果の ROC 曲線を示す．提案モデルでの AUC は 0.968 であったのに対し，副腎転移スライス識別の単一タスク学習では 0.826 であった．マップ②+③のみでは 0.929，③のみでは 0.897 であった．提案モデルでは副腎転移スライス 107 中 99 スライスの識別に成功していた．この時の肝臓および腎臓抽出処理の平均 Dice Index はそれぞれ 0.94, 0.92 であった．

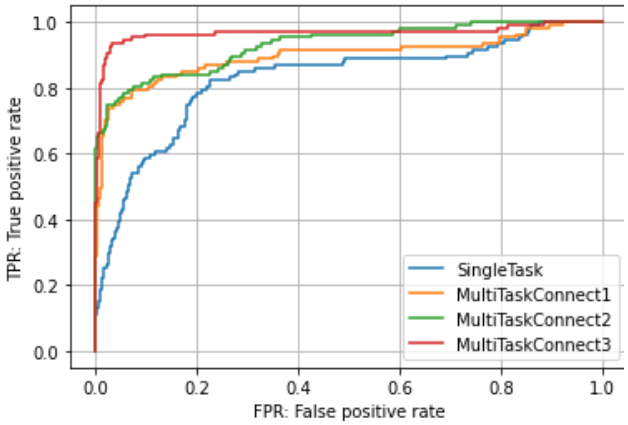


図 2　ROC 曲線

4. 考察

今回の実験結果は，提案するマルチタスクモデルが単一タスク学習時や小さな特徴量マップを解析した時より良好な副腎転移スライスの識別を行うことができることを示している．識別対象が小さい副腎であるため，U-Net の画像圧縮によるミクロな画像情報の損失が病変スライスの識別に直接的に悪影響を与えたと考えられる．ただ，脂肪の少ない症例に関しては病変スライスの識別が難しく，誤識別が見られた．検出精度を向上させるには学習症例数の増加やモデルのさらなる改良が必要と考える．

5. 結論

U-Net による臓器領域の抽出と U-Net の encode 処理によって得られた多チャンネル特徴量マップに転移病変スライスを識別するブロックを追加し，モデルをファインチューニングすることで副腎転移が存在するスライスの識別を行った．このモデルに関して，検出に使用する特徴量マップの選択を実験的に検証した．病変検出数に関しては提案手法によって約 18%の改善が見られた．また，AUC に関しても約 0.07 の改善が見られた．また，同時に行った肝臓および腎臓の領域抽出に関しては，肝臓の平均 Dice Index が 0.94，腎臓が 0.92 であった．今後はより小さな病変の検出や誤検出の抑制のために，症例数の増加やモデルの構造を最適化し，精度の向上を図る．

謝辞

本研究の遂行にあたり，近畿大学病院及び兵庫医科大学病院から多数の臨床データをご提供頂いた．本研究は JSPS 科学研究費 20K11944 の助成を受けたものである．

利益相反の有無

なし

文　献

[1] Chua SC, Groves AM, Kayani I et al: The impact of 18F-FDG PET/CT in patients with liver metastases. Eur J Nucl Med Mol Imaging: 1906-1914, 2007

[2] 藤田広志：医用画像のためのコンピュータ診断支援システムの開発の現状と将来．日本写真学会誌 66 巻 5 号: 484-490, 2003

[3] Z. Kuang, Z. Li, T. Zhao et al: Deep Multi-task Learning for Large-Scale Image Classification. 2017 IEEE Third International Conference on Multimedia Big Data (BigMM): 310-317, 2017

深層学習による CT 画像での乳癌腫瘤影検出における過去画像の有用性に関する検討

守田　裕一[*1], 花岡　昇平[*1], 野村　行弘[*2,3], 中尾　貴祐[*2], 吉川　健啓[*2], 阿部　修[*1]

[*1] 東京大学医学部附属病院　放射線科

[*2] 東京大学医学部附属病院　コンピュータ画像診断学／予防医学講座

[*3] 千葉大学フロンティア医工学センター

Evaluating the effectiveness of time series comparison in deep learning-based detection of breast cancer on CT images

Yuichi Morita[*1], Shouhei Hanaoka[*1], Yukihiro Nomura[*2,3], Takahiro Nakao[*2], Takeharu Yoshikawa[*2], Osamu Abe[*1]

[*1] *Department of Radiology, The University of Tokyo Hospital*

[*2] *Department of Computational Diagnostic Radiology and Preventive Medicine, The University of Tokyo Hospital*

[*3] *Center for Frontier Medical Engineering, Chiba University*

要旨：CT 検査で偶発的に乳癌は 1~3%程発見され, CT でも偶発的乳癌検出は重要である. マンモグラフィーでは過去画像との比較が放射線科医の結節検出感度を上昇させる報告があり, 深層学習に過去画像のある乳癌患者の体幹部 CT 画像を入力し, 乳癌を検出するモデルの構築と評価を行った. 被検者は 31 名の病理で乳癌と診断された女性（平均 69.8 歳）で, 2005 年〜2021 年までに東京大学医学部附属病院で撮影された CT 画像を用いた. 3D Unet に過去画像と現在画像をデータ拡張の上, 2ch で入力し, 訓練 25 例, 検証 6 例として教師あり学習した. 比較のため現在画像のみ 1ch 入力での学習も行った. FROC 解析を用いて評価した. 結果, 2ch で 1.4 False positive/Case で真陽性率 64.5%, 1ch では 2.8 False positive/Case で真陽性率 70.1%だった.

キーワード：Deep learning, Computed Tomography, Breast Cancer

1. はじめに

CT 検査では偶発的に乳癌が 1~3%ほど発見され [1], CT 検査数は増加の一途であり, CT での偶発的乳癌検出が重要である. マンモグラフィーでは過去画像との比較が放射線科医の結節検出感度を上昇させると報告されており[2], 深層学習による乳癌検出でも過去画像のある乳癌患者の体幹部 CT 画像を入力することで, 結節の検出能向上が得られると仮定した.

本研究では過去画像と前回画像を入力した乳癌検出モデルの構築と, 現在画像のみ入力したモデルとの比較を行った.

2. 方法

2005 年 3 月〜2021 年 11 月までに東京大学医学部附属病院で撮像された（単純または造影の）体幹部 CT 画像を使用した. 患者は 31 名の女性（平均年齢 69.8±10.7 歳）で, 放射線科レポートで乳癌が指摘された時点での CT 画像（現在画像）と, 同一患者の少なくとも 3 ヶ月以上前に撮像された CT 画像（過去画像）を匿名化し, 学習に使用した.

それぞれの CT 画像(Matrix: 512×512, FOV: 400-500×400-500mm, スライス厚: 5mm)を Simple ITK を用いて, 乳腺を含む領域を抽出し, Matrix: 320×320pixel, FOV: 400×400mm, スライス厚: 1.25mm に統一した. さらに前回画像を今回画像へと Simple ITK を用いて非剛体変換してレジストレーションした.

深層学習モデルとして, 3D Unet (畳み込み層: 3, フィルター: 16, 32, 64, カーネルサイズ(全層): 3×3×3)を用いた [3]. 学習パラメーターは, オプティマイザ: Adam, エポック数: 150, バッチサイズ: 3, 学習率: 1×10^{-3} とした. 過去画像と現在画像をデータ拡張(x-y 軸での平行移動, 回転, 拡大縮小, 左右反転, ノイズ追加)して, 2ch で入力した. 訓練 25 例, 検証 6 又は 7 例として 5 回交差検証を行った. 乳癌の正解ラベルは今回画像のみ入力した. 損失関数はダイス係数を使用した.

評価はモデルの出力と乳癌の正解ラベルにおける重心を Sci Py により算出し, モデルの予測と正解ラベルの重心のずれが 5 ボクセル以内であれば正答とし, モデルの予測を 2 値化する threshold を変えて Free-response Receiver Operating Characteristic (FROC)カーブを描画した.

学習は GPU(GV100(32 GB); NVIDIA Corporation, CA, USA)を 3 基搭載した PC で PyTorch 2.2.2 を使用した.

3. 結果

現在画像と過去画像を 2ch で入力した結果は図 2A に示す通りとなり, 1.4 False positive/Case で真陽性率は 64.5%となった. 現在画像のみ 1ch で入力した結果は図 2B の通りで, 2.8 False positive/Case で真陽性率 70.1%となった.

4. まとめ

現在画像と過去画像を入力したモデルは, 真陽性率では現在画像のみ学習したモデルを超えることはできなかった. ただし, 症例数が少ないためか 1ch での学習でも既報の感度 90%前後までは達していない[4, 5]. さらに今回は乳腺が非剛体であり, 前回画像と今回画像のレジストレーションを厳密に行えていない. 今後の課題として、症例数の増加やレジストレーションの精度向上, 他のモデルでの学習を行うことで性能向上を図ることができるかもしれない.

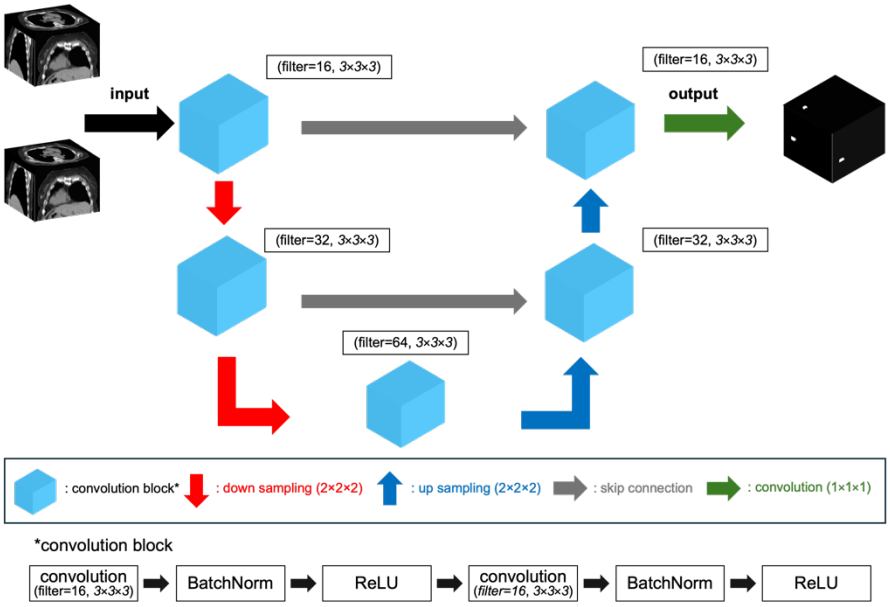


図 1　2ch で学習時の 3D Unet の模式図

青色の直方体が convolution block を示し，図の下に convolution block の処理を示す．

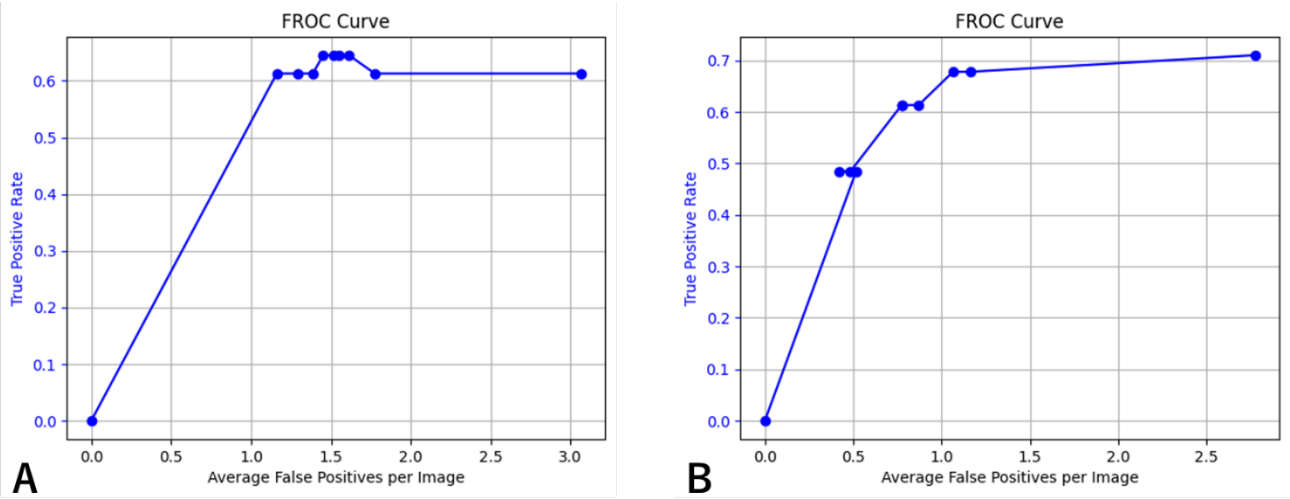


図 2　2ch 入力でのモデルと 1ch 入力でのモデルの結果

(A) 現在画像と過去画像を 2ch で入力した結果で，25 例を 5 回交差検証し，それぞれの検証結果を合計した．

(B) 現在画像のみを 1ch で入力した結果で，25 例を 5 回交差検証し，それぞれの検証結果を合計した．

2 値化するときの threshold を変えながら FROC curve を描画したため，病変候補の数や重心位置が一定ではなくなり，必ずしも右肩上がりのグラフではなくなっている．

利益相反の有無

なし

文　献

［1］Al-Katib S., Gupta G., Brudvik A. et al. A practical guide to managing CT findings in the breast. Clin Imaging.60(2):274-82. 2020

［2］TRIEU P. D. Y., BORECKY N., LI T., BRENNAN P. et al. The Impact of Prior Mammograms on the Diagnostic Performance of Radiologists in Early Breast Cancer Detection: A Focus on Breast Density, Lesion Features and Vendors Using Wholly Digital Screening Cases, Cancers (Basel) 15(4) 2023.

［3］Çiçek Ö., Abdulkadir A., Lienkamp S.S., Brox T. et al. 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. MICCAI 2016, Cham, 2016.

［4］Koh J., Yoon Y., Kim S. et al. Deep Learning for the Detection of Breast Cancers on Chest Computed Tomography. Clinical Breast Cancer. 22(1):26-31. 2022.

［5］Yasaka K., Sato C., Hirakawa H. et al. Impact of deep learning on radiologists and radiology residents in detecting breast cancer on CT: a cross-vendor test study. Clinical Radiology.79(1):e41-e47. 2024.

Masked Autoencoder の自己教師あり学習に基づく頭部 CT 画像からのくも膜下出血の検知

大野　未来矢[*1]，　黒瀬　優介[*2, 3]，渡谷　岳行[*4]，原田　達也[*2, 3, 5]
[*1] 東京大学大学院情報理工学系研究科知能機械情報学専攻
[*2] 東京大学　先端科学技術研究センター，
[*3] 理化学研究所　革新知能統合研究センター，
[*4] 東京大学医学部附属病院　放射線科
[*5] 国立情報学研究所　医療ビッグデータ研究センター

Detection of Subarachnoid Hemorrhage from Head CT Images Based on Self-Supervised Learning of Masked Autoencoder

Mikiya ONO[*1], Yusuke KUROSE[*2,3], Takeyuki WATADANI[*4], Tatsuya HARADA[*2,3,5]
[*1]*Information Graduate School Science and Technology, University of Tokyo*
[*2]*Research Center for Advanced Science and Technology, University of Tokyo*
[*3]*Center for Advanced Intelligence Project, RIKEN*
[*4]*Department of Radiology, The University of Tokyo Hospital*
[*5]*Research Center for Medical Bigdata, National Institute of Informatics*

要旨:くも膜下出血は発症後に緊急の治療を要する疾患であり，診断支援システムの開発の需要が高い．くも膜下出血の微小で多様な出血を網羅する CT 画像データセットの構築はアノテーションコストの観点から困難であるため，本研究では Masked Autoencoder(MAE)をモデルとして用いて，正常な頭部 CT 画像のみを学習に使用した異常検知の手法を提案する．MAE では分割されたパッチをランダムにマスクして，マスクされたパッチの再構成を行う自己教師あり学習によって画像全体の大局的な特徴抽出が学習される．くも膜下出血罹患者の CT 画像は正常な頭部 CT 画像よりも再構成誤差が大きくなるという仮定のもとで異常度を算出する．より鮮明な再構成を行うために、パッチごとに入力画像か再構成されたものかを識別することによる敵対的損失を学習時の損失として加える．実験により提案手法において識別精度の向上が確認された．

キーワード:異常検知，Masked Autoencoder，敵対的学習，くも膜下出血

1. 序論

近年，深層学習の研究の進展により画像認識の性能が向上し，医用分野においても深層学習に基づく診断支援システムの研究が進んでいる．高い識別性能を持つモデルの構築は一般的に大量のラベル付きデータを用いた教師あり学習により行われるが，本研究で扱うくも膜下出血の CT 画像のような医用画像においては画像ごとのアノテーションの付与などに専門の知識を要するため，一般画像と比較してデータセットの構築にコストがかかる．

そこで本研究では正常な頭部 CT 画像のみを用いてモデルの学習を行い，くも膜下出血の識別を行う異常検知の手法を提案する．実験を通して既存手法との比較を行うことで提案手法の有効性を確かめた．

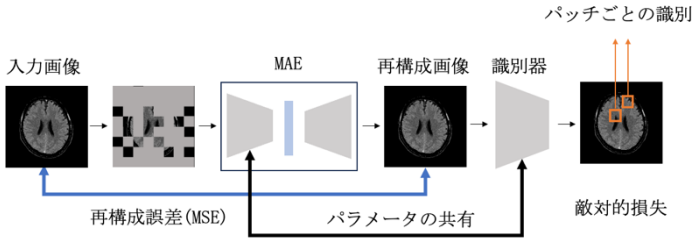


図 1 提案手法の概略

2. 関連研究

疾患のない正常な画像のみで学習を行ったモデルでは疾患に伴う異常な画像が入力された際に入力画像に忠実な再構成ができないという仮定のもとで医用画像を対象として再構成誤差に基づく異常検知が行われている．再構成誤差に基づくものとしてオートエンコーダを使用するもの[1]や，GAN を使

用するもの[2]が挙げられる．Masked Autoencoder(MAE)[3]は画像全体を小さなパッチに分割してからランダムにパッチにマスクをし，マスクされていないパッチのみをエンコーダへ入力してから全体の再構成を行う自己教師あり学習の手法である．MAE が持つ高い表現力に注目して医用画像の異常検知へ適用する手法も提案されており[4]，その既存研究においてはMAE による再構成画像の一部に対して擬似異常モジュールによる幾何学的な変化を加え，識別器を教師あり学習の枠組みで学習させている．この既存手法がくも膜下出血のような微小な異常に対しても有効であるかについて深い探索は行われていない．

3. 手法

提案手法の概略を図 1 に示す.本研究では正常な頭部 CT 画像とくも膜下出血患者の CT 画像の MAE での再構成誤差により異常検知を行う.学習時に平均二乗誤差(L_{mse})のみを損失関数として用いた MAE による再構成画像は不鮮明になりやすい．鮮明な再構成を行うために，GAN-MAE[5]で用いられていた再構成画像に対しパッチごとに再構成されたパッチか，入力画像そのままのパッチかの識別を識別器に行わせることによる敵対的損失(L_{adv})を追加する．学習時における全体の損失(L_{total})はハイパーパラメータλを用いて(1)のようになる．

$$L_{total} = L_{mse} - \lambda L_{adv} \qquad (1)$$

また，推論時には異常スコアを脳領域のみに適用するために CT 画像用の事前学習済みセグメンテーションモデルである TotalSegmentator[6]を使用して脳領域の抽出を行った．さらに，出血領域と正常な脳領域に現れる画素値の特性を考慮することで，出血領域がマスクされて入力された際における再構成誤差の寄与が大きくなるような異常スコアを設計した．

4. 実験

提案手法の有効性の確認のために日本医学放射線学会から提供していただいた，くも膜下出血患者を含む 2,873 名の頭部 CT 画像 65,053 枚に対して学習時には 2,526 名の正常画像 60,647 枚，テスト時には 164 名の正常画像 2,203 枚と 183 名の異常画像 2,203 枚に分割して実験を行った．医用画像に対し MAE を適用し異常検知を行った先行研究［4］を比較手法として用いた.また，敵対的損失を追加して MAE の学習を行ったことによる識別精度への影響を検証した.元の入力画像と再構成画像に対して提案した異常スコアを算出して ROC AUC を評価指標として実験を行った.実験結果を表 1 に示す．提案手法が比較手法よりも優れ，学習時に敵対的損失を追加したモデルにおける識別性能の向上が確認された.

	異常スコア [$\times 10^{-2}$]		ROC AUC
	正常	異常	
比較手法 [3]	-	-	0.617
MSE	3.70	4.49	0.673
MSE + 敵対的損失	3.69	4.69	**0.701**

表 1　実験結果

５．結論

本研究では再構成画像に対し敵対的損失を追加して学習した MAE により，くも膜下出血の異常検知を行った.

今後の展望としては頭部の位置情報の利用による識別精度の向上や，患者単位での識別方法の考案などが挙げられる.

謝辞

本研究は，JST ムーンショット型研究開発事業 JPMJMS2011，CREST 課題番号 JP-MJCR2015,JSPS 科研費 JP23K16990，戦略的イノベーション創造プログラム(SIP)「統合型ヘルスケアシステムの構築」JPJ012425 及び東京大学 Beyond AI 研究推進機構の基礎研究費(AI 自体の進化)の支援を受けたものです.また，貴重な CT 画像データを提供してくださった日本医学放射線学会およびその関係者の皆様に心より感謝申し上げます.

利益相反の有無

なし.

文　献

[1]N. Shvetsova, B. Bakker, I. Fedulova, H. Schulz and D. V. Dylov, "Anomaly Detection in Medical Imaging With Deep Perceptual Autoencoders," in *IEEE Access*, vol. 9, pp. 118571-118583, 2021

[2]ThomasSchlegl,PhilippSeebo¨ck,SebastianMWaldstein,UrsulaSchmidt-Erfurth, and Georg Langs. Unsupervised anomaly detection with generative adversarial networks to guide marker discovery. In *International conference on information processing in medical imaging*, pp. 146–157. Springer, 2017.

[3] Kaiming He, Xinlei Chen, Saining Xie, Yanghao Li, Piotr Dolla´r, and Ross Girshick. Masked autoencoders are scalable vision learners. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, pp. 16000–16009, 2022.

[4] Mariana-Iuliana Georgescu. Masked autoencoders for unsu- pervised anomaly detection in medical images. *Procedia Com- puter Science*, Vol. 225, pp. 969–978, 2023.

[5] ZhengcongFei,MingyuanFan,LiZhu,JunshiHuang,Xiaom- ing Wei, and Xiaolin Wei. Masked auto-encoders meet gener- ative adversarial networks and beyond. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 24449–24459, 2023.

[6] Jakob Wasserthal, Hanns-Christian Breit, Manfred T Meyer, Maurice Pradella, Daniel Hinck, Alexander W Sauter, Tobias Heye, Daniel T Boll, Joshy Cyriac, Shan Yang, et al. Totalsegmentator: Robust segmentation of 104 anatomic struc- tures in ct images. *Radiology: Artificial Intelligence*, Vol. 5, No. 5, 2023.

胸部 X 線画像における緊急性疾患向け異常検出

福島　祥之[*1]，吉田　皓文[*2]，笠井　聡[*2]，近藤　敏志[*1]
[*1] 室蘭工業大学
[*2] 新潟医療福祉大学

Anomaly detection for emergent diseases in chest X-ray Images

Yoshiyuki FUKUSHIMA[*1]，Akifumi YOSHIDA[*2]，Satoshi KASAI[*2]，Satoshi KONDO[*1]
[*1] *Muroran Institute of Technology*
[*2] *Niigata University of Health and Welfare*

要旨：胸部X線画像は健康診断において広く使用され，症例数も多いことから，放射線科医にとって読影にかかる負担は大きい．そのため，本研究では，緊急的な検査を必要とする症例，必要としない症例を異常検出手法によって区別することで膨大な検査の手間を軽減し，健康診断において早く治療しなければ重篤な疾患になる緊急性疾患を即時的に発見することを目的とする．異常検出手法として，画像向け異常検出モデルである PaDiM を用いる．画像の位置ずれに頑健ではない PaDiM の短所を補完するため，訓練段階で特徴量マップの特徴量単位で k-means クラスタリングを行い，推論段階ではクラスタごとの特徴量分布と，入力画像の特徴量分布とのマハラノビス距離を比較し，最短距離の分布を評価に用いる．AUROC の評価値を比較することで提案手法と既存手法の定量比較を行い，提案手法において既存手法を上回る性能が得られることを確認している．

キーワード：医用画像，胸部 X 線画像，異常検出

1. はじめに

胸部X線画像は健康診断において広く使用され, 症例数も多いことから，放射線科医にとって読影にかかる負担は大きい．そのため，緊急的な検査を必要とする症例，必要としない症例を異常検出手法によって区別することで膨大な検査の手間を軽減し, 医師がより緊急性の高い画像を即時的に読影できる機能が求められている．本研究では，最終的な目標として健康診断において早く治療しなければ重篤な疾患になる緊急性疾患を, 異常検出手法を用いて即時的に発見することを目的とする．

本研究では, PaDiM[1]を用いた異常検出を行う．PaDiM は正常な画像のみで再学習を行うことなく異常検出を行う機械学習モデルである．画像の位置ずれに頑健ではない PaDiM の短所を補完するため, 訓練段階で特徴量マップのパッチ単位でクラスタリングを行い, 推論段階では入力画像の特徴量分布とクラスタごとの特徴量分布とのマハラノビス距離を比較し, 最短距離の分布を評価に用いる．

2. 既存手法

本研究で用いる PaDiM は画像向けの異常検出モデルである．ImageNet の事前学習済みモデルに画像を入力して特徴を抽出した後，複数の層の特徴を連結して特徴量を計算する．複数の層から出力された特徴を組み合わせることで，局所的，大域的な特徴の両方を含んだ特徴量となり, 大きさの異なる欠陥にも対応することができる．また学習時には，正常画像の特徴量の各要素の平均と共分散を求め, 推論時にはマハラノビス距離を用いてパッチが正常の分布からどの程度乖離しているかを求める．マハラノビス距離を異常スコアとし，全てのパッチに対して計算したマハラノビス距離のうち, 最大のものを異常度とする．求めた異常度から，AUROC を算出し評価値とする．

3. 提案手法

PaDiM はパッチ単位で特徴量抽出を行うため画像の微細な異常を検出しやすいモデルであるが，一方で，一パッチあたり一つの統計量に依存するため, 画像の位置ずれに対して頑健ではないという問題点がある．本稿で述べるパッチとは，特徴量マップの最小単位を指す．

本研究では，その問題点に対し，以下 2 段階のアプローチを行う．

3.1 肺野抽出

胸部 X 線画像中の肺野の位置は，体格や撮影時の体位によって異なる．そこで，肺野領域のみの画像を用いて特徴量抽出を行うため，胸部 X 線画像から肺野領域を抽出する．肺野抽出においては, 公開されている肺野セグメンテーションモデル[2]を用いて，胸部 X 線画像のマスク画像を作成する．作成したマスク画像から肺野領域を囲むバウンディングボックスを求め，肺野領域のみを切り抜いた胸部 X 線画像を作成する．

3.2　k-means 法の導入

提案手法の訓練段階では，k-means 法を用いて特徴量マップのパッチ単位でクラスタリングを行い，クラスタごとに平均，共分散を求める．推論段階においては，入力した画像の特徴量

の分布と, 訓練時の特徴量に対するクラスタ k 個との間でそれぞれマハラノビス距離を計算し, 最も距離が近いクラスタのマハラノビス距離を採用する. 採用したマハラノビス距離を異常スコアとし, 全てのパッチに対して計算したマハラノビス距離のうち，最大のものを異常度とする．求めた異常度から，AUROC を算出し評価値とする.

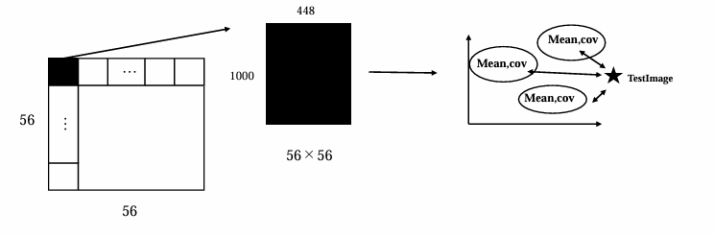


図 1 提案手法の概念図

4. 実験

本研究では，公開データセットである NIH_Chest_Xray[3] データセットを用いた．異常例の緊急性疾患としては pneumothorax を用いた．胸部 X 線画像の画素数は 1024×1024 画素とし，肺野抽出後のデータセットの内訳は，表 1 の通りとした.

PaDiM の事前学習済みモデルには ResNet18 を用いた．特徴量マップは 56×56 パッチであり，訓練画像 100 枚を用いて k-means クラスタリングを行い，訓練画像の特徴量分布を求めた. 予備実験として, 訓練時の k-means 法を実装するにあたり, エルボー法によって適切なクラスタ数 k を求めた結果, 4 クラスタとした.

テスト用画像としては，正常 30 枚，異常 30 枚の計 60 枚を用いた．異常検出の評価値としては，AUROC を用いた.

表 1 抽出後のデータセット

phase	case	number
train	Normal	100
test	Normal	30
	Pneumothorax	30

既存手法，提案手法の結果は表 2 の通りである.

実験に使用した枚数が少なく, 提案手法による改善は僅かであったが, 一パッチあたり複数の統計量と比較することで異常検出性能を改善させることができた.

表 2　既存手法，提案手法の AUROC

手法	AUROC
既存手法	0.722
提案手法	0.729

6. まとめ

本稿では， 画像の位置ずれに頑健ではない PaDiM の短所を補完するため，PaDiM に k-means 法を導入する手法を提案した. 訓練段階では特徴量マップのパッチ単位でクラスタリングを行い, 推論段階では入力画像の特徴量分布とクラスタごとの特徴量分布とのマハラノビス距離を比較し, 最短距離を異常スコアとして評価に用いた．実験の結果，胸部 X 線画像の緊急性疾患向け異常検出性能を向上させることができた.

今後の検討課題として, 画像の枚数を増やすことで既存手法との更なる性能比較をすることが挙げられる．また，医用画像用の事前学習済みモデルを用いること, 異常例として用いる緊急性疾患症例の種類を増やすこと，などが挙げられる.

利益相反の有無

本研究はコニカミノルタ(株)との共同研究に基づくものである.

文　献

［1］Defard，Thomas，et al.　"Padim: a patch distribution modeling framework for anomaly detection and localization．" *International Conference on Pattern Recognition*．Cham: Springer International Publishing，2021.

［2］https://github．com/IlliaOvcharenko/lung-segmentation

［3］Wang，Xiaosong，　et al．"Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases．" *Proceedings of the IEEE conference on computer vision and pattern recognition*，2017.

Masked Autoencoder と注意機構を用いた 12 誘導心電図の異常検知

今村　健太[*1]，黒瀬　優介[*2,3]，原田　達也[*2,3,4]
[*1] 東京大学大学院情報理工学系研究科知能機械情報学専攻
[*2] 東京大学　先端科学技術研究センター
[*3] 理化学研究所　革新知能統合研究センター
[*4] 国立情報学研究所　医療ビッグデータ研究センター

Anomaly detection of 12-lead electrocardiograms using a Masked Autoencoder and attention mechanism

Kenta IMAMURA[*1]，Yusuke KUROSE[*2,3]，Tatsuya HARADA[*2,3,4]
[*1] *Information Graduate School Science and Technology, University of Tokyo*
[*2] *Research Center for Advanced Science and Technology, The University of Tokyo*
[*3] *RIKEN Center for Advanced Intelligence Project*
[*4] *National Institute of Informatics, Medical Big Data Research Center*

要旨：迅速な対応が必要である心疾患の診断に有効である心電図に対して，近年深層学習による診断支援システムの研究が行われている．本研究の目的は 12 誘導心電図に対し，正常な心電図のみを用いて教師なし学習による高精度な異常検知を行うことである．教師なし学習による異常検知手法においては，正常な心電図の特徴を捕捉することが重要であるが、従来の研究では正常な心電図の特徴として時間変化のみを考慮していた．そこで本研究では，学習時にマスクされた誘導心電図を再構築することにより，12 誘導間の関係性を捕捉するモデルを提案した．また，モデルの学習に既知の誘導関係性を制約条件として課すことでより再構築精度の高いモデルの実現を目指した．推論時には罹患者の 12 誘導心電図は正常な 12 誘導心電図よりも再構成誤差が大きくなると仮定し異常度を算出する．また，モデルが誘導ごとでの不確実性を出力することで誘導ごとに正確な異常度を算出可能な方式を実現した．約 20,000 人の 12 誘導心電図が記録されたデータセットを使用して，実験を行い、従来手法と比較し ROCAUC が 0.04 向上することを確認した．

キーワード：異常検知，12 誘導心電図，Masked Autoencoder，強い制約条件，不確実性

1. 研究背景と目的

心電図は非侵襲的で安全かつ効果的な手段として，心疾患の診断の為に広く使われてきた手法である．中でも 12 誘導心電図は，単一の誘導に症状が顕れない疾患に対しても有効な手法として日常診療で使用される．そして近年深層学習の研究が発展し，12 誘導心電図に対する診断支援システムの研究が行われている．しかし，一般的に教師あり学習での識別性能を向上させるためには大量のラベル付きデータが必要であり，特に医療データである 12 誘導心電図は専門家による大量のラベル付きデータセットの作成が必要不可欠であり，大きなコストがかかる問題がある．そのため，正常データのみでアノテーション不要で訓練可能な，教師なし学習による異常検知の研究が盛んに行われている．

12 誘導心電図は 12 方向から心臓の電位活動を観測したデータセットであるため，四肢誘導間には Einthoven の法則が存在し［1]，他の誘導間も強く関連しあっていると考えられる．この時，誘導間の依存関係を捉えることが正常データの特徴を捉えることに対して有効であると考えられる．また，専門家が異常を診断する時には，誘導ごとに異常か正常かを判断し，総合的にその人が異常であるか，どんな症状であるかを診断する．そのため，患者ごとの異常検知だけでなく誘導ごとでの正確な異常度を計算する必要がある．

そこで本研究では，12 誘導心電図に対して教師なし学習による異常検知を行う．その際正常データにおける誘導間の関係性を考慮に加えることで，教師なし学習でも高い異常検知精度を達成することを目指す．

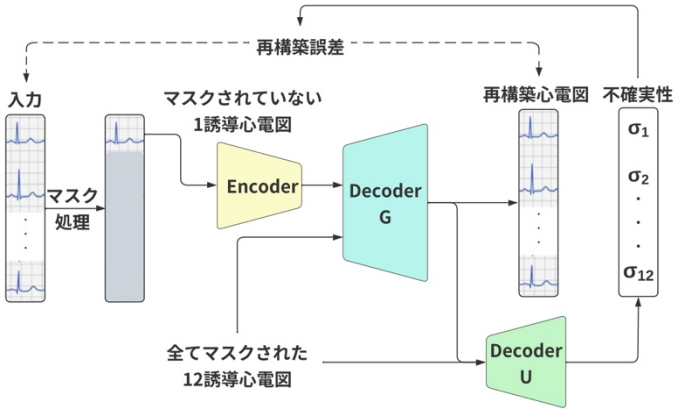


図 1　提案手法のパイプライン

2. 関連研究

心疾患への診断支援のために深層学習による心電図の異常検知をする研究はいくつかなされてきた. 教師なし学習の代表的な方法として，Convolutional Neural Network をベースとした再構築モデルが利用されている［4］. しかし，従来手法では，正常な心電図の特徴に対して, 時間変化のみの考慮だけであり，誘導間の関係性に着目したモデルは提案されていない. それに加え, 誘導ごとでの異常度を正確に算出できていないという問題がある.

3. 提案手法

本研究では, 教師なし学習による異常検知のためのフレームワークとして Masked Autoencoder［2］を参考にした. 1 誘導心電図のみから他の 12 誘導心電図を生成させるように訓練させることで, モデルに誘導間の関係性を学習させる新しい生成手法を提案する. 手法全体のパイプラインを図 1 に示す.

訓練時，正常な 12 誘導心電図$\{x_{\tau,l} \mid \tau = 1,\ldots,T, l = 1,\ldots,12\}$の 11 誘導がランダムにマスクされ入力される. その後, 自己注意機構で構成されたエンコーダは正常な心電図の時間変化の特徴を学習する. デコーダ G はマスクされた 12 誘導心電図とエンコーダからの出力心電図の関係性を利用して，12 誘導心電図$\{\hat{x}_{\tau,l} \mid \tau = 1,\ldots,T, l = 1,\ldots,12\}$を再構築するよう訓練される. デコーダ U は誘導ごとに不確実性$\{\sigma_{\tau,l} \mid \tau = 1,\ldots,T, l = 1,\ldots,12\}$を算出し，再構築誤差を誘導ごとに正規化し，正確な異常度を算出する. 再構築誤差が入力に依存する多変量ガウス分布に従い，時間ごと，誘導ごとに独立であると仮定すると，損失関数は以下のように定式化される.

$$Loss = \frac{1}{T}\frac{1}{12}\sum_{\tau=1}^{T}\left(\sum_{l=1}^{12}\frac{(x_{\tau,l}-\hat{x}_{\tau,l})^2}{\sigma_{\tau,l}^2} + \log\sigma_{\tau,l}^2\right) \quad (1)$$

また, 最終的に生成後の 12 誘導心電図が四肢誘導において Einthoven の法則を保つために，四肢誘導同士に制約条件を付加する. これよりモデル全体が正常な心電図の誘導間の関係性を捕捉するように訓練させる.

推論時マスクされない誘導が重複しないように繰り返し 12 回マスク処理が施され，その都度心電図は再構築され，再構築誤差から異常度が算出されている. 最終的な患者の異常度は算術平均として算出される.

3. 実験

提案手法の有効性を評価するため，12 誘導心電図の異常検知での実験を行った. データセットには 18,885 人の 12 誘導心電図が記録されたデータ［5］を使用する. 比較手法として, 一般的な時系列に対する教師なし学習による異常検知手法を提案した Anomaly Transformer［3］と，心電図の異常検知に特化した，教師なし学習による異常検知モデルである ECGAD［4］を使用する. 評価手法には ROC 曲線の AUC を使用した. 以下に患者ごとでの異常検知において, 比較手法と提案手法で 5 回ずつ実験をした結果の平均と標準偏差を表 1 に示す. 表 1 より提案手法がより高精度な異常検知が可能であることを示している.

表 1 ROC-AUC 値

手法	平均 ± 標準偏差
Anomaly Transformer	0.760 ± 0.033
ECGAD	0.902 ± 0.007
Proposed Method	0.942 ± 0.002

4. 結論と今後の展望

本研究ではラベル付きデータが少ない医療データである 12 誘導心電図に対して，教師なし学習での異常検知を行った. その際，提案手法により，一部のテストデータにおいて患者ごとでの異常検知精度が向上することが示された. 今後は提案手法においても再構築に問題があった, 四肢誘導の心電図をどう生成するのかについて検討していく.

謝辞

本研究は，JST ムーンショット型研究開発事業 JPMJMS2011，CREST 課題番号 JP- MJCR2015, JSPS 科研費 JP23K16990，戦略的イノベーション創造プログラム (SIP)「統合型ヘルスケアシステムの構築」JPJ012425 及び東京大学 Beyond AI 研究推進機構の基礎研究費 (AI 自体の進化) の支援を受けたものです.

利益相反の有無

なし

文　献

［1］ Einthoven, W. “The different forms of the human electrocardiogram and their signification.” In: The Lancet 179.4622 (1912), pp. 853–861.

［2］ He, K. et al. “Masked autoencoders are scalable vision learners”. In:Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2022, pp. 16000–16009.

［3］ Xu, J. et al. “Anomaly Transformer: Time Series Anomaly Detection with Association Discrepancy”. In: International Conference on Learning Representations. 2022.

［4］ Jiang, A. et al. “Multi-scale Cross-restoration Framework for Electrocardiogram Anomaly Detection”. In: International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer. 2023, pp. 87–97.

［5］ Patrick W. et al. Ptb-xl, a large publicly available electrocardiography dataset. Scientific data, Vol. 7, No. 1, p. 154, 2020.

Optimizing YOLOv8 for Leukemia Subtype Detection using Grey Wolf Algorithm-Based Hyperparameter Tuning

Tanzilal MUSTAQIM[1], Chastine FATICHAH[*1], Nanik SUCIATI[1], Takashi OBI[2], Joong-Sun LEE[2]

[*1] *Department of Informatics, Faculty of Electrical Technology and Intelligent Information Technology, Institut Teknologi Sepuluh Nopember, Indonesia*

[*2] *Department of Information and Communications Engineering, Institute of Innovative Research, Tokyo Institute of Technology, Japan*

Abstract : The accurate identification of Acute Lymphoblastic Leukemia (ALL) subtypes is critical for developing effective treatment plans. Traditional manual diagnosis procedures are time- consuming, subjective, and prone to error, necessitating the development of automated and reliable diagnostic methods. This study aims to improve the diagnostic accuracy and efficiency of ALL subtype detection by optimizing the hyperparameters of the You Only Look Once version 8 (YOLOv8) algorithm with the Grey Wolf Optimizer (GWO), a nature- inspired optimization method. The YOLOv8 algorithm has advantages from speed and accuracy in object detection tasks especially medical image domain. However, its efficiency is strongly reliant on the correct selection of hyperparameters, which is a challenging task due to the algorithm's complexity and the enormous dimensionality of the search space. The proposed method leverages the GWO algorithm for hyperparameter tuning, which is inspired by grey wolves' social hierarchy and hunting. This approach aims to systematically explore the hyperparameter space in order to identify the optimal configuration that maximizes the algorithm's effectiveness in detecting ALL subtypes. Our methodology involves a quantitative analysis using a dataset of annotated medical images of distinct ALL subtypes, with the aim of achieving superior model performance metrics compared to baseline YOLOv8 models.

Keywords: Acute Lymphoblastic Leukemia (ALL), YOLOv8, Grey Wolf Optimizer (GWO), Hyperparameter Tuning, Medical Image Analysis

1. Introduction

Acute Lymphoblastic Leukemia (ALL) is a critical cancer form that originates from premature lymphocytes in the bone marrow, leading to the rapid proliferation of immature blood cells that impede the function of normal cells and result in severe health issues like infections, anemia, and bleeding disorders [1]. Hematologists manually examine blood and bone marrow samples under the microscope to identify and classify abnormal lymphoblasts based on their morphology for ALL detection and classification [2]. This method, with its time-consuming process, subjective hematologist judgments, and high error rate—especially in unclear cases—poses significant challenges. The need for dependable and automated diagnostic techniques that boost accuracy, decrease diagnostic times, and eliminate human bias is highlighted by these limitations.

The medical imaging field, especially for ALL disease detection, now uses sophisticated machine learning models like YOLOv8 in response to recent challenges. The precision of hyperparameter tuning in complex models significantly influences their effectiveness [3]. Efficient handling of large search spaces is a challenge for traditional optimization methods like grid search and random search [4]. This study presents the Grey Wolf Optimizer (GWO), based on grey wolves' social hierarchy and hunting methods, as a solution to rectify the inefficiencies [5]. By efficiently searching complex, high-dimensional hyperparameter spaces and dynamically adapting tactics based on the fitness landscape, GWO enhances its search process effectiveness [6]. Through optimizing YOLOv8 model's hyperparameters using the GWO algorithm, we achieve a more precise diagnosis of ALL, enhancing treatment planning and favorable patient outcomes. This method, emphasizing hyperparameter tuning, not only boosts model performance in medical diagnostics but also establishes a new benchmark for advanced machine learning applications.

2. Proposed Methodology

This study enhances the diagnostic accuracy of the YOLOv8 algorithm for Acute Lymphoblastic Leukemia (ALL) subtype detection by optimizing it with the Grey Wolf Optimizer (GWO). Inspired by grey wolves' social hierarchy and hunting tactics, the GWO algorithm refines YOLOv8's hyperparameters over 50 iterations with ten candidate solutions, as illustrated in Fig 1. Key adjustments include learning rate, weight decay, warmup epochs, and optimizer selection, focusing on improving performance metrics such as Precision, Recall, and mean Average Precision (mAP) across different Intersection over Union (IoU) thresholds. The optimization utilizes a dataset of 301 high-quality microscopic images from Fatonah et al. (2020), enabling precise morphological examinations. Moreover, the study details the model’s enhanced computational efficiency by breaking down inference timing into preprocessing, inference, and postprocessing phases, ensuring faster and more

Table I. Metric Evaluation Result

Type	Class	Precision	Recall	mAP50	mAP50-95
Original	ALL (Average)	56.1%	73%	66.6%	47.9%
	Lymphocytes	68.6%	81.1%	80.4%	56.2%
	Prolymphocyte	37.1%	48.6%	34.9%	26.1%
	Lymphoblast	62.7%	89.1%	84.4%	61.5%
Hyperparameter Optimized	ALL (Average)	60%	79.7%	71.9%	53.9%
	Lymphocytes	73.8%	76.1%	83.9%	61%
	Prolymphocyte	35.4%	68.4%	40.6%	31.3%
	Lymphoblast	70.8%	94.6%	91.1%	69.5%

Table II. Inference Time Result

Type	Preprocess (ms)	Inference (ms)	Postprocess (ms)	Total (ms)
Original	0.1	0.7	0.5	1.3
Hyperparameter Optimized	0.1	0.7	0.4	1.2

reliable diagnostics for medical applications.

3. Result and Discussion

The integration of the Grey Wolf Optimizer (GWO) with the YOLOv8 algorithm for detecting Acute Lymphoblastic Leukemia (ALL) subtypes significantly enhanced model accuracy and efficiency through precise hyperparameter tuning. Key adjustments included setting the initial learning rate at 0.0008841232752634459 and weight decay at 0.0005080818185553845 to prevent overfitting, with nine warmup epochs to stabilize training. Additional tweaks involved a warmup momentum of 0.95 and a bias learning rate of 0.05659936775293075, using the Adam optimizer for its adaptive capabilities. After discontinuing mosaic data augmentation post-epoch 17, performance metrics improved dramatically: precision rose from 56.1% to 60%, recall from 73% to 79.7%, and mean Average Precision (mAP) at 50% IoU from 66.6% to 71.9%, with notable gains in precision and mAP for Lymphocytes and Lymphoblasts. This refinement also reduced total processing time from 1.3 ms to 1.2 ms, as shown in Tables I and II, highlighting GWO's role in bolstering the YOLOv8 model's viability for rapid and reliable medical diagnostics.

4. Conclusion

The Grey Wolf Optimizer (GWO) significantly enhanced the YOLOv8 model's performance in detecting acute lymphoblastic leukemia (ALL) subtypes, boosting precision from 56.1% to 60% and recall from 73% to 79.7%. Improvements in mean Average Precision (mAP) were also notable, with mAP50 increasing from 66.6% to 71.9% and mAP50-95 from 47.9% to 53.9%. These enhancements in diagnostic accuracy and computational efficiency make the model more suitable for real-time medical applications.

References

[1] T. Mustaqim, C. Fatichah, and N. Suciati, "Deep learning for the detection of acute lymphoblastic leukemia subtypes on microscopic images: A systematic literature review," *IEEE Access*, 2023.

[2] A. Shah, S. S. Naqvi, K. Naveed, N. Salem, M. A. U. Khan, and K. S. Alimgeer, "Automated Diagnosis of Leukemia: A Comprehensive Review," *IEEE Access*, vol. 9, pp. 132097–132124, 2021, doi: 10.1109/ACCESS.2021.3114059.

[3] G. Atteia, A. Alhussan, and N. Samee, "BO-ALLCNN: Bayesian-Based Optimized CNN for Acute Lymphoblastic Leukemia Detection in Microscopic Blood Smear Images," *Sensors*, vol. 22, no. 15, p. 5520, Jul. 2022, doi: 10.3390/s22155520.

[4] L. F. Rodrigues, A. R. Backes, B. A. N. Travençolo, and G. M. B. de Oliveira, "Optimizing a Deep Residual Neural Network with Genetic Algorithm for Acute Lymphoblastic Leukemia Classification," *J. Digit. Imaging*, vol. 35, no. 3, pp. 623–637, 2022, doi: 10.1007/s10278-022-00600-3.

[5] S. Mirjalili, S. M. Mirjalili, and A. Lewis, "Grey Wolf Optimizer," *Adv. Eng. Softw.*, vol. 69, pp. 46–61, Mar. 2014, doi: 10.1016/j.advengsoft.2013.12.007.

[6] T. Tahsin *et al.*, "GWO-XGB: Grey Wolf Optimization-based eXtreme Gradient Boosting for Hypertension Prediction in Bangladesh," *Proc. Int. Conf. Electron. Commun. Inf. Technol. ICECIT 2021*, 2021, doi: 10.1109/ICECIT54077.2021.9641256.

Computer-aided classification of robot-assisted radical prostatectomy (RARP) images on neurovascular bundle (NVB) preservation

Diego Andres DEL AGUILA MORAGA[*1], Huitao WANG[*1], Satoshi ANDO[*2], Hayato HOSHINA[*2], Hiroshi KAWAHIRA[*3], Yukihiro NOMURA[*4], Toshiya NAKAGUCHI[*4]

[*1] *Department of Medical Engineering, Graduate School of Science and Engineering, Chiba University*

[*2] *Department of Urology, Jichi Medical University*

[*3] *Medical Simulation Center, Jichi Medical University*

[*4] *Center for Frontier Medical Engineering, Chiba University*

Abstract : During RARP operations, the patient's prostate is removed, and the surgeon must do it in such a way as not to damage healthy surrounding structures, such as the neurovascular bundles (NVB) since these are located around the prostate. Preservation of the surrounding structures of the patient's pelvic area promotes the patient's rapid recovery. It also reduces the risk of postoperative problems such as urinary incontinence and erectile dysfunction, among others. With advances in computer vision and deep learning models, we propose to create a computer-aided diagnosis (CAD) system that can predict whether the neurovascular bundles were preserved during the operation to prevent postoperative problems and allow the patient to recover rapidly. Fragments of RARP operations are used as input for the CAD system, and as for output, the confidence level of NVB preservation is returned. For the training of the DL Model, we employed a rigorous methodology, including fine-tuning, oversampling, and using the Youden index. This meticulous approach ensures the reliability and accuracy of our system, giving you the confidence you need in its high performance. We have achieved an impressive average accuracy of 0.86, precision of 0.90, recall of 0.84, F1-score of 0.86, and AUROC of 0.91 across 5-fold.

Keywords : Deep Learning, CAD System, Image processing, Oversampling, Fusion Ensemble, laparoscopic surgery, NVB, RARP

1. Introduction

The prostate gland, situated below the bladder and surrounding the urethra, is a vital part of the male reproductive system. Prostate cancer, a leading cause of mortality among men, often necessitates partial or total removal of the gland. Globally, it is the second most common cancer in men, with over 1.4 million new cases diagnosed in 2020 [1].

Robotic-Assisted Radical Prostatectomy (RARP) is a procedure where the prostate is removed using a robotic system controlled by the surgeon. During surgery, the aim is to minimize damage to surrounding structures, particularly the neurovascular bundles (NVB), crucial for rapid recovery and reducing postoperative complications like urinary incontinence [2].

This research aims to develop a computer-aided diagnosis (CAD) system using computer vision and deep learning to predict NVB preservation and enhance recovery outcomes. Training a neural network to classify NVB preservation has shown promise, and using RARP surgery videos as input can further improve model confidence and feature extraction.

2. Materials and Proposed Method

2.1 Materials

We collected 418 images from patients who underwent RARP surgery at Jichi Medical University between 2016 and 2022. The dataset, approved by the Ethics Review Committee (Number 臨附 23-155), includes RGB images in *.tiff format with an average resolution of 2880 x 1800 pixels. These images are pre-processed to remove black frames and cropped to focus on the region of interest (ROI) around the pelvic cavity.

The dataset is labeled into two classes: “NVB” (174 cases), where the NVB was preserved, and “NO_NVB” (244 cases), where it was not. For training, images are resized to 256 x 256 pixels, with additional augmentations like random cropping, rotation, zooming, and horizontal flipping to enhance the model's performance.

2.2 Proposed Method

Four classification models (ResNet50[3], ResNet18[3], MovileNetV2[4], and EfficientNetV2-S [5]) were modified to classify NVB preservation as a binary output (NVB preserved or not). Due to the limited dataset, transfer learning was employed using pre-trained models. Multiple experiments were conducted to identify suitable hyperparameters, systematically changing one variable at a time. These experiments were named sequentially (X1 to X6) and tested variables like "Weighted Loss Function," "Oversampling," and combinations thereof.

For each experiment, three forms of preprocessed images were used: "Full-Size Image," "ROI-Fix Image," and "ROI-Without-Distractors."

Full-Size Image: This automatic process removes black frames

around the laparoscope image, capturing the entire view for analysis.

ROI-Fix Image: This manual method uses a fixed window to crop "Full-Size" images, focusing on the area around the prostate gland.

ROI-Without-Distractors: This manual method extracts the ROI while excluding surgical instruments that could impact classification accuracy.

The top ten experiments with the highest accuracy were used to create a fusion ensemble, each using 5-fold cross-validation.

3. Experimental Results

The experiments were implemented in Python using libraries like OpenCV for Python, PyTorch, matplotlib, pandas, and NumPy within the framework of PyTorch Lightning.

The experiments that returned better results were X5 and X6, which were applied to "Oversampling for Balancing" and "Oversampling for Balancing + Loss Function: BCEWithlogistisLoss." The models that best responded to these changes were RenNet50 and EfficentNetV2. As shown in Table 1

After applying Youden's index to determine the ideal threshold, the fusion-type assembly archives an average accuracy of 0.83 precision of 0.92, recall of 0.76, F1-score of 0.82, and AUROC of 0.92 across 5-fold. (see Table 2).

E8M+Youden						
Fold	Accuracy	Precision	Recall	F1 Score	AUROC	J
1	0.8235	1.0000	0.6667	0.8000	0.9444	0.6520
2	0.8333	0.8000	0.8889	0.8421	0.9383	0.4942
3	0.8824	1.0000	0.7778	0.8750	0.9861	0.5853
4	0.7647	1.0000	0.5556	0.7143	0.8472	0.6970
5	0.8235	0.8000	0.8889	0.8421	0.9028	0.3617
Avg.	0.8255	0.9200	0.7556	0.8147	0.9238	

Table 2. The results of the five folds of the Fusion Ensemble were obtained using the optimal threshold according to Youden's index.

4. Discussion and Conclusion

Our study demonstrates the effectiveness of deep learning models for classifying NVB preservation in RARP images, achieving high-performance metrics: an accuracy of 0.86, precision of 0.90, recall of 0.84, F1-score of 0.86, and AUROC of 0.91. These results indicate reliable prediction capabilities for NVB preservation. Addressing class imbalance with oversampling and balanced loss functions significantly improved model performance. Using transfer learning with pre-trained models further enhanced the robustness of our CAD system. Additionally, manual ROI extraction methods like "ROI-Fix" and "ROI-Without-Distractors" improved model focus by reducing noise from surgical instruments.

This research proposes and develops a CAD system-based image classification to determine if the patient's NVB was preserved. Trained using techniques such as oversampling, fine-tuning, and ensemble modeling, our CAD system shows high performance and reliability. It has the potential to aid surgeons in making informed decisions during and after RARP surgeries, ultimately improving patient outcomes and recovery.

Future research could explore using video frames from RARP surgeries to provide temporal context, potentially enhancing classification accuracy. However, our study has limitations, including dataset constraints from a single institution and potential subjectivity in manual labeling. Expanding the dataset and incorporating automated labeling techniques could address these issues. Future work should explore additional input methods like video frames to enhance the model's accuracy and generalizability.

Conflict of Interest: None

References

[1] Ferlay J, Ervik M, Lam F, Colombet M, Mery L, Piñeros M, et al. Global Cancer Observatory: Cancer Today. Lyon: International Agency for Research on Cancer; 2020 (https://gco.iarc.fr/today, accessed February 2021)

[2] Ando S, Sugihara T, Hinotsu S, Kishino H, Hirata D, Watanabe R, Yanase A, Yokoyama H, Hoshina H, Endo K, Kamei J, Takaoka E, Fujimura T. Early recovery of urinary continence after robot-assisted radical prostatectomy is associated with membranous urethra and neurovascular bundle preservation. Int J Urol. 2024 May;31(5):492-499. doi: 10.1111/iju.15388. Epub 2024 Jan 9. PMID: 38196247.

[3] He, K, Zhang, X, Ren, S, & Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).

[4] Sandler M, Howard A, Zhu M, Zhmoginov A, Chen LC. Mobilenetv2: Inverted residuals and linear bottlenecks. In Proceedings of the IEEE conference on computer vision and pattern recognition 2018 (pp. 4510-4520).

[5] Tan M, Le Q. Efficientnetv2: Smaller models and faster training. In International conference on machine learning 2021 Jul 1 (pp. 10096-10106). PMLR.

Experiment	Input Type	Model	Accuracy	Precision	Recall	F1 Score	AUROC
X1 – Base Line	ROI-Without-Distractors	MobileNetV2	0.8227	0.7000	0.7333	0.6562	0.7592
X2 – Weighted Loss Function (WL)	Full-size	ResNet18	0.8061	0.6667	0.7334	0.6767	0.7917
X3 – Oversampling	ROI-Without-Distractors	ResNet50	0.8000	0.6470	0.5600	0.5942	0.7736
X4 – Oversampling + WL	Full-size	ResNet50	0.7786	0.5800	0.6000	0.5893	0.7369
X5 – Oversampling for Balance	ROI-FIX	EfficientNetV2	0.8608	0.8678	0.8667	0.8651	0.9130
X6 – Oversampling for Balancing/ BCEwLLoss	ROI-FIX	ResNet50	0.8830	0.8336	0.9778	0.8988	0.9389

Table 1. Results of experiments from X1 to X6 showing those with higher accuracy

Peripheral Pulmonary Lesions Classification in Endobronchial Ultrasonography Using a Multi-branch Framework and Voting Mechanism

Huitao WANG[*1], Kohei SHIKANO[*2], Takahiro NAKAJIMA[*3], Ziyao LI[*4]
Yukihiro NOMURA[*5], Toshiya NAKAGUCHI[*5]
[*1] *Graduate School of Science and Engineering, Chiba University*
[*2] *Department of Respirology, Graduate School of Medicine, Chiba University.*
[*3] *Department of General Thoracic Surgery, Dokkyo Medical University.*
[*4] *East Hospital of Tongji University.*
[*5] *Center for Frontier Medical Engineering, Chiba University.*

Abstract: Background: Lung cancer stands as a significant contributor to cancer-related fatalities worldwide. Endobronchial ultrasonography (EBUS) plays a crucial role in the early diagnosis of lung cancer. A challenge is that even highly experienced physicians cannot directly determine the benign or malignant peripheral pulmonary lesions (PPLs) through EBUS images. Methods: This study develops a computer-aided diagnosis (CAD) system capable of accurately predicting the benign or malignant nature of PPLs directly from EBUS images. This advancement aims to afford patients more treatment time and significantly reduce physicians' diagnostic time. Another challenge is the issue of data imbalance, where the number of malignant cases in the dataset far exceeds the number of benign cases. To address the issues, we propose an innovative multi-branch framework with multiple convolutional neural network (CNN) models. Each CNN model is trained independently. The ensemble of predictions from multiple branches' CNN models is integrated using a majority voting method to form the final prediction result of the model. Also, the Bayesian optimization algorithm is employed to integrate the distinct CNN models. Furthermore, we explored a coordinate system transformation approach, wherein the original EBUS images are converted from polar coordinates to Cartesian coordinates. This innovative image-processing method aims to optimize the representation of images, enhancing the effectiveness of subsequent analyses. The CAD system was evaluated on a set of 2760 EBUS images consisting of 95 lung cancer cases consisting of 82 malignant cases and 13 benign cases. Results: The proposed multi-branch CAD diagnostic system utilizing transformed EBUS images achieved a level of 0.80 in terms of area under the curve, with an accuracy of 0.78, F1-score of 0.80, positive predictive value of 0.77, negative predictive value of 0.83, sensitivity of 0.85, and specificity of 0.72.
Keywords: Lung Cancer, Endobronchial Ultrasonography (EBUS), Peripheral Pulmonary Lesions (PPLs), Majority Voting, Multi-branch

1. Introduction

Lung cancer has consistently ranked among the most prevalent cancers globally, both in terms of incidence and mortality rates. On a global scale, lung cancer stands as the foremost cause of new cancer diagnoses and cancer-related deaths. An estimated 1.6 million individuals succumb to lung cancer annually [1]. Furthermore, there exists a close association between the incidence and mortality rates of lung cancer, as most individuals diagnosed with this ailment ultimately succumb to it [2]. Therefore, early diagnosis and timely treatment of lung cancer are paramount in improving patient survival rates. In recent years, with the widespread application of deep learning algorithms, a plethora of studies have been dedicated to leveraging these advanced algorithms to design diagnostic support systems. The aim is to assist physicians in achieving faster and more accurate results in lung cancer diagnosis. This research developed a computer-aided diagnosis (CAD) system based on the ensemble learning and down-sampling technique to differentiate the benign and malignant PPLs in EBUS images.

2. Materials and Proposed Method

2.1 Materials

The study encompassed a total of 95 patients who underwent endobronchial ultrasound-guided transbronchial lung biopsy (EBUS-TBLB) during the periods from September 2019 to April 2020 and January to May 2022. In the experimental data, there are 82 malignant cases and 13 benign cases. Since the original EBUS data is video data in MOV format, each frame was converted to an image as a preprocessing. After that, image screening is performed to screen the noisy images. Then, the data will be randomly divided into training, validation, and testing sets in the ratio of 2160:300:300. Moreover, data augmentation techniques were also employed in the experiments. For example, techniques such as random horizontal flipping, random vertical flipping, random rotation, brightness adjustment, contrast adjustment, and saturation adjustment were applied. By employing data augmentation, the diversity of image data is increased, thereby enhancing the performance and generalization ability of deep learning models.

2.2 Proposed Method

The CAD system is shown in Figure 1. Due to the extreme imbalance in the dataset, with the number of malignant data being over six times that of benign data, directly training a CNN model would result in a model biased towards malignant data while ignoring benign data. To address this issue, we propose a multi-branch framework. First, we evenly split the malignant data in the training set into seven parts, ensuring that each part contains approximately the same amount of malignant data as the benign data. Then, we combine each of these evenly split malignant data parts with the benign data to create seven different sub-datasets. Each branch corresponds to one of these sub-datasets. A CNN model is then trained on each sub-dataset separately. Finally, using a majority voting mechanism, the predictions from the CNN models on these multiple branches are integrated to produce the final prediction result. Additionally, we discussed the method of model fusion based on the Bayesian Optimization (BO) algorithm [3].

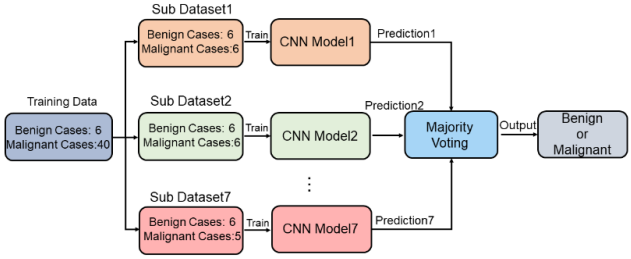


Figure 1. Constructed CAD framework which is based on multi-branch and majority voting. First, a CNN model is trained on each branch separately. Then, using a majority voting mechanism, the predictions from these multiple branch models are integrated to produce the final prediction result.

3. Experimental Results

The experiments were implemented in Python programming language with Python libraries such as OpenCV-python, Scikit-learn, matplotlib, and NumPy.

Seven distinct CNN models were employed as backbone networks, namely ResNet-18, ResNet-50 [4], DenseNet-121, DenseNet-169 [5], MobileNet-V2 [6], ShuffleNet-V2, and EfficientNet-B0. For each CNN model, the original convolutional layers were preserved, and during training, these layers were immobilized, concentrating exclusively on the training of the fully connected layers.

In our research, we employed seven metrics to evaluate the classification performance of the CAD system: Accuracy, Sensitivity, Specificity, Positive Predictive Value (PPV), Negative Predictive Value (NPV), F1 Score, and Area Under the Curve (AUC). Additionally, a four-fold cross-validation was employed.

Based on the experimental results, when conducting majority voting, DenseNet-121 achieved the best experimental results with an accuracy and AUC of 0.71. When using BO-based majority voting, the experimental results can be further improved. Compared to the results of DenseNet-121, the accuracy increased by 7% and the AUC increased by 9%.

4. Conclusion

This research developed a multi-branch CAD framework based on the majority voting and down-sampling technique to differentiate the benign and malignant PPLs in EBUS images. The final experimental results are accuracy, F1-Score, AUC, PPV, NPV, sensitivity, and specificity are 0.78, 0.80, 0.80, 0.77, 0.83, 0.85, and 0.72 respectively. From the experiment results, the developed CAD framework has the potential ability to diagnose PPLs by using the EBUS images based on deep learning.

Conflict of Interest: None

References

[1] Herbst, RS. Morgensztern D, Boshoff C: The biology and management of non-small cell lung cancer. Nature 553(7689): 446-454, 2018.

[2] Dela Cruz CS, Tanoue LT, Matthay RA: Lung cancer: epidemiology, etiology, and prevention. Clinics in Chest Medicine 32(4): 605-644, 2011.

[3] Snoek J, Larochelle H, Adams RP: Practical Bayesian optimization of machine learning algorithms. Advances in Neural Information Processing Systems, 25, Lake Taboe, pp.2951-2959

[4] He K, Zhang X, Ren S, et al: Deep residual learning for image recognition. In: Proceedings of IEEE CVPR 2016, Las Vegas, 2016, pp. 770-778

[5] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks. In: Proceedings of IEEE CVPR 2017, Honolulu, 2017, pp. 2261-2269

[6] Sandler M, Howard M, Zhu M, et al. MobilenetV2: inverted residuals and linear bot-tlenecks. In: Proceedings of IEEE CVPR 2018, Salt Lake City, 2018, pp. 4510-4520

Table1. Comparison results between majority voting and BO-based method.

	Model Name	Accuracy	F1-score	AUC	PPV	NPV	Sensitivity	Specificity
Majority Voting	ResNet-18	0.68	0.68	0.68	0.74	0.60	0.68	0.67
	DenseNet-121	0.71	0.67	0.71	0.81	0.69	0.61	0.81
	MobileNet-V2	0.67	0.69	0.67	0.73	0.65	0.71	0.64
BO-based	-	**0.78**	**0.80**	**0.80**	**0.77**	**0.83**	**0.85**	**0.72**

SE Block を導入した 3D ResNet による大動脈弁狭窄症の重症度自動分類

佐橋　拓哉[*1]，中山　良平[*1]，檜作　彰良[*1]，岡本　寛樹[*2]
[*1] 立命館大学大学院理工学研究科
[*2] 滋賀医科大学循環器内科

Computerized staging classification of aortic valve stenosis using 3D ResNet with SE-Block

Takuya SAHASHI[*1]，Ryohei NAKAYAMA[*1]，Akiyoshi HIZUKURI[*1]，Hiroki OKAMOTO[*2]
[*1] *Graduate School of Science and Engineering, Ritsumeikan University*
[*2] *Department of Cardiovascular Medicine, Shiga University of Medical Science*

要旨：大動脈弁狭窄症（AS：Aortic Stenosis）は，大動脈弁の開口部が狭くなり，左心室と大動脈の間の血流が障害される病態で，その主な原因の一つとして石灰化が挙げられる．AS の重症度は，石灰化の体積や最大血流速度など，複数の要素に基づいて評価されるため，AS の重症度を簡便に評価する手法の開発が求められている．そこで本研究では，心臓 CT 画像から AS の重症と中等症を自動分類する手法を提案する．実験試料は，収縮期と拡張期の心臓 CT 画像 142 症例（中等症 : 43 症例，重症 : 99 症例）である．提案手法は，収縮期の大動脈弁を解析する 3D-ResNet と拡張期の大動脈弁を解析する 3D-ResNet の各出力を統合的に解析する Two-Stream ConvNets で構成される．また，有用な特徴マップに重み付けする SE Block を各 3D-ResNet に導入した．提案手法による AUROC は 0.92 で，収縮期だけを解析した 3D-ResNet（0.76），拡張期だけを解析した 3D-ResNet（0.78）より高い結果が得られ，その有用性が示唆された．

キーワード：心臓 CT 画像，大動脈弁狭窄症，3D-ResNet，Two-Stream ConvNets，SE Block

1. はじめに

大動脈弁狭窄症（AS：Aortic Stenosis）は，大動脈弁の開口部が狭くなり，左心室と大動脈の間の血流が障害される病態で，その主な原因の一つとして石灰化が挙げられる．AS の重症度は，石灰化の体積や最大血流速度など，複数の要素に基づいて評価されるため，AS の重症度を簡便に評価する手法の開発が求められている．

これまでに深層学習技術の一つである畳み込みニューラルネットワーク（CNN：Convolutional Neural Network）を用いたコンピュータ支援診断手法が数多く報告されている．深いネットワーク構成で学習が進まない問題を残差接続により解決した 3D-ResNet は，様々な研究で広く使用されている[1]．また，既存モデルに追加することにより，有用な特徴マップに重みを付けて，精度の改善を図る SE Block（Squeeze and Excitation Block）もある[2]．

AS の重症度を評価するためには，収縮期と拡張期の大動脈弁の変化を解析することが重要である．本研究では，まず，3D ResNet に SE Block を導入した SE-ResNet を構築する．そして，収縮期の大動脈弁を解析する SE-ResNet と拡張期の大動脈弁を解析する SE-ResNet の各出力を統合的に解析する Two-Stream SE-ResNet を構築し，心臓 CT 画像から AS の重症と中等症を自動分類する手法を提案する．

2. 実験試料

実験試料は，滋賀医科大学附属病院で拡張期と収縮期に撮影された 142 症例（中等症 : 43 症例，重症 : 99 症例）の心臓 CT 画像である．図 1 に収縮期と拡張期における大動脈弁狭窄症の中等症と重症の心臓 CT 画像の例を示す．画像サイズは 512×512 画素であり，各症例のスライス画像数は 20 枚である．本研究では，提案手法の学習用に 112 症例（中等症 : 30 症例，重症 : 82 症例），検証用に 13 症例（6 症例，7 症例），評価用に 17 症例（7 症例，10 症例）を使用した．

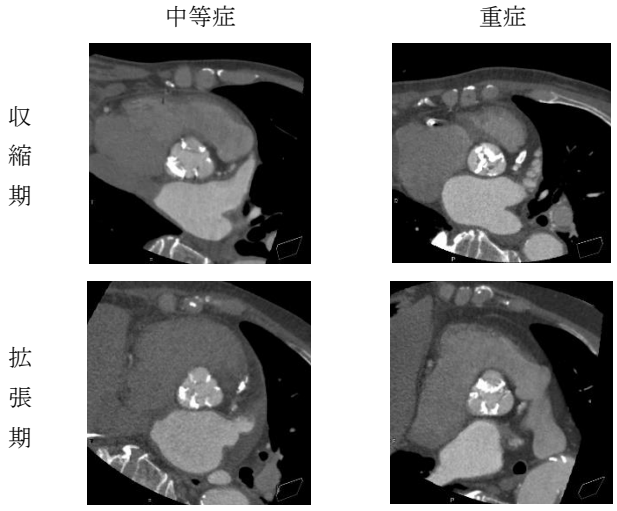


図 1：収縮期・拡張期の中等症と重症の例

3. 方法

1）3D ResNet

ResNet は，残差ブロック（Residual Block）を直列に多数接続することにより，学習時の誤差逆伝播における勾配消失を回避した大規模な CNN モデルである．残差ブロックは，残差接続（Residual Connection）と畳み込み層＋ReLU（Rectified Linear Unit）関数＋畳み込み層の 2 経路を 1 つのブロックとして組み合わせた構造である．残差接続では，畳み込み層＋ReLU 関数＋畳み込み層のブロックに対して，前段の畳み込み層からの入力を，後段の畳み込み層の出力にスキップ接続する．スキップ接続された情報は，加算処理により結合される．3D ResNet は ResNet を 3 次元に拡張したモデルである．

2）SE Block

図 2 に SE Block のネットワーク構造を示す．SE Block は，特徴マップ内のチャネル間の相互依存関係を明示的にモデリングすることで，各チャネルの機能的応答を調整する．SE Block は，入力された特徴マップのどのチャネルを重視すべきかを評価し，各チャネルに重みを割り当てる．SE Block では，まず，ベースネットワークより出力された特徴マップに Global Average Pooling を適用して次元を圧縮する．次に，全結合層を通し ReLU 関数で非線形変換を行い，Sigmoid 関数を適用して 0 から 1 の範囲の値を出力する．最後に，Multiplication により，Sigmoid 関数の出力値を元の入力特徴マップの各チャネルに掛け合わせる．

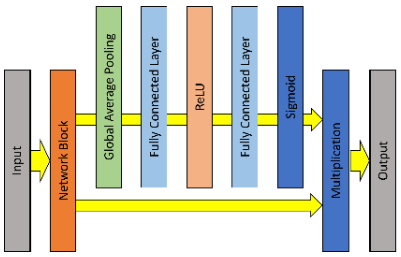


図 2：SE Block のネットワーク構造

3）Two-Stream SE-ResNet

図 3 に提案手法である Two-Stream SE-ResNet のネットワーク構造を示す．Two-Stream SE-ResNet は，3D ResNet に SE Block を導入した SE-ResNet で構成され，収縮期と拡張期の心臓 CT 画像を入力とした．収縮期の大動脈弁を解析する SE-ResNet と拡張期の大動脈弁を解析する SE-ResNet から出力された特徴マップは，チャネル方向に連結される．これにより，収縮期と拡張期の画像から得られる情報を効率的に統合し，分析する．ここで，収縮期と拡張期の SE-ResNet の重みは共有であることに注意されたい．

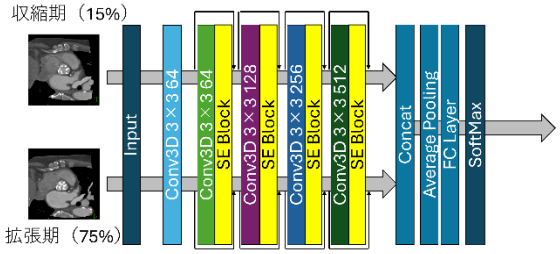


図 3：2 Stream SE-ResNet のネットワーク構造

4. 結果

表 1 に提案手法と，拡張期，収縮期それぞれを 3D ResNet に適用した場合の分類精度の比較を示す．提案手法の正答率，感度，特異度，AUROC（Area under the Receiver Operating Characteristic curve）は 0.69，0.99，0.56，0.76 で，収縮期 3D ResNet（0.69，0.89，0.30，0.76），拡張期 3D ResNet（0.70，0.99，0.50，0.78）よりも高い結果が得られた．

表 1：従来手法と Two-Stream SE-ResNet による分類精度の比較

	正答率	感度	特異度	AUROC
収縮期 3D ResNet	0.69	0.89	0.30	0.76
拡張期 3D ResNet	0.70	0.99	0.50	0.78
Two-Stream SE-ResNet	0.80	0.99	0.56	0.92

5. まとめ

本研究では，収縮期の大動脈弁を解析する SE-ResNet と拡張期の大動脈弁を解析する SE-ResNet の各出力を統合的に解析する Two-Stream ConvNets を構築した．提案手法の分類精度は，拡張期，収縮期それぞれを入力とする 3D ResNet よりも高い結果が得られ，その有用性が示唆された．

利益相反の有無

なし

文　献

［1］Ebrahimi, Amir, Suhuai Luo, and Raymond Chiong. "Introducing transfer learning to 3D ResNet-18 for Alzheimer's disease detection on MRI images." 2020 35th international conference on image and vision computing New Zealand (IVCNZ). IEEE, 2020.

［2］Hu, Jie, Li Shen, and Gang Sun, "Squeeze-and-excitation networks." Proceedings of the IEEE conference on computer vision and pattern recognition. 2018.

深層学習を用いた骨盤 CT 画像による各脚の下肢リンパ浮腫スクリーニング手法の検討

辻　美里[*1]，秋田　新介[*2]，長西　裕樹[*3,4]，松岡　歩[*5]，
甲賀　かをり[*6]，三川　信之[*2]，野村　行弘[*7]
[*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形成・美容外科
[*3] NACS クリニックリンパ浮腫センター北横浜
[*4] 済生会横浜市南部病院形成外科
[*5] 千葉大学医学部附属病院婦人科
[*6] 千葉大学大学院医学研究院産婦人科学
[*7] 千葉大学フロンティア医工学センター

Screening method for lower extremity lymphedema for each leg in pelvic computed tomography images using deep learning

Misato TSUJI[*1]，Shinsuke AKITA[*2]，Hiroki NAGANISHI[*3,4]，Ayumu MATSUOKA[*5]，
Kaori KOGA[*6]，Nobuyuki MITSUKAWA[*2]，Yukihiro NOMURA[*7]
[*1] *Department of Medical Engineering, Graduate School of Science and Engineering, Chiba University*
[*2] *Department of Plastic, Reconstructive and Aesthetic Surgery, Graduate School of Medicine, Chiba University*
[*3] *NACS Clinic Lymphedema Center Kita Yokohama*
[*4] *Department of Plastic Surgery, Saiseikai Yokohamashi Nanbu Hospital*
[*5] *Department of Obstetrics and Gynecology, Chiba University Hospital*
[*6] *Department of Obstetrics and Gynecology, Reproductive Medicine, Graduate School of Medicine, Chiba University*
[*7] *Center for Frontier Medical Engineering, Chiba University*

要旨：下肢リンパ浮腫は婦人科系がん治療後によくみられる合併症であり，患者の生活の質を著しく低下させる．早期の診断・治療が重篤な合併症予防につながるため，スクリーニング手法の確立が重要となる．我々の研究グループはこれまでに，深層学習を用いた骨盤 CT 画像による下肢リンパ浮腫スクリーニング診断手法を提案した．しかし，この手法ではリンパ浮腫が左右どちらの脚に有するのかまでは診断できない点が課題である．本研究では，深層学習を用いた骨盤 CT 画像による各脚の下肢リンパ浮腫スクリーニング手法を提案する．大転子スライスより各脚の部分画像を切り出した上で，脂肪領域強調処理を施した画像を深層学習に入力した．複数の深層学習モデルで比較した結果，ResNet-34 で AUC が 0.918，正解率が 87.1%となり，提案手法による各脚の下肢リンパ浮腫のスクリーニング診断の実現可能性が示唆された．
キーワード：下肢リンパ浮腫，CT，深層学習，医用画像

1. はじめに

下肢リンパ浮腫とは，リンパの流れが滞ることにより脚がむくむ状態を指す．下肢リンパ浮腫は原発性と続発性に分類され，続発性では，がん治療におけるリンパ節郭清や放射線照射により生じる場合が最も多い．発症すると皮膚の肥厚，皮下組織の肥大や線維化が不可逆的に進行する．重症化すると完治が困難で，生活の質が著しく低下するため，早期診断が重要となる．下肢リンパ浮腫の形態評価を目的とした検査には，超音波検査や computed tomography（CT）検査があり，多くの施設で実施が可能である．超音波検査は簡便に実施できるものの，検査間の再現性に限界がある．一方，CT 検査は放射線被ばくがあるものの，短時間で撮影でき，検査間の再現性が高いという利点がある．

我々の研究グループはこれまでに，婦人科系がん治療後の経過観察目的で撮影した骨盤CT画像を対象とした深層学習を用いた下肢リンパ浮腫スクリーニング診断手法[1]を提案した．この手法では，入力画像を大転子レベルの CT 画像に対して脂肪領域強調処理を施した画像として，深層学習モデルにて左右どちらかの脚に下肢リンパ浮腫を有するかどうかの診断を試みた．この手法による正解率は 92.9%を達成しているものの，リンパ浮腫が左右のどちらの脚に有するのかまでは診断できない点が課題である．

本研究では，深層学習を用いた骨盤 CT 画像による左右の脚の下肢リンパ浮腫診断支援手法の検討を目的とする．

2. 使用データセット

千葉大学医学部附属病院にて，婦人科系がん治療後に経過観察目的で撮影したスライス厚 5mm の骨盤 CT 画像 154 名 431 検査分，計 862 脚を使用した．左右の脚に対して，1 名の形成外科医師が ICG 蛍光リンパ管造影検査の結果に基づき陽性／陰性のラベルを付けた．データセットは表 1 に示すように 3 種類のサブセットに分割した．

表 1. データセット内訳

データ	症例			脚		
	陽性	陰性	計	陽性	陰性	計
training	140	161	301	213	389	602
validation	30	30	60	42	78	120
test	35	35	70	49	91	140

3. 深層学習モデルの学習

1 名の診療放射線技師が選択した大転子スライスの CT 画像(図 1(a))に対して，閾値処理およびモルフォロジ処理により体幹領域(図 1(b))を抽出した後に以下の式を用いて脂肪領域強調画像(図 1(c))を作成した．

$$I_{fat}(\boldsymbol{x}) = \begin{cases} 0.01\{I(\boldsymbol{x}) + 125\}, & -125 \le I(\boldsymbol{x}) \le -25 \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

ここで，$I(\boldsymbol{x})$ は位置$\boldsymbol{x}$における画素値である．

脂肪領域強調画像より各脚の部分画像(224×112，図 1(c)黄囲領域)を以下の条件で切り出した．

・x方向の範囲：左右の端から 224 pixel

・y方向の上端：体幹領域上端(y_{min})から 32pixel 前方

なお，左脚の部分画像は水平反転をした後にモデルへ入力した．

深層学習モデルとして，ResNet-18，ResNet-34，ResNet-50, DenseNet-201, MobileNetV3-Small, EfficientNet-B0 を使用した．

データ拡張として，training セットの各画像に対して陽性脚は 2 枚，陰性脚は 1 枚の変換画像を作成した．変換の種類は以下の通りであり，変換画像は epoch 毎に変更した．

・±10 度の範囲のランダム回転

・0.9～1.1 倍の範囲のランダム拡大/縮小

各モデルについて，ランダムサーチによるハイパーパラメータ探索を 20 回試行した．ハイパーパラメータおよび探索範囲は，学習率(10^{-5}～10^{-3})，ならびにバッチサイズ(2～64，ステップ:2)とした．その他の条件は最大エポック数: 500, early stopping の patience: 30，最適化手法: 確率的勾配降下法(weight decay=0.0001，momentum=0.9)，損失関数: クロスエントロピーとした．validation セットにおいて ROC 曲線の下面積(area under the curve, AUC)が最大となる試行のモデルを test セットに適用し，分類性能を評価した．

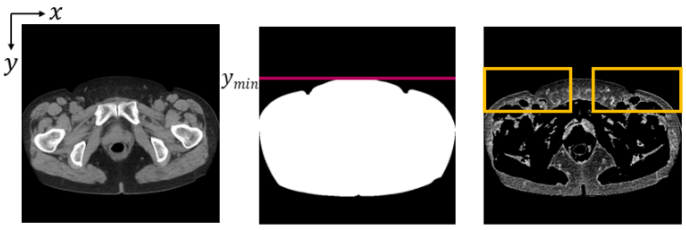


図 1. 入力画像領域例
(a)元画像，(b)体幹領域マスク，(c)脂肪領域強調画像

4. 結果

表 2 に各モデルの分類結果を示す．なお，正解率，感度，特異度は Youden's index により求めたカットオフ点での値である．各モデルを比較した結果，ResNet-34 で AUC および正解率が最良となり，それぞれ 0.918，87.1%であった．

表 2. 各モデルの分類結果

	AUC	正解率 [%]	感度 [%]	特異度 [%]
ResNet-18	0.853	82.1	75.5	85.7
ResNet-34	**0.918**	**87.1**	85.7	87.9
ResNet-50	0.891	85.7	77.6	90.1
DenseNet-201	0.898	82.9	**87.8**	80.2
MobileNetV3-Small	0.838	84.3	75.5	89.0
EfficientNet-B0	0.861	85.0	69.4	**93.4**

5. まとめ

深層学習を用いた骨盤 CT 画像による左右の脚の下肢リンパ浮腫診断支援手法を検討した．複数の深層学習モデルで比較した結果，ResNet-34 で AUC が 0.918，正解率が 87.1%となった．

謝辞

本研究は JSPS 科研費 24K15764 の助成を受けたものです．

利益相反の有無

なし

文　献

［1］ Nomura Y, Hoshiyama M, Shinsuke A, et al: Computer-aided diagnosis for screening of lower extremity lymphedema in pelvic computed tomography images using deep learning. Sci Rep 13:16214, 2023.

脳 MR 画像における Multi-input CNN を用いた特発性正常圧水頭症の鑑別診断支援

澤　風吹[*1]，藤田　大輔[*1]，嶋田　兼一[*2]，石井　一成[*2,3]，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] 兵庫県立はりま姫路総合医療センター [*3] 近畿大学 医学部

Support for Differential Diagnosis of Idiopathic Normal Pressure Hydrocephalus Using Multi-input CNN in Brain MR Images

Fubuki SAWA[*1]，Daisuke FUJITA[*1]，Kenichi SHIMADA，Kazunari ISHII，Syoji KOBASHI
[*1] *Graduate School of Engineering, University of Hyogo*
[*2] *Hyogo Prefectural Harima-Himeji General Medical Center* [*3] *Kindai University, Faculty of Medicine*

要旨：特発性正常圧水頭症(iNPH: idiopathic normal pressure hydrocephalus)は脳脊髄液が過剰に蓄積し，歩行障害，認知障害，尿失禁の 3 徴症を引き起こす．シャント術により症状の改善が見込める．一方，進行性核上性麻痺(PSP: progressive supranuclear palsy)も類似の症状を有するが，現在根治治療法はなく，iNPH と PSP の正確な鑑別診断は重要である．通常臨床では脳 MR 画像におけるいくつかの脳画像所見を元に視覚評価により鑑別していくが，画像に詳しい医師でないと正確な診断が困難な場合がある．そこで本研究では，脳 MR 画像から深層学習による iNPH と PSP の分類モデルを作成し，自動で鑑別診断支援を行うシステムの開発を提案する．本提案法では，脳 MR 画像の灰白質，白質の分離，形状の標準化を行なったものを直接の入力として CNN による分類を行う．入力パターンとして灰白質，白質の Multi-input，およびそれぞれ単体入力の場合の比較を行う．また，GradCAM による注目領域の可視化も行う．実験結果より，Multi-input による提案手法において Accuracy は 0.885，AUC は 0.952 であった．
キーワード：脳 MR 画像，深層学習，CNN，鑑別診断支援，GradCAM

1. はじめに

特発性正常圧水頭症 (iNPH: idiopathic normal pressure hydrocephalus）は，脳脊髄液が正常圧のままで脳室に過剰にたまる状態を指し，歩行障害，尿失禁，認知障害などの症状が現れる[1]. 髄液シャント手術は，カテーテルを腹腔内などに留置して過剰な脳脊髄液を排出する，iNPH の有効な治療法である[2]. 一方，進行性核上性麻痺(PSP: progressive supranuclear palsy)は，iNPH に類似した症状を示すが，根治治療法は存在せず，正確な鑑別診断は極めて重要である．PSP 特有の症状として，垂直核上性視線麻痺[3]があり，これは iNPH ではみられない特徴的な症状であるが，初期には見られない症状であるため鑑別を難しくしている．したがって，早期に正確な鑑別診断を行うことで適切な治療方法が選択でき，患者の生活の質改善が期待できる．通常臨床では，神経所見だけの鑑別は困難なため，脳 MR 画像を用いた画像診断が不可欠である．iNPH では脳室，シルヴィウス裂の拡大，高位円蓋部および正中部の脳溝，くも膜下腔の狭小化などの所見が指標となる [4]．一方，PSP に関連する画像所見としては，矢状面 MRI において中脳の萎縮によるハミングバードサインがある[5]．これら画像所見による鑑別診断は，放射線科医の訓練と経験に大きく依存する主観的な画像解釈のため，観察者内の診断ばらつきが大きく，困難である[6].

iNPH の鑑別診断を支援するために，手動測定による特徴抽出や機械学習技術がいくつかの研究で採用されている．Quattrone らは，iNPH と PSP の鑑別において最大 0.985 の精度を達成した[7]. しかし，この手法は手作業による特徴抽出に大きく依存しており，診断医の時間的負担となる．また，脳の一部分にのみ焦点を当てているため，焦点を当てている部位以外が変形している場合には適切な診断ができないことがある．

本研究では，iNPH と PSP の正確な鑑別診断支援のために深層学習を用いた全自動システムの提案を行う．また，モデルのブラックボックス性改善のため，GradCAM を用いてモデルの解釈性向上も行う．

*1 兵庫県立大学大学院工学研究科電子情報工学専攻
〔〒671-2280 兵庫県姫路市書写 2167 姫路工学キャンパス
e-mail : kobashi@eng.u-hyogo.ac.jp

2. 使用データ

本研究では，兵庫県立はりま姫路総合医療センターで収集した iNPH 患者 39 名，PSP 患者 39 名，計 78 名の 3DT1 強調の脳 MR 画像を対象とする．同病院および兵庫県立大学の倫理委員会により承認の上実施した.(倫理承認番号: [*1]R05-47，[*2]23-014)

3. 提案手法

本研究では，脳 MR 画像を脳画像解析ソフトウェアである SPM12 を使用して前交連−後交連位置合わせを行った後に，灰白質(GM: gray matter)と白質(WM: white matter)，脳脊髄液(CSF: cerebrospinal fluid)の異なる組織タイプに識別を行う．その後，非線形変換により識別された GM, WM を共通の標準空間である MNI(Montreal Neurological Institute)空間に標準化を行う．

この標準化プロセスにおいて，モジュレーションにより体積変化の補正が行われ，出力画像として元の画像における体積情報を保持した画像が得られる．この画像を CNN の直接の入力として，iNPH と PSP の識別を行う分類問題として扱う．図 1

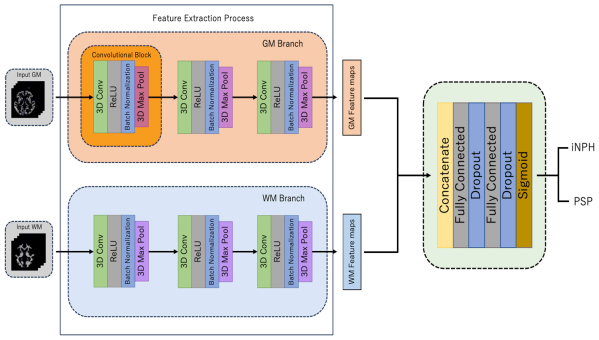


図 1　Multi-input におけるネットワーク構造

に本研究で用いた 3DCNN を用いたネットワーク構造を示す. 前処理後画像は，GM，WM の単体入力，GM+WM Multi-input の 3 パターンの入力の分類精度比較を行う. 図 1 のネットワーク構造において, 単体入力の時はそれぞれの画像の個々の特徴量の抽出，Multi-input では GM と WM の異なる特徴を同時に抽出し全結合層で特徴量の結合を行うことで分類を行う. 元の MR 画像を直接の入力とせず, GM と WM それぞれ別の入力とすることで, 畳み込み層が個別に異なる空間パターンをより効果的に捉えることが可能であると考える．また，モデルの解釈性向上として，GradCAM で図 1 における最終畳み込み層の出力特徴マップに対するモデルの出力の勾配を計算することで注目領域の可視化を行う．この時，モデルの注目領域と iNPH と PSP の MR 画像所見を比較することで，モデルの評価を行う.

3. 実験結果

提案手法を学習データ 62 例, 評価データを 16 例に分割し，層化 5 分割交差検証を用いて学習を行い, 分類性能を Accuracy, Sensitivity，Specificity，Brier score，AUC(area under the curve)を用いて評価した．層化 5 分割交差検証による評価指標の 5Fold の平均値を表 1 に示す．表 1 より GM と WM の Multi-input モデルが AUC=0.952 と最も良い精度を達成した．また，図 2 に GradCAM を用いて，GM における 3DCNN の注目領域の可視化を行った結果を示す.

4. まとめと考察

本研究では，脳 MR 画像から iNPH と PSP を識別する手法を提案した．実験の結果，GM+WM の Multi-input による手法において AUC=0.952 と高精度を達成した．これより，本研究においては，元の MR 画像を直接の入力とするのではなく，GM と WM に分割して入力することでモデルが，iNPH と PSP の分類に有効な特徴量を効率よく学習できたのではないかと考える．また，注目領域を GradCAM で可視化した結果において，iNPH では評価データの半数以上において，シルヴィウス裂，高位円蓋部および正中部の脳溝周辺，PSP ではハミングバードサインの部位などが強調表示された特異的な分布のヒートマップが得られた．一方で，ほとんど注目領域が表示されないことや, 脳画像初見とは一致しない部位が表示される例もあった．そのため，今後は脳画像所見の知識により準拠したアプローチを導入したモデルを構築することで, 解釈性を向上できるだけでなく，精度の向上も期待できる.

表 1　分類モデルの性能評価(5Fold の平均)

入力画像	Accuracy	Sensitivity	Specificity	Brier score	AUC
GM	0.822	**0.950**	0.700	0.128	0.936
WM	0.808	0.814	0.796	0.153	0.849
GM+WM	**0.885**	0.846	**0.925**	**0.047**	**0.952**

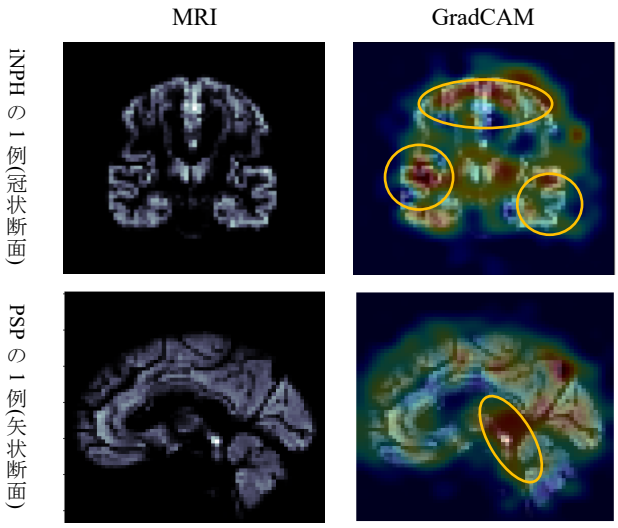


図 2 GradCAM による注目領域の可視化

利益相反の有無

なし

文　献

[1] Gallia G, Rigamonti D, and Williams M: The diagnosis and treatment of idiopathic normal pressure hydrocephalus. Nature Clinical Practice Neurology, Vol. 2, No. 7, pp. 375-381, 2006.

[2] 楢林 勇, 垰本勝司：脳・脊髄の MRI と CT 診断．株式会社 金芳堂, p.188,189, 2003.

[3] 厚生労働科学研究費補助金(難治性疾患政策研究事業)「神経変性疾患領域の基盤的調査研究」一般社団法人日本神経治療学会：進行性核上性麻痺(PSP)診療ガイドライン 2020．Vol.37, No.3, 2020.

[4] Ishii K, Kawaguchi T, Shimada K et al: Voxel-based analysis of gray matter. and CSF space in idiopathic normal pressure hydrocephalus. Dementia and geriatric cognitive disorders, Vol.25, pp.329-335, 2008.

[5] Zanigni S, Buonaura G, Manners D et al: Accuracy of MR markers for differentiating Progressive Supranuclear Palsy from Parkinson's disease. NeuroImage: Clinical, Vol. 11, pp. 736-742, 2016.

[6] Takagi K, Watahiki R, Machida T et al: Reliability and Interobserver. Variability of Evans' Index and Disproportionately Enlarged Subarachnoid Space Hydrocephalus as Diagnostic Criteria for Idiopathic Normal Pressure Hydrocephalus. Asian Journal of Neurosurgery, Vol.15, pp.107-112, 2020.

[7] Quattrone A. Sarica A, Torre D et al: Magnetic Resonance Imaging Biomarkers Distinguish Normal Pressure Hydrocephalus From Progressive Supranuclear Palsy. Movement Disorders, Vol.35, p.8, 2020.

ESRGAN による超解像処理を利用した乳がん石灰化良悪性鑑別 CAD 精度向上の検討

大坂　亮二[*1]，安倍　和弥[*1]，高取　祐介[*2]
[*1] 神奈川工科大学 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

Investigation of Improved Accuracy in Breast Cancer Microcalcification Malignancy Assessment using Super-Resolution Processing with ESRGAN

Ryoji OHSAKA[*1]，Kazuya ABE[*1]，Yusuke TAKATORI[*1]
[*1] *Kanagawa Institute of Technology Electrical and Electronic Engineering*
[*2] *Kanagawa Institute of Technology Electrical and Electronic Engineering*

要旨：乳がん石灰化良悪性鑑別を行うコンピュータ支援診断(CAD)は石灰化部分が微小であることから鑑別性能が低くなる．そこで本研究では，撮影画像に ESRGAN を利用した超解像処理を適応し，乳がん石灰化良悪性鑑別 CAD の精度向上の検討を行った．ESRGAN による超解像処理の学習は教師あり学習で行う．CAD は単純な鑑別を行うものとし，利用する画像は元画像である 256×256pixel と SRCNN と ESRGAN の生成画像である 448×448pixel の 2 パターンで行った．CAD の学習は各画像群で 20 回ずつ行い，元画像における鑑別精度が最高 75．8%であったのに対し，ESRGAN 生成画像の精度は最高 85%となり精度の向上が見られた．また，AUC は元画像が 0．785，ESRGAN 生成画像では 0．915 となった．この結果より，乳がん石灰化良悪性鑑別において超解像処理を行うことによる鑑別精度の向上が確認できた．今後，元画像 448pixel との比較を行い，超解像処理の適応の信頼性の確保を行っていく．

キーワード：超解像処理，コンピュータ支援診断，微小石灰化

1. はじめに

乳がんは日本人女性が罹患するがんの中で最も多く，死亡原因の上位に位置するがんである．そのため 40 歳以上の日本人女性は乳がん検診を受けることが推奨されている．その中でも石灰化は微小であり， コンピュータ支援診断(CAD)において乳がん石灰化良悪性鑑別は鑑別性能が低くなる．

乳がん検診では検診車による撮影画像での 1 次検診により疑いがあるものが病院においての 2 次精査に移行する．1 次検診に利用する撮影画像は病院において撮影される画像に比べ画質が低くなってしまう．

乳がん検診は，現在受診率が全国平均 47．4%[1]となっている．2010 年に比較すると上昇しているが依然として向上させる必要があると考える．そこで，1 次検診での良悪性鑑別による受信者への警告を行うことが出来れば，1 次検診の受診率向上とより高い 2 次精査受診率の実現が可能ではないかと考えた．

そこで，本研究では検診車等で撮影される画質の低い画像に対し，ESRGAN[2]による超解像処理を適応し 1 画像における情報量を増やすことにより良悪性鑑別の精度向上を狙う．これにより，検診車等での撮影画像に対し CAD を適応することでスクリーニングの精度を向上させることが出来ると考える．

2. 手法

2．1 超解像処理

超解像処理には Xintao らによる ESRGAN の教師あり学習をベースとした．開発環境は Anaconda を利用した．損失関数に用いる特徴量は torchvision の事前学習モデルである VGG19[3]を利用している．

学習に使用した画像は 224×224pixel の乳がんの腫瘤及び石灰化の切り取り画像を利用した．教師あり学習であるため学習前に一度 2 分の 1 に画像をスケールダウンし元のサイズに戻す過程を学習させる．この学習により生成されたモデルを利用し異なる 224×224pixel の乳がん石灰化切り取り画像を入力し 448×448pixel の画像の生成を行った．これは，CAD に 112×112pixel での鑑別を行った際精度が最高 65%と低い値から改善が見られなかったことと元画像を利用した．CAD と 224×224pixel に超解像した CAD に明確な差が現れなかったためである．

学習条件は初期学習率1×10^{-4}とし，バッチサイズ 8 とした．使用画像数は 1224 枚として学習を行った．

評価には PSNR[5]を利用し，比較対象として SRCNN[4]による超解像処理を行ったデータとの比較を行った．評価を行った画像は元画像と同じ pixel への超解像を行った際の画質評価となる．この際，生成画像をランダムに 300 枚抽出し平均値を計算する．

2．2 コンピュータ支援診断(CAD)

CAD には VGG16 による単純な識別器を利用した．開発環境は MATLAB を利用した．

学習条件は初期学習率1×10^{-4}，バッチサイズ 8 とした．使用画像は良性悪性共に 300 枚とした．この際，使用画像を学習

データ:検証データ:テストデータで 7:2:1 の比率で分けた．また，学習データにデータ拡張を行って 1260 枚として学習を行った．

ESRGAN と比較のために SRCNN の 2 種類により生成した 448×448pixel の画像を利用したデータと 224×224pixel の元画像を利用した CAD と比較を行う．

評価は各条件 20 回行った．精度は最高値と，上位下位 4 データずつを除いた 12 データの平均値で評価を行った．また，各条件の最高値における受信者操作特性(ROC)から AUC を計算する．

3. 結果

ESRGAN 及び SRCNN により生成された各画像の画質評価では PSNR が 45.049±2.17[dB], SRCNN は 40.69±1.54[dB] となり，約 5[dB]高い値となった．しかし，標準偏差は SRCNN が小さい値となった．これは ESRGAN がノイズから補間を行っているため画素値の小さいずれがあったためであると考えられる．この対策として，画素値を RGB の平均で全て置き換えることとした．

CAD の精度は表 1 に示す．

表 1 CAD の各画像における精度

	元画像224	SRCNN448	ESRGAN448
平均値	68.75	74.03	78.96
最高値	75.83	80	85

これにより ESRGAN を利用した際の精度は平均値最高値ともに優位性を示している．

ROC 曲線を図 1 に示す．図のように ESRGAN が特に高い値となった．

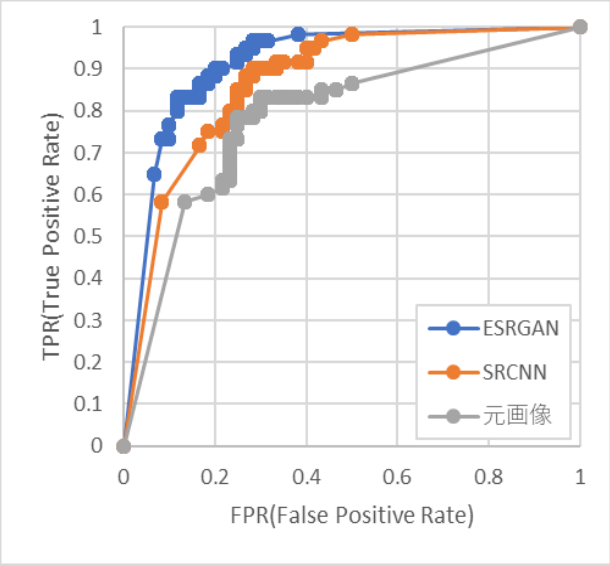


図 1 各データの ROC 曲線

また，この時の AUC は表 2 のようになった．

表 2 AUC の各画像における数値

	元画像224	SRCNN448	ESRGAN448
平均値	0.786	0.870	0.915

表 2 から ESRGAN が元画像とは 0.13，SRCNN とは 0.045 大きい値を得ることが出来た．

ここから ESRGAN が優位性を示していることがわかった．

4. まとめ

本研究では，ESRGAN を用いた超解像処理による乳がん石灰化良悪性鑑別 CAD の精度向上の検討を行った．ESRGAN により生成された 224×224pixel 画像の画質評価では PSNR が 45.049±2．17[dB]，SRCNN は 40.69±1.54[dB]となった．448×448pixel 超解像画像を利用した CAD の精度と AUC 値はともに ESRGAN が高い値を示した．特に AUC 値は 0．915 となった．

このことから鑑別性能が低くなる乳がん石灰化において超解像処理を加えることによって元画像と比較し精度向上が行われることが分かった．

今後の展望として，乳がんの腫瘤と石灰化の 2 種類の良悪性鑑処理への応用を検討している．

利益相反の有無

なし

文 献

[1] 国立がん研究センターがん情報サービス「がん登録・統計」

[2] Xintao Wang， Ke Yu， Shixiang Wu et al.，”ESRGAN: Enhanced super-resolution generative adcersarial networks， Computer Vision ECCV 2018 Workshops Part V: pp. 63-79

[3] Simonyan, K., and Zisserman, A. , “Very deep convolutional networks for large-scale image recognition”, arXiv preprint arXiv:1409.1556,2014

[4] Chao Dong， Chen Change Loy， Kaiming He et al: Learning a Deep Convolutional Network for Image Super-Resolution， Computer Vision ECCV 2014 Part IV: pp. 184-199

[5] Q. Huynh-Thu， M. Ghanbari: Scope of validity of PSNR in image/video quality assessment， IET vol 44: pp. 800-801

3D U-Net による非造影 CT 画像の大動脈・冠動脈石灰化の検出

庄野未彩季[*1]，河田 佳樹[*2]，杉浦 寿彦[*3]，田邊 信宏[*3]，丸茂 一義[*4]，金子 昌弘[*4]，仁木 登[*5]
[*1] 徳島大学大学院創成科学研究科理工学専攻，[*2]徳島大学ポストフォトニクス研究所，
[*3] 千葉大学，[*4] 東京都予防医学協会，[*5] (株)医用科学研究所

By 3DU-Net Detection of aortic and coronary calcification on non-contrast-enhanced CT images

Misaki SHONO[*1]　Yoshiki KAWATA [*2]　Toshihiko SUGIURA[*3]
Nobuhiro TANABE[*3] Kazuyoshi MARUMO[*4]　Masahiro KANEKO[*4] *Noburu NIKI[*5]
[1] Graduate School of Science and Technology for Innovation, Tokushima University
[2] Institute of Post-LED Photonics, Tokushima University
*[3]Chiba University [*4] Tokyo Preventive Medicine Association [*5] Medical Science Insitute[*]*

要旨：画像診断において，専門医は大量の画像を読影することを要求されており，診断する上で大きな負担となっている．そこで，近年これらの読影を支援するコンピュータによる臓器の自動抽出や異常部位の自動検出などについての研究開発が行われている．大動脈・冠動脈の石灰化によって引き起こされる心疾患の死亡率は悪性新生物に続き第 2 位を占めている．心疾患は日本において主な死因の 1 つとされる疾患であり，早期発見・早期治療を受けることが必要とされている．本報告では，正常 100 例と慢性血栓塞栓性肺高血圧症の 22 例の非造影 CT 画像を用いて 3D U-Net による大動脈・冠動脈石灰化を抽出する．
キーワード：CT，CAD，医用画像処理

1. はじめに

動脈石灰化は，動脈にカルシウムが沈着している状態のことであり動脈硬化を引き起こす．冠動脈にカルシウムが沈着することで引き起こす疾患は心疾患であり，加齢とともに年々増加傾向にある．また，心疾患の死亡率は悪性新生物に続き第２位を占めており，2023 年は 23 万人に及んでいる．大動脈石灰化は大動脈にカルシウムが沈着することであり，大動脈石灰化がおこることで高血圧，糖尿病の因子になるとされている．

そこで本研究では，正常例と慢性血栓肺高血圧症例における非造影 CT 画像での冠動脈・大動脈石灰化を抽出し，特徴を解析する．また，胸部において両側の縦郭胸膜に囲まれ心臓・大血管・胸管・気管気管支・食道が位置する空間である縦郭領域のマスクをかけ，3D U-Net を用いて冠動脈・大動脈石灰化の自動検出することを目標とする．

2. CT 画像撮影条件

本研究では，東京都予防医学協会で撮影された正常 100 症例と千葉大学で撮影された慢性血栓肺高血圧症の 22 症例を用いた．東京都予防医学協会から提供を受けた非造影 CT 画像は，キャノンメディカルシステムズの 32 マルチスライス CT システムで撮影され，撮影条件は，管電圧 120kV，管電流 30mA，再構成圧 1.0㎜ であり，千葉大学から提供を受けた非造影 CT 画像は，キャノンメディカルシステムズの 320 列エリアディレクターCT システムで撮影され，撮影条件は，管電圧 120kV，管電流 112-295mA，再構成圧 0.5㎜ である．

3. 研究手順

本手法は，(1)非造影 CT 画像から縦郭領域，冠動脈・大動脈石灰化をマニュアルで抽出し，(2)抽出した縦郭領域を 3D U-Net で学習・自動抽出，(3)抽出した冠動脈・大動脈石灰化を 3D U-Net で学習・自動抽出，(4)検出結果の評価の順に行う．

(1) 学習データの作成

非造影 CT 画像より縦郭領域の抽出を行う．縦郭領域は Felson による縦郭領域区分を用いて胸椎 3 番から 10 番までを縦郭領域と定義し，122 症例のラベル付けを行い学習・評価データの作成を行った．次に，大動脈・冠動脈石灰化をマニュアルで抽出する．石灰化は日本心臓協会で 130HU 以上と定義されているため CT 値 130HU 以上を抽出し，122 症例の大動脈・冠動脈の石灰化にそれぞれ異なるラベル付けを行い学習・評価データの作成を行った．

(2) 縦郭領域の学習

縦郭領域を囲む両肺の領域を作成し，縦郭領域のマスク画像とした．非造影 CT 画像と作成した縦郭領域の教師データを用いて 10fold 法で学習を行った．症例ごとにトレーニングデータ：バリデーションデータ：テストデータ＝8:1:1 に分け，データサイズ 256×256(pixel)，エポック数 100 回で学習させ自動抽出を行った．非造影 CT 画像を図 1(a)，縦郭領域の自動抽出ラベルを(b)に示す．

(3) 冠動脈・大動脈石灰化の学習

非造影 CT 画像と作成した冠動脈・大動脈石灰化の教師データ，(2)で自動抽出した縦郭領域のマスク画像を用いて 10fold

法で学習を行った．症例ごとにトレーニングデータ:バリデーションデータ：テストデータ＝8:1:1 に分け， データサイズ 256×256(pixel)， エポック数 300 回で学習させ自動抽出を行った． 非造影 CT 画像を(c)， 冠動脈・大動脈石灰化の自動抽出ラベルを(d)に示す.

(4) 自動抽出結果の評価

自動抽出した縦郭領域，冠動脈･大動脈の石灰化の評価を行った． 評価には 2 つの集合の平均要素数と共通要素数の割合を表す Dice， 感度， 適合率を用いて自動抽出結果の評価を行う． 真陽性を示す TP， 偽陽性を示す FP， 偽陰性を示す FN の指標を用いて次の式で示す.

$$\mathrm{Dice}=\frac{2TP}{2TP+FP+FN} \quad (1)$$

$$\text{感度}=\frac{TP}{TP+FN} \quad (2), \qquad \text{適合率}=\frac{TP}{TP+FP} \quad (3)$$

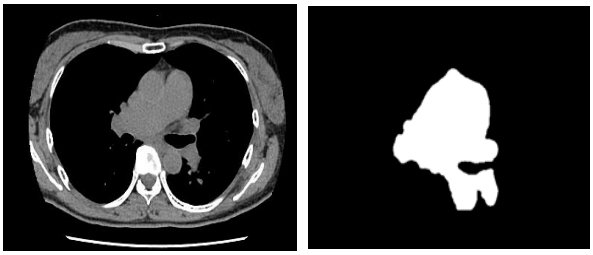
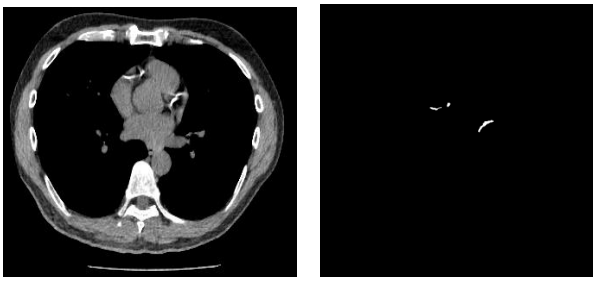


図 1(a)非造影 CT 画像　　(b)縦郭領域自動抽出ラベル



(c)非造影 CT 画像　　(d)石灰化自動抽出ラベル

4. まとめ

本報告では， マニュアルで縦郭領域， 冠動脈・大動脈の石灰化の学習データの作成を行った． 作成した学習データを 3D U-Net を利用して縦郭領域，冠動脈・大動脈石灰化の自動抽出を行った.

今後の課題として， 症例数を増やし， 冠動脈・大動脈石灰化の特徴の確信度を高め， 非造影 CT 画像による高精度な鑑別診断を確立することを目指す.

利益相反の有無

なし

文　献

［1］ 村田 喜代史，村上 貞之，胸部の CT 第 4 版，メディカル・サイエンス・インターナショナル，2018

[2] H. Suzuki, Y. Kawata, N.Niki et al: Segmentation of aorta and main pulmonary artery of non-contrast CT images using U-Net for chronic thrombotic pulmonary hypertension: Evaluation of robustness to contacts with blood vessels. Medical physics :Vol 1203325-, pp1-5, 2022

[3] Mubammad Taba Hagar, MD, Martin Soscbynski, MD, Ruben Saffar, MD et al: Accuracy of Ultrahigh-Resolution Photon-counting CT for Detecting Coronary Artery Disease in a High-Risk Population, Radiology: Vol 307, 2023

[4] Nina P. Haag, MD, Arwed E. Micbael, MD, Simon Lennartz, MD et al: Coronary Artery Calcium Scoring Using Virtual Versus True Noncontrast Images From Photon-Counting Coronary CT Angiography, Radiology: Vol 310,2024

CT 画像と存在確率マップを用いた CNN に基づく全自動僧帽弁形状抽出

益田 幸輝[*1]，石川 亮[*1]，田中 亨[*1]，青山 岳人[*2]，川島 圭太郎[*2]，James V. Chapman[*3]，
阿佐美 匡彦[*4]，Michael Huy Cuong Pham[*5]，Klaus Fuglsang Kofoed[*5]，坂口 卓弥[*2]，佐藤 清秀[*1]
[*1] キヤノン株式会社
[*2] キヤノンメディカルシステムズ株式会社
[*3]Canon Medical Informatics, Inc.
[*4] 三井記念病院　循環器内科
[*5]Department of Cardiology and Radiology, Copenhagen University Hospital - Rigshospitalet

Automatic mitral valve shape extraction from cardiac CT images and existence probability maps

Yukiteru MASUDA[*1]，Ryo ISHIKAWA[*1]，Toru TANAKA[*1]，Gakuto AOYAMA[*2]，
Keitaro KAWASHIMA[*2]，James V. Chapman[*3]，Masahiko ASAMI[*4]，Michael Huy Cuong Pham[*5]，
Klaus Fuglsang Kofoed[*5]，Takuya SAKAGUCHI[*2]，Kiyohide SATOH[*1]
[*1] *Canon Inc.*
[*2] *Canon Medical Systems Corporation.*
[*3] *Canon Medical Informatics, Inc.*
[*4] *Division of Cardiology, Mitsui Memorial Hospital*
[*5] *Department of Cardiology and Radiology, Copenhagen University Hospital - Rigshospitalet*

要旨：コンピュータ断層撮影（CT）や経食道心エコー図（TEE）などによって得られた臨床画像から僧帽弁形状を正確に抽出することは，僧帽弁治療計画において有用である．しかしながら，既存の自動抽出法には，精度面での課題や，精度向上のために別途ランドマークの入力を必要とする（すなわち，全自動ではない）などの課題がある．本発表では，心周期の全位相に対する CT 画像から，僧帽弁形状を全自動かつ高精度で抽出する手法を提案する．本手法は元の CT 画像と，U-Net により推定した僧帽弁領域の存在確率マップの両方を入力として，DenseNet によって僧帽弁形状メッシュを抽出する．204 症例を用いた精度評価を実施し，提案手法における僧帽弁形状抽出の平均誤差は 0.88mm であり，存在確率マップを用いない従来方法と比較して 0.32mm の精度改善を確認した．

キーワード：僧帽弁，CT，機械学習，形状抽出

1. はじめに

重度の僧帽弁閉鎖不全症は 3 年間での死亡率が 40～50%であり，適切な治療をしなければ致死的な結果をもたらす[1]. 僧帽弁の形状及び動態に関する正確な情報は，僧帽弁閉鎖不全症患者の治療計画を決定するために重要である[2].

しかしながら，CT などの医用画像から手動で僧帽弁の形状を抽出するのは非常に時間がかかり，日常的な臨床において実用的ではない．そのため，自動で僧帽弁形状を抽出する方法が求められているが，僧帽弁の形状は症例間で大きく異なり，また心臓の拍動に伴う僧帽弁の動きも大きいことから，形状や動態の多様性が大きく，正確な形状抽出が困難である．

CT や TEE などから僧帽弁形状を抽出する手法が今までいくつか提案されているが，それらは手動でのランドマークとなる座標の入力が必要であったり[3]，画像中の非僧帽弁領域が僧帽弁領域よりも圧倒的に多いというクラス不均衡に起因する誤検出が多い[4]といった課題がある．本稿では，画像から僧帽弁の存在確率マップを推定して形状抽出の入力に加えることで，僧帽弁形状を全自動で精度良く抽出する手法を提案する．

2. 提案手法

本手法では，3 次元心臓 CT 画像からの僧帽弁形状抽出の精度を上げることを目的とし，入力画像から僧帽弁の存在確率マップを推定する機械学習モデルと，推定した存在確率マップと元の CT 画像の両方を入力として，僧帽弁のメッシュ形状を抽出する機械学習モデルで構成される二段階のモデル構造を採用する．

前段の存在確率マップ推定モデルは 3DU-Net [5]を用い，損失関数として Tversky Loss [6]を多クラス用に拡張したものを適用して学習を実施する．存在確率マップは僧帽弁の前尖(anterior)，後尖(posterior)，背景(BG)の 3 クラスのそれぞれで推定し，各クラス k に対する Tversky Loss である Loss_T は以下の式 1 で定義される．

$$\mathrm{Loss}_T(y_k, \hat{y}_k) = 1 - \frac{\sum_{i=0}^{N} y_{0ik}\hat{y}_{0ik}}{\sum_{i=0}^{N} y_{0ik}\hat{y}_{0ik} + \alpha_k \sum_{i=0}^{N} y_{1ik}\hat{y}_{0ik} + \beta_k \sum_{i=0}^{N} y_{0ik}\hat{y}_{1ik}} \quad (1)$$

ここで，y_kはクラス kの GT を示し，$\hat{y}_k$はクラス kの推論値を示す．iは存在確率マップの各画素に対応し，y_{0ik}はクラス kに対応するボクセルを 1，クラスと異なるボクセルを 0 とする値であり，y_{1ik}はその逆である．また，各クラスの Tversky Loss を合計した$\mathrm{Loss}_{\mathrm{MCT}}$は以下の式 2 で定義される．

$$\mathrm{Loss}_{\mathrm{MCT}}(y, \hat{y}) = a \times \mathrm{Loss}_T(y_{ant}, \hat{y}_{ant}) + b \times \mathrm{Loss}_T(y_{pos}, \hat{y}_{pos}) + c \times \mathrm{Loss}_T(y_{BG}, \hat{y}_{BG}) \quad (2)$$

ここで，a，b，cは僧帽弁の前尖，後尖，背景それぞれのクラスの係数であり，本手法では，$a = 0.49$, $b = 0.49$, $c = 0.02$としている．

後段の僧帽弁メッシュ形状抽出モデルには, DenseNet-121 を採用する．このモデルでは，CT 画像と前段のモデルで推定した存在確率マップの両方を別チャンネルとして入力し，前尖 19×9 点，後尖 25×9 点から構成される僧帽弁メッシュの各格子点座標値を抽出する．

3. 評価手法

4 施設において僧帽弁閉鎖不全症も含む 204 人の患者から取得した合計 1585 時相の 3 次元心臓 CT 画像データを学習及び評価に用いた．使用する CT 画像データは，別途自動抽出した左心房及び左心室領域の位置関係に基づいて僧帽弁周辺の領域を自動でクロップすることで, 画像の傾きと大きさを正規化した 64×64×64 の 3 次元画像として入力した．前述した僧帽弁の存在確率マップを前段で推定し, 推定した存在確率マップと心臓 CT 画像の両方を入力として僧帽弁メッシュ形状を後段で抽出するモデル（w/ map）と，CT 画像のみを入力として僧帽弁メッシュ形状を抽出するモデル（w/o map）のそれぞれで学習及び評価を実施し, 存在確率マップの追加によるメッシュ形状抽出の精度向上効果について 10-fold のクロスバリデーションによって検証した．

メッシュ形状抽出の精度評価には，Chamfer Distance（CD）を使用し，推論したメッシュと GT との誤差を評価した．

4. 実験結果

存在確率マップありのモデルとなしのモデルでそれぞれ抽出したメッシュ形状と，入力した CT 画像断面とを重ね合わせた例を図 1 に示す．赤色で示しているのが前尖，青色で示しているのが後尖領域である．

存在確率マップなしの場合は, 僧帽弁の弁口側領域や後尖領域について GT から大きくずれるものがあったが，存在確率マップの追加によって改善が見られた. 存在確率マップなしでの全症例での平均 CD は 1.20mm であり，存在確率マップを追加した際の全症例での平均 CD は 0.88mm であった．また，CD が 1.5mm 以内となる症例の割合は，存在確率マップなしでは 82.3%であったが，存在確率マップの追加によって 96.1%に向上した．

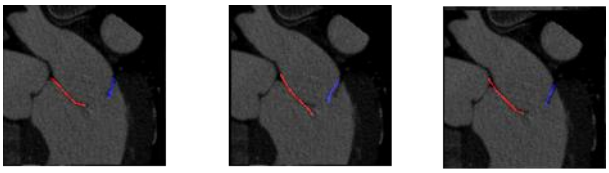


図 1　抽出されたメッシュ断面

5. まとめ

本研究では，CT 画像からの僧帽弁形状抽出において，存在確率マップを推定してから僧帽弁メッシュ形状を抽出する手法を提案した．今後の研究では，この方法で抽出した僧帽弁形状から計算した解剖学的構造が, 臨床診断と介入決定に寄与できるかを検討する．

利益相反の有無

なし

文　献

[1] Lavall D, Hagendorff A, Schirmer SH, et al.: Mitral valve interventions in heart failure. ESC Heart Fail. 2018 Aug;5(4), WILEY, 2018, pp 552-561.

[2] Catherine M Otto, Rick A Nishimura, Robert O Bonow, et al.: 2020 ACC/AHA guideline for the management of patients with valvular heart disease: a report of the American college of cardiology/American heart association joint committee on clinical practice guidelines. J Am Coll Cardiol. Volume 77 Issue 4, Elsevier, 2021, pp 450-500.

[3] Abhishek Twiwari and Kedar A. Patwardhan: Mitral valve annulus localization in 3D echocardiography. Annu Int Conf IEEE Eng Med Biol Soc. Aug;2016, IEEE, 2016, pp 1087-1090.

[4] Eva Costa, Nelson Martins, Malik Saad Sultan, et al.: Mitral valve leaflets segmentation in echocardiography using convolutional neural networks. IEEE 6th Portuguese Meeting on Bioengineering (ENBENG) 22-23 Feb. 2019, IEEE, 2019, pp 1-4.

[5] Özgün Çiçek, Ahmed Abdulkadir, Soeren S., et al.: 3D U-Net: learning dense volumetric segmentation from sparse annotation. Medical Image Computing and Computer-Assisted Intervention – MICCAI 2016, Springer, 2016, pp 424–432.

[6] Seyed Sadegh Mohseni Salehi, Deniz Erdogmus, et al.: Tversky loss function for image segmentation using 3D fully convolutional deep networks. Machine Learning in Medical Imaging. MLMI 2017. Springer, 2017, pp379-387.

Automatical identification of focal liver tumors in abdominal CT images for treatments of radiofrequency ablation

Ganxin Ouyang[*1], Yuma Sugishita[*1], Takeshi Hara[*1], Xiangrong Zhou[*1], Kumi Ozaki[*2]

[*1]*Graduate School of Natural Science and Technology, Gifu University*
[*2]*Department of Radiology, Hamamatsu University School of Medicine*

Abstract: Radiofrequency Ablation (RFA) is one of the important treatment approaches for focal liver tumors. To determine the effectiveness of this treatment, it is necessary to verify whether the tumor area has been appropriately ablated. For this purpose, comparing the ablated areas before and after RFA treatment is crucial. The aim of this study was to evaluate the accuracy of an automatic extraction method for tumor and ablated areas before and after RFA treatment. The experiment utilized 92 tumors before and after RFA treatment. The automatic extraction method was compared between U-Net++ and U-Net. The extraction results were evaluated using the Intersection over Union (IoU). The mean/SD IoU results of the automatic extraction were 31.6/32.8 for tumors before RFA treatment and 56.3/34.2 for areas after treatment.

Key words: liver cancer, CT images, U-Net++, segmentation

1. Introduction

Liver disease is widespread worldwide, with liver cancer being one of the leading causes of death in Japan. Liver cancer kills 25,000 people a year and is the fifth deadliest cancer. The severity of hepatocellular carcinoma often depends on the number and size of the cancer cells. Radiofrequency ablation (RFA) is an important method for the treatment of focal liver tumors. By inserting an electrode needle, radiofrequency energy is emitted to heat the tumor, causing it to coagulate and die. However, human judgment alone cannot determine the accuracy of an automated extraction method for tumors and ablation areas before and after RFA treatment.

The purpose of this study was to evaluate the accuracy of an automated extraction method on tumors and ablation areas before and after RFA treatment. To help doctors provide more accurate and efficient services to a wider range of patients. To determine the effectiveness of this treatment, it is necessary to verify that the tumor area has been ablated properly. For this reason, it is important to compare the ablation areas before and after RFA treatment.

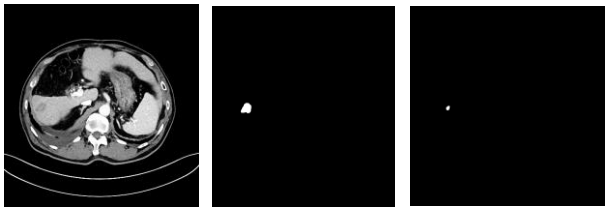
2. Method and Materials

A thousand two hundred eleven images of size 512*512 were used. The batch size was set to 1. The programs were run using U-Net and U-Net++ respectively, and the intersection over union (IoU) was used to evaluate the extraction results. U-Net and U-Net++ are common deep learning models for image segmentation tasks. They are widely used in medical image processing and other applications that require high-precision segmentation [2]. These two models are often chosen for testing because their respective strengths and weaknesses can provide different advantages for different tasks and data sets. The disadvantage of U-Net is that there will be some unnecessary feature redundancy, which will affect the accuracy of segmentation results [3]. However, U-Net++ uses nested skip connections, which can effectively reduce feature redundancy and improve segmentation accuracy [4]. However, due to the complex structure, the computational amount and time of U-Net++ will be larger than that of U-Net. Therefore, testing and comparing the two models helps to find the optimal image segmentation solution for a particular task and datasets.

3. Results and Discussion

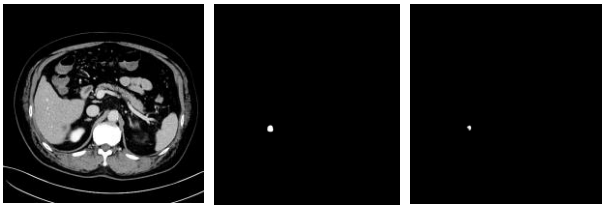
As shown in Figure 1, the average value of U-Net is 42.2. In Figure 2, the average value of U-Net++ is 47.3. Although U-Net++ requires more computational memory, it performs better in terms of accuracy and recognition speed. Therefore, U-Net++ was used as the main method for calculations in subsequent tests, and 92 tumor datasets before and after RFA treatment were used for grouping tests. The experimental results show that U-Net++ is used as the main method to calculate and the extraction results are evaluated using IoU. The mean/standard deviation IoU results extracted automatically were 31.6/32.8 for the tumor before RFA treatment and 56.3/34.2 for the tumor area after RFA treatment. As shown in Figure 3, it can be found that the average value has increased from 31.6 to 56.3. It shows that U-Net++ has a significant improvement in recognition accuracy after RFA treatment. It may be that the contrast is improved because the image becomes black and the tumor part becomes white, and the tumor edges become clear. In addition, the batch size is set to 1 in this experiment, and the next step will adjust the batch size to 2 or 3, or even higher 4. Because the training model is small, the faster method is used, and it is believed that a larger batch size often makes a greater

improvement in IoU.



Original Image Label Image Output Image

Figure 1: U-Net output



Original Image Label Image Output Image

Figure 2: U-Net++ output

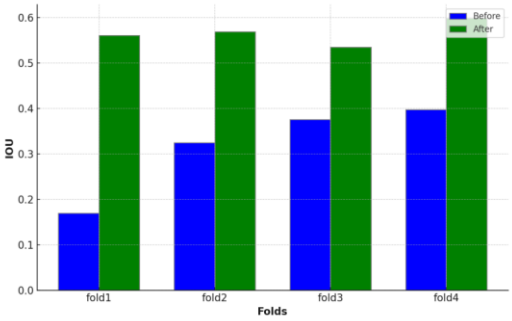


Figure 3: RFA average before and after

4.Conclusions

The image segmentation model based on the U-Net++ method can automatically segment and measure tumor areas in the liver, allowing for more accurate evaluation of the distribution and number of tumors. By adding more input parameters and training data, we can analyze more complex cases to verify that the tumor area has been properly ablated. This enables to judge the effectiveness of RFA treatment, providing a reference for doctors in the actual diagnosis process.

The presence or absence of a conflict of interest

No.

References

[1] https://www.ncc.go.jp/jp/ncce/clinic/hepatobiliary_oncology/liver/index.html

[2] L. Xiaolong, Z. Deng, and Y. Yang. “Recent Progress in Semantic Image Segmentation.” Artificial Intelligence Review 52.2 (2018): 1089–1106.

[3] Ranneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation[C]//Medical image computing and computer-assisted intervention–MICCAI 2015:18th international conference, Munich, Germany, October 5-9, 2015,
proceedings, part III 18. Springer International Publishing, 2015: 234-241.

[4] Zhou Z, Rahman Siddique M, Tajbakhsh N, et al. U-Net++: A nested u-net architecture for medical image segmentation[C]//Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, DLMIA 2018, and 8th International Workshop, ML-CDS 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, Proceedings 4. Springer International Publishing, 2018: 3-11.

Ensemble Multiscale Attention UNet による胸部 CT 画像からの肺腫瘍領域の自動抽出

高橋　礼生[*1]，神谷　亨[*1]，寺澤　岳[*2]，青木隆敏[*2]
[*1] 九州工業大学
[*2] 産業医科大学

Extraction of Lung Tumor Regions from Thoracic CT Images Based on Ensemble Multiscale Attention UNet

Reo TAKAHASHI[*1]，Tohru KAMIYA[*1]，Takashi TERASAWA[*2]，Takatoshi AOKI[*2]
[*1] *Kyushu Institute of Technology*
[*2] *University of Occupational and Environmental Health*

要旨：現在，日本での肺がんによる死亡者数は男女計で 1 位を記録しており，肺がんの早期発見・早期治療が重要課題となっている．肺がんの検査は治療方針を選択するための手段であり，特に，遺伝子検査はがん細胞の増殖・浸潤・転移に関わるドライバー遺伝子変異の有無を確認することができる．ドライバー遺伝子変異の有無を確認する過程では，医師と協力して手作業で肺がん領域を抽出する必要があり，読影医師への負担が懸念される．そこで本論文では，医師の負担軽減のため，アテンション構造，複数スケールの特徴抽出と広範囲受容野の獲得に加え，異なる層数を持つ 2 つのモデルのアンサンブル学習による，肺腫瘍領域の検出を行うため，EMA-UNet を用いた画像解析手法を提案する．実験の結果，EMA-UNet は U-Net と比較して良好な抽出精度が得られた．

キーワード：Computer Aided Diagnosis, Deep Learning, Semantic Segmentation, U-Net, Ensemble Learning

1. 序論

2022 年の死因の約 24.6%ががんであり，がんにおける部位別死亡率では肺がんが最も高く，早期発見・早期治療が重要課題となっている[1]. 従来のがん医療は，がんの種類別に治療や薬が選ばれていたが，2000 年代からがんの原因となっている分子や遺伝子等を標的とした分子標的薬の使用が可能となった[2]. しかし，分子標的薬の使用に際し，がん組織の遺伝子変異の確認のため侵襲的な検査が必要となる. その問題点を解決するため, 画像のみから肺がんの遺伝子変異を識別する研究が行われている[3]. この研究の流れは，胸部 CT 画像から肺がん領域を特定し, 医師と手作業によって腫瘍領域の抽出を行っている. その領域から特徴量を抽出し，機械学習によって遺伝子変異の有無を予測する. 以上の過程で，医師と手作業による腫瘍領域のセグメント作業は, 医師への負担が膨大な点が問題であった. また，セグメント結果も重要であり，胸部 CT 画像から肺腫瘍領域を自動抽出する方法の開発が期待されている.

従来手法では，医療画像セグメンテーションで有用である U-Net[4]や，U-Net をベースとし，改良を加えたモデル[5,6]が提案されている. それらの従来手法によって，円形や楕円形の一般的な形状や, 大小さまざまなスケールの肺腫瘍の抽出が可能となった. しかし，縦隔・肺門や胸壁に広く接する肺腫瘍の抽出精度が低いという問題点が存在する. 遺伝子変異有無の検出のため，腫瘍領域から特徴量を抽出するが，厳密な領域抽出が求められる. そのため，肺腫瘍と通常の肺組織との境界を正確に識別することが望ましい. 以上の観点から，本論文では，胸部 CT 画像を用い，縦隔・肺門や胸壁に広く接した肺腫瘍の領域を自動抽出する手法を提案する.

2. 手法

2.1 ベースモデル

本論文では, 我々が提案した先行手法である改良型 U-Net[6]をベースモデルとして用いる. この手法は，U-Net に MultiRes Block[8]と CBAM[7]を導入し，さらにそれらのモデルに対して層違いのモデルでアンサンブル学習を行っている. 以上の改良により，複数スケールからの特徴抽出を行い，それらの特徴において，どの特徴に焦点を当てるべきかが明らかとなり，大小さまざまなスケールの肺腫瘍に対して抽出精度が向上した.

2.2 ASPP(Atrous Spatial Pyramid Pooling)

ASPP[9]は異なる拡張率の Atrous Convolution を複数使用して異なるスケールのコンテキスト情報を取得し, 大小さまざまな受容野の特徴量を抽出する構造である. Atrous Convolution とは，通常の畳み込みのフィルタに対し，空間的感覚を開けて畳み込みを行う手法である. Atrous Convolution を用いることにより，パラメータ数を増やすことなく，大小さまざまのコンテキスト情報を取得可能である. この多スケールでの特徴抽出能力によって異なるサイズや形状の腫瘍だけでなく, 腫瘍の複雑な内部構造や周囲の肺組織との境界をより正確に識別することが可能となり, 縦隔・肺門や胸壁に広く接した肺腫瘍に対し，正確に境界を識別することが可能と考え，本論文で採用した.

2.3 提案手法

本論文では，先行手法である改良型 U-Net[6]をベースモデルとし, より広範囲の情報を効率的にとらえることができるよう,

表 1 各モデルの平均抽出結果

	Dice	IoU
U-Net[4]	0.830	0.757
Improved U-Net[5]	0.883	0.812
改良型 U-Net[6]	0888	0.820
EMA-UNet(提案手法)	0.898	0.830

ボトルネック部分に ASPP を導入した．また，先行研究と同様に，ASPP を追加したモデルに対するアンサンブル学習を行った EMA-UNet(Ensemble Multiscale Attention UNet)を開発した．

3. 実験結果と考察

本論文で使用した画像は産業医科大学病院で撮像されたもので，医師の指導の元作成した，230 症例 850 枚の胸部 CT 画像をデータセットして用いた．また，モデル検証のため，U-Net と先行研究，そして提案手法に対する 5 分割交差検証を行い，「Dice」と「IoU」を求め，その平均値を算出した．その結果を表 1 に示す．同表から提案手法は Dice=0.898，IoU=0.830 という結果になり，最も高い精度を記録した．

図 1 は本法で抽出に成功した縦隔・肺門や胸壁に広く接する肺腫瘍症例の一つである．赤色がアノテーション領域で，青色がモデルの抽出領域である．改良型 U-Net では抽出精度が低い一方，本法ではおおよその抽出に成功している．提案手法のみで抽出に成功した理由として，ASPP を新たに導入したことにより，あらゆるコンテキスト情報を考慮することが可能となった．これにより，複雑なテクスチャや形状の識別精度が向上し，肺腫瘍の複雑な内部構造や周囲の肺組織との境界を，より正確に識別することが可能になったためだと考えられる．

一方で，辺縁が不整な肺腫瘍に対しては本法を用いても精度の良い抽出が行えなかった．主な原因として二つ考えられる．一つ目は，辺縁不整な形態の肺腫瘍は，円形や楕円形な肺腫瘍と比較し，形状特徴等が複雑であるため，学習が難しいことが考えられる．二つ目はデータ不足である．一般的にはデータが多いほど精度が向上するが，辺縁不整な形態の肺がん例がデータセット内に十分に含まれておらず，このような症例に対する精度が低下したと考えられる．

4. 結論

本論文では，胸部 CT 像から縦隔・肺門や胸壁に広く接した肺腫瘍の自動抽出を行うための手法を提案した．実験の結果，提案手法は先行研究と比較し，抽出精度は 1%の向上にとどまったが，縦隔・肺門や胸壁に広く接した肺腫瘍の抽出精度が向上することを確認できた．今後，さらなる抽出精度向上のため，データの拡張やモデルの改良を行い，複雑な形状を持つ腫瘍の抽出を行う予定である．

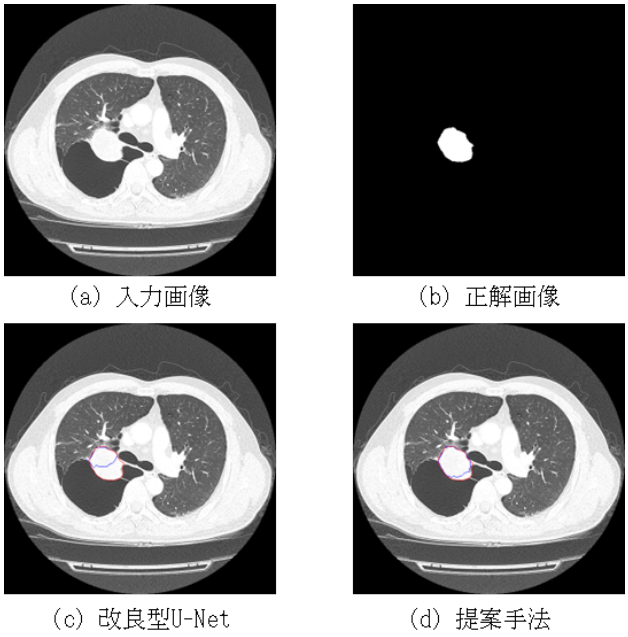


図 1　抽出の成功例

利益相反の有無

なし

文　献

［1］厚生労働省：令和 4 年(2022)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/nengai22/dl/gaikyouR4.pdf (accessed : 2024/05/10)

［2］国立がん研究センターがん情報サービス：個別化治療とは，https://ganjoho.jp/public/dia_tre/treatment/genomic_medicine/gentest02.html(accessed：2024/05/10)

［3］S.Watanabe et al: Detection of Driver Gene Mutations from Thoracic CT Images Based on LightGBM with Radiomics Features. 2022 22nd International Conference on Control, Automation and Systems, 2022, pp.542-545

［4］S.N.Kumar et al: Lung Nodule Segmentation Using UNet. 2021 7th International Conference on Advanced Computing and Communication Systems, Vol1, 2021, pp.420-424

［5］R.Takahashi et al: Extraction of Lung Tumor Regions from Thoracic CT Images Using An Improved U-Net. 2023 23rd International Conference on Control, Automation and Systems, 2023, pp.1489-1493

［6］高橋礼生他：改良型 U-Net を用いた胸部 CT 画像からの肺腫瘍領域の自動識別，北九州医用工学術者協会誌, Vol63, 2023, pp.1-4

［7］S.Woo et al: CBAM：Convolutional Block Attention Module. European Conference on Computer Vision, 2018, pp.3-19

［8］N.Ibtehaz et al: MultiResUNet: Rethinking the U-Net Architecture for Multimodal Biomedical Image Segmentation. Neural Networks, 2020, pp.74-87

［9］L.C.Chen et al: Deeplab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.40, 2018, pp.834-848

Semi-supervised Tubular Structure Segmentation with Consistency

Ruiyun Zhu[*1], Masahiro Oda[*2,1], Yuichiro Hayashi[*1], Takayuki Kitasaka[*3]and Kensaku Mori[*1,2]

[*1] *Graduate School of Informatics, Nagoya University, Furo-cho, Chikusa-ku, Nagoya, Aichi, 464-8601, Japan*

[*2] *Information Technology Center, Nagoya University, Furo-cho, Chikusa-ku, Nagoya, Aichi, 464-8601, Japan*

[*3] *School of Information Science, Aichi Institute of Technology, 1247 Yachigusa, Yakusa-cho, Toyota, Aichi, 470-0356, Japan.*

要旨：This study introduces an innovative semi-supervised methodology for the 3D segmentation of tubular structures, a notable challenge in medical image processing due to the complexity of these structures. Traditional supervised deep learning requires extensive annotated datasets, which are expensive and challenging. To mitigate this, we propose a semi-supervised model utilizing task-level consistency learning with the Hausdorff distance consistency. This approach leverages the geometric properties of both labeled and unlabeled data to improve segmentation accuracy. Our model generates a segmentation and a distance transform map, with Hausdorff distance consistency ensuring geometric shape alignment, thus improving tubular structure segmentation performance. Tested on a 3D CT scan airway segmentation task, our method exceeded recent advanced methods, achieving an 84.0% tree length detection rate, 74.4% branch detection rate, and 89.7% precision rate, demonstrating its effectiveness in medical image segmentation.

キーワード：Semi-supervised learning, Tubular structure segmentation, Hausdorff distance

1. Introduction

Accurate segmentation of tubular structures like airways and blood vessels is crucial for computer-aided diagnosis systems, yet remains a significant challenge in medical image processing. Deep learning has improved medical image analysis but heavily relies on large-labeled datasets. Annotating these structures, such as airways in chest CT scans is labor-intensive and requires significant expertise.

Semi-supervised learning (SSL) methods reduce labor costs by using less labeled data. In SSL segmentation, consistency regularization leverages the geometric properties of targets. Complex structures like airways and blood vessels require a focus on geometric shapes. Distance transform (DT) assigns voxels values based on their distance to the nearest voxel, depicting object shapes. Karimi et al. [1] minimized Hausdorff distance (HD) in CNN training by using DT maps to approximate HD, highlighting differences between predicted maps and ground truth.

This study introduces an SSL method with HD consistency for 3D airway segmentation from 3D CT volumes. Our approach achieved an 84.0% tree length detection rate and a 74.4% branch detection rate, outperforming previous methods.

2. Methods

This study develops an SSL framework to enhance tubular structure segmentation accuracy. We employ a consistency learning approach that incorporates an auxiliary DT regression task. Our framework, illustrated in Fig. 1, uses a multi-head convolutional neural network, with separate output heads for the main segmentation and auxiliary DT regression tasks.

The HD demonstrates the boundary information of the segmentation objectives. Following [1], in image segmentation, the HD metric could be written as

$$L_{hd}(\mathbf{p}_i, \mathbf{g}_i, \mathbf{d}_i^p, \mathbf{d}_i^g) = \frac{1}{|\mathbf{P}|}\sum_{i=1}^{|\mathbf{P}|}\left((\mathbf{p}_i - \mathbf{g}_i)^2 * (\mathbf{d}_i^p + \mathbf{d}_i^g)\right), \quad (1)$$

where * denotes Hadamard product. $\mathbf{p}_i$ and $\mathbf{g}_i$ represent the i-th predicted segmentation map and the corresponding ground truth. $\mathbf{d}_i^p$ and $\mathbf{d}_i^g$ represent the corresponding DT maps of the predicted segmentation map and the ground truth. $|\mathbf{P}|$ is the number of predicted segmentation maps. We note that the HD metric uses DT maps to illustrate the geometric properties of segmentation targets and is adaptable to unlabeled data. As shown in Fig. 1, our network outputs DT and segmentation maps, corresponding to $\mathbf{p}_i$ and $\mathbf{d}_i^p$ in Equation 1. To utilize unlabeled data, we employ pseudo-masking technology to generate pseudo labels and DT maps. We binarize the predicted DT maps using a Heaviside function to create pseudo label

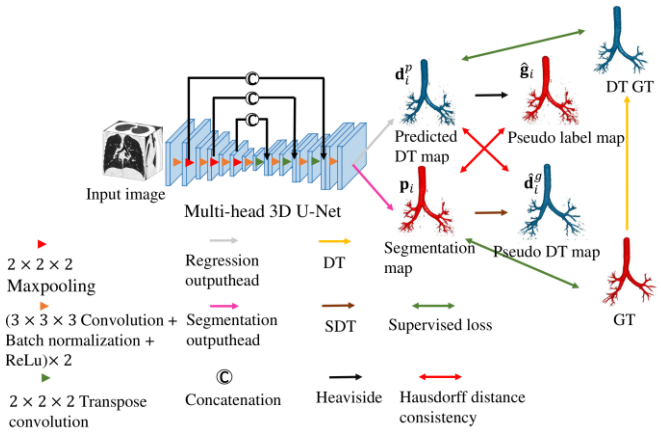


Fig. 1 The proposed framework

maps, $\mathbf{g}_i$, and similarly produce pseudo DT maps, $\mathbf{d}_i^g$, by binarizing and applying a differentiable distance transform [2]. This allows the predicted maps to mutually supervise geometric shape segmentation with unlabeled data. Therefore, our HD consistency could be written as

$$L_{hd}(\mathbf{p}_i, \hat{\mathbf{g}}_i, \mathbf{d}_i^p, \hat{\mathbf{d}}_i^g) = \frac{1}{|\mathbf{P}|}\sum_{i=1}^{|\mathbf{P}|}\left((\mathbf{p}_i - , \hat{\mathbf{g}}_i)^2 * (\mathbf{d}_i^p + \hat{\mathbf{d}}_i^g)\right), \quad (2)$$

where $\hat{\mathbf{g}}_i$ and $\hat{\mathbf{d}}_i^g$ represent the pseudo label maps and pseudo DT maps, respectively.

Our semi-supervised training framework combines supervised and unsupervised approaches, using labeled data for segmentation and DT regression with Dice loss and mean square error loss, respectively.

3. Experimental results

We evaluated our bronchus segmentation method using a binary airway segmentation dataset comprising 90 CT scans (70 from LIDC [3] and 20 from EXACT'09 [4]) with slice thicknesses from 0.5 to 1.0 mm and resolutions of 0.50 to 0.82 mm. The number of slices varied from 157 to 764. The scans were 512×512 pixels. We trained on 80 cases and tested on 10, using tree length detection rate (TL) [5], branch detection rate (BD) [5], and precision rate for evaluation.

We conducted an experiment using 16 labeled and 64 unlabeled CT volumes during training. We compared our results with several previous methods. We repeated the experiment three times and reported the average and standard deviation of segmentation performance of each comparison method in our experiments. The experimental results are shown in Table 1. Our method led with the highest TL and BD rates (TL: 84.0%, BD: 74.4%, precision: 89.7%), comparable to a fully supervised 3D U-Net's TL performance.

4. Discussions

Our SSL method effectively extracted tubular structures from CT volumes. The quantitative results are shown in Table 1. our method achieved the highest TR and BD (TR: 84.0%, BD: 74.4%, and precision rate: 89.7%). However, the precision rate of our method was slightly lower than previous methods due to the false positive issue. The false positive issue might be caused by the errors in approximated differentiable distance transform.

Table 1 Evaluation results. The best performance of each evaluation term is highlighted using a bold font.

Approach	TL (%)	BD (%)	Precision (%)
SASSNet [6]	81.5±1.1	72.5±1.7	**93.2±0.2**
DTC [7]	81.7±1.0	73.3±1.3	92.8±0.6
ICT [8]	80.7±3.6	72.4±4.9	92.9±1.0
Co-BioNet [9]	82.9±3.1	73.5±4.3	91.9±0.9
Our method	**84.0±1.3**	**74.4±4.9**	89.7±0.1

5. Conclusions

This paper presents a semi-supervised method for 3D tubular structure segmentation using consistency learning. We introduced a HD consistency to effectively utilize geometric shape information from unlabeled data, improving tree length and branch detection rates. Future work will aim to enhance precision and expand evaluations to other segmentation tasks.

Acknowledgments

This work was funded by grants from JSPS KAKENHI (24H00720, 21K19898), the JST CREST (JPMJCR20D5), and the JSPS Bilateral Joint Research Project.

Compliance with ethical standards

The authors declare that they have no conflict of interest. All data used in this study are publically available.

References

[1] Karimi D, Salcudean S. E: Reducing the Hausdorff distance in medical image segmentation with convolutional neural networks. IEEE Trans Med Imag 39 (2): 499-513, 2019

[2] Zhang M, Yang G. Z, Gu Y: Differentiable topology-preserved distance transform for pulmonary airway segmentation. arXiv preprint arXiv:2209.08355 1.2, 2022

[3] Armato III S. G, McLennan G, Bidaut L et al: The lung image database consortium (LIDC) and image database resource initiative (IDRI): a completed reference database of lung nodules on CT scans. Med Phys 38 (2): 915-931, 2011

[4] Lo P, Van Ginneken B, Reinhardt J. M et al: Extraction of airways from CT (EXACT'09). IEEE Trans Med Imag 31 (11): 2093-2107, 2012

[5] Feuerstein M, Kitasaka T, Mori K: Adaptive branch tracing and image sharpening for airway tree extraction in 3-D chest CT. Proc Second Int Workshop Pulm Imag Anal Vol. 1, pp. 1-8, 2009

[6] Li S, Zhang C, He X: Shape-aware semi-supervised 3D semantic segmentation for medical images. Proc Int Conf Med Image Comput Comput-Assist Interv 12261, pp. 552–561, 2020

[7] Luo X, Chen J, Song T et al: Semi-supervised medical image segmentation through dual-task consistency. Proc AAAI Conf Artif Intell. Vol. 35. No. 10, 2021

[8] Verma V, Kawaguchi K, Lamb A et al: Interpolation consistency training for semi-supervised learning. Neural Netw 145: 90-106, 2022

[9] Peiris H, Hayat M, Chen Z et al: Uncertainty-guided dual-views for semi-supervised volumetric medical image segmentation. Nat Mach Intell 5 (7): 724-738, 2023

3 次元医用画像の自己教師ありセグメンテーションに関する初期検討

鈴木　敦志[*1]，小林　和馬[*1,2]，浜本　隆二[*1,2]
[*1] 理化学研究所革新知能統合研究センター
[*2] 国立がん研究センター研究所

A Preliminary Study on Self-Supervised Segmentation of 3D Medical Images

Atsushi SUZUKI[*1]，Kazuma KOBAYASHI[*1,2]，Ryuji HAMAMOTO[*1,2]
[*1] *RIKEN Center for Advanced Intelligence Project*
[*2] *National Cancer Center Research Institute*

要旨：患者のプライバシーやアノテーション・コストの観点から，大規模な医用画像データセットを構築することは時に困難である．そのため，下流タスクに転移可能な特徴をデータそれ自体から学習するための事前学習が注目されている．我々は，3 次元医用画像の解剖学的構造に応じたセグメンテーションを獲得するための自己教師あり手法を提案する．具体的には，ランダムな幾何学的・光学的変換に対して，埋め込み表現が不変となるような制約を加えてボクセル単位でのクラスタリングを行う．予め設定したクラスタ数へと画像が分割されることによって，セグメンテーションが得られる．本手法は，U-Net などの様々なセグメンテーション・ネットワークに対して，モデル非依存に適用可能である．原発性脳腫瘍を含む頭部 MRI からなるデータセットにおいて実装し，下流タスクとしての腫瘍セグメンテーションの性能向上に寄与するかについての初期検討を報告する．
キーワード：自己教師あり学習，セグメンテーション，転移学習，MRI，原発性脳腫瘍

1. はじめに

3 次元医用画像に対する疾患セグメンテーションを，少ないアノテーションで実現するための自己教師あり学習が注目されている．自己教師あり学習では，疾患セグメンテーションなどの下流タスクに寄与する識別的な特徴を，データそれ自体から如何に獲得するかという視点が重要である．しかしながら，セグメンテーションそれ自体を事前学習タスクとした手法は，現在までに提案されてこなかった．

本研究では，事前学習タスクとしての自己教師ありセグメンテーション手法を提案する．この手法では，医用画像における解剖学的構造を構成する画像特徴は，一定の幾何学的・光学的変換に対して不変であると想定する．そして，3 次元医用画像のボクセル単位の埋め込み表現が，こうした変換に対して不変なクラスタ割り当てを獲得するように自己教師あり学習することによって，セグメンテーションを行う．

本稿では，その初期検討として，原発性脳腫瘍を含む頭部 MRI からなるデータセットを用いて 3D U-Net [1]を事前学習した．そして，事前学習済みモデルと，事前学習を行わずにスクラッチから学習させたモデル（スクラッチ・モデル）を，下流タスクとしての疾患セグメンテーションに関して比較した．

2. 方法

提案手法は，2 次元医用画像に対する自己教師ありセグメンテーションを報告した著者らの先行研究[2]の 3 次元拡張が主となる． (1)入力画像に対するランダムな変換，(2) セグメンテーション・ネットワーク，(3) クラスタリング・モジュール，(4) 画像再構成・大域的特徴抽出ネットワークの 4 つの要素からなる．以下，これらの詳細について述べる．

2.1 ランダムな画像変換

提案手法では，「医用画像の解剖学的構造を構成する画像特徴は，一定の幾何学的・光学的変換に対して不変である」との仮定に基づき，ボクセル単位での埋め込み表現のクラスタリングを行う[2,3]．そのため，入力画像に対して，ランダムな幾何学的変換（アフィン変換）および光学的変換（Gamma Correction, Intensity Shift/Scale）を加えたペア画像を得て，それぞれをセグメンテーション・ネットワークに入力する．

2.2 セグメンテーション・ネットワーク

セグメンテーション・ネットワークとは，事前学習の対象となるニューラル・ネットワークである．Cチャンネルの入力画像$\boldsymbol{X} \in \mathbb{R}^{C\times H\times W\times D}$に対して，ボクセル単位の埋め込み表現$\boldsymbol{e} \in \mathbb{R}^{Z}$の集合$\boldsymbol{E} \in \mathbb{R}^{Z\times H\times W\times D}$（以下，「埋め込みボリューム」）が出力されるものであれば，ネットワークの構造は問わない．

2.3 クラスタリング・モジュール

クラスタリング・モジュールは，学習可能なK個のクラスタ中心ベクトル$\boldsymbol{q}_k \in \mathbb{R}^{Z}, k \in \{1,\dots,K\}$を保持している．セグメンテーション・ネットワークから出力された埋め込みボリューム$\boldsymbol{E}$を受け取ると，そのボクセル単位の埋め込み表現$\boldsymbol{e}$を，いずれか最近傍のクラスタ中心ベクトル$\boldsymbol{q}_k$へと置換し，置換後ボリューム$\boldsymbol{Q} \in \mathbb{R}^{Z\times H\times W\times D}$を出力する．ここで，ボクセル単位の埋め込み表現$\boldsymbol{e}$が割り当てられたクラスタのインデックス$\boldsymbol{k}$が，そのボクセルにおけるセグメンテーション・ラベル$\boldsymbol{k}$であると

みなすことで，自己教師ありセグメンテーションが得られる．

学習の過程では，クラスタ中心ベクトル$\boldsymbol{q}_k$に対して，埋め込み表現$\boldsymbol{e}$を近づけるように作用する Commitment Loss と，ランダムな変換を与えられて得られたペア画像の間で，ボクセル単位のクラスタ割り当てが一致するように作用する Cross-view Consistency Loss が計算される．一方，クラスタ中心ベクトル$\boldsymbol{q}_k$は，クラスタ$\boldsymbol{k}$に割り当てられた埋め込みボクセル$\boldsymbol{e}$の平均に基づいた指数移動平均によって更新される．

2.4 画像再構成・大域的特徴ネットワーク

画像再構成・大域的特徴抽出ネットワークは，置換後ボリューム$\boldsymbol{Q}$を入力として受け取る．このネットワークはエンコーダ・デコーダ型のアーキテクチャからなり，2 つの役割を担う．1 つ目は，入力画像の再構成であり，再構成画像と入力画像との間の Reconstruction Loss が算出される．2 つ目は，置換後ボリューム$\boldsymbol{Q}$の大域的情報を保持する特徴ベクトルを抽出し，これがサンプル間で類似するように作用する Global Context Loss を計算する．

3. 実験

原発性脳腫瘍を含む頭部 MRI と，3 クラスの腫瘍関連領域（GD-enhancing Tumor，Peritumoral Edema，Necrotic Tumor Core）の正解セグメンテーション・ラベルを含む MICCAI BraTS 2020 データセットをランダムに分割し，学習用データセット（N=296）と検証法データセット（N=73）とした．セグメンテーション・モデルとしての 3D U-Net を，学習用データセットを用いて，提案手法により事前学習した．

続いて，事前学習済みモデルに対して，下流タスクとしての疾患セグメンテーションを再学習させた．再学習においては，セグメンテーション・ネットワークの最終層に畳み込み層と Softmax 関数を追加し，Dice Loss と Cross Entropy Loss からなる損失関数を最小化するように，学習用データセットを用いて訓練した．その学習過程を，スクラッチ・モデルと比較した．

4. 結果

4.1 自己教師ありセグメンテーションの結果

図 1 に，事前学習タスクにて獲得されたセグメンテーション・マップを示す．自己教師ありセグメンテーションの結果は，一般的な解剖学的構造に概ね一致していることがわかる．

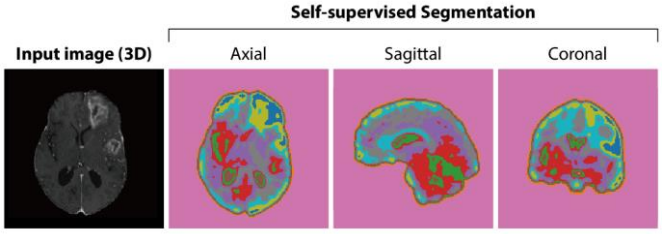


図 1: 自己教師ありセグメンテーションの結果

4.2 下流タスクにおける転移性能の検証

図 2 に，下流タスクにおける学習曲線を示す．学習用データセットにおいて，事前学習済みモデルの損失関数は，スクラッチ・モデルよりも早期に低下した．また，検証用データセットにおいて，腫瘍関連領域の平均 Dice 係数が，事前学習済みモデルにて優越することを確認したが，その差は軽微であった．

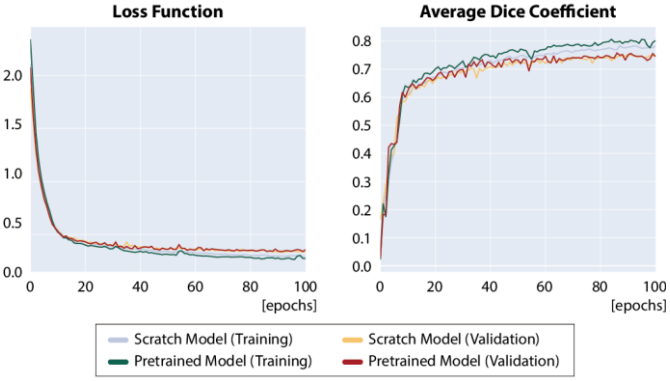


図 2: 下流タスクにおける学習曲線の比較

5. 結論

提案手法は，3 次元医用画像の疾患セグメンテーションにとっての良い事前学習タスクとなる可能性がある．この事前学習タスクは，U-Net などの様々なセグメンテーション・ネットワークに対して，モデル非依存で適応できる．

利益相反の有無

共著者である小林和馬，浜本隆二は富士フイルム株式会社より共同研究費を受けている．

文　献

[1] Ronneberger O, Fischer P, Brox T: U-Net: Convolutional Networks for Biomedical Image Segmentation. MICCAI, 2015

[2] Kobayashi K, Gu L, Hataya R et al: Towards AI-Driven Radiology Education: A Self-supervised Segmentation-Based Framework for High-Precision Medical Image Editing. MICCAI, 2023

[3] Cho JH, Mall U, Bala K et al: PiCIE: Unsupervised Semantic Segmentation using Invariance and Equivariance in Clustering. CVPR, 2021

MRI 単体での肩関節画像診断に向けた深層学習を用いた軟部組織除去手法の初期検討

杉本　裕汰*，野崎　太希*2，寺田　康彦 *1

*1 筑波大学 理工情報生命学術院 数理物質科学研究群

*2 慶応義塾大学医学部　放射線科学教室（診断）

Initial Exploration of Deep Learning-Based Soft Tissue Removal Technique for MRI-Based Shoulder Joint Image Diagnosis

Yuta Sugimoto*1，Taiki Nozaki*2，Yasuhiko Terada*1

*1 *Graduate School of Science and Technology, University of Tsukuba*

*2 *Department of Radiology, School of Medicine, Keio University*

要旨：肩関節部などの骨軟部領域の画像診断では，一般的に軟部組織と骨性構造の評価のために MRI と CT の 2 つの画像診断機器を用いる必要がある．しかし，2 つの検査にはコストがかかるため，MRI のみでの評価の完結（All in one MRI）が望まれている．そこで近年，MRI での骨性構造の描出が可能な zero echo time（ZTE）シーケンスが注目されている．しかし，ZTE シーケンスで得られた画像には，骨性構造だけでなく軟部組織も描出されてしまう．それら軟部組織は，診断時のボリュームレンダリング像を得るときに除去が必要となる．そこで本研究では，ZTE シーケンスで撮像された肩関節 MRI 画像から深層学習を用いて軟部組織を除去する手法を提案する．提案した深層学習モデルの出力画像は，処理前の ZTE 画像と比べて，CT 画像に近いという数値指標を示した．また，作成したボリュームレンダリング像からも軟部組織の除去が視覚的に確認された．

キーワード：コントラスト変換，位置合わせ，synthetic CT，U-Net

1. はじめに

肩関節部などの骨軟部領域の画像診断では, 一般的に軟部組織と骨性構造の評価のために MRI と CT の 2 つの画像診断機器を用いる必要がある．しかし，2 つの検査にはコストがかかるため，MRI のみでの評価の完結（All in one MRI）が望まれている．そこで近年，MRI での骨性構造の描出が可能な zero echo time（ZTE）シーケンスが注目されている．しかし，ZTE シーケンスで得られた画像には, 骨性構造だけでなく軟部組織も描出されてしまう．それら軟部組織は，診断時のボリュームレンダリング像を得るときに除去が必要となり, この除去作業の自動化が望まれている．一方，深層学習を用いた，異なるコントラストをもつ医用画像間のコントラスト変換の研究が盛んになっている[1].

そこで本研究では, ZTE シーケンスで撮像された肩関節 MRI 画像から深層学習を用いて軟部組織を除去する手法を提案する．具体的には，肩関節 ZTE 画像から，軟部組織の信号が描出されない CT 画像へコントラスト変換を行うことで，軟部組織を除去する．

2. 方法

2.1. データセット

聖路加国際病院で撮像された肩の上腕骨と関節窩が描出されている CT 画像と ZTE シーケンスを用いた MR 画像（Coronal 方向）を使用した．

2.1.1. データセットの前処理手順

（1）症例ごとに CT 画像と ZTE 画像の画像サイズとスライス枚数を統一した．統一方法は B スプライン補間を用いて CT 画像を ZTE 画像に合わせた．

（2）CT 画像と ZTE 画像の位置合わせを行った．位置合わせには, それぞれの画像の肋骨以外の骨をセグメンテーションし, セグメンテーション結果に対して相互情報量を用いたアフィン変換を実施した[2]. その後，肩が描出されている領域のみを学習に使用するため，CT 画像と ZTE 画像のマスク画像をそれぞれ作成し，マスク画像同士を要素積で重ね合わせ，両方のマスク内領域以外は背景と同じ値とした．

（3）ネットワークに入力する前処理として，背景除去と外れ値処理を行い，さらに背景除去と標準化処理を行った．各処理は症例単位で行い, 背景処理の閾値を画像最大値の 5%とした．外れ値処理では，画像平均値から±3 倍の標準偏差外の値を外れ値とした．

2.2. ネットワーク及び学習方法

本研究のアーキテクチャには U-Net[3]を利用した. 学習条件はエポックを 500, バッチサイズを 8, 学習率を 1.0×10^{-4} とし，データセット全 18 例を，11 例（学習），4 例（検証），3 例（テスト）に分割した．学習時には平行移動，回転，拡大をしてデータの拡張を行い，損失関数には平均二乗誤差（MSE）を使用した．

ボリュームレンダリングにはフリーソフトウェアである 3D slicer[4]を用いた．

定量評価の際には，ZTE と CT 間，およびモデルの出力結果と CT 間の MSE と SSIM を計算した．なお，MSE は背景を除いた領域内で計算した．

3. 結果・考察

図１にテスト症例の学習結果を，図２に１症例目のボリュームレンダリング像を示す．この結果を見るとモデルの出力画像である synthetic CT 画像では，画像内赤矢印で示す筋繊維などの軟部組織が削除された．作成したボリュームレンダリング像からも軟部組織の除去が視覚的に確認された．その一方で，synthetic CT 画像では CT 画像と比べて画像全体がぼやけて見えた．これは，位置合わせが完全ではないため，骨や軟部組織の境界付近で出力が曖昧になったためだと考える．また，比較的大きな軟部組織の一部で大きな出力誤差があった（図の黄色矢印）．数値評価に関しては，MSE，SSIM ともに synthetic CT の方が ZTE 画像よりも良好な結果を示した．

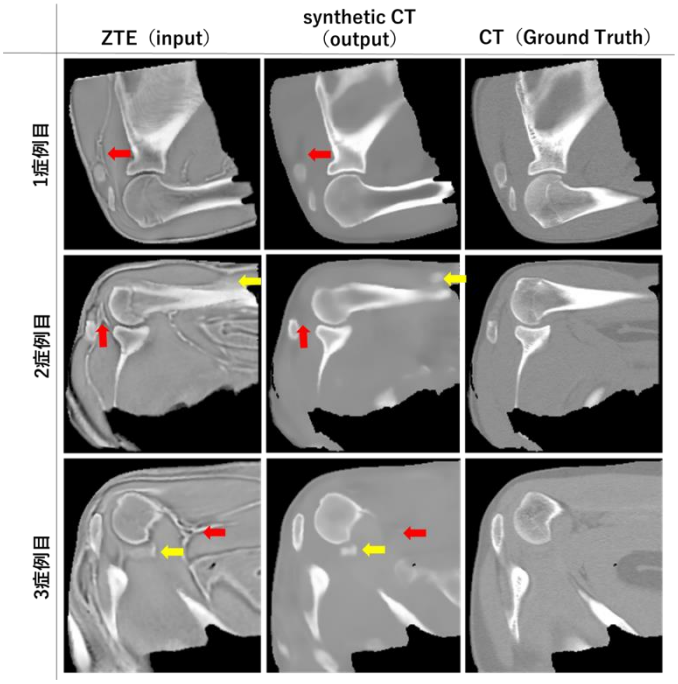


図１．学習結果の画像例

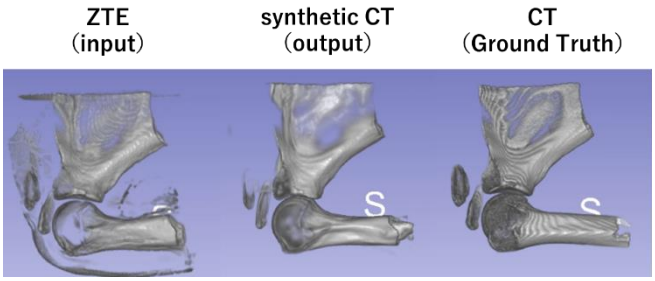


図２．１症例目のボリュームレンダリング像

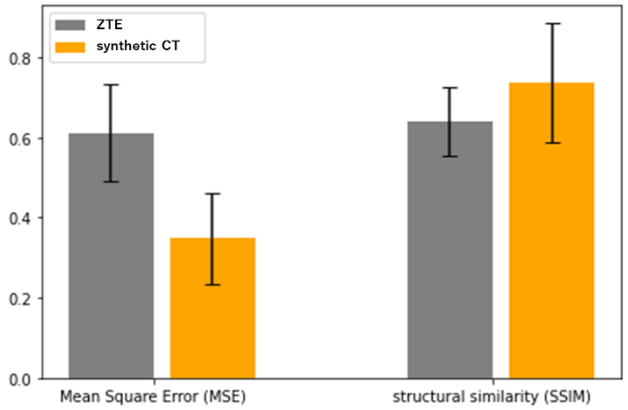


図３．定量評価の結果

4. まとめと今後の展望

本研究では，肩関節 ZTE 画像から U-Net を用いて軟部組織を除去する手法を提案した．U-Net の出力画像は，処理前の ZTE 画像と比べて，CT 画像に近いという数値指標を示した．また，作成したボリュームレンダリング像からも軟部組織の除去が視覚的に確認された．

今後は，コントラスト変換の性能向上を目指し，データセットが unpair の場合の検討や，臨床評価を行う．

利益相反の有無

なし

文　献

[1] Johnstone E, Wyatt JJ, Henry AM, et al (2018) Systematic Review of Synthetic Computed Tomography Generation Methodologies for Use in Magnetic Resonance Imaging–Only Radiation Therapy. International Journal of Radiation Oncology*Biology*Physics 100:199–217. https://doi.org/10.1016/j.ijrobp.2017.08.043

[2] SegmentationAidedRegistration - NAMIC Wiki. https://www.na-mic.org/wiki/SegmentationAidedRegistration. Accessed 30 May 2024

[3] Ronneberger O, Fischer P, Brox T (2015) U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab N, Hornegger J, Wells WM, Frangi AF (eds) Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. Springer International Publishing, Cham, pp 234–241

[4] 3D Slicer image computing platform. In: 3D Slicer. https://slicer.org/. Accessed 30 May 2024

マルチチャンネル化，画像の線形結合，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

滝沢　穂高[*1]，塩田　紘司[*2]，目片　幸二郎[*3]，工藤　博幸[*1]
[*1] 筑波大学システム情報系
[*2] 筑波大学大学院情報理工学位プログラム
[*3] 四条畷学園大学作業療法学専攻

Preliminary study on extraction of cervical vertebral bodies and spinous processes in videofluorography by use of multi channelization, image linear combination and U-Net

Hotaka Takizawa[*1], Koji Shioda[*2], Kojiro Mekata[*3], Hiroyuki Kudo[*1]
[*1] *Institute of Systems and Information Engineering, University of Tsukuba*
[*2] *Master's Program in Computer Science, University of Tsukuba*
[*3] *Shijonawate Gakuen University*

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．本報告では頸部 X 線動画に複数の画像フィルタを適用して特徴画像を生成し，それらの特徴画像を線形結合した画像を U-Net に入力することで，頸部椎体と棘突起を抽出する手法を提案する．線形結合の係数は Dice 係数をエネルギー値とする焼きなまし法を使って最適化する．実際の頸部 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，頸部椎体・棘突起，U-Net，マルチチャンネル化，線形結合

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であるが，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 線動画の各フレームにマルチチャンネル化，画像の線形結合，U-Net を適用し，頸椎を構成する頸椎椎体と棘突起を抽出する手法を提案する．

2. 抽出手法

フレーム画像X_0に線形もしくは非線形の画像フィルタF_m（$m = 1,2,\ldots,\mathrm{M}$）を適用して得られる特徴画像を$X_m$とし，これらの特徴画像を重み係数$w_m$（$m = 1,2,\ldots,\mathrm{M}$）で線形結合した画像を$X_{MC} = \sum_{m=1}^{M} w_m \cdot X_m$とする．結合画像を U-Net に入力し，頸椎椎体と棘突起を抽出する．従来のマルチチャンネル化[2]では M 個の特徴画像から抽出精度を最大化する特徴画像の組み合わせを探索するために焼きなまし法を使っていたが，本手法では重み係数w_mを実数の範囲（負値も含む）で変化させ，抽出精度を最大化する係数の値を探索するために焼きなまし法を使用する．

3. 実験

正常症例３９症例を４つのグループに分け，4-fold 3-phase cross validate[3]で実験した．５つの頸部椎体と５つの棘突起を抽出対象とした．画像フィルタとして，通過フィルタ（入力された濃淡画像をそのまま出力），フィルタサイズの異なる３種類の画像正規化フィルタ，４種類のトップハット変換，３種類のソーベルフィルタを使用した．領域抽出の精度は Dice 係数を用いた．

実験結果を図１から４に示す．図１は原画像，図２は正解ラベル，図３は U-Net のみによる抽出結果，図４は本手法を用いた抽出結果である．図１～図４において，それぞれの色領域は第２～６椎体と棘突起を表す．U-Net による領域抽出の平均 Dice 係数は０．６９７，提案手法による領域抽出の平均 Dice 係数は０．８２７であった．

4. おわりに

頸部 X 線動画のフレームに線形もしくは非線形フィルタを適用し，得られた特徴画像を線形結合して生成された画像を U-Net に入力し，頸椎椎体および棘突起を抽出する手法を提案した．U-Net のみを用いた抽出手法よりも提案手法の方が抽出精度が高いことを示した．焼きなまし法による繰り返し演算に計算時間がかかるので，その短縮が今後の課題である．



図１　原画像



図２　正解ラベル

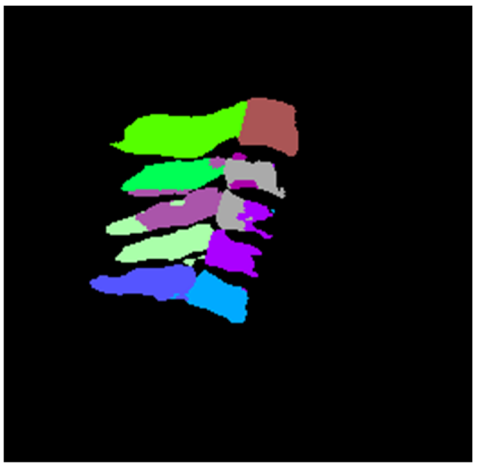


図３　U-Net の結果



図４　提案手法の結果

参考文献

[1] 厚生労働省 令和 2 年(2020)人口動態統計（確定数）の概況.

[2] 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.

[3] Hotaka Takizawa, Ayano Fujinaka, Erika Gunji, Kojiro Mekata, Hiroyuki Kudo, Preprocessing Optimization and Semantic Segmentation for Extraction of Cervical Intervertebral Disks from Videofluorography, Proceedings of 2022 26th International Conference on Pattern Recognition (ICPR), pp.4948-4952, 2022

Optical coherence tomography angiography における血管中心線深度の推定手法の検討

岡本　尚之[*1]，岡村　宙輝[*2]，羽石　秀昭[*1]
[*1] 千葉大学フロンティア医工学センター
[*2] 千葉大学大学院融合理工学府

Depth Estimation of Vascular Centerlines in Optical Coherence Tomography Angiography

Takayuki OKAMOTO[*1]，Hiroki OKAMURA[*2]，Hideaki HANEISHI[*1]
[*1] *Center for Frontier Medical Engineering, Chiba University*
[*2] *Graduate School of Science and Engineering, Chiba University*

要旨：光干渉断層計（OCT）を応用した OCT アンギオグラフィー（OCTA）は，血管構造を 3 次元に描出可能な画像化技術である．OCTA の主な課題として，抽出した血管構造下に伸びるテーリングアーチファクトが発生し，3 次元血管構造の詳細観察を阻害することが挙げられる．本研究は，OCTA の 2 次元投影像で観察できる血管中心線の深さ情報を推定し，これらの推定結果を統合することで血管中心線の 3 次元構造を構築することを目的とする．提案手法では，OCTA に対して血管形状を模擬したテンプレートを設計し，テンプレートマッチングにより血管中心を強調する．さらに，血管走行に沿った断面に対して，設計したコスト関数の最小化により血管中心線の深さ情報を推定する．実測データによる評価の結果，妥当な深さ情報を推定でき，血管構造の特性を容易に把握可能な 3 次元血管中心線マップを取得できることがわかった．
キーワード：光干渉断層計（OCT），OCT アンギオグラフィー，血管中心線，3 次元血管構造

1. はじめに

光干渉断層計（Optical Coherence Tomography: OCT）を応用した OCT アンギオグラフィー（OCT Angiography: OCTA）は，被写体内部の血流情報を非破壊に可視化できるイメージング技術である．OCTA による血流イメージングは，赤血球の動きによって生じる信号値の変動の検出に基づいており，造影剤不要で血流分布の 3 次元情報を取得することが可能である．OCTA は，眼科学，神経科学などの研究分野において，微細な血管情報の観察や解析に応用されており，重要な診断ツールとして位置づけられている．

OCTA の長年の課題として，描出した血管構造下に尾を引くテーリングアーチファクトが挙げられる．これは OCT の撮像原理に由来する課題であり，血管の上下方向の重なりなど，3 次元情報でのみ得られる，血管構造の詳細な観察を阻害している．

3 次元の血管構造を抽出するために，Pissas ら［1］は，網膜 OCTA 像の連続する 2 次元断面に対して深層学習によるセグメンテーションを行い，それらを集約することで 3 次元セグメンテーションを実施した．また，Stefan ら［2］は，Intralipid を投与した OCTA を参照しながら血管構造のアノテーションを実施し，3 次元血管セグメンテーションのための深層学習モデルを開発した．しかし，教師あり学習に基づくセグメンテーション手法は，大量のデータと膨大なアノテーション作業が必要となる．

本研究は，大量のデータを必要とせず，かつ 3 次元画像に対するアノテーション作業を必要としない，解析的なアルゴリズムに基づく血管構造の 3 次元構築を目指す．我々は，血管中心線の深度情報を取得するために，動的輪郭モデルを応用した血管の深さ推定手法を提案する．これにより，血管中心線の 3 次元分布を可視化した血管中心線マップを取得できる．本稿では，マウスの背部真皮の OCTA 像に対して，提案手法を適用した結果について報告する．

2. 手法

提案手法は，以下の 3 ステップで構成されている．

A) 2 次元 *en-face* 画像（深さ方向への投影像）を用いて血管中心線を手動でアノテーションし，血管の分岐点をもとにセグメントに分割する．
B) 3 次元 OCTA 像に対して，テンプレートマッチングを適用し，血管中心を強調した血管中心強調像（Vascular center-weighted: VCW）を取得する．
C) 各セグメントの断面（プロファイル）を 3 次元 OCTA 像と 3 次元 VCW 像から取得し，血管中心線を推定する．この処理を全セグメントで実施し，結果を統合することで 3 次元血管中心線マップを取得する．

処理 B のテンプレートマッチングでは，血管上部とテーリングアーチファクトを模擬した 3 次元テンプレート画像を作成し，類似度評価によって血管中心を強調している．処理 C の血管中心線推定では，取得した 2 種のプロファイル上に点群 $\boldsymbol{x}$ を設定し，スプライン補間を適用した曲線 $S(\boldsymbol{x})$ が以下のコスト関数を最小化するように点群 $\boldsymbol{x}$ を調整する．

$$E\big(S(\boldsymbol{x})\big) = E_{curv} - \alpha E_{octa} - \beta E_{vcw} \quad (1)$$

ここで，E_{curv}は$S(\boldsymbol{x})$の曲率であり，推定結果が滑らかな曲線であることを望ましいとする．E_{octa}とE_{vcw}はそれぞれ，OCTA 像と VCW 像のプロファイルから算出した$S(\boldsymbol{x})$上の画素値の合計であり，これらの項は最大化を目指す．これは，2 種のプロファイルは，画素値が高いほど，血管らしさを意味しているためである．αとβは，各項の重み付けをするためのハイパーパラメータである．式(1)で定義したコスト関数が最小化するように，点群$\boldsymbol{x}$を深さ方向で上下にシフトし，最終的に血管中心線として決定する．

3. 実験

市販の Spectral-domain OCT システム（WP-OCT 800 nm, Wasatch Photonics Inc., NC, USA）を用いて，マウス（C3H, 10 週齢，オス）の背部真皮を撮影した．取得した OCT 像に対して，Speckle Variance 法［3］を適用し OCTA 像を作成した．

4. 結果

図 1 に血管が交差する箇所における推定結果を示す．図 1(a)は *en-face* 画像の拡大図，(b)は推定結果である．提案手法は，複数の血管が密集している領域においても良好な深度推定を実現できていることがわかる．図 2 は，すべての推定結果を統合した 3 次元血管中心線マップであり，3 次元 OCTA 像全体の血管走行が把握できる．

上記のことから，提案する血管中心線深度推定手法は，3 次元での血管アノテーションを利用することなく，*en-face* 画像に対する中心線のアノテーションとセグメント単位での深さ推定により，3 次元血管中心線マップを再構築できることがわかる．血管中心線マップは，血管長など，血管のパラメータを容易に取得できる再構成像であり，実用性に富む表現形態であるといえる．

5. まとめ

3 次元 OCTA 像に対する血管中心線深度の推定手法を提案した．マウスの背部真皮を撮影した OCTA 像を用いた有効性検証の結果，血管走行全体を把握可能な血管中心線マップの生成に成功した．

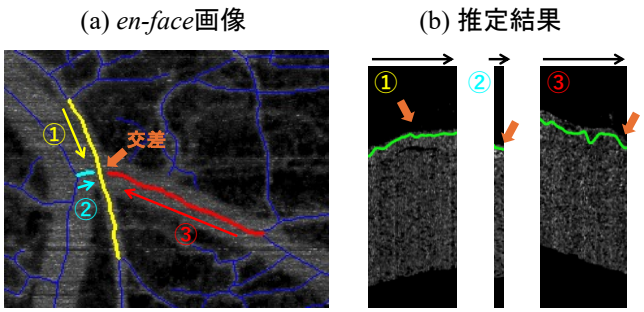


図 1　血管セグメントにおける血管中心線推定結果
(a) *en-face* 画像の拡大図，青線は血管中心線
(b) 推定結果（緑線）

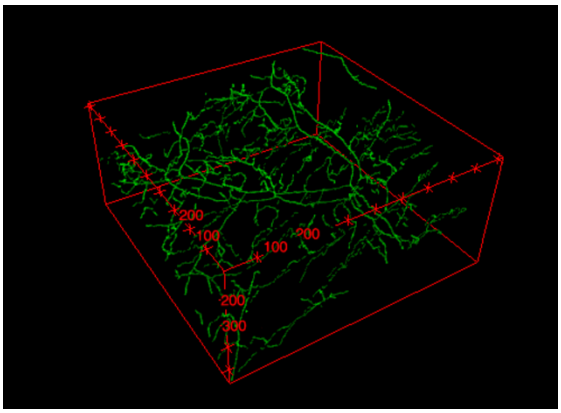


図 2　推定した 3 次元血管中心線マップ

謝辞

研究遂行にあたり貴重なご助言を賜った，千葉大学医学部附属病院 横内裕敬 特任教授，岩瀬雄仁 助教，新沢知広 助教，川俣 勇人 医員に深謝いたします．

利益相反の有無

なし

文　献

［1］ Pissas T, Bloch E, Cardoso MJ et al: Deep iterative vessel segmentation in OCT angiography. Biomed Opt Express 11(5): 2490-2510, 2020.

［2］ Stefan S and Lee J: Deep learning toolbox for automated enhancement, segmentation, and graphing of cortical optical coherence tomography microangiograms. Biomed Opt Express 11(12): 7325-7342, 2020.

［3］ Mariampillai A, Standish BA, Moriyama EH et al: Speckle variance detection of microvasculature using swept-source optical coherence tomography. Opt Lett 33(13): 1530-1532, 2008.

超広角眼底画像における無灌流領域の自動抽出

中野　勝太[*1]，畑中　裕司[*2]，慶野　博[*3]
[*1] 大分大学大学院工学研究科
[*2] 大分大学理工学部
[*3] 杏林大学医学部

Automatic Extraction of Non-perfusion Areas in Ultra-Wide Field Images

Shota NAKANO[*1]，Yuji HATANAKA[*2]，Hiroshi KEINO[*3]
[*1] *Graduate School of Engineering, Oita University*
[*2] *Faculty of Science and Technology, Oita University*
[*3] *School of Medicine, Kyorin University*

要旨：ぶどう膜炎は，眼球のぶどう膜に炎症が起こる疾患群で，視力の低下や失明の原因になる病気である．網膜で血液が流れていない無灌流領域はぶどう膜炎の所見の一つである．ぶどう膜炎の診断のために蛍光眼底造影検査が行われているが，無灌流領域の推定には労力を要するため，医師の負担が懸念されている．本研究では，医師の診断支援を目的とし，超広角眼底造影画像における無灌流領域の自動抽出のためにディープラーニングモデルである U-Net を用いた自動セグメンテーションモデルの開発を行った．無灌流領域と灌流領域に注目し，画像全体より灌流領域を削除することで，無灌流領域を抽出することが可能であると考え，U-Net を用いて灌流領域の自動抽出を試みた．本研究で提案する手法は無灌流領域を特定することが可能であると示唆された．
キーワード：ぶどう膜炎，超広角眼底造影画像，無灌流領域，U-Net

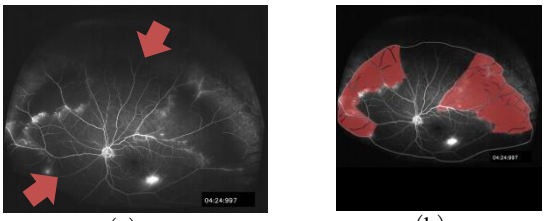
1. はじめに

ぶどう膜炎は，眼球のぶどう膜（虹彩，毛様体，脈絡膜）に炎症が起こる疾患群で, 視力低下や失明の原因になる疾病である. 早期発見と治療により失明を防ぐことができる疾病でもあり, 画像診断により様々な所見が観察されることが報告されている[1][2]．網膜で血液が流れていない無灌流領域はぶどう膜炎の所見の一つであり，蛍光眼底造影（FA）検査での検査が可能である．本研究では，中心部から周辺部にかけてのぶどう膜炎所見を検出するために超広角眼底造影（UWF FA）画像を用いた．従来の眼底カメラの画角は 30°～55°である．従来の眼底カメラを用いた広範囲の撮影には患者の固定と撮影時間がかかってしまう．超広角走査型レーザー検眼鏡（Optos®,Nikon）で撮影される UWF では一度の撮影で 200°以上の視野（網膜領域の 82%）が得られる． FA 所見の評価は主観的であることや医師間での評価のばらつきが存在するため, ぶどう膜炎の臨床を標準化するためには, 客観的かつ定量的な測定法を開発する必要がある[3].

近年, 眼底画像を対象とした定量的解析に関する研究は多々あるが, ぶどう膜炎の無灌流領域の評価に関して明確に検討した報告はない．本研究ではぶどう膜炎の FA スコアの無灌流領域の評価項目に着目した[4]．診療スコアの点数が 2 番目に大きく, 治療の選択を決める重要な所見であることを専門医に有用性を確認した．無灌流領域を病変領域とし，UWF FA 画像から自動抽出および定量評価を行うことで医師の診断支援を研究目的とする．本研究では，無灌流領域と灌流領域（血液が流れている部分）に注目し，UWF FA 画像から U-Net[5]を用いて無灌流領域を特定するシステムの開発を目指した．

2. 方法

本研究では, 大分大学および杏林大学の研究倫理審査委員会の承認の下で，杏林大学医学部付属病院で撮影された 40 枚の UWF FA 画像を対象とした．さらに図 1(b)に示す専門医が無灌流領域をマークした画像を用いた. 医用画像における領域抽出では，U-Net と呼ばれるネットワークの有用性が報告され，眼底画像の血管抽出にも利用されている. そこで本研究の対象としている UWF FA 画像に対しても U-Net を用いることで高い精度の抽出結果を期待できると考えた．40 枚の UWF FA 画像を対象とし，無灌流領域と灌流領域に注目した．図 1 (a)に示すように無灌流領域と周辺部の境界が不明瞭であるため, 無灌流領域のセグメンテーションが困難であった．そのため，図 1(b)の専門医が示した境界内でセグメンテーションを行い, 灌流領域を抽出し, 元画像より削除することで無灌流領域を特定することが可能であると考えた. 灌流領域の抽出の際には教師データ 39 枚，テストデータ 1 枚に分け，一つ抜き交差検証（leave-one-out cross-validation / LOOCV）を行なった．U-Net により抽出した灌流領域と医師の手動抽出した領域を比較し, 抽出率を求めるために画像の重なり度合いを示す IoU（Intersection over Union）を算出した．



(a) (b)

図 1. 使用データ．(a) 元画像（超広角眼底造影画像），
(b) 専門医が無灌流領域をマークした画像

3. 実験結果

本研究の手法を 40 枚の UWF FA 画像に適応させ，算出した IoU は平均値が 0.731，最大値が 0.878，最小値が 0.403 となった．最大値と最小値に注目すると大きな差が見られる．図 2 の (a)に IoU が最小値 0.403 となった結果例，同図(b)に IoU が最大値 0.878 となった結果例を示す．

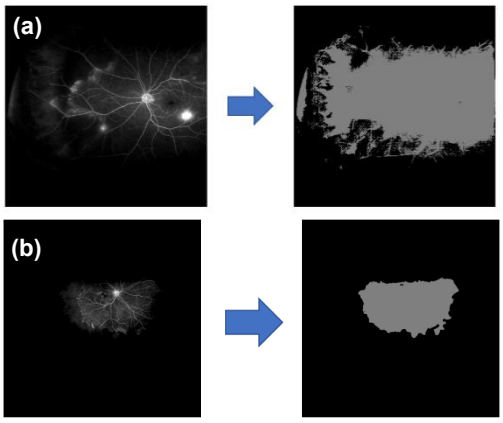


図 2. 超広角眼底造影画像での灌流領域抽出結果．
(a) 元画像(左), IoU 最小値(0.403)の抽出結果(右),
(b) 元画像(左), IoU 最大値(0.878)の抽出結果(右)

4. 考察

本研究では自ら灌流領域の教師画像を作成したため，境界が不明瞭な部分の抽出が困難であった．提案手法では灌流領域を抽出した画像と元画像を比較し，画像の IoU を算出した．IoU の最大値と最小値で大きな差が生じた．原因として灌流領域の境界が不明瞭な部分が抽出されていないことや今回は 1 名の専門医のマーク画像を元に教師データを作成したことが考えられる．教師データの精度を上げるためには複数の専門医がマークした教師データが必要であると考える．また，専門医が無灌流領域をマークした画像の学習用データに対するデータ拡張や学習モデルの改善が必要であると考える．本研究では灌流領域の抽出を行い，元画像と比較することで無灌流領域の特定を試みた．今回の手法では無灌流領域を特定することが可

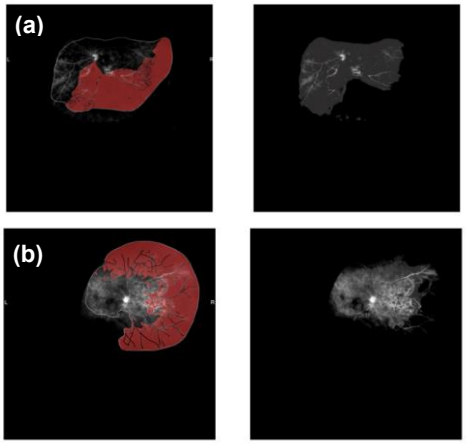


図 3. 医師の診断画像（左）と抽出結果（右）
の比較．(a) データ 1, (b) データ 2

能であると示唆されたが，実用的に用いるためのより正確な抽出方法を検討する必要があると考えられる．

5. まとめ

本研究では，ぶどう膜炎の診断を支援するために，無灌流領域抽出システムの開発に取り組んだ．無灌流領域の特定は可能であることが示唆されたが，詳細な領域や抽出精度が不十分であると考えられた．今後はデータ数の増加や新たな画像を用いた抽出方法を検討する必要があると考えている．

謝辞

本研究の一部は JSPS 科研費 19K12827 の助成を受けたものである．

利益相反の有無

なし．

文　献

[1] Ciardella A P, Prall FR, Borogoker N, Cunningham ET Jr., Imaging techniques for posterior uveitis. Curr. Opin. Ophthalmol.2004, 15,pp. 519-530

[2] Finamor LP, Muccioli C, Belfort R Jr. Imaging techniques in the diagnosis and management of uveitis. Int. Ophthalmol. Clin. 2005, 45, pp.31–40

[3] Tugal-Tutkun I, Herbort CP, Khairallah M. Scoring of dual fluorescein and ICG inflammatory angiographic signs for the grading of posterior segment inflammation (dual fluorescein and ICG angiographic scoring system for uveitis). Int. Ophthalmol.2010, 30, pp.539–552

[4] 日本眼炎症学会（2019）「ぶどう膜炎診療ガイドライン」日本眼炎症学会ぶどう膜炎診療ガイドライン作成委員会, https://www.nichigan.or.jp/Portals/0/resources/member/guideline/uveitis_guideline.pdf（最終アクセス 2024.5.21）

[5] Olaf R, Philipp F, Thomas B, U-Net: Convolutional Networks for Biomedical Image Segmentation,Medical Image Computing and Computer-Assisted Intervention (MICCAI),Springer, LNCS, Vol.9351, 2015,pp.234–240

デノイジング拡散確率モデルを用いた CT 画像再構成

尾崎　翔[*1,*3]，鍛治　静雄[*2]，名和　要武[*3]，今江　禄一[*3]，中川　恵一[*3]
[*1] 弘前大学大学院理工学研究科
[*2] 九州大学　マス・フォア・インダストリ研究所
[*3] 東京大学医学部附属病院　放射線科

Iterative CT reconstruction using denoising diffusion probabilistic model

Sho OZAKI[*1, *3]，Shizuo Kaji[*2]，Kanabu Nawa[*3]，Toshikazu Imae[*3]，Keiichi Nakagawa[*3]
[*1] *Graduate School of Science and Technology, Hirosaki University*
[*2] *Institute of Mathematics for Industry, Kyushu University*
[*3] *Department of Radiology, University of Tokyo Hospital*

要旨：本研究では、デノイジング拡散確率モデルと逐次近似画像再構成法を組み合わせたまったく新しい画像再構成法を提案し、スパースヴューCT 画像再構成によって提案手法の有用性を確認した。デノイジング拡散確率モデルが生成する多様性の起源を特定し、それらを抑制することで解剖学的な構造変化を抑えつつ、CT 画像の高画質化を実現した。指標を用いた定量的な評価を行い、既存手法を大きく上回る結果を得た。この手法は CT のみならず、MRI や PET、SPECT など様々な医用画像モダリティに応用可能である。

キーワード：画像生成 AI，デノイジング拡散確率モデル，CT 画像再構成

1. はじめに

近年、画像生成 AI 研究は急速に発展しており、Stable Diffusion や DALL-E3 といった画像生成 AI が高画質でかつ多様性に富んだ画像の生成を可能にしている。本研究では、Stable Diffusion や DALL-E3 の基盤モデルとして採用されているデノイジング拡散確率モデル(Denoising diffusion Probabilistic Model: DDPM) [1, 2]を用いて CT 画像の画質改善を行う。画像生成 AI が高画質な画像を生成することは画質改善にとって望ましい性質だが、一方で多様性を生み出す性質は、患者の解剖学的な構造変化を伴うため抑制したい。そこで本研究では、デノイジング拡散確率モデルと逐次近似画像再構成法を組み合わせた新しい CT 画像再構成法を提案する。CT 画像再構成に用いられる投影データは患者の解剖学的な構造の情報を含むため、CT 画像再構成法と拡散モデルを組み合わせることによって、患者の解剖学的な構造を保存した医用画像に特化した画像生成モデルが構築可能となる。我々の手法と既存の画像再構成法を、1) 視覚的な定性評価と、2) SSIM や PSNR などの指標を使った定量的な評価を用いて比較する。

2. 手法

DDPM が引き起こす構造変化を抑制するために、CT の画質改善に一般的に用いられてきた逐次近似画像再構成法と DDPM を組み合わせる。通常の DDPM の学習段階では、拡散過程と逆拡散過程の２つの過程がある。まず拡散過程では、元画像に徐々にノイズを加えていき$t = T$で完全なノイズ画像とする。次に深層ニューラルネットワーク（デノイジングモデル）を用いて、ノイズを徐々に除去し、元画像を復元する。この学習でデノイジングモデルが訓練される。次に、推論（画像生成）段階では、学習済みのデノイジングモデルを用いてランダムなノイズ画像から多様な（学習データにはないような）新しい高画質画像を生成する。DDPM がこのような多様性を生み出す起源は以下の２つである：

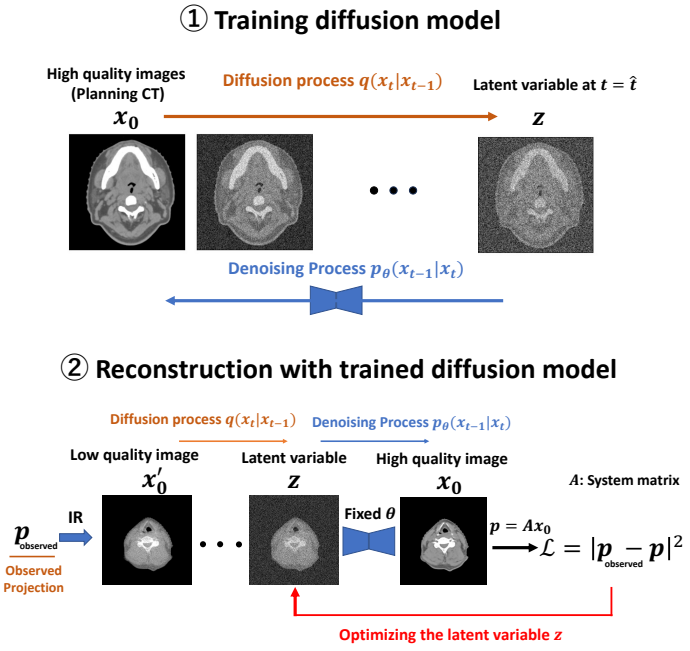


図 1　提案手法

筆頭発表者: 尾崎翔　sho.ozaki@hirosaki-u.ac.jp

1. $t = T$で与える完全なノイズ画像
2. 逆拡散過程で与えるノイズ

これらの多様性の起源を抑制するため、本研究ではまず学習段階で$t = T$まで進まず、途中段階$t = \hat{t}\ (< T)$で止める。これによって潜在変数が入力画像の構造の情報を部分的に保持できるようになる。次に画像生成過程（逆拡散過程）において、与えるノイズのシードを固定する。これにより、DDPM は決定論的となり、決まった入力に対して決まった出力を返すようになる。DDPM の出力からランダム性が排除されることで再構成の収束性が大きく改善する。

図 1 に提案手法の概要を示す。まず多量の高画質画像を用いて、$t = \hat{t}$までのタイムステップで DDPM の学習を行う。画像生成（再構成）段階では、まず通常の逐次近似法で再構成された画像を$t = \hat{t}$まで拡散し、その後学習済みのデノイジングニューラルネットワークを使って高画質化する。DDPM によって出力された画像と投影データとの損失関数を計算し、これを最小にするように潜在変数を最適化する。DDPM の潜在変数を最適化することによって CT の画像再構成を行う手法は他になく、まったく新しい画像再構成法といえる。また、これまでの拡散モデルと逐次近似法を組み合わせる先行研究[3, 4]では、構造保存と画質改善がトレードオフとなり、このトレードオフを調整するためのパラメータが導入されている。このようなトレードオフを調節するパラメータの存在は、画質か構造保存、あるいはその両方の妥協に繋がる。また、このパラメータ調整は CT モダリティごとに行う必要があり、手法の汎化性を著しく損なう。我々の提案手法では、このようなパラメータなしに構造保存と画質改善の両方を実現可能である。またこの手法は、学習過程で高画質画像のみを用いるため、単一の学習済みモデルで複数の CT モダリティの画質改善を行うことが可能であり、マルチモダルな画質改善を行うことができる。

3. 結果

本研究ではスパースビューCT 画像再構成により、提案手法の有効性を実証した。東大病院で取得された放射線治療における治療計画用ファンビーム CT の 3775 枚の高画質画像を学習に用いた。また学習に含まれていない 10 患者の投影データを使用し、1)逐次近似法(IR)、2)トータルバリエーション正則化を用いた IR (IR+TV)、3)DDPM のみ、4)DDPM と組み合わせた IR (DDPM+IR: 提案手法)を用いて、フルスキャン CT 画像再構成と 1/10 投影によるスパースビューCT 画像再構成を行った。画質を定量的に評価するため、IR によるフルスキャン CT 画像を正解画像(Ground Truth: GT)として、SSIM と PSNR の指標をそれぞれの手法で計算した。再構成画像の結果を、対応する指標値とともに図 2 に示す。手法 1)の IR では、スパースな CT

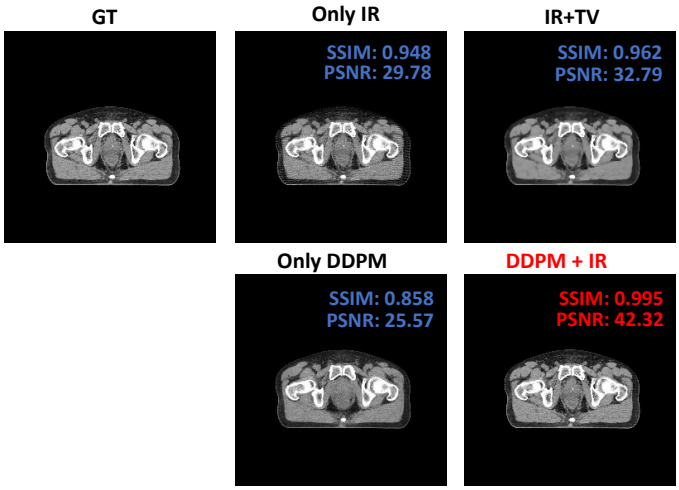


図 2　再構成結果

画像再構成によるストリークアーチファクトが残る。手法 2)の IR+TV では、アーチファクトは低減するものの、全体的にオーバースムージングとなり、組織内の細かい構造が消えてしまう。手法 3)（DDPM のみ）は一見画質を向上させているように見えるが、指標の値は低い。これは、3)の方法では画像内の解剖学的構造が変化してしまうためである。これらの既存手法に対し、我々の提案手法は、解剖学的な構造を保持しつつ画質を向上させることに成功し、定量的指標値では、手法 1)〜4)の中で最も優れた結果を得た。

3. まとめ

本研究では、デノイジング拡散確率モデルと逐次近似画像再構成法を組み合わせたまったく新しい画像再構成法を提案し、スパースヴューCT 画像再構成によって提案手法の有用性を示した。SSIM と PSNR による定量的な評価によって、提案手法が既存手法を大きく上回る結果を得た。この手法は CT のみならず、MRI や PET、SPECT など様々な医用画像モダリティに応用可能である。

利益相反の有無

なし

文　献

［1］Ho J, Jain A, and Abbeel P: Denoising Diffusion Probabilistic Models. NeurIPS 2020

［2］Sohl-Dickstein J, Weiss E, Maheswaranathan N et al : Deep Unsupervised Learning using Nonequilibrium Thermodynamics. PMRL 37: 2256-2265, 2015

［3］Song Y, Shen L, Xing L et al: Solving Inverse Problem in Medical Imaging with Score-Based Generative Models, ICLR 2022

［4］Xia W, Shi Y, Niu Chuang et al: Diffusion Prior Regularized Iterative Reconstruction for Low-dose CT, arXiv: 2310.06949, 2023

マイクロ CT による小動物イメージングのための動態アーチファクト低減手法の構築

福島　まひる[*1]，岡本　尚之[*2]，羽石　秀昭[*2]
[*1] 千葉大学大学院融合理工学府
[*2] 千葉大学フロンティア医工学センター

Motion artifact reduction method for small animal imaging in micro-CT

Mahiru FUKUSHIMA[*1]，Takayuki OKAMOTO[*2]，Hideaki HANEISHI[*2]
[*1] *Graduate School of Science and Engineering, Chiba University*
[*2] *Center for Frontier Medical Engineering, Chiba University*

〒263-8522 千葉市稲毛区弥生町 1-33，e-mail: m_fukushima@chiba-u.jp

要旨：マイクロ X 線 CT による小動物イメージングでは，呼吸や心拍に由来する体動によってモーションアーチファクトが生じる．われわれはこれまでにレトロスペクティブな呼吸同期再構成法を提案してきた．本論文では，この方法を心拍同期再構成に拡張する．具体的には透視画像の横隔膜付近に関心領域を設定し平均輝度値を算出することで呼吸や心拍のパターンを表す波形を生成する．その後，移動平均を閾値としてデータを限定した上で，極小値や極大値を抽出することによって特定位相の投影データを選定する．実データを用いて本手法の有効性検証を実施した結果，実機のマイクロ CT に搭載されている同期処理手法と比較してアーチファクトが低減された画像を取得した．

キーワード：マイクロ CT，in vivo イメージング，心拍同期処理，画像再構成

1. はじめに

マイクロ X 線 CT による小動物 in vivo イメージングは，生体内の形態学的構造を簡便に取得することができるため，疾患分析や薬効調査に有効である[1]．しかし，撮影中の呼吸や心拍による体動はアーチファクトを誘発する．そのため呼吸や心拍の位相を揃えた再構成法が検討されてきた．具体的にはデータ収集時にゲートをかけて必要な位相のデータのみを収集して再構成するプロスペクティブな方法[2]と，データ収集は連続的に行い，後処理として必要なデータのみ選択して再構成するレトロスペクティブな方法[3]の二種類がある．このうち我々は，追加の装置を必要としないレトロスペクティブ法に注目している．これまでの研究で，呼吸同期再構成に取り組み良好な結果を得てきた[4]．現在は，呼吸同期に加え，心拍同期の再構成に取り組んでいる．本稿ではその手法と実験結果について述べる．

2. 手法

本研究では，自然呼吸下のラットを高速に連続撮影したデータを用いる．このデータに図 1 に示す同期処理手法を適用する．その後，選定した投影データを用いて，Maximum Likelihood Expectation Maximization (ML-EM)法による再構成を実施する．

Step 1 輝度値波形の抽出

取得した各透視画像（X 線強度画像）上の横隔膜付近に手動で矩形の関心領域（ROI）を設定し，ROI 内の平均輝度値を算出する．全投影角度の透視画像から算出した平均輝度値は，心拍と呼吸の変動を含む輝度値波形を描く．例えば，肺が収縮したとき，ROI 内の空気に対して組織の割合が増えるため輝度値が下がり，肺が膨張したときはその逆となる．同様に，心臓が拡張したとき心臓領域が ROI 内を占める割合が増すため輝度値が下がり，心臓が収縮したときはその逆となる．連続収集したデータには呼吸と心拍による変動が含まれており，上記の特徴を，Step 2 でのデータ選定の際に利用する．また，輝度値波形には投影角度に由来するトレンドがあるため，周波数空間において 0.1Hz 以下の周波数帯を除去するハイパスフィルタをかける．

Step 2 投影データ選定

吸気より呼気の方が，継続時間が長く横隔膜の動きも少ないため，呼気中のデータの中から心拍同期のデータ選択を行う．まずトレンド除去後の波形から移動平均を算出する．この移動平均を閾値とし，これを下回る領域を呼気とみなす．具体的にはこの範囲に存在する極小値を心臓拡張期として扱う．一方，これらの極小点群の間に存在する極大値を心臓収縮期として投影データを選定する．

3. 実験

実機に搭載されている既存手法[5]を比較対象として，投影データ選定の性能を評価した．既存手法において解析的再構成手法 (FDK 法)を適用し再構成画像を取得した．提案手法は上記の方法で投影データを選定したのちに ML-EM 法を適用した．撮影は，ラット (Slc:Wistar, 雄, 10 週齢) を対象とし，呼吸周期が通常よりも短い約 0.4 秒のデータを取得した．輝度値波形における選定結果と再構成画像を目視で評価した．

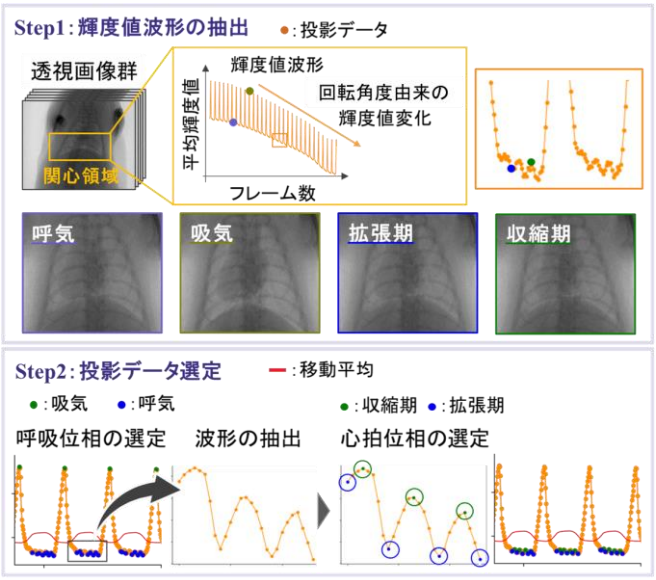


図 1 同期処理　概要図

3.1. 投影データ選定

まず, 輝度値波形の評価では, 選定された投影データが妥当であるか, 輝度値波形全体から判断した. 選定結果を図 2 に示す. 輝度値波形において，既存手法は 1 周期内で選定された投影データ数が少なく，不適切と思われる投影データもあるが，提案手法では安定して同位相の投影データ選定に成功した．この結果より, 呼吸周期の影響を受けない提案手法の有効性が示唆された.

3.2. 再構成結果

再構成画像の評価では, 解析的再構成手法(FDK 法), および ML-EM 法での再構成を実施し, 再構成像上のアーチファクトを評価した. 図 3 に提案手法・既存手法の再構成結果を示す．心臓拡張期・収縮期ともに既存手法と比較して提案手法では，ブレが少ない再構成像を取得した．この結果は提案手法が既存手法と比較してより安定して投影データ選定が行えたためであると考えられる．また，提案手法においてよりノイズが低減された画像を取得したことから ML-EM 法の有効性を確認した.

4. まとめと今後の展望

本研究では，全ての処理をソフトウェアベースで実施する同期処理手法を構築した. 既存手法との比較実験を実施した結果, 呼吸周期が短いデータにおいて，提案手法は安定して特定位相の投影データを選定した．また ML-EM 法の導入によりノイズが低減された画像の取得に成功した．今後はさらなる画質改善手法の探索と構築および疾患モデル等を用いて本手法の有効性の検証を実施する.

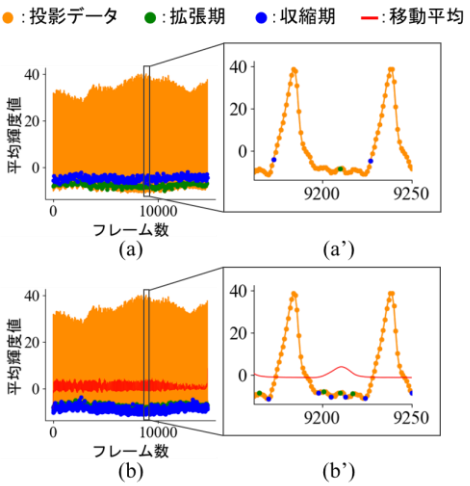


図 2 投影データ選定結果

a) 既存手法　b) 提案手法　a'), b') 拡大図

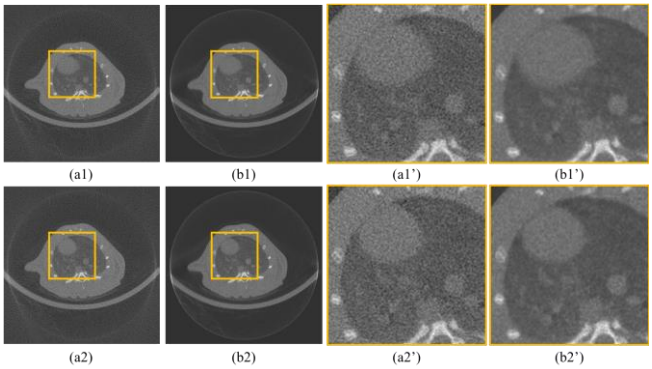


図 3 再構成結果

a) 既存手法　b) 提案手法　1) 心臓拡張期　2) 心臓収縮期

a1') – b2') 拡大図

謝辞

この研究の一部は JSPS 科研費 23K17187 の支援により行われた.

利益相反の有無

なし

文　献

[1] Chavarrías C et al: Extraction of the respiratory signal from small-animal CT projections for a retrospective gating method. Phys Med Biol 53(17): 4683–4695, 2008.

[2] Guo X et al: 4D micro-CT using fast prospective gating. Phys Med Biol 57(1): 257–271, 2012.

[3] Hu J et al: Dynamic small animal lung imaging via a postacquisition respiratory gating technique using micro-cone beam computed tomography. Acad Radiol 11(9): 961–970, 2004.

[4] Fukushima M et al: A robust respiratory gating method for rodent micro-CT imaging. International Journal of Computer Assisted Radiology and Surgery 18: 91–92, 2023.

[5] Koike T, Maesawa M, Hara Y: CT-IMAGE PROCESSING APPARATUS AND METHOD. US Patent 9,895,129,B2, 2018.

多重解像度展開像の相似性を利用した単一画像超解像

正田 優大[*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

Single Image Super-resolution Using Similarity of Multiple Resolution Images

Yuto SHODA[*1]，Kazuki YAMATO[*1] ，Satoshi ITO[*1]
[*1] *Graduate Program in Information, Electrical and Electronic Systems Engineering, Utsunomiya University*

要旨：多重解像度解析の一種である eFREBAS 変換によって得られる展開像の相似性を利用すると単一画像による超解像を考えることができる．これまでは eFREBAS 信号を補間拡大する際の補間処理に起因する信号の平滑化が課題であった．本研究では，eFREBAS 信号の補間時に鮮鋭化処理を導入し，提案法を他の超解像法と比較した．その結果，提案法は他の超解像法よりも良好な LPIPS と PSNR を両立する性能が得られた．また，画像比較による評価では，提案法は鮮鋭さを保ちつつ平滑効果やジャギーなどを抑制する効果が示された．ゆえに，提案法は非学習型の単一画像超解像法であるが，学習型の超解像法に比肩する性能が得られた．

キーワード：超解像，補間，多重解像度解析，eFREBAS 変換

1. はじめに

低解像度画像から高解像度画像を生成する超解像を MR 画像に応用できれば，実質的に撮像時間の短縮につながり患者の負担を軽減できる．超解像は使用画像数により大別すると，単一の観測画像から超解像画像を生成する単一画像超解像，複数の低解像度画像を合成して高解像度画像を生成する再構成型超解像，深層学習を利用する超解像に分けられる．

2010 年に Yang らは学習型超解像を提案した．Dong らは，3 層の畳み込みニューラルネットワーク (Super-Resolution Convolutional Neural Network：SRCNN)[1]を使用して自然画像の超解像を試み，Yang らの方法を超える信号対雑音比を持つ画像の生成に成功している．Dong らのネットワークの層を増やし，最終層のデコンボルーションにより画像拡大を行うとともに高速化を図る方法[2]や，画像の劣化プロセスを考慮した方法[3]などが提案されている．深層学習により超解像は様々な方法が提案され，その性能は年々改善されている．

学習型超解像やニューラルネットワークを使用した方法は，従来の補間法では得られない鮮鋭な画像が得られるが，一方で学習に大量の画像と膨大な時間を必要とする課題がある．そこで，本研究では磁気共鳴画像(MR 画像)を対象とし，学習を必要としない新たな単一画像超解像を提案する．先行研究では，多重解像度解析の特徴を利用して高周波成分を推定する超解像法を提案した[4]．本研究では，高周波成分の推定精度向上により超解像効果を高める方法を検討した．提案法を他の超解像法と比較することで，その有効性を確認した．

2. eFREBAS 変換[4]

eFREBAS 変換は 2 通りのフレネル変換の特性を使用し，画像を縮小スケーリングする方法により画像を周波数成分ごとに画像の形で展開する方法である．eFREBAS 展開空間では，

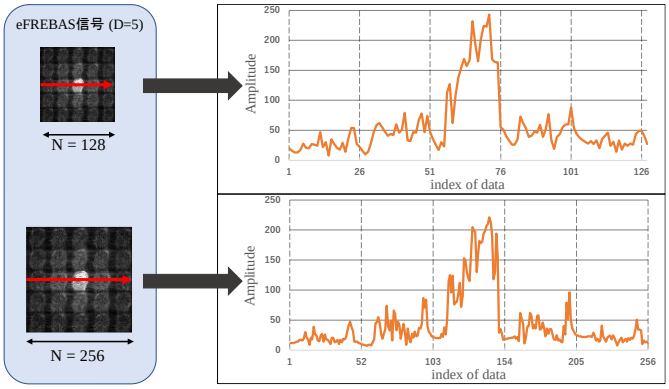


図 1 eFREBAS 信号分布の相似性

画像の輪郭を抽出した形になるが，画像サイズが異なっても展開像は相似した分布となる性質がある．図 1 に画像サイズが 128 と 256 の eFREBAS 信号の中心行 1 次元プロファイルを示す．この分布から信号の分布に相似性があることが確認できる．この性質を利用し，データサイズの小さい画像を eFREBAS 空間上で相似的に拡大することで画像の高周波成分を推定する超解像法を考えることができる(eFRE-SR とする)．しかしながら，これまでの eFREBAS 信号の補間拡大は sinc 関数補間を使用していたため，eFREBAS 信号に平滑化が生じる課題があった．

3. 画像補間拡大アルゴリズム

入力画像をI，eFREBAS 変換の展開数をD，eFREBAS 変換，逆変換をそれぞれΨ_D，Ψ_D^{-1}，拡大倍率をγとした拡大処理をL_γ，入力画像サイズNに対して補間拡大後の画像サイズをN'とする．入力画像Iに対する 2 種類の eFREBAS 変換の展開数をそれぞれD_1，D_2とし，図 2 に展開数$D_1 = 3$，$D_2 = 5$とした場合の画像拡大アルゴリズムを示す．まず，図中(a)のIに対して

展開数$D_1 = 3$で eFREBAS 変換をし，(b)の eFREBAS 信号$\Psi_{D_1} I$を得る．次に，Iに対して展開数$D_2 = 5$で eFREBAS 変換をし，(c)の eFREBAS 信号$\Psi_{D_2} I$を得る．画像(c)の eFREBAS 信号に対して拡大率$\gamma = D_2/D_1$で拡大処理を行う．このとき，補間処理による信号の平滑化が生じるため，eFREBAS 信号の微分処理に相当する周波数成分の強調処理Eを行い鮮鋭化を図った．この補間拡大された eFREBAS 信号(d)の高周波成分を(b)の信号の高周波成分とする推定を行う．推定して得られた eFREBAS 信号(e)を逆 eFREBAS 変換し補間拡大像が得られる．補間外挿した eFREBAS 信号は誤差を含むため，誤差最小化アルゴリズムを用いる．本研究では，式(1)で示す目標画像と補間拡大像I_Lの差である誤差成分を最小化したI_{SR}を求める制約付き最小化問題を適用する．

$$I_{SR} = \mathrm{argmin}\left\{\frac{1}{2}\left\|v - \mathrm{Rect}(k_W)\mathrm{FT}[I_L]\right\|_2^2 + \alpha\sum_{i=1}^{3}\left\|\Psi_{D_i} I_L\right\|_1 + \mathrm{TV}(I_L)\right\} \quad \cdots(1)$$

ここで，vは入力画像のフーリエ信号，$\mathrm{Rect}(k_W)$は信号のうち原点を中心として入力画像と同じデータ数を抽出する処理，FT は Fourier 変換を，TV は Total Variation を表す．また，αはノルムに対する重みである．スパース性を与えるΨの基底は，スケーリング係数が異なる eFREBAS 変換を利用した．また，式(1)は異なるノルムを含んだ最小化問題であり，本研究では CSA(Composite Split Algorithm)を用いた（eFRE-SRE とする）．

4. 実　験

IXI Dataset[2]の画像サイズが 256×256 の MR 画像を，画像サイズが 128×128 になるようにフーリエ空間信号を帯域制限することで低解像度画像を作成する．この低解像度画像 50 枚に対して，超解像アルゴリズムを適用する．eFREBAS 変換の展開数を$D_1 = 3, D_2 = 6$とした．定量的評価として PSNR と SSIM に加え，本研究では新たに LPIPS[3]を導入した．本研究では AlexNet を用いた LPIPS を使用している．提案法と比較として，sinc 関数補間，深層学習手法である SRMD[3]および敵対的学習を使用した超解像法である SRGAN[5]を使用した．1 枚の画像を出力する平均計算時間を表 1 に示す．

50 枚の PSNR，SSIM と LPIPS の平均値を表 1 に，補間拡大像を図 3 に示す．ここで，LPIPS は数値が低いほど目標画像に近い画像であると評価される．表 1 より PSNR，SSIM では SRMD が，LPIPS では eFRE-SRE が最も良好な値を示した．図 3 の SRMD と eFRE-SRE を比較すると，SRMD は PSNR，SSIM は高い値となるが平滑化効果が大きいが eFRE-SRE は目標画像に近い構造を保持している．また，赤矢印部分を比較すると SRGAN は斜め方向のジャギーが顕著であるが，eFRE-SRE では目標画像に近い鮮鋭な構造を保持している．

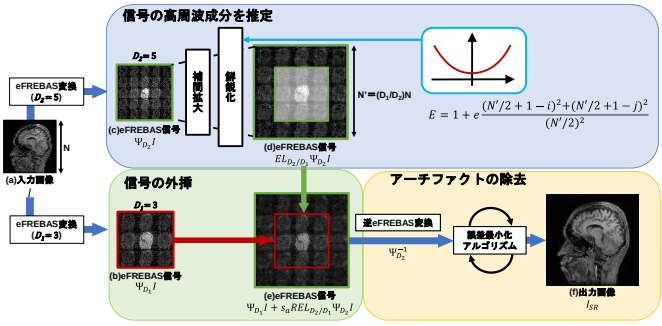


図２　eFREBAS-SRE の超解像アルゴリズム

表１　PSNR,SSIM,LPIPS による評価と計算時間

	PSNR [dB]	SSIM	LPIPS	計算時間(s)
eFRE-SRE	28.74	0.952	**0.0534**	1.07
sinc	28.93	0.951	0.1036	—
SRMD	**31.56**	**0.963**	0.0543	10.82
SRGAN	27.97	0.951	0.0654	0.75

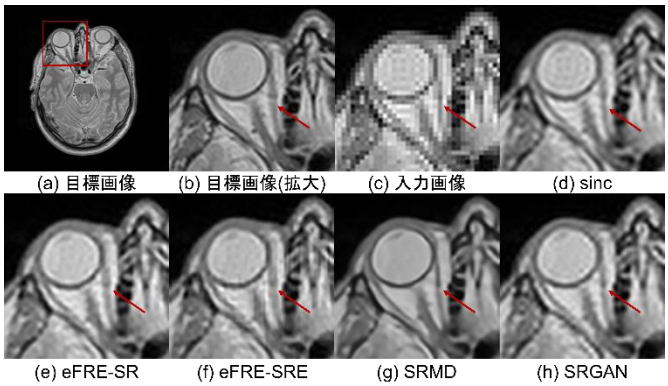


図 3 補間拡大画像の比較

5. まとめ

eFREBAS 展開信号の相似性を利用した超解像法に改良を行い，sinc 関数補間，SRMD，SRGAN との比較を行った．実験結果から，eFREBAS 変換を利用した提案法は，非学習型の単一画像超解像法であるが，学習型の超解像法に比肩する性能が得られた．提案法は，良好な LPIPS を取りつつ比較的高い PSNR が得られる特徴がある．今後の課題として，さらなる高分解能化のためのパラメータ探索が挙げられる．

謝 辞

MR 画像の使用に際し，InformationeXtractionfromImages に感謝の意を表します．

利益相反の有無

なし

文　献

[1] C.Dong et al, IEEE Trans on PAMI, 38, pp.295-307, 2015
[2] C.Dong et al,ECCV,pp.391-407, 2016
[3] K.Zhang et al.，IEEE/CVF Conf.CVPR，pp.3262-3271，2018
[4] 伊藤ら，信学論 J93-D，pp. 999-1008，2010
[5] https://brain-development.org/ixi-dataset/
[6] R.Zhang et al., IEEE/CVF Conf.CVPR, pp.586-595,2018
[7] C.Ledig et al., IEEE Conf.CVPR , pp.105-114, 2017

条件付き敵対生成ネットワークを用いた頭部 MRI 画像における モーションアーチファクト成分の低減

有田　晃大[*1]，臼井　桂介[*1]

[*1] 順天堂大学大学院保健医療学研究科診療放射線学専攻

Reduction of Motion Artifact Components in Head MRI Images Using Conditional Generative Adversarial Networks

Akihiro ARITA[*1], Keisuke USUI[*1]

[*1] *Department of Radiological Technology, Graduate school of Health Science, Juntendo University*

要旨:MRI 撮像中の患者の動きはモーションアーチファクトを引き起こすことから,画像診断能力の低下を招く要因となっている．深層学習による補正法では復元画像の空間分解能の劣化や人体画像の膨大な教師データの確保が課題である．本研究は，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 条件付き敵対生成ネットワーク（Conditional Generative Adversarial Networks: CGAN）による画質改善の精度を比較評価した．15 例の頭部ボランティア画像からモーションアーチファクト有の FLAIR 像を 3000 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．評価は，正規化されたアーチファクトの残差成分を示す Normalized Mean Absolute Error（NMAE）を求めた．その結果，CGAN の補正画像は再現性が高く，模擬アーチファクトの補正画像の NMAE は 32.9%減少，ボランティア画像の結果では 21.9%減少した．従って，CGAN の学習モデルによるモーションアーチファクトの低減効果が実証された．

キーワード：モーションアーチファクト，CGAN，頭部 MRI，深層学習，画質改善

1. はじめに

磁気共鳴画像診断像（Magnetic resonance imaging: MRI）撮像中の患者の頭部の動きは，再構成画像に画像のぼやけ，ゴーストを引き起こし，診断精度を低下させる可能性がある．モーションアーチファクトは位相エンコード方向に沿ってエイリアシングを誘発するため，k 空間におけるデータ収集を戦略化し，画質調整のための様々な動き補正アプローチが実装されている[1]．しかし，k 空間データの取得順序やその修正はエコーシーケンスの手法に限定されており，動きの同期化は動き計測の質に依存していた[2]．近年のディープラーニングに基づくアーチファクト低減処理では，MRI モーションアーチファクトを低減するための潜在的なソリューションとして，いくつかのアプローチが提案されている[3]．条件付き敵対生成ネットワーク（Conditional Generative Adversarial Networks: CGAN）モデルは，敵対損失の高い一貫性を達成できることから，モーションアーチファクト補正に効果的であると考えられる[4]．

本研究では，シミュレーションにより模擬モーションアーチファクト画像を生成し,入力データとしてアーチファクト無し画像をグランドトゥルースとして，このアーチファクト画像に CGAN モデルを学習させた．そして,頭部 MR 画像における CGAN モデルを用いたモーションアーチファクト低減の効果を,健常人のボランティア画像における自発運動に対して検討した．

*1　順天堂大学大学院保健医療学研究科診療放射線学専攻
〔〒113-8421 東京都文京区本郷 2-1-1〕
e-mail:　fhs8423002@juntendo.ac.jp

2. 方法

1）データ収集とモーションアーチファクト画像の作成

CGAN モデルの学習と模擬モーションアーチファクト画像の生成には，頭部の MRI 画像を使用した.原画像は，fluid-attenuated inversion recovery（FLAIR），FOV＝270×230mm^2，スライス厚＝5.0mm，マトリックスサイズ＝602×512，撮像面はアキシャル, 高速スピンエコーシーケンスでデータ収集を行った．塚本らの手法により，これらの頭部 MRI 画像からモーションアーチファクト画像（3000 枚）を作成した［5］．本手法では，動きの無い FLAIR 画像を垂直，水平および斜め方向に±10 ピクセル移動させ，また画像中心を±10°×0.5°回転させて 80 種類の移動画像を用意した．これをフーリエ変換し k 空間の位相エンコード方向に対し，それぞれの移動画像のデータをランダムに再配置して模擬アーチファクト画像を生成した．

2）深層学習モデルの構成

図 1 に CGAN の構造を示す．生成器と識別器に制約条件を与え，識別器は正しいラベルである確率を学習した．

CGAN モデルの学習と評価には，学習モデルに対し原画像と模擬アーチファクト画像からなる 3,000 枚のペア画像を用いた．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．さらに，15 名（男性:女性=12:3，22.7 歳±0.7 歳）のボランティアに対して，頭部を静止させた画像および自由に頭部を動かすことを指示された自発アーチファクト画像のそれぞれ 216 枚を学習データと同じデータ取

得条件で取得した．本研究は自施設の倫理審査委員会（順天堂大学保健医療学部実施許可番号：00031）の承認を受け，参加者全員から文書によるインフォームドコンセントを得た．

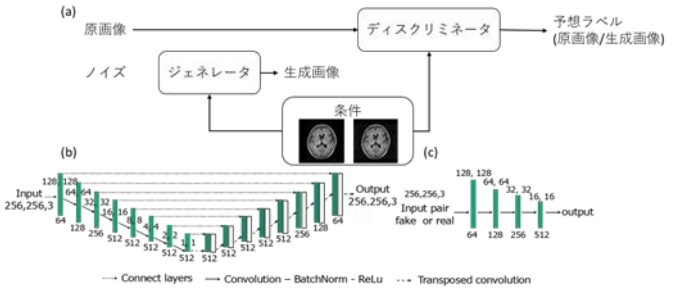


図 1　(a) CGAN のフレームワーク．(b), (c)はそれぞれ生成器と識別器のネットワーク構造を示している．

3）画質評価指標

学習データに含まれない FLAIR 画像からモーションアーチファクト画像(300 枚)を作成し，模擬アーチファクト画像およびボランティアによる自発アーチファクト画像を学習済み CGAN モデルに適用させ, モーションアーチファクトを補正した．補正画像からアーチファクト無し画像を差分し，モーションアーチファクト成分をアーチファクト画像で正規化した平均絶対値誤差 (Normalized Mean Absolute Error: NMAE)を算出した．

3. 結果と考察

図 1，2 にシミュレーションによる模擬モーションアーチファクトおよびボランティアによる自発モーションアーチファクトの補正画像の結果を示す. 学習モデルで各画像を補正処理することにより解像度を維持しながらモーションアーチファクトを低減することができた．表 1 に NMAE の結果を示す．シミュレーションによって作成した模擬モーションアーチファクト画像に対しては NMAE が 32.9%，ボランティアによる自発モーションアーチファクト画像に対しては 21.9%減少した．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近い画像を復元できたといえる．これによって，模擬モーションアーチファクト画像を学習データとして作成されたアーチファクト低減モデルが実際に発生したモーションアーチファクトを遡及的に低減可能であることを実証することができた．

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，モーションアーチファクト成分の低減効果を評価した．本研究の CGAN モデルはボランティアによる実際のモーションアーチファクト画像に対しても高い補正効果が実証された．頭部 MRI 画像におけるモーションアーチファクトの低減は, 画像診断の精度向上, 頭蓋内構造のセグメンテーション, 放射線治療における腫瘍輪郭の描出に実用的であると考えられる．

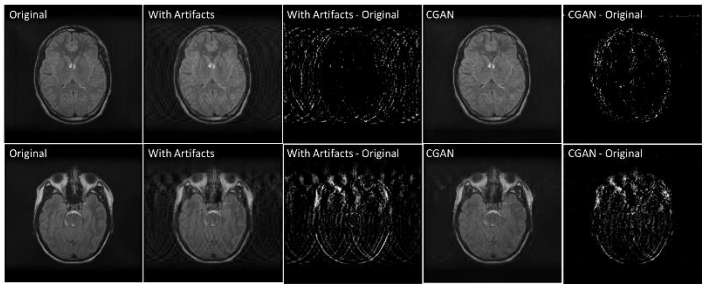


図 1　シミュレーションによる模擬モーションアーチファクト補正画像の結果

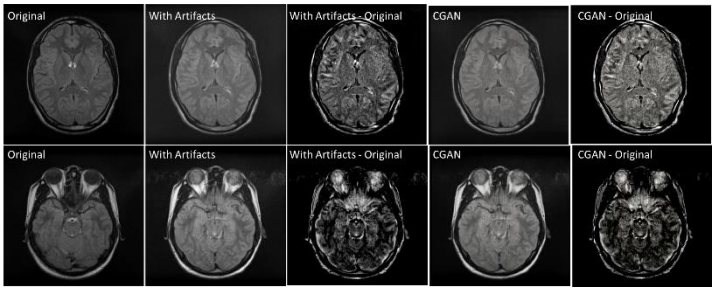


図 2　ボランティアによるモーションアーチファクト補正画像の結果

表 1　アーチファクト画像および補正画像の NMAE の結果

NMAE	アーチファクト画像	補正画像	減少率
シミュレーションデータ	1.39	0.93	32.9%
ボランティアデータ	35.6	27.8	21.9%

利益相反の有無

なし

文　献

［1］Küstner T., et al. LAPNet: Non-rigid registration derived in k-space for magnetic resonance imaging. IEEE Trans Med Imaging 40:3686-3697 202

［2］Kromrey M., et al. Reduction of respiratory motion artifacts in gadoxetate-enhanced MR with a deep learning–based filter using convolutional neural network. Eur Radiol 30:5923–5932, 2020.

［3］Dolz J., Desrosiers C., Ben Ayed I. 3D fully convolutional networks for subcortical segmentation in MRI: A large-scale study. Neuroimage 170;456–470, 2018.

［4］Goodfellow I., et al. Generative adversarial nets. Adv Neural Inf Process Syst 27, 2014.

［5］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

脳腫瘍病変の有無におけるコンディショナル GAN による頭部 CT-MRI 画像変換精度の比較

土屋　諒真[*1]，臼井　桂介[*1]，坂本　肇[*1]，坂野　康昌[*1]，京極　伸介[*1]，代田　浩之[*1]，
[*1] 順天堂大学大学院保健医療学研究科診療放射線学専攻

Comparison Between Head CT to MRI Image Conversion Accuracy Using Conditional Generative Adversarial Networks with and Without Brain Tumor Lesion

Ryoma TSUCHIYA[*1]，Keisuke USUI[*1]，Hajime SAKAMOTO[*1]，Yasuaki SAKANO[*1]，Shinsuke KYOGOKU[*1]，
Hiroyuki DAIDA[*1]
[*1] *Department of radiological Technology, Graduate School of Health Science, Juntendo University*

要旨：深層学習による CT-MRI 画像変換は，放射線治療計画時のレジストレーションの課題を解決し，放射線治療計画の輪郭描出精度の向上が期待できる．関連する先行研究では，多くの場合は病変のない正常画像を用いた学習モデルである．そこで，病変のない画像のみのデータセット，病変のある画像のみのデータセット，病変のある画像と病変のない画像が混在するデータセットの 3 つのトレーニングデータセットを使用して，条件付き敵対的生成ネットワーク（CGAN）による画像変換の精度を評価した．本研究では，病変無しおよび有りの各 100 例の頭部 CT 画像および FLAIR 画像に対して剛体レジストレーションを行い，病変無画像 3312 枚，病変有画像 2753 枚で CT-MRI のペア画像を作成した．90 症例を学習，残りの 10 症例を検証に使用した．評価は MRI の原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．画像変換の結果，病変無しのモデルは定量値が最も高かったものの，腫瘍領域が復元されなかった．しかし，混在データのモデルでは腫瘍領域の復元が可能であり，定量値も病変無しモデルと同等であったため，混在データセットを用いた画像変換の有用性が示唆された．

1. はじめに

深層学習によるコンピュータ断層撮影（Computed tomography：CT）-磁気共鳴画像（Magnetic resonance imaging：MRI）の画像変換は CT 画像のみから位置ずれがなく，組織コントラストに優れた画像を迅速に取得することが可能になる．これにより，放射線治療計画時の CT 画像と MRI 画像のレジストレーション誤差の問題を解決し，輪郭描出精度の向上が期待できる．Li らの論文では，数種類の画像生成ネットワークを用いた深層学習による高い類似度の CT-MRI 画像変換が報告されており，深層学習による画像変換処理の放射線治療計画時のレジストレーションへの有用性を示している[1]．しかし，関連する先行研究では，病変領域の存在しない画像を学習データとして使用しており，病変領域の存在下の画像に対する CT-MRI 画像変換での画像復元精度の検討はなされていない．本研究では，CT 画像と同一スライスの MRI 画像をペアとなる教師画像として，「病変あり」，「病変なし」および病変領域のある画像とない画像を混合した「mix」の 3 つのデータセットを用いて，条件付き敵対的生成ネットワーク（Conditional generated adversarial network：CGAN）による頭部 CT-MRI 画像変換を行い，その画像変換精度を定量的に評価した．

*1　順天堂大学大学院保健医療学研究科
〔〒113-8421 東京都文京区本郷 2-1-1〕
e-mail: fhs8424011@juntendo.ac.jp

2. 方法

1）データセット

The cancer imaging archive より神経膠芽腫（Glioblastoma：GBM）100 症例，Open access series of imaging studies よりアルツハイマー型認知症（Alzheimer's disease：AD）100 症例の CT 画像および fluid attenuation inversion recovery（FLAIR）画像を取得した．GBM 症例を「病変あり」，AD 症例には脳腫瘍が無いため「病変なし」の画像としてそれぞれ利用した．CT 画像はスライス厚 2.5 mm，FLAIR 画像はスライス厚 5.0 mm で撮像された画像である．すべての CT 画像および MRI 画像を field of view（FOV）256×256 mm，マトリクスサイズ 256×256 にリサイズした．その後，3 次元の剛体レジストレーション処理を行い，ペアとなる CT 画像および MRI 画像を「病変あり」画像 2753 枚，「病変なし」画像 3312 枚作成した．「病変あり」お

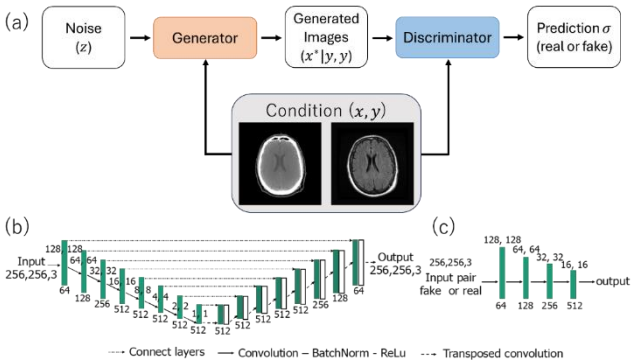


図 1　(a)CGAN のフレームワーク。(b)，(c)はそれぞれの生成器と識別機のネットワーク構造を示している．

よび「病変なし」それぞれ 100 症例の画像のうち，90 例の画像を学習用とし残りの 10 例を検証用とした.「病変なし」画像のみ 2980 枚により構築したモデル（non-lesion model),「病変あり」画像のみ 2478 枚により構築したモデル（lesion model),「病変なし」と「病変あり」画像を混合した 2729 枚により構築したモデル（mix model）の３つのモデルで画像変換を行った．mix モデルでは「病変なし」と「病変あり」症例の混合割合は 1:1（45 症例 : 45 症例),「病変なし」の画像数が約 55%,「病変あり」の画像数が約 45%である. モデルの安定性と学習効果を検証するために，学習では５回の交差検定を行った.

2）CGAN による生成 MRI 画像の合成

本研究における CGAN の構造を図 1 に示す. CGAN は U-Net 構造のジェネレータと PatchGAN ディスクリミネータで構成される[2]．ジェネレータはノイズから合成画像を生成する機能を有しており，PatchGAN ディスクリミネータは生成された画像全体を N×N ピクセルの Patch に分類し, Patch ごとに Real か Fake かの判定を行う機能を有している[3]．CGAN は，この構造にペアとなる画像を条件として与えることで, 生成画像の変換精度を高めていく手法である．ジェネレータは 8 層の U-Net 構造であり，ディスクリミネータは 4 層の畳み込みニューラルネットワーク（Convolutional neural network：CNN）構造である. 本研究では, 入力の CT 画像とペアとなる MRI 画像を教師画像として学習データとして加えた.

3）画質評価方法

画質評価には画像全体の構造的類似度（Structural similarity index：SSIM）とピーク信号雑音比（Peak signal to noise ratio：PSNR）を用いて，MRI の原画像を基準として算出し結果の比較を行った.

3. 結果と考察

図 2 に各学習モデルによる生成 MRI 画像の結果を示す. 3 つのモデルによる生成 MRI 画像は原画像と近いコントラストの画像を生成することができたが, 腫瘍領域の復元精度には差が生じた．non-lesion モデルと lesion モデルでは病変のない正常部分の復元精度は比較的高いが，腫瘍領域の復元精度は低く, 病変の形状が適切に復元されないことに加え, 病変自体が描出されない結果となった．一方で，mix モデルでは腫瘍領域の復元ができており腫瘍が高信号として描出されているが, 形状やサイズが原画像と比較すると異なっている. 表 1 に画像変換による SSIM と PSNR の結果を示す．SSIM および PSNR は non-lesion モデルで最も高くなり, lesion モデルで最も低くなった. mix モデルは non-lesion モデルと比較し低い値であるものの, t 検定では p 値 ＜0.05 の有意水準とした場合の結統計的有意差は生じなかった（SSIM：p = 0.09，PSNR：p = 0.3）．このことから，mix モデルでは組織コントラストに優れる MRI 画像を生成できるとともに, 腫瘍領域を復元できる可能性が示唆された. しかし, 腫瘍のサイズや形状の完全な復元は不完全であり, より多くの学習データやバリエーションのある腫瘍の学習を行うことで，腫瘍領域の復元精度が高まることが考えられる.

4. 結語

深層学習による CT - MRI 画像変換により腫瘍領域を正確に復元するため，入力の CT 画像とペアとなる MRI 画像を学習データとして 3 つのデータセットを用いて CGAN によるモデルを構築し，画像変換精度を比較評価した．本研究により mix モデルによる腫瘍領域の復元が可能であることが示されたが, そのサイズや形状, 位置の復元精度は原画像と比較すると不完全であった.

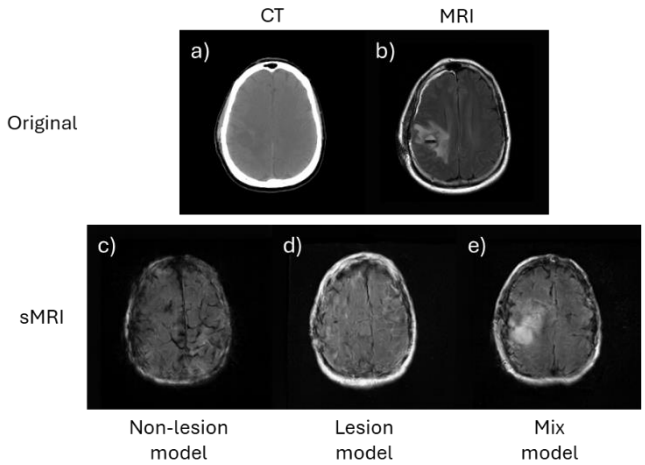


図 2　各学習モデルによる合成画像の結果. (a) 入力 CT 画像．(b) 教師 MRI 画像．(c)-(e) 各学習モデルによる合成画像

表 1　各学習モデルによる変換画像の SSIM および PSNR 結果．*は Non-lesion モデルと比較して有意差があることを示している.

Models	SSIM	PSNR
non-lesion	0.536 ± 0.019	17.9 ± 1.21
lesion	0.476 ± 0.017*	16.8 ± 0.499
mix	0.510 ± 0.026	17.2 ± 0.590

利益相反の有無

なし

文　献

［1］Li W, Li Y, Qin W, et al: Magnetic resonance image (MRI) synthesis from blain computed tomography (CT) images based on deep learning methods for magnetic resonance (MR)-guided radiotherapy. Quant Imaging Med Surg 10(6):1223-1236, 2020

［2］Isora P, Zhu JY, Zhou T, et al.: Image-to image transration with conditional adversarial networks. arXiv:1611.07004, 2018

［3］Ma Y, Liu Y, Zhang D, et al: A Multigranularity Text Driven Named Entity Recognition CGAN Model for Traditional Chinese Medicine Literatures. Comput Intell Neurosci. Sep 24;2022:1495841, 2022

低線量胸部 CT 画像から深層学習を用いた年齢推定モデルの開発

菊野　遥翔[*1]，田中　利恵[*2]，松永　哲夫[*3]，小林　聡[*4]，南　哲弥[*5]，白石　順二[*6]

[*1] 金沢大学大学院医薬保健学総合研究科

[*2] 金沢大学医薬保健研究域付属 AI ホスピタルマクロシグナルダイナミクス研究開発センター

[*3] 石川県予防医学協会，[*4] 金沢大学医薬保健研究域医学系

[*5] 金沢医科大学放射線科，[*6] 福岡国際医療福祉大学

Deep learning-based age estimation from low-dose chest CT images

Haruto KIKUNO[*1]，Rie TANAKA[*2]，Tetsuo MATSUNAGA[*3]，Satoshi KOBAYASHI[*4]，Tetsuya MINAMI[*5]，Junji SHIRAISHI[*6]

[*1] *Graduate School of Health Sciences, Kanazawa Univ.*

[*2] *AI Hospital/Macro Signal Dynamics Research and Development Center, Kanazawa Univ.*

[*3] *Ishikawa Health Service Association*

[*4] *Faculty of Medicine, Institute of Medical, Pharmaceutical and Health Sciences, Kanazawa Univ.*

[*5] *Department of Radiology, Kanazawa Medical Univ.*

[*6] *Fukuoka International Univ. of Health and Welfare*

要旨：肺がん CT 検診は，肺がんの早期発見に有効である．しかし，受診者の約 95%に相当する正常者は一括りに「異常なし」と診断される．深層学習を用いて肺の僅かな経年変化から加齢変化を推定できれば，受診者の生活改善の機会になり得る．本研究の目的は，低線量胸部 CT 画像から年齢推定をする深層学習モデルを開発することである．石川県予防医学協会で過去 11 年間に人間ドックで撮影された低線量胸部 CT 画像約 2.8 万件のうち，異常なし症例について，1 秒量と身長から算出した肺年齢ならびに実年齢と低線量胸部 CT 画像の関係を畳み込みニューラルネットワークに学習させた．学習したモデルを検証したところ，肺年齢は±11.14 歳，実年齢は±4.54 歳の誤差で推定され，喫煙歴が長いほど推定年齢が高くなることが確認された．加齢や喫煙による肺の変化を，開発したモデルが捉えていると考えられる．胸部 CT 画像から推定した年齢と実年齢の差を新しい健康指標として期待できる．

キーワード：年齢推定，胸部 CT，肺年齢，深層学習，予防医学

1. はじめに

現在，肺がんの早期発見を目的に胸部検診として，胸部 X 線検査と低線量胸部 CT 検査が実施されている．低線量胸部 CT 検査は胸部 X 線検査に比べ早期肺がんの発見率が 10 倍以上高く[1]，定期的な検査で肺がんの死亡率が約 40%減少することも報告されている[2]．被ばく線量も一般的な胸部ＣＴ検査の 1/10 程度であり，受診率が増加傾向にある[3]．しかし，低線量胸部 CT 検査の受診者の 95%が「異常所見なし」と診断され，撮影したＣＴ画像はそれ以上活用されていない．そこで，それらの画像から肺の健康度を評価し，受診者に提供することにより，生活の質の向上につながる可能性がある．近年，深層学習を用いて顔写真から高い精度での年齢推定が可能になった[4]．この手法は医用画像からの年齢推定にも応用されており，脳ＭＲ画像では±5.00 歳[5]，胸部Ｘ線写真では±3.67 歳[6]と報告されている．また，CT 画像を対象とした年齢推定では，±1.84 歳の推定誤差を達成しているが，55 歳から 75 歳といった限定的な年齢の分類問題として取り扱う制約がみられた[7]．そこで，対象年齢に制約のない回帰問題として取り扱うことで，より高い精度と汎化性能を有した深層学習モデルを構築できる可能性がある．本研究の目的では，低線量胸部ＣＴ画像から年齢を推定する深層学習モデルを開発することである．

2. 方法

2.1 対象

石川県予防医学協会で 2006 年から 2017 年に人間ドックにて得られた，低線量胸部 CT 画像 27,196 件を対象とした．このうち 16,709 人が喫煙者（M:F = 15,461:1,248，28-83 歳，中央値 51 歳），10,487 人が非喫煙者（M:F = 5,826:4,661，22-83 歳，中央値 50 歳）であった．データベースには画像所見のほか，年齢，身長，体重，喫煙歴，肺機能検査の結果などが含まれている．また肺年齢は性別，身長，肺機能検査の 1 秒率から求められ，以下の日本呼吸器学会の標準回帰式を用いた[8]．

男性：(0.036×身長[cm]-1.178-1 秒量[L]) / 0.028　(1)

女性：(0.022×身長[cm]-0.005-1 秒量[L]) / 0.022　(2)

2.2 データセットの作成

本研究で用いた低線量胸部 CT 画像は，1 件あたり約 100 枚のスライスで構成されている．これら全ての画像を用いて深層学習を行うには，非常に高性能なグラフィックボードや大容量のメモリが必要となるため，1 件あたり 1 枚のスライスを入力する計算コストの低い手法を採用した．採用するスライスは，予備実験で最も年齢推定精度の良かった気管支分岐部のスライスとした．取得した画像に対して，実年齢または肺年齢を正解データとして画像にラベル付けした．元のデータベースは，50 歳代に人数のピークがあり偏った年齢分布となっていた．そこで，偏った年齢でのモデルの構築を防ぐため，各年齢の人数を同程度にした学習データセットを再構築した．したがって，学習用のデータセットとして，非喫煙者の 4,646 人（M：F = 2,586：2,060，22-83 歳，中央値 50 歳）の画像を用いた．一方，評価用のデータセットとして，学習に用いていない正常な非喫煙者（n=5841）と喫煙者(n=16,709)の画像を用いた．さらに，肺，縦隔をセグメンテーションした画像を対象とすることで，年齢推定に用いられる部位の検証を行った．

2.3 年齢推定モデルの学習と評価

本研究では，低線量胸部 CT 画像を入力として，実年齢または肺年齢の推定値を出力とするニューラルネットワーク（Convolution Neural Network:CNN）モデルの構築を行った．モデルは予備実験で最も推定精度の良かった Inception V3 を用い，エポック数は検証データセットの損失が最小になった時点を採用した．また，推定年齢の精度は，正解年齢との平均絶対誤差（Mean Absolute Error:MAE）と相関係数で評価した．さらに，喫煙歴が長いほど，推定年齢が高くなるかを検証した．

3. 結果および考察

実年齢の MAE は±4.54 歳，相関係数は 0.72 となり（表 1），オリジナル画像に続き，肺と縦隔を抽出した画像の MAE が最小となったことから，構築した実年齢推定モデルは，肺と骨や筋肉の画像情報をもとに実年齢を推定していることが示唆された．肺年齢においては MAE が±11.14 歳，相関係数は 0.51 となり（表 1），オリジナル画像に続き，肺以外を抽出した画像の推定誤差が最小となった．このことから，安静吸気息止めで撮影された CT 画像の形態情報から，呼吸機能を加味した肺年齢を推定することは困難であると考えられる．一方，喫煙者の低線量胸部 CT 画像を構築したモデルに入力したところ，実年齢・肺年齢ともに喫煙歴が長いほど実年齢と推定年齢の差が大きくなる傾向がみられた．これらの結果から，加齢や喫煙による肺の変化を，本研究で構築したモデルが捉えているといえる．

表 1．推定年齢の平均絶対誤差と正解年齢との相関

対象	実年齢		肺年齢	
	MAE（歳）	相関係数	MAE（歳）	相関係数
オリジナル(全て)	4.54	0.72	11.14	0.51
肺のみ	12.78	0.06	31.14	0.27
縦隔のみ	13.07	0.14	52.01	0.13
肺と縦隔	6.48	0.09	28.91	0.23
肺以外	26.10	0.37	15.67	0.50
縦隔以外	4.62	0.57	27.92	0.26
肺と縦隔以外	14.93	0.17	32.67	0.19

4. 結語

本研究では，低線量胸部 CT 画像を対象に，実年齢ならびに肺年齢を推定する深層学習モデルを構築した．実年齢については，±4.54 歳の誤差で推定され，推定年齢と実年齢の間に高い相関がみられた（r = 0.72）．肺の健康度，すなわち，加齢や喫煙に伴う形態変化の定量化手法として，今後の臨床活用が期待できる．

利益相反の有無

なし

文　献

［1］ Fujikawa, A., et al., “Lung cancer screening-Comparison of computed tomography and X-ray,” Lung Cancer 61, 195-201, 2008

［2］ Pastorino U., et al., “Prolonged lung cancer screening reduced 10-year mortality in the MILD trial: new confirmation of lung cancer screening efficacy,” Annals of Oncology 30, 1162-1169, 2019

［3］ Kojima, R., et al., “Usefulness of low-dose single-slice CT (SSCT) for mass screening to detect various thoracic diseases including lung cancer,” Annals of The Japanese Respirator Society 42(10), 887-892, 2004

［4］ Greco, A., et al., “Effective training of convolutional neural networks for age estimation based on knowledge distillation,” Neural Computing and Applications 34, 21449-21464, 2022

［5］ Bermudez, C., et al., Anatomical Context Improves Deep Learning on the Brain Age Estimation Task,” Magnetic Resonance Imaging 62, 70-77, 2019

［6］ Ieki, H., et al., “Deep learning-based age estimation from chest X-rays indicates cardiovascular prognosis,” Communications Medicine 2, 159, 2022

［7］ Azarfar, G., et al., “Deep learning-based age estimation from chest CT scans,” International Journal of Computer Assisted Radiology and Surgery 19, 119-127, 2024

［8］ Sasaki, H., et al., Annals of The Japanese Respirator Society, 39(5),1-17, 2001

前眼部 OCT 画像のテクスチャ特徴を用いたぶどう膜炎の前房細胞グレードの推定

清水　悠多[*1]，畑中　裕司[*2]，慶野　博[*3]
[*1] 大分大学大学院工学研究科
[*2] 大分大学理工学部
[*3] 杏林大学医学部

Anterior Chamber Cells Grade Estimation Using Texture Features of Swept-Source Anterior Segment Optical Coherence Tomography

Yuta SHIMIZU[*1]，Yuji HATANAKA[*2]，Hiroshi KEINO[*3]
[*1] *Graduate School of Engineering, Oita University*
[*2] *Faculty of Science and Engineering, Oita University*
[*3] *School of Medicine, Kyorin University.*

要旨：ぶどう膜炎の前房細胞の評価は，現在 SUN Working Group の評価案に従って行われているが，主観的評価であり再現性などが課題となっている．本研究は，テクスチャ解析を用いて，前眼部 OCT 画像からぶどう膜炎における前房細胞グレードの自動推定手法の開発を目的とする．本研究では，OCT 画像中の前房領域を特定し，その領域内を正方形で関心領域に設定しテクスチャ解析を行った．ここでは，画素値の度数分布に基づく統計量，同時生起行列(GLCM)，ランレングス行列(GLRLM)，サイズゾーン行列(GLSZM)，ディペンデンス行列(GLDM)，近傍濃度差行列(NGTDM)への変換から得られる合計９３種類の特徴量を抽出した．抽出した特徴量に対して主成分分析を行い，上位７要素を使用してニューラルネットワークによる重回帰分析を行った．その結果，利用する特徴量を増やすことにより推定精度が改善したことを確認した．
キーワード：ぶどう膜炎，前房細胞，テクスチャ解析，ニューラルネットワーク

1. はじめに

ぶどう膜炎は，眼の中の虹彩や毛様体，脈絡膜などの組織に炎症が生じ，そこから周囲の眼組織にも炎症が少しずつ広がり，目の充血や飛蚊症，ひどい場合は視力低下や失明などを引き起こすものである．

現在，この病気の前房細胞の評価は，細隙灯顕微鏡を用いて Standardization of Uveitis Nomenclature (SUN) Working Group により国際的に標準化された定義[1]に従って行われており，その評価スケールを表 1 に示す．この診断では，前房部内の 1 視野に見える炎症細胞の個数を医師が数えてグレードを決定するため，主観評価となり再現性が低いことが問題である．前房細胞の評価は，細胞の活動性や治療効果の判定にもつながる重要な所見であるため定量的な尺度での判別が求められている．診断を自動化することが可能になれば，細胞グレードの判別を定量的かつ再現性の高いものにすることが期待でき，先行研究[2]では炎症密度の回帰分析に基づく重症度推定法を提案しており，SUN Working Group による評価案に基づいた医師のグレーディングと強い相関があることを示している．しかし，細胞の検出が難しい画像や，ノイズの誤検出などが問題点としてあり，細胞検出以外の推定手法を検討する必要がある．

そこで本研究は，前眼部 OCT 画像を用いて前房細胞グレードの自動推定システムの作成を目的とし，テクスチャ解析及びニューラルネットワークを用いた重回帰分析によるグレード推定法を提案する．畳み込みニューラルネットワーク(CNN)の利用も検討したが，使用できるデータ数が少ないため学習が困難であると判断し，本研究では利用していない．また，前房細胞の散らばりを評価するために，提案システムの活用方法についても検討する．

表 1　SUN Working Group による評価案[1]

グレード	1 視野に見られる細胞数
0	<1（1 個未満）
0.5	1~5
1	6~15
2	16~25
3	26~50
4	>50（51 個以上）

2. 提案手法

本研究では，杏林アイセンターにてぶどう膜炎と診断された 32 例 53 眼の前眼部 OCT 画像を用いた．1 眼につき 4 方向のスライスで撮影を行い，計 212 枚の前眼部 OCT 画像を使用した．画像の大きさは不揃いで，1100×535 pixels 前後の画像 172 枚と 1600×780 pixels 前後の画像 40 枚である．本研究は杏林大学医学部倫理審査委員会の承認を得て行った．

提案手法は，まず前眼部 OCT 画像から前房部分を抽出するとともに，階調数の変更及びヒストグラム平坦化による画像の

前処理を行う．次に，前房部内にテクスチャ解析の関心領域(ROI)となる正方形を指定する．中心となる ROI の指定後，上下左右 8 方向に 10 画素ずつ移動させ，計 9 か所の ROI を 1 枚の画像から抽出しデータ拡張を行う．その後，指定した ROI でテクスチャ解析を行う．利用する特徴量は統計的手法によるもので，濃度ヒストグラムを用いた 1 次統計量が 18 種類．2 次統計量は以下の 5 種類の行列から求められる特徴量を利用している．それぞれの行列名および個数は，同時生起行列(GLCM) 24 種類，ランレングス行列(GLRLM) 16 種類，サイズゾーン行列(GLSZM) 16 種類，ディペンデンス行列(GLDM) 14 種類，近傍濃度差行列(NGTDM) 5 種類となっている．上記の合計 93 種類の特徴量を計算し，主成分分析により次元削減を行う．累積寄与率が 85%程度となる，第 7 主成分までをニューラルネットワークの入力とし，重回帰分析を行い各画像に対する推定結果を出力する．1 眼につき 4 スライスの推定結果の平均値をその眼に対する推定値とし， 4 分割交差検証により精度評価を行う．実験条件は，画像の階調数が 4，8，16，32，64，128 階調の 6 段階，中間層のノード数が 3~11 units の 9 種類，ROI の大きさについても，51×51，61×61，71×71，81×81，91×91，101×101 pixels の 6 種類で，すべての組み合わせに対して交差検証を行った．

3. 結果と考察

実験の結果，階調数 64 階調，中間層のノード数 6 units，ROI が 101×101 pixels の場合において，相関係数が 0.892 となり，結果を図 1 に示す．眼科医による診断においても，医師ごとで診断グレードに±1 段階程度の違いがあるため，本研究でも医師の判定したグレードから±1 以内であることを評価基準とする．図 1 中の青線が医師の判定と差異なし，薄青線が判定との差±1 の基準線である．53 眼中 49 眼について，医師の判定との差が±1 の範囲に収まり，判定との差が＋1 を超える症例はなかった．

グレード 0 の眼については，すべての推定値が 0.5 を上回る結果となったが，映る細胞数が少ないことと，OCT 画像のノイズと炎症細胞の区別が難しいことが理由として挙げられるため，グレード 0.5 も含め，推定結果が判定よりも高くなったと考えられる．

また，グレード毎の眼数に偏りがあるため，グレードが上がるにつれて数値にばらつきがあり，グレード 4 については 3 眼中 2 眼で前房部内にタンパク質の漏出であるフレアが見られ，残りの 1 眼をテストデータとしたとき，フレアの特徴を学習してしまった可能性が高く，推定精度が落ちたと考えられる．

さらに，同じグレードが付けられた画像であっても，目視による比較では別のグレードともとれる画像もあり，必ず同じレベルの画像が同じグレードの教師データとして存在しているわけではないため，精度低下の原因になると考えられる．

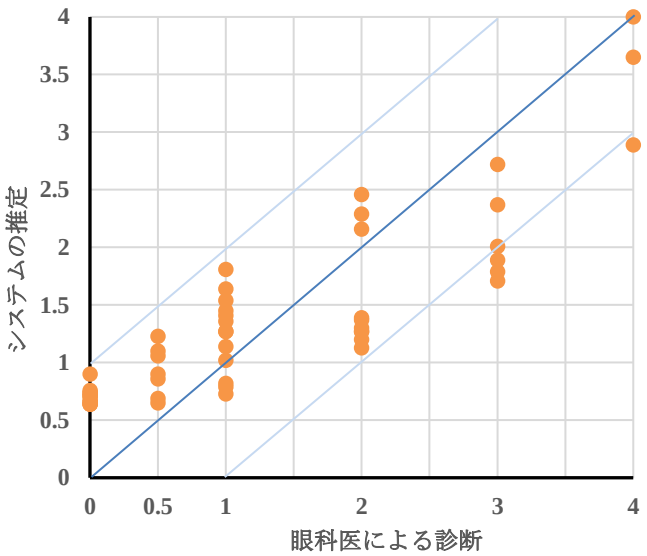


図 1　53 眼に対する推定結果

いずれの場合も，データ数が少ないことが問題であるため，データの確保が最も有効な手段であると考える．

ROI についても，前房部の中央付近を主観で設定しているが，前房部内で均等に炎症細胞が存在しているわけではないため，ROI の場所の選定も重要となる．

今後の展望として，本システムを活用し前房部内の細胞の分布を評価することで，ぶどう膜炎に関する他の所見との関わりを見つけられる可能性がある．

4. まとめ

本研究では，前眼部 OCT 画像を用いたぶどう膜炎の前房細胞グレードの自動推定システムを開発した．これにより，画像診断による前房細胞グレード推定の可能性が示唆された．今後は，前房部内の細胞の分布と病気の関係などについても評価方法を検討していく．

謝辞

本研究は JSPS 科研費 19K12827 の助成を受けたものです．

利益相反の有無

なし

文　献

［1］ Jabs DA, Nussenblatt RB, Rosenbaum JT: Standardization of Uveitis Nomenclature for Reporting Clinical Data. Results of the First International Workshop. Am J Ophthalmol 140: 509–516, 2005

［2］Keino H, Aman T, Furuya R et al: Automated Quantitative Analysis of Anterior Segment Inflammation Using Swept-Source Anterior Segment Optical Coherence Tomography: A Pilot Study. Diagnostics 12: 2703, 2022

深層学習を用いた超音波 RF 信号再構成による転移リンパ節診断予測モデルの開発

前田　一伎[*1]，大村　眞朗[*2]，小玉　哲也[*1,3]
[*1] 東北大学大学院医工学研究科
[*2] 富山大学学術研究部工学系
[*3] 東北大学大学院医工学研究科がん医工学センター

Development of Predictive Model for Diagnosis Metastatic Lymph Node by Ultrasound RF Signal Reconstruction using Deep Learning

Kazuki MAEDA[*1], Masaaki OMURA[*2], Tetsuya KODAMA[*1,3]
[*1] *Graduate School of Biomedical Engineering, Tohoku University*
[*2] *Faculty of Engineering, University of Toyama*
[*3] *Biomedical Engineering Cancer Research Center, Graduate School of Biomedical Engineering, Tohoku University*

要旨：転移リンパ節は，重要な予後因子である．われわれの先行研究では，ヒトと同等の大きさのリンパ節を有するモデルマウスを用いた非臨床試験で，転移リンパ節内で血管が欠損する灌流欠損を造影高周波超音波で可視化し，灌流欠損が転移リンパ節の初期段階を判定する重要な指標になることを明らかにした．しかし，造影剤投与は手間やコスト，ならびに一部のアレルギー患者には適用できないなどの課題がある．本研究では，造影剤を必要としない転移リンパ節判定システムを開発することを目的とする．学習に使用するデータセットは，リンパ節の超音波 RF 信号再構成情報を使用し，これらのデータを学習用と検証用に分割して深層学習を実行した．造影前データを入力としたモデル予測データと検証用の造影後データを比較すると，約 99%一致した．本研究は，超音波 RF 信号に基づく深層学習モデルの有用性を示すものである．

キーワード：リンパ節，血流，超音波，RF 信号，深層学習

1. 緒言

がん患者の死因のうち 90%は，転移に起因している[1]．特に，リンパ節転移は遠隔転移前の重要な予後因子であり，転移リンパ節の早期発見が患者の生存率向上に大きく寄与する[2]．図 1 は，転移にともなうリンパ節内部構造の変化を示す．

転移リンパ節内部では，腫瘍の増殖にともない血管が圧排され，血管の欠損領域である灌流欠損が形成される．われわれの先行研究におけるマウスを用いた非臨床試験では，造影高周波超音波でこの欠損を可視化し，転移初期段階のリンパ節を評価する重要な指標であることを明らかにした[3]．この手法では造影剤の投与が必要であり，手間やコストのほか，一部のアレルギー患者には適用できないという課題がある[4]．

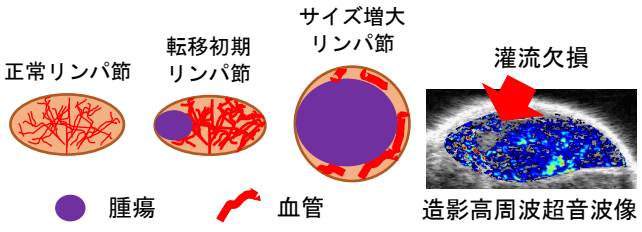


図 1．リンパ節内部構造の変化

本研究では，造影剤を使用しない転移初期リンパ節の検出を目的にする．本実験では，高精細な非造影血流像を推定するために，正常マウスのリンパ節を用いて，造影前後の超音波 RF 信号データを組込んだ深層学習モデルを構築した．

2. 実験方法

実験マウスは，ヒトと同等の大きさのリンパ節（10 mm 程度）を有するリンパ節腫脹マウス（MXH54/Mo/*lpr-lpr*, n=1）を用いた．脇下に位置する固有腋窩リンパ節を撮像し，高周波超音波診断装置から出力される B モード RF 信号を取得した（図 2）．

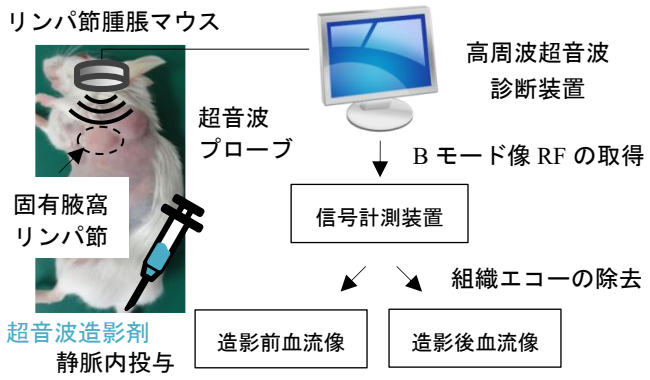


図 2．超音波 RF 信号取得実験概要図

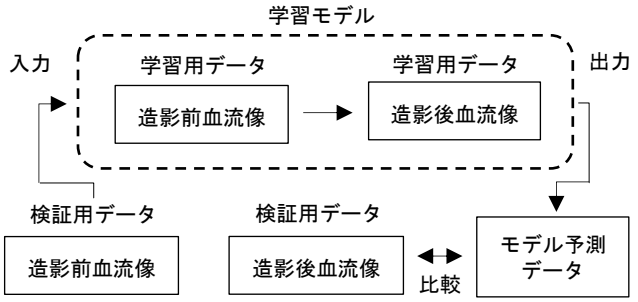


図 3. 予測モデル関係図

まず非造影での RF 信号を計測した．つづいて，マウスの尾静脈に超音波造影剤（Sonazoid）を 100 μL 投与した．10 分経過後に，造影状態の RF 信号を計測した．次に，造影前後の信号データを用いて，組織エコーを除去するフィルタを適用し，再構成をおこなった．フレームバイフレーム，逐次加算平均最大値投影の 3 パターンの再構成により，血流像を生成した．

そして，造影前血流像を入力データ，造影後血流像を教師データとするデータセットを作成した．3:1 の割合で学習用と検証用に分割し，U-Net モデルによる学習を実行した（図 3）．損失関数は平均二乗誤差，評価関数は決定係数を用いた．

3. 実験結果

各再構成パターンにおける学習モデルの出力結果を図 4（フレームバイフレーム），図 5（逐次加算平均），図 6（最大値投影）に示す．図 4 では，実際の造影後血流像と比較して，平滑化された予測画像が出力された．図 5 および図 6 では，実際の造影後血流像とモデル予測画像がほぼ一致することが判明した．各パターンにおける決定係数値は，フレームバイフレーム:0.68，逐次加算平均:0.96，最大値投影:0.99 となった．

4. 考察

学習モデルの出力結果によると，逐次加算平均および最大値投影の再構成血流像における教師データとモデル予測データの一致率が非常に高かった．フレーム加算処理の影響を受けているため，学習しやすい入力データと教師データの組合せのためであると考えられる．今回は，時間経過による僅かな変化を学習させたため，精度が高くなる傾向にあり，過学習の影響を考慮する必要がある．今後は，異なるリンパ節のデータ適用や，転移状態における欠損領域反映の可能性について検討し，さらなるモデルの改良を加えていく予定である．

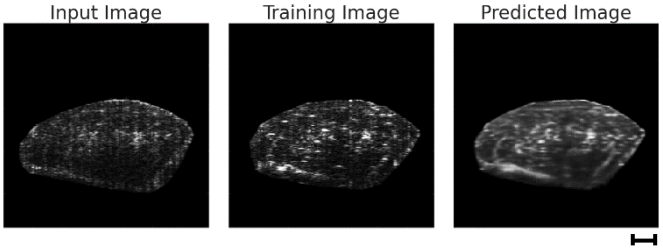


図 4. リンパ節血流像（フレームバイフレーム） 1 mm

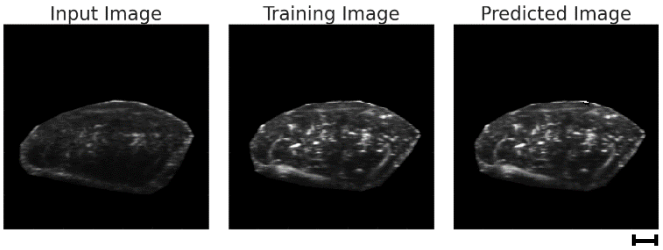


図 5. リンパ節血流像（逐次加算平均） 1 mm

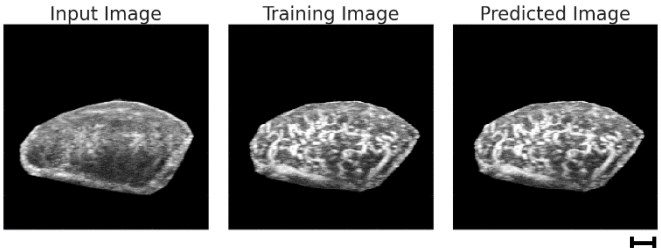


図 6. リンパ節血流像（最大値投影） 1 mm

5. 結言

超音波 RF 信号情報を用いて，造影前血流像から造影後血流像を予測するモデルを構築した．本研究は，リンパ節の超音波解析において，RF 信号再構成と深層学習の組合せが有用であることを示した．

利益相反の有無

なし

文　献

［1］Mehlen P, Puisieux A: Metastasis: a question of life or death. Nat Rev Cancer 6: 449-458, 2006

［2］Kawada K, Taketo K: Significance and mechanism of lymph node metastasis in cancer progression, Cancer Res 71: 1214-1218, 2011

［3］Yamaki T, Sukhbaatar A, Mishra R et al: Characterizing perfusion defects in metastatic lymph nodes at an early stage using high-frequency ultrasound and micro-CT imaging. Clin Exp Metastasis 38: 539-549, 2021

［4］Dietrich C, Nolsøe C, Barr R et al: Guidelines and Good Clinical Practice Recommendations for Contrast-Enhanced Ultrasound (CEUS) in the Liver-Update 2020 WFUMB in Cooperation with EFSUMB, AFSUMB, AIUM, and FLAUS. Ultrasound Med Biol 46: 2579-2604, 2020

対照学習を用いた画像特徴抽出モデルの事前学習の有効性の検証

渡辺　翔吾[*1]，連　乃駿[*1]，今岡 幸弘[*1]，和久 景子[*1]，盛田　健人[*2]，
小橋　昌司[*3]，西村　邦宏[*1]，飯原　弘二[*1]
[*1] 国立循環器病研究センター，[*2] 三重大学，[*3] 兵庫県立大学

A feasibility study of the effectiveness of Contrastive pre-training image feature extraction models

Shogo Watanabe[*1]，Nice Ren[*1]，Yukihiro Imaoka[*1]，Kento Morita[*2]，Keiko Waku[*1]，
Syoji Kobashi[*3]，Kunihiro Nishimura[*1]，Koji Iihara[*1]
[*1] *National Cerebral and Cardiovascular Center* [*2] *Mie University*，[*3] *University Hyogo*

要旨：医用画像は臨床診断において重要な位置を占めており，疾患や予後に関わる情報を含んでいる．画像からより重要な情報を抽出することは，疾患分類や予後予測に繋がると考えられるが，そのためには汎用的な画像特徴抽出モデルが必要となる．そこで本研究では，画像情報と構造化された臨床情報を用いて対照学習を行い，より汎用的な画像特徴抽出モデルの事前学習を目指した．対象とする画像は，脳梗塞を発症した患者の MR 画像とし，FLAIR，T2*，DWI を使用した．下流タスクとして脳梗塞再発予測を扱い，臨床情報のみの再発予測と，臨床情報に画像特徴抽出モデルで得られた画像特徴量を加えたものとの比較を行った．その結果，臨床情報のみでの再発予測の精度 ROC AUC 0.66 であったのに対し，対照学習を用いて抽出した画像特徴量を加えることで ROC AUC 0.74 への向上が見られた．これにより，画像データと構造化データの対照学習に基づく事前学習の可能性が示唆された．
キーワード：脳梗塞，再発予測，対照学習，MRI，Transformer

1. はじめに

脳血管疾患のうち，脳梗塞は 70%を占めており，初回脳梗塞発症後の再発は患者のＱＯＬ低下に深く関わる．再発予防には，予防のための意識を患者へ促すための脳梗塞再発予測モデル開発が有用であると考えられる．

脳梗塞再発予測は古くから研究されており，従来は年齢や性別といった患者の基本情報に加え，喫煙歴や高血圧の有無や，併存症・既往歴などに点数付けをした再発リスクスコアが提案されている．[1, 2]

近年では，上述の臨床情報を用いた機械学習による脳梗塞の再発予測モデルの研究がいくつか報告されている．[3, 4] 一方，画像データを用いる脳梗塞再発予測モデルの報告[4]はまだ少ないながら，医用画像には臨床情報だけでは捉え切れていない情報が含まれていると考えられ，これを用いることで再発予測の性能向上が期待される．

しかしながら，医用画像からどのように情報を抽出するのかは普遍的な課題である．そこ本研究では，構造化された臨床情報と MR 画像を用いて対照学習を行うことにより，画像から特徴量抽出するモデルを検討し，その有用性を検討した．

2. 方法

下流タスクとなる再発予測の対象として，2013～2019 年に国立循環器病研究センターに脳梗塞で予定外入院した患者のうち，退院後 1 年以内に再発して再入院した患者を抽出し，これを脳梗塞再発予測のためのデータセットとして用意した．

MRI には複数の撮像法があるが，今回は Covert Brain Infarction (CBI)[5]と脳梗塞との関連性も視野に入れて，脳梗塞再発予測においては，退院日に近い FLAIR 画像を使用した．一方，事前学習に使用するデータは，同期間で収集することができた患者の入院期間内の MRI と DPC で収集可能な構造化データとした．MR 画像のモダリティは，FLAIR，T2*，DWI を使用した．本研究は，国立循環器病研究センターの倫理委員会の承認を受けている．

事前学習モデルの構築において，Contrastive Language-Image Pre-training (CLIP) [6]の方式を用いた．CLIP では，画像とその画像に対応付けられたキャプション文章を用いて対照学習を行うことで，画像・テキストそれぞれの情報抽出モデルの事前学習を行う．本研究では，キャプション文章を構造化データに置き換えて，同様の対照学習を実施する．

画像・テキストのそれぞれの Encoder はいずれも Transformer ベースのモデルを採用し，入力画像は 3D とした．学習目標は CLIP と同様に，対応するペアの画像と患者情報を 1 に近づけるように，異なるペアでは -1 に遠ざけるように学習を行う．

ミニバッチサイズ 12 で最大 500 epoch の事前学習を行った．最適化アルゴリズムには，AdamW($\beta_1 = 0.9, \beta_2 = 0.98, weight\ decay = 0.2$)を使用し，学習率を最小値 1×10^{-7} から最大値 1×10^{-4} まで周期的に変化させ，1 サイクル終了ごとに学習率の最大値は指数関数的に減少させた．

事前学習を実施したのち，学習済みの画像 Encoder を用いて，脳梗塞再発予測データセットに使用する FLAIR 画像から特徴を抽出し，これを画像特徴量として再発予測モデルの変数に加える．再発予測モデルには，LightGBM[7]を使用し，臨床情報は，年齢，性別などを含む 22 変数を用いた．

3. 結果

臨床情報のみを用いた脳梗塞再発予測モデルと, 対照学習により事前学習された画像特徴量抽出モデルを用いて FLAIR 画像から抽出した画像特徴量を加えたとの ROC AUC の比較を表 1 に示す.

臨床情報のみの場合より, 事前学習モデルを使用して FLAIR 画像から抽出した画像特徴量を加えた場合の方が, 高い精度が得られた.

表 1. 教師あり学習と異常検知の比較

	臨床情報のみ	臨床情報 +FLAIR 画像特徴量
ROC AUC	0.66	**0.74**

4. まとめ

本研究では, MR 画像と構造化された患者情報との対照学習により画像特徴抽出モデルの事前学習を行い, その有用性を検討した. 対照学習で事前学習した画像特徴抽出モデルから得られた画像特徴量を, 脳梗塞再発予測モデルに加えることで, 臨床情報のみの場合と比べて予測精度の向上が見られた.

謝辞

画像データの抽出を行って頂いた国立循環器病研究センター情報統括部に深謝致します.

利益相反の有無

なし.

文　献

［1］Kerman N. W, Viscoli M. C, Brass M. L et al: The Stroke Prognosis Instrument II (SPI-II) A Clinical Prediction Instrument for Patients With Transient Ischemia and Nondisabling Ischemic Stroke. Stroke 31(2): 456-462, 2000.

［2］Weimar C, Diener HC, Alberts J. M et al: The Essen Stroke Risk Score Predicts Recurrent Cardiovascular Events: A Validation Within the REduction of Atherothrombosis for Continued Health (REACH) Registry. Stroke 40(2): 350-354, 2009.

［3］ Abedi V, Avula V, Chaudhary D et al: Prediction of Long-Term Stroke Recurrence Using Machine Learning Models. J Clin Med 10(6): 1286, 2021.

［4］ Wang H, Sun Y, Zhu J et al: Diffusion-weighted imaging-based radiomics for predicting 1-year ischemic stroke recurrence. fneur: 13, 2022.

［5］Thomas Raphael M, Johannes K, Laurent R et al: Covert Brain Infarction Towards: Precision Medicine in Research, Diagnosis, and Therapy for a Silent Pandemic. Stroke 51(8): 2597-2606, 2020.

［6］ Radford Alec et al.: Learning Transferable Visual Models From Natural Language Supervision. arXiv preprint arXiv:2103.00020.

[7] Ke, Guolin, et al. Lightgbm: A highly efficient gradient boosting decision tree. Advances in neural information processing systems 2017, 30

TMS コイルによる脳内誘導電場の回帰精度改善に向けた頭部 MRI の自己教師あり学習

牧　豊大[*1]，横田　達也[*1]，平田　晃正[*2]，本谷　秀堅[*1]
[*1] 名古屋工業大学大学院工学研究科情報工学専攻
[*2] 名古屋工業大学大学院工学研究科電気・機械工学専攻

Self-supervised learning of head MR images to improve the regression accuracy of electric fields in the brain using TMS coil

Toyohiro MAKI[*1]，Tatsuya YOKOTA[*1]，Akimasa HIRATA[*2]，Hidekata HONTANI[*1]
[*1] *Department of Computer Science, Nagoya Institute of technology*
[*2] *Department of Electrical and Mechanical Engineering, Nagoya Institute of technology*

要旨：経頭蓋磁気刺激法 (Transcranial Magnetical Stimulation: TMS) は，頭部に置いたコイルによって誘導される電場を用いた非侵襲的な刺激手法である．コイルによって刺激されている部位を求めること，また反対にある部位を刺激する上での最適なコイルの位置を求めることは TMS にとって重要である．これらを達成するためには，正確に誘導電場を計算する必要がある．誘導電場は頭部 MRI 画像から電磁シミュレーションを用いて計算される．電磁シミュレーションは，MRI 画像から導電率の空間的な分布を構築すること及びその分布から電場を計算する二つの工程で構成される．しかし，いずれの工程も実時間で行うことはできない．近年，CNN を用いた電場を実時間で推定する手法が提案されている．本研究では，Transformer 及びその事前学習を用いて，誘導電場の回帰精度の改善を目指す．

キーワード：経頭蓋磁気刺激法，電場推定，Transformer，事前学習（5 語以内）

1. はじめに

経頭蓋磁気刺激法(Transcranial Magnetic Stimulation: TMS) はコイルが発生させる磁場によって誘導される電場を用いた頭部への非侵襲的な刺激法である[1]．TMS を行う上で，コイルによって刺激されている脳内の位置を求めることは重要であり，そのためにはコイルによる誘導電場の推定が必要である．脳内には導電率の異なる組織が複雑に分布しているため，誘導電場はコイルの位置のみで決定することはできない．コイルの位置に加えて，脳内の空間的な導電率の分布から誘導電場は電磁シミュレーションされる[2].

電磁シミュレーションの流れを図 1 に示す．まず，MRI (Magnetic Resonance Imaging) 画像を導電率の異なる頭部の組織ごとに領域分割する．次に，領域分割された組織に対応する導電率を割り当てることで，導電率の空間的な分布である VCM (Volume Conductor Model) が構築される．頭部の組織の導電率は事前に与えられている．最後に，VCM とコイルの位置から電場は計算される．しかし，MRI 画像の領域分割及び VCM からの電磁シミュレーションを実時間で行うことは困難である．

近年深層学習を用いた高速な誘導電場の推定法が提案されている [3, 4]．これらの手法は，MRI 画像及びコイルの位置情報を入力とし誘導電場を出力とする教師あり学習である．教師データは電磁シミュレーションを用いて作成され，DNN (Deep Neural Network) のアーキテクチャには CNN (Convolutional Neural Network) を用いた U-Net が採用されている．電場推定

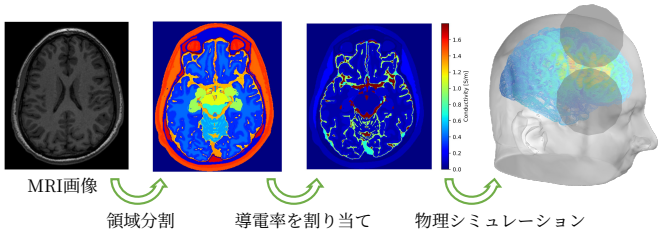


図 1 電場のシミュレーションの流れ

の問題に深層学習を適用する上で注意すべき点は，コイルの位置情報の表現方法である．MRI 画像をコイル中心の座標系に変換する手法[3]と真空でのコイルによるベクトルポテンシャルの時間微分を MRI 画像に追加して DNN に入力する方法[4] が提案されている．

本研究では，transformer を用いることで誘導電場の回帰精度の改善を目指す．transformer は大量のメモリを必要とするため，3 次元画像に適用することは困難である．そのため，attention を計算する領域を制限する swin transformer [5] をエンコーダに利用している U-Net である，Swin UNETR [6]を採用した．CNN を用いた電場推定法[4]と比較して，推定精度が改善することを確認した．加えて，swin transformer に対して事前学習を行なうことによりさらなる電場精度の改善を目指す．Transformer は事前学習を行うことで領域分割の精度が改善することが知られている[6]．電場の物理シミュレーションには領域分割が必要であるため，領域分割の精度改善に寄与する機

構を導入することで, 電場推定の精度が向上することを期待する.

2. データセット

HCP[7]をデータセットに採用した. HCP は被験者 1113 人の T1 及び T2 強度画像のデータセットであり，分解能は 0.70mm ×0.70mm×0.70mm である. 本研究では、14 人の被験者の MRI 画像を実験に用いた. SimNIBS[8]を用いて T1 及び T2 強度画像を白質, 灰白質, 脳脊髄液(Cerebrospinal Fluid: CSF) ，頭蓋, 眼球, 緻密骨, 海綿骨, 筋肉, 血管の領域に分割した. そして, これらの組織に対応する導電率を割り当て，VCM を作成した. 誘導電場は SimNIBS[8]を用いて計算した.

本研究では、脳波(Electroencephalography: EEG)の計測に使われる 76 箇所の位置にコイルを設置した. 各位置に対して，頭皮の法線周りに 20 度おきに 360 度コイルを回転させ，電場を計算した. 14 人のうち 11 人を学習に, 3 人をテストに用いた. 従って, 学習データとテストデータの小計はそれぞれ 15048 通りと 4104 通りである.

3. 手法

本研究では教師あり学習を用いて電場の回帰を行う. T1 強度画像を$\boldsymbol{x} \in \mathbb{R}^{H\times W\times D}$とし，電磁シミュレーションで得られた電場を$\boldsymbol{t} \in \mathbb{R}^{3\times H\times W\times D}$とする. 本研究では，コイルの位置を真空中のベクトルポテンシャル$\boldsymbol{A} \in \mathbb{R}^{3\times H\times W\times D}$で表現する. $\boldsymbol{y}$を電場回帰を実現するニューラルネットとし，そのパラメータを$\boldsymbol{w}$とする. 一般的な回帰問題と同様に下記を仮定する[9].

$$\boldsymbol{t} = \boldsymbol{y}(\boldsymbol{x}, \boldsymbol{A}, \boldsymbol{w}) + \boldsymbol{\epsilon} \tag{2}$$

ここで，$\boldsymbol{\epsilon}$はガウシアンノイズを表す. 最適化の目的関数も，一般的な回帰問題と同様に$\boldsymbol{y}$と$\boldsymbol{t}$の間の平均二乗誤差とする. アーキテクチャには SwinUnetr [6]を採用した. SwinUnetr は, swin transformer[5]でエンコーダが構成され，CNN でデコーダが構成されている U-Net である.

4. 結果とまとめ

誘導電場の可視化結果を図 2 に示す. 図 2 では，SimNIBS[8]で抽出した灰白質の表面に誘導電場を表示している. 色は電場強度に対応する. 次に, CNN を用いた電場推定法[4]を Baseline とし，Swin UNETR との比較を表 1 に示す. TMS は部位によって重要性が異なり, 特に神経細胞が分布している灰白質や白質の精度は重要であるため, 部位ごとでの比較を行った. 本研究では，VCM の構築の際に用いた部位を比較対象に用い，全ての部位に対して, 誘導電場の回帰精度が改善していることを確認した. 部位ごとに精度がばらつくのは，各部位に割り当てられる導電率の値が異なるためであると考えられる. 今後は，今回用いた transformer を大量の MRI 画像で事前学習することで，さらなる精度の改善を目指す.

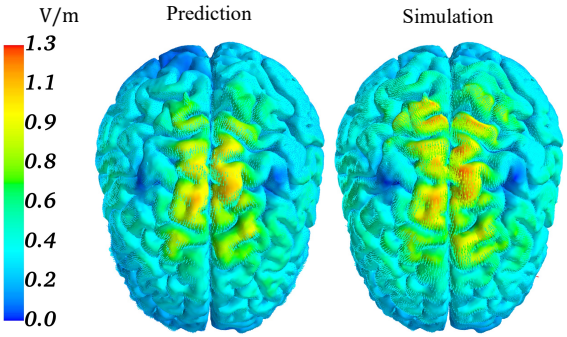


図 2 Swin Unetr で推定した電場とシミュレーションで計算した電場

表 1 各部位での二乗誤差の比較

	Baseline	SwinUnetr
White Matter	5.57×10^{-3}	$\mathbf{4.23\times10^{-3}}$
Gray Matter	5.97×10^{-3}	$\mathbf{4.46\times10^{-3}}$
CSF	2.12×10^{-2}	$\mathbf{1.89\times10^{-2}}$
Scalp	2.01×10^{-2}	$\mathbf{1.47\times10^{-2}}$
Eye	5.60×10^{-3}	$\mathbf{2.98\times10^{-3}}$
Compact Bone	8.65×10^{-2}	$\mathbf{6.79\times10^{-2}}$
Spongy Bone	1.96×10^{-2}	$\mathbf{1.41\times10^{-2}}$
Blood	7.33×10^{-3}	$\mathbf{5.79\times10^{-3}}$
Muscle	5.58×10^{-3}	$\mathbf{4.27\times10^{-3}}$

利益相反の有無

なし

文　献

[1] Rossi S, Hallett M, Rossini P. M, Pascual-Leone A, Safty of TMS Consensus Group, et al: Safety, ethical considerations, and application guidelines for the use of transcranial magnetic stimulation in clinical practice and research, Clinical neurophysiology, vol.120, no.12, pp.2008–2039, 2009.

[2] Aonuma S, Gomez-Tames J, Laakso I, et al: A high-resolution computational localization method for transcranial magnetic stimulation mapping, Neuroimage, vol.172, pp.85–93, 2018.

[3] Yokota T, Maki T, Nagata T, et al: Real-time estimation of electric fields induced by transcranial magnetic stimulation with deep neural networks, Brain stimulation, vol.12, no.6, pp.1500–1507, 2019.

[4] Xu G, Rathi Y, Camprodon J.A, Cao H, Ning L: Rapid whole-brain electric field mapping in transcranial magnetic stimulation using deep learning, Plos one, vol.16, no.7, p.e0254588, 2021.

[5] Liu Z, Lin Y, Cao Y, et al: Swin transformer: Hierarchical vision transformer using shifted windows, Proceedings of the IEEE/CVF international conference on computer vision, pp.10012–10022, 2021.

[6] Tang Y, Yang D, Li W, et al: Self-supervised pre-training of swin transformers for 3d medical image analysis, Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp.20730–20740, 2022.

[7] Van Essen D.C, Smith S.M, Barch D.M, et al: The WU-Minn human connectome project: an overview, Neuroimage, vol.80, pp.62–79, 2013.

[8] Thielscher A, Antunes A, Saturnino G.B: Field modeling for transcranial magnetic stimulation: A useful tool to understand the physiological effects of TMS? In 2015 37th annual international conference of the IEEE engineering in medicine and biology society (EMBC), pp.222-225, IEEE, 2015.

[9] Bishop C.M: Pattern Recognition and Machine Learning. Springer, 2006.

画像分離に深層学習を利用する新たな MR マルチスライス撮像法の提案

遠藤 尚哉[*1]，佐藤 裕貴[*1]，大内 翔平[*2]，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

[*2] 小山工業高等専門学校 電気電子創造工学科

Proposal of New MR Simultaneous Multi-Slice Imaging Using Deep Learning for Image Separation

Naoya ENDO[*1]，Yuki SATO[*1]，Shohei Ouchi[*2]，Satoshi ITO[*1]

[*1] *Graduate Program in Information, Electrical and Electronic Systems Engineering, Utsunomiya University*

[*2] *National Institute of Technology, Oyama College*

要旨：MRI の高速撮像法の一つに複数のスライス像を同時に撮像する Simultaneous Multi-slice Imaging (SMS)がある．SMS は一般に重なった画像の分離には受信コイルの感度分布を必要とするが，正確な感度分布を求めることは困難であり，分離されたスライス像の画質に課題があった．本研究では，受信コイルの感度差を使用せずにスライス像を分離する新たな SMS を提案する．スライス画像の分離には撮像時に与える位相変調と深層学習を利用する．本研究では，基本的な特性を評価することを目的とし，スライス像に与える位相変調係数，同時撮像枚数および位相画像への応用についてシミュレーション実験を行った．その結果，位相画像の対してもスライス像の分離可能性が示され，新たな SMS としての実現可能性を示すことができた．

キーワード：Simultaneous Multi-Slice Imaging，ホログラフィ，高速撮像，深層学習

1. はじめに

MRI の撮像高速化に，同時マルチスライス撮像(Simultaneous Multi-slice Imaging : SMS)がある．圧縮センシング(CS)，パラレルイメージング(PI)[1]等の MRI 撮像高速化手法と比較して，SMS は信号空間の間引きを行うことなく複数のスライスを同時に撮像する高速化法である．

SMS において受信信号を単純に逆フーリエ変換再構成すると同時に励起したスライス像が重畳した像となる．得られる像はスライス像と受信コイル感度の積和で表現される．複数の受信コイルを使用すると再生像の関する複数の式が得られるので連立方程式を解くことにより原理的にスライス像を分離することが可能となる．しかしながら，受信コイルの感度を正確に求めることは難しく，CHAIPIRINA[2]などの改良法が提案されているが，SMS には課題が残っている．

我々はホログラフィの原理を使用し，2 次元収集信号から任意の断面に焦点を合わせることのできる撮像法を提案している[3]．本研究では，汎用のフーリエ変換映像法に応用可能な形式の新たな SMS を提案する．本法では，位相エンコード時に与える位相変調を手掛かりに畳み込みニューラルネットワーク(CNN)がスライス像を分離するのでスライス像の分離に受信コイルの感度分布を使用しない．そのため g ファクタにより不均一な雑音特性が生ずに安定した再構成が可能な SMS が期待できる．本研究では，提案する SMS についてシミュレーションにより基礎的な検討を行い，さらに初期の実験により有効性を評価すること目的とする．

2. フーリエ変換ホログラム型 SMS

ここでは，3 枚のスライスの同時撮像を考える．図 1 にパルスシーケンスを示す．スライス 1 のみを励起する RF-1 パルス

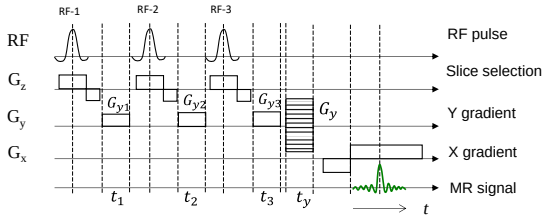


図 1．提案する SMS のパルスシーケンス

を印加した後に勾配磁界 G_{y1} を適用すると，スライス 1 のみに位相変調が与えられる．次にスライス 2 のみを励起する RF-2 パルスを印加した後に勾配磁界 G_{y2} を適用する．すると，スライス 2 とすでに励起済のスライス 1 に位相変調を与えることができる．このときスライス 1 には G_{y1} と G_{y2} に与えた位相変調が加算される．スライス 3 に対しても同様にして位相変調を与え，通常のフーリエ変換映像法の撮像を行うと，3 枚のスライス像の信号が合算された式(1)の信号が得られる．

$$v(t, G_y) = \iint_{-\infty}^{\infty} \{\rho(x,y,z_1)e^{-j\gamma(G_{y1}yt_1+G_{y2}yt_2+G_{y3}yt_3)} + \rho(x,y,z_2)e^{-j\gamma(G_{y2}yt_2+G_{y3}yt_3)} + \rho(x,y,z_3)e^{-j\gamma G_{y3}yt_3}\} e^{-j\gamma(G_x tx+G_y t_y y)} dxdy \quad \cdots (1)$$

ここで $k_i = \gamma G_{yi} t_i$ (i は整数)とし，スライス 1 に焦点を合わせるために $e^{j\gamma(G_{y1}yt_1+G_{y2}yt_2+G_{y3}yt_3)}$ を乗じた像は式(2)となる．

$$\rho(x,y,z_1) = \rho(x,y,z_1) + \rho(x,y,z_2)e^{jk_1 y} + \rho(x,y,z_3)e^{j(k_1+k_2)y} \quad \cdots (2)$$

式(2)に示すように求めたい第 1 項の像に第 2 項と第 3 項が重畳された形とる．与式は式(1)の一つしかないので 3 枚のスライス像を分離することは劣決定問題であり，通常は解くことができない．本研究では深層学習を利用し，焦点面の像成分を抽

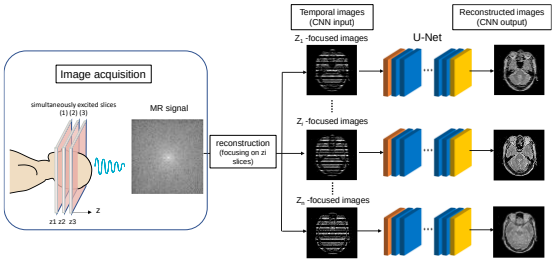


図 2 フーリエ変換ホログラム型 SMS の概念図

出する.

3. U-Net を使用した画像分離

図 2 にスライス分離の概念図を示す. 式(2)のように各スライスに焦点を合わせた再生像(以降, 一次再生像)より焦点面のみを取り除くために畳み込みニューラルネットワーク（U-Net[4]）を使用した. CNN の入力画像には一次再生像を使用し, 出力である教師画像には目標とするスライス位置の画像を使用した. 基礎検討としてスライス像毎に CNN を用意し, 学習を行った.

4. 再構成シミュレーション

3 枚のスライス画像を同時撮像する場合に各スライス像に与える位相変調係数を k_{m1}, k_{m2}, k_{m3} とし, 位相変調係数の差 ($k_{m3}-k_{m1}$)と再構成像の平均 PSNR の関係を図 3(a)に示す. 実関数画像は IXI[5]データセットを, 位相画像は fastMRI[6]データセットを使用した. 図 3 より位相変調の差を大きくすると PSNR が高くなる傾向が示された. これは, CNN が位相変調を手掛かりにスライス像を分離するためだと考える. 同時撮像枚数と PSNR の関係を図 3(b)に示す. 同時撮像枚数を増やすと PSNR が低下する理由は, 撮像枚数を増やすと隣接する位相変調係数の差が小さくなるためと考える. 同時撮像枚数を 2 枚から 4 枚とし, スライス像 1 に焦点を合わせた像を図 4 に示す. (a)から(d)はシミュレーションに使用した 4 枚のスライス像, (e)から(g)は再構成像, (h)から(j)は目標画像との差画像である. 同時撮像枚数が増えると誤差が大きくなるが, 隣接する像の影響が大きくなることはなかった. 図 5 は位相を含む複素画像に同時撮像 3 枚の シミュレーション実験を行った結果である. 図 3 より複素画像の場合は実関数画像より PSNR が低下する傾向が示されたが, 位相画像の場合もスライス像を

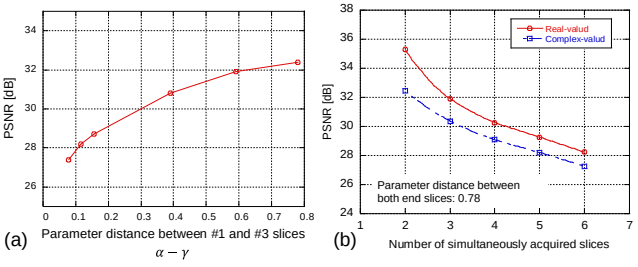


図 3 位相変調係数と同時撮像枚数に対する PSNR 特性

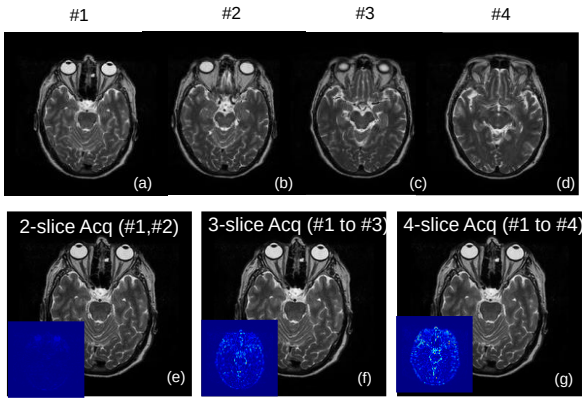


図 4 同時撮像枚数と再生像の関連(スライス像 1 に合焦)

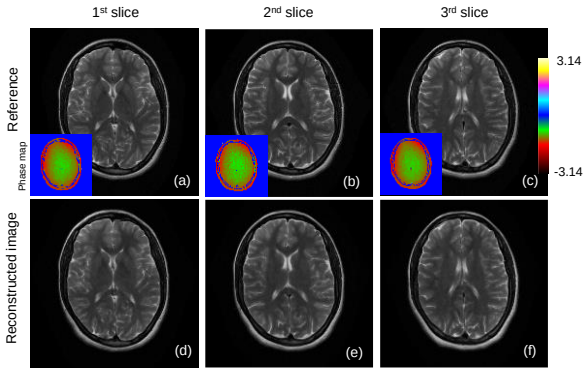


図 5 位相画像への適用(同時撮像 3 枚 SMS)

分離できる可能性が示された. 本法は不十分な計測データをデータ駆動科学で補う点で計測と信号処理を融合した新たな SMS と考える. 今後は単一 CNN による同時再構成や MRI を使用した実験を行う予定である.

5. まとめ

スライス像の分離に深層学習を利用する新しい MR マルチスライス撮像法を提案し, シミュレーション実験により有効性を評価した. 実関数画像, 位相画像ともに単一の MR 信号から複数のスライス像を同時に再生取得できる可能性が示された.

謝辞

本研究の一部は, 科研費(23K03864), 医科学応用財団, 萩原科学技術財団の助成を受けて行われた. MR 画像の使用に際し, IXI, fastMRI 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] K. P. Prussmann, Magn. Reson. Med., vol. 42, pp.952-962, 1999

[2] F. A. Breuer, Magn. Reson. Med., vol. 53, pp. 684-691, 2005

[3] S. Ito, Y. Yamada, 7th International Society for Magnetic Resonance in Medicune(ISMRM2004), Kyoto Japan, no. 351, 2004

[4] O. Ronneberge, International conference on medical image computing and computer-assisted intervention. Springer; 2015. pp. 234-241.

[5] Imperial College London. IXI dataset. https://braindevelopment.org/ixi-dataset/

[6] J. Zbontar, et al. https://doi.org/10.48550/arXiv.1811.08839, 2018

生成型 X-Q 空間学習による拡散尖度イメージングパラメタの推定

増谷 佳孝[*1]，一関 雄輝[*1]，紺谷 昂生[*1]
[*1] 東北大学大学院医学系研究科

Parameter Inference for Diffusional Kurtosis Imaging by Synthetic X-Q Space Learning

Yoshitaka MASUTANI[*1]，Yuuki ICHINOSEKI[*1]，Kousei KONYA[*1]
[*1] *Tohoku University Graduate School of Medicine*

要旨：拡散尖度イメージングを含め，拡散 MRI の信号値モデルパラメタの推定は一般に voxel-by-voxel で行われる．本研究では，推定されたパラメタマップの空間的滑らかさの向上を目的として，生成型 Q 空間学習に空間正則化を導入した生成型 X-Q 空間学習の手法を提案する．すなわち，パラメタ推定対象位置の Q 空間の信号群に加え，近傍の信号群を入力に追加した X-Q 空間データを入力とすることでパラメタ推定の頑健性を向上させる．学習データとなる X-Q 空間の信号の元となるパラメタの局所空間分布は２次元の 3×3 のパターンとし，２次までの多項式近似による基底パターンの線形和により生成する．拡散尖度イメージングのパラメタ推定を例として学習データの合成，パラメタ推定の性能評価を行うことを本研究の目的とする．
キーワード：拡散 MRI，信号値モデル，パラメタ推定，生成型 Q 空間学習，生成型 X-Q 空間学習

1. はじめに

拡散 MRI（diffusion MRI: dMRI）とは，水分子の移動検出の強さや方向を変えた複数の傾斜磁場（motion probing gradient: MPG）を用いた拡散強調像（diffusion weighted image: DWI）群の撮像法を指し，組織の局所特徴をパラメトリックに記述した信号値モデルにより微細構造や機能などの定量的特徴を得ることができる[1]．拡散尖度イメージング（diffusional kurtosis imaging: DKI）のモデルでは，パラメタとして微細構造による水分子の拘束に起因する拡散の非ガウス性としての拡散尖度および拡散係数が各ボクセル位置において定量値として得られる．パラメタの推定は，一般的には複数の DWI 信号へのモデルのフィッティングが使用されるが，近年では機械学習により推定の頑健性や計算速度の向上を目指す試み[2]が報告され，様々なモデルに適用されている[1]．筆者らは，合成データのみで学習を行う生成型 Q 空間学習（synthetic Q-space learning: synQSL）の手法を提案し，その有効性を検証してきた[3]．フィッティングを含めパラメタ推定は基本的に voxel-by-voxel で行われるが，生体組織の特徴の空間的連続性を考慮すると，空間的な正則性を仮定することで推定の頑健性の向上につながると考えられる．そこで，筆者は周辺の情報を含めて入力とした生成型 X-Q 空間学習（synthetic XQ-space learning: synXQSL）の手法を提案し，DKI パラメタの推定においてその有用性を検証したので報告する．

2. 方法

生成型 X-Q 空間学習では，パラメタ推定対象位置の Q 空間データ，すなわち異なる MPG 設定の複数の信号値群に加え，近傍の Q 空間データを追加した X-Q 空間データを合成して，学習処理に使用する．以下では，その合成方法，学習・テスト処理，評価実験方法について述べる．

1）X-Q 空間データの合成

本研究では，２次元の 3×3 のパターンでパラメタの局所空間分布を定義し，２次までの多項式近似による基底パターンの線形和により生成する．まず，基準信号値：S_0，拡散係数：D，および拡散尖度：Kを一定範囲の乱数で生成して 3×3 の領域内で均一に設定する．次に，これらのパターンに対して図 1 に示す５つの基底パターンに対する係数を一定範囲の乱数で各パラメタ独立に発生させて線形結合し，元の均一なパターンとの和により局所変化を含む各パラメタのパターンを得る．これらの基底は実データの調査[4]に基づき決定した．最後に，3×3 の各位置において以下の DKI 信号値モデル式により複数の b 値に対する信号値に変換して Rice 雑音[5]を重畳し，正解のDおよびKと合わせて学習データ 1 セットを完成させる．

$$S(b) = S_0 \exp\left(-bD + \frac{1}{6}b^2D^2K\right) \qquad (1)$$

ここでSは DWI 信号値，bは MPG 強度を示す b 値であり，本研究では$b = 0, 50, 850, 1000, 1500, 2000, 2500$ s/mm^2 の 7 種を使用した．

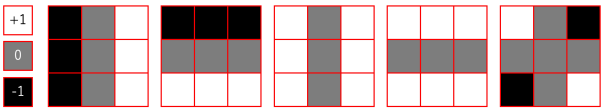


図 1 パラメタの局所パターンを構成する５つの基底

2）学習処理

1)の手順に従って 10^6 セットの合成データを生成するが，乱数のシードを変えて訓練用，検証用，テスト用の３種を作成した．また，基準信号値の平均：$\overline{S_0}$に対する Rice 雑音のσの比を雑音比（noise ratio: NR）と定義し，$NR = \sigma/\overline{S_0} = 0.000, 0.001, 0.010, 0.100$の４種を設定した．パラメタの推定は$D$と$K$の各パラメタを独立に出力する多層パーセプトロン（multi-layer

perceptron: MLP）を用い，中間層の層数およびユニット数などのハイパーパラメタをチューニングした．また，3)の評価実験での比較対象となる synQSL での同様のデータセットの作成，および学習処理を行なった．

3）評価実験

synQSL との比較により評価を行う．まず，学習データとテストデータの全ての NR の組み合わせによる RMSE で定量評価した．また，正解のパラメタが既知であるデジタルファントム画像データによって視覚的および定量的に評価を行なった．このファントムは 128×128×128 のマトリクスサイズで複数のS_0，D，Kの組み合わせパターン[6]を持つ．本研究では$NR = 0.100$の Rice 雑音を付加したものでパラメタ推定を行なった．

3. 結果

合成データでの RMSE 評価では，D（図 2 上）およびK（同下）の推定において，雑音の多い（$NR = 0.100$）データで synQSL に対する synXQSL の明確な RMSE 低減効果が確認された．また，以前の synQSL での報告[3]と同様にテストデータに合わせた NR のデータでの学習時に RMSE が最小となる現象が synXQSL でも確認できた．デジタルファントムによる実験（図 3）においては，パラメタマップの空間変化が大きい箇所（矢印の箇所など）で synXQSL の大きなDの推定エラーが確認されたが，パラメタの均一な部分での定量評価においてはKの推定で synXQSL による改善効果が確認された．

4. おわりに

生体特徴の連続性を考慮して周辺の信号値を入力に追加することで dMRI パラメタ推定の頑健性向上を目指す synXQSL の手法を提案した．synQL との比較を DKI モデルのパラメタ推定で行なったところ一定の改善効果が確認された．現在，臨床画像データでの検証を行なっており，視覚による評価で有用性が示唆されている．今後は，X-Q 空間データの生成法の詳細な検討や他の信号値モデルへの適用などを行う予定である．

謝辞

本研究の一部は JSPS 科研費 21K12650 によるものである．

利益相反の有無

なし．

文　献

［1］Masutani Y: Recent advances in parameter inference for diffusion MRI signal models, Magn Reson Med Sci 21:132-147, 2022

［2］Golkov V, Dosovitskiy A, Sperl JI, et al: q-space deep learning: twelve-fold shorter and model-free diffusion MRI scans. IEEE Trans Med Imag 35:1344-1351, 2016

［3］Masutani Y, Noise level matching improves robustness of diffusion MRI parameter inference by synthetic q-space learning. IEEE 16th International Symposium on Biomedical Imaging (ISBI), Venice, Italy, Apr, 2019

［4］増谷佳孝: 生成型 X-Q 空間学習のための拡散強調像および拡散 MRI パラメタマップの局所パターン解析，第 49 回日本磁気共鳴医学会大会，横浜, 2021 年 9 月

［5］Jensen JH, Helpern JA, Ramani A, et al: Diffusional kurtosis imaging: the quantification of non-gaussian water diffusion by means of magnetic resonance imaging. Magn Reson Med 53:1432-40, 2005

［6］Masutani Y, Aoki S: Fast and robust estimation of diffusional kurtosis imaging (DKI) parameters by general closed-form expressions and their extensions. Magn Reson Med Sci 13:97-115, 2014

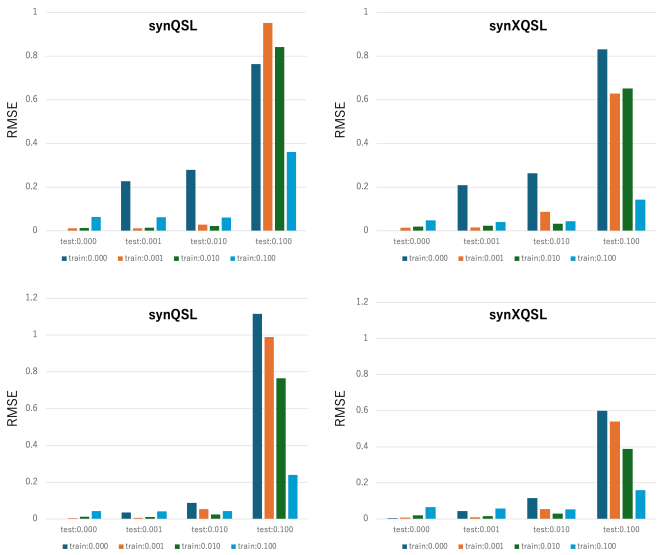


図 2 合成データによる RMSE の比較（上：$D \times 10^3$ mm^2/s，下：K）

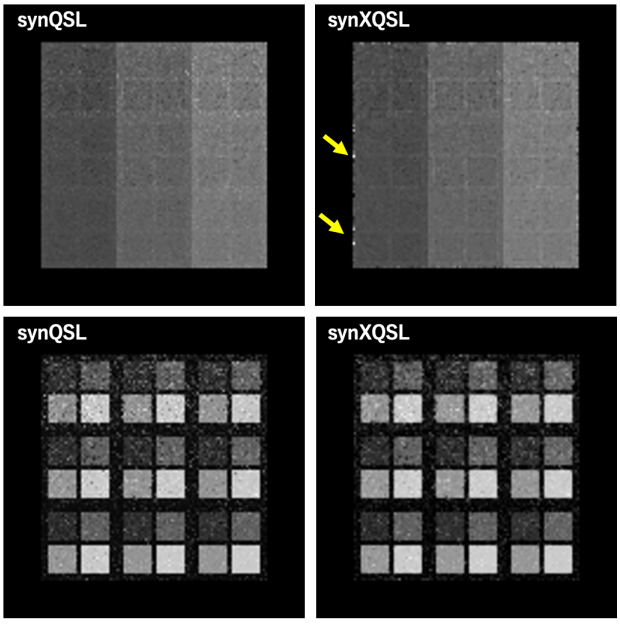


図 3 デジタルファントムにおける推定結果（左：D，右：K）

MRI を用いたラット肝臓の定量的磁化率マッピングにおける手法検討

中村　浩也[*1]，山口　雅之[*2]，寺田　康彦[*1]
[*1] 筑波大学大学院　理工情報生命学術院　数理物質科学研究群
[*2] 国立がん研究センター　先端医療開発センター　機能診断開発分野

Methods in quantitative susceptibility mapping of rat liver using MRI

Hiroya Nakamura[*1], Masayuki Yamaguchi [*2], Yasuhiko Terada [*1]
[*1] *Graduate School of Science and Technology, University of Tsukuba*
[*2] *National Cancer Center Hospital East, Department of Diagnostic Radiology*

要旨：磁気共鳴画像法（MRI）を用いた肝臓の造影検査に用いられる超常磁性酸化鉄（SPIO）は，正常な肝臓内とがん化した肝臓内で蓄積量が異なる．そのため，この蓄積量の推定ができれば，がん化の定量評価につながると期待される．しかし，この肝臓内の SPIO の定量化手法はいまだ確立されていない．そこで，近年注目されているのが，MRI の位相画像から磁化率画像を得る，定量的磁化率マッピング（QSM）である．一般に QSM は，一つの静磁場方向で撮像する Morphology enabled dipole inversion（MEDI）法と，複数の静磁場方向で撮像する Calculation of Susceptibility through Multiple Orientation Sampling（COSMOS）法などが採用される場合が多い．本研究では，SPIO 投与下のラット肝臓を対象とした QSM の各再構成手法の有効性の検証を目的とした．その結果，ラット肝臓内の SPIO の微小な位相変化に対しては MEDI 法が有効であることが示された．本研究により，QSM による肝臓内の SPIO 定量化の可能性が示された．

キーワード：定量的磁化率マッピング（QSM），ラット肝臓，SPIO

1. はじめに

MRI を用いた肝臓の造影検査に用いられる SPIO は，正常な肝臓とがん化した肝臓で蓄積量が異なる．そのため，この蓄積量の推定を行うことができれば，がん化の定量評価につながると期待される[1]．しかし，この肝臓内の SPIO の定量化手法はいまだ確立されていない．そこで，近年注目されているのが，定量的磁化率マッピング（QSM）である．QSM は，MRI 撮像によって得られた位相画像から，磁化率の分布を画像化する手法である．本研究では，SPIO 投与下のラット肝臓を対象とした QSM の再構成手法の有効性の検証を目的とした．

2. 方法

2.1 実験装置

4.7 T 縦型超伝導磁石（QXFORD, 201.850 MHz/89 mm bore）と内径 30 mm の高周波（RF）プローブを用いた．

2.2 撮像サンプル

SPIO の磁化率値を調べるために，内径 27.5 mm，高さ 60 mm の試験管内に，異なる濃度の SPIO（0.1, 0.3, 0.5, 0.7, 0.9 mMFe）をアガロースゲルで固定したファントム（SPIO ファントム）を用意した．

また，同様の試験管内に 0.5 mMFe の SPIO を投与したラット肝臓（SPIO 肝臓）と SPIO を投与していないラット肝臓（reference）をアガロースゲルで固定したものを 4 サンプルずつ用意した．

さらに，背景磁場成分の情報を得るために，同様の試験管内にアガロースゲルのみを満たしたファントム（ゲルファントム）を用意した．

2.3 実験方法

3D グラディエントエコー法を利用した．すべてのサンプルの撮像は voxel size = 250×250×250 μm^3，TR = 200 ms，TE = 2.5 ms で行った．また，撮像サンプルを静磁場に対して 0°，60°，120°と回転させ，撮像を行った．

2.4 解析方法

まず，背景磁場成分の除去をするため，撮像した SPIO ファントム，SPIO 肝臓，reference の位相画像から，ゲルファントムの位相画像を減算した．その後，MEDI[2]，COSMOS[3]法により QSM 再構成を行って磁化率画像を求めた．

2.4.1 MEDI

１つの静磁場方向の位相画像を用いて磁化率画像を求める手法であり，本研究では 0°の撮像データを用いて磁化率画像を求めた．また，MEDI の正則化パラメータは $\lambda=5\times10^{-9}$ に設定した．

2.4.2 COSMOS

異なる複数の静磁場方向の位相画像を用いて磁化率画像を求める手法であり，本研究では 0°，60°，120°の 3 つの撮像データを用いて磁化率画像を求めた．磁化率画像を求める際には，３つの撮像データの位置を合わせるために DIPY[4]によるレジストレーションを行った．レジストレーションの操作には，回転と平行移動を使用した．

3. 結果と考察

図１に MEDI と COSMOS による QSM 結果を示す．どち

らの場合も，SPIO 肝臓内の磁化率を計測することができた．また，reference は SPIO による位相変化がないため，肝臓内で磁化率値の変化はほとんど見られなかった．MEDI と COSOMOS を比較すると，MEDI の方がアーチファクトの少ない画像を得られた．これは，MEDI は位置合わせを必要としないのに対し，COSMOS はレジストレーション処理で３方向の位相画像を位置合わせする際に，位相画像が平滑化され，QSM 再構成が正確にできなかったためであると考えられる．

図２では，MEDI の方が，SPIO 濃度と磁化率が比例関係に近い結果を得ることができた（赤線）．COSMOS はアーチファクトの影響を受け，ばらつきのある結果となった．MEDI の場合，SPIO 肝臓に投与した濃度と同じ濃度（0.5 mMFe）での SPIO の磁化率の平均値は 2.58 ppm であった．これは，表１に示す４つの SPIO 肝臓内の磁化率値と近い値となった．そのため MEDI では，SPIO ファントムの定量結果と比較することで，ラット肝臓内のおおよその SPIO 濃度を推定することが可能である．一方，COSMOS では，アーチファクトによって４つの SPIO 肝臓内の磁化率値にばらつきがあるため，SPIO 濃度を定量することが困難である．

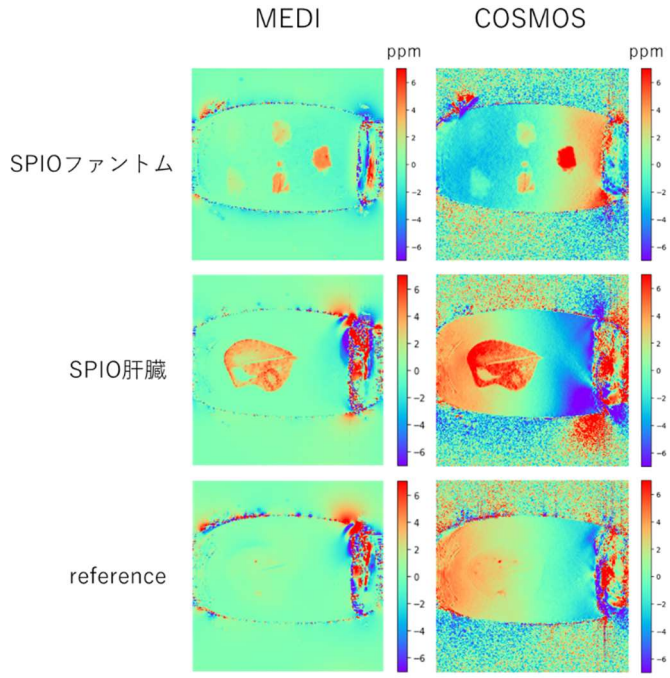


図１　MEDI と COSMOS による QSM 結果

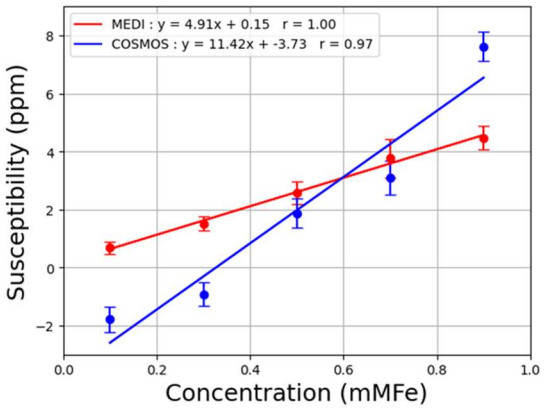


図２　SPIO ファントムにおける SPIO 濃度と磁化率の関係

表１　４つの SPIO 肝臓内の磁化率値

		SPIO1	SPIO2	SPIO3	SPIO4
MEDI	平均値 [ppm]	2.20	3.24	2.23	3.17
	標準偏差 [ppm]	0.88	1.06	0.99	1.01
COSMOS	平均値 [ppm]	0.53	1.86	2.35	5.05
	標準偏差 [ppm]	0.92	1.26	0.89	1.31

4. まとめ

本研究により，MEDI 法においてラット肝臓内のおおよその SPIO 濃度を推定することが可能となった．そのため，SPIO を投与したラット肝臓内の QSM において，MEDI 法が有効であることが示された．今後は，SPIO 濃度を変えたラット肝臓の QSM をしていく予定である．

利益相反の有無

なし．

文　献

[1] T. Furuta, M. Yamaguchi, M. Minami, O. Abe, and H. Fujii, “Treatment margins in radiotherapy for liver tumors visualized as T2*-hypointense areas on SPIO-enhanced MRI at 9.4 T,” *MAGMA*, vol. 33, no. 5, pp. 701–712, Oct. 2020.

[2] T. Liu *et al.*, “Morphology enabled dipole inversion (MEDI) from a single - angle acquisition: Comparison with COSMOS in human brain imaging,” *Magnetic Resonance in Med*, vol. 66, no. 3, pp. 777–783, Sep. 2011.

[3] T. Liu, P. Spincemaille, L. De Rochefort, B. Kressler, and Y. Wang, “Calculation of susceptibility through multiple orientation sampling (COSMOS): A method for conditioning the inverse problem from measured magnetic field map to susceptibility source image in MRI,” *Magnetic Resonance in Med*, vol. 61, no. 1, pp. 196–204, Jan. 2009.

[4] J. Kong, R. Giridharagopal, J. S. Harrison, and D. S. Ginger, “Identifying Nanoscale Structure–Function Relationships Using Multimodal Atomic Force Microscopy, Dimensionality Reduction, and Regression Techniques,” *J. Phys. Chem. Lett.*, vol. 9, no. 12, pp. 3307–3314, Jun. 2018.

勾配加重クラス活性化マッピング(Grad-CAM)を用いたMRIモーションアーチファクト分類の位相方向による影響

赤沼　優文[*1]，臼井　桂介[*1]，有田　晃大[*1]，坂本　肇[*1]，
坂野　康昌[*1]，京極　伸介[*1]，代田　浩之[*1]
[*1] 順天堂大学大学院保健医療学研究科

Phase-Oriented Effects of MRI Motion Artifact Classification Using Gradient-Weighted Class Activation Mapping (Grad-CAM)

Masafumi AKANUMA[*1]，Keisuke USUI[*1]，Akihiro ARITA[*1]，Hajime SAKAMOTO[*1]，Yasuaki SAKANO[*1]，Shinsuke KYOGOKU[*1]，Hiroyuki DAIDA[*1]
[*1]*Department of Radiological Technology, Graduate school of Health Science, Juntendo University*

要旨：MRI のモーションアーチファクトは強度や発生方向が異なり，画像診断の妨げとなる．一方で転移学習にて分類モデルを作成し Grad-CAM を用いることでその分類理由を明らかにできる．先行研究では，アーチファクトが強いほど強く反応したが位相方向への影響は不明であった．本研究では，位相方向毎にモデルを作成し Grad-CAM の結果に及ぼす影響を検討した．25 例の頭部 MRI 画像の T2 強調像を用い，アーチファクト有りの画像をシミュレーションにより 9000 枚作成した．70%を学習データ，30%を検証データとし，GoogLeNet を使用した転移学習を行った．位相方向が縦横モデルのテスト精度は 91.5%，縦モデルは 96.4%，横モデルは 96.7%であり，縦横モデルが最も低かった．Grad-CAM の結果にはモデルの特徴が現れており，縦横モデルにおいては位相方向による影響が見られなかった．

キーワード：モーションアーチファクト，Grad-CAM，頭部 MRI，深層学習

1. はじめに

磁気共鳴画像診断像（Magnetic resonance imaging: MRI）に発生するモーションアーチファクトは，画像取得中の体動や呼吸，血流が原因となり，そのアーチファクトの強度や方向が異なる．これまでに転移学習を用いた画像分類が実施され［1］，このモーションアーチファクトの分類においても有効であることが判明している．人工知能（Artificial Intelligence: AI）によるモーションアーチファクト画像の検出においては，その判断理由を明確にすることで，術者の信頼を得ることができる．そこで，AI の判断理由を可視化することのできる勾配加重クラス活性化マッピング（Graddient-weighted Class Activation Mapping:Grad-CAM）を用いることで［2］，モーションアーチファクト画像の判定理由が明確化できる．一方で，モーションアーチファクトは設定する位相方向によって出現方向が異なり，これは分類精度に影響を与える可能性がある．また，モーションアーチファクトの発生方向の違いは Grad-CAM の解析結果に差が生じる可能性がある．本研究では，仮想的なモーションアーチファクト画像を作成し，GoogLeNet を用いた転移学習によってアーチファクト発生方向別の分類精度を検証した．さらに，Grad-CAM を併用し AI の判定根拠が位相方向の違いに与える影響を明らかにした．

*1　順天堂大学保健医療学研究科診療放射線学専攻
〔〒113-8421 東京都文京区本郷 2-1-1〕
e-mail:fhs8424001@juntendo.ac.jp

2. 方法

1）モーションアーチファクト画像の作成

Open Access Series of Imaging Studies (OASIS)で取得したアルツハイマー型認知症の頭部 MRI 画像（624 枚）に対し［3］，塚本らの手法を用いてモーションアーチファクト画像を作成した［4］．本手法では，モーションアーチファクトのない T2 強調画像を上下左右斜め方向に 1 ピクセルずつ±5 ピクセル移動させ，また 0.5°ずつ±5°の回転運動で移動させることで計 50 種類の移動画像を作成した．これをフーリエ変換し，k 空間のデータを取得した．これらの k 空間のデータをランダムに再配置し，逆フーリエ変換することでモーションアーチファクト画

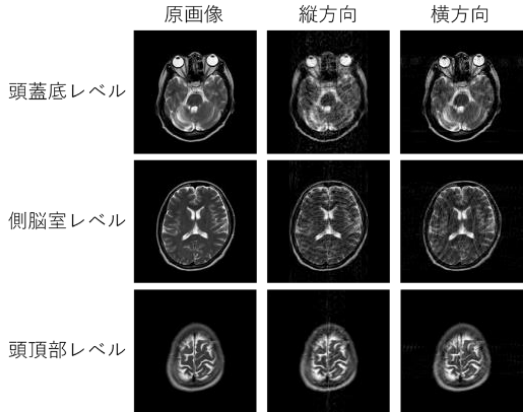


図 1 原画像と位相方向別のモーションアーチファクト画像

像を作成した. 図 1 に高さレベルの異なる位置の原画像と各位相方向に作成したモーションアーチファクト画像を示す.

2）分類モデルの作成

作成したモーションアーチファクト画像と原画像を用いて, GoogLeNet による転移学習を行い, 分類モデルを作成した. 図 2 に GoogLeNet を用いた転移学習の概略を示す. アーチファクト発生方向別にモデルを作成し, 縦と横方向を併せたものをモデル 1, 縦方向のみ使用したものをモデル 2, 横方向のみ使用したものをモデル 3 とした. 各々, 学習データは 12600 枚, 検証データは 5400 枚, テストデータは 720 枚で実施した.

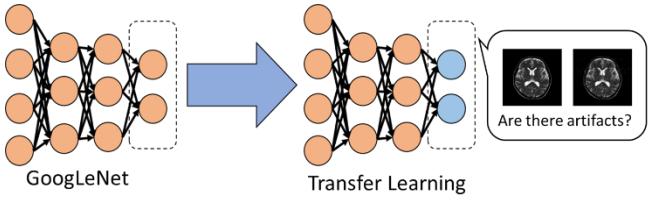


図 2 GoogLeNet を用いた転移学習の概略

3）Grad-CAM による判断理由の評価

テストデータに使用したモーションアーチファクト画像の内, 正しく分類した画像のみ抽出し Grad-CAM を用いて注目箇所のヒートマップを取得した. 同一スライスでアーチファクトの強さが異なる画像のヒートマップを積算しアーチファクトの無い原画像に重ね合わせて表示した.

3. 結果と考察

表 1 に各モデルにおける検証精度とテスト画像に対する分類精度の結果を示し, 図 3 に頭蓋底・側脳室・頭頂部のレベルにおける, Grad-CAM の結果を各アーチファクト発生方向に分けて示す. 正解率および F 値の結果から, モデル 2, 3 が高い値を示したため, アーチファクトの発生方向と一致した学習モデルを使用することで, 精度よく分類できることが示された. 一方で, 再現率はモデル 1 が最も高い値を示したことから, アーチファクトを検出する能力は低くないものの, アーチファクトが無い画像を有りと分類するなどの偽陽性が増える可能性がある. 図 3 の結果から, Grad-CAM によりモーションアーチファクトの分類理由を可視化することができた. 頭蓋底レベルと側脳室レベルにおいて, モデル 1 では検出箇所に広がりを持つ形となり, アーチファクト発生の方向が判定しにくいが, モデル 2・3 では検出箇所が方向別に出現する傾向があり, アーチファクトの発生方向を理解しやすい. 一方で頭頂部レベルでは, モデル 1 においてもアーチファクトの発生方向と一致したヒートマップが検出されており, スライス毎に位相方向による影響の差が発生している.

4. 結語

AI による頭部 MRI 画像のモーションアーチファクト画像の分類における位相方向の影響を検証するため, シミュレーションで作成したアーチファクト画像と原画像を学習データとして, GoogLeNet を用いた転移学習による分類モデルを作成し, その影響を Grad-CAM を用いて評価した. その結果, 位相方向別に分類モデルを作成することで, モーションアーチファクトの発生方向を正しく検知し術者にわかりやすく表示できる.

表 1 各モデルにおける検証精度とテスト画像に対する分類精度

	検証精度	正解率	精度	再現率	F 値
モデル 1	99.7%	91.5%	85.6%	99.4%	92.2%
モデル 2	99.4%	96.4%	93.4%	96.5%	96.5%
モデル 3	99.3%	96.7%	94.7%	98.9%	96.7%

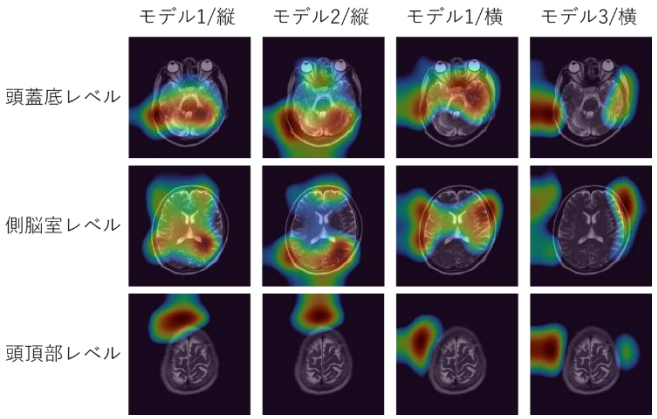


図 3 各モデルにおける Grad-CAM を用いたヒートマップ

利益相反の有無

なし

文　献

［1］ Szegedy, Christian, Wei Liu, et al: "Going deeper with convolutions." In Proceedings of the IEEE conference on computer vision and pattern recognition, 2015, pp. 1-9.

［2］R. R. Selvaraju, M. Cogswell, A. Das, et al: "Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization," 2017 IEEE International Conference on Computer Vision (ICCV), Venice, Italy, 2017, pp. 618-626.

［3］ Pamela J LaMontagne, Tammie L.S. Benzinger, John C. Morris, et al: " OASIS-3: Longitudinal Neuroimaging, Clinical, and Cognitive Dataset for Normal Aging and Alzheimer Disease ", 2019.

［4］ 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 77:2021,463-470.

弾性波画像の振幅対ノイズ比を利用した MR エラストグラフィ解析手法の改良

玉田　綾[*1]，菅　幹生[*1, 2]
[*1] 千葉大学　融合理工学府　医工学コース
[*2] 千葉大学　フロンティア医工学センター

Improvement of MR elastography analysis method using the amplitude-to-noise ratio of elastic wave images

Aya TAMADA[*1]，Mikio SUGA[*1, 2]
[*1] *Graduate School of Science and Engineering, Chiba University*
[*2] *Center for Frontier Medical Engineering, Chiba University*

要旨：MR エラストグラフィは，定量的に粘弾性を測定可能な手法である．測定では，外部加振装置により対象内に発生させた弾性波を MRI で画像化し，解析手法を適用することで弾性率画像を生成する．解析手法には弾性波画像の振幅対ノイズ比（amplitude-to-noise ratio: ANR）が低い領域では推定誤差が生じやすい課題がある．本研究では，弾性率画像の定量性改善のため，ANR を利用した解析手法を開発することを目的とした．粘弾性体伝播過程で反射や減衰することを想定した 3 次元弾性波画像を数値シミュレーションにより生成し，ガウスノイズを 5 段階の強度で加えた．誤差低減手法として ANR の閾値を設定し，低 ANR 領域を除いて弾性率を推定した．ANR の閾値を設定しない場合に対して閾値を設定した場合では弾性率画像に生じる誤差と変動係数が共に小さくなった．以上の結果より，ANR 閾値を利用した解析手法により定量性が向上することが示唆された．
キーワード：MR エラストグラフィ，MRI，MRE，振幅対ノイズ比，フィルタ処理

1. はじめに

生体組織の粘弾性率を非侵襲的かつ定量的に測定できる方法として magnetic resonance imaging (MRI)を利用した MR エラストグラフィ(magnetic resonance elastography: MRE) [1]がある．MRE は，はじめに MRI 装置内で外部加振装置を用いて撮像内部に弾性波を伝播させる．次に，変位エンコード傾斜磁場(motion encoding gradient: MEG)を含む MRE パルスシーケンスを用いて撮像することにより，弾性波を画像化する．最後に，得られた弾性波画像を解析することで粘弾性率を推定する．生体組織のように粘性のある対象では，弾性波は伝播する過程で減衰するため，加振領域から離れるほど振幅対ノイズ比(amplitude-to-noise ratio: ANR)が低下する．ANR が低下した領域では，粘弾性率推定誤差が生じやすい．本研究では，弾性率画像の定量性改善のため，ANR を利用した解析手法の開発を目的とし，数値シミュレーションで作成した 3 次元弾性波画像を用いてその効果を評価した．

2. 方法

2.1　シミュレーション概要

粘弾性体伝播過程で反射や減衰することを想定した 3 次元弾性波画像を数値シミュレーションにより生成した(図 1)．また，ガウスノイズを 5 段階の強度で加えた．次に，作成した弾性波画像から，式 1 を用いて振幅画像，式 2 を用いて ANR 画像を得た．

$$A_i = \sqrt{{W_{x,0}}_i^2 + {W_{x,90}}_i^2 + {W_{y,0}}_i^2 + {W_{y,90}}_i^2 + {W_{z,0}}_i^2 + {W_{z,90}}_i^2} \quad (1)$$

$$ANR_i = \frac{Amp_i}{SD} \quad (2)$$

A_i: 振幅画像，i: 画素番号
W_{D,θ_i} :弾性波画像，D: 変位方向(x, y, z)，θ: 初期位相角度
ANR_i: 振幅対ノイズ比画像
SD: 対象内ノイズ分布（加振なしで取得した弾性波画像）の標準偏差

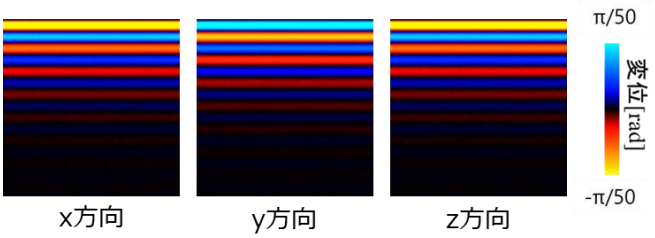


図 1　作成した弾性波画像

2.2　シミュレーション設定

シミュレーションパラメータを表 1 に示す．弾性波画像に 5 段階のレベルでガウスノイズを付加し，解析における ANR 閾値設定の有無と貯蔵弾性率推定誤差の関係を評価した．ANR 閾値を下回った領域は貯蔵弾性率画像において該当領域の値を削除した．弾性波画像から貯蔵弾性率の算出には積分型粘弾性率分布推定手法[2]を用いた．

表 1 シミュレーションパラメータ

弾性波シミュレータ	FOV	[mm]	384 × 384
	Matrix	[pixel]	128 × 128
	ピクセルサイズ	[mm]	3.0
	加振周波数	[Hz]	60
	想定弾性率	[kPa]	4.5
	加振振幅		1.0
	振動平面法線ベクトル		(0.0, 1.0, 1.0)
	加振変位ベクトル		(1.0, 1.0, -1.0)
	付加ノイズ標準偏差		0.01, 0.02, 0.03, 0.04, 0.05
フィルタ	ANR閾値		1, 2, 3, 4, 5, 6, 7, 8, 9

3. 結果

付加ノイズ強度 5 段階の結果画像を図 2 に示す．また，それぞれの貯蔵弾性率推定結果と標準偏差，ノイズを付加しない真値との誤差を図 4，図 5 に示す．関心領域は，ANR 閾値を設定しない場合は外周-4 pixel，ANR 閾値を設定する場合は ANR 閾値を超えた領域の外周-4 pixel とした．また，ノイズ SD0.05 の貯蔵弾性率分布に 9 段階の ANR 閾値を設定した場合のうち 5 段階の結果画像を図 3 に，それぞれの結果とノイズを付加しない真値との誤差と CV 値を図 6 に示す．

ANR 閾値を設定することで，弾性率の減衰により貯蔵弾性率推定誤差が強く生じている下部領域が測定領域から除外されることが確認できた．また，ノイズなしとの誤差は各ノイズレベルで ANR 閾値を設定しない場合と比較して最大で約 9.8 ポイント低下した．また，ノイズ SD0.05 の貯蔵弾性率分布に対して ANR 閾値を 1 から 9 に上げることで誤差は約 0.77 ポイント，CV 値は約 4.57 ポイント低下した．

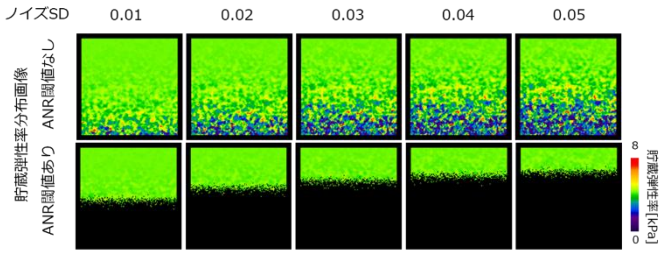


図 2 付加ノイズ強度別貯蔵弾性率分布（ANR 閾値=7）

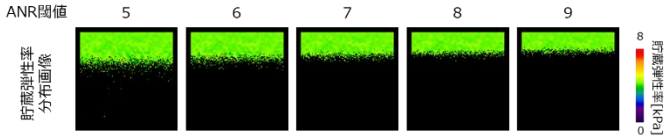


図 3 ANR 閾値別貯蔵弾性率分布（ノイズ SD=0.05）

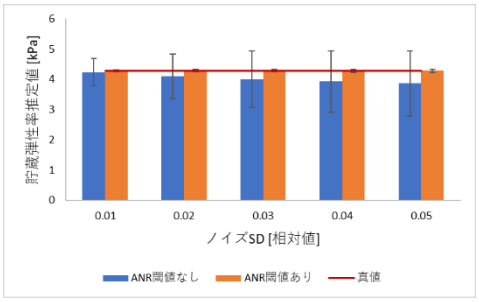


図 4 付加ノイズ強度別貯蔵弾性率推定値

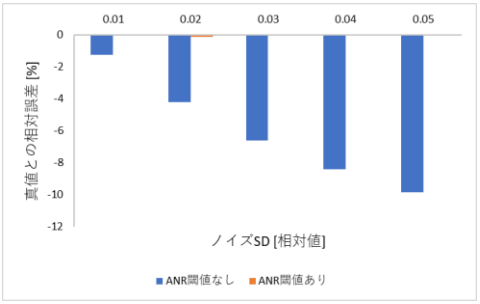


図 5 付加ノイズ強度別貯蔵弾性率推定誤差

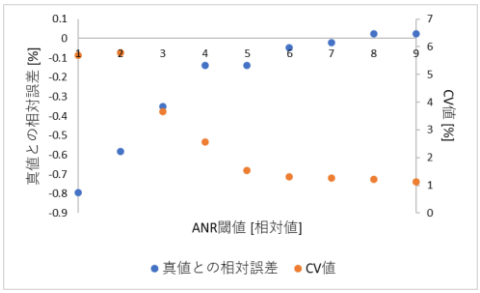


図 6 ANR 閾値別貯蔵弾性率推定誤差と CV 値

4. まとめ

3 次元の弾性波伝播を想定した弾性波画像から算出した ANR に閾値を設定することで，貯蔵弾性率推定誤差が低減できることが確認できた．

謝辞

研究遂行にあたりご助言を賜った富士フイルムの谷口陽様，富士フイルムヘルスケアの瀧澤将宏様，岡邦治様に深謝いたします．

利益相反の有無

なし

文　献

[1] Muthupillai R et al: Magnetic resonance elastography by direct visualization of propagating acoustic strain waves. Science 269:1854-1857, 1995

[2] Takeda T et al: Development of three-dimensional integral-type reconstruction formula for magnetic resonance elastography. Int J Comput Assist Radiol Surg 16:1947-1956, 2021

NOISE2VOID による脳 SPECT 画像の画質改善

草刈　颯太[*1]，成田　和陽[*2]，松岡　将宏[*3]，松原　佳亮[*4]，
越野　一博[*5]，渡部　浩司[*6]，湯浅　哲也[*3]，銭谷　勉[*1]
[*1] 弘前大学大学院理工学研究科　[*2] 弘前大学理工学部　[*3] 山形大学大学院理工学研究科
[*4] 秋田県立大学システム科学技術学部　[*5] 北海道情報大学経営情報学部
[*6] 東北大学先端量子ビーム科学研究センター

Improving Brain SPECT Image Quality by NOISE2VOID

Sota KUSAKARI[*1]，Kazuya NARITA[*1]，Masahiro MATSUOKA[*2]，Keisuke MATSUBARA[*3]，
Kazuhiro KOSHINO[*4]，Hiroshi WATABE[*5]，Tetsuya YUASA[*2]，Tsutomu ZENIYA[*1]，
[*1] *Hirosaki University*　[*2] *Yamagata University*　[*3] *Akita Prefectural University*
[*4] *Hokkaido Information University*　[*5] *Tohoku University*

要旨：SPECT 装置における空間分解能と検出効率はトレードオフの関係にあり，高解像度化に伴って検出効率が低下し，画像に生じるノイズ量は増加する．本研究では，ブラインドスポットネットワークによる自己教師あり学習を用いたノイズ低減手法である NOISE2VOID により SPECT 画像の画質改善を試みた．180 方向の投影画像で学習した NOISE2VOID ネットワークを用いて投影画像のノイズ低減を行い，処理後の投影画像を OS-EM 法により再構成した．シミュレーションによる脳数値ファントムの再構成画像では，エッジを保持しつつノイズが低減され，PSNR は 6.69 dB から 20.04 dB へ，SSIM は 0.443 から 0.836 へ大幅に向上した．開発中の高解像度 SPECT 装置を用いて撮像した脳物理ファントムの再構成画像においても，ノイズが大きく低減され，ファントムの構造が明瞭に描出された．

キーワード：SPECT，NOISE2VOID，画像再構成，ノイズ低減，自己教師あり学習

1. はじめに

SPECT（**s**ingle **p**hoton **e**mission **c**omputed **t**omography）は，目的の臓器ないし組織に集積した放射性標識薬剤から放出されるγ線を捉えることにより，体内の標識薬剤分布を画像化することのできるモダリティである．SPECT 画像は，血流や代謝，神経活動といった生体機能の評価に広く用いられており，現在の医療において大きな役割を担っている．

SPECT 装置における空間分解能と検出効率はトレードオフの関係にあり，高解像度化に伴ってγ線の検出効率は低下し，結果として，画像内のノイズ量は増加する．近年では，医用画像の分野においても深層学習を活用したノイズ低減手法が注目を集めている［1］が，一般的な深層学習では大量の教師データを必要とする．ゆえに，大量かつ高品質な教師データを収集することが難しい SPECT 画像への適用は困難である．そこで，我々は，ターゲット画像のみでノイズを低減することが可能な手法である deep image prior（DIP）［2］に着目し，DIP を用いたノイズ低減処理が，脳 SPECT 画像の画質改善に有効であることを示した［3］．

本研究では，さらなる画質改善を目指して，自己教師あり学習を用いたノイズ低減手法である NOISE2VOID（N2V）［4］に着目し，N2V を用いて脳 SPECT 画像のノイズ低減を行うことによって，その画質改善を試みた．

2. 方法

2.1 NOISE2VOID

N2V は，画像において信号は隣接する画素と高い相関関係にあるのに対し，ノイズは隣接画素との相関関係が低いことに根差したノイズ低減手法である．この観察に基づき，N2V では受容野に死角（blind spot）を持つ特殊な畳み込みニューラルネットワーク（CNN: **c**onvolutional **n**eural **n**etwork）である blind-spot network を用いる．死角に位置する画素をターゲットとし，その画素値を近傍の画素から予測することにより，ノイズ低減能力を獲得する．ノイズ低減は以下の最小化問題に帰着できる．

$$\arg\min_{\boldsymbol{\theta}} \sum_i L(f(\tilde{x}_i;\boldsymbol{\theta}), x_i) \tag{1}$$

ただし，$f(\cdot)$は CNN，$\boldsymbol{\theta}$はネットワークのパラメータ，$L(\cdot)$は最小 2 乗誤差（MSE: **m**ean **s**quared **e**rror），iは画素のインデックス，$\tilde{x}_i$は画素x_i近傍の受容野，x_iは死角に位置する画素である．

2.2 NOISE2VOID の SPECT 画像再構成への適用

SPECT 装置で収集されたすべての方向の投影画像で学習させた N2V ネットワークを用いて投影画像のノイズ低減を行い，N2V 処理後の投影画像を OS-EM（**o**rdered **s**ubsets-**e**xpectation **m**aximization）法により再構成する．

3. 実験

脳数値ファントムを用いたシミュレーションにより得られ

たデータ，および開発中の頭部用高解像度 SPECT 装置［5］で脳物理ファントムを撮像して得られた実測データの両方で N2V の画質改善効果を検証した．さらに，N2V 処理を経た再構成画像を，投影画像を直接 OS-EM 法で再構成したもの，OS-EM 法で再構成した画像にガウシアンフィルタ（GF: **G**aussian **f**ilter）を適用したもの，DIP を用いて処理した投影画像を OS-EM 法で再構成したものと比較した．

3.1 シミュレーションデータによる評価

脳数値ファントムから 180 方向の投影画像を作成した．投影画像を，実測画像と同程度のカウント（約6.89×10^6）となるように調整したうえで，ポアソン分布に従う統計ノイズを付加した．ノイズを含む投影画像を N2V 処理し，それらを OS-EM 法により再構成した（iteration : 10，subset : 5）．再構成画像は，視覚的に評価するのに加え，正解画像との間のピーク信号対雑音比（PSNR: **p**eak **s**ignal to **n**oise **r**atio）および構造的類似性指数（SSIM: **s**tructural **sim**ilarity）により定量的にも評価した．

3.2 実測データによる評価

人間の脳を精巧に模した脳物理ファントム［6］に対し，394 MBq の ^{99m}Tc 溶液を封入し，開発中の高解像度 SPECT 装置を用いて 180 方向より撮像した．得られた 180 枚の投影画像に対し，N2V 処理を施したものを OS-EM 法で再構成した（iteration：10，subset：5）．再構成画像は視覚的に評価した．

4. 結果

4.1 シミュレーションデータによる評価

図 1 に脳数値ファントムの再構成画像を示す．N2V 処理によってエッジを保持しつつノイズが大幅に低減され，ファントムの構造が明瞭に描出された．算出した PSNR と SSIM の値は表 1 の通りであり，PSNR，SSIM ともに N2V 処理を経たものが最も高い値を示した．

4.2 実測データによる評価

図 2 に，脳物理ファントムの再構成画像を示す．実測データにおいても，N2V 処理によってエッジを保持しつつノイズが大きく低減され，ファントムの構造が明瞭に描出された．

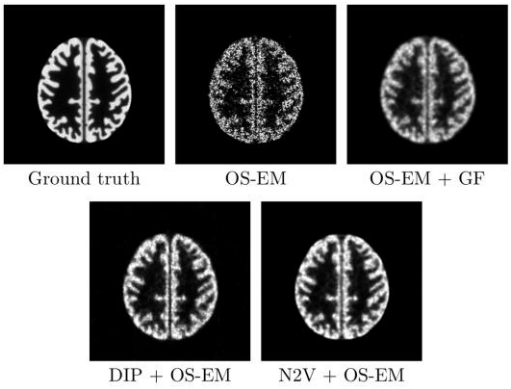


図 1　脳数値ファントムの再構成画像

表 1　脳数値ファントム再構成画像の PSNR と SSIM

手法	PSNR	SSIM
OS-EM	6.69 dB	0.443
OS-EM + GF	18.69 dB	0.726
DIP + OS-EM	18.96 dB	0.734
N2V + OS-EM	20.44 dB	0.835

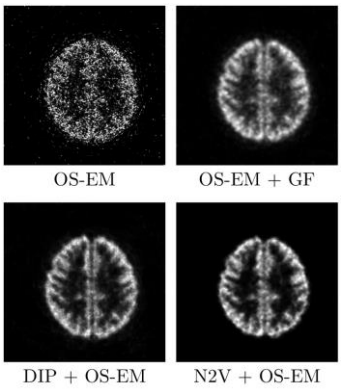


図 2　脳物理ファントムの再構成画像

5. まとめ

本研究により，N2V を用いたノイズ低減処理は脳 SPECT 画像の画質改善に有効であることが示唆された．加えて，N2V を用いたノイズ低減処理は，DIP を利用したノイズ低減処理と同等ないしそれ以上の効果を有することが示唆された．

謝辞

本研究は JSPS 科研費 JP22K19501 の助成を受けたものです．

利益相反の有無

なし

文　献

［1］K. Matsubara, M. Ibaraki, M. Nemoto, et al., “A review on AI in PET imaging,” Ann. Nucl. Med., vol. 36, no. 2, pp. 133–143, 2022.

［2］D. Ulyanov, A. Vedaldi, and V. Lempitsky, “Deep image prior,” International Journal of Computer Vision, vol. 128, no. 7, pp. 1867–1888, 2020.

［3］A. Yabe, Y. Tsushima, K. Fukuhara, et al., “Improve image quality of high spatial resolution SPECT by deep image prior,” in 2021 IEEE Nuclear Science Symposium and Medical Imaging Conference (NSS/MIC), 2021, pp. 1–3.

［4］A. Krull, T.-O. Buchholz, and F. Jug, “Noise2Void-learning denoising from single noisy images,” arXiv e-prints, pp. arXiv–1811, 2018.

［5］T. Zeniya, K. Gaku, Y. Hori, et al., “Development of high-resolution brain SPECT system using full-digital gamma camera with multiple position-sensitive pmts,” in 2015 IEEE Nuclear Science Symposium and Medical Imaging Conference (NSS/MIC), 2015, pp. 1–3.

［6］H. Iida, Y. Hori, K. Ishida, et al., “Three-dimensional brain phantom containing bone and grey matter structures with a realistic head contour,” Ann. Nucl. Med., vol. 27, pp. 25–36, 2013.

ピンホール SPECT イメージングにおける検出確率の近似手法の比較

縄野　勇大[*1]，尾川　浩一[*2]
[*1] 法政大学大学院理工学研究科
[*2] 法政大学理工学部

Comparison of methods for approximating probability of detection in pinhole SPECT imaging

Yudai NAWANO[*1]，Koichi OGAWA[*2]
[*1] *Graduate School of Science and Engineering, Hosei University*
[*2] *Faculty of Science and Engineering, Hosei University*

要旨：SPECT において，ML-EM 等の逐次的画像再構成法を用いる場合，画素と投影データの bin で決まる検出確率が重要となる．ジオメトリが複雑になると検出確率の計算が困難になるため，この値を近似的に求める方法が採用されるが，誤差が大きくなることが予想される．本研究では近似的に検出確率を求める方法と厳密に検出確率を求める方法を比較した．近似的に検出確率を求める方法として画素を横切る ray の長さで近似する ray-driven 法(Siddon の方法，Joseph の方法)，および検出器と画素との位置関係を計算に用いる distance-driven 法を用いた．本研究では，ピンホールジオメトリにおけるそれぞれの計算手法の検出確率を用いて，ML-EM 法による画像再構成を行い，シミュレーション結果から異なる検出確率の近似計算手法における再構成画像の違いを考察した．
キーワード：SPECT, ML-EM 法，検出確率，画像再構成

1. はじめに

統計的画像再構成の一つである ML-EM 法は画素と検出器の間の検出確率に基づいて画像再構成が行われる．この検出確率は，画素と bin の重った部分から面積を求めることで厳密に計算することができる．本研究では厳密に検出確率を求める AI 法(Area Integration method[1])，画素を横切る ray の長さで検出確率を近似する ray-driven 法(Siddon の方法[2]，Joseph の方法[3])，および検出器と画素との位置関係を計算に用いる distance-driven 法[4]による再構成画像の違いを，ピンホールジオメトリで比較した．

2. 検出確率の計算手法

それぞれの計算手法における検出確率の計算の概念を図 1 に示す．図 1(a)の AI 法では，$bin\ i$と画素jの重なりの厳密な面積C_{ij}を検出確率に用いる．図 1(b)の Siddon の方法では，画素と投影線との交差距離l_1が検出確率となる．図 1(c)の Joseph の方法では，投影線に対する 2 画素間の距離d_1, d_2と，1 画素と投影線が交差する距離の最大値Lを検出確率の算出に用いる．Joseph の方法における検出確率C_{ij}は以下のように表される．

$$C_{ij} = \frac{d_1}{d_1 + d_2} L \tag{1}$$

図 1(d)に示した Distance-driven 法では，基準となる軸に検出器と画素の境界を投影し，その位置関係から検出確率C_{ij}を計算する．ここでp_1, p_2は画素の境界を投影した位置，d_1, d_2は検出器の境界を投影した位置である．この時，画素jにおける$bin\ i$の検出確率C_{ij}は以下のように示される．

$$C_{ij} = \frac{p_2 - d_2}{\cos\beta(d_3 - d_2)} L \tag{2}$$

ここでβは投影線と画素とのなす角度である．

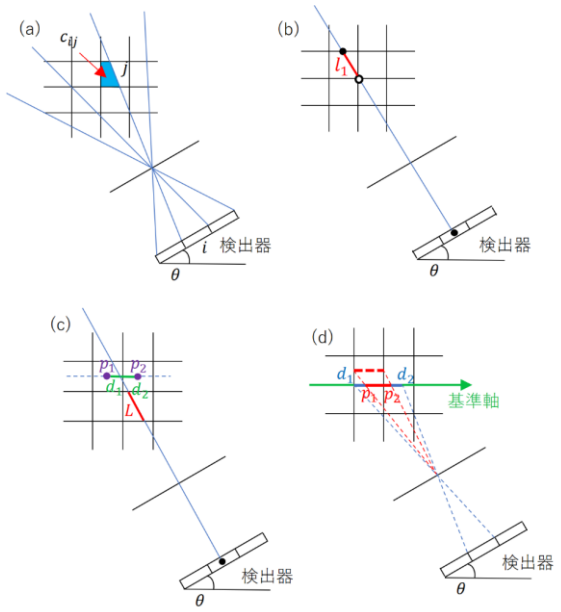


図 1　C_{ij}の計算手法 (a)AI 法，(b)Siddon の方法，(c)Joseph の方法，(d)distance-driven 法

3. シミュレーション条件

それぞれの検出確率の近似計算手法に対する再構成画像の評価のため，ピンホール SPECT のジオメトリでシミュレーションを行った．ファントムは Shepp Logan phantom，ファン

トムの中心からピンホールコリメータまでの距離は 18.9 cm，ファントムの中心から検出器までの距離は 22.65 cm とし，コリメータ径は無限小，コリメータの厚さは無限小，検出器は 1100 pixels，検出器のピクセルサイズは 0.025 mm，投影数は 360 とし，画像サイズは 128 ×128 pixels，画素サイズは 0.1 cm × 0.1 cm とした．

3. シミュレーション結果と考察

図 2 にシミュレーションに用いた原画像とそれぞれの計算手法を用いた，ML-EM 法による反復回数 1000 回の再構成画像を示す．

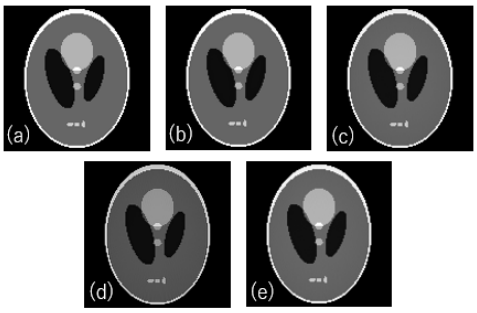


図 2　再構成画像の比較 (a)原画像, (b)AI 法, (c)Siddon の方法, (d)Joseph の方法, (e)distance-driven 法

図 2 では手法の違いを判断するのが困難なため,それぞれの計算手法における再構成画像と原画像との誤差画像を計算した(図 3)．図 3 では，最小値 0，最大値 5 として表示している．図 4 に誤差画像の$y = 64$の位置でのプロファイルを示す．図 5 に再構成画像と原画像との root mean squared error(RMSE)を示す．

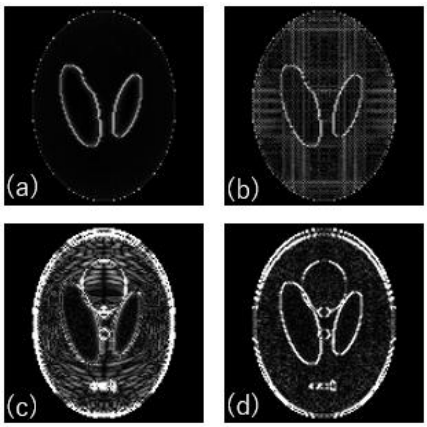


図 3　誤差画像の比較 (a)AI 法, (b)Siddon の方法, (c)Joseph の方法, (d)distance-driven 法

図 5 から，AI 法に次いで Siddon の方法による再構成画像の精度が若干良いことを示している．AI 法の近似手法において，本研究で比較した 3 つの手法の中で Siddon の方法が最も簡易的な計算手法であり，他の手法よりも良い結果となった．また，検出確率における計算時間の比は AI 法，Siddon の方法，Joseph の方法, distance-driven 法でおよそ10:1:1:6であった．

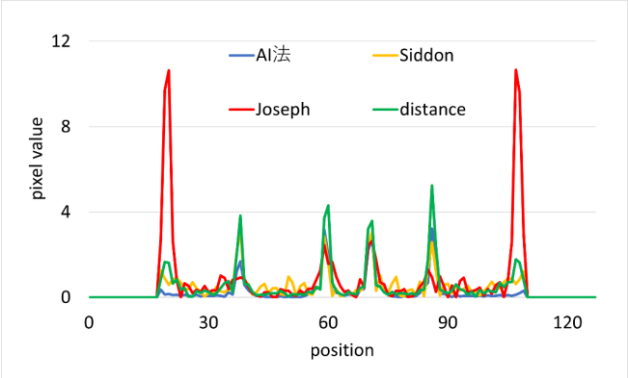


図 4　誤差画像の$y = 64$の位置のプロファイル

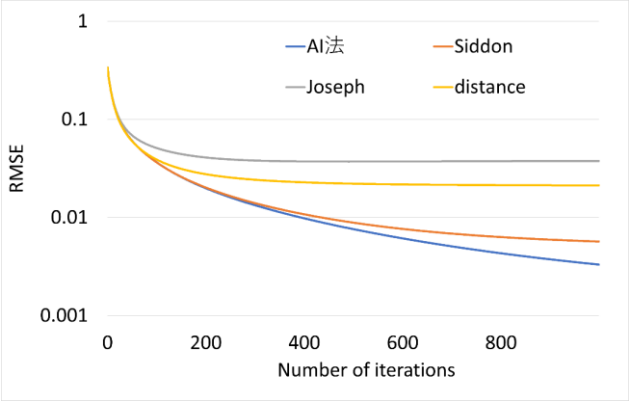


図 5　再構成画像の RMSE

4. 結論

AI 法以外の計算手法では再構成画像で同様の特徴を示していた．また，わずかではあるが Siddon の方法が他の近似手法よりも優れた結果を示した．

利益相反の有無

なし

文　献

[1] Tang X, et al. :3D weighting in cone beam image reconstruction algorithms: ray-driven vs. pixel-driven. Proceedings of IEEE EMBS, pp. 1478-1481, 2008.

[2] Siddon R. L.: Fast calculation of the exact radiological path for a three-dimensional CT array. Med Phy, vol. 12, no. 2, pp. 252-255, 1985.

[3] Joseph P. M.: An improved algorithm for reprojecting rays through pixel images. IEEE Trans. Med Imag, vol. 1, no. 3, New York, pp. 192-196, 1982.

[4] De Man B, Basu S.: Distance-driven projection and back projection in three dimensions. In: Nucelman S, Patton D. D. eds. Imaging for Medicine Vol. 2. Plenum Press, New York & London, pp. 2463-2475, 2004.

臨床用 Whole Gamma Imaging 装置のシミュレーション設計

菊地　智也[*1,2]，田久　創大[*2]，菅　幹生[*1,3]，田島　英朗[*2]，
赤松 剛[*2]，錦戸　文彦[*2]，山谷　泰賀[*2]
[*1] 千葉大学融合理工学府医工学コース, [*2] 量子科学技術研究開発機構,
[*3] 千葉大学フロンティア医工学センター

Design simulation of a clinical whole gamma imaging system

Tomoya Kikuchi[*1,2]，Sodai Takyu[*2]，Mikio Suga[*1,3]，　Hideaki Tashima[*2]，
Go Akamatsu[*2], Fumihiko Nishikido[*2]，Taiga Yamaya[*2]
[*1] *Graduate School of Science and Engineering, Chiba University*
[*2] *National Institutes for Quantum Science and Technology*
[*3] *Center for Frontier Medical Engineering, Chiba University*

要旨：Whole gamma imaging (WGI)装置は，PET 検出器リングの内側に散乱検出器リングを挿入し，PET とコンプトンイメージングの２つの画像化手法を１つの装置で実現する．今まで QST では小動物用 WGI の開発を進めてきた．本研究では小動物用 WGI の開発を通して得られた知見をもとに，ヒト用 WGI をシミュレーションによって設計した．散乱検出器にはピッチが 1.5 mm で 5.0 mm 厚の HR-GAGG3 層 DOI 検出器を，吸収検出器にはピッチが 3.0 mm で 20 mm 厚の LGSO 検出器を用いた．従来の円形の WGI ではリング径が大きくなることで散乱検出器と撮像対象の距離が大きくなり，コンプトンイメージングの空間分解能の劣化が予測される．そのため、通常の円形に配置した場合と散乱検出器の長軸半径をそろえた楕円状（扁平率 0.1）に配置した場合を比較した．一度の撮像で陽電子と 909 keV のエネルギーをもつ単一ガンマ線の撮像が可能な ^{89}Zr 線源を用いたシミュレーションを行い，PET 感度，909 keV のエネルギーを対象としたコンプトン感度，空間分解能を評価した．その結果，検出器の配置の違いによる大きな性能の変化が無いことが分かった．そのため，汎用性が高く製造が容易な円形の形状が適当であると結論した．

キーワード：Whole gamma imaging, PET，コンプトンカメラ, Geant4, ^{89}Zr

1. はじめに

Whole gamma imaging (WGI)装置は PET とコンプトンイメージングを組み合わせた新たな核医学診断装置である[1]. PET リングの内側に散乱体リングを挿入することで, 異なる二つのイメージング技術を一つのシステムで実現する．これまで，PET に近いコンプトンイメージング性能を有する WGI の開発を目的に小動物用 WGI 装置の開発をすすめてきており，昨年度の WGI4 号試作機の報告で達成した[2-4]．[4]．本研究では，小動物用 WGI の開発を通して得られた知見をもとに臨床用 WGI の設計をした. コンプトンイメージングにおける空間分解能は散乱体からの距離に比例するため，臨床用 WGI では空間分解能の低下が予測される. 空間分解能の低下を軽減するためには, 散乱検出器を撮像対象に近づけることが望ましい. ヒトを撮像する場合, 散乱体を楕円形のリングにすればヒトの体に近づけた配置にすることができる．そこで, 散乱検出器を円形に配置した場合と楕円形に配置した場合と検出器配置を設計し, モンテカルロシミュレーションによって, 性能向上効果が楕円配置によって得られるかを検討した.

2. 方法

1）臨床用 WGI シミュレーションジオメトリ

Geant4 を用いて，HR-GAGG 結晶を散乱体として、LGSO 結晶を吸収体として用いた臨床 WGI システムをモデル化した（図 1）．シミュレーションしたジオメトリの主な仕様を表 1 に示す. 設計の際, 散乱検出器の配置は, 寝台の厚みを考慮し, 標準体型の患者の胴体の中心と視野中心が一致するようにした．また，実機開発の際，使用可能な検出器数にはデータ収集回路による制限がある．臨床用 WGI に使用する予定のデータ集積回路では検出器のチャネル数が 512 に制限される. 吸収体では 4 検出器を 1 チャネルとするマルチプレクシング方式で若干の性能劣化を犠牲に感度の向上を図った. コンプトンイメージングにおいて散乱体のエネルギー分解能が極めて重要であるため. 散乱検出器にはマルチプレクシング方式を用いなかった．吸収体リングの半径は 510 mm である．1 つの吸収体リングは 256 個の検出器と 64 チャネルで構成され，4 検出器を

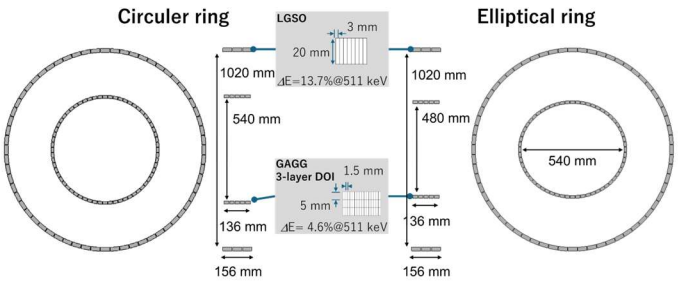


図 1 臨床用 WGI のシミュレーションジオメトリ

表 1　主要パラメータ

	吸収検出器	散乱検出器	
	(PET リング)	円形	楕円形
素材	LGSO	HG-GAGG	
エネルギー分解能 @511 keV	13.7 %	4.6 %	
結晶サイズ	3.0 × 3.0 × 20 mm^3	1.5 × 1.5 × 5 mm^3	
結晶数/検出器	8 × 8 × 1	16 × 16 × 3	
DOI	Non-DOI	3-layer	
検出器数 (per ring)	768 (256)	320 (64)	300 (60)
チャネル数 (per ring)	192 (64)	320 (64)	300 (60)
リング数	3	5	5

1 チャネルとした．円形の散乱体リングの半径は 270 mm で，1 つの散乱体リングは 64 検出器で構成されている．楕円形の配置の場合，散乱体リングの長軸半径は 270 mm，短軸半径は 240 mm で，1 つの散乱体リングは 60 検出器で構成される．

2）評価方法

^{89}Zr を注入したデレンゾファントム（図 2）をモデル化し，シミュレーションでは視野中心と中心から 190 mm の位置に配置した．デレンゾファントムは直径 10，8，5，4，3 mm のロッドから構成される．画像再構成にはリストモード OSEM 法を用いた．サブセット数は 8 で，最大 20 回の反復を行った．ボクセルサイズは 1.5×1.5×1.5 mm^3 とした．

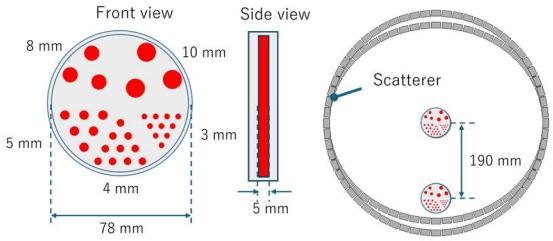


図 2 デレンゾファントム及びその配置図

3. 結果

表 2 に 2 つの形状の検出器リングについて，各線源位置における PET イベントと 909 keV のエネルギーを対象としたコンプトンイベントの感度を示す．視野中心では，円形の配置の方が楕円形の配置よりわずかに感度が優れていた．一方，周辺領域（190 mm）では，円形と楕円形の配置の違いによる有意な感度差は確認されなかった．線源に検出器がより近づく楕円形の配置の方が優れた感度を有すると予測していたが，異なる結果となった．これは，楕円配置によって散乱検出器が線源に近づいたが，検出器数は減り，また吸収検出器との距離が広がったためと考えられる．

表 2　PET イベントとコンプトンイベントの感度

	PET		Compton (909 keV)	
	円形	楕円形	円形	楕円形
視野中心	2.3 %	2.2 %	0.28 %	0.27 %
視野端	2.0 %	2.0 %	0.35 %	0.35 %

図 3 にはデレンゾファントムの PET 画像とコンプトン画像を示す．PET イメージングでは線源の位置や検出器の配置によらず，3 mm のロッドまで識別できた．コンプトンイメージングではいずれの散乱検出器の配置も，ロッドの識別に大きな差はなかった．中心部では 8 mm，周辺領域では 5 mm のロッドまで識別ができた．結果として，PET イメージングとコンプトンイメージングどちらにおいても円形と楕円形の配置の違いによるロッドの識別能力に有意差は認められなかった．これは，体の厚みだけでなく寝台の厚みも考慮する必要があり，楕円配置の短軸半径を画像に影響を与えるほど小さくできなかったためと考えられる．

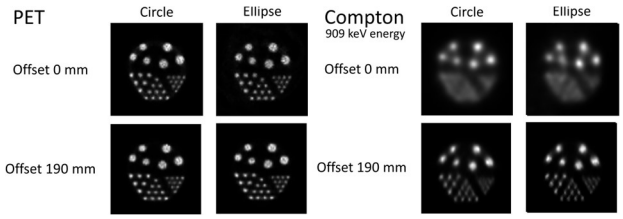


図 3　再構成画像

4. まとめ

本研究では，臨床 WGI 装置の PET とコンプトンイメージングにおいて，円形の配置に対して楕円形の散乱体配置に有意な性能差がないことをシミュレーションにより示した．したがって，製造の容易さの点から，円形の配置が臨床 WGI 装置に適した散乱体配置であると考えられる．

謝辞

本研究の一部は科研費 JP20H05667，23K28463，23H03775，中谷医工計測技術振興財団の助成を受けたものです．

利益相反の有無

無し

文　献

［1］ E. Yoshida et al., “Whole gamma imaging: a new concept of PET combined with Compton imaging”, Phys. Med. Biol. 65 (2020) 125013.

［3］ T. Kikuchi et al, “Whole Gamma Imaging 4 号試作機の PET・コンプトンカメラハイブリッドイメージングシミュレーション”, 2023 JAMIT, OP10-6.

［2］ T. Kikuchi et al., “PET-Compton hybrid imaging simulation of a small animal whole-gamma-imaging system”, 2023 IEEE NSS MIC, MIC-M-20-05

［3］ G. Akamatsu et al., “Development of the 4th Whole Gamma Imaging Prototype for 89Zr Mouse Imaging Demonstration”, 2023 IEEE NSS MIC, MIC-M-10-431

対向パネル型 PET のシミュレーション：TOF 分解能と感度が画質に及ぼす影響

石川　大洋[*1,2]，赤松　剛[*1]，田島　英朗[*1]，錦戸　文彦[*1]，
高橋　美和子[*1]，橋本　二三生[*1,2,3]，大田　良亮[*3]，山谷　泰賀[*1,2]
[*1] 量子科学技術研究開発機構
[*2] 千葉大学
[*3] 浜松ホトニクス株式会社

Simulation study of a panel-type PET geometry: effect of TOF resolution and system sensitivity on image quality

Taiyo ISHIKAWA[*1,2], Go AKAMATSU[*1], Hideaki TASHIMA[*1], Fumihiko NISHIKIDO[*1],
Miwako TAKAHASHI[*1], Fumio HASHIMOTO[*1,2,3], Ryosuke OTA[*3], Taiga YAMAYA[*1,2]
[*1] *National Institutes for Quantum Science and Technology*
[*2] *Chiba University*
[*3] *Hamamatsu Photonics K. K.*

要旨：30 ps の time-of-flight (TOF) 分解能を持つチェレンコフ輻射体一体型マイクロチャンネルプレート光電子増倍管(CRI-MCP-PMT)により，非リング型 PET でも断層像が取得できる可能性が示された．しかし，TOF 分解能と検出器感度の両立が課題となっており，これらの変動が画質に与える影響は明らかにはなっていない．本研究では，BGO シンチレータをチェレンコフ輻射体としたマルチチャンネル型 CRI-MCP-PMT を仮定し，対向パネル型 PET を Geant4 シミュレーションによりモデル化し，検出器感度と TOF 分解能に対する画質を調査した．従来相当のリング型 PET（TOF 分解能 210ps）では，画像ノイズの指標であるパーセント標準偏差が 7.6%であった．これに対して提案するパネル型 PET（TOF 分解能 30ps）では，検出器感度が 50%でも従来装置よりも良好な 6.8%を示した．

キーワード：TOF-PET，対向パネル型 PET，超高時間分解能，チェレンコフ光検出器，CRI-MCP-PMT

1. はじめに

陽電子断層撮像法（PET）において，消滅放射線の飛行時間差 (Time-of-flight, TOF) の情報は画質改善に有効である[1]．しかし，従来のシンチレーション検出器では，TOF 分解能の改善には限界が見えてきた．そこで本研究では，チェレンコフ発光の検出に着目する．これまで，チェレンコフ輻射体を窓材としたマイクロチャンネルプレート光電子増倍管（CRI-MCP-PMT）が開発され，30 ps の TOF 分解能が実証されている（4.5 mm の空間分解能に相当）[2]．もはや画像再構成が不要な TOF 分解能とも言え，パネル型のような非リンクジオメトリでの断層撮像の可能性も示されている[3]．

本研究の目的は，PET ガイド下手術などを想定したパネル型 PET の実現可能性を検討することである．これまで，30 ps の TOF 分解能を持つパネル型 PET のシミュレーションを実施し，210 ps の TOF 分解能を有する従来のリング型装置 [4] と同等の空間分解能が実現できることを示した[5]．そこで本研究では，TOF 分解能と検出器感度の間のトレードオフ関係について検討する．これは，より優れた TOF 分解能を達成するためには輻射体をより薄くすることが有効であるが，そうすると検出器感度が低下してしまうためである．加えて，生成されるチェレンコフ光子の数は極端に少ないため，放射体でチェレンコフ光が無事発生しても，それを必ずしも検出できるとは限らない．感度の低下は TOF 情報の持つ画質改善効果を打ち消す可能性がある．

2. 手法

BGO シンチレータをチェレンコフ輻射体とし，5.75 mm ピッチの位置分解能をもつマルチチャンネル型 CRI-MCP-PMT を仮定した Geant4 モンテカルロシミュレーションを行った．この検出器は，石英ガラスを窓材に持つ市販の 4×4 マルチアノードの MCP-PMT の改造を想定したものである．そして，提

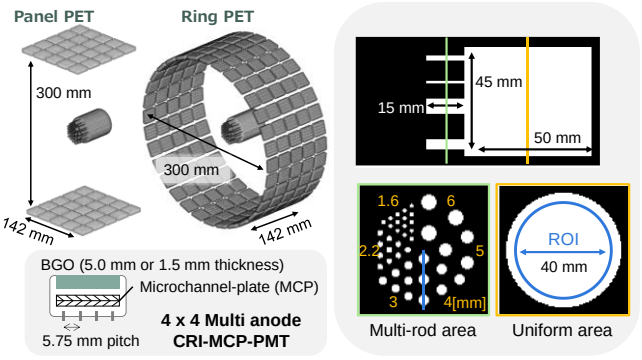


図 1　シミュレーションジオメトリ（左）と数値ファントム（右）

案するパネル型 PET と従来のリング型 PET を比較した（図 1 左）．パネル型 PET は 300 mm の距離で対向させた 2 枚の検出器パネル（142 mm×142 mm）で構成され，計 50 個の検出器を使用している．リング型 PET は 160 個の検出器を使用して直径 300 mm，体軸長 142 mm の検出器リングを構成し，TOF 分解能を 210 ps とした．画質評価用の数値ファントム（21 MBq の陽電子分布）は直径 45 mm の円柱型均一領域とマルチロッド領域から構成され（図 1 右），データ収集時間は 600 秒とした．また，提案するパネル型 PET においては，消滅放射線の検出時刻をチェレンコフ光子から，位置・エネルギー情報をシンチレーション光子から取得することを想定した．消滅放射線との相互作用で生成されるチェレンコフ光子の数が極端に少ないことに起因する検出器感度の低下は，同時計数カウント数を 50%，10%へと減らすことで再現した．輻射体の厚さは 5.0 mm と 1.5 mm の 2 種類を再現した．画像再構成には MLEM 法を使用した．ロッド分解能は 4 mm ロッド列のピーク対バレー比から算出し，画像ノイズは，ロッド分解能が同一となる特定の反復回数の再構成画像から均一領域のパーセント標準偏差（%SD）で評価した．

3. 結果と考察

%SD は TOF 分解能が 50 ps から 30 ps へ変化することで改善した（図 2）．TOF 分解能 30 ps のパネル型 PET では 6.3%であり，TOF 分解能 210 ps のリング型 PET より低い値を示した（7.6%）．一方で，TOF 分解能 40 ps のパネル型 PET では TOF 分解能 210 ps のリング型 PET の数値より高い 10.8%となり，TOF 分解能は 30 ps が必要である可能性が示された．

%SD は同時計数カウント数が減少すると，悪化する傾向を示した（図 3）．しかし，TOF 分解能 30 ps のパネル型 PET では，検出器感度が 50%であれば，カウントをすべて使用した TOF 分解能 210 ps のリング型 PET より低い 6.8%を示したことから，良好な画質を維持できる可能性がある．

パネル型 PET において輻射体の厚さを変化させた場合には，厚さ 1.5 mm のとき（厚さ 5.0 mm での検出器感度 10%に相当），%SD は 12.6%であり，厚さ 5.0 mm，TOF 分解能 40 ps の条件と比較して高い値を示した．検出器感度の高さは，TOF 分解能の低下による画質の低下を補う可能性がある．

4. 結論

パネル型 PET の開発に向けた CRI-MCP-PMT 検出器に求められる性能を明らかにするために，検出器感度と TOF 分解能が画質へ与える影響をシミュレーションにより調査した．結果として，既存のリング型 PET と同等の画質を達成するためには，TOF 分解能は 30 ps を維持することが必要であるが，50%の検出器感度は許容される可能性が示された．

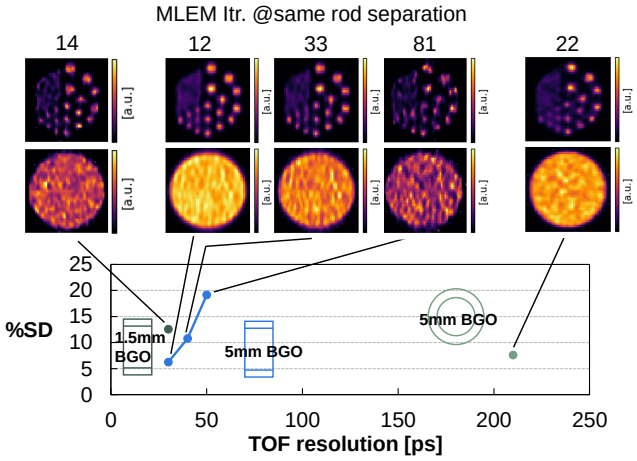


図 2　TOF 分解能と均一領域の%SD の関係．再構成画像のロッド分解能は 0.85 で一定とした．

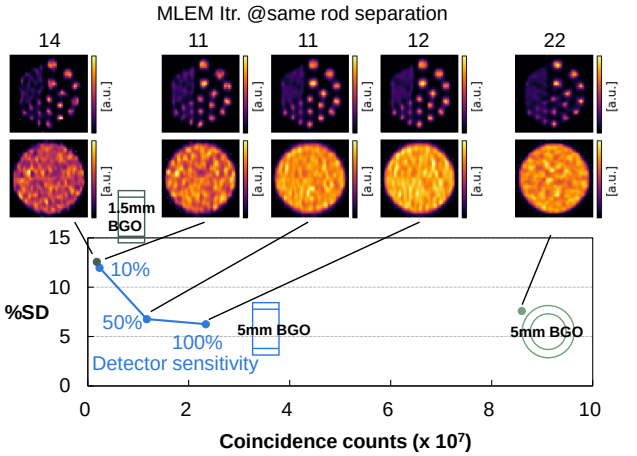


図 3　同時計数カウント数と均一領域の%SD の関係．再構成画像のロッド分解能は 0.85 で一定とした．パネル型 PET の TOF 分解能は 30 ps とした．

利益相反の有無

橋本氏と大田氏は浜松ホトニクス株式会社の社員である．

文　献

［1］D. R. Schaart: Physics and technology of time-of-flight PET detectors. Phys. Med. Biol. 66: 09TR01, 2021

［2］R. Ota et al.: Coincidence time resolution of 30 ps FWHM using a pair of Cherenkov-radiator-integrated MCP-PMTs. Phys. Med. Biol. 64: 07LT01, 2019

［3］S. I. Kwon et al.: Ultrafast timing enables reconstruction-free positron emission imaging. Nat. Photon. 15: 914-918, 2021

［4］J. van Sluis, et al.; Performance Characteristics of the Digital Biograph Vision PET/CT System. J. Nucl. Med. 60: 1031-1036, 2019

［5］T. Yamaya et al.: Dual-panel PET system to be enabled by 30-ps super-fast detector: a preliminary simulation study. Presented at The 3rd ICRPT, Yokohama, Japan, 2024

TOF-DOI 検出器を用いた半球型頭部 PET 装置 1 リング試作機の開発

成田　胡桃[*1,2]，赤松　剛[*1]，吉田　英治[*1]，田島　英朗[*1]，
岩男　悠真[*1]，高橋美和子[*1]，山谷泰賀[*1,3]
[*1] 量子科学技術研究開発機構
[*2] 千葉大学大学院融合理工学府
[*3] 千葉大学フロンティア医工学センター

Development of a hemispherical brain PET one-ring prototype with TOF-DOI detectors

Kurumi NARITA[*1,2]，Go AKAMATSU[*1]，Eiji YOSHIDA[*1]，Hideaki TASHIMA[*1]，
Yuma IWAO[*1]，Miwako TAKAHASHI[*1]，Taiga YAMAYA[*1,3]
[*1] *National Institutes for Quantum Science and Technology*
[*2] *Graduate School of Science and Engineering, Chiba University*
[*3] *Center for Frontier Medical Engineering, Chiba University*

要旨：量研では世界初の半球型頭部 PET 装置 VRAIN を開発し，2.2 mm ロッド分解能を実現した．PET は神経変性疾患の病態解明に有用であり，PET 装置の空間分解能が高いほど，より早期の微細な変化を検出できる．そこで我々は，次期 VRAIN として，理論限界の 1 mm 分解能を目標とした次世代装置の開発に着手した．1 mm 分解能により，微小な神経核の描出が可能となり，早期診断に役立つと考えられる．次世代装置の 1.6 mm のシンチレータピッチは，VRAIN の 4.2 mm の約 1/3 である．また VRAIN と同様のガンマ線飛行時間差（time-of-flight: TOF）計測に加えて，検出器深さ方向位置（depth-of-interaction: DOI）も検出可能な新型検出器を採用した．本研究では，この新型検出器を 36 個使用して直径 30 cm の 1 リング PET 試作機を開発し，ロッドファントムを用いて空間分解能を評価した．OSEM 画像再構成による 1 mm ロッドの描出性能は，昨年度 SAMIT で報告したシミュレーション結果と一致した．特に，撮像視野辺縁においては DOI 情報による空間分解能の向上が認められた．
キーワード：PET，脳，TOF，DOI

1. はじめに

PET は局所の病理学的変化を画像化することができ，神経変性疾患の診断や病態解明に有用である．図 1 に示すように，量研では検出器を頭部の形状に合わせて半球状に配置した頭部 PET 装置 VRAIN を開発し，2.2 mm の空間分解能を達成した[1]. 空間分解能にはまだ伸びしろがあり，理論的にはシンチレータピッチをより小さくすることで，空間分解能が向上する[2]．また，ガンマ線の飛行時間差(time-of-flight: TOF)と，検出器の深さ方向の検出位置(depth-of-interaction: DOI)の 2 つの計測の両立によって，画像ノイズの低減および視野全体での均一な空間分解能が期待できる．量研では，シンチレータピッチが 1.6 mm (VRAIN のシンチレータ幅ピッチ: 4.2 mm)で，TOF と DOI の両方の計測が可能な検出器 (crosshair light-sharing (CLS) 検出器) を開発した[3]．さらに，我々は，この検出器を半球型頭部 PET 装置に応用した場合，1 mm の空間分解能が期待できることをシミュレーションで示した[4]. 本研究では，シミュレーション結果を受けて，CLS 検出器を用いて 1 リングの卓上試作機を開発し，1mm 分解能を実証することを目的とする．

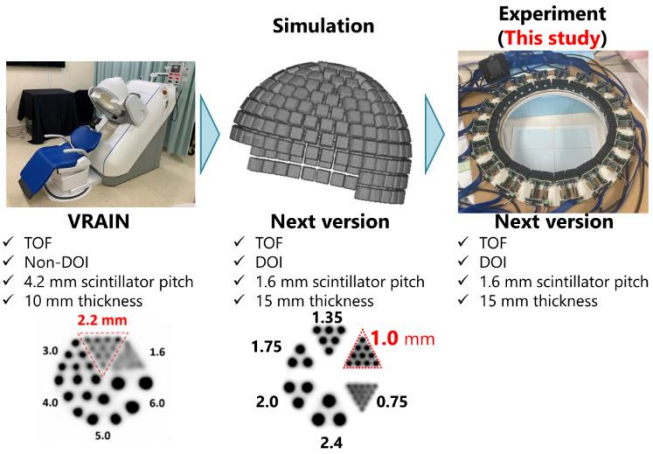


図 1.　半球型頭部 PET 装置「VRAIN」と次世代機の比較

2. 方法

1）Crosshair light sharing (CLS) 検出器

CLS 検出器の構造を図 2 に示す. 検出器は fast-LGSO シンチレータが 14×14 アレイ，multi-pixel photon counters (MPPC) が 8×8 アレイ状に配置されている．素子サイズはシンチレータが 1.6×1.6×15 mm^3(ピッチサイズ)，MPPC 受光面が 3×3 mm^2 である. 各シンチレータは反射材と光学接着剤の組み合わせによって，光が隣り合うシンチレータに分配される構造になっている.

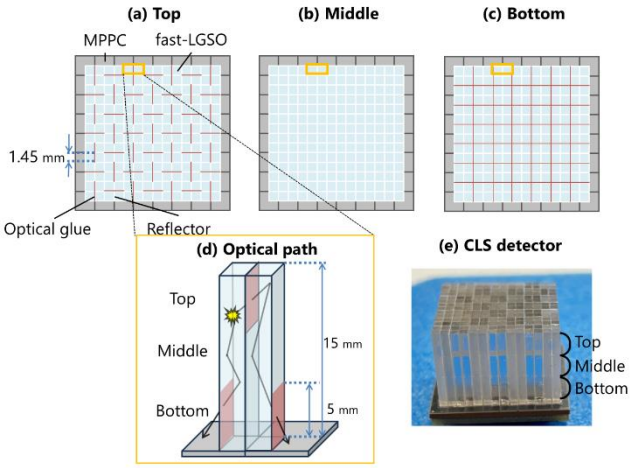


図 2.　CLS 検出器の構造

DOI は隣り合うシンチレータ下の 2 つの MPPC の出力比から計算される[3].

2）1 リング試作機

CLS 検出器を 36 個用いて 1 リング試作機を開発した．リング直径は 30 cm，体軸方向の視野は 2.6 cm である．データ収集には PETsys TOFPET2 ASIC (PETsys Electronics, SA, Portugal) を用いた．感度補正は，中空ドーム型ファントムの下部に ^{18}F 溶液 (33.4 MBq) をリング状に分布させ，2 時間収集を行った．

3）性能評価

3.1）空間分解能評価

ロッド直径がそれぞれ 0.75, 1.00, 1.35, 1.70, 2.00, 2.40 mm の ^{22}Na ultra-micro hot phantom (0.44 MBq) を用いて空間分解能評価を行った. DOI の効果を調べるため, ファントムを視野中心, 5 cm オフセット，10 cm オフセットの位置に配置してそれぞれ 5 時間計測した. 画像再構成には 3D-OSEM 法を用いた（subset: 8, iteration: 8）.

3.2）画像評価

Hoffman 3D brain phantom のアクリルプレート 4 枚を ^{18}F 溶液 62.3 MBq に浸し，12 時間測定した（図 4）．画像再構成には 3D-OSEM 法を用いた（subset: 8, iteration: 8）.

3. 結果・考察

図 3 に DOI 計測の有無それぞれの ultra-micro hot phantom の再構成画像を示す．視野中心において 1 mm ロッドを識別できた．10 cm オフセットの位置では，DOI 計測無しでは識別できなかった 1.7 mm ロッドが DOI 計測有りでは識別でき，DOI 計測による空間分解能の向上が認められた．図 4(b)に Hoffman phantom の再構成画像を示す．TOF 情報と DOI 情報を含めた画像再構成を適用した. 検出器数が 1 リング分に限られるためノイズが多いものの，灰白質・白質・脳室を可視化できた．Hoffman phantom 画像のさらなる画質改善に向け，検出器の校正手法および画像再構成パラメータの最適化に取り組む予定である．

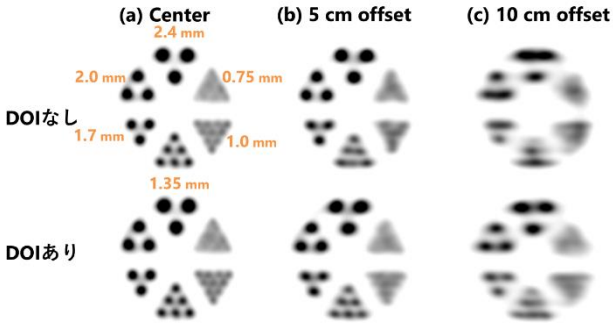


図 3.　ultra-micro hot phantom の再構成画像

(a) Hoffman phantomを用いた計測　(b) 再構成画像

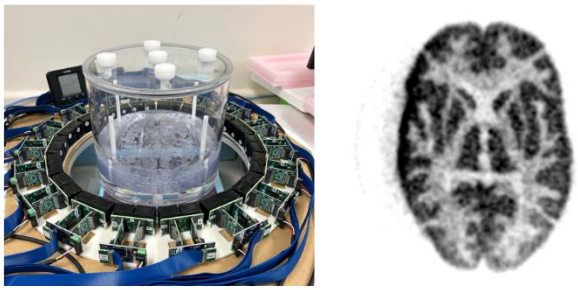


図 4.　Hoffman phantom の計測と再構成画像

4. 結論

次世代の半球型頭部用 PET 装置開発に向け，1.6 mm ピッチのシンチレータによる新型 TOF-DOI 検出器を用いた 1 リング試作機を開発し，1 mm 空間分解能を有することを実証した．

謝辞

本研究は，中谷財団未来 PET 創造研究ユニットおよび日本医療研究開発機構から研究費の提供を受けています (23he2302010h0101).

利益相反の有無

本研究は，株式会社アトックスとの共同研究であり，共同研究費の提供を受けています.

文　献

[1] G. Akamatsu, *et al.*, “Performance evaluation of VRAIN: a brain-dedicated PET with a hemispherical detector arrangement,” *Phys. Med. Biol.*, vol. 67, no. 22, p. 225011,2022

[2] W. W. Moses, “Fundamental limits of spatial resolution in PET,” *Nucl. Instrum. Methods Phys. Res. Sect. Accel. Spectrometers Detect. Assoc. Equip.*, vol. 648, pp. S236–S240, 2011

[3] E. Yoshida, et al., “Timing estimation of the exponentiated energy-weighted average for crosshair light sharing TOF-DOI PET detector,” *Nucl. Instrum. Methods Phys. Res. Sect. Accel. Spectrometers Detect. Assoc. Equip.*, vol. 1059, p. 168949, 2024.

[4] K. Narita, *et al.*, “One-millimeter resolution hemispherical brain PET: a simulation study,” in *2023 IEEE Medical Imaging Conference (MIC)*, pp. 1–1., 2023

OpenPET 初の重粒子線がん治療臨床応用

田島 英朗[*1]，寅松 千枝[*1]，浜戸 アクラム[*1]，岩男 悠真[*1]，赤松 剛[*1]，カン ハンギュ[*1]，
錦戸 文彦[*1]，田尻 稔[*1]，水野 秀之[*1]，小藤 昌志[*1]，山谷 泰賀[*1]
[*1] 量子科学技術研究開発機構

The first clinical application of OpenPET for carbon-ion therapy

Hideaki TASHIMA[*1]，Chie TORAMATSU[*1]，Akram HAMATO[*1]，Yuma IWAO[*1]，
Go AKAMATSU[*1]，Han Gyu KANG[*1]，Fumihiko NISHIKIDO[*1]，Minoru TAJIRI[*1]，
Hideyuki MIZUNO[*1]，Masashi KOTO[*1]，Taiga YAMAYA[*1]
[*1] *National Institutes for Quantum Science and Technology*

要旨：開放空間を持つ OpenPET は重粒子線照射中に PET 測定が可能である．照射によって生体内で副次的に生成される陽電子放出核種をその場でイメージングすることで，患者体内での治療ビームの飛程検証や，治療効果予測ができるようになると期待されている．昨年の報告では，OpenPET 装置を HIMAC（Heavy Ion Medical Accelerator in Chiba）の治療室へ設置し，頭部ファントムへの照射と OpenPET 測定を行った結果を示した．本発表では，頭頚部がん患者を対象とした臨床試験を開始し，初の OpenPET 臨床測定を実施した結果を報告する．実際の治療では垂直と水平の 2 つ照射ポートを用い，照射は片方ずつ行われるが，OpenPET 装置は水平照射のみに対応しているため，先に垂直照射を行い，その後 OpenPET 装置を測定位置に移動し，水平照射に合わせて測定を開始した．測定は照射後 10 分間継続した．その結果，患者体内にて重粒子線が照射された領域に生成された陽電子放出核種を捉えることに成功した．

キーワード：In-beam PET，OpenPET，重粒子線がん治療，飛程検証，臨床応用

1. はじめに

重粒子線治療は，周囲の臓器への影響を最小限に抑えながら，腫瘍に高い線量を集中させることが可能なため，非常に効果的ながん治療法である．また，治療可能ながんの種類も増加しており，保険適用範囲も広がってきている．一方で，患者個別の治療効果は経過観察によって評価するしかなく，治療ビームの飛程や治療効果など，実際の照射をその場で評価する手法は確立されていない．重粒子線がん治療では，治療ビームとして炭素粒子を加速させて照射する．その際，生体との核破砕反応によって様々な陽電子放出核種が照射領域に生成される．そのため，PET を用いた飛程検証法が有望視されている［1］．また，生成される陽電子放出核種は半減期が短いものがほとんどであるため，短時間で十分なデータ量を得るためには，照射中及び照射直後からの測定を行う In-beam PET が望ましいが，従来の In-beam PET は対向型で主に 2D イメージングに限定されていた．そこで我々は，3D イメージングが可能なフルリング型でありながら，In-beam PET が可能な OpenPET 装置の開発を行った（図 1）［2-4］． OpenPET は円筒を並行する斜めの 2 平面で切り取ったジオメトリで，円筒 PET の検出器配置から，体軸方向に検出器をずらしながら配置することで実現している．円筒型 PET と比較して傾斜角度の大きな LOR（Line of Response）が増えるが，深さ方向の検出位置情報を取得可能な 4 層 DOI 検出器［5］を用いることで，パララックスエラーによる分解能劣化の影響を抑えることに成功した．昨年の発表では，開発したヒトサイズ OpenPET 装置を HIMAC（Heavy Ion Medical Accelerator in Chiba）の治療室へ設置し，頭部ファントムを用いた In-beam PET 測定結果を報告した［6, 7］．本発表では，頭頚部がんの重粒子線治療を対象とした OpenPET 初の臨床応用結果を報告する．

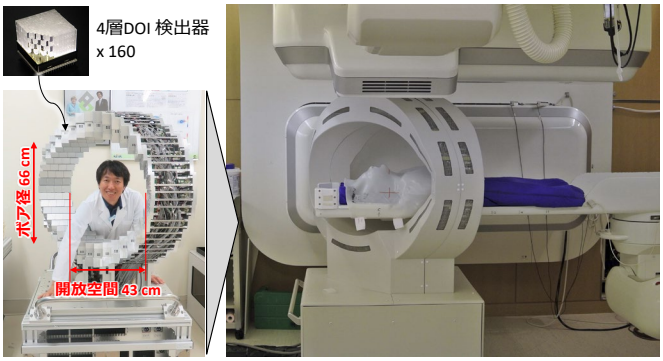


図 1. QST 独自方式の 4 層 DOI 検出器を用いて開発し，現在 HIMAC の治療室へ設置している OpenPET 装置．

2. 方法

本研究は量子科学技術研究開発機構(QST)臨床研究審査委員会によって承認された．HIMAC での頭頚部がん治療では，16 分割照射を行い，各照射回において生物学的効果比（RBE: Relative Biological Effect）加重線量でおよそ 4 Gy の照射が行われる．各照射回で水平・垂直の 2 門照射を行う患者を対象にボランティアをリクルートした．ボランティア患者からはインフ

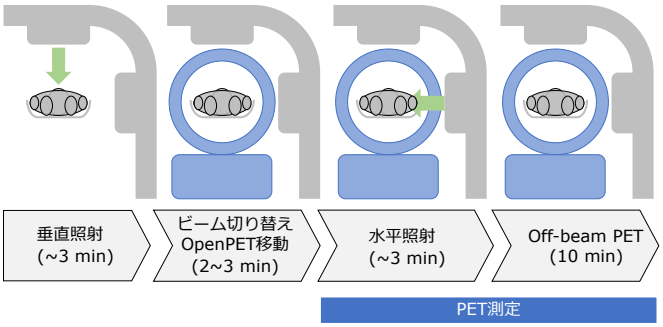


図 2. 臨床 OpenPET In-beam 測定プロトコル.

ォームドコンセントを文書で取得している．現在の OpenPET 装置は水平照射の In-beam 測定用に設計されているため，まず OpenPET 測定なしで水平照射を行い，その後ビーム切り替えの間に OpenPET 装置を移動，水平照射開始と同時に測定を開始し，照射終了後 10 分間測定を継続して行った（図 2）．OpenPET 装置の速やかな移動と，測定位置の再現性確保のために，ガイドレールとストッパーのついた敷板を床に設置した．

OpenPET 測定ではすべてのシングルイベントを記録し，エネルギー弁別，同時計数，結晶識別はオフライン処理として実施し，同時計数イベントを抽出した．その際，重粒子線照射では照射中，ビームが実際に出ている（スピルオン）時間と，出ていない（スピルオフ）時間が 0.1 秒から 2 秒程度の不規則な間隔で繰り返されており，スピルオフ時間の同時計数イベントも照射終了後のイベントに加えて抽出した．画像再構成には先見情報として Media Root を用いた 3D リストモード MAP-OSEM (Maximum A Posteriori-Ordered Subset Expectation Maximization) 法を用いた．減弱補正と散乱補正には治療計画 CT を位置合わせして用いた．ポストスムージングとして，半値幅 3mm の 3D ガウシアンフィルタを適用した．

3. 結果

図 3 に測定を行った照射回の治療計画線量分布と，In-beam 測定によって得られた初の臨床 OpenPET 画像を示す．それぞれ治療計画 CT 画像との融合画像として 3 方向の断面像を表示した．患者体内にて重粒子線が照射された領域に陽電子放出核種が生成された様子を捉えることに成功した．なお，PET 画像の境界は空間分解能による制限やノイズ低減のためのスムージングの影響を強く受けている点に注意が必要である．

4. まとめ

OpenPET の重粒子線がん治療における臨床応用を開始し，初の臨床画像取得に成功した．今後，計画線量と PET 画像のプロファイル解析や，ダイナミック再構成による洗い出し効果の解析を進める予定である．

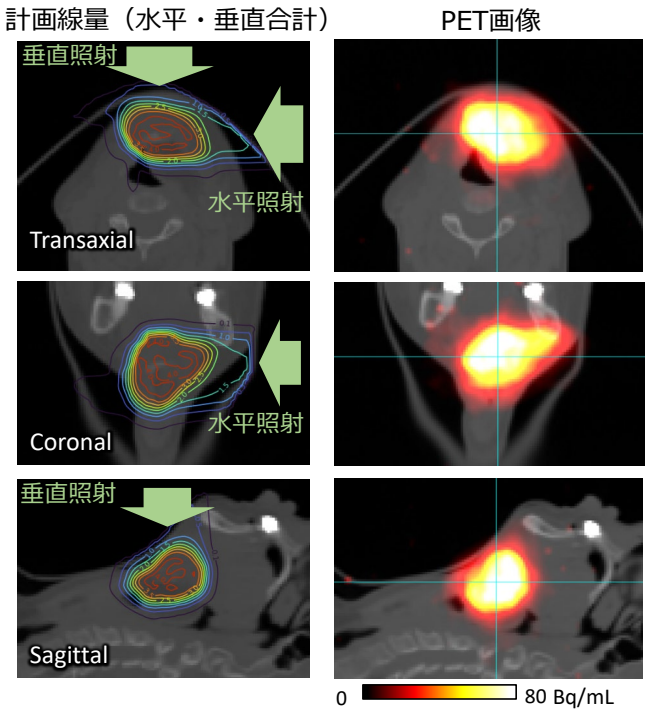


図 3. 治療計画の RBE 加重線量（左）と HIMAC 重粒子線がん治療で得られた初の臨床 In-beam OpenPET 画像（右）.

謝辞

研究遂行にあたりご協力いただいております QST イメージング物理研究グループの皆様並びに QST 病院関係者に感謝申し上げます.

利益相反の有無

本研究に関する利益相反はありません.

文　献

[1] Parodi K and Polf JC: In vivo range verification in particle therapy. Medical Physics 45: e1036-e1050, 2018

[2] Yamaya T, Inaniwa T, Minohara S et al: A proposal of an open PET geometry. Phys Med Biol 53: 757-73, 2008

[3] Tashima H, Yamaya T, Yoshida E et al: A single-ring OpenPET enabling PET imaging during radiotherapy. Phys Med Biol 57: 4705-18, 2012

[4] Tashima H, Yoshida E, Iwao Y et al: Development of a multiuse human-scale single-ring OpenPET system. IEEE TRPMS 5: 807-816, 2021

[5] Hirano Y, Nitta M, Inadama N et al: Performance evaluation of a depth-of-interaction detector by use of position-sensitive PMT with a super-bialkali photocathode. Radiol Phys Technol 7: 57–66, 2014

[6] 田島英朗，寅松千枝，Mohammadi A et al: 重粒子線がん治療における初の臨床適用に向けた OpenPET 装置開発．第 42 回日本医用画像工学会大会: OP10-5, 2023

[7] Tashima H, Toramatsu C, Mohammadi A et al: Bench-to-Clinical Transfer of OpenPET: First In-Beam Test in a HIMAC Treatment Room. 2023 IEEE NSS MIC RTSD, M-15-02, Vancouver, BC, Canada, 2023

股関節鏡視下手術における術中動画のセグメンテーション画像と仮想股関節鏡シミュレータによる仮想股関節画像との連携による最適ポータル位置の推定

川上　申之介[*1]，福田　紀生[*2]，西井　孝[*3]，大竹　義人[*4]，佐藤　嘉伸[*4]
[*1] 関西女子短期大学医療秘書学科
[*2] 脳情報通信融合研究センター
[*3] 大阪急性期・総合医療センター整形外科
[*4] 奈良先端科学技術大学院大学情報科学領域

Optimal portal position estimation by connecting segmentation image from arthroscope hip surgery video and virtual arthroscope simulator.

Shinnosuke KAWAKAMI[*1], Norio FUKUDA[*2], Takashi NISHII[*3], Yoshito OTAKE[*4], and Yoshinobu SATO[*4]
[*1] *Kansai Women's College*
[*2] *Center for Information and Neural Networks*
[*3] *Osaka General Medical Center*
[*4] *Nara Institute of Science and Technology*

要旨：股関節唇の低侵襲修復手術においては股関節鏡を挿入し手術が行われるが，挿入口であるポータル位置により得られる視認性が影響をうけると考えられる．最も手術をしやすい視認性が得られているかどうかを知るためには、手術対象部位である股関節唇と、ランドマークとして視野に入る大腿骨頭をセグメンテーションできれば有用であると考える．我々は 14 症例の股関節斜視鏡による術中動画から切り出した画像(各症例約 10000 枚)から各症例 80 枚を t-SNE を利用して選定し，作成したマスク画像を正解画像として，テスト用の 1 症例画像を除く他の症例の画像から U-Net++により学習させたモデルをつくり，テスト用 1 症例画像に対して股関節唇および大腿骨頭を分離抽出させ症例毎の Dice 値の平均値により精度を評価することとした。また学習時の Unet++におけるパラメータを調整することにより精度に影響があるかどうかを多重比較により調べた。結果、統計的有意差の有無が見られた。さらに仮想股関節シミュレータで網羅的に生成した画像と教師画像とを比較することにより術中動画におけるポータル位置を推定するための方法について考察したので報告する。

キーワード： arthroscope，segmentation，U-Net，t-SNE

1. はじめに

股関節唇断裂などの修復には低侵襲な股関節鏡視下手術が行われるが，股関節鏡はポータルと呼ばれる直径 1cm 程度の傷(穴)を股関節の皮膚上に開けそこから刺入される．そのため得られる視認性はポータル位置で決定されていると考えられる. 我々は現在ポータル位置の視認性における最適性を定義しその最適位置の術前推定を目的とし, 15 症例の CT 画像から作成したサーフェスモデルを用いた仮想股関節鏡による視認性評価システムを開発中である。これらの症例に対応する実際の手術動画に映っている股関節唇およびランドマークとしての大腿骨頭をセグメンテーションし, シミュレータ側での再現につなげることで, 手術におけるポータル位置を評価できると考える. 動画のセグメンテーションについては膝関節では研究が進められているが[1]，股関節に対してはまだなされておらず新規性があると考え，U-Net++を用いて学習済みモデルを作成した後、股関節唇および大腿骨頭をセグメンテーションし、予測された画像の視認性評価を行ったので報告する。

2. 画像の選定

CT 画像 15 症例に対応した手術動画がある 14 症例の術中動画を用いる。動画の撮影時間は各 30 分～2 時間程度であり，概ね股関節鏡の刺入前から手術を終えた後までが記録されている．0.5 秒毎に静止画像を生成し 1 症例約数千枚から数万枚程度の画像を得る．U-Net++での学習およびテストに用いるため、3 回の t-SNE を行うことで学習およびテストに必要な画像を抽出することとした．選定した 14 症例の静止画群に対してアノテーションしマスク画像を作成する. 作成枚数については、時間的に近い似た画像になるのを避けるため 1 症例 80 枚とし

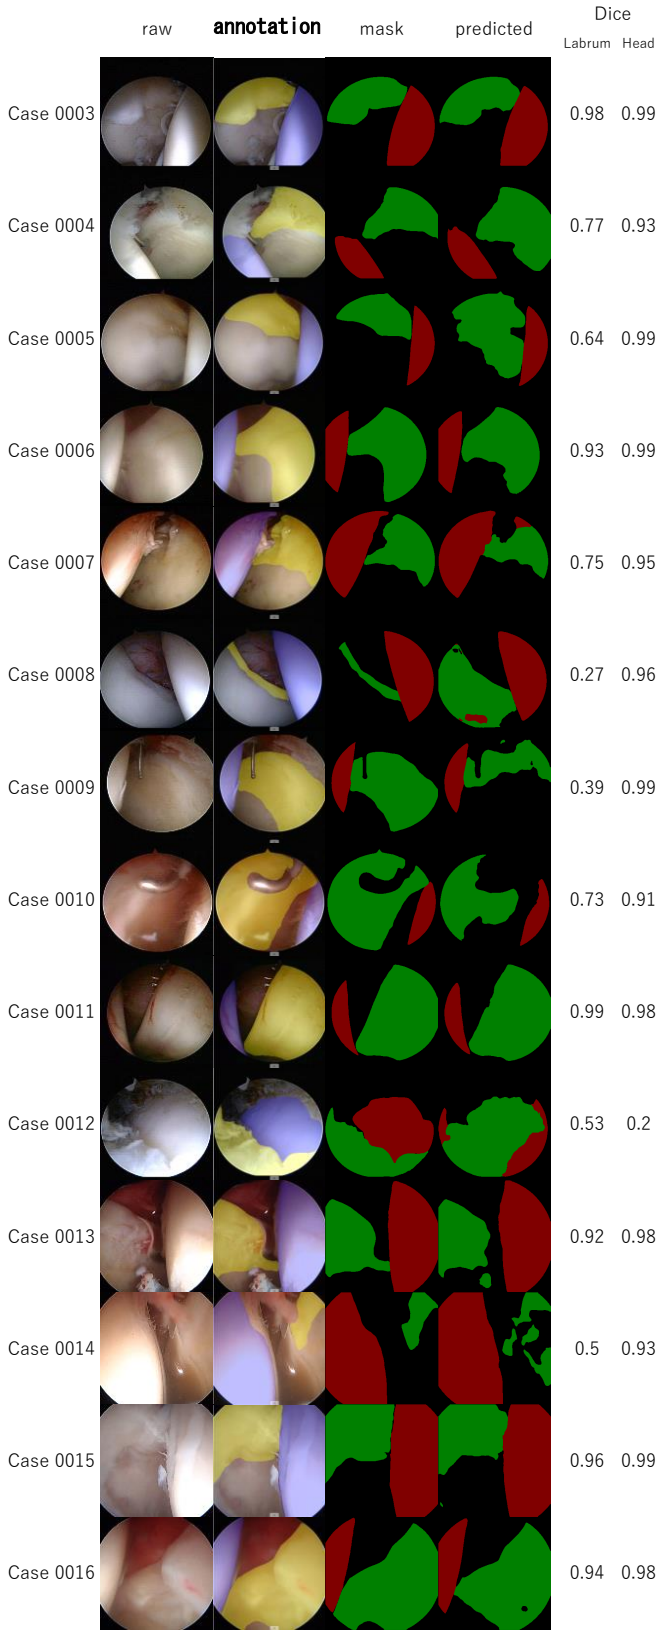


図 1. 各症例 80 枚のうちの代表的な 1 枚について左から、動画から切り出した静止画、アノテーション、マスク(教師画像)と U-Net++による予測結果(緑は股関節唇、赤は大腿骨頭)。

た。これにより 14 症例で合計 1120 枚の画像が得られる。なお学習用画像のサイズは縦横 320 画素にリスケールしたため 1 枚の画像の全画素数は 102,400 画素である.

3. 方法

14 症例の選定画像およびそれに対応する作成済みマスク画像のうち 1 症例の画像をテスト用とし，残りの 13 症例のマスク画像を学習用としてモデルを生成し、14 次の cross validation により 14 症例分のテスト結果が得られる．学習には Unet++モジュールに用意されている encoder、pre-trained weights, pooling、decoder および epoch 数を変えてパラメータ変更の効果を試すこととした。結果の評価には各症例の股関節唇、大腿骨頭それぞれの Dice 値の平均値を用いて多重比較し有意差検定を行う。

4. 結果

図 1 は各症例の代表的な 1 枚について、左から元画像、アノテーション画像、マスク画像(教師画像)、モデルによる予測画像である。特に第 1 2 症例については動画像が判別困難のため結果から除外し考察することとし、各症例の股関節唇と大腿骨頭の Dice 値を示したものが図 2 である。

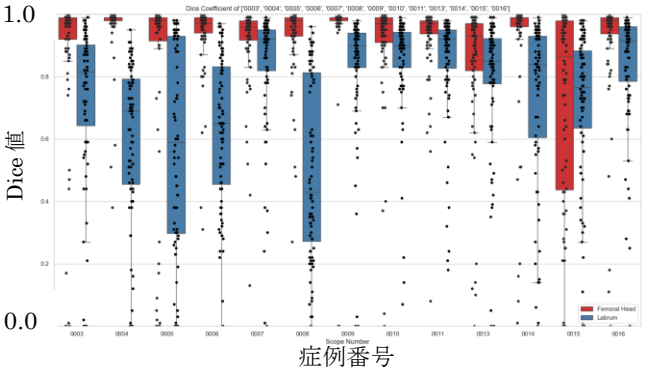


図 2. 全 12 症例の股関節唇の Dice 値平均が最も高かった時のパラメータ設定により作成した学習済みモデルによる結果。青は股関節唇の、赤は大体骨頭の四分位範囲を示す。

5. まとめ

現段階の結果では、股関節唇の抽出精度が低いため、今後、nnU-Net 等を利用して、Dice 値の向上を目指す。

利益相反の有無

なし.

文　献

［1］Yaqub Jonmohamadi, Yu Takeda,Fengbei Liu, Fumio Sasazawa, Gabriel Maicas, Ross Crawford, Jonathan Roberts,Ajay K. Pandey, Gustavo Carneiro: Automatic Segmentation of Multiple Structures in Knee Arthroscopy Using Deep Learning, IEEE Access, Vol.8: pp51853 - 51861, 2020

Segment Anything Model を用いて生成されたマスクの分類による腹腔鏡映像からの血管・膵臓領域自動抽出の検討

髙見　一慧[*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[*1,3,5]

[*1] 名古屋大学大学院情報学研究科

[*2] 愛知工業大学情報科学部

[*3] 名古屋大学情報基盤センター

[*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 Segmentation of Blood Vessel and Pancreas Regions from Laparoscopic Videos using Classification of Masks Generated by Segment Anything Model

Ikkei TAKAMI[*1]，Yuichiro HAYASHI[*1]，Takayuki KITASAKA[*2]，Masahiro ODA[*3,1]，Kazunari MISAWA[*4]，Kensaku MORI[*1,3,5]

[*1] *Graduate School of Informatics, Nagoya University*

[*2] *Faculty of Information Science, Aichi Institute of Technology*

[*3] *Information Technology Center, Nagoya University*

[*4] *Aichi Cancer Center Hospital*

[*5] *Research Center for Medical Big Data, National Institute of Informatics*

要旨：本稿では，Segment Anything Model（SAM）で生成したマスクを分類し，腹腔鏡映像の血管領域と膵臓領域を自動抽出する手法について述べる．腹腔鏡手術は患者にとって負担が小さい手術である一方，術者にとって手術難易度が高く，負担が大きい手術である．そのため，術者を支援するシステム開発が必要とされている．SAM は汎用セグメンテーションモデルの 1 つで，画像の一部分を点やボックスなどのプロンプトで指定し，それに対するマスクを生成し，セグメンテーションを行う．SAM は強力なゼロショット性能を持つ一方で，生成されたマスクがクラス情報を持たないという問題がある．そのため本研究では，SAM が腹腔鏡画像から生成したマスクを基に深層学習モデルを用いてクラス分類を行い，血管領域，膵臓領域の自動抽出を行う手法を提案する．実験の結果，従来手法では抽出が難しい血管領域の抽出が可能であった．

キーワード：腹腔鏡下手術，血管領域抽出，膵臓領域抽出，Segment Anything Model

1. はじめに

近年, 日本ではがんの罹患数, 死亡数は増加傾向にある[1-3]. がんの治療方法の 1 つに腹腔鏡手術がある. 腹腔鏡手術は患者にとって低侵襲であるため負担の小さい手術である一方で, 術者にとって難易度が高く，負担の大きい手術である．また，腹腔鏡手術において, 血管や膵臓は損傷により合併症を引き起こす可能性がある. より安全な手術を実施するために血管領域や膵臓領域を自動抽出するシステム開発が必要とされている.

Segment Anything Model (SAM)[4]とは大量の画像で学習した汎用セグメンテーションモデルである. セグメンテーション対象の画像に対して, 点やバウンディングボックスなどのプロンプトを対話的に与え, それに基づく画像マスクを生成することでセグメンテーションを行う.

従来の抽出手法[5]では学習に用いるアノテーション付き画像を得るために大きな負担が必要であった．SAM はアノテーション付き画像を必要とせず，ゼロショットで抽出可能だが，生成されたマスクはクラス情報を持っていないという問題点が存在する．そのため本研究では，SAM が腹腔鏡画像から生成したマスクをクラス分類することにより，血管領域，膵臓領域の自動抽出を行う．

2. 提案手法

提案手法では, 腹腔鏡画像に対するマスクを SAM で生成後, 深層学習モデルを用いてマスクのクラス分類を行い, クラス情報付きマスクを作成し, 血管領域, 膵臓領域の自動抽出を行う.

まず, 本提案手法では画像全体に等間隔で自動配置された点プロンプトを基に，SAM を用いてマスク生成を行う.

次に, マスクのクラス分類を行う深層学習モデルの訓練データ，評価データについて述べる．本提案手法では血管領域，膵臓領域のどちらかのみアノテーションが付いている画像と, 血管領域, 膵臓領域の両方アノテーションが存在する画像の 2 種類の画像を用いる．まず，全ての画像からアノテーションを参考にして血管領域または膵臓領域を覆うマスクと画像の組を作成する．次に，後者の画像から血管領域または膵臓領域でな

い領域（以下，背景領域と呼ぶ）を覆うマスクと画像の組を作成する．これらのマスクと画像の組を訓練データとして，深層学習モデルの訓練に用いる．評価データとして血管領域，膵臓領域に両方アノテーションが存在する画像に対して，画像全体に等間隔に点プロンプトを自動生成し，それらを基に SAM を用いて画像全体にマスクを生成したものを用いる．

マスクの分類に用いる深層学習モデルには VGG16[6]の入力層を 4 チャンネル画像が入力できるように変更したものを用いる．入力は RGB 画像にマスクを重ねた 4 チャンネル画像に対して，マスク周辺をクロップし，256×256 画素にリサイズした画像を用いる．評価データを深層学習モデルで分類し，血管領域のマスク，膵臓領域のマスクと分類されたマスクを抽出結果として得る．

抽出結果を得た後，抽出結果と腹腔鏡画像のアルファブレンドを行い，抽出結果を可視化する．

3. 実験ならびに結果

本実験では，愛知県がんセンターから提供された腹腔鏡下胃切除術の映像を利用した．18 症例の腹腔鏡映像のフレームに対して手動でアノテーションを行った合計 1228 枚の腹腔鏡画像を利用した．このうち血管領域，膵臓領域の両方アノテーションが存在する画像は 71 枚であった．抽出結果の精度評価には適合率，再現率，F 値を用いた．

実験の結果として，評価用データに対する認識精度を表 1 に，抽出結果を図 1 に示す．表 1 より再現率が高い一方，適合率が低いため，未抽出は少ないが過抽出は多いことが分かった．図 1 の抽出結果を見ると，血管領域と膵臓領域は抽出されているが，誤分類を原因とする過抽出が多く，特にガーゼや手術器具を血管領域または膵臓領域として抽出してしまう例が多いことが分かった．また，血管を覆うマスクが生成されない場合があることがわかった．

4. 考察

過抽出の理由としてデータ量の不足が考えられる．SAM で血管を覆うようなマスクが生成できない場合がある理由として，医用画像における SAM のマスク生成の精度が悪い可能性が考えられる．そのためファインチューニングなどでマスク生成の精度を向上させることで改善されると考えられる．

5. むすび

本研究では，腹腔鏡画像に対してマスクを生成後，深層学習モデルを利用してマスクのクラス分類を行うことで，血管領域と膵臓領域の自動抽出を行った．血管領域や膵臓領域を抽出できたが，過抽出や SAM のマスク生成精度の問題という課題が得られた．そのため今後の課題として，学習データの量と質の向上，SAM のファインチューニングを行うことが考えられる．

表 1: 抽出の認識精度

	適合率	再現率	F 値
血管領域	0.081	0.240	0.122
膵臓領域	0.344	0.790	0.479

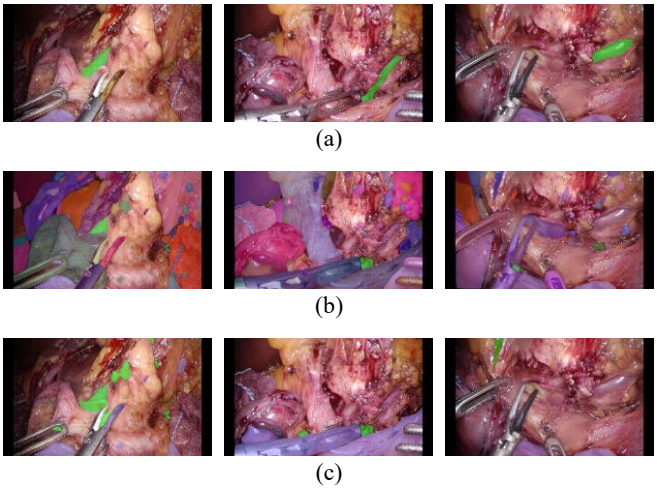


図 1: 抽出結果の一部．緑色の領域が血管領域，紫色の領域が膵臓領域を表す．(a) ground truth，(b) SAM で腹腔鏡画像にマスクを生成した結果，(c) 血管領域，膵臓領域の抽出結果．

謝辞

本研究は JST CREST JPMJCR20D5，JSPS 科研費 24H00720，21K19898 の支援を受けた．

利益相反の有無

なし

文　献

［1］国立研究開発法人国立がん研究センター：国立がん研究センターがん情報サービス「がん統計」（厚生労働省人口動態統計）．https://ganjoho.jp/reg_stat/statistics/data/dl/excel/cancer_mortality(1958-2022).xls, (2024 年 5 月 15 日閲覧)

［2］国立研究開発法人国立がん研究センター：国立がん研究センターがん情報サービス「がん統計」（全国がん登録）．https://ganjoho.jp/reg_stat/statistics/data/dl/excel/cancer_incidenceNCR(2016-2019).xls, (2024 年 5 月 15 日閲覧)

［3］国立研究開発法人国立がん研究センター：国立がん研究センターがん情報サービス「がん統計」（全国がん罹患モニタリング集計（MCIJ））．https://ganjoho.jp/reg_stat/statistics/data/dl/excel/cancer_incidence(1975-2015).xls, (2024 年 5 月 15 日閲覧)

［4］Alexander K, Eric M, Nikhila R et al: Segment anything. arXiv preprint arXiv:2304.02643, 2023.

［5］Paul MS, Stefan L, Anna K et al: Deep learning for semantic segmentation of organs and tissues in laparoscopic surgery. CDBME 6(1): 20200016, 2020.

［6］Karen S, Andrew Z: Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv preprint arXiv:1409.1556, 2014.

改良を加えた YOLO モデルに基づく内視鏡下手術画像からの術具先端検出

劉　育彰[*1]，林　雄一郎[*1]，小田　昌宏[*1, 2]，森　健策[*1, 2, 3]
[*1]名古屋大学情報学研究科知能システム専攻
[*2] 名古屋大学情報基盤センター
[*3] 国立情報学研究所医療ビッグデータ研究センター

Surgical Tool Tip Detection for Endoscopic Surgery based on Enhanced YOLO Model

Yuzhang LIU[*1]，Yuichiro HAYASHI[*1]，Masahiro ODA[*1, 2]，Kensaku MORI[*1, 2, 3]，
[*1] *Graduate School of Informatics, Nagoya University*
[*2] *Information Technology Center, Nagoya University*
[*3] *Research Center for Medical Bigdata, National Institute of Informatics*

要旨：腹腔鏡ツールの検出は, 低侵襲手術を支援する上で重要な役割を果たし, ツールの姿勢推定や手術段階の認識などのタスクを容易にする. しかし, 現在の検出技術は主にツール全体に焦点を当てており, 実際にはツールの先端が最も重要な情報を含んでいる. 手術中, 組織の把持, 切除, 血管シールなどの操作は, ツールの先端によって行われるため, 先端の検出は腹腔鏡手術を支援する上で重要である. 本研究は, 腹腔鏡ツールの先端の検出に取り組むことを目的としている. 縫合操作の腹腔鏡トレーニングビデオに基づき, 特定のフレームを選択してツールの先端を注釈付けし, データセットを作成する. その後, ツール検出に特化した改良型 YOLOv8 モデルを訓練する. 手術工具の種類が少ない手術環境において、本方法の手術工具先端検出の mAP は 0.925 でした.
キーワード：腹腔鏡ツール検出，YOLOv8 モデル，腹腔鏡ツールの先端検出

1. Introduction

Laparoscopy, a minimally invasive surgery, reduces patient trauma and accelerates recovery[1]. Laparoscopic Tool Detection (LTD) is crucial for assisting laparoscopic procedures, aiding in tasks like tool pose estimation[2] and surgical phase recognition[3]. CNN-based methods are well-established for LTD[4].

Current research on laparoscopic tool detection has certain limitations. These methods primarily focus on detecting entire tools and using the detection results for enhanced laparoscopic video processing tasks[2,3]. In these studies, detecting tool tips, which contain more critical information such as whether the tool tips are open or performing operations on tissue, is often ignored. Few studies focus on detecting the tips of surgical tools. One exception is a previous study[5] that used the YOLOv3[6] model for detecting tool tips in minimally invasive spine surgery. However, the images used in this study were collected from spine surgery, where the field of view is smaller and naturally focuses on the tool tips. In contrast, typical laparoscopic frames have a larger field of view and more complex surgical scenarios. Therefore, the methods proposed in this study are difficult to directly apply to laparoscopic tool tip detection.

Recently proposed YOLOv8[7] model has enhanced detection accuracy while maintaining high-speed inference, making it suitable for tool detection. This study explores detecting laparoscopic tool tips using the YOLOv8 model. We selected and annotated frames to create a tool tip detection dataset. An improved YOLOv8 model, tailored for laparoscopic tool detection, was trained and tested on this dataset. In surgical scenarios with fewer instrument categories, our approach demonstrated accurate tool tip detection.

2. Method

In our preliminary research on laparoscopic tool detection, we improved the YOLOv8 model. Laparoscopic tool tips, which contain critical information, appear smaller when near the image edges. To address this, we introduced the SPD-Conv module[8] into YOLOv8 to enhance the detection of smaller targets.

The SPD-Conv module, is composed with a non-strided convolution layer following Space-to-Depth (SPD) transformation. The SPD layer downsamples and rearranges the input tensor's spatial dimensions into the channel dimension. For a feature map

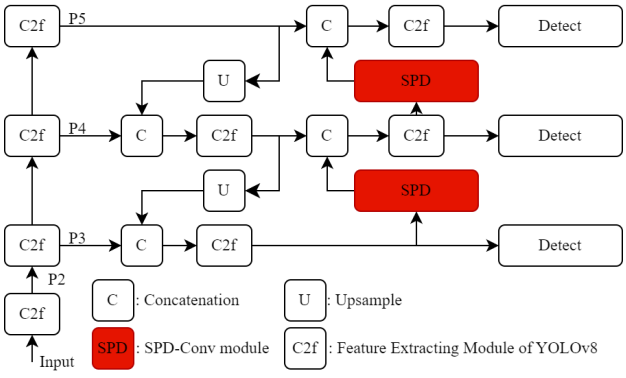


図 1　改良された YOLOv8 モデルの構造

表 1　腹腔鏡ツールの先端検出の実験結果

Laparoscopic Tool	mAP_{50}	$mAP_{50:95}$
All	0.925	0.482
Forceps	0.937	0.550
Needle Driver	0.912	0.415

X of size $S \times S \times C_1$, it generates s^2 sub-maps, each downsampled by s, concatenated along the channel axis to form a new map **X'**, size of **X'** is $(S/s) \times (S/s) \times s^2C_1$. Then, **X'** is processed by a convolution with stride 1 and a kernel count of C_2 ($C_2 < s^2C_1$).

SPD-Conv module is designed to encounter loss of feature information caused by convolution with stride larger than 1, and demonstrates improved performance in detecting small-sized target[8]. SPD-Conv module replaces the downsampling convolutional modules in YOLO models. The updated YOLOv8 network structure is shown in 図 1.

3. Experiment

In this study, the training of the improved YOLOv8 model was divided into two stages. We pre-trained the Enhanced YOLOv8 model using a combined dataset from EndoVis17[9] and EndoVis18[10].

For the surgical tool tip detection task, experimental data was collected from 10 EndoVis17 and EndoVis18. We selected 170 frames featuring suturing operation, using 103 for training and 67 for testing. All training was completed on an NVIDIA V100 GPU. Experimental result for detection of laparoscopic tool tips is shown in 表 1. 図 2 gives an example of the visualized detection results.

4. Discussion

The mAP50 scores were high across all categories, indicating effective detection of laparoscopic tool tips. However, the mAP50:95 scores were lower. This may have been due to the small size of the bounding boxes for the annotated tool tips, which affected the mAP when the IOU threshold was higher.

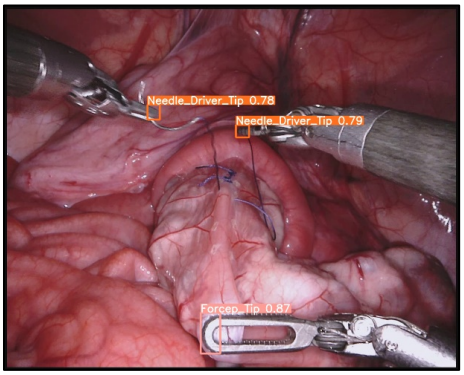


図 2 視覚化された検出結果の例

5. Conclusion

In this study, we created a dataset for detecting laparoscopic surgical tool tips in suturing operation. The dataset is used to train and test an improved YOLOv8 model tailored for laparoscopic tool detection. Experimental result proved the effectiveness of our proposed approach. However, there are some limitations, such as difficulty in determining whether detected tool tips belong to the same tool instance when the tool tips are open. To address this issue, we plan to incorporate text annotations, construct a multimodal dataset, and make improvements to model structure.

謝辞

This study was funded by MEXT/JSPS KAKENHI 21K19898, 26108006 and 17H00867 JST Moonshot R\&D JPMJMS2033, and JST CREST JPMJCR20D5.

利益相反の有無

The authors declare that they have no conflict of interest.

文　献

[1] Alkatout I, Mechler U, Mettler L et al: The development of laparoscopy—a historical overview. Front Surg 8: 799442, 2021.

[2] Hasan K, Calvet L, Rabbani N et al: Detection, segmentation, and 3D pose estimation of surgical tools using convolutional neural networks and algebraic geometry. Med Image Anal 70: 101994, 2021.

[3] Nwoye C I, Yu T, Gonzalez C et al: Rendezvous: Attention mechanisms for the recognition of surgical action triplets in endoscopic videos. Med Image Anal 78: 102433, 2022.

[4] Yang C, Zhao Z, Hu S: Image-based laparoscopic tool detection and tracking using convolutional neural networks: a review of the literature. Comput Assist Surg 25(1): 15-28, 2020.

[5] Cho S, Kim Y et al: Automatic tip detection of surgical instruments in biportal endoscopic spine surgery. Comput Biol Med 133: 104384, 2021.

[6] Redmon J, Farhadi A: YOLOv3: An incremental improvement. arXiv preprint arXiv:1804.02767, 2018.

[7] Jocher G, Chaurasia A, Qiu J: Ultralytics YOLOv8. 2023. Accessed 11 January 2024. https://github.com/ultralytics/ultralytics.

[8] Sunkara R, Luo T: No more strided convolutions or pooling: A new CNN building block for low-resolution images and small objects. Joint European Conference on Machine Learning and Knowledge Discovery in Databases: Springer Nature Switzerland 443-459, 2022.

[9] Allan M, Shvets A et al: 2017 robotic instrument segmentation challenge. arXiv preprint arXiv:1902.06426, 2019.

[10] Allan M, Kondo S, Bodenstedt S et al: 2018 robotic scene segmentation challenge. arXiv preprint arXiv:2001.11190, 2020.

色彩の分離に基づいた 3 次元点群顔データからの口唇領域の抽出

木原　成海[*1]，木村（野元）　菜美子[*2]，大河内　孝子[*2, 3]，李　光旭[*4]，中村　典史[*2, 5]，神谷　亨[*1]
[*1] 九州工業大学大学院，[*2] 鹿児島大学大学院医歯学総合研究科，
[*3] 国立病院機構鹿児島医療センター歯科口腔外科，[*4] 天津工業大学電子情報工学科，
[*5] インドネシア大学歯学部口腔顎顔面外科

Extraction of Lip Region Based on Separation of Color from 3D Point Cloud Data of Face

Narumi KIHARA[*1]，Namiko KIMURA-NOMOTO[*2]，Takako OKAWACHI[*2, 3]，
Guangxu LI[*4], Norifumi NAKAMURA[*2, 5], Tohru KAMIYA[*1]
[*1] *Kyushu Institute of Technology,* [*2] *Kagoshima University,*
[*3] *National Hospital Organization Kagoshima Medical Center,* [*4] *Tiangong University*
[*5] *Universitas Indonesia*

要旨：口唇裂は，上口唇に披裂が見られる先天異常である．口唇裂は様々な症状を引き起こし，特に顎顔面の形態異常は口唇裂患者にとって大きな心理的負担となるため，外科手術によって自然な見た目の口唇・外鼻部を形成することが重要である．口唇裂の外科手術は複数回に渡って行われることが一般的であるが，顔の左右対称性に関する基準が曖昧なことから，手術方針が医師の主観的な判断に依存することが懸念されている．そこで，顔の左右対称性を定量的に示す指標の開発が期待されている．本論文では，口唇裂の症状が現れる口唇部に注目した解析を行う準備段階として，顔を撮影した 3 次元点群データから口唇領域を抽出する手法を提案する．抽出処理では，口唇の候補領域を HSV 変換し，H（色相）に対し判別分析法を適用することにより，色彩の分離に基づいた抽出を図る．実験の結果，提案手法によって効果的に口唇領域を抽出できることを確認した．
キーワード：口唇裂，3 次元点群データ，HSV 変換，判別分析法，主成分分析

1. 序論

口唇裂は，上口唇が正常に形成されないことによって生じる先天異常である．日本人においては，出生児のうち約 500 人に 1 人の割合で発生することが知られている[1]．口唇裂の症状には，顎顔面の形態異常，哺乳障害，言語障害などがある．特に，口唇裂が引き起こす形態異常により，口唇裂患者は非口唇裂者より外見への満足度が低いことなどが報告されている[2]．したがって，口唇裂患者の QOL(Quality of Life)を向上するにあたり，外科手術によって自然な見た目の口唇・外鼻部を形成することが重要となる．しかし，口唇裂の外科手術において，顔の左右対称性の基準が曖昧であり，手術方針が医師の主観的な判断に依存することが懸念されている．この問題点を解決する方法の一つとして，顔の左右対称性を定量的に解析し，その結果をフィードバックすることによって医師の診断を客観的に支援する手法の開発が期待されている．

顔の左右対称性に関する先行研究では，3 次元データを用いて解析を行うことが一般的である．その例として，細木ら[3]や Al-Rudainy ら[4]の研究が挙げられるが，一次手術後の口唇裂患者の顔に依然として残る非対称な部分を十分に評価できないことが課題とされた．その理由として，解析のために静止画のデータを用いることが挙げられる．静止画は人の表情を瞬間的に切り取ったものであるのに対し，私たちの顔は常に動いているため，一つの静止画だけに基づいた評価では対称性の検討は不十分であると考えられる．そこで，木原らは時間的な変化を加味した 3 次元データ，すなわち 4 次元データから顔のランドマーク点の時系列変化を検出し，その結果を利用して対称性解析を行う手法を提案した[5]．しかし，評価対象がランドマーク点だけに限られることが課題とされた．

本論文では，4 次元データを用いた顔の対称性解析の準備段階として，3 次元点群顔データから口唇領域を抽出する手法を提案する．口唇裂の症状が現れる口唇領域を抽出し，それを評価対象とすることで，より広範囲の情報を取り入れた対称性解析の実現が期待される．

2. 手法

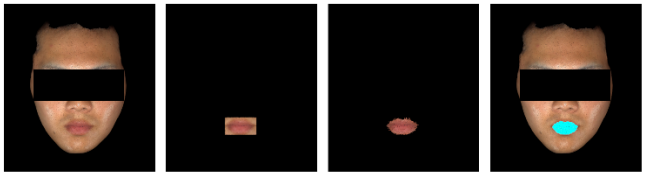
口唇領域の抽出処理は，候補領域抽出，色相分離，外れ値除去の順番で行われる．以下に各処理について述べる．

1）候補領域抽出

はじめに，MediaPipe[6, 7]を用いて顔データからランドマーク点を検出し，口唇部の上端・下端・左端・右端を表す点の座標に基づき，同部を囲むような矩形領域を候補領域として抽出する．これにより，検出対象である口唇領域の存在する範囲が候補領域内に限定される．

2）色相分離

候補領域は口唇領域と皮膚領域に大別できると考えられる．そこで，両者の色が異なることに注目し，色を二つのグループ



顔データ　候補領域　色相分離　抽出結果

図 1　口唇領域抽出の過程

に分離する処理を行う. はじめに, 候補領域の各点の色を RGB 空間から HSV 空間に変換する. ただし, 通常の色相は 0 と 360 で赤, 120 で緑, 240 で青を表すが, 候補領域に多く含まれる暖色付近で値が連続となるようにするため, 60 で青, 180 で赤, 300 で緑を表すように色相値を調整する. 次に, 調整された色相に対して判別分析法[8]と同様のアルゴリズムを適用する. 判別分析法は, グレースケール画像を二値化するための閾値を決定する手法の一つであり, 基準より小さいクラスと大きいクラスの分離度が最大となる数値を選択する. これを色相に応用することにより, 候補領域を口唇領域と皮膚領域に最もよく分離する閾値を自動で決定することができる.

3）外れ値除去

色相分離によって得られた口唇領域では, エッジ部分にまばらな点が見られる. なぜなら, 口唇領域と皮膚領域の境界は曖昧で, 色が徐々に変化するからである. エッジ部分のまばらな点は, 対称性解析においてノイズのように作用する可能性があるため, Rusu らの方法[9]によって除去する. 同手法では, 点群データの全ての点に対し, 注目点からある半径内の近傍点までの平均ユークリッド距離を計算し, 平均ユークリッド距離が大きいものを外れ値と見なして除外する. これにより, エッジ部分のまばらな点を減らすことができる. 以上の処理により, 3 次元点群顔データからの口唇領域の抽出が可能となる. 処理の過程を 2 次元画像として出力した例を図 1 に示す.

3. 実験・考察

本論文での被験者は, 一次手術を既に終えている 5 歳前後の口唇裂患者 21 名, 成人の非口唇裂者 4 名である. 3 次元点群データの取得には, Canfield Scientific 社製の VECTRA®H1 を用いた. 口唇裂患者については, リラックスした表情を正面から撮影した. 非口唇裂者については, それに加えて「ア」の発音で徐々に口を開く様子も撮影し, 将来的に 4 次元データとして扱うことを想定している.

口唇領域の抽出結果を図 2 に示す. 同図では, オリジナルデータと, それに抽出結果を水色で重ね合わせたデータを描画している. これらの画像から, 閉口状態では口唇領域を良好に抽出できていることが分かる. このことから, 顔データから候補領域を選択し, 同領域に対して色彩の分離を行うことが, 閉口状態の口唇領域の抽出に有効であることが伺える. 一方で, 開口状態では舌領域の過抽出が見られる. これは, 色彩の分離処理において, 口唇領域と舌領域の色が類似しているため, 十分に分離ができなかったからだと考えられる. 舌領域は, 顔の対称性解析という観点では不要であり, 解析処理においてノイズのように作用する可能性がある. したがって, 過抽出の抑制・除去が今後の課題である.



口唇裂患者　非口唇裂者（閉口状態）　非口唇裂者（開口状態）

図 2　口唇領域の抽出結果

4. 結論

本論文では, HSV 空間における色相の分離に基づき, 3 次元点群顔データから口唇領域を抽出する手法を提案した. 実験の結果, 閉口状態では良好に抽出できることを確認したが, 開口状態では舌領域の過抽出も見られた. 今後の課題として, 舌領域の過抽出を抑制・除去することに加え, 抽出精度を評価するための正解データの作成が挙げられる. さらに, 口唇領域の抽出結果を利用して対称性解析を行い, 口唇裂の臨床現場において有用な評価指標の開発にも取り組みたい.

利益相反の有無

なし

文　献

［1］ 高橋, 口唇裂・口蓋裂の基礎と臨床, 日本歯科評論社, 1996.

［2］ O. Hunt, D. Burden, P. Hepper et al: Self-Reports of Psychosocial Functioning among Children and Young Adults with Cleft Lip and Palate, The Cleft Palate Craniofacial Journal, Vol. 43: 598-605, 2006.

［3］ D. Hosoki, T. Kamiya, N. Kimura-Nomoto et al: Symmetric Plane Detection and Symmetry Analysis from A 3D Point Cloud Data of Face, International Conference on Control, Automation and Systems: 402-406, 2020.

［4］ D. Al-Rudainy, X. Ju, S. Stanton et al: Assessment of Regional Asymmetry of the Face Before and After Surgical Correction of Unilateral Cleft Lip, Journal of Cranio-Maxillofacial Surgery, Vol. 46: 974-978, 2018.

［5］ N. Kihara, N. Kimura-Nomoto, T. Okawachi et al: Facial Symmetry Analysis for Cleft Lip Patients from 4D Point Cloud Data, International Conference on Control, Automation and Systems: 1502-1505, 2023.

［6］ C. Lugaresi, J. Tang, H. Nash et al: MediaPipe: A Framework for Building Perception Pipelines, arXiv:1906.08172, 2019, Access 2024/5/7.

［7］ Y. Kartynnik, A. Ablavatski, I. Grishchenko et al: Real-time Facial Surface Geometry from Monocular Video on Mobile GPUs, arXiv:1907.06724, Access 2024/5/7.

［8］ ディジタル画像処理編集委員会, ディジタル画像処理, 財団法人画像情報教育振興協会（CG-ARTS 協会）, 東京都, 2004, pp. 175-176.

［9］ R.B. Rusu, Z.C. Marton, N. Blodow et al: Towards 3D Point Cloud Based Object Maps for Household Environments, Vol. 56, No. 11: 927-941, 2008.

大腸内視鏡動画像を用いた 3 次元復元に関する初期的検討

小野坂　捺 [*1], 伊東　隼人 [*2,1], 小田　昌宏 [*3,1], 三澤　将史 [*4], 森　悠一 [*5,4],
工藤　進英 [*4], 森　健策 [*1,3,6]
[*1] 名古屋大学大学院情報学研究科
[*2] 福岡大学理学部応用数学科
[*3] 名古屋大学情報基盤センター
[*4] 昭和大学横浜市北部病院消化器センター
[*5] オスロ大学医学部 健康・社会インスティテュート
[*6] 国立情報学研究所医療ビッグデータ研究センター

Preliminary Study of Three-Dimensional Reconstruction from a Colonoscopic Video

Natsu ONOZAKA[*1], Hayato ITOH[*2,1], Masahiro ODA[*3,1], Masashi MISAWA[*4], Yuichi MORI[*5,4],
SHIN-EI KUDO[*4] and Kensaku MORI[*1,3,6]
[*1] *Graduate School of Informatics, Nagoya University*
[*2] *Department of Applied Mathematics, Faculty of Science, Fukuoka University*
[*3] *Information Technology Center, Nagoya University*
[*4] *Digestive Disease Center, Showa University Northern Yokohama Hospital*
[*5] *Institute of Health and Society, University of Oslo*
[*6] *Research Center for Medical Bigdata, National Institute of Informatics*

要旨： 大腸内視鏡検査中のポリープ見落とし防止を目的に，検査中の未観測領域を検出する技術が求められている．内視鏡画像列からの大腸内腔形状の 3 次元復元により，未観測領域を未復元部分として視覚化できる．教師なし深度推定による大腸内腔形状 3 次元復元では，大腸内壁表面の非拡散反射と大腸そのものの変形が大腸内腔形状の復元精度に影響すると考えられる．非拡散反射の影響を軽減した内視鏡カメラ画像における深度推定は既に提案されているが，大腸の変形による問題は未解決である．しかし，動画像中の近いフレーム間のポーズ推定のみを考えれば，変形は小さいと仮定できる．本稿では大腸内壁表面の非拡散反射の影響を抑えた深度推定手法の訓練済みモデルを，教師なし深層学習による 3 次元形状復元手法へ組み込み，様々な内視鏡画像列から復元を行う．大腸内腔形状の復元結果より，ポーズ推定が一定の性能で機能している一方，カメラの動きが複雑なシーンで復元精度が低下するようにみえることを確認した．
キーワード：大腸内視鏡，3 次元復元，教師なし学習，深度推定，ポーズ推定

1. はじめに

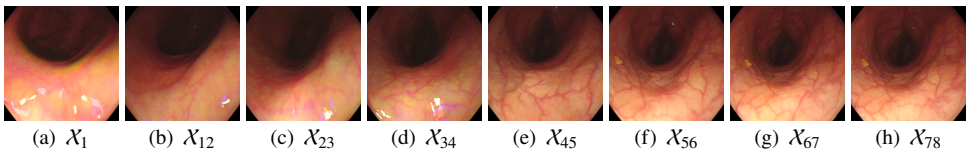
内視鏡検査中の大腸ポリープ見落としを防ぐ計算機支援診断技術として，内視鏡動画像列からの大腸内腔形状の 3 次元復元がある．未観測領域は，復元されず欠損することで視覚的にわかりやすく示せる．教師なしモデルに基づく深度・ポーズ推定の学習による大腸内腔形状の 3 次元復元では，大腸内壁表面の非拡散反射と大腸そのものの変形が学習時に悪影響を与えると考えられる．拡散反射モデルに基づく仮想大腸内視鏡画像の生成を補助タスクに加えたドメイン変換により，非拡散反射の影響を軽減した大腸内視鏡カメラ画像からの深度推定 [1] は提案されている一方で，大腸の変形の課題は未解決である．本稿では，大腸内壁表面の非拡散反射の影響を抑えた深度推定の訓練済みモデルを，教師なし深層学習による 3 次元復元手法へ組み込み，様々な内視鏡画像列から大腸内腔形状の 3 次元復元を行う．文献 [2] では最大 10 枚の画像からの形状復元にとどまっていたが，本稿では使用する画像枚数を増やし，よりカメラの移動が大きいシーンからの大腸内腔形状復元性能について調査する．内視鏡画像列の違いが復元精度に与える影響を調査することで，教師なしモデルに基づく大腸内腔形状復元に関する今後の改善に向けた知見を得る．

2. 手法

SfMLearner に代表される深層学習による教師なし深度推定モデルは，深度推定ネットとポーズ推定ネットの二つの深層ネットワークからなる [3]．教師なし深度推定モデルを用いた大腸内腔形状の復元における課題のひとつに，非拡散反射の影響で正確な深度推定ができないことが挙げられる．本稿では SfMLearner から各種の改良がなされたモデルである Monodepth2 [4] の深度推定部分を，拡散反射モデルに基づく深度推定 [1] の学習済みモデルに置き換える．MonoDepth2 のポーズ推定部分のみを学習させ，大腸内腔形状の復元における非拡散反射の影響を軽減する．

3. 実験と結果

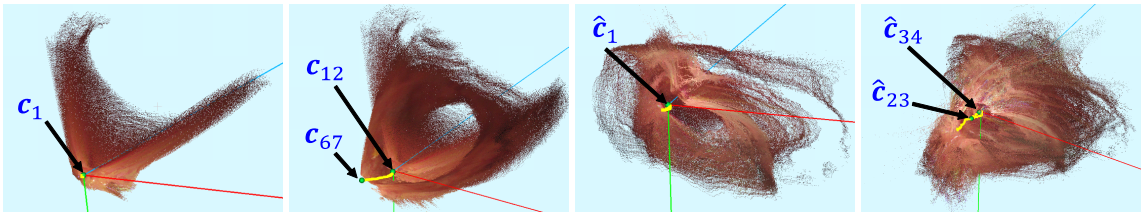
深度推定モデルは，RGB 3 チャネルの実内視鏡画像 9,189 枚と RGBD 4 チャネルの仮想内視鏡画像 8,085 枚で学習済みの重みを



(a) $\mathcal{X}_1$ (b) $\mathcal{X}_{12}$ (c) $\mathcal{X}_{23}$ (d) $\mathcal{X}_{34}$ (e) $\mathcal{X}_{45}$ (f) $\mathcal{X}_{56}$ (g) $\mathcal{X}_{67}$ (h) $\mathcal{X}_{78}$

(i) $\mathcal{Y}_1$ (j) $\mathcal{Y}_{12}$ (k) $\mathcal{Y}_{23}$ (l) $\mathcal{Y}_{34}$ (m) $\mathcal{Y}_{45}$ (n) $\mathcal{Y}_{56}$ (o) $\mathcal{Y}_{67}$ (p) $\mathcal{Y}_{78}$

図 1 内視鏡時系列画像シーン 1：$\{\mathcal{X}_1, \mathcal{X}_2, \ldots, \mathcal{X}_{80}\}$ およびシーン 2：$\{\mathcal{Y}_1, \mathcal{Y}_2, \ldots, \mathcal{Y}_{80}\}$ の一部．シーン 1 は一定の速さでカメラがまっすぐ引き抜かれるシーン，シーン 2 はカメラの前進と後退，回転運動があるとみられるシーン．



(a) シーン 1；15 枚 (b) シーン 1；80 枚 (c) シーン 2；15 枚 (d) シーン 2；80 枚

図 2 シーン 1，2 の画像列から再投影した 3 次元点群．1 枚目の画像を撮影した内視鏡の光学中心を原点として，赤が X 軸，黄緑が Y 軸，青が Z 軸（奥行き方向）を表す．黄は推定カメラ位置で，$\mathcal{X}_t, \mathcal{Y}_t$ におけるカメラ位置をそれぞれ $\boldsymbol{c}_t, \hat{\boldsymbol{c}}_t$ とする．

利用し [1]，ポーズ推定の学習時，深度推定の重みは更新しない．ポーズ推定 [4] の学習には，訓練データに 40,577 枚，検証データに 4,509 枚の RGB 3 チャネルの実内視鏡画像を用いた．大腸内腔形状の復元に用いる画像列は，大腸の変形が小さく，カメラの回転や移動が一定程度あるとみられるシーン（30fps）から 1 フレーム単位で切り出した画像列を用いた．ここで，拡散反射モデルに基づく深度推定では，カメラ中心から大腸壁までの物理的距離を 0-10cm の範囲で推定する．そのため，10cm より遠い距離もすべて 10cm として推定される．さらに，光源からの距離の二乗オーダで光量は減衰するため，カメラから一定以上離れた位置の深度推定は不安定になる．したがって，復元時に閾値以上の推定深度値のピクセルは無視する．さらに，大腸内腔形状の 3 次元復元に加え，ポーズ推定モデルの出力からカメラの軌跡を推定した．図 1 に復元に用いたシーンを，図 2 に復元結果とカメラの推定位置を示す．

4. 考察

図 2 の座標系においてカメラの推定位置は，内視鏡が後ろに進む $\mathcal{X}_{12}$ から $\mathcal{X}_{67}$ では Z 軸の負の方向へ，内視鏡が前に進む $\mathcal{Y}_{23}$ から $\mathcal{Y}_{34}$ では正の方向へ変化し，実際の内視鏡の動きと推定位置の変化に類似性が観測できた．シーン 1 に比べてカメラの動きが複雑なシーン 2 では，大腸内腔形状が正しく復元されていないことが知られた．シーン 2 において復元精度が低い要因の一つに，ポーズ推定の精度が不十分であることが考えられる．MonoDepth2 は，深度とポーズの推定結果から異なるビュー間の画像を再構成し，ピクセル間の再投影誤差が小さくなるようネットワークを学習している．そのため，深度推定が不安定な領域がポーズ推定の学習にも悪影響を与えるとみられる．したがって，ポーズ推定の学習時，深度推定が不安定な領域を用いないことで推定精度が改善する可能性がある．また，3 次元復元時の誤差を抑える一般的方法にバンドル調整があるが，大腸内壁表面のテクスチャは画像間で対応する識別的な局所特徴がほぼ無いため適用が難しいと予想される．大腸特有の性質を考慮した工夫が必要である．

5. むすび

異なる 2 つの画像列から 3 次元復元を行った．今後，カメラがまっすぐ移動しないシーンの画像列でも大腸内腔形状の復元精度が落ちないよう学習および復元手法の改善が必要である．

謝辞 本研究は JST【ムーンショット型研究開発事業】【JPMJMS2214】の支援を受けた．

利益相反の有無

なし．

文献

[1] H. Itoh, et al: Unsupervised colonoscopic depth estimation by domain translations with a Lambertian-reflection keeping auxiliary task, IJCARS 16: 989-1001, 2021

[2] 小野坂捺，他：教師なしモデルベース深度推定を利用した大腸の 3 次元形状復元，信学技報 MI2023-60: 87-90, 2024

[3] T. Zhou, et al: Unsupervised learning of depth and ego-motion from video, Proc. CVPR: 1851-1858, 2017

[4] C. Godard, et al: Digging into self-supervised monocular depth estimation, Proc. ICCV: 3828-3838, 2019

Radiology Report Generator using Transformer with Image Enhancement Analysis

Hilya TSANIYA*[1], Takashi OBI [*2], Joong Sun LEE[*2], Chastine FATICHAH*[1], Nanik SUCIATI*[1]

[*1] *Department of Informatics, Faculty of Electrical Technology and Intelligent Information Technology, Institut Teknologi Sepuluh Nopember, Indonesia*

[*2] *Department of Information and Communications Engineering, Institute of Innovative Research, Tokyo Institute of Technology, Japan*

Abstract : It takes a lot of time and requires the involvement of skilled radiologists to compose a radiology report. Therefore, it would be beneficial to have technology that can produce a report automatically. Developing a coherent predictive text is the main challenge in automatic report generation. It is necessary to develop methods that can increase the relevance of features in producing predictive text. To leverage the visual and semantic features, the transformers method is used. An enhancement method was also used to improve the noise-prone nature of the medical image. Therefore, this study constructed a medical report generator model using the transformer approach and image enhancement implementation. The proposed model is an encoder-decoder with text feature embedding using the Transformer method and visual feature extraction utilizing a pre-trained ChexNet that is also used for multi-label classification for abnormalities tags with a Multi-Head Attention (MHA) mechanism. The image data quality was also improved by applying the gamma correction method. The use of gamma correction produces medical images with a more scattered histogram representation. The comparison of the report-generated performance is evaluated using a Bilingual Assessment Understudy (BLEU). The MHA model with a gamma correction obtains 5% better using BLEU with a 4 n-gram evaluation value than the model without gamma correction implementation. The MHA model also produces 15% better results than the baseline model. This method is able to outperform the baseline model and other previous works. In conclusion, the use of the transformer is effective in leveraging visual and text features for generating medical reports. The addition of an image enhancement approach has also been found to have an impact on the model's performance.

Keywords: Medical Image Captioning, ChexNet, Multi-Head Attention, Image Enhancement, BERT Embedding

1. Introduction

A radiology report contains diagnoses based on radiology medical images interpreted by radiologists. The radiologists examine patient images for abnormalities and write medical reports to arrive at a final diagnosis. This process can be tedious, especially for less-experienced radiologists. According to a study [1], the workload of radiologists has continued to increase significantly in the last decade. Automatic radiology report could help alleviate this burden and minimize human errors.

Deep learning approaches have been explored to tackle various problems such as generating better-structured radiology reports [2], leveraging information by exploring features from visual region and text input [3], and utilizing pre-trained models to balance visual input with semantic knowledge from the radiology reports [4]. Recently, cross-modal confounders were explored to mitigate data bias and leverage linguistic knowledge [5].

However, there are still several issues to address in medical report generation. Image quality often decreases due to the acquisition process [6]. The process of predicting tags for abnormality detection is crucial for extracting regional information, which subsequently influences the generation of medical report. In this study, we address these problems using a contrast-based enhancement method to improve the medical image quality. We also use a pre-trained model to extract the visual features for predicting tags of the images. These tags enhance the text embedding by multiplying the weights, thereby increasing the semantic information used to generate medical reports.

2. Proposed Method

A model to generate medical reports has been developed, utilizing the pre-trained model ChexNet [7] as a visual feature extractor to predict image tags and generate radiology reports. This pre-trained model is fine-tuned with a dataset for tag prediction with 180 target labels. The features extracted from medical images are then used in the report generation training process. The proposed solution is illustrated in Figure 1.

The experiment was conducted on the Indiana University dataset from Open-I, which contains 5,072 records with 9,199 images and 3,973 tags associated with the radiograph images. The dataset also included tags extracted from the images using the MTI labeler. The images were processed with ChexNet, unfreezing the last layer to predict tags and extract features for text prediction. Text features were extracted using the BERT architecture to obtain the report embedding. These two inputs are aligned to capture the context for the image regions and report text using multi-head attention, and then passed to GPT-2 as a decoder during the training process.

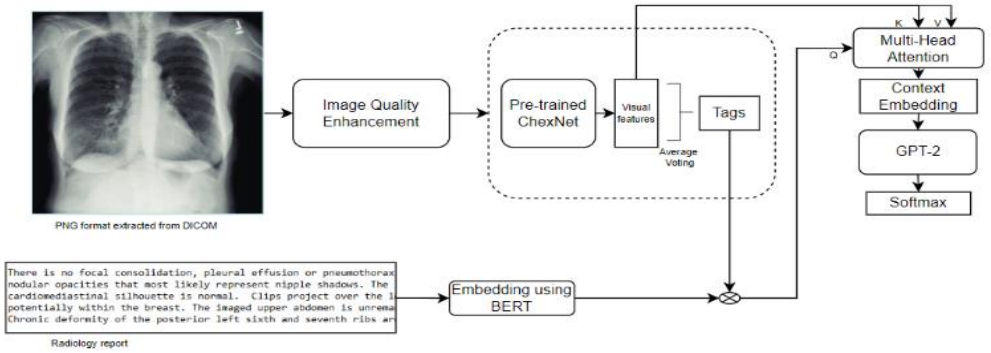


Fig 1. Proposed methodology overview

3. Result and Discussion

The output includes tags for the medical images and diagnostic text. The results show a tag prediction accuracy of 76%. We also compared the performance of the combination of the pre-trained model as a visual extractor with a transformer and the addition of contrast-based enhancement, which improved model performance. The comparison includes the impact of image enhancement and context-building multi-head attention (MHA). The model was evaluated using BLEU scores for n-grams ranging from 1 to 4. These scores were calculated based on the precision of similarity between the predicted text and the ground truth, considering n words at a time, as defined by Equation (1). The results are summarized in Table 1.

$$BLEU = BP.exp\sum_{n=1}^{N} w_n log p_n \quad (1)$$

Table1. Comparison using BLEU evaluation

Model	BLEU Evaluation			
	BLEU-1	BLEU-2	BLEU-3	BLEU-4
ChexNet-GPT-2	0.2757	0.2857	0.2907	0.3317
ChexNet-GPT-2 + Image Enhancement	0.2783	0.2868	0.2919	0.3482
ChexNet-GPT-2 + MHA	0.2893	0.2932	0.3239	0.3814
ChexNet-GPT-2 + Image Enhancement + MHA	**0.3089**	**0.3177**	**0.3240**	**0.3865**

Based on Table 1, The implementation of image enhancement and MHA for context building achieved 5% better performance compared to the model without image enhancement, and 15% better performance with MHA, as evaluated by BLEU.

4. Conclusion

In conclusion, the integration of image enhancement techniques and multi-head attention (MHA) for context building has significantly improved model performance over the traditional encoder-decoder architecture. The combination of these methods not only enhances the accuracy of tag prediction but also improves the quality of the generated diagnostic text. The results, as evidenced by the BLEU scores, indicate that the proposed methodology is more effective in capturing the contextual information of medical images, leading to more accurate and reliable radiology reports. This advancement underscores the potential of leveraging advanced deep learning techniques to improve automated medical report generation, ultimately contributing to more efficient and accurate medical diagnostics.

References

[1] L. I. T. Lee, S. Kanthasamy, R. S. Ayyalaraju , R. Ganatra, "The Current State of Artificial Intelligence in Medical Imaging and Nuclear Medicine," *British Institute of Radiology Journal,* 第 卷 1, 第 1, 2019.

[2] M. Li, B. Lin, Z. Chen, H. Lin, X. Liang , X. Chang, "Dynamic Graph Enhanced Contrastive Learning for Chest X-ray Report Generation," 著: *2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Vancouver, 2023.

[3] T. Tanida, P. Muller, G. Kaissis , D. Rueckert, "Interactive and Explainable Region-guided Radiology Report Generation," 著 : *2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Vancouver, 2023.

[4] J. Chen, H. Guo, K. Yi, B. Li , M. Elhoseiny, "VisualGPT: Data-efficient Adaptation of Pretrained Language Models for Image Captioning," 著: *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Orleans, 2022.

[5] W. Chen, Y. Liu, C. Wang, J. Zhu, S. Zhao, G. Li , C.-L. Liu, "Cross-Modal Causal Intervention for Medical Report Generation," 著: *IEEE Conference*, 2024.

[6] H. Tsaniya, C. Fatichah , N. Suciati, "Exposure Fusion Framework in Deep Learning-Based Radiology Report Generator," *IPTEK Journal of Science and Technology,* 第 卷 33, 2022.

[7] P. Rajpurkar, J. Irvin, K. Zhu, B. Yang, H. Mehta, T. Duan, D. Ding, A. Bagul, C. Langlotz, K. Shpanskaya, M. P. Lungren , A. Y. Ng, "CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning," Arxiv, 2017.

PET-CT 画像所見文における部位および正常/異常識別のための深層学習モデルの構成に関する検討

山中　唯歩生[*1]，成田　紗弥[*1]，間普　真吾[*1]，楊　鯤昊[*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

Design of Deep Learning Models for Anatomic and Normal/Abnormal Classification in the Sentences of PET-CT Image Findings

Ibuki YAMANAKA[*1], Saya NARITA[*1], Shingo MABU[*1], Kunhao YANG[*1], Shoji KIDO[*2]
[*1] *Graduate School of Sciences and Technology for Innovation, Yamaguchi University*
[*2] *Graduate School of Medicine, Osaka University*

要旨：本研究では大量に蓄積された PET-CT 画像所見文をもとに，機械学習に適した教師ラベル付きデータセットを構築することを目的としている．先行研究では自然言語処理ニューラルネットワークの一つである UTH-BERT で画像所見文を解析し，全身，頭部，頭頚部，胸部，腹部，その他の部位に文章を分割する方式を提案した．この方式では入力に識別対象文だけでなくアテンションが付与された前文も利用することで，識別における前文の重要性を判定できるようになった．一方，機械学習に適したデータセットを構築するにあたり，部位ごとのデータとして整理され，正常と異常のラベルも付与されているのが望ましい．したがって，本研究では部位識別に加えて正常/異常のクラス識別も行うモデルに拡張した．前文と識別対象文を利用したモデルにおいて，部位および正常異常識別の 2 つのタスクを効果的に実行するための最適なモデルの構成について検討した．

キーワード：PET-CT 画像所見文，自然言語処理

1. はじめに

先行研究[1]では，ラベル付きデータセット作成の第 1 段階として，PET-CT 画像所見文に着目し，それらを自然言語系ニューラルネットワークで解析し，全身，頭部，頭頚部，胸部，腹部，その他の文章に分割し，部位ごとの所見文を作成することを目的とした．具体的には，識別対象文以外にアテンションを付与した前文を利用して部位識別を行った．しかし，コンピューター支援診断モデルの構築においては，教師あり学習や性能評価のために異常と正常のラベルも付与されていることが望ましい．しかし，異常・正常を識別させるモデル構築のために大量の教師ラベル付きデータを用意することは，データセット生成を効率的に行う本研究の目的の一つに反する．したがって，これまで開発してきたモデルを拡張し，部位識別に加えて正常/異常のクラス識別を効果的に行うモデルの構築を目指す．

2. 構成

先行研究のモデルでは，識別対象文とその前文の特徴量をそれぞれ別の UTH-BERT[2]から取得する．まず，注意機構[3]で識別対象文と前文の特徴量から前文の重要度を算出する．この重要度は，識別対象文に対してその前文の特徴量が文脈としてどれだけ重要であるかを示す．そして，重要度と前文の特徴量の積によって重要度に応じた特徴量を抽出する．次に，重み付けされた前文の特徴量と識別対象文の特徴量を連結させて，全結合層に接続することで部位識別を行う．本研究では，UTH-BERT と注意機構を有する本モデルを基盤とし，正常と異常の識別も効率的に行うことが可能となる最適なネットワークの構成を明らかにするため研究を行った．検証した構成は 4 種類であり，表 1 のようにまとめられている．構成 1 は，先行研究のモデル(2 つの UTH-BERT で特徴抽出を行うモデル)に部位識別と正常/異常識別を行う全結合層をそれぞれ追加し，2 つの識別目的に対して同時に学習するモデルであり，図 1 に示す構造を有する．構成 2 では，識別対象文と前文で UTH-BERT1 つを共有し，2 つの識別目的に対して同時に学習する，構成 3 では，2 つの UTH-BERT を用いるものの，部位識別と正常/異常識別のネットワークをそれぞれ独立に学習する方式である．構成 4 は，UTH-BERT を 1 つ，2 つの目的をそれぞれ独立に学習する方式である．構成 1 と 2 では，特徴抽出層を 2 つの目的で共有させ，構成 3 と 4 では共有させないことの影響を検証している．また，構成 1 と 3 では識別対象文と前文の特徴抽出をそれぞれ別の UTH-BERT で行った場合，構成 2 と 4 では共通の UTH-BERT で行った場合を検証している．

表 1：各構成のモデルの構造

	学習方法		UTH-BERT 数	
	同時	独立	2	1
構成 1	○		○	
構成 2	○			○
構成 3		○	○	
構成 4		○		○

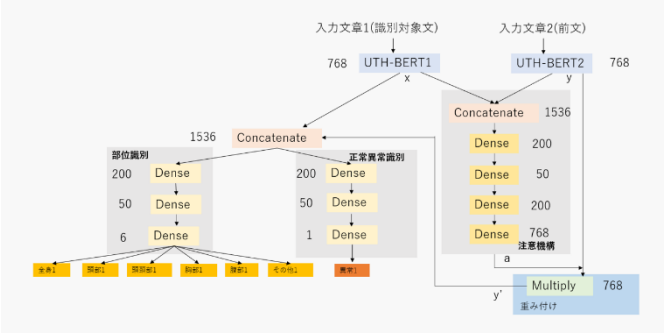


図 1：構成 1 のモデルの構造

表 3：Accuracy による正常異常識別の性能比較

	Accuracy
構成 1	0.962
構成 2	0.963
構成 3	0.961
構成 4	0.964
構成 4 の前文なし	0.956

表 2：F 値による部位識別の性能比較

	全身	頭部	頭頚部	胸部	腹部	その他	平均
構成 1	0.788	0.802	0.851	0.949	0.947	0.851	0.865
構成 2	0.795	0.790	0.862	0.951	0.952	0.855	0.868
構成 3	0.800	0.809	0.866	0.951	0.951	0.861	0.873
構成 4	0.787	0.854	0.866	0.954	0.956	0.866	0.880
構成 4 の前文なし	0.790	0.804	0.800	0.921	0.921	0.837	0.846

3. 実験

3.1 データセット

実験には，医療法人仁泉会 MI クリニックから提供された PET-CT 画像所見文を用いる．

3.2 部位識別比較

部位識別の結果を表 2 に示す．構成 1 と比較して，構成 2 は頭部を除いて F 値は向上した．構成 3 と比較して，構成 4 は全身を除いて F 値は向上した．これらの比較から，BERT を 2 個使用するより，1 個使用して識別対象文と前文の特徴抽出ネットワークを共有する方が，性能は向上することが分かる．構成 1 と比較して，構成 3 の方が F 値は高く，構成 2 と比較して，構成 4 の方が F 値は高い．よって，部位識別と正常異常識別を同時に行う学習より，部位識別だけを行う学習の方が性能は向上した．一番性能の高い構成 4 において，前文なしの場合と比較すると，前文ありの構成 4 が良い性能を示した．

3.3 正常異常識別比較

表 3 は正常異常識別の結果を表しており構成 4 が最も良い結果を示した．また，構成 1 と比較して構成 2 の Accuracy が向上しており，構成 3 と比較して構成 4 の Accuracy は向上していることから，BERT2 より 1 個の方が，性能は向上することが分かった．構成 4 において，前文なしの場合の性能が低下することが分かった．

4. まとめ

部位識別においては，BERT を 2 個用意するよりも 1 個を共有する方が性能は高く，正常異常識別と同時に学習するより部位識別だけの学習の方が性能は高くなった．よって，BERT を 1 個使用して部位識別だけの学習を行う場合が最適なモデルとなった．正常異常識別において，BERT を 2 個用意するよりも 1 個用意する方が性能は高くなった．したがって，BERT を 1 個使用して正常異常識別だけの学習を行う場合が最も良好であった．

謝辞

本研究は JSPS 科研費 JP21H03840，JP22K12152 の助成を受けたものです．

利益相反の有無

大阪大学大学院医学系研究科人工知能画像診断学共同研究講座は，富士フィルム株式会社との共同講座です．

文　献

[1] 成田紗弥，間普真吾，木戸尚治：UTH-BERT と注意機構を用いた医療診断レポートにおける部位識別..第 42 回日本医用画像工学会大会,2023,pp223-224

[2]Yoshimasa Kawazoe, Daisaku Shibata, Emiko Shinohara et al.. A clinical specific bert developed using a huge japanese clinical text corpus. PLos One, Vol. 16, No.11,p.e0259763,2021.

[3]岡谷貴之，深層学習 改訂版第 2 版，講談社，2022，pp149-153

ChatGPT は整形外科専門医試験に合格可能か？
～医療画像認識能力を含めた成績の検討～

中嶋　望[*1]，藤森　孝人[*2]
[*1] 堺市立総合医療センター　整形外科
[*2] 大阪大学大学院　整形外科

Can ChatGPT pass the Japanese Board of Orthopaedic Surgery Examination?
The results include medical image recognition.

Nozomu NAKAJIMA[*1]，Takahito FUJIMORI[*2]
[*1] *Department of Orthopedic Surgery, Sakai City Medical Center*
[*2] Department of Orthopedic Surgery, Graduate School of Medicine, Osaka University

要旨：【目的】人工知能の進歩により，医師を含む士業の仕事にも今後活用されるのは間違いない．現時点における大規模言語モデル（ChatGPT）の性能を，整形外科専門医試験を用いて評価する．【方法】過去３年分（２０２１－２０２３年）の試験問題を使用して正答率を調べた．ChatGPT のモデルは GPT-3.5 と GPT-4 を使用した．画像を含む問題について，GPT-3.5 に対しては画像なしでの出題としたが，GPT-4 については画像なしの場合と画像を含めた場合の双方での成績を比較した．【結果】GPT-3.5 と GPT-4 の正答率はそれぞれ 30%（28-32%）と 58%（55-60%）であった．GPT-4 は合格点を上回っていたが，GPT-3.5 は合格レベルに達しなかった．画像問題では，画像の有無で成績に差を認めなかった．【結論】知識としては整形外科専門医試験に合格可能なレベルにあるが，hallucination（幻覚）などの問題があり実臨床への応用にはまだ課題がある．医療画像の認識能力についてはまだ不十分であるが，学習を重ねることで改善の余地がある．
キーワード：AI，大規模言語モデル，ChatGPT，整形外科専門医試験

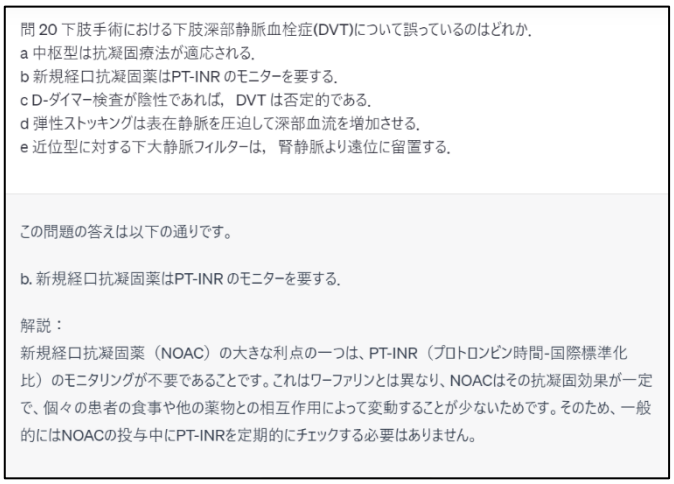
1. はじめに

2022 年に ChatGPT が発表されて以来，大規模言語モデルは世界的な注目を集めており進化が著しい．多言語対応，自然な会話，膨大な知識といったスキルを持ち，医療分野でも注目されている．初期モデルである GPT.3.5 は米国医師国家試験に合格可能レベルと報告された[1]．2023 年 3 月にはバージョンアップした GPT-4 が発表され，大幅に精度が向上した．画像認識、音声認識など，multimodal な機能も順次追加されており，今後も進化が予想される．本研究では，代表的な大規模言語モデルの一つである ChatGPT を用いて，整形外科専門医試験（JBOSE）における現時点での性能を，画像認識能力を含めて評価することを目的とした．

2. 方法

整形外科専門医試験は，2 年間の初期研修の後に専門施設で 3 年 9 か月の研修を受けた医師が受ける試験で，1 年に 1 回開催される．CBT（Computer Based Testing）形式で 100 問出題され，選択肢回答式である．今回は，2021 年～2023 年に開催された第 33～35 回の試験を使用した．試験問題，正解は日本整形外科学会のホームページからダウンロードした[2]．

大規模言語モデルとして，GPT-3.5 及び GPT-4 を使用した．問題文と選択肢はテキストデータで一問ずつ入力して回答させた（図１）．画像付きの問題は，GPT-3.5 ではテキストデータのみ入力し，GPT-4 ではテキストデータのみの場合と画像付きの場合の 2 通りで入力した．評価は，それぞれのモデルで正答率を計算し，試験に合格可能かどうか判定を行った．合格点は公開されていないが，公表されているデータ（総受験者数、合格者数、平均点、標準偏差）を用いて算出した．



（図１）テキスト問題の入力例（正答）．

3. 結果

【基本データ】

合格点は，第 33 回が 43.7%，第 34 回が 53.8%，第 35 回が 52.7%と算出された．試験後に公式発表される削除問題を除き，テキスト問題・画像問題の割合は，それぞれ 77 問・21 問，73

問・26 問，64 問・33 問であった．

【各モデルの成績】

各モデルにおいて，画像問題では正答率が下がる傾向にあった．GPT-4 の正答率は全問題でそれぞれ 60%（33 回），55%（34 回），60%（35 回）であり，合格点を上回った．画像問題を除いた場合には 64%，63%，73%であり受験者平均と同程度であった．画像問題の正答率は 38%，35%，39%であり，テキストデータのみの入力とした場合（48%，31%，36%）と同程度の正答率であった．GPT-3.5 の正答率は 28%，32%，30%となり，いずれの年度でも合格点に達しなかった．

4. 考察

整形外科分野における ChatGPT の性能として，英語ベースの試験では Kung らが GPT-3.5 が卒後 1 年目レベル，GPT-4 では卒後 5 年目で合格可能なレベルと報告している [3]．一方で，GPT-4 でも合格レベルに達しないとした報告 [4] もあり，様々である．合格点の違いもあり一概に比較は出来ないが，本研究では GPT-4 であれば日本の整形外科専門医試験に合格可能と示された．GPT-3.5 においては言語間の性能差が大きく [5]，英語以外では精度が大きく下がっていたが，GPT-4 では解消されている．専門分野においては，学習データが少なくなるため，学習言語の違いにより精度に差が出ている可能性はある．

画像問題においては，テキストのみで主題した場合と比較して正答率が変わらなかった．回答を見ると，例えば骨折の画像を見たときに「骨折である」という所までは判断出来るが，それ以上の情報（骨折の新しさ，内的原因の有無，骨の強度など）が判断出来ない．専門医試験では基本的に骨折の有無が分かるだけで回答できる問題はないため，正答に結びつかない．医療画像については個人情報保護の観点から Web 上に出回ることは少なく，学習データが不足している可能性がある．

ChatGPT は専門家に匹敵する知識を持ち合わせている事が分かるが，回答のランダム性や Hallucination といった問題点が挙げられる．ChatGPT の根幹をなす Transformer の性質として，同じ質問をしてもタイミングによって回答が異なる場合がある．また間違った情報であっても，あたかも事実であるかのように生成する事があり，“Hallucination”と呼ばれている．一見，事実の様に見えるため専門家でないと真偽の判断が困難である場合が多い．これらの問題は，人工知能を医療現場に応用するにあたり患者の不利益を来す可能性が高く，大きな課題である．

現状としてはサポート役としての機能に留まり，最終的には医者の確認が必須な AI であると思われる．しかし広範囲における専門的な知識やユーザーフレンドリーな使用感，マルチモーダルな機能は，非常に強力なツールとなる可能性を秘めている．医療画像の認識能力については不十分であり特有の問題点もあるが，AI の進歩は著しく，今後も定期的に評価を行う必要がある．

利益相反の有無

なし

文　献

[1] Kung TH, Cheatham M, Medenilla A, et al. Performance of ChatGPT on USMLE: Potential for AI-assisted medical education using large language models. PLOS Digital Health. 2023;2(2).

[2] The Japanese Orthopaedic Association. Accessed October 16, 2023. https://www.joa.or.jp/english/

[3] Kung JE, Marshall C, Gauthier C, Gonzalez TA, Jackson JB. Evaluating ChatGPT Performance on the Orthopaedic In-Training Examination. JBJS Open Access. 2023;8(3).

[4] Saad A, Iyengar KP, Kurisunkal V, Botchu R. Assessing ChatGPT’s ability to pass the FRCS orthopaedic part A exam: A critical analysis. Surgeon. Published online October 1, 2023. doi:10.1016/j.surge.2023.07.001

[5] Seghier ML. ChatGPT: not all languages are equal. Nature. 2023;615(7951):216.

紙ベースで取得された患者報告型アウトカムを画像化して、自動読み取りする AI の開発

藤森　孝人[*1]，喜多洸介[*2]，鈴木 裕紀[*2]，蟹江 祐哉[*1]，古家 雅之[*1]，
岡田 誠司[*1]，木戸 尚治[*1]

[*1] 大阪大学大学院医学系研究科器官制御外科学整形外科

[*2] 大阪大学大学院医学系研究科人工知能画像診断学講座

Development of Artificial Intelligence for Automated Entry of a Paper-Based Questionnaire on Patient-Reported Outcomes using Deep Learning

Takahito Fujimori[*1], Kosuke Kita[*2], Yuki Suzuki[*2], Yuya Kanie[*1], Masayuki Furuya[*2], Seiji Okada[*1], Shoji Kido[*2]

[*1] *Osaka University Graduate School of Medicine Department of Orthopaedic Surgery*

[*2] *Osaka University School of Medicine Graduate School of Medicine Diagnostic and Interventional Radiology*

要旨：【目的】深層学習を用いて患者報告型アウトカムを自動集計する人工知能を開発すること.
【方法】大学病院で収集したアウトカム用紙(1305 セット)を訓練データ、関連病院で収集した用紙(483 枚)をテストデータとした. 用紙を JPG に変換し, 各ページを画像として認識させた． 各質問毎に全結合層を設けて, 読み取り結果を求めた．評価指標として選択肢問題は Accuracy を,VAS は相関係数及び絶対誤差を算出した. EfficientNetB0 をモデルとして使用した.【結果】選択肢問題の Accuracy は,2 択問題で 99.9%, 5 択問題で，99.2%，全体で 99.7%であった. VAS の相関係数は 0.989, 絶対誤差は平均 0.34, 中央値 0.25 であった. 【結論】アンケート用紙からの自動読み取り AI は,高い精度の結果を示し,実用的なツールになると考えらえた.

キーワード：深層学習, 患者報告型アウトカム, 自動読み取り, 日本整形外科学会腰椎評価質問票, VAS

1. はじめに

腰痛は世界中で約 5 億 7,000 万人が罹患しており, 健康関連患者報告アウトカム（HR-PRO）を用いた QOL 評価が重要である. 現在の紙ベースのデータ収集は主に光学式文字認識（OCR）技術に使用しているが, 専用のフォーム以外には対応できない. 本研究では, 紙ベースの HR-PRO を画像化し,DL モデルで データ収集の自動化を目指した.

2. 方法

質問票データセット

対象は, 日本整形外科学会腰痛評価質問票（JOABPEQ）で, この HR-PRO は多言語で検証され, 世界中で使用されている. JOABPEQ は 3 ページからなり, 25 のカテゴリー別質問と 3 つの視覚的アナログスケール（VAS）がある. 患者は選択肢から適切な回答を選び, VAS では 0 から 10cm の直線に痛みのレベルを示す.

対象施設

2016 年 4 月 1 日から 2021 年 4 月 1 日までに, 学術医療センターと地域医療センターで JOABPEQ を記入した患者のデータを使用した. 学術センターから 1698 人, 地域センターから 537 人のデータが収集された.

グランドトゥルース

データ入力は専門会社に委託し, 2 人の入力者が独立して作業した. 一致した回答を正解とし, 矛盾がある場合は別の監督者が最終判断を行った. VAS は 2 人の測定値の平均を取った. 欠損を除外し, 最終的に学術センターから 1305 枚, 地域センターから 483 枚の JOABPEQ 用紙を使用した.

前処理

JOABPEQ フォームの PDF を JPEG 形式に変換し, 640×880 ピクセルにリサイズした.

モデルの構築

事前に訓練された CNN（EfficientNetB0）を用いて特徴量を抽出し, 各ページ毎に処理した. 抽出された特徴量を用いて完全連結層（FC）を構築し, 5 重の交差検証を用いて訓練した. クロスエントロピーと平均二乗誤差を損失関数として使用し, アダム・オプティマイザを用いてモデルを訓練した.

性能評価

学術センターで訓練したモデルを地域センターの 483 の JOABPEQ フォームで評価した. カテゴリ質問の精度と VAS のピアソン相関係数（R 値）を計算し, 絶対誤差も評価した.

精度を高める自動除外システム

精度を向上させるため, カットオフ値以下の予測確率を持つ質問を自動的に除外するアルゴリズムを考案した.

3. 結果

DL モデルの構築

5 つの異なる Fold でモデルを構築し, テストデータセットでのカテゴリ質問の全体的な精度は Fold:1 が 0.994, Fold:2 が 0.993, Fold:3 が 0.996, Fold:4 が 0.986, Fold:5 が 0.992 であった. これらのモデルを統合することで, DL モデルはテストデータセットで 0.997 の総合精度を達成した.

カテゴリ質問に対する精度

各カテゴリカル質問に対する精度は 0.981 から 1.000 の範囲であった. 特に, 2 つの選択肢を含む質問は 0.999 の高い精度を示し, 5 つの選択肢を提供する質問は 0.992 の精度を示した.

自動除外システムによる精度向上

確率のしきい値を 0.695 に設定すると, JOABPEQ フォームの 1%が除外され, 全体の精度は 0.9995 に達した. 確率のしきい値を 0.9996 に設定すると, JOABPEQ フォームの 35%が除外され, 全体の精度は 1.000 になった.

VAS の予測性能

VAS のピアソン相関係数は 0.985（VAS_1）, 0.991（VAS_2）, 0.991（VAS_3）であり, 平均は 0.989 であった. 絶対誤差の平均値は 0.34, 中央値は 0.25, 最大値は 4.18, 最小値は 0 であった.

処理速度

JOABPEQ フォーム 483 件を処理するための DL モデルの処理時間は 787 秒であった. 1 ページあたりの処理時間は, 1 ページ目が 0.88 秒, 2 ページ目が 0.69 秒, 3 ページ目が 0.06 秒であった.

症例提示

患者が非典型的な方法で回答をマークする場合, DL モデルにとって困難となる. 例えば, 2 つの選択肢に印をつけた場合や複数の選択肢に印をつけた場合, チェックマークを使用した場合などである. しかし, これらの困難な回答に対してもモデルは正しい予測を出力することができた. VAS では, 丸印や十字印などの指示と異なる印の付け方でも, 絶対誤差 1 未満で予測することができた. 一方, 患者が数字を用いたり複数の印を付けたりした場合, 予測は正しい VAS から絶対誤差 2 以上乖離した.

4. 考察

本研究の目的

本研究の目的は, 紙ベースの HR-PRO フォームからデータを抽出するための DL モデルを開発することである. これは HR-PRO を用いた自動データ収集に DL を採用した最初の研究である. 我々のモデルは, カテゴリ分類の質問で 0.997 という高い精度を達成し, VAS については 0.989 という強いピアソン相関係数を観察した. モデルの性能は外部検証によって評価され, 実臨床への適合性が実証された.

手動データ収集と OCR の課題

紙ベースの HR-PRO から手作業でデータを収集するのは手間がかかる. OCR 技術を活用した Teleform は, 専用にデザインされた紙フォームでは高精度を示すが, 既存の紙フォームでは精度が低い. OCR はフォームからデータを収集するために回答の位置を認識する必要があるが, 既存の紙フォームでは位置を正確に識別するのが難しいため, 精度が低下する.

DL モデルの利点

我々のモデルは, 複数のマークや回答の位置を認識し, 精度を向上させた. 各質問に対する回答を検出する物体検出モデルの代わりに, ページ全体を読み込んで特徴量を抽出する CNN を活用した. VAS の読み取りに関しても, 非典型的なマーキングや距離測定に対応できる点で, OCR よりも優れている.

5. 結論

我々は, 従来の OCR に代わる可能性のある DL モデルを開発した. この DL モデルは, HR-PRO から回答フィールドの位置を固定せずにデータを検索する能力を実証した. 特に VAS に対して有効であり, 将来の臨床研究に有望である.

謝辞

本研究は JSPS 科研費 JP21K20966 の助成を受けたものです.

利益相反の有無

「なし」

カスタマイズ可能なクエリに基づく Human-in-the-Loop 型医用画像検索

小林　和馬[*1, 2]
[*1] 国立がん研究センター研究所
[*2] 理化学研究所革新知能統合研究センター

User-Customizable Queries for Human-in-the-Loop Medical Image Retrieval

Kazuma KOBAYASHI[*1, 2]
[*1] *National Cancer Center Research Institute*
[*2] *RIKEN Center for Advanced Intelligence Project*

要旨：現代の病院では膨大な放射線画像がデータベースに蓄積されている．こうしたデータベースから，手元の放射線画像に対して類似する画像や，あるいは，特定の所見に関して異なる画像を自在に取得し，比較読影できれば，診断や教育に有用となることが期待される．そのためには，手元の放射線画像が含む医学的特徴をユーザがカスタマイズすることで，検索に用いるクエリを構築できることが求められる．本研究では，医用画像の特徴分解を応用することで，例示画像に含まれる医学的所見をユーザが必要に応じてカスタマイズし，それを反映したクエリを構築することを可能とした．原発性脳腫瘍を含む頭部 MRI からなるデータセットを用いて実装し，臨床医によるユーザ評価試験を行った．結果，手元の放射線画像に対して，カスタマイズを行わない場合には類似した画像が，カスタマイズを行った場合には，その内容に応じた画像が適切に取得できることが認められた．
キーワード：Query-by-customization, Content-based medical image retrieval, Human-machine interaction, Feature decomposition

1.　はじめに

病院のデータベースに保存される医用画像の増加に伴い，効率的な検索手法が求められている．症例比較は診断と教育に不可欠であり，単なる類似画像の検索以上の情報ニーズがある．例えば，神経膠腫のグレード診断には腫瘍の造影増強の解析が必要であり，対照的な所見を持つ画像との比較が有用である．また，病変画像と健常画像を比較することで，病変の広がりをより正確に評価できる．これらのニーズに対応するために，検索画像の所望の特徴を柔軟にカスタマイズできるコンテンツベース医用画像検索（CBMIR）システムが不可欠である．

CBMIR システムの設計では，検索したい画像の特徴を表現したクエリベクトルをどのように構築するかが技術的な中心課題となる．従来，**Query-by-example** と呼ばれるアプローチが主流であった（**図 1a** 参照）[1]．この手法では，例示画像からその特徴を表すクエリベクトルを直接的に抽出する．しかし，例示画像に類似した参照画像の取得はできても，異なる特徴を有する画像を検索対象とすることができなかった．

一方，より最近になって，**Query-by-sketch** と呼ばれる別のアプローチが提案された（**図 1b** 参照）[2]．この手法では，ユーザが選択したテンプレート画像の上に，病変を表すセマンティック・ラベルをスケッチして組み合わせることで，例示画像に頼ることなく所望のコンテンツを指定できる．利点として，類似画像を見つけることが困難な希少症例などの検索を実現できる．しかし，医師が例示画像を既に手元に有している状況では，例示画像の特徴をわざわざ手動で再構成するために労力がかかるなど，効率的ではなかった．

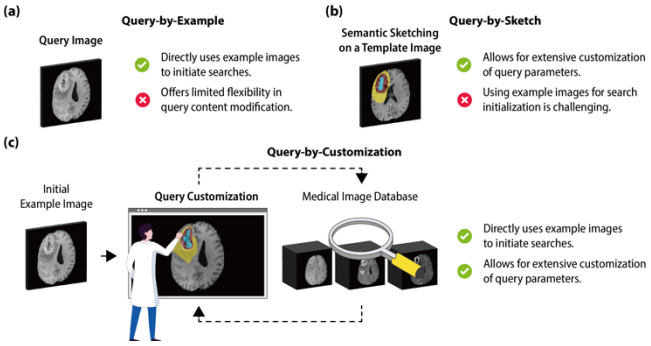


図 1. 既存手法と Query-by-customization アプローチ.

2.　提案手法

本稿では，例示画像からカスタマイズ可能なクエリを抽出する **Query-by-customization** アプローチを提案する（**図 1c** 参照）．技術的な基盤は，筆者らの先行研究における医用画像の特徴分解に基づいており［2，3］，これは医用画像の全体の特徴（E）を，正常特徴（N）と異常特徴（A）とに分解する．

$$E = N + A \qquad (1)$$

ここで，正常特徴とは，異常を含む医用画像に対して，もしその異常が存在しなかった場合の仮想的な正常特徴を指す．また，異常特徴とは，この仮想的なベースラインからの差分として表現される．これらの組み合わせによってクエリベクトルを構成することで，正常特徴により病変の解剖学的位置を指定し，異常特徴により病変の画像的特徴（腫瘍の外観や範囲など）を表現することができる．

医用画像の特徴分解を応用することによって，ユーザは 2 段

階のステップで例示画像のクエリ情報をカスタマイズすることができる．まず，テンプレート画像（初期状態では例示画像自体がテンプレートとして機能する）を変更することで，正常特徴を更新し，検索対象の画像の解剖学的位置を変更することができる．次に，疾患関連領域のセマンティック・セグメンテーション・ラベル（元は例示画像から抽出されたもの）を編集することによって，異常特徴を更新し，検索対象の画像が含む疾患の特徴を修正することができる．これらの更新された正常特徴と異常特徴の組み合わせにより，元の例示画像に含まれていない特徴を含むクエリベクトルが構築される．

3. 実験

原発性脳腫瘍と，それに関連する 3 種類の領域のセグメンテーション・ラベル（GD-enhancing Tumor, Peritumoral Edema, Necrotic Tumor Core）を含む頭部 MRI からなるデータセット（MICCAI BraTS 2019）を，291 症例からなる学習用データセットと 335 症例からなるテスト用データセットに分割した．学習用データセットを用いて，医用画像の特徴分解を行うためのニューラルネットワークを訓練した．学習済みのニューラルネットワークを用いて，Query-by-customization アプローチによる医用画像検索システムを，テスト用データセットにおいて実装した．

続いて，症例比較について 4 つのシナリオを設定した［4］．

1. Disease/Normal Comparison: 異常を有する例示画像に対して，疾患関連領域のセグメンテーション・ラベルを削除することで，これに対応する正常画像が検索される．
2. Same-Disease Comparison: 異常を有する例示画像に対して，特にユーザによる操作を加えないことで，これに対応する異常画像が検索される．
3. Different-Disease Comparison (Different Appearance): 異常を有する例示画像に対して，疾患関連領域のセグメンテーション・ラベルを編集することで，異なる疾患関連領域の特徴を有する異常画像が検索される．
4. Different-Disease Comparison (Different Location): 異常を有する例示画像に対して，テンプレート画像を変更することによって，異なる解剖学的位置に類似の病変を有する画像を検索することができる．

テスト用データセットからランダムに取得した 20 枚の画像を例示画像として，以上の 4 つのシナリオに基づく Query-by-customization アプローチによる検索を実行した．それぞれの例示画像に応じて検索された画像について，期待された通りの所見を有しているかどうかを臨床的観点からスコアリングし，既存手法と比較した．

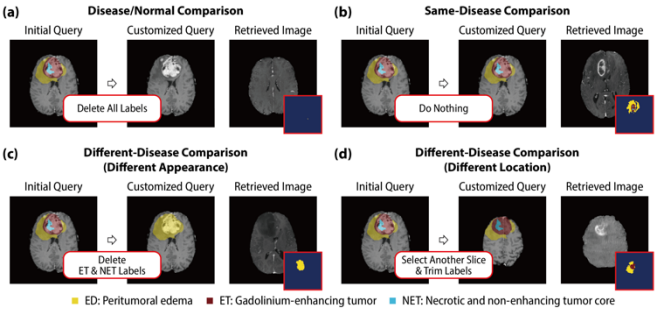


図 2. 症例比較のシナリオごとの検索結果の例.

4. 結果

図 2 に示す通り，症例比較に関する 4 つのシナリオに応じて，提案手法は適切な画像を検索できることが示された．更に，Query-by-example アプローチが有効な Same-Disease Comparison において，提案手法は臨床的により妥当な検索結果を得ることができると示された（例として，検索意図に従った画像が検索結果上位 5 症例に占める割合である Precision@5 は，提案手法において 0.59±0.08，Query-by-example アプローチにおいて 0.31±0.06 であった）．また，同シナリオにおいて，提案手法は Query-by-sketch アプローチと同等の検索性能である一方，クエリを構築する所要時間が有意に短縮されることも示された．

5. 結語

本研究では，例示画像からユーザーがクエリ情報をカスタマイズ可能な Query-by-customization アプローチを実証した．これにより，様々な症例比較のシナリオにおいて，例示画像を起点とした Human-in-the-Loop 型の柔軟な検索が可能となった．

謝辞

本研究は JSPS 科研費（JP22K07681），JST ACT-X（JPMJAX23C9）の助成を受けたものです．

利益相反の有無

研究代表者は富士フイルム株式会社より共同研究費を得ている．

文 献

［1］Li Z, Zhang X, Muller H et al: Large-scale retrieval for medical image analytics: A comprehensive review. Med Image Anal 43: 66-84, 2018

［2］Kobayashi K, Lin G, Hataya R et al: Sketch-based semantic retrieval of medical images. Med Image Anal 92: 103060, 2024

［3］Kobayashi K, Hataya R, Kurose Y et al: Decomposing normal and abnormal features of medical images for content-based image retrieval of glioma imaging. Med Image Anal 74: 102227, 2021

［4］Kok EM, Bruin ABH, Leppink J. et al: Case Comparisons: An Efficient Way of Learning Radiology. Acad Radiol 22: 1226-1235, 2015

没入型 VR を用いた放射性医薬品投与訓練における緊張度の計測

垣本　晃宏[*1,2]，藤瀬　大助[*3]，長谷川　慎[*3]，奥田　保男[*3]，太田　悠斗[*4]，谷　碧翔[*4]，船橋　正夫[*1]
[*1] 森ノ宮医療大学　医療技術学部　診療放射線学科
[*2] 浜松医科大学　光尖端医学教育研究センター　フォトニクス医学研究部　生体機能イメージング研究室
[*3] 量子科学技術研究開発機構　本部　情報基盤部
[*4] 森ノ宮医療大学　保健医療学部　診療放射線学科

Measurement of Stress Levels in Training for radiopharmaceutical injection Using Immersive VR

Akihiro KAKIMOTO[*1,2]，Daisuke FUJISE[*3]，Shin HASEGAWA[*3]，Yasuo OKUDA[*3]，
Yuto OHTA[*4]，Rikuha TANI[*4]，Masao FUNAHASHI[*4]
[*1] *Faculty of Medical Science Technology, Morinomiya University of Medical Science*
[*2] *Biofunctional Imaging, Institute for Medical Photonics Research, Hamamatsu University School of Medicine*
[*3] *National Institutes for Quantum Science and Technology*
[*4] *Faculty of Health Sciences, Morinomiya University of Medical Science*

要旨：診療放射線技師へのタスクシフトにより，放射性医薬品投与における静脈路確保などの業務拡大が認められた．そこで我々は，診療放射線技師養成校において非侵襲かつ被ばくゼロで当該業務訓練を実施可能な没入型 VR システムの開発を進めている．今回，肘窩部位の MR 画像より作成した 3D オブジェクトを VR 上に投影させ，操作中の緊張度の計測を試みた．対象は同意が得られた 20～21 歳の学生 10 名（男性 6 名，女性 4 名）とし，手指操作や医用画像の投影など没入度に差を設けた 2 種類の VR 操作時の緊張度を計測した．主観的な気分評価尺度を示す POMS2 および TDMS-ST では没入度の高い方がポジティブな感情が維持される傾向がみられ，脳波計測も同様に緊張度を示す β 波成分が高値を示した．これらより，VR 上に医用画像を投影することで高い緊張感が得られる可能性が示唆された．今後は，緊張度と医療技術トレーニング効果の関連性を検証する予定である．
キーワード：タスクシフト，VR，没入，緊張，医療技術

1. はじめに

「良質かつ適切な医療を効率的に提供する体制の確保を推進するための医療法等の一部を改正する法律」(医政発 0528 第１号)の公布により，近年，医師から多職種へのタスクシフトが進められている．診療放射線技師においては，診療放射線技師法の改正(2021 年 10 月 1 日施行)に伴い，放射性検査医薬品の投与のための静脈路を確保する行為，抜針及び止血を行う行為が新たに技師の業務に加わった．しかしながら，当該実務作業の習得には，非密封の放射性同位元素(RI)を扱う管理区域が必要であり，かつ穿刺や放射線被ばくのリスクを伴うため，コスト面や倫理面でハードルが高い．このような背景の中，診療放射線技師養成校においても，告示研修および新カリキュラムのため，当該業務の実習が必要とされている状況である．

そこで我々は，安全に何度も繰り返しトレーニング可能な VR 技術に着目し，放射性医薬品投与に関連する診療放射線技師の実務作業を疑似体験できる VR システムを開発した．本システムには，実際のヒトを対象とした上肢血管 MR 画像より生成された 3D モデルが搭載されており，実空間上では視認することができない上肢内部構造を VR 空間では医用画像として可視化することができる．

2. 目的

VR 操作中の緊張度と医療従事者のパフォーマンスやシミュレーション教育には関連性があると考えられているが，その根拠となる文献は不足している［1］．そこで，本研究は核医学検査において診療放射線技師が担う，放射性医薬品投与に関する患者接遇及び手技を VR 上で体験する際の緊張度の計測を試みた．また，診療放射線技師の目線で当該業務をトレースすることができる動画視聴型 VR と，専用グローブを着用して当該業務を疑似体験でき，かつ上肢血管画像を可視化することのできる没入型 VR の 2 種類の教材を用いて，その緊張度の差異を比較することを目的とした．

3. 方法

本研究は所属機関における倫理委員会の審査および承認を得て実施された．対象は診療放射線技師養成校 3 年次の学生で，かつ臨床実習前の専門科目を全て修了し，病院での臨床実習を控えた計 10 名(20～21 歳，男性 6 名，女性 4 名)とした．

操作者にヘッドマウント型ディスプレイ VIVE Pro Eye(HTC)，VR 専用グローブ Molison Hans Vib+[L] (Feel the same)，およびウェアラブル脳波計 FocusCalm(Brainco)を装着してもらい，約 6 分間の 360° 動画視聴型 VR と約 10 分の没入型 VR を体験し

てもらった．VR コンテンツは両者共に，核医学検査における放射性医薬品投与に関して，患者入室から退室までの診療放射線技師が行う一連の接遇および静脈注射等の業務である．



(a)　360°動画視聴型 VR　　(b)　没入型 VR

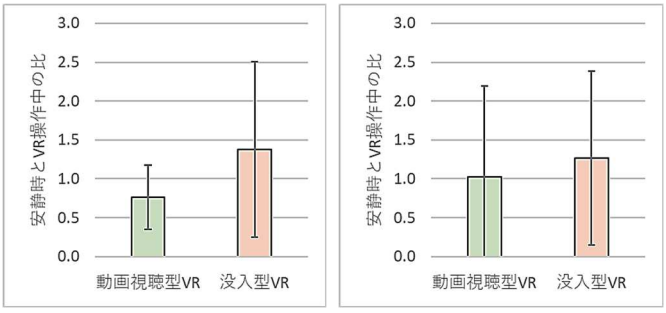
図 1　　VR ゴーグルに投影される映像画面．

緊張度計測の指標として，各種の生体情報および心理スコアを測定し，VR 操作前の安静時と操作直後の差異を比較した．生体情報として唾液アミラーゼと脳波，心理スコアとして気分プロフィール検査 POMS2(Profile of Mood States 2nd Edition)と二次元気分尺度 TDMS-ST(TDMS-ST Two-dimensional Mood Scale-Short Term)を利用した．

4. 結果

唾液アミラーゼは，動画視聴型 VR で−6.4KU/L，没入型 VR で−4.8 KU/L と両者共に VR 操作前後で低下した．

心理状態の指標である POMS2 の活気(VA)では，VR 操作前後で動画視聴型 VR は−0.7，没入型 VR は 0.6 の変化となった．同じく，TDMS-ST の活力(V)では，動画視聴型 VR で 0.1，没入型 VR は 1.0 となった．



(a)　β波　　(b)　α波

図 2　安静時と VR 操作中の脳波平均成分の比．

今回使用した簡易脳波計は，α，β波等の成分は各周波数の成分比で数値化される．そこで，脳波は VR 操作前の安静状態(1 分)と VR 視聴(約 6 分)もしくは操作中(約 10 分)の積算比で比較した．β波は，動画視聴型 VR で 0.8 倍，没入型 VR で 1.4 倍であった．また，α波は，動画視聴型 VR で 1.0 倍，没入型 VR で 1.3 倍となった．

5. 考察

交感神経活動の指標値となるαアミラーゼは VR 操作後に低下する傾向であった．これは，ストレス負荷前後の緊張度が緩和されたものと考察される［2］．VR 操作後直ぐに唾液をサンプリングしたが，VR 操作による緊張度をより正確に計測するためには操作中に採取する必要がある．

質問紙による心理検査では，POMS2 および TDMS-ST 共に，没入型 VR の方は活気・活力等のスコアが高くなった．しかし，スコアの変動が小さいため，心理状態が大幅に変化したというよりも，動画視聴型 VR よりも没入型 VR の方がポジティブな感情が維持される傾向であると考えられる．

安静時と VR 操作中の脳波を比較すると，β波およびα波は両者共に，動画視聴型 VR よりも没入型 VR の方が高値を示したことから，没入型 VR 操作時の方が緊張および集中状態であるといえる．結果，手指の動きの連動と医用画像を可視化した没入型 VR 教材では高い緊張感，覚醒した集中状態でトレーニング可能である可能性が示唆された．

6. まとめ

今回，放射性医薬品投与における患者接遇および医療技術訓練を VR 環境下で実施する際の緊張度を計測した．今後．本システムを用いた医療技術訓練における緊張度と教育効果の関連性を調査し，将来的には OJT(On the Job Training; 実務訓練)や OSCE (Objective Structured Clinical Examination; 客観的臨床能力試験)での応用を目指す．

謝辞

本研究の根幹となる放射性医薬品の投与業務に関しまして，浜松医科大学尾内康臣教授をはじめ，核医学分野に携わる医師，看護師，診療放射線技師の皆様に貴重なご助言を賜りました．改めて深謝申し上げます．また，本研究は JSPS 科研費 22K13770 の助成を受けたものです．

利益相反の有無

なし．

文　献

［1］Meese, Merrick M, O'Hagan, Emma C, Chang, Todd P et al: Healthcare Provider Stress and Virtual Reality Simulation: A Scoping Review. Simul Healthc. **16**(4): 268-274, 2021

［2］入江正洋，福盛英明：大学生のプレゼンテーションストレスと唾液中アミラーゼ反応．　健康科学 **32**: 71-75, 2010

第 43 回日本医用画像工学会大会（JAMIT2024）
大会役員委員会名簿

五十音順・敬称略

大 会 役 員

大　会　長	清水　昭伸	東京農工大学
大会長補佐	根本　充貴	近畿大学
企画立案アドバイザ	中岡　竜介	国立医薬品食品衛生研究所
	中田　典生	東京慈恵会医科大学
	原　　武史	岐阜大学
	橋本二三生	浜松ホトニクス株式会社

プログラム委員会

委員長	花岡　昇平	東京大学
副委員長	根本　充貴	近畿大学
	野村　行弘	千葉大学
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
	稲井　邦博	名古屋工業大学
	彌冨　　仁	法政大学
	上村　幸司	国立循環器病研究センター
	内山　良一	宮崎大学工学部
	大竹　義人	奈良先端科学技術大学院大学
	小田　昌宏	名古屋大学
	小尾　高史	東京工業大学
	神谷　　亨	九州工業大学
	川岸　将実	キヤノン株式会社
	河田　佳樹	徳島大学
	北坂　孝幸	愛知工業大学
	北村　圭司	株式会社 島津製作所
	木戸　尚治	大西脳神経外科病院
	木村　裕一	近畿大学
	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SIT総合研究所大学院理工学研究科
	周　　向栄	岐阜大学
	庄野　　逸	電気通信大学
	陣崎　雅弘	慶應義塾大学
	菅　　幹生	千葉大学
	杉本　直三	京都大学
	高丸　和也	富士フィルムヘルスケア株式会社
	滝沢　穂高	筑波大学
	橘　　理恵	室蘭工業大学
	田中　利恵	金沢大学
	陳　　延偉	立命館大学
	寺本　篤司	名城大学
	中口　俊哉	千葉大学
	中田　典生	東京慈恵会医科大学
	中山　良平	立命館大学
	橋本　正弘	慶應義塾大学
	橋本二三生	浜松ホトニクス株式会社
	畑中　裕司	大分大学
	羽石　秀昭	千葉大学
	原　　武史	岐阜大学
	本谷　秀堅	名古屋工業大学
	増谷　佳孝	東北大学
	間普　真吾	山口大学
	目加田慶人	中京大学
	森　　健策	名古屋大学
	山谷　泰賀	国立研究開発法人量子科学技術研究開発機構
	湯浅　哲也	山形大学

日本医用画像工学会（JAMIT）
役　員　名　簿
（令和６年４月15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
	橋本二三生	浜松ホトニクス株式会社
	畑中　裕司	大分大学
	花岡　昇平	東京大学
	増谷　佳孝	東北大学
	目加田慶人	中京大学
	湯澤　史佳	キヤノンメディカルシステムズ
代議員	青山　正人	広島市立大学
	有村　秀孝	九州大学大学院
	石田　隆行	大阪大学大学院
	伊藤　聡志	宇都宮大学
	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
	笠井　　聡	新潟医療福祉大学
	神谷　　亨	九州工業大学
	北坂　孝幸	愛知工業大学
	木戸　尚治	大西脳神経外科病院
	工藤　博幸	筑波大学
	近藤　世範	新潟大学
	菅　　幹生	千葉大学
	鈴木　賢治	東京工業大学
	鈴木　秀宜	ザイオソフト
	砂口　尚輝	名古屋大学
	銭谷　　勉	弘前大学大学院
	高橋　哲彦	群馬パース大学
	滝沢　穂高	筑波大学
	健山　智子	藤田医科大学
	陳　　延偉	立命館大学
	縄野　　繁	新松戸中央総合病院
	根本　充貴	近畿大学
	野崎　太希	慶應義塾大学
	野村　行弘	千葉大学
	橋本　雄幸	杏林大学
	羽石　秀昭	千葉大学
	本谷　秀堅	名古屋工業大学
	村松千左子	滋賀大学
	目加田慶人	中京大学
	山谷　泰賀	放射線医学総合研究所
	吉川　悦次	浜松ホトニクス
	米山　明男	九州シンクロトロン光研究センター
監　　事	森田　尚孝	島津製作所
	清水　昭伸	東京農工大学