JAMIT Annual Meeting 2018
第37回日本医用画像工学会大会

会　期：2018 年 7 月 25 日(水)～7 月 27 日(金)
会　場：筑波大学　天王台キャンパス　大学会館
大会長：工藤 博幸(筑波大学)

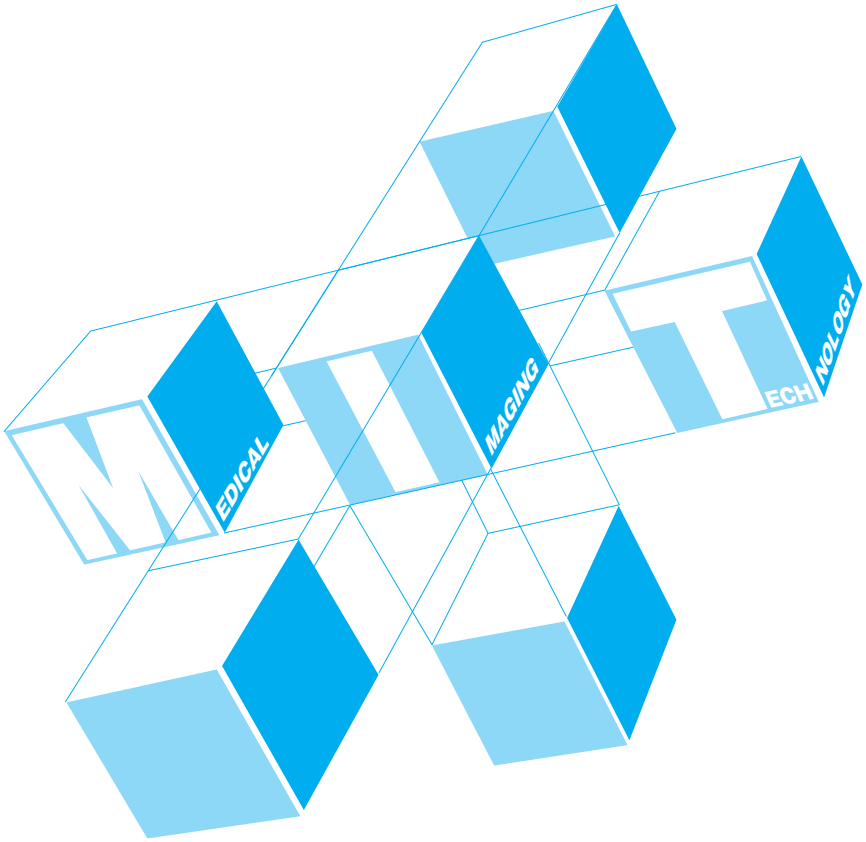

主　催　日本医用画像工学会
(The Japanese Society of Medical Imaging Technology)
共　催　筑波大学
後　援　一般社団法人　日本画像医療システム工業会
(JIRA:Japan Medical Imaging and Radiological Systems Industries Association)
一般社団法人　保健医療福祉情報システム工業会
(JAHIS:Japanese Association of Healthcare Information Systems Industry)
一般社団法人　電子情報技術産業協会
(JEITA:Japan Electronics and Information Technology Industries Association)
協　賛　IEEE東京支部
医用画像認知研究会
可視化情報学会
看護理工学会
情報処理学会
電子情報通信学会
日本医学放射線学会
日本核医学会
日本画像医学会
日本磁気共鳴医学会
日本生体医工学会
日本脳神経CI学会
医用画像情報学会
応用物理学会
画像電子学会
三次元画像コンファレンス実行委員会
文部科学省科研費補助金・新学術領域研究
「多元計算解剖学」
日本医学物理学会
日本医療情報学会
日本核医学技術学会
日本コンピュータ外科学会
日本写真学会
日本超音波医学会
日本放射線技術学会
筑波大学3D-CGバーチャル手術シミュレーションユニット

学会長ご挨拶

第 37 回日本医用画像工学会大会は筑波大学教授 工藤博幸大会長の運営のもとで，2018 年 7 月 25 日（水）から 27 日（金）の 3 日間，筑波大学 天王台キャンパス 大学会館にて開催されることになりました．一年以上前から準備をされてきた大会関係者や事務局の皆様，そして企業の業務委員会の皆様のご尽力に厚く御礼申し上げます．

人工知能（Artificial Intelligence: AI）は第３次のブームを迎え，新聞などに AI の文字が現れない日はないほどとなっていますが，AI の定義も種々ある中，言葉だけが先行しているような感があります．JAMIT に関連する領域での AI の利用は診断技術が中心となると思いますが，医用画像診断に AI を適用するためにはカルテなどの文字情報と画像がリンクする必要があり，自然言語処理とディープラーニング（深層学習）技術がキーテクノロジーとなると思っています．今回の大会でも，２つのシンポジウムで AI 技術を取り扱うことになっており，初学者も含め AI 技術の概要を理解できると思います．さらに，前回の大会同様，学会の場で実際に体験しながら AI 技術の理解を深めるハンズオンのセッションも予定されています．また，特別講演では X 線を波動としてとらえることによりコントラスト分解能を向上させる X 線位相イメージング，および光学顕微鏡を用いた植物の受精のイメージングなど会員の皆様にインスピレーションを与えるような話題も用意されています．さらに外科手術シミュレータは筑波大学の特色ある研究のひとつになっていますので，このシンポジウムも大変興味あるものになると思われます．最後に，今回の大会長の工藤先生は東北大学在学中から CT の画像再構成の研究に取り組んで来られ，解析的なアプローチで X 線 CT の３次元画像再構成問題や局所領域の再構成，ガンマ線 CT の吸収補正問題などで大きな成果を上げてきましたが，今大会ではさまざまなモダリティの再構成問題を一堂に会して取り扱うシンポジウムも企画されていますので楽しみです．

今大会の中では上記のさまざまな魅力的な企画が用意されていますので，会員の皆様には実りの大きい大会となると思っております．この大会における皆様の活発な意見交換により，医用画像工学の研究が大きく進展することを期待しています．

日本医用画像工学会
会長　**尾川　浩一**（法政大学）

大会長ご挨拶

第 37 回日本医用画像工学会大会（JAMIT 2018）を，会期 7/25（水）～ 7/27（金）にわたって筑波大学天王台キャンパスの大学会館にて開催させていただくことになりました．今回の大会のテーマは「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」に設定して，この内容に合致した特別講演，チュートリアルセッション，シンポジウムセッション，ランチョンセミナーなどを大会長補佐の滝沢穂高先生（筑波大），プログラム委員長の目加田慶人先生（中京大学）と一緒に企画しました．以下に，主な内容を紹介させていただきます．

人工知能（ＡＩ）特に深層学習（ディープラーニング）は２～３年ほど前に医用画像分野に黒船のように襲来して，JAMIT2016（羽石秀昭大会長：千葉開催）では JAMIT 会員への紹介を主としたチュートリアルが開催され，JAMIT2017（藤田廣志大会長：岐阜開催）では「ハンズオンセミナー」や「ランチョンセミナー」など組織的な企画セッションが行われ一般講演もかなり申し込みがあり，次第に JAMIT に浸透してきました．JAMIT2018 においてもこの革新的な方向性を引き継ぎ，「チュートリアル：深層学習にできること・できないこと・期待すること」，「（岐阜に引き続き）JAMIT ハンズオンセミナー」，「シンポジウム：ディープラーニング：基礎理論から応用へ」，「シンポジウム：ＡＩ画像処理の応用事例と有効性・将来性・課題」，「深層学習に関するランチョンセミナー」の５つの企画を行うことにしました．また，一般講演でもかなりの数の深層学習に関する演題の申し込みがあると期待しています．初心者の方にはＡＩを勉強して始めるきっかけになる，ＡＩ研究者の方には医用画像分野におけるＡＩ研究の様相を知ることができる，ＡＩ盛りだくさんの大会になると思われます．

また，JAMIT が昔から取り扱ってきた得意分野のイメージングに関しても，新しい方向性を目指したり会員にインスピレーションを与えたりする特別講演２件を企画しました．１件目は，X 線を波動と捉えて位相シフト分布を画像化する X 線位相イメージングに関する講演「実用化を目指す X 線位相イメージング」で，当該テーマの世界的権威である百生敦先生（東北大）にお願いしました．２件目は，会員の皆様が楽しく聞ける医用イメージングにもインスピレーションを与える講演として，植物の受精瞬間を捕らえた光学顕微鏡イメージングで世界的に注目されている東山哲也先生（名古屋大）に「顕微鏡イメージングで植物のメカニズムを視る」をお願いしました．また，関連するイメージングに関するシンポジウムとして，JAMIT のお家芸である CT,MRI,PET,SPECT の画像再構成に関する「医用画像再構成の基礎と新しい展開」，光を用いた新しいイメージングモダリティを拓く「光断層イメージングの新しい展開」を企画しました．

更に，つくば色が見えるシンポジウムとして，筑波大学が医工産学連携で７年間ほどかけて行ってきた手術シミュレータ開発プロジェクトに関するシンポジウム「医用画像を活用した 3D バーチャル手術：ソフト開発から，臨床評価，医学教育までとこれからの未来」を企画しました．

つくばでの JAMIT 大会の開催は，JAMIT2007 を「つくば国際会議場」にて開催（武田徹大会長）して今回が２回目の開催になります．当時はつくばエクスプレス（TX）が運行開始して間もない時期でしたが，その後 10 年間が経過してつくばの街並みや雰囲気もかなり変化して都会化して便利な街に変革しています．TX のつくば駅前は賑やかになり，おいしく食事ができる店やショッピングができる店が多くできました．上記の学会の内容と合わせて変革した新しいつくばもお楽しみください．最後に，JAMIT は私がこれまで CT の画像再構成の研究を行ってきた上で最もお世話になった愛着がある学会で，今回大会長として JAMIT に恩返しできるということで充実感もって大会長の仕事に取り組んでいます．

是非，7/25（水）～ 7/27（金）にはつくばにお越しくださいませ．

第 37 回日本医用画像工学会大会
大会長　**工藤　博幸**（筑波大学）

交通案内

つくばエクスプレス「つくば」駅／「つくばセンター」バスターミナルまでのアクセス

1．「秋葉原」からつくばエクスプレスで約 45 分.
2．「羽田空港」から高速バスで約 105 分.
3．「成田空港」から高速バスで約 60 分.
4．「東京駅」から高速バスで約 60 分.
5．「東京駅」からは最寄りバス停「大学会館」まで直行する高速バスがあります．約 75 分.

「つくば」駅／「つくばセンター」バスターミナルから最寄りのバス停「大学会館前」までのアクセス

バ　ス　「つくばセンター」にて 6 番バスのりばから「筑波大学中央」行，または「筑波大学循環（右回り）」にご乗車下さい（左回りは遠回りになります）．8 個目のバス停「大学会館前」にて下車して下さい．所要時間は約 15 分です.

タクシー　「つくばセンター」タクシー乗り場（3 番バスのりばと 4 番バスのりばの間）でご乗車頂き，バス停「大学会館前」とご依頼下さい.

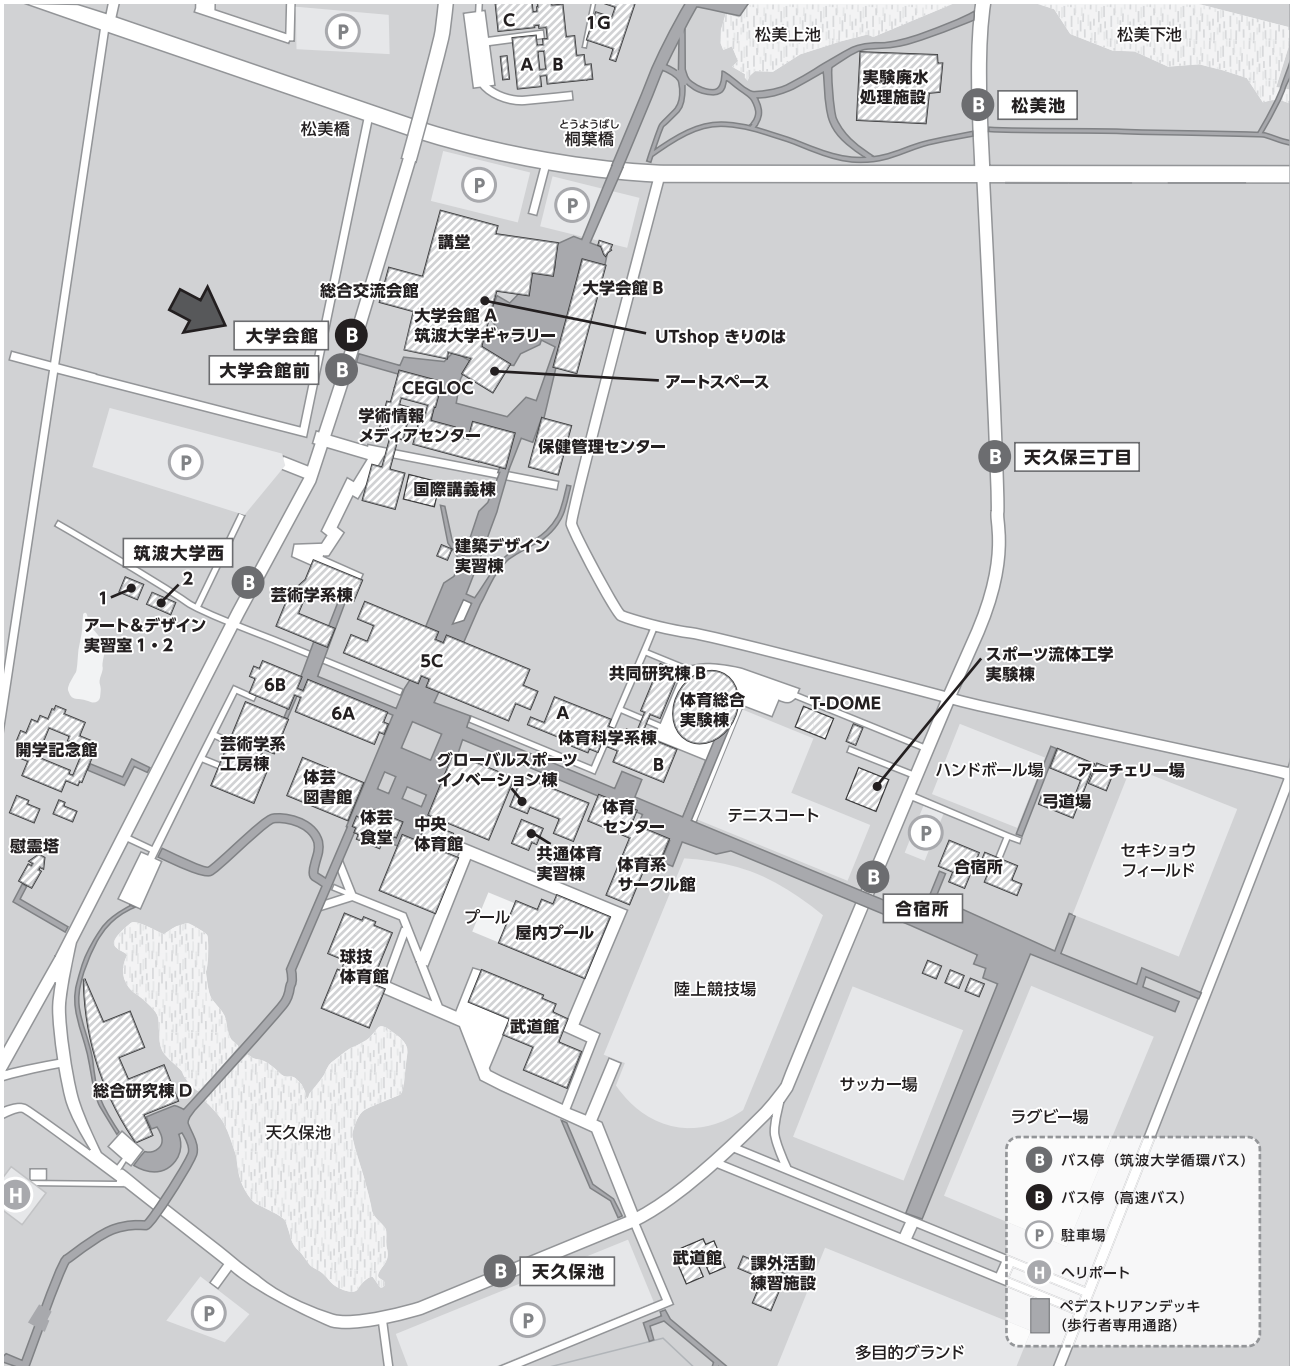

会場案内図

筑波大学　大学会館　つくば市天王台 1-1-1　筑波大学天王台キャンパス構内

筑波大学 大学会館 2F

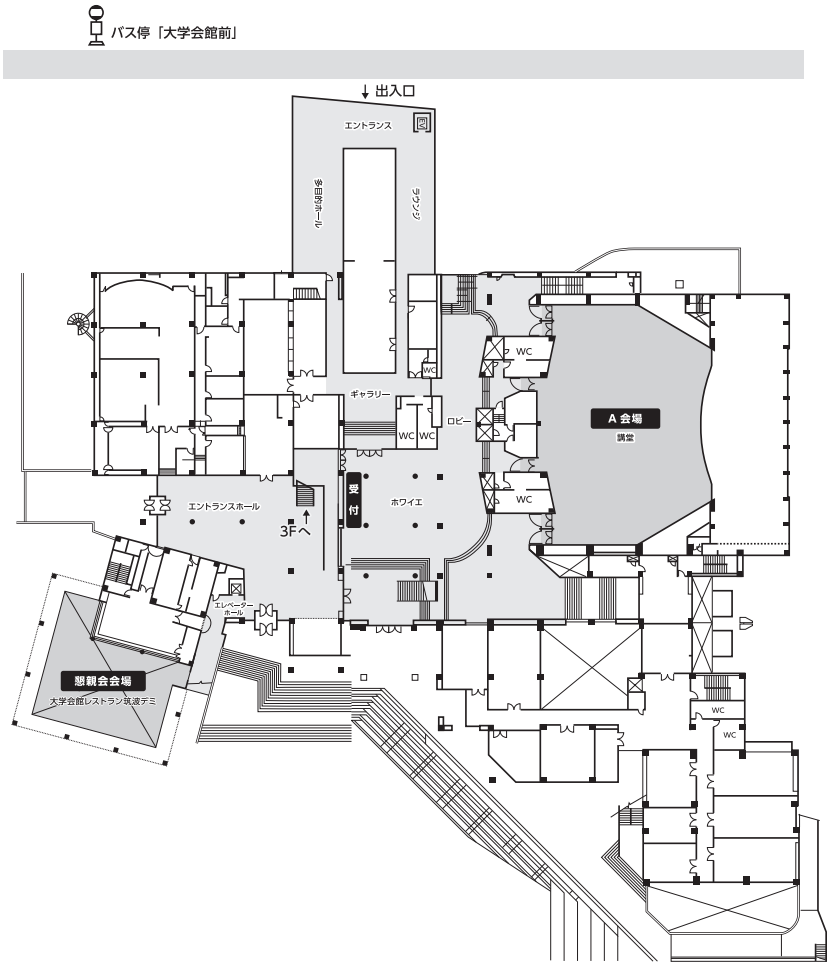

筑波大学 大学会館 3F

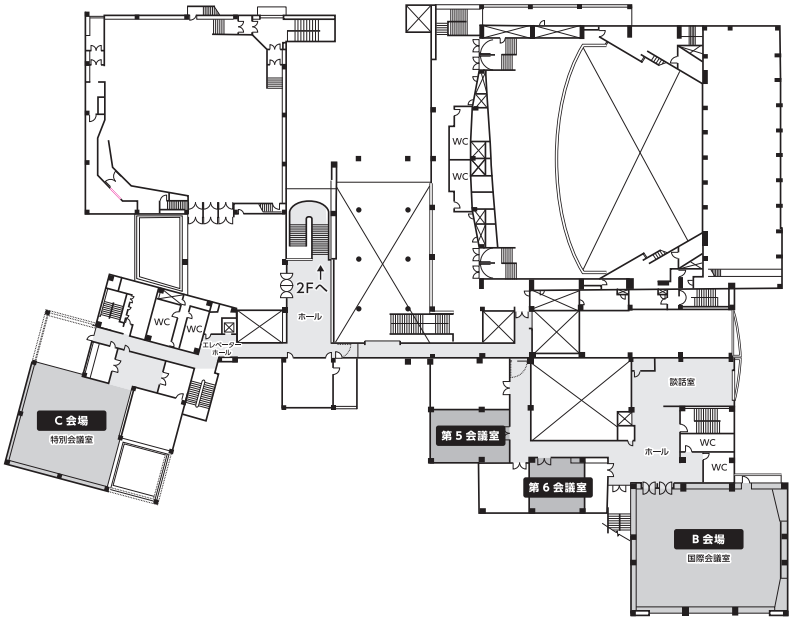

参加者へのご案内

1. 会　期：2018年7月25日（水）～7月27日（金）

2. 会　場：筑波大学　天王台キャンパス　大学会館

〒305-8577　つくば市天王台1-1-1　　TEL:029-853-6515（問い合わせ先）
http://www.tsukuba.ac.jp/access/

講演会場：2階講堂（A会場），3階国際会議室（B会場），3階特別会議室（C会場），
3階第5会議室（幹事会，編集委員会，広報委員会，ハンズオンセミナー），
3階第6会議室（大会事務局）
ご参加いただくには参加証の提示が必要です．
充電は国際会議室（B会場）のみで可能です．

3. 参加登録

1）登録：当日　会場受付（2階）
7月25日（水）　12：20～18：00
7月26日（木）　8：30～17：00
7月27日（金）　8：30～15：00

2）参加費
正会員（賛助会員含む）：13,000円　　学生会員：5,000円　　非会員：20,000円
（会場での受付のみ／事前登録はありません）

4. 総　会

日時：7月26日（木）　13：30～14：30　　会場：A会場（講堂）

5. 予稿集について

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

6. 発表者へのご案内

1）一般演題の発表時間は，**1演題：口演12分，討論3分（計15分）**です．
2）発表使用機材はPCに限ります．（ノートPCは各自で持参して下さい．）
3）ノートPCの動作不良に備え，バックアップデータをUSBメモリでもご持参下さい．
4）ご持参のノートPCのRGB出力端子が「D-SUB15pin」であることをご確認下さい．
「D-SUB15pin」の端子がない場合は，変換器を必ずご持参下さい．また，専用ACアダプターも必ずご持参下さい．

7. 座長へのご案内

担当セッションが始まる10分前までに，座長席の近くにお越しいただき待機して下さい．

8. 発表者資格

一般演題の筆頭発表者は，日本医用画像工学会の会員に限ります．非会員の方は必ず大会前に入会手続きを完了して下さい．

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/）
〒103-0025　東京都中央区日本橋茅場町1-6-17　5階　（株）メイプロジェクト内
TEL:03-6264-9071　FAX:03-6264-8344　E-mail:jamit @ may-pro.net

10. 利益相反（COI）について

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

11. 各種役員会

1）広報委員会　7月25日（水）12：15～12：45　会場：第5会議室
2）幹事会　7月26日（木）12：10～13：10　会場：第5会議室
3）編集委員会　7月27日（金）12：10～13：10　会場：第5会議室

12. 特別講演

特別講演1：7月26日（木） 14：30～15：20　会場：A会場（講堂）
実用化を目指すX線位相イメージング
百生　敦（東北大学）
座　長：工藤　博幸（筑波大学／JAMIT2018大会長）

特別講演2：7月26日（木） 15：20～16：10　会場：A会場（講堂）
顕微鏡イメージングで植物のメカニズムを視る
東山　哲也（名古屋大学）
座　長：尾川　浩一（法政大学／日本医用画像工学会 会長）

13. 第8回JAMITチュートリアル講演会 （教育委員会企画）

（コニカミノルタ科学技術振興財団　JAMITハンズオンセミナー　連携企画）
「深層学習にできること・できないこと・期待すること」
第37回日本医用画像工学会大会のプログラムの一環として「第8回日本医用画像工学会（JAMIT）チュートリアル講演会～深層学習にできること･できないこと･期待すること～」を第1日目の午後に開催いたします．チュートリアルでは，医用画像工学に携わる若手研究者や最新の動向を得たい第一線の研究者を対象として，現在の研究に役立つテーマを専門の研究者が講演します．

日　時：7月25日（水） 13：00～15：40　会　場：A会場（講堂）
座　長：花岡　昇平（東京大学）／平野　　靖（山口大学）
講演1：医用画像における深層学習を利用した研究のはじめかた
小田　昌宏（名古屋大学）
講演2：AIでできたこと・できなかったこと・これからの期待
中田　典生（東京慈恵会医科大学）
講演3：深層学習のための研究環境最前線
阮　　佩穎（エヌビディア合同会社）

14. コニカミノルタ科学技術振興財団　JAMITハンズオンセミナー

教育委員会企画として，本年も「コニカミノルタ科学技術振興財団　JAMITハンズオンセミナー」を開催します．技術的な内容を若手研究者や学生の皆様に提供し，今後の研究活動のきっかけとなる内容を予定します．参加者の皆様は，ご自身のコンピュータを持参いただき，具体的な操作を通じて学んでいただきます．そして，チュートリアル講演とも連携して，人工知能の基本，深層学習の実装，医学応用に関しても，一度に学んでいただく計画としました．

7月25日水曜日のチュートリアル講演の受講後は，120分のハンズオンセミナーに参加していただきます．セミナーは，学会期間中2回開催します（同一内容）．いずれかの中でご都合のよい時間に1回受講してください．ここでは，深層学習の習得を目的として，4つの課題に取り組んでいただきます．

課題1：胸部単純X線画像の方向を認識する
課題2：胸部単純X線画像のセグメンテーション
課題3：画像の超解像処理
課題4：これらを統合した研究アイディアに関する議論

GPUなしでも操作できる程度の画像と学習枚数を使い，スクリプトの書き方，評価方法などを学んでいただきます．なお，実験対象の画像や課題は，変更の可能性があります．

詳細は，7月1日から公開予定の「コニカミノルタ科学技術振興財団JAMIT　ハンズオンセミナー」の専用ウェブページをご覧ください．セミナーは以下のスケジュールで2回開催します（ウェブ上での予約制）．当日予約枠も各回2席程度用意します．

開催スケジュール：7月1日　専用ウェブページで資料を公開
・環境構築，データのダウンロード
・セットアップマニュアル公開
・予約受付開始

受講スケジュール：**7月25日水曜日**　チュートリアル講演の受講をお願いします．
7月25日水曜日　午後4時から午後6時
7月26日木曜日　午後4時から午後6時（25日と同一内容）

会　　場：第５会議室（大学会館３階）
運営スタッフ：中田　典生（東京慈恵会医科大学／ JAMIT 教育委員会委員長）／
原　　武史（岐阜大学／ JAMIT 教育委員会）／小田　昌宏（名古屋大学）／
福岡　大輔（岐阜大学）／李　　鎔範（新潟大学）／松原　友子（名古屋文理大学）
本セミナーは，コニカミノルタ科学技術振興財団の支援を得て実施しています．

15. シンポジウム

シンポジウム１：**7 月 26 日（木） 16：25 ～ 17：55**　　**会場：A 会場（講堂）**
医用画像再構成の基礎と新しい展開
世話人／座長：田島　英朗（量子科学技術研究開発機構）
講演１：PET 画像再構成の原理と実際、そして新しい展開
小林　哲哉（島津製作所）
講演２：正則化逐次近似画像再構成法の基礎
篠原　広行（首都大学東京 / 昭和大学藤が丘病院）
講演３：SPECT における諸問題と最近の動向
尾川　浩一（法政大学）

シンポジウム２：**7 月 27 日（金） 10：30 ～ 12：00**　　**会場：A 会場（講堂）**
ディープラーニング：基礎理論から応用へ
世話人／座長：庄野　　逸（電気通信大学）
講演１：深層学習の基礎理論と発展
園田　　翔（早稲田大学）
講演２：統計的機械学習
安田　宗樹（山形大学）
講演３：Generative Adversarial Networks の基礎と応用
金子　卓弘（NTT コミュニケーション科学基礎研究所）

シンポジウム３：**7 月 27 日（金） 13：30 ～ 15：00**　　**会場：A 会場（講堂）**
ＡＩ画像処理の応用事例と人工知能デモクラシーについて
世話人／座長：中田　典生（東京慈恵会医科大学）
講演１：大腸内視鏡画像に AI 画像処理を応用したリアルタイム内視鏡画像診断支援システムの開発
山田　真善／斎藤　　豊（国立がん研究センター）
上條　憲一／今岡　　仁／髙橋　郁磨（日本電気株式会社）
近藤　裕子／山田　滋美／浜本　隆二（国立がん研究センター）
講演２：人工知能による画像診断システムの高度化
宮崎　　靖（日立製作所）
講演３：医療画像特に脳動脈瘤検出における人工知能活用について
緒方　　剛（エルピクセル）
講演４：Democratizing AI in Radiology（放射線科における人工知能デモクラシーについて）
George Shih（MD.ai.Inc.（Department of Radiology,Cornell University））

シンポジウム４：**7 月 27 日（金） 15：15 ～ 16：45**　　**会場：A 会場（講堂）**
医用画像を活用した 3D バーチャル手術：ソフト開発から、臨床評価、医学教育までとこれからの未来
世話人：大城　幸雄（筑波大学）
座　長：北坂　孝幸（愛知工業大学）
Ⅰ．講演セッション
講演１：医工連携によるバーチャル手術の取り組みとこれからの未来
大城　幸雄（筑波大学）
講演２：３Ｄバーチャル手術のための医用画像セグメンテーション
滝沢　穂高（筑波大学）
講演３：フルハイビジョン裸眼立体表示の医療応用
掛谷　英紀（筑波大学）
講演４：Hepatic Cockpit
矢野　博明（筑波大学）
講演５：先端医療技術とタッチレスインターフェイス
坂本　堪亮（株式会社ネクステッジテクノロジー）
Ⅱ．総合討論

シンポジウム５：**7 月 26 日（木） 16：25 ～ 17：55　　会場：B 会場（国際会議室）**

光断層イメージングの新しい展開

世話人／座長：星　　詳子（浜松医科大学）

講演１：タイムドメイン拡散光トモグラフィーの課題と展望
星　　詳子（浜松医科大学）

講演２：階層ベイズ拡散光トモグラフィによるタスク時と安静時の脳活動計測
下川　丈明（ATR 脳情報解析研究所）

講演３：組織深部拡散蛍光トモグラフィー：時間領域からのアプローチ
西村　吾朗（北海道大学）

講演４：光音響トモグラフィーと定量的画像再構成
大川　晋平／平沢　　壮／辻田　和宏／櫛引　俊宏／石原　美弥（防衛医科大学校）

16. ランチョンセミナー

7 月 26 日（木） 11：55 ～ 12：40　　会場：A 会場（講堂）

医療分野におけるディープラーニングの活用事例と NVIDIA ディープラーニング技術の最新情報について

座　長：森　　健策（名古屋大学）

講演１：医療分野におけるディープラーニング最新情報と NVIDIA の取組みについて
岩崎　　豊（エヌビディア合同会社）

講演２：NVIDIA のディープラーニング最新技術情報について
鈴木　博文（エヌビディア合同会社）

参加者の皆様にお弁当をご用意いたしますが，数に限りがございます．講堂が飲食禁止のため，講堂にてセミナー受講後，会場に隣接するレストラン『大学会館レストラン筑波デミ』にてお召し上がりください．

17. 懇親会

参加者相互の情報交換のため，懇親会を企画いたしました．ぜひご参加ください．

日　時：7 月 26 日（木） 18：15 ～ 20：15　　会場：『大学会館レストラン筑波デミ』

参加費：無料（大会参加費に含まれます．参加は大会参加者に限ります．）

ご 協 力 団 体

本大会は下記企業及び団体にご協力いただきました．心より感謝申し上げます．

共　　催 ：筑波大学

後　　援 ：一般社団法人　日本画像医療システム工業会
JIRA : Japan Medical Imaging and Radiological Systems Industries Association
一般社団法人　保健医療福祉情報システム工業会
JAHIS : Japanese Association of Healthcare Information Systems Industry
一般社団法人　電子情報技術産業協会
JEITA : Japan Electronics and Information Technology Industries Association

助　　成 ：公益財団法人　コニカミノルタ科学技術振興財団

展　　示 ：株式会社 GDEP アドバンス
株式会社ニューテック
一般財団法人　未来科学研究所
株式会社 LEXI　　（五十音順）

広 告 掲 載 ：医歯薬出版株式会社
株式会社インナービジョン
株式会社オーム社
キヤノンメディカルシステムズ株式会社
株式会社システムインフロンティア
株式会社島津製作所
株式会社ネクステッジテクノロジー
浜松ホトニクス株式会社
株式会社緑野リサーチ　　（五十音順）

協　　賛 ：IEEE 東京支部
医用画像情報学会
医用画像認知研究会
公益社団法人　応用物理学会
一般社団法人　可視化情報学会
一般社団法人　画像電子学会
看護理工学会
三次元画像コンファレンス実行委員会
一般社団法人　情報処理学会
文部科学省科研費補助金・新学術領域研究「多元計算解剖学」
一般社団法人　電子情報通信学会
一般社団法人　日本医学物理学会
公益社団法人　日本医学放射線学会
一般社団法人　日本医療情報学会
一般社団法人　日本核医学会
特定非営利活動法人　日本核医学技術学会
日本画像医学会
一般社団法人　日本コンピュータ外科学会
一般社団法人　日本磁気共鳴医学会
一般社団法人　日本写真学会
一般社団法人　日本生体医工学会
公益社団法人　日本超音波医学会
日本脳神経 CI 学会
公益社団法人　日本放射線技術学会
筑波大学 3D-CG バーチャル手術シミュレーションユニット

第1日目 /7月25日（水）

	A会場（講堂）	B会場（国際会議室）	C会場（特別会議室）	第5会議室
12:50	12:50 – 13:00　開会式			12:15 – 12:45 広報委員会
13:00	**第8回 JAMIT チュートリアル講演会（教育委員会企画）** 13:00 – 14:00 TL1「医用画像における深層学習を利用した研究のはじめかた」 小田　昌宏 14:00 – 14:30 TL2「AIでできたこと・できなかったこと・これからの期待」 中田　典生 14:40 – 15:40 TL3「深層学習のための研究環境最前線」 阮　　佩穎 座長：花岡　昇平／平野　　靖			
16:00	16:00 – 18:00　一般演題1 OP1「セグメンテーション」（OP1-1 ～ 8） 座長：陳　　延偉／花岡　昇平	16:00 – 18:00　一般演題2 OP2「イメージング」（OP2-1 ～ 8） 座長：伊藤　聡志／山谷　泰賀	16:00 – 18:00　一般演題3 OP3「質的診断」（OP3-1 ～ 8） 座長：河田　佳樹／平野　　靖	16:00 – 18:00 ハンズオンセミナー1
18:00				

第2日目 /7月26日（木）

	A会場（講堂）	B会場（国際会議室）	C会場（特別会議室）	第5会議室
9:00	9:00 – 10:15　一般演題4 OP4「レジストレーション」（OP4-1 ～ 5） 座長：斉藤　　篤／増谷　佳孝	9:00 – 10:15　一般演題5 OP5「X線イメージング」（OP5-1 ～ 5） 座長：北村　圭司／武田　　徹	9:00 – 10:15　一般演題6 OP6「CAD」（OP6-1 ～ 5） 座長：木戸　尚治／金　　亨燮	
10:30	10:30 – 11:45　一般演題7 OP7「深層学習，超解像」（OP7-1 ～ 5） 座長：彌冨　　仁／小田　昌宏	10:30 – 11:45　一般演題8 OP8「VR, AR」（OP8-1 ～ 5） 座長：中口　俊哉／目加田慶人	10:30 – 11:45　一般演題9 OP9「治療支援」（OP9-1 ～ 5） 座長：有村　秀孝／大竹　義人	
11:55	11:55 – 12:40　ランチョンセミナー LS「医療分野におけるディープラーニングの活用事例とNVIDIA ディープラーニング技術の最新情報について」 岩崎　　豊／鈴木　博文 座長：森　　健策	12:00 – 13:30　昼食	12:00 – 13:30　昼食	12:10 – 13:10 幹事会
13:30	13:30 – 14:30　総会			
14:30	14:30 – 15:20　特別講演1 SL1「実用化を目指すX線位相イメージング」 百生　　敦 座長：工藤　博幸			
15:20	15:20 – 16:10　特別講演2 SL2「顕微鏡イメージングで植物のメカニズムを視る」 東山　哲也 座長：尾川　浩一			
16:25	16:25 – 17:55　シンポジウム1 SY1「医用画像再構成の基礎と新しい展開」 小林　哲哉／篠原　広行／尾川　浩一 座長：田島　英朗	16:25-17:55　シンポジウム5 SY5「光断層イメージングの新しい展開」 星　　詳子／下川　丈明／西村　吾朗／ 大川　晋平／平沢　　壮／辻田　和宏／ 櫛引　俊宏／石原　美弥 座長：星　　詳子		16:00 – 18:00 ハンズオンセミナー2
18:15	18:15 – 20:15　懇親会（会場「大学会館レストラン筑波デミ」）			

第3日目 /7月27日（金）

	A会場（講堂）	B会場（国際会議室）	C会場（特別会議室）	第5会議室
9:00	9:00-10:15　一般演題10 OP10「CAD」（OP10-1 ～ 5） 座長：内山　良一／木村　裕一	9:00 – 10:15　一般演題11 OP11「イメージング，シミュレーション」（OP11-1 ～ 5） 座長：大西　　峻／湯浅　哲也	9:00 – 10:15　一般演題12 OP12「CAD」（OP12-1 ～ 5） 座長：小尾　高史／畑中　裕司	
10:30	10:30 – 12:00　シンポジウム2 SY2「ディープラーニング：基礎理論から応用へ」 園田　　翔／安田　宗樹／金子　卓弘 座長：庄野　　逸	10:30 – 12:00　一般演題13 OP13「CAD」（OP13-1 ～ 6） 座長：野村　行弘／八上　全弘		
12:00	昼食	昼食	昼食	12:10 – 13:10 編集委員会
13:30	13:30 – 15:00　シンポジウム3 SY3「AI画像処理の応用事例と人工知能デモクラシーについて」 山田　真善／斎藤　　豊／上條　憲一／今岡　　仁／ 髙橋　郁磨／近藤　裕子／山田　滋美／浜本　隆二／ 宮崎　　靖／緒方　　剛／George Shih 座長：中田　典生			
15:15	15:15-16:45　シンポジウム4 SY4「医用画像を活用した3Dバーチャル手術：ソフト開発から、臨床評価、医学教育までとこれからの未来」 大城　幸雄／滝沢　穂高／掛谷　英紀／矢野　博明／ 坂本　堪亮 座長：北坂　孝幸	15:15-16:45　一般演題14 OP14「CAD」（OP14-1 ～ 6） 座長：健山　智子／根本　充貴		
16:50	16:50　閉会式			

特別講演

7 月 26 日（木）14:30 ～ 15:20　**A 会場（講堂）**

SL1「実用化を目指すX線位相イメージング」

座長：工藤　博幸
（筑波大学／ JAMIT2018 大会長）

SL1　実用化を目指すX線位相イメージング
百生　　敦（東北大学）

7 月 26 日（木）15:20 ～ 16:10　**A 会場（講堂）**

SL2「顕微鏡イメージングで植物のメカニズムを視る」

座長：尾川　浩一
（法政大学／日本医用画像工学会　学会長）

SL2　顕微鏡イメージングで植物のメカニズムを視る
東山　哲也（名古屋大学）

第 8 回 JAMIT チュートリアル講演会

（教育委員会企画）

7 月 25 日（水）13:00 ～ 15:40　**A 会場（講堂）**

TL「深層学習にできること・できないこと・期待すること」

座長：花岡　昇平（東京大学）
平野　　靖（山口大学）

TL1　医用画像における深層学習を利用した研究のはじめかた
小田　昌宏（名古屋大学）

TL2　AI でできたこと・できなかったこと・これからの期待
中田　典生（東京慈恵会医科大学　超音波応用開発研究部・放射線医学講座）

TL3　深層学習のための研究環境最前線
阮　　佩穎（エヌビディア合同会社）

シンポジウム

7 月 26 日（木）16:25 ～ 17:55　**A 会場（講堂）**

SY1「医用画像再構成の基礎と新しい展開」

座長：田島　英朗（量子科学技術研究開発機構）

SY1-1　PET 画像再構成の原理と実際、そして新しい展開
小林　哲哉（株式会社島津製作所　基盤技術研究所　AI ソリューションユニット）

SY1-2　正則化逐次近似画像再構成法の基礎
篠原　広行（首都大学東京 / 昭和大学藤が丘病院放射線科）

SY1-3　SPECT における諸問題と最近の動向
尾川　浩一（法政大学理工学部）

7 月 27 日（金）10:30 ～ 12:00　**A 会場（講堂）**

SY2「ディープラーニング：基礎理論から応用へ」

座長：庄野　　逸（電気通信大学）

SY2-1　深層学習の基礎理論と発展
園田　　翔（早稲田大学先進理工学部）

SY2-2　統計的機械学習
安田　宗樹（山形大学大学院理工学研究科）

SY2-3　Generative Adversarial Networks の基礎と応用
金子　卓弘（NTT コミュニケーション科学基礎研究所）

7 月 27 日（金）13:30 ～ 15:00　**A 会場（講堂）**

SY3「ＡＩ画像処理の応用事例と人工知能デモクラシーについて」

座長：中田　典生（東京慈恵会医科大学）

SY3-1　大腸内視鏡画像に AI 画像処理を応用したリアルタイム内視鏡画像診断支援システムの開発
山田　真善
（国立がん研究センター中央病院　内視鏡科／国立がん研究センター研究所 がん分子修飾制御学分野）
斎藤　　豊（国立がん研究センター中央病院　内視鏡科）
上條　憲一（日本電気株式会社　未来都市づくり推進本部）
今岡　　仁（日本電気株式会社　バイオメトリクス研究所）
髙橋　郁磨（日本電気株式会社　未来都市づくり推進本部）
近藤　裕子（国立がん研究センター研究所 がん分子修飾制御学分野）
山田　滋美（国立がん研究センター研究所 がん分子修飾制御学分野）
浜本　隆二（国立がん研究センター研究所 がん分子修飾制御学分野）

SY3-2　人工知能による画像診断システムの高度化
宮崎　　靖（株式会社 日立製作所　ヘルスケアビジネスユニット）

SY3-3　医療画像特に脳動脈瘤検出における人工知能活用について
緒方　　剛（エルピクセル株式会社）

SY3-4　Democratizing AI in Radiology（放射線科における人工知能デモクラシーについて）
George Shih（MD.ai.Inc. (Department of Radiology, Cornell University)）

7 月 27 日（金）15:15 ～ 16:45　**A 会場（講堂）**

SY4「医用画像を活用した 3D バーチャル手術：ソフト開発から、臨床評価、医学教育までとこれからの未来」

座長：北坂　孝幸（愛知工業大学）

SY4-I-1　医工連携によるバーチャル手術の取り組みとこれからの未来
大城　幸雄（筑波大学医学医療系消化器外科）

SY4-I-2　３Ｄバーチャル手術のための医用画像セグメンテーション
滝沢　穂高（筑波大学システム情報系）

SY4-I-3　フルハイビジョン裸眼立体表示の医療応用
掛谷　英紀（筑波大学システム情報系）

SY4-I-4　Hepatic Cockpit
矢野　博明（筑波大学システム情報系）

SY4-I-5　先端医療技術とタッチレスインターフェイス
坂本　堪亮（株式会社ネクステッジテクノロジー）

SY4-II　総合討論

7 月 26 日（木）16:25 ～ 17:55　**B 会場（国際会議室）**

SY5「光断層イメージングの新しい展開」

座長：星　　詳子（浜松医科大学）

SY5-1　**タイムドメイン拡散光トモグラフィーの課題と展望**
星　　詳子（浜松医科大学）

SY5-2　**階層ベイズ拡散光トモグラフィによるタスク時と安静時の脳活動計測**
下川　丈明（ATR 脳情報解析研究所）

SY5-3　**組織深部拡散蛍光トモグラフィー：時間領域からのアプローチ**
西村　吾朗（北海道大学　電子科学研究所）

SY5-4　**光音響トモグラフィーと定量的画像再構成**
大川　晋平（防衛医科大学校）
平沢　　壮（防衛医科大学校）
辻田　和宏（防衛医科大学校）
櫛引　俊宏（防衛医科大学校）
石原　美弥（防衛医科大学校）

ハンズオンセミナー

7 月 25 日（水）16:00 ～ 18:00　**第 5 会議室**

HS1「ハンズオンセミナー 1」

7 月 26 日（木）16:00 ～ 18:00　**第 5 会議室**

HS2「ハンズオンセミナー 2（1 と同一内容）」

ランチョンセミナー

7 月 26 日（木）11:55 ～ 12:40　**A 会場（講堂）**

LS「医療分野におけるディープラーニングの活用事例と NVIDIA ディープラーニング技術の最新情報について」

座長：森　　健策（名古屋大学）

LS1　医療分野におけるディープラーニング最新情報と NVIDIA の取組みについて
岩崎　　豊（エヌビディア合同会社　エンタープライズ事業部）

LS2　NVIDIA のディープラーニング最新技術情報について
鈴木　博文（エヌビディア合同会社　エンタープライズ事業部）

第 1 日　7 月 25 日（水）　A 会場（講堂）

12:50 ～ 13:00　**開会式**

13:00 ～ 15:40　**TL「深層学習にできること・できないこと・期待すること」**

座長：花岡　昇平（東京大学）
平野　　靖（山口大学）

TL1　医用画像における深層学習を利用した研究のはじめかた
小田　昌宏（名古屋大学）

TL2　AI でできたこと・できなかったこと・これからの期待
中田　典生（東京慈恵会医科大学　超音波応用開発研究部・放射線医学講座）

TL3　深層学習のための研究環境最前線
阮　　佩穎（エヌビディア合同会社）

16:00 ～ 18:00　**OP1「セグメンテーション」**

座長：陳　　延偉（立命館大学）
花岡　昇平（東京大学）

OP1-1　Fully convolutional network を用いた少量画像データ学習からの頭部解剖構造抽出
杉野　貴明（名古屋大学大学院情報学研究科）

OP1-2　畳み込みニューラルネットワークを用いた眼底画像における毛細血管瘤の自動検出　～偽陽性候補の削減～
宮下　充浩（滋賀県立大学大学院工学研究科電子システム工学専攻）

OP1-3　被検者固有統計的形状モデルを用いた低線量撮影小児 CT 像からの肝臓セグメンテーション
中山　幸陽（東京農工大学）

OP1-4　CycleGAN による異種モダリティ画像生成を用いた股関節 MRI の筋骨格セグメンテーション
松岡　拓未（奈良先端科学技術大学院大学　情報科学研究科）

OP1-5　CNN を用いた単純 X 線画像における腰椎椎体部の検出およびラベリング
高田　真弘（株式会社リコー　研究開発本部　リコー ICT 研究所 AI 応用研究センター　第 2 ソリューション開発グループ）

OP1-6　Fast Marching Algorithm に基づく小児 CT 像からの腸管閉塞部位検出手法
西尾　光平（名古屋大学大学院情報学研究科）

OP1-7　機械学習による内視鏡動画インスタンスセグメンテーションのための手動アノテーションツールの開発
小澤　卓也（名古屋大学大学院情報学研究科）

OP1-8　ウサギ心臓の屈折 CT 像における線維配向の可視化ならびに評価
小田　紘久（名古屋大学大学院情報科学研究科）

16:00 ～ 18:00　**OP2「イメージング」**

座長：伊藤　聡志（宇都宮大学）
山谷　泰賀（量子科学技術研究開発機構）

OP2-1　新しいコンセプトの装置「Whole Gamma Imaging」における陽電子・ガンマ線同時放出核種イメージングのための検出器応答関数の提案
田島　英朗（量子科学技術研究開発機構 放射線医学総合研究所）

OP2-2　肩部撮像における 4 チャンネル照射コイルを利用した Regional RF shimming での SAR 低減
小高　晃弘（株式会社 日立製作所 ヘルスケアビジネスユニット）

OP2-3　放射光 CT 画像による肺細葉の 3 次元構造解析
泓田　彰汰（徳島大学 大学院 先端技術科学教育部）

OP2-4　新しいパッド用素材を用いた磁場均一性改善効果の評価
鴨志田　諒（東北大学大学院医学系研究科画像情報学分野）

OP2-5　畳み込みニューラルネットワークによる PET 画像ノイズ除去
大手　希望（浜松ホトニクス株式会社　中央研究所）

OP2-6　深層学習を利用した MR 圧縮センシング再構成の基礎検討
大内　翔平（宇都宮大学 大学院 工学研究科 情報システム科学専攻）

OP2-7　深層学習を利用した MR 画像の雑音除去に関する検討
高野　航平（宇都宮大学 大学院 工学研究科 情報システム科学専攻）

OP2-8　クラスタリングに基づく CNN 選択による MRI 高画質化の検討
野口　喜実（株式会社　日立製作所　研究開発グループ）

16:00 ～ 18:00　**OP3「質的診断」**

座長：河田　佳樹（徳島大学）
平野　　靖（山口大学）

OP3-1　PANCAN モデル，Lung-RADS における肺結節の悪性リスク評価
景山　　健（徳島大学大学院先端技術科学教育部）

OP3-2　細分化した病変組織で学習した CNN による Gleason 分類精度の評価
鈴木　秀智（三重大学大学院工学研究科情報工学専攻）

OP3-3　ゲノム・画像情報を用いた早期 COPD 検診法の研究開発
野崎　元貴（徳島大学大学院 先端技術科学教育部）

OP3-4　扁平上皮肺がん患者から選択した特徴量に基づく扁平上皮頭頸部がん患者の生存予測のための特徴量選択手法の検討
亀澤　秀美（帝京大学福岡医療技術学部診療放射線学科）

OP3-5　主成分分析を用いたレディオミクス特徴量による肺がん患者の予後予測法
山田　真大（九州大学医学系学府　保健学専攻）

OP3-6　Deep Learning を用いた胸部 CT 像中の肺結節の画像所見の検出および良悪性鑑別
福嶋　一茂（山口大学大学院創成科学研究科）

OP3-7　複数シーケンス乳房 MRI 画像における腫瘤病変の良悪性分類アルゴリズムの開発
柴原　　翔（立命館大学大学院　理工学研究科）

OP3-8　ディープラーニングを用いた乳房超音波検査画像の自動読影
井上　謙一（湘南記念病院 乳がんセンター）

第 1 日　7 月 25 日（水）　第 5 会議室

16:00 ～ 18:00　**HS1「ハンズオンセミナー 1」**

9:00 ～ 10:15　OP4「レジストレーション」

座長：斉藤　　篤（東京農工大学）
　　増谷　佳孝（広島市立大学）

OP4-1　機械学習に基づく X 線透視画像からの膝蓋骨方向検出に関する基礎検討
　林田　大幹（埼玉工業大学 工学部 情報システム学科）

OP4-2　胃の変形情報を利用した経時リンパ節の自動対応付け手法の精度向上に関する研究
　舘　　高基（名古屋大学大学院情報学研究科）

OP4-3　Demons アルゴリズムの一般化とその応用
　増谷　佳孝（広島市立大学大学院 情報科学研究科）

OP4-4　膵癌腫瘍のマルチモーダル 3 次元モデルの構築と 3 次元ミクロ解剖構造解析
　五嶋　優詞（名古屋工業大学）

OP4-5　膵癌腫瘍の経時変化計測のための部分剛体微分同相写像
　田村　友輝（名古屋工業大学）

10:30 ～ 11:45　OP7「深層学習，超解像」

座長：彌冨　　仁（法政大学）
　　小田　昌宏（名古屋大学）

OP7-1　ベイズ最適化法に基づく冠動脈 MRA 高解像度化のための Convolutional Neural Network の最適化
　田中　滉大（立命館大学大学院　理工学研究科）

OP7-2　畳み込みニューラルネットワークを用いたシネ MRI（Magnetic Resonance Imaging）の高フレームレート化
　高瀬　唯人（立命館大学大学院　理工学研究科）

OP7-3　スパースコーディングを利用した単一画像超解像に関する基礎検討
　竹間　康浩（宇都宮大学大学院 工学研究科 情報システム科学専攻）

OP7-4　modified SRCNN を用いたガンマカメラのプラナー画像における超解像画像生成
　籾内　政哉（岐阜大学院　自然科学技術研究科　知能理工学専攻）

OP7-5　Fully convolutional network を用いた小構造物セグメンテーション方法の検討及び腹部動脈への適用
　小田　昌宏（名古屋大学情報学研究科）

11:55 ～ 12:40

LS「医療分野におけるディープラーニングの活用事例と NVIDIA ディープラーニング技術の最新情報について」

座長：森　　健策（名古屋大学）

LS1　医療分野におけるディープラーニング最新情報と NVIDIA の取組みについて
岩崎　　豊（エヌビディア合同会社　エンタープライズ事業部）

LS2　NVIDIA のディープラーニング最新技術情報について
鈴木　博文（エヌビディア合同会社　エンタープライズ事業部）

13:30 ～ 14:30　**総会**

14:30 ～ 15:20　**SL1「実用化を目指すＸ線位相イメージング」**

座長：工藤　博幸
（筑波大学／ JAMIT2018 大会長）

SL1　実用化を目指すX線位相イメージング
百生　　敦（東北大学）

15:20 ～ 16:10　**SL2「顕微鏡イメージングで植物のメカニズムを視る」**

座長：尾川　浩一
（法政大学／日本医用画像工学会　学会長）

SL2　顕微鏡イメージングで植物のメカニズムを視る
東山　哲也（名古屋大学）

16:25 ～ 17:55　**SY1「医用画像再構成の基礎と新しい展開」**

座長：田島　英朗（量子科学技術研究開発機構）

SY1-1　PET 画像再構成の原理と実際、そして新しい展開
小林　哲哉（株式会社島津製作所　基盤技術研究所　AI ソリューションユニット）

SY1-2　正則化逐次近似画像再構成法の基礎
篠原　広行（首都大学東京 / 昭和大学藤が丘病院放射線科）

SY1-3　SPECT における諸問題と最近の動向
尾川　浩一（法政大学理工学部）

9:00 ～ 10:15　OP5「X 線イメージング」

座長：北村　圭司（島津製作所）
武田　　徹（北里大学）

OP5-1　縞走査を行わない位相計測手法
廉　　松哲（筑波大学）

OP5-2　X 線位相イメージングにおける統計的画像再構成法の高速化
上田　亮介（筑波大学）

OP5-3　4 方向撮影による胸部トモシンセシスの最適投影角の検討
堀　　拳輔（北里大学大学院医療系研究科）

OP5-4　X 線トモシンセシス装置における金属アーチファクト補正技術の検討
山川　恵介（日立製作所　研究開発グループ）

OP5-5　フォトンカウンティング型 X 線 CT を用いた金コロイド粒子の定量
上甲　拓巳（法政大学　理工学部　応用情報工学科）

10:30 ～ 11:45　OP8「VR, AR」

座長：中口　俊哉（千葉大学）
目加田慶人（中京大学）

OP8-1　脳神経外科手術支援のための手術顕微鏡画像からの脳表の 3 次元形状復元に関する検討
林　雄一郎（名古屋大学大学院情報学研究科）

OP8-2　スマートグラスを用いた整形外科手術ナビゲーションシステム
西尾　祥一（兵庫県立大学）

OP8-3　開腹下手術の術中ナビゲーションシステムの新しい機能の開発
服部　麻木（東京慈恵会医科大学高次元医用画像工学研究所）

OP8-4　腹腔鏡下手術のための VR 手術再観察システムの開発
鈴木　拓矢（中京大学 工学部）

OP8-5　標準脳機能アトラスの投影による未来予測手術の具現化
田村　　学（東京女子医科大学　先端生命医科学研究所　先端工学外科学分野）

16:25 ～ 17:55　SY5「光断層イメージングの新しい展開」

座長：星　　詳子（浜松医科大学）

SY5-1　タイムドメイン拡散光トモグラフィーの課題と展望
星　　詳子（浜松医科大学）

SY5-2　階層ベイズ拡散光トモグラフィによるタスク時と安静時の脳活動計測
下川　丈明（ATR 脳情報解析研究所）

SY5-3　組織深部拡散蛍光トモグラフィー：時間領域からのアプローチ
西村　吾朗（北海道大学　電子科学研究所）

SY5-4　光音響トモグラフィーと定量的画像再構成
大川　晋平（防衛医科大学校）
平沢　　壮（防衛医科大学校）
辻田　和宏（防衛医科大学校）
櫛引　俊宏（防衛医科大学校）
石原　美弥（防衛医科大学校）

第２日　７月26日（木）　C会場（特別会議室）

9:00 ～ 10:15　OP6「CAD」

座長：木戸　尚治（山口大学）
金　　亨燮（九州工業大学）

OP6-1　肝臓がん検出器のための 3D-DCGAN を用いた学習用画像生成法
池田　裕亮（中京大学工学部）

OP6-2　多時相造影 CT 画像を用いた腎臓解析
松下　和樹（徳島大学大学院 先端技術科学教育部）

OP6-3　ResNet を用いた指骨 CR 画像からの骨粗しょう症の自動識別
畠野　和裕（九州工業大学）

OP6-4　CT 画像を用いた上腕骨頭３次元統計的形状モデルによる人工肩関節設計
久保　有輝（兵庫県立大学）

OP6-5　符号化欠損領域情報の自動検出を想定した腹腔鏡画像の色情報解析と医用画像診断に関する考察
河畑　則文（名古屋大学未来社会創造機構）

10:30 ～ 11:45　OP9「治療支援」

座長：有村　秀孝（九州大学）
大竹　義人（奈良先端科学技術大学院大学）

OP9-1　股関節鏡シミュレータにおける視認性に基づくポータル位置と刺入方向の評価：１５症例による検証
川上申之介（奈良先端科学技術大学院大学 情報科学研究科）

OP9-2　取り下げ

OP9-3　X 線画像を用いた経気管支診断支援向け処置具３次元位置マッピング法の基礎検討
松崎　和喜（日立製作所 研究開発グループ）

OP9-4　前立腺癌放射線治療におけるベイズ領域推定法のための解剖学的特徴点に基づいた前立腺位置推定法
二宮　健太（九州大学大学院　医学系学府保健学専攻）

OP9-5　画像誘導放射線治療のリアルタイム腫瘍追跡における患者個別深層学習を実現する非線形データ拡張方法
照沼　利之（筑波大学医学医療系）

16:00 ～ 18:00　**HS2「ハンズオンセミナー 2（1 と同一内容）」**

9:00 ～ 10:15　OP10「CAD」

座長：内山　良一（熊本大学）
木村　裕一（近畿大学）

OP10-1　深層学習による単純ＣＴにおける急性期脳梗塞の自動検出
高橋　規之（秋田県立脳血管研究センター）

OP10-2　Capsule network を用いた磁化率強調像の教師あり学習による脳循環代謝異常の予測の試み
松原　佳亮（秋田県立脳血管研究センター放射線医学研究部）

OP10-3　脳 MRI 画像類似症例検索のための 3 次元畳み込みオートエンコーダによる次元削減
新井　颯人（法政大学）

OP10-4　MRI における脳転移検出に対する Convolutional Neural Network の応用：線量分布を正解データとして利用
村田　仁樹（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）

OP10-5　ＳＶＭを用いた嚥下時Ｘ線サジタル透視動画における舌骨の追跡
八板　駿平（筑波大学大学院システム情報工学研究科コンピュータサイエンス専攻）

10:30 ～ 12:00　SY2「ディープラーニング：基礎理論から応用へ」

座長：庄野　　逸（電気通信大学）

SY2-1　深層学習の基礎理論と発展
園田　　翔（早稲田大学先進理工学部）

SY2-2　統計的機械学習
安田　宗樹（山形大学大学院理工学研究科）

SY2-3　Generative Adversarial Networks の基礎と応用
金子　卓弘（NTT コミュニケーション科学基礎研究所）

13:30 ～ 15:00　SY3「ＡＩ画像処理の応用事例と人工知能デモクラシーについて」

座長：中田　典生（東京慈恵会医科大学）

SY3-1　大腸内視鏡画像に AI 画像処理を応用したリアルタイム内視鏡画像診断支援システムの開発
山田　真善
（国立がん研究センター中央病院　内視鏡科／国立がん研究センター研究所 がん分子修飾制御学分野）
斎藤　　豊（国立がん研究センター中央病院　内視鏡科）
上條　憲一（日本電気株式会社　未来都市づくり推進本部）
今岡　　仁（日本電気株式会社　バイオメトリクス研究所）
髙橋　郁磨（日本電気株式会社　未来都市づくり推進本部）
近藤　裕子（国立がん研究センター研究所 がん分子修飾制御学分野）
山田　滋美（国立がん研究センター研究所 がん分子修飾制御学分野）
浜本　隆二（国立がん研究センター研究所 がん分子修飾制御学分野）

SY3-2　人工知能による画像診断システムの高度化
宮崎　　靖（株式会社 日立製作所　ヘルスケアビジネスユニット）

SY3-3　医療画像特に脳動脈瘤検出における人工知能活用について
緒方　　剛（エルピクセル株式会社）

SY3-4　Democratizing AI in Radiology（放射線科における人工知能デモクラシーについて）
George Shih（MD.ai.Inc.（Department of Radiology, Cornell University））

15:15 ～ 16:45　**SY4「医用画像を活用した 3D バーチャル手術：ソフト開発から、臨床評価、医学教育までとこれからの未来」**

座長：北坂　孝幸（愛知工業大学）

SY4-I-1　医工連携によるバーチャル手術の取り組みとこれからの未来
大城　幸雄（筑波大学医学医療系消化器外科）

SY4-I-2　３Dバーチャル手術のための医用画像セグメンテーション
滝沢　穂高（筑波大学システム情報系）

SY4-I-3　フルハイビジョン裸眼立体表示の医療応用
掛谷　英紀（筑波大学システム情報系）

SY4-I-4　Hepatic Cockpit
矢野　博明（筑波大学システム情報系）

SY4-I-5　先端医療技術とタッチレスインターフェイス
坂本　堪亮（株式会社ネクステッジテクノロジー）

SY4-II　総合討論

16:50 ～ 17:00　**閉会式**

第３日　7月27日（金）　B 会場（国際会議室）

9:00 ～ 10:15　**OP11「イメージング，シミュレーション」**

座長：大西　　峻（千葉大学）
湯浅　哲也（山形大学）

OP11-1　非局所トータルバリエーションを用いたスパースビュー CT 画像再構成の画質改善
金　　鎔采（筑波大学システム情報工学研究科コンピュータサイエンス専攻）

OP11-2　深層学習による放射型 CT の画像補正
鈴木　朋浩（筑波大学システム情報工学研究科）

OP11-3　管電流変調と bow-tie フィルタの X 線 CT 画像上の雑音分散への効果
梅田　祐司（名古屋大学大学院医学系研究科医療技術学専攻医用量子科学講座）

OP11-4　SDF 撮影法を用いた微小循環酸素飽和度推定の撮影深度補正
橋本　涼平（千葉大学大学院融合理工学府）

OP11-5　非剛体変換を用いた低線量四次元 CT 画像からの肝腫瘍領域の描出精度
鈴木健太郎（済生会横浜市東部病院　放射線部）

10:30 ～ 12:00　OP13「CAD」

座長：野村　行弘（東京大学）
八上　全弘（京都大学）

OP13-1　Z-score 画像を用いた悪性腫瘍の自動抽出と治療効果判定および被ばく線量測定のためのシステムの開発
羽賀　愛美（岐阜大学　大学院　自然科学技術研究科　知能理工学専攻）

OP13-2　3 次元 CT 画像を用いたじん肺の重症度診断基準の定量的評価
日野　公貴（徳島大学大学院 先端技術科学教育部）

OP13-3　HoTPiG 特徴量を用いた胸部 CT における結節自動検出
花岡　昇平（東京大学医学部附属病院放射線科）

OP13-4　CNN による胸部 CT 画像からの経時的差分画像上の異常陰影の検出
長尾　充朗（九州工業大学）

OP13-5　CT 画像を用いた脂肪量計測の改良
井手上　凌（新居浜高専）

OP13-6　隣接復元を用いた SLAM ベースの気管支鏡追跡の改善
王　　成（名古屋大学大学院情報科学研究科）

15:15 ～ 16:45　OP14「CAD」

座長：健山　智子（広島工業大学）
根本　充貴（近畿大学）

OP14-1　加重積算による肝臓の ADC 精度向上
西原　　崇（株式会社日立製作所 ヘルスケアビジネスユニット）

OP14-2　機械学習を用いた腹部動脈血管名自動命名における臓器情報および多血管相互関係利用方法の検討
鉄村　悠介（名古屋大学大学院情報学研究科）

OP14-3　造影マルチスライス CT 画像における大腸がんの転移性リンパ節解析
坂東　佳祐（徳島大学大学院 先端技術科学教育部）

OP14-4　教師なし深度推定を利用した RGB-D 特徴抽出に基づくポリープのトリナリサイズ推定
伊東　隼人（名古屋大学大学院　情報学研究科）

OP14-5　3 次元 residual networks (ResNets) を用いた大腸 CAD における偽陽性陰影の識別
植村　知規（九州工業大学）

OP14-6　CNN を用いた自己進化型 CAD システムの提案
安倍　和弥（神奈川工科大学）

9:00 ～ 10:15　OP12「CAD」

座長：小尾　高史（東京工業大学）
畑中　裕司（滋賀県立大学）

OP12-1　Faster R-CNN を用いた子宮頸部細胞診における悪性細胞の検出
津森　太亮（山口大学大学院　創成科学研究科　電気電子情報系専攻）

OP12-2　マウスの脳の二光子顕微鏡画像からの神経細胞認識処理の開発
君塚　　涼（東京農工大学）

OP12-3　Automatic detection of image quality failure for the practical use of whole slide imaging scanner
ホシャイン サカワット（School of Engineering, Tokyo Institute of Technology, Japan）

OP12-4　深層学習器を用いた悪性黒色腫自動識別における識別根拠の評価
村林　誠也（法政大学 理工学部 応用情報工学科）

OP12-5　クラス別学習による細胞画像セグメンテーション
松月　大輔（名城大学理工学研究科電気電子工学専攻）

抄　録

（著者から提出された内容をそのまま掲載します）

第1日　7月25日（水）　A会場（講堂）

12:50 ～ 13:00　**開会式**

13:00 ～ 15:40　**TL「深層学習にできること・できないこと・期待すること」**

座長：花岡　昇平（東京大学）
平野　　靖（山口大学）

深層学習への期待が続いている．このような状況のなかで，新たに深層学習に関連する研究を開始する場合，新旧の情報が入り混じり，環境構築に手間取る場合が多い．また，最新の動向に追いつくためには，情報の取捨選択が必要である．今回のJAMITチュートリアルは，大会期間中に会場で開催される「コニカミノルタ科学技術振興財団JAMITハンズオンセミナー」と一部連携して，医用画像における深層学習の実際について集中的に講演を企画した．講演１では，深層学習を始めるために必要な知識の獲得と，具体的な利用例や研究事例について，データの収集方法も含めて講演いただく．講演２では，すでに深層学習の研究を実施しているものの，さらにその発展を考えている開発者／研究者に向けて，実行環境の最前線や，大規模環境な計算環境で実行されている研究事例の解説を行う．講演３では，導入が始まっている人工知能システムについて，その利用経験や今後期待する内容を，深層学習関連の研究を行っている臨床医の立場から解説する．

TL1　医用画像における深層学習を利用した研究のはじめかた

○小田　昌宏
名古屋大学

深層学習を用いた医用画像処理研究の成果が多数報告され，従来手法を凌ぐ成果が得られている．現在，最先端の研究に追随するためには深層学習の利用が必須とも言える状況になっている．本講演では，深層学習利用により研究成果を得るために何が必要であるかを，深層学習利用のビギナーを対象として紹介する．医用画像処理には，検出，セグメンテーション，レジストレーション，画像変換，時系列情報処理等様々な処理が含まれる．深層学習はこれらほとんどの処理で利用可能であり，特に検出とセグメンテーションでは非常に高い性能を示す．研究者にとっての深層学習利用の恩恵として，研究開発スピードの向上，従来手法を超える成果を得られる可能性がある点などが挙げられる．また，目的別のアルゴリズム開発に要する時間を短縮し，実用化面への注力が可能である点も有用である．

TL2　AIでできたこと・できなかったこと・これからの期待

○中田　典生
東京慈恵会医科大学　超音波応用開発研究部・放射線医学講座

米国を中心にAIを活用した画像診断支援診断システムが医療機器として認可された．また超音波診断装置には自動計測機能にAIが利用された装置が実用化されるようになった．これらの実用化や実臨床への普及が広がるにつれ，AI診断支援システム開発のための教師学習用データの作成が重要になった．これらの作成に携わる医師には，深層学習や機械学習の基本的知識の取得，膨大な教師学習用データ収集の必要性の認識や収集に必要な経済的財源の確保などの問題に取り組む必要性がある．また工学系研究者に必要なことは，世界中で絶対的に不足しているAI開発エンジニアの養成が急務である．さらには，立法行政機関を巻き込んだAI開発企業（主にスタートアップ）の支援，国内のみならず国際間の教師学習用データ収集の仕組みづくりや経験の蓄積が重要である．本講演では，これらの問題についてスタートアップ企業から世界有数の巨大AI企業の実例を挙げながら解説・考察する．

TL3　深層学習のための研究環境最前線

○阮　　佩穎
エヌビディア合同会社

画像認識や音声認識のような，基本的な分類や認識問題から始まった深層学習の流行は，年々広がりを見せている．その適用先は，自動運転車や医用画像を用いた診断支援などの応用から，大規模シミュレーションと組み合わせる応用まで，多岐にわたる．その一方，問題設定が大規模化，複雑化するにつれ，より多くの計算機資源が必要とされる状況は継続している．このような背景のもと，深層学習においては，高い演算性能をもつGPUを活用し学習を高速化することが一般的となっている．また，ハードウェアのみならずソフトウェアを含むエコシステム全体として継続的な性能向上や利便性の向上が行われており，さまざまな環境が提供されている．本講演では，深層学習に用いるGPUや関連するソフトウェアについて最新の状況を紹介する．あわせて，医用画像における適用例や，今後活用を期待できる手法などについても紹介する．

16:00 ～ 18:00　**OP1「セグメンテーション」**

座長：陳　　延偉（立命館大学）
花岡　昇平（東京大学）

OP1-1　Fully convolutional network を用いた少量画像データ学習からの頭部解剖構造抽出

○杉野　貴明[1]，Roth Holger[1]，小田　昌宏[1]，庄野　直之[2]，金　　太一[2]，森　　健策[1,3,4]

[1]名古屋大学大学院情報学研究科，[2]東京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

実践的訓練・シミュレーションの実施が難しい脳外科手術のシミュレータとして，近年，頭部解剖構造を再現した精巧な頭部モデルの開発が進められている．そこで本研究では，こうしたモデルの生成・標準化に有用な解剖構造データベースの構築を目的として，医用画像から正確な頭部解剖構造抽出を可能とする深層学習ベースのセグメンテーション手法を提案する．特に本稿では，深層学習ベースの手法で課題となる学習データ作成における手動アノテーションの負担を軽減するため，スパースアノテーションによる少量の学習データから精密な解剖構造抽出結果をもたらすネットワーク及びその学習手法を構築する．Visible Korean Human プロジェクトによる人体断面画像データを基に抽出精度の検証実験を実施したところ，本手法により全画像枚数の一部を学習に用いるだけでも高い精度での頭部解剖構造抽出が可能であることが示された．

OP1-2　畳み込みニューラルネットワークを用いた眼底画像における毛細血管瘤の自動検出　～偽陽性候補の削減～

○宮下　充浩[1]，畑中　裕司[2]，小郷原一智[2]，村松千左子[3]，砂山　　渡[2]，藤田　広志[3]

[1]滋賀県立大学大学院工学研究科電子システム工学専攻，[2]滋賀県立大学工学部電子システム工学科，[3]岐阜大学大学院医学系研究科再生医科学専攻知能イメージ情報分野

糖尿病網膜症は本邦の失明原因の 2 位である．その初期所見の 1 つである毛細血管瘤は，眼底画像上で小さく，低コントラストであるため，医師であっても発見が困難である．筆者らは医師の診断補助を目的とした毛細血管瘤の自動検出法の実現を目指し，JAMIT2017 で 3 種類の毛細血管瘤の強調画像を用いた畳み込みニューラルネットワーク (CNN) で毛細血管瘤を自動検出する手法を示した．しかし，毛細血管瘤の強調画像では，一部の偽陽性が強調されてしまう問題があった．また，テクスチャ特徴を中心とした 48 種類の特徴量を用いた偽陽性候補の削除処理も提案しているが，十分な判別性能が得られていない．本研究では，グレースケール画像を用いた CNN を追加し，従来の CNN の結果と組み合わせることで検出性能の向上を図った．また，現在は偽陽性候補の削除処理の改善を進めており，JAMIT2018 では最新の結果を報告する予定である．

OP1-3　被検者固有統計的形状モデルを用いた低線量撮影小児 CT 像からの肝臓セグメンテーション

○中山　幸陽[1]，斉藤　　篤[1]，Biggs Elijah[2]，Linguraru Marius[2]，清水　昭伸[1]

[1]東京農工大学，[2]Children's National Health System

In this paper, we propose a liver segmentation algorithm for childhood CT scan using a patient specific statistical shape model (SSM). A childhood CT volume is acquired by low dose CT scan, because a child is more sensitive to radiation dose than an adult. Consequently, the CT volume has lower signal-to-noise ratio, which makes segmentation difficult. Although an SSM based segmentation algorithm can handle such low-quality CT volumes, no SSM of a childhood liver has been proposed. Since the childhood liver has higher variability in shape and size than an adult, an SSM designed for a child is mandatory for the liver segmentation. This paper proposes a segmentation algorithm based on a patient specific SSM of a child that can describe difference in shape and size caused by difference in age of a patient. Given the age of a child, the patient specific SSM is constructed and used in the segmentation process. The segmentation algorithm with the patient specific SSM was applied to liver segmentation of 42 CT volumes of children whose ages are between 2 weeks to 7 years. The segmentation results showed superiority of the algorithm against a segmentation method with a conventional SSM in terms of accuracy.

OP1-4　CycleGAN による異種モダリティ画像生成を用いた股関節 MRI の筋骨格セグメンテーション

○松岡　拓未[1]，日朝　祐太[1]，大竹　義人[1]，高尾　正樹[2]，高嶋　和磨[2]，Jerry Prince[3]，菅野　伸彦[2]，佐藤　嘉伸[1]

[1]奈良先端科学技術大学院大学　情報科学研究科，[2]大阪大学　医学系研究科，[3]Department of Electrical and Computer Engineering, Johns Hopkins University

医用画像からのセグメンテーションは，定量的な診断や患者個別のシミュレーションのため重要である．医用画像は，その撮像モダリティにより異なる特徴をもつ．CT は骨の構造を明瞭に撮影することができるのに対して，MR は軟組織の構造を明瞭に撮影することができる．このような違いはセグメンテーションにおいても考慮する必要がある．そこで本研究では，CycleGAN を用いて MRI から同患者同姿勢の CT 画像を生成することにより，セグメンテーションに活用する手法を提案する．

OP1-5　CNN を用いた単純 X 線画像における腰椎椎体部の検出およびラベリング

○髙田　真弘[1]，木下　　彰[1]，川端　茂徳[2]

[1]株式会社リコー　研究開発本部　リコー ICT 研究所 AI 応用研究センター　第 2 ソリューション開発グループ，[2]東京医科歯科大学

医用画像装置の発展に伴い，MRI などの形態画像から診断を支援するシステムが提供されてきている．特に，脊椎分離症や脊椎側彎症などの脊椎に関する症状において異常箇所を提示するような診断支援システムの要求が高まっている．これらのシステム全般で最も重要な技術としては，異常箇所の部位を高精度に特定する技術が要求されている．また，ユーザが介入することなく，全自動で動作可能なシステムを実現できればユーザの負担を軽減することができる．

そこで本稿では，腰部の単純 X 線画像から部位の特定をすることを目的として，CNN を用いた腰部の単純 X 線画像から腰椎椎体部の検出とラベリングまでを全自動で行う手法について提案する．また，椎体部に加えて，椎間板と仙骨の部位を検出が可能な CNN のネットワークを構築することで，高精度な検出を可能にした．更に，椎間板と仙骨を加えたことで，高精度なラベリング結果を得ることが可能となった．

OP1-6　Fast Marching Algorithm に基づく小児 CT 像からの腸管閉塞部位検出手法

○西尾　光平[1]，小田　紘久[2]，千馬　耕亮[3]，北坂　孝幸[4]，Roth Holger[1]，伊東　隼人[1]，小田　昌宏[1]，檜　　顕成[3]，内田　広夫[3]，森　　健策[1,5,6]

[1]名古屋大学大学院情報学研究科，[2]名古屋大学大学院情報科学研究科，[3]名古屋大学大学院医学系研究科，[4]愛知工業大学大学院情報科学部，[5]名古屋大学情報基盤センター，[6]国立情報学研究所 医療ビッグデータ研究センター

本研究では，血管造影された小児イレウス患者の CT 像から腸管閉塞部位を検出する手法について報告する．イレウス患者は，腸管内に腹水等と濃度値の差が小さい食物・便が含まれていることや，腸管が複雑に折り重なっていることから，これまでの抽出手法では精度よく腸管内領域を抽出できない．そこで本研究では，血管造影 CT 像であることに着目し，Fast Marching Algorithm に基づいた手法により腸を抽出することで腸管閉塞部位検出を行う．手動で入力したシードポイントから食物・便である液体領域と空気領域を交互に抽出することで，閉塞部位まで腸管内領域を辿り閉塞部位を検出する．このとき，液体領域では Fast Marching Algorithm，空気領域では領域拡張法を用いる．提案手法をイレウスによる腸管閉塞部位が存在する血管造影された小児 CT 像 5 症例に適用し，辿ることのできた腸管の割合により評価を行った．辿ることのできた腸管の割合の平均は 75.4% であった．

OP1-7　機械学習による内視鏡動画インスタンスセグメンテーションのための手動アノテーションツールの開発

○小澤　卓也[1]，小田　紘久[1]，伊東　隼人[1]，北坂　孝幸[2]，Roth Holger R.[1]，小田　昌宏[1]，林　雄一郎[1]，三澤　一成[3]，伊藤　雅昭[4]，竹下　修由[4]，森　　健策[1,5,6]

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

本研究では，内視鏡動画像に対する術具や解剖領域を手動でインスタンスセグメンテーションするための，アノテーションツール開発について報告する．内視鏡動画像に対して詳細に術具や解剖領域がアノテーションされたデータは，手術支援機器における画像からの解剖構造の自動識別技術の実現や内視鏡手術手技の評価技術の実現など，内視鏡手術の安全性を高める研究において利用価値が高い．しかし現状，術具や解剖構造を詳細にセグメンテーションしたデータベースは存在せず，これらデータの生成基盤の構築が求められている．そこで本研究では，動画像に対してセグメンテーション作業を行う為のツール「NuVAT」を開発した．このツールにより，セグメンテーション作業をお絵かきツールを扱う感覚で簡単に行うことが可能になった．実際にこのツールは国立がん研究センター東病院にて，腹腔鏡動画像における術具・解剖領域のアノテーション作業に利用された．

OP1-8　ウサギ心臓の屈折 CT 像における線維配向の可視化ならびに評価

○小田　紘久[1]，Roth Holger R.[2]，砂口　尚輝[3]，宇佐美紀子[3]，小田　昌宏[2]，島雄　大介[4]，市原　　周[5]，湯浅　哲也[6]，安藤　正海[7]，秋田　利明[3]，成田　裕司[3]，森　　健策[2,8,9]

[1]名古屋大学大学院情報科学研究科，[2]名古屋大学大学院情報学研究科，[3]名古屋大学大学院医学系研究科，[4]北海道科学大学保健医療学部，[5]名古屋医療センター臨床研究センター，[6]山形大学大学院理工学研究科，[7]東京理科大学研究推進機構総合研究院，[8]名古屋大学情報基盤センター，[9]国立情報学研究所 医療ビッグデータ研究センター

屈折 CT は高解像度な 3 次元画像撮像モダリティのひとつであり，生物の軟組織に対して高いコントラストをもつ．我々は屈折 CT を用いて，エタノール固定を施したウサギの心臓全体を撮影した．このマイクロ CT 像のうち，とりわけ左心室における線維が良好に視認できるよう，ヘッセ行列を用いた画像処理を行い，2 次元および 3 次元の可視化を行う．さらに構造テンソルを用いたファイバートラッキングおよび線維配向の統計により , 左心室ならびに心臓全体がどのような構造をもつのかを視覚的・定量的に明らかにする．

第 1 日　7 月 25 日（水）　　B 会場（国際会議室）

16:00 ～ 18:00　**OP2「イメージング」**

座長：伊藤　聡志（宇都宮大学）
山谷　泰賀（量子科学技術研究開発機構）

OP2-1　新しいコンセプトの装置「Whole Gamma Imaging」における陽電子・ガンマ線同時放出核種イメージングのための検出器応答関数の提案

○田島　英朗[1]，吉田　英治[1]，奥村　勇介[2,1]，菅　　幹生[2]，河地　有木[3]，鎌田　　圭[4]，パロディ カティア[5]，山谷　泰賀[1]

[1]量子科学技術研究開発機構 放射線医学総合研究所，[2]千葉大学，[3]量子科学技術研究開発機構 高崎量子応用研究所，[4]株式会社 C&A，[5]ミュンヘン大学

我々の提案する WGI (Whole Gamma Imaging) は，PET 核種に対する高感度化，シングルガンマ核種のイメージング，陽電子とほぼ同時にガンマ線を放出する核種（3 ガンマ核種）の利用による単一崩壊イメージングなどを一つの装置で可能とする新しいコンセプトである．WGI は，PET とコンプトンイメージングを組み合わせた画期的な手法で，従来の PET リングの内側に散乱検出器リングを設け，PET リングを吸収検出器として機能させることで，PET の同時計数に加え，シングルガンマ線をコンプトンイメージングの原理で検出可能である．本研究では , 3 ガンマ核種イメージングのための検出器応答関数を提案し，WGI のコンセプト実証機において逆投影により画像を生成する際に，同時計数線の情報のみを用いた場合と提案手法を用いた場合を比較した．その結果，提案手法による逆投影像は，より鮮明な画像になることが示された．

OP2-2　肩部撮像における 4 チャンネル照射コイルを利用した Regional RF shimming での SAR 低減

○小高　晃弘，伊藤　公輔，森分　周子，瀧澤　将宏

株式会社 日立製作所 ヘルスケアビジネスユニット

【目的】高磁場 MRI では高解像度の画像を得られるが，SAR 増大による撮像パラメータの制約が課題である．特に，肩部撮像では頭部に近いため制約が厳しい．本研究は，3T MRI の肩部撮像における SAR 低減を目的とする．
【方法】領域を限定して照射を補正する，Regional RF shim を肩部で最適化した．評価には，4CH 独立照射制御システムを有する 3T MRI((株) 日立製作所製) を用いた．健常ボランティア 15 人 (日立グループ倫理審査委員会で審査済み) を評価した．照射分布を表す B1 map を取得し，撮像領域を抽出した．照射の均一度指標と SAR の線形結合を，係数を変えて最小化するアルゴリズムを適用し , その効果を確認した．QD 照射と比較して照射均一度が失われず , SAR を最大に低減する係数を決定した．
【結果】決定した係数では，SAR は QD 照射よりも約 30% 低減し，撮像領域の照射均一度は維持した．

OP2-3　放射光 CT 画像による肺細葉の 3 次元構造解析

○泓田　彰汰[1]，斉藤くるみ[1]，大西　　悟[1]，河田　佳樹[2]，仁木　　登[2]，梅谷　啓二[3]，阪井　宏彰[4]，
中野　恭幸[5]，岡本　俊宏[6]，伊藤　春海[7]

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

次世代の画像診断に向け，肺 3 次元ミクロ構造を観察して疾患の極初期段階を診断することは極めて重要な問題である．

しかし，肺の微小構造を示す顕微鏡像では立体構造のイメージが困難であり，肺 3 次元ミクロ構造は十分に解析されていないという現状がある．

本研究は，兵庫県の大型放射光施設 (SPring-8) にて肺標本を撮影し，解析を行った．

また，細血管を観察するため肺標本には造影剤としてバリウムを注入している．

撮影には，Nikon 製のカメラ D800E(画素配列 7,360 × 4,912 pixels，画素サイズ 3.07 μ m) を使用した．

肺 3 次元ミクロ構造は気管支系と血管系に分けられ，血管系は肺動脈，肺細動脈，毛細血管，肺細静脈，肺静脈に分けられる．

本報告では，肺胞房領域 (肺胞管と複数の肺胞嚢を含む，呼吸細気管支の最終分岐が支配する領域の仮称) の血管抽出結果を示す．

それに加え，造影肺標本に対する最適な撮影条件の考察を述べる．

OP2-4　新しいパッド用素材を用いた磁場均一性改善効果の評価

○鴨志田　諒[1]，青羽　南臣[1]，会田　健人[1]，永坂　竜男[2]，五十嵐寛光[3]，町田　好男[1]

[1]東北大学大学院医学系研究科画像情報学分野，[2]東北大学病院，[3]株）六濤

【目的】磁場均一性は MRI の性能向上のための重要な前提の一つであるが，実際の撮影では，被検体が入ることで不均一性が生じてしまう．臨床現場で対応できる方法としてパッドを装着する方法がある．その素材としてこれまでも多くの試料が利用されているが，本研究では新しいパッド用素材について従来の素材と比較検討した．

【方法】3T の MRI を使用した．市販のポリエチレン容器を加工し，水の周囲をいくつかの物質で満たしたファントムを作成した．充填物質は空気，水，米，新素材（カプセル化したフルオロカーボン）とした．グラディエントエコー法で得た位相画像をアンラップして位相分布を求め，これを磁場強度に換算し，磁場均一性改善効果を評価した．

【結果】新素材を用いることによる磁場均一性の改善効果は従来素材の米に近いもので，臨床上有用なレベルであると考えられた．新素材の利用により，安定した磁場均一性改善効果が期待される．

OP2-5　畳み込みニューラルネットワークによる PET 画像ノイズ除去

○大手　希望，得居　　葵，橋本二三生，磯部　卓志，斉藤　右典，大村　友秀

浜松ホトニクス株式会社　中央研究所

畳み込みニューラルネットワークによる PET 画像ノイズ除去を検討した．Remez らの DenoiseNet（DN）を用いた．DN をそのまま PET 画像の横断面に適用すると，冠状・矢状断面に横筋を生じた．畳み込みを 3D 空間に広げると横筋は消えたが，ノイズ除去の計算時間が 7.5 倍に増加した．隣接 N スライスを N チャンネル画像としてノイズ除去すると，計算時間を増やさず，横筋を消すことができた．N=3 で横筋が目立たなくなり，N=5 でピーク信号対雑音比がフラットになった．DN の学習には健常ボランティアの頭部 PET 画像 32 例を用いた．それらは浜松医科大学に設置された頭部用 PET 装置（Hamamatsu HITS-655000）で計測された．リストモード収集データを 1/32 に間引いて低カウント画像を再構成し，全データを用いて再構成した画像とペアにして，訓練データとした．

OP2-6　深層学習を利用した MR 圧縮センシング再構成の基礎検討

○大内　翔平，伊藤　聡志

宇都宮大学 大学院 工学研究科 情報システム科学専攻

MRI における撮像時間の短縮法として，圧縮センシングの応用が近年注目を集めている．圧縮センシングによれば，信号を間引くことで撮像時間の短縮が可能となるが，画像再構成に要する時間が長くなる．

本研究では，深層学習を利用した圧縮センシング再構成を試みた．深層学習では，残差学習法を応用して，アーチファクトを含む画像とアーチファクトを含まない画像の画像対で学習を行った．これにより，深層学習ネットワークに対してアーチファクトを含む画像を入力として与えると，アーチファクトのみを推定するようにした．

提案法を用いると，従来の圧縮センシングによる再構成法では 10 秒以上を要した再構成計算が，CPU のみを利用した場合では 1.5 秒以下に，GPU を利用した場合では 0.6 秒以下に短縮できた．また，従来法では良好な再構成が困難であった間引き法において，提案法では良好な再構成が行える場合があった．

以上より，提案法の有効性が示された．

OP2-7　深層学習を利用した MR 画像の雑音除去に関する検討

○高野　航平，伊藤　聡志
宇都宮大学 大学院 工学研究科 情報システム科学専攻

MR 画像では主磁界強度が大きくなるにつれ，高品質な画像が得られるようになってきているが，撮像の高速化も進んでいるため依然として低 S/N 比の画像が得られている．診断精度を高めるため，医用画像では，細部構造の保存性と雑音除去性能を両立した雑音除去法が求められている．

本研究では，近年注目を浴びている深層学習を用いた雑音除去法の MR 画像への応用について検討を行った．学習に際しては，残差学習法によって雑音を含む入力画像から雑音成分を推定するように学習させた．本方法を雑音除去性能が高いことで知られる BM3D や WNNM と比較した．定量評価ではこの 2 種と同等以上の結果が得られた．また，本方法は細部構造や医用画像で重要となる弱コントラストの保存性が高いことが示された．さらに，学習モデルとテストモデルの性質の類似度が高いほど有効であることが示唆された．

以上から，本方法は MR 画像の雑音除去において有用な方法になりうる可能性が示された．

OP2-8　クラスタリングに基づく CNN 選択による MRI 高画質化の検討

○野口　喜実，荻野　昌宏
株式会社　日立製作所　研究開発グループ

近年注目されている畳み込みニューラルネットワーク（CNN）は特に画像認識分野において広く用いられている手法であるが，画像再構成技術への応用も可能であり，従来技術と比較して高い性能が得られている．本研究では CNN を利用し，少数の観測データから再構成された劣化 MRI 画像の高画質化について検討した．

本検討においては，公開されている約 550 枚の画像データをフーリエ変換して作成した観測データから高周波成分 75％を除去することで 4 倍速相当の劣化画像を作成し，ネットワークを学習した．また，画像の局所的な特徴量をクラスタリングによって分類し，それぞれ異なる CNN に入力することにより，画質の向上を図った．同様に作成した 30 枚の評価用画像において，PSNR35.1dB を実現し，単一の CNN を利用した場合に比べて約 1.5dB の画質向上を確認した．

第 1 日　7 月 25 日（水）　C 会場（特別会議室）

16:00 ～ 18:00　**OP3「質的診断」**

座長：河田　佳樹（徳島大学）
平野　　靖（山口大学）

OP3-1　PANCAN モデル，Lung-RADS における肺結節の悪性リスク評価

○景山　　健[1]，河田　佳樹[2]，仁木　　登[2]，楠本　昌彦[3]，大松　広伸[4]，青景　圭樹[3]，土田　敬明[5]，松元　裕司[5]，江口　研二[6]，金子　昌弘[7]
[1]徳島大学大学院先端技術科学教育部，[2]徳島大学大学院社会産業理工学研究部，[3]国立がん研究センター東病院，[4]網走刑務所，[5]国立がん研究センター中央病院，[6]帝京大学医学部，[7]東京都予防医学協会健康支援センター

日本において，肺がんは，がん死亡者数第一位を占め，増加傾向にある．肺がんを早期発見する方法のひとつとして，近年胸部 3 次元 CT 画像を用いて肺がん候補を高精度に発見する肺がん CT スクリーニンが実施されているものの，20 ～ 55％の非がん症例を対象に不要な生検が実施されている．そこで，肺がん CT スクリーニングにおける肺がんの偽陽性率を低下させるために，世界各国で結節をカテゴリー管理し採点する悪性リスクモデルが複数公開されてきた．本研究では，悪性リスクモデルの開発の基礎実験として，近年評価されている PANCAN モデル，Lung-RADS の悪性リスクモデルを日本人の thin-section CT 画像を対象にして比較評価し，良悪性の鑑別因子を調査した．その結果，結節の良悪について PANCAN モデルが有意に優れる性能を示し，PANCAN 悪性リスクモデルの予測因子に含まれる性別，結節のサイズ，結節の位置，スピキュラーの有無が有用な悪性度指標として期待できる結果を得た．

OP3-2　細分化した病変組織で学習したCNNによるGleason分類精度の評価

○鈴木　秀智[1]，藤本　祐基[1]，白石　泰三[2]，太田　義勝[1]

[1]三重大学大学院工学研究科情報工学専攻，[2]桑名市総合医療センター

これまでの計算機によるGleason分類では，4種類のGleasonパターン（正常，パターン3，パターン4，パターン5）の標本中の大きさに基づいてGleasonスコアが算出され，80%以上の分類精度と，Gleasonスコアの正解率が得られていた．しかし，進行によって高分化しているがん組織は多様な組織構造をもつため，これらの違いを考慮せずに分類する方法では，さらなる精度の向上は難しいと考えられる．そこで，本研究では，高分化しているGleasonパターン4とGleasonパターン5を，それぞれ，4個と2個のクラスに細分して8クラスのデータを作成し，これを用いて学習したCNNによる分類精度の評価を行なった．実験の結果，細分したデータを使うことで，Gleasonパターンの分類精度が89.2%から91.6%に改善されることを確認した．また，組織標本のセグメンテーションの精度の向上も確認した．

OP3-3　ゲノム・画像情報を用いた早期COPD検診法の研究開発

○野崎　元貴[1]，鈴木　秀信[2]，河田　佳樹[2]，仁木　　登[2]，増田　清士[3]，井本　逸勢[3]，金子　昌弘[4]

[1]徳島大学大学院 先端技術科学教育部，[2]徳島大学大学院 社会産業理工学研究部，[3]徳島大学大学院医歯薬学研究部，[4]東京都予防医学協会

慢性閉塞性肺疾患（COPD）は，タバコ煙を主とする有害物質を長期に吸入暴露することで生じた肺の炎症性疾患である．しかし喫煙者の15%ほどに発症するのみである．本研究は，喫煙者で気腫型COPDの進展度と関連するCT画像と一塩基多型(SNP)を用いて検討する．画像情報としてCT検診の経年画像からLAV%の増加量を求め，進展度と定義し，進展度が高い群，進展度が低い群として2群に分類する．ゲノム情報としてCOPDと肺がんに関連する可能性が示唆されているSNPを文献から調査する．唾液からDNAを精製し，調査結果12種類の各SNPのプローブを混合しプレートを作成する．作成したプレートを解析するリアルタイムPCR装置にかけ，遺伝子型を判定する．進展度で分類した2群間で判定したSNPの遺伝子型に有意差があるかどうかを統計的に解析し，検討した．

OP3-4　扁平上皮肺がん患者から選択した特徴量に基づく扁平上皮頭頸部がん患者の生存予測のための特徴量選択手法の検討

○亀澤　秀美[1]，有村　秀孝[2]，スーフィー マーゼン[3]

[1]帝京大学福岡医療技術学部診療放射線学科，[2]九州大学大学院医学研究院保健学部門，[3]奈良先端科学技術大学院大学情報科学研究科

We investigated the feasible feature selection approaches for the survival prediction of squamous cell head and neck cancer (SCHNC) patients based on radiomic features (RFs) selected from squamous cell lung cancer (SCLC) patients. 486 RFs were calculated from the tumor regions in the computed tomography images. Significant features for survival prediction were selected by artificial neural network based feature selection (ANNFS) approach and least absolute shrinkage and selection operator. Statistical significant differences between survival curves of two patient groups, which were stratified by the median of each feature into two subtypes, were assessed. The ANNFS approach could be useful for the survival prediction of SCHNC patients based on RFs selected from SCLC patients.

OP3-5　主成分分析を用いたレディオミクス特徴量による肺がん患者の予後予測法

○山田　真大[1]，有村　秀孝[2]，マーゼン スーフィー[3]

[1]九州大学医学系学府　保健学専攻，[2]九州大学大学院　医学部研究員保健学部門，[3]奈良先端科学技術大学院

The aim of this study was to develop an approach for prediction of lung cancer patients' prognoses using principal component analysis (PCA)-based radiomic features. 486 radiomic features were extracted from CT images of 197 patients. The PCA was applied for 486 normalized radomic features to reduce the number of features, and the PCA coefficients of the first to tenth principal components (PCs) were considered as PCA-based radiomic features. 197 patients were stratified into two groups by medians of PCA-based radiomic features. Finally, survival probabilities were calculated by the Kaplan-Meire method and evaluated by statistically significant differences between stratified patient groups. PCA coefficients of the first, fourth and fifth PCs were powerful prognostic factor ($p<0.05$).

OP3-6　Deep Learning を用いた胸部 CT 像中の肺結節の画像所見の検出および良悪性鑑別

○福嶋　一茂[1]，平野　　靖[1]，木戸　尚治[1]，岩野　信吾[2]

[1]山口大学大学院創成科学研究科，[2]名古屋大学大学院医学系研究科

近年，コンピュータ診断支援 (CAD) システムに関する研究では，Deep Learning が使用される機会が多くなってきており，従来よりも高い性能を示すことが報告されている．肺結節の良悪性鑑別のための CAD システムでも同様の傾向があるが，それらは CT 像等を入力とし，良性あるいは悪性の尤度のみを出力するものが一般的である．一方で患者に対して医師が肺結節の診断結果を説明する際には，良悪性の尤度だけでは不十分であり，診断結果の根拠を説明することが求められる．そこで本研究では Deep Learning の一形態である CNN(Convolutional Neural Network) を用いて，CT 像中の肺結節が悪性であることを示唆する画像所見の存在の尤度を診断の根拠として提供し，さらにそれらの尤度を入力とする NN(Neural Network) によって良悪性の鑑別結果を医師に提供する CAD システムの構築を行った．55 個の良性結節と 120 個の悪性結節を含むデータベースを用いて本手法の性能を評価した結果，識別率は 79.02 ± 8.43[%] となった．

OP3-7　複数シーケンス乳房 MRI 画像における腫瘤病変の良悪性分類アルゴリズムの開発

○柴原　　翔[1]，中山　良平[2]，大西　悠吾[1]，檜作　彰良[2]，中島　　恵[3]，難波　　清[3]

[1]立命館大学大学院　理工学研究科，[2]立命館大学　理工学部　電子情報工学科，[3]北斗病院　乳腺外科

乳房 MRI（Magnetic Resonance Imaging）は，マンモグラフィや超音波検査よりも感度が高いが，特異度は同程度であり，その改善が望まれている．本研究では複数シーケンスの乳房 MRI 画像における腫瘤病変の良悪性分類アルゴリズムを開発することを目的とする．実験試料は，38 患者の MRI（T1 ／ T2 強調画像，T1 ／ T2 強調ダイナミック造影画像）で構成される．提案手法では，まず，各シーケンス画像を畳み込みニューラルネットワークに学習させ，良悪性の分類に有用な特徴マップを抽出する．次に，各特徴マップをサポートベクターマシンで統合することにより，腫瘤病変を良性または悪性に分類する．Leave-one out patient 法を用いた評価実験の結果，正答率 97.3%，感度 100.0%，特異度 75.0%，陽性予測度 93.8%，陰性予測度 100.0%が得られ，提案手法の高い鑑別精度が示された．

OP3-8　ディープラーニングを用いた乳房超音波検査画像の自動読影

○井上　謙一[1]，川崎あいか[1]，小清水佳和子[1]，山中　千草[1]，佐々木　毅[2]，土井　卓子[1]

[1]湘南記念病院 乳がんセンター，[2]東京大学医学部大学院医学系研究科人体病理学病理診断学分野

[背景] 人工知能を用いた画像認識は医療分野でも研究がなされている．我々は乳腺の超音波検査 (US) 画像を用いて乳癌の自動判定を検討した．[対象と方法] 当院で撮影された US 画像から，正常乳腺組織，良性腫瘍，悪性腫瘍が描出されている部位をそれぞれ切り出しベース画像とした．その際，画像の範囲内で 128x128 ピクセルでどこを切り出してもその特徴が描出されるように集めた．ベース画像からランダムに切り出した画像を教師ありデータとして，畳み込みニューラルネットワーク (CNN) に学習させ，精度を計測した．[結果] 正常乳腺 95 画像，良性病変 1206 画像，悪性病変 358 画像から，ランダムに 5000 枚ずつ切り出した画像計 15000 枚を用いた．CNN は 20 層の ResNet で学習させたところ，正診率は 98.7% であった．悪性病変に対する精度は，感度 99.4%，特異度 98.5%，PPV97.0%，NPV99.7% であった．またこの学習モデルを用いて別のオリジナル US 画像をスキャンし，癌が疑わしい部分を赤く光らせるアルゴリズムも作成した．[考察]US を自動読影できるようになれば，総合検診を念頭とした乳癌検診の効率・精度は飛躍的に向上する可能性を秘めている．[結語]CNN で US 画像の自動読影システムを構築した．更に検証を重ね，全国で利用できるシステムの構築を目指す．

9:00 ～ 10:15 **OP4「レジストレーション」**

座長：斉藤　　篤（東京農工大学）
増谷　佳孝（広島市立大学）

OP4-1 機械学習に基づくX線透視画像からの膝蓋骨方向検出に関する基礎検討

○林田　大幹[1]，山崎　隆治[1]，田島未輝斗[1]，冨田　哲也[2]，河野　賢一[3]，佐藤　嘉伸[4]，菅本　一臣[2]

[1]埼玉工業大学 工学部 情報システム学科，[2]大阪大学大学院 医学系研究科 運動器バイオマテリアル学，[3]東京大学大学院 医学系研究科 整形外科学，[4]奈良先端科学技術大学院大学 情報科学研究科

現在，我々は，1方向X線透視画像を用いた2D/3Dレジストレーションに基づく膝関節3次元運動計測の全自動化に向けて様々な要素技術の開発を行っている．その一つとして，2次元X線透視画像上の膝関節部位（大腿骨，脛/腓骨，膝蓋骨）の方向（相対的な角度）を予め把握しておくことは非常に重要である．特に，膝蓋骨については，レジストレーションが不安定であるため実行前にできるだけ膝蓋骨の初期点（位置と姿勢）を対象シルエットに対し適切に近づけておく必要があるが，もしX線透視画像上の膝関節部位間の方向が予め分かっていれば，マニュアル作業による初期点設定の手間を大幅に削減できる可能性がある．そこで本研究では，X線透視画像上の大腿骨に対する膝蓋骨の方向（角度）を予め機械学習により学習させ，対象となる膝蓋骨の方向を自動的に検出することを試みた．機械学習には，SVM，ランダムフォレスト，CNNを用い，性能評価を行った結果，各手法において高い成功率で膝蓋骨の方向を検出できることが分かった．

OP4-2 胃の変形情報を利用した経時リンパ節の自動対応付け手法の精度向上に関する研究

○舘　　高基[1]，小田　昌宏[1]，林　雄一郎[1]，中村　嘉彦[2]，北坂　孝幸[3]，三澤　一成[4]，森　　健策[1,5,6]

[1]名古屋大学大学院情報学研究科，[2]苫小牧工業高等専門学校，[3]愛知工業大学情報科学部，[4]愛知県がんセンター中央病院，[5]名古屋大学情報基盤センター，[6]国立情報学研究所医療ビッグデータ研究センター

本稿では，胃の変形情報を利用した経時リンパ節の自動対応付け手法について報告する．がんの進行度及び治療の有効性を確認する際には，リンパ節の経時変化が観察される．この際，医師により目視でリンパ節の対応付けが行われるが，この作業は煩雑かつ定量性に欠けるため，自動対応付け手法の開発が望まれている．経時リンパ節の自動対応付け手法には濃度値情報を利用した非剛体位置合わせが多く用いられるが，濃度値情報にはリンパ節の位置の変化を解析する上で余計な情報が多く，対応付けに失敗する可能性がある．そこで本手法では，CT像から抽出した胃領域の変形を解析し，その変形場を利用して対応付けを行う．胃領域は点群として表現し，変形場はICP，TPS-RPMを利用して算出した．実験は11組の経時症例から抽出したリンパ節画像を対象に行い，リンパ節の組全ての内正しく対応付けを行うことが出来た組の割合で評価を行った．全体での正解率は78.1%であった．

OP4-3 Demonsアルゴリズムの一般化とその応用

○増谷　佳孝[1]，石田　善喜[2]

[1]広島市立大学大学院 情報科学研究科，[2]広島市立大学 情報科学部

Demonsアルゴリズムは２つの画像の信号差や勾配に基づく画像レジストレーションの古典的な一手法であるが，基本的に同一のモダリティかつ各画素が単一の値をもつスカラ画像間での使用に限定されている．本研究では，信号差や勾配を２つの画像の局所特徴間の距離で置き換えることで，様々な画像間のレジストレーションが可能となることを示す．例えば，カラー画像では画素間の色距離，スカラ画像の場合も局所領域の複数の画素値を使用して２つの画像の局所領域間の距離を定義して用いる．３次元のカラー画像ファントムおよび拡散テンソル画像を含む多様な画像や複数の局所画素値を用いたレジストレーション実験の例により，その特性や有効性・拡張性について検証した結果を報告する．

OP4-4　膵癌腫瘍のマルチモーダル 3 次元モデルの構築と 3 次元ミクロ解剖構造解析

○五嶋　優詞[1]，本谷　秀堅[1]，横田　達也[1]，クグレ マウリシオ[1]，岩本　千佳[2]，大内田研宙[2]，
橋爪　　誠[2]
[1]名古屋工業大学，[2]九州大学

In this study, we propose a method of registration between an MRI image and a set of pathological microscope images of a pancreatic cancer tumor of a KPC mouse. MRI images can be captured non-invasively but their resolution is low. On the other hand, microscopic images can be obtained only invasively although the resolution is high. Registration of these images is needed for realizing a multi-resolution model representing the correlation between the MRI images and the corresponding pathological images. In order to register the 2D pathological microscope images to the 3D MRI image, the proposed method first reconstructs a 3D pathological microscope image and then register between the 3D pathological microscopic image and the tumor region in the MRI image. The 3D pathological microscope image is reconstructed from a spatial series of 2D microscope images. For the reconstruction of an appropriate 3D image, the microscope images should be non-rigidly registered together. We employed a non-rigid registration method that deforms every image so that the spatial patterns in the resultant image have smooth structures. After the 3D image reconstruction, the proposed method then registers between the MRI image and the reconstructed 3D pathological image by means of a mutual-information based non-rigid registration. Down sampling the 3D microscope image so that the both images have same spatial resolution, the proposed method deforms the microscope images to the MRI image by maximizing their mutual information. We report the result of the registration and of the description of the microstructures in the reconstructed 3D pathological image.

OP4-5　膵癌腫瘍の経時変化計測のための部分剛体微分同相写像

○田村　友輝[1]，横田　達也[1]，Mauricio Kugler[1]，Valentin Triquet[1]，清　　智也[2]，岩本　幸英[3]，
大内田研宙[3]，橋爪　　誠[3]，本谷　秀堅[1]
[1]名古屋工業大学，[2]東京大学，[3]九州大学

Purpose

The objective of our research is to describe the temporal change of the tumor region in the whole body MRI images of a KPC mouse captured at different time. For accurately describing the tumorgrowth, non-rigid registration should be applied to normalize the body motion. Here, in order to suppress the deformation of the tumor caused by the registration, we develop a Large Deformation Diffeomorphic Metric Mapping(LDDMM) that transforms the tumor region rigidly.

Method

Given a set of corresponding landmarks on the peripheral organs in a source image and a target image, the proposed method first non-rigidly registers the two images by referring to those corresponding landmarks. This non-rigid registration also non-rigidly maps the landmarks of the tumor region in the source image non-rigidly. The proposed method next estimates the destination locations of the tumor landmarks in the target image by converting the non-rigid mapping of the tumor landmarks to a rigid mapping. Then, we can have a set of corresponding landmarks that consists of (a) the landmarks on the peripheral organs that would be registered non-rigidly and (b) the landmarks in the tumor region that can be registered rigidly. Our method iterate the non-rigid registration of the landmarks and the conversion of the non-rigid mapping of the tumor landmarks to the rigid one until they are converged.

Results

We experimented with both artificial images and real images and confirmed the effect. We also confirmed that the results obtained depend on the scale of the kernel and the arrangement of landmarks.

Conclusion

We proposed a partial rigid diffeomorphism. This enabled accurate measurement of tumor deformation from MRI images taken at different times.

10:30 ～ 11:45

OP7「深層学習，超解像」

座長：彌冨　仁（法政大学）
小田　昌宏（名古屋大学）

OP7-1　ベイズ最適化法に基づく冠動脈 MRA 高解像度化のための Convolutional Neural Network の最適化

○田中　滉大[1]，中山　良平[2]，小林　大輝[1]，檜作　彰良[2]，石田　正樹[3]，北川　覚也[3]，佐久間　肇[3]
[1]立命館大学大学院 理工学研究科，[2]立命館大学 理工学部 電子情報工学科，[3]三重大学 医学部附属病院 放射線診断科

近年，CNN（Convolutional Neural Network）は医用画像にも応用され，優れた成果が報告されている．しかし，CNN は手動で設定すべきハイパーパラメータが多数あり，結果がそれらに大きく左右される問題がある．本研究では，ベイズ最適化法を用いて，冠動脈 MRA の高解像度化に適用する CNN のハイパーパラメータを自動で決定し，より高精度に高解像度化することを目的とする．ベイズ最適化法では，まず，実験試料の冠動脈 MRA から最適化用データとして，無作為に少数データを選択する．次に，CNN のハイパーパラメータ探索にガウス過程によるサンプリングを行い，最適なハイパーパラメータを決定する．ベイズ最適化を用いた CNN による高解像度化画像の元画像に対する Root Mean Squared Error は 3.74 で，従来の CNN（6.91）よりも高い結果が得られ，ベイズ最適化によるハイパーパラメータの決定の有用性が示された．

OP7-2　畳み込みニューラルネットワークを用いたシネ MRI（Magnetic Resonance Imaging）の高フレームレート化

○高瀬　唯人[1]，中山　良平[2]，檜作　彰良[2]，石田　正樹[3]，北川　覚也[3]，佐久間　肇[3]
[1]立命館大学大学院　理工学研究科，[2]立命館大学　理工学部　電子情報工学科，[3]三重大学　医学部附属病院　放射線診断科

近年，動画像の時間分解能を向上する時空間超解像技術が活発に研究されている．本研究では，時空間超解像技術の概念を CNN（Convolutional Neural Network）に展開し，シネ MRI の時間分解能を忠実に向上できるか検討した．まず，シネ MRI（時間分解能 20msec）のフレーム数を 1/2 に間引きし，低フレームレート画像を生成した．そして，低フレームレート画像の小領域（パッチ）を CNN に入力し，CNN の出力値と対応するシネ MRI のパッチ間の誤差が最小となるように CNN を学習する．シネ MRI と CNN による高フレームレート化画像間の Root Mean Square Error，Structural Similarity Index は 9.75，0.9948 で，線形補間法によるフレーム内挿技術（9.83，0.9945）よりも高く，CNN によるシネ MRI の高フレームレート化の有用性が示唆された．

OP7-3　スパースコーディングを利用した単一画像超解像に関する基礎検討

○竹間　康浩，柴田　光貴，伊藤　聡志
宇都宮大学大学院 工学研究科 情報システム科学専攻

MR 画像など画素数が少ない場合は，画像を補間拡大する処理が行われる．このとき，単なる補間ではなく，超解像の効果があれば低解像度画像では確認できなかった情報を得ることができ，画像診断の精度を高めることが期待できる．

本研究室で提案されている eFREBAS 変換によりスパースコーディングされた空間では，全て同サイズの展開像を有し，かつ，それらは相互に相似性を持った分布を有している．そこで本研究では，eFREBAS 空間における展開像の相似性を利用し，eFREBAS 空間にて信号を外挿することにより画像を超解像的に拡大する方法を考える．実験の結果，学習型超解像に比べて超解像効果が大きく，鮮鋭度の高い補間像が得られることを確認した．

OP7-4　modified SRCNN を用いたガンマカメラのプラナー画像における超解像画像生成

○籾内　政哉[1]，原　　武史[1]，片渕　哲朗[2]，藤田　廣志[1]
[1]岐阜大学院　自然科学技術研究科　知能理工学専攻，[2]岐阜医療科学大学　保健科学部　放射線技術学科

The image resolutions of planar scintigram images taken by gamma cameras in single photon emission computed tomography (SPECT) devices have lower spatial ones than the original imaging property of the devices. Super-resolution technique was already applied to various natural images or movies, but the application to medical images are limited because of the difficulty of obtaining enough dictionary image data. The purpose of this study was to propose a super-resolution technique based on modified super-resolution convolutional neural network (mSRCNN) which was trained combined images from medical and non-medical image databases. The structure of mSRCNN consists of convolutional and de-convolutional layers. The number of neurons in each layer of the mSRCNN is given by 128*128 - 128*128 - 128*128 - 256*256. The image database was consisted of image pairs of original and scanned images. The original images were used for the gold standard without any blurs. The scanned images were obtained as a grey-scale phantom image, where the grey level was scaled to the radioactivity. The phantom images were created by using a specific image printer which the inks were containing radioactivity materials. As an evaluation of those image quality, we used two indices of peak signal-to-noise ratio (PSNR) and structural similarity (SSIM). We compared the mSRCNN images and the scanned ones. 83 image pairs were used for the experiment. We used 75 cases for training and 8 cases of test. The PSNR and SSIM of scanned images and restored ones were improved from 10.18 to 16.93 and from 0.364 to 0.437, respectively. In conclusions, it is suggested that this method using deep learning technique can contribute to improve image quality of planar images from gamma cameras.

OP7-5　Fully convolutional network を用いた小構造物セグメンテーション方法の検討及び腹部動脈への適用

○小田　昌宏[1]，Roth Holger R.[1]，北坂　孝幸[2]，三澤　一成[3]，藤原　道隆[4]，森　　健策[1,5]
[1]名古屋大学情報学研究科，[2]愛知工業大学情報科学部，[3]愛知県がんセンター，[4]名古屋大学医学系研究科，[5]国立情報学研究所医療ビッグデータ研究センター

本発表では Fully convolutional network（FCN）を用いた小構造物セグメンテーション手法と，CT 像からの腹部動脈セグメンテーションへの適用法を報告する．様々な解剖構造セグメンテーションに FCN が適用されて良好な結果が報告されている．しかし，画像上での体積がセグメンテーション結果に影響するため，体積の小さい血管等の小構造物セグメンテーション精度は低くなる傾向がある．この問題に対処するため，最大輝度値投影画像として作成した局所画像を用いることで画像上に占める小構造物の体積を上昇させ，セグメンテーション精度を改善するアプローチが考えられる．また，大域的画像情報を入力とし，局所領域におけるセグメンテーション結果を出力する FCN 構造を提案する．本稿ではこれらを用いて腹部動脈セグメンテーションを行う．実験では，従来手法と比較して提案手法は見落としの少ない結果を出力していた．

11:55 ～ 12:40　LS「医療分野におけるディープラーニングの活用事例と NVIDIA ディープラーニング技術の最新情報について」

座長：森　　健策（名古屋大学）

急速に進んでいる医療分野でのディープラーニングの活用について，NVIDIA が協業を進めている米国での事例をご紹介し，さらに GPU 製品，サーバーシステムやソフトウェアからなる最新の NVIDIA ディープラーニング技術をご紹介いたします．

LS1　医療分野におけるディープラーニング最新情報と NVIDIA の取組みについて

岩崎　　豊
エヌビディア合同会社　エンタープライズ事業部

この数年で医療分野におけるディープラーニングの活用は急速に進んでいます．本セミナーでは NVIDIA とディープラーニング の活用について先進的に協業を進めている米国マサチューセッツ総合病院（MGH）での事例を紹介します．また医療分野へのディープラーニングの活用に対する NVIDIA の取組みを国内の状況も含めてご紹介します．

LS2　NVIDIA のディープラーニング最新技術情報について

鈴木　博文
エヌビディア合同会社　エンタープライズ事業部

医用画像の診断支援を含め，ディープラーニングの活用は急速な広がりを見せています．また昨今のディープラーニングに要求される計算性能は飛躍的に高くなってきており，更に高性能，高効率な計算システムが必要とされています．
本セミナーでは，最新の GPU 製品およびサーバーシステムの技術情報をご紹介すると同時に迅速な開発を支援するツールやソフトウェア環境についてご紹介します．

14:30 ～ 15:20　SL1「実用化を目指すＸ線位相イメージング」

座長：工藤　博幸
（筑波大学／ JAMIT2018 大会長）

SL1　実用化を目指すＸ線位相イメージング

○百生　　敦
東北大学

Ｘ線の波としての性質，すなわちＸ線位相コントラストを活用すると，従来のＸ線透視画像と大きく異なる高感度化への展開が期待される．主に軽元素で構成される軟組織によるＸ線の減衰は少なく，従来法では十分なコントラストが得られないが，Ｘ線位相イメージングではその撮影が可能になってくるからである．Ｘ線位相コントラスト生成技術は，Ｘ線光学分野において考案され，幾つかの方式が実証されている．特に，Ｘ線透過格子を用いるＸ線 Talbot-Lau 干渉計として知られる方式は，病院で使われているＸ線源や画像検出器を用いて装置化できるため，その実用化が大いに期待されている．講演者は，この十数年，この方式による医用画像機器や非破壊検査機器の開発を続けてきた．軟骨が可視化できることに基づく関節リウマチの早期診断を狙った装置は，現在大学病院において臨床研究に供されている．講演では，その原理から実用化の現状まで，できるだけ平易に解説する．

15:20 ～ 16:10　SL2「顕微鏡イメージングで植物のメカニズムを視る」

座長：尾川　浩一
（法政大学／日本医用画像工学会　学会長）

SL2　顕微鏡イメージングで植物のメカニズムを視る

○東山　哲也
名古屋大学

動かないように思える植物も，顕微鏡を通して覗いてみると，実にダイナミックに動いています．特に花の中では，花粉から伸びだした細い管である「花粉管」が，正確に卵のある分まで到達し，泳げない２つの精細胞を「重複受精」させます．私たちの研究から，初めてその様子が生きたまま映像として捉えられました．そして顕微鏡下での様々なライブセル解析から，花粉管誘引などの現象を支える生理活性分子が，鍵分子として見つかってきました．現在は，マイクロ流体デバイスを用いて，当研究所オリジナルの蛍光分子を使った１分子レベルでの詳細なイメージングや，組織丸ごとを使った深部イメージングなどにチャレンジしています．本講演では，植物の生殖を中心として，顕微鏡イメージングで見えてきた植物の未知の世界を紹介します．どんな逆境にも負けず，あの手この手で生殖を達成する，植物の真の姿をお楽しみ下さい．

16:25 ～ 17:55

SY1「医用画像再構成の基礎と新しい展開」

座長：田島　英朗（量子科学技術研究開発機構）

近年の医用画像装置の進歩は目覚ましく，特に体の中の様子を３次元的に観察できるCT・MRI・PET・SPECTなどのイメージング装置は，患者個々人の病態を細かく調べることができ，個別化医療の実現など医療診断の質の向上に大きく貢献しています．撮像された医用画像を元にしたコンピュータ画像診断支援の研究も盛んに行われていますが，本シンポジウムでは，今一度イメージングの手法自体に立ち返って，医用画像装置で測定された生の情報から画像を再構成するまでの基礎的な原理や方法，そして，現在注目されている画像再構成の手法や新しい展開について，画像再構成をご専門とされている諸先生方よりご講演いただきます．

SY1-1　PET 画像再構成の原理と実際、そして新しい展開

○小林　哲哉

株式会社島津製作所　基盤技術研究所　AI ソリューションユニット

画像再構成を必要とする様々なイメージング装置 (CT, MR, PET, SPECT など) において，観測対象とする物理量分布を高精度に推定するためには，重要なポイントが３つある．

（１）イメージング物理の理解

物理量分布と装置が計測する生データの物理的関係を正確にモデル化（数式化）すること．

（２）イメージング問題の定式化

観測モデルを出発点として，目標とする画質と計算の複雑さのトレードオフを念頭に置いて，画像再構成問題を具体的な数値計算問題（最適化問題）に落とし込むこと．

（３）イメージング問題の解法の選択・導出

現実的な計算時間で実用的な画像が得られる数値計算アルゴリズムを選択すること，または新たに導出すること．

本講演では，上記のポイントを通して，PET 画像再構成の原理と実際を述べる．加えて，新しい展開として，吸収補正のためのCT撮影を不要にできる可能性を秘めた「吸収補正付き画像再構成」について，その原理や具体的なアルゴリズムを紹介する．

SY1-2　正則化逐次近似画像再構成法の基礎

○篠原　広行

首都大学東京 / 昭和大学藤が丘病院放射線科

尤度（画像から推定される観測データの尤もらしさ）と画像の事前確率との和の事後確率を最大化する正則化逐次画像再構成法は，1) 低線量 CT による被ばくの低減と画質の向上，2) 圧縮センシング MRI による高速撮像，3) PET 画像の収束性の向上などに応用されている．これまで CT 逐次近似法のアルゴリズムは公表されておらずブラックボックスになっていたが，工藤は 3 種類の逐次近似（IR）法（True IR, Hybrid IR, Image denoising IR）の数式を示した（Med Imag Tech 32: 239-248, 2014）．そこで，1) に関心をもつ学生や医療技術者の学習支援を目的に，それら数式を数値実験する例を紹介する．圧縮センシング MRI では 2 次元直交座標, 3 次元直交座標, 2 次元極座標それぞれのサンプリングからの再構成画像の数値評価と視覚評価，そして，最近の PET に搭載された正則化ブロック勾配法について紹介する．

SY1-3　SPECT における諸問題と最近の動向

○尾川　浩一

法政大学理工学部

SPECT は臓器の機能を映像化するイメージング法であり，体内に集積した放射性医薬品からのガンマ線をガンマカメラで計測し，その集積を３次元的に映像化する．このデータ収集の過程において，ガンマ線源から放出されたガンマ線が体内の原子と吸収や散乱などの相互作用を起こす．また，検出器側ではコリメータが必要となり，これも計測データに影響を与える．これらの画質劣化の問題は，古くから解析的な方法あるいは逐次近似的な方法で補正が試みられてきた．本発表では，画像再構成を含めたこれらの画質劣化の解決方法について概説するとともに，近年の SPECT などで話題となっている半導体検出器を用いたイメージングやピンホールコリメータを用いたイメージングについても述べる．

9:00 ～ 10:15　OP5「X 線イメージング」

座長：北村　圭司（島津製作所）
武田　　徹（北里大学）

OP5-1　縞走査を行わない位相計測手法

○廉　　松哲，工藤　博幸
筑波大学

X 線位相撮影では生体の軟組織などを従来の X 線撮影より高いコントラストで観察することができ，医療診断への応用が期待されている．Talbot 干渉計による測定では回折格子をサブミクロンレベルで複数回移動（縞走査）し撮影するため，装置には非常に高い精度と安定性が求められる．縞走査を必要としない手法として Fourier 変換法があるが，高周波成分を捨てるため一般的に解像度が大幅に下がる．我々は縞走査なしで位相が求められる新たな画像解析手法を提案する．この手法では２段階の手順を行う．１段階目は Talbot 干渉計で得られる三つの画像（吸収，visibility，位相）において隣接画素値がほぼ同じだと仮定し，不足する測定データを隣接画素の測定データで補い近似位相画像を求める．２段階目は，近似位相画像から濃度値の変化が大きい箇所を推定し，上記の仮定とのずれが大きい部分を補正することで高解像度のまま復元を行う．提案手法では従来の Fourier 変換方法よりも高い解像度で位相を求められ，回折格子の移動が不要であるため高速 CT 撮影などへの応用が期待できる．

OP5-2　X 線位相イメージングにおける統計的画像再構成法の高速化

○上田　亮介，工藤　博幸，山嵜　　深
筑波大学

X 線断層撮影では吸収率分布を画像化するが，生体軟組織など軽元素から成る測定対象では吸収コントラストは低く，鮮明な画像が得られないことがある．対して，X 線の波としての性質を利用する位相イメージングでは，X 線が物体を通過する際の位相シフト量を画像化し，はるかに高いコントラストを得ることができる．特に実験室でも利用可能な Talbot-Lau 干渉計は医用応用が期待されている．近年，この位相イメージングによる CT において，統計的画像再構成法が提案された [Ritter2016,PlosOne]．この手法では，尤度最大化により吸収，散乱，位相に対する３つのコントラスト画像を得ることができ，ノイズ低減や測定回数の削減などの様々なポテンシャルが期待されている．しかし，反復回数が多く，３つの画像を同時に再構成するため計算量が多い課題がある．本研究では，Kudo らによって近年提案された FBP 組み込み型高速化手法 [Kudo2016,in proc. SPIE] を Ritter らの統計的画像再構成方に応用した．この手法は解析的手法である FBP 法を反復法に組み込むことにより劇的な反復数の削減を可能とする．Kudo らの論文では重み付き２乗誤差を最小化する反復法を構築しているが，本研究では尤度最大化問題にも応用可能とした．Talbot 干渉計により撮影された画像を用いた再構成結果と，本手法による収束速度の改善結果を報告予定である．

OP5-3　4 方向撮影による胸部トモシンセシスの最適投影角の検討

○堀　　拳輔[1]，董　　居忠[2]，岡本　啓公[3]，関　　将志[3]，村石　　浩[1]，齊藤　典生[2]，
Thet Thet Lwin[1]，渡辺　　宝[1,4]，王　　波[2]，武田　　徹[1]
[1]北里大学大学院医療系研究科，[2]つくばテクノロジー株式会社，[3]北里大学病院放射線部，[4]首都大学東京大学院人間健康科学研究科

【目的】トモシンセシスは，現在肺結節検出に用いられている単純 X 線像と比較して感度を改善でき，CT と比較して低被ばくである．既存のトモシンセシスは，X 線管が動作して 60 方向程度撮影するため，約 10 秒を要し，息止めによる患者の負担が大きい．一方，提案する固定型 X 線管を用いた 4 方向撮影トモシンセシスは，1 秒以内での撮影とさらなる被ばく低減が実現できる．本研究では，4 方向撮影時の最適投影角について検討した．【方法】X 線撮影装置で種々の模擬結節を含む胸部ファントムを 1° 毎に撮影し，再構成したトモシンセシス像についてコントラストノイズ比（CNR）及び Artifact Spread Function を用いた定量評価を行った．【結果】広角に比べ，挟角で撮影した方が，奥行分解能は劣るが，良好な CNR が得られた．【結論】結節検出が目的の 4 方向撮影トモシンセシスは挟角撮影が適していることが示唆された．

OP5-4　X 線トモシンセシス装置における金属アーチファクト補正技術の検討

○山川　恵介[1]，高橋　啓子[2]，中村　　正[2]
[1]日立製作所　研究開発グループ，[2]日立製作所　ヘルスケアビジネスユニット

近年，乳房や整形で用いられるトモシンセシスにおいて，代表的な FBP 画像では投影データの角度欠損により，金属と軟部組織間等の吸収値差が大きい条件で金属アーチファクトが増加する．これを低減するため，断層画像撮影では画像の金属位置に基づく投影データの補間法が用いられるが，トモシンセシスでは位置毎のアーチファクトのばらつきが大きく画像上の金属抽出が困難で，境界のアーチファクト低減が不十分な場合がある．そこで，境界の画質向上を目的として，操作者の負荷を抑えつつ，投影データの 2 次元と投影角度方向を含む 3 次元を複合した領域拡張ベースの投影データ金属抽出法を提案する．これにより，周辺領域に対して抽出した金属の吸収値差を小さくし再構成することで，アーチファクトを低減できる．シミュレーションと整形用固定具を模擬したファントム実験において，周辺領域の画質を維持し高いアーチファクト低減効果が得られたので報告する．

OP5-5　フォトンカウンティング型 X 線 CT を用いた金コロイド粒子の定量

○上甲　拓巳，小沼　瑞稀，尾川　浩一
法政大学　理工学部　応用情報工学科

金コロイド粒子をリガンドとして利用し，さまざまな標識を行うことにより特定の細胞に集積させることが可能となる．一方で，金の元素は 80.7keV に k 吸収端があるので x 線の計測の際にエネルギーウィンドウを用いてエネルギースペクトルに関する情報を得ることで，金コロイドの定量を高い空間分解能で行えることになり，x 線 CT を機能イメージングのモダリティとして活用することが期待できる．本研究では，フォトンカウンティング型検出器を用い，得られた投影データに対して特異値分解法を使用し金コロイド粒子の量を定量する際の諸問題をシミュレーションによって検討した．具体的には，集積濃度と測定に用いる光子の数の関係などであり，モンテカルロ法を用いた光子の輸送計算から得られたエネルギースペクトルから検討した．この結果，光子数が少なくなると，金コロイドの定量結果に大きな影響を与えることが明らかとなった．

10:30 ～ 11:45　OP8「VR, AR」

座長：中口　俊哉（千葉大学）
目加田慶人（中京大学）

OP8-1　脳神経外科手術支援のための手術顕微鏡画像からの脳表の 3 次元形状復元に関する検討

○林　雄一郎[1]，柴田　睦実[2]，藤井　正純[3]，森　　健策[1]
[1]名古屋大学大学院情報学研究科，[2]名古屋大学大学院情報科学研究科，[3]福島県立医科大学脳神経外科

我々は脳神経外科手術において，MRI などの術前の 3 次元医用画像と術中の手術顕微鏡画像を融合することによる手術支援を検討している．本稿では 3 次元医用画像と手術顕微鏡画像を融合するために，手術顕微鏡画像から脳表の 3 次元形状の復元について検討を行ったので報告する．形状復元にはこれまで開発してきたステレオ内視鏡画像から臓器の 3 次元形状を復元する手法を用いる．この手法では，ステレオ画像間の特徴点の対応付けにより視差を求め，その視差を用いて臓器の 3 次元形状を復元する．脳の模型を撮影した手術顕微鏡画像から提案手法を用いて形状復元を行い，模型の 3 次元形状が復元できることを確認した．

OP8-2　スマートグラスを用いた整形外科手術ナビゲーションシステム

○西尾　祥一[1]，ホセイン モアゼム[1]，小橋　昌司[1]，平中　崇文[2]
[1]兵庫県立大学，[2]高槻病院

現在，整形外科手術は手術手技，使用器具の種類が豊富であるため，手術器械の受け渡しを行う器械出し看護師は大きな負担を強いられている．また，人工膝関節置換術において医師の骨切り等を補助するためのナビゲーションシステムは存在するが，看護師の器械出しを補助するためのシステムは確立されていない．そこで，本研究では，スマートグラスを用いて手術中に看護師に手技種類，手技進行度の理解や次に使用する器具の選定の補助を行うシステムの構築法を提案する．本手法では，まず，医師視点の手術映像より画像認識技術である畳み込みニューラルネットワーク (CNN) を用いて手技種類の推定を行う．得られた推定結果より器械出し看護師が装着しているスマートグラスに対して使用器具の選定を物体検出技術により，拡張現実 (AR) を用いて指示する．実験では人工膝関節置換術を対象として CNN を利用した手技認識モデル，手術器具検出モデルの構築を行った．

OP8-3　開腹下手術の術中ナビゲーションシステムの新しい機能の開発

○服部　麻木[1]，兼平　　卓[2]，岡本　友好[2]，二川　康郎[2]，恩田　真二[3]，安田　淳吾[3]，矢永　勝彦[3]，
鈴木　直樹[1]

[1]東京慈恵会医科大学高次元医用画像工学研究所，[2]東京慈恵会医科大学附属第三病院外科，[3]東京慈恵会医科大学消化器外科

われわれは肝胆膵領域の開腹下手術におけるナビゲーションシステムの開発と臨床応用を行なっており，本大会でも報告してきた．本システムは，ナビゲーション用の立体硬性鏡やタブレット型 PC の背面のカメラで撮影した術野画像上に，術前の X 線 CT から三次元再構築した臓器モデルを重畳して表示し，肉眼では見ることができない臓器内部の腫瘍や血管などの三次元的な位置を術者が直感的に把握できることを目的としている．これまでに数十例の臨床試験を行なってきたが，臓器の内部構造の提示だけでなく，さらに有効な情報を術者に提供できるよう，新しい機能の開発を開始した．本機能は，肝部分切除において腫瘍から任意に距離を設定したマージンの領域や術中に設定した切除面と，切除に用いる手術器具先端の距離を常にモニタリングし，設定した許容される距離を超えると音声などで警告を発するものである．開発した機能を臨床試験に適用した結果を報告する．

OP8-4　腹腔鏡下手術のための VR 手術再観察システムの開発

○鈴木　拓矢[1]，道満　恵介[1]，目加田慶人[1]，三澤　一成[2]，森　　健策[3]

[1]中京大学 工学部，[2]愛知県がんセンター，[3]名古屋大学 大学院情報学研究科

腹腔鏡下手術は，医師の視野が腹腔鏡映像に限定される環境下で血管・臓器の位置を把握し処置しなければならないため高難度である．近年の手術現場では，手術ナビゲーションシステムが利用されているが，ナビゲーションシステムに提示される事前に抽出した臓器に関する情報とその時点の腹腔鏡映像との対応づけをしなければならない．

そこで本研究では，血管・臓器の 3 次元的形状と患者の手術映像を位置合わせし，過去に行われた手術を再観察する教育システムを提案する．本システムでは，人体の 3 次元的な形状や位置関係の理解力を向上させるために VR ディスプレイである zSpace を用い，内視鏡映像と位置合わせされた血管・臓器を 3 次元的に観察可能である．

OP8-5　標準脳機能アトラスの投影による未来予測手術の具現化

○田村　　学[1,2]，丸山　隆志[2,1]，マンジャン ジャンフランソワ[3]，佐藤　生馬[4]，新田　雅之[2,1]，齋藤　太一[2]，
正宗　　賢[1]，川俣　貴一[2]，伊関　　洋[1]，村垣　善浩[1,2]

[1]東京女子医科大学　先端生命医科学研究所　先端工学外科学分野，[2]東京女子医科大学　脳神経外科，[3]生物医学画像研究所　ニューロスピン　コンピュータ支援画像部門，[4]公立はこだて未来大学　システム情報科学部　情報アーキテクチャ学科

The purpose of this study is to transform to the digitized intra-operative imaging and the compiled brain-function database for the future-predicting glioma surgery based on patient’s future perspective depending on the tumor resection rate as well as the post-operative complication rate.

Brain-function database was transformed to normalized brain digitized brain-mapping localization with the modified electric stimulus probe. This normalized brain with functional information, was projected to individual patient’s brain and predicted of brain function.

We successfully acquired log data with the location of medical device integrated into intra-operative MR image and digitized brain function was converted to a normalized brain data format in 17 cases with acceptable accuracy. For the electrical stimulation positions in which patients showed speech arrest (SA), speech impairment (SI), motor and sensory responses during cortical mapping processes, the data was tagged and testing task and electric current for the stimulus were recorded. There were 23 SA, 14 SI, 15 motor and 1 sensory responses (53 responses in total) including 17 cases. According to the evaluation of transformation accuracy for the 10 subjects, referring to each two neighbouring sulci on the electro-stimulator position, the first transformation from intra- to pre-operative MRI with non-rigid registration was calculated at 4.5 ± 1.0 mm, while the second transformation from pre-operative to normalized brain with SPM normalization was calculated at 5.8 ± 1.4 mm in average.

This image integration and transformation methods to carry out brain normalization should evaluate practical brain mapping in OR.

16:25 ～ 17:55

SY5「光断層イメージングの新しい展開」

座長：星　　詳子（浜松医科大学）

光イメージング技術は非侵襲で，生きている細胞や組織の中で生じている遺伝子やタンパク質などの分子レベルのプロセスの追跡を可能にした．しかし，これらの光技術の対象は，顕微鏡下で直進光を観察できる細胞や組織，皮膚，マウスなどの小動物に限られている．また，臨床応用が進んでいる光干渉断層法（OCT）も検出可能深度は数ミリメーターである．これは，主として生体内で光が強く散乱されることに起因しているが，ヒト生体深部のイメージングは，生体組織に対して比較的高い透過性を有する近赤外線を照射し，検出された散乱光から数理的処理により生体の機能・構造情報を抽出する拡散光トモグラフィー（DOT）や，光音響効果によって発生した超音波を検出する光音響トモグラフィー（PAT）などによって可能である．本シンポジウムではパルス光を光源とする time-domain DOT，定常光を光源とする CW-DOT，蛍光をイメージングする Fluorescence DOT，PAT を紹介し，これらの医用画像法としての展望について議論する．

SY5-1　タイムドメイン拡散光トモグラフィーの課題と展望

○星　　詳子
浜松医科大学

光と生体の相互作用は，吸収と散乱で，その程度は吸収･散乱係数によって表される．近赤外線は，ヘモグロビンや脂肪，水，タンパクなどの生体物質により吸収され，細胞膜や小器官など屈折率に違いがあるところで散乱される．従って，この波長領域の吸収係数は，他の医用画像法では検出できない生化学的・生理学的機能情報を持ち，散乱係数は生体組織の構造や細胞形態などの情報を持つ．拡散光トモグラフィー (DOT) は，生体のように濁った系で位置情報を失った散乱光を検出して吸収係数･散乱係数の分布を求める方法で，高度な数理科学技術に基づく生体内光伝播解析（順問題解析）と逆問題解析を必要とする．パルス光を用いる time-domain DOT は，計算負荷が高く計算処理の高速化は必要であるが，定量計測が可能で，革新的診断・治療（光による操作）・経過観察法として期待される．ここでは，DOT を概説し，開発のボトルネック課題とそれに対する取り組みと，今後の展望について述べる．

SY5-2　階層ベイズ拡散光トモグラフィによるタスク時と安静時の脳活動計測

○下川　丈明
ATR 脳情報解析研究所

拡散光トモグラフィー（DOT）は，近赤外分光法（NIRS）による非侵襲生体計測を発展させたイメージング法である．我々は，連続光 DOT による脳機能計測を対象として，階層ベイズ DOT (HB-DOT) 法を提案してきた． HB-DOT 法は，大脳皮質の活動を高い空間分解能で推定するだけでなく，NIRS 計測においてアーチファクト信号を引き起こす頭皮血流変化を同時推定することができる．我々はその有効性をタスク誘発脳活動の可視化において確かめてきた (O. Yamashita et al., NeuroImage 135 (2016) 287-299)．現在，我々は安静時の脳活動計測における HB-DOT 法の有効性を調べている．DOT から得られた領野間の機能的結合行列と fMRI から得られた機能的結合行列とを比較することによってその性能を評価した結果について紹介する．

SY5-3　組織深部拡散蛍光トモグラフィー：時間領域からのアプローチ

○西村　吾朗
北海道大学　電子科学研究所

光学的手法の中で蛍光法は最も感度の高いものとされているが，深さ数ミリより深い生体組織内の蛍光を観測しイメージングするのは極めて難しい．これは組織による強い光散乱と吸収，さらに非特異的な背景光が蛍光の観測を妨げるためである．これらに対し，散乱体の中での蛍光の伝搬をモデル化し，その逆問題を解くことにより３次元の画像を得る手法を拡散蛍光トモグラフィーと呼ぶ．本講演では，パルス光を用い蛍光を時間領域から計測し，時間応答より蛍光画像を３次元再構成する手法を解説するとともに，今後を展望する．

SY5-4　光音響トモグラフィーと定量的画像再構成

○大川　晋平，平沢　　壮，辻田　和宏，櫛引　俊宏，石原　美弥
防衛医科大学校

医学・生物学分野において光音響トモグラフィーが広く研究されている．ヘモグロビン等の生体内色素が光を吸収した際に熱膨張することで光音響波が発生する．この光音響波を超音波トランスデューサで測定し，色素分布を比較的高い空間分解能で画像化することができる．ヘモグロビンに吸収されやすい近赤外光を用いることで生体深部の血管をイメージングすることができるため，末梢血管に症状が現れる糖尿病や，血管新生を伴うがんの診断に役立つことが期待されている．光音響トモグラフィーの原理と医学・生物学研究への応用事例を概観し，生体内の光と光音響波伝播の物理現象に基づいて色素濃度分布を定量的に画像化することを目指す定量的光音響トモグラフィーについての研究事例を紹介する．

9:00 ～ 10:15　**OP6「CAD」**

座長：木戸　尚治（山口大学）
　　金　　亨燮（九州工業大学）

OP6-1　肝臓がん検出器のための 3D-DCGAN を用いた学習用画像生成法

○池田　裕亮[1]，小西　孝明[1]，道満　恵介[1]，縄野　　繁[2]，目加田慶人[1]
[1]中京大学工学部，[2]国際医療福祉大学三田病院

肝がんの読影は医師の目視で行われており，医師の負担軽減のため機械学習による読影支援が望まれる．しかし，機械学習に使用する多くの症例画像を集めるのは困難である．そのため，健常症例に病変を埋め込む症例画像生成がおこなわれている．実病変画像を学習データとして用いた 3D-DCGAN による人工病変画像生成では学習データの不足によりうまく学習することはできなかった．

本研究では別手法で生成した 3 次元的な人工病変画像と実病変画像を学習データとして用いた 3D-DCGAN による画像生成法を提案する．学習に用いた人工病変画像は健常症例に対し病変をポアソンブレンディング法とシグモイド関数を用いた方法の 2 種類で埋め込み生成した．学習データとして使用する人工病変画像の枚数や種類を変えながら 3D-DCGAN により人工病変画像を生成した．

OP6-2　多時相造影 CT 画像を用いた腎臓解析

○松下　和樹[1]，鈴木　秀宣[2]，河田　佳樹[2]，仁木　　登[2]，飯沼　　元[3]
[1]徳島大学大学院 先端技術科学教育部，[2]徳島大学大学院 社会産業理工学研究部，[3]国立がん研究センター中央病院放射線診断部

次世代の画像診断に向けて疾患の極初期段階を診断することは極めて重要で興味深い問題である．腎臓の正常形態，極早期の疾患形態の画像化とその定量的な形態解析の実現は質の高い画像診断への貢献が期待される．本報告では多時相 (動脈相・門脈相・平衡相) マルチスライス造影 CT 画像を用いて，腎臓を三次元形態で抽出し，造影剤の循環動態を解析することで腎機能を定量化し医師に有益な情報が提供することを目指す．本手法は (1) 多時相造影 CT 画像より腎臓の抽出 (2) 抽出した腎臓を腎皮質と腎錐体，尿管に分類 (3) 多時相による腎臓内の血管，腎皮質，腎錐体，尿管の CT 値の遷移調査，からなる．(1) 多時相において造影 CT 画像より腎臓を半自動で抽出する．(2) 抽出した腎臓を閾値処理を用いて腎皮質と腎錐体，尿管に分類する．(3) 腎臓内の血管と腎皮質，腎錐体，尿管それぞれの多時相における CT 値遷移を解析することで腎臓内の造影剤の循環動態を明らかにする．

OP6-3　ResNet を用いた指骨 CR 画像からの骨粗しょう症の自動識別

○畠野　和裕[1]，植村　知規[1]，村上　誠一[2]，陸　　慧敏[1]，タン ジュークイ[1]，金　　亨燮[1]，
青木　隆敏[2]
[1]九州工業大学，[2]産業医科大学病院

骨の主な疾患として骨粗しょう症が挙げられる．骨粗しょう症に対する画像診断は有効であるが，類似した低骨量を呈する画像も多く，画像診断における客観性や再現性に問題がある．そこで本稿では，指骨 Computed Radiography (CR) 画像から骨粗しょう症の自動識別を行うための画像診断支援法を提案する．提案手法では，深層畳み込みニューラルネットワークを用いた識別器を構築し，骨粗しょう症有無の識別を行う．実験では，101 症例に対し提案手法を適用し，ROC（Receiver Operating Characteristic）曲線上の AUC（Area Under the Curve）を用いて評価したところ，0.93 という結果を得た．

OP6-4　CT 画像を用いた上腕骨頭３次元統計的形状モデルによる人工肩関節設計

○久保　有輝[1]，井城　一輝[1]，盛田　健人[1]，新居　　学[1]，無藤　智之[2]，田中　　洋[2]，乾　　浩明[2]，
小橋　昌司[1]，信原　克哉[2]
[1]兵庫県立大学，[2]信原病院

現在用いられている多くの人工肩関節の骨頭部分は球または楕円に近似して設計されている．しかし，同形状は実際の上腕骨頭形状を十分に表現しているとは言い難い．また，２次元 X 線写真による形状解析が行われているが，３次元的な形状解析はほとんど行われていない．そこで本研究では，人工肩関節設計の目安と成り得る３次元形状を把握するため，上腕骨の３次元統計的モデル作成法を示す．本手法では，まず肩関節 CT 画像から上腕骨領域を抽出する．次に抽出領域から上腕骨形状に基づく座標系を決定する．求めた座標系を基準に位置姿勢を校正し，主成分分析によって上腕骨頭の３次元統計的形状モデルを取得する．実験では被験者８例から上腕骨頭３次元統計的形状モデルを構築することで，本手法による上腕骨頭形状の個人間変動の統計的モデル化法を確立するとともに，統計的形状モデルによる個人の生体肩形状に類似した人工肩関節モデル設計の可能性を示した．

OP6-5　符号化欠損領域情報の自動検出を想定した腹腔鏡画像の色情報解析と医用画像診断に関する考察

○河畑　則文[1]，中口　俊哉[2]
[1]名古屋大学未来社会創造機構，[2]千葉大学フロンティア医工学センター

筆者らは，今までに腹腔鏡画像の医用画像診断に関して，PSNR を用いて符号化画質の観点から応用可能かと検討した．しかし，カラー画像では，色情報の影響が十分に PSNR に反映されていないことがあり，PSNR のみで符号化画質を判断するのは難しいという結論に至った．それゆえに，従来の PSNR による評価に加えて，色情報やデータマイニングを用いて複数の画像特徴を考慮していくことが必要である．医用画像における符号化欠損や劣化は，各々特性や性質，使用状況が異なるため，最終的に，コンピュータによる自動診断システムを構築する必要がある．本論文では，内視鏡で撮影された腹腔鏡画像において，符号化欠損領域情報を付加し，視覚の空間周波数特性を考慮している S-CIELAB 色空間を用いて，色情報の解析と PSNR とのデータマイニング（サポートベクターマシンによる分類）を行い，医用画像診断に応用可能であるか，そして，符号化欠損領域情報の自動検出を想定した考察を行った．

10:30 ～ 11:45　OP9「治療支援」

座長：有村　秀孝（九州大学）
大竹　義人（奈良先端科学技術大学院大学）

OP9-1　股関節鏡シミュレータにおける視認性に基づくポータル位置と刺入方向の評価：１５症例による検証

○川上申之介[1]，福田　紀生[1]，西井　　孝[2]，大竹　義人[1]，佐藤　嘉伸[1]
[1]奈良先端科学技術大学院大学 情報科学研究科，[2]大阪急性期・総合医療センター整形外科

Arthroscopic labral repair relies on the field of view obtained by the arthroscope inserted through a few millimeter skin incision called a portal. The field of view of the arthroscope is different depending on the position of the portal and the insertion angle therefrom. A typical portal position is geometrically determined as the landmark of the anterior superior iliac spine and the greater trochanter of each patient. However it is not necessarily appropriate portal that the insertion of the arthroscope from that position will give the best view. We performed automated visibility measurement using a preoperative 3D surface models constructed from 15 patient-specific computed tomography data using the hip arthroscope simulator currently under development. Test insertion is performed by changing the insertion angle from 25 portal positions when representative portal positions are shifted by 5 millimeters on the skin surface. The target position for the arthroscope is set to 25 positions near centers of the femoral head and fitted sphere to the acetabular rim. We calculated automatically the rate of the labral tears to be captured within a field of view of a camera to the total captured pictures. As a result, we were able to estimate the portal position that can obtain visibility higher than the typical portal position and the insertion direction. Particular o’ clock position of the labral tears especially captured on the arthroscope inserted from each shifted portal positions are also shown. We verified the validity of the cost function by a reasonable and reproducible result of such greedy search. From now on, we will speed up this search and plan to efficiently search for a wider range using some optimization algorithm.

OP9-2　取り下げ

OP9-3　X 線画像を用いた経気管支診断支援向け処置具 3 次元位置マッピング法の基礎検討

○松崎　和喜[1]，馬場　理香[1]，山川　恵介[1]，飯村　隆志[2]，松元　祐司[3]，中井　俊之[3]，北川まゆみ[4]，麻生　智彦[4]

[1]日立製作所 研究開発グループ，[2]日立製作所 ヘルスケアビジネスユニット，[3]国立がん研究センター中央病院内視鏡科，[4]国立がん研究センター中央病院放射線技術部

X 線装置は末梢肺病変に対する経気管支鏡診断において，腫瘍細胞を採取する処置具位置を確認する目的で利用されている．X 線画像は処置具をリアルタイムに認識可能だが，2 次元投影像のため病変の前後方向の位置把握が困難な場合がある．本研究では X 線装置を用いた経気管支鏡診断支援を目指し，処置具の 3 次元位置を明瞭にする 3D 位置マッピング技術を提案し，要素技術を開発した．提案技術の基本原理は，複数方向の X 線画像と診断用に事前撮影した CT 画像を用い，術中の患者に対して位置決めを実施，処置具の 3 次元位置を認識し，CT 画像上にその 3 次元位置を表示する．患者位置決めは，2 次元画像（X 線画像）と 3 次元画像（CT 画像）による画像レジストレーション法を用い，GPU による高速化を図った．また処置具の位置認識には，パターンマッチング法を用いて自動化した．本報告では，主に人体ファントムを用いて提案手法の実現可能性を検討した．

OP9-4　前立腺癌放射線治療におけるベイズ領域推定法のための解剖学的特徴点に基づいた前立腺位置推定法

○二宮　健太[1]，有村　秀孝[2]，笹原　基希[1]，廣瀬　貴章[1,3]，大賀　才路[4]

[1]九州大学大学院　医学系学府保健学専攻，[2]九州大学大学院　医学研究院保健学部門，[3]九州大学病院　医療技術部，[4]九州大学大学院　医学研究院臨床放射線科学

We aimed to develop a prostate localization method based on anatomical feature (AF) points in a Bayesian delineation framework (BDF) for prostate cancer radiotherapy. Prostate locations were estimated by using a random forest from five AF points, which were manually selected on prostates, bladder and rectums in sagittal planes of planning computed tomography images. The proposed method was applied for placing probabilistic atlas to extract prostate regions in BDF. Centroids of prostate regions determined by radiation oncologists were employed as reference prostate locations. The average location estimation error of prostates and Dice's similarity coefficient between the reference and extracted prostate regions were 2.4 ± 1.3 mm and 0.80 ± 0.070 for 44 test cases, respectively.

OP9-5　画像誘導放射線治療のリアルタイム腫瘍追跡における患者個別深層学習を実現する非線形データ拡張方法

○照沼　利之[1]，友田　光一[3]，榮　　武二[1,2]，大西かよ子[1,2]，奥村　敏之[1,2]，櫻井　英幸[1,2]

[1]筑波大学医学医療系，[2]筑波大学附属病院陽子線医学利用研究センター，[3]筑波大学大学院人間総合科学研究科

放射線治療時に呼吸性移動臓器の腫瘍を追跡することが求められており X 線透視による画像処理法が研究されている．X 線透視のエネルギー領域では光電効果が支配的であり比較的高原子番号から組成される骨構造が強調される．従って投影された骨構造に影響されない腫瘍追跡を実現する画像処理方法が求められていた．我々は，教師あり学習による画像セグメンテーション法のために，特定患者の CT 情報のみから非線形な訓練用画像を大量生成する方法を考案した (Terunuma, et al., Radiol Phys Technol (2018) 11: 43)．このデータ拡張方法は，訓練画像と教師画像間の共起確率を利用して，腫瘍追跡にとって重要な情報は腫瘍を含む軟組織特徴であり，追跡に不要な情報は骨構造特徴であるという異なる重要度認識を誘導することを目的としている．本発表では，考案した非線形なデータ拡張方法のメリット・デメリットを考察し，実臨床 X 線透視画像を使用した追跡結果について紹介する．

9:00 ～ 10:15

OP10「CAD」

座長：内山　良一（熊本大学）
木村　裕一（近畿大学）

OP10-1　深層学習による単純ＣＴにおける急性期脳梗塞の自動検出

○高橋　規之[1]，木下　俊文[1]，大村　知己[1]，松原　佳亮[1]，李　　鎔範[2]，豊嶋　英仁[1]
[1]秋田県立脳血管研究センター，[2]新潟大学大学院保健学研究科

近年，急性期脳梗塞に対する血栓回収療法が行われるようになり，発症早期に画像診断で虚血変化を捉えることが重要になってきた．しかし，CT 画像では早期虚血変化を同定することは難しい．そこで，本研究では深層学習を用いた単純 CT における急性期脳梗塞の早期虚血変化の自動検出法を提案する．脳 CT 画像をアトラスに変換した後，左右脳実質に関心領域を設定し対象領域のみを抽出する．最後に，抽出された左右領域を一対として入力画像に貼り付け学習した．本研究ではレンズ核と島を対象領域とした．レンズ核に早期虚血変化を認めた 50 例と島に認めた 51 例，さらに正常 28 例を加えて CNN を学習した．その結果，レンズ核と島領域に対する検出感度はそれぞれ 100％と 90.2％，特異度は 89.3％と 92.9％，正診率は 96.2％と 91.1％であった．このことから提案手法の有用性が示された．

OP10-2　Capsule network を用いた磁化率強調像の教師あり学習による脳循環代謝異常の予測の試み

○松原　佳亮[1]，高橋　規之[1]，梅津　篤司[2]，茨木　正信[1]，木下　俊文[1]
[1]秋田県立脳血管研究センター放射線医学研究部，[2]東北大学病院放射線診療科

近年 Geoffrey Hinton により提案された Capsule network (CapsNet) は画像上のオブジェクトの空間情報を保持したまま学習が可能であり，膨大な学習データを必要としないため，医用画像診断における応用が期待できる．本研究では CapsNet を用いて磁化率強調像 (SWI) を学習し，脳虚血に伴う酸素摂取率 (OEF) 亢進の予測を試みた．片側性脳血管狭窄閉塞症の患者 (n=145) の SWI から抽出した 108 x 108 voxels の領域を入力，中大脳動脈支配領域における OEF の患側 / 健側比が 1.05 以上かどうかを教師とし，CapsNet による教師あり学習を実施した．その結果，78.7 ± 1.9% の正答率で OEF 亢進を予測できた．CapsNet により OEF 亢進がある程度予測できることが示されたが，精度向上のために学習の更なる工夫が必要とされる．

OP10-3　脳 MRI 画像類似症例検索のための 3 次元畳み込みオートエンコーダによる次元削減

○新井　颯人[1]，茶山　祐亮[1]，彌冨　　仁[1]，大石　健一[2]
[1]法政大学，[2]ジョンズ・ホプキンズ大学

医療分野において，視覚的あるいは病気特有の特徴による類似症例検索技術は診断支援などの目的で需要の高い技術である．しかし患者個体差あるいは撮影環境の差による影響は疾病に依存して発生する特異的な特徴よりも大きく実現が難しい．

こうした背景から画像処理と機械学習を用いた効果的な検索技術の構築が期待されるが，MRI などの高次元なモダリティを扱うシステム構築のためには次元圧縮が必須である．そこで，本研究では 3 次元脳 MRI 画像に対する類似症例検索システム実現のため大規模な次元圧縮技術を提案する．提案手法は画像の位置合わせと 3 次元深層畳み込みオートエンコーダから構成される．本手法は神経科医が診断時に注目する領域を保持したまま 500 万次元からなる入力を 150 次元にまで圧縮し 1 ボクセルあたりの RMSE 約 8％を実現した．本研究では，圧縮された各次元が元の入力のどの領域に寄与するかの可視化を行い更なる利便性向上の可能性を確認した．

OP10-4　MRI における脳転移検出に対する Convolutional Neural Network の応用：線量分布を正解データとして利用

○村田　仁樹[1]，花岡　昇平[2]，野村　行弘[1]，竹永　智美[1]，中尾　貴祐[3]，高橋　　涉[2]，名和　要武[2]，吉川　健啓[1]，林　　直人[1]，阿部　　修[2,3]

[1]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，[2]東京大学医学部附属病院　放射線科，[3]東京大学大学院医学系研究科　生体物理医学専攻

Recently, computer-assisted detection (CAD) for disease attracts a lot of medical researchers as well as technologists and physicists. Most of state-of-the-art CAD utilizes convolutional neural network (CNN). The purpose of this study is to apply CNN for detecting brain metastases in MRI. In contrast to the standard CAD, where the ground truth is prepared by medical experts, we used radiation dose profile to define the ground truth of brain metastases.

348 contrast-enhanced brain MR images including 993 brain metastases were used in this study. The MR images were acquired for the treatment planning of Gamma Knife by 1.5-Tesla MR scanners (Siemens Magnetom Vision, GE Signa HDx/HDxt) with a T1-weighted 3D gradient echo sequence. We normalized the MR images to the three-dimensional isotropic images with 1.88 mm of voxel size. The ground truth of brain metastases was defined by the region where the radiation dose is greater than 20 Gy. Our CNN performs a voxel-wise classification, to judge whether the reference voxel belongs to metastases or normal tissues. The input of CNN is 15^3 cube volume of interest, whose central voxel is the reference voxel to be judged. For the computation, we used a supercomputer system (Reedbush-H) with NVIDIA Tesla P100 and with Python 2.7.5 and Keras 2.0.5 installed.

Among 348 cases, 214 cases were used for training CNN, while the remaining cases were equally assigned to validation and test sets. Through random search with respect to hyper parameters of CNN, including the number of convolutional layers and filter numbers, we obtained sensitivity 0.70 with 8.4 FPs/case for the test set. This result suggests that radiation dose profile have the potential to develop CAD system with CNN.

OP10-5　ＳＶＭを用いた嚥下時Ｘ線サジタル透視動画における舌骨の追跡

○八板　駿平[1]，滝沢　穂高[2]，目片幸二郎[1,3]，工藤　博幸[2]

[1]筑波大学大学院システム情報工学研究科コンピュータサイエンス専攻，[2]筑波大学システム情報系，[3]神戸赤十字病院

嚥下時 X 線サジタル透視動画 (Videofluorography, VF) における嚥下フェーズは舌骨の位置および運動方向によって同定される．本報告では SVM を用いて舌骨を自動追跡する手法を提案する．まず VF の各フレームに，判別分析法とモルフォロジ演算，RANSAC を適用し，舌骨の可動領域を求める．その可動領域にパッチベースの SVM を適用し，舌骨の候補領域を抽出する．一般に，舌骨候補領域は各フレームで複数抽出されるので，時間軸方向に候補領域を連結した経路パターンも複数存在する．しかし，舌骨を含む候補領域は他の候補領域よりも面積が大きくなる傾向があるため，経路パターンの体積は舌骨を含む回数が多いほど大きくなりやすい．本手法では，体積最大のパターンを選択し，そのパターンに属する候補領域を舌骨とする．実動画像に適用した結果を示す．

10:30 ～ 12:00　SY2「ディープラーニング：基礎理論から応用へ」

座長：庄野　　逸（電気通信大学）

深層学習（ディープラーニング）は，画像処理，音声処理，言語処理といった分野を中心に現在の人工知能技術を支える要素技術の地位を確立しつつある．その応用範囲は識別，検出といったセンサ情報を集約する情報処理課題に留まらず，セグメンテーション，データ生成と言った能動的に情報を推定するような情報処理課題にも拡大しつつある．本シンポジウムでは，このディープラーニングに関して，基本的な部分に焦点をあて，基礎理論から生成モデルなどに至るまでの話題と現在の研究動向などを提供することを目的としている．講演者には，第一線で活躍している新進気鋭の若手に依頼を行っており，基本的な部分からの視点で，今後の技術発展の展望などを講演していただく予定である．ディープラーニングの実装を始めた初学者の方，どう発展させて良いか悩んでおられる方等が，本講演で新たな視点を発見していただければ幸いである．

SY2-1　深層学習の基礎理論と発展

○園田　　翔

早稲田大学先進理工学部

画像処理をはじめとする多くの応用分野で，深層学習の活躍が目覚ましい．特に近年では，画像認識のような認識タスクだけでなく，画像生成のような生成タスクにまで活躍の幅を広げている．1990 年代の理論によれば，ニューラルネットは「深層」でなくとも任意の関数を実現できることが分かっている．（この性質は，医用画像に携わる人々にとって馴染み深い，Fourier 変換や Radon 変換の理論を援用して証明される．）また，一般に深層構造の学習は困難であることも知られている．それでは，なぜ深層にするのか．本講演では，従来理論との違いに触れつつ，深層学習について最近の理論を紹介する．はじめに，浅いニューラルネットの動作原理を簡単に説明する．次に，深層ニューラルネットの理論を紹介する．最後に，工学応用にあたって目指すべき方向性について述べる．

SY2-2　統計的機械学習

○安田　宗樹
山形大学大学院理工学研究科

本講演では，まず，グラフィカルモデルの一種であるマルコフ確率場（ＭＲＦ）に焦点を当てる．ＭＲＦは画像処理分野を含む様々な分野で広く利用されている統計モデルである．ＭＲＦは，統計的機械学習の手法により，データ分布をもっとも再現する形に最適化されるため，(データの)生成モデルと呼ばれることがある．ＭＲＦを利用した画像処理の一般的な枠組みでは，ＭＲＦを事前分布としたベイズ推定を通して，画像処理（例えば，ノイズ除去やセグメンテーションなど）行う．本講演では，マルコフ確率場の基礎から出発して，統計的機械学習，ベイズ推定までの流れを概説する．次に，統計的機械学習と深層学習との架け橋的モデルである，(確率的オートエンコーダとして解釈することができる）制限ボルツマンマシンについて解説する．時間が許せば，統計的機械学習と深層学習に関する最新の研究成果についても紹介したい．

SY2-3　Generative Adversarial Networks の基礎と応用

○金子　卓弘
NTT コミュニケーション科学基礎研究所

「高精細な画像が必要になったときに，データベースから探し出すのではなく新規に作り出したい．」「テキストだけから思い描く画像を生成できるようにしたい．」「顔画像を理想の芸能人のような髪型・表情に変換したい．」このように，画像を新規に生成・変換したいという場面は様々なケースで考えられるが，これらを実現するためには，画像のような複雑なデータを忠実に再現・表現できるようなモデルを構築することが必要になる．この問題を解く鍵となる技術として生成モデルの研究が古くから活発に行われているが，解くのは容易ではなく様々な課題が残されていた．ところが，近年，生成モデルが，発展著しい深層学習と組み合わさることによって大きなブレイクスルーが起きている．本講演では，これら深層生成モデルのうち代表的なものの一つである Generative Adversarial Networks (GAN) を取り上げ，基礎から応用まで幅広く説明する．GAN は非常に高いポテンシャルを持ったモデルであり，GAN によって初めてできるようになったタスク，高精度化に成功したタスクは数多く存在する．これらを幅広く紹介することで，聴衆の皆様の研究・開発のヒントになるような情報を少しでも提供できれば幸いである．

13:30 ～ 15:00　SY3「ＡＩ画像処理の応用事例と人工知能デモクラシーについて」

座長：中田　典生（東京慈恵会医科大学）

SY3-1　大腸内視鏡画像に AI 画像処理を応用したリアルタイム内視鏡画像診断支援システムの開発

○山田　真善[1]，斎藤　　豊[2]，上條　憲一[3]，今岡　　仁[4]，髙橋　郁磨[3]，近藤　裕子[5]，山田　滋美[5]，浜本　隆二[5]

[1]国立がん研究センター中央病院　内視鏡科／国立がん研究センター研究所 がん分子修飾制御学分野，[2]国立がん研究センター中央病院　内視鏡科，[3]日本電気株式会社　未来都市づくり推進本部，[4]日本電気株式会社　バイオメトリクス研究所，[5]国立がん研究センター研究所 がん分子修飾制御学分野

【目的】大腸内視鏡検査中に自動的に大腸前がん病変および早期大腸癌の特徴をリアルタイムで検出する AI システムの開発研究を目的とし，国立がん研究センターと日本電気株式会社（NEC）が共同でプロトタイプを開発した．
【方法】深層学習のアルゴリズムを用い，約 5000 病変の内視鏡画像を教師あり学習させた．このシステムは，AI が内視鏡装置から得られる動画像を網羅的に解析し大腸前がん病変および早期大腸癌の異常を検出し，リアルタイムに内視鏡医に知らせることで病変の発見を支援する．
【成績】AI は 4840 枚の評価セットを 106.0 秒で解析した（21.9 ミリ秒 / 枚）．その隆起型病変検知に対する感度と特異度はそれぞれ 98％と 99％であった．この評価セットの一部を用い内視鏡医 12 名で読影試験を行った結果，人間の感度と特異度の中央値はそれぞれ 87% と 96% であった．
【結論】本 AI システムが大腸内視鏡検査中に内視鏡医の病変発見をリアルタイムに支援する可能性が示唆された．

SY3-2　人工知能による画像診断システムの高度化

○宮崎　靖
株式会社 日立製作所　ヘルスケアビジネスユニット

医療分野への人工知能活用に関しては，再入院リスク予測，難病診断支援，投薬支援など様々な取り組みが行われている．一方，リスクに応じた規制が行われている医療機器においても，早期実用化が期待されている画像診断支援分野での実運用に向けて動き出しており，米国では深層学習を利用したシステムが認可され，国内でも早期上市に向けた評価指標や開発ガイドラインの整備が進められている．当社では画像診断（DI）に人工知能（AI）を活用した「DI x AI ソリューション」の早期実用化をめざしており，いわゆる診断支援（CAD）だけでなく，撮像支援や画像再構成（イメージング）の領域も含め検査全体の効率化・高度化のため開発を進めている．本講演では，我々がめざしている人工知能を活用した画像診断システムの高度化の事例紹介，およびブラックボックス化や良質の教師データの整備などの課題に対する取り組みについて紹介する．

SY3-3　医療画像特に脳動脈瘤検出における人工知能活用について

○緒方　剛
エルピクセル株式会社

昨今内視鏡診断や放射線科領域，病理領域の画像診断において人工知能，特に深層学習の活用が活発になり，この領域に於いて世界各国，特に米国や中国において多くのベンチャー企業などが挑戦し，既に米国では医療機器として許可が下りるなど研究の段階から製品化へ臨床実用の段階に来ている．医療画像診断における人工知能技術の応用は，画像診断装置の技術的発展，画像診断検査の増加による医療画像の増大に伴う放射線科医の負担増・不足を解決する手段として期待されている．本講演では日本発の医療画像での人工知能活用の応用事例，特に脳動脈瘤検出技術を例に現状を紹介し，臨床においての有効性・今後の課題について，実際の臨床現場での試用経験，フィードバックと合わせて紹介する．

SY3-4　Democratizing AI in Radiology（放射線科における人工知能デモクラシーについて）

○ George Shih
MD.ai.Inc.（Department of Radiology, Cornell University）

医療以外の AI では，Democratizing AI（人工知能デモクラシー）が提唱されるようになった．人工知能デモクラシーは，だれでも AI を使えるようにするだけはなく，だれでも，やる気さえあれば，AI 開発に従事できる環境を提供することである．これは近い将来 AI や ICT の進歩により無くなっていく職業がある一方で，AI 開発という新しい職業（雇用）の場を作ることを意味する．現在，AI を活用した医用画像の診断支援における課題は教師学習用データの作成である．近年この問題を解決するため，公的な教師学習用データ（Public Datasets）の公開が行われるようになった．今回はこの公的に公開されている数万枚から十数万枚程度の医用画像を使ってアノテーションやラベリングを可能とするクラウドソーシングサービス MD.ai（https://www.md.ai/）の使用方法を動画にて解説して，その実用性を検証する．

15:15 ～ 16:45

SY4「医用画像を活用した 3D バーチャル手術：ソフト開発から、臨床評価、医学教育までとこれからの未来」

座長：北坂　孝幸（愛知工業大学）

医用画像を活用したコンピュータ外科をはじめとする ICT 技術の医療への応用は，外科，内科，放射線科などの幅広い診断，治療になくてはならないものになっている．いまや医療技術は，画像処理，新規計測法，機械学習，深層学習，制御工学，ロボティクスなどの異種の刺激と融合により高度で多彩な変化を遂げている．医学教育では，実際の患者を対象にしたトレーニングから，人体構造と機能を模したシミュレータやバーチャル教材でトレーニングを行うシミュレーション教育の重要性が高まっている．

本シンポジウムでは，「つくば」だからこそ集結可能な多様な分野の専門家たちで構成されたリサーチユニットのこれまでの活動成果についての講演と，これからの医療技術や医学教育の開拓，未来について，それぞれ医学，システム情報，企業の専門の立ち位置をつないで発展的シナリオを創造していく．

SY4-I-1　医工連携によるバーチャル手術の取り組みとこれからの未来

○大城　幸雄
筑波大学医学医療系消化器外科

われわれは，IT 技術と臨床外科の融和によるコンピュータ外科を活用して，外科手術支援技術とそこから派生する新たな外科教育システムの開発を行っている．手術シミュレーションには医用画像を高度に解析し，臨床に有用な機能を様々に肉付けすることが必要であり，医工連携によってしかなしえない．その後，シミュレーションからナビゲーションへと向かうのは自然な流れであり現在研究開発を進めている．外科手術支援から派生する教育への効果はとても大きく，連携するそれぞれの研究室の独自の技術を生かしたアイディア，成果が多く生まれた．わが国ではアカデミア発の研究から実用化，事業化することは簡単ではないが，われわれの研究グループから生まれたことは大きな成果であったと自負している．

SY4-I-2　３Ｄバーチャル手術のための医用画像セグメンテーション

○滝沢　穂高
筑波大学システム情報系

本講演では，本プロジェクトにて開発を進めてきた，腹部ＣＴ画像から臓器を抽出するためのＧＵＩシステムとその要素技術について報告する．ＧＵＩシステムは医師と相談しながら開発を進め，画像の見易さや操作性に工夫を加えた．要素技術としては，計算解剖モデル（統計形状モデル，確率アトラス）に基づく臓器抽出手法，対話的グラフカットに基づく臓器抽出法，より容易なインプリメントでグラフカットと同等の性能が実現できる脱グラフカット手法を開発した．これらの手法を腹部ＣＴ画像に適用した結果を示すとともに，３Ｄバーチャル手術への応用について議論する．

SY4-I-3　フルハイビジョン裸眼立体表示の医療応用

○掛谷　英紀
筑波大学システム情報系

これまでの裸眼立体ディスプレイは解像度が低い，立体視ができる視域が狭いなどの理由で，実用的に使われることがほとんどなかった．講演者は最近，広い視域とフルハイビジョンの解像度をあわせもつ２種類の裸眼立体ディスプレイを開発した．一つは時分割指向性バックライト方式，もう一つは時分割パララックスバリア方式である．講演では，それら裸眼立体表示方式の原理について述べるとともに，肝臓手術シミュレータや腹腔鏡手術トレーニングシステムなど，医療用途における開発した裸眼立体ディスプレイの試験的利用の事例について報告する．

SY4-I-4　Hepatic Cockpit

○矢野　博明
筑波大学システム情報系

我々は，医学生や研修医のための肝臓手術手技学習用シミュレータ Hepatic Cockpit を筑波大学消化器外科と共同で開発を進めている．Hepatic Cockpit のユーザは肝臓手術シミュレータソフトウエア Liversim 内で定義されたバーチャルな肝臓を自身の自由な視点位置から観察することができ，肝臓右葉を素手で把持・操作し，超音波メスのモックアップを使って任意の部位について３次元的な切除動作を繰り返し練習することが可能である．裸眼立体視ディスプレイによる視点移動に対応したクロストークの少ない立体視，肝臓操作時の肝臓の硬さ分布表現や変形操作に伴うバーチャルな肝臓の復元力，超音波メスが肝臓に接触した際の反力提示，切離時の振動提示などの体性感覚フィードバックを備えていることが特徴である．本講演では Hepatic Cockpit のこれまでの変遷と今後の課題について紹介する．

SY4-I-5　先端医療技術とタッチレスインターフェイス

○坂本　堪亮
株式会社ネクステッジテクノロジー

弊社の開発したタッチレスインターフェイス技術が，医療に役立つのでないかと考えていた中，2014 年以来，筑波大学の医工学連携 CREIL（現在の T-CreDo）を介して，医学医療系消化器外科の 3D-CG バーチャル手術シミュレーションユニットをご紹介頂き，今日に至っております．現場での利用と改良を経て，外科手術室でのコンピュータ操作のタッチレス操作を実現しました．現在は，弊社の 3D センサーを使った，手術ナビゲーションシステムの共同開発に至っています．つくばの一企業である弊社がどのように筑波大大学病院と関わってきたかについて紹介いたします．

SY4-II　総合討論

9:00 ～ 10:15

OP11「イメージング，シミュレーション」

座長：大西　　峻（千葉大学）
湯浅　哲也（山形大学）

OP11-1　非局所トータルバリエーションを用いたスパースビュー CT 画像再構成の画質改善

○金　　鎔采 [1]，工藤　博幸 [2]
[1]筑波大学システム情報工学研究科コンピュータサイエンス専攻，[2]筑波大学システム情報系情報工学域

スパースビュー CT の画像再構成において，非局所トータルバリエーション（TV）を用いた手法は TV 項に付加する重みを適切に計算することで，通常の TV と比較して滑らかな濃度変化やテクスチャーを保存しやすく，画質性能に優れる．本研究では，非局所 TV の画質性能を更に向上させるため以下の考え方に基づく改良手法を提案する．画像再構成反復計算の各反復回数で，最新の再構成画像からストリークアーティファクトが強く発生している画素を同定して，非局所 TV 項の重みを計算する際にアーティファクト画素に通常より大きい重みを割り当てて強く平滑化を行う．キーになるアーティファクト画素の同定は，データ項のみによる更新画像と平滑化項のみによる更新画像の差の絶対値を画素毎に計算してその大小で決定する．本手法は様々な反復法と組み合わせ可能な一般性を持つが，著者らが用いている近接スプリッティングに基づく Row-Action 型画像再構成法に組み込んで医療用 CT 実画像を用いたシミュレーション実験を行った結果，特に少ない反復回数における顕著な画質改善（ストリークアーティファクトの低減）が実現できることが明らかになった．

OP11-2　深層学習による放射型 CT の画像補正

○鈴木　朋浩，工藤　博幸
筑波大学システム情報工学研究科

PET/SPECT 等の ECT の画像再構成では，吸収補正が必要であり統計雑音が多いため主として逐次近似再構成法が用いられるが，計算時間が長い問題がある．また，近年は CT/MRI 画像を利用した補正が流行しているが，比較的複雑な処理が必要となる．本研究では，フィルタ補正逆投影（FBP）法で得た，雑音が多く吸収補正されていない PET/SPECT 画像に対し，畳み込みニューラルネットワーク（CNN）を用い吸収補正とデノイジングを同時に行う手法を検討した．CNN の学習データとして，元放射能分布画像と元吸収分布画像からシミュレーションにより作成した ECT 投影データの FBP 再構成画像を用いた．また，その際に FBP 再構成画像に加えて CT 画像（マルチモダリティ画像）を入力チャネルに用いることで，より良好な画像補正結果が確認された．本手法により逐次近似画像再構成の計算を行わずに吸収補正やデノイジングが可能となる．

OP11-3　管電流変調と bow-tie フィルタの X 線 CT 画像上の雑音分散への効果

○梅田　祐司，池田　　充，田之上和矢，藤井　啓輔，川浦　稚代，今井　國治
名古屋大学大学院医学系研究科医療技術学専攻医用量子科学講座

これまで我々は，雑音を量子雑音に限定した場合における X 線 CT 画像の関心領域内の雑音分散の（アンサンブル領域の）期待値を解析的な式によって与えることについての検討を行ってきたが，管電流変調と bow-tie フィルタが同雑音分散に与える影響については未検討であった．そこで今回，管電流変調を適応した場合と bow-tie フィルタを設定した場合について，雑音分散に対する影響とこれらを考慮して解析的に計算した雑音分散の精度に関する検討を仮想的な X 線撮影系に対するシミュレーションによって実施した．その結果，管電流変調を適応した場合と bow-tie フィルタを設定した場合においても，解析的に計算した期待値はシミュレーション画像からの推定値とよく一致し，解析的に計算した期待値の精度が高いことが示された．さらに，解析的に計算した期待値から，管電流変調を適応した場合と bow-tie フィルタを設定した場合，雑音分散値の変動は減少することを予測できることも示された

OP11-4　SDF 撮影法を用いた微小循環酸素飽和度推定の撮影深度補正

○橋本　涼平[1]，倉田　智宏[2]，関根　　雅[3]，大西　　峻[3]，中野　和也[3]，羽石　秀昭[3]

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

毛細血管と細動脈および細静脈によって構成される微小循環領域での酸素状態の可視化は，疾患の状態の把握や機序の理解をする上で重要である. そこで, 我々はこれまでに微小循環の観察と解析を目的に, Sidestream Dark-Field(SDF) カメラを試作し, さらに SDF 画像から酸素飽和度 (SO2) の推定を行う SDF オキシメトリを開発してきた．しかし，SDF オキシメトリの精度は組織表面から撮影対象までの深さ (撮影深度) に大きく依存している．本発表では光伝搬モンテカルロシミュレーションに基づく SDF オキシメトリの撮影深度補正手法を提案する．本手法では，血管部に対する光子のパスを 3 通りに分類した上で，血液の吸光特性に対する補正パラメータを撮影深度毎に求める．光学ファントム実験を実施し，取得した SDF 画像に対して提案手法を適用した結果，推定誤差が 25% から 3% に補正された．前述の実験から SDF オキシメトリに対する提案手法の有効性が示唆された.

OP11-5　非剛体変換を用いた低線量四次元 CT 画像からの肝腫瘍領域の描出精度

○鈴木健太郎[1,2]，臼井　桂介[3]，笹井　啓資[3]

[1]済生会横浜市東部病院　放射線部，[2]順天堂大学大学院　医学研究科，[3]順天堂大学医学部　放射線治療学講座

目的：肝腫瘍に対する定位放射線治療法は，呼吸運動を反映した四次元 CT 画像内の腫瘍領域を正確に描出する必要がある．肝腫瘍の描出には正常組織との間に高いコントラストが求められるが, 信号雑音比の向上には被ばく線量の増加が伴う．そこで, 四次元 CT 画像間の変形を補正する非剛体変換を利用して各時相画像を重ね合わせることで，位置ずれを補正し肝腫瘍のコントラストの向上と領域の描出精度の改善を目指す.

方法：造影後の腹部四次元 CT 画像に対してガウスノイズを付与し低線量で撮影した CT 画像を推定した後，これを用いて非剛体変換と平均加算処理を各時相画像に対して実施した．閾値処理にて肝腫瘍の領域を描出し，原画像から描出される腫瘍領域との類似度をダイス係数と平均表面距離により評価した.

結果：25% 線量相当のノイズを付加した腫瘍領域のダイス係数は 0.88，平均表面距離は 1.03mm であり，低線量画像に対する腫瘍輪郭の描出精度が向上した.

10:30 ～ 12:00　OP13「CAD」

座長：野村　行弘（東京大学）

八上　全弘（京都大学）

OP13-1　Z-score 画像を用いた悪性腫瘍の自動抽出と治療効果判定および被ばく線量測定のためのシステムの開発

○羽賀　愛美[1]，原　　武史[1]，伊藤　　哲[2]，加藤　正也[2]，松迫　正樹[3]，周　　向栄[1]，片渕　哲朗[4]，藤田　広志[1]

[1]岐阜大学　大学院　自然科学技術研究科　知能理工学専攻，[2]大雄会病院　第一放射線科，[3]聖路加国際病院　放射線科，[4]岐阜医療科学大学　保健科学部

Standardized Uptake Value (SUV) is a semi-quantitative measurement of FDG-PET. In the FDG-PET examination, a determination of therapeutic effect using Total Lesion Glycolysis (TLG) has been accepted in clinical situations. TLG is an indicator reflecting the degree of sugar metabolism and volume in tissue. The purpose of this study was to propose an automatic segmentation of tumors using Z-score image, which was obtained by the statistical image analysis, and to develop a computer-aided diagnostic system for cancer therapy and dose measurements. For the automatic segmentation of region of interest (ROI) around the lesions, we used CT images from PET/CT devices and applied our multiple organs segmentation method, which is based on a deep convolutional network approach. Organ and torso labels determined on the CT images were imposed on PET image. The lesions on FDG-PET images were segmented based on the Z-score and SUV from FDG-PET image. Regions with small (<10 mm3) or low SUV (<2.0 SUV) were eliminated as false-positive regions after the initial detection step. As a result of the performance evaluation for the detection scheme, 64.9% (124/191) of tumors in 34 cases were segmented correctly, but 38.4 false-positives per case were remained. Based on the automated detection results, the differences of volumes, SUVs, Z-scores and effective doses of lesions were annotated on the image. TLGs were also obtained from the two time different examinations of pre- and post-treatment FDG-PET/CT images.

OP13-2　3 次元 CT 画像を用いたじん肺の重症度診断基準の定量的評価

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

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

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

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

本報告では，3 次元じん肺 CT 画像から 2 回のマニュアル処理と自動処理で粒状影を抽出し，じん肺 CT 画像のデータベースを作成する．このデータベースを用いて X 線写真の診断結果と粒状影の個数・大きさ・重症度別に解析・比較・評価を行う．

OP13-3　HoTPiG 特徴量を用いた胸部 CT における結節自動検出

○花岡　昇平[1]，野村　行弘[2]，根本　充貴[3]，三木聡一郎[2]，吉川　健啓[2]，林　　直人[2]，阿部　　修[1]，増谷　佳孝[4]，清水　昭伸[5]

[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]近畿大学生物理工学部医用工学科，[4]広島市立大学情報科学研究科，[5]東京農工大学工学部電気電子工学科

A novel feature set for medical image analysis, named HoTPiG (Histogram of Triangular Paths in Graph), was introduced by the authors and its effectiveness in cerebral aneurysm detection was proven. In this study, HoTPiG is applied to a nodule detection problem in chest CT datasets. Given a graph structure extracted from a binarized volume, HoTPiG can effectively encode both the morphological characteristics and the local branching pattern of the structure around each graph node. Therefore, HoTPiG is expected to be effective in eliminating false positives at the branching points of the vessels. In the result, the proposed method showed the sensitivity of 89.3% when the false positive number is 10 per case. We concluded that HoTPiG feature set is also effective in lung nodule detection.

OP13-4　CNN による胸部 CT 画像からの経時的差分画像上の異常陰影の検出

○長尾　充朗[1]，植村　知規[1]，陸　　慧敏[1]，タン ジュークイ[1]，金　　亨燮[1]，村上　誠一[2]，青木　隆敏[2]，平野　　靖[3]，木戸　尚治[3]

[1]九州工業大学，[2]産業医科大学，[3]山口大学

近年，医師の画像診断は CT などの技術の進歩に伴い，診断性能が格段と向上しているが，被験者一人あたりの画像枚数も増加している．このことから医師への負担軽減等を目的とした CAD システムの開発が進んでいる．一方，日本の平成 27 年がんの部位別死亡者数において，肺がんは男女計で第 1 位を示しており，早期発見・早期治療が重要であると考えられる．また近年，機械学習の分野において注目を浴びているものに，深層学習がある．これは，多量の学習データを入力として与え，未知データからのパターン識別が可能で，人手の介在が少ないという利点がある．そこで本論文では，胸部 CT 画像からの異常陰影の検出法を提案する．主な処理の流れとしては，経時的差分像技術による正常構造の除去を行い，差分像上の残った領域に対する CNN による識別を行う．提案法を 25 症例の同一被験者で構成される過去･現在画像に適用し，その有効性を確認した．

OP13-5　CT 画像を用いた脂肪量計測の改良

○井手上　凌[1]，三井　　正[1]，平野　雅嗣[1]，山崎　克人[2]

[1]新居浜高専，[2]栄宏会小野病院

In this paper, we describe a software to measure fat volume using CT images. This software measures the volume of subcutaneous fat and visceral fat automatically. Using the presence of the muscle tissue between the subcutaneous fat and visceral fat as a guide, fat boundary line is set on the two-dimensional CT slice image. Fat separation and measurement are then performed on each image. The problem with this software is that reduction in CT value of the muscle tissue gives a false positive in the position of the fat boundary. In this research, we reduced the influence of this problem. We focused on the part where the boundary line curved unnaturally because it showed that the calculated boundary had an error at that point. We attempted to reduce the error by flattening the region using linear interpolation. In particular, we centered on the simple spine-like shape that faced the inside of the human body. This algorithm reduced the problem of this spiky shape as a whole. But there remained some errors where the shape of boundary line was complex. In addition, since this method ignores the structure of the body, we considered that if the interval to be interpolated is long, it may affect the measured fat volume.

OP13-6　隣接復元を用いたSLAMベースの気管支鏡追跡の改善

○王　　成[1]，小田　昌宏[2]，林　雄一郎[2]，本間　裕敏[3]，高畠　博嗣[4]，森　　雅樹[3]，名取　　博[5]，森　　健策[2,6,7]

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

We present an improved bronchoscope tracking method based on SLAM. Bronchoscope navigation provides additional location information for physicians during bronchoscopic examination. However, the previous navigation system mainly uses electromagnetic sensor for tracking, which requires additional device. We simplify the tracking by using visual SLAM. Bronchoscopic posture is obtained using the reconstructed feature points in adjacent frames. And new points are reconstructed afterwards among tracked frames. However, tracking may fail due to the decrease of trackable points. We utilize additional reconstruction to find more trackable point in adjacent frames after the bronchoscopic posture is obtained. More trackable points can make tracking robust. Experimental results showed that the proposed method can track more frames robustness than the previous method.

15:15 ～ 16:45　OP14「CAD」

座長：健山　智子（広島工業大学）
根本　充貴（近畿大学）

OP14-1　加重積算による肝臓のADC精度向上

○西原　　崇，瀧澤　将宏，白勢　竜二，村瀬　毅倫，磯部　正幸

株式会社日立製作所 ヘルスケアビジネスユニット

[背景 / 目的]
肝臓DWIでは，肝左葉のADC値が不正に増加する問題がある．肝臓DWIは複数積算で撮像する場合が多く，本報告では加重積算することでADC値の精度を向上させる方法を検討した．
[方法]
撮像対象は健常ボランティア2名とした．本研究計画は日立グループ倫理審査委員会で審査済みである．息止めでb値=1000のDWIを12回撮像し，ピクセル毎に信号値を①全12積算を加算平均，②中央値以上を加算平均，③最大値のみ，の3パターンで加重積算して領域毎にADC値とSNRを比較した．
[結果 / 結論]
ADC値は，拍動の小さい肝下部に対して肝左葉が① 1.35倍，② 1.14倍，③ 1.06倍であり，SNRは① 22.0，② 21.7，③ 15.4であった．健常ボランティアでは各領域のADC値はほぼ一定と予想されることから，加重積算で精度が向上していることが分かるが，SNRを加味すると②程度が最適と考える．

OP14-2　機械学習を用いた腹部動脈血管名自動命名における臓器情報および多血管相互関係利用方法の検討

○鉄村　悠介[1]，Roth Holger[1]，林　雄一郎[1]，小田　昌宏[1]，三澤　一成[2]，森　　健策[1,3,4]

[1]名古屋大学大学院情報学研究科，[2]愛知県がんセンター，[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

本稿では，3次元腹部CT像から抽出した腹部動脈領域に対する機械学習による血管名自動命名について，条件付き確率場モデルにおいて考慮する特徴量を改良することで精度向上を図った．これまで腹部動脈領域に対して機械学習を用いて血管名自動命名を行う手法が幾つか提案されてきた．しかしこれらの手法では，ある血管そのものがもつ特徴や，ある血管と一対一に対応する血管との関係性の利用に重きを置いており，高度な血管構造の把握が困難であった．そのため複雑な分岐構造をもつ動脈で精度が低くなる問題があった．そこで本稿では，自動抽出臓器と血管との関係性やある血管と複数の血管との関係性を活用することにより問題の解決，精度の向上を図った．その結果，複雑な構造をもつ肝動脈の命名精度が大幅に向上し，腹部動脈22種類の命名精度は最大で95.3%となった．

OP14-3　造影マルチスライス CT 画像における大腸がんの転移性リンパ節解析

○坂東　佳祐[1]，鈴木　秀宣[2]，河田　佳樹[2]，仁木　　登[2]，飯沼　　元[3]

[1]徳島大学大学院 先端技術科学教育部，[2]徳島大学大学院 社会産業理工学研究部，[3]国立がん研究センター中央病院放射線診断部

大腸がんは高い死亡率を占める疾患である．遠隔転移のない大腸がん患者の予後を予測するうえで最も大きな要因は転移性リンパ節の有無である．一般に径が大きいリンパ節ほど転移の可能性が上がるが，径の小さいリンパ節にも転移が確認される場合がある．大腸がん患者の予後を高精度に予測するには大きさ以外の判断指標が必要である．本報告の目的は，多時相造影 CT 画像 (動脈相，門脈相，平衡相) からリンパ節を抽出し，時相間の CT 値の比較を行うことで転移性リンパ節の特徴を明らかにすることである．本手法は (1) リンパ節の抽出，(2) 時相によるリンパ節の CT 値の遷移調査からなる．(1) 多時相のリンパ節の抽出は血管の 2cm 以内に存在する CT 値 -20~150[H.U.] の塊形状を半自動抽出する．(2) 時相によるリンパ節の CT 値遷移の調査は，個々のリンパ節の中心座標を算出し，解析に用いる．これらより，多時相造影 CT 画像からリンパ節を抽出し，時相によるリンパ節の解析を行う．

OP14-4　教師なし深度推定を利用した RGB-D 特徴抽出に基づくポリープのトリナリサイズ推定

○伊東　隼人[1]，ロスホルガ[1]，三澤　将史[2]，森　　悠一[2]，小田　昌宏[1]，工藤　進英[2]，森　　健策[1,3,4]

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

大腸内視鏡検査におけるポリープのサイズ情報は診断において非常に重要である．特に，5㎜以下の小さなポリープ，10mm 以上の大きなポリープ，それ以外のポリープといった 3 カテゴリに関するサイズ推定（トリナリ推定）は治療計画を立てる上で重要である．しかし内視鏡画像だけを用いたサイズ推定は熟練の専門医にとっても困難な問題である．そこで内視鏡画像・動画像からポリープのサイズ推定を行う CAD システムが望まれている．内視鏡画像には 3 次元情報が欠如しており，2 次元画像からの精密なサイズ推定は不良設定問題である．本研究ではこの不良設定問題をトリナリサイズ推定に緩和し，内視鏡画像からポリープのサイズ推定に有用な特徴を深層学習によって抽出，そして分類する手法を提案する．特徴抽出においては教師無し学習による深度推定を利用する．提案手法により高精度のトリナリサイズ推定を達成した

OP14-5　3 次元 residual networks (ResNets) を用いた大腸 CAD における偽陽性陰影の識別

○植村　知規[1]，陸　　慧敏[1]，金　　亨燮[1]，橘　　理恵[2]，弘中　　亨[3]，Näppi Janne[3]，吉田　広行[3]

[1]九州工業大学，[2]大島商船高等専門学校，[3]Massachusetts General Hospital and Harvard Medical School

近年，高い精度での病変検出が可能な支援診断 (CAD) システムが多く提案されている．一方で，大腸 CAD システムでは，現在でも疑陽性陰影も多く検出される傾向にある．そこで本論文では，疑陽性陰影の識別に焦点を当て，畳み込みニューラルネットワーク (CNN) を用いた新たなモデルである 3 次元 ResNet モデルを提案し，大腸 CAD における疑陽性陰影の識別を試みた．提案モデルは，2 層の 3 次元の畳み込み層に 3 層の 3 次元残差ブロックを加えて深層化を行うことで，腹部 CT 等の 3 次元データに対し，より深い CNN による解析を可能とする．実験では，仰臥位 / 伏臥位からなる腹部 CT40 症例を用い，提案モデルと 2 次元 ResNet との比較実験を行った．実験では，両モデルの偽陽性の識別能を ROC 曲線下面積 (AUC) として求め，AUC 値の統計的有意差を t 検定にて検定した．結果として 3 次元 ResNet は AUC: 0.970，2 次元 ResNet は AUC: 0.959 を示し，P=0.03 であることから，3 次元 ResNet が有意に偽陽性を高い精度で識別できることが示された．

OP14-6　CNN を用いた自己進化型 CAD システムの提案

○安倍　和弥[1]，武尾　英哉[1]，永井　優一[2]，縄野　　繁[3]

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

近年，CAD の研究分野にも CNN が積極的に用いられるようになった．一般的に，機械学習には様々なバリエーションを持った症例画像を網羅的に与えて学習を行うことで，汎用的で高性能な判別器を設計する．これは，学習に含まれていない画像はうまく検出ができないと考えられるからである．実際に比較的典型的な症例のみを使って学習した CNN と症例を網羅して学習した CNN では後者の方が性能が高いことが確認された．これは CAD のリリース時にも同様のことが考えられる．開発時に用いる症例は，実際に運用する病院での症例を網羅しているとは限らないからである．

そこで本論文では，再学習機能を組み込んだ自己進化型 CAD システムを提案する．従来の CAD システムはリリース後に判別器を更新することはできなかった．そこで，CAD システムに読影レポート情報（電子カルテ）を利用した誤認識訂正機能を持たせ，ある一定のデータを適用した後に再学習を行うことで判別器を更新する仕組みを提案する．本機能により，再学習を行わない場合と比べて性能の向上が見られた．また，複数回の再学習によって段階的な性能向上も見られ，その病院にマッチした CAD に進化していく過程も確認された．

9:00 ～ 10:15　**OP12「CAD」**

座長：小尾　高史（東京工業大学）
畑中　裕司（滋賀県立大学）

OP12-1　Faster R-CNN を用いた子宮頸部細胞診における悪性細胞の検出

○津森　太亮[1]，木戸　尚治[2]，平野　　靖[2]，森　　正樹[3]，稲井　邦博[4]，今村　好章[3]

[1]山口大学大学院　創成科学研究科　電気電子情報系専攻，[2]山口大学大学院　創成科学研究科，[3]福井大学医学部附属病院　病理診断科／病理部，[4]福井大学　医学部　病因病態医学講座・分子病理学領域

子宮頸がん検診には細胞診が用いられるが，細胞診では多くの正常細胞の中から悪性細胞を探し出す必要がある．そのため，本研究は Deep Learning を用いて悪性細胞を検出してその組織型を判別し，細胞検査士の負担を軽減することを目的とする．

本研究では，物体検出に使われる Faster R-CNN を用いて，細胞の検出，及び検出した細胞の悪性度の分類を行った．悪性度の分類は細胞診で良悪性を分類するためのベセスダ分類を基に，「正常群」，「内科的経過観察群」，「要外科的処置群」の 3 クラスで行った．

使用するデータは訓練データとテストデータに分け，5 分割交差検証を行い，各クラスにおける Faster R-CNN の結果と検査士による診断結果を F 値を用いて比較すると，「要外科的処置群」では 82.3 ± 2.9%，「内科的経過観察群」は 75.0 ± 8.6% であり提案手法の有効性が示された．また「正常群」の F 値は 47.9 ± 9.0% であったが検査士により全ての正答がアノテーションされていないことが原因と推察された．

OP12-2　マウスの脳の二光子顕微鏡画像からの神経細胞認識処理の開発

○君塚　　涼[1]，道川　貴章[2]，竹本　智子[3]，横田　秀夫[3]，宮脇　敦史[2,4]，清水　昭伸[1]

[1]東京農工大学，[2]国立研究開発法人理化学研究所　光量子工学研究センター　生命光学技術研究チーム，[3]国立研究開発法人理化学研究所　光量子工学研究センター　画像情報処理研究チーム，[4]国立研究開発法人理化学研究所　脳神経科学研究センター　細胞機能探索技術研究チーム

脳神経細胞の自動抽出は，生物学的解析の効率を高める面から求められているが，細胞のコントラストの差や，脳深部での SN 比の悪化により容易ではない．本稿では，深層学習による脳神経細胞の自動認識処理を提案する．この処理では二光子顕微鏡で撮影されたマウスの脳組織画像を入力とし，U-net を用いて脳神経細胞の細胞体のセグメンテーションを行う．メモリの制限によりパッチベースの方法論を採用し，また，学習データ不足を補うためのオーグメンテーションを行った．損失関数は従来法の cross entropy の他，Dice 係数を拡張した式を用い，比較を行う．学習と性能の評価は，二光子顕微鏡画像を学習データ，バリデーションデータ，テストデータに分割し，正解の細胞体領域との一致度と，細胞体単位での検出率や連結成分単位の拾いすぎなどを用いた．また，従来法である Boosting との比較を行い，本手法の有効性について議論する．

OP12-3　Automatic detection of image quality failure for the practical use of whole slide imaging scanner

○ホシャイン サカワット[1]，Nakamura Tomoya[1,2]，Kimura Fumikazu[3]，Yagi Yukako[4]，Yamaguchi Masahiro[1]

[1]School of Engineering, Tokyo Institute of Technology, Japan，[2]PRESTO, Japan Science and Technology Agency, Japan，[3]Department of Biomedical Laboratory Sciences, Shinshu University, Japan，[4]Department of Pathology, Memorial Sloan Kettering Cancer Center, New York, USA

Whole slide imaging (WSI) scanner scans pathological samples for digital pathology. Sometimes, the scanned image is poor in quality such as focus error and noise. The scanned image must be evaluated and rescanned if necessary. However, human evaluation is not practical. Therefore, it is necessary to evaluate the image and detect slides to rescan for the practical use of WSI scanner. In this paper, we propose a method to detect slides necessary to rescan. At first, tissue artefacts (i.e. air bubble, tissue fold) were detected from low resolution image using machine learning technique. Then quality was estimated at high resolution excluding the artefact and mostly white blocks. Slides were detected to rescan by applying a threshold on quality. The method was demonstrated on differently stained slides which were scanned by two different scanners

OP12-4　深層学習器を用いた悪性黒色腫自動識別における識別根拠の評価

○村林　誠也，彌冨　　仁

法政大学 理工学部 応用情報工学科

皮膚がんの一種であるメラノーマは極めて悪性度が高く早期の発見が非常に重要となるが，その様相は母斑に酷似しており熟練の皮膚科専門医でも識別精度は 8 割程度に留まる．近年提案されている convolutional neural networks(CNN) を転移学習する自動識別手法では専門医に匹敵する識別精度を実現している．しかし，これらのシステムは診断の根拠を提示することができず改善の余地が残されていた．そこで本研究では，診断の確定している 2,372 例（メラノーマ 824 例，母斑 1,548 例）のダーモスコピー画像を用いて高精度な識別器を構築するとともに，識別の根拠として結果に大きく寄与した領域を提示するシステムを構築した．得られた結果に対し，あらかじめ 5 人の皮膚科専門医が診断指標の 1 つである 7-point checklist に基づき診断した結果との整合性の検証および評価を行った．

OP12-5　クラス別学習による細胞画像セグメンテーション

○松月　大輔[1]，堀田　一弘[1]，松田　道行[2,3]，寺井　健太[2]，今西　彩子[2]，平松　侑樹[1]

[1]名城大学理工学研究科電気電子工学専攻，[2]京都大学生命科学研究科　生体制御学，[3]京都大学医学研究科　病態生物医学

今日，人工知能技術による処理の自動化が様々な所で進められており，細胞画像中の「細胞膜」や「細胞核」のセグメンテーションでも Deep learning を用いるのが主流になりつつある．一般に，画像のセグメンテーションでは 1 枚の画像中に複数のクラスが存在する．クラス数が増えた場合やクラス毎に出現頻度が異なる場合，セグメンテーションの精度が低下してしまう．そこで本論文ではクラス別に学習を行い，その結果を統合する方法を提案する．評価実験では，「細胞膜」，「細胞核」，「背景」を含むデータセットを用い，従来法である U-net と提案手法の精度比較を行った． Intersection over Union を用いた精度評価を行い，提案手法が従来法を上回ることを確認した．

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

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

発行日：２０１８年7月２４日

発行者：工藤博幸

製作所：トーヨー企画株式会社

Fully convolutional network を用いた 少量画像データ学習からの頭部解剖構造抽出

杉野　貴明[*1]　Holger R. Roth[*1]　小田　昌宏[*1]　庄野　直之[*2]

金　太一[*2]　森　健策[*1,3,4]

要旨

実践的訓練・シミュレーションの実施が難しい脳外科手術のシミュレータとして，頭部解剖構造を再現した精巧な頭部モデルの開発が進められている．そこで本研究では，こうしたモデルの作成・標準化に有用な解剖構造データベース構築を目的として，医用画像から正確な頭部解剖構造抽出を可能とする深層学習ベースのセグメンテーション手法を提案する．特に本稿では，多量の学習データの作成が困難という深層学習ベースの手法に伴う問題を考慮し，スパースアノテーションによる少量の学習データから精密な解剖構造抽出結果をもたらすネットワーク及びその学習手法を構築する．Visible Korean Human プロジェクトによる人体断面画像データを基に抽出精度の検証実験を実施したところ，本手法により全画像枚数の 10%を学習に用いるだけでも平均約 90%の高い精度での頭部解剖構造抽出が可能であることが示された．

キーワード：セグメンテーション，頭部解剖構造，Fully convolutional network，スパースアノテーション

1. はじめに

実践的な訓練やシミュレーションの実施が困難な脳外科手術を対象に，頭部解剖構造を忠実に再現した頭部モデルの開発が進められている[1]．解剖学的多様性を反映した生体忠実性の高いモデルを実現するためには，医用画像からの解剖構造抽出技術を通じた精密な解剖構造モデルデータのデータベース構築が重要である．こうした要求を満たす高精度な自動解剖構造抽出手法として，近年では Fully convolutional network (FCN)を活用した方法[2]が優れた性能を示している．ただし，このような深層学習ベースの手法で良い抽出性能を発揮するには，一般に多くの学習データが必要となるが，精密な解剖構造モデルデータ作成に見合った解像度の医用画像及びそのアノテーションデータを大量に用意するのは困難なことが多い．そのため，少量の学習データからでも十分な精度を発揮できる解剖構造抽出手法が求められている．

そこで本稿では，全画像枚数の一部のみをアノテーション（スパースアノテーション）することで得られる少量学習データを基に，頭部解剖構造を高精度に抽出するための FCN のネットワーク構造及びその学習手法を提案すると共に，ネットワーク構造の違いによる抽出性能への影響について検証する．

*1 名古屋大学大学院情報学研究科
〔〒464-8601 名古屋市千種区不老町〕
e-mail: tsugino@mori.m.is.nagoya-u.ac.jp
*2 東京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

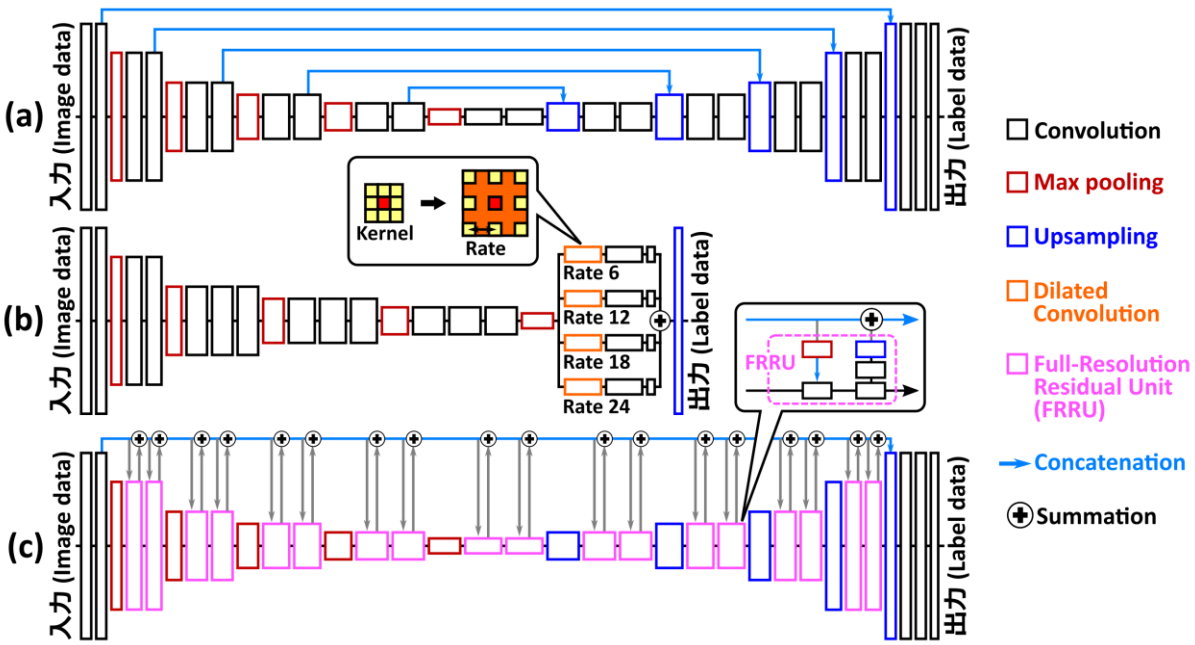

図 1 ネットワーク構造の概略図：(a) 2D U-net，(b) DeepLabv2，(c) Residual unit-based FCN (RU-FCN)

2. 方法

2.1 FCN の構造

FCN により，画像情報を基にサイズ・形状の異なる複数の解剖構造領域を抽出する場合，マルチスケールの画像特徴を反映した特徴マップの獲得が重要であり，そのためのネットワーク構造が多く提案されている．U-net[2]は，Skip connection と呼ばれる構造により浅層と深層で得られる画像特徴を段階的に統合することで，マルチスケールの特徴マップを獲得する（図 1 (a)）．また DeepLabv2[3]は，通常より間隔を広げたカーネルを用いた畳み込み（Dilated convolution）層を取り入れることで計算コストを抑えながらマルチスケールの特徴マップの獲得を可能にしている（図 1 (b)）．近年では，より細かい Skip connection を組み合わせた Residual unit を取り入れることで，更なるマルチスケールの画像特徴統合を可能にする構造が開発されてきている[4]．

そこで本研究では，更なる画像特徴統合が可能な Full-resolution residual unit (FRRU)[4]に着目し，U-net の畳み込み層を FRRU に置き換えた Residual unit-based FCN (RU-FCN)を提案する（図 1 (c)）．

2.2 FCN の学習法

スパースアノテーションにより得られる少量の学習データから効果的な学習を図るためにデータ拡張を行う．本研究では，同一症例の一部の画像からの学習に基づき，残りの画像の解剖構造抽出を行うことを想定しており，学習画像と抽出を実施する画像間でコントラストや抽出対象の位置・スケール等に大きな差はないと考えられる．そのため，余分なデータ拡張を避けるために，回転と弾性変形の 2 種類の画像処理に絞り，各学習画像にそれぞれの処理を加えることによってデータ拡張を実施する．

また，サイズが不均一な複数の解剖構造領域の抽出を扱う場合，サイズの小さい抽出対象クラスは学習過程における影響力が小さく，結果として抽出精度が低下する傾向にある．そこで，サイズの小さい解剖構造の抽出精度を高めるために，学習画像内の各対象領域のピクセル比に基づいて重み付けされた交差エントロピー損失関数を用いて FCN の学習を実施する．

3. 実験及び考察

Visible Korean Human プロジェクト[5]による人体断面画像及びそのセグメンテーションデータ 1 例を用いて，FCN の頭部解剖構造抽出精度の基礎的検証を行った．使用した画像のサイズは 512[pixel]×512[pixel]×235[枚]，解像度は 0.40[mm]×0.40[mm]×1.0[mm]である．本実験では，頭蓋骨，大脳，間脳，小脳，脳幹, 眼球, 副鼻腔の 7 領域を抽出対象とし，2D U-net[2]，DeepLabv2[3]，RU-FCN の 3 種類のネットワークによる抽出結果を比較した．少量データ学習時における抽出性能を評価するため，10 枚置きに選択された全画像枚数の 10%（24 枚）で学習，残りの 90%（211 枚）でテストを実施した．

表 1 に各 FCN の Dice スコアによる抽出結果を示す．全対象領域において RU-FCN が最も高い精度を示した．これは，FRRU が単純な Skip connection よりもサイズ・形状の異なる複数領域の抽出に有用なマルチスケールの画像特徴の獲得に寄与するためであると考えられる. したがって, 本実験結果より Residual unit ベースのネットワーク構造が頭部解剖構造抽出に有効に働くことが示唆された．

表 1 FCN 構造別の頭部解剖構造抽出結果

抽出領域	Dice スコア [%]		
	2D U-net	Deep Labv2	RU-FCN
（背景）	98.3	97.9	**98.6**
頭蓋骨	85.9	82.6	**88.2**
大脳	95.5	94.3	**96.1**
間脳	80.5	74.2	**81.0**
小脳	90.9	91.7	**93.0**
脳幹	82.8	83.0	**86.3**
眼球	92.1	86.9	**94.5**
副鼻腔	84.6	84.2	**89.4**
平均*	87.5	85.3	**89.8**
標準偏差*	5.5	6.6	**5.2**

*背景を除いて算出した値

4. まとめ

本稿では少量データ学習から高精度に頭部解剖構造を抽出するための FCN ベースのセグメンテーション手法を提案した．実験結果から，Residual unit ベースの FCN を用いることで平均約 90%の精度が達成され，少量データ学習からでも高精度な解剖構造抽出が可能であることが示された．今後は手術シミュレーションにおいて重要な血管・神経等のより微細な組織を含めた構造抽出の実現を目指す．

謝辞

本研究の一部は，革新的研究開発推進プログラム (ImPACT)，MEXT/JSPS 科研費 (26108006, 17K20099, 17H00867)，ならびに JSPS 二国間交流事業の助成によった．

利益相反の有無

なし

文　献

［1］ 益田泰輔, 新井史人, 太田信, et al.：バイオニックヒューマノイド：次世代手術訓練用人体モデルのデザイン．ロボティクス・メカトロニクス講演会 2017, 2A-N07, 2017.

［2］ Ronneberger O, Fischer P, and Brox T: U-net: Convolutional networks for biomedical image segmentation. In: MICCAI, LNCS 9351, pp. 234-241, 2015.

［3］ Chen L, Papandreou G, Kokkinos I, et al.: DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs. IEEE Trans Pattern Anal Mach Intell **40**(4): 834-848, 2018.

［4］ Pohlen T, Hermans A, Mathias M, et al.: Full-resolution residual networks for semantic segmentation in street scenes. In: CVPR, pp. 4151-4160, 2017.

［5］ Shin DS, Chung MS, and Park JS: Systematized methods of surface reconstruction from the serial sectioned images of a cadaver head. J Craniofac Surg **23**(1): 190-194, 2012.

Segmentation of head anatomical structures using a fully convolutional network trained from a small amount of image data

Takaaki SUGINO[*1], Holger R. ROTH[*1], Masahiro ODA[*1], Naoyuki SHONO[*2], Taichi KIN[*2], Kensaku MORI[*1,3,4]

*1 Graduate School of Informatics, Nagoya University
*2 Graduate School of Medicine, The University of Tokyo
*3 Information Technology Center, Nagoya University
*4 Research Center for Medical Bigdata, National Institute of Informatics

Elaborate human head models have been developed as a simulator for brain surgeries, which surgeons have difficulty in training and simulating in a practical manner. Thus, for construction of a database of head anatomical data applicable to creation and standardization of such head models, we propose a fully convolutional network (FCN)-based method to accurately segment head anatomical structures from medical images. Especially in this study, we aim to propose a FCN architecture and its training strategy to provide accurate segmentation of head anatomical structures from training on sparsely-annotated data. The result of the validation experiment using a set of head sectioned images from the Visible Korean Human project showed that the proposed FCN could achieve the high mean accuracy of about 90% for segmentation of head anatomical structures even from training on 10% of all the images.

Key words: Segmentation, Head anatomical structures, Fully convolutional network, Sparse annotation

畳み込みニューラルネットワークを用いた眼底画像における毛細血管瘤の自動検出　～偽陽性候補の削減～

宮下　充浩[*1]　畑中　裕司[*2]　小郷原　一智[*2]　村松　千左子[*3]

砂山　渡[*2]　藤田　広志[*3]

要旨

糖尿病網膜症は本邦の失明原因の第 2 位である．その初期所見の 1 つである毛細血管瘤は，眼底画像上で小さく，低コントラストであるため，医師であっても発見が困難である．筆者らは，3 種類の毛細血管瘤の強調画像を用いた畳み込みニューラルネットワーク(CNN)による毛細血管瘤の自動検出手法を提案した．しかし，一部の偽陽性が誤って強調される問題と，48 種類の特徴量を用いたニューラルネットワーク(NN)による偽陽性候補の削除処理の性能が十分でない問題があった．本論文では，緑成分画像を用いた CNN の追加によって検出処理を改良すると共に，NN の入力次元の縮約によって偽陽性候補処理を改良した．

キーワード：眼底画像，糖尿病網膜症，毛細血管瘤，畳み込みニューラルネットワーク，偽陽性候補削除

1. はじめに

眼底検査で発見可能な糖尿病網膜症は，日本における成人の失明原因で第 2 位となっている．糖尿病網膜症の眼底所見は，出血，白斑および毛細血管瘤である．**図 1** に示すように，健診などで使用される非造影の眼底画像において，毛細血管瘤は小さくて低コントラストであるので，医師が目視で検出することは困難である．そこで，国内外の研究グループは，眼底画像から毛細血管瘤を自動検出する手法を提案している［1-4］．

これまでに，Top-Hat 変換と k 最近傍法を組み合わせて候補を検出する手法［1］，緑成分画像からガウスフィルタ，Kirsch フィルタを適用し，マルチエージェントを用いた手法［2］などが提案されている．さらに，筆者らも濃度勾配ベクトル集中度を用いた毛細血管瘤の検出処理と，48 種類の特徴量を用いた偽陽性候補の削除処理による手法［3］を提案した．しかし，これらの従来手法は，検出処理において特徴量のパラメータ設定が複雑であり，複数の眼底画像データベースに対応しづらい課題があった．特に，毛細血管瘤の濃淡分布や形状は多様であるため，特徴量ベースの手法が多様な毛細血管瘤に対応できていなかった．そこで，筆者らは 3 種類の毛細血管

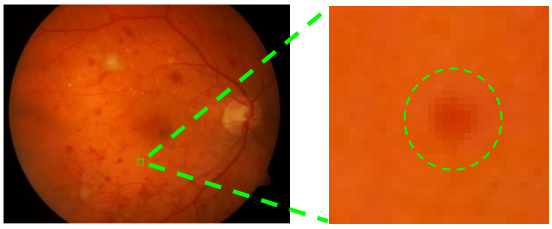

図 1 眼底画像と毛細血管瘤の症例．

*1 滋賀県立大学大学院工学研究科電子システム工学専攻
〔〒522-8533 滋賀県彦根市八坂町 2500〕
e-mail: oh23mmiyashita@ec.usp.ac.jp
*2 滋賀県立大学工学部電子システム工学科
*3 岐阜大学工学部電気電子・情報工学科

瘤の強調画像を入力とした畳み込みニューラルネットワーク（CNN: Convolutional Neural Network）で毛細血管瘤を自動検出する手法を提案した［4］．しかし，毛細血管瘤の強調画像では，画像内の一部が強調されてしまう問題があった．また，テクスチャ特徴を中心とした 48 種類の特徴量による偽陽性候補の削除処理も行っているが，十分な判別性能が得られていなかった．本論文では，これらの問題の対策を検討し，偽陽性候補の削減に取り組んだ手法について述べる．

2. 手法

本研究では，従来手法［4］の CNN ベースの検出処理と，特徴量ベースの偽陽性候補の削除処理の改良を主たる目的とした．新たに緑成分画像（G 成分画像）を入力とした CNN による毛細血管瘤の検出処理を加え，従来の毛細血管瘤の強調処理後の CNN の結果と合わせて最終的な検出結果とした．その後，48 種類の特徴量［3］を選定する処理を新たに加え，ニューラルネットワークにより偽陽性候補を削除した．以下に各処理の詳細を述べる．

1） 毛細血管瘤の検出処理

画像ごとに異なる眼底画像の明るさやコントラストの影響を軽減するために，ガンマ補正とヒストグラム拡張を行う．その後，RGB カラー画像の中で，毛細血管瘤のコントラストが最大となる G 成分画像に対して，shape index［5］，2 重リングフィルタ［6］およびガボールフィルタ［7］を適用することにより，**図 2** に示すような毛細血管瘤の強調画像を作成した．これらの画像の一部を抽出したパッチを CNN に入力し，毛細血管瘤を検出した［4］．

しかし，強調画像が正常構造を強調してしまうことによって，偽陽性候補が多く生じていた．そこで，本研究では新たに G 成分画像の一部を抽出したパッチを入力とした CNN を追加し，毛細血管瘤を検出した．

最後に，**図 3** に示すように 2 つの CNN での検出結果から，共通して検出した領域を最終的な毛細血管瘤の候補領域とした．この処理により，検出処理における偽陽性候補の削減を期待した．なお，2 つの検出処理では，共に CNN の学習モデルとして GoogLeNet［8］を使用した．

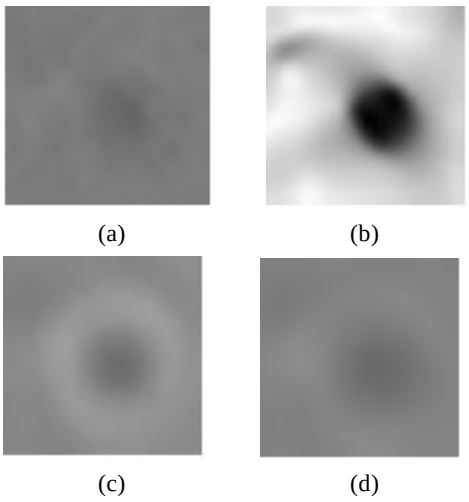

図 2 毛細血管瘤が強調された画像. (a)G 成分画像，(b)shape index の画像，(c)2 重リングフィルタ，(d)ガボールフィルタ

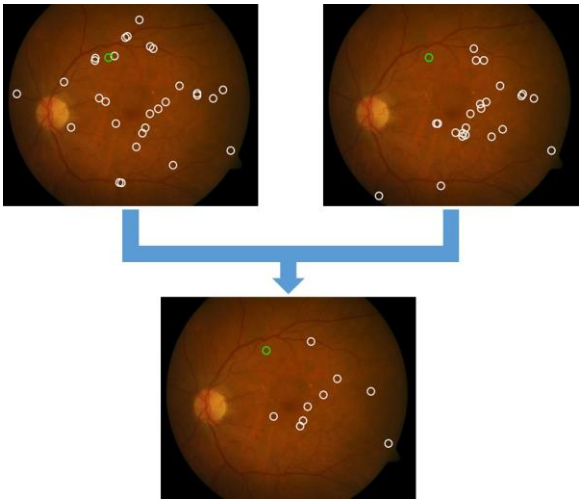

図 3 毛細血管瘤の候補領域の検出の例．（緑：毛細血管瘤，白：偽陽性）

2） 偽陽性の削除処理

従来手法［4］では，48 種類の特徴量［3］を計算し，閾値処理で明確な偽陽性候補を削除した後にニューラルネットワーク（NN: Neural Network）で毛細血管瘤と偽陽性候補に分類していた．しかし，特徴量の偽陽性候補

の分類への寄与について検討できていなかった．そこで，本研究では，新たに t 検定による特徴量の有意差検定を行い，$p<0.05$ の特徴量だけを使用した．さらに，選定した特徴量を主成分分析することによって，相関の高い入力特徴量の削減と，NN の過学習の可能性を減らすための入力次元の縮約を行った．なお，主成分分析の累積寄与率が 95%を初めて超える第 13 主成分までを NN に入力した．

3. 実験

本研究では、毛細血管瘤の検出評価用に公開されている DIARETDB1（Standard Diabetic Retinopathy Database Calibration level 1）［9］と ROC（Retinopathy Online Challenge）［10］を使用した．

DIARETDB1 は学習用画像 28 枚，評価用画像 61 枚で構成されており，これらの画像は撮影画像 50°で解像度が 1500×1152 画素の BMP 形式のカラー画像である．このデータベースでは，4 名の専門家がそれぞれ単独で読影を行ったときの読影結果およびその病変に対する確信度が公開されている．本研究では，確信度の平均が 0.75 以上となる領域を Gold Standard とした．学習用画像 28 枚のうち，毛細血管瘤を含む画像は 19 枚，毛細血管瘤を含まない画像は 9 枚であり，合計 83 箇所の毛細血管瘤が存在している．評価用画像 61 枚のうち，毛細血管瘤を含む画像は 21 枚，毛細血管瘤を含まない画像は 40 枚であり，合計 100 箇所の毛細血管瘤が存在している．

ROC データベースは学習用画像 50 枚，評価用画像 50 枚で構成されているが，評価用画像の Gold Standard が非公開であるため，学習用画像のみを CNN の学習に使用した．学習用画像は，768×576 画素の画像 22 枚，1058×1061 画素の画像 3 枚，1389×1383 画素の画像 25 枚で構成されており，4 名の専門家によって決定された Gold Standard も公開されている．学習用画像 50 枚のうち，毛細血管瘤を含む画像は 37 枚，毛細血管瘤を含まない画像は 13 枚であり，合計 336 箇所の毛細血管瘤が存在している．

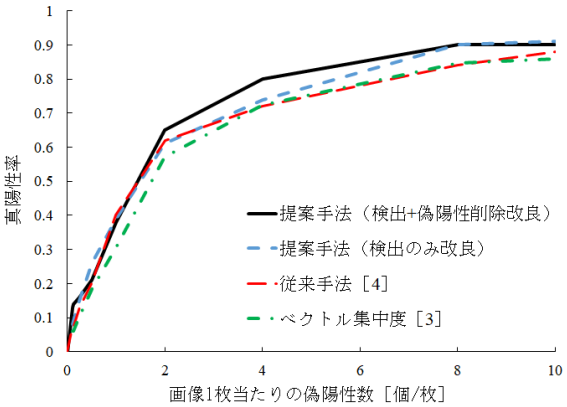

図 4 最終結果の性能比較．

評価には，DIARETDB1 の評価用画像 61 枚を用いて，提案手法を FROC（Free-response Receiver Operating Characteristic）解析で評価した．

4. 結果および考察

提案手法の t 検定適用前と適用後の結果，著者らの従来手法［4］の結果，井上らのベクトル集中度［3］の結果を**図 4** に示す．

画像当たりの偽陽性候補数（FPI: False Positives per Image）を 1/8，1/4，1/2，1，2，4 および 8 箇所としたときの真陽性率の平均 AS を性能比較の指標とする．検出処理を改良することによって，AS は従来手法の 0.426 から 0.449 に改善された．この結果は，G 成分画像を入力とした CNN を加えることで，検出処理段階での偽陽性数を減少させられたことを意味している．

また，偽陽性候補の削除処理を改良することによって，AS が 0.463 に向上した． FPI が 2 から 8 の間で，改良した偽陽性候補の削除処理による真陽性率が最良であった．しかし， FPI が 1 以下の場合の真陽性率が，偽陽性候補の削除処理を改良する前の結果を下回ることがあった．これは，全体的な判別性能は向上したものの，真陽性と偽陽性を明確に分類できるほどの特徴空間を得られていないものと考えられる．今後は，現在使用しているテクスチャ特徴に基づく特徴量以外の特徴

量などを用いることで，偽陽性候補の削除処理における毛細血管瘤と偽陽性候補の分類精度を向上させるなどの対策が必要であると考えられる．また，t 検定を適用した結果，いくつかの重要でないと考えられる特徴量を取り除くことができた．特徴量の中で，青成分（B 成分）に関する特徴量は，候補領域内の B 成分の毛細血管瘤検出用の 2 重リングフィルタの平均出力値以外すべて有意差なしとなった．逆に，G 成分に関する特徴量はすべて有意差ありとなった．このことから，本研究において毛細血管瘤と偽陽性の分類で B 成分の重要性は低く，G 成分は重要であると考えられる．また，円形度や縦横比など形状に関する特徴量で有意差ありと判定された．このことから，CNN を用いた候補領域検出では，不整形な毛細血管瘤を検出できている反面，不整形な偽陽性も多く検出していると考えられる．

5. まとめ

本研究は，従来手法の問題点を改良することで偽陽性数を減らすことを目的とした．新たに毛細血管瘤の検出処理に G 成分画像を用いた CNN を追加した．さらに，偽陽性候補の削除処理において, t 検定による NN の入力特徴量の選択処理と，主成分分析による入力次元の縮約を行った．以上の変更の結果，偽陽性の誤検出数を減らす研究目的を達成した．

謝辞

本研究の一部は，公益財団法人電気通信普及財団研究調査助成および JSPS 科研費 16K014158，26108005 により行われました．

利益相反の有無

なし

文　献

［1］ Niemeijer M, Ginneken V, Staal J, et al: Automatic detection of red lesions in digital color fundus photographs. IEEE Trans Med Imaging **24**: 584-592, 2005

［2］ Pereira C, Veiga D, Mahdjoub J, et al: Using a multi-agent system approach for microaneurysm, detection in fundus images. Artif Intell Med **60**: 179-188, 2014

［3］ 井上剛，畑中裕司，奥村進，他：濃度勾配ベクトル集中度による眼底画像における毛細血管瘤の自動検出．画像電子学会誌 **44**: 58-66, 2015

［4］ 宮下充浩，畑中裕司，小郷原一智，他：畳み込みニューラルネットワークを用いた眼底画像における毛細血管瘤の自動検出．Med Imag Tech **36**: 掲載決定, 2018

［5］ 石田降行, 桂川茂彦, 藤田広志（監修）: 医用画像ハンドブック. オーム社, 東京, 2010, pp309-312

［6］ Hatanaka Y, Inoue T, Okumura S, et al: Automated microaneurysm detection method based on double-ring filter and feature analysis in retinal fundus images, Pros. 25th IEEE Internat Symp Computer-Based Med Sys: 1-4, 2012

［7］ Kaur J, Sinha H P: Automated detection of retinal blood vessels in diabetic retinopathy using Gabor filter. International Journal of Computer Science and Network Security **12**: 109-115, 2012

［8］ Szegedy C, Liu W, Jia Y, et al: Going Deeper with Convolutions. IEEE Computer Vision and Pattern Recognition: 1-9, 2015

［9］ Kauppi T, Kalesnykiene V, Kamarainen J K, et al: Diaretdb1 diabetic retinopathy database and evaluation protocol. Pros. 11th Conf. on Med Image Understanding and Analysis 2007: 61-65, 2007

［10］ Niemeijer M, Ginneken B V, Cree M J, et al: Retinopathy Online Challenge: Automatic Detection of Microaneurysms in Digital Color Fundus Photographs. IEEE Trans. Med Imaging **29**: 185-195, 2010

Automatic Detection of Microaneurysms in Retinal Image by Using Convolution Neural Network –Reduction of False Positive Candidates–

Mitsuhiro MIYASHITA[*1], Yuji HATANAKA[*2], Kazunori OGOHARA[*2], Chisako MURAMATSU[*3], Wataru SUNAYAMA[*2], Hiroshi FUJITA[*3]

*1 Division of Electronic Systems Engineering, Graduate School of Engineering, the University of Shiga Prefecture
*2 Department of Electronic Systems Engineering, School of Engineering, the University of Shiga Prefecture
*3 Department of Electrical, Electronic & Computer Engineering, Faculty of Engineering, Gifu University

Diabetic retinopathy is the second cause of blindness in Japan. Microaneurysm is one of the early findings of diabetic retinopathy, and it appears dark small dot in the retinal images, thus it is difficult for physicians to detect them visually. We proposed a microaneurysms detection by using convolution neural network (CNN) with three types of microaneurysm emphasized images. However, there were two problems, they mis-emphasized normal regions and included poor performance of false positives reduction. The proposed method added CNN using grayscale images, and the false positives reduction was improved based on compression of the features dimension for NN.

Key words: Retinal Image, Diabetic Retinopathy, Microaneurysm, Convolution Neural Network, Delete False Positive Candidate

Liver segmentation from low radiation dose pediatric CT using a patient-specific statistical shape modeling

Koyo NAKAYAMA[*1], Atsushi SAITO[*1], Elijah BIGGS[*2], Marius George LINGURARU[*2], Akinobu SHIMIZU[*1]

Abstract

In this paper, we propose a liver segmentation algorithm for a pediatric computed tomography (CT) scan using a patient-specific statistical shape model (SSM). The pediatric CT volume is acquired at a low dose because radiation is harmful to young children. Consequently, the pediatric CT volume has lower signal-to-noise ratio, which makes the organ segmentation task difficult. Although an SSM-based segmentation algorithm can handle such low-quality CT volumes, no SSM of a pediatric liver has been proposed. Since children's livers have higher variability in terms of shape and size compared with adults, conventional SSM designed for adults may have some limitations when describing children's livers. To overcome this issue, we propose a patient-specific SSM that can describe differences in shape and size caused by patient age. Given the patient-specific SSM, a patient-specific probabilistic atlas is constructed and used to estimate the posterior probability distribution for liver segmentation. The liver segmentation algorithm was tested on 42 CT volumes of children aged between two weeks and seven years. The accuracy of segmentation results using the patient-specific SSM is 0.821, which is superior to that of the non-conditional SSM with statistically significant difference ($p = 1.8 \times 10^{-3} < 0.01$).

Keywords：computed tomography, segmentation, liver, child, statistical shape model

1. Purpose

Most computer-aided diagnosis (CAD) systems for medical imaging are designed for adults [1]. Very few studies have focused on children whose anatomy as well as findings of diseases are different from adults. Sudhin et al. [2] estimated the weight of organs including the liver from post-mortem magnetic resonance (MR) images of children, but manual segmentation was necessary for images with insufficient contrast. In addition, variations in the shape, size, and location of children's organs are greater than those of adults, which makes organ segmentation by CAD system difficult. Another difficulty is the low signal-to-noise ratio (SNR) caused by low-dose imaging because the use of radiation in pediatric imaging is minimized to reduce its harmful effects.

Since the characteristics of diseases are different among organs, diagnostic algorithms are typically developed specific to each organ. Therefore, organ segmentation is helpful to a CAD system. In the segmentation process, the statistical shape model (SSM) of an organ plays an important role by providing

*1 Tokyo University of Agriculture and Technology
〔2-24-16 Naka-cho, Koganei, Tokyo 184-8588, Japan〕
e-mail: s175477r@st.go.tuat.ac.jp
*2 Sheikh Zayed Institute for Pediatric Surgical Innovation, Children's National Health System
〔111 Michigan Avenue, NW Washington, DC 20010, USA〕

a superior shape prior of a given image, which makes the segmentation robust against the aforementioned difficulties. It is, however, difficult to construct an SSM that can accurately describe the shape of a child's organ because of large variations in shape, size, and location.

The overall goal of this paper is to propose a CAD system for computed tomography (CT) volumes of children. We propose a segmentation process of the pediatric liver with a conditional SSM [3], where the shape prior of a given image is generated by the conditional SSM. The shape prior dramatically increases the robustness of segmentation against large variations in shape, size, and location of the organ as well as low SNR. This paper presents the experimental results of applying the proposed liver segmentation algorithm to 42 CT volumes to demonstrate the effectiveness of the method.

2. Method

The inputs of the proposed segmentation algorithm are the abdominal CT volumes of children, with age used as a condition of the SSM, and four anatomical landmarks (i.e., outer tip of the eighth right and left ribs, the tip of tenth thoracic spinous process, and the tip of the fourth lumbar spinous process) were manually identified. We employed a basic segmentation framework that consists of three steps: (i) spatial standardization of the image using rigid registration between the input landmarks and the reference model computed by partial Procrustes analysis of the training dataset; (ii) estimation of parameters of the intensity distribution of an input CT volume using the atlas-guided expectation-maximization (EM) algorithm [4]; and (iii) the liver region extraction by maximum a posteriori (MAP)-based segmentation. We used a patient-specific probabilistic atlas (PA) generated by the conditional SSM in the atlas-guided EM algorithm, instead of a PA generated by non-conditional SSM. The advantage of the conditional over non-conditional SSM is that the shapes are more locally distributed and the resulting PA yields better parameter estimation.

3. Results

We conducted a two-fold cross-validation study using 42 cases of abdominal CT volumes of children aged between two weeks and seven years. The size of input CT volume was 512 × 512 × 109–747 voxels, with voxel size of 0.291–0.625 × 0.291–0.625 × 0.625–3 mm^3. The image size after spatial standardization was 512 × 512 × 512 voxels with 0.5 mm isotropic voxel size. We assumed intensity distribution with a mixture of four Gaussians (one liver class and the three other classes) in the atlas-guided EM algorithm. Segmentation accuracy was evaluated by the Jaccard index (JI) of an extracted region and manually delineated true liver region. The segmentation results using our conditional SSM were compared with those obtained with the non-conditional SSM.

The average JI when using the conditional SSM was 0.821 ± 0.073, while that of the non-conditional SSM was 0.812 ± 0.084. As shown in Fig 1, JI improved for most cases with the use of the conditional SSM. We found a large improvement in JI for the cases with relatively large or small liver. We performed the Wilcoxon signed-rank test between these JIs, and significant difference with $p < 0.01$ was observed ($p = 1.8 \times 10^{-3}$). Fig 2 shows the segmentation results of a case with a larger-sized liver than the average. The PA based on the non-conditional SSM had some difficulty describing the shape of the liver, which resulted in undersegmentation (see red arrows in Fig 2). The conditional SSM reduced this error owing to the successful estimation of patient-specific PA.

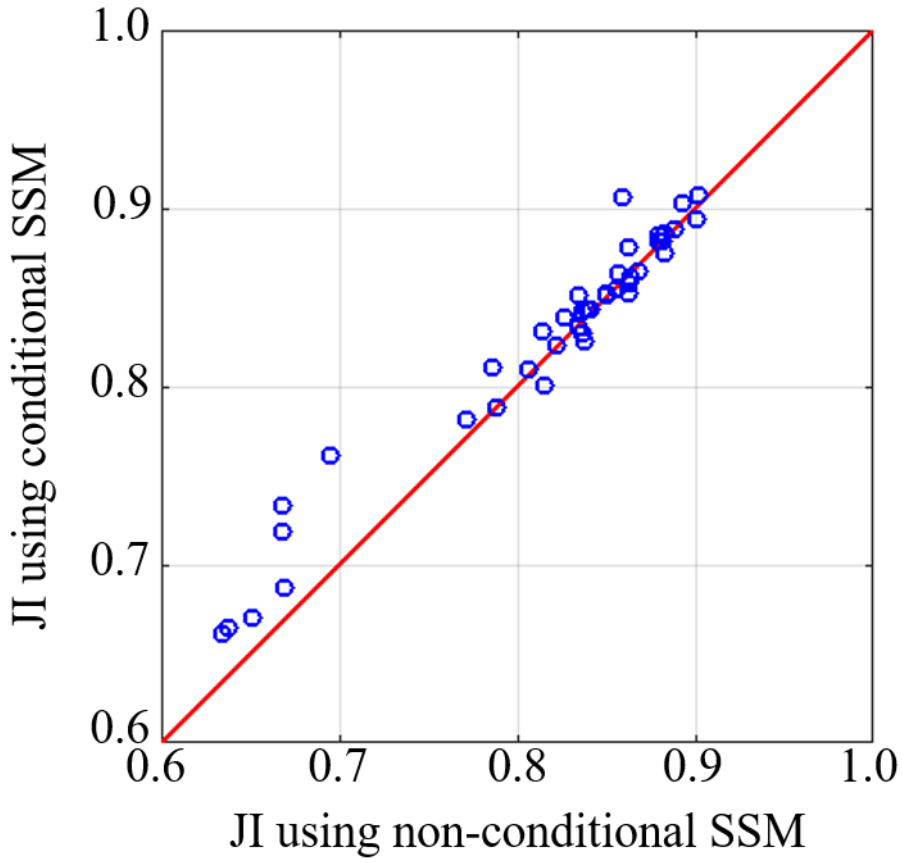

Fig 1. JI of the segmentation results. The values along the vertical and horizontal axes show the JI using the conditional and non-conditional SSM, respectively.

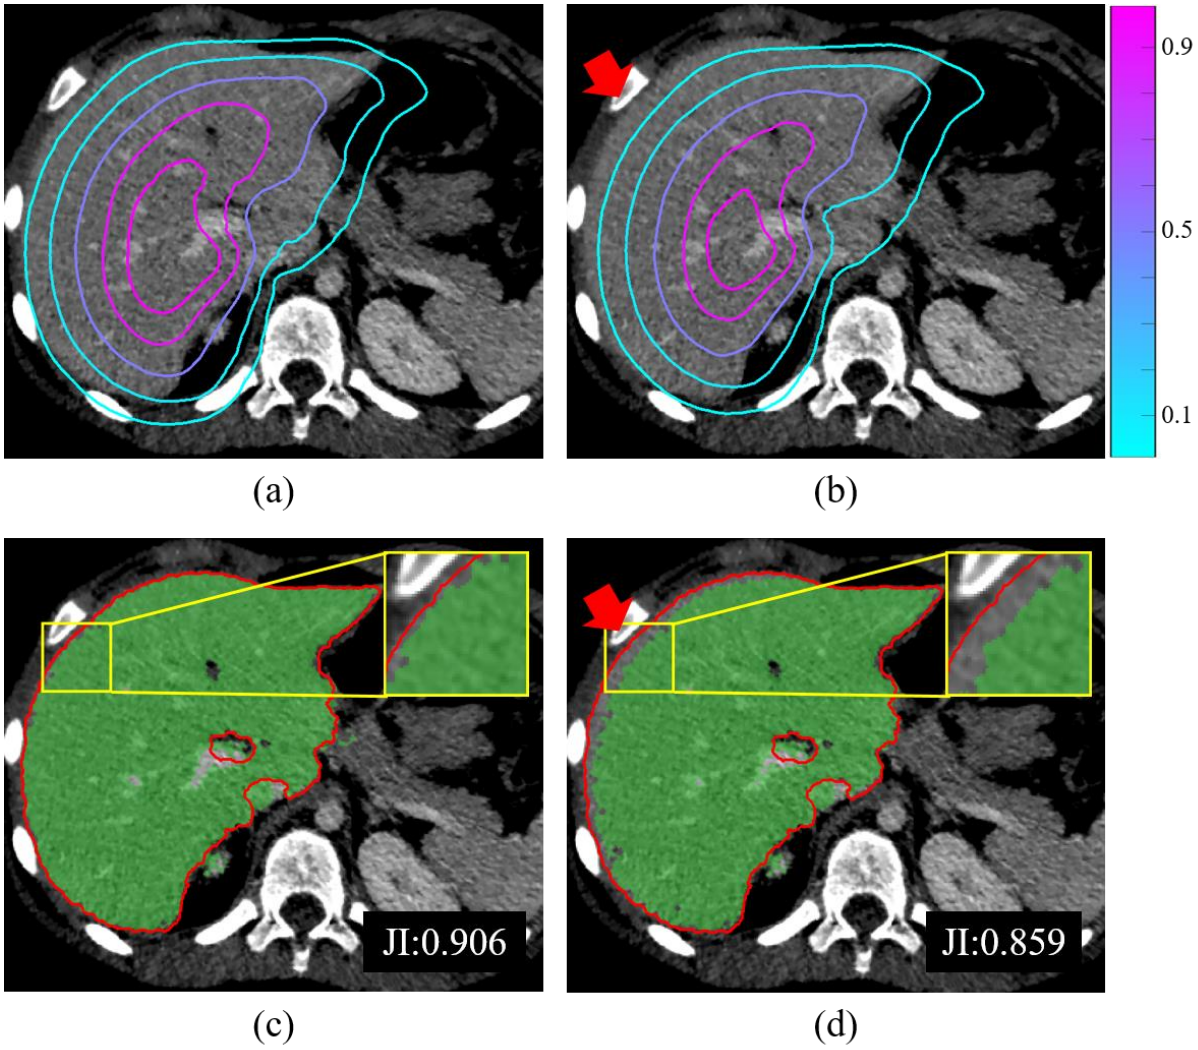

Fig 2. The upper row shows iso-contour lines of PA using (a) conditional SSM and (b) non-conditional SSM. The lower row shows the segmentation results of the example shown in the upper row using (c) conditional SSM and (d) non-conditional SSM.

4. Conclusion

We conducted liver segmentation from pediatric CT volumes using the conditional SSM adapted to the age of patients. The intensity distributions of the liver and the three other classes were estimated by the atlas-guided EM algorithm, where we used patient-specific PA generated by the conditional SSM as a prior. Liver segmentation was then performed by MAP rule using the resulting posterior probability. The PA represented larger- or smaller-sized livers better and yielded more accurate liver segmentation results. Liver segmentation according to age was found to be effective for CT volumes of children.

Competing interests

We don’t have any competing interests.

References

[1] Kunio Doi: Computer-Aided Diagnosis in Medical Imaging: Historical Review, Current Status and Future Potential. Comput Med Imaging Graph **31**: 198-211, 2007

[2] Sudhin Thayyil, Silvia Schievano, Nicola J. Robertson et al: A semi-automated method for non-invasive internal organ weight estimation by post-mortem magnetic resonance imaging in fetuses, newborns and children. European Journal of Radiology **72**: 321-326, 2009

[3] Sho Tomoshige, Elco Oost, Akinobu Shimizu et al: A conditional statistical shape model with integrated error estimation of the conditions; Application to liver segmentation in non-contrast CT images. Medical Image Analysis **18**: 130-143, 2014

[4] Akinobu Shimizu, Rena Ohno, Takaya Ikegami et al: Segmentation of multiple organs in non-contrast 3D abdominal CT images. International Journal of Computer Assisted Radiology and Surgery **2**: 135-142, 2007

CycleGAN による異種モダリティ画像生成を用いた 股関節 MRI の筋骨格セグメンテーション

松岡　拓未[*1]　日朝　祐太[*1]　大竹　義人[*1]　高尾　正樹[*2]

高嶋　和磨[*2]　Jerry L. Prince[*3]　菅野　伸彦[*2]　佐藤　嘉伸[*1]

要旨

医用画像からのセグメンテーションは，定量的な診断や患者個別のシミュレーションのため重要である．医用画像は，その撮像モダリティにより異なる特徴をもつ．CT は骨の構造を明瞭に撮影することができるのに対して，MR は軟組織の構造を明瞭に撮影することができる．このような違いはセグメンテーションにおいても考慮する必要がある．そこで本研究では，CycleGAN を用いて MRI から同患者同姿勢の CT 画像を生成することにより，セグメンテーションに活用する手法を提案する．本稿では，生成前後の画像の画像の類似度を考慮した手法とラベルデータを用いた制約を用いる手法の比較検討を行った．

キーワード：画像生成，セグメンテーション，CT 画像，MR 画像，股関節

1. はじめに

人工股関節全置換術において，術前筋萎縮の定量評価は，術後の筋力および日常生活動作の回復や転倒リスクを予測し，リハビリメニューを考慮する上で重要である．3 次元的な筋萎縮評価を行うためには，3 次元画像から筋骨格領域の抽出を行う必要がある．しかし，筋骨格領域の抽出は，整形外科医にとって集中力を要する負担の大きい作業であり，股関節では 1 症例あたり約 40 時間もの作業時間を要する．そのため，股関節 CT 画像あるいは MR 画像からの筋肉および骨領域の自動抽出手法の開発が求められる．

我々は，これまでに階層的マルチアトラス法，畳み込みニューラルネットワーク（CNN）を用いた股関節 CT 画像からの筋肉領域の自動抽出手法を提案した [1,2]．さらにこれらの手法の MR 画像への適用を検討している．しかし，既存手法は，ラベル付き学習データを必要とするため，MR 画像でも同様に手法を適用しようとする場合，その対象となるモダリティ毎に手動領域抽出し，ラベル付きデータを作成する必要がある．そこで我々は，異種モダリティ画像生成に着目し，抽出対象 MR 画像を CT 画像に変換し，これまでに開発した手法[1,2]の MR 画像への適用を目指している．

*1 奈良先端科学技術大学院大学 先端科学技術研究科 情報科学領域
〔〒630-0192 奈良県生駒市高山 8916-5〕
e-mail: {otake, yoshi}@is.naist.jp
*2 大阪大学大学院 医学研究科
*3 Department of Electrical and Computer Engineering, Johns Hopkins University
投稿受付：2018 年 5 月 15 日

従来，異種モダリティ画像生成には対応ありの学習データが必要であったが，近年CycleGAN [3]と呼ばれる対応なしの学習データでも画像生成技術が開発された．しかし，生成された画像が元の画像の形状を保つことが容易ではない．そこで，我々はこれまでに，生成前後の画像の類似度を考慮した CycleGAN と，学習データのバリエーション（学習データ数）に対する画像生成の精度の調査を行ってきた[4]．一方で，ラベルデータを用いた制約を加えた CycleGAN も提案されている[5]．そこで，本稿では，生成前後の画像の画像の類似度を考慮した手法とラベルデータを用いた制約を用いる手法の比較検討を目的とする．

2. 手法

本稿では，2 種類の CycleGAN による MR 画像からの自動抽出を比較する．一つは，生成前後の画像の類似度を考慮した CycleGAN である．もう一つはラベルデータを用いた制約を加えた CycleGAN である．

2.1 CycleGAN

CycleGAN の概要図を図 1 に示す．ネットワークG_{CT}とG_{MR}はそれぞれ，MR 画像を CT 画像に変換する生成器(G)，CT 画像を MR 画像に変換する生成器(D)である．ネットワークD_{CT}とD_{MR}はそれぞれ本物の画像と生成画像を識別する識別器である．識別器が式(1)，式(2)を最大化することにより生成画像を識別しようとするのに対し，生成器は式(1)，式(2)を最小化することで本物の画像と識別不能な画像を生成する．

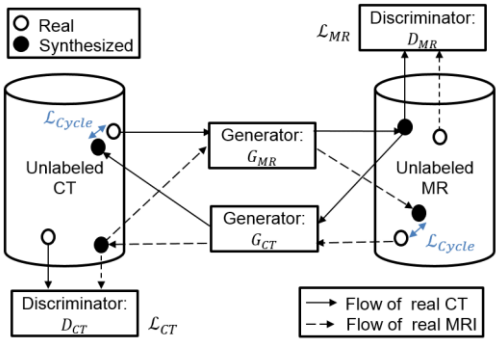

図 1　CycleGAN

$$\mathcal{L}_{CT} = \sum_{x \in I_{CT}} \log D_{CT}(x) + \sum_{y \in I_{MR}} \log(-D_{CT}(G_{CT}(y))) \quad (1)$$

$$\mathcal{L}_{MR} = \sum_{y \in I_{MR}} \log D_{MR}(y) + \sum_{x \in I_{CT}} \log(-D_{MR}(G_{MR}(x))) \quad (2)$$

ここで，x，yはドメインI_{CT}，I_{MR}から得られた画像である．さらに，MR 画像の対応する CT 画像を得るため，Cycle-consistency が用いられる．Cycle-consistency は本物の画像と再構成された画像の差である．Cycle-consistency は式(3)で定義される．

$$\mathcal{L}_{Cycle} = \sum_{x \in I_{CT}} |G_{CT}(G_{MR}(x)) - x| + \sum_{y \in I_{MR}} |G_{MR}(G_{CT}(y)) - y| \quad (3)$$

目的関数は式(4)で表される．

$$\mathcal{L}_{total} = \mathcal{L}_{CT} + \mathcal{L}_{MR} + \lambda_{Cycle}\mathcal{L}_{Cycle} \quad (4)$$

ここで，λ_{Cycle}は重み係数である．

式(5)を最小・最大化することで，それぞれのネットワークを学習する．

$$\hat{G}_{MR}, \hat{G}_{CT} = \arg \min_{G_{CT}, G_{MR}} \max_{D_{CT}, D_{MR}} \mathcal{L}_{total} \quad (5)$$

最後に，生成された画像から筋骨格領域のラベルを U-Net[5]により自動抽出することで，異種モダリティからのセグメンテーションを行う．

2.2 CycleGAN + Gradient-consistency loss

CycleGAN は生成された画像が元の画像の形状を保つことが容易ではない．そこで，我々はこれまでに，生成前後の画像の類似度を考慮した CycleGAN を提案している[4]．勾配相関を用いた損失（GC loss）は式(6)で定義される．

$$\mathcal{L}_{GC} = \frac{1}{2}\left(\sum_{x \in I_{CT}} (1 - GC(x, G_{MR}(x))) + \sum_{y \in I_{MR}} (1 - GC(y, G_{CT}(y)))\right) \quad (6)$$

2.3 Ess-Net (Label-consistency loss)

ラベルデータを用いた制約を加えた CycleGAN も提案されている[5]. この手法の 概要図を図 2 に示す．この手法は生成器，識別器に加えて抽出器(S)も同時に学習する．正解ラベ

ルと抽出器が抽出したラベルとの誤差を学習に反映させることで，形状を保った画像変換が期待できる．ラベルによる損失は式(7)の交差エントロピーで定義される．ただし，tは CT 画像の正解ラベル，iは画素のインデックスである．

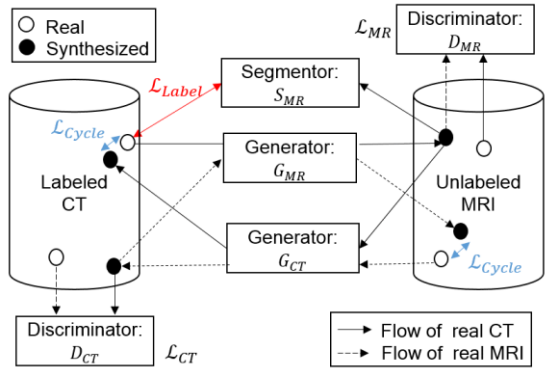

図 2　Ess-Net

$$\mathcal{L}_{Label} = -\sum_{i} t_i \log S_{MR}(G_{MR}(x_i)) \qquad (7)$$

3. データセット

本研究では，大阪大学病院で撮影された 312 症例の MR 画像（3D SPGR）と 633 症例の CT 画像を用いた．CT 画像のうち 20 症例は中殿筋，小殿筋を含む 19 の筋肉，骨盤，大腿骨，仙骨が手動で抽出されている．また，MR 画像のうち 10 症例は中殿筋，小殿筋，骨盤，大腿骨が手動で抽出されている．

MR 画像の Field of view は 320×320 [mm^2]，マトリックスサイズは 256×256，スライス間隔は 2.0 [mm]である．CT 画像の Field of view は 360×360 [mm^2]，マトリックスサイズは 512×512，スライス間隔は 1.0～6.0 [mm]で撮影した後，ボリューム全体が 1.0 [mm]となるように補間した．また，Field of view が MR 画像と同様になるよう切り抜き，256×256 にリサイズした．

4. 実験

本稿では，以下の 2 つの実験を行った．1) Gradient-consistency を考慮した CycleGAN を用いた手法でセグメンテーション精度と Label-consistency を考慮した Ess-Net を比較した．さらに，2) 本物の MR 画像と生成 MR 画像の差の調査のために，Ess-Net の一部として学習された抽出器S_{MR}を用いて本物の MR 画像と生成 MR 画像からの抽出を行い，その精度を比較した．

4.1 CycleGAN+U-Net と Ess-Net の比較

定量評価には，MR の手動ラベルと異種モダリティ画像生成を用いたセグメンテーション結果の Dice 係数を用いた．また，学習データ数を公平にするために，Ess-Net は CycleGAN で事前学習し，その後 MR 画像とラベル付きの CT 画像のみを用いて転移学習された．

図 3 に Gradient-consistency を考慮した CycleGAN によって生成された画像の抽出結果と，Ess-Net による抽出精度の比較を示す．図 3 より，Ess-Net の精度が上回っているのは中殿筋のみである．

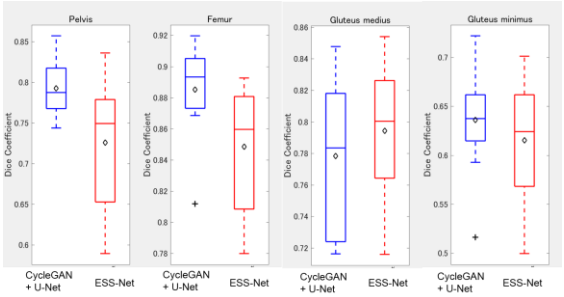

図 3　CycleGAN+U-Net (with GC loss) と Ess-Net の比較

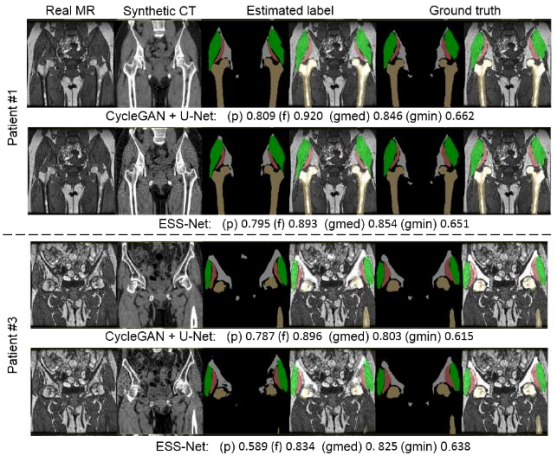

図 4　画像生成と自動抽出結果の典型例．p, f, gmed, gmin は，骨盤，大腿骨，中殿筋，小殿筋の Dice 係数を示す．

4.2 本物の MR 画像と生成 MR 画像の差の調査

本物の MR 画像と生成 MR 画像の差を調査するために，生成された MR 画像から筋骨格領域を抽出し定量評価を行った．まず， MR 画像とラベル付き CT 画像を用いて Ess-Net の学習を行った．テスト時には，CT 画像からターゲットとなる MR 画像を生成した．評価尺度には，CT の手動ラベルと生成 MR 画像からのセグメンテーション結果の Dice 係数を用いた．ただし，CT 画像データセットは，2-fold に分割し，交差検証により行った．

結果を図 4 に示す．実験 4.1 で評価した Ess-Net のセグメンテーション結果と比較した．いずれの領域についても生成 MR 画像からの抽出精度と本物の MR 画像からの抽出精度に差があることがわかる．これより，生成 MR 画像と本物の MR 画像に違いがあると考えられる．

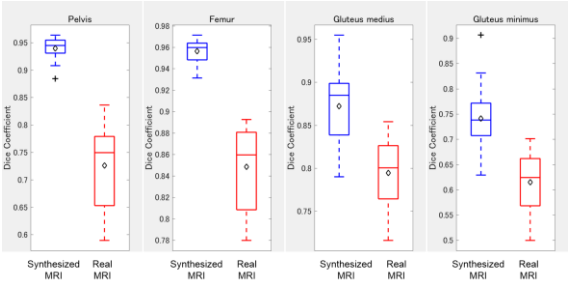

図 4　本物の MR 画像と生成 MR の差の調査

5. 考察

先行研究において，学習データの数は，画像生成およびセグメンテーションの精度に影響を与えることが示唆されている[4]．今回の実験では Ess-Net の転移学習では，CT 画像はラベルを有する 20 症例しか用いていないため，300 症例を用いた CycleGAN と比較して，画像生成の精度が低下したと考えられる．よって今後，Ess-Net の学習には，自動セグメンテーションした 300 症例を加えて，学習データのバリエーションを増やす必要があると考えられる．ただし，この場合，自動セグメンテーション手法による抽出誤差が，画像生成に与える影響についても同時に調査する必要がある．

ところで，Ess-Net は元論文では脾臓領域の抽出精度しか報告されていない[5]．今回の実験でも中殿筋では向上したがその他では CycleGAN の方が上回ったので，Ess-Net は全ての領域において精度が向上する可能性は低いと考えられる．しかしながら，Ess-Net のパラメータのチューニングが十分でない可能性も考えられる．

実験 4.2 において，本物の MR 画像からの抽出精度に比べて，CT 画像から生成した MR 画像からの抽出精度は高くなった．すなわち，生成された MR 画像は元の CT 画像の大まかな形状を保っているが，生成された MR 画像では本来の MR 画像に含まれるテクスチャや空間周波数が表現できていない可能性が考えられる．

4. まとめ

本研究では，生成前後の画像の類似度を考慮した手法とラベルデータを用いた制約を用いる手法の比較を行った．また，本物の MR 画像と生成 MR 画像の差が大きいため，セグメンテーションの精度が低下している可能性があることを示した．今後は，このドメインシフトの影響を軽減するアプローチ[5]を取り入れ，本物の MR 画像と生成 MR 画像の差に頑健なセグメンテーション手法を検討したいと考えている．

謝辞

本研究の一部は， MEXT/JSPS 科学研究費補助金，新学術領域「多次元計算解剖学」(No.26108004)， JST さきがけ「ビッグデータ統合活用のための次世代基盤技術の創出・体系化」，の支援による．

利益相反の有無

なし

文　献

[1] Yokota, Futoshi, et al. "Automated muscle segmentation from CT images of the hip and thigh using a hierarchical multi-atlas method." International journal of computer assisted radiology and surgery (2018): 1-10.

[2] 日朝祐太，大竹義人，横田太, et al. "畳み

込みニューラルネットワークを用いた CT 画像からの股関節および大腿部の筋骨格領域自動抽出" 電子情報通信学会技術研究報告 (2017) vol. 117, no. 280

[3] Zhu, Jun-Yan, et al. "Unpaired image-to-image translation using cycle-consistent adversarial networks." arXiv preprint arXiv:1703.10593 (2017).

[4] Hiasa, Yuta, et al. "Cross-modality image synthesis from unpaired data using CycleGAN: Effects of gradient consistency loss and training data size." *arXiv preprint arXiv:1803.06629* (2018).

[5] Huo, Yuankai, et al. "Adversarial Synthesis Learning Enables Segmentation Without Target Modality Ground Truth." *arXiv preprint arXiv:1712.07695* (2017).

[6] Ronneberger, Olaf, Philipp Fischer, and Thomas Brox. "U-net: Convolutional networks for biomedical image segmentation." *International Conference on Medical image computing and computer-assisted intervention*. Springer, Cham, 2015.

[7] “Learning from Synthetic Data: Addressing Domain Shift for Semantic Segmentation”, arXiv:1711.06969 (2017)

CycleGAN-based image synthesis for multi-modality musculoskeletal segmentation of hip MRI

Takumi MATSUOKA[*1], Yuta HIASA[*1], Yoshito OTAKE [*1], Masaki TAKAO [*2], Kazuma TAKASHIMA[*2], Jerry L. PRINCE[*3], Nobuhiko SUGANO[*2], Yoshinobu SATO[*1]

*1 Graduate School of Information Science, Nara Institute of Science and Technology

*2 Graduate School of Medicine, Osaka University

*3 Department of Electrical and Computer Engineering, Johns Hopkins University

Segmentation from medical images facilitates quantitative diagnosis and patient-specific modeling. Different types of medical image have different advantages and disadvantages: Boundaries of bones look clear in CT images, while MRIs capture structure of soft tissue in detail. These features should be taken into account for segmentation. We aim for a segmentation method in which an CT image is synthesized from the corresponding MRI. In this paper, we compared two segmentation methods: one that reflects the similarity between an original image and synthetic image and one that restrict the structure based on the structure of labels.

Key words: Image synthesis, Segmentation, CT image, MR image, Musculoskeletal region

CNN を用いた単純 X 線画像における腰椎椎体部の検出およびラベリング

高田　真弘[*1]　木下　彰[*1]　川端 茂徳[*2]

要旨

医用画像装置の発展に伴い，MRI などの形態画像を用いて診断を支援するシステムが注目されている．特に，脊椎側彎症などの脊椎に関する症状において異常箇所を提示するような診断支援システムの要求が高まっている．これらのシステム全般で最も重要な技術は，異常箇所の部位を高精度に特定することである．また，ユーザが介入することなく，全自動で処理を行うシステムを実現できればユーザの負担を軽減することができる．本研究では，腰部の単純 X 線画像から部位の特定をすることを目的としており，CNN を用いて腰部の単純 X 線画像からの腰椎椎体部と椎間板と仙骨の検出をし，各部位のラベリングまでを全自動で行う手法を提案する．CNN の前処理を工夫し，粒状ノイズ，低コントラストを含む画像においても頑健に検出ができる．評価画像 60 枚を用いた評価により，93.3%の高ラベリング精度を得た．

キーワード：CNN，単純 X 線画像，腰部，検出，ラベリング

1. はじめに

近年，医用画像装置の発展に伴い，MRI などの形態画像を用いて診断を支援するような診断支援システムが注目されている．特に，脊椎に関する症状，例えば，脊椎側彎症などの異常な箇所の提示するシステムなどの要求が高まっている．しかし，異常な箇所を提示するだけではなくて，何番目のどの部位に問題があるのか(例えば，3 番目の腰椎椎体部に異常がある等)についても特定する必要がある．更に，医師の負担軽減という観点から考えると，診断したい領域を指定する等の手動での作業を要するシステムではなく，完全に自動で処理されるシステムであることが望ましい．そこで，我々は腰部の単純 X 線画像に対して，腰椎椎体部と椎間板と仙骨を自動で検出すると供に，検出した腰椎椎体部・椎間板と仙骨が何番目の部位かを特定するラベリング処理を開発した．

本研究では，単純 X 画像からの腰椎椎体部と椎間板と仙骨の検出についても自動で検出を行い，その検出結果に基づきラベリングを実施する手法について提案する．また，腰椎椎体部と椎間板と仙骨のラベリング精度について評価した結果を示す．

*1 株式会社リコー　研究開発本部　リコーICT 研究所　AI 応用研究センター　第 2 ソリューション開発グループ
〔〒243-0460 神奈川県海老名市泉二丁目 7 番 1 号〕
e-mail: masahiro.mt.takada@jp.ricoh.com
*2 東京医科歯科大学　大学院医歯学総合研究科　先端技術医療応用学講座・特任教授　東京都文京区湯島 1-5-45

2. 関連研究

単純 X 線画像から脊椎の椎体部を検出する目的として多くの研究で対象とされている部位は頚椎であり，単純 X 線画像を用いた腰椎検出に関する文献は少ない．そのため，まず頚椎椎体部の検出手法から説明していく．頚椎椎体

部の検出手法には，X 線画像の頚椎領域を手動で指定した後に指定された領域内から頚椎椎体部を検出する手法と，X 線画像から直接頚椎椎体部を検出する手法の 2 つに大別される．例えば，Mohamed Amine Larhmam[1]は，X 線画像の頚椎領域を手動で指定した後に，エッジ抽出によって抽出した輪郭から頚椎椎体部の平均モデルを作成し，そのモデルを用いて一般化ハフ変換を行い，検出された頚椎椎体部の候補点に対して k-means のクラスタリングをすることで頚椎椎体部の中心を検出する手法を提案している．また，Fabian Lecron[2]は，X 線画像から直接頚椎椎体部を検出するために，edge polygonal approximation アルゴリズムで検出された特徴点に対して SIFT 特徴量を求め，SVM を用いて特徴点を分類することによってユーザによる頚椎領域の指定なしに頚椎椎体部を検出する手法を提案している．一方，X 線画像から腰椎を検出する技術としては，Ruhan Sa[3]が，腰椎椎体部を検出するために，HOG 特徴量と multi-stage SVM を用いる手法を提案している．しかしながら，手法[3]ではラベリングまでは実施できていないこと，HOG 特徴量を用いていることから，コントラストの変化に弱く，特定の条件において撮影して得られた X 線画像に限定されるという課題がある．

そこで，我々は，CNN を用いて単純 X 線画像における腰部の腰椎椎体部・椎間板・仙骨の検出とラベリングまでを全自動で行う手法を提案する. CNN を用いることでノイズやコントラストの変化に対して頑健な検出ができ，仙骨の検出を可能にしたことで，仙骨を基準点としたラベリングができる．また，腰椎椎体部・椎間板・仙骨の 3 つの部位の検出ができることから，ラベリング処理で利用できる情報が増えたことで，高精度なラベリングを実現した．

3. 提案手法

3.1 提案手法の概要

提案手法の流れを図 1 に示す．まず，腰椎椎体部・椎間板・仙骨の検出を行うために必要な学習画像とその前処理について 3.2 節にて説明

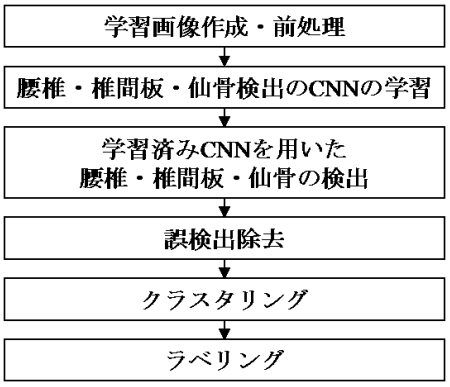

図 1　提案手法の流れ

する. CNN のネットワーク構成と学習方法について 3.3 節で説明する．3.4 節では，3.3 節で説明した CNN の学習モデルを用いて，腰椎椎体部と椎間板と仙骨の検出を行い，3.5 節では検出結果から誤検出点を除去する方法について説明し，3.6 節では誤検出除去後の検出点の情報を基に各部位毎の代表点を算出するクラスタリング方法について説明を行う．最後に，3.7 節では算出した代表点の情報を基に腰椎椎体部，椎間板，仙骨のラベリング処理について説明をする．

3.2 学習画像・前処理

CNN を用いた検出を行うためには学習画像が必要となる．提案手法では腰椎椎体部・椎間板・仙骨の検出を行うことからこれら 3 つの部位を取り囲むような矩形領域を単純 X 線画像から切り取ることに加えて，3 つの部位以外の

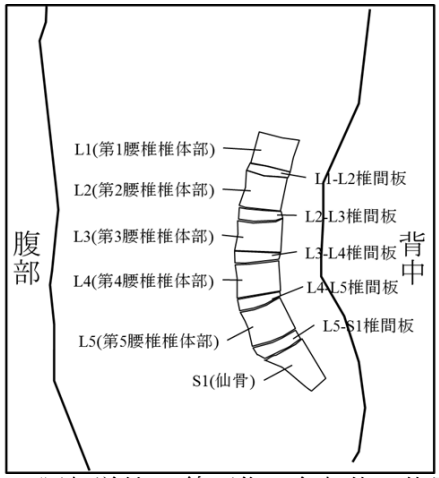

図 2　腰部単純 X 線画像の各部位の位置

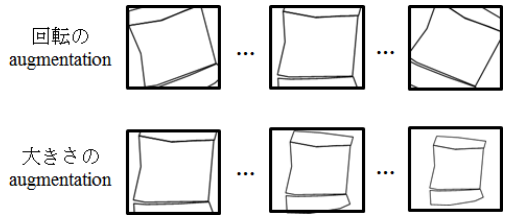

図 3　回転と大きさの augmentation の概要

領域からランダムに矩形領域を切り出し，合計 4 つのクラスに分けて学習画像を切り出す（図 2）.

また, CNN では前処理が精度に大きな影響を与えることが知られている．提案手法では，学習画像の前処理として，図 2 のような腰部側面の単純 X 線画像に対して augmentation を行い，骨の曲がり具合を吸収できるように回転の augmentation を実施すると供に，骨の大きさを吸収できるように拡大縮小の augmentation を実施する．更に，ここで得られた画像に対して，画像ボケを吸収できるようにしガウシアンフィルタのカーネルサイズを変えて適用したボケの augmentation の実施し，ノイズを吸収できるようにノイズを画像に付加する augmentation を実施する．最後に，これらそれぞれの画像に対してコントラストの変化に対応できるように画像強調処理の実施を行う.

まず，骨の回転の augmentation では，予備実験から通常想定される回転の角度の 2 倍程度の augmentation を行うことで回転に対してロバストになることが判明したため，背骨の曲がり具合(局所的に見ればどの程度回転しているか)を吸収できるように，各部位毎に想定される骨の回転角度の 2 倍の回転角度で augmentation を実施する． 具体的には，画像の左側を腹部，右側を背中として, (時計回り方向:反時計回り方向:回転角度の刻み)とすると, 腰椎椎体部の画像に対しては(30° :60° :5°)，椎間板の画像に対しては(40° :60° :10°)，仙骨の画像に対しては(30° :60° :10°)，3 つの部位以外の領域の画像に対しては(5° :5° :1°)で augmentation を行う．同様に骨の大きさの augmentation においても想定される骨の大きさの変化量の 2 倍で augmentation を実施する．具体的には，腰椎椎体部，椎間板，仙骨の画像に対しては，矩形領域の縦幅=切り取る矩形領域の縦幅×(1 , 1.1, 1.2)，矩形領域の横幅=切り取る矩形領域の横幅×(1, 1.1, 1.2)のそれぞれ 3 通りの augmentation を実施し，3 つの部位以外の領域の画像に対しては，矩形領域の縦幅=切り取る矩形領域の縦幅×(1 , 1.1, 1.2, 1.3)，矩形領域の横幅=切り取る矩形領域の横幅×(1, 1.1, 1.2, 1.3)のそれぞれ 4 通りの augmentation を実施する（図 3）.

回転・大きさ・ノイズ・ボケの augmentation を行い切り出されたそれぞれの画像に対してコントラスト平坦化処理を実施することで前処理を終了とする.

3.3　CNN のネットワーク

3.2 節の前処理をした学習画像を CNN に入力し学習を行う．腰椎椎体部・椎間板・仙骨の検出に用いる CNN のネットワーク構造を表 1 に示す．conv はコンボリューション層，fc は全結合層，input は入力チャネル数，output は出力チャネル数を示している．損失関数には Softmax 関数，最適化手法には Adam，を利用した．また，出力層 fc8 で出力される 4 つのラベルはそれぞれ腰椎，椎間板，仙骨，腰椎・椎間板・仙骨以外に対応するラベルに設定することで検出を行う.

表 1　腰椎椎体部と椎間板と仙骨のネットワーク

	input	output	kernel size	stride	padding
conv1	1	48	5	2	0
conv2	48	128	3	1	1
conv3	128	192	3	1	1
conv4	192	192	3	1	1
conv5	192	128	3	1	1
fc6	128	128			
fc7	64	64			
fc8	64	4			

3.4　腰椎と椎間板と仙骨の検出

3.3 節で学習した学習済みの CNN を用いて X 線画像全体からの腰椎椎体部・椎間板・仙骨の検出を行う．図 4 に学習時と評価時の腰椎椎体部と椎間板と仙骨の検出の概要を示す．評価時

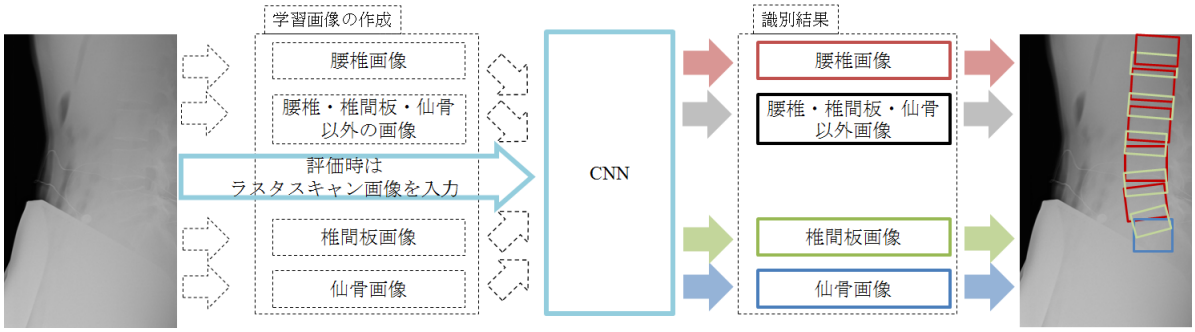

図 4　腰椎椎体部と椎間板と仙骨の検出の概要

は X 線画像全体に対してラスタスキャンを行い検出窓の切り出しを行う．腰椎椎体部・椎間板・仙骨の大きさの変化に対応するために，検出窓の大きさを変化させる．具体的には，入力画像サイズが 1722×1316pixel に対して，検出窓の stride は幅高さ共にそれぞれ 20 pixel とし，検出窓の大きさは幅 300 pixel×高さ 250 pixel を基準とし，1 stride 毎に幅を 300 pixel×(0.8, 0.9, 1.0, 1.1, 1.2)まで 5 通りで値を変化させ，高さは，幅毎に高さ 250×{幅の倍率+ (0.0, 0.1, 0.2)}の 3 通りで変化させる．全検出窓から X 線画像を切り出し，CNN の入力画像として適用する．出力層の 4 つのラベルの中で Softmax の値が最も高いラベルを用いることで，腰椎椎体部・椎間板・仙骨の検出を行う．

3.5　誤検出除去

腰椎椎体部・椎間板・仙骨の検出用 CNN によって出力された腰椎椎体部・椎間板・仙骨の検出点を基に，誤検出となっている腰椎椎体部・椎間板・仙骨の検出点を削除する手順を図 5，誤検出除去前後の結果を図 6 に示す．赤色が腰椎椎体部の検出点，緑色が椎間板の検出点，青色が仙骨の検出点を示している．

まず，仙骨として検出された点のみに対してクラスタリングし，最も検出点を多く含んでいるクラスタを仙骨の推定位置とし，その他のクラスタに属している候補点を削除する．

次に，仙骨の推定位置の情報を基に腰椎椎体部と椎間板の誤検出点を削除する．仙骨の推定位置よりも下側(足の方)にある腰椎椎体部と椎間板の検出点を削除する(図 5(b))．

図 5(b)の処理後に残った腰椎椎体部・椎間板・仙骨の検出点を用いて，図 5(c)のようにロバスト推定(RANSAC)を適用する．ここで利用した RANSAC は，繰り返し回数 k を 2000，次数を 3 で算出し，近似曲線からの距離が 150pixel 以内にある検出点を残し，それ以上に離れている点を削除することで，誤検出除去後の結果を得る．図 6(a)が誤検出除去前，図 6(b)が誤検出除去後の結果を示しており，腹部や背中周辺に存在していた誤検出点を削除できている．

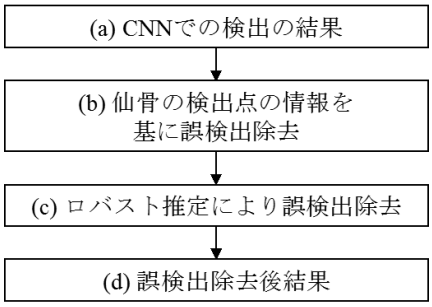

図 5　誤検出除去の流れ

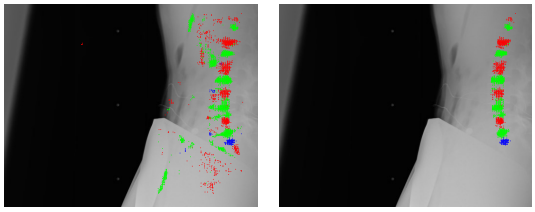

(a) 誤検出除去前　　(b) 誤検出除去後

図 6　誤検出除去の前後の結果

3.6　クラスタリング

誤検出除去後の検出点に対してクラスタリングを行い，クラスタリング結果を 3.7 節のラベリング処理に利用する．クラスタリングは腰椎椎体部・椎間板・仙骨の各部位毎に実施する．

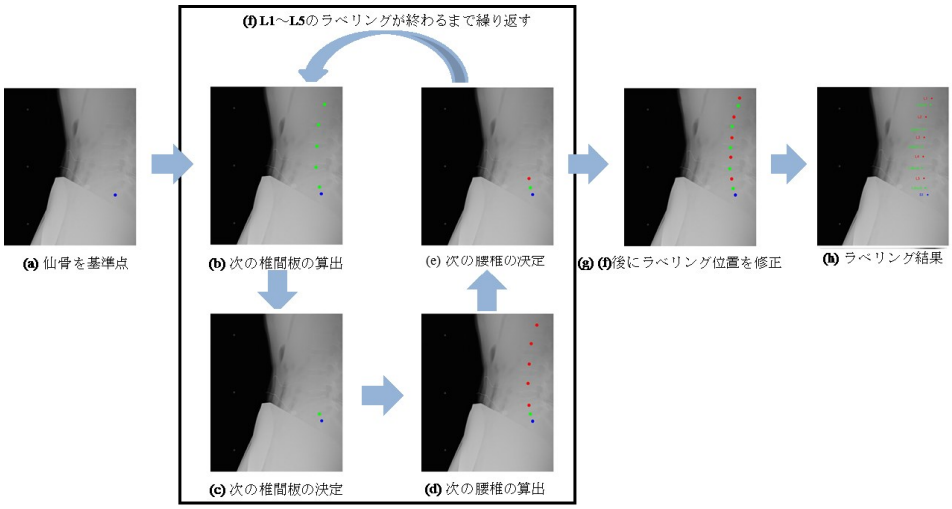

図 6　ラベリングの処理の概要

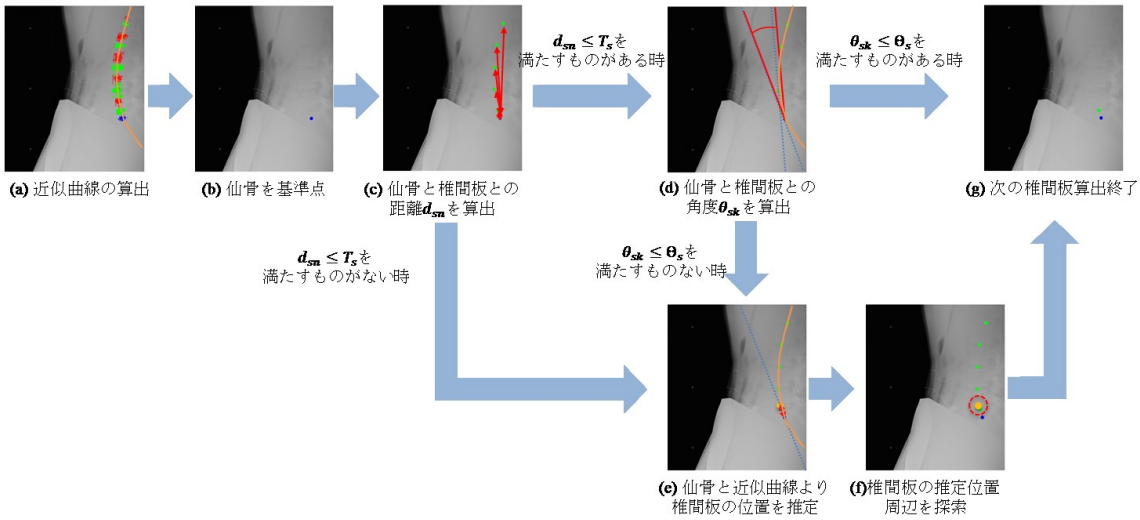

図 7　基準点の次点の位置を算出する処理の概要(仙骨基準の例)

また，今回のクラスタリングには Mean Shift を用い，カーネル幅 k=50 にて実施した．

3.7　ラベリング

3.6 節のクラスタリングの結果を用いて，腰椎椎体部・椎間板・仙骨のラベリングを実施する．ラベリングの処理の概要を図 6 に示す．

ラベリングには 3.6 節にてクラスタリングを行った腰椎椎体部・椎間板・仙骨の各クラスタの点を利用し実施する．まず，ラベリングでの基準として，図 6(a)のように，検出精度の高い仙骨の結果を基準点とする．図 6(b)では仙骨と各椎間板のクラスタ点間の距離と角度の情報を基に図 6(c)のように仙骨の次の椎間板を推定する．同様に，図 6(d)では，図 6(c)で推定された椎間板位置を基準点として，椎間板と各腰椎椎体部のクラスタ点間の距離と角度の情報を基に図 6(e)のように椎間板の次の腰椎椎体部を推定する．この図 6(b)~図 6(e)の処理を第 1 腰椎椎体部(L1)から第 5 腰椎椎体部(L5)のラベリングを推し終わるまで繰り返し実行する．図 6(g)では，推定された各ラベリング位置に対して，各ラベリング位置間の距離を用いることでラベリング位置の修正を行い，図 6(h)に示す最終的なラベリングの結果を得る．

図 6(b)と図 6(d)の腰椎椎体部と椎間板の推定算出方法の詳細について図 7 に示し説明する．ここでは基準点を仙骨とした場合の説明を行

う．まず，図 7(a)で誤検出除去後の検出点を通る 3 次の近似曲線を算出し，式(1)を得る．ここでp_nは近似曲線のパラメータであり，xは x 座標，yは y 座標を示している．

$$x = p_1 y^3 + p_2 y^2 + p_3 y + p_4 \quad (1)$$

図 7(b)ではラベリングを完了している位置の中で最も L1 に近い位置を基準点とする．ここでは，ラベリング処理の開始時であるため，仙骨を基準点とする．次に，図 7(c)では仙骨と次の椎間板候補の各クラスタ点との距離$D_s = \{d_{s1}, d_{s2}, \dots, d_{sn}\}$を算出する．閾値距離を$T_s$とすると，仙骨の座標より y 座標が小さく，かつ$D_s \leq T_s$を満たすものがある時は図 7(d)に進み，満たすものがない時は図 7(e)に進む．図 7(e)については後述する．図 7(d)では，仙骨と椎間板のなす角度$\Theta_s = \{\theta_{s1}, \theta_{s2}, \dots, \theta_{sn}\}$を算出する．式(1)を用いて，仙骨の y 座標の位置を通る接線と仙骨の検出枠分 y 座標を小さくした位置を通る接線を算出する．2 つの接線の角度をそれぞれθ_{T1}，θ_{T2}とする．θ_{T1}を中心としてθ_{T1}とθ_{T2}の差分だけ振った角度の範囲にあり，かつ仙骨の座標より y 座標が小さく，かつ$D_s \leq T_s$を満たすクラスタ点が存在する時は，その中でD_sの値が最も小さい値の点を図 7(g)のように次の椎間板位置として得る．この条件を満たさない時は図 7(e)に進む．図 7(e)では，式(1)の近似曲線と仙骨の y 座標y_sを用いて，y_sに対応するx_sを求め，y_sを通る接線を算出し，式(2)を得る．

$$y = ax + b \quad (2)$$

$$\begin{pmatrix} x_s = p_1 {y_s}^3 + p_2 {y_s}^2 + p_3 y_s + p_4 \\ \mathrm{a} = \dfrac{1}{3p_1 {y_s}^2 + 2p_2 y_s + p_3} \\ b = -a x_s + y_s \end{pmatrix}$$

式(2)を用いて，仙骨を基準に距離D離れた椎間板位置を推定する．

$$x_d = -\frac{ab - a y_s - x_s}{a^2 + 1} \pm \sqrt{\mathrm{abs}\left(\frac{D^2 - {x_s}^2 - (b - y_s)^2}{a^2 + 1} + \left(\frac{ab - a y_s - x_s}{a^2 + 1}\right)^2\right)} \quad (3)$$

$$y_d = a \cdot x_d + b \quad (4)$$

式(3)から 2 つの解が得られるため，式(3)と式(4)より，2 つの椎間板の推定位置候補の求められる．求められた椎間板推定位置の内 y 座標が小さい位置を椎間板の推定位置とする．

図 7(f)では図 7(e)で算出した椎間板推定位置を中心として，距離T_c内の範囲に椎間板のクラスタ点が存在するかを求めし，存在する場合はそのクラスタ点を椎間板位置として得る．クラスタ点が複数存在する場合は距離が近いクラスタ点を椎間板位置として得る．存在しない場合は，図 7(e)にて算出した椎間板推定位置を椎間板位置として取得し，次の椎間板位置の算出処理を終了する．同様に，次の処理では椎間板を基準点として次の腰椎椎体部の位置を算出する．更に次の処理では腰椎椎体部を基準点として椎間板の位置を算出する．この処理を L5 から順にラベリングをしていき L1 が求まるまで繰り返し行うことで腰部単純 X 線画像におけるラベリングを完了とする．

4. 結果

提案手法における条件を記載する．学習画像は augmentation を行った画像を含めて，各部位毎に腰椎椎体部：17043 枚，椎間板：11130 枚，仙骨：1551 枚，腰椎椎体部・椎間板・仙骨以外：120900 枚を作成して学習に用いた．CNN の学習時は学習画像を 32×32 にリサイズして入力画像とした．1 バッチ 200 枚とし，バッチ内の比率は，腰椎椎体部：椎間板：仙骨：腰椎椎体部・椎間板・仙骨以外の画像 ＝0.30 : 0.30 : 0.10 : 0.30 とし，epoch 数を 20 とした．

また，評価では，評価画像を 60 枚とした．ラベリングが成功か否かの判定は，ラベリング処理後の腰椎椎体部，椎間板，仙骨の算出位置が各部位内に収まっている場合を成功とする．

提案手法を用いた腰椎椎体部・椎間板・仙骨のラベリングの精度の結果を表 2 に示し，ラベリングの結果画像例を図 8 に示す．図 8(a)には成功した例を示し，図 8(b)には失敗した例を示す．表 2 では(a)に全ての部位でラベリングが成功した時のラベリング精度，(b)には各部位毎のラベリング精度，(c)には各部位ごとのラベリン

表 2　腰椎椎体部・椎間板・仙骨のラベリング精度の結果

(a) 全部位のラベリングが成功した時の精度

部位	L1～S1
ラベリング精度	93.3%

(b) 各部位毎のラベリング精度

部位	L	L_{disc}	S
ラベリング精度	96.3%	96.7%	98.3%

(c) 各部位毎のラベリング精度の詳細

部位	L1	$L_{disc}1$	L2	$L_{disc}2$	L3	$L_{disc}3$	L4	$L_{disc}4$	L5	$L_{disc}5$	S1
ラベリング精度	96.7%	95.0%	96.7%	96.7%	95.0%	96.7%	96.7%	96.7%	96.7%	98.3%	98.3%

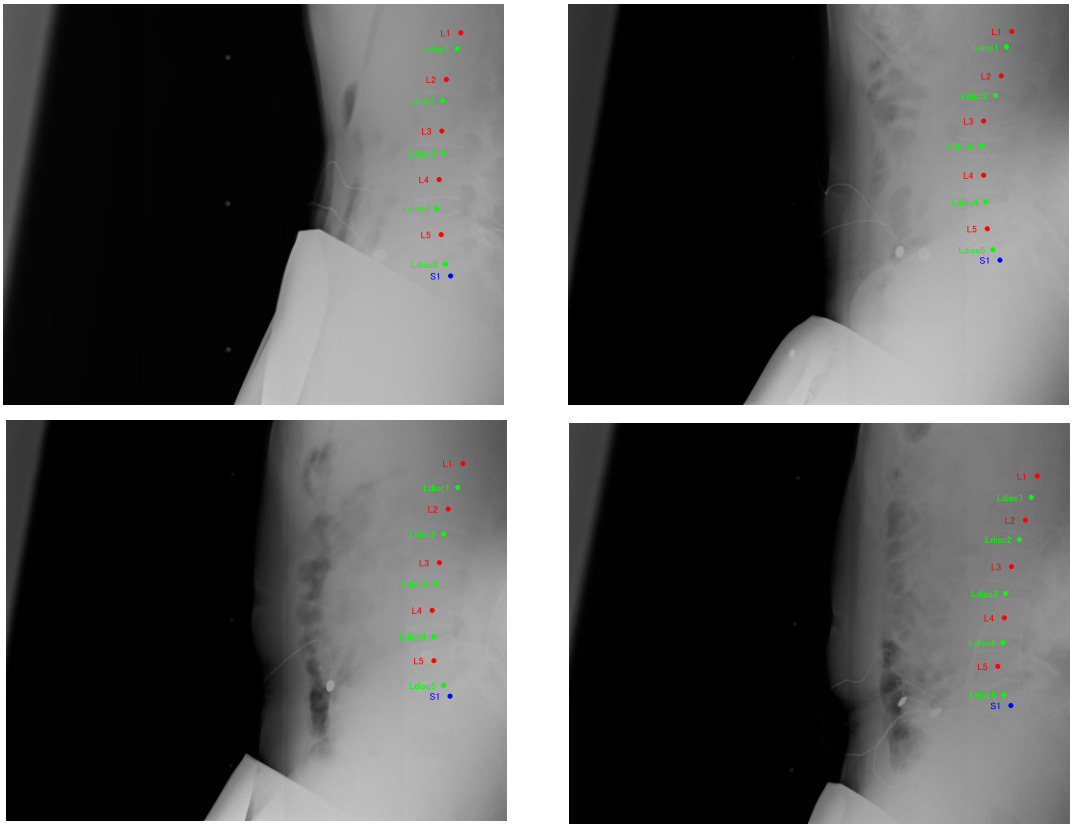

(a) 成功例

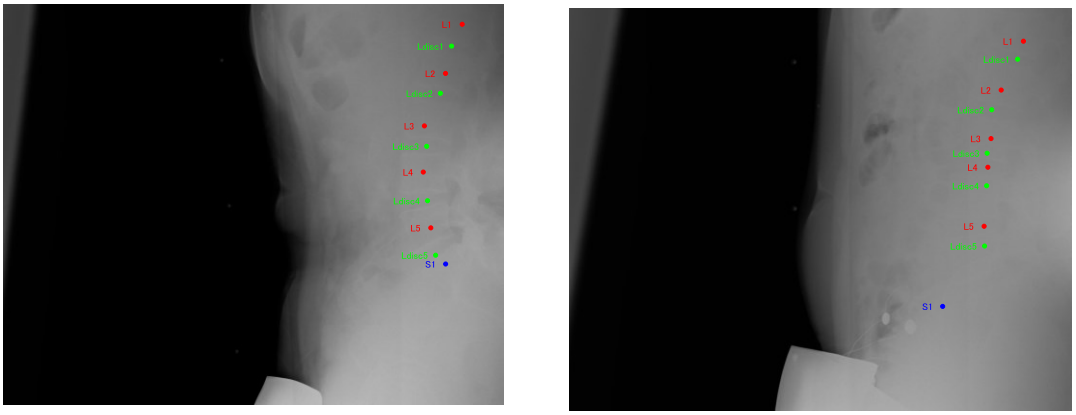

(b) 失敗例

図 8　腰椎・椎間板・仙骨の検出およびラベリング後の結果画像

グ精度の詳細を記載している．図 8(a)から低コントラストの X 線画像からでも腰椎椎体部・椎間板・仙骨のラベリングが出来ることが分かる．また，表 2(a)より，L1～S1 までのラベリングが全て成功しているものは，評価画像 60 枚中 56 枚であったことから，全部位のラベリング精度は 93.3%であった．また，表 2(b)より，各部位毎のラベリング精度は腰椎椎体部(L)・椎間板(L_{disc})・仙骨(S)でそれぞれ 96.3%, 96.7%, 98.3%といずれも高精度に推定できた．一方，図 8(b)では被験者が筋肉質な人あるいは体厚がある人のため十分な線量が受光されず，画質が著しく悪い X 線画像となった．提案手法で構築した CNN では線量が十分でないなど画質が著しく悪い画像に対して対応していないため腰椎椎体部・椎間板・仙骨の検出が難しく，ラベリングが失敗することが分かった．

5. まとめ

提案手法を用いることで，腰部単純 X 線画像に対して腰椎椎体部・椎間板・仙骨の検出とラベリングを 93.3%と高精度で行えることが分かった． また，低コントラスト画像に対しても有効であることが分かった．一方，図 8(b)のような筋肉質な人あるいは体厚がある人の場合に十分な線量が受光されず，画質が著しく悪い X 線画像が得られた場合は，ラベリング失敗することが分かった．

利益相反の有無

なし

文　献

[1] Mohamed Amine Larhmama, Mohammed Benjelloun and Saïd Mahmoudi: Vertebra identification using template matching modelmp and K-means clustering, IJCARS, 2013.
[2] Fabian Lecron, Mohammed Benjelloun and Saïd Mahmoudi: Fully automatic vertebra detection in x-ray images based on multi-class SVM, Proc of SPIE, 2012.
[3] Ruhan Sa, William Owens and Raymond Wiegand: Fast scale-invariant lateral lumbar vertebrae detection and segmentation in X-ray images, Conf of EMBC, 2016.

Detection and labeling of lumbar vertebral body using CNN in X-ray image

Masahiro Takada[*1], Akira Kinoshita[*1], Shigenori Kawabata[*2]

*1 RICOH COMPANY, LTD.

*2 Tokyo Medical and Dental University .

Abstract

Along with the development of medical imaging devices, there is an increasing demand for morphological image-based diagnosis support systems. For application to diagnosing spinal disorders such as spondylolysis and spinal scoliosis, it is vital that the affected areas are precisely located in CT or MRI images. In this study, we propose a novel method that automatically detects and labels lumber vertebral body from plain X-ray images. The proposed method incorporates CNN to detect vertebral bodies, intervertebral discs and sacrums. By considering the geometrical relationships between the three parts, the detected vertebral bodies are labeled according to their orders. The performance of the proposed method is empirically evaluated using 60 plain X-ray images, and the results show the effectiveness of our approach with labeling precision reaching 93.3%.

Key words: Key words: CNN, plain X-ray image, lumbar, detection, labeling

著者紹介

髙田　真弘　(たかだ　まさひろ)
2014 年東京理科大学工学部電気工学科卒．2016 年東京理科大学大学院工学研究科電気工学専攻卒．現在，株式会社リコー 研究開発本部 リコーICT 研究所 所属．画像処理の研究に従事.

木下　彰　(きのした　あきら)
2006 年芝浦工業大学工学部電子工学科卒．2008 年芝浦工業大学大学院工学研究科電気電子情報工学専攻卒．現在，株式会社リコー 研究開発本部 リコーICT 研究所 所属．画像処理の研究に従事.

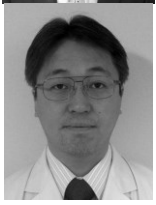

川端 茂徳　(かわばた　しげのり)
1993 年東京医科歯科大学・医学部卒．2002 年同大大学院卒．現在，同大・先端技術医療応用学講座・特任教授．医博．脊椎外科，脊髄機能診断の研究に従事.

Fast Marching Algorithm に基づく小児 CT 像からの腸管閉塞部位検出手法

西尾　光平[*1]　小田　紘久[*2]　千馬　耕亮[*3]　北坂　孝幸[*4]

Holger R. Roth[*1]　伊東　隼人[*1]　小田　昌宏[*1]

檜　顕成[*3]　内田　広夫[*3]　森　健策[*1,5,6]

要旨

本稿では，血管造影された小児イレウス（腸閉塞）患者のCT像から腸管閉塞部位を検出する手法を提案する．イレウス患者の腸管内に含まれている食物・便は，腹水等と濃度値の差が小さいことから，これまでの抽出手法では精度よく腸管内領域を抽出できない．そこで本研究では一般的に血管造影CT像が使われることに着目し, Fast Marching Algorithm に基づいた手法により腸を抽出することで腸管閉塞部位検出を行う．手動で指定した初期の抽出開始点から食物・便である液体領域と空気領域を交互に抽出することで，閉塞部位までの腸管内領域を辿り閉塞部位を検出する．このとき，液体領域では血管造影により造影された腸壁の強調処理とFast Marching Algorithmを組み合わせた手法，空気領域では領域拡張法を用いる．提案手法をイレウスによる腸管閉塞部位が存在する血管造影された小児CT像5症例に適用し，辿ることのできた腸管の割合により評価を行った．辿ることのできた腸管の割合の平均は75.4%であった．

キーワード：Computer-Aided Detection (CADe)，イレウス，小腸自動抽出，小児外科

1. はじめに

イレウス（腸閉塞）患者の約 5 分の 1 は，放置すると腸管壊死等の重篤な状態を引き起こすため，緊急手術が行われる［1］．手術が必要か否かの判断には, 腹部 CT 像において拡張した腸管を辿り，閉塞部位の位置や状態を確認する必要がある．これは，救急医などイレウス診断の経験の浅い医師には容易でなく，自動で閉塞部位を検出し，診断を支援するシステムが求められる．

イレウス診断では，血管造影 CT 像により腸壁を造影することで，拡張した腸管を辿ることを容易にしている（図 1 参照）．しかし，とりわけ小腸では，腸管内に含まれる食物や便が腹水等と濃度値の差が小さいことや，腸管は複雑に折り重なっており，大腸の抽出手法を流用しても精度よく腸管内領域を抽出できない［2］．そこで本研究では，血管造影により造影された腸壁の強調処理と Fast Marching Algorithm［3, 4］を組み合わせた手法により腸管内領域を抽出し，抽出した腸管を辿り腸管閉塞部位を検出する手法を提案する．

*1 名古屋大学大学院情報学研究科
〔〒464-8601　名古屋市千種区不老町〕
e-mail: knishio@mori.m.is.nagoya-u.ac.jp
*2 名古屋大学大学院情報科学研究科
*3 名古屋大学大学院医学系研究科
*4 愛知工業大学大学院情報科学部
*5 名古屋大学情報基盤センター
*6 国立情報学研究所医療ビッグデータ研究センター

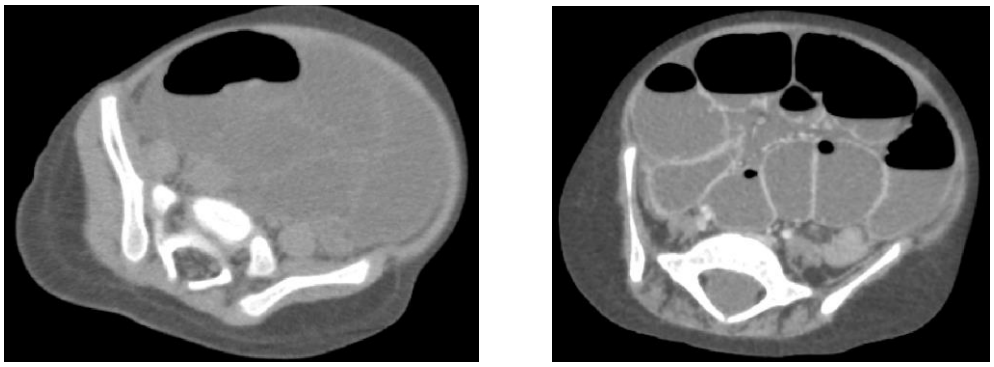

(a) (b)

図 1 血管造影 CT 像の例．(a) 腸壁の判別が困難な例．(b) 腸壁の判別が容易な例

2. 手法

本手法は，入力された腹部 CT 像において，腸管内を自動抽出し，その終端を閉塞部位として検出する．初期の抽出開始点は腸管内の任意の点を手動で指定する．液体領域の抽出には Fast Marching Algorithm を用いる．面状構造強調処理［5］をもとに，伝播速度が腸壁付近で小さくなるような速度関数を設定する．空気領域では領域拡張法を用いる．一度の抽出では，液体領域と空気領域の境界で抽出が終了するため，抽出開始点を次の領域へ自動更新する．領域の抽出と抽出開始点の自動更新を繰り返し，液体領域と空気領域を交互に抽出する．抽出開始点の自動更新の際，続きの領域が存在しないと判断した点を腸管閉塞部位として検出する．なお抽出結果は，閉塞部位までの経路の観察を支援するために初期の抽出開始点からの距離に応じた色分けにより示す．

3. 実験と結果

イレウスによる腸管閉塞部位をもつ小児の血管造影 CT 像 5 症例に本手法を適用し，腸管の抽出および閉塞部位検出を行った．CT 像の仕様は，画像サイズ 512×512×(385-701) 画素，ピクセルサイズ 0.39-0.63 mm，スライス間隔 0.40-0.80 mm であった．

腸管を正しく辿れたかどうかの評価のため，手動で作成した腸管領域と抽出した腸管領域から中心線を求め，辿ることのできた腸管の割合と，中心線間の平均誤差距離により評価した．評価値を表 1 に，抽出結果の例を図 2 に示す．

さらに閉塞部位の検出可否も評価した．手動で作成した閉塞部位と自動検出結果との距離が 30mm 未満のとき検出成功と定義した．5 症例に含まれる 10 個の閉塞部位のうち 7 個は検出可能であった．

4. 考察

提案する腸管閉塞部位検出手法は，腸管内部と腸管外部を区別し抽出することで閉塞部位を検出することが可能であった．また，腸管内部領域の抽出結果の色付けを行うことで，初期の抽出開始点から閉塞部位までの経路の観察を容易にした．しかしながら，腸管内部と腸壁の一部あるいは全体が腸壁として判別しにくいような症例では腸管外部に過抽出が発生し精度が低下した．

5. むすび

本稿では，Fast Marching Algorithm を用い

表 1 辿ることのできた割合と平均誤差距離の結果．

Case	1	2	3	4	5	Ave.
Rate [%]	48.2	55.3	74.3	99.9	99.2	75.4
Distance [mm]	2.01	1.93	3.39	4.23	2.53	2.82

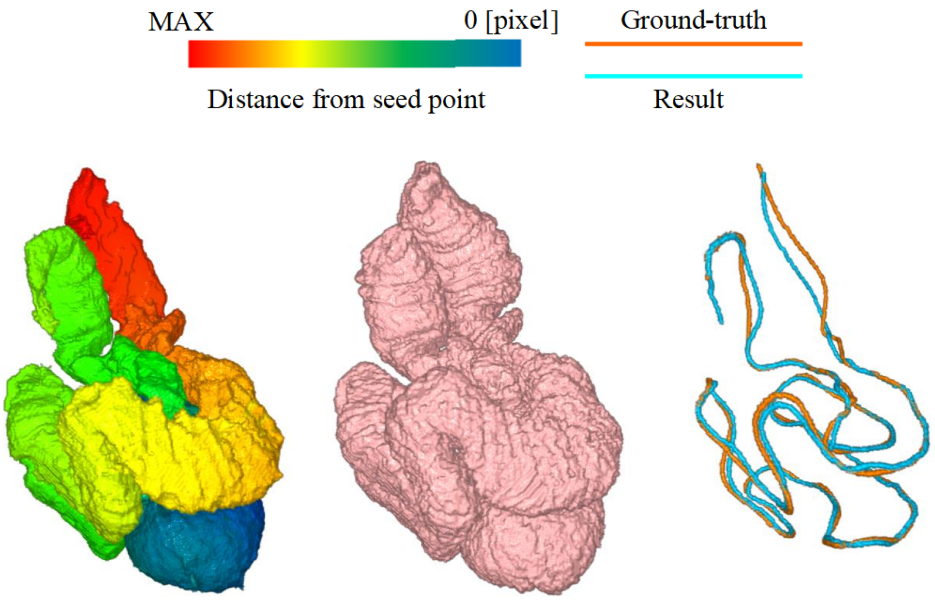

(a) (b) (c)

図 2 Case 5 の抽出結果例．(a) 抽出結果．(b) 手動で作成した腸管領域．(c) 抽出結果と手動で作成した腸管の中心線．

て腹部 CT 像から腸管閉塞部位を検出する手法を提案した．5 症例に含まれる 10 個の閉塞部位のうち 7 個が検出可能であった．辿ることのできた腸管の割合の平均は 75.4%であった．今後の課題として，広域的な構造の考慮や不明瞭な腸壁領域への対処が挙げられる．

謝辞　日頃より熱心に御討論頂く名古屋大学森研究室の諸氏に感謝する．本研究の一部は JSPS/MEXT 科研費 (26108006, 17H00867, 17K20099) ならびに JSPS 二国間交流事業によった．

利益相反の有無　なし

文　献

［1］ 加藤治文　他編　：標準外科学第 13 版．医学書院，2013

［2］ Uitert R, Summers R: Automatic Correction of Level Set Based Subvoxel Precise Centerlines for Virtual Colonoscopy Using the Colon Outer Wall. IEEE TMI **26**: 1069-1078, 2007

［3］ Osher S, Sethian J: Fronts propagating with curvature-dependent speed. JCP **79**, 1988

［4］ Sethian J: Level Set Methods and Fast Marching Method. JCIT **11**, 1999

［5］ Sato Y, Westin C, Bhalerao A et al: Tissue Classification Based on 3D Local Intensity Structures for Volume Rendering. IEEE TVCG **6:** 160-180, 2000

Detection of intestinal obstruction from pediatric CT image based on Fast Marching Algorithm

Kohei NISHIO [*1], Hirohisa ODA [*2], Kosuke CHIBA[*3], Takayuki KITASAKA[*4], Holger R. ROTH[*1], Hayato ITOH [*1], Masahiro ODA [*1], Akinari HINOKI[*3], Hiroo UCHIDA[*3], Kensaku MORI[*1,5,6]

*1 Graduate School of Informatics, Nagoya University
*2 Graduate School of Information Science, Nagoya University
*3 Nagoya University Graduate School of Medicine
*4 School of Information Science, Aichi Institute of Technology
*5 Information Technology Center, Nagoya University
*6 Research Center for Medical Bigdata, National Institute of Informatics

Abstract:

In this paper, we propose a detection method of intestinal obstructions from abdominal CT volumes of ileus patients. Segmentation of the intestines is difficult because the intestines contain foods and fecal materials, which have similar intensities to ascites intensities on CT volumes. Also, the intestines have complexed structure. Therefore, previous segmentation methods of the intestine were not able to segment the intestines of ileus patients from CT volumes. In this paper, we use angiographic CT volumes that are commonly used for diagnosis, and we detect intestinal obstruction by segmenting intestine using the Fast Marching Algorithm-based method. In this method, fluid region and air region are alternatively segmented from a manually specified seed point. Then the intestinal obstruction is detected from the segmented intestine region. The Fast Marching Algorithm is applied to segment the fluid region with the intensity enhancement filter of the intestine wall for not to segment the region outside intestine. The region growing is applied to segment the air region. We evaluated the proposed method by using five angiographic CT volumes. The experimented result demonstrated that the proposed method can extract 75.4% of the intestine regions. Furthermore it was able to detect obstruction points.

Keywords: Computer-Aided Detection (CADe), ileus, automated small intestine segmentation, pediatric surgery

機械学習による内視鏡動画インスタンスセグメンテーションのための手動アノテーションツールの開発

小澤　卓也[*1]　小田　紘久[*2]　伊東　隼人[*1]　北坂　孝幸[*3]

Holger R. Roth [*1]　小田　昌宏[*1]　林　雄一郎[*1]　三澤　一成[*4]

伊藤　雅昭[*5]　竹下　修由[*5]　森　健策[*1,6,7]

要旨

本論文では，内視鏡動画像において術具や解剖領域を機械学習によりインスタンスセグメンテーションするために必要とされるアノテーションデータを効率的に生成可能な内視鏡動画像アノテーションツール開発について報告する．内視鏡動画像に対して詳細に術具や解剖領域がアノテーションされたデータは，手術支援機器における画像からの手術状況の自動識別技術の実現や内視鏡手術手技の評価技術の実現など利用価値が高い．従ってこれらのデータベースを効率的に生成するための基盤構築が求められている．そこで本研究では，動画像に対してセグメンテーション作業を行う為のツール NuVAT を開発した．このツールにより，セグメンテーション作業をお絵かきツールを扱う感覚で簡単に行うことが可能になった．実際に国立がん研究センター東病院において，腹腔鏡動画像における術具・解剖領域のアノテーション作業に利用された．

キーワード：セグメンテーションツール，アノテーションツール，内視鏡手術動画

1. 背景と目的

現在，がん治療の手法の一つとして内視鏡外科手術が行われている．一般的に内視鏡手術は術者にとって難易度が非常に高く[1]，特に細かな操作を行う際には，術者の手術経験が重要になるためである．従って内視鏡動画像に映る術具や解剖構造をコンピュータ等で認識し，それを基にした新たな治療支援技術の開発や手術手技の定量評価が求められている．

内視鏡動画像における術具や解剖構造といったラベルの自動セグメンテーションには，深層学習が有望と考えられる．しかしながら学習時には大量の手動セグメンテーション結果が必要である．手動セグメンテーションツールとして，TSLAB［2］，MITK (The Medical Imaging Interaction Toolkit)［3］，PLUTO [4]などのソフトウェアが開発されている．また，Maier-Hein らによって，クラウドソーシングを利用したアノテーション手法も提案されている[5]．しかし，動画に対する深層学習用のアノテーションデータを作成するための機能としては未だ不十分である．

また，内視鏡手術動画中の術具領域の輪郭

*1 名古屋大学大学院情報学研究科
〔〒464-8601 名古屋市千種区不老町 IB 電子情報館南棟 4 階 466 号室〕
e-mail: tozawa@mori.m.is.nagoya-u.ac.jp
*2 名古屋大学大学院情報科学研究科
*3 愛知工業大学情報科学部
*4 愛知県がんセンター
*5 国立がん研究センター東病院
*6 名古屋大学情報基盤センター
*7 国立情報学研究所医療ビッグデータ研究センター

は多角形で囲まれた領域として表されること

図 1　内視鏡動画中のフレームの画像．右上・左下からは臓器把持用の Grasper 鉗子，下からは切

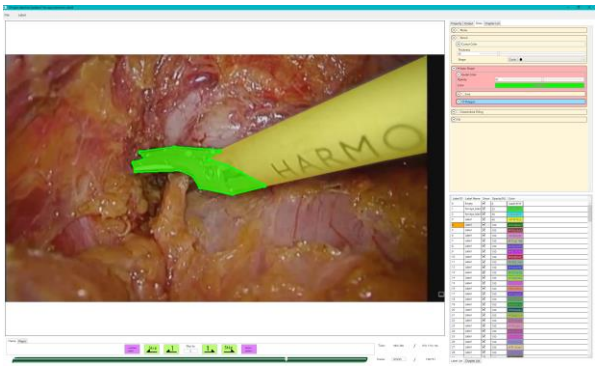

離用の Point dissector 鉗子が現れている．

図 2　NuVAT の多角形ラベリングツールを使用している様子．

表 1 NuVAT に実装したラベリングツール

描画機能	概要
ペン	フリーハンド描画
直線	指定した 2 点を直線で結ぶ
塗りつぶし多角形	指定した頂点で囲まれた領域を塗りつぶす
閉領域塗りつぶし	指定した画素を含む閉領域を塗りつぶす
フレーム間コピー	隣接したフレーム間でラベル画像をコピーする
画像全体塗りつぶし	フレーム全体を単一ラベル値で塗りつぶす

が多い．一方で，解剖構造の輪郭は複雑な曲線によって表されるため，ラベルとして単純な矩形や頂点位置を記録するだけでは不十分である．画素単位でセグメンテーションを行う必要があると同時に，直線や多角形領域を指定してラベリングする機能が必要になる．

そこで本研究では，内視鏡動画像中の一部のフレームに対するラベルデータを生成する，お絵かきツールを扱う感覚で生成するツール NuVAT (Nagoya University Video Annotation Tool) を開発する．

2. NuVAT の概要

内視鏡動画像に対するセグメンテーションを目的とした深層学習を行う際の問題として，フレーム毎に画素単位でラベル付けされたデータが大量に必要である点が挙げられる．そこで，効率的にセグメンテーションデータを生成するツールが必要になる．本研究において，手動セグメンテーションツール NuVAT は，1)画素単位で正確かつ効率的にアノテーション作業を遂行し，2)深層学習に利用しやすい形式でラベルデータを出力するという設計思想のもとに開発された．

1)について，画素単位でのセグメンテーションを可能にするため，NuVAT に既存のお絵かきツールを使用する感覚でセグメンテーションを行うための機能を実装した．ラベリング機能としてペン機能や多角形描画機能などを実装した．組み込んだ機能一覧を表 1 に示す．図 1 で示したフレームの術具領域をセグメンテーションする場合を例に挙げる．この時，背景領域を 0，術具領域を種類ごとに 0 より大きい整数でラベル付けした画像を生成する．図 2 は，NuVAT を内視鏡動画像に対する手動セグメンテーションに利用した例である．このツールで動画を読み込み，フレームを遷移させつつ，お絵かきツールを扱う感覚でラベル付けを行うことが可能である．

2)について，作成したセグメンテーションデータは深層学習を行うためのアプリケーションでも利用可能にするため，一般的な画像ファイルフォーマットでフレーム毎に出力する．ラベル付けした画像はあらかじめ指定したフォルダに，PNG，PGM などの一般的に用いられる画像フォーマットでフレーム毎に自動出力される．深層学習を行う際の学習データとして，これらの画像の組を利用すること

が可能である．

3. 使用実績

国立がん研究センターにて NuVAT を用いて内視鏡動画像に対してセグメンテーションしたデータを作成した．5 種類の鉗子を先端と柄を区別してラベル付けしたデータや，腸管をラベル付けしたデータ，出血の領域をラベル付けしたデータなど，様々なデータを作成した． これらのデータは，自動セグメンテーションを目的とした CNN の訓練データとして用いられている．その結果は機会を改めて紹介する．

4. むすび

本研究では動画像に対するセグメンテーションツールを開発した．実際に動画セグメンテーションを進めるにあたり十分な機能を有すると考えている．更なる改善として，フレーム間でラベルをトラッキングする機能や，フレーム画像の内で似た画素値を持つ領域を塗りつぶす機能などを検討している．

謝辞　日頃から熱心に御討論頂く国立がん研究センターの皆様ならびに森研究室諸氏に深謝する．本研究は JSPS 科研費 JP17H00867, JP26108006, AMED の課題番号 JP18he1802002 の支援を受けた．

利益相反の有無　なし

文　献

［1］ 佐久間一郎: 低侵襲手術ロボットシステム．バイオメカニズム学会誌=Journal of the Society of Biomechanisms, **32**(3): 147-152, 2008

［2］ Carlos C, Yanez EM, Garca N: Tool for Semiautomatic Labeling of Moving Objects in Video Sequences: TSLAB. Sensors, **15**(7): 15159-15178, 2015

［3］ Nolden M, Zelzer S, Seitel A et al: The Medical Imaging Interaction Toolkit: challenges and advances. International Journal of Computer Assisted Radiology and Surgery, **8**(4): 607-620, 2013

［4］ 二村幸孝，出口大輔，北坂孝幸 他: PLUTO : 医用画像診断支援共通プラットフォーム．Medical Imaging Technology, **26**(3), 187-191, 2008

［5］ Maier-Hein L, Mersmann S, Kondermann D et al: Crowdsourcing for reference correspondence generation in endoscopic images．Medical Image Computing and Computer-Assisted Intervention – MICCAI 2014, **17**(2): 349-356, 2014

Development of manual annotation tool for endoscopic video sequences for automated instance segmentation

Takuya OZAWA[*1], Hirohisa ODA[*2], Hayato ITOH[*1], Takayuki KITASAKA[*3], Holger R. Roth [*1], Masahiro ODA[*1], Yuichiro HAYASHI[*1], Kazunari MISAWA[*4], Masaaki ITO[*5], Nobuyoshi TAKESHITA[*5], Kensaku MORI[*1,6,7]

*1 Graduate School of Informatics, Nagoya University
*2 Graduate School of Information Science, Nagoya University
*3 School of Information Science, Aichi Institute of Technology
*4 Aichi Cancer Center Hospital
*5 National Cancer Center Hospital East
*6 Information Technology Center, Nagoya University
*7 Research Center for Medical Bigdata, National Institute of Informatics

We report a manual annotation tool for endoscopic video sequence in this paper. Carefully annotated endoscopic video data is quite useful for many applications. Such data can be used in development of surgery situation recognition systems or quantitative evaluation of surgical techniques. Therefore, development of such data creation framework is required. In this paper, we show an annotation tool for video sequence, which is called "NuVAT". This tool makes manual annotation task easy, like illustration drawing using simple drawing tools. This tool was used at the National Cancer Center Hospital East for annotation of surgical tools and anatomical structures on laparoscopic video frames.

Key words: Segmentation tool, Annotation tool, Endoscopic video sequences

ウサギ心臓の屈折CT像における線維配向の可視化ならびに評価

小田 紘久 [*1], Holger R. Roth[*2], 砂口 尚輝 [*3], 宇佐美 紀子 [*3],
小田 昌宏 [*2], 島雄 大介 [*4], 市原 周 [*5], 湯浅 哲也 [*6],
安藤 正海 [*7], 秋田 利明 [*3], 成田 裕司 [*3], 森 健策 [*1,8,9]

要旨

屈折 CT は高解像度な 3 次元画像撮像モダリティのひとつであり，生物の軟組織に対して高いコントラストをもつ．ウサギ心臓の屈折 CT 像では，心筋の線維を分ける面状の組織である cleavage plane が良好に視認可能である．本稿ではこの屈折 CT 像において，CP および線維を容易に可視化できることを示し，さらにその結果が解剖学上の知識に概ね合致していることを確認する．CP はヘッセ行列による暗面状強調フィルタにより強調した．線維は構造テンソル解析による方向推定を行い，またその追跡を行った．3 次元での重畳表示により，両者が概ね並行していることが視認できた．線維方向の統計は解剖学上の知識と概ね一致していた．

キーワード: 微細解剖構造解析, ファイバートラッキング, 心臓解剖構造

1. はじめに

心臓は多数の線維で構成されている．心不全のメカニズム解明には，とりわけ全身に血液を送り出す左心室の線維配向と，それを束にする心筋シートについて詳しい調査が必要である．我々は 3 次元の高解像度画像撮像モダリティであるマイクロ CT を用いて，心臓の撮像と解析に取り組んできた．マイクロ CT には，吸収 X 線を用いる撮像装置や屈折 X 線 [1] によるものがある．吸収 X 線を用いる撮像装置は一般に販売され，卓上サイズの製品もある．屈折 X 線のものは大型加速器を必要とするが，心臓などの軟組織に対して高いコントラストをもつ．

屈折 X 線を用いたマイクロ CT 画像（以下，屈折 CT 像）では，線維の束を区切る面状の組織である cleavage plane (CP) を良好に視認可能である．CP は心不全の発生により角度が変わるとされる心筋シートとも並行するものと考えられ，構造を詳しく調査すべきである．本稿では CP の強調処理と線維の追跡結果を 3 次元で重畳表示して両者が交差せずに進むかどうか調査する．その上で，線維方向を定量的に計測し，解剖学での知識に概ね即した結果が得られるかどうか調査する．これらを通して，心臓の線維の解析のために屈折 CT が有用であることを示す．

2. 材料と手法

1) 材料

エタノール固定のウサギ心臓の屈折 CT 像を用いた．画像サイズは $1600 \times 1600 \times 1240$ 画素で，各画素は解像度 15μm の等方性ボクセルであった．

撮影された画像は，心基部から心尖部に向かう線分が 3 次元画像の Z 軸と並行になるよう，手動で回転した．また，左心室のマスクを半自動セグメンテーションにより作成した．後述の処理はすべてこのマスク内で行われる．画像の一例を図 1 （a） に示す．

[*1] 名古屋大学大学院情報科学研究科
〔〒 464-8601 名古屋市千種区不老町〕
email: hoda@mori.m.is.nagoya-u.ac.jp
[*2] 名古屋大学大学院情報学研究科
[*3] 名古屋大学大学院医学系研究科
[*4] 北海道科学大学保健医療学部
[*5] 名古屋医療センター臨床研究センター
[*6] 山形大学大学院理工学研究科
[*7] 東京理科大学研究推進機構総合研究院
[*8] 名古屋大学情報基盤センター
[*9] 国立情報学研究所医療ビッグデータ研究センター

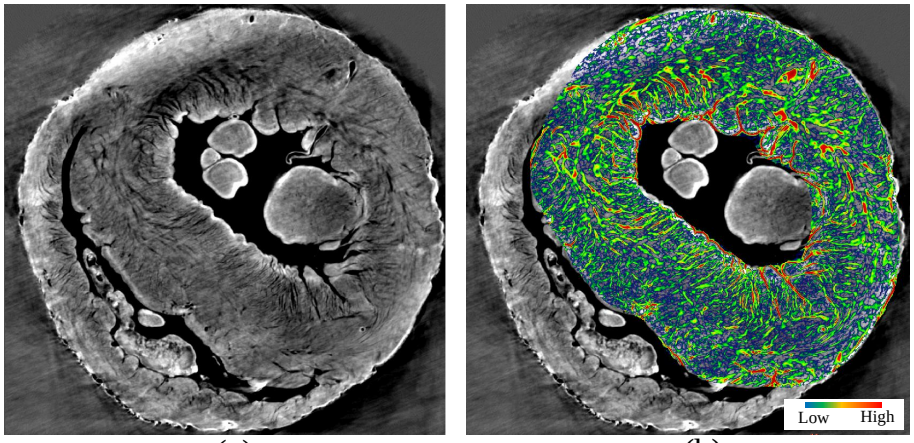

(a) (b)

図 1 ウサギ心臓の屈折 CT 像．(a) 屈折 CT 像の Axial 断面．(b) CP 強調結果．

2) CP 強調画像の作成

屈折 CT 像上において CP は，周囲の筋線維領域よりも濃度値が低く，面らしい形状をもつ．ヘッセ行列を用いた暗面状強調フィルタ [2] を用いてその領域を強調する．ヘッセ行列の算出には Difference of Gaussian (DoG) を用いるが，この際のガウシアンカーネルの標準偏差の集合を $\mathcal{S}$ とし，$\mathcal{S}$ の要素ごとに得たフィルタ出力の最大値を CP 強調画像とする．CP 強調画像の一例を図 1 （b） に示す．

3) 線維の追跡

線維の方向推定と追跡により，線維の流れを可視化する．ある点における線維の方向推定には構造テンソル解析を用いる [3]．構造テンソルは 3×3 の行列として表現される．その最小固有値に対応する固有ベクトル方向を線維方向とし，その方向に追跡を行う．

3. 実験および結果

1) 3 次元での重畳表示

CP および線維は 3 次元空間で複雑な構造をもつ．それを効果的に表示するため，追跡結果と CP 強調画像の 3 次元での重畳表示を行う．パラメータ設定は $\mathcal{S} = \{\sqrt{2}, 2, 2\sqrt{2}\}$[voxels] とした．3 次元での重畳表示の結果を図 2 に示す．

2) LV の内側・外側での線維方向計測

心基部と心尖部の中間付近において，方向ごとの線維変化をそれぞれ求めた．心基部と心尖部の中間付近の Axial 断面において，LV マスクの中心点から 8 方向に放射探索を行い，外側に向かうに従って線維方向がどのように変化するかを計測した．またそれらの平均も求めた．結果のグラフを図 3 に示す．

4. 考察

図 2 では，面状の形状をもつ CP の間を，線維が CP とクロスせずに進んでいることが視認できる．構造テンソルの解析において，筋線維と CP の濃度差が考慮されているためと考えられる．しかし CP は面状であり，それと並行となる方向は無数に存在するため，線維方向推定が正しいかどうかは別途検証が必要である．

図 3 においては，左心室の外壁に近い部分では，線維の立ち上がり角度が正の値（左心室の外から見て左肩上がり），内壁の部分では負の値（右肩上がり）である．これは解剖学上の知識に概ね即しており，線維方向の推定が概ね正確に可能であったとわかる．なお，左心室の内壁や外壁付近ではこの知識に反する場合もあった．内壁や外壁付近は複雑な構造をしており，線維方向に外れ値が発生しやすい可能性がある．

上記の 2 点から，正当性が確認された線維追跡結果に対して，CP 強調結果が概ねクロスしないことが確認できたことから，両者の解析結果が正当であったといえる．

5. むすび

ウサギ心臓の屈折 CT 像から，左心室の CP や線維の解析を行い，両者の結果の正当性を確

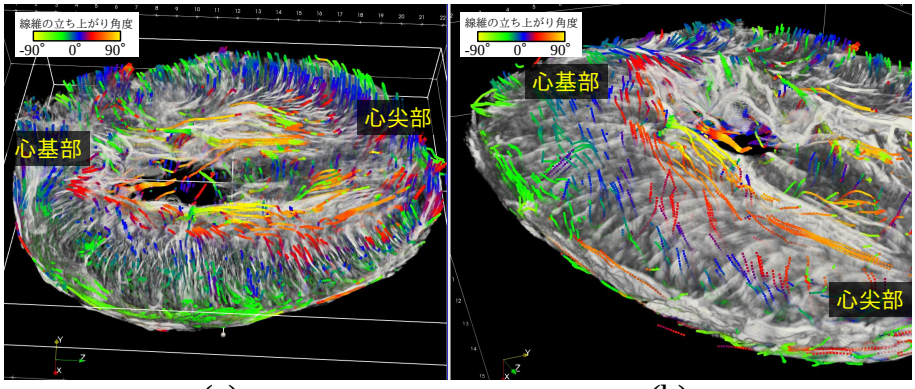

(a) (b)

図 2 CP 強調画像と線維追跡結果の 3 次元重畳表示．心臓を縦に輪切りするようにクロップ．白色が CP 強調画像，黄・緑・青・赤またはそれらの中間色のものが線維追跡結果．(a)(b) それぞれ異なる角度から描画．

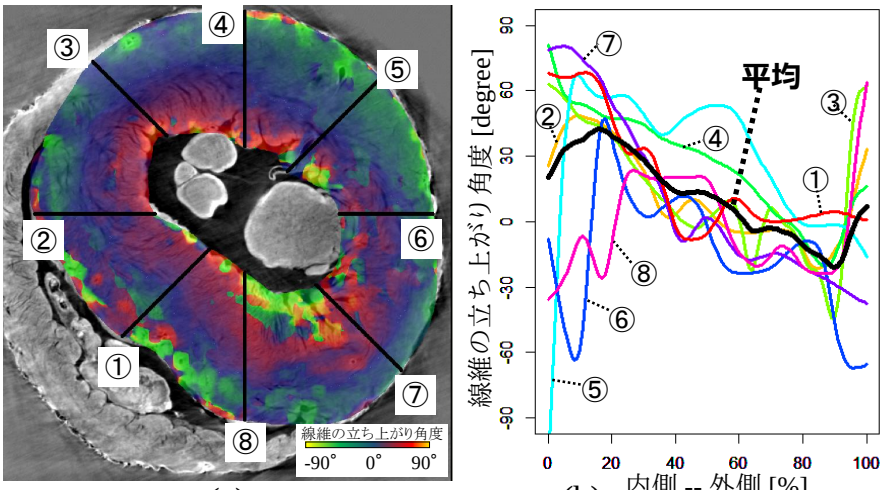

(a) (b)

図 3 Axial スライス上の線維方向観測．(a) 線維の立ち上がり角度および観測に用いる線分．(b) 線分上の立ち上がり角度およびそれらの平均．

認した．これにより，屈折 CT 像を用いて心臓の構造を概ね正確に調査できることを示した．

謝辞　本研究の一部は MEXT/JSPS 科研費 (26108006, 17H00867, 17K20099, 16H05427, 17H05288) および JSPS 二国間交流事業によった．

利益相反　なし

文　献

[1] Sunaguchi N, Yuasa T, Huo Q, et al.: X-ray refraction-contrast computed tomography images using dark-field imaging optics, Appl. Phys. Lett., **97**(15): 153701, 2010.

[2] Sato Y, Westin C.-F, Bhalerao A, et al.: Tissue classification based on 3D local intensity structures for volume rendering, IEEE TVCG, **6**(2): 160–180, 2000.

[3] 小田紘久, 小田昌宏, 北坂孝幸ら：マイクロ CT 画像からの線維方向追跡に関する検討, 信学技報, **115**(301): 9–14, 2015.

Visualization and evaluation of fiber orientation on refraction CT volume of rabbit heart

Hirohisa Oda[*1], Holger R. Roth[*2], Naoki Sunaguchi[*3], Noriko Usami[*3], Masahiro Oda[*2], Daisuke Shimao[*4], Shu Ichihara[*5], Tetsuya Yuasa[*6], Masami Ando[*7], Toshiaki Akita[*3], Yuji Narita[*3], Kensaku Mori[*1,8,9]

[*]1 Graduate School of Information Science, Nagoya University
[*]2 Graduate School of Informatics, Nagoya University
[*]3 Nagoya University Graduate School of Medicine
[*]4 Department of Radiological Technology, Hokkaido University of Science
[*]5 Clinical Research Center, Department of Pathology, Nagoya Medical Center
[*]6 Graduate School of Engineering and Science, Yamagata University
[*]7 Research Institute of Science and Technology, Tokyo University of Science
[*]8 Information Technology Center, Nagoya University
[*]9 Research Center for Medical Bigdata, National Institute of Informatics

Abstract

Refraction CT is a high-resolution imaging modality, which enables us to obtain volumetric images having high soft tissue contrast. On a refraction CT volume of a rabbit heart, the cleavage planes (CPs) that separate myocardial fibers are shown clearly. In this paper, we demonstrate that CPs and the myocardial fibers can be visualized clearly using image processing techniques easliy. Moreover, we confirm that these visualization results follow the cardiac anatomical studies. CPs were enhanced by dark-plate-like structure enhancement filter based on the Hessian matrix. Orientations of myocardial fibers were estimated using structure tensor analysis. On superimposed 3D visualization of CPs and myocardial fibers, we could confirm that they were running in parallel. Statistics of myocardial fiber orientations followed anatomical studies well.

Keywords: Tiny anatomical structure analysis, fiber tracking, cardiac anatomical structure

新しいコンセプトの装置「Whole Gamma Imaging」における陽電子・ガンマ線同時放出核種イメージングのための検出器応答関数の提案

田島 英朗[*1]　吉田 英治[*1]　奥村 勇介[*2,1]　菅 幹生[*2]　河地 有木[*3]

鎌田 圭[*4]　Katia Parodi[*5]　山谷 泰賀[*1]

要旨

我々の提案する WGI (Whole Gamma Imaging) は，PET 核種に対する超高感度イメージング，シングルフォトン核種のイメージング，陽電子とほぼ同時にガンマ線を放出する核種（β^+-γ 核種）のイメージング（3 ガンマイメージング）などを一つの装置で可能とする新しいコンセプトである．WGI は，PET とコンプトンイメージングを組み合わせた画期的な手法で, 従来の PET リングの内側に散乱検出器リングを設け, PET リングを吸収検出器として機能させることで，PET の同時計数に加え，シングルガンマ線をコンプトンイメージングの原理で検出可能である．本研究では，3 ガンマイメージングのための検出器応答関数を提案し，WGI のコンセプト実証機において逆投影により画像を生成する際に，同時計数線の情報のみを用いた場合と提案手法を用いた場合を比較した．その結果，提案手法による逆投影像は，より鮮明な画像になることが示された．

キーワード : PET，コンプトンイメージング，WGI，検出器応答関数，β^+-γ 核種

1．はじめに

我々は，核医学装置の新しいコンセプトとして，WGI（Whole Gamma Imaging）の提案を行った．WGI は，PET の原理とコンプトンイメージングの原理を組み合わせた画期的な手法で，従来の PET の検出器リングの内側に，散乱検出器のリングを設け，PET の検出器リングを吸収検出器としても機能させることで，PET の同時計数測定に加え，シングルガンマ線をコンプトンイメージングの原理で検出することができる．WGI の実現により，

・PET 核種に対する高感度化
・シングルフォトン核種のイメージング
・3 ガンマイメージング[1, 2]

が一つの装置で可能となる（**図 1**）．3 ガンマイメージングとは，陽電子崩壊とほぼ同時に 1157keV のシングルガンマ線を放出する ^{44}Sc のような β^+-γ 核種のイメージングである．本研究では，WGI で 3 ガンマイメージングを行うために必要な検出器応答モデルの提案を行った．

*1 量子科学技術研究開発機構
放射線医学総合研究所
〔〒263-8555 千葉市稲毛区穴川 4-9-1〕
e-mail: tashima.hideaki@qst.go.jp
*2 千葉大学
*3 量子科学技術研究開発機構
高崎量子応用研究所
*4 株式会社 C&A
*5 Ludwig-Maximilians Universität München

2．手法

1）3 ガンマイメージングの検出器応答関数

PET では，陽電子崩壊と対消滅によって発生する 511 keV のガンマ線対の同時計数測定をリ

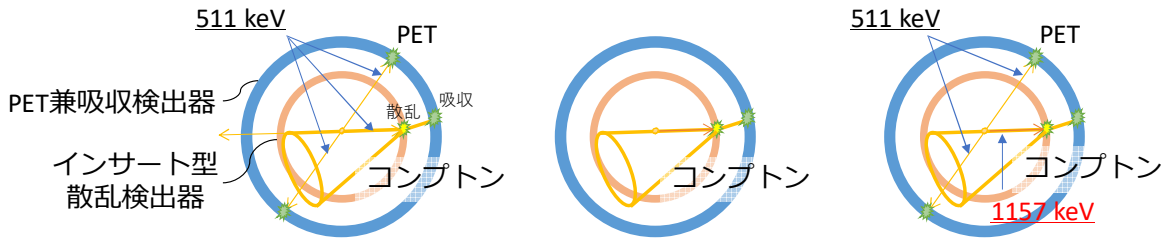

図 1 WGI の 3-in-1 コンセプト

ング状に配置した検出器により行うことで，線源の位置を 2 つの検出点を結ぶ直線（LOR：Line of Response）上に同定する．そして，複数の LOR の情報から，画像再構成の原理によって元の放射能分布を求める．一方，コンプトンイメージングでは，散乱検出器と吸収検出器でそれぞれ位置とエネルギーの情報を測定し，散乱位置を頂点とし，エネルギー情報からクライン=仁科の公式より決まる散乱角を半頂角とする円錐面上に同定する．散乱検出器と吸収検出器のエネルギーをそれぞれ E_s，E_a とすると，散乱角 θ は次式であらわされる．

$$\theta = \arccos\left(\left(\frac{1}{E_s+E_a}-\frac{1}{E_a}\right)m_e c^2+1\right) \qquad (1)$$

ここで，m_e は電子の質量，c は真空中の光速である．WGI の 3 ガンマイメージングでは，β^+-γ 核種から同時に放出される 3 本のガンマ線を同時に測定することで，直線と円錐面の交点に線源を同定することが可能である．**図 2** のように，**c**，**c'**を同時計数検出位置，**d** を **c** から **c'**へ向かう方向ベクトル，**s** を散乱検出器での検出位置，**a** を吸収検出器での検出位置，**n** を **a** から **s** に向かう方向ベクトル，t を **c** から直線と円錐面の交点 **p** までの距離とすると，**p** は次の連立方程式を解くことで求められる．

$$\begin{cases} \mathbf{p} = \mathbf{c} + t\mathbf{d} \\ \dfrac{(\mathbf{p}-\mathbf{s})\cdot\mathbf{n}}{|\mathbf{p}-\mathbf{s}|} = \cos\theta \end{cases} \qquad (2)$$

ただし，実際に測定可能なエネルギー情報

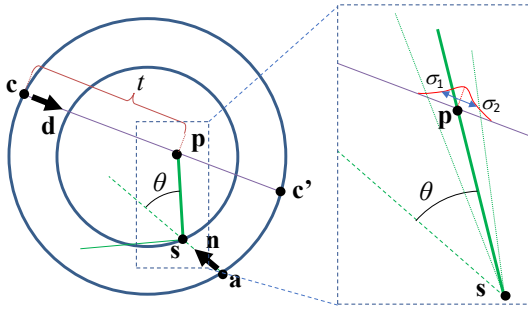

図 2 WGI における 3 ガンマイメージングの検出器応答関数モデル

は，検出器のエネルギー分解能に依存して誤差を含んでおり，得られる散乱角には揺らぎが存在する．そのため，提案する 3 ガンマイメージングの検出器応答関数のモデルではその揺らぎを考慮して，角度方向に非対称ガウス関数による広がりを持たせた．非対称ガウス関数の分散 σ_1，σ_2 は，式（1）のエネルギー E_s にエネルギー分解能に応じた変動を与えた結果起こる連立方程式の解 t の変動として求める．

2）実験

提案した検出器応答関数を用いて，WGI の世界初のコンセプト実証機[3]（**図 3**）で測定した ^{44}Sc のデータを逆投影することで画像化した．その際，比較のため，LOR の情報のみを用いて逆投影した結果と比較した．^{44}Sc は，陽電子崩壊とほぼ同時に 1157keV の単一ガンマ線を放出する半減期が 3.97 時間の β^+-γ 核種で，これまでの PET 用金属核種と同様にさまざまな薬剤

図 3 WGI コンセプト実証機

を標識することが可能である [4] . 半減期 60 年の ^{44}Ti をジェネレータとして ^{44}Sc が生成される．今回，粉末状の安定核の ^{45}Sc に対してサイクロトロンで垂直照射を行うことで生成された ^{44}Ti (166 kBq) を用いた．点状の ^{44}Ti/^{44}Sc 線源を WGI 試作機の中心から 20 mm 間隔で動かしながら，各位置で 120 分ずつ測定した．

3. 結果

図 4 に提案する検出器応答モデルを用いた逆投影像と，LOR 情報のみを用いた逆投影像を示す．提案モデルの方がより鮮明な画像となった．

4. まとめ

WGI コンセプトの一つである 3 ガンマイメージングに必要な検出器応答関数のモデルを提案し，試作機による ^{44}Sc 測定データに適用した．3 ガンマ核種の応答を考慮することで，実際にイメージングが可能で，より鮮明な画像が得られることを示した．

謝辞

本研究の一部は JSPS 科研費 16H02641 の助成を受けたものです．

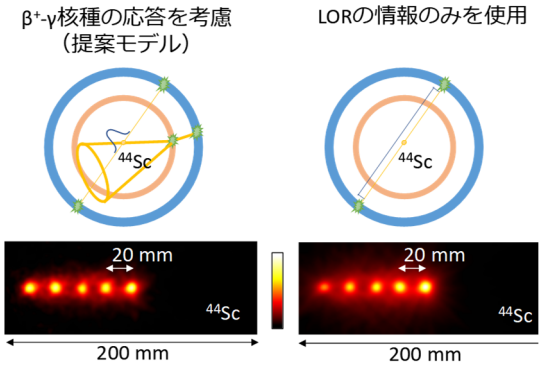

図 4 提案モデルによる ^{44}Sc の逆投影像（左）と LOR 情報のみを用いた逆投影像（右）

利益相反の有無

なし

文　献

［1］ Grignon C, Barbet J, Bardiès M, et al.: Nuclear medical imaging using $\beta^+\gamma$ coincidences from ^{44}Sc radio-nuclide with liquid xenon as detection medium. Nucl Instr Meth Phys Res Sect A **571**: 142-145, 2007

［2］ Lang C, Habs D, Parodi K, et al.: Sub-millimeter nuclear medical imaging with high sensitivity in positron emission tomography using $\beta^+\gamma$ coincidences. Journal of Instrumentation **9**: P01008, 2014

［3］ Yoshida E, Tashima H, Okumura Y, et al. : Concrete realization of the whole gamma imaging concept. IEEE NSS&MIC: M-21-2, Atlanta, 2017

［4］ Müller C, Bunka M, Reber J, et al.: Promises of Cyclotron-Produced ^{44}Sc as a Diagnostic Match for Trivalent β^--Emitters: In Vitro and In Vivo study of a ^{44}Sc-DOTA-Folate Conjugate. J Nucl Med **54** (12): 2168-2174, 2013

A Proposed Detector Response Function for "Whole Gamma Imaging" of a β^+ - γ Emitter

Hideaki Tashima[*1], Eiji Yoshida[*1], Yusuke Okumura[*2], Mikio Suga[*2],
Naoki Kawachi[*3], Kei Kamada[*4], Katia Parodi[*5], Taiga Yamaya[*1]

*1 National Institute of Radiological Sciences,
National Institutes for Quantum and Radiological Science and Technology
*2 Chiba University
*3 Takasaki Advanced Radiation Research Institute,
National Institutes for Quantum and Radiological Science and Technology
*4 C&A Corporation
*5 Ludwig-Maximilians-Universität München

Whole gamma imaging (WGI) is our new concept combining positron emission tomography (PET) and Compton imaging. The WGI enables followings in one system: super high sensitivity imaging of PET nuclides, imaging of single photon emitters, and imaging of β^+-γ emitters that emit a gamma-ray at almost the same time as the positron emission (3-gamma imaging). A scatterer detector ring is inserted into a conventional PET detector ring so that the PET detector ring functions as an absorber detector. In addition to the PET coincidence, single gamma rays can be detected by the principal of the Compton imaging. In this study, we proposed a detector response function model necessary for the 3-gamma imaging. We generated back projection images of a β^+-γ emitter, which was measured by the first WGI prototype developed for a proof-of-concept, to compare the proposed detector response function model with a model using only line-of-response information. The result showed the image generated by the proposed model was clearer.

Key words: PET, Compton imaging, WGI, Detector response function, β^+-γ nuclide

4チャンネル照射コイルを用いたRegional RF Shimによる肩・上肢撮像におけるSAR低減

小高 晃弘[*1]　伊藤 公輔[*1]　森分 周子[*1]　瀧澤 将宏[*1]

要旨

【目的】高磁場MRIでは高解像度の画像を得られるが, SAR増大による撮像パラメータの制約と照射不均一が課題である. 特に,肩や上肢の撮像では頭部に近いためパラメータの制約が厳しく, 上肢では体幹部に干渉されて照射不均一が目立つ. 本研究は, 3T MRIの肩, 上肢撮像におけるSAR低減と, 照射不均一改善を目的とする.

【方法】領域を限定して照射を補正するRegional RF shimを肩, 上肢で最適化した. 評価には, 4チャンネル独立照射制御システムを有する 3T MRI((株)日立製作所製)を用いた. 健常ボランティア 15 人を評価した. 照射分布を表すB1 mapを取得し、撮像領域を抽出した. 照射の均一度指標とSARの線形結合を, 係数を変えて最小化するアルゴリズムを適用し, その効果を確認した. 照射均一度と SAR 共に低減する係数を決定した.

【結果】決定した係数では, 領域を抽出しないRF shimよりもSARを20%程度低減し, 撮像領域の照射均一度も改善した.

キーワード：Regional RF shim, B1 map, 3T-MRI, 肩・上肢撮像, 4チャンネル独立照射制御

1. 序文

MRIでは, 被検体に高周波の電磁場であるRF波を照射し, 得られた信号を画像化する. 高いSNRを得るため, 3T以上の高磁場MRIが臨床的に用いられている. RF波の波長は静磁場強度に反比例するため、3Tの高磁場MRIでは生体のサイズと同程度の短い波長になる. そのため, 高磁場MRIには2つの課題がある.

1つ目は, SAR増大である. SARは被検体が吸収する熱量であり, 制限値を超えないように, 撮像パラメータに制約が加えられる. SARはRF波の周波数（波長の逆数）の2乗に比例するため, 高磁場MRIではSARが増大し, 制約が大きい. 特に, 肩, 上肢の撮像では頭部に近いため, 頭部に対する安全性を鑑み, SARは他部位よりも厳しく制限される.

2つ目の課題は, RF照射不均一の増大である. 高磁場MRIではRF波の波長が短いため, RF波の干渉の強弱差が撮像視野内で大きく, RF照射不均一になる. RF照射不均一は, 画像に輝度の不均一や信号低下領域を生じさせ, 診断の妨げとなる.

B1 map はRF照射の空間的分布を示す. 多チャンネル照射コイルを用いたRF shimは, 各チャンネルのRF波の照射パワーと位相を制御して, B1分布を均一に補正する技術である. ここで, 肩や上肢の撮像では, 撮像部位である肩や上肢のB1分布を均一にし, 横の体幹部では極力RF波を照射せずにSARを抑えることが望ましい.

本研究では, 4チャンネル独立制御可能なRF照射

*1 株式会社日立製作所ヘルスケアビジネスユニット
〔〒277-0804 千葉県柏市新十余二 2-1〕
e-mail: akihiro.odaka.mt@hitachi.com

系をもつ 3T MRI での肩，上肢撮像において，領域を限定する RF shim(Regional RF shim)を最適化し，SAR を低減すると共に，B1 も均一にすることを目的とする．

2. 方法

本研究計画は日立グループ倫理審査委員会で審査済みであり，本研究のデータは全ての被験者からインフォームド・コンセントを得た上で取得した．

2.1. RF shim のアルゴリズム検討

健常ボランティア 15 名の肩、上肢の B1 map を取得し，B1 map を評価しながら Regional RF shim(以下，Regional)のアルゴリズムを調整した．B1 map には種々の計測法が提唱されているが[1][2][3][4]，今回は multi Td 法[5]で計測した(TR, 7.5msec; TE, 1msec; slice thickness, 10mm; FOV, 500×500mm^2; matrix, 64×64×3)．4 チャンネル独立制御可能な RF 照射系を備えた 3T MRI((株)日立製作所製)で撮像した．

Regional では，B1 map から肩や上肢領域のみを抽出し，抽出した領域内の USD (均一度の指標であり小さいほど均一)と SAR の線形結合を，係数(A)を変えて最小化するアルゴリズムを適用した．USD と SAR はそれぞれ式(1)，式(2)で計算した．

$$USD = \frac{\text{標準偏差}\left(B1\left(P_{CH1\sim4}, y_{CH1\sim4}\right)\right)}{\text{平均}\left(B1\left(P_{CH1\sim4}, y_{CH1\sim4}\right)\right)} \quad (1)$$

$$SAR = \sum_i^{CH1\sim4}\left((1-\alpha_i)\times P_i\right)/\text{体重} \quad (2)$$

(P　：　RF 波の照射パワー)

(y　：　RF 波の位相)

(α　：　RF 照射コイルにおけるコイル損失)

Regional の目的関数(F)は式(3)で定義した．

$$F = A\times\frac{SAR}{SAR_{QD}} + (1-A)\times\frac{USD_{(\text{抽出領域})}}{USD_{QD(\text{抽出領域})}} \quad (3)$$

(SAR_{QD}　：　QD 照射時の SAR)

(USD_{QD}　：　QD 照射時の USD)

変数はチャンネル毎の RF 波の照射パワー(P)と位相(y)であり，目的関数(F)を最小にする値を計算した．結果の USD と SAR を，領域を限定しない RF shim (以下，従来法)の結果と比較した．従来法の目的関数(F)は式(4)で定義した．

$$F = 1\times\frac{USD_{(\text{全体})}}{USD_{QD(\text{全体})}} \quad (4)$$

RF 照射不均一は肩では大きくないが，上肢では大きい．そこで Regional の係数(A)は，肩では，従来法と比較して抽出領域の USD が失われず，SAR を最大に低減する値に，上肢では，SAR も抽出領域の USD も低減する値に決定した．

2.2. RF shim の効果確認

健常ボランティア 1 名の B1 map を取得し，Regional と従来法で，各チャンネルの RF 波の照射パワーと位相(shim パラメータ)を計算した．さらに，結果の shim パラメータを用いて，T1-weighted image (T1WI) [6]と STIR 画像を撮像した．撮像パラメータを表 1 に示す．画像の評価には，図 1 のように脂肪領域と筋領域に計 4 つの ROI を設置し，2 つの ROI 内の信号強度(SI)の平均値の差(Signal Intensity Difference，以下，SID)を式(5)で計算した．

$$SID(A,B) = \frac{\left|\text{平均}\left(SI^{ROIA}\right) - \text{平均}\left(SI^{ROIB}\right)\right|}{\text{平均}\left(SI^{ROIA}\right) + \text{平均}\left(SI^{ROIB}\right)} \quad (5)$$

評価項目と，SID 計算に用いた ROI の組み合わせは表 2 のようになる．筋や脂肪の均一度は SID が小さいほど高く，また筋と脂肪のコントラストは SID が大きいほど高いことを意味する．

表 1 撮像パラメータ

	肩		上肢	
	T1WI	STIR	T1WI	STIR
シーケンス	Fast spin-echo	Fast spin-echo	Fast spin-echo	Fast spin-echo
TR/TE	636ms/10.2ms	8989ms/ 65ms	520ms/10ms	4000ms/ 70ms
FOV	160×160mm	160×160mm	170×170mm	170×170mm
Freq#×phase#	352×320	256×192	256×256	256×256
slice thickness	3mm	3mm	5mm	5mm
scanning time	3 min 5 sec	2 min 50 sec	2 min 1 sec	1 min 40 sec

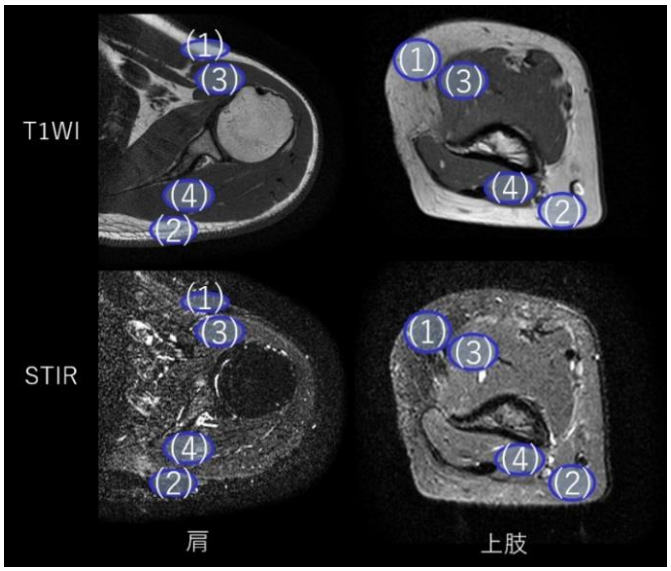

図 1 画像評価での ROI の設置位置
肩(左図), 上肢(右図) , T1WI(上段), STIR 画像(下段)
各番号の位置に, 約 25(縦)×60(横)pixel の楕円の ROI を設置(画像全体は 256×256pixel)

表 2 画像評価の ROI の組み合わせと評価項目

ROI の組合せ	評価項目
(1) , (2)	脂肪の均一度
(3) , (4)	筋の均一度
(1) , (3)	筋と脂肪の コントラスト 1
(2) , (4)	筋と脂肪の コントラスト 2

3. 結果

3.1. RF shim のアルゴリズム検討結果

Regional の係数を 0 から 1 まで 0.1 毎に変えたときの, 被験者 15 人の SAR と USD の平均を図 2 に示す. 結果から, 肩の係数は 0.6 に, 上肢の係数は 0.3 に決定した.

従来法と, 決定した係数の Regional で得られた B1 map における, SAR と抽出領域の USD を表 3 に示す. Regional において, 結果の SAR は肩で約 23%、上肢で約 22%従来法よりも小さくなった. また Regional において, 結果の USD は肩では維持し, 上肢では従来法よりも約 15%小さくなった. USD が低減したことから, 腕領域内の B1 不均一が緩和したことが示された.

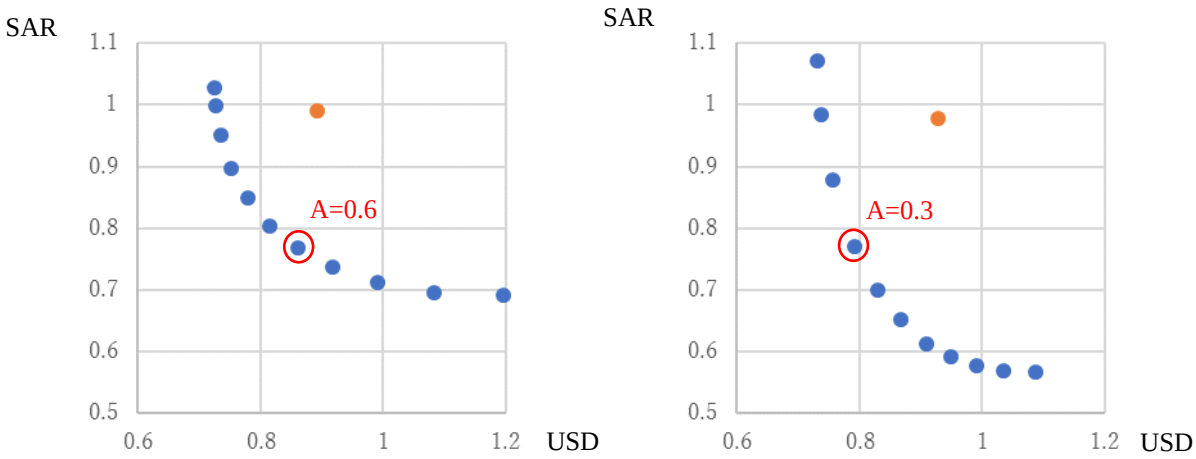

図 2 係数による SAR と USD の変化

被検者 15 人の平均、肩(左図), 上肢(右図) , QD 照射での値を 1 とする

青点 ： 左から順に係数 A=0, 0.1, 0.2, …, 1 での Regional, 橙点 ： 従来法

表 3 従来法と Regional による結果の SAR と撮像領域内 USD

優位確率(p 値)は Student T test により計算した

		従来法	Regional	有意確率(p 値)
肩	SAR	0.99 ± 0.06	0.77 ± 0.10	1.7×10^{-7}
	USD	0.89 ± 0.09	0.86 ± 0.12	2.1×10^{-1}
上肢	SAR	0.98 ± 0.07	0.77 ± 0.09	1.8×10^{-4}
	USD	0.93 ± 0.14	0.79 ± 0.17	2.1×10^{-3}

3.2. RF shim の効果確認結果

従来法と Regional での B1 map を図 3 に示す. Regional によって上肢では, 撮像領域内の B1 の低下が目立つ領域が緩和した. また Regional では, 従来法と比較して, 体幹部における B1 平均が肩で 25%, 上肢で 22%小さくなり, SAR 低減効果が示された.

従来法と Regional により得られた T1WI と STIR 画像を図 4 に, 各画像の SID を表 4 に示す. T1WI と STIR 画像は, 肩では従来法, Regional 共に信号強度の低下は目立たなかった. 上肢では, 従来法において T1WI や STIR 画像で信号強度低下が目立つ領域が見られたが, Regional では緩和された. また肩, 上肢共に, 筋や脂肪の均一度の SID は Regional の方が従来法よりも小さく, 均一度が向上したことが示された. 筋と脂肪のコントラストの SID は, Regional で従来法同等であり、コントラストが維持した.

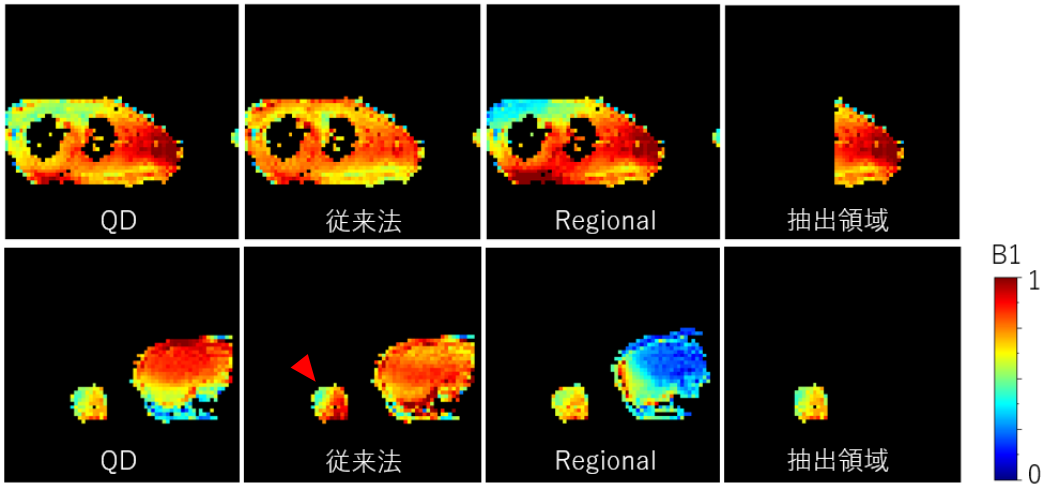

図 3 各手法での B1 map

肩(上段)、上肢(下段)、矢印領域で B1 の低下が目立つ

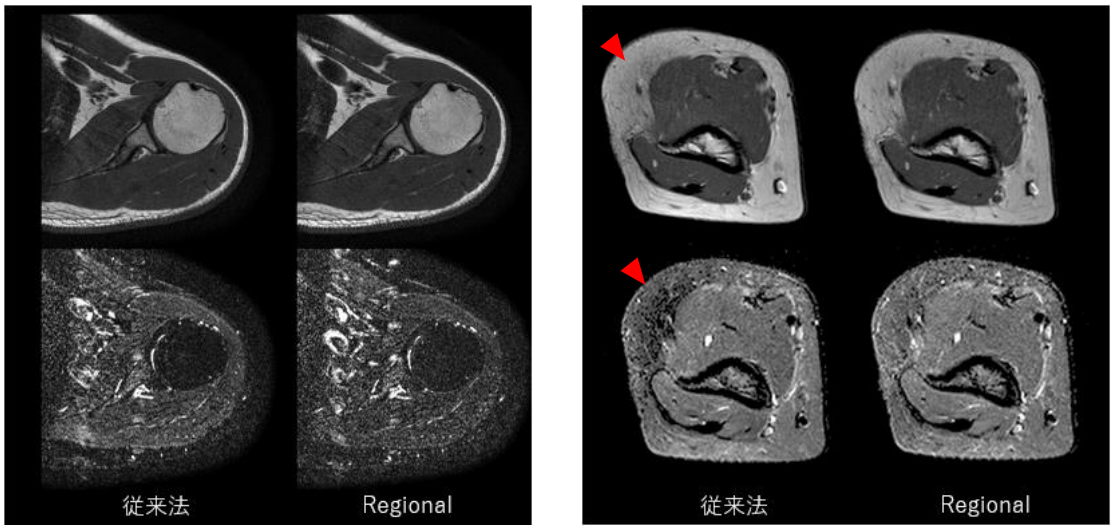

図 4 従来法と Regional により得られた画像の比較

肩(左図), 上肢(右図), 矢印領域で信号強度の低下が目立つ

表 4 従来法と Regional で得られた画像における SID の比較

		肩		上肢	
	評価項目	従来法	Regional	従来法	Regional
T1WI	脂肪の均一度	9.9	0.6	22.2	5.7
	筋の均一度	11.1	5.0	5.1	3.2
	筋と脂肪のコントラスト 1	106.1	113.2	72.7	76.2
	筋と脂肪のコントラスト 2	105.3	110.1	90.8	84.0
STIR	脂肪の均一度	16.3	1.6	20.7	0.3
	筋の均一度	15.3	8.1	12.3	6.9

4. 考察

従来法において，撮像領域のB1不均一は，肩では大きくないが，上肢では大きかった．これは，上肢は体幹部に比べて撮像領域が小さいため，RF shimが従来法では体幹部の方に最適化され，撮像領域で最適化できていなかったためと考えられる．

Regionalによって上肢では，撮像領域内のB1の低下が目立つ領域が緩和したが，画像で対応する領域では信号強度低下が緩和しており，B1不均一の緩和が画像における均一度向上に貢献したことが分かる．

Regionalは，今回適用した肩，上肢以外への適用も考えうる．下肢などにRegionalを適用すれば，各部位で均一な画像を得ることが期待できる．今回の肩・上肢での結果は，4チャンネル独立照射制御システムにおける，Regional RF shimの効果を示すものであり，他部位への展開を考えても効果が期待できる結果であった．

5. 結論

Regional RF shimを肩と上肢の撮像に適用した．SARを20%程度低減し，照射不均一による信号強度低下を改善した．

利益相反の有無

なし

文献

[1] Insko EK and Bolinger L. Mapping of Radiofrequency Field. J Magn Reson Ser A 1993; 103: 82-85

[2] Yarnykh VL. Actual Flip-Angle Imaging in the Pulsed Steady State: A Method for Rapid Three-Dimensional Mapping of the Transmitted Radiofrequency Field. Magn Reson Med 2007; 57: 192-200

[3] Sacolick LI, Wiesinger F, Hancu I et al. B1 mapping by Bloch–Siegert shift. Magn Reson Med 2010; 63: 1315–1322

[4] Nehrke K, Börnert P. DREAM-a novel approach for robust, ultrafast, multislice B(1) mapping. Magn Reson Med 2012;68:1517–1526

[5] Ito, et al. ISMRM 2013; 23: 2598, 2599.

[6] Signal weighting (T1, T2, PD) and sequences parameters : TR, TE, 出版元 Denis Hoa

Regional RF shim reduces SAR in shoulder and upperarm imaging using 4-channel RF transmit coil

Akihiro Odaka[*1], Kosuke Ito[*1], Chikako Moriwake[*1], Masahiro Takizawa[*1]

*1 Hitachi, Ltd. Healthcare Business Unit

【Purpose】In high field MRI, SAR becomes higher, and imaging protocols tend to be limited. Also, spatial distribution of RF irradiation (B1 map) becomes inhomogeneous, and it causes shadings in image. Especially in shoulder and upperarm imaging, the limitation of imaging protocols is severe because head is near. Also, in upperarm imaging, inhomogeneity of B1 map is outstanding because of the interference of trunk region. The purpose of this study is to reduce SAR and to improve B1 homogeneity in shoulder and upperarm imaging.

【Method】Regional RF shim corrects RF irradiation by limiting the area. We optimized Regional RF shim to shoulder and upperarm imaging. 3T MRI system (Hitachi, Ltd.) and 4-channel RF transmit coil were used. 15 healthy volunteers were evaluated. B1 maps were acquired and imaging area was extracted. The algorithm to minimize the linear combination of index of B1 homogeneity and SAR was applied by changing coefficients. We determined the coefficients which reduce both SAR and B1 homogeneity.

【Result】With the determined coefficients, SAR was reduced about 20% compared to the RF shim which doesn't limit the area, and B1 homogeneity of the imaging area was also improved.

Key words: Regional RF shim, B1 map, 3T-MRI, shoulder and upperarm imaging, 4-channel RF transmit coil

著者紹介

小高　晃弘（おだか　あきひろ）
2014 年，東京大学大学院・新領域創成科学研究科修士課程了．同年（株）日立メディコ入社．2015 年より（株）日立製作所ヘルスケアビジネスユニット，現在に至る．MRI の研究開発に従事．日本医用画像工学会，日本磁気共鳴医学会，各会員

伊藤公輔（いとう　こうすけ）
2006 年，東北大学大学院理学研究科修了．2007 年，（株）日立メディコ入社．MRI の開発研究に従事．修士（理学）．第 32 回日本医用画像工学会大会奨励賞受賞．日本医用画像工学会，日本磁気共鳴医学会，各会員．

森分　周子（もりわけ　ちかこ）
1991年大阪大学医療技術短期大学部診療放射線技術学科修了．同年（株）日立メディコ入社．2015年より（株）日立製作所ヘルスケアビジネスユニット．MRIの研究・開発に従事．日本磁気共鳴医学会会員，MRI専任技術者．

瀧澤　将宏（たきざわ　まさひろ）
1994 年，横浜市立大学文理学部物理学課程卒，（株）日立メディコ技術研究所入社．2015年より（株）日立製作所ヘルスケアビジネスユニット，現在に至る．MRI の開発研究に従事．2013 年，千葉大学大学院工学研究科博士課程了，博士（工学）．医用画像工学会論文賞受賞．日本医用画像工学会，日本磁気共鳴医学会，日本放射線技術学会，ISMRM各会員．

放射光 CT 画像による
肺 3 次元ミクロ構造解析

泓田　彰汰[*1]　斉藤　くるみ[*1]　大西　悟[*1]　河田　佳樹[*2]　仁木　登[*2]

梅谷　啓二[*3]　阪井宏彰[*4]　中野恭幸[*5]　岡本　俊宏[*6]　伊藤　春海[*7]

要旨

肺の正常形態と極早期の疾患形態のミクロレベルでの画像化とその定量的な形態解析は，次世代の胸部画像診断への貢献が期待できる．しかし，3 次元のミクロ構造と細血管は十分に解析されていないという現状がある．本研究は，高輝度放射光 CT で撮影した肺 3 次元画像から得られる血管系と壁構造の自動抽出アルゴリズムを構築する．

キーワード：放射光 CT，肺，二次小葉，細葉，SPring-8

1. はじめに

肺の正常形態と極早期の疾患形態のミクロレベルでの画像化とその定量的な形態解析は，次世代の胸部画像診断に貢献することが期待できる．肺は気管支・肺動脈系の太さに応じた支配域に分割される．肺葉と葉気管支，肺区域と区域気管支，肺亜区域と亜区域気管支，肺 2 次小葉と小葉気管支，肺細葉と終末細気管支などは支配域とそれぞれに関与する責任気管支の名前である[1]．末梢肺構造は二次小葉の解剖によって理解され，それに基づいた病態解析が行われている．しかし，3 次元の気管支系や細血管系は十分に解析されていないという現状がある．肺標本を高輝度放射光 CT で撮影し，その画像から気管支系や血管系の微細構造を 3 次元的に可視化して解析する．

*1 徳島大学大学院先端技術科学教育部
システム創生工学専攻
〔〒770-8506 徳島市南常三島町 2-1〕
e-mail: c501838019@tokushima-u.ac.jp
*2 徳島大学大学院社会産業理工学研究部
*3 (財)高輝度光科学研究センター
*4 兵庫県立尼崎総合医療センター
*5 滋賀医科大学
*6 Cleveland Clinic Heart and Vascular Institute
*7 福井大学 高エネルギー医学研究センター

2. 放射光 CT の撮影条件と肺標本

撮影対象の伸展固定肺標本は直径 3.6cm であり，Heitzman 法に準じて作製された．二次小葉の細血管を観察するためにナノ粒子造影剤としてバリウムを使用した．撮影した肺標本は米国人肺標本である．撮影装置には大型放射光施設 SPring-8 の BL20B2 ビームラインを利用した．BL20B2 の光源は偏光電磁石である．このビームラインの全長は 215m であり，光源から標本までの距離は 210m である．ビームサイズは 300mm x 30mm でありビームの広がり角は約 0.0054° と，ほぼ平行な X 線ビームとなっている．ビームサイズに比べ肺標本が大きいため，通常の CT 撮影では肺標本全体の撮影を行うことができない．そこで，以下の方法によりオフセット撮影（拡

大撮影）を行った[2].

(1) 検出器から中心をずらして肺標本を置いた.
(2) 手順(1)の状態で肺標本を 360° 撮影した
(3) 同じ投影方向の左右画像を重複した部分を考慮し重ね合わせた.
(4) 手順(3)で重ね合わせた投影像を 1 枚の投影像として再構成を行った.

撮影には，Nikon 製のカメラ D800E を使用した.

3. 肺胞房領域の解析

我々は，肺胞管と肺胞嚢をまとめた領域を肺胞房領域と仮称している．図 1 の手順に従って肺胞房領域の血管系を解析する．まず，壁構造を抽出し肺動静脈を抽出する．次に，造影剤が充填している細動静脈を抽出する．さらに毛細血管においては，4 次元曲率やヘシアンフィルタなどの各種フィルタを用いて抽出する．抽出結果より，血管系の自動抽出プログラムのアルゴリズム構築を行う. また，壁構造の自動抽出プログラムの作成に向け，壁構造のマニュアル抽出を行い教師データを作成する.

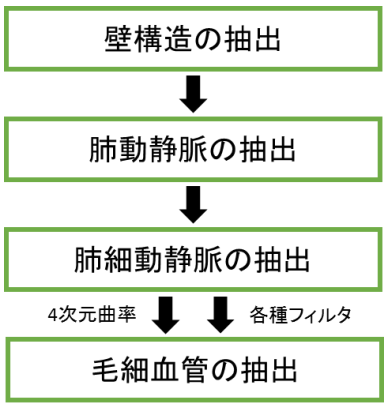

図 1 血管系の解析手順

4. 抽出結果

肺胞房領域における血管のマニュアル抽出結果を図 2 に示す．また，壁構造のマニュアル抽出結果を図 3 に示す．図 2 は肺細静脈まで抽出したものであるが，発表では様々な手法で抽出した毛細血管も合わせて示す.

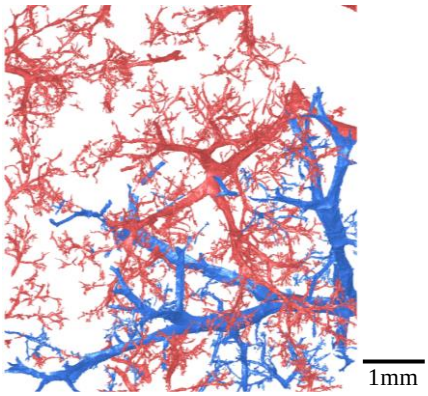

図 2 血管系のマニュアル抽出結果

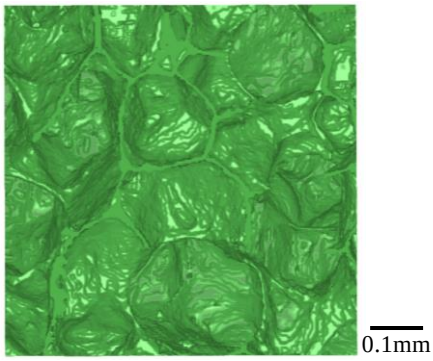

図 3 壁構造のマニュアル抽出結果

5. まとめ

肺標本の放射光 CT 画像から，肺胞房領域の血管系を様々な手法を用いて抽出できた．また，壁構造をマニュアルで抽出し教師データを作成できた．今後は，解析結果から血管系と壁構造の自動抽出アルゴリズムを構築する.

利益相反の有無

なし

文　献

［1］ 伊藤春海 : 呼吸器感染症の画像診断に必要とされる肺既存構造． Antibiotic &Chemotherapy: 22-29, 2007

［2］ K.Saito, Y.Kobayashi, Y.Kawata et al: Bronchial based pulmonary acinus analysis in human lungs using a synchrotron radiation micro-CT, Proc.SPIE Medical Imaging, Vol.10578, pp.105781W-1-6, 2018.2

Analysis of the microstructure of the lung using synchrotron radiation SRμCT images

Shota FUKETA[*1], Kurumi SAITO[*1] Satoru OHNISHI[*1] Yoshiki KAWATA[*2] Noboru NIKI[*2]
Keiji UMETANI[*3] Hiroaki SAKAI[*4] Yasutaka NAKANO[*5] Toshihiro OKAMOTO[*6] Harumi ITOH[*7]

*1 Tokushima University Graduate School of Advanced Technology and Science
*2 Tokushima University Graduate School of Technology, Industrial and Social and Sciences
*3 Japan Synchrotron Radiation Research Institute
*4 Hyogo Prefectural Amagasaki General Medical Center
*5 Shiga University of Medical Science
*6 Cleveland Clinic Heart and Vascular Institute
*7 University of Fukui Biomedical Imaging Research Center

Changes on CT of images at micro level from the normal lung, which indicate a very early stage lung disease and quantitative analysis of morphology on these images may contribute to the diagnosis of chest image in the next generation. However, three-dimensional structures of blood vessels have not been fully analyzed. The purpose of this study is to construct the algorithm for automatically picking up the blood vessels and the wall structure from 3D images using Synchrotron radiation micro CT (SRμCT).

Key words: Synchrotron radiation micro CT (SRμCT), lung, secondary pulmonary lobule, pulmonary acinus, SPring-8

新しいパッド用素材を用いた磁場均一性改善効果の評価

鴨志田　諒[*1]　青羽　南臣[*1]　会田　健人[*1]　永坂　竜男[*2]

五十嵐　寛光[*3]　町田　好男[*1]

要旨

磁場不均一性の改善は MR 撮像において高画質な画像を得るために重要なことであり，これまでに様々な方法による磁場不均一性の改善について検討されてきた．磁場強度が大きく乱れる体の部位の例として頸部が挙げられるが，過去にも頸部にパッドを装着することによる磁場不均一性の改善に関して検討されており，そのパッドの素材として市販の米などを用いることで磁場不均一性が改善され，脂肪抑制画像の画質向上が期待できることが報告されている．本検討では新しいパッド用素材の磁場不均一性改善効果を評価した．

キーワード：MRI，磁場不均一性，パッド，フルオロカーボン

1. はじめに

磁場均一性（静磁場均一性）は MRI における基本的要件のひとつであり，その向上は，MR イメージングの実現及び高速化，あるいは多彩な情報を高精度に得るための前提のひとつである．しかし，実際の撮影では，被検体が入ることによりあらたな不均一性が生じてしまう．

それに対して，臨床現場でも対応可能なパッドを装着する方法もあり，頸部用パッド等の補助具として以前より市販されているものもある．頸部のような形状が複雑な部位では大きな磁場不均一性が発生することが多いが，パッドを装着することにより磁場の乱れを抑制することで，脂肪抑制効果を向上させることができる．また，パッドの素材としてはこれまでも多くの試料が利用されており［1-4］，例えば，被検体の周りを米で満たすことで脂肪抑制効果の向上等が期待できるということが報告されている［1, 2］．本検討では，頸部形状を模擬して作成したファントムを用いて基礎的な実験を行うこととした．

図 1 は今回評価対象とした新素材で，カプセル化したフルオロカーボンである．カプセ

図 1 フルオロカーボンマイクロカプセル（FMC）．細かい粒状のカプセルからなる．

*1 東北大学大学院医学系研究科保健学専攻画像情報学分野
〔〒980-8575 仙台市青葉区星稜町 2-1〕
e-mail:kamoshida.ryo@med.tohoku.ac.jp
*2 東北大学病院診療放射線部放射線部門
*3 株）六濤

ル壁膜材はゼラチン，カプセル粒径は 300 ~ 1000 μm である．以下，フルオロカーボンマイクロカプセル，FMC と呼ぶ．

2. 方法

磁場不均一性の計測のために行った撮像実験と使用したファントム，および後処理について述べる．

1）ファントムの作成

今回の実験では市販のボトルを加工したものをファントムとして使用した．以下，作成方法について説明する．

丸手付ボトルはポリエチレン製で，頸部のような複雑な形状の例として図 2 の赤丸の部分に注目して実験に用いることとした．頸部の周辺にパッドを装着することを模擬するために，図 3 に示す加工を行い，図 4 に示すようにいくつかの試料を充填した．

2）撮像実験

使用装置は Philips 3.0T MRI 装置，ファントムは前記の丸手付ボトルを加工したものである．以下の撮像条件にて絶対値画像と位相画像を取得した．

グラディエントエコー法
TR = 500 ms，TE = 16.1 ms，FA = 18°，
FOV = 180 mm, 収集マトリクス 256×256,
スライス厚 4 mm，スライス枚数 11

上記撮像条件下では，1 ppm の静磁場不均一性は 2.06 回転分の位相差に相当する．よって，位相画像における位相一回転分は 0.485 ppm の静磁場不均一性を表すことになる．

3）位相のアンラッピング処理と磁場強度への換算

得られた位相画像に対し位相アンラッピング処理を施し滑らかにつなげた．これを磁場強度（ppm 表記）に換算し不均一性の評価を行った．

図 2 実験に使用した丸手付ボトル．
（直径 9.1 cm，高さ 25 cm，（株）エーゼット製）

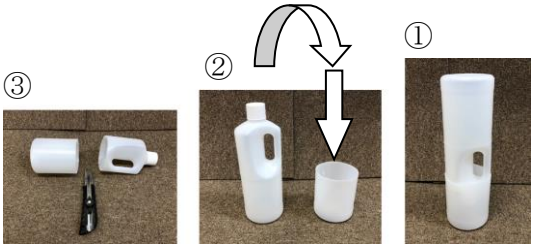

図 3 ファントムの加工手順．
① カッターでボトルを半分にした．
②, ③ 底側の部分に別のボトルを逆さにして挿入した．

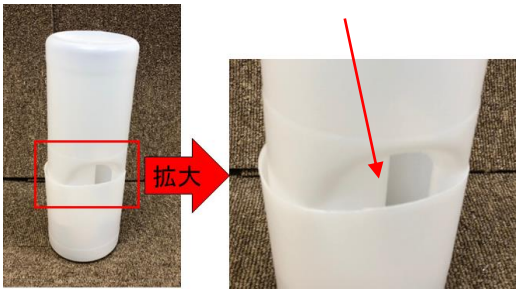

図 4 加工済みファントムへの試料の充填．
ボトル本体の中を水で満たし，赤い囲いの部分にある隙間から 4 種類の周辺物質（空気，水，米，FMC）を容器に充填した．

3. 結果

1）絶対値画像と位相画像

収集により得られた絶対値画像（図 5）と位相画像（図 6）を示す．

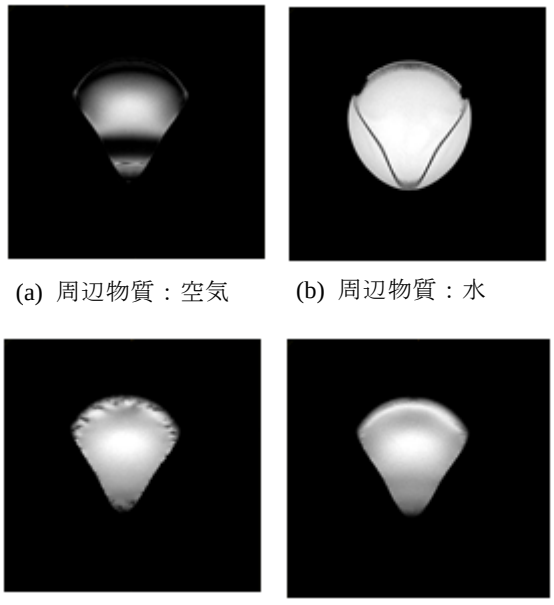

(a) 周辺物質：空気　(b) 周辺物質：水

(c) 周辺物質：米　(d) 周辺物質：FMC

図 5 周辺物質を変えたときの絶対値画像．画質に違いがあることがわかる．

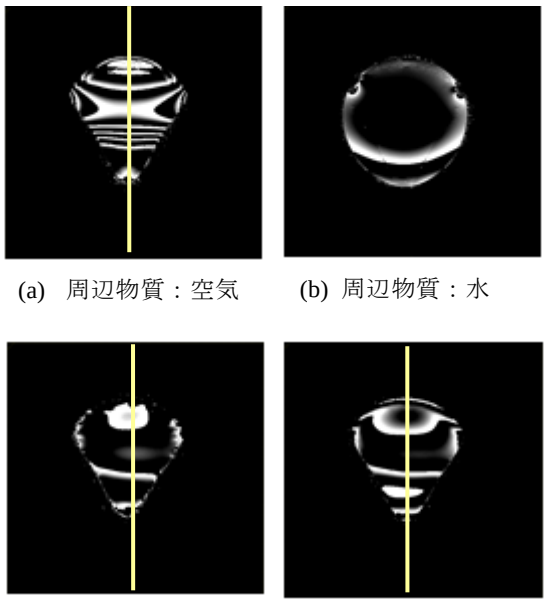

(a) 周辺物質：空気　(b) 周辺物質：水

(c) 周辺物質：米　(d) 周辺物質：FMC

図 6 周辺物質を変えたときの位相画像．磁場不均一性の違いがわかる．

図 5 の絶対値画像では以下のような特徴が見られた．

(a) 周辺物質：空気
通常の撮影と同じ状況．磁場の乱れが原因と思われる信号の低下が見られた．

(b) 周辺物質：水
全体が均一に画像化されている．理想的な画像である．

(c) 周辺物質：米
空気の際に見られた信号の低下が改善されていたが，ファントム辺縁部の画質の劣化が見られた．

(d) 周辺物質：FMC
米と同様に信号の低下が改善されていた．またファントム辺縁部の画質の劣化は見られなかった．

2）位相アンラッピングと不均一性の評価

図 6 中に示した線 ROI 上でアンラッピング処理を行った（図 7）．周辺物質が空気・米・FMC それぞれの場合について，ファントム領域の最大位相差を求め，これを磁場強度（ppm 表記）に換算し，それを本検討における磁場不均一性の指標として比較した（表 1）．

4. 考察

例えば一般臨床で問題となる水と脂肪の周波数差 3.5 ppm を考えると，1 ppm 以下のオーダーへの不均一性改善が求められる．磁場強度分布の計算の結果，周辺物質を FMC とした場合，空気と比べて 1.46 ppm の改善が見られ，ppm 以下のオーダーとなった． FMC による磁場不均一性の改善は他の素材と同様に米に近いものであり，十分な効果が得られたといえる［3］．よって FMC を用いることで，磁場不均一性の有用な改善が期待できると考えられる．

また，FMC の粒子径は米と比べて小さいため，米を使用した際に見られた画質の劣化は見られなくなるという利点もあった．

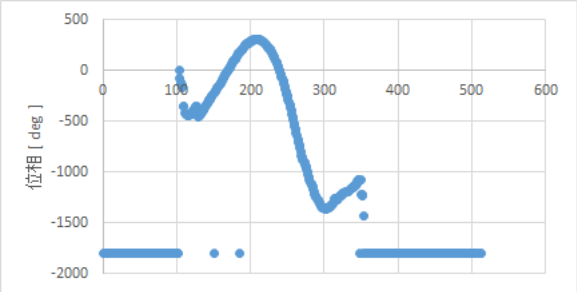

(1) 周辺物質：空気

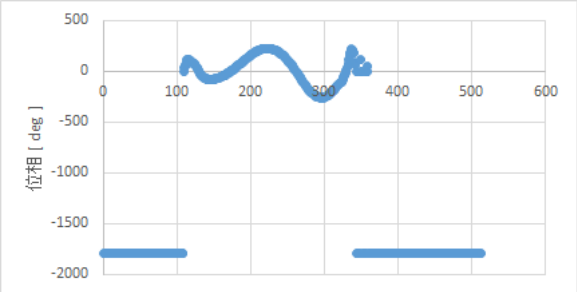

(2) 周辺物質：米

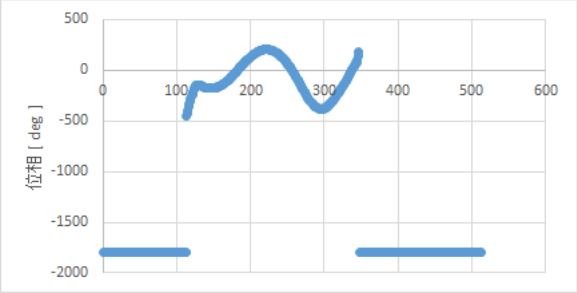

(3) 周辺物質：FMC

図 7 アンラッピング処理後の位相データ.

表 1 線 ROI における最大位相差と磁場不均一性の周辺物質依存性.

	最大位相差 [degree]	磁場不均一性 [ppm]
空気	1667	2.25
米	486	0.655
FMC	588	0.792

5. まとめ

新しい素材である FMC を用いた磁場不均一性の改善効果について，ファントム実験により検証した．その結果，MRI で期待される磁場均一性改善効果を持つことが確認できた．今後はこの素材の特性を活かした使用方法を検討していきたい．

利益相反の有無

なし．

文　献

［1］ Moriya S, Miki Y, Yokobayashi T et al: Improved CHESS Imaging With the Use of Rice Pads: Investigation in the Neck, Shoulder, and Elbow. Journal of Magnetic Resonance Imaging **31**: 1504-1507, 2010

［2］ Moriya S, Miki Y, Yokobayashi T et al: Rice Pads Reduce Geometric Distortion of Echo-planar Diffusion-weighted Images of the Cervical Spinal Cord. Magn Reson Med Sci, **10**: 65-69, 2011

［3］ 池口裕昭，庄内孝春，巳上綾 他：脂肪抑制 Magnetic Resonance Image のためのポリスチレンボール弾を用いた静磁場不均一軽減補助具の試作と効果の検討. 日本放射線技術学会雑誌 **69**: 71-79, 2013

［4］ 真鍋努，永田覚，板垣典子 他：X 線消化管造影剤「硫酸バリウム」を用いた磁場補正効果の検証．第 6 回東北放射線医療技術学術大会予稿集：p72, 2016

Evaluation of magnetic field homogeneity improvement using new pad material

Ryo KAMOSHIDA[*1], Minami AOBA[*1], Kento AITA[*1], Tatsuo NAGASAKA[*2], Hiromitsu IGARASHI[*3], Yoshio MACHIDA[*1]

*1 Tohoku University Graduate School of Medicine
*2 Tohoku University Hospital
*3 Rikutoh Corporation

Magnetic field homogeneity improvement is important for obtaining high quality MR images, and various methods has been studied for the homogeneity improvement. Pad attachment is one of practical approaches for this purpose. It was reported that the fat suppressed MR image quality can be improved in neck examination by using a pad with rice as a material. In this study, we evaluated the magnetic field inhomogeneity improvement by using new pad material.

Key words: MRI, Magnetic field inhomogeneity, Pad, Fluorocarbon

畳み込みニューラルネットワークによる PET 画像ノイズ除去

大手　希望[*1]　得居　葵[*1]　橋本二三生[*1]　磯部　卓志[*1]

斉藤　右典[*1]　大村　知秀[*1]

要旨

畳み込みニューラルネットワーク（convolutional neural network; CNN）を低計数 PET 画像のノイズ除去に応用した．CNN の構造は Remez らの DenoiseNet（DN），U-Net に residual learning を追加したネットワーク（UR-Net）を基にした．DN で横断面を 1 スライスずつノイズ除去すると冠状・矢状面に横筋を生じた．隣接 N スライスを N チャンネル画像としてノイズ除去する DN-Nch により，この問題が解決した．計数を元データの 1/2，1/4，1/8，1/16，1/32，1/64，1/128 とした場合で DN，UR-Net を比較した．計数 1/4，1/8 以外は UR-Net で高いピーク信号対雑音比（peak signal to noise ratio; PSNR）がえられた．UR-Net を 2 段に重ねた UR-Net×2 で，より高い PSNR がえられた．

キーワード：PET，深層学習，デノイジング，ノイズ除去，畳み込みニューラルネットワーク

1. はじめに

陽電子放射断層撮影装置（positron emission tomography; PET）は，陽電子を放出する放射性薬剤を被検体に投与し，生体内の電子と対消滅して生じるγ線対を同時計数することで，生体内の分子や細胞の機能を空間的・時間的に画像化できる分子イメージング装置である［1］.

PET 撮像は，被曝軽減のため，できるかぎり低投与量での計測が求められる．また，ダイナミック収集や全身収集では，短い時間間隔での PET 計測となり，1 フレーム当たりの同時計数が少なくなることに起因して再構成画像の信号対雑音比（signal to noise ratio; S/N）が低下する．そのため，装置の高感度化［2, 3, 4］や，少ない同時計数から低雑音の再構成画像を得る低計数 PET 技術が検討されている．低計数 PET 技術として，次の 3 項目が挙げられる．

（1）統計的画像再構成［5, 6, 7］は，観測データがポアソン分布に従うとして，最尤法により断層画像を再構成する手法であり[15, 16, 17, 18] ，装置の点応答関数やデータ補正[19, 20], 画像の滑らかさなどの先験情報[21, 22]を画像再構成内に組み込むことにより，S/N を改善できることが知られている．一方で，上記手法は膨大な計算時間を要し，かつパラメータの調整が難しい.

（2）サイノグラムのノイズ除去には，バイラテラルフィルタ[8, 23]，制約付き最小二乗法[9], 辞書学習とスパース表現[10, 24]などの技術が応用されている．しかし，depth-of-interaction（DOI）[25]や time-of-flight（TOF）[26]によりサイノグラムが高次元になると，データサイズが大きくなり実行が困難となる場合が生じる.

*1 浜松ホトニクス株式会社中央研究所
〔〒434-8601 浜松市浜北区平口 5000〕
e-mail: kibou@crl.hpk.co.jp

（3）再構成画像のノイズ除去として，ウェーブレット縮退[11]，ガイデッドフィルタ[12, 27, 28]，ノンローカルミーンズ[13, 29]，ブロックマッチング 4D フィルタ[14]などが応用されている．これらは，前述の手法に比べ簡便な手法であるが，再構成画像中における雑音分布の複雑さに起因する誤差が生じる可能性がある[28]．

近年，深層学習（deep learning; DL）[30]と呼ばれる機械学習が，コンピュータビジョンの分野で革新的な技術として注目されている．従来の機械学習が，生データから前もって抽出された特徴量を入力として分類・回帰を学習するのに対して，DL は生データを入力として特徴抽出と分類・回帰を 1 つのネットワークの中で同時に学習する[31]．この特徴を利用して，DL は画像認識[32]などの高次ビジョンだけではなく，超解像[33, 34, 35, 36, 37]，ノイズ除去[38, 39, 40, 41, 42, 43]などの低次ビジョンにも応用されている．DL を再構成画像のノイズ除去に応用することができれば，再構成画像の複雑な雑音の分布を生データから学習し，それに合わせたノイズ除去が可能になると期待できる．

再構成画像のノイズ除去に DL を応用した先行研究として，residual encoder decoder (RED)[41]を低線量 CT 画像のノイズ除去に応用した手法[44]や，4 層の CNN を 3 段に結合した auto-context CNN を PET 画像のノイズ除去に応用した手法[45]が挙げられる．また，Xu らは U-Net[46]に residual learning[47]を追加したネットワーク（ここでは UR-Net と呼ぶ）を，超低計数 PET 画像のノイズ除去に応用した[48]．さらに Gong らは，UR-Net を低計数 PET の統計的画像再構成に画像表現として組み込んだ[49]．上記のように，DL を応用した様々なノイズ除去法が検討されているが，PET 画像について，これらの性能差を比較した研究は行われていない．

そこで本研究では，畳み込みニューラルネットワークの構造の違いによる PET 画像のノイズ除去効果を比較・検討することを目的とする．本論文では，DenoiseNet（DN）[43]，UR-Net[48, 49]，DN を三次元空間に拡張した DN-3D を比較対象とし，頭部 PET 画像に適用した結果を報告する．

2．方法

畳み込みニューラルネットワークの構造の違いによる PET 画像のノイズ除去効果を確認するため，図 1 に示す 4 種類の CNN を用いた．

1）DenoiseNet（DN）

DN は 15 層の CNN である．各畳み込み層では 3×3 のフィルタ 64 個を，下層からの入力に畳み込み，64ch の特徴マップを得る．次に，1ch を出力層に送り，残り 63ch を rectified linear unit（ReLU）

$$f(x) = \max(0, x) \tag{1}$$

で活性化した後，次の層に送る．最後に，入力画像と各層の出力画像を加算し，ノイズ除去画像とする．

2）UR-Net，UR-Net×2

UR-Net は，U-Net[45]と residual learning[46]を組み合わせた構造となる．画像を縮小していくエンコーダー部，画像を拡大していくデコーダー部，特徴マップを画像に変換する再構成部からなる．

エンコーダー部は畳み込み 7 層からなり，ストライド 2 の畳み込みで特徴マップを縮小する．デコーダー部は畳み込み 4 層と逆畳み込み[50]3 層からなり，ストライド 2 の逆畳み込みで特徴マップを拡大する．再構成部は畳み込み 1 層からなる．なお，活性化関数には ReLU を使用し，図 1 に示すように，2，4，6 層目を 8，10，12 層目にスキップ結合する．最後に，入力画像と再構成部の出力画像を加算してノイズ除去画像とする．

UR-Net×2 は，UR-Net を 2 段積み重ねた 30 層の CNN である．

3）DN-3D

DN-3D は 3×3×3 の 3D 畳み込み 10 層からなる．各層は 64ch の 3D 特徴マップの内，1ch を出力層に送り，残り 63ch を ReLU で活性化した後，次の層に送る．出力層では，入力画像と各層の出力画像を加算し，ノイズ除去画像とする．

DenoiseNet（DN）

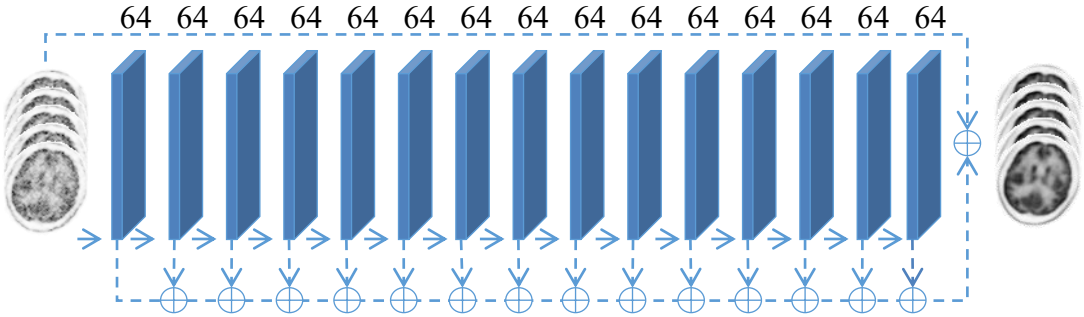

UR-Net

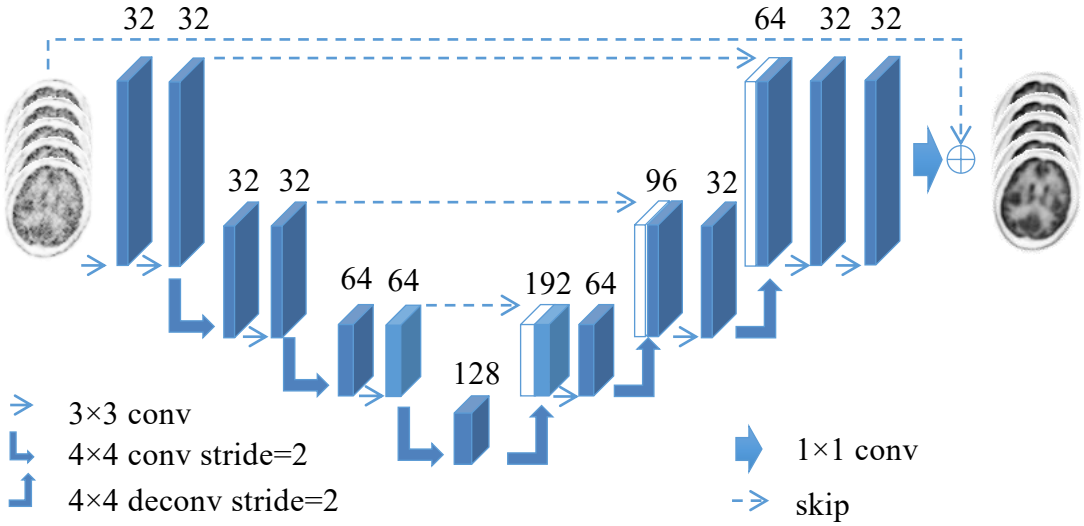

UR-Net×2

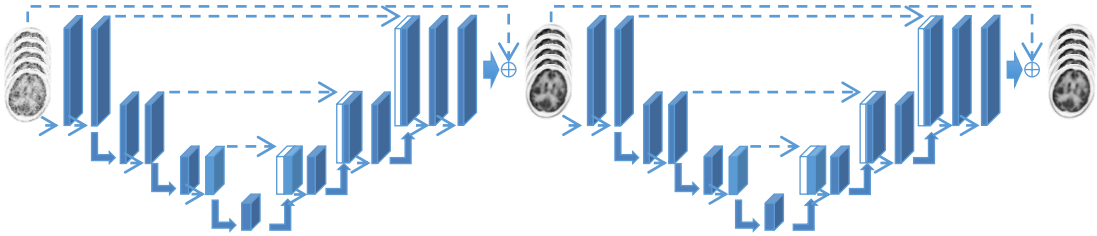

DN-3D

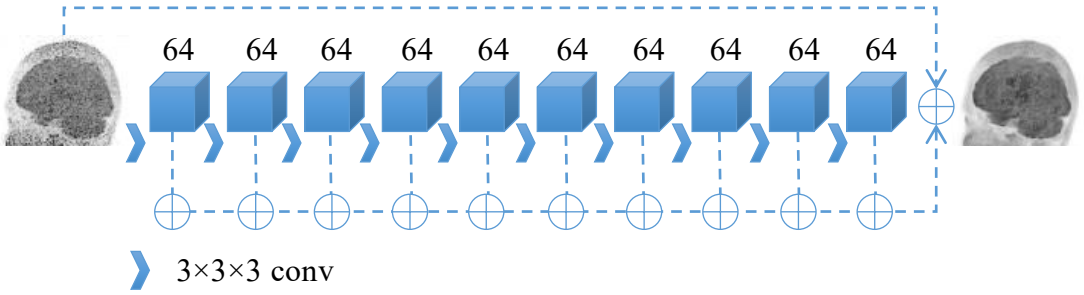

図 1 CNN の構造

4）DN-Nch，UR-Net-Nch

DN-3D は三次元画像を扱うため，計算時間やメモリ使用量が増大してしまう．そこで，隣接 N スライスを N チャンネルの二次元画像として上記ネットワーク構造に入出力し，それぞれ DN-Nch，UR-Net-Nch と表記する．DN-Nch は，各畳み込み層の 64ch の特徴マップの内，Nch を出力層に送り，残り「64-N」ch を次の層に送る．UR-Net-Nch は，入出力以外は変わらない．

5）データセット

共同研究先の浜松医科大学の承認のもと，32 例の頭部 PET 画像を訓練に使用した．1 例を評価用に残し，残り 31 例を訓練用とした．

ニコチン受容体のトレーサーである[^{11}C]-MeQAA[51]を投与された健常ボランティア 32 名は，頭部用 PET 装置（Hamamatsu HITS-655000[52]）にて 62 分間計測された．シングル計数をリストモード収集し，ソフトウェアで同時計数した[53]. その後，同時計数のリストデータをリストモード DRAMA 法[54]で画像再構成した．画像サイズは 128（X）×128（Y）×83（Z）[voxel], 画素サイズは 2.6（X）×2.6（Y）×2.4（Z）mm^3 とした．

同時計数を 1/2，1/4，1/8，1/16，1/32，1/64，1/128 に間引いて再構成し低計数 PET 画像とした．なお，同時計数を間引かない再構成画像を真とした．画像を平均値の 20 倍で割って規格化した．

6）訓練方法

画像の数が少ないため画像からランダムに小領域（パッチ）を抽出し訓練データとした．パッチサイズは Nch : 64（X）×64（Y）×N（Z），3D : 32（X）×32（Y）×32（Z）とし，パッチの XYZ 軸をランダムにフリップし，データを水増しした．パッチ複数個をまとめてミニバッチとし，ミニバッチ単位で CNN の内部パラメータを更新した．

計数 1/32 の低計数 PET 画像のみで訓練した場合と，計数 1/2，1/4，1/8，1/16，1/32，1/64，1/128 を混合し異なる計数のノイズ除去を訓練した場合（ブラインドノイズ除去）の 2 パターンおこなった．バッチサイズは Nch では 32（計数 1/32），または 128（ブラインドノイズ除去），3D では 1 とした．

損失関数にはノイズ除去したパッチと真のパッチの二乗誤差のミニバッチ平均を利用し，誤差逆伝播法[55, 56]と Adam[57]により，CNN の内部パラメータを 20 万回更新した．実装には深層学習フレームワーク Chainer[58]を用い，GPU（Quadro P6000）を用いて高速化した．

7）評価方法

評価用の低計数 PET 画像をノイズ除去し，真の画像とのピーク信号対雑音比（peak signal to noise ratio; PSNR）を評価した．

$$\mathrm{PSNR} = 20\log\left(\frac{\mathrm{Peak}}{\mathrm{RMSE}}\right) \tag{2}$$

Peak は真の画像の最大画素値，RMSE は真の画像とノイズ除去画像の平方平均二乗誤差である．真の画像の「画素値が Peak×0.01 以上の領域」を関心領域（region of interest; ROI）とし，ROI 内で PSNR を算出した．

低計数 PET 画像から一定間隔でパッチを抽出し，ノイズ除去したパッチを書き戻した後，パッチのオーバーラップを平均してノイズ除去画像とした．パッチを抽出する間隔はパッチサイズの 1/4 とした．ただし，Nch ではパッチ抽出の Z 方向の間隔は 1 とした．

3．結果

図 2 に DN，DN-5ch による冠状面のノイズ除去画像を示す．DN は横筋を生じるが，DN-5ch はこれを生じなかった．表 1 に計数 1/32 での DN，DN-3D，DN-5ch の PSNR および計算時間を示す. また，図 3 に更新回数に対する DN-5ch，UR-Net-5ch，UR-Net-5ch×2 の PSNR の推移を示す．

図 4 にブラインドノイズ除去での更新回数に対する DN-5ch，UR-Net-5ch，UR-Net-5ch×2 の PSNR の推移を示す. 計数 1/2 から 1/128 に加えて，真の画像をノイズ除去した場合も示す．これは，Buades らの method noise に相当する[59]. 図 5 にガウシアンフィルタ 6mm（Gauss 6mm），UR-Net-5ch×2 による横断面のブラインドノイズ除去画像を示す．

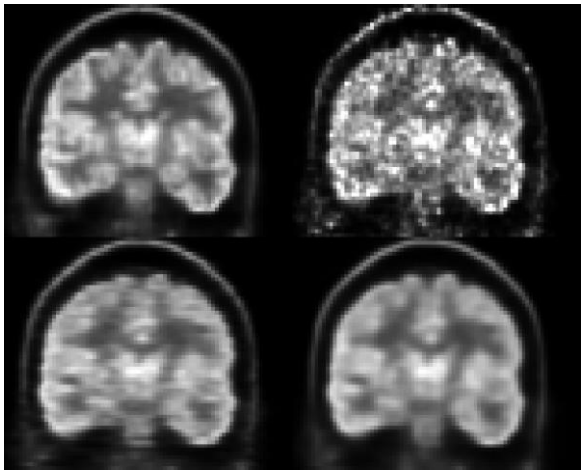

図 2 DN，DN-5ch による冠状面のノイズ除去画像．計数 1/32．左上から真，ノイズ除去なし，DN，DN-5ch．

表 1 計数 1/32 での DN, DN-3D, DN-5ch の PSNR および計算時間．

ノイズ除去	PSNR [dB]	計算時間 [秒]
なし	21.81	-
DN	27.40	2.32
DN-3D	28.39	18.57
DN-5ch	**28.79**	**2.54**

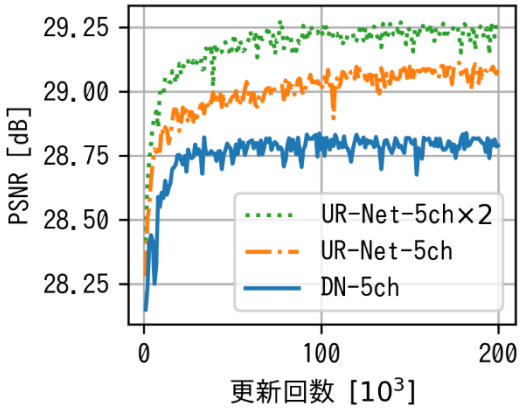

図 3 計数 1/32 での DN-5ch，UR-Net-5ch，UR-Net-5ch×2 の更新回数に対する PSNR の推移．

4. 考察

本研究では，畳み込みニューラルネットワークの構造の違いによる PET 画像のノイズ除去効果を比較・検討した．

図 2 に示すように，DN は冠状面に横筋を生じたが，DN-5ch ではこれを生じなかった．また表 1 に示すように，DN-5ch では，DN-3D の約 1/7.3 の計算時間で，より高い PSNR が得られた．DN-3D に比べ DN-5ch で PSNR が向上した理由として，データセット数の不足が考えられる．今後，2D からの転移学習[60]など，学習方法を工夫すれば 3D でより高い PSNR が得られる可能性があると考えられる．

本研究では，図 3 に示すように UR-Net-5ch×2 で最も高い PSNR がえられた．これらの結果から，PET 画像のノイズ除去では，UR-Net-5ch×2 が最適と考えられる．

図 4 に示すように，ブラインドノイズ除去では，計数 1/4，1/8 以外は UR-Net-5ch で DN-5ch より高い PSNR が得られた．Salmon らはポアソンノイズ除去において，極端な低計数では画素を束ねて 1 画素当たりの計数を増やした方が高い PSNR が得られたと報告しており[60]，PET 画像においても極端な低計数では解像度を落とした方が高い PSNR が得られると考えられる．

図 5 から，計数をまぜた訓練によりブラインドノイズ除去が可能と考えられる．しかし，超低計数での解像感の維持が課題である．

5. まとめ

本研究では，畳み込みニューラルネットワークの構造の違いによる PET 画像のノイズ除去効果を比較・検討した．極端に低計数では DN より UR-Net でより高い PSNR が得られた．隣接 N スライスを N チャンネル画像としてノイズ除去することで，冠状・矢状面の横筋が消失した．UR-Net を 2 段積み重ねた UR-Net×2 で，より高い PSNR が得られた．

謝辞

研究遂行にあたり貴重なご助言を賜った尾内康臣 浜松医科大学教授に深謝いたします．

利益相反の有無

なし．

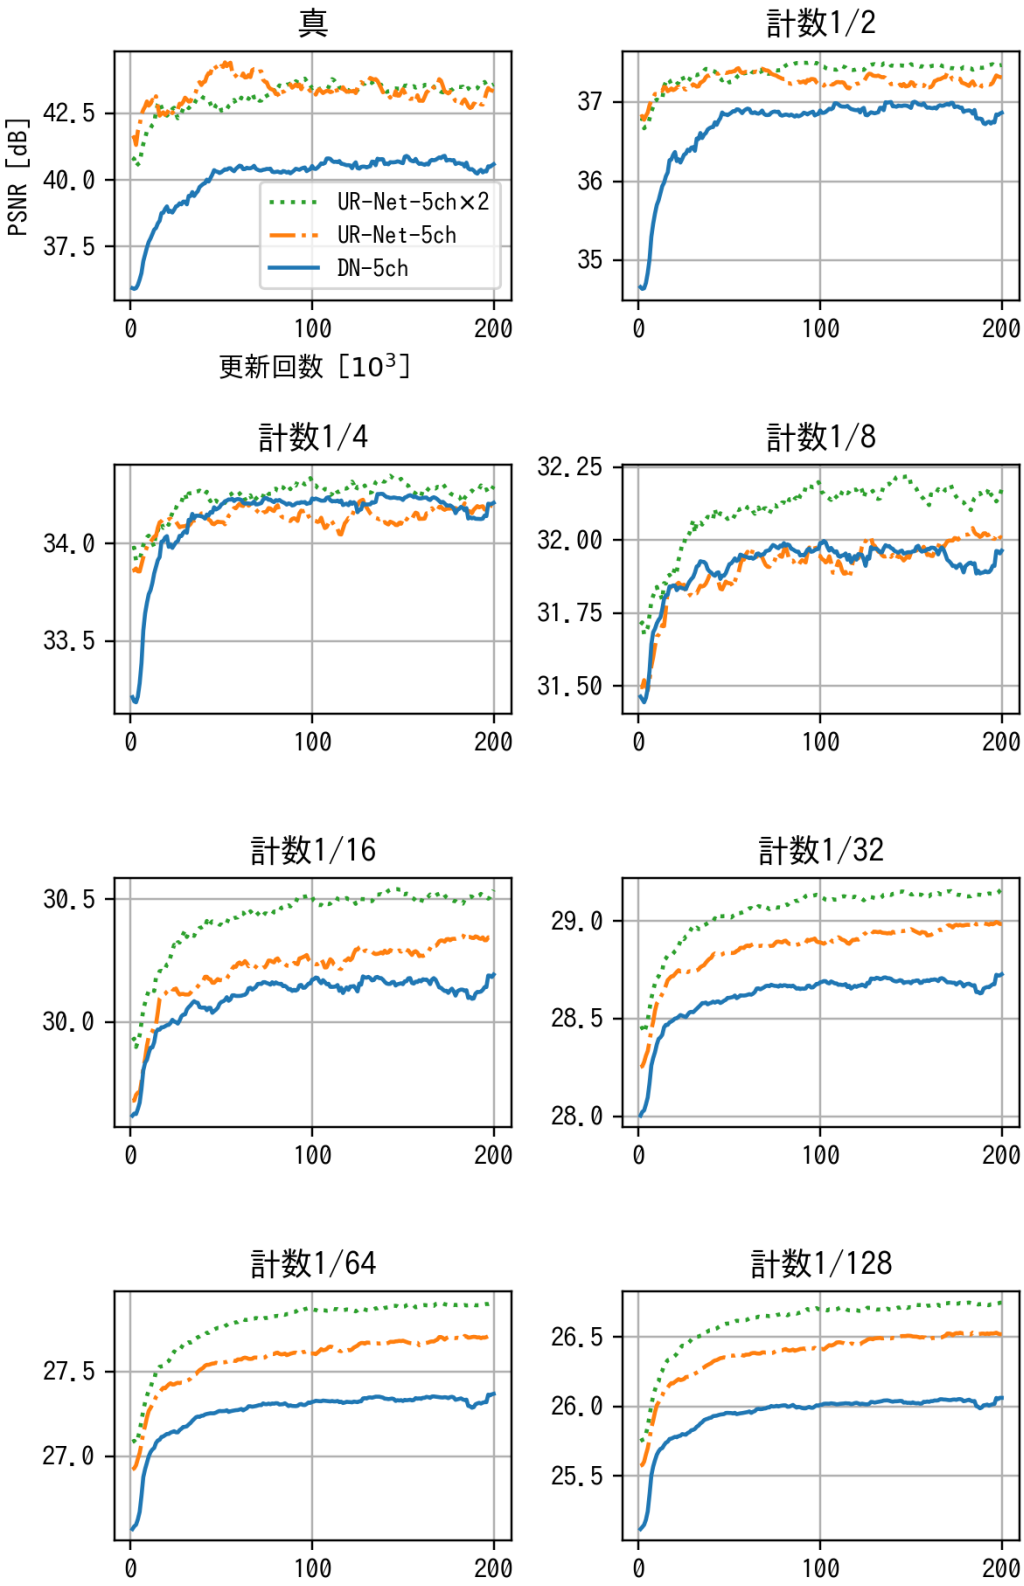

図 4 更新回数に対する DN-5ch，UR-Net-5ch，UR-Net-5ch×2 の PSNR の推移（ブラインドノイズ除去）

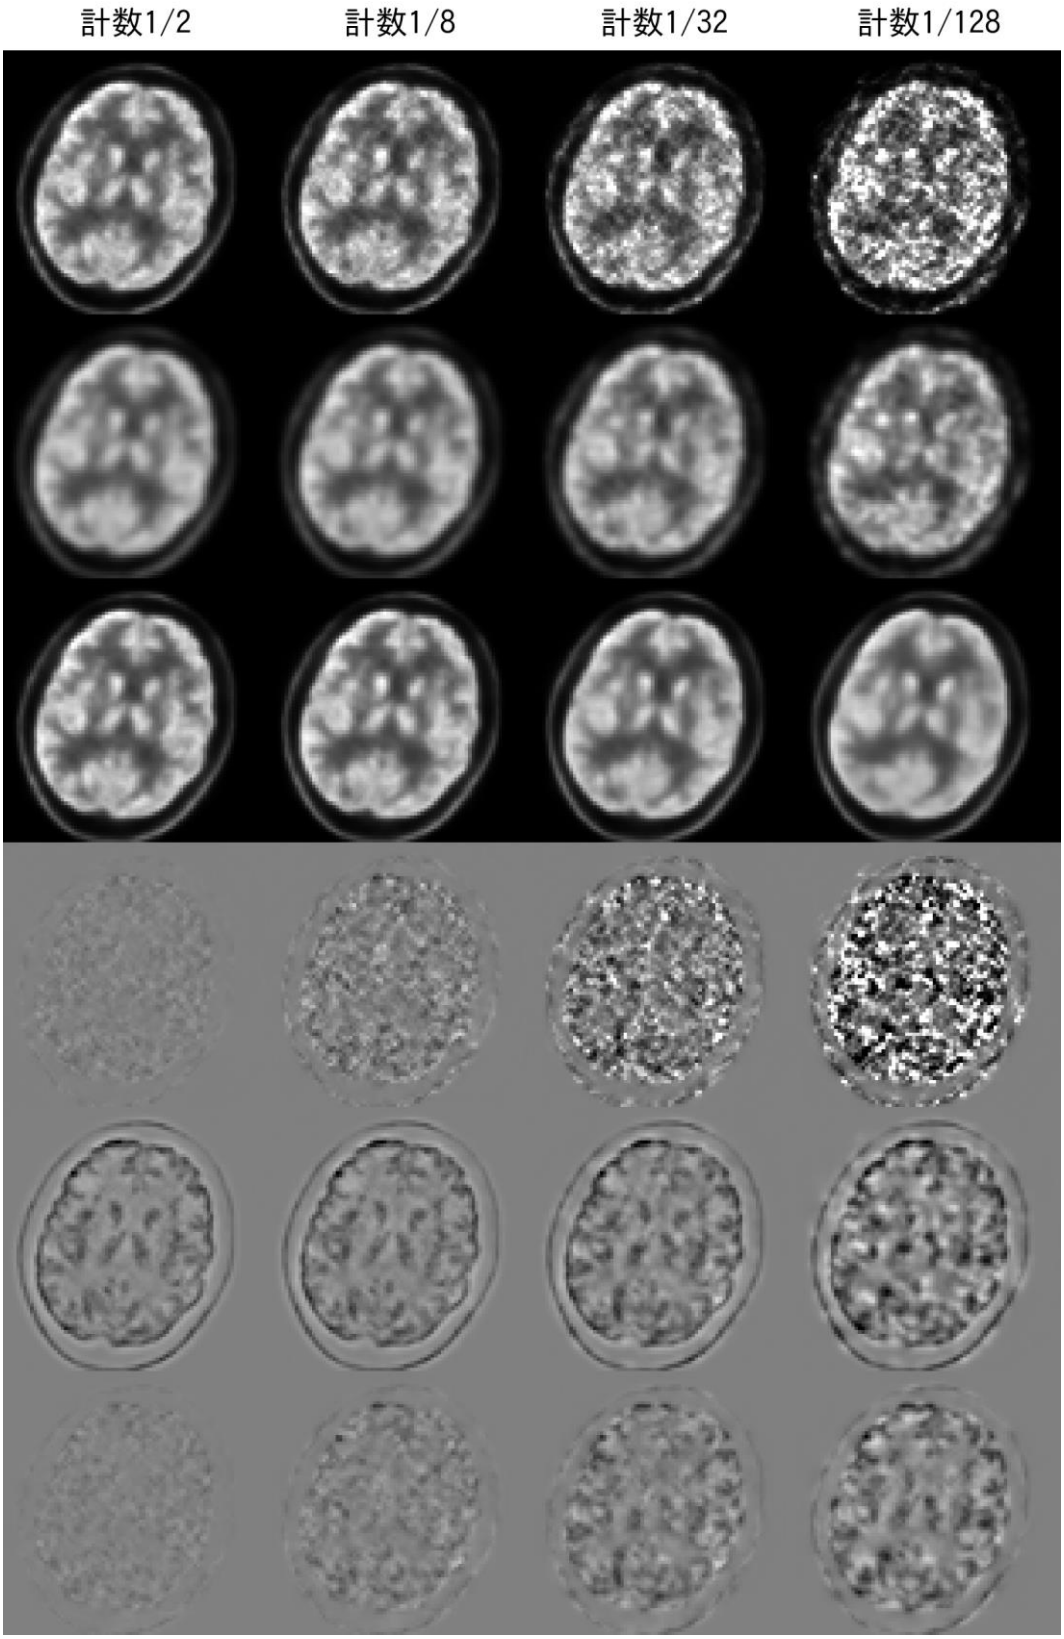

図 5 横断面のブラインドノイズ除去画像．上からノイズ除去なし， Gauss 6mm，UR-Net-5ch×2，下半分は真との差

文　献

［1］　北村圭司：PET．日本医用画像工学ハンドブック編集委員会編：医用画像工学ハンドブック．日本医用画像工学会, 東京, 2012, pp293-320

［2］　Zhang X, Zhou J, Cherry SR: Quantitative image reconstruction for total-body PET imaging using the 2-meter long EXPLORER scanner. Phys Med Biol **62**: 2465-2485, 2017

［3］　Tashima H, Yamaya T: Proposed helmet PET geometries with add-on detectors for high sensitivity brain imaging. Phys Med Biol **61**: 7205-7220, 2016

［4］　Lecoq P: Pushing the limits in time-of-flight PET imaging. IEEE Transactions on Radiation and Plasma Medical Science **1**: 473-485, 2017

［5］　Qi J, Leahy RM: Iterative reconstruction techniques in emission computed tomography. Phys Med Biol **51**: 541-578, 2006

［6］　小林哲哉：エミッション CT における統計的画像再構成の基礎と展開．　Med Imag Tech **31**: 21-25, 2013

［7］　工藤博幸：低被曝 CT における画像再構成法―統計的画像再構成，逐次近似的画像再構成，圧縮センシングの基礎―．　Med Imag Tech **32**: 239-248, 2014

［8］　Mnduca A, Yu L, Trzasko JD et al: Projection space denoising with bilateral filtering and CT noise modeling for dose reduction in CT. Med Phys **36**: 4911-4919, 2009

［9］　La Riviere PJ, Bian J, Vargas PA: Penalized-likelihood sonogram restoration for computed tomography. IEEE Trans Med Imag **25**: 1022-1036, 1990

［10］　Karimi D, Ward RK: Sinogram denoising via simultaneous sparse representation in learned dictionaries. Phys Med Biol **61**: 3536-3553, 2016

［11］　Shidahara M, Ikoma Y, Kershaw J et al: PET kinetic analysis: wavelet denoising of dynamic PET data with application to parametric imageing. Ann Nucl Med **21**: 379-386, 2007

［12］　Yan J, Lim CS, Townsed DW: MRI-guided brain PET image filtering and partial volume correction. Phys Med Biol **60**: 961-975, 2015

［13］　Chan C, Fulton R, Barnett R et al: Postreconstruction nonlocal means filtering of whole-body PET with an anatomical prior. IEEE Trans Med Imag **33**: 636-650, 2014

［14］　Maggioni M, Katkovnik V, Egiazarian K et al: A nonlocal transform-domain filter for volumetric data denoising and reconstruction. IEEE Trans Image Process **22**: 119-133, 2013

［15］　Shepp LA, Vardi Y: Maximum likelihood image reconstruction for emission tomography. IEEE Trans Med Imag **1**: 113-122, 1982

［16］　Hudson HM, Larkin RS: Accelerated image reconstruction using ordered subsets of projection data. IEEE Trans Med Imag **13**: 601-609, 1994

［17］　Browne J, de Pierro AB: A row-action alternative to the EM algorithm for maximizing likelihood in emission tomography. IEEE Trans Med Imag **15**: 687-699, 1996

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

［19］　Panin VY, Kehren F, Michel C et al: Fully 3-D PET reconstruction with system matrix derived from point source measurements. IEEE Trans Med Imag **25**: 907-921, 2006

［20］　Politte DG, Snyder DL: Corrections for accidental corrections and attenuation in maximum-likelihood image reconstruction for positron-emission tomography. IEEE Trans Med Imag **10**: 82-89, 1991

［21］　Green PJ: Bayesian reconstructions from emission tomography data using a modified EM algorithm. IEEE Trans Med Imag **9**: 84-93, 1990

［22］　Nuyts J, Beque D, Dupont P et al: A concave prior penalizing relative differences

for maximum–a-posteriori reconstruction in emission tomography. IEEE Trans Nucl Sci **49**: 56-60, 2002

［23］ Tomasi C, Manduchi R: Bilateral filtering for gray and color images. in *Proc IEEE Int'l Computer Vision Conf*: 839-847, 1998

［24］ Aharon M, Elad M, Bruckstein A: K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation. IEEE Trans Image Process **54**: 4311-4322, 2006

［25］ Yamaya T, Hagiwara N, Obi T et al: Transaxial system mdoels for jPET-D4 image reconstruction. Phys Med Biol **50**: 5339-5356, 2005

［26］ Conti M, Bendriem B, Casey M et al: First experimental results of time-of-flight reconstruction on an LSO PET scanner. Phys Med Biol **50**: 4507-4526, 2005

［27］ He K, Sun J, Tang X: Guided image fitering. IEEE Trans Pattern Anal Mach Intell **35**: 1397-1409, 2013

［28］ 大手希望, 中村明弘, 渡辺光男: がん検診全身 PET 画像の雑音モデルを用いたガイデッドイメージフィルタリング. Med Imag Tech **34**: 259-266, 2016

［29］ Buades A, Coll B, Morel J: A non-local algorithm for image denoising. in *Proc IEEE Conf Comp Vis Patt Recogn* **2**: 60-65, 2005

［30］ LeCun Y, Bengio Y, Hinton G: Deep learning. Nature **521**: 436-444, 2015

［31］ Suzuki K: Survey of deep learning applications to medical image analysis. Med Imag Tech **35**: 212-226, 2017

［32］ Krizhevsky A, Sutskeevr I, Hinton GE: ImageNet classification with deep convolutional neural networks. in *Proc Advances in Neural Inf Process Syst*: 1097-1105, 2012

［33］ Dong C, Loy CC, He K et al: Image super-resolution using deep convolutional networks. IEEE Trans Pattern Anal Mach Intell **38**: 295-307, 2015

［34］ Kim J, Lee KJ, Lee KM et al: Accurate image super-resolution using very deep networks. in *Proc IEEE Conf Comp Vis Patt Recogn*: 1646-1654, 2016

［35］ Kim J, Lee KJ, Lee KM et al: Deeply-recursive convolutional network for image super resolution. in *Proc IEEE Conf Comp Vis Patt Recogn*: 1637-1645, 2016

［36］ Tai Y, Yang J, Liu X et al: Image super-resolution via deep recursive residual network. in *Proc IEEE Conf Comp Vis Patt Recogn*: 2017

［37］ Ledig C, Theis L, Fei-Fei L: Photo-realistic single image super-resolution using a generative adversarial network. in *Proc IEEE Conf Comp Vis Patt Recogn*: 4681-4690, 2017

［38］ Jain V, Seung HS: Natural image denoising with convolutional networks. in *Proc Advances in Neural Inf Process Syst*: 769-776, 2008

［39］ Burger HC, Schuler CJ, Harmeling S: Image denoising: Can plain neural networks compete with BM3D? in *Proc IEEE Conf Comp Vis Patt Recogn*: 2392-2399, 2012

［40］ Xie J, Xun L, Chen E: Image denoising and inpainting with deep neural networks. in *Proc Advances in Neural Inf Process Syst*: 350-352, 2012

［41］ Mao XJ, Shen C, Yang YB: Image restoration using very deep convolutional encoder-decoder networks with symmetric skip connections. in *Proc Advances in Neural Inf Process Syst*: 2802-2810, 2016

［42］ Zhang K, Zuo W, Chen Y et al: Beyond a Gaussian denoiser: Redsidual learning of deep CNN for image denoising. IEEE Trans Image Process **26**: 3142-3155, 2017

［43］ Remez T, Litany O, Giryes R et al: Deep class-aware image denoising. *IEEE SampTA Conf Rec*: 138-142, 2017

［44］ Chen H, Zhang Y, Kalra K et al: Low-dose CT with a residual encoder-decoder convolutional neural network. IEEE Trans Med

Imag **36**: 2524-2535, 2017

[45] Xiang L, Qiao Y, Nie D et al: Deep auto-context convolutional neural networks for standard-dose PET image estimation from low-dose PET/MRI. Neurocomputing **267**: 406-416, 2017

[46] Ronneberger O, Fischer P, Brox T: U-Net: convolutional networks for biomedical image segmentation. in *International Conference on Medical Image Computing and Computer-Assisted Intervention*: 234-241, 2015

[47] He K, Zhang X, Ren S et al: Deep residual learning for image recognition. in *Proc IEEE Conf Comp Vis Patt Recogn*: 770-778, 2016

[48] Xu J, Gong E, Pauly J et al: 200x low-dose PET reconstruction using deep learning. *arXiv preprint arXiv:1712.04119*, 2017

[49] Gong K, Gaun J, Kim K et al: Iterative PET image reconstruction using convolutional neural network representation. *arXiv preprint arXiv:1710.03344*, 2017

[50] Long J, Shelhamer E, Darrell T et al: Fully convolutional networks for semantic segmentation. in *Proc IEEE Conf Comp Vis Patt Recogn*: 3431-3440, 2015

[51] Ogawa M, Nishiyama S, Tukada H et al.: Synthesis and evaluation of new imaging agent for central nicotinic acetylcholine receptor α7 subtype. Nucl Med Biol **37**: 347-355, 2010

[52] Watanabe M, Saito A, Isobe T et al.: Performance evaluation of a high-resolution brain PET scanner using four-layer MPPC DOI detectors. Phys Med Biol **62**: 7148-7166, 2017

[53] Isobe T, Yamada R, K Shimizu et al: Development of a new brain PET scanner based on single event data acquisition. in *Proc IEEE Nucl Sci Symp Conf Rec*: 3540-3543, 2012

[54] Nakayama T, Kudo H: Derivation and implementation of ordered-subsets algorithms for list-mode PET data. in *Proc IEEE Nucl Sci Symp Conf Rec*: 1900-1904, 2005

[55] Rumelhart DE, Hinton GE, Williams RJ: Learning representation by back-propagating errors. Nature **323**: 533-536, 1986

[56] LeCun Y, Boser B, Denker J et al: Handwritten digit recognition with a back-propagation network. Advances in Neural Inf Process Syst **2**: 396-404, 1990

[57] Kingma DP, Ba J: Adam: a method for stochastic optimization. in *Workshop on Machine Learning System at Neural Inf Process Syst*: 2015

[58] Tokui S, Oono K, Hido S et al: Chainer: a next-generation open source framework for deep learning. in *Workshop on Machine Learning System at Neural Inf Process Syst*: 2015

[59] Buades A, Coll B, Morel JM: A review of image denoising algorithms, with a new one. Multiscale Model Simul **4**: 490-530, 2005

[60] Shan H, Zhang Y, Yang Q et al: 3D convolutional encoder-decoder network for low-dose CT via transfer learning from a 2D trained network. *arXiv preprint arXiv:1802.05656*, 2018

[61] Salmon J, Harmany Z, Deledalle CA et al: Poisson noise reduction with non-local PCA. J Math Imaging and Vis **48**: 279-294, 2014

PET Image Noise Removal by Convolutional Neural Network

Kibo OTE[*1], Aoi Tokui[*1], Fumio HASHIMOTO[*1], Takashi ISOBE[*1], Akinori SAITO[*1], Tomohide OMURA

*1 Hamamatsu Photonics, Cnetral Research Laboratory

A convolutional neural network (CNN) was applied to noise removal of low count PET images. The architecture of CNN was based on Remez 's DenoiseNet (DN) and U-Net with residual learning (UR-Net). When noise was removed from the transverse section by one slice at DN, a streak artifact occurred on the coronal / sagittal plane. This problem was solved by DN-Nch which removes noise by using adjacent N slices as N channel images. DN and UR-Net were compared when the count was 1/2, 1/4, 1/8, 1/16, 1/32, 1/64, 1/128 of the original data. A high peak signal to noise ratio (PSNR) was obtained with UR-Net other than 1/4 and 1/8. Higher PSNR was obtained with UR-Net × 2 where UR-Net was stacked in two layers.

Key words: PET, deep learning, denoising, noise removal, convolutional neural network

著者紹介

和文でも英文でも可.

大手　希望　(おおて　きぼう)
1998 年静岡大・工学部・情報知識工学科卒．2000 年同大大学院･理工学研究科･計算機工学専攻了．現在，浜松ホトニクス（株）･中央研究所･第 5 研究室所属．PET 装置の画像再構成，ノイズ除去の研究開発に従事.

得居　葵　(とくい　あおい)
2015 年北里大・医療衛生学部・医療工学科・診療放射線技術科学専攻卒．2017 年筑波大大学院・人間総合科学研究科・フロンティア医科学専攻了．現在，浜松ホトニクス（株）・中央研究所・第 5 研究室所属．PET 装置の画像再構成，ノイズ除去の研究開発に従事.

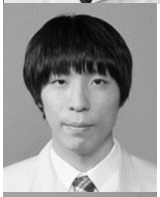

橋本　二三生　(はしもと　ふみお)
2016 年藤田保健衛生大大学院・保健学研究科修士課程修了．診療放射線技師．現在，浜松ホトニクス（株）・中央研究所・PET 研究グループ所属．医用画像処理，解析等の研究に従事．日本放射線技術学会会員.

磯部　卓志　(いそべ　たかし)
1998 年名古屋大大学院・理学研究科・物質理学専攻（物理系）修了．現在，浜松ホトニクス（株）･中央研究所･第 5 研究室所属．PET 装置のデータ収集及び画像再構成システムの研究開発に従事.

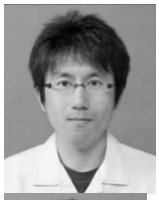

斉藤　右典　(さいとう　あきのり)
2002 年茨城大・理学部・自然機能科学科卒 2006 年同大大学院・理工学研究科卒．現在，浜松ホトニクス（株）･中央研究所･第 5 研究室所属．PET 装置の性能評価等に従事

大村　知秀　(おおむら　ともひで)
1984 年静岡大学工学部電子工学科卒．1986 年同大大学院工学研究科修士課程修了．同年浜松ホトニクス(株)入社．中央研究所第 5 研究室副研究室長．主として PET 装置用検出器の研究開発に従事.

深層学習を利用したMR圧縮センシング再構成の基礎検討

大内 翔平[*1]，伊藤 聡志[*1]

要旨

サンプリング定理を満たさない少数信号から画像再構成を行う圧縮センシングを MRI に応用する場合に，画像再構成に反復処理を伴うため，極めて多くの再構成時間を要するという問題がある．本研究では，圧縮センシングによる少数信号からの再構成画像に生じるアーチファクトを，深層学習を用いて除去する手法を検討する．本方法によれば，従来の圧縮センシングによる再構成法では10秒以上を要した再構成計算が，CPUのみを利用した場合では1.5秒以下に，GPUを利用した場合では0.3秒以下に短縮できた．また，従来の反復的解法では良好な再構成が困難であった間引き法において，本方法では良好な再構成が行える場合があり，本方法の有効性が示された．

キーワード： 圧縮センシング，再構成，深層学習

1. はじめに

MRIにおける撮像では，信号収集に要する時間，すなわち撮像時間がX線CTと比較して長いことが課題となっている．撮像時間の短縮化を目的として圧縮センシング(Compressed Sensing：CS)[1,2]の応用[3]が進んでいる．CSによれば，観測対象の信号がスパース性を満足することを条件に，サンプリング定理を満足しない少数の観測信号からの画像再生を行うことが可能となる．これにより，収集信号量の削減が可能であり，撮像時間の短縮化が図れるが，一方で，画像再構成は数理的な反復処理を伴い，計算コストが大きくなる問題がある．

近年，音声認識や画像認識の分野で，深層学習による手法が従来法を凌駕する性能を示すことが報告され[4][5]，大きな注目を集めている．画像処理の分野では，畳み込みニューラルネットワーク(Convolutional Neural Network；CNN)の様々な問題への適用が進んでおり，JPEGのような圧縮処理が施された画像に生じるアーチファクトやリンギングの除去[6]等に応用されている．

医用画像の再構成に，深層学習を利用する手法の検討も行われており[7]，中でも画像に生じたアーチファクトのみをネットワークに推定させる残差学習法は，アーチファクトを取り除いた画像を直接推定するよりも優れた性能を示すことが報告されている[8]．実際にラジアルスキャンサンプリングによるMR画像に対する，残差学習法による再構成では，従来のCS反復再構成法に比べ，アーチファクト除去性能および詳細構造の復元性能が向上し，再構成時間が高速化したことが報告されている[8].

本研究では，残差学習法による深層学習を利用することにより，MRIのCS再構成を高速化することを目的とする．具体的には，再構成の所要時間および再構成画像の品質について，CS反復再構成法との比較を行った．

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

2. 残差学習法

残差学習法は， K.Zhang らが提案した CNN による画像の白色雑音除去法であり[9]， K.He らによって提案された残差学習[10]の手法を，バッチ正則化[11]と組み合わせて応用している．

残差学習は，深層学習ネットワークの深層構造が原因で生じる，学習効率の低下問題を回避するための手法として提案された．残差学習によるネットワークでは，入力データと出力データの差分をネットワークによって推定する．すなわち，入力データを所望の出力に変換するために必要となる，入力データに加減算するべき成分のみを推定させる．

また, バッチ正則化(Batch Normalization)は学習過程において，学習用データを予め正規化することで，内部共変量シフトによる学習効率の低下の影響を軽減する手法である．

残差学習法では，ネットワークに入力された雑音重畳画像から雑音成分のみを推定し，推定結果を入力画像から減算することで雑音除去画像を得る．本方法によれば，CNNによる雑音除去画像の直接推定法と比して，学習速度および雑音除去性能が向上するとともに，雑音除去法として有名なBM3D (Block-Matching and 3D filtering)， TNRD(Trainable Nonlinear Reaction Diffusion)を上回る結果が得られることが報告されている[9].

3. 圧縮センシング再構成への応用

圧縮センシングの MRI への応用により，収集信号量の削減が可能となるが，削減後の信号に対して未収集点にゼロデータを補い，単純に逆フーリエ変換を行うと（ゼロフィル再構成），再生画像にはアーチファクトが発生する．反復的解法では，この信号に対してスパース化関数を適用し，条件付き最小化問題を解くことによって，再構成を行っていた．良好な再構成画像を得るには，これらの処理を数十から数百回にわたって反復する必要があり(反復的解法)，2 次元画像の再構成に 10 秒以上を要している[12].

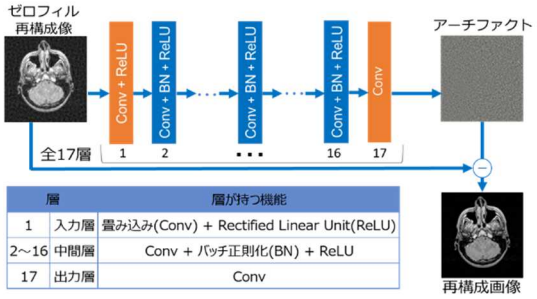

層		層が持つ機能
1	入力層	畳み込み(Conv) + Rectified Linear Unit(ReLU)
2～16	中間層	Conv + バッチ正則化(BN) + ReLU
17	出力層	Conv

図 1. ネットワークアーキテクチャ

本研究ではゼロフィル再構成像に生じるアーチファクトが雑音成分に近似すると仮定して，残差学習法によってアーチファクトを推定し，ゼロフィル再構成像からアーチファクトを取り除くことにより，目標とする像を得る方法を検討する．本方法によれば，ネットワークの学習には時間を要するが，学習済みネットワークを使用したアーチファクトの推定には反復的解法のような反復処理を必要とせず，高速に再構成を行うことが可能となる．

4. 画像再構成シミュレーション

4.1 ネットワークのアーキテクチャ

本研究で使用する深層学習ネットワークのアーキテクチャを図 1 に示す．全 17 層のネットワークとし，第 1 層を入力層，第 2 層～16 層を中間層，第 17 層を出力層とした．第 1 層は，畳み込み(Conv) によるサイズ 3×3×1 のフィルター64 枚と ReLU で構成されている．これにより，入力された画像から 64 通りの特徴を取得することが可能である．第 2 層～16 層は，サイズ 3×3×64 のフィルター64 枚による畳み込みとバッチ正則化・ReLU で構成されている．また，第 17 層は，サイズ 3×3×64 のフィルターによる

畳み込みで構成した．パラメータの更新手法には Adam を採用した．

ネットワークに入力する画像は，ゼロフィル再構成像とし，ネットワークによってアーチファクトのみを推定する．その後，推定した結果をネットワークへの入力画像から減算することで，再構成を行う．

4.2 学習用データセット

本研究ではデータセットとして，全信号による逆フーリエ変換像(フルデータ像)とゼロフィル再構成像の画像対を 40 組用意した．使用した画像は，キャノンメディカル社製 MRI によって撮像した，頭部のプロトン密度強調像である．撮像条件として，高速スピンエコー法を使用し，TR は 3,000ms，TE は 13ms，スライス厚は 3.0mm，フリップ角 90°，分解能は 0.94mm，256×256 画素とした．

ゼロフィル再構成像は，図 2 に示す信号収集点分布に従って収集した信号から再生した．収集する信号量はいずれの分布ともに 40%である．なお， 2 次元方向にランダムな分布を適用した場合，ゼロフィル再構成像にはガウス雑音に近似したインコヒーレントなアーチファクトが生じるが，位相エンコード方向のみにランダムな分布を適用した場合のゼロフィル再構成像には，コヒーレントなアーチファクトが重畳することがあり，ガウス雑音との近似度は必ずしも高くない．

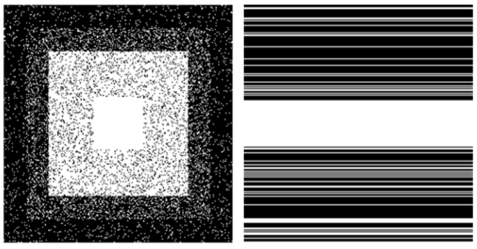

2次元方向 ランダム分布　　位相エンコード方向 ランダム分布

図 2. 使用する信号収集点分布

表 1. 計算機環境

CPU	Intel Core i7-7700 (3.6GHz)
RAM	32GB (DDR4-2400)
GPU	NVIDIA GeForce GTX1080Ti
Software	MATLAB R2017b MatConvNet 1.0-beta25 CUDA Toolkit 9.0 / cuDNN 7.0.5

4.3 データ拡張

本研究では，40 枚のボランティア画像を学習に用いる．深層学習による推定の結果は，学習に用いるデータセットの内容による影響が大きく，データセットが少ない場合，汎化性能が低下する可能性がある．これを考慮して，データ拡張(data augmentation)によって画像対数を増量したデータセットによる学習も行うこととした．本研究では，40 組の画像対に対して 90 度，180 度，270 度の回転を施した画像対を作成することで，合計画像対数を 160 組とした．以降，データ拡張を適用していない，40 組の画像対を持つデータセットを標準データセットとし，データ拡張を適用した 160 組の画像対を持つデータセットを拡張データセットとする．

4.4 画像再構成

本研究で使用した計算機環境を表 1 に示す．標準データセットおよび拡張データセットによって学習したネットワークを使用して，ボランティア画像に対して再構成を行い，反復的解法と処理時間および再構成像の品質の比較を行った．なお，学習はすべての場合において 50 エポックとした．品質の比較には，ピーク信号対雑音比(Peak Signal-to-Noise Ratio ; PSNR)および，画像が持つ構造的特徴の保存性を評価する SSIM(Structural SIMilarity index)[13]を使用した．PSNR は，フルデータ像と再構成像の平均二乗誤差(RMSE)と，フルデータ像の最大輝度値 $\max[\hat{x}]$ を用いて式(1)によって導出する．

$$\mathrm{PSNR} = 20\log\frac{\max[\hat{x}]}{\mathrm{RMSE}}[\mathrm{dB}] \quad (1)$$

また，SSIM は注目画素とその周辺の 11×11 画素を 1 つの領域とし，フルデータ像を X，再構成像を Y とした場合の，領域内の各画素値の平均μ_x, μ_y, 標準偏差σ_x, σ_y, 相互相関σ_{xy} から，注目領域の輝度値$l(X,Y)$, コントラスト$c(X,Y)$, 構造$s(X,Y)$の相似性を導出する．この 3 要素の総合的な相似性$S(X,Y)$を式(2)によって注目画素ごとに求め，各$S(X,Y)$ を平均することで算出する

$$S(X,Y) = l(X,Y)\cdot c(X,Y)\cdot s(X,Y) = \left(\frac{2\mu_X\mu_Y + C_1}{{\mu_X}^2 + {\mu_Y}^2 + C_1}\right)\cdot\left(\frac{2\sigma_X\sigma_Y + C_2}{{\sigma_X}^2 + {\sigma_Y}^2 + C_2}\right)\cdot\left(\frac{\sigma_{XY} + C_3}{\sigma_X\sigma_Y + C_3}\right) \quad (2)$$

式(2)において，C_1，C_2，C_3は発散を防ぐために設けた，小さな正定数である．本研究では画像の最大輝度値を$\max[\hat{x}]$として，$C_1 = (0.01\cdot\max[\hat{x}])^2$，$C_2 = (0.03\cdot\max[\hat{x}])^2$，$C_3 = C_2/2$とした．

2 種類のボランティア画像(モデル 1, モデル 2)に対して，2 次元方向ランダム分布を適用したときの再構成結果を図 3，図 4 に，位相エンコード方向ランダム分布を適用したときの再構成結果を図 5，図 6 に示す．また，図 3，図 5 に示したモデル 1 の画像を本方法によって再構成した際の，各エポック単位での再構成画像の品質評価の推移を図 7，図 8 に示す．各種再構成像の品質評価および学習時間, 再構成時間の比較は表 2 に示した．なお，再構成時間については，同様の再構成処理を CPU で実行した場合と，GPU で実行した場合の処理時間を示す．PSNR と SSIM は 7 枚の再構成画像の平均値を算出したものである．

2 次元方向ランダム分布においては，再構成画像は反復的解法，本方法ともにアーチファクトが除去されていることが確認できる．しかし，フルデータ像と比較すると，反復的解法では再構成画像が若干粗くなり，本方法では平滑化される傾向にあった．また，再構成画像のコントラストも，反復的解法の方が高かった．

位相エンコード方向ランダム分布においては，反復的解法ではアーチファクトの残留が確認されたが，本方法では大部分のアーチファクトを除去できていた．一方で，コントラストに関しては反復的解法による再構成画像の方が高い結果となった．

次に，使用したデータセットによる再構成結果の差異を比較すると，2 次元方向ランダム分布では，両データセットによる再構成画像間でほとんど差が見られなかった．位相エンコード方向ランダム分布では，拡張データセットの使用によって，アーチファクト除去性能が向上していることが確認できた．評価値に関しても，拡張データセット使用時の方が PSNR，SSIM ともに上昇した．また，図 7，図 8 より，拡張データセットで学習した場合，標準データセットを使用した場合と比較してエポック数増加に伴う PSNR，SSIM の推移が安定することが分かった．

表 2 より，学習の所要時間については，データセットの画像対数の増加に従って学習時間も増加した． 再構成時間については，反復的解法が

表 2. 学習・再構成の所要時間および再構成画像の品質評価結果

信号収集点分布	再構成法	データセット	学習時間	再構成時間	PSNR[dB]	SSIM
2 次元方向ランダム分布	反復再構成	－	－	11.4 秒	35.93	0.980
	深層学習再構成	標準	約 75 分	CPU : 1.2 秒	33.05	0.964
		拡張	約 300 分	GPU : 0.3 秒	32.74	0.963
位相エンコード方向ランダム分布	反復再構成	－	－	11.4 秒	29.94	0.933
	深層学習再構成	標準	約 75 分	CPU : 1.2 秒	29.09	0.936
		拡張	約 300 分	GPU : 0.3 秒	29.28	0.937

約 10 秒を要するのに対し，本方法では GPU を利用することで，反復的解法よりも 38 倍高速となる約 0.3 秒となり，大幅に高速化された．

5. 考　察

図 3 から図 6 より，反復的解法と本方法では，使用する分布によって再構成画像の特徴に差異が見られ，２次元方向ランダム分布適用時には反復的解法が，位相エンコード方向ランダム分布では本方法が SSIM の面において優れる結果になった．反復的解法では，反復再構成処理によって未収集信号を復元した信号空間を逆フーリエ変換することで，アーチファクトの除去を図っている．そのため，再構成像の品質は信号収集点分布に伴う信号の間引き方法に影響すると考えられる．一方の本方法では，ゼロフィル再構成像のアーチファクトを推定するため，再構成像の品質は生じたアーチファクトの様相に影響すると考えられる．以上より，適用する信号収集点分布による差異が生じたものと推測できる．

また，拡張データセットを使用した学習においては，標準データセットの使用時よりも学習が安定し，再構成像の品質が向上する傾向にあった．この傾向は，位相エンコード方向ランダム間引き適用時の方が顕著に表れた．これは，残差学習法での除去が想定されているガウス雑音と，実際に生じたアーチファクトとの近似度合いによるものであると考えられる．2 次元方向ランダム分布によって生じるアーチファクトは，インコヒーレントとなり，ガウス雑音との近似度が高い．一方で位相エンコード方向ランダム分布によって生じるアーチファクトは，コヒーレントとなり，ガウス雑音との近似度は低くなる．これにより，位相エンコード方向ランダム分布ではネットワークが十分な学習を行うためには，多くのデータセットが必要となるため，拡張データセットによる品質の向上が見られたが，一方の２次元方向ランダム分布におけるネットワークの学習は，標準データセットのみで十分であったため，拡張データセットによる品質の向上がほとんど見られなかったと考えられる．

6. まとめ

本研究では，MRI における圧縮センシング再構成の高速化を目的として，深層学習による画像再構成について基礎検討を行った．その結果，学習には時間を要したが，再構成時間は大幅に短縮化され，2 次元画像の再構成を約 0.3 秒で行うことができた．また，再構成画像の高画質化の可能性が示された．今後は，さらなる高画質化に向けてネットワークアーキテクチャの改良について検討していく予定である．

謝 辞

本研究の一部は，平成 29 年度科学研究費助成金(基盤研究(C) 16K06379，新学術領域研究 16H01530)により実施された．また，本研究を遂行するにあたり，画像データを提供いただいたキヤノンメディカルシステムズ(株)に感謝の意を表します．

利益相反の有無

なし

文 献

[1] Donoho DL: Compressed sensing. IEEE Trans Inform Theory, **52**: 1289-1306, 2006

[2] Candès EJ, Wakin MB: An Introduction To Compressive Sampling. IEEE Signal Processing Magazine, **25** : 21-30, 2008

[3] Lustig M, Donoho DL and Pauly JM: Sparse MRI: The application of compressed sensing for rapid MR imaging. Magn Reson Med, **58** : 1182-1195, 2007

[4] Hinton GE, Deng L, Yu D et al : Deep Neural Networks For Acoustic Modeling In Speech Recognition. IEEE Signal Processing Magazine, **29** : 82-97, 2012

[5] Krizhevsky A, Sutsukever I, Hinton GE: ImageNet Classification With Deep Convolutional Neural Networks. Advances in Neural Information Processing Systems, Lake Tahoe, 2012, pp1097-1105

[6] Dong C, Deng Y, Loy CC at el : Compression Artifacts Reduction by a Deep Convolutional Network. IEEE International Conference on Computer Vision, Santiago, 2015, pp576-584

[7] Wang S, Su Z, Ying L et al: Accelerating magnetic resonance imaging via deep learning. IEEE 13th International Symposium on Biomedical Imaging, Prague, 2016, pp514–517

[8] Han YS, Lee D, Yoo J et al : Accelerated Projection Reconstruction MR imaging using Deep Residual Learning. 25th Annual Meeting of International Society for Magnetic Resonance in Medicine, Hawaii, O690, 2017

[9] Zhang K, Zuo W, Chen Y et al: Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising. IEEE Transactions on Image Processing, **26**, 3142-3155, 2017

[10] He K, Zhang X, Ren X et al : Deep Residual Learning for Image Recognition. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, 2016, pp770-778

[11] Ioffe S, Szegedy C : Batch normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. 32nd International Conference on Machine Learning, **37**: 448–456, 2015

[12] 小久保 潤, 伊藤 聡志, 山田 芳文 : GPU を利用した FREBAS 変換圧縮センシングの高速化. 第 32 回日本医用画像工学会大会, OP11-6, 2013

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

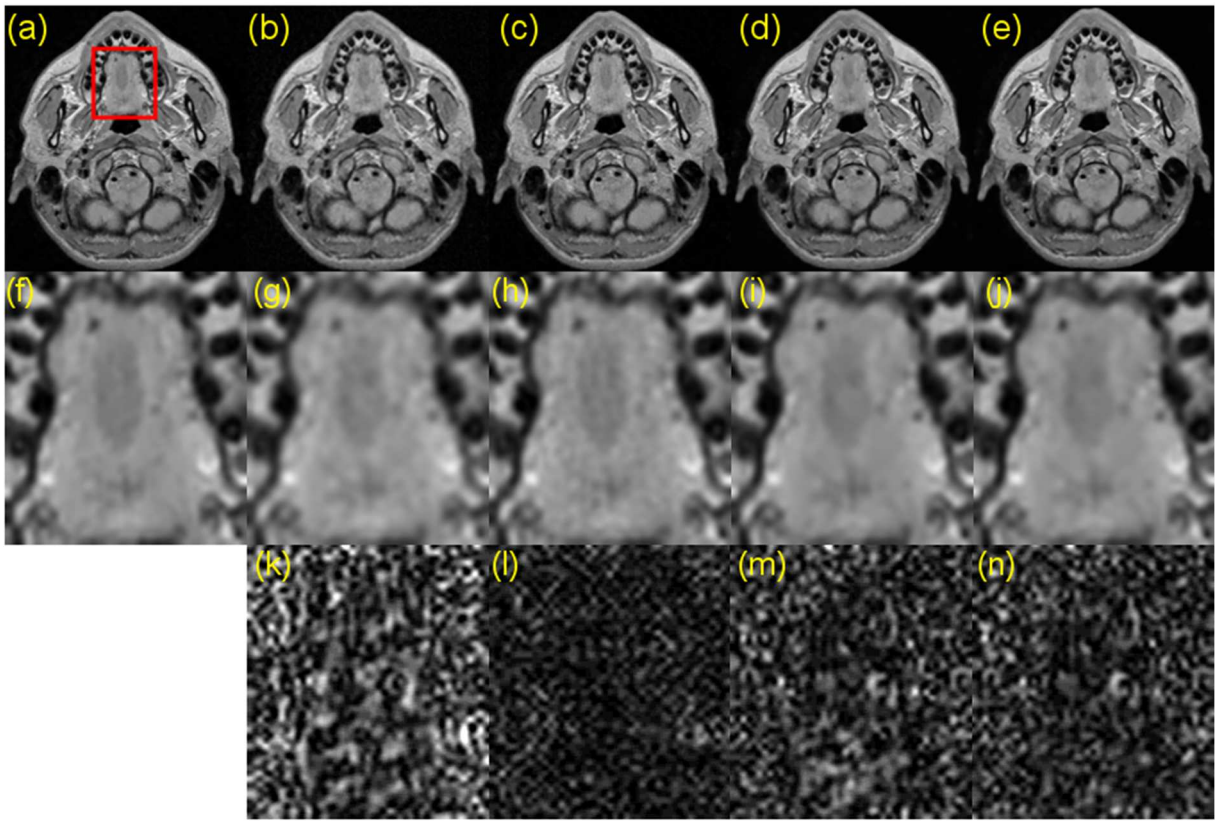

図 3. 2 次元方向ランダム分布適用時の再構成像比較(モデル 1) : (a)フルデータ像, (b)ゼロフィル再構成像, (c)反復再構成像, (d)深層学習による再構成像(標準データセット), (e)深層学習による再構成像(拡張データセット) (f)～(j)はそれぞれ(a)～(e)の拡大画像, (k)～(n)はそれぞれ(g)～(n)のフルデータ像との差分画像

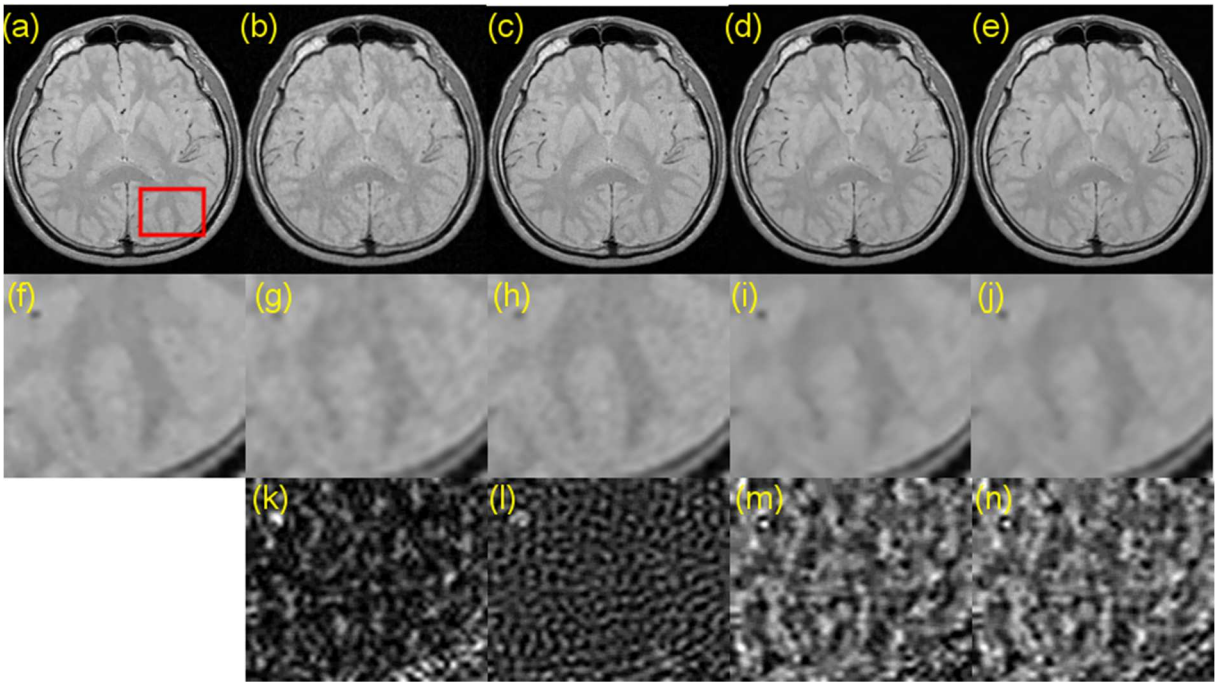

図 4. 2 次元方向ランダム分布適用時の再構成像比較(モデル 2) : (a)フルデータ像, (b)ゼロフィル再構成像, (c)反復再構成像, (d)深層学習による再構成像(標準データセット), (e)深層学習による再構成像(拡張データセット) (f)～(j)はそれぞれ(a)～(e)の拡大画像, (k)～(n)はそれぞれ(g)～(n)のフルデータ像との差分画像

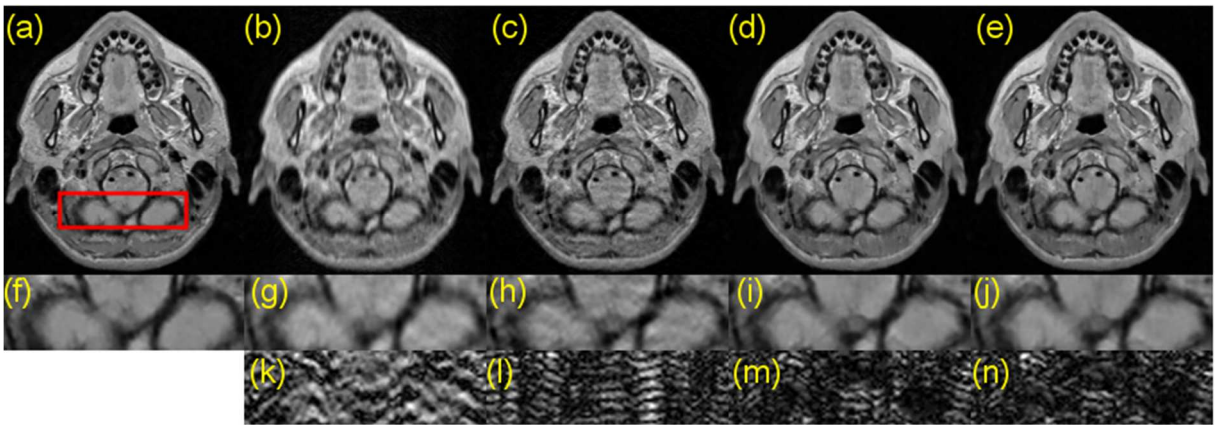

図 5. 位相エンコード方向ランダム分布適用時の再構成像比較(モデル 1)：(a)フルデータ像，(b)ゼロフィル再構成像，(c)反復再構成像，(d)深層学習による再構成像(標準データセット)，(e)深層学習による再構成像(拡張データセット)　(f)～(j)はそれぞれ(a)～(e)の拡大画像，(k)～(n)はそれぞれ(g)～(n)のフルデータ像との差分画像

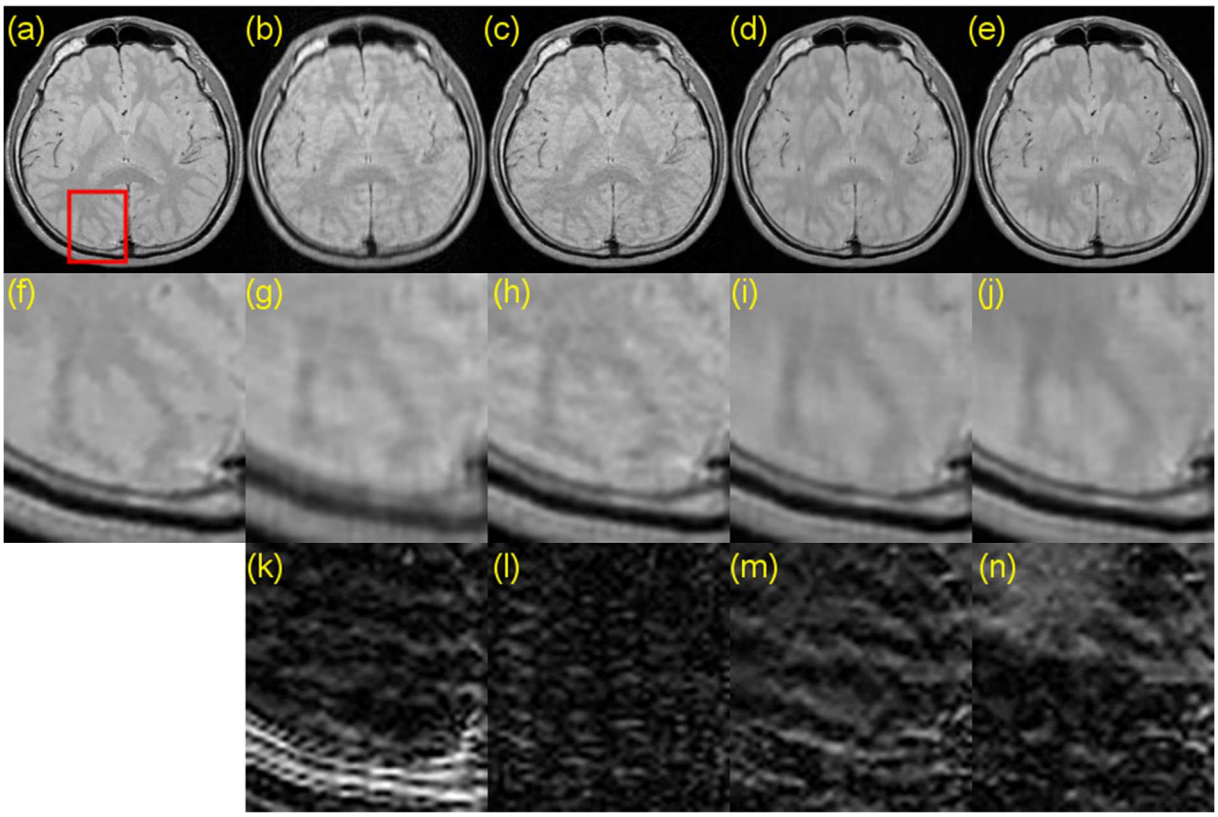

図 6. 位相エンコード方向ランダム分布適用時の再構成像比較(モデル 2)：(a)フルデータ像，(b)ゼロフィル再構成像，(c)反復再構成像，(d)深層学習による再構成像(標準データセット)，(e)深層学習による再構成像(拡張データセット)　(f)～(j)はそれぞれ(a)～(e)の拡大画像，(k)～(n)はそれぞれ(g)～(n)のフルデータ像との差分画像

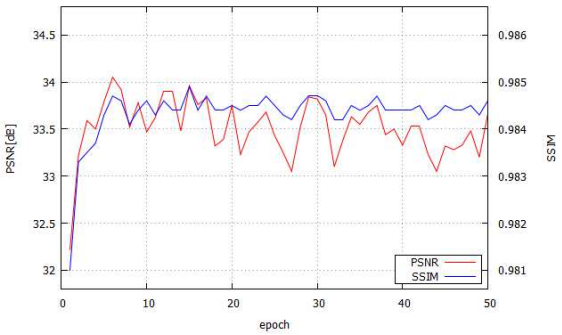

(a)標準データセット使用時

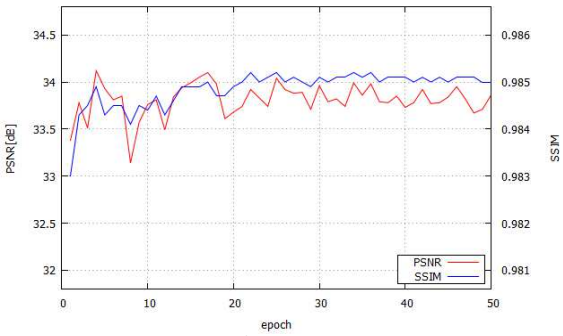

(b)拡張データセット使用時

図 7. 深層学習再構成像のエポック毎の品質評価の推移(モデル１・２次元方向ランダム分布)

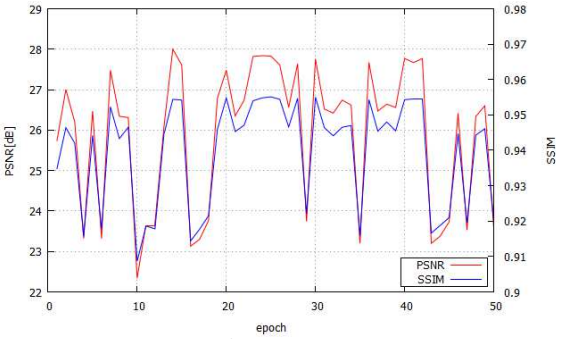

(a)標準データセット使用時

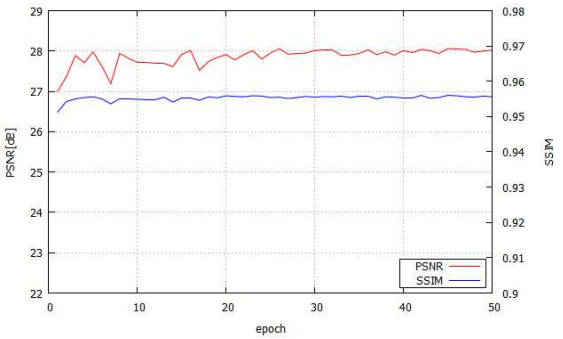

(b)拡張データセット使用時

図 8. 深層学習再構成像のエポック毎の品質評価の推移(モデル１・位相エンコード方向ランダム分布)

Study on MR Compressed Sensing Reconstruction using Deep Learning

Shohei OUCHI[*1], Satoshi ITO[*1]

*1 Graduate School of Engineering, Utsunomiya University

Recently, compressed sensing (CS) has been proposed to reduce the scan time of MR acquisition. CS reconstruction requires an iterative reconstruction, so it is more computationally intensive than traditional inverse Fourier reconstruction, and the obtained image tend to have artificial appearances.In this study, removal of aliasing artifacts due to under-sampling in CS is examined using image processing based on deep learning network. We used residual learning for deep learning network in which reconstruction error is estimated by the pair of clean images and alias occurring images. Reconstruction experiments showed that CPU time is reduced to 1.2s from 11.4s which is required for iterative reconstruction. These results indicate that residual learning has the potential to be high speed and high quality image reconstruction method in CS.

Key words: Compressed Sensing, Reconstruction, Deep Learning

深層学習を利用したMR画像の雑音除去に関する検討

高野 航平[*1]，伊藤 聡志[*1]

要旨

本研究では，深層学習を用いた雑音除去法のMR画像への応用について検討を行った．学習に際して，残差学習法によって雑音を含む入力画像から雑音成分を推定する方式を採用した．本方法を自然画像で雑音除去性能が高いことで知られるBM3D やWNNMと比較した．定量評価ではこの2種と同等以上の結果が得られた．また，本方法は細部構造や医用画像で重要となる弱コントラストの保存性が高いことが示された．また，学習モデルと雑音除去対象の性質の類似度が高いほど有効であることが示唆された．以上により，本方法はMR画像の雑音除去に適した方法であることが示された．

キーワード：雑音除去，深層学習，残差学習法

1. はじめに

核磁気共鳴現象を利用した生体映像法(Magnetic Resonance Imaging：MRI)は，X線CTやPET などの画像診断装置と異なり被曝を伴わずに生体を映像化することができる装置として医療分野で広く普及している．MRI により得られる断層像の画質は，主磁界の高磁界強度化と技術の進展により，高分解能，高 S/N 比化している．しかし，その一方で，パラレルイメージング(parallel imaging)などに代表される撮像や，機能的MRI の撮像の利用が増えたことにより，依然として雑音が混入した低 S/N 比の画像が得られることがある．画像診断の精度を高めるためには生体内の細部構造の保存性と高い雑音除去性能を満足する雑音除去法が必要となり，これまでに多くの方法が提案されているが，平滑化と細部構造の保存という相反する条件を両立することは難しく，改善の余地が残されている．

医用画像の雑音除去問題には，自然画像に対して提案されてきた雑音除去法を利用することが多い．中でも，BM3D(Block-matching and 3D filtering)[1]やWNNM(Weighted Nuclear Norm Minimization)[2]に代表されるNon Local mean法は自然画像の雑音除去問題では高性能で知られ，医用画像に対して応用した事例もみられるが[3]，細部構造の保存が課題となっている．近年，雑音除去問題に深層学習が注目されており，K. Heらが提案する残差学習法[4]を用いた自然画像の雑音除去で良好な結果が得られたとの報告がなされている[5].

本研究ではMR画像の雑音除去問題に対して，残差学習を用いた深層学習を応用する方法について検討を行う．残差学習法は雑音が重畳された入力画像から雑音成分のみを推定する手法である．この手法は雑音量が比較的少ない場合において高い雑音除去効果を示すことが知られており，一般に雑音量が最大輝度値の5%以下の画像が多い MR 画像においても高い雑音除去性能

*1 宇都宮大学 大学院工学研究科
情報システム科学専攻
[〒321-8585 栃木県宇都宮市陽東7-1-2]
e-mail: mt186521@cc.utsunomiya-u.ac.jp

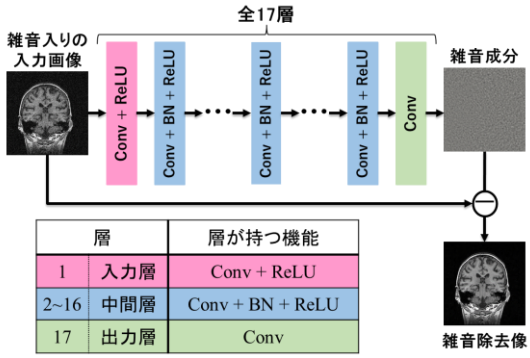

図 1　DnCNN の構成図

を示すことが期待できる．本研究では，深層学習による雑音除去法を，前述した BM3D および WNNM と比較し，信号対雑音比と SSIM[6]による評価を行うとともに得られる画像の特徴を明らかにすることを目的とする．

2. 深層学習を使用した雑音除去法

本研究で用いる基本的なニューラルネットワークには K.Zhang らが提案する DnCNN [5]を用いた．DnCNN の概略を図 1 に示す．第 1 層では畳み込み処理(Conv)と Rectied linear unit(ReLU)を，第 2 層～最終一つ手前の層は Conv と ReLU の間で Batch Normalization(BN)を，最終層では Conv のみを行う．Conv と ReLU には入力データの特徴を抽出する役割があり，BN には学習効率の向上の役割がある．

なお，図 1 におけるネットワークへの入力では，実際には図 2 のように画像を小さな単位に分割するパッチ化を行う．パッチのマトリクスサイズは，ネットワークの層数を d とするとき(2d+1)×(2d+1)が望ましく，パッチのマトリクスサイズを 35×35 とするとき，層数 d は 17 となる．ネットワーク中の畳み込み処理に用いるフィルタサイズは，K.Simonyan らが良好な結果を示した 3×3 とした[7].

DnCNN は学習の際に残差学習法を用いている．残差学習法では，雑音画像から雑音除去像を

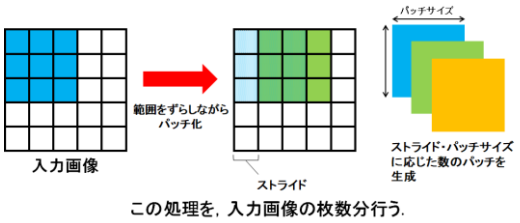

図 2　入力画像パッチ化の概略

推定するのではなく，雑音成分を推定する．そして，雑音画像から推定した雑音を除くことにより雑音除去像を求める．以降，残差学習による雑音除去法を DL と称する．

3. 雑音除去実験と評価

被験者の同意が得られた，高 S/N 比を有する 256×256 画素のプロトン密度強調像(PDW 像)を用いて雑音除去実験を行った．DL は学習するモデルによる雑音除去性能の依存度を調べるために，以下の 2 通りの学習モデルを使用した．

1. 40 種類の PDW 像 を学習した場合(DL_PP)
2. 1 の学習データと撮像断面が同一である 40 種類の T_2強調像(T2W 像)を学習した場合(DL_T2P)

雑音除去性能を評価するために BM3D，WNNM と比較を実施した．この 2 種は図 3 に示すようにいずれも，画像の自己相似性に着目し，画像中に含まれる類似パッチの情報を利用して雑音除去を行う手法である．類似パッチごとにまとめた後における雑音成分の縮退プロセスはこの 2 種で異なり，WNNM の方が複雑かつ時間を要する代わりに，雑音除去像は高品質なものとなる．

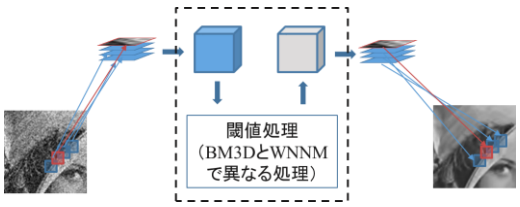

図 3　BM3D，WNNM

雑音は最大輝度値の 5.0%のガウス型白色雑音とし，これを 6 種類のモデル画像に重畳し，雑音除去を行った．

なお，本研究で使用したすべての MR 画像の撮像は，主磁界強度が 1.5T のキャノンメディカル製 MRI で行った．PDW 像は高速スピンエコー法を使用し，エコー時間間隔(TR)が 3000ms，エコー時間(TE)が 13ms，スライス厚が 3mm の条件で撮像が行われた．T2W 像は，TR が 3000ms，TE が 90ms，スライス厚が 3mm の条件で撮像した．雑音除去対象と同一の画像は学習データセットには含めなかったが，同一人物のものであり，撮像断面が異なるものであった．学習時間は CPU 使用のみで約 16 時間，GPU 利用で 1 時間を要した．使用した計算機の仕様を表 1 に示す．MATLAB を用いて深層学習を用いるにあたり MatConvNet を使用した．

表 1　使用した計算機の仕様

CPU	Intel core i7-7700 3.60GHz
GPU	NVIDIA GeForce GTX 1080Ti
メモリ	32GB
コンパイラ	Visual Studio 2017 MATLAB R2017b CUDA 9.0 CuDnn 7.0.5

DL におけるパッチのマトリクスサイズによる PSNR(peak signal-to-noise ratio)と SSIM を比較した．それぞれの平均値を図 4，図 5 に示す．
図 4，図 5 より，DL_PP はパッチのマトリクスサイズが大きいほど良好な結果を示した．

パッチのマトリクスサイズが 40×40 の場合に得られた各方法の PSNR と SSIM それぞれの平均値を図 6 と図 7 に示す．この結果から，雑音除去を行う PDW 像と同じ PDW 像を学習したネットワークを使用した場合に最も高い PSNR が得られ，異なる T2W 像を学習した場合には PSNR が僅かに低下することが示された．また，得られた PSNR と SSIM ともに，BM3D と WNNM より高い値を示した．図 8 に雑音除去像(PDW 像)の例を示す．なお，コントラストを確認しやすくするための調整を行っている．

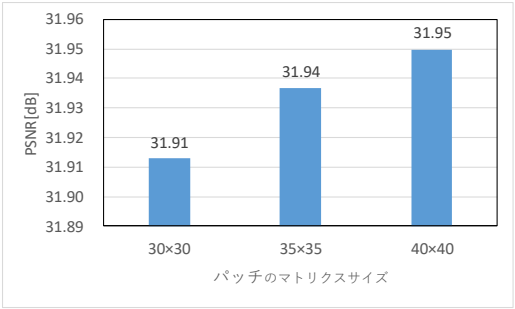

図 4　パッチのマトリクスサイズごとの PSNR

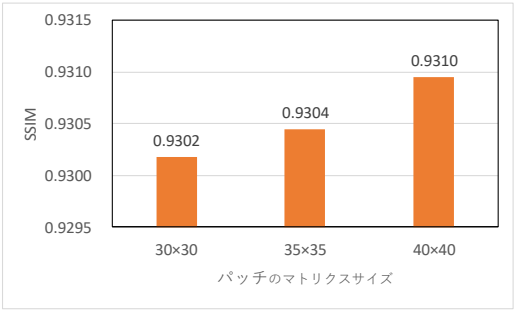

図 5　パッチのマトリクスサイズごとの SSIM

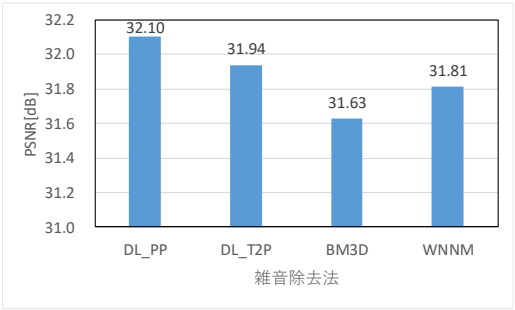

図 6　雑音除去法別 PSNR

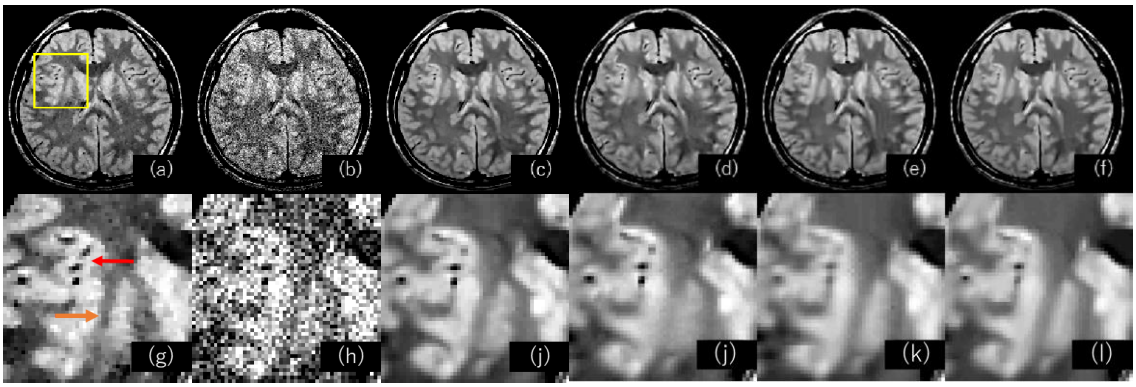

図 8　雑音量 5%での雑音除去像比較：(a)原画像，(b)雑音重畳画像，(c)DL_PP，(d)DL_T2P，(e)BM3D，(f)WNNM，(g)～(l)それぞれ(a)～(f)の拡大画像

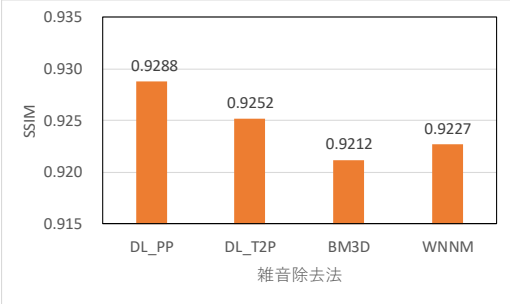

図 7　雑音除去法別 SSIM

図 8 における各拡大画像より，DL による雑音除去像 2 種はともに赤矢印で示す画像左上の黒い小孔が BM3D，WNNM に比べ明瞭に描出されていることが確認できる．図 8 の橙矢印に示す箇所に着目すると，(i)では保てている微弱なコントラストの変化を(j)では保持できていない．また，DL における雑音除去に要した時間は BM3D と同等の約 2 秒であり，WNNM は約 70 秒であった．

5. 考察

図 7 より，BM3D，WNNM では十分に構造を保つことのできなかった小孔などの微細な構造を DL では良好に描出することができ，かつ高い PSNR と SSIM の値を得た．このような微細な小孔は学習した画像群に多く見られたため，数十枚に及ぶ学習により構造の保存性が高められたものと考える．一方，BM3D や WNNM は与えられた単一の雑音重畳画像のみの情報量で雑音除去を行うため小孔を平滑化してしまったものと考える．

DL_T2P は DL_PP に比べると画像の組織部全体に‘もや’がかかった様相を示した．このことから，学習した画像が異なる場合，小孔や輪郭部のような輝度値の強度差が大きい部位は適切に雑音除去できるが，コントラスト変化が小さい部位の描出性能は低下するものと考えられる．これは同じ頭部の画像でも PDW 像と T2W 像とコントラストの異なる像を学習したことが要因と考える．

6. まとめ

深層学習を使用した雑音除去法を MR 画像の雑音除去問題に応用した．雑音除去実験の結果，BM3D や WNNM を大きく上回る雑音除去性能が示された．特に，医用画像で重要となる弱コントラストや細部構造の保存性が優れる結果が得られた．学習に関して対象画像と同種の画像を学習することが有効であった．以上から，深層学習は MR 画像の雑音除去法として優れた性能を有しており，有用な方法になりうることが示唆された．今後はさらに，異なる層数での検証や，

多様な学習データのパターンでの検証などを通じて雑音除去性能の改善を図る予定である.

謝 辞

本研究の一部は，平成 29 年度科学研究費助成金(基盤研究(C) 16K06379，新学術領域研究 16H01530)の補助を受けて実施された．また，本研究を遂行するにあたり，画像データを提供いただいたキヤノンメディカルシステムズ(株)に感謝の意を表します.

利益相反の有無

なし

文 献

[1] Dabov K, Foi A, Katkovnik V et al: Image Denoising by Sparse 3-D Transform-Domain Collaborative Filtering. IEEE Tran Image Proc **16**: 2080-2095, 2007

[2] Gu S, Xie Q, Meng D et al: Weighted Nuclear Norm Minimization and Its Applications to Low Level Vision. Conf IEEE CVPR, Columbus, 2014, pp.2862-2869

[3] Manjn JV, Caballero JC, Lull JJ et al: MRI denoising using non-local means. Med Image Anal **12**: 514-523, 2008

[4] He K, Zhang X, Ren S et al: Deep residual learning for image recognition. Conf IEEE CVPR: Las Vegas, 2016, pp.770-778

[5] Zhang K, Zuo W, Chen Y et al: Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising. IEEE Tran Image Proc **26**: 3142-3155, 2017

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

[7] Simonyan K, Zisserman A: Very deep convolutional networks for large-scale image recognition. ICLR: arXiv:1409.1556 [cs.CV], San Diego, 2015

Study on MR Image Denoising using Deep Learning

Kohei TAKANO[*1], Satoshi ITO[*1]

*1 Graduate School of Engineering, Utsunomiya University

In this study, studies on image denoising method using deep learning is examined. Learning process estimate noise component from input noisy image based on residual learning. Proposed method was compared to BM3D or WNNM that is known as the state-of-the art in denoising of natural images. Simulation studies showed that superior results were obtained in both PSNR and SSIM evaluations. In addition, details or contrast of images were much more remained in proposed method than BM3D or WNNM. These results indicate that proposed Deep Learning based denoising has a possibility to be an excellent image denoising method in MR imaging.

Key words: Image Denoising, Deep Learning, Residual Learning

テンプレート（全ての原稿の種類に共通） Ver. 2.1（2017.3.21 改訂）

クラスタリングに基づく CNN 選択による MRI 高画質化の検討

野口　喜実[*1]　荻野　昌宏[*1]

要旨

近年注目されている畳み込みニューラルネットワーク（CNN）は特に画像認識分野において広く用いられている手法であるが，画像再構成技術への応用も可能であり，従来技術と比較して高い性能が得られている．本研究では CNN を利用し，少数の観測データから再構成された劣化 MRI 画像の高画質化について検討した．本検討においては，公開されている約 550 枚の画像データをフーリエ変換して作成した観測データから高周波成分 75%を除去することで 4 倍速相当の劣化画像を作成し，ネットワークを学習した．また, 画像の局所的な特徴量をクラスタリングによって分類し, それぞれ異なる CNN に入力することにより，画質の向上を図った．同様に作成した 31 枚の評価用画像において PSNR35.1dB を実現し，単一の CNN を利用した場合に比べて約 1.3dB の画質向上を確認した．

キーワード：MRI，高画質化，CNN

1. はじめに

MRI(Magnetic Resonance Imaging)装置は放射線による被ばくがなくコントラストに優れること等から，全身の診断に用いられているが，撮影に時間を要することが課題である．例えば頭部のルーチン検査では 15～25 分程度を要し，腹部においては息止めの必要がある等，被撮影者の負担も生じており，撮影時間の短縮が望まれている．MRI の撮影高速化に関しては，圧縮センシング[1]が用いられつつあるが，繰り返し最適化処理による再構成時間や画質等の課題がある．

本検討では少数の観測データにより再構成された劣化 MRI 画像を，CNN を用いて高画質化することにより，MRI の撮影を高速化する手法について検討した．

近年 CNN(Convolutional Neural Network)をはじめとする Deep Learning を用いた画像処理技術が盛んに研究されており，画像認識分野だけでなく超解像技術[2]やボケ除去，欠損復元[3][4]など, 画像処理への応用においても従来技術と比較して高い性能が報告されている．また CNN は多数の畳込みフィルタで構成されており，繰り返し処理に比べ，並列計算による高速化が可能である．

以降，2 章で提案手法について説明する．また 3 章において実験に利用したデータと実験結果について述べ, 4 章にて結論を述べる．

2. 提案手法

本章ではまず 2.1 節において提案手法で利用したネットワークの構造について概要を述べた後，2.2 節において提案手法について詳細に説明する．

*1 株式会社 日立製作所 研究開発グループ
〔〒185-8601 東京都国分寺市東恋ヶ窪一丁目 280 番地〕
e-mail: yoshimi.noguchi.mf@hitachi.com

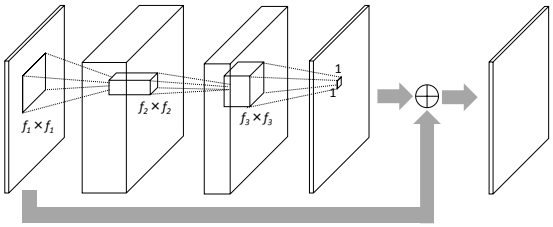

図 1 使用したネットワーク構成

2.1. ネットワーク構造

CNN を用いた劣化画像の高画質化技術として，SRCNN と呼ばれる超解像手法がある[2]．SRCNN で利用されるネットワークはプーリング層を持たず，3 つの畳込み層のみで構成される．SRCNN の学習においては，元画像を教師データとし，元画像を縮小して生成した劣化画像を入力画像として学習を行う．パッチを切り出して学習することにより，データ拡張と学習時間の短縮を実現しており，従来手法であるスパースコーディング等と比較しても高い精度が得られている．

本検討においても SRCNN と同様のアプローチを検討した．利用したネットワーク構造を図 1 に示す．少数の観測データから再構成した劣化 MRI 画像からパッチを切り出して入力とし，劣化のない MRI 画像を教師として学習させることで MRI 画像の高画質化を実現する．また，最終層に Residual 構造[5]を設けることで精度向上を図った．

2.2. クラスタリングを用いた適応的ネットワーク選択

本検討では画質向上のため，学習データセットをクラスタリングによりサブセットに分類し，サブセットごとにネットワークの学習および最適化を行うこととした．クラスタリングには k-means 法を用い，学習データを 4 クラスに分類した．またクラスタリングに用いる特徴量ベクトルとしては，処理速度も考慮し，入力パッチの輝度値を 1 次元ベクトル化し利用することとした．

提案手法の概要を図 2 に示す．推定時には，図 3 に示すように，入力パッチと各クラスタ重心との最近傍探索することによりネットワークを選択することとした．

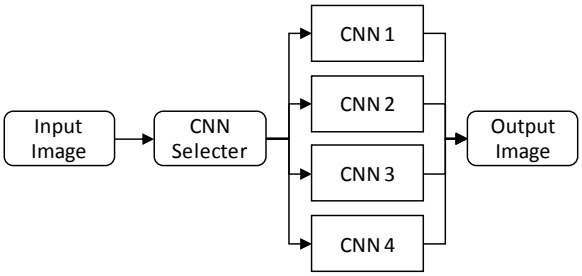

図 2 提案手法の概要

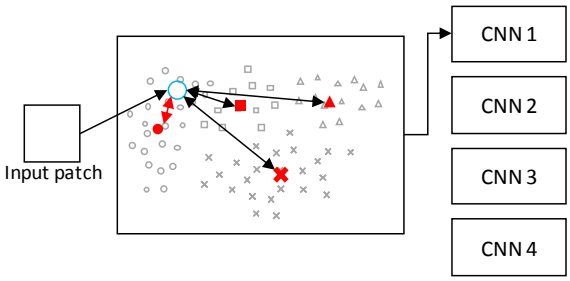

図 3 最近傍探索による CNN の選択

3. 実験

手法の有効性を検証するために実験を行った．3.1 節にて使用したデータおよび学習データの生成方法について述べる．また 3.2 節にて実験結果を示す．

3.1. 学習データ

本検討においては，学習および評価用のデータセットとして，IXI dataset[6]を利用した．581 枚の頭部 T1 強調画像から，評価用データとして無作為に 31 枚を抽出し，残りの 550 枚を用いてネットワークを学習させた．なお，学習データのうち 50 枚をバリデーションデータとして利用し，パラメータの最適化を実施した．

学習データの生成手法について述べる．まず劣化のない元の MRI 画像をフーリエ変換し疑似的な k-space データを作成する．作成した k-space データから 25%のデータをサンプリングし，逆フーリエ変換することで 4 倍速相当の劣化画像を作成した(図 4)．k-space

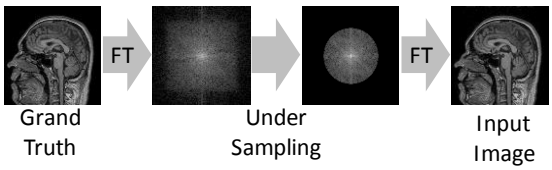

図 4 学習データの作成

図 5 サンプリングパターン

データのサンプリングパターンとしては，平行線状，放射線状および円形状の 3 パターンについて検討した(図 5)．なお，学習におけるパッチサイズとして 33×33 画素とした．

3.2. 実験結果

まずサンプリングパターンを変えた場合について，学習時のバリデーションデータにおける平均 2 乗誤差の推移を図 6 に示す．図 6 に示すとおり，平行線状および放射状に比べて円形のサンプリングパターンを用いた場合に 2 乗誤差が小さくなる傾向が見られた．これは，平行線状および放射線状のサンプリングパターンを利用した場合，パッチ外の構造物によるアーチファクトが発生することで，推定結果に誤差が生じてしまうためであると考えられる．

次にネットワーク構造を変化させた場合について述べる．3 層の CNN および最終層に Residual 構造を追加した場合，提案手法の 3 つのネットワークについて学習および評価した．サンプリングパターンは円形状を利用し，最終的なネットワーク構成としては 4 つの CNN すべてにおいて f_1=9, f_2=5, f_3=5 とした．また最適化手法として Adam[7]を利用した．クラスタリングによって得られた各クラスタの重心を図 7 に示す．

評価用データ 31 枚における平均 PSNR の比較結果を表 1 に示す．提案手法であるクラスタリングを用いた場合，単一のネットワーク

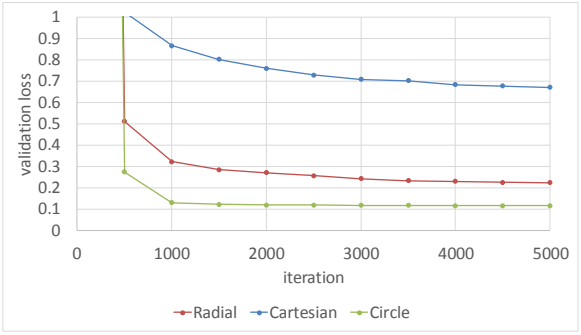

図 6 サンプリングパターンによる学習時の比較

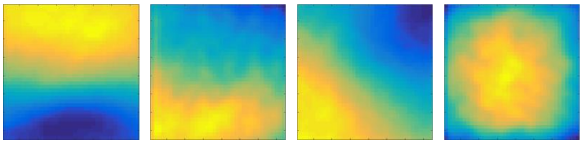

図 7 各クラスタの重心画像

表 1 実験結果

Method	PSNR[dB]
3 層 CNN	32.8
3 層 CNN＋Residual	33.8
3 層 CNN＋Residual ＋クラスタリング	35.1

を用いた場合に比べ PSNR において約 1.3dB の改善が見られた．提案手法による高画質化結果を図 8 に示す。

3.3. 考察

表 1 に示すとおり，クラスタリングを用いた提案手法は単一の CNN を用いた場合に比べ画質の向上が見られた．これは画像をサブセットに分割したことで，各 CNN に入力されるパッチの性質が類似し，推定問題が容易になったためであると考えられる．図 7 に示す各クラスタの重心画像でも，エッジや孤立点のようなクラスタに分類されていることが確認できる．

また図 8 上段に示すように，推定画像では微細な構造や微弱なエッジの復元が確認できる．一方で図 8 下段に示すように，テクスチ

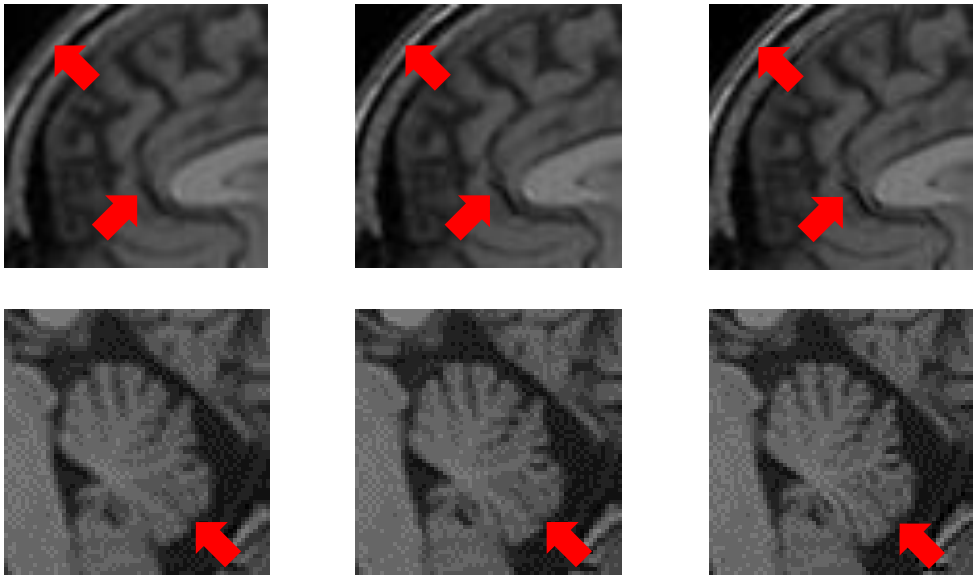

図 8 実験結果の例(左：入力画像(劣化画像)，中央：推定画像，右：正解(元画像))

ャ様の構造については，十分な高画質化結果が得られなかった．これは異なるテクスチャであっても，高周波成分が失われることで非常に類似した劣化画像となってしまうため，真の画像への推定がうまく学習されなかったのではないかと考えられる．

4. おわりに

MRI の撮影高速化という課題に対し，4 倍速相当劣化画像の CNN を用いた高画質化について検討した．クラスタリングを利用した CNN の適応的選択により，単一のネットワークを利用した場合に比べ PSNR において 1.3dB の改善を確認した．

今後の課題としては，U-Net[8]をはじめとするより深いネットワークの検討や，DCGAN[9]の適用による精度向上，ネットワーク選択手法の改良，臨床データでの評価等があげられる．

利益相反の有無

著者は株式会社日立製作所の社員である．

文　献

［1］ D. L. Donoho,”Compressed sensing”, IEEE Trans. Inf. Theory, vol.52, no.4, pp.1289-1306, April. 2006.

［2］ Chao Dong, Chen Change Loy, Kaiming He, Xiaoou Tang, “Learning a Deep Convolutional Network for Image Super-Resolution”, ECCV, 2014.

［3］ Junyuan Xie, Linli Xu, Enhong Chen, “Image Denoising and Inpainting with Deep Neural Networks”, NIPS, 2012.

［4］ Li Xu, Jimmy SJ. Ren, Ce Liu, Jiaya Jia, “Deep Convolutional Neural Network for Image Deconvolution”, NIPS, 2014

［5］ Jiwon Kim, Jung Known Lee, Kyoung Mu Lee, “Accurate Image Super-Resolution Using Very Deep Convolutional Networks”, arXiv: 1511.04587v1, 2015

［6］ IXI Dataset , brain-development.org, http://brain-development.org/ixi-dataset/

［7］ D. Kingma, J. Ba. Adam: A Method for Stochastic Optimization. International Conference for Learning Representations, 2015.

［8］ Olaf Ronneberger, Philipp Fischer,

Thomas Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation", Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015 pp 234-241, 2015.

［9］ Alec Radford, Luke Metz, Soumith Chintala, "Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks", arXiv:1511.06434, 2015.

Study of improvement image quality for MRI using adaptive CNN selection

Yoshimi NOGUCHI[*1], Masahiro OGINO[*1]

*1 Hitachi, Ltd. Research & Development Group

Recent years, Convolution Neural Network (CNN) is widely used, especially for image recognition, but it can also be applied to image reconstruction technology, and high performance is obtained as compared with conventinal methods. In this paper, we studied the quality improvement of degraded MRI image reconstructed from a small number of observation data using CNN. In this study, we created degraded images were removed 75% of the high frequency component (acceraration factor = 4) from the 550 published image data, and train CNN by original images and degraded images. In addition, local feature quantities of images were classified by clustering and input to different CNNs, respectively, to improve image quality. PSNR of 35.1 dB was realized in the 31 images for evaluation data, and image quality improvement of about 1.3 dB was confirmed compared with using single CNN.

Key words: MRI, improvemet image quality, CNN

著者紹介

野口　喜実（のぐち　よしみ）
2009 年千葉大工学部電子機械工学科卒. 2011 年同大大学院博士前記課程了．現在, 株式会社日立製作所研究開発グループメディカルシステム研究部．医用画像処理技術に関する研究開発に従事．日本医用画像工学会会員.

荻野　昌宏（おぎの　まさひろ）
1996 年金沢大学電気情報工学科卒．1998 年同大大学院修士課程了．現在，株式会社日立製作所研究開発グループメディカルシステム研究部．画像処理技術に関する研究開発に従事．情報処理学会会員.

PANCAN モデル，Lung-RADS における 肺結節の悪性リスク評価

景山 健[*1] 河田 佳樹[*2] 仁木 登[*2] 楠本 昌彦[*3] 大松 広伸[*4]

青景 圭樹[*3] 土田 敬明[*5] 松元 裕司[*5] 江口 研二[*6] 金子 昌弘[*7]

要旨

肺がんは，がん死亡者数第一位を占め，増加傾向にある．肺がんを早期発見する手法の一つとして，近年胸部 3 次元 CT 画像を用いて肺がん候補を発見する肺がん CT スクリーニングが実施されているものの，20～55%の非がん症例を対象に不要な生検が実施されている．肺がん CT スクリーニングにおける肺がんの偽陽性率を低下させるため，世界各国で結節をカテゴリー管理し採点する悪性リスクモデルが複数公開されてきた. 本研究では, 悪性リスクモデルの開発の基礎実験として, 近年評価されている PANCAN モデル，Lung-RADS の悪性リスクモデルを日本人の thin-section CT 画像を対象にして比較評価し，良悪性の鑑別因子を調査する．

キーワード：肺がん，胸部 3 次元 CT 画像，PANCAN モデル，Lung-RADS

● はじめに

肺がんは，がん死亡者数第一位を占め現在も増加傾向にある．このような傾向にある要因のひとつとして，肺がんの治療には，がんが増殖する前に発見すること，つまり早期発見が必要であることが挙げられる．

肺がんを早期発見する方法のひとつとして，近年胸部 3 次元 CT 画像を用いて肺がんの候補を高精度に発見する肺がん CT スクリーニングが施行されている．肺がん CT スクリーニングにおいて，CT 検診者の約 20%に肺がん候補が確認されているが，確認された肺がん候補が実際に肺がんである割合は 1%程度に過ぎず、20～55%の非がん症例を対象に不要な生検が実施されている．[1][2]

そこで、肺がん CT スクリーニングにおける肺がんの偽陽性率を低下させるため、PANCAN モデルや Lung-RADS，NCCN ガイドラインなどの結節をカテゴリー管理し採点する悪性リスクモデルがカナダやアメリカ，ヨーロッパ圏など世界各国で複数公開されてきた．

本研究の目的は、悪性リスクモデルの開発の基礎実験として、近年評価されている PANCAN モデル、Lung-RADS の悪性リスクモデルを日本人の CT 画像を対象にして比較評価し、良悪性の鑑別因子を調査する。

*1 徳島大学大学院先端技術科学教育部
〔〒770-8506 徳島市南常三島町 2-1〕
e-mail: c501838009@tokushima-u.ac.jp
*2 徳島大学大学院社会産業理工学研究部
*3 国立がん研究センター東病院
*4 網走刑務所
*5 国立がん研究センター中央病院
*6 帝京大学医学部
*7 東京都予防医学協会健康支援センター

● 悪性リスクモデルの比較評価

本研究では，国立がん研究センターの thin-section CT 画像を用いて評価を行う．このデータセットから解析対象としたものは，結節 915 個(良性結節 382 個, 悪性結節 533 個)である．

ROC 解析による PANCAN モデルおよび Lung-RADS の悪性リスクモデルの性能比較を行った結果を図 1 に示す．この ROC 解析によって、PanCan モデルの AUC が 0.83、Lung-RADS の AUC が 0.72 であり，この結果に有意差が存在するという結果を得た．

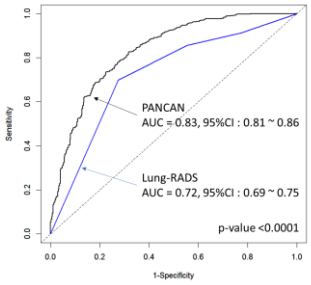

図 1 ROC 解析による PANCAN・Lung-RADS 悪性リスクモデルの性能比較

PANCAN モデルにおける結節の stage によるリスクスコア分布を図 2 に，良性結節の組織によるリスクスコア分布を図 3 に示す．

図 3･図 4 から, 良性結節において Granuloma の組織型に分類される結節の悪性度リスクが高く，stageIA1 に分類される結節の悪性度リスクに匹敵することが分かった．

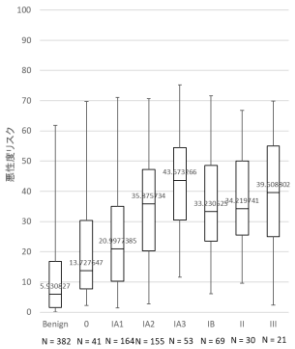

図 3 PANCAN モデルにおける結節の stage によるリスクスコア分布

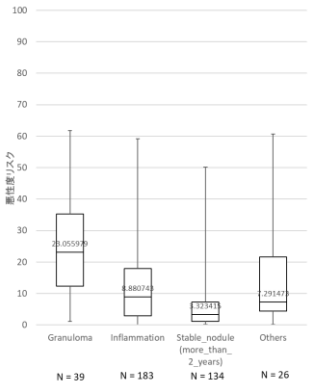

図 4 PANCAN モデルにおける良性結節の組織によるリスクスコア分布

● まとめ

PANCAN モデル，Lung-RADS の悪性リスクモデルを日本人の CT の像を対象にして比較評価した結果，結節の良悪について PANCAN モデルが有意に優れる性能を示し，PANCAN 悪性度リスクモデルの予測因子に含まれる性別，結節のサイズ，結節の位置，スピキュラーの有無が有用な悪性度指標として期待できる結果を得た．

また，PANCAN モデル，Lung-RADS の悪性度リスクモデルが用いる予測因子では Granuloma の組織型に分類される結節と stage0･IA1 に分類される結節を区別できない結果を得た．

今後の課題として，Granuloma の組織型に分類される結節と stage0・IA1 に分類される結節を区別できる鑑別因子の調査を行う．

利益相反の有無

なし

文　献

［1］ McWilliams A. et al.: Probability of cancer in pulmonary nodules detected on first screening CT, N. Engl. J. Med. 2013; 369: 910-919.

［2］ Bach P.B. et al. : Benefits and harms of CT screening for lung cancer A systematic review. JAMA 2012; 307: 2418-2429.

Malignancy risk estimation of pulmonary nodule: comparison of the PANCAN model and Lung-RADS

Takeru KAGEYAMA[*1], Yoshiki KAWATA[*2], Noboru NIKI[*2], Masahiko KUSUMOTO[*3], Hironobu OHMATSU[*4], Yoshiki AOKAGE[*3], Takaaki TSUCHIDA[*5], Yuji MATSUMOTO[*5], Kenji EGUCHI[*6], Masahiro KANEKO[*7]

*1 Tokushima University Graduate School of Advanced Technology and Science

*2 Tokushima University Graduate School of Technology, Industrial and Social Sciences

*3 National Cancer Center Hospital East

*4 Abashiri Prison

*5 National Cancer Center Hospital

*6 Teikyo University Faculty of Medical Technology

*7 Tokyo Health Service Association Health Support Center

Lung cancer accounts for the number of cancer deaths first, and it is on an increasing trend. Although lung cancer CT screening that discovers lung cancer candidates using chest 3-dimensional CT images has been carried out recently as one of the methods for early detection of lung cancer, unnecessary definitive diagnosis is being carried out to non-cancer samples of 20 to 55%. In order to reduce the false positive rate of lung cancer in lung cancer CT screening, multiple malignant risk models have been published that categorize and score nodules in various countries around the world. In this study, as a basic experiment of development of a malignant risk model, we make comparison between PANCAN model and Lung-RADS, which have been recently evaluated, and valuate them for Japanese thin-section CT images, investigate factors.

Key words: Lung cancer, Chest 3-dimensional CT images, PANCAN model, Lung-RADS

細分化した病変組織で学習したCNNによるGleason分類精度の評価

鈴木 秀智[*1]，藤本 祐基[*1]，白石 泰三[*2]，太田 義勝[*1]

要旨

これまでの計算機によるGleason分類では，4種類のGleasonパターン（正常，パターン3，パターン4，パターン5）の標本中の大きさに基づいてGleasonスコアが算出され，80%以上の分類精度と，Gleasonスコアの正解率が得られていた．しかし，進行によって高分化しているがん組織は多様な組織構造をもつため，これらの違いを考慮せずに分類する方法では，さらなる精度の向上は難しいと考えられる．そこで，本研究では，高分化しているGleasonパターン4とGleasonパターン5を，それぞれ，4個と2個のクラスに細分して8クラスのデータを作成し，これを用いて学習したCNNによる分類精度の評価を行なった．実験の結果，細分したデータを使うことで，Gleasonパターンの分類精度が89.2%から91.6%に改善されることを確認した．また，組織標本のセグメンテーションの精度の向上も確認した．

キーワード：医用画像処理，組織標本画像，前立腺がん，グリソンスコア，深層学習

1. はじめに

近年，増え続ける組織細胞診作業に対する病理医の不足のため，診断作業の計算機支援が強く望まれ,関連する研究が行われている．

前立腺がんは男性のがん患者の中では非常に多く，検査技術の向上や団塊の世代の高齢化に伴い,診断件数の増加が懸念されている．前立腺がんの診断ではGleason scoreの評価が重要であり，最近では，Gummeson らの研究[1]がある．我々は，Gummeson らの方法[1]を基に，低スコアのパターンを考慮することで分類精度の改善を試みたが，さらなる改善が必要であった[2].

本研究では，特に分類精度が悪かった高スコアのパターン（パターン4, 5）を細分化することで，クラス内での組織構造の変動を小さくし，それを学習させることで分類精度の向上を試みる．

*1 三重大学大学院工学研究科情報工学専攻〔〒514-8507 津市栗真町屋町1577〕
e-mail: suzuki@net.info.mie-u.ac.jp
*2 桑名総合医療センター

2. 提案手法

Gleason パターンを 8 クラスに細分し，CNN(Convolutional Neural Network)で学習させて分類器を作成する．

2.1 CNN の構成

CNN は，従来法[2]と同様に，畳み込み層とプーリング層の組を4段使って300次元の特徴ベクトルに変換し,3段の全結合NNで8クラスの識別器を構成する．

2.2 高スコアパターンの細分化

本研究では，BE（正常およびパターン 1,2 を含む），パターン3は従来通りとし，パターン4および5について，組織構造によって，以下のように細分化する（合計8クラス）．

- パターン 4：hypernephromatoid，小型で管腔形成が不明瞭な腺管，癒合状腺管，篩状腺管
- パターン 5：孤立細胞性増殖と索状配列，充実性増殖

2.3 画像データ

前立腺組織標本の WSI(Whole Slide Imaging)画像から，クラス（パターンを細分したもの）ごとにパッチ（部分画像）を切り出し，データ拡張によって枚数を増やした．得られたパッチの枚数はクラスによって異なり，おおよそ 900～50000 枚の範囲である．

3. 実験

3.1 実験の概要

ソフトウェアライブラリ TensorFlow[3]を用いて CNN を構成し，学習と評価を行なった．構成した CNN については 2.1 を参照．

2.3 で作成したパッチのほぼすべてを用いて，4 交差検証法により分類精度を評価した．

実験では，[1]で得られた学習済みモデルをファインチューニングして分類器を作成した．

3.2 実験結果

4 交差検証法による分類内訳を表 2 に示す．

表 2 実験結果の混同行列（単位：[%]）

予測 / 正解	BE	G3	G4	G5
BE	94.83	2.96	2.08	0.13
G3	2.61	91.57	5.6	0.22
G4	2.99	2.64	87.68	2.7
G5	0.05	0.84	6.77	92.34

分類精度の平均は 91.6[%]であった．

3.3 考察

分類精度については，従来法[2]では 89.2%であったのが 91.6%に改善された．改善の原因は，細分化されたクラスで学習することによって，パターン 3 および 4 での分類精度が向上したためである．

分類結果を細分化されたクラスで調べると，以下の誤分類が多かった．

・充実度が低い G5-B が G4-B に誤分類

・G4-B,C が BE または G3 に誤分類

これらは組織構造が似ているので，分類精度を上げるには，学習データを追加する，または，前処理によって分類が容易な画像に変換する，などが必要であると考えられる．

図 1 は，構成された分類器を用いて，組織標本画像の画素に分類ラベルを付けることでクラスごとに分割した結果の一例である．クラスにもよるが，精度の高い分割結果が得られている．

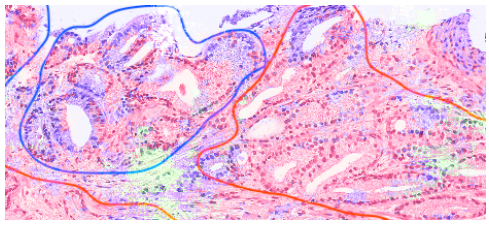

図 1 セグメンテーションの例．枠線は病理医による分割．画素の色は分類結果（赤は G3，青は G4，緑は G5 であり，色が濃いほど尤度が高い）．

3. まとめ

本研究では，高スコアのパターンを細分類することで分類精度を 2.4%向上させることができた．しかし，クラス間で組織構造が似ているものや，低スコアのパターンでの誤分類があるため，さらなる精度向上の工夫が必要である．また，診断精度の向上と病理医への有効な情報の提供のために，組織標本画像の分割精度の向上も必要である．

謝辞

研究遂行にあたり貴重なご助言を賜った三重大学医学系研究科腫瘍病理学教室の皆様に深謝いたします．

利益相反の有無　なし

文　献

［1］Gummeson A: Prostate Cancer Classication using Convolutional Neural Networks. Master thesis, Lund University, 2016

［2］藤本祐基，鈴木秀智，白石泰三，太田義勝：CNN を用いた Gleason score の算出システム. 日本医用画像工学会第 36 回大会(JAMIT 2017)予稿集，OP4-6，2017

［3］TensorFlow： https://www.tensorflow.org

ゲノム・画像情報を用いた早期 COPD 検診法の研究開発

野崎 元貴† 鈴木 秀宣† 河田 佳樹† 仁木 登†
増田 清士†† 井本 逸勢†† 金子 昌弘†††

あらまし 慢性閉塞性肺疾患（COPD）とは,従来慢性気管支炎や肺気腫と呼ばれてきた病気の総称である.COPD の気腫性病変は CT 画像上で低吸収領域(LAV)として描画される.この LAV が増加する人としない人がいる.本研究は,この違いを CT 画像情報と SNP を用いて統計的に検討する. 結果,LAV が増加する人としない人の間に,SNP の違いがある可能性が示唆された.

キーワード COPD, CT, SNP

1. はじめに

慢性閉塞性肺疾患（COPD）とは,従来慢性気管支炎や肺気腫と呼ばれてきた病気の総称であり,タバコ煙を主とする有害物質を長期にわたって吸入曝露することで生じた肺の炎症性疾患である.不可逆性の呼吸器疾患であるため,早期に発見することが重要である.COPD の気腫性病変は CT 画像上で低吸収領域(LAV)として描画される.最大の原因は喫煙である.しかし,喫煙者であっても LAV が増加する人とほとんど変化しない人がいる.このことから人によって何らかの違いがあると考えられる.そこでこの違いを CT 画像から抽出した LAV とゲノム情報である SNP を用いて明らかにする.

2. 実験

本研究では,SNP 解析を行うため,唾液サンプルの収集を行い,187 名分のサンプルを収集した.この中で低線量肺がん CT 検診画像があり,喫煙情報がある 160 名を用いた.撮影装置は東芝社製 Aquilion である.撮影条件は管電圧 120kV,管電流 30mAs,スライス厚 1mm,再構成間隔 1mm,画素サイズ 0.625mm,画像サイズ 512×512 画素,再構成関数 FC01 である.

†徳島大学先端技術科学教育部
[〒770-8506 徳島県徳島市 南常三島町 2-1]
E-mail:c501738018@tokushima-u.ac.jp
††徳島大学
[〒770-8503 徳島県徳島市 蔵本町 3-18-15]
†††東京都予防医学協会
[〒162-8402 東京都新宿区市谷砂土原町 1-2]

まず CT 画像より LAV を抽出する. 原画像から肺野を抽出し.閾値処理(CT 値-950HU 以下)により LAV 候補領域を抽出する. 候補領域から距離値と 4 次元超曲面曲率のノルムを用いてノイズ成分を除去し, 残った領域を LAV とした.

今回用いる CT 画像は呼吸状態が統一されていないため,全データをそのまま解析すると信頼性にかける結果となる.そこで(1)肺野体積変動 3%以内,(2)正常肺ピーク CT 値の標準偏差が 5 未満,(3)検診回数が 3 回以上,(4) LAV%の経年変化から近似直線を求め,近似直線と実データのフィッティングのいい例,以上 4 つのステップでデータの選択を行った.結果を図 1 に示す.

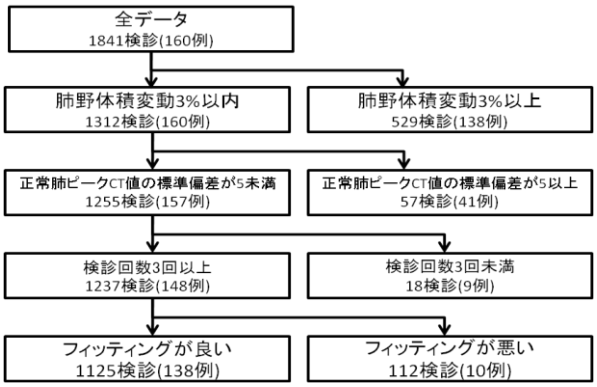

図 1 CT 画像データ

選択した 138 例の喫煙状況内訳は,喫煙者 66 例,過去喫煙者 60 例,非喫煙者 12 例である.喫煙者の LAV%を初回検診と最大となった検診時を結んだ結果を図 2 に示す.急激に増加する人と変化しない人がいることがわかる.この違いを SNP を用いて解析する.解析を行う SNP は COPD と肺がんに関連する可能性があるものを文献から調査した.表 1 に今回用いる SNP12 種類を示す. 収集した唾液サンプルを用いて, 12 種類の SNP 解析を行う.

表 1　SNP12 種類

SNP	Gene	文献	SNP	Gene	文献
rs7733088	HTR4	[1]	rs1051730	CHRNA3	[2][3]
rs7671167	FAM13A	[2][3]	rs2736100	TERT	[5]
rs13118928	HHIP	[3]	rs401681	CLPTM1L	[6]
rs13180	CHRNA5	[3]	rs3117582	BAG6	[7]
rs3923564	SFTPD	[4]	rs1333040	CDKN2B-AS1	[8]
rs7937	RAB4B	[2]	rs10849605	RAD52	[9]

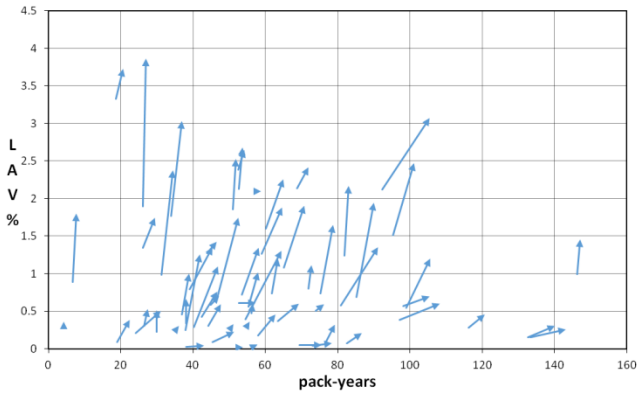

図 2　喫煙者 LAV%初回から最大

図 2 で LAV%が増加する群としない群に分ける.この 2 群と SNP 解析の結果から図 3 の分割表を各 SNP で作成する.図 3 の分割表より図 4 で示す Dominant,Recessive モデル分割表を作成する.図 4 の分割表でロジスティック回帰分析を行う.

	rs1333040		
	TT	CT	CC
1%未満	14	15	3
1%以上	15	10	7

図 3　SNP(rs1333040)分割表

AlleleT Dominant

	rs1333040	
	TT+CT	CC
1%未満	29	3
1%以上	25	7

AlleleT Recessive

	rs1333040	
	TT	CT+CC
1%未満	14	18
1%以上	15	17

図 4 SNP(rs1333040)モデル分割表

3. 実験結果

各統計解析に対して複数の SNP が LAV が増加する人としない人に有意差があると思われる結果が得られた.

4. まとめ

CT 画像情報と SNP を用いて LAV が増加する人としない人の違いを調査し,SNP の違いによって判断できる可能性が示唆された.今回は SNP を単変数で扱ったが,組み合わせることでより顕著に結果が出ないか検討する.またより多くの検体を用いて解析を進める.

利益相反の有無

なし

文　献

[1] Wang, X., Ma, K., Chi, L., Cui, J., Jin, L., Hu, J.-F., Li, W., “Combining telomerase reverse transcriptase genetic variant rs2736100 with epidemiologic factors in the prediction of lung cancer susceptibility”, Journal of Cancer, 7 (7), pp. 846-853.2016.

[2] Kachuri, L., Latifovic, L., Liu, G., Hung, R.J., “Systematic review of genetic variation in chromosome 5p15.33 and telomere length as predictive and prognostic biomarkers for lung cancer”,Cancer Epidemiology Biomarkers and Prevention, 25 (12), pp. 1537-1549.2016.

[3] Godfrey Essien Etokebe , Shanbeh Zienolddiny, Zeljko Kupanovac, Morten Enersen, Sanja Balen,”Association of the FAM46A Gene VNTRs and BAG6 rs3117582 SNP with Non Small Cell Lung Cancer (NSCLC) in Croatian and Norwegian Populations”, PLOS ON.2015

[4] Timofeeva, M.N., Hung, R.J., Rafnar, T., Christiani, “Influence of common genetic variation on lung cancer risk: Meta-analysis of 14 900 cases and 29 485 controls”, Human Molecular Genetics, 21 (22), art. no. dds334, pp. 4980-4995.2012.

[5] Zhang, Y.a, Yang, X.b, You, J.a, Li, S.a, Duan, M.c, Li, H.a, He, H.a, Chen, N.a, Jin, T.de, Fu, J.a, “Variants in multi-gene polymorphism association analysis of lung cancer in the Chinese Han population.” International Journal of Clinical and Experimental MedicineOpen Access, Volume 9, Issue 3, 30 March 2016, Pages 6807-6812.

[6] Wilk, J.B., Shrine, N.R.G., Loehr, L.R., Zhao, J.H., Manichaikul, A. Lopez, L.M., Smith, A.V.,“Genome-wide association studies identify CHRNA5/3 and HTR4 in the development of airflow obstruction”, American Journal of Respiratory and Critical Care Medicine, 186 (7), pp. 622-632.2012

[7] Lee, J.H., Cho, M.H., McDonald, M.-L.N., Hersh, C.P., Castaldi, P.J., Crapo, J.D., Wan, E.S., “Phenotypic and genetic heterogeneity among subjects with mild airflow obstruction in COPDGene” Respiratory Medicine, 108 (10), pp. 1469-1480.2014

[8] Mateusz SiedlinskiDustin TingleyPeter J. LipmanMichael H. ChoAugusto A. LitonjuaDavid SparrowPer Bakke, ”Dissecting direct and indirect genetic effects on chronic obstructive pulmonary disease (COPD) susceptibility”, Human Genetics, Volume 132, Issue 4, pp 431–441.2013.

[9] Chen, W., Brehm, J.M., Manichaikul, A., Cho, M.H., Boutaoui,N., Yan, Q., Burkart, K.M.,“A genome-wide association study of chronic obstructive pulmonary disease in Hispanics”, Annals of the American Thoracic Society, 12 (3), pp. 340-348.2015

Evaluation of early COPD screening method using CT image information and SNP

Genki Nozaki † Hidenobu Suzuki † Yoshiki Kawata † Noboru Niki †
Kiyoshi masuda † † Issei Imoto † † Masahiro Kaneko † † †

† System Innovation Engineering ,Graduate School of Advanced Technology and Science, The University of Tokushima

† † Tokushima University

† † † Tokyo Prevention Medical Association

Chronic Obstructive Pulmonary Disease is a general term for diseases that have been conventionally called chronic bronchitis and emphysema.The emphysematous lesion of COPD is drawn as a low absorption region on the CT image.The person who increases this LAV In the present study, this difference is statistically examined using CT image information and SNP.Therefore, it is suggested that there is a difference in SNP between people who increase LAV and those who do not increase It was done.

Investigation of radiomic feature selection approaches for survival prediction of squamous cell head and neck cancer patients based on features selected from squamous cell lung cancer patients

Hidemi KAMEZAWA[*1], Hidetaka ARIMURA[*2], Mazen SOUFI[*3]

Abstract

We have investigated the feasible feature selection approaches for the survival prediction of squamous cell head and neck cancer (SCHNC) patients based on radiomic features selected from squamous cell lung cancer (SCLC) patients. 486 radiomic features were calculated from the tumor regions in the computed tomography images. Significant features for survival prediction were selected by using artificial neural network (ANN)-based feature selection approach and least absolute shrinkage and selection operator (LASSO). Statistical significant differences between survival curves of two patient groups, which were stratified by the median of each feature into two subtypes, were assessed. The ANN-based feature selection approach could be useful for the survival prediction of SCHNC patients based on radiomic features selected from SCLC patients.

Keywords：Radiomics, Survival prediction, Feature selection, Artificial neural network

1. Introduction

Radiation therapy has been widely used for treatment of head and neck cancer patients, but the survival time for each patient would not be predicted before treatment, depending on the cancer. Recently, the various researchers have studied the survival predictions based on radiomics using the relationships between clinical outcomes and image features in clinical images [1-7]. To the best of our knowledge, there have been few studies that radiomic features associated with the survivals of the squamous cell lung cancer (SCLC) patients could be feasible for prediction of the survivals of the squamous cell head and neck cancer (SCHNC) patients. Further, there has been few trials about the investigation of the useful feature selection approach for the survival prediction. Therefore, we have investigated the feasible feature selection approaches for the survival prediction of SCHNC patients based on radiomic features selected from SCLC patients.

*1 Department of Radiological Technology, Faculty of Fukuoka Medical Technology, Teikyo University〔Misaki-machi 6-22, Omuta 836-8505, Japan〕
e-mail: kamezawa@fmt.teikyo-u.ac.jp
*2 Division of Medical Quantum Science, Department of Health Sciences, Faculty of Medical Sciences, Kyushu University
*3 Graduate School of Information Science, Nara Institute of Science and Technology

2. Materials and Methods

Fig. 1 shows the overall scheme of this study. We employed computed tomography (CT) images of 86 SCLC patients for the feature selection, and 28

SCHNC patients for a test of the selected features. All cases were obtained from The Cancer Imaging Archive public database.

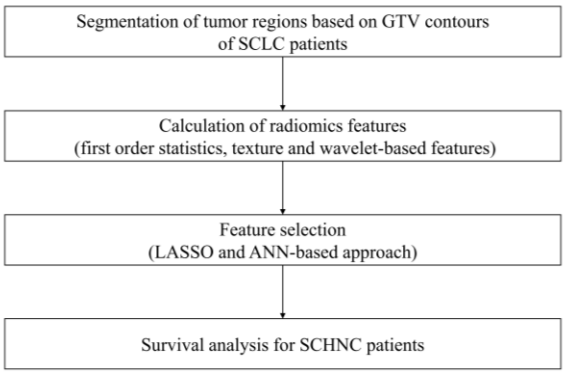

Fig. 1 An overall scheme of this study.

1) Radiomic features

486 radiomic features, i.e., statistic (n=14), texture (n=40), wavelet-based features (n=432), were extracted from tumor regions in the CT images. Eight sub-volumes, i.e., LLL, LLH, LHL, LHH, HLL, HLH, HHL, and HHH, were produced by the three-dimensional volume decomposition using Coiflet wavelet transform. The low- and high-frequency bands in the wavelet domain denote L and H, respectively.

2) Feature selection

Significant features for survival prediction were selected by least absolute shrinkage and selection operator (LASSO) and artificial neural network (ANN)-based feature selection approach. The LASSO has been widely used for feature selection from high dimensional data in radiomics research [8, 9]. The radiomic features, which has non-zero coefficients, were selected as significant features for survival prediction when the cross-validation error in LASSO regression model was the smallest.

On the other hand, ANN-based feature selection approach was reported as a useful feature selection approach for the survival prediction of SCHNC patients based on features selected from SCLC patients [10]. The ANN was constructed for selecting 10 features that could classify the SCLC patients into shorter and longer survival groups than 2 years. The numbers of nodes in the input, hidden and output layers in ANN were 486, 244 and 2, respectively. The learning rate and iteration were set as 0.1 and 250, respectively. The rectified linear unit (ReLU) function was employed as an activation function. The radiomic features associated with the 2-year survival were selected based on a feature weighting approach proposed by Zeng et al [11]. If the radiomic feature is important for survival prediction, the feature weight becomes larger. The feature weight (W_i) for an input unit (i) in the training network is given by

$$W_i = \sum_{j=1}^{H} \sum_{k=1}^{O} \left| V_{i,j} \cdot V_{j,k} \right| \qquad (1)$$

where H is the number of the hidden units, O is the number of the output units, $V_{i,j}$ is the network weight from input unit (i) to hidden unit (j), and $V_{j,k}$ is the network weight from hidden unit (j) to output unit (k).

3) Survival analysis

Survival analysis was performed with the 10 features, which were selected by the LASSO and ANN-based feature selection approach. The survival times of the SCHNC patients, who were stratified into two subtypes with respect to the median of each of the 10 features, were estimated using a Kaplan-Meier method. The statistical significant differences between survival curves of the two subtypes were assessed for the selected features using a log-rank test.

3. Results and Discussion

The p values of 10 features, which selected by LASSO and ANN-based feature selection approach, in comparison between the survival curves of the two subtypes for the SCHNC patients were shown in

Tables 1 and 2, respectively. The homogeneity feature of the HHL image (HHL_Homogeneity), which was selected by using ANN-based feature selection approach, demonstrated a statistically significant difference ($p < 0.01$) between the two subtypes of SCHNC as shown in Fig. 2, but the other features did not.

Table 1 The *p* values of the 10 features selected by LASSO in comparison between the survival curves of the two subtypes for the SCHNC patients.

Radiomic feature	*p* value
HHL_MAD*	0.060
LHH_Correlation	0.062
LHL_MAD	0.078
HLH_GLN**	0.120
HLH_Max	0.124
HHL_ZSN***	0.298
HHH_SZE+	0.497
HHH_HGZE++	0.532
LHL_HGZE	0.650
HHL_Mean	0.696

* MAD: mean absolute deviation, ** GLN: gray-level non-uniformity, *** ZSN: zone size non-uniformity, + SZE: small zone emphasis, ++ HGZE: high gray-level zone emphasis

Table 2 The *p* values of the 10 features selected by ANN-based feature selection approach in comparison between the survival curves of the two subtypes for the SCHNC patients.

Radiomic feature	*p* value
HHL_Homogeneity	0.002
Uniformity	0.051
HHL_Uniformity	0.086
LHL_Energy	0.086
HLH_RLN*	0.115
LHL_Complexity	0.144
AutoCorrelation	0.360
LHL_Skewness	0.669
LHL_SZE**	0.689
LHH_Entropy	0.859

* RLN: run length non-uniformity, ** SZE: small zone emphasis

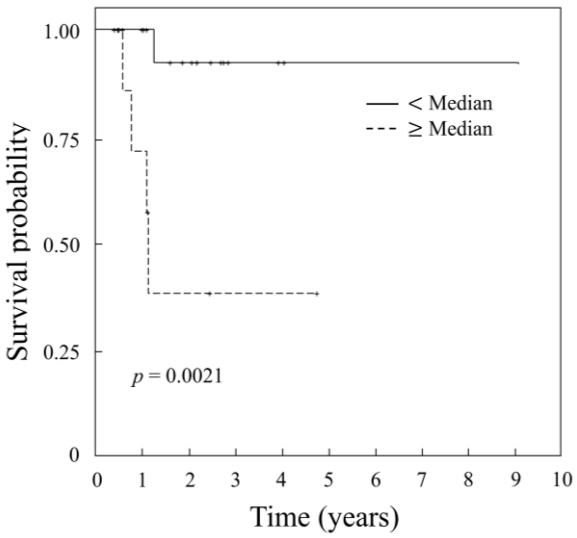

Fig. 2 Survival curves of the two subtypes for the HHL_Homogeneity feature selected by ANN-based feature selection approach.

3. Conclusions

Our results suggest that the ANN-based feature selection approach might useful for the survival prediction of SCHNC patients based on features selected from SCLC patients. Moreover, the 2-year survival of the SCHNC patients could be predicted by using at least the radiomic feature of HHL_Homogeneity selected among the features for SCLC patients using the ANN-based feature selection approach.

Acknowledgement

This research was supported by JSPS KAKENHI Grant Number JP 17K15808. The authors express their gratitude to all members of the Arimura Laboratory for valuable comments and helpful discussions.

Competing interests

The author have nothing to declare for this study.

References

［1］ Gillies RJ, Kinahan PE and Hricak H: Radiomics: Images Are More than Pictures, They Are Data. Radiology **278**: 563-577, 2016

［2］ Wong AJ, Kanwar A, Mohamed AS et al: Radiomics in head and neck cancer: from exploration to application. Transl Cancer Res **5**: 371-382, 2016

［3］ Corolle TP, Grossmann P, Hou Y et al: CT-based radiomic signature predicts distant metastasis in lung adenocarcinoma. Radiother Oncol **114**: 345-350, 2015

［4］ Aerts HJ, Velazquez ER, Leijenaar RT et al: Decoding tumour phenotype by noninvasive imaging using a quantitative radiomics approach. Nat Commun **5**: 4006, 2014

［5］ Lambin P, Rios-Velazquez E, Leijenaar R et al: Radiomics: extracting more information from medical images using advanced feature analysis. Eur J Cancer **48**: 441-446, 2012

［6］ Kumar V, Gu Y, Basu S et al: Radiomics: the process and the challenges. Magn Reson Imaging **30**: 1234-1248, 2012

［7］ Soufi M, Arimura H, Nakamoto T et al: Exploration of temporal stability and prognostic power of radiomic features based on electronic portal imaging device images. Phys Med **46**: 32-44, 2018

［8］ Liu Z, Zhang XY, Shi YJ et al: Radiomics analysis for evaluation of pathological complete response to neoadjuvant chemoradiotherapy in locally advanced rectal cancer. Clin Cancer Res **23**: 7253-7262, 2017

［9］ Chan HM, van der Velden BHM, Loo CE et al: Eigentumors for prediction of treatment failure in patients with early-stage breast cancer using dynamic contrast-enhanced MRI: a feasibility study. Phys Med Biol **62**: 6467-6485, 2017

［10］ Kamezawa H, Arimura H, Soufi M: Survival prediction of squamous cell head and neck cancer patients based on radiomic features selected from lung cancer patients using artificial neural network. Proc. SPIE **10579** (1057918) **(**Medical Imaging 2018: Imaging Informatics for Healthcare, Research, and Applications):1-6, 2018

［11］ Zeng X, Martinez T R: Feature weighting using neural network. 2004 IEEE International Joint Conference on Neural Networks, 2004

扁平上皮肺がん患者から選択した特徴量に基づく扁平上皮頭頸部がん患者の生存予測のための特徴量選択手法の検討

亀澤　秀美[*1], 有村　秀孝[*2], スーフィー　マーゼン[*3]

*1 帝京大学福岡医療技術学部診療放射線学科

*2 九州大学医学研究院保健学部門

*3 奈良先端科学技術大学院大学情報科学研究科

我々は，扁平上皮肺がん（SCLC）患者から選択した特徴量に基づき扁平上皮頭頸部がん（SCHNC）患者の生存予測を可能とする特徴選択手法を検討した．コンピュータ断層撮影画像の腫瘍領域から 486 種のレディオミクス特徴を計算した．生存予測を行うために重要な特徴を人工ニューラルネットワーク（ANN）に基づく特徴選択手法および least absolute shrinkage and selection operator（LASSO）により選択した．選択した各特徴の中央値により層別化された 2 つの患者群の生存曲線間の統計的有意差を評価した．ANN に基づく特徴選択手法は，SCLC 患者から選択した特徴量に基づく SCHNC 患者の生存予測に有用である可能性を示した．

キーワード：レディオミクス，生存予測，特徴選択，人工ニューラルネットワーク

An approach for prediction of lung cancer patients' prognoses using PCA-based radiomic features

Masahiro YAMADA[*1], Hidetaka ARIMURA[*2], Mazen SOUFI[*3]

Abstract

The aim of this study was to develop an approach for prediction of lung cancer patients' prognoses using principal component analysis (PCA)-based radiomic features. 486 radiomic features were extracted from CT images of 197 patients. The PCA was applied for 486 normalized radiomic features to reduce the number of features, and the PCA coefficients of the first to tenth principal components (PCs) were considered as PCA-based radiomic features. 197 patients were stratified into two groups by medians of PCA-based radiomic features. Finally, survival probabilities were calculated by the Kaplan-Meire method and evaluated by statistically significant differences between stratified patient groups. PCA coefficients of the first and fourth PCs showed prognostic powers ($p<0.05$).

Keywords：radiomics, lung cancer, principal component analysis, prediction of prognoses, Kaplan-Meire method

1. Introduction

Biopsy, which invasively extracts a part of tumor tissue, is needed for personalized medicine of lung cancer. Personalized medicine is a medical concept of treating patients with consideration of omics information (e.g. gene) obtained from the biopsy. However, it costs patients to perform the invasive biopsy, and it takes long time to receive a part of tumor information. On the other hand, medical images, which are routinely and quickly acquired in non-invasive and lower cost way, could include the entire information of tumors. Therefore, radiomics based on the medical images has been proposed as a novel field for performing practical personalized medicine. Radiomics is composed of "radio", which means radiological or medical images, and "omics", which means study field that comprehensively radiomics, a large number of image features (e.g. >400) are comprehensively extracted from various types of medical images, and some features are considered to be associated with patient prognoses including survival, metastases, and recurrence [1]. Therefore, it is substantially important to select radiomic features, which are associated with patient prognoses. In this study, principal component analysis (PCA), which is one of feature dimension reduction methods, has been applied for selection of radiomic features. The aim of this study was to develop an approach for prediction of lung cancer patients' prognoses using PCA-based radiomic features.

---

*1 Department of Health Sciences, Faculty of Medical Sciences, Kyushu University〔3-1-1 Maidashi, Higashi-ku, Fukuoka, 812-8582, Japan〕

e-mail: masahiro19940622@gmail.com

*2 Department of Health Sciences, Graduate School of Medical Sciences, Kyushu University

*3 Nara Institute of Science and Technology (NAIST)

2. Materials and Methods

2.1. Clinical cases

Computed tomography (CT) images (pixel size: 0.977 mm, matrix size: 512 × 512, slice thickness: 3mm) of 197 lung cancer patients were selected from non-small cell lung carcinoma (NSCLC)-Radiomics of The Cancer Imaging Archive (TCIA) database [2]. The database included 3 pathological subtypes of NSCLC, which were adenocarcinoma, squamous cell carcinoma, large cell carcinoma. Patients (male: 140, female: 57, age: 42-92 (mean: 68)) were treated by radiotherapy or radiochemotherapy. The regions of interest (ROI) for lung tumors were extracted by using the gross tumor volumes (GTVs) defined by a radiation oncologist.

2.2. Overall procedure

Figure 1 shows an overall procedure of our proposed approach.

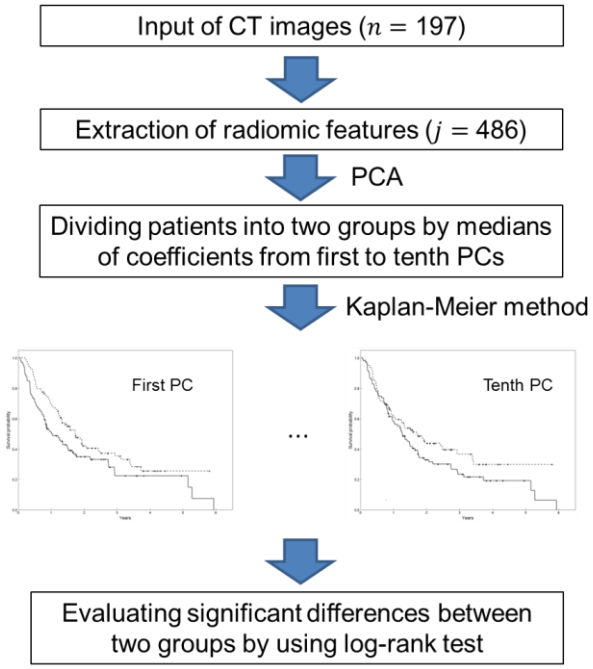

Figure 1. An overall procedure of our proposed approach

First, we input CT images of 197 lung cancer patients, and acquired 486 radiomic features. Next, we applied PCA to reduce the number of features and divided the patients into two groups by medians of coefficients from first to tenth principal components, which were considered as PCA-based radiomic features. Finally, survival probabilities were calculated by using a Kaplan-Meier estimator and evaluated significant differences between two groups by using log-rank test.

2.3. Extraction of radiomic features

In this study, 486 radoimic features which included statistical features, texture features and wavelet features were calculated. Statistical features describe the image histograms within GTV. Texture features were calculated by using gray-level co-occurrence matrix (GLCM) [3], gray-level run length matrix (GLRLM) [4], gray-level size zone matrix (GLSZM) and neighborhood gray-tone difference matrix (NGTDM). GLCM and GLRLM types, the features were computed by considering neighboring pixels at a distance of one pixel and angles of 0°, 45°, 90° and 135°. Figure 2-6 show original CT images, GLCM, GLRLM, GLSZM and NGTDM of homogeneity and inhomogeneity tumor.

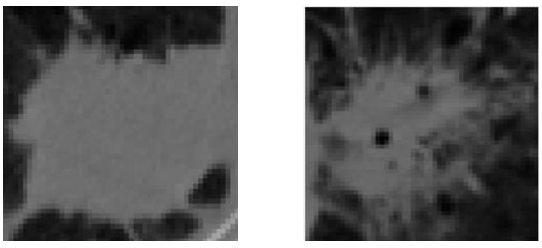

Figure 2. Original images of homogeneity (left) or inhomogeneity (right) tumor.

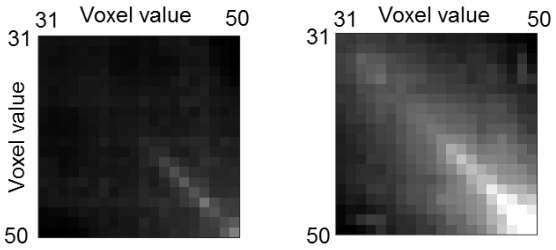

Figure 3. GLCM of homogeneity (left) and inhomogeneity (right) tumor respectively.

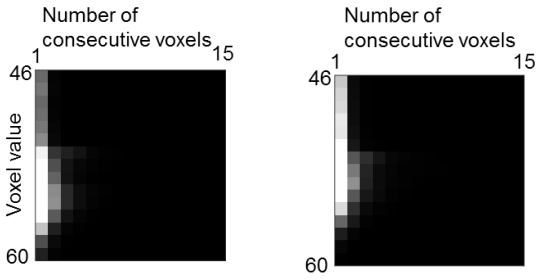

Figure 4. GLRLM of homogeneity (left) and inhomogeneity (right) tumor respectively.

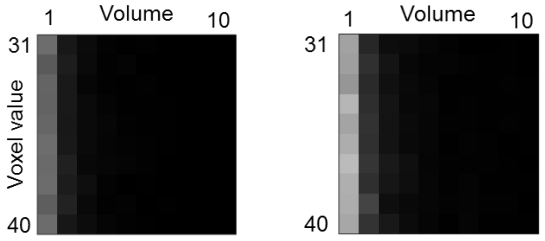

Figure 5. GLSZM of homogeneity (left) and inhomogeneity (right) tumor respectively.

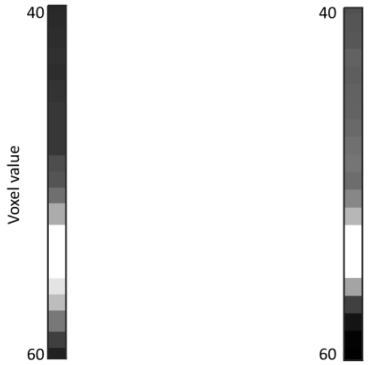

Figure 6. NGTDM of homogeneity (left) and inhomogeneity (right) tumor respectively.

They can represent differences of tumor texture. The final feature values were obtained by averaging those obtained from the matrices corresponding with the four angles. Wavelet features were extracted using images which were transformed by coiflet wavelet function at three dimensions. These features were computed in MATLAB2015b.

2.4. Principal component analysis

Principal component analysis (PCA) is one of the statistical techniques, which converts the new coordinate system and takes principal component axes in descending order in variance. The pth component value c_{ip} for the ith patient was calculated by

$$c_{ip} = \left(\boldsymbol{x}_i - \overline{\boldsymbol{x}}, \boldsymbol{e}_p\right)$$

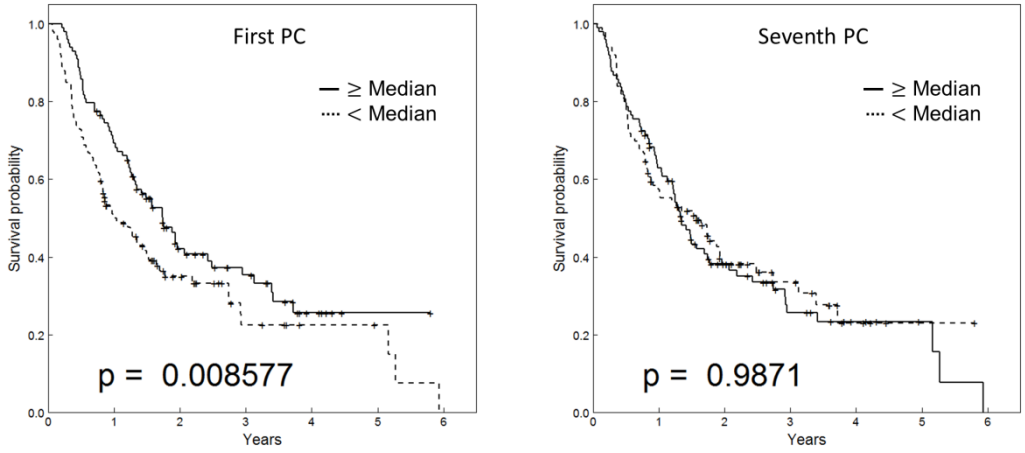

Fig 7. Survival probability of two groups, which are the strongest (left) and the weakest (right) prognostic performances.

where $\boldsymbol{x}_i$ is the radiomic feature for the ith patient, $\bar{\boldsymbol{x}}$ is the mean value of $\boldsymbol{x}_i$ and $\boldsymbol{e}_p$ is pth eigenvector. The first to tenth principal component coefficients were considered PCA-based radiomic features for each patient.

2.5. Calculation of survival probability

We divided the patients into two groups using the median of each PCA-based radiomic features and survival probability were calculated by using Kaplan-Miere method. Log-rank test was used for calculation of statistical significant differences [5]. The survival analysis was performed by using 'survival' package in R ver. 3.4.1 [6]

3. Results and Discussion

Figure 7 shows the survival probabilities of two groups which are the strongest and the weakest prognostic performances. Table 1 shows the contribution rate and p-value for principal component number.

Table 1 Contribution rate and p-value for PC number.

PC number	Contribution rate	p-value
1	0.3711	0.0086
2	0.1534	0.3010
3	0.0563	0.1140
4	0.0344	0.0206
5	0.0289	0.1088
6	0.0278	0.4289
7	0.0249	0.9871
8	0.0201	0.0628
9	0.0175	0.2444
10	0.0148	0.2096

There were statistical significant differences between two survival curves in lung cancer patients stratified based on the first and fourth principal component. PCA-based radiomic features could be associated with survival prediction for lung cancer patients. However, we need to validate this approach in other databases.

4. Conclusions

We may develop an approach for prediction of lung cancer patients' prognoses using PCA-based radiomic features.

Acknowledgement

The authors would like to express their appreciation to all of the members of the Arimura laboratory who provided precious comments and advices for this study.

Conflict of interests

The authors do not have any conflict of interests to disclose.

References

[1] Mazen Soufi, Hidetaka Arimura, et al.: Exploration of temporal stability and prognostic power of radiomic features based on electronic portal imaging device images, Physica Medica: European Journal of Medical Physics, 2018; 46; 32-44

[2] The Cancer Imaging Archive, NSCLC-Radiomics in Netherlands (http://www.cancerimagingarchive.net/)

[3] Haralick RM, Shanmugam K: Dinstein I. Textural features for image classi fi cation. IEEE Trans Syst Man Cybern, 1973; 3; 610-621

[4] Galloway MM: Texture analysis using gray level run lengths. Comput Graph Image Process, 1975; 4; 172–179

[5] Peto R, Peto J: Asymptotically e ffi cient rank invariant test procedures, J R Stat Soc Ser A, 1972; 135:185-207

[6] R Development Core Team: R: A Language and Environment for Statistical Computing. R Found Stat Comput Vienna Austria 2016; 0: {ISBN}3-900051-07-0.doi:10.1038/sj.hdy.6800737.

主成分分析を用いたレディオミクス特徴量による肺がん患者の予後予測法

山田真大[*1]，有村秀孝[*2]，スーフィー　マーゼン[*3]

*1 九州大学大学院医学系学府保健学専攻
*2 九州大学大学院医学研究院保健学部門
*3 奈良先端科学技術大学院大学

本研究の目的は主成分分析(principal component analysis (PCA))に基づくレディオミクス特徴量による肺癌患者の予後予測法の開発である．197 症例の肺癌患者の CT 画像を用いて 486 のレディオミクス特徴量を抽出した．特徴量の数を減らすため，標準化された 486 のレディオミクス特徴量に PCA を適用し，第 1 から 10 主成分の係数を主成分分析に基づくレディオミクス特徴量と定義した. それぞれの主成分分析に基づくレディオミクス特徴量の中央値を用いて 197 症例の患者群を 2 群に分けた．最後に，カプランマイヤー法を用いて生存確率を計算し，2 群間の統計的有意差を評価した．第 1，4 主成分の係数において 2 群間に有意差が見られた($p<0.05$).

Key words: レディオミクス，肺癌，主成分分析，予後予測，カプランマイヤー法

Deep Learning を用いた胸部 CT 像中の肺結節の画像所見の検出および良悪性鑑別

福嶋　一茂[*1]　平野　靖[*1]　木戸　尚治[*1]　岩野　信吾[*2]

要旨

近年，コンピュータ診断支援(Computer-Aided Diagnosis, CADx)システムに関する研究では，Deep Learning が使用される機会が多くなってきており，従来よりも高い性能を示すことが報告されている．肺結節の良悪性鑑別のための CADx システムでも同様の傾向があるが，それらは CT 像等を入力とし，良性あるいは悪性の尤度のみを出力するか，クラス分類するものが一般的である．一方で患者に対して医師が肺結節の診断結果を説明する際には，良悪性の尤度だけでは不十分であり，診断結果の根拠を説明することが求められる．そこで本研究では Deep Learning の一形態である CNN(Convolutional Neural Network)を用いて，CT 像中の肺結節が悪性であることを示唆する画像所見の存在の尤度を診断の根拠として提供し，さらにそれらの尤度を入力とする NN(Neural Network)によって良悪性の鑑別結果を医師に提供する CADx システムの構築を行った．55 個の良性結節と 120 個の悪性結節を用いて本手法の性能を評価した結果，識別率は 79.02±8.43[%]となった．

キーワード：画像所見，肺結節，良悪性鑑別，CT，Deep Learning

1. はじめに

医師が CT 像中の肺結節の良悪性を鑑別する際には，多数の画像所見の有無や程度を判断材料に用いる [1]．しかし，CT 像のような３次元濃淡画像内の濃淡分布を適切に認識することは難しい上，CT 像が撮影される機会や一回に撮影されるスライス数も増えたことにより医師の負担が増加している．そのため，コンピュータ診断支援 (Computer-Aided Diagnosis, CADx)システムの導入が求められ，CADx システムの開発に関する研究も活発に行われている．近年，Deep Learning[2]を用いた CADx システムが高い性能を示す報告[3][4]が上げられている．しかし，肺結節の診断結果を患者に説明する際には，一般的な Deep Learning が出力するような良悪性の尤度だけでは不十分であり，診断の根拠が必要である．

そこで本研究では Deep Learning を用いて肺結節の画像所見の有無を識別し，その結果に基づく良悪性鑑別を医師に提供することによって負担を軽減することと，画像所見の尤度を診断の根拠として提供するシステムを開発することを目的とした．Deep Learning の手法は多々あるが画像認識の分野では一般的に CNN(Convolutional Neural Network)が用いられる．SVM を用いた手法[5]や Random Forest を用いた手法[6][7]などの従来手法ではまず人間が有用な画像所見を特徴量として定量化し，その特徴量を識別器で分類するという手順で識別を行っていた．それに対して，CNN

*1 山口大学大学院創成科学研究科電気電子情報系専攻
〔〒755-8611 宇部市常盤台 2-16-1〕
e-mail: i076vg@yamaguchi-u.ac.jp
*2 名古屋大学医学部放射線医学教室

では定量化手法を CNN 自体が能動的に学習するため，十分な数の学習データがあれば，より簡便に適切な特徴抽出や良悪性鑑別を行うことができると見込まれる．

2. 提案手法

本研究では，CT 像から切り出した肺結節周辺の 3 次元画像に対し CNN を用いて，肺がんを示唆する画像所見の識別モデルを作成した．用いた画像所見は辺縁の明瞭性，形状が類円形であるか否か，ノッチの有無，Air Bronchogram の有無である．図 1 に提案手法における CNN の学習と識別のフローチャートを示す．なお，画像所見の識別モデルは，画像所見ごとに作成したため，それぞれの画像所見に対する CNN の構造は異なる．その後，画像ごとに各識別モデルが出力した画像所見の有無に関する尤度を入力として NN(Neural Network)で肺結節の良悪性鑑別を行なった．図 2 に提案手法における NN の学習と識別のフローチャートを示す．

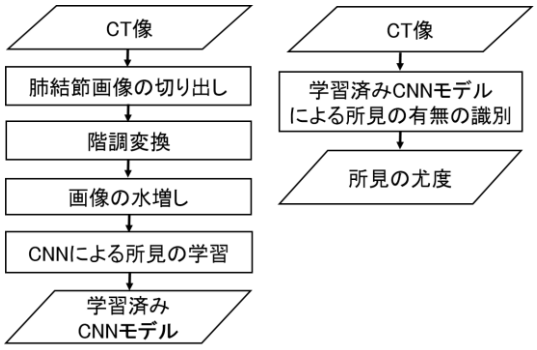

図 1 CNN の学習(左)と識別(右)

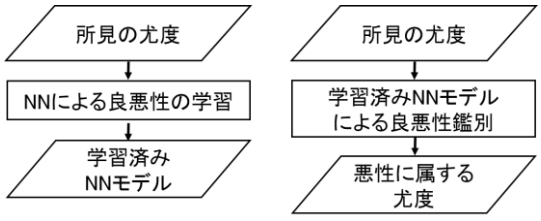

図 2　NN の学習(左)と識別(右)

1)　肺結節周辺画像

本研究で用いたデータベースには解像度の異なる CT 像が含まれているため，B-Spline 補間を用いてスライス内のスペーシングサイズを 0.625[mm]，スライス間隔を 0.500[mm]に統一した．次に一般的に直径 30[mm]以下とされる肺結節が納まるように肺結節の中心から 50×50×60[voxel]で画像を切り出した．これは 31.25[mm]×31.25[mm]×30[mm]に対応する．図 3 に切り出した肺結節周辺画像の結節中心付近の 1 スライスを示す．

図 3 肺結節周辺画像の 1 スライスの例

2)　階調変換

CT 像は–1024~3071[HU]に CT 値が分布する 4096 階調の 3 次元濃淡画像であるが，肺結節及びその周辺構造の CT 値は–1024～200[HU]に集中している．そこで，この範囲の CT 値を 256 階調に変換することで注目する所見の CNN による学習が効率的に行えるようにした．図 4 に図 3 に示す結節の CT 値のヒストグラムを示す．

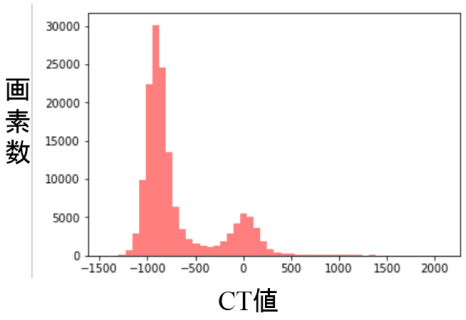

図 4 図 3 に示す結節の CT 値のヒストグラム

3) 画像の水増し

Deep Learning の学習で過学習を起こさずに, 高い汎化性能を得るためには多くのデータが必要となる. インターネットの普及に伴い様々なデータの収集が簡便化してきているが，CT 像のように収集が容易でないものも多い. そこで, 本研究では画像処理によってデータ数の水増しを行った. 具体的には，1[volume]の CT 像に対して頭尾方向の軸は固定し, 残り 2 軸について，以下の処理を行い水増しした.

・正方向及び負方向にそれぞれ 3[voxel]までの範囲で中心座標を平行移動(48 [volume])

・中心から 10° ずつ回転(35[volume])

・鏡映(2[volume])

その結果, もとの画像数は 86 倍に水増しされた.

4) 画像所見の識別

「辺縁の明瞭性」,「形状が類円形であるか否か」,「ノッチの有無」,「Air Bronchogram の有無」の 4 つの画像所見に対して，CNN による識別モデルをそれぞれ作成し, 学習と識別を行った. これらの画像所見は, いずれも所見が見られる場合には結節ががんである可能性が高いと考えられる. 作成した CNN では畳込み層と全結合層で Batch Normalization によって画像をミニバッチごとに正規化することで, 学習における勾配消失を抑制した. 各識別モデルはテストデータの画像ごとに所見の有無に関する尤度を出力した. 表 1~4 に各所見に対する CNN 識別モデルを示す. なお, 識別モデルの層の数やフィルタサイズなどは, 識別率が高くなるように実験的に定めた.

表 1 辺縁の明瞭性の CNN 識別モデル

	フィルタサイズ	ストライド	出力マップサイズ	チャネル数	活性化関数
入力画像	-	-	50×50×60	1	-
convolution	3×3×3	1	50×50×60	16	Relu
max pooling	2×2×2	2	25×25×30	16	
convolution	3×3×3	1	25×25×30	32	Relu
convolution	3×3×3	1	25×25×30	32	Relu
convolution	3×3×3	1	25×25×30	32	Relu
max pooling	2×2×2	2	13×13×15	32	-
fully connect	-	-	1×1×1	16	Relu
fully connect	-	-	1×1×1	2	softmax

表 2 形状の CNN 識別モデル

	フィルタサイズ	ストライド	出力マップサイズ	チャネル数	活性化関数
入力画像	-	-	50×50×60	1	-
convolution	3×3×3	1	50×50×60	16	Relu
max pooling	2×2×2	2	25×25×30	16	
convolution	3×3×3	1	25×25×30	32	Relu
convolution	3×3×3	1	25×25×30	32	Relu
max pooling	2×2×2	2	13×13×15	32	-
fully connect	-	-	1×1×1	16	Relu
fully connect	-	-	1×1×1	2	softmax

表 3 ノッチの CNN 識別モデル

	フィルタサイズ	ストライド	出力マップサイズ	チャネル数	活性化関数
入力画像	-	-	50×50×60	1	-
convolution	3×3×3	1	50×50×60	32	Relu
max pooling	2×2×2	2	25×25×30	32	
convolution	3×3×3	1	25×25×30	64	Relu
max pooling	2×2×2	2	13×13×15	64	-
convolution	3×3×3	1	13×13×15	128	Relu
max pooling	2×2×2	2	7×7×8	128	-
fully connect	-	-	1×1×1	32	Relu
fully connect	-	-	1×1×1	2	softmax

表 4 Air Bronchogram の CNN 識別モデル

	フィルタサイズ	ストライド	出力マップサイズ	チャネル数	活性化関数
入力画像	-	-	50×50×60	1	-
convolution	3×3×3	1	50×50×60	32	Relu
max pooling	2×2×2	2	25×25×30	32	
convolution	3×3×3	1	25×25×30	64	Relu
convolution	3×3×3	1	25×25×30	64	Relu
max pooling	2×2×2	2	13×13×15	64	-
convolution	3×3×3	1	13×13×15	128	Relu
convolution	3×3×3	1	13×13×15	128	Relu
convolution	3×3×3	1	13×13×15	128	Relu
max pooling	2×2×2	2	7×7×8	128	-
fully connect	-	-	1×1×1	64	Relu
fully connect	-	-	1×1×1	2	softmax

5)　肺結節の良悪性鑑別

入力は 4 つの画像所見の有無に関する 4 つの尤度とし，三層 NN で肺結節の良悪性鑑別を行った．出力は悪性である尤度とし，学習係数を 0.03，学習回数を 900 回とした．

3. 実験

1) 対象データ

実験では，名古屋大学医学部附属病院で撮影され，名古屋大学の倫理審査委員会の承認を得た，肺結節を含む胸部 CT 像 296 症例を用いた．
これらの CT 像は，いずれもヘルシンキ宣言の倫理的原則に沿っており，当該患者へのインフォームド・コンセントを得たうえで収集された．症例には複数の肺結節を含むものもあるため，肺結節は 300 個であった．対象とした CT 像の詳細を以下に示す．

・スライスサイズ：512×512[pixels]
・スペーシングサイズ：0.566~0.781[mm]
・スライス間隔：0.301~1.00[mm]
・スライス枚数：306~1086 枚

各肺結節には医用画像工学の専門家による各画像所見の有無についてのラベルと医師の診断による良悪性のラベルが与えられている．交差検証を行うために 5 つに分割した画像所見の識別に用いたデータセットの内訳を表 5 に示す．また，良悪性鑑別では結節数の少ない良性症例は全て用いた．一方で悪性結節については良性結節の数との差異が少なくなるように適切に症例数を決定した．そのため，300 個の肺結節について出力された尤度の内，良悪性鑑別に用いるデータは悪性 120 個と良性 55 個とした. これらを同様に 5 分割したデータセットの内訳を表 6 に示す.

表 5 画像所見の別に用いたデータセット

		set_1	set_2	set_3	set_4	set_5	合計
辺縁明瞭性	辺縁不明瞭	19	19	18	18	18	92
	辺縁明瞭	41	41	42	42	42	208
形状	不整形	36	36	36	35	35	178
	類円形	24	24	24	25	25	122
ノッチ	有り	16	16	15	15	15	77
	無し	44	44	45	45	45	223
Air Bronchogram	有り	24	24	24	24	23	119
	無し	36	36	36	36	37	181
全データ	原画像	60	60	60	60	60	300
	水増し後	5160	5160	5160	5160	5160	25800

表 6 良悪性鑑別に用いたデータセット

	set_1	set_2	set_3	set_4	set_5	合計
悪性	24	24	24	24	24	120
良性	11	11	11	11	11	55
データ数	35	35	35	35	35	175

2) 評価方法

画像所見の識別と肺結節の良悪性鑑別はどちらも 5 分割したデータセットの内 1 つをテストデータとし，残り 4 つを学習データとする 5 交差検証で行った．前者については CNN が出力した尤度に対して 0.5 をしきい値として分類し，後者は NN が出力した尤度をテストデータごとに ROC 解析による最適なしきい値[8]で分類した．

4. 結果

各画像所見の識別率は「辺縁明瞭性」が 86.99±2.26[%]，「形状」が 68.00±6.38[%]，「ノッチ」が 75.88±1.97[%]，「Air Bronchogram」が 72.57±3.94[%]となった．また，「辺縁明瞭性」，「形状」，「ノッチ」，「Air Bronchogram」の識別結果をそれぞれ表 7~10 に示す.

表 7 辺縁明瞭性の識別結果

		CNN の識別結果	
		明瞭	不明瞭
医用画像工学の専門家によるラベル付け	明瞭	196	12
	不明瞭	24	68

表 8 「形状」の識別結果

		CNN の識別結果	
		類円形	不整形
医用画像工学の専門家によるラベル付け	類円形	40	82
	不整形	62	116

表 9 「ノッチ」の識別結果

		CNN の識別結果	
		無し	有り
医用画像工学の専門家によるラベル付け	無し	214	9
	有り	63	14

表 10 「Air Bronchogram」の識別結果

		CNN の識別結果	
		無し	有り
医用画像工学の専門家によるラベル付け	無し	157	24
	有り	59	60

良悪性鑑別で NN の出力した悪性に属する尤度に対して，データセットごとに ROC 解析による最適なしきい値の設定を行った結果，得られた識別結果を表 11 に示す． 良悪性鑑別で NN の出力した悪性に属する尤度に対して，データセットごとに ROC 解析による最適なしきい値の設定を行った結果，得られた識別結果を表 11 に示す．交差検証による識別率は 79.02±8.43[%]となった．

表 11 良悪性鑑別の識別結果

		CNNによる識別結果		識別率[%]
		悪	良	
set_1	医・悪	21	3	82.85
	医・良	3	8	
set_2	医・悪	16	8	71.43
	医・良	2	9	
set_3	医・悪	23	1	94.29
	医・良	1	10	
set_4	医・悪	17	7	77.14
	医・良	1	10	
set_5	医・悪	18	6	74.29
	医・良	3	8	
平均				79.02
標準偏差				8.43

5. 考察

1) 画像所見識別実験結果の考察

画像所見識別実験では CNN を用いて学習と識別を行い，いずれの所見についてもおおむね 70% 程度以上の識別率を得ることができた．

「辺縁明瞭性」の識別率は 86.99±2.26[%]となった．他の所見と比べて識別率が高く，識別モデルの構成も畳込み層が 4 層，プーリング層が 2 層と比較的少ない層の数で，感度 93.3[%]，特異度 85.0[%]という結果を得た．このようになった要因として，この所見が結節境界のエッジの強さの違いを表すものであり，人の目でみても単純な特徴であると推察されることから，浅いネットワークであっても高い識別精度が得られたと考えられる．

「形状」の識別率は 68.00±6.38[%]となった．形状は類円形か不整形の二分類で，3 次元的な特徴ではあるものの辺縁明瞭性と同様に単純な特徴で学習は容易であると予測された．しかし，識別精度は低く，標準偏差も大きくなった．表 8 の識別結果と分類に失敗した入力画像を見ると結節の濃

度が低いものや辺縁部が不明瞭であるものは識別に失敗していた．また，類円形と不整形の分類のための明確な基準がなく，主観的な判断による影響が強いことが考えられる．よって識別モデルを再構築すること，および本実験において有効な所見であるのか再検討が必要である．

「ノッチ」の識別率は 75.88±1.97[%]となった．今回，用いた画像所見の中ではラベルの偏りが大きく，すべてノッチが無いと識別された場合でも識別率が約 70%となる．表 9 に示す識別結果から考えても出力が「ノッチ無し」に偏り，適切に識別できていないことがわかる．「ノッチ」は一部のスライスに表れる特徴であり，3 次元の画像において特徴を識別することが難しかったのではないかと思われる．今回は畳込み層が 1~3 層，プーリング層が 1~3 層で探索を行なった．本研究ではあまり探索を行なわなかった深いネットワークや特徴の次元数を大きくすることで 3 次元的な一部に凹みのある特徴としてとらえるように識別モデルを変更することが考えられる．

最後に「Air Bronchogram」の識別率は 72.57±3.94[%]となった．識別結果は表 10 となり，識別に失敗した画像には「Air Bronchogram 有り」のラベルがついていないが結節内に似たような低 CT 値の影が確認できるものがいくつか存在した．これは空洞状の低 CT 値領域の所見であり，管状の低 CT 値領域である「Air Bronchogram」とは異なる所見である．この差異を表現できるかどうかがこの所見の識別において重要であると考えられる．こちらも改善策としては深いネットワークの構築により，複雑な特徴の表現を可能とすることが考えられる．

2)　肺結節の良悪性鑑別実験の考察

肺結節の良悪性鑑別実験では最終的な識別精度は 79.02±8.43[%]となった。同じデータセットで画像所見の判別を行わず，画像から直接良悪性鑑別を行った識別精度が 70.08±9.00[%]であったことから，本研究の画像所見の尤度を用いた良悪性鑑別は有用であると考えられる．しかし、1)で考察したように画像所見に対して識別精度が十分だったものは少なく，データセットごとに識別精度にもばらつきがあるため，信頼性には疑問が残った．より多くの画像所見を用い，正確な画像所見の識別と尤度を得ることができれば，精度と信頼性の高い結果が得られることが予想される．また，本研究では NN を用いた識別器でもパラメータの最適化はしていない．今後はネットワークモデルの改善やパラメータ最適化手法の検討を行うことで，鑑別精度を向上させ，システムの実用性を高めることを目標とする．

6. まとめ

本稿では，胸部 CT 像を用いて肺結節周辺画像から肺がんに関する画像所見を 3D-CNN によって識別し，その結果を入力とした NN で肺結節の良悪性鑑別を行う手法を提案した．その結果，79.02±8.43 という識別率を得た．これは画像所見を用いずに画像から直接良悪性鑑別を行った手法と同程度の識別率であるが，本手法は良悪性の尤度だけでなく所見の有無を提供することが可能となっている．これにより医師が患者へ診断について説明する際に用いることができる．また，画像所見を判断材料とする医師の診断により近い方法であるため鑑別精度の向上が期待される．今後は CNN と NN のネットワークの改善とパラメータ調整の手法の検討や扱うデータの再検討が必要である．

7. 謝辞

本研究を行うに当たり，日頃よりご指導，御助言をいただいた山口大学大学院創成科学研究科電気電子情報系専攻画像支援診断工学研究室の皆様に深く感謝致します．また本研究は日本学術振興会科学研究費補助金新学術領域研究(26108009)による支援を受けた．

利益相反の有無

無し.

文　献

［1］　林秀行，芦澤和人，福島文 他: 高分解能 CT による孤立性肺結節の良悪性の鑑別，断層映像研究会雑誌 **32**, 108-114, 2005

［2］　LeCun Y, Bengio Y, Hinton G : Deep learning, Nature **521**, 436–444, 2015.

［3］　Tu X, Xie M, Gao J, et al. : Automatic Categorization and Scoring of Solid, Part-Solid and Non-Solid Pulmonary Nodules in CT Images with Convolutional Neural Network, Scientific Reports, **7**, Article number: 8533, 2017

［4］　van Ginneken B : Fifty years of computer analysis in chest imaging: rule-based, machine learning, deep learning, Radiological Physics and Technology **10**, 23-32, 2017

［5］　Takizawa H, Nishizako H : Lung cancer detection from X-ray CT scans using discriminant filters and view-based support vector machine , The Journal of the Institute of Image Electronics Engineers of Japan **40**, 59-66, 2011

［6］　Le V, Yang D, Zhu Y et al. : Quantitative CT analysis of pulmonary nodules for lung adenocarcinoma risk classification based on an exponential weighted grey scale angular density distribution feature, Computer Methods and Programs in Biomedicine **160**,141-151, 2018

［7］　Gong J, Liu J Y, Zheng B et al. : Automatic detection of pulmonary nodules in CT images by incorporating 3D tensor filtering with local image feature analysis, Physica Medica **46**, 124-133

［8］　Akobeng AK : Understanding diagnostic test 3: Receiver operating characteristic curves, Acta Paediatrica, International Journal of Paediatrics **96**, 644-647, 2007

Detection of medical image findings and discrimination between benign and malignant nodules in chest CT images by using Deep Learning

Kazushige FUKUSHIMA[*1], Yasushi HIRANO[*1], Shoji KIDO[*1,]
Shingo IWANO[*24]

*1 Graduate School of Sciences and Technology for Innovation, Yamaguchi University
*2 Department of Radiology, School of Medicine, Nagoya University

Computer-Aided Diagnosis (CADx) systems based on Deep Learning have been actively researched in recent years, and it have been reported to exhibit their high performance. The CADx systems for benign and malignant discrimination exhibit a similar tendency. They generally convert input medical images into likelihood of their benignancy and malignancy. On the other hand, when medical doctors explain the diagnosis to patients, they need to explain not only the likelihood of malignancy of the lung nodule but also basis of the diagnosis. In this paper, we proposed a CADx system which provides medical doctor with likelihood of the existence of the medical image finding related to lung cancer CNN (Convolutional Neural Network) for obtaining the likelihood of the medical image findings, and NN (Neural Network) for obtaining the likelihood of the malignancy of the lung nodule. As a result of evaluating the performance of the proposed system using 55 benign and 120 malignant nodules, the discrimination rate was 79.02±8.43[%].

複数シーケンス乳房 MRI(Magnetic Resonance Imaging) 画像における腫瘤病変の良悪性分類アルゴリズム

柴原 翔[*1]　中山 良平[*2]　大西 悠吾[*1]　檜作 彰良[*2]
難波 清[*3]　中島 恵[*3]

要旨

乳房 MRI（Magnetic Resonance Imaging）は，マンモグラフィや超音波検査よりも感度が高いが，特異度は同程度であり，その改善が望まれている．本研究では複数シーケンスの乳房 MRI 画像における腫瘤病変の良悪性分類アルゴリズムを開発することを目的とする．実験試料は，43 患者の MRI（T1／T2 強調画像，T1 強調ダイナミック造影画像とその差分画像）で構成される．提案手法では，まず，各シーケンス画像を畳み込みニューラルネットワークに学習させ，良悪性の分類に有用な特徴マップを抽出する．次に，各特徴マップをサポートベクターマシン（SVM）で統合することにより，腫瘤病変を良性または悪性に分類する．Leave-one out patient 法を用いた評価実験の結果，感度 100.00%，特異度 84.62%，陽性予測度 93.75%，陰性予測度 100.00%が得られ，提案手法の高い鑑別精度が示された．

キーワード：乳房 MRI，畳み込みニューラルネットワーク（CNN），複数シーケンス

1. はじめに

乳がんの効果的な検査法として，マンモグラフィと磁気共鳴画像診断装置(MRI) がある．マンモグラフィは乳がん検診に導入され，乳がん早期発見のための低コストイメージモダリティとして知られるが，その感度(がんをがんと正しく診断した割合)，特異度（正常を正常と正しく診断した割合）は決して高くない．一方，MRI は MRI は乳がんの検査法として，最も優れた感度，特異度を有することが知られている．しかし，乳がん検診に MRI を導入することはコストの面から非現実的であり，現在はマンモグラフィで病変を発見し，その精密検査として，MRI が実施されている状況である．

MRI で悪性の可能性があると診断された場合，患部の切片を直接採取する針生検が実施される．針生検は患者の身体的，精神的負担が大きく，不要な針生検は避けるべきである．そこで，MRI 画像上での正確な良悪性の診断が重要となるが，経験豊富な放射線科医でさえ困難な作業となっている．この問題に対処するために，近年，医用画像をコンピュータで解析し，その解析結果を医師に提示するコンピュータ支援診断（CAD : computer-aided diagnosis）システムが開発されてきた[1,2]．また，人工知能の一つで，画像認識に高いパフォーマンスを有する畳み込みニューラルネットワークが提案され，一般画像だけでなく，医用画像にも幅広く応用されている．

そこで本研究では，複数シーケンスで撮影された乳房 MRI 画像を畳み込みニューラルネットワークに学習させることにより，腫瘤病変の画像特徴と代謝・生理機能を統合的に解析し，悪性の可能性を評価するアルゴリズムを開発する

2. 方法

1）実験試料

実験試料は，医療法人北斗病院（帯広市）で，2009 年 10 月 21 日から 2015 年 7 月 17 日までに

*1 立命館大学大学院　理工学研究科
〔〒525-8577 草津市野路東 1-1-1〕
e-mail: ri0050xe@ed.ritsumei.ac.jp
*2 立命館大学理工学部電子情報工学科
*3 北斗病院　乳腺外科

MR 撮影装置(GE MEDICAL SYSTEMS 製)を用いて撮影された 43 患者（年齢：20-82 歳，平均年齢：55.7 歳）の MRI 画像で構成される．これらには, T1 強調画像, T2 強調画像, T1 強調 DCE（Dynamic contrast enhanced image：ダイナミック造影）画像，そして T1 強調画像の差分を取った画像の 4 種類が含まれる．T1 強調 DCE 画像は, 造影剤投与前, 投与直後, 1 分後, 2 分後, 4 分後の 5 時相で，差分画像は 4 時相で構成される．

2）畳み込みニューラルネットワーク（CNN)の構成

本研究では, CNN により複数シーケンスで撮影された MRI 画像を統合的に解析することにより, 良悪性の分類を実施する. 本研究では, CNN を特徴抽出として使用する．シーケンス画像ごとに CNN が作成され，それらは入力層，中間層（畳み込み層，畳み込み層，バッチ正規化，ReLU 関数，プーリング層，畳み込み層，バッチ正規化，ReLU 関数，プーリング層，畳み込み層，ReLU 関数，プーリング層），そして全結合で構成される．入力層には各シーケンス画像を切り出した関心領域画像が入力される．畳み込み層のフィルタサイズは 5×5, フィルタ数は 32, ストライド 1，パディング 2 で全ての畳み込み層で同じである．また，プーリング層でのフィルタサイズは 3×3，ストライドは 2 である．そして各シーケンス画像から出力された特徴マップを統合する全結合層を配置し，SVM(Support Vector Machine)により良悪性の分類を行う．

CNN の学習では，関心領域を拡散強調画像，T1 強調画像，T2 強調画像，さらに 5 時相の T1 強調 DCE 画像，4 時相で構成される T1 強調画像の差分画像から切り出し，各シーケンス画像の関心領域を独立して CNN に入力することにより，特徴マップ抽出の学習を実施した．ここでは，全関心領域画像を左右反転させ，新たな学習データとして追加した．CNN および SVM の学習と評価は，Leave-One Patient-Out 法を用いた．Leave-One Patient-Out 法は 1 患者データを評価用，残り患者データを学習用に用いる．そして全ての患者データが評価用に使用されるまで，この学習と評価を繰り返す.

3）評価指標

本研究では，提案手法の評価として，感度，特異度，正答率，陽性予測度，陰性予測度の 5 指標を用いる．正答率は次式で定義される．

$$A = \frac{TP + TN}{TP + TN + FP + FN}$$

ここで，TP(True positive)：真陽性，FP(False Positive)：偽陽性，TN(True Negative)：真陰性，FN(False Negative)：偽陰性である．真陽性とは，病気があり検査においても陽性と判断された割合のことであり，偽陽性とは病気がないのに検査において陽性と判断さ

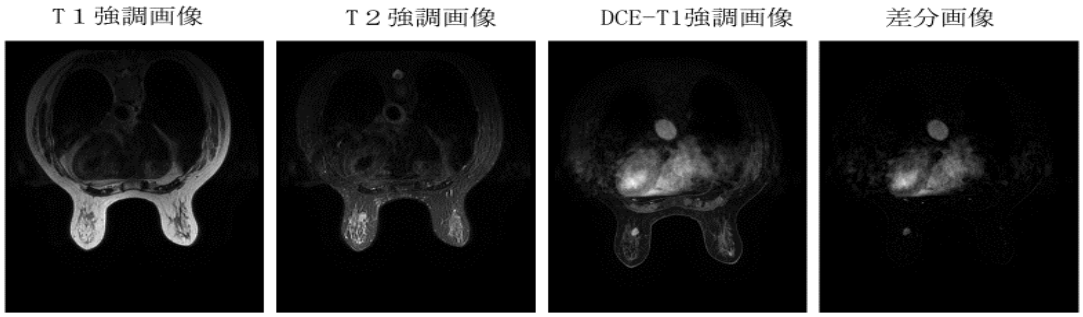

図１　T1強調画像，T2強調画像，DCE−T1強調画像，およびその差分画像の比較

れた割合のことである．また真陰性とは，病気がなく検査においても陰性と判断された割合であり，偽陰性とは，病気があるのに，検査では陰性と判断された割合である．感度(S_+)，特異度(S_-)は，それぞれ

$$S_+ = \frac{TP}{TP + FN}$$

$$S_- = \frac{TN}{TN + FP}$$

で定義される．また，陽性予測度(P_+)，陰性予測度(P_-)は

$$P_+ = \frac{TP}{TP + FP}$$

$$P_- = \frac{TN}{TN + FN}$$

で定義される．

3. 結果と考察

表 1 に従来法，提案手法の良悪性鑑別結果を示す．従来法は正答率 81.57%，感度 85.00%，特異度 77.77%，陽性予測度 80.95%，陰性予測度 82.35%であった．そして提案手法は正答率 97.62%，感度 100.00%，特異度 84.615%，陽性予測度 93.75%，陰性予測度 100.00%と，全体的に高くなった．これは，DCE-MRI 画像に加えて他のシーケンス画像が追加されたことにより，良悪性の情報量が増え，従来法に比べて，より特徴量空間に違いが現われることに起因するためだと考える．

しかし，本研究のための症例データ数は 43 患者と少なく，抽出する特徴量が複雑ではない．データ数を増やしていったときに識別関数がサポートベクタマシーンでよいのか，もしくはニューラルネットワークのソフトマックス関数を用いて分類したほうがよいのか，これらを今後の検討課題とする．

4. まとめ

本研究では，複数シーケンス乳房 MRI 画像を畳み込みニューラルネットワークに並列に学習させることで腫瘤病変の良悪性鑑別を行った．従来の乳房 DCE-MRI 画像だけを用いた従来法より，提案手法による複数シーケンス画像を用いて特徴量を抽出した方が高い識別結果を示した．提案手法を臨床に応用することにより，今までの臨床では，良性でありながら，生体検査を受診していた患者数の軽減が期待できる．

表 1 従来法・提案手法の結果比較（%）

	従来法	提案手法
正答率	81.57	97.62
感度	85.00	100.00
特異度	77.77	84.615
陽性予測度	80.95	93.75
陰性予測度	82.35	100.00

謝辞

研究遂行にあたり貴重なご助言を賜った北斗病院のスタッフの方々に深謝いたします．

利益相反の有無

なし

文　献

[1] Guillaume Lemaitre, Robert Marti, Jordi Freixenet, Joan C. Vilanova, Paul M. Walker, Fabrice Meariaudeau: Computer-Aided Detection and diagnosis for prostate cancer based on mono and multi-parametric MRI. Computers in Biology and Medicine: Volume 60, 8-31,2015.

[2] Yawen Xiao, Jun Wu, Zongli Lin, Xiaodong Zhao: A deep learning-based multi-model ensemble method for cancer prediction. Computer Methods and Programs in Biomedicine: Volume 153 1-9, 2018.

テンプレート（全ての原稿の種類に共通） Ver. 2.1（2017.3.21 改訂）

ディープラーニングを用いた乳房超音波検査画像の自動読影

井上 謙一[*1*2] 川崎あいか[*1] 小清水佳和子[*1]

山中千草[*1] 佐々木毅[*3] 土井卓子[*1]

要旨

[背景]人工知能を用いた画像認識は医療分野でも研究がなされている。我々は乳腺の超音波検査(US)画像を用いて乳癌の自動判定を検討した。

[対象と方法]当院で撮影された US 画像から、正常乳腺組織、良性腫瘍、悪性腫瘍が描出されている部位をそれぞれ切り出しベース画像とした。その際、画像の範囲内で 128x128 ピクセルでどこをランダムで切り出してもその特徴が描出されるように集めた。ベース画像からランダムに切り出した画像を教師ありデータとして、畳み込みニューラルネットワーク(CNN)に学習させ、精度を計測した。

[結果]正常乳腺 95 画像、良性病変 1206 画像、悪性病変 358 画像から、ランダムに 5000 枚ずつ切り出した画像計 15000 枚を用いて、CNN は 20 層の ResNet で学習させたところ、正診率 98.1%、感度 94.9%、特異度 99.7%、PPV99.4%、NPV97.4%であった。またこの学習モデルを用いて別のオリジナル US 画像をスキャンし、癌が疑わしい部分を赤く光らせるアルゴリズムも作成した。

[考察]US を自動読影できるようになれば、総合検診を念頭とした乳癌検診の効率・精度は飛躍的に向上する可能性を秘めている。

[結語]CNN で US 画像の自動読影システムを構築した。更に検証を重ね、全国で利用できるシステムの構築を目指す。

キーワード：乳癌、超音波検査、機械学習、畳み込みニューラルネットワーク、ディープラーニング

1. はじめに

近年のコンピュータの飛躍的な機能向上と人工知能(AI)の飛躍的な精度の向上とがあいまって、現在では AI があらゆる分野に導入され、業務の効率化が進められている。この第 4 次産業革命とも呼ばれる AI により、業務内容の構造自体が大きく変わりつつあり、医療分野でも例外ではない。

*1 湘南記念病院 かまくら乳がんセンター
〔〒248-0027 鎌倉市笛田 2-2-60〕
*2 e-mail: kinoue@syonankinenhp.or.jp
*3 東京大学医学部大学院医学系研究科人体病理学病理診断学分野
〔〒113-003 東京都文京区本郷 7-3-1〕

今回我々は、乳腺の超音波検査画像における病変の特徴的所見を学習させることで良悪性を判断させた。また、それを応用した超音波検査画像の自動読影システムを構築したので提案する。

2. 対象と方法

当院で撮影された乳腺超音波検査画像から、正常乳腺組織、良性腫瘍、悪性腫瘍が描出されている部位をそれぞれ切り出しベース画像とした。その際、縦、横共に 128 ピクセル以上となるように切り出した。ベース画像は、正常乳腺 95 画像、良性病変 1206 画像、悪性病変 358 画像を得た。

カテゴリー毎に得られたベース画像から、128×128 ピクセルで画像をランダムに各 5000 枚ずつ切り出した。その際に、それぞれの画像

のサイズによって選ばれやすさの重みづけをした。そうすることで、サイズの小さい画像から何度も似たような画像が選択されることを防いだ。そうやって切り出した合計 15000 枚の画像を教師ありデータとして、畳み込みニューラルネットワーク(CNN)に学習させ、精度を計測した。CNN は ResNet[1]をベースとした。畳み込み層の数は複数パターン用意し、精度の違いを検討した。

次に、癌が疑わしい部分を赤く光らせるアルゴリズムも作成した(特許申請中)。即ち、超音波検査画像の一部を 128×128 ピクセルの枠で切り出し、その画像が正常、良性病変、悪性病変のいずれであるかを判定する。もし良性病変なら青く、悪性病変なら赤く光らせる。そして枠を少し右にずらし、その部位でまた同様に判定させる。そうやって画像を左上から右下までスキャンするようにスライドさせ、都度判定させることで、良性病変の部位は青く、悪性病変はより赤く光らせることができる。

図 1 スキャン方法

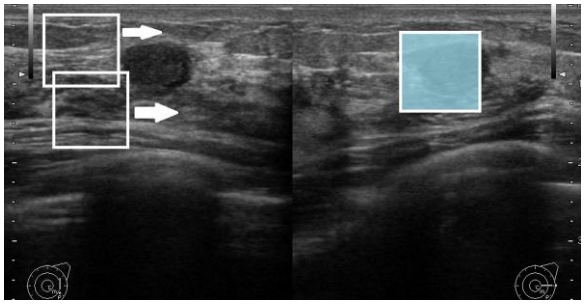

3. 結果

CNN を、まずは畳み込み層 20 層のモデルで学習させたところ、正診率 98.1%、感度(=recall rate)94.9%、特異度 99.7%、PPV(=precision rate)9.4%、NPV97.4%となった。

次に、CNN の畳み込み層を増やしたモデルを複数パターン用意し、同条件で学習させたところ、畳み込み層が 58 層の CNN が最も良好な成績を収めた。その際の精度は、正診率 92.6%、感度 88.0%、特異度 94.4%であった。

図 2 CNN の畳み込み層毎の学習曲線

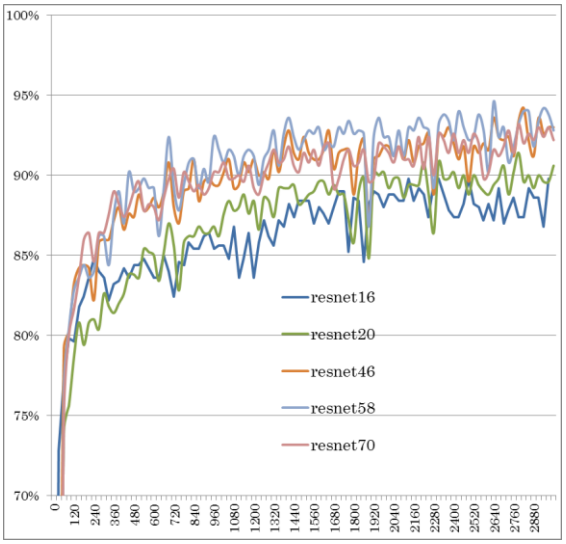

ところが、この学習モデルを用いて超音波検査画像をスキャンしたところ、殆どの腫瘤を良性と判断しており、実用には耐えなかった。

図 3 CNN58 層で悪性が半分青く光っている

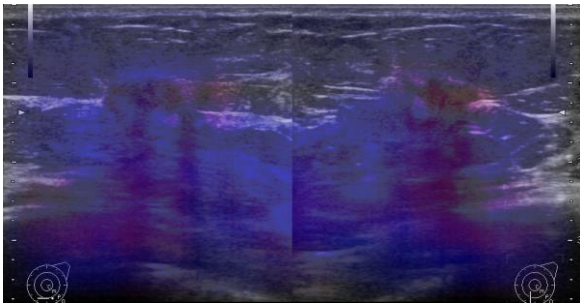

図 4 CNN58 層で良性を青く光らせている

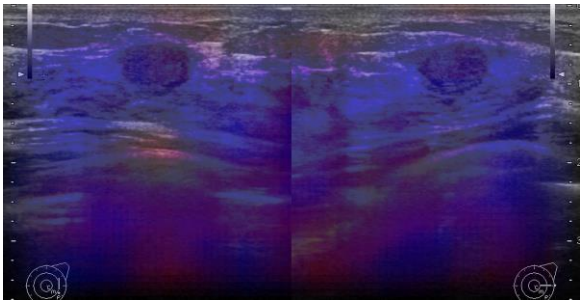

一方、最も成績が不良だった畳み込み層 16

層の CNN でスキャンさせたところ、悪性病変を赤く、良性病変を青く光らせることができた。

図 5 悪性病変が赤く光っている

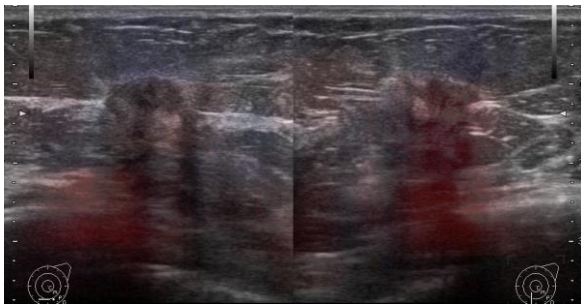

図 6 良性病変が青く光っている

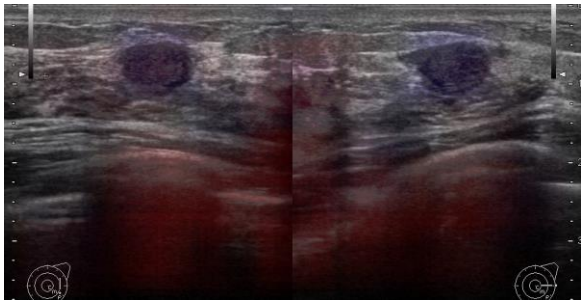

4. 考察

スキャン結果の違いは、58 層の CNN が過学習を起こしたために、腫瘤を良性よりに判定しがちになったためと考えた。

超音波検査画像はグレイスケールであり、背景や人物と異なり病変の形状もそれほどバラエティに富んでいるわけではないため、過剰に CNN を深くするのは余分な特徴を抽出してしまい、却って精度が低下すると考えられた。従って、今後データを増やして学習させる際も､畳み込み層を 16 層以下に抑えた上で検討すべきと思われた。

Becker[2]らの検討では、アルゴリズムが異なるとはいえ同じ乳腺 US での学習結果は感度 84.2%、特異度 80.4%とある。本研究では 16 層の精度でも正診率 87.6%、感度 95.1%、特異度 87.4%と十分にそれらを上回る精度を誇っている。

ただし今回の超音波検査画像は、当院で同一の機器で、同一の検査技師が撮影した画像であり、他の機器には応用が効かないと思われる。どの超音波検査機器でも判定できるように学習させるには、おそらく畳み込み層をより深くした上で様々な機器で撮影された画像を学習する必要があると思われた。

そうしてどの機器からの画像でも判定できるような学習モデルが完成すれば、それを全国の医療機関に配布することで、超音波検査の精度は飛躍的に向上する。例えば、今後の乳癌検診は、マンモグラフィと超音波検査を併用した総合判定に移行しつつあるが、超音波検査を自動読影できるようになれば、検診の効率・精度は飛躍的に向上する可能性を秘めている。

5. 結語

CNN で超音波検査画像の自動読影システムを構築した。更に検証を重ね、全国で利用できるシステムの構築を目指す。

利益相反の有無

なし

文 献

［1］He K, Zhang X, Ren S el al: Deep Residual Learning for Image Recognition. arXiv:1512.03385

［2］Becker AS, Mueller M, Stoffel E et al: Classification of breast cancer in ultrasound imaging using a generic deep learning analysis software: a pilot study. Br J Radiol. 2018 Feb;91(1083)

Automatic Detection and Diagnosis of Breast Cancer From Ultrasound Images Using Deep Learning

Kenichi INOUE[*1], Aika KAWASAKI[*1], Kanako KOSHIMIZU[*1],
Chigusa YAMANAKA[*1], Takeshi SASAKI[*2], Takako DOI[*1]

*1 Shonan Memorial Hospital, Breast Cancer Center
*2 Department of Pathology, Graduate School of Medicine, The University of Tokyo

[Background] Deep learning is very useful tool to help make decision in a variety of platform, including medicine. We have constructed an automatic detection and diagnosis system of breast cancer from ultrasound images. [Materials and Methods] From ultrasound images of breast, images were cropped around the area of lesions by 128 pixels or over in both width and height as base images. Lesions were categorized into three groups, including malignant lesion, benign lesion or normal gland. From base images, images were randomly cropped by 128x128 pixels and trained with convolutional neural network as supervised learning and evaluated its accuracy. [Result] Base images including 95 normal gland, 1206 benign lesions and 358 malignant lesions were obtained. 15000 images were cropped and trained with ResNet-based convolutional neural network. The result showed 98.1% of accuracy, 94.9% of sensitivity and 99.7% of specificity. We have also constructed the scanning system to detect and diagnose lesions, drawing color at the area of lesion. [Discussion] Automatic detection and diagnosis system of breast cancer could be utilized as useful tool to detect breast cancer, especially in breast screening. [Conclusion] An automatic detection and diagnosis system would make breast screening more efficient and more accurate.

Key words: Breast Cancer, Breast Screening, Machine Learning, Deep Learning, Convolutional Neural Network

著者紹介

井上 謙一 （いのうえけんいち）
1999 年旭川医科大学卒、2009 年北海道大学大学院医学研究科 高次診断治療学専攻修了。現在、湘南記念病院 乳がんセンター 副センター長。乳腺外科医として診療する傍ら、AI を用いた乳癌画像診断の研究に従事。

機械学習に基づく X 線透視画像からの膝蓋骨方向検出に関する基礎検討

林田　大幹[*1]，山崎　隆治[*1]，田島　未輝斗[*1]，冨田　哲也[*2]，
河野　賢一[*3]，佐藤　嘉伸[*4]，菅本　一臣[*2]

要旨

現在，我々は，1 方向 X 線透視画像を用いた 2D/3D レジストレーションに基づく膝関節 3 次元運動計測の全自動化に向けて様々な要素技術の開発を行っている．その一つとして，2 次元 X 線透視画像上の膝関節部位（大腿骨，脛/腓骨，膝蓋骨）の方向（相対的な角度）を予め把握しておくことは非常に重要である．特に，膝蓋骨については，レジストレーションが不安定であるため実行前にできるだけ膝蓋骨の初期点（位置と姿勢）を対象シルエットに対し適切に近づけておく必要があるが，もし X 線透視画像上の膝関節部位間の方向が予め分かっていれば，マニュアル作業による初期点設定の手間を大幅に削減できる可能性がある．そこで本研究では，X 線透視画像上の大腿骨に対する膝蓋骨の方向（角度）を予め機械学習により学習させ，対象となる膝蓋骨の方向を自動的に検出することを試みた．機械学習には，SVM，ランダムフォレスト，CNN を用い，性能評価を行った結果，各手法において比較的高い成功率で膝蓋骨の方向を検出できることが分かった．

キーワード：膝蓋骨，方向検出，SVM，ランダムフォレスト，CNN

1. はじめに

整形外科領域において，膝関節の 3 次元的な運動情報を正確かつ定量的に把握することは，様々な関節疾患の診断・治療や手術計画などを行う上で非常に重要である．これまで，我々は，1 方向 X 線透視画像を用いた 2D/3D レジストレーションに基づく膝関節 3 次元運動計測法を提案し[1]，その全自動化に向けて現在様々な要素技術の開発を行っている．その一つとして，2 次元 X 線透視画像上の膝関節部位（大腿骨，脛/腓骨，膝蓋骨）の方向（相対的な角度）を予め把握しておくことは重要である．特に，大腿骨，脛/腓骨に比べ，骨自身の大きさが小さく形状特徴の少ない膝蓋骨（図 1）は，レジストレーションが不安定であるため，レジストレーション実行前にできるだけ膝蓋骨の初期点（位置と姿勢）を膝蓋

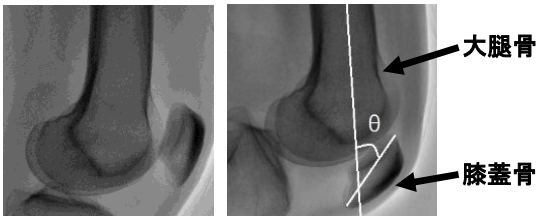

図 1 膝関節 X 線透視画像（左：原画像，右：大腿骨に対する膝蓋骨の角度の定義）．

*1 埼玉工業大学工学部情報システム学科
〔〒369-0293 埼玉県深谷市普済寺 1690〕
e-mail: {j5147hvo, yamazaki}@ sit.ac.jp
*2 大阪大学大学院医学系研究科運動器バイオマテリアル学
*3 東京大学大学院医学系研究科整形外科学
*4 奈良先端科学技術大学院大学情報科学研究科

骨シルエットに対して近づけておく必要がある．従来はこの初期点の設定を，マニュアル作業によって丁寧に行っていたため，膨大な X 線画像に対して処理が行われることから，多大な労力となり解析者の負担となっていた．

一方で，大腿骨，脛/腓骨に対しては，比較的安定した（自動的な）レジストレーション結果がこれまで得られている．そこで本研究では，2 次元 X 線透視画像上の“大腿骨に対する膝蓋骨の方向（角度）”を予め機械学習により学習させておき，生成した識別器を用いて対象となる膝蓋骨の方向（大まかな初期姿勢）を自動的に検出することを目的とする．機械学習法としては，今回，SVM（Support Vector Machine），ランダムフォレスト，および CNN（Convolutional Neural Network）の 3 つの手法を用いて性能評価を行い，その有効性を調査する．

2. 方法

本研究では，膝 X 線透視画像に対して前処理を行わず，個々の画素値をそのまま特徴量として機械学習し，識別器を生成する．以下，使用した機械学習法[2-4]について簡単に述べる．

1）SVM

教師あり学習の一つで，2 クラス識別器の代表的な手法である．識別関数 $f(x)$は，以下のように表すことができる．

$$f(x) = sgn\left(\sum_{i=1}^{m}\left(w_i K(x, x_i)\right) + b\right) \qquad (1)$$

ここで，x は d 次元の特徴量，x_i はサポートベクタ，K はカーネル関数，w が識別境界となる超平面の重みベクトル，b はバイアス項（閾値）である．実際に角度識別を行う際は，予め一定範囲の角度で分割された多くの学習データ用いて識別器を生成し（w と b を求め），生成した識別器を用いて角度の検出を行う．

2）ランダムフォレスト

複数の決定木構造を持った多クラス識別器を構築するアンサンブル学習アルゴリズムである．実際には，予め一定範囲の角度で分割された学習データからランダムサンプリングにより作成したサブセットごとに決定木を構築し，複数の決定木の結果を統合して角度識別を行う．

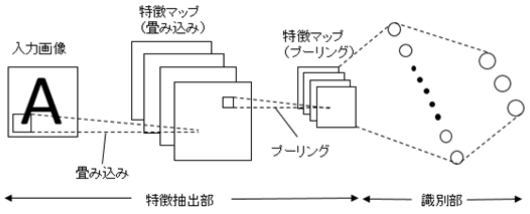

図 2 CNN の構成．

3）CNN

通常のニューラルネットワークとは違い，全結合層だけでなく，畳み込み層とプーリング層から構成されるニューラルネットワークである（図 2）．畳み込み層は，空間的（3 次元的）な情報を維持し，この層では入力画像に対して各フィルタとの畳み込み演算が行われ，特徴マップが生成される．プーリング層は，畳み込み層の後に適用される層であり，入力データを扱いやすい形に変形(情報圧縮)するために用いられる．Max Pooling や Average Pooling などがある．

3. 実験および結果

膝蓋骨の方向（大腿骨に対する膝蓋骨の角度）検出を行うために，実際の膝 X 線透視画像，計 235 枚を用いて SVM，ランダムフォレスト，CNN による性能評価を行った．本研究では，膝 X 線透視画像に対してそれぞれ大腿骨に対する膝蓋骨の方向（角度）θ を 15° ごとに分割し，対応する角度範囲の画像に振り分けた．すなわち，θ＜0° ，0≦θ＜15° ，15≦θ＜30° ，30≦θ＜45° ，45≦θ＜60° ，60≦θ＜75° ，75≦θ＜90° ，90° ≦θ の計 8 パターンの範囲の角度を検出対象とした．膝蓋骨の方向は，図 1 右に示すように膝蓋骨の上・下端を結んだ線と，大腿骨体に対して平

表 1 各手法による膝蓋骨方向検出の成功率.

機械学習法	成功率（%）
SVM	91.4
ランダムフォレスト	85.1
CNN	80.8

行に引いた線が交差する角度 θ を定義して用いた．また，各機械学習法において，SVM のカーネル関数 K には線形カーネルを使用し，ランダムフォレストの決定木の数は 10 本とした．CNN では，畳み込み層に対して，フィルタサイズは 5×5, フィルタ数は 8 を適用し，プーリングには Max Pooling を使用した．畳み込み層からプーリング層までの階層数は 2 とした．

各機械学習法の性能評価実験では，今回，使用画像全体の 80%を学習用画像に用い，残りの 20%を評価用画像として調査を行った．結果は，テストデータがラベル付けされた角度に分類できたものを成功，分類できなかったものを失敗として成功率（%）として表記した．各手法による成功率を表 1 に示す．

4. 考察およびまとめ

本研究では，機械学習に基づく X 線透視画像からの膝蓋骨方向検出に関する初期検討を行った．各機械学習法（SVM，ランダムフォレスト，CNN）において比較的高い成功率で膝蓋骨の方向を検出できることが分かったが，手法により精度のばらつきが見られた．

本実験では今回, SVM を用いた場合に最も高い成功率で膝蓋骨の方向を検出できたが，一方でランダムフォレストや CNN を用いた場合にのみ検出可能な例も一部見られた．この原因としては各手法のパラメータが影響していると考えられるが，今後はデータセットをさらに増加し，様々な条件下で詳細に検討を行う必要がある．しかしながら，1 方向 X 線透視画像を用いた膝関節 3 次元運動計測の全自動化のための要素技術として，本手法は十分に有効な手段に成り得る可能性があると考えられる．

文　献

［1］　林佑一，山崎隆治，冨田哲也，河野賢一，佐藤嘉伸，菅本一臣：濃度ベース 2D/3D レジストレーションを用いた 1 方向 X 線画像からの膝蓋骨位置・姿勢推定に関する基礎検討．電子情報通信学会技術研究報告 **116** : 71-76, 2017

［2］　Andreas C. Muller, Sarah Guido : Python ではじめる機械学習．オライリージャパン，2017

［3］　新納浩幸 : Chainer v2 による実践深層学習．オーム社，2017

［4］　SONY Neural Network Console: https://dl.sony.com/ja/

Basic Study for Orientation Detection of Patella from X-ray Fluoroscopic Image Using Machine Learning

Hiroki HAYASHIDA[*1], Takaharu YAMAZAKI[*1], Mikito TAJIMA[*1], Tetsuya TOMITA[*2], Kenichi KONO[*3], Yoshinobu SATO[*4], Kazuomi SUGAMOTO[*2]

*1 Department of Information Systems, Saitama Institute of Technology

*2 Division of Orthopaedic Biomaterial Science, Osaka University Graduate School of Medicine

*3 Department of Orthopaedic Surgery, Graduate School of Medicine, The University of Tokyo

*4 Graduate School of Information Science, Nara Institute of Science and Technology

We have developed some elemental techniques for full automation of 3D knee kinematic measurement based-on 2D/3D registration using a single-plane fluoroscopic image. As one of them, to preliminarily estimate orientation between knee joint silhouettes on 2D X-ray fluoroscopic image is very important. In particular, accurate initial orientation estimation of patella with respect to femur provides stable 2D/3D registration process and reduces time-consuming and labor-intensive manual operations in some process. In this study, therefore, we present an orientation detection method of patella from X-ray fluoroscopic image using machine learning, which SVM, Random forest and CNN are utilized. As results of performance evaluation using these machine learnings, orientation detection of patella was successfully performed, and possibility for full automation of 3D knee kinematic measurement was suggested.

Key words: Patella, Orientation detection, SVM, Random forest, CNN

胃の変形情報を利用した
経時リンパ節の自動対応付け手法の精度向上に関する研究

舘　高基[*1]　小田　昌宏[*1]　林　雄一郎[*1]　中村　嘉彦[*2]

北坂　孝幸[*3]　三澤　一成[*4]　森　健策[*1 *5 *6]

要旨

本稿では，胃の変形情報を利用した経時リンパ節の自動対応付け手法について報告する．がんの進行度及び治療の有効性を確認する際には，リンパ節の経時変化が観察される．この際，医師により目視でリンパ節の対応付けが行われるが，この作業は煩雑かつ定量性に欠けるため，自動対応付け手法の開発が望まれている．経時リンパ節の自動対応付け手法には濃度値情報を利用した非剛体位置合わせが多く用いられるが，濃度値情報には小構造物の位置の変位を解析する上で不要な情報が多く，リンパ節の変位を正確に捉えることが出来ずに対応付けに失敗する可能性がある．そこで本手法では，CT 像から抽出した胃表面の変形を解析し，その変形場を利用して対応付けを行う．胃領域は点群として表現し，変形場は ICP，TPS-RPM を利用して算出した．実験は 11 組の経時症例から抽出したリンパ節画像を対象に行い，リンパ節の組全ての内正しく対応付けを行うことが出来た組の割合で評価を行った．全体での正解率は 78.1%であった．

キーワード：リンパ節，経時変化，ICP，TPS-RPM

1. はじめに

がんの進行度合いや治療の有効性を確認する際にはがんの発生した部位近くのリンパ節の経時変化観察が重要である．しかし，目視での経時画像間でのリンパ節対応付けは煩雑であるため，自動対応付け手法の開発は外科手術支援において有用である．経時画像間でのリンパ節の自動対応付け手法には主に濃度値情報による非剛体位置合わせ [1]が利用されるが，濃度値情報では腹部臓器の形状の変化を正確に捉えることが出来ず対応付けに失敗する可能性がある．そこで本稿では，抽出した胃領域の形状変化を利用してリンパ節の変位を解析し、腹部 CT 像内のリンパ節の対応付けを行う手法を検討したため報告する．

2. 手法

本手法では，胃の点群画像を利用して変形を解析した．胃の変形は，点群間の位置合わせ手法である ICP [2]，TPS-RPM [3]を利用して，一方の CT 像の胃領域をもう一方の CT 像の胃領域へと変形して位置合わせすることにより解析した．その後に，獲得した変形場をリンパ節領域に対しても適用することにより，胃の変形によるリンパ節の移動の解析を行った. このようにして移動したリンパ節と，位置合わせの基準となった CT 像側のリンパ節を重ね合わせ，距離が最も近いリンパ節を対応関係とした．

*1 名古屋大学大学院情報学研究科
〔〒464-8601　名古屋市千種区不老町〕
e-mail: ktachi@mori.m.is.nagoya-u.ac.jp
*2 苫小牧工業高等専門学校
*3 愛知工業大学情報科学部
*4 愛知県がんセンター中央病院
*5 名古屋大学情報基盤センター
*6 国立情報学研究所医療ビッグデータ研究センター

3. 実験

腹部造影 CT 像 18 枚からなる経時症例 11 組を用いて実験を行った．CT 像の仕様は，画像サイズが 512×512×488-982 画素，画素解像度が 0.645-0.822mm，スライス厚が 0.500-0.801mm となっている．また，各経時症例の撮影間隔は約 2 ヶ月であり，同一患者から 2 回のみ撮影された症例が 4 例，3 回撮影された症例が 2 例, 4 回撮影された症例が 1 例となっている．これらの CT 像から手動で抽出したリンパ節，胃領域を入力とした．出力は画像間での対応するリンパ節の組であり，その正解率は 78.1%であった．提案手法によるリンパ節の移動を図 1 に示す．

4. 考察

本手法では，腹部領域の経時リンパ節に対して胃の変形情報を適用することで，78.1%の正解率で対応付けを行うことが出来た．ここで，濃度値情報による非剛体位置合わせ[1]を利用した際の正解率は 69.0%であり，9%ほど精度の向上が確認された．しかし，従来手法よりも精度が悪化した症例も確認された．これは，図 2 に示すように画像間での胃の形状が大きく変形している一方でリンパ節の位置がほぼ変化しておらず，胃の変形のみを考慮した本手法では正しくリンパ節の変位を捉えられなかったことが原因であると考えられる．このため，より詳細に腹部領域の変化を捉えられるように，胃以外の臓器の変形情報を利用してより詳細な変形場を構築する必要があると考えられる．

5. まとめ

本稿では，胃の変形情報を利用した経時リンパ節の自動対応付けについて報告した．精度は 78.1%であり，濃度値情報による非剛体位置合わせを利用した従来手法より良好な精度で対応付けを行うことが出来た．今後の課題としては，より腹部領域の変形を詳細に捉えられるよう，胃以外の変形情報を利用することが挙げられる．

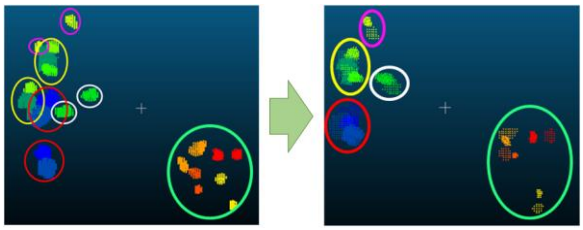

図 1　経時画像上のリンパ節領域を重ねて表示した図．左側が提案手法適用前，右が適用後である．対応関係にある同色のリンパ節が大きく接近している．

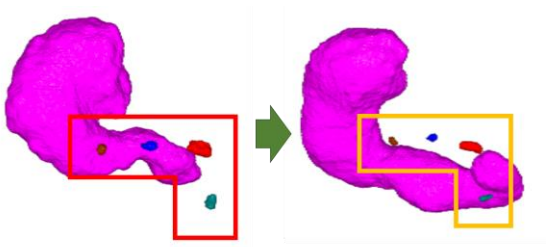

図 2　経時画像上の胃とリンパ節．胃領域(桃色)部分は大きく変形している一方で，矩形で囲んだリンパ節領域はほぼ変位していないことが確認できる．

謝辞　日頃から熱心にご討論いただく名古屋大学森研究室の諸氏に深く感謝する．本研究の一部は，JSPS 科研費 26108006，17H00867，JSPS 二国間交流事業によった．

利益相反の有無　なし．

文　献

［1］　中村嘉彦，他：3 次元腹部 X 線 CT 像からの経時リンパ節の自動検出精度の検討．電子情報通信学会技術研究報告，MI **116**：39-42, 2016

［2］　Besl. P. J, et al : A method for registration of 3-D shapes. IEEE Transactions on Pattern Analysis and Machine Intelligence **14**：239-256, 1992

［3］　Chui. H, et al : A new point matching algorithm for non-rigid registration. Computer Vision and Image Understanding **89**：114-141, 2003

Automatic Lymph Nodes Matching in Follow-up CT Volumes using Stomach Deformation

Kouki TACHI[*1], Masahiro ODA[*1], Yuichiro HAYASHI[*1], Yoshihiko NAKAMURA[*2]
Takayuki KITASAKA [*3], Kazunari MISAWA[*4], Kensaku MORI[*1 *5 *6]

*1 Graduate School of Informatics, Nagoya University
*2 National Institute of Technology, Tomakomai College
*3 Faculty of Information Science, Aichi Institute of Technology
*4 Aichi Cancer Center Hospital
*5 Information Technology Center, Nagoya University
*6 Research Center for Medical Bigdata, National Institute of Informatics

In this paper, we report an automated matching method of follow-up lymph nodes using stomach deformation. Observing follow-up lymph nodes is important to check cancer stages or treatment evaluation. For observing temporal change of the lymph nodes, surgeons try to find corresponding lymph nodes on follow-up CT volumes. However, this work is complicated and time consuming. Therefore, an automatic corresponding lymph nodes matching method is required. Non-rigid registration based on intensity information is often used for automatic matching of follow-up lymph nodes. However, intensity contains useless information for analyzing changes in the position of lymph nodes, and this causes incorrect matching of lymph nodes. Therefore, we propose an automatic matching method of follow-up lymph nodes using deformation of the stomach surface. We analyze the changes in the position of lymph nodes based on stomach deformation. Stomachs are represented as point clouds, and we calculate deformation field by using the ICP and TPS-RPM. Experiments were performed on lymph nodes extracted from 11 pairs of follow-up CT volumes. The accuracy of the proposed method was 78.1%.

Key words: lymph node, temporal change, ICP, TPS-RPM

Demonsアルゴリズムの一般化とその応用

増谷　佳孝[*1]　石田　善喜[*2]

要旨

Demons アルゴリズムは２つの画像の信号差や勾配に基づく可変形画像レジストレーションの古典的な一手法であるが，基本的に同一のモダリティかつ各画素が単一の値をもつスカラ画像間での使用に限定されている．本研究では，信号差や勾配を２つの画像の局所特徴間の距離で置き換えることで，様々な画像間のレジストレーションが可能となることを示す．例えば，カラー画像では画素間の色距離，スカラ画像の場合も局所領域の複数の画素値を使用して２つの画像の局所領域間の距離を定義して用いる．３次元のカラー画像ファントムおよび拡散テンソル画像を用いたレジストレーション実験の例により，その特性や有効性・拡張性について検証した結果を報告する．

キーワード：画像レジストレーション，Demons アルゴリズム，拡散テンソル画像

1. はじめに

Demons アルゴリズム[1]は Thirion らにより提案された可変形画像レジストレーション[2]の古典的一手法であり，２つの画像の同位置における信号差や勾配に基づき，一方の画像を変形させる変位ベクトルを発生させる．その後，微分同相写像[3]の導入による変形の効率化や正則化など，様々な拡張がなされてきたが同一のモダリティかつ各画素が単一の値をもつスカラ画像間での使用に限定されていた．そこで Modat ら[4]は，Demons アルゴリズムにおける信号値の勾配を正規化相互情報の勾配で置換し，異なるモダリティ間の Demons アルゴリズムを提案した．本研究ではこれをさらに一般化し，Demons アルゴリズム中で使用される信号差を２つの画像の局所特徴間の距離と捉え，様々な距離で置き換えることで多様な画像間のレジストレーションが可能となることを示す．局所特徴の例として，本研究ではカラー画像での画素間の色距離の例などを示す．また実験ではカラー画像ファントムおよび拡散テンソル画像[5]より計算される拡散テンソルカラーマップのボリュームデータを用いた３次元画像レジストレーションについて，他の手法との比較によりその特性や有効性・拡張性について検証した結果を示す．

*1 広島市立大学大学院 情報科学研究科
〔〒731-3194 広島市安佐南区大塚東 3-4-1〕
e-mail: masutani@hiroshima-cu.ac.jp
*2 広島市立大学 情報科学部
投稿受付：

2. 方法

Demons アルゴリズムによる画像レジストレーションにおいて，固定される参照画像，変形により更新される画像を浮動画像とする．位置$\mathbf{x}$における参照画像の信号値を$R(\mathbf{x}_c)$，浮動画像の時刻tにおける浮動画像の信号値を$F(\mathbf{x}_c, t)$とすると，浮動画像に対して同時刻，同位置において発生する変位ベクトル$\mathbf{u}(\mathbf{x}_c, t)$は，以下の式で表される．

$$\mathbf{u}(\mathbf{x}_c, t) = \frac{F(\mathbf{x}_c, t) - R(\mathbf{x}_c)}{|\nabla R|^2 + \left(F(\mathbf{x}_c, t) - R(\mathbf{x}_c)\right)^2}(\nabla R) \quad (1)$$

ただし，∇Rは$\mathbf{x}_c$における参照画像の空間微分による勾配ベクトルで，

$$\nabla R = \left.\frac{\partial R}{\partial \mathbf{x}}\right|_{\mathbf{x}=\mathbf{x}_c} \tag{2}$$

である．また，浮動画像の勾配を使用する方法での変位ベクトルは，

$$\mathbf{u}(\mathbf{x}_c, t) = \frac{F(\mathbf{x}_c, t) - R(\mathbf{x}_c)}{|\nabla F|^2 + \left(F(\mathbf{x}_c, t) - R(\mathbf{x}_c)\right)^2}(\nabla F) \tag{3}$$

であり，(2)と同様に

$$\nabla F = \left.\frac{\partial F}{\partial \mathbf{x}}\right|_{\mathbf{x}=\mathbf{x}_c} \tag{4}$$

である．両者は，発生させる変位ベクトルが常に参照画像の勾配方向に固定されるか，浮動画像の変形に伴って動的に変化するかの違いがあるが，どちらも同位置における両画像の画素値の差が小さくなるよう変形が繰り返され，勾配法を用いた最適化の過程と考えることができる[6].

ここで，上記の式(1)および (3)に含まれる信号差$(F-R)$は，$\mathbf{x}_c$における両画像の局所特徴間の距離の最も単純な指標を表していると考えることができる．ただし，$(F-R)$のままでは負の距離が得られるので，両者が一致するときに 0 となりそれ以外は正の値をとる以下の距離を時刻tにおいて定義する．

$$\begin{aligned} d(\mathbf{x}_R, \mathbf{x}_F, t) &= |F(\mathbf{x}_R, t) - R(\mathbf{x}_F)| \\ &= \begin{cases} F(\mathbf{x}_F, t) - R(\mathbf{x}_R) & (R \le F) \\ R(\mathbf{x}_R) - F(\mathbf{x}_F, t) & (R > F) \end{cases} \end{aligned} \tag{5}$$

式(5)は，参照画像と距離画像で異なる位置の局所特徴の距離に対しても定義可能である点が重要である．次に，この距離の位置$\mathbf{x}_c$における空間微分を考えるが，参照画像の局所特徴である信号値を取得する位置$\mathbf{x}_R$は$\mathbf{x}_c$に固定する．すなわち，

$$\left.\frac{\partial d}{\partial \mathbf{x}_F}\right|_{\mathbf{x}_F=\mathbf{x}_c} = \left.\frac{\partial}{\partial \mathbf{x}_F}|F(\mathbf{x}_F, t) - R(\mathbf{x}_C)|\right|_{\mathbf{x}_F=\mathbf{x}_c} \tag{6}$$

とする．このとき参照画像の信号値は$\mathbf{x}_F$に関して不変であるので式(5)より，

$$\left.\frac{\partial d}{\partial \mathbf{x}_F}\right|_{\mathbf{x}_F=\mathbf{x}_c} = \begin{cases} \left.\dfrac{\partial F}{\partial \mathbf{x}_F}\right|_{\mathbf{x}_F=\mathbf{x}_c} & (R \le F) \\ -\left.\dfrac{\partial F}{\partial \mathbf{x}_F}\right|_{\mathbf{x}_F=\mathbf{x}_c} & (R > F) \end{cases} \tag{7}$$

である．したがって，FとRの大小関係に関わらず以下が成り立つ．

$$d(\mathbf{x}_c, \mathbf{x}_c, t)(\nabla_F d) = (F(\mathbf{x}_c, t) - R(\mathbf{x}_c))\left.\frac{\partial F}{\partial \mathbf{x}}\right|_{\mathbf{x}=\mathbf{x}_c} \tag{8}$$

ただし，

$$\nabla_F d = \left.\frac{\partial d}{\partial \mathbf{x}_F}\right|_{\mathbf{x}_F=\mathbf{x}_c} \tag{9}$$

である．式(8)の右辺は式(3)の一部に相当し，該当部分を式(8)の左辺および式(9)で置き換えることにより，両画像の局所特徴間の距離に基づく一般化された Demons アルゴリズムが得られる．このとき変位ベクトルは以下のようになる．

$$\mathbf{u}(\mathbf{x}_c, t) = \frac{d(\mathbf{x}_c, \mathbf{x}_c, t)}{|\nabla_F d|^2 + d(\mathbf{x}_c, \mathbf{x}_c, t)^2}(\nabla_F d) \tag{10}$$

ただしdは式(5)の例に限らず時刻tにおける両画像の異なる位置の局所特徴間の距離で，

$$d = d(\mathbf{x}_R, \mathbf{x}_F, t) \ge 0 \tag{11}$$

となる任意のものでよい．既に示したようにdの最も単純な表現が式(5)の両画像の画素値の差分絶対値であり，浮動画像の勾配を用いる式(3)と一致する．

その他の距離として，３つの色成分を持つカラー画像に対しては以下のように定義できる．

$$d(\mathbf{x}_R, \mathbf{x}_F, t) = \sqrt{\begin{aligned} &\left(r_R(\mathbf{x}_R) - r_F(\mathbf{x}_F, t)\right)^2 \\ &+\left(g_R(\mathbf{x}_R) - g_F(\mathbf{x}_F, t)\right)^2 \\ &+\left(b_R(\mathbf{x}_R) - b_F(\mathbf{x}_F, t)\right)^2 \end{aligned}} \tag{12}$$

但し，r_R，g_R，b_R，r_F，g_F，b_Fは参照画像および浮動画像の RGB 成分である．同様に，ベクトルやテンソルのように各画素位置で

複数の属性を持つような画像でも定義できる．一方，単一の属性を持つ濃淡画像であっても，周辺位置の画素値を用いることにより複数の属性の局所特徴となり，以下のような距離が定義できる．

$$d(\mathbf{x}_R, \mathbf{x}_F, t) = \sqrt{\sum_{\mathbf{dx}\in\mathbf{\Omega}} \left(R(\mathbf{x}_R + \mathbf{dx}) - F(\mathbf{x}_F + \mathbf{dx}, t)\right)^2} \tag{13}$$

ただし，$\mathbf{\Omega}$は近傍を定義するベクトル集合である．さらに，異なるモダリティの画像間の場合は正規化相互情報[4]を用いた距離，あるいは同種の画像でも両画像の信号値にバイアスやスケールの差異が存在する場合は正規化相互相関を用いた距離が定義できる．ただし，これらの指標は領域間の信号値群の類似度であるため，逆数などを用いた距離表現への変換が必要である．

本稿ではカラー画像を対象とし，次節で拡散テンソルカラーマップ[5]を用いた実験結果を示す．拡散テンソルカラーマップは拡散 MRI データの 2 階テンソル近似に基づき，脳白質線維などの線維方向を色で示したもので，通常のカラー画像と同様に RGB 成分を持つほか，拡散異方性を表す Fractional Anisotropy (FA)値[5]をアルファ(A)成分として追加した 4 つの RGBA 色成分を持つ場合が多い．図 1 に拡散テンソルカラーマップと FA 画像の例を示す．

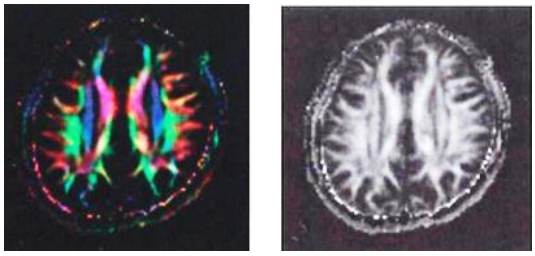

図 1 拡散テンソルカラーマップ（左）および FA 画像（右）．

脳白質線維の線維方向は拡散テンソルの最大固有値に対応した固有ベクトル$\mathbf{e}_1$で近似されるため，拡散テンソルカラーマップの色成分は次式で表される．

$$\begin{pmatrix} R \\ G \\ B \\ A \end{pmatrix} = FA \begin{pmatrix} |x_1| \\ |y_1| \\ |z_1| \\ 1 \end{pmatrix} \tag{14}$$

x_1，y_1，z_1はそれぞれ$\mathbf{e}_1$のxyz成分で，FAは 0~1 の値をとる FA 値で以下の式で表される．

$$FA = \sqrt{\frac{3}{2} \cdot \frac{(\lambda_1 - \lambda_M)^2 + (\lambda_2 - \lambda_M)^2 + (\lambda_3 - \lambda_M)^2}{{\lambda_1}^2 + {\lambda_2}^2 + {\lambda_3}^2}} \tag{15}$$

λ_1，λ_2，λ_3は拡散テンソルの固有値を降順に並べたものでλ_Mは 3 つの平均である．拡散テンソルカラーマップを一般化された Demons アルゴリズムでレジストレーションする場合には，式(11)を拡張しアルファ成分を加えた式(14)の色表現の距離を使用する．また，色距離の浮動画像座標に関する偏微分は，一般に用いられる画像の勾配計算と同様，中心差分による近似で求めた．

3. 結果

本研究では，色距離に基づく提案手法の基本的性質を明らかにするため，拡散テンソルカラーマップと同様に 4 つの色成分を持つ合成画像も作成して実験を行った．

また，実験では提案手法を含む以下の 4 つの方法による結果を比較する

方法 1 ：RGBA4 成分による色距離を用いた提案手法

方法 2 : 参照画像および浮動画像の色成分を平均して濃淡画像とし，従来の Demons アルゴリズムを用いて変位ベクトルを得る方法

方法 3 : 各色成分で独立に従来の Demons アルゴリズムを適用する方法

方法 4 : 色成分ごとに従来の Demons アルゴリズムより得た変位ベクトルの平均を用いる方法

ここで，方法 3 では各色成分を独立にレジストレーションするため，2 つのカラー画像間の写像が色成分の数である 4 種類決定されることになる．医用画像をはじめとする 2 つの画像間の一意の対応付けが重要な意味

を持つ場合には不適切ではあるが，後述するレジストレーションの指標である色距離の推移の観察時に誤差としての色距離の下限を示すものとして比較のため用いた．

1） 合成画像での結果

Shepp–Logan ファントム[7]を模したカラーのボリュームデータを作成し，内部の配置を変更して参照画像と浮動画像を作成した（図２）．マトリクスサイズは 128×128×128 で各色成分は 8 ビットの深度を持ち，内部および外郭の形状は球および楕円体である．また，拡散テンソルカラーマップと同様にアルファチャンネルを持つがファントム内部で均一とした．これらに対し，画像レジストレーションを 4 つの方法で行った結果を図３に示す．なお，本実験では画像の変形を 100 回の固定回数で行った．

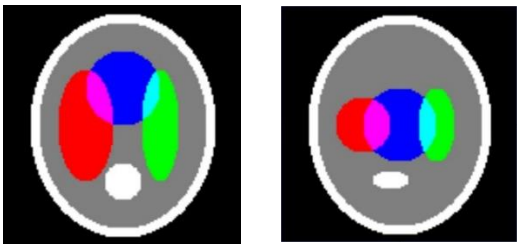

図 2 実験用カラーボリュームデータ（左：参照画像，右：浮動画像）．

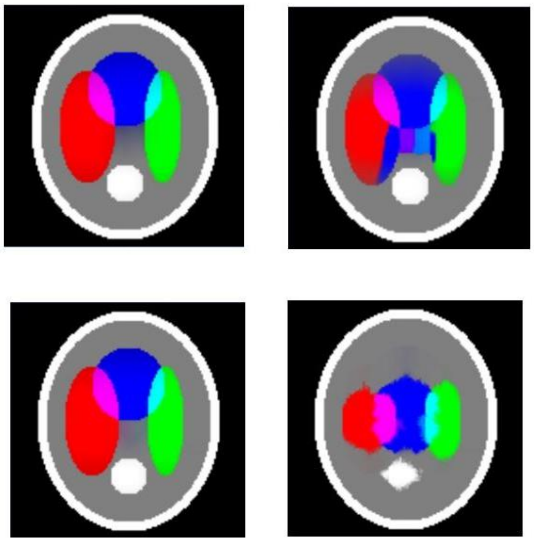

図 3 画像レジストレーション結果（左上:方法１，右上：同２，左下：同 3，右下：同４）．

方法２および４ではレジストレーションに失敗しているが，方法１と方法３では参照画像に近い結果を得ている．提案した方法１では，青色の領域の下部の灰色領域に信号の低下が見られたものの参照画像に近い画像を得た．この信号低下は，画像変形時の画素値補間に基づくものであることが確認された．一方，方法３で比較した 4 手法の中で最も参照画像に近い結果を得たが，先に述べた通り各色成分を独立にレジストレーションしたためである．また，これらの方法について画像全体での平均および最大の色距離の推移を図４に示す．

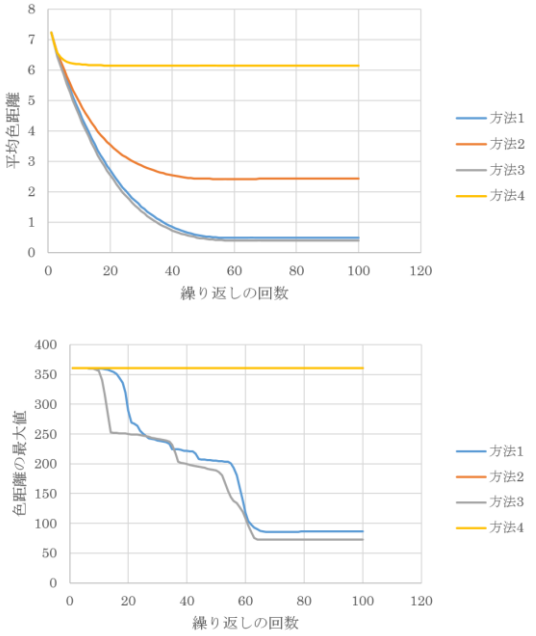

図 4 レジストレーション過程における色距離の推移（上：画像全体の色距離平均，下：同最大値）方法 2 と 4 は重なっている．

この結果でも方法３が方法１より小さい色距離を得ている．

2） 拡散テンソルカラーマップでの結果

異なる２例の拡散テンソルカラーマップのボリュームデータ（図５）を使用した．マトリクスサイズは 128×128×80 で，それぞれ年齢が 20 代～30 代の正常ボランティアである．結果および画像全体の色距離の平均と最大値の推移を図６および図７に示す．

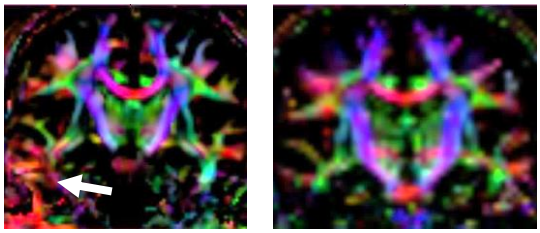

図 5 異なる 2 例の拡散テンソルカラーマップの冠状断面（左：参照画像，右：浮動画像）.

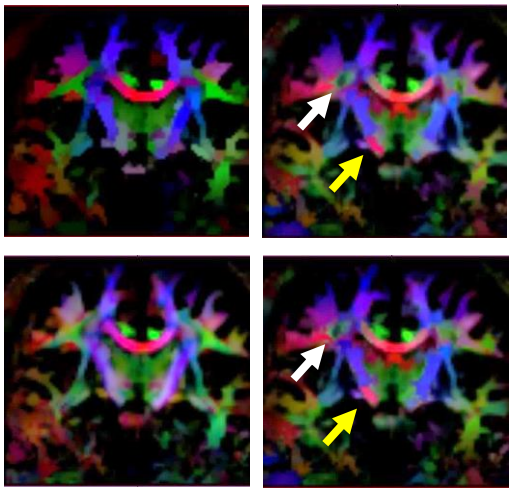

図 6 画像レジストレーション結果（左上：方法 1，右上：同 2，左下：同 3，右下：同 4）.

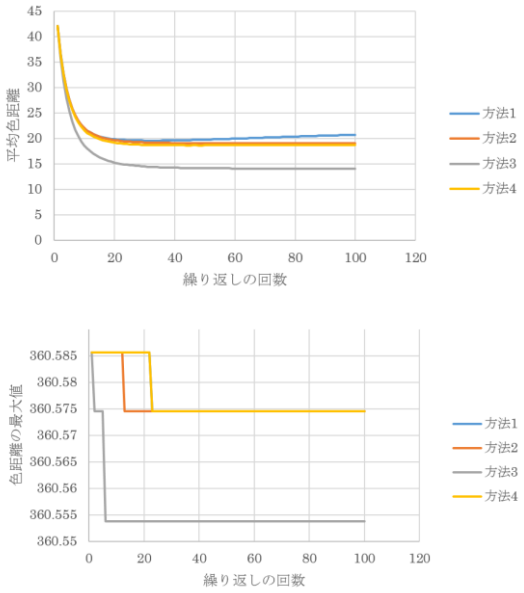

図 7 画像レジストレーション過程における色距離の推移（上：画像全体の色距離平均，下：同最大値）方法 1 と 4 および方法 2 の一部は重なっている.

方法 2 と方法 4 では，脳内で前後方向に走行し拡散テンソルカラーマップでは緑の成分が最も高く表示される上縦束がほぼ消失している（図 6 の白色矢印）．さらに，頭尾方向に走行し青の色成分が最も高い皮質脊髄路の一部（同黄色矢印）で赤の色成分が最も大きくなっている．以上の結果からレジストレーションに失敗しているといえる．一方，提案手法である方法 1 では良好な結果を得ている．また，合成画像と同様に方法 3 が最も参照画像に近い画像を得ているが，先に述べた通り異なる患者間の画像レジストレーションにおいて局所間の一意の対応関係を得るという目的では使用できない．

画像全体の平均色距離の推移については，合成画像での結果と類似しているが，提案手法では 30 回の繰り返し後に僅かながら上昇する現象が見られた．これは主に参照画像にのみ含まれる脳白質以外のアーチファクトの領域（図 5 の白矢印）などが原因であることがわかった．また，色距離の最大値については，どの手法でも変動は小さく差異は観察されなかった．

4. 考察

本研究で示した Demons アルゴリズムの一般化は，Modat ら[4]が示した大域的な正規化相互情報の勾配に基づく Demons アルゴリズムをさらに一般化したものであると考えられる．また，本稿で示したのは Demons アルゴリズムの最も根幹である部分の変位ベクトル計算部分の一般化であり，これまでに報告のある微分同相写像[3]や正則化[8]などの導入と矛盾しない．よって，今後様々な発展が期待できる．

本稿では，その一例として拡散テンソルカラーマップなどのカラー画像のレジストレーションによりその有効性を示した．拡散テンソルカラーマップのレジストレーションは色成分が白質線維の方向を示しており，厳密には画像変形ごとに方向の補正[9]を行う必要があり，アーチファクトなど一方の画像

にしか存在しない領域への対処と同様, 今後の課題である.

5. おわりに

本研究では, 可変形画像レジストレーションの古典的一手法である Demons アルゴリズムで使用されている変位ベクトル計算において, 単純な信号差を局所特徴間の距離で置換できることを示し, 拡散テンソルカラーマップなどのカラー画像レジストレーションの例を示した. 今後様々な画像に対しての実験により, 提案手法のさらなる有効性の検証や発展を目指す.

謝辞

本研究は広島市立大学情報科学部医用情報科学科平成 29 年度卒業論文の一部である. 日頃より活発な議論を頂く広島市立大学医用情報科学科・専攻の皆様に感謝します. 本研究は新学術領域「多元計算解剖学」, および CREST 「現代の数理科学と連携するモデリング手法の構築」の助成を受けたものです.

利益相反の有無

なし

文　献

［1］ J. P. Thirion, “Image matching as a diffusion process: an analogy with Maxwell's demons”, Medical Image Analysis, vol.2, no.3, pp.243-260, 1998

［2］ A. Sotiras, C. Davatzikos, and N. Paragios, Deformable Medical Image Registration: A Survey, IEEE trans. Med. Img. vol.32, no.7, pp.1153-1190, 2013

［3］ T. Vercauteren, X. Pennec, X, A. Perchant, and N. Ayache, Diffeomorphic demons: Efficient nonparametric image registration, Neuroimage 45, S61–S72, 2009

［4］ M. Modat, T. Vercauteren, GR. Ridgway, DJ. Hawkes, NC. Fox, S. Ourselin, Diffeomorphic Demons using Normalised Mutual Information, Evaluation on Multi-Modal Brain MR Images, Proc. SPIE Med. Img. 2010: Img. Proc.; vol.7623, pp. 76232K/1-76232K/4, 2010

［5］ 青木茂樹，安部修，増谷佳孝，高原太郎“これでわかる拡散 MRI 第 3 版”，秀潤社，2013

［6］ X. Pennec, P. Cachier, N. Ayache, Understanding the Demon's Algorithm: 3D Non-Rigid registration by Gradient Descent, proc. Int. Conf. on Med. Img. Comp. and Comp.-Assist. Intervention 1999, LNCS1679, pp.597-605, 1999

［7］ LA. Shepp, BF. Logan, The Fourier Reconstruction of a Head Section, IEEE trans. Nucl. Sci. vol.21, no.3, pp.21–43, 1974

［8］ D. Demirovic，A. Serifovic-Trblic，N. Prljaca，Ph. C. Cattin，Bilateral filter regularized accelerated Demons for improved discontinuity preserving registration , Computerized Medical Imaging and Graphics，vol. 40，pp.94-99, 2015

［9］ DC. Alexander, C. Pierpaol, PJ. Basser PJ, JC. Gee, Spatial transformations of diffusion tensor magnetic resonance images, IEEE trans. Med. Img. vol.20, no.11, pp.1131-1139, 2001

Generalizing Demons Algorithm and its Application

Yoshitaka MASUTANI [*1], Yoshiki ISHIDA[*2]

*1 Hiroshima City University Graduate School of Information Sciences

*2 Hiroshima City University

The Demons algorithm is known as one of the classical methods for deformable image registration based on signal value difference and signal gradient, and its use is basically limited to for monomodal and scalar images. In this study, we show that the signal value difference and signal gradient used in the algorithm can be replaced with generalized distance between local features of two images and its gradient, such as color distances of color images. Through the experiments by using volume data sets of synthetic color images and diffusion tensor colormap images, we validate the proposed method and discussion its characteristics.

Key words: image registration, demons algorithm, diffusion tensor image

著者紹介

増谷　佳孝（ますたに　よしたか）
1991 年東大・工・精密機械工学科卒. 1994 年同大大学院・工学系・精密機械工学専攻修士課程, 1997 年同博士課程了. ハンブルク大医用数学・情報処理研究所, シカゴ大病院放射線科, 東大病院放射線科などを経て 2018 年現在, 広島市立大学大学院医用情報科学専攻・教授. 2003 年日本医用画像工学会論文賞および奨励賞受賞. 博士（工学）・博士（医学）. 拡散 MRI を中心とした多次元の医用画像解析の研究に従事. 医用画像工学会, 電子情報通信学会, 磁気共鳴医学会, IEEE など, 各会員.

石田　善喜（いしだ　よしき）
2017 年広島市立大学情報科学部医用情報科学科卒.

Construction of multimodal 3D model of pancreatic cancer tumor and 3D micro anatomical structure analysis

Yushi GOTO[*1], Hidekata HONTANI[*1], Tatsuya YOKOTA[*1], Kugler MAURICIO[*1], Chika IWAMOTO[*2], Kenoki OHUCHIDA [*2], Makoto HASHIZUME[*2]

Abstract

In this study, we propose a method of registration between an MRI image and a set of pathological microscope images of a pancreatic cancer tumor of a KPC mouse. MRI images can be captured non-invasively but their resolution is low. On the other hand, microscopic images can be obtained only invasively although the resolution is high. Registration of these images is needed for realizing a multi-resolution model representing the correlation between the MRI images and the corresponding pathological images. In order to register the 2D pathological microscope images to the 3D MRI image, the proposed method first reconstructs a 3D pathological microscope image and then register between the 3D pathological microscopic image and the tumor region in the MRI image. The 3D pathological microscope image is reconstructed from a spatial series of 2D microscope images. For the reconstruction of an appropriate 3D image, the microscope images should be non-rigidly registered together. We employed a non-rigid registration method that deforms every image so that the spatial patterns in the resultant image have smooth structures. After the 3D image reconstruction, the proposed method then registers between the MRI image and the reconstructed 3D pathological image by means of a mutual-information based non-rigid registration. Down sampling the 3D microscope image so that the both images have same spatial resolution, the proposed method deforms the microscope images to the MRI image by maximizing their mutual information. We report the result of the registration and of the description of the microstructures in the reconstructed 3D pathological image.

Keywords : multimodal, multi-resolution, registration

---

*1 Nagoya Institude of Technology

*2 Kyusyu University

1 Purpose

Cancer is one of the deadliest diseases among all diseases and has been accounting for cause of death among Japanese for many years. Among them, since pancreatic cancer exists in the deep part of the body and has a thin organ shape, it is not easy to observe the detailed structure, and early detection and treatment are very difficult. The purpose of this study is to describe the relationship between the temporal change of pancreatic cancer and micro anatomical structure by registering MRI image shown in left of Figure 1 and pathological microscope images shown in right of Figure 1.

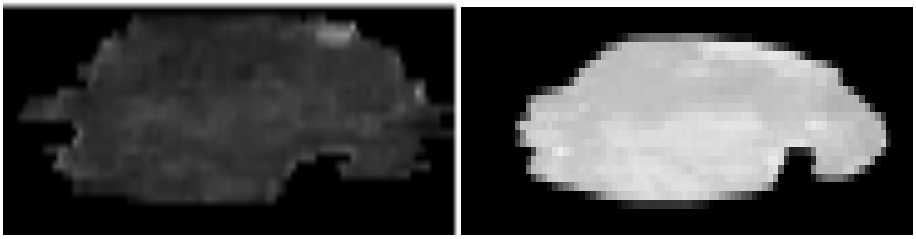

Fig.1 Left : MRI image.
Right : pathological microscope image

2. Method

We first reconstruct a 3D microscope image of the pancreas tumor and then register it with the corresponding volume region in the MRI image. The 3D microscope image is reconstructed from a series of 2D microscope images by non-rigid registration of them. We manually label the tumor region in the MRI image and rigidly register the 3D microscope image with the labeled region in the MR image by referring to the outer boundary of the tumor. After the rigid registration, we apply a large deformation diffeomorphic mapping (LDDMM) in order to align the tumor regions more accurately. It should be noted that the LDDMM registers the given two images, the 3D microscope image and the MR image, without referring to the patterns inside of the tumor regions. We then register the inside of the tumor regions based on the image patterns by maximizing the mutual information of the patterns. Let the 3D microscope image be denoted by $I(x,y,z)$ and let the MR image be denoted by $J(x,y,z)$. The proposed method deforms the 3D microscope image by using B-spline deformation, which is controlled by the locations of control points. Let the coordinates of the control points be denoted by $\boldsymbol{\mu}$ and let the deformed image be denoted by $I_{\mu(x,y,z)}$. Let the probability densities of the voxel values of I_{μ} and J be denoted by $p(I,\boldsymbol{\mu})$

and $p(J)$ respectively and the closed space H_i created by the eight control points around the control point $\boldsymbol{\mu_i} = (\mu_{2i-1}, \mu_{2i}, z)$. Then the mutual information of them is given as follows:

$$S(\boldsymbol{\mu}) = \arg\max_{\boldsymbol{\mu}} \left\{ -\sum\sum p(I,J;\boldsymbol{\mu}) \log_2 \frac{p(I,J;\boldsymbol{\mu})}{p(I;\boldsymbol{\mu})p(J)} \right\}$$
$$\text{subject to } \boldsymbol{\mu_i} \in H_i \quad (\text{for all } i)$$

The proposed method iteratively updates the coordinates of the control points by maximizing $S(\boldsymbol{\mu})$ and non-rigidly registers the 3D microscope image with the tumor region in the MR image.

3. Results

An example of the experimental results is shown in Fig.2. As shown, the mutual information was increased by the proposed method and, roughly speaking, the brighter regions in the MR image were registered with the necrosis regions observed in the microscope image.

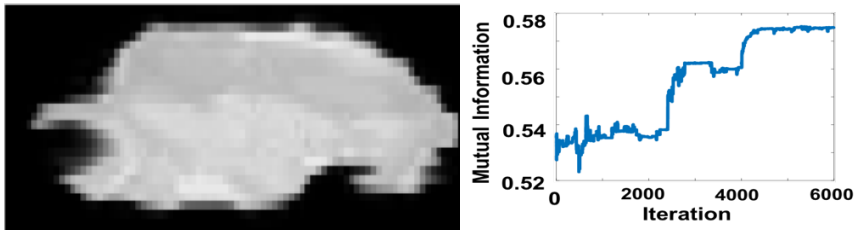

Fig 2. Left : Pathological microscope Image of result of registration.
Right : Change of value of mutual information

4. Conclusion

In this study, we modeled the relationship between images of different modalities of MR images representing temporal change of pancreatic cancer and microscopic images representing micro anatomical structure. As a result, the relationship between the pixel value pattern of the MR image and the micro anatomical structure of the microscopic image can be examined.

Competing interests

The authors declare no conflicts of interest associated with this manuscript.

References

[1] M. F. Beg, M. I. Miller, A. Trouve and L. Younes. Com- puting Large Deformation Metric Mappings via Geodesic Flows of Diffeomorphisms. International Journal of Com- puter Vision, vol.61, no.2, pp.139-157, 2005.

[2] P.Thevenaz, M.Unser, Spline Pyramids for Inter-Modal Image Registration Using Mutual Information, In Pro- ceedings of the SPIE Conference on Mathematical Imag- ing: Wavelet Applications in Signal and Image Process- ing V, vol.3169, pp.236-247, 1997.

Partial rigid diffeomorphism for measuring temporal change of pancreatic cancer tumor

Yuki Tamura[*1], Tatsuya Yokota[*1], Mauricio Kugler[*1], Valentin Triquet[*1],

Tomonari Sei[*2], Yukihide Iwamoto[*3], Kenoki Ohuchida[*3],

Makoto Hashizume[*3], Hidekata Hontani[*1]

Abstract

The objective of our research is to describe the isotropic temporal change of the tumor region in the whole body MRI images of a KPC mouse captured at different time. For accurately describing the tumor growth, non-rigid registration should be applied to normalize the body motion. Here, in order to suppress the tumor deformation caused by the registration, we develop a Large Deformation Diffeomorphic Metric Mapping(LDDMM)[1] that transforms the tumor region rigidly. Given a set of pairs of corresponding landmarks on peripheral organs in a source image and a target image, the proposed method first non-rigidly registers the two images by referring to those corresponding landmarks. This non-rigid registration maps the tumor region in the source image non-rigidly. The proposed method next determines the destination locations of landmarks generated in the tumor region in the source image by converting the non-rigid mapping of the tumor region to a rigid mapping. Then, we can have a set of pairs of the corresponding landmarks that consists of (a) the landmarks on the peripheral organs that would be registered non-rigidly and (b) the landmarks in the tumor region that can be registered rigidly. Our method iterate the non-rigid registration of the landmarks and the conversion of the non-rigid mapping of the tumor landmarks to the rigid one until they are converged. We experimented real MRI images and confirmed the effect.

1. Purpose

The objective of this study was to develop a method that can describe anisotropic growth of a pancreas tumor of a KPC mouse observed by a temporal series of MRI images of the whole body of the KPC mouse. Given the temporal series of MRI images, we manually label the tumor region in each image and describe the growth of the tumor by comparing the manually labeled regions. A growth would be anisotropic: The rate of growth can vary from portion to portion of the tumor. In order to observe such the variety of the rate of the growth, we need normalize the location and the pose of the tumor in the images and we employ a non-rigid registration method for the normalization. One problem here is that non-rigid registration would deform the tumor region itself and would prevent accurate observation of the tumor growth. We hence develop a method that can non-rigidly register the given two images, a source image and a target image, while the shape of the tumor in the source image is preserved.

*1 Nagoya Institute of Technology
*2 The University of Tokyo
*3 Kyushu University

2. Method

A set of pairs of corresponding landmarks is manually distributed on the surfaces of peripheral organs in the source and target images. The proposed method deforms the source image so that the landmarks would be registered to the corresponding landmarks in the target image. This non-rigid registration would deform the tumor region. Comparing the original tumor regions in the source image and the deformed image, the method estimates the rigid mapping that is the most consistent with the non-rigid deformation that registers the peripheral organs and computes the tumor region that has the shape identical with that of the tumor in the original source image but has the pose and location that would be different from those in the source image. The method iteratively computes the non-rigid registration of the peripheral organs and the rigid registration of the tumor region until they are converged. We applied the method to the temporal series of MRI images of a KPC mouse.

3. Results

We applied our method to two MRI images. The source image was captured two weeks before the target image was captured. Fig.1 shows the peripheral organs and the tumor manually labeled in the source image and the target image. We put about 100 landmarks on the surfaces of the peripheral organs in each image. Fig.2 shows the registered tumor regions. As one can see, the tumor region in the source image was successfully involved by the tumor in the target image. We can now observe the rate of the growth by comparing the difference of the regions.

4. Conclusion

We proposed partial rigid diffeomorphism to describe temporal change of pancreatic cancer tumor and conducted an experiment. Between the 6^{th} week tumor and the 8^{th} week tumor it was possible to achieve a roughly good alignment. This can describe the tumor growth. In the future we will align with all weeks and describe the temporal change of the tumor perfectly.

Competing interests

None.

References

[1] M.I.Miller, A.Trouv´e and L.Younes: Geodesic Shooting for Computational Anatomy, Journal of Mathematical Imaging and Vision 24(2), pp.209-228,2006.

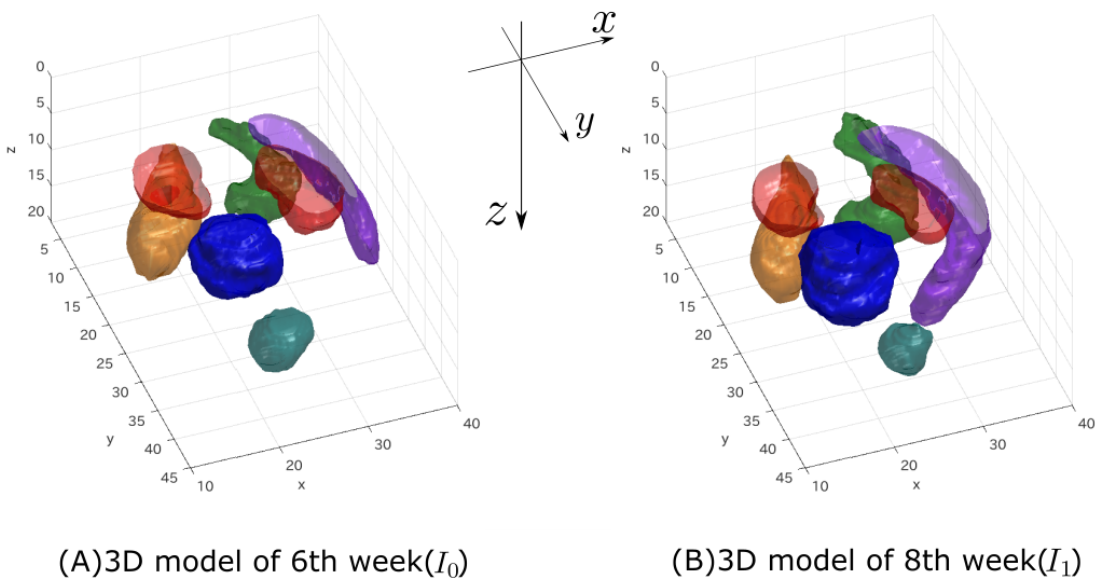

Fig. 1 3D models

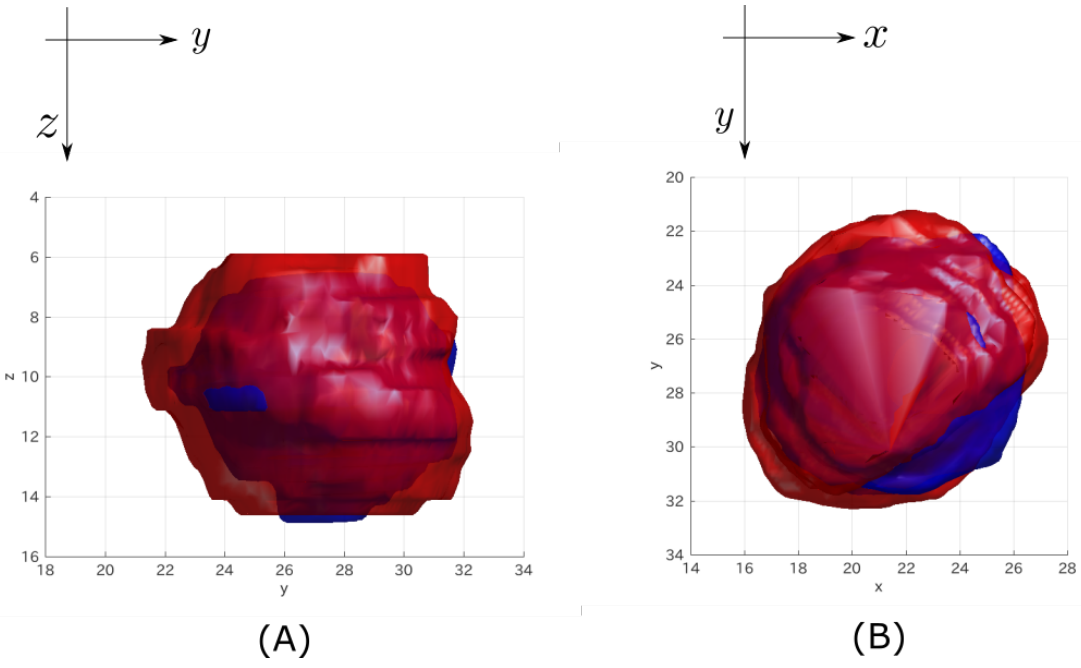

Fig. 2 The result of alignment

縞走査を行わない位相計測手法

廉　松哲[*1]　工藤　博幸[*1]

要旨

X 線位相撮影では生体の軟組織などを従来の X 線撮影より高いコントラストで観察することができ，医療診断への応用が期待されている．Talbot 干渉計による測定では回折格子をサブミクロンレベルで複数回移動（縞走査）し撮影するため，装置には非常に高い精度と安定性が求められる．我々は縞走査なしで位相が求められる新たな画像解析手法を提案する．この手法では２段階の手順を行う．1 段階目は Talbot 干渉計で得られる三つの画像（吸収，visibility，位相）において隣接画素値がほぼ同じだと仮定し，不足する測定データを隣接画素の測定データで補い近似位相画像を求める．２段階目は，近似位相画像から濃度値の変化が大きい箇所を推定し，上記の仮定とのずれが大きい部分を補正することで高解像度のまま復元を行う．提案手法では回折格子の移動が不要であるため高速 CT 撮影などへの応用が期待できる．

キーワード：X 線位相撮影，Talbot 干渉計，位相計測，位相復元

1. はじめに

X 線撮影では X 線が物体を透過する時，物体の吸収によってX線の強度が変化することでコントラスト画像を形成している．今日において病院でのX線撮影や工業の非破壊検査など幅広い分野に応用されている．一方で X 線の波動性から分かるように物体を通過する時X線の位相シフトも同時に生じる．特に，X 線が軽元素からなる物体（弱吸収物体）を通過する時，位相の変化が吸収の変化より大きくなることが報告されている．従って生体軟組織などの観察では従来のX線撮影方法より高いコントラストを持つ画像の提供が可能になり医療分野への応用が期待されている．2000 年代に入ってからX線位相撮影方法で軟骨や乳房撮影（phase contrast mammography）を行うなどので実際の応用に向けて研究が進んでいる [1].

開発された数多いX線位相撮影方法の中でも回折格子を用いた Talbot 干渉計法は通常の X 線管線源を使うことが可能になって注目されている．Talbot 干渉計法では主に縞走査を用いて位相を復元している [2,3]. 縞走査のため回折格子をサブミクロンレベルで移動させて複数回の撮影を行っているが，移動誤差が生じやすく，求められた位相も正確でなくなる．他方で縞走査なしの近似手法も開発されている．Fourier 変換方法では撮影条件によって撮影画質が劣化する，或いは復元過程で高周波の成分を捨てることで求められた画像の解像度が下がるという問題が指摘されている [4]. 他にも特殊な回折格子を用いる方法などの手法が提案されている[5,6,7]．いずれも新しいハードウェアが必要であり，しかも制作（或いは操作）過程で）かなり高い安定性（或いは精度）が要求されている．

本研究では Talbot 干渉計法において，縞走査（回折格子の移動）がなく，一回の撮影から位相が求められる位相復元手法を提案する．その原理について簡単に説明する．本手法では位相コントラス

*1 筑波大学システム情報系
〔〒305-8573 つくば市天王台 1-1-1〕
e-mail: songzhe.lian@gmail.com
投稿受付：2018 年 5 月 15 日

ト画像に関わる三つの変数（吸収, visibility, 位相）において隣接画素値がほぼ同じだと仮定し，不足する測定データを隣接画素の測定データで補い近似位相画像を求める．そして求められた近似位相画像から濃度値の変化が大きい箇所（物体の不連続な部分など）を推定し，上記の仮定とのずれが大きい部分を補正することで精度が向上された位相画像を復元している．実験結果は提案手法では従来の Fourier 変換方法より解像度が高い画像が得られることを示している．

2. 背景理論と提案手法

2.1 Talbot 干渉計

Talbot 干渉計は図 1 に示したように線源，二つの回折格子と検出器で構成されている [3, 4]．X 線が一番目の回折格子を通ると干渉（Talbot 効果）によって一定の距離の後で格子像（自己像）が現れる．ここで光路上に物体を置くとゆがんだ格子像が生じる．この格子像が生じる位置に二番目の回折格子を少しずらして置くとモアレ縞が生じる．従って Talbot 干渉計ではモアレ干渉縞の強度分布から解析手法によって物体の位相を求めている．

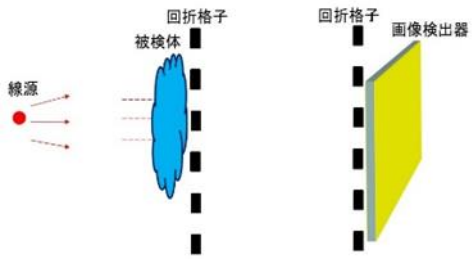

図 1 Talbot 干渉計

2.2 位相の復元

Talbot 干渉計で測定されるモアレ干渉縞の強度は各ピクセル (m,n) において次のように書くことができる．

$$I(m,n)=a_0(m,n)\\ \left(1+V(m,n)\cos\left(f_0*n+\phi(m,n)\right)\right) \tag{1}$$

ただし a_0 は吸収, V は visibility, ϕ は位相であり，f_0 はモアレ干渉縞の周波数である．Talbot 干渉計法では位相を求めるため物体がない時の背景の撮影とある時の撮影をそれぞれ行っている．ここで f_0 は背景の撮影から求められる．

式(1)で各ピクセルにおいて，三つの変数（吸収, visibility, 位相）があり，位相を求めるためには少なくとも三回の測定が必要である．そのため，縞走査法では回折格子を格子周期方向に M（M≥3）回移動して撮影することで複数回の撮影を行っている．そして複数個のデータを用いて最小二乗法などで位相が求められる．

2.3 提案手法

ステップ 1

上で説明したように，式(1)では変数の数が方程式の数（測定データの数）より多いため位相を求めることができない．本手法では変数の近似を用いてこの問題を解決する．具体的には次のような近似を行っている．式(1)で一つのピクセル (m,n) において，隣接している各ピクセルの変数は次の式を満たすと仮定する．

$$\begin{aligned} &a_0(m,n-1)\approx a_0(m,n+1)\approx a_0(m,n)\\ &V(m,n-1)\approx V(m,n+1)\approx V(m,n)\\ &\phi(m,n-1)\approx \phi(m,n+1)\approx \phi(m,n)\end{aligned} \tag{2}$$

これらの近似を用いて，式(1)から

$$\begin{aligned} &I(m,n-1)\approx a_0(m,n)\\ &\left(1+V(m,n)\cos\left(f_0*(n-1)+\phi(m,n)\right)\right)\\ &\overset{def}{=} I_{-1}(m,n)\end{aligned} \tag{3}$$

と書くことができる．これはピクセル (m,n) において新しいデータ I_{-1} が増えたことを意味する．同じ近似で我々は少なくとも三つのデータを得ることができる．

$$\begin{aligned} &I_{-1}(m,n)=I(m,n-1),\\ &I_0(m,n)=I(m,n),\\ &I_1(m,n)=I(m,n+1).\end{aligned} \tag{4}$$

この三つのデータを用いて次のように最小二乗法で位相が求められる．

$$\min_{a_0,V,\phi}\sum_{k=0,\pm1}\left(I_k - a_0\left(1+V\cos\left(f_0*(n+k)+\phi\right)\right)\right) \tag{5}$$

ステップ 2

次の段階では式(5)で求められた近似位相画像を用いて画像の精度が向上される方法を提案する．ステップ 1 では変数の近似仮定(2)に基づいて位相画像を復元している．従って物体の連続した部分は大体正しく復元できるが不連続なところの復元は誤差が生じやすい．

本研究では重み付き最小化問題を解くことでこの問題を補正する．

まずは重み関数Wに対して説明する．重み関数はステップ(1)でもとめられる近似位相像ϕを用いて注目（位相値を求める）ピクセル(m,n)の付近の各ピクセルの重み（関数値）を決めている．位相値が$\phi(m,n)$と近接するほど大きい重みを与えている．例えば次のような関数は可能である．

$$W(i,j)=\exp\left(-\left(\phi(i,j)-\phi(m,n)\right)^2\right) \tag{6}$$

次に取得された重み関数を用いて，式(5)の代わりに重み付きの最小化問題を解いて位相を求める．

$$\min_{a_0,V,\phi}\sum_{k=0,\pm1}W(\cdot,n+k)$$
$$\left(I_k - a_0\left(1+V\cos\left(f_0*(n+k)+\phi\right)\right)\right) \tag{7}$$

ここで重みをつかって精度が向上できる原理に対して説明する．

図 2 のように位相値が求められるピクセル(m,n)が境界(不連続なところ)に位置したとする．

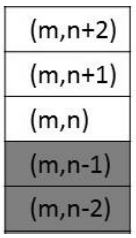

図 2 近似位相像と重み

この時，ピクセル$(m,n-1)$において式(2)の仮説は正しくない．従って画素$(m,n-1)$のデータは計算から排除するべきである．重み関数はこの作用を行っている．関数の作り方によって$(m,n-1)$は(m,n)と位相値に大きい差があるため重みが小さくなる．特に位相値の差が大きくなると

$$W(m,n-1)\approx 0 \tag{8}$$

この式はピクセル$(m,n-1)$のデータが式(7)の計算で排除されることを意味する．結果として不連続なピクセルでもより正確な位相が求められる．

3. 実験結果

シミュレーションではまず物体の位相（正解画像）と吸収関数，visibility 関数を用いて式(1)で一枚の干渉縞を形成する．その干渉縞画像に雑音を加えてから従来手法と本発明手法でそれぞれ位相像を求める．ここで吸収関数と visibility 関数は弱吸収物体を観察することを想定して物体の形と関係ない Gauss 関数を用いている．実験では Shepp-Logan phatom（256*512）を物体の位相像としている．

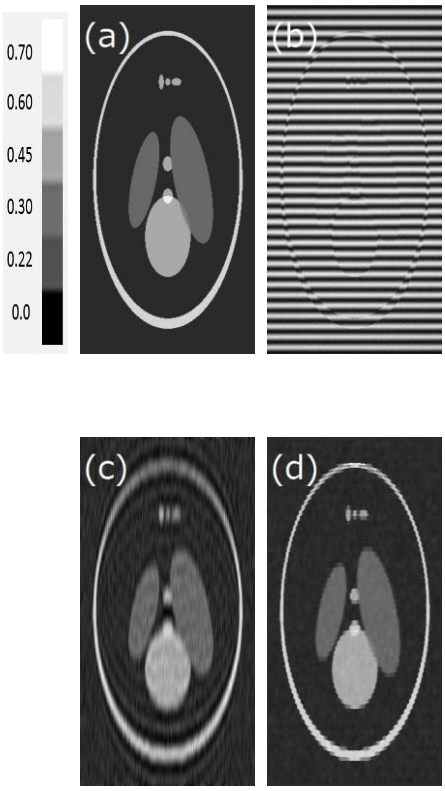

図 3 (a) Shepp-Logan phatom (b) 撮影されるモアレ干渉縞 (c) (d)は縞走査なし，Fourier 変換方法と提案手法でそれぞれ復元した位相像である．

図 3(b)は式（1）で計算した干渉縞である．図 3 (c)-(d)は縞走査がなく，一枚の撮影データを用いて, それぞれ Fouirer 変換方法と提案手法で求めた位相像である. 提案手法では Fouirer 変換方法より解像度が上がった画像が得られる．

4. まとめ

本研究では縞走査なしで一回の撮影から物体の位相像を取得することができる位相復元方法を提案した. 従来の Fourier 変換方法と比べるとより高い解像度を持つ画像が求められる．近似手法なので従来の縞走査法より精度が若干下がるが回折格子の移動がないため設備面での高い精度が要求されない．特に CT 撮影をする時，回折格子を複数回移動する必要がなくなり，設備の操作が簡単になる．従って提案手法の高速 CT 位相撮影での応用が期待される．

謝辞

本研究は The JST-ERATO project (Grant Number JPMJER1403)の助成を受けたものである．

利益相反の有無

「なし」

文　献

［1］ Bravin A, Coan P, and Suortti P, “X-ray phase-contrast imaging: from pre-clinical applications towards clinics,” Phys. Med. Biol. 58, R1–R35 (2012).

［2］ Momose A, Kawamoto S, Koyama I, Hamaishi Y, Takai K, and Suzuki Y, “Demonstration of X-Ray Talbot interferometry,” Jpn. J. Appl. Phys. 42, L866–L868 (2003).

［3］ Weitkamp T, Diaz A, David C, Pfeiffer F, Stampanoni M, Cloetens P, and Ziegler E, “X-ray phase imaging with a grating interferometer,” Opt. Express 12(16), 6296–6304 (2005).

［4］ Takeda M, Ina H and Kobayashi S, ”Fourier-transform method of fringe-pattern analysis for computer-based topography and interferometry,” J. Opt. Soc. Am. 72, 156-160 (1982).

［5］ Ge Y., Li K., Garrett J. & Chen G.-H. Grating based x-ray differential phase contrast imaging without mechanical phase stepping. Opt. Express 22, 14246–14252 (2014).

［6］ Kottler C, Pfeiffer F, Bunk O, Gr¨unzweig C, and David C, “Grating interferometer based scanning setup for hard X-ray phase contrast imaging,” Rev. Sci. Instrum. 78, 043710 (2007).

［7］ Arboleda C, Wang Z, and Stampanoni M, “Tilted-grating approach for scanning-mode X-ray phase contrast imaging,” Opt. Express 22(13), 15447–15458 (2014).

X 線位相イメージングにおける統計的再構成法の高速化

上田 亮介[*1]　工藤 博幸[*1]　山嵜 深[*1]

要旨

生体軟組織など軽元素からなる測定対象では吸収コントラストは低く，鮮明な画像が得られないことがある．これに対して，X 線の波としての性質を利用する位相イメージングでは，はるかに高いコントラストを得ることができる．近年，位相 CT 画像再構成において統計的画像再構成法が提案された[4，5]．この手法では，吸収，散乱，位相に対する３つのコントラスト画像を得ることができ，ノイズ低減や測定回数削減などの様々なポテンシャルが期待されている．しかし，反復回数が多く，３つの画像を同時に再構成するため計算量が多い課題がある．これを解決するため，本研究では，近年提案された FBP 法組み込み型高速化手法[6]を統計的画像再構成法に応用する．この手法は解析的手法である FBP 法を反復法に組み込むことにより劇的に反復回数の削減を可能とする．FBP 法組み込み型高速化法は，重み付き２乗誤差を最小化する画像再構成関数に対して提案されたが，本研究では位相 CT の尤度最大化問題に適用する．数値ファントムと Talbot 干渉計により撮影されたマウス耳小骨サンプルに対し再構成を行い，本手法により反復回数が削減できることを示す．

キーワード：画像再構成，X 線位相イメージング

1. はじめに

X 線は物体を透過する際，吸収により X 線強度あるいは光子数が減衰する．これを利用した吸収コントラスト像は医用画像診断に広く利用されている．特に X 線 CT(Computed Tomography)は，現代の医用診断において非常に重要である．また，X 線が物体を透過する際に起きる現象は吸収だけではない．X 線は波としての性質を持ち，透過時に屈折し位相がシフトする．生体軟組織では位相コントラストは吸収コントラストよりもはるかに高く[1]，X 線位相イメージングは医用応用が期待されている．また，X 線が物体を透過する際には小角散乱が起き，これを利用した散乱コントラスト像に関する研究が近年報告されている[2，3]．

X 線による位相計測手法のひとつに，回折格子を用いる Talbot 干渉計がある[1]．Talbot 干渉計における CT 画像生成の手順は次の通りである．まず，回折格子をスライドさせることで１投影方向につき複数枚のモアレ画像を測定する．次に，モアレ画像から吸収・散乱・位相に対応する投影像(サイノグラム)を求める．最後に，それぞれの投影像に対して個別に CT 画像再構成を行う．再構成アルゴリズムには吸収 CT で用いられている様々な手法を適用できる．

近年，上記のような手順を用いず，モアレ画像から吸収・散乱・位相に対する３つのコントラスト像を直接同時に再構成する手法が報告された[4，5]．この手法では，X 線光子数の統計的ゆらぎを表す確率分布がポアソン分布であると仮定し，尤度を反復法で最大化させる統計的再構成法を用いている．この統計的同時再構成法の利点として，従来手法よりもノイズ抑制効果が高い，あるいは，測定するモアレ画像の枚数を削減可能なポテンシャルが指摘されている[4，5]．しかし，この手法は反復法であるため FBP 法よりもはるかに計算時間がかかる．統計的同時再構成法は報告されたばかりの比較的新しい手法であり，このような手法に対する高

*1 筑波大学大学院システム情報系
〔〒305-8573 つくば市天王台 1-1-1〕
e-mail: ueda@imagelab.cs.tsukuba.ac.jp

速解法はこれまでほとんど研究されていない．

本論文では，上記の吸収・散乱・位相コントラスト画像の統計的同時再構成法に対する高速化手法を提案する．本提案手法は，従来の吸収 CT 画像再構成に対して工藤らが提案した FBP 組み込み型高速解法[6]を基礎にしている．FBP 組み込み型解法は，反復型解法の 1 ステップに解析的手法である FBP 法を利用する．工藤らは重み付き 2 乗誤差の最小化問題にこの高速化手法を適用することで，反復回数の劇的な削減を達成している．本論文ではこの手法を，統計的同時再構成法で扱う負の対数尤度の最小化問題に適用する．数値ファントムおよび，マウス耳小骨小片試料を測定した吸収・散乱・位相コントラストの実画像を用いて，提案手法の高速化性能を検証する．

2. Talbot 干渉計を用いた CT 画像再構成法

Talbot 干渉計では回折格子を移動させることで，複数のモアレ画像を生じさせ、位相を計測する[1]．図 1 に Talbot 干渉計の模式図を示す．

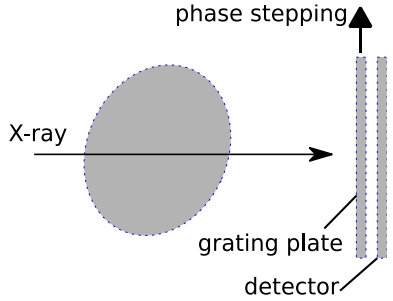

図 1 Talbot 干渉計の模式図

回折格子が測定対象の下流に設置され，検出器面に沿って移動可能となっている．この回折格子を移動(位相ステッピング)させることで，異なるモアレ画像を生じさせる．このとき k 番目の位相ステッピングでのモアレ画像，すなわち測定される X 線強度$\boldsymbol{N}_k$は

$$\boldsymbol{N}_k = \boldsymbol{T} \circ \left[1 + \boldsymbol{V} \circ \cos\left(\boldsymbol{\Phi} + \Phi_{\mathrm{ps},k}\right)\right] \quad (1)$$

と書ける．ここで，$\boldsymbol{T}, \boldsymbol{V}, \boldsymbol{\Phi}$をそれぞれ

$$\boldsymbol{T} = \boldsymbol{N_0} \circ \exp(-A\boldsymbol{\mu}) \quad (2)$$

$$\boldsymbol{V} = \boldsymbol{V_0} \circ \exp(-A\boldsymbol{\sigma}) \quad (3)$$

$$\boldsymbol{\Phi} = \boldsymbol{\Phi_0} + DA\boldsymbol{\phi} \quad (4)$$

と定義した．式中の演算$\boldsymbol{f} \circ \boldsymbol{g}$はベクトル$\boldsymbol{f}$と$\boldsymbol{g}$の要素同士の積を表し，ベクトルの次元を$m$としたとき$\boldsymbol{f} \circ \boldsymbol{g} = (f_1 g_1, f_2 g_2, \ldots, f_m g_m)^T$ と書ける．

また，本論文中ではベクトルに対する指数関数，及び三角関数は要素ごとに適用するとし，例えば$\cos \boldsymbol{\Phi} = (\cos\Phi_1, \cos\Phi_2, \ldots, \cos\Phi_I)^T$と表す．式(1)中に現れる$\Phi_{\mathrm{ps}}$は位相ステッピングによるシフト量であり，$\Phi_{\mathrm{ps}} = 2\pi k/K$，　$(k = 1,\ 2,\ \ldots,\ K)$と書ける．ここでKは 1 投影方向あたりの位相ステッピングの回数である．式(2)-(4)に現れる$\boldsymbol{\mu}$，$\boldsymbol{\sigma}$，$\boldsymbol{\phi}$はそれぞれ再構成すべき吸収・散乱・位相画像であり，画素数を$\sqrt{J} \times \sqrt{J}$としてJ次元ベクトルで表す．$\boldsymbol{N_0}$，$\boldsymbol{V_0}$，$\boldsymbol{\Phi_0}$は測定対象を置かずに計測することで得られるバックグラウンド成分である。これらは I 次元ベクトルで表す．また，式中に現れる行列Aは従来の吸収 CT 画像再構成で用いられるものと同じ投影行列である．式(4)で表される$\boldsymbol{\Phi}$は微分位相画像と呼ばれ，Dは位相ステッピング方向に関する微分演算子である．

FBP 法により画像再構成を行う場合は 2 段階の手順をとる。まず，式(1)で表される X 線強度Nから吸収・散乱・位相画像に対するサイノグラム$\{A\mu, A\sigma, DA\phi\}$を求める．この処理を位相抽出と呼ぶ．$M \geq 3$のとき，式(1)のフーリエ係数を抽出することで$\boldsymbol{T}, \boldsymbol{V}$および$\boldsymbol{\Phi}$が求められ，これより式(2)-(4)を用いてサイノグラムが得られる．次に，位相抽出によって得たサイノグラムに対し FBP 法を適用し再構成を行う。微分位相画像に対しては， Hilbert フィルタを利用することで FBP 法による画像再構成ができることが知られている[7].

2.1 統計的画像再構成法

近年 Ritter らにより報告された統計的同時画像再構成法は，中間データであるサイノグラムを求めずに，測定した X 線強度データから直接画像を再構成する[4]. 直接再構成する利点として，X 線光子数のゆらぎに起因するノイズの統計的性質を組み込める点や，位相ステッピングの回数を削減できる可能性が指摘されている[4, 5]. 例えば文献[5]では，Ritter らの手法に正則化項を加える再構成手法を提案し，スライディングウィンドウという測定方法を用いることで，各投影方向での位相ステッピング回数を 1 回に削減している．位相ステッピングの回数が削

減できれば，高速な撮影が可能となる．

Ritter らにより報告された最尤推定法による再構成手法を述べる．まず，検出器で得られるX線光子数の統計的ゆらぎは，ポアソン分布に従うことが知られている．このとき，測定される光子数の確率分布はパラメータ$\boldsymbol{\theta}=(\boldsymbol{\mu},\ \boldsymbol{\sigma},\ \boldsymbol{\phi})$を用いて

$$P_{\overline{N_i}}=\frac{\overline{N_i}(\theta)^{N_i}}{N_i!}e^{-\overline{N_i}} \tag{5}$$

として表せる．$\overline{N_i}$は推定光子数で、下付きの添え字$(i=1,2,\dots,I\times J\times K)$は測定データのインデックスである．このとき尤度は$L(\boldsymbol{\theta})=\prod_i P_{\overline{N_i}}$で求められ，これを最大化することで画像を再構成する．尤度最大化は負の対数尤度を最小化することと等価であるため，次の最小化関数を解く．

$$\min_{\boldsymbol{\theta}}\ \log L=\sum_i -N_i\log\overline{N_i}+\overline{N_i} \tag{6}$$

Ritter らはこの関数を勾配法で解いており，その反復式は，

$$\boldsymbol{\theta^{n+1}}=\boldsymbol{\theta^{n}}-\alpha\nabla\log L(\boldsymbol{\theta^{n}}) \tag{7}$$

と書ける．ただし，αはステップサイズ，∇は$\boldsymbol{\theta}$に関する偏微分を表す．この Ritter らの手法は，最尤推定法としては簡単であるが，収束が遅く計算時間が長い問題点がある．

3．提案手法

収束速度の問題点を改善するため，本論文では工藤らによって提案された FBP 組み込み型高速化法[6]を上記の統計的同時再構成に応用する．FBP 法は解析的手法であるため非常に速く再構成が可能であるが，反復法で利用される正則化や検出光子数の統計的性質を利用することができない．これに対して，反復法は様々な物理現象のモデルや正則化を組み込むことができる反面，計算時間が多い．これを解決するため，工藤らは反復法の各ステップに FBP 法を組み込むことで，FBP 法と反復法の長所を併せ持つ高速解法を提案し，反復回数の劇的な削減を達成した．しかし，これはサイノグラムから画像を再構成する手法であり，Ritter らの手法のように中間データとしてサイノグラムを求めずに，X 線強度データから直接画像を再構成する方法については適用されていない．本論文では，工藤らの手法を応用して，Ritter および Brendel らが用いる統計的同時画像再構成法[4, 5]を高速化する手法を提案する．

まず，式(6)を次式のように、制約付き最小化問題に書き換える．

$$\min_{\boldsymbol{\theta}}\sum_i -N_i\log\widetilde{N}_i+\widetilde{N}_i \tag{7}$$

$$\begin{aligned}\text{s.t. }\ & G_\mu A_\mu\boldsymbol{\mu}=G_\mu\boldsymbol{z_\mu}\\ & G_\sigma A_\sigma\boldsymbol{\sigma}=G_\sigma\boldsymbol{z_\sigma}\\ & G_\phi A_\phi\boldsymbol{\phi}=G_\phi\boldsymbol{z_\phi}\end{aligned} \tag{8}$$

ただし，$A_\mu=A_\sigma=A$および$A_\phi=DA$であり，$\widetilde{\boldsymbol{N}}$，$\widetilde{\boldsymbol{T}}$，$\widetilde{\boldsymbol{V}}$，$\widetilde{\boldsymbol{\Phi}}$は

$$\widetilde{\boldsymbol{N}}=\widetilde{\boldsymbol{T}}\circ\left[1+\widetilde{\boldsymbol{V}}\circ\cos\left(\widetilde{\boldsymbol{\Phi}}+\Phi_{\mathrm{ps}}\right)\right] \tag{9}$$

$$\widetilde{\boldsymbol{T}}=\boldsymbol{N_0}\circ\exp\left(-\boldsymbol{z_\mu}\right) \tag{10}$$

$$\widetilde{\boldsymbol{V}}=\boldsymbol{V_0}\circ\exp(-\boldsymbol{z_\sigma}) \tag{11}$$

$$\widetilde{\boldsymbol{\Phi}}=\boldsymbol{\Phi_0}+\boldsymbol{z_\phi} \tag{12}$$

と定義した．また，式(8)中の制約条件に現れる，G_μ，G_σ，G_ϕは投影行列の条件数を下げるための前処理行列である．式(8)は等式制約であるため，この制約付き最小化問題は式(6)と同じ解$\boldsymbol{\theta}=(\boldsymbol{\mu},\ \boldsymbol{\sigma},\ \boldsymbol{\phi})$を持つ．ラグランジュ未定乗数法により主双対問題の形に再定式化すると，

$$\begin{aligned}\min_{\substack{\boldsymbol{\mu},\sigma,\boldsymbol{\phi}\\ \boldsymbol{z_\mu},\boldsymbol{z_\sigma},\boldsymbol{z_\phi}}}\max_{\boldsymbol{\lambda_\mu},\boldsymbol{\lambda_\sigma},\boldsymbol{\lambda_\phi}}\ & \sum_i -N_i\log\widetilde{N}_i+\widetilde{N}_i\\ & +\boldsymbol{\lambda_\mu^T}G_\mu(A_\mu\boldsymbol{\mu}-\boldsymbol{z_\mu})\\ & +\boldsymbol{\lambda_\sigma^T}G_\sigma(A_\sigma\boldsymbol{\sigma}-\boldsymbol{z_\sigma})\\ & +\boldsymbol{\lambda_\phi^T}G_\phi(A_\phi\boldsymbol{\phi}-\boldsymbol{z_\phi})\end{aligned} \tag{13}$$

が得られる．これは鞍点問題であり，式(13)の評価関数を適切な最適化手法を用いて，主変数である$\boldsymbol{\mu}$，$\boldsymbol{\sigma}$，$\boldsymbol{\phi}$，$\boldsymbol{z_\mu}$，$\boldsymbol{z_\sigma}$，$\boldsymbol{z_\phi}$に関して最小化，双対変数である$\boldsymbol{\lambda_\mu}$，$\boldsymbol{\lambda_\sigma}$，$\boldsymbol{\lambda_\phi}$に関して最大化することで画像を再構成することができる．

式(16)式の関数を解く反復法の一つである APP(Alternating projection proximal)法[8]を用いて反復式を導出すると，

(Extrapolation)

$$\begin{aligned}\boldsymbol{v_s^*}=\boldsymbol{v_s^n}+\alpha_s G_s'(A_s\boldsymbol{s^n}-\boldsymbol{z_s^n})\\ (\boldsymbol{s}=\boldsymbol{\mu},\boldsymbol{\sigma},\boldsymbol{\phi})\end{aligned} \tag{14}$$

(Primal update)

$$\begin{aligned}\boldsymbol{s^{n+1}}=\boldsymbol{s^n}-\tau_s A_s^T\boldsymbol{v_s^*}\\ (\boldsymbol{s}=\boldsymbol{\mu},\boldsymbol{\sigma},\boldsymbol{\phi})\end{aligned} \tag{15}$$

$$\boldsymbol{z}_{\boldsymbol{\mu}}^{\boldsymbol{n+1}} = \boldsymbol{z}_{\boldsymbol{\mu}}^{\boldsymbol{n}} - \gamma_{\mu}\left(\sum_i N_i - \widetilde{N}_i - \boldsymbol{\nu}_{\boldsymbol{\mu}}^{*}\right) \quad (16)$$

$$\boldsymbol{z}_{\boldsymbol{\sigma}}^{\boldsymbol{n+1}} = \boldsymbol{z}_{\boldsymbol{\sigma}}^{\boldsymbol{n}} - \gamma_{\sigma}\sum_i \left(N_i - \widetilde{N}_i\right)\widetilde{\boldsymbol{T}}^{\boldsymbol{n}} \circ \widetilde{\boldsymbol{V}}^{\boldsymbol{n}}/\widetilde{N}_i \times \cos\left(\widetilde{\boldsymbol{\Phi}}^{\boldsymbol{n}} + \Phi_{\mathrm{ps}}\right) - \boldsymbol{\nu}_{\boldsymbol{\sigma}}^{*} \quad (17)$$

$$\boldsymbol{z}_{\boldsymbol{\phi}}^{\boldsymbol{n+1}} = \boldsymbol{z}_{\boldsymbol{\phi}}^{\boldsymbol{n}} - \gamma_{\phi}\sum_i \left(N_i - \widetilde{N}_i\right)\widetilde{\boldsymbol{T}}^{\boldsymbol{n}} \circ \widetilde{\boldsymbol{V}}^{\boldsymbol{n}}/\widetilde{N}_i \times \sin\left(\widetilde{\boldsymbol{\Phi}}^{\boldsymbol{n}} + \Phi_{\mathrm{ps}}\right) - \boldsymbol{\nu}_{\boldsymbol{\phi}}^{*} \quad (18)$$

(Dual update)

$$\boldsymbol{\nu}_{\boldsymbol{s}}^{\boldsymbol{n+1}} = \boldsymbol{\nu}_{\boldsymbol{s}}^{\boldsymbol{n}} + \alpha_s G_s'(A_s \boldsymbol{s}^{\boldsymbol{n}} - \boldsymbol{z}_{\boldsymbol{s}}^{\boldsymbol{n}}) \quad (\boldsymbol{s} = \boldsymbol{\mu}, \boldsymbol{\sigma}, \boldsymbol{\phi}) \quad (19)$$

と書ける．ただし，式を見やすくするため$G_s' = G_s^T G$, $\boldsymbol{\nu}_s = G_s^T \boldsymbol{\lambda}_s$ $(s = \mu, \sigma, \phi)$と定義した。上式から，G_μ, G_σ, G_ϕはそれぞれ$\boldsymbol{\mu}, \boldsymbol{\sigma}, \boldsymbol{\phi}$に関する係数行列$A$および$A_\phi$に作用する前処理行列であることがわかる。これらの前処理行列を適切に設計することで係数行列の条件数を下げられ，収束速度を向上できる。また，$\boldsymbol{z}_{\boldsymbol{\mu}}$，$\boldsymbol{z}_{\boldsymbol{\sigma}}$，$\boldsymbol{z}_{\boldsymbol{\phi}}$は測定したX線強度データから位相抽出によって求められるサイノグラムに相当し，式(16)-(18)は位相抽出計算を行っているとみなせる．最初に位相抽出を従来手法で行って得られたサイノグラムを$\boldsymbol{z}$の初期値とし，他の6変数は初期値0の場合を考えると，式(14), (15)による初回のステップは

$$\boldsymbol{\mu}^{\boldsymbol{1}} = \alpha_\mu \tau_\mu A^T G_\mu \boldsymbol{z}_{\boldsymbol{\mu}}^{\boldsymbol{0}} \quad (20)$$

$$\boldsymbol{\sigma}^{\boldsymbol{1}} = \alpha_\sigma \tau_\sigma A^T G_\sigma \boldsymbol{z}_{\boldsymbol{\sigma}}^{\boldsymbol{0}} \quad (21)$$

$$\boldsymbol{\phi}^{\boldsymbol{1}} = \alpha_\phi \tau_\phi A^T D^T G_\phi \boldsymbol{z}_{\boldsymbol{\phi}}^{\boldsymbol{0}} \quad (22)$$

と書ける．$\boldsymbol{z}_{\boldsymbol{\mu}}^{\boldsymbol{0}}$，$\boldsymbol{z}_{\boldsymbol{\sigma}}^{\boldsymbol{0}}$，$\boldsymbol{z}_{\boldsymbol{\phi}}^{\boldsymbol{0}}$がサイノグラムであることに注意すると，$G_\mu$，$G_\sigma$，$D^T G_\phi$が FBP フィルタとなるように前処理行列を設計することで，最初の 1 回の反復で FBP 法と同等の画像が得られる．従って，G_μ，G_σに Shepp-Logan フィルタ，$D^T G_\phi$に Hilbert フィルタを用いることで，収束速度の向上が期待できる．

上記の導出では省略したが，工藤らの論文にあるように，正則化付き最小化問題への応用も容易であり，正則化関数に Total Variation ノルムを用いれば圧縮センシング法を利用することも可能となる．具体的には，式(6)に微分可能とは限らない正則化関数ψを追加した次の問題を解く．

$$\min_{\mu,\ \sigma,\ \phi} \beta_\mu \psi(\boldsymbol{\mu}) + \beta_\sigma \psi(\boldsymbol{\sigma}) + \beta_\phi \psi(\boldsymbol{\phi}) + \sum_i -N_i \log \overline{N_i} + \overline{N_i} \quad (23)$$

β_μ，β_σ，β_ϕはそれぞれ正則化の強さを示すパラメータである．このとき，式(15)に相当する計算式は近接写像，

$$\boldsymbol{s}^{\boldsymbol{n+1}} = \mathrm{prox}_{\tau_s, \beta_s \psi}[\boldsymbol{s}^{\boldsymbol{n}} - \tau_s A_s^T \boldsymbol{\lambda}_{\boldsymbol{s}}^{*}] \quad (\boldsymbol{s} = \boldsymbol{\mu}, \boldsymbol{\sigma}, \boldsymbol{\phi}) \quad (24)$$

となる．

4. 収束速度改善の検証

4.1 数値ファントム

図 2 に示す数値ファントムを用いて，本論文で提案する FBP 前処理行列の効果を検証した．数値ファントムの画像サイズは256×256とし，吸収・散乱・位相画像の濃度値の最大値は，次節で述べるマウス耳小骨小片試料の画像を参考にしてそれぞれ$\mu_{\max} = 80[\mathrm{cm}^{-1}]$，$\sigma_{\max} = 40[\mathrm{cm}^{-1}]$，$\phi_{\max} = 10^{-3}[\mathrm{rad} \cdot \mathrm{cm}^{-1}]$とした．

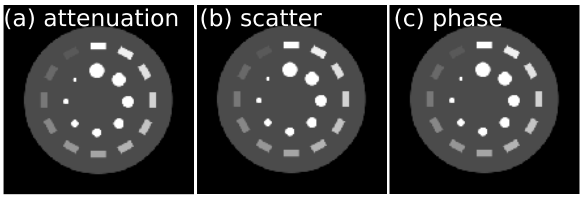

図 2 数値ファントム (a)吸収画像$\boldsymbol{\mu}$，(b)散乱画像$\boldsymbol{\sigma}$，(c)位相画像$\boldsymbol{\phi}$．各画像の最大値は$\boldsymbol{\mu_{\max} = 80[\mathrm{cm}^{-1}]}$, $\boldsymbol{\sigma_{\max} = 40[\mathrm{cm}^{-1}]}$, $\boldsymbol{\phi_{\max} = 10^{-3}[\mathrm{rad} \cdot \mathrm{cm}^{-1}]}$.

数値ファントムを用いて模擬測定データを作成し，統計的同時再構成法により再構成を行った．位相ステッピングは 5 回とし，投影方向数は256で平行ビームを想定した．また，バックグラウンド成分は$N_0 = 5000$，$V_0 = 0.9$，$P_0 = 0$とした．図 3 は FBP 前処理なし(上段)と FBP 前処理あり(下段)の場合の再構成画像で，それぞれ 10 反復の結果である．FBP 前処理なしの場合を原画像と比較すると，10 回の反復では収束が不十分で上手く再構成できておらず，構造が明確に復元できていない．一方，FBP 前処理ありの場合では，わずか 10 回の反復で 3 画像とも原画像とほぼ一致している．

吸収，散乱，位相画像の NRMSE(Normalized Root Mean Square Error)値の推移を図 4 に示す．前処理行列なしでは 100 回，前処理ありでは 50

回までを示している．前処理なしでは 3 画像とも収束が遅く，100 回以上の反復が必要であった．これに対して，前処理ありは収束が速く，10-20 回の反復でほぼ収束した．

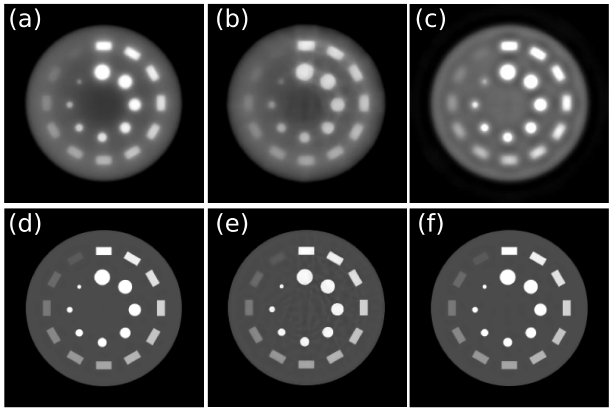

図 3 統計的手法により数値ファントムを再構成した結果．反復回数は 10 回．上段は FBP 前処理なし，下段は FBP 前処理あり．左から順に吸収・散乱・位相画像．.

4.2 マウス耳小骨小片試料

Talbot 干渉計で計測したマウス耳小骨小片試料を用いて FBP 前処理の効果を検証する．図 5 は従来手法，すなわち位相抽出によりサイノグラムを求め，FBP 法により再構成した結果であり、これを原画像として用いる．

FBP 前処理を用いずに統計的画像再構成を行った場合と，本論文で提案した FBP 前処理を用いた場合の再構成結果を示す．位相ステッピングは 5 回とし，投影方向数は400で平行ビームを想定した．画像サイズは512 × 512（画素）とした．図 6 は各手法で 16 回反復したときの結果である．FBP 前処理なしの場合を図 5 の原画像と比較すると，16 回の反復では上手く再構成できていないことがわかる．吸収(図 6(a))および散乱画像(図 6(b))では構造が明確ではなく，位相画像(図 6(c))では試料内側ほど復元が遅い．また 3 画像とも濃度値が図 5 の原画像よりも低く，反復回数が明らかに不十分である．一方，FBP 前処理ありの場合では，3 画像とも FBP 法による結果と同じ明確な構造が見られる．画像の濃度値も FBP 法による結果とほぼ同程度であり，少ない反復回数で再構成できている．吸収，散乱，位相画像の NRMSE 値の推移を図 7 に示す．FBP 前処理により収束速度が大きく向上している．前処理なしでは，吸収，散乱，位

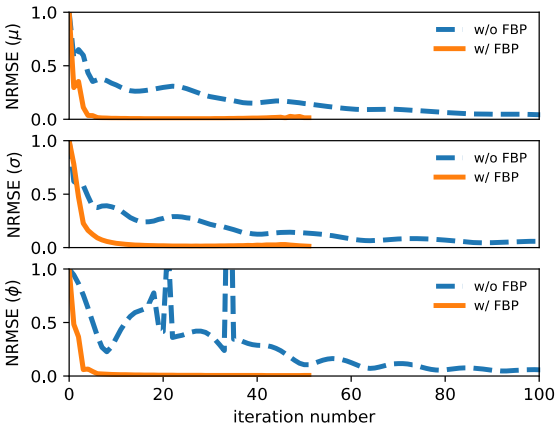

図 4 数値ファントム再構成における吸収(**μ**)，散乱(**σ**)，位相画像(**ϕ**)の NRMSE 値の推移．破線は FBP 前処理なし，実線は FBP 前処理あり

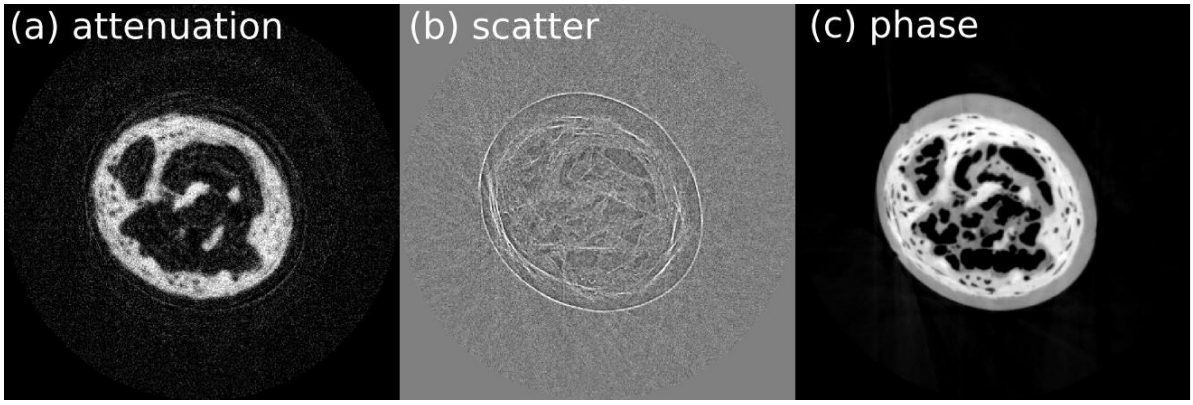

図 5 位相抽出と FBP 法により再構成したマウス耳小骨サンプル．(a)吸収画像，(b)散乱画像，(c)位相画像

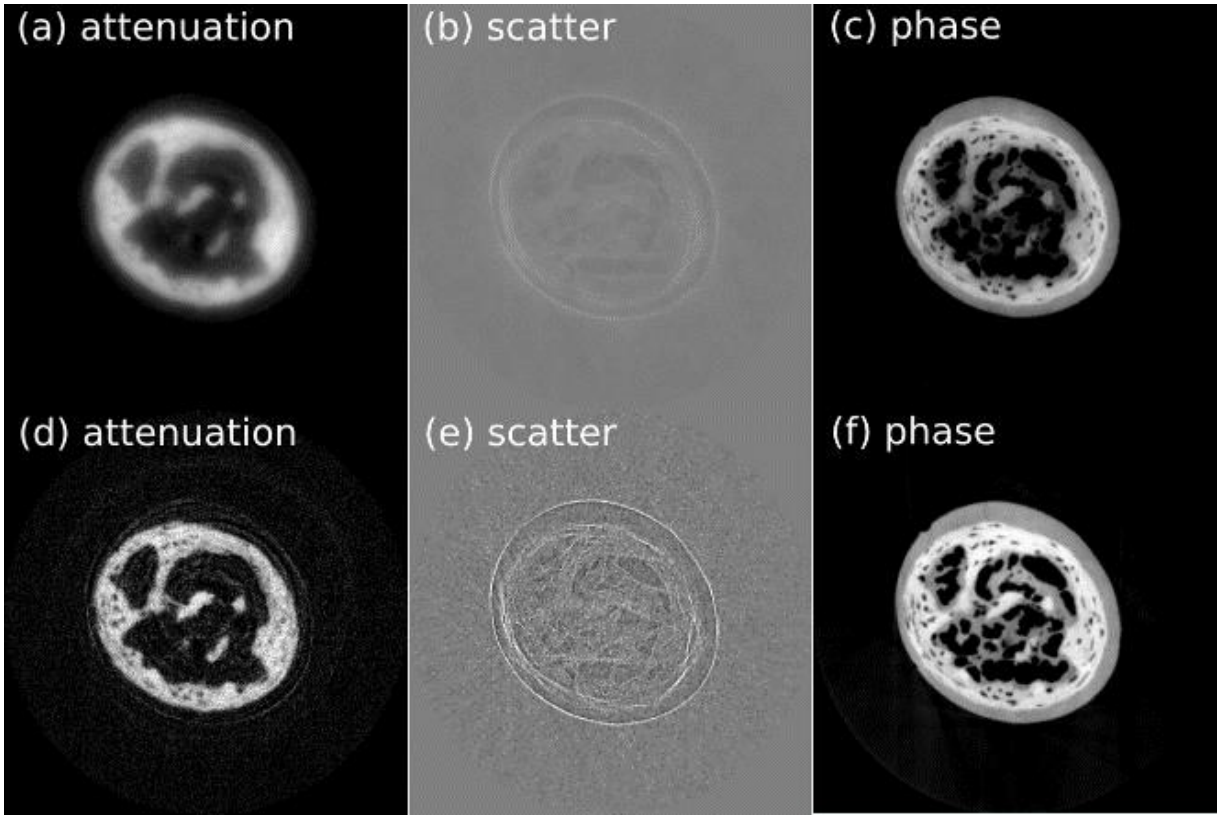

図 6 統計的手法により再構成した反復回数 16 でのマウス耳小骨サンプル．上段は FBP 前処理なし，下段は FBP 前処理あり．

相の 3 画像とも収束が非常に遅く，数百回の反復が必要である．これに対して，前処理ありでは数十回の反復で収束している．画像の変化から視覚的に判断すると，本実験の事例では収束に必要な反復回数は 10-20 ステップであった．

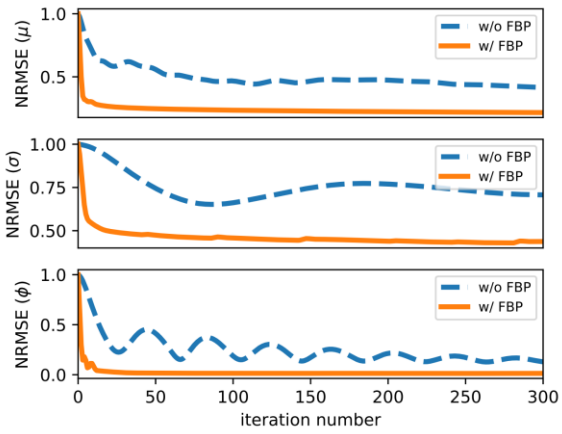

図 7 マウス耳小骨サンプル再構成における吸収(**μ**)，散乱(**σ**)，位相画像(**ϕ**)の NRMSE 値の推移．破線は FBP 前処理なし，実線は FBP 前処理あり．

5. 結論

近年報告された統計的同時画像再構成を用いれば，Talbot 干渉計を用いた X 線 CT 位相画像再構成における位相ステッピングの回数を削減できるとみられており[4, 5]，測定時間の短縮が可能となる．しかし，この手法では収束までの反復回数が多く，計算時間が長い問題があった．本論文ではこれを解決するため，FBP 組み込み型高速化法[6]を応用することで，反復回数を削減する手法を提案した．数値ファントム，及び Talbot 干渉計で測定されたマウス耳小骨小片試料の実画像を再構成するシミュレーション実験を行った．その結果，従来手法では 100 回以上の反復が必要であったが，本提案手法では 10-20 回で高精度に再構成でき，反復回数を大きく削減できることが示された．

謝辞

実験データを提供して頂いた慶應義塾大学の松尾光一教授，東北大学の百生敦教授に謝意を表する．本研究は JST ERATO JPMJER1403 の助

成を受けたものである．

利益相反の有無

なし

文　献

［1］ 百生敦: X 線位相イメージングの最近の展開．Med Imag Tech **24**:359-366，2006.

［2］ 木戸一博，巻渕千穂，清原淳子他: タルボ・ロー干渉計による X 線画像技術.Konica Minolta Tech Report **8**:82-85，2011.

［3］ 星野嘉秀，清原淳子，木戸一博他: X 線タルボ・ロー撮影装置における臨床研究.Konica Minolta Tech Report，**11**:53-56，2014.

［4］ A. Ritter，G. Anton，and T. Weber. Simultaneous maximum-likelihood reconstruction of absorption coefficient，refractive index and dark-field scattering coefficient in X-Ray Talbot-Lau tomography. PloS one，**11**:e0163016，2016.

［5］ B. Brendel，M. Teuffenbach，P. B. Noël，et al. Penalized maximum likelihood reconstruction for x-ray differential phase-contrast tomography. Medical Physics，**43**:188–194，2016.

［6］ H. Kudo，F. Yamazaki，T. Nemoto，et al. A very fast iterative algorithm for TV-regularized image reconstruction with applications to low-dose and few-view CT. Proc. SPIE，**9967**，996711，2016.

［7］ F. Pfeiffer，C. Kottler，O. Bunk，et al. Hard X-Ray phase tomography withlow-brilliance sources. Physical Review Letters，**98**:108105，2007.

［8］ P. Tseng. Alternating projection-proximal methods for convex programming and variational inequalities. SIAM Journal on Optimization，**7**:951，1997.

Acceleration of statistical image reconstruction in X-ray phase tomography

Ryosuke UEDA[*1], Hiroyuki KUDO[*1], Fukashi YAMAZAKI[*1]

*1 University of Tsukuba

Phase imaging can achieve higher contrast resolution in measurement of biological soft tissues than attenuation imaging. Recently, simultaneous statistical image reconstruction methods have been reported [4, 5]. The method can reconstruct attenuation, scatter and phase images directly from a set of measured moiré images. We expect that the method has some potentials, e.g., reduction of noise and measurement data. However, the method takes a large computational time. To resolve this issue, we improve the convergence speed of this iterative method. Our method is based on the FBP embedded-type acceleration method [6] developed in attenuation computed tomography. This acceleration method can reconstruct images with a small number of iterations by embedding the FBP structure in the iterative method. The original method was developed to solve the penalized weighted least square problem. We applied the method to solve the maximum likelihood problem. Using the proposed method, we reconstruct a numerical phantom and a real image of mouse bone sample measured by Talbot interferometer. We show the improvement of a convergence speed by the proposed acceleration method.

Key words: Computed Tomography, Phase imaging

テンプレート（全ての原稿の種類に共通） Ver. 2.1（2017.3.21 改訂）

4 方向撮影による胸部トモシンセシスの最適投影角の検討

堀　拳輔[*1]　董　居忠[*2]　岡本　啓公[*3]　関　将志[*3]　村石　浩[*1]

齊藤　典生[*2]　Thet-Thet-Lwin[*1]　原　秀剛[*1]　渡辺　宝[*1, 4]

橋本　雄幸[*5]　王　波[*2]　武田　徹[*1]

要旨

トモシンセシスは，現在肺がん検診に用いられる単純 X 線撮影と比較して結節検出能が高く，Computed Tomography (CT)と比較して低被ばくでの検査が可能である．しかし，従来のトモシンセシスは 60 方向程度の撮影に約 10 秒要するため，息止めによる患者への負担が大きい．提案する 4 方向撮影によるトモシンセシスは 1 秒以内で撮影可能となる．本研究では，4 方向撮影における最適な投影角について検討した．広角と比較して, 挟角での撮影では奥行方向の分解能は劣るが, よりコントラストよく結節を描出できた．検診応用を考えた時，挟角での撮影が適していることが示された．

キーワード：トモシンセシス，肺結節，胸部，ファントム，断層像

1. はじめに

現在，肺がん検診に用いられる単純 X 線像は，肋骨や肺内血管と重なる結節を見落としやすい．胸部病変の精査に CT が用いられているが，患者の被ばく線量が多い．胸部トモシンセシスは, 単純 X 線装置の X 線管を機械的に動作させ，異なる角度方向から投影像を収集することで，断層像を再構成する[1]．トモシンセシス像は，単純 X 線像と比べて高感度で肺結節を検出でき[2]，CT と比較して低被ばくで撮影可能である[3, 4]．しかし，従来法では，約 60 方向の撮影に 10 秒程度要するため，患者の息止め時間が長い．一方，本研究で提案するトモシンセシスは，小型の固定型 X 線管[5]を 4 個用い，1 秒以内で撮影可能となる．先行研究で，従来の 60 方向トモシンセシスと比べ，4 方向トモシンセシスは十分な画質を担保でき，臨床応用できる可能性を示した[6]．そこで，4 方向トモシンセシスにおける最適投影角を決定するため，視覚的及び定量的に検討した．特に，定量的評価に関しては，学会で報告する．

*1 北里大学大学院医療系研究科
〔〒252-0373 相模原市南区北里 1-15-1〕
e-mail: mm17042@st.kitasato-u.ac.jp
*2 つくばテクノロジー株式会社
*3 北里大学病院放射線部
*4 首都大学東京大学院人間健康科学研究科
*5 杏林大学保健学部

2. 方法

本実験では，単純 X 線撮影装置(Discovery XR656: GE Healthcare)を用い，種々の大きさの模擬結節(CT 値+100)を含む胸部ファントム(ラングマン: 株式会社京都科学)を 1°毎に回転させ，投影像を収集した．X 線管の管電

圧を 120 kVp，管電流時間積を 3.2 mAs/projection，撮影距離を 150 cm とした．収集した投影像から表 1 に示す 4 方向を選択し，Simple Back Projection 法により，トモシンセシス像を再構成した．

表 1 再構成に用いた投影角

収集角度範囲 [°]	収集角度 [°]
14	-7, -2, 2, 7
20	-10, -3, 3, 10
30	-15, -5, 5, 15
46	-23, -8, 8, 23
56	-28, -9, 9, 28
60	-30, -10, 10, 30

3. 結果

単純 X 線像と比較し，すべての 4 方向トモシンセシス像で，特に肋骨の重なりの影響があまり見られず，15 mm の模擬結節を明瞭に描出できた（図 1）．広角と比べて挟角撮影によるトモシンセシス像では，血管の重なりが多少目立つが，結節のエッジが保存され，高いコントラストで描出できた（図 1 B, C, D）．

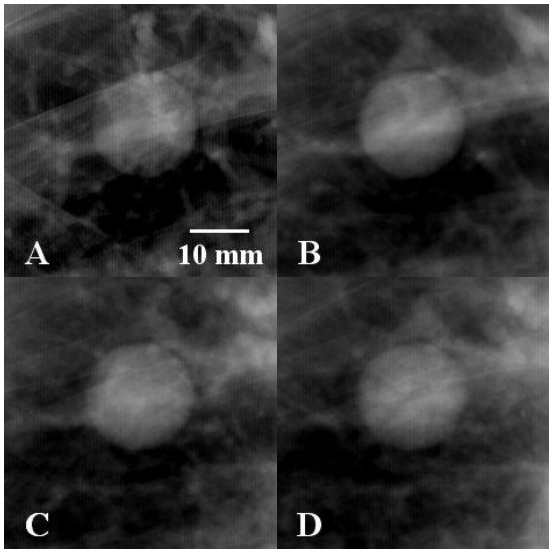

図 1 15 mm 模擬結節拡大像
(A) 胸部単純 X 線像, (B) 4 方向トモシンセシス像 (収集角度±10°), (C) 4 方向トモシンセシス像 (収集角度±23°), (D) 4 方向トモシンセシス像 (収集角度±30°)

4. まとめ

結節検出が目的の検診応用を考えた場合，挟角での撮影が適していることが示された．

謝辞

本研究は，一部，平成 28, 29 年度 戦略的基盤技術高度化支援事業 ポータブル 3D 表示装置の実用化開発 (受付番号: 2830812010)，北里大学医療衛生学部特別研究費補助 No. 2017-1013 の支援を受けた．ポータブル 3D 表示 X 線撮影装置 (特許番号: 第 6281119 号)が登録されている．

利益相反の有無

なし

文　献

［1］ James T. Dobbins, H Page McAdams: Chest tomosynthesis: technical principles and clinical update. European Journal of Radiology **72**: 244-251, 2009

［2］ James T. Dobbins III, H Page McAdams, Jae-Woo Song et al: Digital tomosynthesis of the chest for lung nodule detection: Interim sensitivity results from an ongoing NIH-sponsored trial. Med. Phys. **35** (6): 2544-2557, 2008

［3］ Magnus Bath, Angelica Svalkvist, Alexa von Wrangel et al: Effective dose to patient from chest examinations with tomosynthesis. Radiation Protection Dosimetry **139**: 153-158, 2010

［4］Robert J. McCunney, Jessica Li: Radiation risks in lung cancer screening programs. Chest **145** (3): 618-624, 2014

［5］王波，齊藤典生，劉小軍：特公 平 28-5967637, 2016

［6］堀拳輔，董居忠，岡本啓公，他：少数方向トモシンセシスによる肺内結節検出に関する基礎的検討．生体医工学 **56** (1):16-21, 2018

Evaluation of Adequate Projection Angle for 4 Projections Chest Tomosynthesis

Kensuke HORI[*1], Juzhong DONG[*2], Hiromasa OKAMOTO[*3], Masashi SEKI[*3], Hiroshi MURAISHI[*1], Norio SAITO[*2], Thet-Thet-LWIN[*1], Hidetake HARA[*1], Takara WATANABE[*1, 4], Takeyuki HASHIMOTO[*5], Wang BO[*2], Tohoru TAKEDA[*1]

*1 Kitasato University Graduate School of Medical Sciences

*2 Tsukuba Technology Co., Ltd.

*3 Department of Radiology, Kitasato Hospital

*4 Department of Radiological Sciences, Tokyo Metropolitan University

*5 Department of Medical Radiological Technology, Faculty of Health Science, Kyorin University

Tomosynthesis not only demonstrates higher sensitivity for nodule detection than currently used X-ray radiography in cancer screening, but also allows low exposure compared to Computed Tomography (CT). Since conventional tomosynthesis acquires 60 projection images over 10 sec, long breath-holding is difficult for patient. Proposed 4 projection tomosynthesis can acquire images within 1 sec. In this study, adequate projection angle was evaluated for 4 projections tomosynthesis. The nodule was depicted much clearly by narrow angle image, however, depth resolution was poor in comparison to wide angle image. Thus, narrow angle may be suitable for 4 projections tomosynthesis in clinical screening.

Key words: Tomosynthesis, Pulmonary nodule, Chest, Phantom, Tomography

X 線トモシンセシス装置における
金属アーチファクト補正技術の検討

山川　恵介[*1]　高橋　啓子[*2]　中村　正[*2]

要旨

近年, 乳房や整形で用いられるトモシンセシスにおいて, 代表的なフィルタ補正逆投影法（Filtered Back Projection method : 以下，FBP 法）[1]による画像では投影データの角度欠損により，金属と骨梁間等の吸収値差が大きい条件で金属アーチファクトが増加する．これを低減するため，断層画像撮影では画像の金属位置に基づく投影データの補間法が用いられるが，トモシンセシスでは位置毎の金属アーチファクトのばらつきが大きく画像上の金属抽出が困難で，境界の金属アーチファクト低減が不十分な場合がある．そこで，境界の画質向上を目的として，操作者の負荷を抑えつつ，投影データの 2 次元と投影角度方向を含む 3 次元を複合した領域拡張ベースの投影データ金属抽出法を提案する．これにより，周辺領域に対して抽出した金属の吸収値差を小さくし再構成することで，金属アーチファクトを低減できる．シミュレーションと整形用固定具を模擬したファントム実験において，周辺領域の画質を維持し高い金属アーチファクト低減効果が得られたので報告する．

キーワード：トモシンセシス，金属アーチファクト補正

1. はじめに

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

DT 装置は, 180 度以上の方向から撮影する X 線 CT と比較して, 20 度や 40 度の一部の投影角度で収集される為，角度欠損によりアーチファクトが発生する課題がある．FBP 法による DT 画像では，特に金属と骨梁間等の吸収値差が大きい条件で金属アーチファクトが増加する．これを低減する為，X 線 CT では画像の金属位置に基づく投影データの補間法[3]が用いられるが，DT 装置では位置毎の金属アーチファクトのばらつきが大きく画像上の金属抽出が困難で，境界部の金属アーチファクト低減が不十分な場合がある．そこで操作者の負荷を抑えつつ，領域拡張法[4]をベースとした高精度な投影データ金属抽出法を提案する．シミュレーションと整形用固定具を模擬したファントム実験において，周辺領域の画質を維持し高い金属アーチファクト低減効果が得られたので報告する．

*1 日立製作所　研究開発グループ
〔〒185-8601 国分寺市東恋ヶ窪 1-280〕
e-mail: keisuke.yamakawa.fd@hitachi.com
*2 日立製作所　ヘルスケアビジネスユニット

2. 方法

提案法では，機器出力された投影データから操作者が金属の一部を選択し，領域拡張法を用いて金属を抽出する．抽出後の金属に対して，周辺情報との差が小さくなるよう投影データの値を抑制する．次に金属抑制後の投影データに FBP 再構成を実施後，別途作成した金属画像の位置に基づき，DT 画像上の抑制された金属の値を復元する．これにより FBP 再構成時，金属と周辺情報の差が小さくなる為，金属アーチファクトを低減できる．領域拡張法では，各投影角度の 2 次元投影データ上でそれぞれ開始点の設定が必要である為，投影角度数が多くなるほど操作者に負荷を与えてしまう．そこで投影角度を含む 3 次元と各投影角度の 2 次元方向を複合することで，代表的な開始点のみを用いて，金属を抽出できる方法を提案した．

日立製 X 線透視診断装置の DT 機能を用い，X 線の照射条件は管電圧 75kV, 管電流 200mA, 撮影時間 20msec/投影，投影角度 40 度，投影数 59 とした．画像評価の為，図 1 に示すように整形外科用の人工股関節の装着に必要なスクリューを想定し，豚の骨に固定したファントムを用いた．画像のスライス位置は，天板から股関節の高さを踏まえて，天板から 85mm 離れた位置とした．

(a) ファントム概観　　(b) DT 画像

図 1 ファントム実験

3. 結果

従来の FBP 法，提案法において，金属挿入部を拡大した DT 画像を図 2 に示す．図 2 (a) の従来法では，X 線源の回転方向に相当する横方向への負値の金属アーチファクト成分（矢印 2 箇所）が大きいが，図 2（b）の提案法を用いることで低減でき，周辺組織の維持および金属アーチファクトに埋もれた組織情報を確認できた．

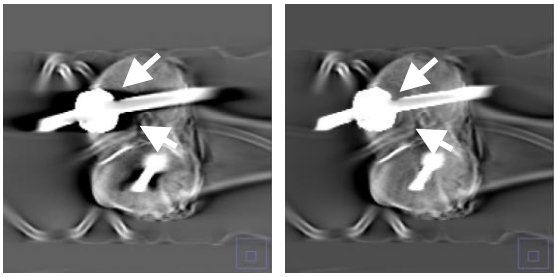

従来法　　提案法

図 2 豚の骨ファントムにおける
従来法，提案法の比較
（矢印：金属アーチファクト低減前後の箇所）

4. まとめ

本報告では金属アーチファクトを低減させる為，投影データの 2 次元と投影角度方向を含む 3 次元を複合した領域拡張ベースの投影データ金属抽出法を提案した．本方法は操作者が一部の開始点を選択するだけで，各投影角度の金属を抽出できる為，負荷低減の観点より提案法の優位性が期待できる．

利益相反の有無

山川恵介，高橋啓子，中村正は㈱日立製作所の社員である．

文　献

［1］Feldkamp, L. A., et al: Practical cone-beam algorithm. J. Opt. Soc. Am, A1, pp612-619, 1984

［2］H. Machida, et al: Whole-Body Clinical Applications of Digital Tomosynthesis. Radiographics, 36(3), pp735-750, 2016

［3］W. A. Kalender, et al: Reduction of CT Artifacts Caused by Metallic Implants. Radiology, pp576-577, 1987

［4］田村秀行編著：コンピュータ画像処理．オーム社，東京，2006, pp206-212

Evaluation of Metal Artifact Correction for X-ray Tomosynthesis

Keisuke YAMAKAWA[*1], Keiko TAKAHASHI[*2], Tadashi NAKAMURA[*2]

*1 Hitachi, Ltd. Research & Development Group

*2 Hitachi, Ltd. Healthcare Business Unit

X-ray Digital Tomosynthesis (DT) is one of medical diagnosis systems to image the patient's inner structure by sweeping the X-ray tube in X-ray digital radiography. The DT image reconstructed by limited projection angles causes metal artifact severely compared with CT acquired by over 180 degrees. Metal Artifact Correction (MAC) methods are proposed to reduce the metal artifact. In CT, the typical MAC detects metal from projection data by reconstructed image in Filtered Back Projection method (FBP). DT cannot utilize the reconstructed image because of enhanced metal artifact acquired by limited projection angles in FBP. We propose a new method to detect metal accurately from projection data, and reduce the metal artifact effectively. We applied region growing (RG) to detect metal from projection data. The RG needs the start point set by user. Because of the projection data acquired by many projection angles, it is very hard for user to set the points each projection angle. We propose MAC based RG by combination of 3D RG for growing the few points to other projection angles and 2D RG for growing the points furthermore. We compared the proposed method with the conventional FBP. In the phantom, the proposed method reduced the metal artifact close to metals.

Key words: Tomosynthesis, Metal Artifact Correction

フォトンカウンティング型 X 線 CT を用いた 金コロイド粒子の定量

上甲　拓巳[*1]　小沼　瑞稀[*1]　尾川　浩一[*2]

要旨

本研究の目的は，フォトンカウンティング型 X 線 CT を用いて金コロイド水溶液の濃度定量を行う際の発生光子数と定量精度を評価することである．本研究では，X 線のエネルギーを弁別することが可能なフォトンカウンティング型検出器を用い，得られた投影データに特異値分解法を用いて金コロイド粒子の分布を映像化し、定量する際の精度をシミュレーションによって検討した．具体的には，金コロイド水溶液の濃度が 3 wt%と 5 wt%の時に発生光子数を 20 万個から変化させると、どのように金コロイド水溶液の濃度の定量精度が変化するかを，モンテカルロ法を用いた光子輸送計算から得られた投影データを用いて検討した．その結果，金コロイド水溶液の濃度と発生光子数が定量精度に大きく関係することが明らかになった．

キーワード：X 線 CT，フォトンカウンティング，金コロイド，　特異値分解法

1.　はじめに

金コロイド粒子［1-3］をリガンドとして利用し、さまざまな標識を行うことにより特定の細胞に集積させることが可能となる。また、金の元素は 80.7keV に k 吸収端があり、X 線 CT におけるデータ収集においてエネルギースペクトルを計測することが可能ならば、金コロイドについての分布情報を得ることが可能になる。この結果、高空間分解能の X 線 CT 装置を機能イメージングのモダリティとして活用することが期待できる．

一方，現在、研究が進められているフォトンカウンティング型検出器［4］は，複数のエネルギーウィンドウを用いて光子数を測定するため、透過光子のエネルギースペクトルに関する情報が得られることになり、金コロイドの定量が可能となる．

*1 法政大学理工学研究科応用情報工学専攻

*2 法政大学理工学部応用情報工学科

〔〒184-8584 小金井市梶野町 3 丁目 7-2〕

e-mail: football.taku.0622@gmail.com

本研究では，フォトンカウンティング型検出器による金コロイド粒子の定量をシミュレーションによって検証した．具体的には，X 線の発生光子数と金コロイド水溶液の濃度を変化させ，モンテカルロ法を用いて光子輸送を行い，得られた投影データに対して，特異値分解法を用いて金コロイドの定量に関する評価を行なった．

2.　シミュレーション方法

本研究では，より臨床に近いように 3 次元の脳ファントムを使用し，その内部に球形の腫瘍部を設定し、金コロイド粒子を集積させた．　図 1 は 3 次元の脳ファントムの 64 スライス目を切り出したものである．腫瘍部分の直径を 6 mm とし，3 wt%ならびに 5 wt%の金コロイドを含む水溶液を想定した．　X 線管から放出された光子の数は，検出器画素 1 個あたり 20 万から 2 千個まで変化させた．

シミュレーションで使用したジオメトリを図 2 に示す．線源の前には厚さ 2 mm の Al のフィルタを置き，管電圧が 90 kV の X 線を照射するものと仮定した．また，X 線源と回転中心の距離は 720 mm

とし，回転中心と検出器間の距離は 80 mm とした．再構成画像は 128×128×128 (ボクセルサイズ : 0.5×0.5×0.5 mm^3)、検出器は 128×128 （ピクセルサイズ : 0.5×0.5 mm^2）で 1° ごとに 360 投影行った．画像再構成には ML-EM 法を使用し，反復回数は 150 回とした．データ収集のためのエネルギーウィンドウは，金コロイドの k 吸収端を考慮して bin0(51-60keV)，bin1(61-70keV)，bin2(71-80keV)，bin3(81-90keV)に設定した．

本研究では，定量性を評価するにあたり誤差率を式(1)で算出した．媒質の密度を理論値とし，再構成後の金コロイドが集積した領域の密度の平均値を実測値とした．

$$\text{Error ratio}(\%) = \frac{|\text{理論値} - \text{実測値}|}{\text{理論値}} \times 100 \qquad (1)$$

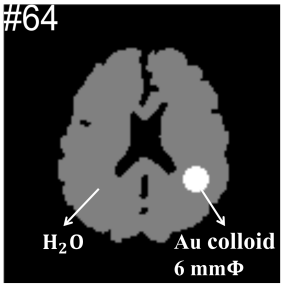

図 1. シミュレーションファントム

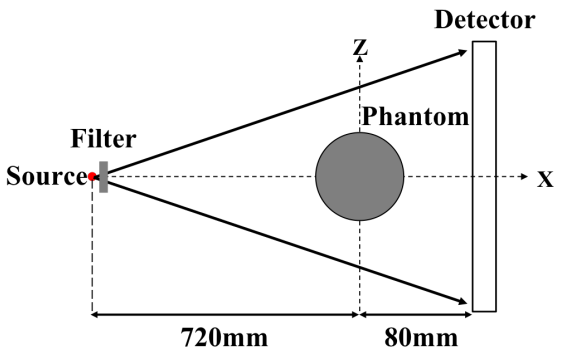

図 2. シミュレーションジオメトリ

3. 媒質分離の方法

X 線を照射した時のエネルギーウィンドウ $k\ (k = 0, 1, \cdots, K)$ において，対象物を透過せずに空気を透過して検出された光子数を$I_0(k)$，対象物を透過して検出された光子数を$I(k)$と書くものとする．CT の投影データ $T(k)$は，Lambert-Beer の法則から以下のように表せる．

$$T(k) = \log\left(\frac{I_0(k)}{I(k)}\right) \qquad (2)$$

これらの投影データは，それぞれのエネルギーウィンドウ k における媒質 n の質量減衰係数 $\mu_n'(k)$ と画素(i,j)における媒質 n の面密度$w_n(i,j)$の線形結合で式(3)のように表せる．また，面密度 $w_n(i,j)$は，(i,j) における媒質 $n\ (n = 1, 2, \cdots, N)$ の密度ρ_nと透過距離 d_n から式(4)のように表せる．

$$T(k) = \sum_{n=1}^{N} \mu_n'(k) * w_n(i,j) \qquad (3)$$

$$w_n(i,j) = \rho_n * d_n(i,j) \qquad (4)$$

行列形式で表現すると、

$$\begin{bmatrix} T(1) \\ \vdots \\ T(K) \end{bmatrix} = \begin{bmatrix} \mu_1'(1) & \cdots & \mu_N'(1) \\ \vdots & \ddots & \vdots \\ \mu_1'(K) & \cdots & \mu_N'(K) \end{bmatrix} \begin{bmatrix} w_1(i,j) \\ \vdots \\ w_N(i,j) \end{bmatrix} \qquad (5)$$

となり、投影データのベクトルを **T**，質量減衰係数の行列を **M**，面密度のベクトルを **w** とすると投影データは以下のように表すことができる．

$$\mathbf{T} = \mathbf{M}\mathbf{w} \qquad (6)$$

したがって，特異値分解法［5-6］を用いて，**M** の擬似逆行列 $\mathbf{M}^+$ を用いて **w** を求め、媒質分離を行った後の投影データを再構成することで金コロイド，および水の部分の密度を得ることができる．

4. 結果

発生光子数が 20 万個で，金コロイド水溶液の濃度が 3 wt%の水と金コロイド分布の再構成画像を図 3 に，また，発生光子数が 2 千個の場合のそれぞれの再構成画像を図 4 に示す．さらに，金コロイド水溶液の濃度が 3 wt%と 5 wt%の場合に関して、発生光子数の変化に対する金コロイド濃度の誤差率をそれぞれ表 1，表 2 に示す．また，図 5 には，X 線の発生光子数と金コロイドの濃度値の誤差率の関係を示す．

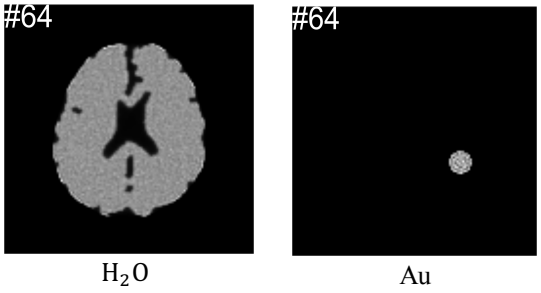

図 3. 分離後の再構成画像(発生光子数 20 万個)

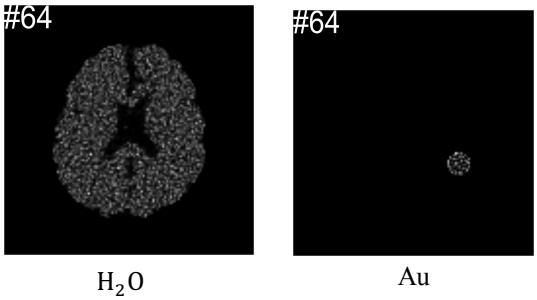

図 4. 分離後の再構成画像(発生光子数 2 千個)

表 1 金コロイド水溶液(3 wt%)における水と金コロイド濃度の誤差率

	発生光子数		
	20 万個	10 万個	5 万個
H_2O(97%)	0.30%	0.79%	1.96%
Au (3%)	0.71%	0.78%	2.28%

表 2 金コロイド水溶液(5 wt%)における水と金コロイド濃度の誤差率

	発生光子数		
	20 万個	10 万個	5 万個
H_2O(95%)	1.23%	0.74%	0.52%
Au (5%)	0.19%	0.22%	0.80%

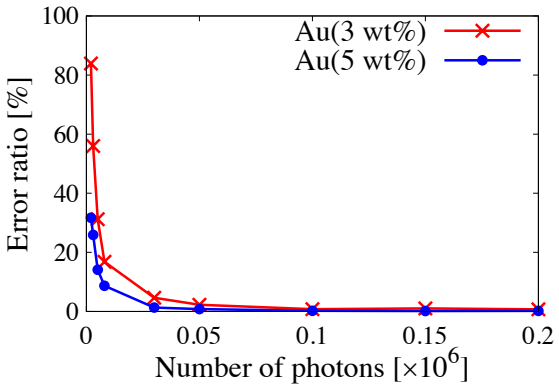

図 5. 発生光子数と誤差率の関係

5. 考察

図 3 と図 4 を比較すると，発生光子数の少ない図 4 の場合、画像は劣化していることが分かる．また，表 1,2 より，光子数が少なく金コロイド水溶液の濃度が低い方が測定精度は悪くなっていることが分かる．これは，光子が少なくなるにつれてエネルギースペクトルの測定精度が悪化し，特異値分解における精度が低下するためであると考えられる．しかし，発生光子数が 5 万個でも誤差率は 3%以下と高い精度で金コロイド水溶液の濃度定量できることが分かった．

また，図 5 から発生光子数によらず金コロイド濃度が低い方がより測定精度が悪いことが分かる．これは，金コロイド濃度が低い方が X 線の減衰量の変化が小さく，金のエネルギースペクトルの特性が現れにくくなるためだと考えられる．

6. まとめ

本研究では，フォトンカウンティング型検出器を用いた金コロイド水溶液の濃度定量のシミュレーションを行った．その結果，検出器の画素あたり5万個の光子数を用いることで，金コロイド水溶液の濃度が3 wt%の時は濃度推定の誤差率3%以下，金コロイド水溶液の濃度が 5 wt%の時の濃度推定の誤差率1%以下で金コロイド水溶液の濃度定量できることが明らかとなった．

謝辞

本研究にあたって，様々な面でお世話になった助手の村田一心博士に感謝します．

利益相反の有無

なし

文　献

[1] Kobayashi Y, Inose H, Nakagawa T, et al.: X-ray imaging technique using colloid solution of Au/silica core-shell nanoparticles. J Nanostruct Chemi, 6, 2013, pp.62-66

[2] Hainfeld JF, Slatkin DN, Focella TM, et al.: Gold nanoparticles: a new X-ray contrast agent. Brit J Radiol, 79, 2006, pp.248-253

[3] Takahashi S Matsuoka O: Cross placental transfer of ^{198}Au-colloid in near term rats. J Rad Res, 22, 1981, pp.242-249

[4] Ogawa K, Kobayashi T, Kaibuki F, et al.: Development of an energy-binned photon-counting detector for X-ray and gamma-ray imaging. Nucl Inst Meth Phy Res A, 664, 2012, pp.29-37.

[5] Maji T, Matsumoto M, Kaibuki F, et al.: Material decomposition using a singular value decomposition method. Conf Rec Nucl Sci Symp Med Imag, DOI: 10.1109/NSSMIC.2013.6829379, 2013.

[6] Firshing M, Butler AP, Scott N, et al: Contrast agent recognition in small CT using the Medipix2 detector. Nucl Inst Meth Res A, 607, 2009, pp-179-182.

肝臓がん検出器のための 3D-DCGAN を用いた学習用画像生成

池田 裕亮[*1]　小西 孝明[*1]　道満 恵介[*1]　目加田 慶人[*1]　縄野 繁[*2]

要旨

肝がんの読影は医師の目視で行われており，医師の負担軽減のため機械学習による読影支援が望まれている．しかし，機械学習に使用する多くの症例画像を集めるのは困難である．そのため，健常症例画像に病変画像を埋め込む研究がおこなわれている．本稿では深層学習の一種である DCGAN を用いて 3 次元的な人工病変画像を生成する手法について報告する．健常症例画像に対し病変を Poisson Blending 法と肝がんの濃度分布に基づく手法の 2 種類の方法で埋め込み人工病変画像を生成する．生成した人工病変画像を学習データとして利用することで，3D-DCGAN により人工病変画像が生成できることを示す．

キーワード：CT 画像，深層学習，コンピュータ診断支援，画像生成

1. はじめに

現在，肝がんを CT 画像から医師の目視により診断している．そのため医師の負担軽減のため機械学習による自動検出が望まれている．機械学習で利用する大量の症例画像を集めることは困難であるため健常症例画像に病変画像を埋め込む画像生成手法を開発している．

我々は 3 次元的な肝臓がんの人工病変画像を以下の 2 つの手法により生成した．

- Poisson Blending 法（PB 法）[1]
- シグモイド関数をベースに肝がんの濃度分布を模擬する方法（濃度分布法）[2]

また，二次元断面画像を Deep Convolutional Generative Adversarial Networks（DCGAN）[3] により生成した．
これらの人工病変画像を学習データとして畳み込みニューラルネットワーク（CNN）による肝臓がん検出手法を提案した[4]．ここで，人工的な病変画像の生成手法のうち，DCGAN による方法のみ 3 次元的な人工病変画像が生成できていないのは，学習データとして利用可能な実病変の数が少なかったことによる．

そこで本稿では，3D-DCGAN を用いて 3 次元的な人工病変画像を生成することを目的とする．3 次元的な濃度分布特徴を学習させるため，実病変画像の濃度分布に近い値を持つ PB 法や濃度分布法で生成した人工病変画像を学習データに用いる．生成した人工病変画像の性質について報告する．

2. DCGAN を用いた画像生成

提案手法では図 1(a)に示す肝がん実病変画像，同図(b)に示す PB 法で生成した画像，同図(c)に示す濃度分布法で生成した画像を学習データとし，3D-DCGAN による人工病変画像を生成する．学習に使用する人工病変画像の画像生成手法の種類と枚数を変えた 6 つの組合せを表 1 に示す．3D-DCGAN の学習には表 1 に示した人工病変画像の組合せと実病変 106 画像を用いる．

*1 中京大学 工学部
〔〒470-0393 愛知県豊田市貝津町床 101〕
e-mail: ikeda.y@md.sist.chukyo-u.ac.jp,
e-mail:{kdoman,mekada}@sist.chukyo-u.ac.jp
*2 国際医療福祉大学三田病院
e-mail: snawano@iuhw.ac.jp

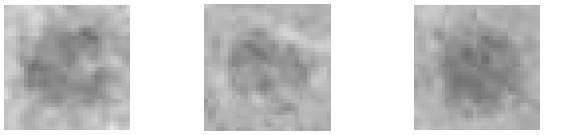

(a) 実病変　(b) PB 法　(c) 濃度分布法

図 1　3D-DCGAN の学習データ

表 1　人工病変画像生成法の組合せと枚数

組合せ	PB 法で生成した枚数	濃度分布法で生成した枚数
1	25	25
2	50	0
3	0	50
4	100	100
5	200	0
6	0	200

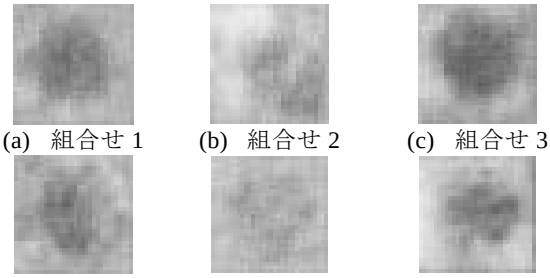

(a) 組合せ 1　(b) 組合せ 2　(c) 組合せ 3

(d) 組合せ 4　(e) 組合せ 5　(f) 組合せ 6

図 2 表 1 で示した組合せで学習した 3D-DCGAN の生成画像

3. 生成結果と考察

各組合せで 3D-DCGAN の学習をおこない，生成した画像を図 2 に示す．同図(b)および(e)はどちらも人工病変に PB 法のみを用いて生成した画像を使用したが，3D-DCGAN で生成された画像では病変の辺縁が不明瞭になるなど十分な質の病変画像が生成できなかった．これは PB 法で埋め込む際に，病変領域とその周辺領域の濃度変化を連続的に変化させる性質があるからである．これらと比較して，同図(a)，(c)，(d)，(f)は実病変画像に類似した病変を生成できていると思われる．このことから，実病変画像に加えて，PB 法や濃度分布法で生成した人工病変画像を用いることで，3D-DCGAN の学習が適切に収束することを確認した．ただし，図 3 に示すように実病変とは異なる画像も生成されることがあるため，ネットワーク構造の改善などが必要である．

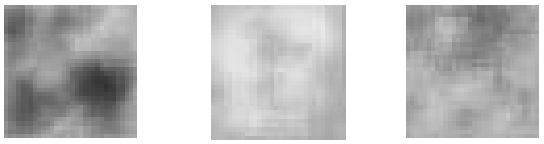

図 3　生成失敗例

4. まとめと今後の課題

3D-DCGAN を用いた肝臓がんの人工病変画像生成のために，学習データに PB 法や濃度分布法で生成した画像を用いた．実病変画像に，PB 法と濃度分布法で生成した画像を加えることで， 3D-DCGAN の学習が可能となり，条件によっては実病変に類似した特徴をもった病変画像が生成できることが確認された．

今後の課題として，3D-DCGAN のネットワーク構造の改善，回転や平行移動などのデータ増強手法の併用，生成された人工病変画像を利用した肝臓がん検出器の学習などが挙げられる．

謝辞

本研究の一部は日本学術振興会科研費補助金の援助による．

利益相反の有無

なし

文　献

［1］ P. Perez et al. “Poisson image editing”, ACM Special Interest Group on Computer 2003, pp.27-31, July 2003

［2］ 小西他，“人工的な病変画像を用いた 3D-CNN による転移性肝がん検出”, 電子通信学会 医用画像研究会(MI)技術研究報告, vol.116, no.393, pp.21-22, Jan. 2017

［3］ A. Radford et al. “Unsupervised representation learning with deep convolutional generative adversarial networks”, Int. Conf. on Learning Representations 2016, 67, May. 2016

［4］ T. Konishi et al. “Lesion image synthesis using DCGANs for metastatic liver cancer detection”, Int. Workshop on Frontiers of Computer Vision 2018, O4-4, Feb. 2018

Learning sample generation using 3D-DCGAN for a liver cancer detection

Yusuke IKEDA[*1], Takaaki KONISHI[*1], Keisuke DOMAN[*1], Yoshito MEKADA[*1], Shigeru NAWANO[*2]

*1 School of Engineering, Chukyo University

*2 International University of Health and Welfare Mita Hospital

It is demanded for computer-assisted detection which reduces the burden of the doctor, since the diagnosis of liver cancer is usually performed by a doctor's visual check. It is, however, difficult to collect a massive number of case images for machine learning. So far, we proposed three kinds of methods for generating 2D artificial lesion images: Poisson Blending, the CT-value distribution of liver cancer, and 2D-DCGAN. This research proposes a generation method of 3D artificial lesion images using 3D-DCGAN based on the 2D generation methods. Experimental results showed the effectiveness of the proposed method.

Key words: CT image, Deep Learning, Computer Aided Diagnosis, Images Synthetic

多時相造影 CT 画像を用いた腎臓解析

松下　和樹[*1)] 鈴木　秀宣[*2)] 河田　佳樹[*2)] 仁木　登[*2)] 飯沼　元[*3)]

要旨

近年,マルチスライス CT 装置の開発,発展により 3 次元画像による解析,診断が可能となった.CT 画像撮影時に造影剤を用いることにより,血管,臓器及び病変などが鮮明になり,より正確な情報を得ることができる.本報告では腹部造影マルチスライス CT 画像の時相による特徴を明らかにし,腎臓を抽出,分類することで腎臓画像解析を行う.

キーワード:CT, 腹部血管, 腎臓

■　背景, 目的

生活習慣や食生活の変化により,糖尿病,腎硬化症,糸球体腎炎を始めとする慢性腎臓病に成人の 8 人に 1 人がかかっており新たな国民病となっている.この慢性腎臓病は腎臓の機能が低下し始めた初期の段階では自覚できる症状がなく,血尿や尿が出にくいなどの自覚症状が現れた際にはすでに腎不全などに進行しており,完治が難しいため,早期発見が非常に重要である. 本研究は多時相造影 CT 画像を用いて, 腎臓を抽出し,造影剤の循環動態を解析することで腎機能を定量化し医師に有益な情報を提供することを目的とする.

*1 徳島大学大学院先端技術科学教育部システム創生工学専攻

〔〒770-8506 徳島県徳島市南常三島町 2-1〕

e-mail:c501738009@tokushima-u.ac.jp

*2)徳島大学大学院社会産業理工学研究部

*3)国立がん研究センター中央病院放射線診断部

■　CT 画像 撮影条件

国立がん研究センター中央病院で行われた大腸癌術前 CT 検査の画像を用いた. これらの画像は東芝社製 Aquilion PRIME(80 列 160 スライス)で撮影された造影マルチスライス CT 画像である. 撮影条件は管電流 230mA, 管電圧 120kV, 再構成間隔 0.5mm であり, 横隔膜から下腹部までの腹部全体を撮影している. 動脈相の画像はボーラストラッキング法で撮影されており,撮影時間は 22 秒~32 秒である.門脈相,平衡相の撮影時間はそれぞれ 60 秒,180 秒である.

■　手法

本手法は(1)多時相造影 CT 画像より腎臓を抽出(2)腎臓を腎皮質と腎錐体,尿管に分類(3)多時相における腎臓内の血管,腎皮質,腎錐体,尿管の CT 値の遷移調査,からなる.(1)多時相において造影 CT 画像より腎臓を半自動で抽出する.(2)抽出した腎臓を閾値処理を用いて腎皮質と腎錐体,尿管に分類する.(3)腎臓内の血管と腎皮質,腎錐体,尿管それぞれの多時相における CT 値遷移を解析することで腎臓内の造影剤の循環動態を明らかにする.

■　結果

造影 CT 画像より血管と腎臓の抽出を行った.ラベリング処理を用いて腎錐体を分割した.図 1 に腎臓抽出・分類アルゴリズムを示す.また図 2 に抽出した血管と腎臓データの 1 例を示す.腎皮質,腎錐体,尿管を部位別に分類し,それぞれの多時相における CT 値ヒストグラムをとった.その結果を図 3,図 4 に示す.そこで腎臓の造影剤循環動態が明らかになった.

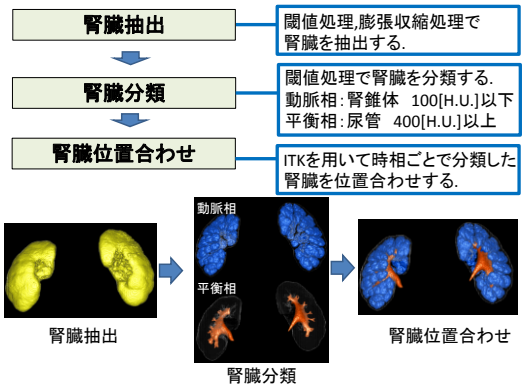

図 1.腎臓抽出アルゴリズム

赤色:動脈,青色:静脈,
黄緑:尿管,それ以外:腎錐体
図 2.血管・腎臓抽出結果

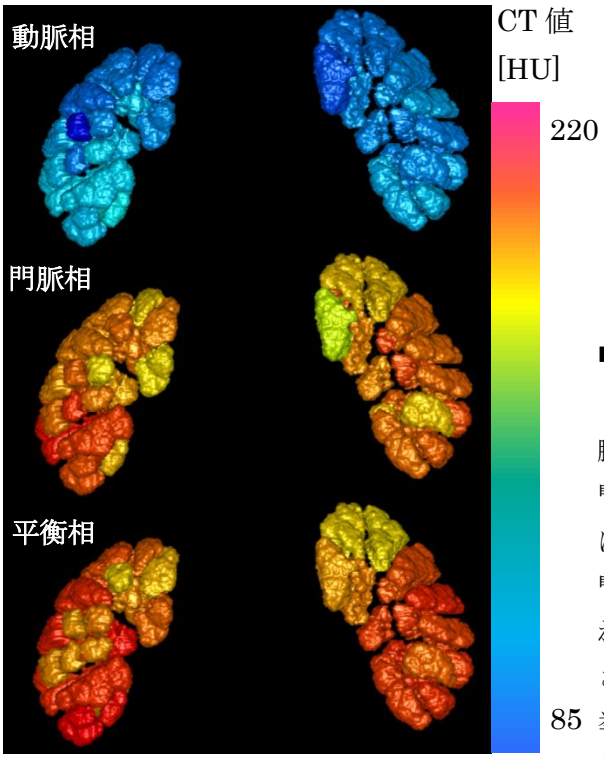

図 3.多時相における腎錐体の
CT 値レインボースケール表示

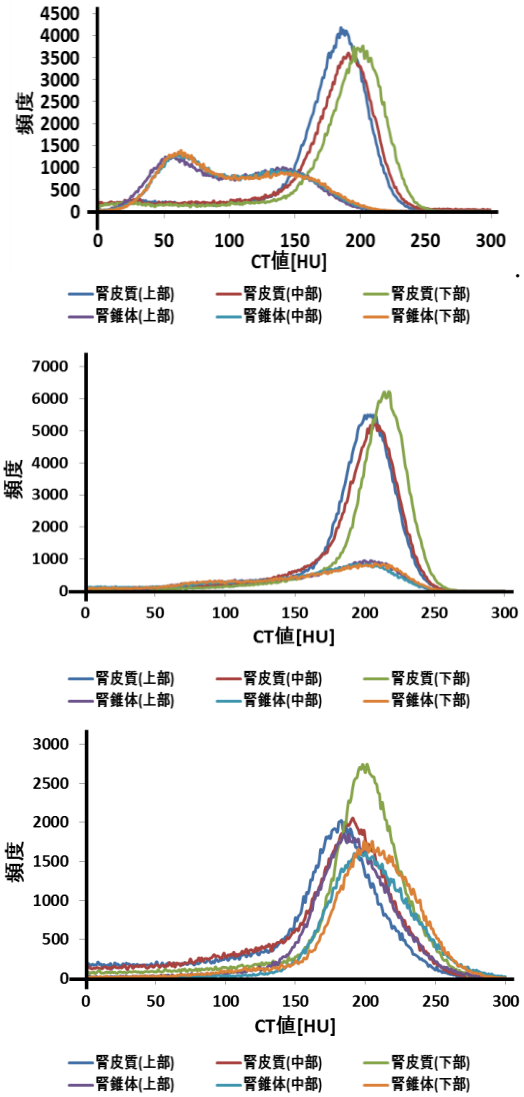

図 4.多時相における腎皮質と
腎錐体の部位別 CT 値ヒストグラム
(上:動脈相　中:門脈相　下:平衡相)

■　まとめ

造影マルチスライス CT 画像から血管と腎臓を抽出し,さらに詳細に解析を行うために腎臓を腎皮質,腎錐体,尿管に分類した. 時相による腎臓内の CT 値の遷移の調査を行った. 腎臓は上部から造影剤が循環する傾向が見られた.今後の課題として,症例数を増やしさまざまな症例と比較して解析を行うことなどが挙げられる.

利益相反の有無

無し

Analysis of abdominal blood vessel and kidney in multi-phase contrast CT

Kazuki Matsushita[*1)] Hidenobu Suzuki[*2)] Yoshiki Kawata[*2)] Noboru Niki[*2)] Gen Iinuma[*3)]

*1 System Innovation Engineering , Graduate School of Advanced Technology and Science, The University of Tokushima

*2 The University of Tokushima

*3 Radiology Division, National Cancer Center Hospital

In recent years, with the development of multi-slice CT apparatus, analysis and diagnosis by three-dimensional image became possible.By using the contrast agent at the time of CT image photographing, blood vessels, organs, lesions and the like become clear and more accurate information can be obtained.In this report, we analyze the kidney image by clarifying the characteristics of the abdominal contrast multislice CT image by time phase, extracting and classifying the kidneys.
Key words: CT, abdominal blood vessel,kidny

ResNet を用いた指骨 CR 画像からの骨粗しょう症の自動識別

畠野　和裕[*1]　村上　誠一[*2]　植村　知規[*1]　陸　慧敏[*1]

タン ジュークイ[*1]　金　亨燮[*1]　青木　降敏[*2]

要旨

骨の主な疾患として骨粗しょう症が挙げられる．骨粗しょう症に対する画像診断は有効であるが，医師の主観的な評価が主流とされている．それに伴い，医師の負担増加や経験差による診断結果のばらつきや病変部の未検出が懸念されている．そこで本稿では，指骨 Computed Radiography（CR）画像から骨粗しょう症の識別を行う，医師に提示するための診断支援手法を提案する．提案手法では，深層畳込みニューラルネットワークの一種である，Residual Network（ResNet）を用いた識別器を構築し，骨粗しょう症有無の識別を行う．ResNet の学習および識別には，CR 画像から生成した 3 種類の画像を用いる．実験では，101 症例に対し提案手法を適用し，Receiver Operating Characteristics（ROC）曲線上の Area Under the Curve（AUC）値を用いて評価したところ，最大で 0.931 という結果を得た．

キーワード：Computer Aided Diagnosis, Computed Radiography, Osteoporosis, Convolutional Neural Network

1. はじめに

近年，日本における人口の急速な高齢化に伴い，骨粗しょう症の患者が年々増加し，2015 年時点では約 1300 万人と推測されている．今後の高齢社会の進行とともに介護の問題と相まって，その対策が医療のみならず社会的にも重要な課題となっている[1].

一方，骨粗しょう症に対する画像診断は有効であるが，骨粗しょう症に類似した低骨量を呈する画像も多く，読影医師の経験の差から診断が異なり，客観性や診断の再現性に欠けることが知られている[2]．また膨大な画像枚数の読影や各画像から骨粗しょう症の患部を正確に読み取ることは非常に困難であり，多くの労力と時間が必要とされ，読影医師への負担が懸念されている．

これらの問題を克服するため，骨粗しょう症の定量的な評価を行うため，Kajihara ら[3]は，Computed Radiography（CR）画像から指骨領域の「自動抽出」，「自動位置合わせ」，「特徴量解析」の三つのステップによるコンピュータ支援診断（Computer Aided Diagnosis : CAD）システムを提案した．この中でも特徴量解析では，まず，指骨領域内部から抽出された関心領域（Region of Interest : ROI）に対し，16 種類の統計的特徴量を算出し，これらの特徴量から識別に有効であると思われる 2 種類の特徴量を手動で選定した．そして，こ

---

*1　九州工業大学
〔〒804-8550　福岡県北九州市戸畑区仙水町 1-1〕
*2　産業医科大学
〔〒807-8556　福岡県北九州市八幡西区医生ヶ丘 1-1〕

の 2 種類の特徴量から Artificial Neural Network（ANN）を用いた正常・異常の自動識別を行い，真陽性率（True Positive Rate : TPR）: 92.89[%], 偽陽性率（False Positive Rate : FPR）: 5.96[%] という結果を得た．しかし，先行研究の計測対象は正常例が 5 症例，異常例が 7 症例の計 12 症例であり, 汎用的な識別のためにはより多くの症例に対して適用する必要があった．また，新しい症例に応じた特徴量の手動選定では，識別の結果に影響を及ぼす可能性があることから，汎用性のある CAD システムの開発が求められている．

ところで近年，新たな機械学習の手法として深層学習に注目が集まっている．特に，画像認識に広く応用されている深層畳込みニューラルネットワークは，画像データから識別に有効な特徴量を自動で抽出し，効率的な学習が行え，様々なパターン認識分野において有効性が示されている．医用画像分野においても，この深層畳込みニューラルネットワークを用いた肺やマンモグラフィ，脳などを対象とした CAD システムの開発が数多く報告されている[4 – 7] ．我々[8]は，深層畳込みニューラルネットワークのモデルの一種である AlexNet[9]を識別器に用いた骨粗しょう症の識別法を提案した．CR 画像から基節骨，中節骨，末節骨をそれぞれ抽出し，各指骨内で骨粗しょう症が顕著に表れる矩形領域を選定し，識別器への入力として各矩形領域から生成した疑似カラー画像を用いたところ，TPR : 75.5[%]，FPR : 13.9[%]という結果を得た．この手法は，より多くの症例を対象とした深層学習による識別の可能性を見出すことが可能であったが，未だ識別精度に課題があった．

本論文では，多くの症例に対してより汎用的な識別を可能にした，骨粗しょう症の診断を行うための CAD システムの開発を目的とする．具体的には，被験者の両手を撮影した CR 画像の指骨領域に，解剖学的に骨粗しょう症の症状が顕著に表れる部分に ROI を設定し，深層畳込みニューラルネットワークのモデルの一種である Residual Network[10]（ResNet）を用いて自動で特徴を抽出し, ROI ごとに疾患の識別を行う．さらに，文献[8]における各指骨内の矩形領域のみを対象とした学習データではなく，各指骨全体を入力画像として用いる．提案手法を 101 症例の CR 画像に適用した結果について考察とその有効性を述べる．

2. 手法

入力画像の識別を行うため，ResNet を用いた識別器を構築する．ResNet の学習および，識別を行う入力画像には，指骨 CR 画像から生成した画像を用いる．本稿では，3 種類の入力画像を生成し，各画像で学習および，識別の評価を行う．以下に識別器への入力画像および，識別器についての詳細を述べる．

2. 1 入力画像の生成

入力画像は，両手を撮影した DICOM 形式の CR 画像（画像サイズ：2010×1670[pixel], 階調数：1024 階調（10[bits])）をビットマップ形式（階調数：256 階調（8[bits])）に変換して生成する．図 1 に指骨 CR 画像の例を示す. 以下に 3 種類の入力画像について述べる.

第一の入力画像は骨梁画像である．骨梁画像は骨粗しょう症の症状が顕著に表れる指骨領域内部に ROI を設定し, 40×40[pixel]の矩形で切り出す．骨梁画像では，骨梁の網目構造の複雑さや画像内の明るさ，濃淡変化の滑らかさに着目している. 正常症例は中節骨下部，基節骨上部と下部，中手骨の上部に ROI を設定し，手動で抽出する．異常症例は，より良い学習データの生成のため，中節骨下部，基節骨上部と下部，中手骨の上部のうち，骨粗しょう症の症状が表れている個所を放射線技師により選定し，ROI を設定する．

第二の入力画像は疑似カラー画像[8]である．骨梁画像は，単純に画像内のテクスチャ特徴のみを用いて正常・異常の識別を行うため, 識別に必要な情報量の不足が懸念される．そこで，CR 画像から 3 種類の画像を生成し，

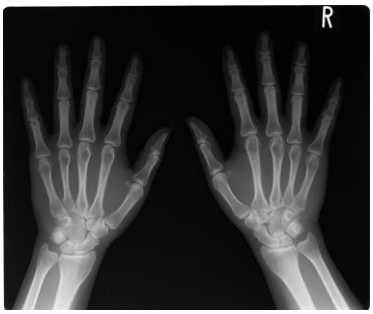

図 1 指骨 CR 画像の例.

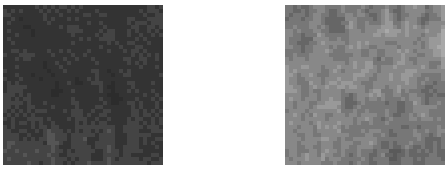

図 2　骨梁画像の例

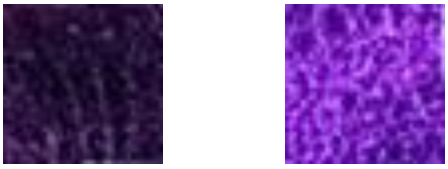

図 3　疑似カラー画像の例

図 4　指骨領域画像の例

各画像の同一の指骨領域内部から ROI を 40×40[pixel]の矩形で切り出した後，この 3 種類の ROI を R，G，B チャンネル（各 8 ビット）に割り当てた疑似カラー画像を生成し，学習および識別に用いる．疑似カラー画像では，骨梁画像では表現しきれなかった，骨梁の網目構造や濃淡変化を見ることができる．骨梁画像と比較した場合，疑似カラー画像を入力画像に用いることにより，識別精度の向上が見られた[8]．正常症例，異常症例に対する ROI の設定方法は骨梁画像と同様である．

第三の入力画像は各指骨領域画像である．この画像は骨梁画像，疑似カラー画像とは異なり，1 つの指骨領域全体を ROI とすることにより，より広い範囲の濃淡変化を見ることができるとともに，指骨の変形等の形状情報を用いることができる．指骨領域画像は CR 画像の指骨領域に対し，手動でラベリングを行い，指骨領域を抽出することで作成する．正常症例は中節骨, 基節骨に ROI を設定する．異常症例は，中節骨，基節骨のうち，骨粗しょう症の症状が表れている指骨を放射線技師により選定し，ROI を設定する．図 2 に骨梁画像の一例を，図 3 に疑似カラー画像の一例を，図 4 に指骨領域画像の一例をそれぞれ示す．

2．2　識別器の構築

近年，画像認識分野における一般画像認識において，深層畳込みニューラルネットワークは従来の手法を大きく上回る性能を示している．Support Vector Machine や ANN などの従来の一般的な識別手法では，手動で有効な特徴量を設計し，画像からの特徴量抽出を最適化しなければならない．しかし，深層畳込みニューラルネットワークは，識別に有効な特徴量を自動で抽出することができるため，識別結果が特徴量の設計者へ依存することを軽減するだけでなく，人の手では記述が困難な特徴量も設計することができる．

本手法では，深層畳込みニューラルネットワークモデルの一種である ResNet[10]を用いた識別器を構築する．ResNet は 2015 年の ImageNet Competition の最良モデルとして提案された．従来の畳込みニューラルネットワークは層を重ねるごとに高度で複雑な特徴を抽出することが可能なため，深層化を実現することは重要な課題であった．しかし，単純に層を深くすると勾配消失等が起きて性能が悪化する傾向があった．この課題に対して ResNet では，残差ブロック（Residual Block）を導入した．残差ブロックでは，通常の畳込みニューラルネットワークのように，ある層で求める最適な出力を学習するのではなく，層の入力を参照した残差関数を学習する．残差ブロックを導入した結果，層の深度の限界を押し上げるとともに, 精度向上を実現した．残差ブロックには様々な構造が提案されてい

表 1 モデルの詳細．Act. Func：Activation Function.

No.	Type	Kernel	Stride	Act. Func
0	Input	-	-	-
1	Convolution	3×3×16	1	ReLU
2	Residual Block	3×3×16	1	ReLU
3	Residual Block	3×3×32	1	ReLU
4	Residual Block	3×3×64	1	ReLU
5	Fully Connet	64	-	Softmax
6	Output	-	-	-

るが， 本稿では Full pre-activation[11]を用いる．Full pre-activation は，残差ブロックの前方に Batch Normalization を配置し，活性化関数（Rectified Linear Unit : ReLU），畳込み層と続いたのち，残差ブロックへの入力を足し合わせる構造となっている．本手法では，1 つの畳込み層，3 つの残差ブロック，1 つの全結合層で構成されたネットワークを用いる．各層の詳細を表 1 に示す．

3. 実験と結果

本実験で使用した画像は，産業医科大学病院で収集されたものでヘルシンキ宣言の倫理的原則に沿っており，倫理審査委員会の承認を得ている．本稿では CR 画像からの骨粗しょう症診断支援を行うための深層学習モデルを構築し，5 分割交差検証法に基づき，3 種類の入力画像別に構築したネットワークの性能評価を行う．なお，ResNet の学習時には，TensorFlow[12]で実装されている Momentum SGD（Stochastic Gradient Descent : 確率的勾配降下法）を用いて最適化を行う．ハイパパラメータは学習率を 0.001，バッチサイズを 10，最大エポック数を 50000，Momentum の減衰率を 0.9，重み減衰を 0.0002 とした．また，データ数の不足による過学習防止とデータ数の偏りを軽減するため，学習データに対してデータオーギュメンテーションを行う．具体的には，学習中に入力画像に対し，鏡像反転，ランダムクロップを行う．

実験では CR 画像 101 症例から，学習および，検証用データセットを生成する．各データセットにおけるデータ数の詳細を表 2 に示す．性能評価には Receiver Operating Characteristics（ROC）曲線上の Area Under the Curve（AUC）[13]を用いる．

実験結果の詳細として，図 5 に各入力画像で構築した識別器での ROC 曲線を，表 3 に各 ROC 曲線の AUC を示す．結果として，指骨領域画像を ResNet の入力画像に用いた場合，AUC が 0.931 という結果を得た．骨梁画像，疑似カラー画像を用いた場合と比較すると，AUC が最大で 0.29 と改善されたため，その有効性が確認できた．

4. 考察

表 3 より，指骨領域画像を入力画像として用いて識別器を構築したときの AUC が一番高い値を示している．骨梁のみを用いた手法と比較すると，文献[8]での疑似カラー画像を用いることにより識別精度の向上は見られたが，本提案法での指骨領域全体を加味した手法の性能には至らなかった．以上より，指骨 CR 画像から骨粗しょう症の識別を行うためには，指骨の全体的な特徴や情報が有効であると考えられる．

指骨領域画像を入力画像として用いた場合の識別結果の例を図 5，図 6 に示す．指骨の色は各指骨に対し識別を行い，そのときの骨粗しょう症に対する尤度の度合いを示す．赤色は尤度 0.8 以上，黄色は尤度 0.6 以上 0.8 未満，緑色は尤度 0.4 以上 0.6 未満，水色は尤度 0.2 以上 0.4 未満，青色は尤度 0.2 未満をそれぞれ表す．すなわち，正常症例では青い指

表 2 データセットの詳細.

(a)　骨梁画像・疑似カラー画像.

	異常症例	正常症例
Data 1	78	224
Data 2	78	224
Data 3	77	224
Data 4	77	224
Data 5	77	224

(b)　指骨領域画像.

	異常症例	正常症例
Data 1	71	112
Data 2	71	112
Data 3	71	112
Data 4	70	112
Data 5	70	112

骨ほど，異常症例では赤い指骨ほど良好な結果である．正常症例，異常症例ともにおおむね良好な結果が得られている．続いて，失敗した例とその原因について述べる．正常症例では，小指の末節骨，基節骨が異常症例と識別される症例が見られた．これは小指が人差し指，中指，薬指と比較した場合，骨の厚みがなく，濃度値も低いため，異常症例と識別された可能性がある．この対策として，指の種類や骨の種類別に識別器を構築することが挙げられる．また，異常症例では，手骨の形状が大きく変形した症例で失敗した例が見られた．指骨一つ一つの形状は大きく変形していないので，骨の脆弱化により骨梁の網目構造が潰れてしまったため，通常の異常症例とは異なる構造と識別されたと考える．この対策として，手骨の形状が大きく変形した症例と早期の症例ごとに識別器を構築することが挙げられる．

次にデータ数について述べる．表 2 に示すように指骨領域画像は他の 2 種類の画像と比較すると画像枚数が少量であった．深層学習における学習過程では，なるべく多くの学習データを準備する必要があるが，一般画像と比較するとデータ数を揃えることは困難で，医療画像でも入力画像やネットワーク構造を

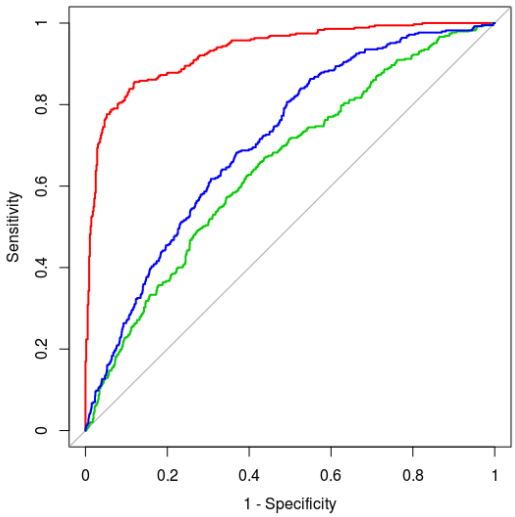

図 3 各入力の ROC 曲線．赤 : 指骨領域画像，青 : 疑似カラー画像，緑 : 骨梁画像．

表 3 各入力の AUC.

	AUC
骨梁画像	0.648
疑似カラー画像	0.711
指骨領域画像	0.931

工夫するなど，識別精度の向上を実現する必要がある．また，さらなる精度の向上には，正常症例･異常症例の 2 クラス分類ではなく，指の種類や症状別に多クラス分類を行う必要があると考える．これらを行うには，今後データ数を増加させる必要がある．

最後に，本手法では指骨の抽出を手動で行った．指骨領域画像を自動で生成するには精密な自動抽出法が必要と考える．また，自動抽出した指骨領域画像で識別性能を評価し，手動で抽出した場合と比較する必要があり，これらは今後の課題である．

5. まとめ

指骨 CR 画像から生成した入力画像と ResNet を用いた骨粗しょう症診断支援の識別器を構築し，5 分割交差検証法により性能を評価した. 結果として, AUC が最大で 0.931 という識別精度を得た．本手法では手動で指骨領域を抽出しているため，指骨の自動抽出

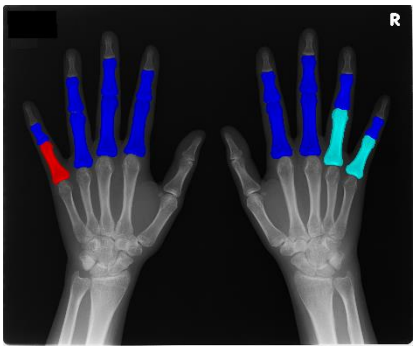

図 5 識別結果の例（正常症例）

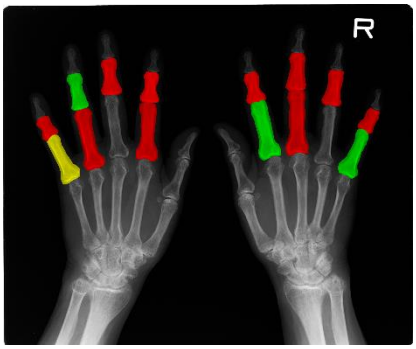

図 6 識別結果の例（異常症例）

法を実装するとともに，自動抽出した指骨で識別性能を評価する必要があり，これらは今後の課題である．

謝辞

本研究は，文部科学省科学研究費補助金(16K14279, 17K10420, 17K14694)，文部科学省卓越研究員事業補助金(16809746)の補助を受けている．

利益相反の有無　なし

文　献

［1］　折茂他：骨粗鬆症の予防と治療ガイドライン 2015 年版，ライフサイエンス出版株式会社，pp.1-76, 2015

［2］　村上他：CR(computed radiography) 踵骨画像を用いた骨粗鬆症の新しい評価法，日本放射線技術学会雑誌，Vol.59，No.10，pp.1285-1294, 2003

［3］　Kajihara et al.,:Identify Rheumatoid Arthritis and Osteoporosis from phalange CR images based on image registration and ANN, ICIC Express Letters, Vol.10, No.10, pp.2435-2440, 2016

［4］Wei et al., : Multi-scale Convolutional Neural Networks for Lung Nodule Classification, IPMI2015, pp.588-599, 2015

［5］　Setio et al.,: Pulmonary Nodule Detection in CT Images: False Positive Reduction Using Multi-View Convolutional Networks. IEEE Transactions on Medical Imaging. 35. 1-1. 10.1109/TMI.2016.2536809, 2016

［6］　Kallenberg et al.,: Unsupervised deep learning applied to breast density segmentation and mammographic risk scoring, IEEE Trans. Med. Imaging, pp.1322-1331, 2016

［7］Qi et al.,: Automatic Detection of Cerebral Microbleeds from MR Images via 3D Convolutional Neural Networks, IEEE Trans. Med. Imaging, pp.1182-1195, 2016, pp.2435-2440, 2016

［8］畠野他：DCNN による指骨 CR 画像からの骨粗しょう症の自動識別，Medical Imaging Technology，Vol.36，No.2，pp.90-95，2018

［9］Krizhevsky et al., : Imagenet Classification with Deep Convolutional Neural Networks, NIPS, 2012

［10］He et al., : Deep Residual Learning for Image Recognition, arXiv : 1512.03385 [cs.CV], 2015

［11］He et al., : Identify Mapping in Deep Residual Networks, arXiv : 1603.05027v3 [cs.CV], 2016

［12］TensorFlow, https://www.tensorflow.org/

［13］Akobeng : Understanding diagnostic tests 3 : Receiver operating characteristic curves, Acta Paediatrica, Vol.96, No.5, pp.664-647, 2007

Automatic Identification of Osteoporosis from Phalanges Computed Radiography Images Based on ResNet

Kazuhiro HATANO[*1], Seiichi MURAKAMI[*2], Tomoki UEMURA[*1], Huimin LU[*1],
Joo Kooi TAN[*1], Hyoungseop KIM[*1], Takatoshi AOKI[*2]

*1 Kyushu Institute of Technology
*2 University of Occupational and Environmental Health

Osteoporosis is known as a disease of bone. Visual screening using Computed Radiography (CR) images is an effective method for osteoporosis. However, subjective evaluation is a general method by the physician. With this, there are concerns about variation in diagnosis results and undetected lesions due to increased burden on doctors and experience. In this paper, we propose a diagnostic support method to distinguish osteoporosis from phalanges CR images and present them to doctors. In the proposed method, we construct a classifier based on Residual Network (ResNet) which is one type of deep convolution neural network, and identify the presence or absence of osteoporosis. For training and evaluating of ResNet, we use three kinds of images generated from CR images. In the experiment, we apply our proposal method to 101 cases and the 0.931 of the Area Under the Curve (AUC) value on the Receiver Operating Characteristics (ROC) curve was obtained.

Key words: Computer Aided Diagnosis, Computed Radiography, Osteoporosis, Convolutional Neural Network

著者紹介

畠野　和裕　(はたの　かずひろ)
2017 年九州工業大学工学部機械知能工学科知能制御工学コース卒，現在，九州工業大学工学府機械知能工学専攻知能制御工学コースに在籍中.
日本医用画像工学会会員.

CT 画像を用いた上腕骨頭 3 次元統計的形状モデルによる人工肩関節設計

久保有輝[*1]・新居　学[*1]・無藤智之[*2]・田中　洋[*2]

乾　浩明[*2]・信原克哉[*2]・小橋昌司[*1]

要旨

現在用いられている多くの人工肩関節の骨頭部分は球または楕円への近似で設計されている．しかし，同形状は実際の上腕骨頭形状を十分に表現しているとは言い難い．本研究では，人工肩関節設計の目安と成り得る 3 次元形状を把握するため，上腕骨頭の 3 次元統計的モデル(SSM)作成法を示す．本手法では，まず肩関節 CT 画像から上腕骨領域を抽出し，抽出領域から上腕骨形状に基づく座標系を決定する．求めた座標系を基準に位置姿勢を校正し，主成分分析によって上腕骨頭の SSM を取得する．実験では被験者 8 例から上腕骨頭 SSM を構築し，SSM による個人の生体肩形状に類似した人工肩関節モデル設計の可能性を示した．

キーワード：上腕骨，主成分分析，統計的形状モデル，人工肩関節

1. はじめに

変形性関節症などで損傷した上腕骨頭の治療法の 1 つとして，上腕骨頭を人工肩関節に置換する手術が適用される．その骨頭部分の形状は球または楕円状に近似した設計が多い．それらが一因で，健常時と比較して術後の肩の可動域は制限される．一方，骨頭形状の特徴を考慮した人工関節の有用性は確認されており［1］，個人の形状を再現するオーダーメイド型が理想的だが，コストの面から導入は困難である．

*1 兵庫県立大学大学院工学研究科
〔〒671-2280 兵庫県姫路市書写 2167〕
e-mail: kobashi@eng.u-hyogo.ac.jp
*2 信原病院
〔〒679-4017 兵庫県たつの市揖西町 720〕

本研究では人工肩関節設計の新しい設計法として，CT，MR 画像などの 3 次元断層画像を用いた上腕骨頭 3 次元統計的形状モデル(statistical shape model; SSM)を用いた設計法を提案する．

2. 使用データ

健常被験者の左腕 CT 画像 8 例を用いた．撮影断面は axial(体軸断)で，スライス厚は 1.25mm，スライス数は 601～705，スライス画素数は 512×512(pixel)である．被験者は同関節に顕著な疾患が見られない健常被験者 21～79 歳の男性である．同実験は信原病院の倫理委員会にてその実施が承認され，各被験者からは承認された手続きに従い，インフォームドコンセントを得た．図 1 に断層画像の一例を示す．

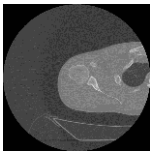

図 1 左腕 3 次元 CT 断層画像の一例

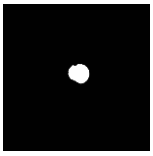

図 2 領域抽出結果

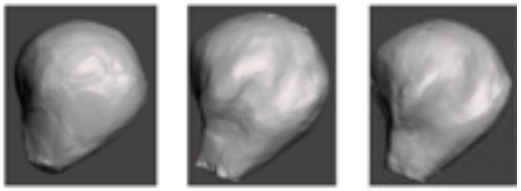

(a) -0.25σ_1　　(b)平均　　(c)+0.25σ_1

図 3 SSM に基づく人工肩関節形状モデル設計

3. 提案法

1）3 次元断層画像から上腕骨領域の抽出

各被験者の 3 次元断層画像から上腕骨領域を手動で抽出する. 抽出領域ボクセルには 1, それ以外には 0 を与える.

2）上腕骨座標系決定および位置姿勢の校正

各被験者において上腕骨座標系(x-y-z 座標系)を決定し，上腕骨形状に基づいた画像の位置合わせにより，被験者の位置，姿勢の正規化を行う．ここで座標系の原点は解剖頸の重心，x 軸は上腕骨の骨軸ベクトル，y 軸は x 軸と解剖頚面との外積とし，z 軸は x 軸と y 軸の外積とする.

3）3 次元統計的形状モデルの構築

位置姿勢を校正した上腕骨領域を符号付き距離に変換し，行がボクセルの距離値，列が被験者に対応する行列$\boldsymbol{F}$を作成する. 主成分分析は行列$\boldsymbol{F^T}$の共分散行列を固有値分解することで求められる. これを用いて SSM を構築する．平均形状$\overline{\boldsymbol{F^T}}$と主成分スコア$\boldsymbol{\theta}$の荷重和によって，個人形状$\widetilde{\boldsymbol{F^T}}$は再構築できる.

$$\widetilde{\boldsymbol{F^T}} = \overline{\boldsymbol{F^T}} + \boldsymbol{\theta V^T} \qquad (1)$$

ここで$\boldsymbol{V}$は固有ベクトルである.

4. 実験結果

図 1 に対する上腕骨領域の抽出結果を図 2 に示す．SSM による個人形状の再現性能を評価するため, 式(1)で各個人形状を再構築した. 各被験者の再構築形状と元形状との類似度 Jaccard Index(J.I.)を用いて精度評価した．平均 J.I.は 0.9991 であった. 実験結果より SSM は, 個人形状を高精度に再現できることを確認した.

5. 考察

上腕骨頭の個人間変動を考慮し，SSM を用いた人工肩関節形状モデル設計例を示す．形状パラメータを変化させて設計したモデルを図 3 に示す．中心モデルは平均形状，他モデルは平均形状に対して形状パラメータを ±0.25σ_1した形状である．ここで，σ_1は第 1 主成分スコアの標準偏差である.

個人間変動を考慮した人工肩関節モデルによる個人形状への類似度を評価するため，形状パラメータを-0.5σ_1，-0.25σ_1，0，+0.25σ_1，+0.5σ_1と変化させた 5 つのモデル（モデル A，B，C，D，E）を設計し，1 種類のモデル(パターン 1)，3 種類のモデル(パターン 2)，全 5 種類のモデル(パターン 3)において，各被験者と最も類似している人工関節を選択した場合の類似度(J.I.)を求めた. 表 1 にその結果を示す. 同表より，各パターンを用いた場合に残存する形状誤差率の平均がそれぞれ 0.58%，0.55%，0.52%となり，SSM に基づいた人工肩関節形状モデルを複数設計することで，より個人の生体肩形状に類似した人工肩関節を選択可能であることが確認された.

表 1 パターン別に残存する形状誤差率

被験者番号	パターン 1 (モデル C)	パターン 2 (モデル BCD)	パターン 3 (全モデル)
1	0.23%	0.20%	0.19%
2	0.18%	0.17%	0.17%
3	0.41%	0.37%	0.33%
4	1.94%	1.88%	1.84%
5	0.16%	0.16%	0.15%
6	1.08%	1.02%	0.98%
7	0.45%	0.41%	0.37%
8	0.20%	0.18%	0.17%
平均	0.58%	0.55%	0.52%
最大	1.94%	1.88%	1.84%

6. まとめ

本研究では SSM を用いた個人間変動を考慮した人工肩関節形状モデルの設計法を提案した．SSM 構築法を確立するとともに，SSM によるモデル設計の可能性を示した．今後の課題はモデルの有効性を評価するため被験者数を増加させる必要がある．

利益相反の有無　なし

文　献

［1］ BJ Jun, JP Iannotti, MH McGarry et al: The effects of prosthetic humeral head shape on glenohumeral joint kinematics: a comparison of non-spherical and spherical prosthetic heads to the native humeral head. J. of shoulder and elbow surgery 22: 1423-1432, 2013

Design of artificial shoulder joint using 3-D statistical shape model of humeral head with CT images

Yuki KUBO[*1], Manabu NII[*1],Tomoyuki MUTO[*2], Hiroshi TANAKA[*2]
Hiroaki INUI[*2], Katsuya NOBUHARA[*2], Syoji KOBASHI[*1],

*1 University of Hyogo
*2 Nobuhara Hospital

Currently, the humeral head portion of the artificial shoulder joint is mostly designed as a sphere or ellipse. However, it is hard to the design represent the individual shape. This research introduces a method to construct 3-D statistical shape model (SSM) of the humeral head toward the new design of artificial shoulder joint. Firstly, the humerus is segmented from CT images, and then anatomical coordinate system of the individual shape is determined. Secondly, each humerus is aligned to a common reference space by using the determined anatomical coordinate system of the humeral head. Finally, 3-D SSM of the humeral head is constructed by applying principal component analysis to the aligned images. In experiments, we constructed SSM using 8 subjects, and discusses the possibility of designing artificial shoulder joint approximating individual shape.

Key words: Humerus, Principal component analysis, Statistical shape model, Artificial shoulder joint.

符号化欠損領域情報の自動検出を想定した腹腔鏡画像の色情報解析と医用画像診断に関する考察

河畑　則文[*1]　中口　俊哉[*2]

要旨　筆者らは，今までに腹腔鏡画像の医用画像診断に関して，PSNR を用いて符号化画質の観点から応用可能かと検討した．しかしながら，PSNR では，カラー医用画像の色情報に関する影響が十分に測れていないことがあり，PSNR のみで符号化画質を判断するのは難しいという結論に至った．それゆえに，従来の PSNR による評価に加えて，色情報を用いて複数の画像特徴を考慮していくことが必要である．医用画像における符号化欠損や劣化は，各々特性や性質，使用状況が異なるため，最終的に，コンピュータによる自動診断システムを構築する必要がある．本論文では，内視鏡で撮影された腹腔鏡画像において，符号化欠損領域情報を付加し，視覚の空間周波数特性を考慮している S-CIELAB 色空間を用いて，色情報の解析を行い，医用画像診断に応用可能であるか，そして，符号化欠損領域情報の自動検出を想定した考察を行った．

キーワード：腹腔鏡画像, H.265/HEVC, PSNR, S-CIELAB 色空間, CIEDE2000

1.　まえがき

現在，工学分野における多視点 3D 画像及び 8K 高精細画像の医療応用が急速に進んでおり，手術支援のための画像処理技術に基づく新しい診断法の研究開発が日々進められている [1]. 手術支援には様々な方法が存在するが [2, 3], 本研究では情報工学から見る画像処理技術に基づく支援を考える．手術を行う際に，必ずディスプレイを注視して，どの部位を行っているかを逐一確かめており，画像がディスプレイに正しく表示されている必要がある．どの程度の劣化なら知覚するのかは明らかでないし，作業を行うにあたってはより少ない方が望ましい．筆者は今までに，多視点 3D 画像の符号化画質評価に関する研究を行ってきた [4]．その際に用いる画像は工学的な 3DCG 画像であり，非圧縮画像を用いてきた．しかし，本研究で用いる医用画像である腹腔鏡画像においては必ずしも非圧縮とは限らず，画質がいつも良い状況とは限らない．それゆえに，医用画像に対応可能な画像処理に基づく画像診断法を考える．

我々は，以前に，内視鏡で撮影された内視鏡で撮影された腹腔鏡動画像からフレーム静止画像として切り出した医用画像を用いて，ある画像領域において，H.265/HEVC 符号化を行い，評価画像を生成し，符号化欠損領域情報の自動検出を想定して，PSNR (Peak Signal to Noise Ratio)を用いることにより，符号化画質の観点から, 客観的な評価を行った [5]. 結果として，カラー画像では，色情報の影響が十分に PSNR に反映されていないことがあり，PSNR のみで符号化画質の判断は難しいのではないかという結論に至った．

本論文では, 内視鏡で撮影された腹腔鏡画像において，符号化欠損領域情報を付加し，視覚の空間周波数特性を考慮している S-CIELAB 色空間を用いて，輝度，CIEDE2000 を用いて，色差を各々測定することにより，色情報の解析を行った．最後に，総合的に，医用画像診断に応用可能であるか，そして，符号化欠損領域情報の自動検出を想定した考察を行った．

2.　関連研究

文献 [2]では，三次元画像情報を利用した医用画像診断支援を提案しており，仮想的に腹腔

*1 名古屋大学未来社会創造機構
〔〒464-8601 名古屋市千種区不老町〕
e-mail: norifumi@nagoya-u.jp
*2 千葉大学フロンティア医工学センター
〔〒263-8522 千葉市稲毛区弥生町 1-33〕
e-mail: nakaguchi@faculty.chiba-u.jp
投稿受付：2018 年 5 月 15 日

鏡手術をシミュレーションすることを可能にしている．文献 [6]では，腹腔鏡下手術において，2 つのカメラを配置した立体腹腔鏡を用いて，リアルタイム処理に適した三次元復元を目的とするアルゴリズムの提案を行っている．文献 [7]では，拡張現実に基づく手術支援として，内視鏡像への超音波画像重畳システムの提案，画像重畳の精度評価，動物実験による有用性について示している．

本研究では，画像情報分野からの医用工学分野の応用として，画像処理，符号化画質評価の観点から医用画像診断への応用を考えていく．

3. 実験

3.1. 本研究で使用した医用画像

本研究で用いた医用画像は，図 1 に示すように，内視鏡により，肝臓と胃の周辺を撮影した腹腔鏡下手術動画像 (約 15 秒間)をフレーム画像として切り出したものである．使用した動画像は特定の治療行為は行っていない．

3.2. 評価画像の生成と画像処理手順

評価画像の生成は，以下の手順で行った．

(1). まず，腹腔鏡下手術動画像（以下，腹腔鏡静止画像または動画像）をフレーム静止画像として切り出し処理を行う．本研究では，全部で 427 枚を切り出した．

(2). 次に，フレーム静止画像として切り出した 427 枚の腹腔鏡画像に対して，図 2 のように，71 枚間隔で 7 枚のフレーム静止画像を選択する．

(3). 7 枚のフレーム画像に対して，H.265/HEVC 符号化 [8]により，ある画像領域に符号化欠損処理を行う．

(4). 本研究では，図 3 に示すような 4 つの領域に分けて考え，符号化処理を行う．ここで，図 2 の$A = 1$は図 3 で示す画像領域で符号化処理をしていることを示す．

(5). 符号化欠損処理の後，腹腔鏡フレーム静止画像の原画像と評価画像に対して，PSNR (Peak Signal to Noise Ratio)を用いることにより，符号化画質を客観的に評定する．

(6). 全てのパターンについて，(5)の処理を繰り返し行い，各パターンを比較し，最終的に検出可能かどうかを判定する．

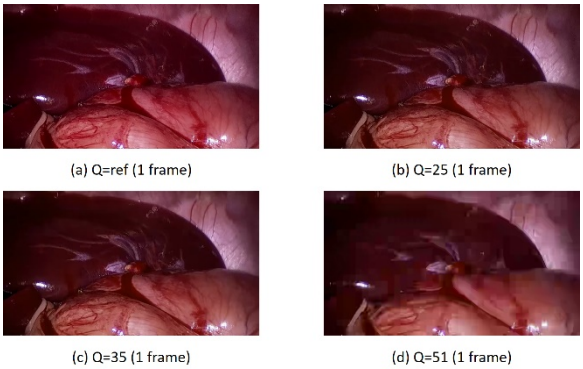

図 1: 本研究で使用した医用画像（腹腔鏡下手術動画像からフレーム画像として切り出したもの）

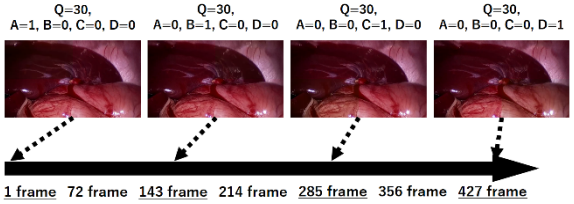

図 2: フレーム静止画像の概要

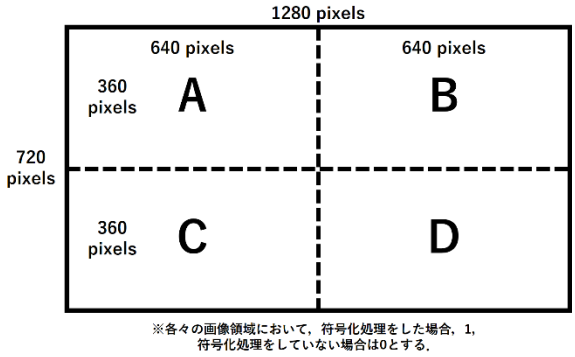

図 3: 本研究で用いる画像領域

3.3. S-CIELAB 色空間と CIEDE2000

3.2 節では，評価画像の生成と PSNR を用いて客観評価を行うまでの手順について説明した．本節では，図 4 に示すような，元画像と処理画像を読み込んで，S-CIELAB 色空間に変換して，L^*，そして，CIEDE2000 で ΔE_{00}を求めるフローチャートについて簡単に説明する．

3.3.1. S-CIELAB 色空間

L^*，a^*，b^*は式 (1)-(3)で表される．

$$L^* = \begin{cases} 116\left(\frac{Y}{Y_n}\right)^{\frac{1}{3}} - 16 & \left(\frac{Y}{Y_n} > 0.008856\right) \\ 903.3\left(\frac{Y}{Y_n}\right) & (otherwise) \end{cases} \quad (1)$$

$$a^* = \begin{cases} 500\left[\left(\frac{X}{X_n}\right)^{\frac{1}{3}} - \left(\frac{Y}{Y_n}\right)^{\frac{1}{3}}\right] & \left(\frac{X}{X_n}, \frac{Y}{Y_n} > 0.008856\right) \\ 500 * \left[\left[7.787\left(\frac{X}{X_n}\right) + \frac{16}{116}\right] - \left[7.787\left(\frac{Y}{Y_n}\right) + \frac{16}{116}\right]\right] & (otherwise) \end{cases} \quad (2)$$

$$b^* = \begin{cases} 200\left[\left(\frac{Y}{Y_n}\right)^{\frac{1}{3}} - \left(\frac{Z}{Z_n}\right)^{\frac{1}{3}}\right] & \left(\frac{Y}{Y_n}, \frac{Z}{Z_n} > 0.008856\right) \\ 200 * \left[\left[7.787\left(\frac{Y}{Y_n}\right) + \frac{16}{116}\right] - \left[7.787\left(\frac{Z}{Z_n}\right) + \frac{16}{116}\right]\right] & (otherwise) \end{cases} \quad (3)$$

ここで，X_n, Y_n, Z_nは標準光の下における完全拡散反射面の三刺激値である (RGB).

3.3.2. CIEDE2000

ΔE_{00}は式 (4)-(5)で示される．明度差ΔL^*，彩度差ΔC^*，色相差ΔH^*を基準として，重価係数(S_L，S_C，S_H)やパラメトリック係数 (K_L，K_C，K_H)等の補正を加える．

$$\Delta E_{00} = \sqrt{L^2 + C^2 + H^2 + (R_T CH)} \quad (4)$$

$$L = \frac{\Delta L'}{K_L \cdot S_L}, C = \frac{\Delta C'}{K_C \cdot S_C}, H = \frac{\Delta H'}{K_H \cdot S_H} \quad (5)$$

3.4. 実験内容

本研究では，大きく分けて，以下の 3 つの実験を行った．

1) PSNR による客観的評価
   (1). 腹腔鏡画像中の全体に符号化による欠損が生じた場合
   (2). 腹腔鏡画像中の 3/4 に符号化による欠損が生じた場合
   (3). 腹腔鏡画像中の 1/2 に符号化による欠損が生じた場合
   (4). 腹腔鏡画像中の 1/4 に符号化による欠損が生じた場合
2) S-CIELAB 色空間に変換して L^*を測定

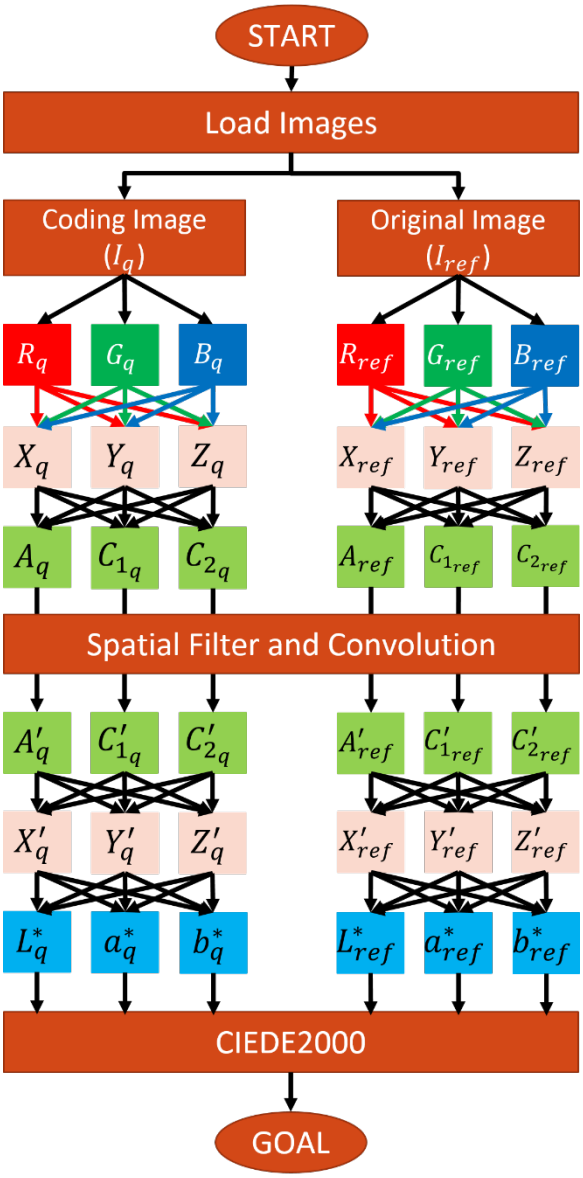

図 4: S-CIELAB 色空間と CIEDE2000 色差式 [4, 9]

3) CIEDE2000 を用いて，ΔE_{00}を測定

1)-3)を各々実験 1 (Exp. 1-1, 1-2, 1-3, 1-4)，実験 2 (Exp. 2)，実験 3 (Exp. 3)とした．

3.5. 実験方法と評価方法

実験方法としては，本研究では，コンピュータによる客観評価を主としているため，高精細ディスプレイや 8 視点パララックスバリアディスプレイを用いた多視点 3D 画像の主観評価実験は行っていない．実験の主な仕様としては，コンピュータの動作環境 (Windows 10 Pro, MATLAB R2016a)，画像の画面解像度 (1280×

表 1: 評価基準と検出想定基準

PSNR (dB)	評価（符号化画質）	評価（検出を想定）
50以上	非常に良い	ほとんど検出できない
45以上50未満	良い	あまり検出できない
40以上45未満	普通	まあまあ検出可能
35以上40未満	悪い	検出可能
35未満	非常に悪い	非常に検出可能

720 (画像全体に関して)，640×360 (画像領域に関して))である．

評価方法としては，客観評価指標 PSNR (Peak Signal to Noise Ratio)を用いた．PSNR はあるデータが元データからその程度劣化したかを表す指標である．値が大きいほど劣化は小さく，値が小さいほど激しい劣化になる．

本研究では，表 1 に示すように，PSNR が 50 以上を「非常に良い（ほとんど検出できない)」，45 以上 50 未満を「良い(あまり検出できない)」，40 以上 45 未満を「普通（まあまあ検出可能)」，35 以上 40 未満を「悪い（検出可能)」，35 未満を「非常に悪い（非常に検出可能)」とした．

4. 実験 1 の結果と考察

実験 1 は，PSNR の客観的評価を行っている．この部分は，以前の筆者らの文献[8]で詳細に議論しているため，簡単に以下に結果を述べる．

4.1. 実験 1-1: 全体領域

実験 1-1 は，腹腔鏡フレーム静止画像の全体領域に符号化欠損処理を行っている場合である．実験 1-1 の結果から，$Q = 20$で 45 dB 前後で「良い（あまり検出できない)」を満たし，$Q = 40, 51$は「非常に悪い（非常に検出可能)」と判断される．「普通（まあまあ検出可能)」に着目すると，$Q = 20, 25$のみ満たした．

4.2. 実験 1-2: 3/4 領域

実験 1-2 は，腹腔鏡フレーム静止画像のある 3/4 領域に符号化欠損処理を行っている場合である．実験 1-2 の結果から，“0111”以外のパターンに関しては，$Q = 51$で「非常に悪い（非常に検出可能)」と判断される．

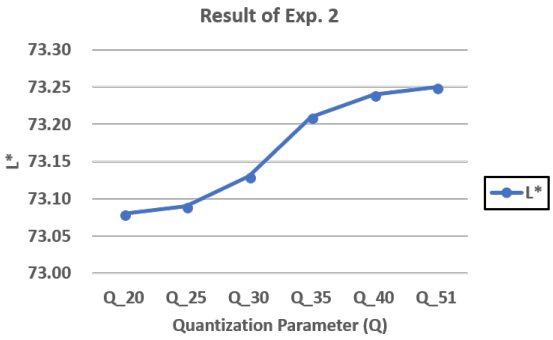

図 5: 実験 2 の結果

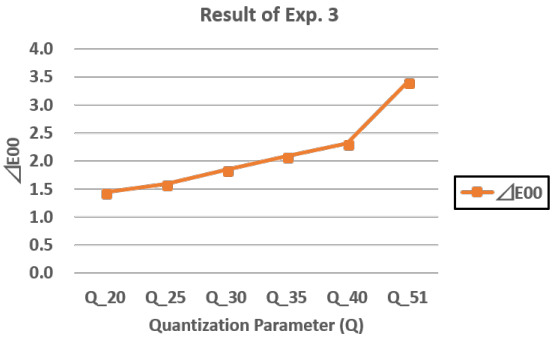

図 6: 実験 3 の結果

4.3. 実験 1-3: 1/2 領域

実験 1-3 は，腹腔鏡フレーム静止画像のある 1/2 領域に符号化欠損処理を行っている場合である．実験 1-3 の結果から，実験 1-1 や 1-2 のように符号化領域が大きい時と違い，パターン間の差分が大きくなっていることがわかる．

4.4. 実験 1-4: 1/4 領域

実験 1-4 は，腹腔鏡フレーム静止画像のある 1/4 領域に符号化欠損処理を行っている場合である．実験 1-4 の結果から，画像領域の下部分(“0010,” “0001”)の PSNR が上部分 (“1000,” “0100”)と比較して低いという結果となり，4 つの実験の中で，一番差が出ているのではないかと考えられる．

5. 実験 2 の結果と考察

実験 2 は，S-CIELAB 色空間に変換後の L^*で，図 5 の縦軸は L^*，横軸は量子化パラメータ Qを示す．符号化領域は考慮していない．実験 2 の結果から，$30 \leq Q \leq 35$で急激に上昇が見られるが，$20 \leq Q \leq 25$，$40 \leq Q \leq 51$でほとんど変化していない．このことから，QとL^*は比例の関係では無く，一定の収束をすることがわかる．

6. 実験 3 の結果と考察

実験 3 は，CIEDE2000 で求めた色差 ΔE_{00}を示す．図 6 の縦軸はΔE_{00}，横軸は量子化パラメータ Qを示す．符号化領域は考慮していない．実験 2 とは逆に，QとΔE_{00}は$Q < 40$で比例の関係にあるが，$40 < Q < 51$では急激な上昇が見られる．$Q = 20$と$Q = 51$では 2.3 倍程度の差が見られ，L^*とは違った結果となった．

7. まとめ

本論文では，腹腔鏡フレーム静止画像を用いて，符号化欠損領域情報の自動検出を想定して，従来の PSNR を用いて，符号化画質の客観的評価に加えて，色情報に関する議論を行った．

実験 1 の結果から，腹腔鏡画像の方が 3DCG 画像よりも劣化が知覚され易く，符号化欠損領域が小さい場合にパターン間における差分が大きくなり，部位の境界部分において客観的には劣化が知覚され易いことが明らかになった．

その後の実験 2 では S-CIELAB 色空間における輝度，実験 3 では CIEDE2000 における色差を測定した．実験 2 から，輝度に関しては，必ずしも Q の変化に応じて一定で変化していないという知見が得られた．一方，実験 3 から，CIEDE2000 色差については，$Q < 40$である程度一定で変化するが，Q の最小値と最大値で 2.3 倍程度の差があるという知見が得られた．

全体の結果から，PSNR で不十分な色情報に関して，S-CIELAB 色空間を用いて解決された．相互に見ていく必要がある．これらの知見は，医用画像診断にも応用できる結果といえる．

今後の展望としては，本研究の発展として，符号化欠損領域の検出に関するパターン認識の理論の適用，機械学習の適用，3D 画像 [10] や高精細画像の医用応用を進めていく．

利益相反の有無　無し

文　献

[1]. 山下紘正，谷岡健吉，千葉敏雄，“8K スーパーハイビジョンの医療応用”，信学誌 Vol.100, No.10, pp.1100--1105, 2017 年 10 月.

[2]. 森健策, “3 次元画像情報を利用した医用画像診断支援”，映情学誌 Vol.65, No.4, pp.448--452, 2011.

[3]. Y. Hayashi, K. Misawa, M. Oda, D. J Hawkes, and K. Mori, “Clinical application of a surgical navigation system based on virtual laparoscopy in laparoscopic gastrectomy for gastric cancer,” *Int'l J Computer Assisted Radiology and Surgery*, Vol. 11, Issue 5, pp.827--836, May 2016.

[4]. N. Kawabata and M. Miyao, “Multi-view 3D CG Image Quality Assessment for Contrast Enhancement Based on S-CIELAB Color Space,” *IEICE Trans. on Information and Systems*, Vol.E100-D, No.07, pp.1448--1462, July 2017.

[5]. 河畑則文，中口俊哉，“符号化欠損領域情報の自動検出を想定した医用画像診断の基礎検討”，信学技報, vol.117, no.432, IE2017-106, ITS2017-74, pp.77--82, 2018 年 2 月.

[6]. 岡田義道，小石毅，牛木卓，中口俊哉，津村徳道，三宅洋一，“腹腔内三次元復元を目的としたステレオ対応探索の高速化法”，*Med Imag Tech* Vol.25, No.5, pp.389--398, November 2007.

[7]. 小熊諒，中口俊哉，中村亮一，山口匡，川平洋，羽石秀昭，“腹腔鏡下手術用超音波プローブの屈折角検出を用いた内視鏡像への超音波画像重畳システム”，*Med Imag Tech* Vol.32, No.3, pp.203--211, May 2014.

[8]. F. Bossen, D. Flynn, and K. Sühring, “HM Software Manual,” https://hevc.hhi.fraunhofer.de/svn/svn_HEVCSoftware/, accessed May 15, 2018.

[9]. N. Kawabata, “Image Quality Assessment for Multi-view 3D CG Images and 5K High Definition Images Based on S-CIELAB Color Space,” *Proc. of IDW'17*, Vol.24, 3D5-1, pp.849--852, Sendai, Japan, December 2017.

[10]. L. T. Cook, S. J. Dwyer, S. Batnitzky, and K. R. Lee, “A Three-Dimensional Display System for Diagnostic Imaging Applications,” *IEEE Computer Graphics and Applications*, Volume 3, Issue 5, August 1983.

Consideration on Color Information Analysis of Laparoscopic Images and Medical Image Diagnosis for Automatic Detection of Coded Defect Region Information

Norifumi KAWABATA[*1] and Toshiya NAKAGUCHI[*2]

*1 Institutes of Innovation for Future Society, Nagoya University

*2 Center for Frontier Medical Engineering, Chiba University

In previous, we studied whether we can apply or not for medical image diagnosis of laparoscopic images from coded image quality field by using PSNR. However, PSNR is not measured sufficiently for affection on color medical imaging information. Therefore, we came to conclusion that it is difficult to judge coded image quality by the only PSNR. Therefore, we need to consider multiple image characteristics by using color information in addition to image quality assessment by using PSNR. The coded defect and degradation in the medical imaging field is each differenced for characteristics, nature, and status of use, comparing to image in the engineering field. Therefore, the automatic diagnosis system by computer is needed in addition to judgement by human eyes previously. In this paper, we used medical images as a frame still image cut from laparoscopic video filmed endoscope. First, we encoded and decoded for these images by H.265/HEVC, and then, we assessed objectively based on PSNR considering the coded image quality whether the automatic detection of coded defect region information is possible or not. Next, we analyzed for color information based on S-CIELAB color space including visual spatial frequency characteristics. Finally, we discussed for medical image diagnosis.

Key words: Laparoscopic Image, H.265/HEVC, Peak Signal to Noise Ratio (PSNR), S-CIELAB Color Space, CIEDE2000

ベイズ最適化法に基づく冠動脈 MRA 高解像度化のための Convolutional Neural Network の最適化

田中 滉大[*1]　中山 良平[*2]　小林 大輝[*1]　檜作 彰良[*2]
石田 正樹[*3]　北川 覚也[*3]　佐久間 肇[*3]

要旨

近年，CNN（Convolutional Neural Network）は医用画像の分類問題，回帰問題に応用され，優れた成果が報告されている．しかし，CNN は手動で設定すべきハイパーパラメータが多数あり，結果がハイパーパラメータに大きく左右される問題がある．本研究の目的は，冠動脈 MRA（Magnetic Resonance Angiography）画像の高解像度化のための CNN のハイパーパラメータをベイズ最適化により自動で決定することである．ベイズ最適化では，まず，実験試料の冠動脈 MRA 画像からベイズ最適化用のデータとして，無作為に少数データを選択する．次に，CNN のハイパーパラメータ探索にガウス過程によるサンプリングを行い，CNN の最適なハイパーパラメータを決定する．ベイズ最適化により決定したハイパーパラメータを用いた CNN による高解像度化画像の冠動脈 MRA 画像に対する RMSE（Root Mean Squared Error）および PSNR（Peak Signal-to-Noise Ratio）は，3.74，35.5 であった．ベイズ最適化を適用しなかった従来の CNN の RMSE，PSNR は 6.91，31.3 であり，冠動脈 MRA 画像の高解像度化におけるベイズ最適化の有用性が示唆された．

キーワード：ベイズ最適化，Convolutional Neural Network（CNN），高解像度化

1. はじめに

虚血性心疾患の効果的な検査法として冠動脈 MRA がある．冠動脈 MRA は放射線被曝が無く，造影剤を必要としないため患者に優しい非侵襲的検査法である．しかし，MR 装置の機構的な制約により CT（Computed Tomography）に比べ低解像，低画質な画像となり，臨床ではより高解像，高画質な画像が望まれている．

近年，低解像画像を高解像度化する手法として超解像技術に CNN を応用した研究が報告されている[1]．この手法では，参照用の低解像画像とそれに対応する高解像画像を局所領域に切り出し，それらの信号パターンの関係を CNN が学習することにより高解像度化を行う．

高精度な高解像度化が期待できる CNN であるが，その構成や学習法など事前に手動で決定しなければならないハイパーパラメータが多数あり，それらが不適切であると結果が著しく低下する問題がある．また，CNN において，ハイパーパラメータの組み合わせは膨大にあり，従来のグリッドサーチやランダムサーチによる最適なハイパーパラメータの探索は膨大な時間を要する．そこで，ベイズ推定を応用した CNN のベイズ最適化が提案されている[2]．この手法では，最適化を行うブラックボックス関数をガウス過程に従うと仮定し，ベイズ推定により事前の情報を取り入れ，事後分布に反映させることにより効率的にパラメータの最適化を実施する．

本研究では，ベイズ最適化を用いてハイパーパラメータを決定した CNN により，冠動脈 MRA 画像の高解像度化を行う．

*1 立命館大学大学院理工学研究科
〔〒525-8577 草津市野路東 1-1-1〕
e-mail: ri0051sk@ed.ritsumei.ac.jp
*2 立命館大学理工学部電子情報工学科
*3 三重大学附属病院中央放射線部

2. 方法

1）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 60 患者の冠動脈 MRA 画像である．これらは 32 チャンネル心臓コイルを搭載した 1.5 T MR システム（Philips 社製）により，自由呼吸，

ナビゲーターエコー法による呼吸同期, T2 ステップ法による心筋信号抑制，そして SPIR 法による脂肪信号抑制の条件下で撮影され，画像サイズは 512×512 pixel である．

2）ベイズ最適化によるパラメータの最適化

ベイズ最適化では，ハイパーパラメータと損失関数の関係をブラックスボックス関数の入出力とみなす．そして，ブラックスボックス関数をガウス過程に従うと仮定し，出力を最小化するパラメータの組み合わせを探索する．

まず，学習データから無作為に選択した標本点について，ガウス過程に基づいて事前分布を予測する．そして，以下の手順を繰り返し行うことにより，パラメータの最適化を行う．

1. ガウス過程モデルの更新
2. ベイズ推定により事前分布から事後分布を予測
3. 事後分布に基づき獲得関数を最小化する新しい標本点を計算

上記 1〜3 の処理を繰り返すことにより，40 のハイパーパラメータの組み合わせで CNN を学習し，最も高精度な高解像度化画像を出力する組み合わせを最適なハイパーパラメータとして決定する．本研究では獲得関数として，EI（Expected Improvement）を用いる．EI は事前に予測された値の局所領域だけでなく，大域的にも標本点を探索するため，局所解に陥りにくい特長がある．EI は次式により定義される．

$$EI(x, Q) = E_Q\left[\max\left(0, \mu_Q(x_{best}) - f(x)\right)\right]$$

標本点：x，事後分布：Q

最小の事後平均の位置：x_{best}

事後平均の最小値：$\mu_Q(x_{best})$

目的関数：$f(x)$

ここで，目的関数は RMSE（Root Mean Squared Error：平均平方誤差）を用いた．表 1 に最適化を行うハイパーパラメータとその探索範囲を示す．

3) CNN による高解像度化手法

高解像度化のための CNN は，対応する位置の高解像画像と低解像画像の信号パターンの関係を学習させる必要がある．そこで，まず，元の冠動脈 MRA 画像を高解像画像として定義した．一方，低解像画像は，高解像画像をダウンサンプリングすることにより，128×128 の縮小画像を生成し，それを Bicubic 法により，256×256 に拡大した画像で定義した．そして，低解像度画像を 11×11 の大きさのパッチ（局所領域）に分割し，CNN の入力とした．また，入力パッチに対する教師データとして，低解像パッチに対応する位置の高解像パッチを与え，CNN の出力値と教師データ間の RMSE が最小となるように CNN の学習を行った．

表 1 ハイパーパラメータとその探索範囲

ハイパーパラメータ	探索範囲
隠れ層の数	1 〜 5
フィルタサイズ	1, 3, 5, 7, 9
フィルタ数	16, 32, 64

CNN の学習には，確率的勾配降下法（SGD：Stochastic Gradient Descent）を用い，その学習係数は10^{-9}と設定した．また，ミニバッチサイズとエポック数はそれぞれ，128 と 100 である．

4）評価指標

本研究では，低解像 MRA 画像から生成された高解像度化画像の MRA 元画像に対する RMSE，および PSNR（Peak Signal-to-Noise：ピーク信号対雑音比）を用いて，提案手法の評価を行った．

RMSE は, MRA 元画像と高解像度化画像間の画素値の差を表す指標である．RMSE は次式で定義され，RMSE の値が 0 に近いほど誤差が少なく，元の MRA 画像に近い画像が得られたことを示す．

$$\mathrm{RMSE} = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(I - I')^2}$$

N：画像数

I ：高解像 MRA 画像

I'：高解像度化 MRA 画像

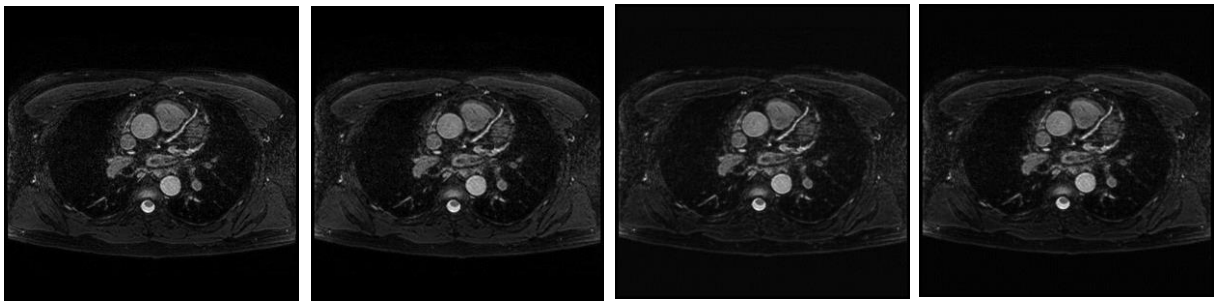

元のMRA画像　　Bicubic法による生成画像　　ベイズ最適化なしCNNによる生成画像　　ベイズ最適化ありCNNによる生成画像

図1　元のMRA画像，Bicubic法による生成画像，ベイズ最適化なしCNNによる生成画像，ベイズ最適化ありCNNによる生成画像による高解像度化画像の比較

PSNR は高解像度化画像が MRA 元画像と比較して，どの程度劣化したかを表す指標である．PSNR は次式で定義され，PSNR の値が大きいほど，劣化が少ないことを示す．

$$PSNR = 20 * log_{10}\left(\frac{MAX_I}{RMSE}\right)$$

MAX_I：高解像 MRA 画像の最大画素値

表 2 元の MRA 画像に対する忠実度

	Bicubic 法	ベイズ最適化なし CNN	ベイズ最適化あり CNN
RMSE	4.79	6.91	3.74
PSNR	33.1	31.3	35.5

3. 結果と考察

ベイズ最適化により決定されたハイパーパラメータを用いた CNN は，低解像 MRA 画像を 11×11 の大きさに分割した各パッチを入力とする入力層，7×7 の大きさのフィルタを 64 用意した畳み込み層，ReLU（Rectified Linear Unit）関数，7×7 の大きさのフィルタを 32 用意した畳み込み層，ReLU 関数，そして，全結合層と 3×3 の大きさの出力層で構成される．

図 1 に MRA 元画像，Bicubic 法による生成画像，ベイズ最適化なし CNN による生成画像，ベイズ最適化あり CNN による生成画像を示す．ここで，ベイズ最適化なし CNN は，我々の従来の研究において経験的に決定されたハイパーパラメータを使用し，11×11 のパッチを入力とする入力層，1×1 の大きさのフィルタを 64 用意した畳み込み層，ReLU 活性化関数，5×5 の大きさのフィルタを 32 用意した畳み込み層，ReLU 関数，そして，全結合層と 3×3 の大きさの出力層で構成される．ベイズ最適化あり／なし CNN による生成画像は，元の MRA 画像に比べノイズが低減された印象を受ける．しかし，ベイズ最適化なし CNN による生成画像は少しボケた画像となっている．

表 2 に Bicubic 法による生成画像，ベイズ最適化なし CNN による生成画像，ベイズ最適化あり CNN による生成画像の MRA 元画像に対する忠実度を示す．ベイズ最適化あり CNN による生成画像が他の手法による生成画像よりも，全ての指標において，忠実度が高い結果となった．

本研究では，CNN の隠れ層の数，フィルタサイズ，フィルタ枚数をベイズ最適化により決定した．今後は，学習率，バッチサイズ，エポック数などもベイズ最適化で決定することにより，更なる性能向上が期待できる．

4. まとめ

本研究では，ベイズ最適化を用いてハイパーパラメータを決定した CNN により，冠動脈 MRA 画像の高解像度化を行った．ベイズ最適化なし CNN より，提案手法による高解像度化画像の方が，元の MRA 画像に対する忠実度が高い結果を示し，その有用性が示唆された．

謝辞

研究遂行にあたり貴重なご助言を賜った三重大学医学部附属病院のスタッフの方々に深謝いたします.

利益相反の有無

なし

文　献

[1] Dong C, Loy CC, He K, Tang X: Image Super-Resolution Using Deep Convolutional Networks. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.38(2), pp.295-307, 2016.

[2] Mockus J, Tiesis V, Zilinskas A: The application of Bayesian methods for seeking the extremum. Towards Global Optimization 2, pp.117–129, 1978.

[3] Shahriari B, Swersky K, Wang Z, Adams R P, Freitas N, “Taking the Human Out of the Loop: A Review of Bayesian Optimization”, Proceedings of the IEEE, Vol.104, No.1, 2016.

畳み込みニューラルネットワークを用いたシネ MRI（Magnetic Resonance Imaging）の高フレームレート化

高瀬 唯人[*1]，中山 良平[*1]，檜作 彰良[*1]
石田 正樹[*2]，北川 覚也[*2]，佐久間 肇[*2]

要旨

本研究の目的は，畳み込みニューラルネットワーク（CNN: Convolutional neural network）を用いて，シネ MRI 画像の高フレームレート化を行うことである．本研究では，まず，通常撮影されたシネ MRI 画像を高フレームレート画像と定義し，高フレームレート画像から偶数番目フレームを間引くことにより，1/2 のフレームレートを有する低フレームレート画像を生成した．CNN の学習では，低フレームレート画像と高フレームレート画像をパッチ（小領域）に分割後，CNN の入力層に低フレームレートパッチを入力し，対応する位置の高フレームレートパッチを教師データとして出力層に与える．そして，CNN の出力値と教師データ間の Root Mean Squared Error（RMSE）が最小となるように CNN 内の重み係数を更新する．CNN により生成した高フレームレート化画像のシネ MRI 画像に対する RMSE，Structural Similarity Index, および Signal to Noise ratio は 6.376, 0.9975, 65.984 であった．従来の線形補間法では 6.618, 0.9970, 65.725 であり，CNN によるシネ MRI 画像の高フレームレート化の有用性が示唆された．

キーワード：シネ MR，畳み込みニューラルネットワーク（CNN），高フレームレート化

1．はじめに

心臓を対象とした MRI 撮影の一つで, 頻繁に用いられる方法として，シネ MRI 検査[1]がある. 非侵襲的で正確な診断が出来る MRI 検査であるが, CT 検査に比べて撮影に時間がかかり，音がうるさく，狭い装置内に長時間滞在する必要があるため，患者の体力的負担が大きい．特に，シネ MRI は，高いフレームレートの動画を撮るのに比例して撮影時間が増加する問題がある．当然，フレームレートを下げることで撮影時間の短縮は可能であるが，詳細な心筋の動きを把握できず, 診断能の低下を引き起こす[2].

近年，畳み込みニューラルネットワーク（CNN : Convolutional Neural Network）を用いて，解像度を向上させる超解像処理が報告されている[3,4]．これらの手法では，事前に多くの低解像画像とそれに対応する高解像画像を用意し，小領域に分割した低解像パッチと高解像パッチを用いて CNN に信号パターンの関係を学習させる．

本研究では，低フレームレートパッチと高フレームレートパッチの関係を学習させた CNN により, 低フレームレートのシネ MRI 画像を高フレームレート化した画像を生成する．

*1 立命館大学理工学部電子情報工学科
〔〒525-8577 草津市野路東 1-1-1〕
e-mail: ri0051rh@ed.ritsumei.ac.jp
*2 三重大学医学部附属病院放射線診断科

2．方法

1）実験試料

実験試料は，三重大学医学部附属病院の 3T MR 装置（フィリップス社）で撮像された健常ボランティア 6 名のシネ MRI を用いた. これらのシネ MRI の時間分解能は 20 msec である．

2）CNN による高フレームレート化

本研究で用いた CNN は，シネ MRI 画像を 15×15 の大きさに分割した各パッチを入力とする入力層，1×1 のフィルタを 64 枚用意した畳み込み層，ReLU（Rectified Linear Unit）活性化

関数，5×5 のフィルタを 32 枚用意した畳み込み層，ReLU 活性化関数，3×3 のフィルタを 32 枚用意した畳み込み層，ReLU（Rectified Linear Unit）活性化関数，3×3 のフィルタを 32 枚用意した畳み込み層，ReLU（Rectified Linear Unit）活性化関数，全結合層，そして，3×3 の大きさの出力層で構成される．

CNN の学習では，まず，シネ MRI 画像の偶数番目のフレームを間引きし，フレームレートを 1/2 とした低フレームレート画像を生成する．次に，線形補間法を用いて，低フレームレート画像の偶数番目にフレーム間の平均画像を補間することにより，元のシネ MRI 画像と同じフレーム数の低フレームレート画像を生成する．そして，平均画像とその前後フレーム画像の 3 枚 1 組を入力画像とし，それを切り出した 15×15×3 のパッチを CNN の入力とした．また，教師データとして，入力平均画像のフレームに対応する間引きした偶数番目のシネ MRI 画像において，入力パッチの中心位置にある 3×3 の領域を与えた．そして，CNN の出力値と教師データとの RMSE が最小となるように CNN 内の重み係数を更新した．

3）評価指標

本研究では，低フレームレート画像から生成された画像のシネ MRI 画像に対する RMSE, SSIM(Signal to Noise Ratio), および SNR(Signal to Noise Ratio)の 3 つの指標を用いて，提案手法の評価を行った．

RMSE は，シネ MRI 画像と高フレームレート化画像間の画素値の差を表す指標である．RMSE は次式で定義され，RMSE の値が，0 に近いほど誤差が少なく，元のシネ MRI 画像に近い画像が得られたことを示す．

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(I - I')^2}$$

N：画像の画素数

I：シネ MRI 画像

I'：生成画像

SSIM は，画素値，コントラスト，構造の 3 つの要素がどの程度変化したかを統合的に評価する指標であり，次式で定義される．

$$SSIM(x,y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}$$

μ_x, μ_y，σ_x, σ_y，そして，σ_{xy}はシネ MRI 画像と高フレームレート化画像の平均画素値，標準偏差，そして共分散値を示す．C_1, C_2は定数であり，C_1=$(K_1L)^2$，C_2=$(K_2L)^2$で与えられる．ここで，K_1, K_2は定数，Lが表示される画素値の最大値である．

SNR（Signal to Noise Ratio）は信号レベルに対する雑音レベルの比であり，雑音の大きさNに対する信号の大きさSの比で，次式で定義される．

$$SNR = \frac{S}{N}$$

SNR の値が大きいほど，雑音が少ない画像であることを示す．

3．結果と考察

図 1 にシネ MRI 画像，低フレームレート画像を提案手法および線形補間法で高フレームレート化した画像を示す．提案手法は線形補間に

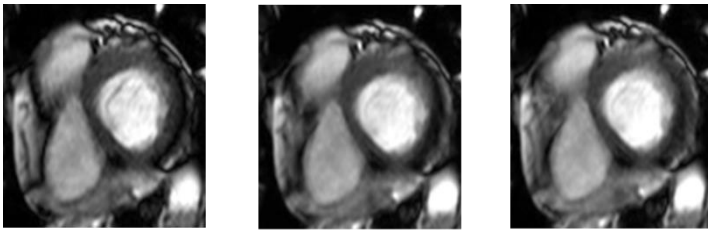

元画像　　提案手法画像　　線形補間画像

図1　元画像，提案手法により高フレームレート化した画像，および線形保管法による出力画像の比較

比べてボケが少なく，心壁の動きを忠実に再現できている印象を受ける．

表 1 に提案手法，線形補間法による高フレームレート化画像の元のシネ MRI 画像に対する忠実度の比較を示す．提案手法が線形補間法により得られた画像よりも全ての指標において，忠実度が高い結果となった．

フレームレート 40msec の低フレームレート画像でもフレームごとの変化量が少なかったため，提案手法と線形補間法の結果に大きな差は無かった．しかし，変化量の多い心壁部では提案手法による高フレームレート化画像が最も忠実に再現できた結果となり，臨床における有用性が示唆された．

表 1 元のシネ MRI 画像に対する忠実度

	提案手法画像	線形補間法
RMSE	6.376	6.618
SNR	65.984	65.725
SSIM	0.9975	0.9970

4. まとめ

本研究では CNN を用いて，シネ MRI 画像の高フレームレート化を行った．線形補間法より，提案手法による高フレームレート画像の方が，元のシネ MRI 画像に対する忠実度が高い結果を示し，その有用性が示唆された．

謝辞

研究遂行にあたり貴重なご助言を賜った三重大学医学部附属病院放射線診断科のスタッフの方々に深謝いたします．（本研究は JSPS 科研費 17K10399 の助成を受けたものです．）

利益相反の有無

なし

文　献

[1] O. Oshiro, A. Matani, K. Chihara. 3D visualization of myocardial motion and blood flow using cine-MR images. IEEE 06 August 2002

[2] Yudai Suzuki, Keigo Kawaji, Amit R. Patel. Toward effective noise reduction for sub-Nyquist high-frame-rate MRI techniques with deep learning. IEEE 08 February 2018

[3] Kathiravan Srinivasan, Avinash Ankur, Anant Sharma. Super-resolution of Magnetic Resonance Images using deep Convolutional Neural Networks. IEEE 27 July 2017

[4] Dong C, Loy CC, et al.: Image Super-Resolution Using Deep Convolutional Networks. IEEE 01 June 2015

スパースコーディングを利用した単一画像超解像に関する基礎検討

竹間 康浩 *1)，柴田 光貴 *2)，伊藤 聡志 *1)

要旨

MR 画像など画素数が少ない画像を観察する場合は，画像を補間拡大することが多い．このとき，単なる補間ではなく，超解像の効果があれば補間による‘ぼけ’や低解像度画像では確認できなかった情報を得ることができ，画像診断の精度を高めることが期待できる．eFREBAS 変換によりスパース展開された像は全て同サイズであり，かつ，周波数帯域別に分離した像は互いに相似性を持っている．そこで，eFREBAS 空間における展開像の相似性を利用し，eFREBAS 空間にて信号を外挿する方法について検討を行った．実験の結果，比較した学習型超解像に比べて鮮鋭度が高く，かつ，被写体の分布に近い補間拡大像が得られることを確認した．

キーワード: スパースコーディング, 超解像, 補間，eFREBAS 変換

1　はじめに

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

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

一方，再構成型超解像は，複数の異なる画像を利用する方法が多く，周波数空間の補間により高解像度画像を生成することも可能である [1, 2]．しかしながら，高解像度画像の全画素数を未知数とする問題を解くので画像生成に多くの時間を要する問題がある．近年，新たな超解像として学習型超解像が注目されている．これは，解像度の異なる学習用画像からパッチの対応関係を学習し，低解像画像にパッチの対応関係をあてはめて高解像度画像を推定するものである [3, 4]．学習型超解像は 1 枚の入力画像に対し，高解像度画像を推定するので単一画像超解像と考えることもできるが，学習されたパッチの対応関係には単一画像を超える情報量が含まれているので，単なる補間を超えた解像度の画像を生成できる可能性がある．学習型超解像では S/N 比を低下させずに輪郭が鮮鋭な画像が得られる利点があるが，画像の解像度改善は必ずしも大きくない．

本研究では，医用画像でも比較的画素数が少なく補間拡大処理がしばしば行われる磁気共鳴画像 (MR 画像) を対象とし，スパース性に基づいた単一画像超解像を検討する．MR 画像では，高解像度

*1 宇都宮大学 大学院工学研究科
情報システム科学専攻
[〒 321-8585 栃木県宇都宮市陽東 7-1-2]
e-mail:itohst@is.utsunomiya-u.ac.jp
*2 現在，JA 栃木中央会

のディスプレイ向きに補間処理されることが多いが，ゼロフィル補間や Bicubic 補間などでは，画像の鮮鋭さが失われる．そこで，画像のスパース表現に基づき，鮮鋭な画像を生成する新たな超解像的画像補間法を提案する．スパースコーディングとして eFREBAS 変換 [5, 6] を利用し，画像の高周波成分を推測して画像を拡大する手法をとる．そのため，単一画像超解像であるが，鮮鋭な画像の再生が期待される．

2 スパースコーディングを利用した画像補間

2.1 eFREBAS 変換

eFREBAS 変換はアルゴリズムの異なる 2 通りのフレネル変換が実質的に異なる標本化間隔を持つ性質を利用し，画像を任意のサイズでスケーリングする方法である．ここで，簡単化のため，一次元信号を扱うものとする．変数 Δx を入力画像の画素サイズ，N をデータ数，m をフレネル変換された信号の折り返しの次数を表す整数，D を画像のスケーリング係数とすると，eFREBAS 展開像 I_{scale} は以下の式により表現することができる [5, 6]．eFREBAS 変換では展開スケール D として任意の実数を選択できる．

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

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

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

2.2 画像補間アルゴリズム

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

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

式 (3) により得られた像を下記の制約付き最小化問題を適用する．

$$\mathrm{argmin}\left\{\frac{1}{2}||FI - EFI_L||_2^2 + \alpha||\Psi I_L||_1 + \beta||I_L||_{TV}\right\} \quad (4)$$

ここで，E は，信号のうち原点を中心として元画像と同じデータ数を抽出する処理を意し，Ψ はスパース化関数，$||\cdot||_{TV}$ は全変動 (Total Variation) ノルムである．

図 1 を使用して式 (3) のアルゴリズムを説明する．(a) に示す入力画像 I をスケーリング係数 $D = 3$ と $D + 2 = 5$ で eFREBAS 変換した像が，それぞれ (d) と (b) であり，$D \times D$ の数のサブ画像に分離される．図 (d) の外側の信号を良好に推定できれば超解像効果を持った画像拡大が可能となる．本研究では，eFREBAS 変換の階層的分布から，(e) の外側にある信号は，(b) の最外郭のサブ画像分布に近似している性質を利用した．すなわち，サブ画像のサイズが等しくなるように (b) の画像を $(D+2)/D$ 倍に拡大し．$L_{(D+2)/D}\Psi_{D+2} I$ を作成する．次に，緑色の枠で囲んだ最も外側のサブバンド像を抽出する操作 R_p により $R_p L_{(D+2)/D}\Psi_{D+2} I$ を (e) の eFREBAS 信号の外側に外挿する．そして，(e) の信号をスケーリング係数 D+2 で逆 eFREBAS 変換 (Ψ_{D+2}^{-1}) すれば，補間拡大された像を得ることができる．ただし，補間外挿した eFREBAS 信号は，誤差を多く含むので画像にはアーティファクトが生じる．そのため，スパース性を利用した誤差の軽減を式 (4) により行う．スパース性を与える Ψ の

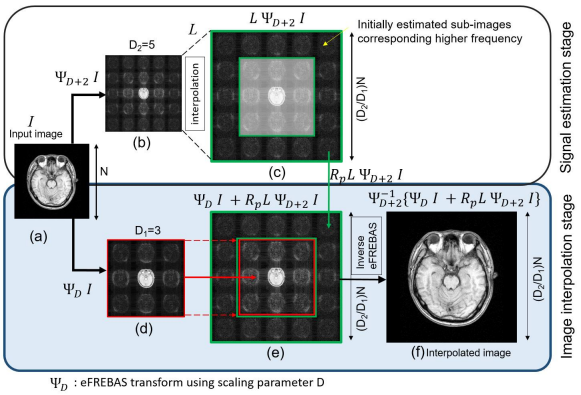

図 1: スパースコーディングに eFREBAS 変換を利用した画像の補間拡大アルゴリズム

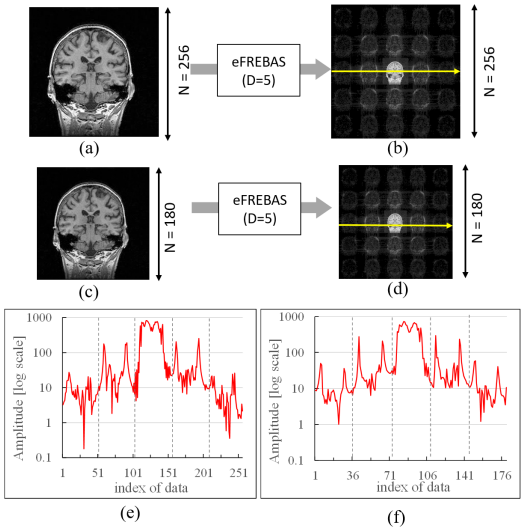

図 2: サイズの異なる入力画像に対する eFREBAS 展開像の相似性: (a) 256×256 画素の画像, (b) 画像 (a) の eFREBAS 展開像 (D=5), (c) 180×180 画素の画像, (d) 画像 (c) の eFREBAS 展開像 (D=5), (e), (f) それぞれ (b) と (d) の黄線上の信号強度分布

基底は，アーティファクト除去の観点から式 (3) で使用したものと異なる分布を持つ関数がよく，本研究では，スケーリング係数の異なる eFREBAS 変換を使用した．

3 画像拡大実験

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

提案手法を使用し，チャート画像の拡大を行った．図 3(a) に示す 256×256 画素の画像を用意し，そのフーリエ変換信号のうち，中央 128 ×128 点の信号から構成される帯域制限像を入力像 (b) とする画像拡大を行った．画像 (b) を図 1 のアルゴリズムに従い eFREBAS 変換の $D = 3$ で展開した像の外側に，$D = 5$ で展開し補間拡大した像を外挿した．$\alpha = 1.0 \times 10^{-6}$，$\beta = 1.0 \times 10^{-5}$とし，式 (4) の Ψ には，画像拡大に使用した基底と異なる eFREBAS 変換の $D = 4$ と 7 の基底を交互に使用した．展開スケール $D = 3$ と 5 を使用した場合に 128x128 画素の拡大像は，214($\approx 128 \times (5/3)$) 画素となるが，拡大率を 2 倍とするためにフーリエ変換空間のゼロフィル外挿を使用して 256×256 点に拡大した．式 (4) の解法には CSA(Composite Splitting Algorithm)[7] を使用した．反復処理を 5 回として結果を図 3(c) に示す．比較のために行った Yang らの方法 [8] による拡大像を同図 (d) に示す．図 (e) と (f) は，それぞれ (c) と (d) の黄線上の輝度値分布である．図 (e) と (f) などから提案法による拡大図は，中央寄りに線が密になる領域でも線の分離が良好であり，Yang らの方法に比べて分解能が高く，鮮明な画像が得られている．また，矢印の部分をみると Yang らの方法は，入力画像のジャギーをそのまま拡大した形で輝度値の不連続部分が生じているが，提案法では滑らかに線が繋がる形の像を構成している．図 3 は規則的，かつ輝度値が 2 値的である特殊な画像への応用例であるが，提案法

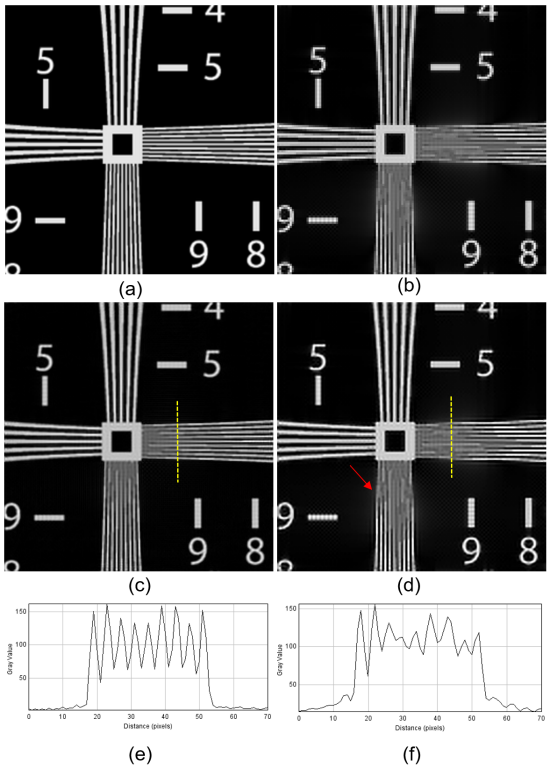

図 3: チャート画像の拡大結果: (a) 目標とする高分解能画像 (256×256 画素), (b) 入力画像として使用した (a) の帯域制限画像 (128×128), (c) 提案法による拡大像, (d) Yang らの方法, (e) (f) 提案法と Yang らの方法の黄線上の輝度値分布

による拡大像は鮮鋭な画像が生成されることが示された．

次に MR 像を対象とした画像拡大実験を行った．文書により同意を得たボランティアに対しキャノンメディカル製 1.5T MRI を使用して撮像された 10 種類の頭部像を使用した．提案法と比較法として Yang の方法，Bicubic 法および MR 画像で使用されることの多いゼロフィル再構成による拡大を行った．ゼロフィル再構成は信号空間の両端にゼロデータを外挿し，逆フーリエ変換を行うものであり，sinc 関数補間に相当する．256×256 画素の MR 画像を図 3 と同様な手法で 128×128 画素の画像に縮小し，縮小画像を 2 倍に拡大する実験を行った．評価方法は，目標画像との平方平均二乗誤差を画素値の最大値との比を取る PSNR(peak signal-to-noise ratio)，および画像が持つ構造的な特徴の保存性を評価する SSIM (structural similarity index)[9] を使用した．

表 1　PSNR と SSIM の比較

	Sparse SR (Proposed)	Yang's SR	Zerofill Recon	Bicubic
PSNR	28.51	28.64	28.01	24.81
SSIM	0.883	0.880	0.879	0.861

$$\mathrm{PSNR} = 20\log_{10}\frac{\max[I_L]}{\mathrm{RMSE}} \tag{5}$$

Yang らの方法を使用する際に，PSNR と SSIM の評価に使用した画像は提案法で使用した帯域制限による縮小画像ではなく，Lanczos 法による縮小画像を使用した．これは，画像サイズが偶数であり，画像空間の原点に対して左右の点数が非対称であること，および畳み込み積分による縮小画像が作成されることにより 1/2 画素の位置ずれが生じ，画像を拡大する際にも位置ずれがそのまま残って PSNR の計算を正しく行えないためである．提案法では，Yang らの方法のように画像空間でマッピングを行っていないので，帯域制限画像を使用できる．本研究において，128×128 画素の画像を 2 倍に拡大する計算は，CPU に Intel Core i7-6850K 3.6 GHz，メモリを 32 GB 搭載した計算機上の Matlab (R2015a) により行われた．Yang らの方法は，画像拡大に 50.7 s を要し，一方，提案法は，1.1 s であった．PSNR と SSIM の評価結果を表 1 に示す．提案法は PSNR と SSIM ともにゼロフィル再構成を上回り，Yang らの方法に比肩する値が得られた．次に再生像の結果を図 4 に示す．(a) は目標とする 256×256 画素の高分解能画像，(b) は入力画像として使用した 128×128 画素からなる (a) の帯域制限画像ある．なお，この図では PSNR 評価が目的ではないので帯域制限画像の (b) を全ての方法の入力画像とした．提案法，ゼロフィル再構成，Yang らの方法による拡大像を，それぞれ (c), (d), (e) に示す．また，拡大像の領域 A と B の局所像を (f) から (i) と (j) から (m) に示す．提案法 (c) とゼロフィル再構成像 (d) をみると画像の表現は似ているが，提案法の方が輪郭が鮮鋭化されている．局所像の (h) と (i) を比較すると Yang らの方法は画像の輝度値が不自然に変化する部分があり，また矢印の部分をみると提案法の方が目標とする高解像度画像である (f) の構造に近いことがわかる．局所像 B の比較では，矢印の部分を見ると Yang らの方法で

は画像を縮小したことによるジャギーがそのまま拡大した粗い粒状の分布を呈しているが，提案法では滑らかな線状を構成しており，この部分でも目標とする (j) の画像に近い結果が得られた．

4　考　察

フーリエ変換領域の信号を打ち切ると一般に再生像にはリンギングアーティファクトが生じるが，窓関数を適用しない帯域制限画像に比べて Lanczos 法による縮小画像はリンギングアーティファクトが抑えられる．そのため，Lanczos 法を利用した縮小画像からの拡大画像より PSNR を計算する際は Lanczos 法を利用した Yang らの方法に有利に働くものと考える．表 1 に示す PSNR の結果をみると Yang らの方法の PSNR は提案法を 0.1dB ほど上回っているが，リンギングアーティファクトの影響があると考える．再構成画像を見ると，Yang らの方法は，入力画像と高分解能画像とのパターンを対応付ける関係から入力画像のパターンがそのまま拡大画像に現れることがある．図 3 のチャート画像では，斜め方向の構造を低解像度で表現したときに現れる段差が矢印で示された部分ではそのまま現れる形になった．提案法では，収集した信号空間を利用しつつ拡大画像を作成するゼロフィル補間と同様な性質をもつので，拡大画像は輝度値の段差は生じにくく目標とする高解像度画像により近い分布の画像を生成することができた．

図 4 の (c) と (d) を比較すると提案法による拡大像はゼロフィル再構成像に近いが，輪郭がより鮮鋭化されている．このことから，スパース化空間である eFREBAS 変換空間での信号外挿は，輪郭の鮮鋭さを保つことに寄与していると考えることができる．

Yang らの方法は，スパースコーディングにより得られた基底について低解像度パッチと高解像度パッチとの対応関係を学習する．入力された低解像度画像をパッチに分解し，それぞれのパッチに対し高解像度パッチを割り当て，L1 ノルム等の制約を満足する画像を出力する．低解像度パッチに高解像度パッチを割り当てる作業と L1 ノルム最小化で多くの計算コストを要し，128×128 画素の計算に 50.7 s を要した．一方，提案法では eFREBAS 展開空間における相似性の利用が高解像度パッチへの対応付けに相当し，対称画像に即した基底を高速

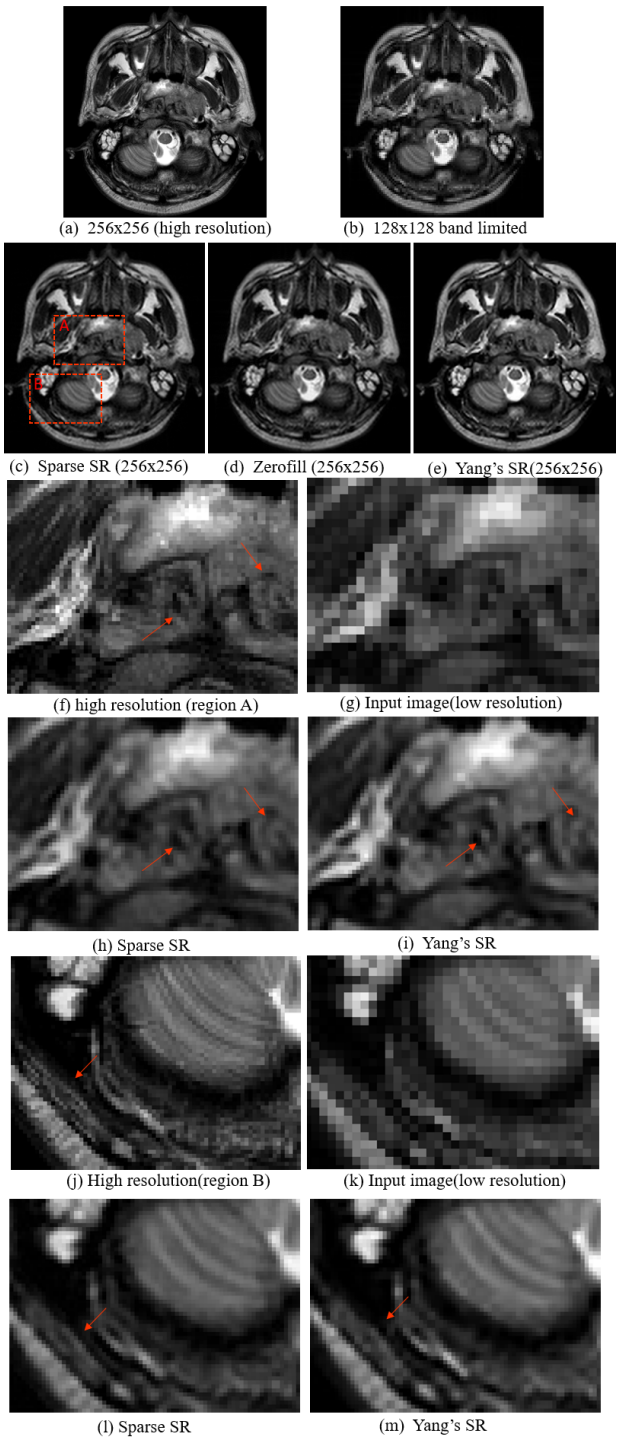

図 4: MR 画像の拡大結果: (a) 目標画像 (256×256 画素), (b) 入力画像として使用した (a) の帯域制限画像 (128×128), (c) 提案法による拡大像 (拡大率 2 倍), (d) ゼロフィル再構成, (e) Yang らの方法, (f)〜(i) 提案法と Yang らの方法の領域 A の拡大像，(j)〜(m) 提案法と Yang らの方法の領域 B の拡大像

に推定できる．また，事前の学習は必要はないので，極めて短時間で初期推定を行うことができる．また，式 (4) の反復は 5 回程度で終えることができるので，1.1s と約 1/46 の時間で画像補間処理を行うことができた．医用画像の生成では実際の生体の分布を反映しない不連続な分布や計算コストの増大は避けるべきであり，この点において提案法は有利であると考える．本方法は，基本的な画像拡大率は eFREBAS 変換の展開スケールの比に由来するが，本研究で行ったように，フーリエ変換空間におけるゼロフィル外挿処理を利用することにより任意の倍率で拡大を行うことが可能である．今後は，さらなる画質や異なる拡大倍率について検討を行う予定である．

5　まとめ

多重解像度解析である eFREBAS 変換をスパースコーディングとして利用し，スパース化された空間の分布特性を利用した画像拡大法について検討を行った．分解能評価用に使用した画像から提案法は超解像の効果を有し，Yang らの方法よりも高分解能な画像を生成することが示された．MR 画像を対象とした検討では，ゼロフィル再構成よりも鮮鋭であり，Yang らの方法よりも目標とする高分解能画像に近い構造の画像が得られた．特に斜め方向に伸びる構造において不自然な輝度値の不連続がみられず滑らかな画像表現が可能であることが示された．今後は，拡大率の変更やさらなる高分解能化について検討を行う予定である．

謝　辞

本研究の一部は，平成 29 年度科学研究費助成金 (基盤研究 (C) 16K06379，新学術領域研究 16H01530) により実施された．また，画像データを提供いただいた (株) キャノンメディカルシステムズに感謝の意を表します．

利益相反の有無

なし．

文　献

[1] Tsai T, Huang T: Multiframe Image Restoration and Registration. Adv Comput Vis Image Process, **1**: 317–339, 1984

[2] Stark H, Oskoui P: High-resolution Image Recovery from Image Plane Arrays, using Convex Projections. J Opt Soc Am A, Opt Image Sci, **6**: 1715–1726, 1989

[3] Yang J, Wright J, Huang T et al.: Image Super-resolution via Sparse Representation. IEEE Trans Image Process, **19**: 2861–2873, 2010

[4] Dong C, Loy CC, He K et al. : Image Super-resolution using Deep Convolutional Networks. IEEE Trans on PAMI, **38**: 1–14, 2015

[5] Ito S, Yamada Y: Multiresolution Image analysis using dual Fresnel transform Pairs and Application to Medical Image Denoising. IEEE ICIP2003 Map8.7, Barcelona, Spain, 2003

[6] 伊藤聡志, 山田芳文: 拡張 FREBAS 変換を利用した雑音画像の多段階鮮鋭化. 信学論 **J93-D**: 999–1008, 2010

[7] Huan J, Zhang S, Metaxas D: Efficient MR image reconstruction for compressed MR imaging. Medical Image Analysis **15**: 670–679, 2011

[8] Yang J, Wight J, Huang T et al. : Image Super-Resolution Via Sparse Representation. IEEE Tran. Image Process **19**: 2861–2873, 2010

[9] Wang Z, Bovik AC, Sheikh HR et al. : Image Quality Assessment :From Error Visibility to Structural Similarity. IEEE Trans. Image Process **13**: 600–612, 2004

Study on Single-image Super Resolution using Sparse Coding

Yasuhiro CHIKUMA*1, Mitsutaka SHIBATA*1, Satoshi ITO*1
*1 Graduate School of Engineering, Utsunomiya University

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

Super-resolution of planar image on scintigrams by modified super-resolution convolutional neural network

Masaya MOMIUCHI[*1], Takeshi HARA[*1],
Tetsuro KATAFUCHI[*2], Hiroshi FUJITA[*1]

Abstract

The image resolutions of planar scintigram images taken by gamma cameras in single photon emission computed tomography (SPECT) devices have lower spatial ones than the original imaging property of the devices. Super-resolution technique was already applied to various natural images or movies, but the application to medical images are limited because of the difficulty of obtaining enough dictionary image data. The purpose of this study was to propose a super-resolution technique based on modified super-resolution convolutional neural network (mSRCNN) which was trained combined images from medical and non-medical image databases. The structure of mSRCNN consists of convolutional and de-convolutional layers. The number of neurons in each layer of the mSRCNN is given by 128*128 - 128*128 - 128*128 - 256*256. The image database was consisted of image pairs of original and scanned images. The original images were used for the gold standard without any blurs. The scanned images were obtained as a grey-scale phantom image, where the grey level was scaled to the radioactivity. The phantom images were created by using a specific image printer which the inks were containing radioactivity materials. As an evaluation of those image quality, we used two indices of peak signal-to-noise ratio (PSNR) and structural similarity (SSIM). We compared the mSRCNN images and the scanned ones. 83 image pairs were used for the experiment. We used 75 cases for training and 8 cases of test. The PSNR and SSIM of scanned images and restored ones were improved from 10.18 to 16.93 and from 0.364 to 0.437, respectively. In conclusions, it is suggested that this method using deep learning technique can contribute to improve image quality of planar images from gamma cameras.

Keywords：planar scintigram image, super-resolution

1. Purpose

The image resolutions of planar scintigram images taken by gamma cameras in single photon emission computed tomography (SPECT) devices have lower spatial ones than the original imaging property of the devices. Super-resolution technique was already applied to various natural images or movies, but the application to medical images are limited because of the difficulty of obtaining enough dictionary image data. The purpose of this study was to propose a super-resolution technique based on modified super-resolution convolutional neural network (mSRCNN) which was trained by combined images from medical and non-medical image databases.

2. Method

The structure of SRCNN [1] consists of three convolutional layers. The structure of mSRCNN consists of three convolutional and a de-convolutional layer. The number of neurons in each layer of the mSRCNN is given by 128*128*128 - 128*128*64 - 128*128*32 - 256*256. Generally, image database

*1 Department of Intelligence Science and Engineering, Graduate School of Natural Science and Technology, Gifu University
〔1-1 Yanagido, Gifu, Gifu 501-1193, Japan〕
e-mail: momiuchi@fjt.info.gifu-u.ac.jp
*2 Faculty of Health Science, Gifu University of Medical Science

consisted of image pairs of low-quality and high-quality images is used for the training of neural network for the super-resolution. However, planar scintigrams are in a low image-quality, appropriate image pairs of low and high quality images will be the keys for the image restore. In this study, the image database was consisted of image pairs of original and scanned images. The original images were general image data obtained by digital cameras and CT devices. The data can be used for the gold standard without any blurs. The scanned images were obtained as a grey-scale phantom image, where the grey levels of the original images were scaled to the radioactivity. The phantom images were created by using a specific image printer which the inks contain radioactivity materials. Fig.1(a) and Fig.1(b) are examples of the experimental images. Fig.1(a) is the original image of the non-medical image taken by a digital camera. Fig.1(b) is the scanned image of Fig.1(a) by a gamma camera after the image density was converted to the radioactivity. We compared the mSRCNN images and the scanned ones. As an evaluation of those image quality, we used two indices of peak signal-to-noise ratio (PSNR) and structural similarity (SSIM) [2].

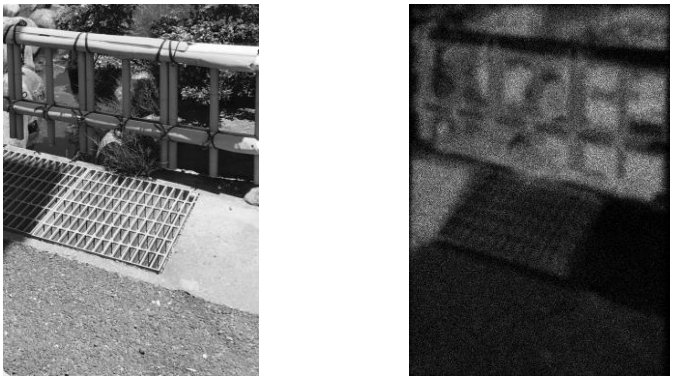

(a) Original image **(b)** Scanned image

Fig.1 Examples of the experimental images

3. Results

83 image pairs were used for the experiment. We used 75 cases for the training and 8 cases for the test. The PSNR and SSIM of scanned images and restored ones were improved from 10.18 to 16.91 and from 0.364 to 0.451, respectively. As validation of the usefulness of the database, 2-fold cross validation was performed. In an experiment in database of medical images only, we used 21 cases for the training and 21 cases for the test. In another experiment in database combining medical and non-medical images, we used 62 cases for the training and 21 cases for the test. The PSNR and SSIM of restored images in database consisting only medical images were improved from 10.52 to 17.35 and from 0.405 to 0.486, respectively. The PSNR and SSIM of restored images in database combining medical and non-medical images were improved from 10.52 to 17.44 and from 0.405 to 0.493, respectively.

4. Conclusion

In conclusions, it was suggested that the method using deep learning technique could contribute to improve image quality of planar images from gamma cameras. In addition, it was suggested that combining non-medical images in a database of medical images could contribute to improvement in accuracy.

References

[1] Dong C, Loy CC, He K et al: Image Super-Resolution Using Deep Convolutional Networks. IEEE Transactions on Pattern Analysis and Machine Intelligence **38**: 295-307, 2016

[2] Wang Z, Bovik AC, Sheikh HR et al: Image quality assessment: From error visibility to structural similarity. IEEE Transactions on Image Processing **13**: 600-612, 2004

Fully convolutional network を用いた小構造物セグメンテーション方法の検討及び腹部動脈への適用

小田　昌宏[*1]　Holger R. Roth [*1]　北坂　孝幸 [*2]　三澤　一成 [*3]

藤原　道隆 [*4]　森　健策 [*1,5]

要旨

本稿では fully convolutional network（FCN）を用いた小構造物セグメンテーション手法と，CT 像からの腹部動脈セグメンテーションへの適用例を報告する．様々な解剖構造セグメンテーションに FCN が適用されて良好な結果が報告されている．しかし，画像上での面積・体積がセグメンテーション結果に影響するため，体積の小さい血管等の小構造物セグメンテーション精度は低くなる傾向がある．この問題に対処するため，最大輝度値投影画像を用いることで，小構造物が高輝度値を持つ場合に画像上に占める体積を上昇させ，セグメンテーション精度を改善する方法が考えられる．また，大域的画像情報を入力とし，局所領域におけるセグメンテーション結果を出力する FCN 構造を提案する．本稿ではこれを用いて CT 像からの腹部動脈セグメンテーションを行った．実験では再現率 73%でセグメンテーションが可能であった．

キーワード：腹部動脈抽出，深層学習，Fully convolutional network，CT 像

1. はじめに

医用画像からの解剖構造自動セグメンテーションは様々な診断及び治療支援において利用される．従来からアトラスベースの手法等が用いられてきたが，近年は深層学習を用いることでセグメンテーション精度が高まっている．腹部臓器においては fully convolutional network（FCN）を用いて肝臓，脾臓等が 90%を超える精度でセグメンテーション可能とする報告もある[1]．このような FCN を用いたセグメンテーション手法では，画像上で比較的大きな面積・体積を占める実質臓器において高精度な結果が得られる．しかし，画像上に占める面積・体積が小さい血管等の小構造物を対象とする場合，十分なセグメンテーション結果が得られにくい. これは FCN を用いたセグメンテーションでは，体積の小さい対象物は軽視される傾向にあるためである．FCN で小構造物をセグメンテーションするために, (1)画像をクリッピング（パッチ画像）し画像上の小構造物が占める割合を上昇させる，(2)ネットワークパラメータ最適化において，対象領域の面積・体積の逆数を用いた class balancing 損失関数を用いる，という 2 通りの方法がある．

本稿では，FCN を用いた小構造物のセグメンテーション手法を提案する．上記(1)の方法

*1 名古屋大学大学院情報学研究科知能システム学専攻
〔〒464-8601 名古屋市千種区不老町〕
e-mail: moda@mori.m.is.nagoya-u.ac.jp
*2 愛知工業大学情報科学部
*3 愛知県がんセンター
*4 名古屋大学医学系研究科
*5 国立情報学研究所医療ビッグデータ研究センター

を採用し，FCN の入力パッチサイズに対して出力パッチサイズを小さくすることで小構造物のセグメンテーションを行う．本手法を使用し，最大輝度値投影（MIP）画像をパッチとして腹部動脈セグメンテーションを行った．

2. 小構造物セグメンテーション手法

2D 画像パッチを入出力として持つ FCN ネットワークでセグメンテーションを行う．このネットワークは U-net [2]を基に作成した．U-net と異なる点として，エンコードを行う層数よりも少ない層をデコード層に使用し，より局所的なセグメンテーション結果を出力する．本ネットワークに元画像から生成したパッチ（元画像パッチ）と正解領域画像から生成したパッチ（正解パッチ）を与え学習を行う．学習済みネットワークを用いて元画像パッチからセグメンテーションを行う．

3. 腹部動脈セグメンテーション

腹部 CT 像に含まれる大動脈を含む大血管を領域拡張法でセグメンテーションし，残りの動脈領域に対して 2.のネットワークを用いたセグメンテーションを行った. パッチは 3D の CT 像と腹部動脈領域画像から 2D 画像を切り出して生成した．パッチに動脈領域をより多く含めるため，MIP 画像を元画像パッチとして使用した．正解パッチは手動セグメンテーションした腹部動脈領域画像から作成した 2 値画像である．これらのパッチを用い，ネットワークの学習及びセグメンテーションを行った．パッチ単位のセグメンテーション結果を 3D 画像として再構成し，腹部動脈セグメンテーション結果を得た．

4. 実験及び考察

動脈層の造影 CT 像 4 例を用いて腹部動脈セグメンテーションを行った．CT 像の仕様は，画像サイズ 512×512 pixels，スライス枚数 753～980 枚，画素間隔 0.64～0.74 mm，再構成間隔 0.5 mm，スライス厚 1.0 mm，管電圧 80 kVp，管電流 398～672 mAs である．提案手法で得られた領域を図 1 に示す．正解領域に対する再現率は 73%であった．

提案手法は複雑な走行状態を持つ腹部動脈に対してセグメンテーションを行った．多数の細い動脈が集まった個所，周囲と血管の濃度差が小さい肝臓内の血管もセグメンテーション可能であった．結果から，提案手法は細い血管のセグメンテーションに利用可能であることが分かった．しかし，過抽出や見落としが多く存在した．提案手法は領域の連続性を考慮せずパッチ単位のセグメンテーションを行うため，今後は大域的な血管構造を考慮する必要がある．

5. むすび

本稿では FCN を用いた画像からの小構造物セグメンテーション手法を提案した．これを腹部動脈セグメンテーションに適用し，細い血管を含む結果を得た. 今後の課題として，見落としや過抽出領域の削減，大域的血管構造の考慮が挙げられる．

謝辞　本研究の一部は，JST ACT-I（課題番号 JPMJPR16U9 ），JSPS 科研費 26108006, 25242047, 17H00867，AMED 研究費「革新的がん医療実用化研究事業」, ならびに栢森情報科学振興財団研究助成金によった．

利益相反の有無　なし

文　献

[1] Roth HR, et al: Hierarchical 3D fully convolutional networks for multi-organ segmentation. arXiv:1704.06382, 2017

[2] Ronneberger O, Fischer P, Brox T et al: U-Net convolutional networks for biomedical image segmentations. MICCAI 9351: 234-241, 2015

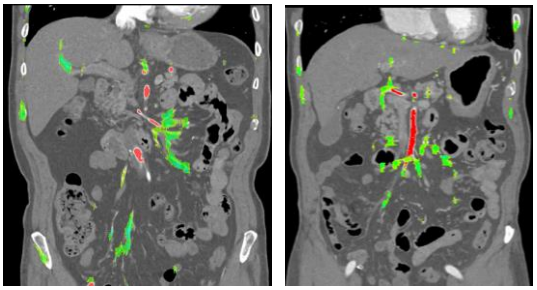

図 1 セグメンテーション結果の Coronal 断面表示．赤が領域拡張法，緑が 2.のネットワークで得た領域．

Small structure segmentation method using fully convolutional network and its application to abdominal artery

Masahiro ODA[*1], Holger R. ROTH[*1], Takayuki KITASAKA[*2], Kazunari MISAWA[*3], Michitaka FUJIWARA[*4], Kensaku MORI[*1,5]

*1 Graduate School of Informatics, Nagoya University
*2 School of Information Science, Aichi Institute of Technology
*3 Aichi Cancer Center
*4 Nagoya University Graduate School of Medicine
*5 Research Center for Medical Bigdata, National Institute of Informatics

In this paper, we present a small structure segmentation method using a fully convolutional network (FCN) and its application to abdominal artery segmentation from CT volumes. FCN is applied to segment various anatomical structures. In segmentations using FCN, area or volume of the segmentation target in images affects segmentation accuracy. Segmentation accuracies of small targets such as the blood vessels tend to be low. To improve segmentation accuracies of them, we used maximum intensity projection images to increase area or volume of the segmentation target in images. We also propose a FCN structure that has large or global images as the input and small or local segmentation results as the output. We applied the FCN structure to abdominal artery segmentation from CT volumes. The recall rate of the segmentation result was 73%.

Key words: Abdominal artery segmentation, Deep learning, Fully convolutional network, CT image

脳神経外科手術支援のための手術顕微鏡画像からの脳表の 3 次元形状復元に関する検討

林　雄一郎[*1]　柴田　睦実[*2]　藤井　正純[*3]　森　健策[*1, *4]

要旨

本稿では手術顕微鏡画像からの脳表の 3 次元形状の復元について述べる．脳神経外科手術において，MRI などの術前の 3 次元医用画像と術中の手術顕微鏡画像を融合することができれば手術支援として有用である．手術顕微鏡画像から脳表の 3 次元形状を復元することができれば，3 次元医用画像と手術顕微鏡画像の位置合わせに利用することが可能である．そこで，手術顕微鏡により撮影された画像からの脳表の 3 次元形状の復元について検討を行った．形状復元にはこれまで開発してきたスレテオ内視鏡画像から臓器の 3 次元形状を復元する手法を用いる．この手法では，ステレオ画像間の特徴点の対応付けにより視差を求め，その視差を用いて臓器の 3 次元形状を復元する．脳の模型を手術顕微鏡により撮影し，撮影した手術顕微鏡画像から形状復元を行ったところ，模型の脳表の 3 次元形状が復元できることを確認した．

キーワード：手術ナビゲーション，手術支援，スレテオ画像，脳神経外科，顕微鏡

1. はじめに

脳神経外科手術では，術前に撮影された CT や MRI などの様々な画像を用いて手術計画の立案を行う．また，術中には手術顕微鏡を用いて微細な解剖学的構造物を確認しながら手術を行っている．そこで，術前の CT や MRI などの 3 次元医用画像と術中に得られる手術顕微鏡の画像を統合することによる手術支援の研究が行われている［1, 2］．我々も術前の 3 次元医用画像と術中の手術顕微鏡画像をはじめとした様々な画像を融合することによる手術支援の検討を進めてきた．

このような手術支援を行うためには 3 次元医用画像と手術顕微鏡画像の位置合わせを行う必要がある．手術顕微鏡画像から脳の 3 次元形状を復元することができれば，3 次元医用画像との位置合わせに利用することができる．そこで，本稿では手術顕微鏡画像からの脳表の 3 次元形状復元手法の検討を行った．我々はこれまで，スレテオ画像を用いた臓器の 3 次元形状復元手法を検討してきた[3, 4]．本稿では，この手法を用いて脳の模型を撮影した手術顕微鏡画像から脳表の 3 次元形状の復元を試みたので報告する．

*1 名古屋大学大学院情報学研究科
〔〒464-8601 名古屋市千種区不老町〕
e-mail: yhayashi@mori.m.is.nagoya-u.ac.jp
*2 名古屋大学大学院情報科学研究科
*3 福島県立医科大学脳神経外科
*4 国立情報学研究所医療ビッグデータ研究センター

2. 3 次元形状復元手法

本稿では，文献［4］の手法を用いて手術顕微鏡画像から脳表の 3 次元形状の復元を行う．まずキャリブレーション処理を行い，手術顕微鏡のカメラパラメータを求める．求めたカメラパラメータを用いて手術顕微鏡画像を平

行化する．次に，平行化された手術顕微鏡画像の左右画像間で特徴点の対応付けを行う．この手法では，2 段階で特徴点の対応付けを行っている．まず，左右画像間で SURF 特徴量を用いて特徴点の抽出と特徴点の対応付けを行う．その後，得られた対応点の近傍領域で正規化相互相関を用いた対応点探索を行い，対応点を増加させる．さらにこの手法では，特徴点の対応付けの際にクロスチェックを行い誤対応点の削減を行っている．最後に，左右画像間で対応付けられた対応点の位置とカメラパラメータを用いて各対応点の 3 次元座標を計算することにより 3 次元形状を復元する．

3. 結果

脳の模型を手術顕微鏡により撮影し，手術顕微鏡画像から脳表の 3 次元形状の復元を行った．脳の模型を撮影した手術顕微鏡画像の左右画像の一例を図 1 に示す．また，図 1 の画像から脳表の形状を 3 次元復元した結果を図 2 に示す．図 2 では 3 次元復元した結果を 2 方向から観察した図を示す．図 2 から脳表の 3 次元形状が復元されていることが確認できる．

4. むすび

本稿では，脳神経外科手術支援のための手術顕微鏡画像からの脳表の 3 次元形状復元について述べた．脳の模型を手術顕微鏡により撮影した画像を用いて形状復元を行い，模型の脳表の 3 次元形状を復元できることを確認した．今後の課題としては，実際の手術画像への応用などが挙げられる．

謝辞

日頃ご討論いただく名古屋大学森研究室諸氏に感謝する．本研究の一部は文部科学省・日本学術振興会科学研究費助成事業（JP26108006，JP17H00867，JP15H04948）によった．

利益相反の有無

なし

文　献

［1］ Edwards PJ, King AP, Maurer CR Jr et al: Design and evaluation of a system for microscope-assisted guided interventions (MAGI). IEEE Trans Med Imag **19**: 1082-1093, 2000.

［2］ Paul P, Fleig O, Jannin P: Augmented virtuality based on stereoscopic reconstruction in multimodal image-guided neurosurgery: methods and performance evaluation. IEEE Trans Med Imag **25**: 1500-1511, 2005.

［3］ Eshghi M，林雄一郎，柴田睦実　他：脳神経外科手術ナビゲーションのためのステレオ画像からの脳表の 3 次元形状の復元．日本コンピュータ外科学会誌 **18**: 246-247，2016.

［4］ 柴田睦実，森田千尋，林雄一郎　他：腹腔鏡下胃切除術のための手術ナビゲーションシステムにおけるステレオ内視鏡画像からの臓器形状復元に関する検討．第 35 回日本医用画像工学会大会予稿集，OP1-10，

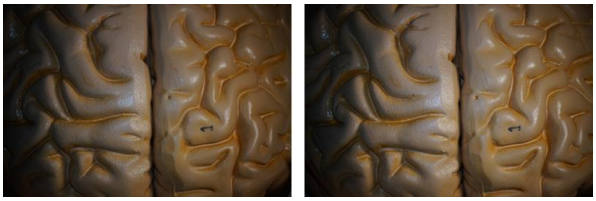

図 1 手術顕微鏡画像

図 2 復元結果

A Study on Brain Surface Reconstruction from Surgical Microscopic Images for Neurosurgery Assistance

Yuichiro HAYASHI[*1], Mutsumi SHIBATA[*2], Masazumi FUJII[*3], Kensaku MORI[*1, *4]

*1 Graduate School of Informatics, Nagoya University
*2 Graduate School of Information Science, Nagoya University
*3 Department of Neurosurgery, Fukushima Medical University
*4 Research Center for Medical Bigdata, National Institute of Informatics

This paper reports brain surface reconstruction from surgical microscopic images. Fusion of intraoperative surgical microscopic images and preoperative images such as MRI is useful for assisting neurosurgery. 3D reconstruction of brain surface from the microscopic images is help to fuse of these images. Therefore, we reconstruct a 3D brain surface from surgical microscopic images. We have developed the 3D organ surface reconstruction method from stereo laparoscopic images. This 3D reconstruction method computes 3D point sets of organ surface using relationships of corresponding points among stereo images. We took a brain phantom by a surgical microscope and applied the 3D reconstruction method to the surgical microscopic images. The experimental results showed that the method could reconstruct the brain surface from the surgical microscopic images.

Key words: Surgical navigation, Surgical assistance, Stereo, Neurosurgery, Microscope

スマートグラスを用いた整形外科手術ナビゲーションシステム

西尾　祥一[*1], Md Moazzem Hossain[*2], 平中　崇文[*3]

小橋　昌司[*1]

要旨

現在，整形外科手術は手術手技，使用器具の種類が豊富であるため，手術器械の受け渡しを行う器械出し看護師は大きな負担を強いられている．また，人工膝関節置換術において医師の骨切り等を補助するためのナビゲーションシステムは存在するが，看護師の器械出しを補助するためのシステムは確立されていない．そこで，本研究では，スマートグラスを用いて手術中に看護師に手技種類，手技進行度の理解や次に使用する器具の選定の補助を行うシステムの構築法を提案する．本手法では，まず，医師視点の手術映像より画像認識技術である畳み込みニューラルネットワーク(CNN)を用いて手技種類の推定を行う．得られた推定結果より器械出し看護師が装着しているスマートグラスに対して使用器具の選定を物体検出技術により，拡張現実(AR)を用いて指示する．実験では人工膝関節置換術を対象として CNN を利用した手技認識モデル，手術器具検出モデルの構築を行った．

キーワード：畳み込みニューラルネットワーク，物体認識、整形外科手術のコンピュータ支援，手術手順認識，手術室看護師

1. はじめに

人工膝関節置換術は，国内症例数約 8 万の主要な整形外科手術の一つである．手術の特徴は手技(約 27 種)が複雑で，使用する手術器具(約 120 種)も多く，器械出しを行う看護師に大きな負担をかける手術である．負担軽減の方法としては，看護師自身が多くの訓練を積む，手術器械メーカーの人が立ち会うなどあるが，それぞれ，多大な労力を要する，人件費の発生など問題があり，自動ナビゲーションシステムの構築が望まれている．内視鏡手術映像から画像認識技術などを用いて手術手技を認識する研究[1]があるが，整形外科手術において，実用的なナビゲーションシステムはまだ確立されていない．

本論文では，整形外科手術ナビゲーションシステムを提案する．

2. 提案法

2.1. 整形外科手術ナビゲーションシステムの提案

遠隔支援等で活用が期待されるスマートグラスを用いた看護師支援のためのナビゲーションシステムの構築を提案する．整形外科手術ナビゲーションシステムの概観を図 1 に示す．まず，術者のスマートグラス RGB 画像を取得する. RGB 画像は, 無線通信(Bluetooth)

*1 兵庫県立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]
e-mail: kobashi@eng.u-hyogo.ac.jp
*2 International University of Business Agriculture and Technology, Bangladesh
*3 高槻病院

を介して処理サーバーに送信される．現在の手術手順を自動的に認識し，次の手順で使用する使用器具を予測する．次に第 1 ステップの認識結果に基づいて，次の手順で使用する手術器具を，外科医及び器械出し看護師を含む手術室内の全ての看護師に、スマートグラスのディスプレイを介して、テキスト・AR 表示によって指示する．

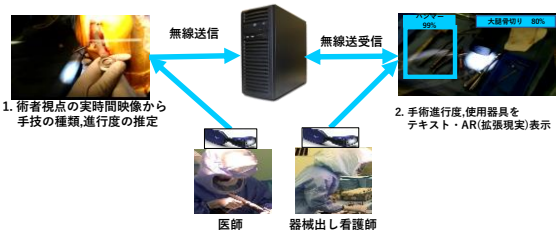

図 1 整形外科手術ナビゲーションシステムの概念図

2.2. 手術手技自動認識システムの提案

手技自動認識システムは，医師視点の RGB 画像より現在の手術手順を把握するためのシステムである．手術手技自動認識システムは ImageNet で事前学習済みの CNN モデルである Mobile Net を用いて構築した．

Mobile Net を使用して入力画像(224×224 サイズの RGB 画像)より 1001 次元の画像特徴ベクトルを得る．得られた画像特徴を用いて，再学習させた Mobile Net の出力層により各クラスに属する確率を推定する．そして最も確率値の高いクラスが手術手技の推定結果となる．

2.3. 手術器具検出システムの提案

手術器具検出システムは領域ベースの畳み込みニューラルネットワークである Faster R-CNN を利用して構築した．同システムは看護師視点の RGB 画像中から物体の領域候補を推定する．

3. 使用データ

手術手技認識はスマートグラスで撮影された 5 件の単顆人工膝関節手術(UKA)動画を使用した．症例 1,2,3,4,5 の動画から UKA の手技書に従って画像を抽出し，18 種類の訓練，評価データセットを作成した．手術器具検出システムの評価実験は ZIMMER BIOMET 社の UKA 手術器具(31 種)をカメラ，スマートグラスで撮影した写真及び映像を使用した．

4. 実験結果・考察

手技自動認識システムの評価結果を図 2 に示す．平均認識率は 26.6%であった．手術器具検出システムの評価結果を図 3 に示す．平均認識率は 88%であった．

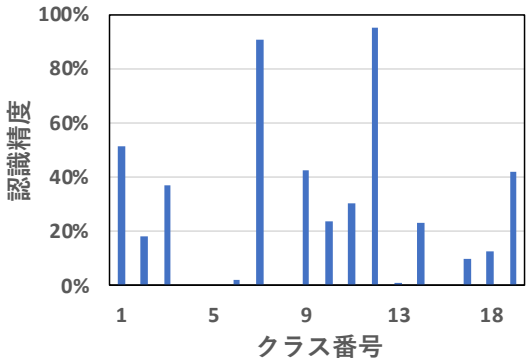

図 2 手術手技自動認識システムの評価結果

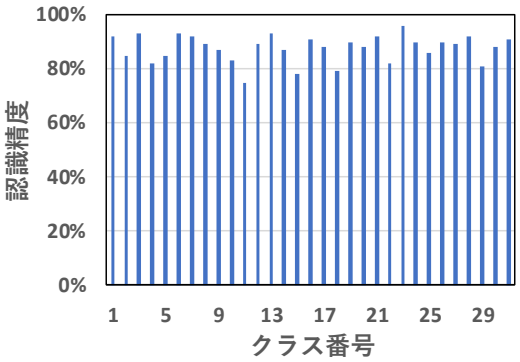

図 3 手術器具検出システムの評価結果

5. まとめ

本研究では整形外科手術ナビゲーションシステムを提案し，実験において手技自動認識システム，手術器具検出システムの構築，及び評価を行った．今後の課題としては，時系列を考慮したネットワークの適応，学習データの増築による精度改善である．

利益相反の有無　なし

文　献

［1］ M. Volkov, D. A. Hashimoto, G. Rosman, O. R. Meireles, and D. Rus, "Machine learning and coresets for automated real-time video segmentation of laparoscopic and robot-assisted surgery," pp. 754-759, 2017.

Real-time Computer Aided Orthopedic Surgery Navigation System using Smart Glasses to Assist Operating Room Nurse

Shoichi NISHIO[*1] , Md Moazzem Hossain[*2]
Hiranaka Takafumi[*3] , Syoji KOBASHI[*1]
*1 University of Hyogo
*2 International University of Business Agriculture and Technology
*3 Takatsuki Hospital

At present, orthopedic surgery has a large variety of surgical techniques. Procedures are complicated, and many types of equipment have been using in the surgery. So, operating room nurses who deliver surgical instruments to surgeon are supposed to be forced to incur a heavy burden. Although there is a navigation system for assisting surgeons in artificial joint replacement surgery, but no system exists for assisting operating room nurses. This work proposes a computer-aided navigation system that indicates the current procedure and procedure progress for nurses, and also instructs nurses to prepare surgical instruments to be used in the next procedure using smart glasses. Firstly, the system estimates the current status of the surgery procedure using a convolutional neural network (CNN) by utilizing real-time video images taken from smart glasses which was worn by operating surgeon. Then, the system indicates nurses the surgical instrument to be used at the next procedure in the smart glass worn by the nurses. The system was implemented with the object detection technology and the augmented reality. Experiment results demonstrated a satisfactory performance of our proposed system of recognizing surgery procedures and surgical instrument detection system.

Key words: Computer-aided orthopedic surgery, Operating room nurse, Surgical procedure recognition, Convolutional Neural Network

開腹下手術の術中ナビゲーションシステムの新しい機能の開発

服部　麻木[*1]　兼平　卓[*2]　岡本　友好[*2]　二川　康郎[*2]

恩田　真二[*3]　安田　淳吾[*3]　矢永　勝彦[*3]　鈴木　直樹[*1]

要旨

患者の X 線 CT データから三次元再構築した臓器モデルを用い，肝胆膵領域の開腹下や鏡視下手術において，撮影した術野画像上に臓器モデルを重畳表示することで，手術がある程度進むまで確認することが難しい臓器内部の腫瘍や血管などの三次元的なオリエンテーションや，術前に計画した切除面を術者に提示する術中ナビゲーションシステムの開発し，臨床試験を行なってきた．本システムは手術の節目ごとに内部構造を確認するために用いられているが，本システムをより有効活用するために，切除に用いる手術器具の先端位置を常に計測し，計画した切除面や腫瘍からのマージンの領域との距離を術者に情報として提供する機能の開発を開始した．開発中の新しい機能の概要について報告する．

キーワード：術中ナビゲーション，肝胆膵領域外科手術

1. はじめに

われわれは肝胆膵領域の開腹下手術におけるナビゲーションシステムの開発と臨床応用を行なっており，本大会でも報告してきた．

本システムは，ナビゲーション用の立体硬性鏡やタブレット型 PC の背面のカメラで撮影した術野画像上に，術前の X 線 CT から三次元再構築した臓器モデルを重畳して表示し，肉眼では見ることができない臓器内部の腫瘍や血管などの三次元的な位置を術者が直感的に把握できることを目的としている．これまでに数十例の臨床試験を行なってきたが，臓器の内部構造の提示だけでなく，さらに有効な情報を術者に提供できるよう，新しい機能の開発を開始した．本機能は，肝部分切除において腫瘍から任意に距離を設定したマージンの領域や術中に設定した切除面と，切除に用いる手術器具先端の距離を常にモニタリングし，あらかじめ設定した許容される距離を超えると音声などで警告を発するものである．開発中の新しい機能について報告する．

*1 東京慈恵会医科大学高次元医用画像工学研究所

〔〒201-8601 狛江市和泉本町 4-11-1〕

e-mail: hat@jikei.ac.jp

*2 東京慈恵会医科大学附属第三病院外科

*3 東京慈恵会医科大学消化器外科

2. 方法

システム構成の概要を図 1 に示す．構成は今まで開発してきたシステムをほぼそのまま用いるが，これまでレジストレーションのみに用いてきたポインティングデバイスを肝臓の部分切除に用いるペアン鉗子などの手術器具に置き換え，レジスト

レーションと術中の手術器具の位置計測両方に用いるようにした．

術中は常に手術器具先端の位置を計測し，臓器モデル上に先端位置との距離を色の変化で術者に提示する機能を持たせた．また，術前に計画，もしくは術中に設定した切除面を臓器モデル上に表示し，その切除面と手術器具先端との距離も切除面上にマッピングできるようにした．さらに腫瘍切除の際に目安となる腫瘍表面からのマージンの領域を設定し，この領域と手術器具先端との三次元的な位置関係も提示できるようにした．これらの情報はディスプレイに表示するだけでなく，手術器具先端があらかじめ設定した切除面からの距離やマージンの領域から外れた時に音声で警告を発するようにし，術者がナビゲーション情報を得ながら手技に集中できるようにした．

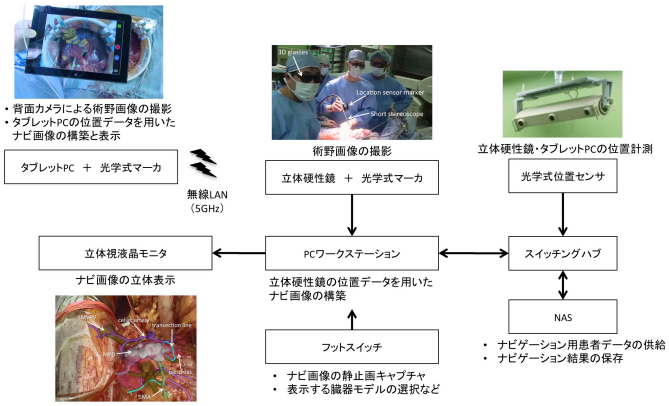

図1 立体硬性鏡とタブレットPCを用いた手術ナビゲーションシステムの構成

3. 結果

図2に手術の対象となる臓器に手術器具先端を近づけた時の距離を臓器モデル上へマッピングした結果を示す．また設定した切除面からの距離を切除面上にマッピングした結果を図3に示す．これらの画像提示だけでなく，手術器具先端と切除面との距離があらかじめ設定した許容される距離より離れると，切除面のどちら側にどれだけ離れたかを術者に音声で伝えることができた．

4. まとめ

術野画像への臓器モデルの重畳表示とともに，手術器具先端位置と切除面や腫瘍との空間的な位置関係を常に術者に画像と音声で提示することにより，臓器内部構造の確認だけでなく，手術手技を行なっている間も情報提供可能なナビゲーションシステムとすることができた．今後，術者への情報提示手法やユーザインターフェイスを改良し，臨床応用を行なっていく予定である．

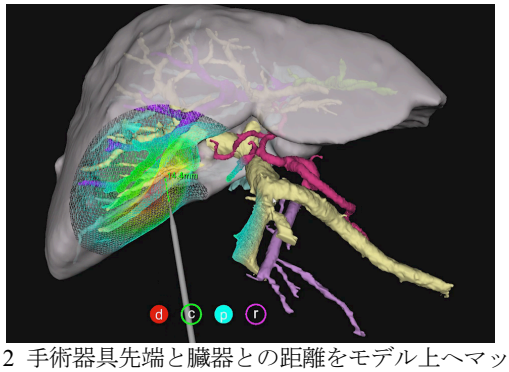

図 2 手術器具先端と臓器との距離をモデル上へマッピングした結果

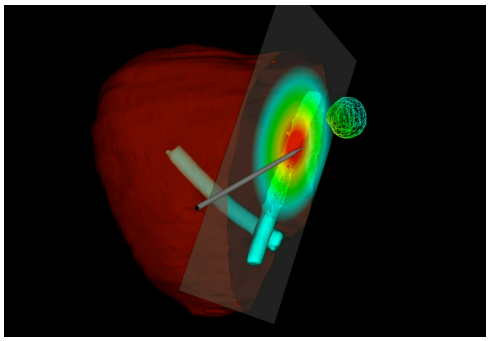

図 3 手術器具先端と設定した切除面の距離をマッピングした結果

利益相反の有無　なし

腹腔鏡下手術のための VR 手術再観察システムの開発

鈴木　拓矢[*1]　道満　恵介[*1]　目加田　慶人[*1]

三澤　一成[*2]　森　健策[*3]

要旨

腹腔鏡下手術では，医師の視野が腹腔鏡映像に限定される．医師は血管・臓器の位置を把握し処置しなければならないが，限定された環境下での手術は高難度である．近年の手術現場では，手術ナビゲーションシステムが利用されている．しかし，医師は手術ナビゲーションシステムに提示される臓器の情報と，腹腔鏡映像とを対応づけしなければならない．本研究では，過去に行われた手術を再観察する教育システムを提案する．本システムでは血管・臓器の 3 次元的形状と患者の手術映像を位置合わせする．また，本研究では人体の 3 次元的な形状や位置関係の理解力を向上させるために，VR デバイスである zSpace を用いる．これにより，医師は内視鏡映像と位置合わせした血管・臓器を 3 次元的に観察可能である．

キーワード：腹腔鏡下手術，VR 教育，仮想化内視鏡

1. はじめに

腹腔鏡を使用する手術では，開腹手術と異なり,医師の視野が腹腔鏡映像に限定される．そのような環境下では患者固有の血管・臓器の位置を把握し，処置することが高難度である．近年では，医用画像を分かりやすく可視化するシステム[1]や，手術ナビゲーションシステム[2]が利用されている．特に手術ナビゲーションシステムは，手術中に利用される支援システムとして有用である．手術ナビゲーションシステムは CT 画像から生成した血管・臓器を提示する．生成した血管・臓器は手術映像に映る血管・臓器と同様の位置・姿勢になるように自動で位置合わせされる．しかし，手術ナビゲーションシステムの映像と腹腔鏡映像で提示している血管・臓器の情報を，医師は手術中に対応付けしなければならない．対応付けには多くの手術経験が必要であるため，若手の医師には依然として高難度な手術である．

そこで本研究では，過去の手術に対して，両者を同時に再観察する教育システムを提案する．本システムは患者固有の血管・臓器の 3 次元的形状と，熟練医師が手術した際の腹腔鏡映像を位置合わせする．なお，本研究では VR ディスプレイである zSpace[3]を用いる．これにより，医師は内視鏡映像と位置合わせした血管・臓器を 3 次元的に観察できる．

2. 提案システム

提案システムの動作中の例を図 1 に示す．本システムでは，事前に撮影された腹腔鏡映像と患者の血管・臓器のポリゴンを位置合わせする．位置合わせされた映像とポリゴンは

*1 中京大学 大学院工学研究科
〔〒470-0397 豊田市貝津町床立 101〕
e-mail: suzuki.t@md.sist.chukyo-u.ac.jp
e-mail: kdoman@sist.chukyo-u.ac.jp
e-mail: y-mekada@sist.chukyo-u.ac.jp
*2 愛知県がんセンター
e-mail: misawakzn@aichi-cc.jp
*3 名古屋大学 大学院情報学研究科
e-mail: kensaku@is.nagoya-u.ac.jp
投稿受付：2018 年 5 月 14 日

VR 空間上で重畳する．映像とポリゴンの位置合わせでは，事前にポリゴンの位置と姿勢

図 1 システムの全体図

を手動で付与しておき，システム利用時にその情報を参照し適用する．

本システムでは，腹腔鏡映像とポリゴンの対応情報を確認するために，腹腔鏡映像の透明度の変更や切り替えが可能である．腹腔鏡映像の透明度を調節することで腹腔鏡映像と腹腔鏡映像に位置合わせされたポリゴンが合成された状態となる．医師は合成表示や，透明度の切り替えをすることで，腹腔鏡映像とポリゴンの照合が容易となる．また，本システムは他の臓器によって隠れている血管・臓器を観察するために，血管や臓器のポリゴンの表示・非表示することも可能である．これにより，医師は任意の血管・臓器の位置関係を把握できる．

3. 1. 評価実験

熟練医師 1 名が提案システムを評価し，若手医師の教育に有用であるか考察した．

使用した腹腔鏡映像の解像度は 1,440×1,080 で，フレームレートは 30 [fps] のものであった．ポリゴンは事前に撮影された患者の CT 画像から抽出したものを用いた．

実験の結果，腹腔鏡映像とポリゴンの位置合わせした際に生じるずれが大きいという指摘を受けた．肝臓の位置ずれは少なかったものの，他の臓器は位置ずれが大きく，対応づけが失敗したことが問題であった．

3. 2. 考察

腹腔鏡映像とポリゴンが大きく位置ずれした原因は，手動で位置と姿勢を決定していたことや，システム内で使用している仮想カメラの視野角と手術中に使用された腹腔鏡の視野角の差異が影響したと考えられる．位置合わせでは，医師が意識的に対応付けすることなく映像を観察できる必要がある．熟練医師との考察の結果，許容される位置のずれ幅は，利用者側から見て 1cm～3cm 以内であるとされた．位置ずれを小さくするには，腹腔鏡映像の情報を用いた血管・臓器の奥行き推定が必要である．腹腔鏡映像から推定された奥行き情報を用いてポリゴンを位置合わせすることで精度向上が期待される．

4. まとめ

本稿では，腹腔鏡下手術を担当する若手医師のために，熟練医師がした手術を再観察するシステムを提案した．腹腔鏡映像の透明度変更や，ポリゴンの表示・非表示をすることで，普段確認できない血管・臓器を観察できる．今後は位置合わせで生じるずれを小さくすることで，若手医師の教育に有用であることが示唆された．

謝辞

本研究の一部は，日本学術振興会科研費補助金の援助による．

利益相反の有無

なし

文　献

［1］ Y. Nimura, H. Huy Bui, T. Kitasaka, K. Misawa, and K. Mori: Vasculature CAD: A CAD for understanding individual vasculature based on direct drawing of blood vessel names to vasculature on volume-rendered image, Radiological Society of North America Scientific Assembly and Annual Meeting Program 2011, LL-INE1177, p.319, Dec. 2011.

［2］ K. Mori, Y. Suenaga, and J. Toriwaki: Fast software-based volume rendering using multimedia instructions on PC platforms and its application to virtual endoscopy, Proc. SPIE, vol.5031, pp.111-122, May 2003.

［3］ zSpace, Inc., https://zspace.com/, 2018 年 5 月 14 日最終アクセス

Development of a VR re-observing system for understanding laparoscopic surgery

Takuya SUZUKI[*1], Keisuke DOMAN[*1], Yoshito MEKADA[*1], Kazunari MISAWA[*2], Kensaku MORI[*3]

*1 Graduate School of Engineering, Chukyo University

*2 Aichi Cancer Center

*3 Graduate School of Informatics, Nagoya University

Laparoscopic surgery is quite difficult operation because the surgeon can see only a laparoscopic video for observing the position and the shape of blood vessels and organs. Although surgical navigation systems are used these days, a surgeon should observe a laparoscopic video while referring to the pre-observed organs displayed by the system. This research proposes an education system to re-observe a past surgery using 3D-matching blood vessels and organs with a laparoscopic video. The proposed system uses "zSpace", a VR display, and enable us to three-dimensionally observe pre-observed blood vessels and organs overlaid on a laparoscopic video.

Key words: Laparoscopy, VR-Based Education, Virtual Endoscopy

Normalized Brain Datasets with Functional Information

Project the Future-predicting Glioma Surgery

Manabu TAMURA[*1,2], Takashi MARUYAMA[*1,2],
Jean-Francois MANGIN[*3], Ikuma SATO[*4], Masayuki NITTA[*1,2],
Taiichi SAITO[*2], Ken MASAMUNE[*1], Takakazu KAWAMATA[*2],
Hiroshi ISEKI[*1], Yoshihiro MURAGAKI[*1,2]

Abstract

The purpose of this study is to transform to the digitized intra-operative imaging and the compiled brain-function database for the future-predicting glioma surgery based on patient's future perspective depending on the tumor resection rate as well as the post-operative complication rate. Brain-function database was transformed to normalized brain digitized brain-mapping localization with the modified electric stimulus probe. This normalized brain with functional information, was projected to individual patient's brain and predicted of brain function.

We successfully acquired log data with the location of medical device integrated into intra-operative MR image and digitized brain function was converted to a normalized brain data format in 17 cases with acceptable accuracy. For the electrical stimulation positions in which patients showed speech arrest (SA), speech impairment (SI), motor and sensory responses during cortical mapping processes, the data was tagged and testing task and electric current for the stimulus were recorded. There were 23 SA, 14 SI, 15 motor and 1 sensory responses (53 responses in total) including 17 cases. According to the evaluation of transformation accuracy for the 10 subjects, referring to each two neighbouring sulci on the electro-stimulator position, the first transformation from intra- to pre-operative MRI with non-rigid registration was calculated at 4.5 ± 1.0 mm, while the second transformation from pre-operative to normalized brain with SPM normalization was calculated at 5.8 ± 1.4 mm in average.

This image integration and transformation methods to carry out brain normalization should evaluate practical brain mapping in OR.

Keywords：normalized brain, awake craniotomy, brain mapping, transformation, accuracy

---

*1 Faculty of Advanced Techno-Surgery, Institute of Advanced Biomedical Engineering and Science, Tokyo Women's Medical University, Tokyo
〔8-1 (TWIns) Kawada-cho, Shinjuku-ku, Tokyo 162-8666, Japan〕
e-mail: tamura.manabu@twmu.ac.jp

*2 Department of Neurosurgery, Neurological Institute, Tokyo Women's Medical University, Tokyo, Japan

*3 The Computer Assisted Neuroimaging Laboratory, Neurospin, Biomedical Imaging Institute, CEA, Gif sur Yvette, France

*4 Faculty of System Information Science Engineering, Future University Hakodate, Hakodate, Japan

1. Purpose

Neuroimaging has improved dramatically in recent years, and has had a tremendous impact on all neurosurgical procedures. For brain tumor resection, neuroimaging with MRI technology has two major purposes, 1) prediction of anatomical structures and 2) prediction of brain function. Especially pre-surgical simulation with MRI is useful for understanding how to access the lesions and how to avoid intra- and post-operative neurological deficits. For the purpose of accurate simulation, we use volumetric MRI not only for viewing tumor localization but also for representing 3D-views of sulci and gyri with an additional information. This sulci imaging is applied to plan the neurosurgical procedure and functional mapping in glioma surgery with a software platform, BrainVISA[(1)], allowing automated extraction, identification and statistical information of the sulci [(2)].

Firstly, in 2000, an intra-operative MRI enabled surgeons to evaluate the extent of tumor resection in the operation room. A navigation system can accurately localize the surgeon's procedure for tumor removal, and grasp the position of the surgical area has been implemented, providing ground-breaking precision guided surgery in over 1,750 operations[(3)]. Secondly, starting in 2004, a dedicated device IEMAS™ (Intraoperative Examination Monitor for Awake Surgery) has been used in over 380 cases when performing brain mapping in awake craniotomy, providing a time-synchronized recording display with electric stimulation, updated navigation system, and patient conditions while examining linguistic function [(4, 5)]. However, this visualization is limited to analog information that has been recorded on video and seen with the naked eye.

With the goal of new expansion to solve this problem, the electrical stimulation probe is recorded as log (digitized) data, and together with task information, electrical stimulus conditions, and patient response during mapping, it is stored in a database format as digital information.

2. Method

The first steps of our system include performing MR acquisition with 3T scanner for patients scheduled in awake surgery due to tumor localization, accumulate 3D volumetric axial T1-weighted image (WI) images (TE: 4.6 ms, TR: 6.8 ms, voxel size 1x1 mm) of thin slices (2 mm), and prepare for tumor resection pre-operatively. Using BrainVISA software, the acquired MRI images are analyzed based on object-based morphometry, which can provide sulci analysis that gets to the core of brain development and cortical dysplasia [(6)].

Generally, video analysis using IEMAS for visualization of mapping processes during awake craniotomy was conducted. The area where the electrical stimulus is applied by the surgeon and position where a response occurred is visualized alongside testing tasks conducted by the examiner (mainly number counting, picture naming (n), verb generation (v), and reading (r) kanji characters and hiragana, calculation) and electrical current values from 2 to 8 mA using an Ojemann cortical stimulator. The evaluation confirmed whether there was any speech arrest (SA) and/or speech impairment (SI) following electrical stimulation, and the area stimulated, task presented, and stimulus current were determined through the video records. The visualized data is entered into the electrical stimulus probe's database and is also essential for map creation on a normalized brain.

Then brain-function database using preparatory mapping and IEMAS, is transformed to normalized brain digitized brain-mapping localization with the modified electric stimulus probe. Normalized brain

with functional information is projected to individual patient's brain and predicted of brain function. Finally, structural and functional digitized data predict an intra-operative brain information.

More specifically, a sterilized instrument that could be read into the navigation system that provides updated intra-operative 0.4T MRI was installed on the bipolar electrode probe. Reading in images and position was performed using the 3D-Slicer [7], and the position log of the probe was acquired in a digital format. A coordinate transformation to convert the digital function information into the MNI-icbm normalized brain data format [8], and plot it on a 3-D brain image for visualization was carried out. Do not convert brain function response points from the intra-operative MRI (T1-WI, TE: 10 ms, TR: 27 ms, voxel size 0.9x0.9 mm) during surgery directly into normalized brain data, and first convert using the non-rigid registration [9] for each patient to the pre-operative MRI. Each pre-operative MRI is converted to the normalized format [8] using the SPM12 [10] image software coordinate transformation method in coordination with MATLAB [11].

3. Results

Log acquisition (digital format) for localization from mapping the electro-stimulator probe was conducted and this log data was acquired successfully in all cases. For the electrical stimulation positions in which patients showed SA, SI, motor and sensory responses during the cortical mapping processes, the data was tagged and testing task and electric current for the stimulus were recorded. There were 23 SA, 14 SI, 15 motor and 1 sensory responses (53 responses in total) including 17 cases. For all 17 subjects with 37 SA/SI plots and 16 motor/sensory plots, the intra-operative electro-stimulator position data was used in combination with pre-operative MRI for conversion to the normalized brain data format (Figure 1). With a focus on the language mapping, there were language responses of 14 cases on normalized 3D-brain map. There was variation of distribution for language function localization (B-Broca, NM-negative motor, W-Wernicke), task (n, v, r) and SA/SI- induced electrical stimulus intensity as to threshold. In color bar, SA (red) and SI (green) difference is mainly labelled and threshold (from 2 to 6 mA of electrical stimulus intensity) distribution is also labelled additionally. Motor unique and sensory responses in 3 cases are shown in blue.

According to the evaluation of transformation accuracy for the 10 subjects, referring to (1) each two neighbouring sulci on the electro-stimulator position and (2) the cortex surface near each tumor, the first transformation from intra- to pre-operative MRI with non-rigid registration was calculated at (1) 4.5 ± 1.0 mm, (2) 4.1 ± 1.7 mm in average, while the second transformation from pre-operative to normalized brain with SPM normalization was calculated at (1) 5.8 ± 1.4 mm, (2) 8.6 ± 3.3 mm in average.

The normalized brain datasets with functional information could project onto individual patient brain and predict the brain function. This backward conversion was performed and the accuracy of the projection was also evaluated comparing the practical brain function with brain functional simulation of 'future-predicting surgery' (Figure 2).

4. Conclusion

Intraoperative digitized localization datasets for cortical and subcortical brain mapping are acquired precisely in glioma neurosurgery. Integrated image fusion and transformation, normalized datasets compiled brain function can lead the future-predicting glioma surgery in showing individual brain function and the complication risk for maximum glioma resection.

Figures

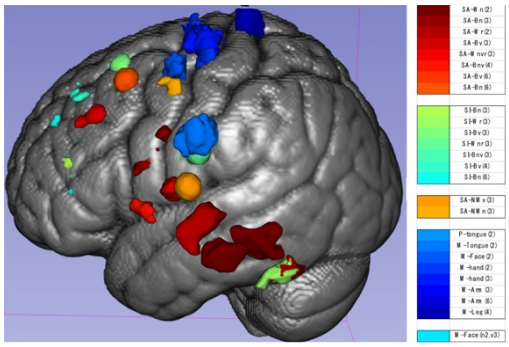

Fig. 1. SA/SI language, motor and sensory response plots onto normalized brain in color map. With a focus on the language mapping, there were language responses of 14 cases on normalized 3D-brain map. There was variation of distribution for language function localization (B, NM, W), task (n, v, r) and SA/SI- induced electrical stimulus intensity as to threshold. In color bar, SA (red) and SI (green) difference is mainly labelled and threshold (from 2 to 6 mA of electrical stimulus intensity) distribution is also labelled additionally. Motor unique and sensory responses in 3 cases are shown in blue.

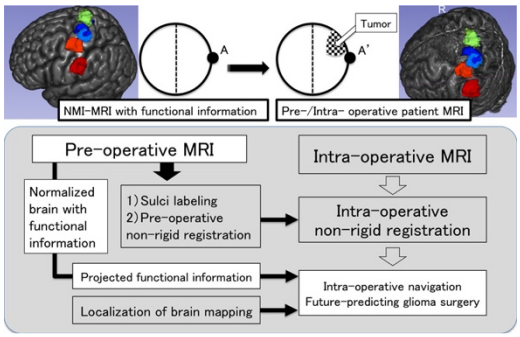

Fig. 2. Normalized brain datasets with functional information project the future-predicting glioma surgery. With the collaboration concerning image registration regarding to normalization of shifted brain and electrical distribution simulation for cortical brain mapping regarding to physics, we aim at the intra-operative brain mapping assistance using projected patient's MRI.

Conflict of interests

No potential conflicts of interest are disclosed.

Acknowledgment

This study is supported by Grant-in-Aid for Scientific Research (B-22300093, C-12007086), CREST (JST), JSPS Grant-in-Aid for Scientific Research on Innovative Areas (Multidisciplinary Computational Anatomy, JSPS KAKENHI Grant-15H01128, 17H05306) and the MIC Grant-162101001 (SCOPE).

References

1) BrainVISA. (Accessed at http://brainvisa.info/)

2) Tamura M, Maruyama T, Nitta M, Saito T, Yoshimitsu K, Konishi Y, Okamoto J, Ikuta S, Masamune K, Mangin J-F, Okada Y, Iseki H, Muragaki Y: Preoperative MRI-based delineation of the sulcal and gyral anatomy and its usefulness for glioma resection in neurosurgery. *International Journal of Computer Assisted Radiology and Surgery* 10: S91-S92, 2015

3) Muragaki Y, Iseki H, Maruyama T, Tanaka M, Shinohara C, Suzuki T, Yoshimitsu K, Ikuta S, Hayashi M, Chernov M, Hori T, Okada Y, Takakura K: Information-guided surgical management of gliomas using low-field-strength intraoperative MRI. *Acta Neurochir Suppl* 109: 67-72, 2011

4) Yoshimitsu K, Maruyama T, Muragaki Y, Suzuki T, Saito T, Nitta M, Tanaka M, Chernov M, Tamura M, Ikuta S, Okamoto J, Okada Y, Iseki H: Wireless Modification of the Intraoperative Examination Monitor for Awake Surgery -Technical Note. *Neurol Med Chir (Tokyo)* 51: 472-476, 2011

5) Tamura M, Muragaki Y, Saito T, Maruyama T, Nitta M, Tsuzuki S, Iseki H, Okada Y: Strategy of Surgical Resection for Glioma Based on Intraoperative Functional Mapping and Monitoring. *Neurol Med Chir (Tokyo)* 55: 383-398, 2015

6) Mangin JF, Riviere D, Cachia A, Duchesnay E, Cointepas Y, Papadopoulos-Orfanos D, Scifo P, Ochiai T, Brunelle F, Regis J: A framework to study the cortical folding patterns. *Neuroimage* 23 Suppl 1: S129-138, 2004

7) 3D Slicer. (Accessed at https://www.slicer.org)

8) The McConnell Brain Imaging Centre. (Accessed at http://www.bic.mni.mcgill.ca/ServicesAtlases/ICBM152NLin2009)

9) Liu Y, Kot A, Drakopoulos F, Yao C, Fedorov A, Enquobahrie A, Clatz O, Chrisochoides NP: An ITK implementation of a physics-based non-rigid registration method for brain deformation in image-guided neurosurgery. *Front Neuroinform* 8: 33, 2014

10) Statistical Parametric Mapping (SPM). (Accessed at http://www.fil.ion.ucl.ac.uk/spm/)

11) MATLAB. (Accessed at http://www.mathworks.com/index.html?s_tid=gn_loc_drop)

Evaluation of Portal Location and Insertion Direction Based on the Visibility by Automatic Image Processing Using Hip Arthroscope Simulator

Shinnosuke KAWAKAMI[*1], Norio FUKUDA[*1], Takashi NISHII[*2], Yoshito OTAKE[*1], and Yoshinobu SATO[*1]

Abstract

Arthroscopic labral repair difficulty depends on the field of view by the arthroscope inserted through a few millimeter skin incision called a portal. The field of view of the arthroscope is different depending on the portal location and the insertion direction therefrom. A representative portal location is geometrically determined with the anterior superior iliac spine and the greater trochanter of each patient as the landmark. However it is not necessarily appropriate portal that the insertion of the arthroscope from that location will give the best view. We performed automated visibility measurement using preoperative 3D surface models constructed from 15 patient-specific computed tomography data using the hip arthroscope simulator currently under development. Test insertion and rendering was performed from a total of 25 locations shifted by 5 mm from anterior to posterior, inferior and superior from the representative location on the skin surface (Fig.1 a). Target point for inserted arthroscope from these shifted portal was set to 200-400 points near the center of the fitted sphere to the articular cartilage which exclude femoral head. We carried out automated counting for intensity of pixels of the labral tear to be captured within a field of view of the arthroscope to the total captured pictures. As a result, we estimated portal location and insertion direction (Fig.1 b) that brought the highest visibility (Table 1). Moreover, mean intensity of pixels of particular o'clock direction of the labral tear captured on the arthroscope inserted from each shifted portal locations were also shown (Fig.1 c). We verified the validity of the cost function by a reasonable and reproducible result of such greedy search. From now on, we will speed up this search and plan to efficiently search for a wider range using some optimization algorithm.

Keywords：preoperative planning, hip arthroscopy, medical image

1. Purpose

The instrument which should be inserted firstly into the hip joint in the arthroscopic labral repair is the arthroscope. Therefore it must be inserted from the safest portal [1] and [2]. Representative portal location is defined by the uniform distances relative to two anatomical landmarks that is the greater trochanter and the anterior superior iliac spine. The anterolateral portal is used as a representative safest portal which established firstly using landmarks. However, this portal location is not always suitable from the visibility perspective due to the anatomical variation among patients as well as various pathological variations.

*1 Graduate School of Information Science, Nara Institute of science and technology
〔8916-5 Takayama, Ikoma, Nara, Japan〕
e-mail: shinnosuke-k@is.naist.jp
*2 Department of Orthopaedic Surgery, Osaka General Medical Center
〔3-1-56 Mandaihigashi, Sumiyoshi-ku Osaka-shi, Osaka, Japan〕

Therefore if the portal location could not correspond to these variations, inserted arthroscope will collide with acetabular or femoral head and will not be able to capture the labral tear to repair. To avoid this, the way to search the optimal paths is feasible. In endoscopic surgery, a study for as a preoperative planning using this way is in progress [3]. In arthroscopic hip surgery, especially arthroscopic labral repair, we propose the way that computation for all enable path through different portal locations to the point near the labral tear to search the portal location and insertion direction which brought the optimized visibility.

2. Method

Arthroscopic images of labral tear are obtained by the virtual camera placed in the tip of the virtual arthroscope. Firstly, the femoral head is pulled 10 or 15 millimeter toward inferior and rotate 5 degree around inferior-superior axis toward anterior to ensure the work space of the joint cavity based on an advise by the expert surgeon. A representative portal (anterolateral) location is determined using landmarks on the 3D models. Inserted arthroscope can swing at the portal as a fulcrum. Finally the arthroscope is inserted with various insertion direction at shifted 25 portal locations by the following procedure.

1) Coloring the surface of labral tear at angular intervals of 30 degree which is corresponding to 1-12 o'clock. We defined 12 o'clock is anterior axis direction at the inflection point on the positive side of the inferior axis of the anterior superior iliac spine and 3 o'clock is inferior axis direction based on 12 o'clock
2) Establish 25 locations which are shifted 5 millimeter from representative portal location toward inferior or superior and anterior or posterior direction which are numbered from 0 to 24 (Fig.1 a).
3) Arthroscope direction is set to the target points within the space between articular cartilage and femoral head sphere, then the insertion angle from anterior axis (theta) and from superior axis (phi) is determined (Fig.1 b).
4) Arthroscope is inserted through the shifted portal locations to target point with rendering and rotating around the line of sight direction as a rotating axis at angular intervals of 45 degree till reaching the target or colliding with femoral head or articular cartilage
5) Try next target point
6) Arthroscope insertion to all target is finished, portal location is shifted from inferior to superior or anterior to posterior
7) Iterate on 3) to 6) till the end of rendering at 25th portal location

We defined the following cost equation as a min-max constraint optimization problem, here px, py and pz is a coordinate of shifted portal on the skin surface, and theta, phi is an insertion direction of arthroscope.

$$f(px, py, pz, \theta, \varphi) = \max\{c(px, py, pz, \theta, \varphi)\} \quad (1)$$

3. Results

We have carried out automatic measurement against 15 cases and then we plotted pie graph with color

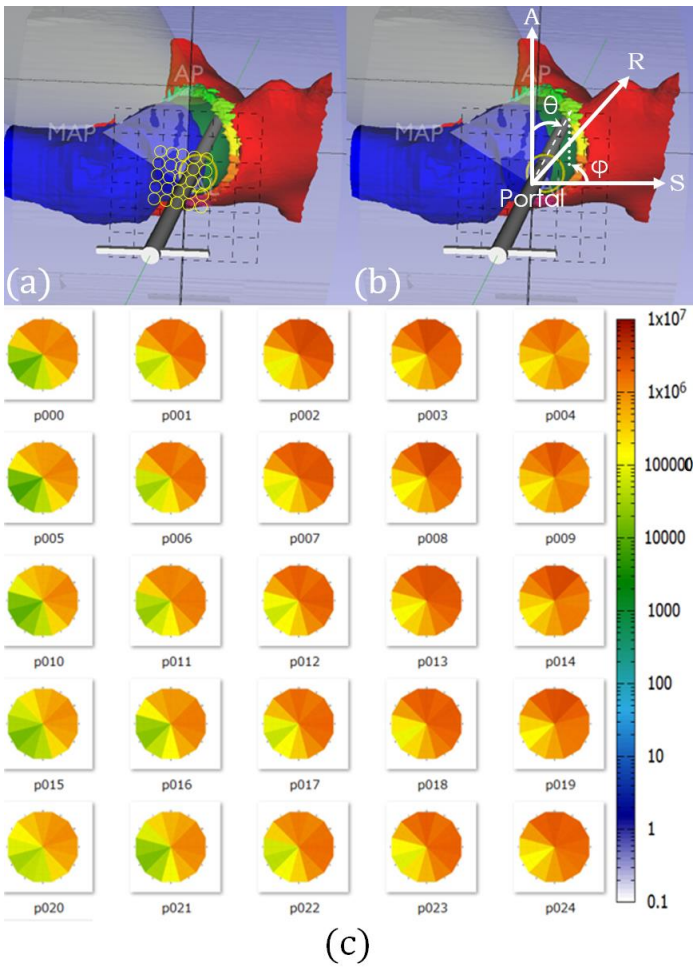

(c)

Fig. 1 (a) 25 yellow circles are portal location for arthroscope insertion. (b) arthroscope insertion angle definition. (c) resulting mean count of captured pixels of labral tear at 1-12 o'clock for 15 cases.

Table 1 For 15 cases, the portal location and the insertion angle defined in Fig. 1 when maximizing the number of captured pixels of labral tear at all time o'clock direction of labral tear.

case	portal	θ	φ	max count (x10^5)
1	20	117.8	68.1	7.7
2	11	92.4	86.2	6.9
3	0	115.7	69.2	11.0
4	2	107.9	74.4	5.7
5	1	120.3	68.4	9.8
6	1	118.6	67.9	6.0
7	14	88.6	91.6	6.1
8	23	96.0	82.5	5.0
9	20	91.3	64.5	8.0
10	18	108.7	74.2	4.9
11	0	121.5	67.2	8.2
12	19	95.0	85.0	6.9
13	8	98.0	82.0	4.1
14	12	95.4	83.6	6.9
15	19	91.8	86.0	5.7

map of the number of captured pixels at each o'clock direction of the labral tear when arthroscope inserted from each 25 portal location. Each pie graph show high visibility tendency at specific portal locations. The tendency suggests several possible cause. One is the anatomical variation among patients especially locational relation between inserted arthroscope and labral tear due to the morphological variation of articular cartilage. Another is locational relation between portal location and femoral head and articular cartilage. To analyze the visibility related to the trend of location, we calculated a mean count at each o'clock direction and plotted (Fig.1 c). As pie graph shows that the visibility of inserted arthroscope is higher at superior anterior location than the representative portal location p012 in the Fig.1 c. Furthermore, as shown in Fig. 1 c, at the representative portal location p012, the direction of 11 o'clock we defined is somewhat weaker for the direction from 1 o'clock to 8 o'clock, but p002, p003, p008, p013, p014, p019 show that the direction of 11 o'clock is well captured. Moreover, as shown in Table 1, a combination of portal location and insertion angle showing the highest visibility in each 15 cases were obtained. Regarding the direction of insertion from these portal locations, it is necessary to verify the safety of whether or not the safe distance from neurovascular is maintained, but prior research [1] and [2] on safety and confirmation to the expert surgeon are currently in progress.

4. Conclusion

We showed the tendency of the inserted arthroscope visibility at 25 portal locations shifted from representative portal location using data of 15 cases. In addition, portal locations and insertion direction were obtained with brought the highest visibility for each 15 cases leaving the verification of safety. Also, as a result of mean the pixel counts for each clock time direction of the labral tear obtained from each portal location by inserted arthroscope, a location with better visibility at a specific clock direction is obtained as compared with the representative portal location. However, it is necessary to further verify. Besides since the number of target points for inserted arthroscope is still small, we will speed up this search and plan to efficiently search for a wider range using some optimization algorithm.

Compliance with ethical standards

Conflict of interest The authors declare that they have no conflicts of interest in relation to this article and they respect protection of human and animal rights.

References

[1] J.W. Thomas Byrd: Surgical Technique: Supine Position. Operative Techniques in Orthopaedics Vol.15, issue 3: 204-217, 2005

[2] William J. Robertson, M.D., and Bryan T. Kelly, M.D.: The Safe Zone for Hip Arthroscopy: A Cadaveric Assessment of Central, Peripheral, and Lateral Compartment Portal Placement. The Journal of Arthroscopic and Related Surgery, Vol.24, No9: 1019-1026, 2008

[3] Xiaojun Chen, Jun Cheng, Xin Gu, Yi Sum, Constantinus Politis: Development of preoperative planning software for transforaminal endoscopic surgery and the guidance for clinical applications. The International Journal for Computer Assisted Radiology and Surgery, Vol.11, issue 4: 613-620, 2016

X 線画像を用いた経気管支診断支援向け 処置具 3 次元位置マッピング法の基礎検討

松崎　和喜[*1]　馬場　理香[*1]　山川　恵介[*1]　飯村　隆志[*2]

松元　祐司[*3]　中井　俊之[*3]　北川　まゆみ[*4]　麻生　智彦[*4]

要旨

X 線装置は末梢肺病変に対する経気管支鏡診断において，腫瘍細胞を採取する処置具位置を確認する目的で利用されている．X 線画像は処置具をリアルタイムに認識可能だが，2 次元投影像のため病変の前後方向の位置把握が困難な場合がある．本研究では X 線装置を用いた経気管支鏡診断支援を目指し，処置具の 3 次元位置を明瞭にする 3D 位置マッピング技術を提案し，要素技術を開発した．提案技術の基本原理は，複数方向の X 線画像と診断用に事前撮影した CT 画像を用い，術中の患者に対して位置決めを実施，処置具の 3 次元位置を認識し，CT 画像上にその 3 次元位置を表示する．患者位置決めは，2 次元画像（X 線画像）と 3 次元画像（CT 画像）による画像レジストレーション法を用い，GPU による高速化を図った．また処置具の位置認識には，パターンマッチング法を用いて自動化した．本報告では，主に人体ファントムを用いて提案手法の実現可能性を検討した．

キーワード : X 線画像，経気管支診断，処置具，3 次元位置マッピング

1. はじめに

X 線装置を用いた診断・治療の手技は，体内に挿入した処置具の位置や動きを 2 次元の X 線投影画像上に表示しながら行われる．このような手技の一つに，肺がんの確定診断を目的とした経気管支内視鏡生検がある[1]. 内視鏡を被験者の口から挿入し，内視鏡画像を確認しながら気管，および分岐した気管支を経由して病変まで進むが，分岐数が多くなる抹消では，気管支が内視鏡径よりも細いため，挿入が不可となる．このような場合に，X 線透視下で内視鏡先端からガイドシースと呼ばれる管状筒を誘導，病変部に留置し，ガイドシース内に鉗子や細胞診ブラシを挿入して生検を行う．

X 線画像は，処置具が画像上にリアルタイム表示される長所があるものの，2 次元投影像のため，画像奥行方向の情報は失われ，画像上で処置具と病変が重なって見えたとしても，必ずしも処置具が病変部にあるとは限らない．気管支内視鏡生検においても同様で，鉗子，ブラシなどの処置具と疾患部位との奥行方向の位置関係が不明瞭で，生検が困難な場合がある．このような課題に対し，本研究では X 線画像と診断用に事前撮像した 3 次元の CT 画像を用いる 3D 位置マッピング法を提案した．

*1 (株)日立製作所 研究開発グループ
〔〒185-8601 国分寺市東恋ヶ窪 1-280〕
e-mail: kazuki.matsuzaki.gv@hitachi.com
*2 (株)日立製作所　ヘルスケアビジネスユニット
*3 国立がん研究センター 中央病院 内視鏡科 呼吸器内視鏡
*4 国立がん研究センター 中央病院 放射線技術部

2. 方法

1) 提案手法

3D 位置マッピング法の概要を図 1 に示す．まず，生検手技中の被験者位置と，CT 撮影時の被験者位置を一致させる画像レジストレーションを行う（図 1(1)）．ここで生検時の被験者は X 線装置で取得された 2 次元画像であり，診断時の被験者は CT 装置で取得された 3 次元画像であるため，これらをレジストレーションするためには工夫が必要である．2 次元画像と 3 次元画像のレジストレーション法として，放射線治療等に用いられる患者位置決め法が知られている[2]．これは 3 次元画像である CT 画像から，X 線画像を取得した装置体系を模擬し，X 線画像と類似した計算投影画像を演算する（図 1(1)-1）．さらに 2 次元の計算投影画像と X 線画像の類似度を計算する（図 1(1)-2）．これらを対応撮影角度毎にレジストレーションすることで，生検時と診断時における被験者の移動，回転量を求めることが可能となる．次に，生検時に取得した X 線画像上で，処置具の特徴部位，特に先端位置を検出する（図 1(2)）．X 線画像は投影画像であるため，実際の処置具先端は，画像上の先端位置と X 線源を結ぶ直線上に存在する．これら直線を X 線源およびパネルを回転させ複数方向から求めることで，理想的には直線が交わる位置に処置具が存在し，3 次元位置を算出することが可能である（図 1(3)）．最後に，求めた 3 次元位置を CT 画像上にマッピングする（図 1(4)）．前述した画像レジストレーション法と，処置具先端の自動認識認法の詳細について，次節で述べる．

2）2D-3D 画像レジストレーション法

実撮像 X 線画像と CT 画像から作成した計算投影画像とをレジストレーションするため，画素値ベース法を採用した．画素値ベース法は，画素値を比較する類似度と，類似度の最大，もしくは最小を探索する最適化法が必要である．今回は類似度と最適化法として，医用画像の分野で実績のある標準化相互情報量（Normalized Mutual Information : NMI）[3]と Powell 法[4]を用いた．また臨床における 3D 位置マッピング法の利用シーンは，内視鏡生検手技中であり，迅速な結果提示が求められる．そこで計算負荷の高い計算投影画像の計算に，近年さまざまな分野で高速化に用いられる GPU を採用し，計算の高速化，およびレジストレーション結果の妥当性を検討した．

3）処置具位置認識法

複数方向の各 X 線画像を用いて処置具の先

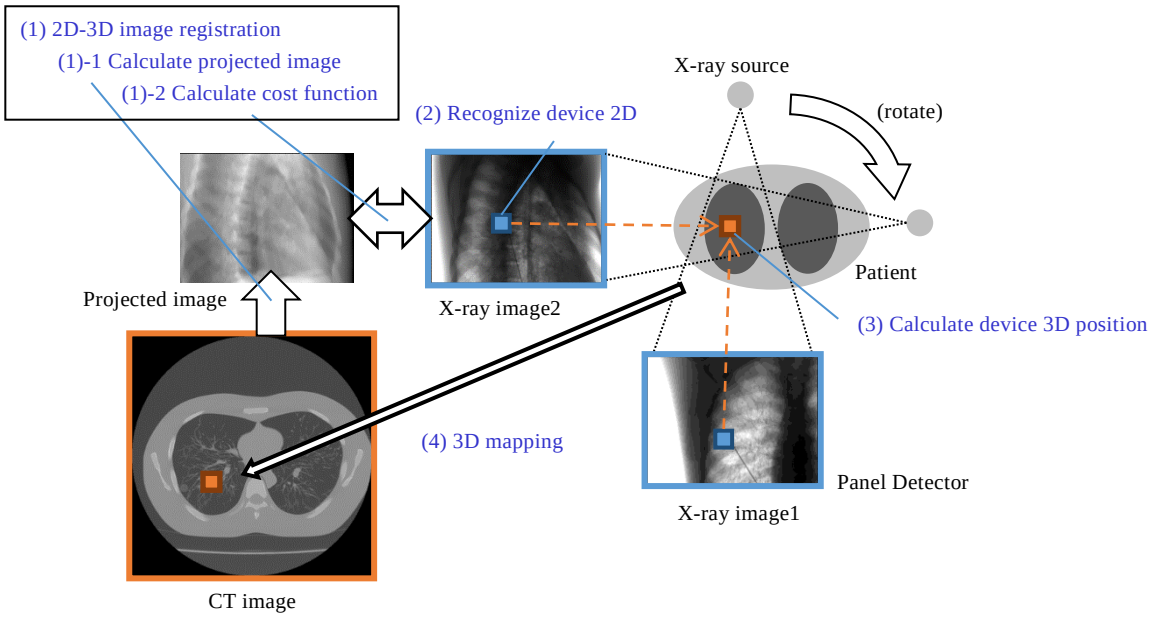

図 1　3D 位置マッピング法の基本原理

端位置の検出法には，画像中の処置具形状が比較的明瞭でテンプレート作成が容易，また計算負荷が低いパターンマッチング法を採用した．処置具は曲線のパターンが複数存在するため，必要なパターン画像の種類が膨大となる．そのため処置具形状を短く分割，直線形状とみなし，任意の処置具位置から先端に向け，曲線に沿い逐次的に探索して，処置具の複数パターンに対応する方法を提案，評価した．

3. 結果

本研究では，人体ファントムを用い 3 方向の X 線画像と CT 画像の組合せを，ファントムや処置具の位置を変更して 3 ケース取得し，開発手法を評価した． 撮影した X 線画像例を図 2 に示す．各方向において処置具とその先端（図 2 矢印）は認識可能だが，模擬腫瘍および処置具と腫瘍の位置関係の認識は困難であった．

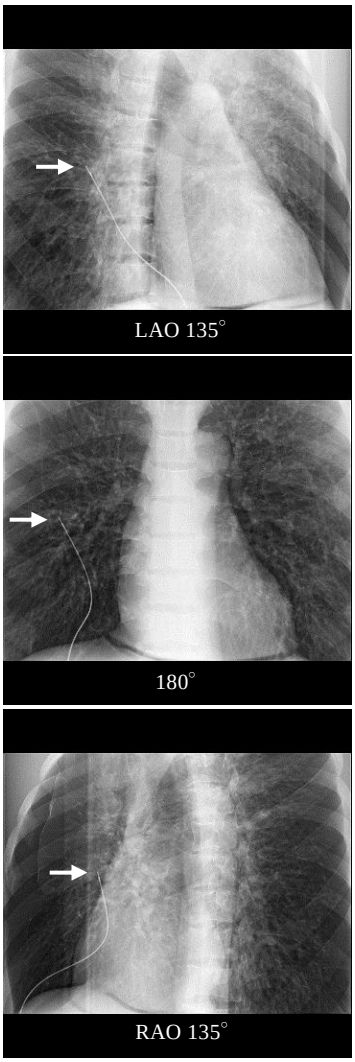

図 2　3D 位置マッピング用 X 線画像例(3 方向)

画像レジストレーションにおける計算投影画像の取得に CPU もしくは GPU を用いた場合に要した計算時間の比較結果を表 1 に示す．CPU と比較し GPU を用いた場合，約 100 倍の高速化が可能であり，レジストレーション単体の計算時間は約 10 秒以内であった．また画像レジストレーションの 6 パラメータに関する精度評価結果を表 2 に示す．全ケースで各軸方向の誤差は，1mm 以下，各軸回転の誤差は，1° 以下を確認した．

表 1 画像レジストレーションの計算時間

	Case 1	Case 2	Case 3
CPU [msec.]	1333830	1067499	1131438
GPU [msec.]	10018	8224	8643

表 2 GPU による画像レジストレーション結果

	Case 1	Case 2	Case 3
Shift x [mm]	0.02	0.11	0.10
Shift y [mm]	-0.15	0.06	0.07
Shift z [mm]	-0.09	-0.2	-0.19
Rotate x [deg.]	0.08	0.14	0.17
Rotate y [deg.]	0.07	0.02	0.02
Rotate z [deg.]	-0.01	-0.02	0.08

各方向の X 線画像における処置具先端位置の認識結果を表 3 に示す．全ケースの平均誤差 0.24 mm，最大誤差 0.43mm を確認した．

表 3 処置具先端位置の認識結果

	Direction	Error[mm]
Case 1	LAO 135°	0.39
	180°	0.19
	RAO 135°	0.19
Case 2	LAO 135°	0.19
	180°	0.19
	RAO 135°	0.19
Case 3	LAO 135°	0.19
	180°	0.43
	RAO 135°	0.19

3D 位置マッピングの結果表示例を図 3 に示す．X 線画像のみでは認識困難であった腫瘍位置および腫瘍と処置具の位置（図 3 十字交点）関係が明瞭となり，特に処置具が模擬腫瘍の背側に位置している状態を明瞭に認識可能であった。

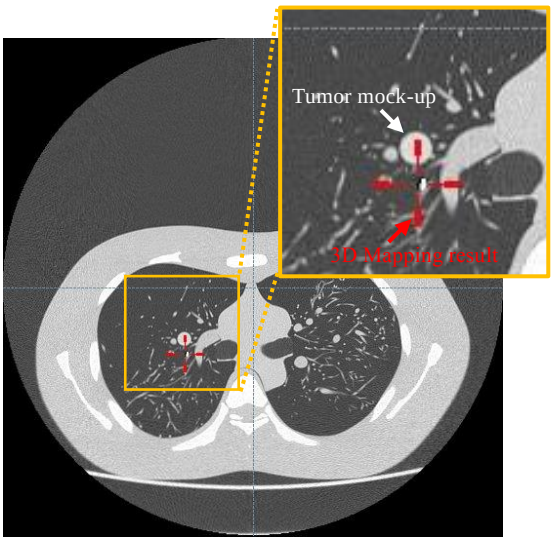

図 3　3D 位置マッピング表示結果例

4. まとめ

X 線装置を用いた診断・治療手技，特に経気管支診断を支援する処置具 3 次元位置マッピング法を提案，開発し，ファントムを用いた基礎検討を実施した．2D - 3D 画像レジストレーションでは，画素値ベース法，および GPU を用いて自動，高速化可能なことを確認した．また X 線画像における処置具先端位置を，パターンマッチング法により高精度に認識可能なことを確認した．これらを 3 次元位置マッピング法に適用し，X 線画像のみでは困難であった腫瘍と処置具の位置関係の明瞭化が可能なことを確認した．以上から，3 次元位置マッピング法は X 線装置を用いた手技支援に有用であると考えられる．

利益相反の有無

本研究の発表者である松崎和喜，馬場理香，山川恵介，飯村隆志は，（株）日立製作所に属する社員である．

文　献

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

［2］　梅川徹：粒子線治療向け繰返し DRR 生成による自動 6 自由度患者位置決め法．医学物理 29，2009

［3］　F. Maes, et al. : Multi-Modality Image Registration by Maximization of Mutual Information. IEEE Transactions on Medical Image, 1997, pp.14-22

［4］　W. H. Press, et al. : Numerical Recipes in C (C 言語による数値計算のレシピ), 技術評論社，東京，1993

Feasibility study of x-ray image guided device 3D mapping method for diagnostic bronchoscopy

Kazuki MATSUZAKI[*1], Rika BABA[*1], Keisuke YAMAKAWA[*1], Takashi IIMURA[*2],
Yuji MATSUMOTO[*4], Toshiyuki NAKAI[*3], Mayumi KITAGAWA[*4], Tomohiko ASO[*4]

*1 Hitachi, Ltd. Research & Development Group
*2 Hitachi, Ltd. Healthcare Business Unit
*3 National Cancer Center Hospital Department of Endoscopy
*4 National Cancer Center Hospital Department of Radiological Technology

In medical diagnosis or therapy using x-ray imaging apparatus, we proposed 3D mapping method that navigates a device to lesion, and developed image processing methods and applications. The x-ray image enables us to monitor devices; however, the depth position is unclear due to projection image from x-ray apparatus. In 3D mapping, we used multiple angle x-ray images in diagnostic bronchoscopy and CT image for diagnosis. First, patient positioning was carried out using image registration method with x-ray images and CT image. Then, a position of a device for diagnostic biopsy was calculated from multiple angle x-ray image. Finally, the 3D position was mapped in CT image. The 3D mapping technique is carried out in diagnostic bronchoscopy; therefore, all image processing methods need to be short period of time and automated procedure. In this study, we developed fast ray-trace method using GPU, and automated device recognition method using pattern matching. As a result, maximum calculation time for automated image registration was about 10.0 second in all test cases, and the maximum device recognition error was 0.43mm, we achieved the target specifications. In conclusion, 3D mapping methods has good potential to recognize 3D position of device in diagnostic bronchoscopy.

Key words: X-ray image, Diagnostic bronchoscopy, treatment tool, 3D mapping

Prostate localization method based on anatomical feature points in a Bayesian delineation framework for prostate cancer radiotherapy

Kenta NINOMIYA[*1], Hidetaka ARIMURA[*2], Motoki SASAHARA[*1]
Taka-aki HIROSE[*1,3], Saiji OHGA[*4]

Abstract

We aimed to develop a prostate localization method based on anatomical feature (AF) points in a Bayesian delineation framework (BDF) for prostate cancer radiotherapy. Prostate locations were estimated by using a random forest from five AF points, which were manually selected on prostates, bladder and rectums in sagittal planes of planning computed tomography images. The proposed method was applied for placing probabilistic atlas to extract prostate regions in BDF. Centroids of prostate regions determined by radiation oncologists were employed as reference prostate locations. The average location estimation error of prostates and Dice's similarity coefficient between the reference and extracted prostate regions were 2.4±1.3 mm and 0.80±0.070 for 44 test cases, respectively.

Keywords : prostate cancer radiotherapy, anatomical feature points, Bayesian inference, probabilistic atlas, planning computed tomography

1. Introduction

More than 1 million men worldwide are diagnosed with prostate cancer per year [1]. Prostate cancer is the second most common type of cancer in the world, whereas the mortality due to prostate cancer accounts for only 6.6% of all cancer deaths [1]. Therefore, prostate cancer is curable, and radiotherapy has contributed to the low mortalities [2]. Around 40% of prostate cancer patients over the age of 65 years are treated only with radiotherapy [3]. With regard to radiotherapy treatment plans for prostate cancer, radiation oncologists manually delineate contours of the clinical target volume (CTV). However, low contrasts of prostates with surrounding tissues on planning computed tomography (CT) images could lead to tedious delineations and interplanner variations in CTV contours [4, 5]. Therefore, the automated delineation frameworks of the prostate on CT images are needed for clinical practice, since automated delineation frameworks could reduce these variations of contours.

Bayesian delineation frameworks (BDF) could be feasible for estimation of the low contrast

*1 Department of Health Sciences, Graduate School of Medical Sciences, Kyushu University〔3-1-1 Maidashi, Higashi-ku, Fukuoka, 812-8582, Japan〕
e-mail: knt.eat.24splash@gmail.com
*2 Sciences Department of Health Sciences, Faculty of Medical Sciences, Kyushu University
*3 Department of Medical Technology, Kyushu University Hospital
*4 Department of Clinical Radiology, Graduate School of Medical Sciences, Kyushu University

prostates [6, 7]. However, one of the drawbacks in the BDF is that the prostate locations where probabilistic atlases (PAs), which represent existence probabilities of the prostate at each voxel, should be positioned are unknown. No trials have been made for developing approaches for determination of prostate locations, where the PAs should be positioned.

The goal of this study was to develop a prostate localization method based on anatomical feature (AF) points in the BDF for prostate cancer radiotherapy.

2. Materials and frameworks

We used 44 cases including planning CT images (pixel size: 0.9766 mm, matrix size: 512×512) and binary images of the prostates which were derived from their contours determined by radiation oncologists. The binary images of prostates were used as the reference prostate regions and centroids of them were served as reference centroids of prostate regions (CPRs) (prostate locations).

The CPRs were estimated using a random forest (RF) [8] from five AF points, which were manually selected on prostates, bladder and rectums in sagittal planes of planning CT images.

Figure 1 illustrates the five AF points of the lowest point of the bladder, contact point of the bladder with the prostate, "center" point of the prostate, front point of the rectum, and rear point of the rectum, which were manually determined as position vectors on the sagittal planes of planning CT images. The lowest and contact points of the bladder were selected based on the evidence that the lower bladder border correlated with the prostate displacements [9]. The "center" points of the prostate were selected by an observer as prostate rough locations. The front and rear points of the rectum were reportedly moved by volume changes in the rectum, displacing the prostates [9, 10].

The RF was constructed for the estimation of prostate locations along the anterior-posterior (AP) and superior-inferior (SI) directions, separately, since the CPR displacements along the left-right (LR) direction were small (<1.3 mm). The CPRs along the AP and SI directions were separately estimated using RF, which learned the relationships between the reference CPRs and the AF points. The RF was trained for each direction by feeding 43

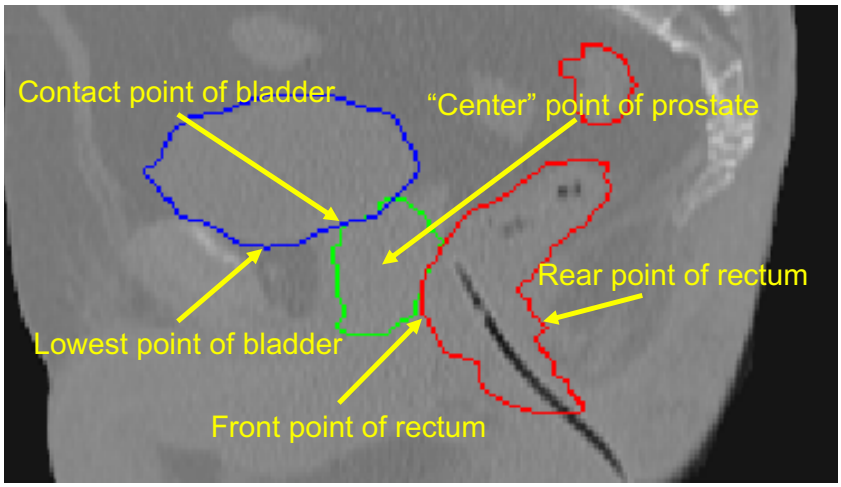

Figure 1. Five anatomical feature points (*) manually selected on the bladder edge (blue), the rectum edge (red), and within the prostate (green): the lowest point of the bladder, a contact point of the bladder with the prostate, a "center" point of the prostate, a front point of the rectum, and rear point of the rectum.

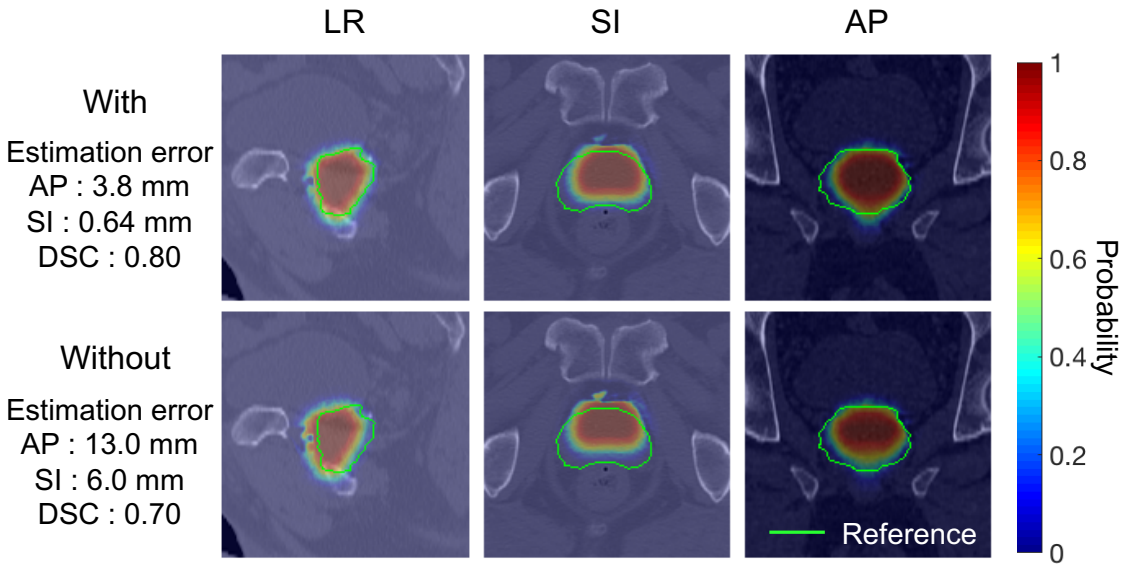

Figure 2. Prostate regions estimated with and without the proposed method.

training datasets of the reference CPRs and feature vectors consisting of five coordinates of the AF points.

To investigate the feasibility of the proposed method, estimated CPRs were applied for placing prostate PA at the coordinates and extracting prostate regions using the BDF with occurrence probabilities of CT values with prostate regions and its surrounding regions. [11].

The proposed framework was evaluated by calculating location estimation errors of CPRs and the Dice's similarity coefficient (DSC) [12] based on a leave-one-out-cross-validation test for 44 cases. The location estimation errors were calculated by subtracting the estimated CPRs from the reference CPRs along the AP and SI directions. The DSCs were calculated between estimated and reference prostate regions. The location estimation errors and DSCs with the proposed method were compared to that without the proposed method by Student's t-test (two tailed).

3. Results and Discussion

Figure 2 shows the prostate regions estimated with and without the proposed method. Table 1 summarizes results of the evaluations. The average location estimation errors for 44 test cases with and without the proposed method were 2.4±1.3 and 5.6±3.7 mm ($p<0.001$), respectively. The average DSCs for 44 test cases were 0.80±0.070 (with) and 0.69±0.13 (without) ($p<0.001$).

In this study, only 43 cases were used for the RF training in the leave-one-out test. The use of a lesser number of training data can lead to overfitting to the teaching data in the training step [13]. The use of several larger datasets that have a variety of CPRs or anatomical feature points can help provide a more accurate estimation of the CPRs.

Table 1. Average location estimation errors in mm of CPRs and DSCs with and without the proposed method.

		With	Without
Estimation error (mm)	AP	2.0±2.0	5.7±4.6
	SI	2.8±2.2	5.5±4.3
	Mean	2.4±1.3	5.6±3.7
DSC		0.80±0.070	0.69±0.13

4. Conclusions

We have developed the prostate localization method based on AF points in the BDF for prostate cancer radiotherapy. The proposed method could be feasible for estimation of the prostate locations in the BDF.

Acknowledgement

The authors would like to express their appreciation to all of the members of the Arimura laboratory who provided precious comments and advices for this study.

Conflict of interests

The authors do not have any conflict of interests to disclose.

References

[1] Torre LA, Bray F, Siegel RL et al: Global Cancer Statistics. 2012. CA a cancer J Clin, 2015; 65:87–108

[2] Hamdy FC, Donovan JL, Lane JA et al: 10-Year Outcomes after Monitoring, Surgery, or Radiotherapy for Localized Prostate Cancer N Engl J Med, 2016; 375:1415–1424

[3] Miller KD, Siegel RL, Lin CC et al: Cancer treatment and survivorship statistics, 2016; CA Cancer J Clin 2016; 66:271–289

[4] Fiorino C, Reni M, Bolognesi A et al: Intra- and inter-observer variability in contouring prostate and seminal vesicles: Implications for conformal treatment planning. Radiother Oncol, 1998; 47:285–292

[5] Livsey JE, Wylie JP, Swindell R et al: Do differences in target volume definition in prostate cancer lead to clinically relevant differences in normal tissue toxicity? Int J Radiat Oncol Biol Phys 2004; 60:1076–1081

[6] Chen S, Lovelock DM, Radke Richard J. RJ.: Segmenting the prostate and rectum in CT imagery using anatomical constraints. Med Image Anal, 2011; 15:1–11

[7] Martínez F, Romero E, Dréan G et al: Segmentation of pelvic structures for planning CT using a geometrical shape model tuned by a multi-scale edge detector. Phys Med Biol, 2014; 59:1471–1484

[8] Meinshausen N: Quantile Regression Forests. J Mach Learn Res, 2006; 7:983–999

[9] Roeske JC, Forman JD, Mesina CF et al: Evaluation of changes in the size and location of the prostate, seminal vesicles, bladder, and rectum during a course of external beam radiation therapy. Int J Radiat Oncol Biol Phys, 1995; 33:1321–1329

[10] Zelefsky MJ, Crean D, Mageras GS et al: Quantification and predictors of prostate position variability in 50 patients evaluated with multiple CT scans during conformal radiotherapy. Radiother Oncol, 1999; 50:225–234

[11] Ninomiya K, Arimura H, Sasahara M et al: Automated delineation framework of clinical target volume on treatment planning computed tomography based on Bayesian inference for prostate cancer radiation therapy. Proc Jpn Society Med Imag Tech, 2017; 520-524

[12] Crum W, Camara O, Hill D et al: Generalized Overlap Measures for Evaluation and Validation in Medical Image Analysis. IEEE Trans Med Imaging, 2006; 25(11):1451-1461

[13] Bishop CM: Pattern Recognition and Machine Learning. Pattern Recognit, USA: Springer; 2006.

前立腺癌放射線治療におけるベイズ領域推定法のための解剖学的特徴点に基づいた前立腺位置推定法

二宮健太[*1]，有村秀孝[*2]，笹原基希[*1]，
廣瀬貴章[*1,3]，大賀才路[*4]

*1 九州大学大学院医学系学府保健学専攻
*2 九州大学大学院医学研究院保健学部門
*3 九州大学病院医療技術部
*4 九州大学大学院医学研究院臨床放射線科

本研究の目的は前立腺癌放射線治療におけるベイズ領域推定法のための解剖学的特徴点に基づいた前立腺位置推定法を開発することである．治療計画 CT 画像上の前立腺，膀胱，直腸から選択された５つの解剖学的特徴点を学習した，Random forest 法を用いて前立腺の位置を推定した．提案手法で推定した位置座標に確率アトラスを配置し，ベイズ領域推定法を用いて領域推定を行った．放射線腫瘍医によって決定された前立腺領域を参照領域として用い，提案手法の評価を行った．提案手法を用いた場合の平均の前立腺位置推定誤差と DSC はそれぞれ，2.4±1.3 mm と 0.80±0.070 であった．

Key words: 前立腺癌放射線治療，解剖学的特徴点，ベイズ推定，確率アトラス，治療計画 CT

画像誘導放射線治療のリアルタイム腫瘍追跡における患者個別深層学習を実現する非線形データ拡張方法

照沼　利之[*1]　友田　光一[*2]　榮　武二[*1]

大西　かよ子[*1]　奥村　敏之[*1]　櫻井　英幸[*1]

要旨

新たなマーカーレス腫瘍追跡法が筆者らにより開発された．提案法は，従来のいわゆるビックデータを利用する深層学習ではなく放射線治療を受ける患者個別情報から非線形なデータ拡張により多数の訓練画像を生成した深層学習である点が特徴である．訓練用画像の画像特徴と教師画像間の位置的な共起確率を制御することにより，骨構造特徴が追跡に不必要な情報であり軟組織特徴が追跡に重要な情報であるという認識を誘導した．提案された非線形データ拡張による過学習抑制効果を臨床画像で確認した．

キーワード：患者個別深層学習，非線形データ拡張，リアルタイム腫瘍追跡、画像誘導放射線治療

1. はじめに

深層学習(DL: deep learning)の医用応用は，CAD (computer assisted diagnosis)を代表する診断領域で特に進んでおり，治療領域においても治療計画支援のために臓器抽出や腫瘍領域推定などの研究例がある．これらの深層学習では一般的に教師あり学習が採用され，訓練画像はいわゆるビックデータ,すなわち「多数の患者」の「正しい情報」である．

一方，放射線治療時のリアルタイム X 線透視による腫瘍追跡の場合は，事前情報として治療計画作成時に取得した対象患者の CT (computer tomography)情報を活用可能である．

*1 筑波大学医学医療系
〔〒305-8576 つくば市天王台 1-1-1〕
e-mail: terunuma@pmrc.tsukuba.ac.jp
*2 筑波大学大学院人間総合科学研究科

一般的にマーカーレス腫瘍追跡法の研究では，CT から作成した仮想 X 線透視画像(DRR: digitally reconstructed radiograph)の腫瘍領域をテンプレート学習する template matching (TM)法が試みられていた．しかし次の要因，1）X 線透視のエネルギー領域では光電効果が大きく透視画像上に骨構造が強調され追跡の妨げになること，2）CT 画像と X 線透視画像の分解能の差やX線透視の被曝量の問題から学習用 DRR と臨床 X 線透視画像の画質が異なること，などにより TM 法のようなデータベース参照型手法では追跡精度の向上は難しい．訓練画像と試験画像の画質差に対応するためには統計的手法の導入が不可欠であり，多数のテンプレートを使用する方法も考えられるがリアルタイムの演算の問題がある．

筆者らは,上記の骨構造による誤追跡に対処するために，深層学習を用いたマーカーレス腫瘍追跡法を開発した．提案法は，治療対象の「１患者のみ」から訓練画像を作成すると

同時に，臨床的に「誤った情報」を積極的に使用するデータ拡張方法である［1］．本報告では，提案法の訓練データ生成の意義を再考するとともに，臨床画像による追跡結果ついて考察する．

2. 方法

通常の治療計画 4 DCT で作成される DRR は呼吸位相毎の 10 枚の画像となる．このデータ数は一般的な深層学習が要求する訓練データ数からすると少なすぎるため，いわゆるデータ拡張(data augmentation)が必要である．
我々の提案手法では，軟組織 DRR にランダムに骨 DRR を重ね合わせた画像を訓練画像とする［1］．これは，深層学習は多数のデータ間の統計的な共起確率により重要な特徴量を抽出する手法であるという我々の理解に基づいている．この方法により，図 1 に示すように，訓練画像の軟組織特徴の位置は教師画像（腫瘍位置を楕円で示す）に対して強相関となるが，骨特徴の位置は教師画像に対して無相関となる．従って，深層学習が進むにつれて，腫瘍追跡に重要な情報は軟組織特徴であり追跡に不必要な情報は骨特徴であるという認識を誘導することが期待できる．

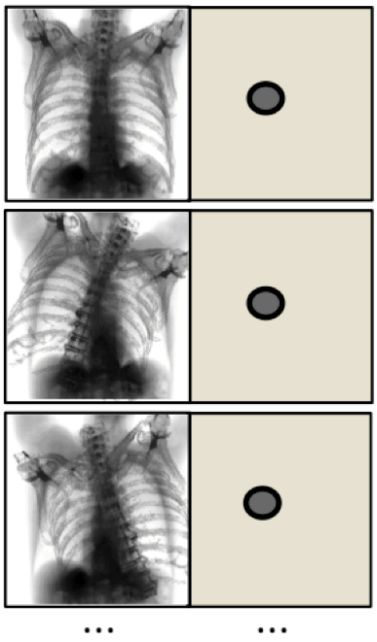

図 1　訓練画像（左）と教師画像（右）の例

深層学習におけるデータ拡張法として画像の幾何学変換やノイズ付加が知られている．一般的にノイズ付加では一様ノイズが使用されるが，ランダムであれば特に一様である必要性は少なく，ノイズが特定のパターンであっても共起確率が低く保たれてば問題はない．従って，我々の提案法は骨構造というノイズパターンをランダムに重ね合わせた非線形のデータ拡張法とみなすことができる．一般的にデータ拡張は過学習を抑制する効果があることが知られており，本提案法でも同様に過学習抑制効果が期待できる．本報告では，この過学習抑制効果を訓練画像と異なる画質の試験画像，1）人工的に試験画像のみにノイズを加えた場合，2）試験画像として臨床画像を使用した場合，で検証する．本提案法では CNN(convolutional neural network)に SegNet を使用している．

3. 結果

人工的に試験画像のみにノイズを加えた場合の結果例を図 2 に示す． この例では，骨構造をランダムに重ね合わせたノイズなし訓練用 DRR で学習した CNN(convolutional に，標準偏差 30 %の正規分布ノイズを印可した試験用 DRR による追跡結果を図 2 に示す．

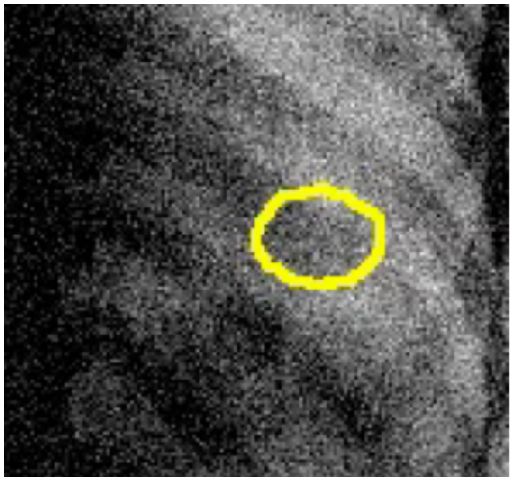

図 2　ノイズ付加試験画像による追跡結果例
（黄色：任意に作成した楕円形標的）

試験画像として臨床画像を使用した結果例を図 3 に示す.

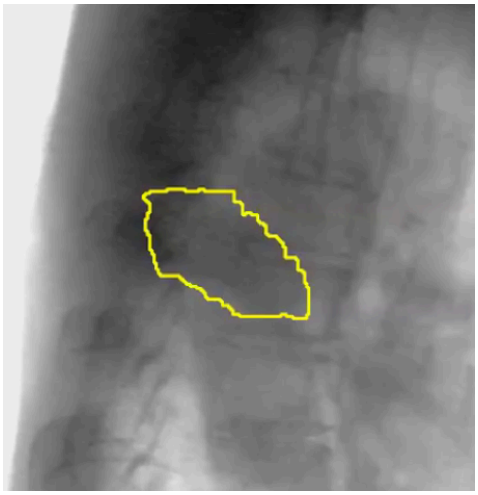

図 3　臨床画像による追跡結果例
（黄色：投影した臨床標的体積）

臨床画像による試験では, 訓練用画像は治療計画用 CT による空間分解能 1.0 mm/pixel および2.5 mm/slice による CT 情報から作成されており，臨床 X 線透視画像の空間分解能 0.3 mm/pixel と大きく乖離する．また，当施設の X 線透視画像は I.I. (image intensifier)により取得されており約 10 %の画像ノイズを持つ．このような画質差に対しても強靭な追跡が可能であることを考えると，本提案法が過学習抑制効果を持つことは明らかである.

4. まとめ

提案された患者個別深層学習によるマーカーレス腫瘍追跡法の非線形データ拡張による過学習抑制効果が示された．臨床 X 線透視画像による試験においてもその有用性が示された.

謝辞

本研究は JSPS 科研費 17K09054 の助成を受けたものです.

利益相反の有無

なし

文　献

［1］ Terunuma T, Tokui A, Sakae T: Novel real-time tumor-contouring method using deep learning to prevent mistracking in X-ray fluoroscopy. Radiol. Phys. Technol. **11(1)**: 43-53, 2018

深層学習による単純ＣＴにおける急性期脳梗塞の自動検出

高橋　規之[*1]，木下　俊文[*1]，大村　知巳[*1]

松原　佳亮[*1]，李　鎔範[*2]，豊嶋　英仁[*1]

要旨

近年，急性期脳梗塞に対する血栓回収療法が行われるようになり，画像診断で早期虚血変化を捉えることが益々重要になってきた．しかし，CT 画像では早期虚血変化を同定することが難しい．そこで，本研究では deep learning を用いた単純 CT における急性期脳梗塞の早期虚血変化の自動検出法を提案する．脳 CT 画像をアトラスに変換した後，左右脳実質に関心領域を設定し対象領域のみを抽出する．最後に，抽出された左右領域を一対として切り出し，CNN への入力画像とした．本研究ではレンズ核を対象領域とした．正常 28 例と，レンズ核に早期虚血変化を認めた 50 例を評価に用いた．その結果，レンズ核に対する検出感度は 92%，特異度は 96.4%，正診率は 93.6%，AUC 値は 0.980 であった．

キーワード：CT, 急性期脳梗塞，畳み込みニューラルネットワーク

1. はじめに

近年，急性期脳梗塞に対する血栓回収療法が行われるようになり，発症から治療までの時間短縮が求められ，画像検査を短時間で終える必要性が出てきた．そのため短時間で行える単純 CT 検査が見直されてきている．単純 CT では，脳梗塞による早期虚血変化を捉えることが重要であるが，CT 値がわずかに低下した虚血変化を同定することが難しく，そのためには読影医師の知識と経験が必要となる．

我々は，過去にこの問題を解決するために早期虚血変化のコンピュータ支援診断（computer-aided diagnosis: CAD）システムを提案した [1,2]. 提案したシステムでは，脳アトラスを用いたボクセル統計解析により Z スコアマップを作成し，早期虚血変化域を高信号化した．アトラス上に設定した関心領域内の Z スコア分布から特徴量を抽出して判別分析を行い，虚血変化の有無を判定した．

近年，深層学習の高い識別性能に注目が集まり，医用画像における CAD の改善にも応用されてきた[3]．画像認識では convolutional neural network（CNN）がよく用いられており，事前に画像からの特徴量を抽出する必要がなく画素値情報のみを入力するだけで高い識別率を実現している．このような背景から，CT 画像の急性期脳梗塞早期虚血変化の検出にも深層学習が有用であることが考えられる．本研究では深層学習を用いた単純 CT における急性期脳梗塞の早期虚血変化の自動検出法を提案する．

2. 方法

本研究は秋田県立脳血管研究センターの倫理委員会の承認を得た．

対象画像として，発症 4.5 時間以内の急性期脳梗塞 50 例と正常例 28 例の単純 CT 画像を使用した．これらの画像は，37 例が Siemens 社製，

*1 秋田県立脳血管研究センター放射線医学研究部
[〒010-0874 秋田市千秋久保田町 6-10]
e-mail: takahashi-noriyuki@akita-noken.jp
*2 新潟大学大学院保健学研究科
投稿受付：2017 年　月　日

41 例が Canon 社製の CT 装置から得られた．1 例当たりのスライス数は 28～32 枚，スライス厚は 4～5 mm であった. 脳梗塞 50 例の内訳は，右レンズ核に早期虚血変化を認めた 23 例と左に認めた 27 例である．神経放射線科医師 2 名の合議により早期虚血変化の有無を決定した．

初めに，statistical parametric mapping（SPM8）を用いて，CT 画像の脳実質形状をアトラスに変換する．変換後，半値幅 2 mm のガウシアンフィルタを用いて平滑化処理を行った．アトラス変換後の画像サイズは 313×377×34，ボクセルサイズは 0.5×0.5×4 mm になった．次に，左右のレンズ核にそれぞれ関心領域（region of interest: ROI）を設定する[図 2(b)]．ROI の位置と形状は，本研究で使用した CT 画像とは別に用意した，アトラス変換した CT 画像を参考にして決定した．レンズ核は連続する 3 スライスに描出されていたため，1 例当たり 3 スライスに ROI を設定した[図 2(b)]．1 スライスごとに左右の ROI 内を切り出し，左右一対を図 2(c)のように貼り付け，識別のための入力画像（140×140 pixels）を作成した．右側に虚血変化がある場合を RI，左側にある場合を LI，どちらにもない正常を N として，3 群で学習･識別を行った．

ここでは，RI を 69（23 例×3 スライス）枚，LI を 81（27 例×3 スライス）枚，N を 84（28×3 スライス）枚それぞれ作成した．

深層学習用ツールとして DIGITS 5.0（NVIDIA corporation）を用いた．ネットワークには AlexNet [4]を使用した．また，data augmentation [4] によって対象画像から学習用画像を増やした．移動 10 パターン，回転 5 パターン，左右反転 2 パターンで，1 枚の画像から 100 枚の画像を生成した．なお，移動では左右レンズ核領域の間隔を 20 pixels 広げ，上下左右に 10 pixels シフトした. 回転は 5 度間隔で 10 度まで行った．左右反転では虚血側が反転するため，反転した LI を RI に，同様に反転した RI を LI に混ぜて学習した．したがって，対象画像は，N が 8,400 枚，RI と LI がそれぞれ 7,500 枚になった．学習には，これらの画像を用い，学習率は 0.001，エポック数は 12 とし，最適化手法には AdaGrad を用いた．

性能評価には leave-one-out 交差検証を用い，症例に関する識別性能を求めた．78 例の全 234 スライスの識別結果を求めた後，症例ごとに各群の 3 スライスの平均出力値を求め，最も高い値を示した群を症例に対する識別結果とした．

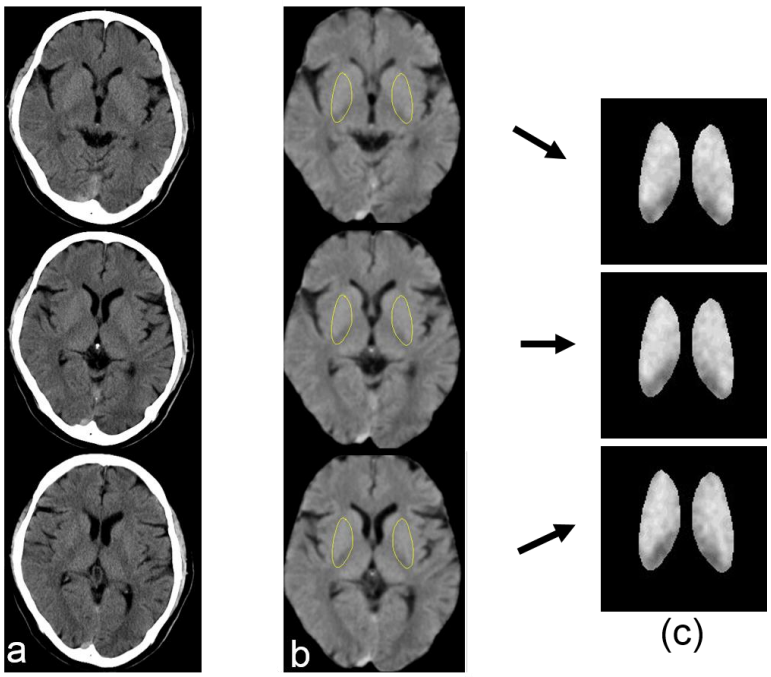

図 2 学習画像作成例． (a) CT 画像 (b) アトラス変換画像（黄色線は ROI） (c) 識別入力画像

3. 結果と考察

レンズ核に早期虚血変化を認めた 50 症例と正常 28 例における正診率は 93.6%, 感度は 92%, 特異度は 96.4%になった．識別結果を表 1 に示す．提案法は, ASPECTS のレンズ核領域に対して正確に早期虚血変化を検出できることがわかった．図 3 に，レンズ核の識別の例を示す．

本研究では，深層学習においては比較的少ない症例数であったが，高い正診率を獲得することができた．本手法では，早期虚血変化の存在判定に必要な領域のみを，脳アトラスをベースとして抽出し，左右領域を一対として画像に張り付けた．脳領域全体からの虚血変化の検出ではなく，関心領域内での識別を対象としたことが，高い性能を有した理由であると考える．

臨床では，視覚的定量化手法である Alberta Stroke Programme Early CT Score（ASPECTS）を用いて医師が虚血の範囲を同定する．ASPECTS 法は中大脳動脈領域を 10 分割し，各領域で虚血変化の有無を判定する．それらの領域の 1 つであるレンズ核領域は，なかでも発生頻度が高く診断に重要である．この領域で高い正診率を得た本手法は，急性期脳梗塞の診断に有効であることが示唆された．今後，残りの 9 領域について試みる予定である．

4. まとめ

深層学習を用いた単純 CT における急性期脳梗塞の早期虚血変化を自動検出するアルゴリズムを提案し臨床画像に適用した結果，高い検出性能を得た．提案手法は単純 CT における急性期脳梗塞の診断支援に有用であると考える．

利益相反の有無

なし

表 1 レンズ核領域の識別結果

	識別結果			
正解		RI	LI	N
	RI	20	1	2
	LI	0	26	1
	N	1	0	27

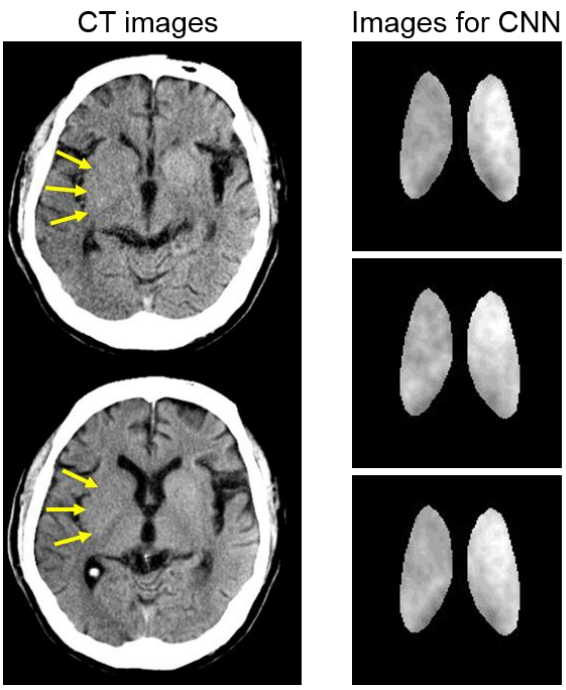

図 3 レンズ核の早期虚血変化を正しく検出した例

文　献

[1] Takahashi N, Tsai DY, Lee Y, et al.: Z-score mapping method for extracting hypoattenuation areas of hyperacute stroke in unenhanced CT. Acad Radiol. **17**: 84–92, 2010

[2] Takahashi N, Tsai DY, Lee Y, et al.: Computer-aided detection scheme for identification of hypoattenuation of acute stroke in unenhanced CT. Radiol Phys Technol. **5**: 98–104, 2012

[3] Roth HR, Lu L, Liu J, et al.: Improving Computer-aided detection using convolutional neural networks and random view aggregation, IEEE Transactions on Medical Imaging. **35**: 1170–1181, 2016

[4] Krihevesky A, Sutskever I, Hinton GE: ImageNet classification with deep convolutional neural networks, Proc. of 26th Annual Conference on Neural Information Processing Systems (NIPS), 1106–1114, 2012

Computerized Detection of Acute Stroke in Unenhanced CT Using Deep Learning

Noriyuki TAKAHASHI[*1], Toshibumi KINOSHITA[*1], Tomomi OHMURA[*1], Keisuke MATSUBARA[*1], Yongbum LEE[*2], Hideto TOYOSHIMA[*1]

*1 Research Institute for Brain and Blood Vessels-Akita

*2 Graduate School of Health Sciences, Niigata University

For thrombolysis of hyperacute stroke, quantifying the extent of regions of early ischemic change is mandatory. However, detection of regions of the ischemic change is considerably difficult on unenhanced CT images. Our purpose of this study is to develop an atlas-based detection method of ischemic change of hyperacute stroke on CT images using a convolutional neural network (CNN). The algorithm of the developed method consisted of four main steps: anatomic standardization, determination of region of interest (ROI), cropping the ROIs, and classification using the CNN. The method was applied to 50 patients who had early ischemic change areas (<4.5 h) in the lentiform nucleus and 28 normal controls. As a result, we obtained the sensitivity of 92%, the specificity of 96.4% and the accuracy of 93.6% for the classification in the lentiform nucleus region. The newly developed method has the potential to accurately identify ischemic change of hyperacute stroke in the lentiform nucleus in unenhanced CT.

Key words: CT, hyperacute stroke, convolutional neural network

Capsule network を用いた磁化率強調像の教師あり学習による脳循環代謝異常の予測の試み

松原　佳亮[*1]　高橋　規之[*1]　梅津　篤司[*2]

茨木　正信[*1]　木下　俊文[*1]

要旨

近年 Geoffrey Hinton により提案された Capsule network (CapsNet)は画像上のオブジェクトの空間情報を保持したまま学習が可能であり，膨大な学習データを必要としないため，医用画像診断における応用が期待できる．本研究では CapsNet を用いて磁化率強調像(SWI)を学習し，脳虚血に伴う酸素摂取率(OEF)亢進の予測を試みた．片側性脳血管狭窄閉塞症の患者(n=145)の SWI から抽出した 108 x 108 voxels の領域を入力，中大脳動脈支配領域における OEF の患側/健側比が 1.05 以上かどうかを教師とし，CapsNet による教師あり学習を実施した．その結果，78.7±1.9%の正答率で OEF 亢進を予測できた．CapsNet により OEF 亢進がある程度予測できることが示されたが，精度向上のために学習の更なる工夫が必要とされる．

キーワード：深層学習，磁化率強調像，capsule network，脳卒中，CAD

1. はじめに

脳虚血に伴う酸素摂取率(oxygen extraction fraction, OEF)の亢進を測定する方法としては[^{15}O]酸素ガスを用いた PET 検査が gold standard となっており，手術を行うかどうかの意思決定において重要な検査となっている［1］．一方，MR 装置で撮像された磁化率強調像(susceptibility-weighted imaging, SWI)に於いても，脱酸素ヘモグロビンの増加に伴う静脈の増強所見から OEF の亢進を捉えることができる［2, 3］．しかし，SWI 上の微細な静脈増強所見を正確に読影するには経験を要するため，静脈増強所見の読影を支援するシステムが望まれている．

近年，従来より深いニューラルネットワークにより学習を行う深層学習の技術が広範な分野で活発に利用され始めており，特に convolutional neural network (CNN)は自然画像処理の分野において目覚しい成果を挙げている［4, 5］．脳血管障害の医用画像診断においても脳虚血領域の抽出［6］や脳梗塞の検出［7］, MR angiography 上の動脈瘤の検出［8］などに応用されている．

一方で CNN はプーリング処理等により歪みや平行移動に対する不変性を獲得する代わりに，画像上のオブジェクトの向き，位置やオブジェクト同士の位置関係などの空間的情報を学習の過程で失ってしまうという欠点がある［9, 10］．そのためオブジェクト個々の特徴しか認識できない．また空間的情報の学習ができないため，高い認識精度を獲得するためにはオブジェクトの向きや位置が異なる大量のデータを学習しなければならない．従って大量のデ

*1 秋田県立脳血管研究センター放射線医学研究部
〔〒010-0874 秋田市千秋久保田町 6-10〕
e-mail: matsubara@akita-noken.jp
*2 東北大学病院放射線診療科

ータの準備が困難な医用画像の分野においてはデータ拡張などの工夫が必要となる．

上記の CNN の問題を解決する新しいネットワークとして capsule network (CapsNet) が Geoffery Hinton らにより提案された［11］．CapsNet はオブジェクトの向きや位置などの空間的情報をベクトルで扱う capsule を連ねたネットワークであり，capsule 間の結合の強さを学習していくことで空間的情報を認識することができる．従って位置などの情報が重要となる医用画像の分野における応用が期待できる．

本研究では CapsNet の医用画像分野への可用性・有用性を検討するために，SWI の教師あり学習による OEF 亢進の予測について CapsNet の適用を試みたので報告する．

2．方法

2.1．対象

本研究では SWI 及び ^{15}O PET 検査の両方を施行した片側性主幹動脈狭窄閉塞症患者 145 名を対象とし，対象患者の SWI 及び ^{15}O PET データを後方視的に解析した．

2.2　SWI

SWI は 1.5T（MAGNETOM VISION，シーメンス）もしくは 3T MRI 装置（Verio，シーメンス）で撮像した．おおよその脳の形状・位置を合わせるため，代表的な 1 例を参照とした線形の位置合わせ処理を行った．位置合わせには FSL FLIRT (Wellcome centre integrative neuroimaging, University of Oxford, UK)［12］を用いた．撮像された SWI の側脳室～半卵円中心レベルの各スライス（5 スライス）の患側半球から図 1 のように 108×108 の領域（パッチ）を抽出し，それぞれを学習における入力データとした．入力したデータの総数は 145 例×5 スライス×5 領域=3625 patches とした．

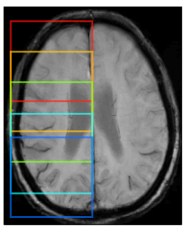

図 1 SWI における 108×108 のパッチの抽出例

2.3　^{15}O PET

^{15}O PET データは PET/CT 装置（SET-3000GCT/M，島津）で 3D 収集した．収集条件等詳細は先行研究と同様である［13］．オートラジオグラフィー法［14］により計算した OEF 定量画像の中大脳動脈支配領域に楕円形の関心領域を取り，OEF の患側/健側比を評価した．OEF の患側/健側比が 1.05 以上か否かを OEF の亢進の有無と定義し，学習におけるラベルとした．

2.4．CapsNet

本研究で適用した CapsNet を図 2 に示す．CapsNet は Conv1, PrimaryCaps, DigitCaps の 3 つの層で構成される［11］．

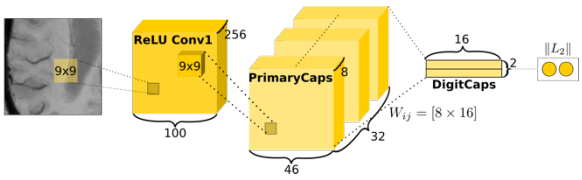

図 2 本研究で適用した CapsNet（［11］Figure 2 を改変）

Conv1 は入力画像の局所特徴量を抽出する通常の畳み込み層である．PrimaryCaps では Conv1 の出力を畳み込み層で 8 次元のベクトル(capsule)に変換する．この capsule に画像上オブジェクトの空間的情報が格納される．DigitCaps では PrimaryCaps で出力された 8 次元の capsule に対して capsule 間の結合度を計算する routing 処理（詳細は後述）が行われ，2 個の 16 次元 capsule が出力される．最後に 2 個の 16 次元 capsule を基にして OEF が更新されているか否かの 2 クラス分類を行う．Conv1 及び PrimaryCaps における畳み込みカーネルの大きさは 9×9 とした．

CapsNet ではオブジェクト同士の空間的な関係を学習するために”routing”によって各 capsule 同士の結合度 c_{ij} を学習する．l 層目（本研究の場合は PrimaryCaps，添字は i）から l+1 層目（本研究の場合は DigitCaps，添字は j）の capsule への入力は以下のように計算される．

$$\mathbf{s}_j = \sum_i c_{ij} \cdot \hat{\boldsymbol{u}}_{j|i} \quad (1)$$

$$\hat{\boldsymbol{u}}_{j|i} = \boldsymbol{W}_{ij} \cdot \boldsymbol{u}_i \quad (2)$$

$\boldsymbol{u}_i$ は l 層目の i 番目の出力ベクトルであり，$\mathbf{W}$ はそれに適用される重み行列である．(1), (2)式が示す通り，l+1 層目の capsule は l 層目の capsule のアフィン変換の重み付き総和である．なお，capsule の長さがその capsule の存在確率（0 から 1 の値）を表すようにするために，以下の(3)式にあるような”squashing”を行った．

$$\mathbf{v}_j = \frac{\|s_j\|^2}{1+\|s_j\|^2} \cdot \frac{s_j}{\|s_j\|} \tag{3}$$

ここで $\mathbf{v}_j$ は出力ベクトルである．l 層目の capsule と l+1 層目の capsule との結合度 c_{ij} は以下の softmax 関数により計算される．

$$c_{ij} = \frac{\exp(b_{ij})}{\sum_k \exp(b_{ik})} \tag{4}$$

“routing”では各 capsule の結合の重み b_{ij} を予測したベクトル$\hat{\boldsymbol{u}}_{j|i}$と現在の出力ベクトル $\mathbf{v}_j$ との一致度$a_{ij} = \hat{\boldsymbol{u}}_{j|i} \cdot \mathbf{v}_j$で逐次的に更新しすることで capsule 間の結合度を学習していく．詳細は［11］を参照されたい．

CapsNet による分類の評価関数としては以下の margin loss を用いた．

$$L_k = T_k \cdot \max\left(0, m^+ - \|\mathbf{v}_j\|\right)^2$$

$$+\lambda \cdot (1 - T_k) \cdot \max\left(0, m^- - \|\mathbf{v}_j\|\right)^2 \tag{5}$$

T_k はクラス k が存在する時に 1 となる変数であり，m+, m-, λ については［11］で提案されている値を用いた（$m^+ = 0.9$, $m^- = 0.1$, $\lambda = 0.5$）．［11］と同様に DigitCaps の出力を 3 層の全結合層で構成された decoder で再構成された画像と入力画像との二乗誤差(reconstruction loss)に 0.0005 を掛けたものを margin loss に足し合わせた誤差を total loss とし，total loss を誤差逆伝播することで学習を行った．バッチサイズは 32，エポック毎のバッチ数は 91 として，50 エポックの学習を行った．学習率は 0.0001 とし，エポック毎に 0.9 の割合で学習率を減衰させた．最適化には Adam［15］を用いた．入力した SWI パッチに対してデータ拡張は行わなかった．CapsNet の実装は PyTorch ライブラリ［16］を用いて行った．

2.5. 判別精度の評価

CapsNet による OEF 亢進の判別精度については正答率(accuracy)，感度(sensitivity)，特異度(specificity)による評価を行った．精度評価のために 145 例のデータを 5 分割し，5-fold cross validation を行った．

CapsNet の有用性を検証するための参照として，108×108 のパッチに対してテクスチャ解析を行って得られた特徴量をサポートベクターマシン(SVM)で学習した場合の精度についても評価した．

表 1 OEF 亢進の判別精度．単位は%．
括弧内は標準偏差．

学習方法	正答率	感度	特異度
SVM	71.0 (2.3)	47.8 (5.1)	85.6 (1.3)
CapsNet	78.7 (1.9)	63.0 (2.5)	88.5 (1.7)

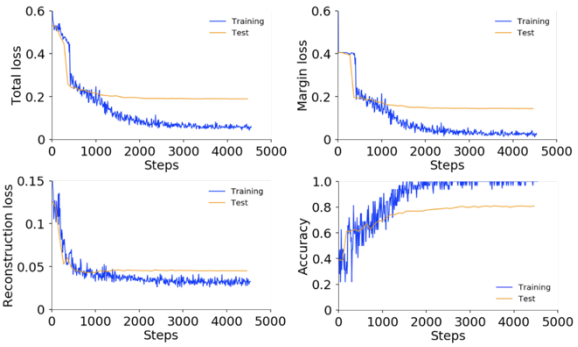

図 3 CapsNet による学習の学習曲線. Total loss, margin loss, reconstruction loss 及び正答率について示している．青が training，オレンジが test である．

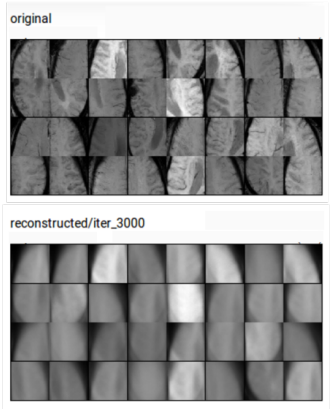

図 4 入力画像（上）と decoder で再構成された画像（下）．

3. 結果

表 1 にあるように CapsNet による OEF 亢進の判別精度は正答率，感度，特異度の全てにおいて SVM より優れていた. 図 3 に代表的な cross validation データセットの学習における学習曲線を示す．Test において training より大きな誤差がみられ，正答率も悪かった.

decoder で再構成された DigitCaps の出力を図 4 に示す．頭部の輪郭や大まかなテクスチャは復元できているが，細かい構造まで復元するには至らなかった.

4. 考察

本研究により CapsNet を用いて SWI を学習させることで OEF の亢進を約 8 割の正答率で判別できることが示された. この成績は SVM などの従来の機械学習手法より優れたものであり，医用画像診断の分野においても CapsNet が応用できる可能性が示された.

一方で，CapsNet の判別精度について約 8 割という正答率は必ずしも高い値ではなく，また特に感度は 63%と依然悪い数値となっている．本検証においては test データにおける誤差が training のそれより大きくなる過学習の傾向がみられている．従って，学習率などのハイパーパラメータや CapsNet における capsule の数，チャンネル数などを調整し，精度を向上させる必要がある.

Decoder による再構成において細かい構造を復元できなかった要因としては，[11] と同様にノード数の少ない全結合ネットワークを decoder として用いたことが考えられる．[11] では画像サイズが 28×28 と小さい MNIST データセットを対象としていたため，復元ができていたが，今回は 108×108 と大きかった．Reconstruction loss を改善し，学習自体の質を向上させるためにも，ノードの数を増やすか，畳み込みネットワークによる復元を行うなどする必要があるだろう.

5. まとめ

CapsNet を用いた SWI の学習により OEF の亢進をある程度予測することが可能であることが本研究により示された．更なる精度の向上の為に学習のパラメータの更なる検証や学習方法の工夫が必要である.

謝辞

本研究は JSPS 科研費 JP16K19869 の助成を受けたものです.

利益相反の有無

なし

文　献

［1］ Okazawa H and Kudo T: Clinical impact of hemodynamic parameter measurement for cerebrovascular disease using positron emission tomography and 15O-labeled tracers. Ann Nucl Med **23**: 217-227, 2009

［2］ Santhosh K, Kesavadas C, Thomas B et al: Susceptibility weighted imaging: a new tool in magnetic resonance imaging of stroke. Clin Radiol **64**: 74-83, 2009

［3］ Park MG, Yang TI, Oh SJ et al: Multiple hypointense vessels on susceptibility-weighted imaging in acute ischemic stroke: surrogate marker of oxygen extraction fraction in penumbra? Cerebrovasc Dis **38**: 254-261, 2014

［4］ Krizhevsky A, Sutskever I, Hinton GE: ImageNet Classification with Deep Convolutional Neural Networks. In: Pereira F, Burges CJC, Bottou L et al eds. Advances in Neural Information Processing Systems Vol. 25. Curran Associates, Inc. 2012, pp1097-1105

［5］ Szegedy C, Vanhoucke V, Ioffe S et al: Rethinking the Inception Architecture for Computer Vision. In Proceedings of IEEE Conference on Computer Vission and Pattern Recognition (CVPR), Las Vegas, 2016, pp2818-2826

［6］Chen L, Bentley P, Rueckert D: Fully automatic acute ischemic lesion segmentation in DWI using convolutional neural networks. NeuroImage Clin **15**: 633-643, 2017

［7］Ghafoorian M, Karssemeijer N, Heskes T et al: Deep multi-scale location-aware 3D convolutional neural networks for automated detection of lacunes of presumed vascular origin. NeuroImage Clin **14**: 391-399, 2017

［8］Nakao T, Hanaoka S, Nomura Y et al: Deep neural network-based computer-assisted detection of cerebral aneurysms in MR angiography. J Magn Reson Imaging **47**: 948-953, 2018

［9］Preserve Knowledge: Geoffrey Hinton: What is wrong with convolutional neural nets? | Fields Institute 2017. https://www.youtube.com/watch?time_continue=3&v=Mqt8fs6ZbHk（2018 年 4 月 24 日閲覧）

［10］Kendrick Tan: Capsule Networks Explained. https://kndrck.co/posts/capsule_networks_explained/（2018 年 4 月 24 日閲覧）

［11］ Sabour S, Frosst N, Hinton GE: Dynamic Routing Between Capsules. In: Guyon I, Luxburg UV, Bengio S et al eds. Advances in Neural Information Processing Systems Vol. 30. Curran Associates, Inc. 2017, pp3856-3866

［12］Jenkinson M, Bannister PR, Brady JM et al: Improved optimization for the robust and accurate linear registration and motion correction of brain images. NeuroImage **17**: 825-841, 2002

［13］Ibaraki M, Miura S, Shimosegawa E et al: Quantification of Cerebral Blood Flow and Oxygen Metabolism with 3-Dimensional PET and ^{15}O: Validation by Comparison with 2-Dimensional PET. J Nucl Med **49**: 50-59, 2008

［14］Mintun MA, Raichle ME, Martin WRW et al: Brain Oxygen Utilization Measured with O-15 Radiotracers and Positron Emission Tomography. J Nucl Med **25**: 177-187, 1984

［15］ Kingma D, Ba J: Adam: A method for stochastic optimization. arXiv preprint arXiv: 1412.6980, 2014

［16］ PyTorch core team: PyTorch. https://pytorch.org/（2018 年 5 月 9 日閲覧）

Computer-aided prediction of elevation in oxygen extraction fraction in cerebrovascular disease: supervised learning of susceptibility weighted image with capsule network

Keisuke MATSUBARA[*1], Noriyuki TAKAHASHI[*1], Atsushi UMETSU[*2]
Masanobu IBARAKI[*1], Toshibumi KINOSHITA[*1]

*1 Department of Radiology and Nuclear Medicine, Research Institute for Brain and Blood Vessels - Akita
*2 Department of Diagnostic Radiology, Tohoku University Hospital

Capsule network (CapsNet), proposed by Geoffrey Hinton, can learn spatial features of objects on image and their relationship. We aimed to demonstrate applicability for CapsNet on prediction of elevation in oxygen extraction fraction (OEF) in stroke with supervised learning of susceptibility weighted image (SWI). Patches of 108 x 108 voxels were extracted from SWI on 145 patients with steno-occlusive disease, and regarded as input of the supervised learning. Larger ratio of OEF between ipsi- and contra-lateral territories for middle cerebral artery than 1.05 was defined as elevation of OEF. Trained CapsNet classified elevation of OEF with 78.1 ± 1.9 % accuracy. The results suggest CapsNet can be useful to diagnose OEF elevation from SWI. Further improvement of hyperparameters and architecture of CapsNet is required for more accurate diagnosis of stroke.

Key words: deep learning, susceptibility weighted imaging, capsule network, stroke, CAD

脳 MRI 画像類似症例検索のための 3 次元畳み込みオートエンコーダによる次元削減

新井　颯人[*1]　茶山　祐亮[*1]　彌冨　仁[*1]　Kenichi Oishi[*2]

for the Alzheimer's Disease Neuroimaging Initiative

要旨

医療分野において，病気特有の視覚的特徴をもとにした類似症例検索技術は診断支援の目的で非常に需要が高い．しかし，患者個体差や撮影環境差の影響は疾病に起因する特徴よりも大きく実現が困難である．そのため，画像処理と機械学習技術による効果的な類似症例検索技術の構築が期待されるが，MRI など 3 次元モダリティでは 1 症例あたり数百万 voxel（=次元）以上のデータとなり元の情報を保持した上での次元圧縮が必須である．そこで本研究では，類似症例検索システムのための大規模な次元圧縮技術を提案する．提案手法は，脳 MRI 画像の位置合わせと，三次元畳み込みオートエンコーダから構成され，500 万次元の入力を 150 次元までに圧縮しつつ，臨床現場で神経科医が着目する領域を保持し，1 voxel 当たりの RMSE で約 8%を実現した．本研究では，圧縮された各次元が元の入力のどの領域に寄与するかの可視化を行い，検索システムの更なる利便性向上の可能性を確認した．

キーワード：脳 MRI, 次元圧縮, オートエンコーダ, 類似画像検索

1. はじめに

神経学的疾病は世界で最も一般的な障害と言われている[1]. 神経放射線医学は神経障害の診断および管理の重要な役割を果たし，日々様々な手法を用いたニューロイメージングが行われている．特に，脳の解剖学的構造や病理を放射能被爆なしに撮影可能である magnetic resonance image（MRI）が広く用いられ，神経学的疾病の診評価のために多数の脳画像が撮影されている．撮影画像は医療画像管理システム Picture Archive and Communication System（PCAS）に記録されており，大量の脳 MRI 画像と，それに対応する医療記録からなるこのビッグデータはさまざまな病気の診断と治療方法に関わる新たな証拠を提供する可能性がある．そのため，既存の臨床記録から臨床関連情報を抽出する努力がなされているが，その際不可欠となるのがデータ検出技術である．

現在，文字列をキーとした医療画像の検索は広く使用されている．しかし，データベースから期待する画像を検索するためには画像の特徴を正しく記述するための知識が必須となる上，1 つの画像に含まれる情報量は膨大であるため適切な指定は困難である．したがって，一般に content-based image retrieval（CBIR）と呼ばれる，画像由来の特徴に基づきデータベースから画像を検索する技術が強く望まれている．

従来，CBIR を 3 次元画像に適用するためにいくつかの試みがなされてきたが[2], [3], 一般的な CBIR システムへの運用性は十分に評価されておらず，未解決の問題である．特に高分解能の脳 MRI 画像の場合, 次元の数が非常に大きく，CBIR 技術に深く関わる識別，回帰，クラスタリングを直接行うことが困難である．そのため適切な次元削減が不可欠である，これらの診断様式に適した次元削減技術は未だ少ない．

一方, 近年の機械学習技術, 特に Convolutional neural networks（CNN）の画像認識性能は劇的に改善され[4], 医療画像を使用して医師が診断する際に留意する視覚的特徴の自動認識が実用的となった．さらに，2 次元画像に対して有望な結果を示す CNN の処理を多次元に対する処理に拡張することで，3 次元画像を連続したスライスではなく，3 つの空間次元すべての位置情報を加味した高い認識精度が期待される．Hosseini-Asl ら[5] は 3 次元脳 MRI を用いてア

*1 法政大学理工学研究科応用情報工学専攻

*2 Department of Radiology,
Johns Hopkins University School of Medicine

ルツハイマー病（AD）を予測する分類問題に3D-CNN を導入し，入力として画像スライスを使用する従来の方法を超える精度を達成している．しかし，限られた種類の病気に分類する分類器は，生物学的および病理学的に異種の臨床事例に適応する必要がある検索システムには適用できない．そこで脳全体の特徴を認識する特徴抽出器を構築することにより，実用的な特徴表現の獲得が見込まれる．また，過去の症例に対する類似性を定量的に決定するために，抽出された特徴はクラスタリング手法により距離メトリックに基づいたグループ化がなされなければならない．

そこで，本論文では，CBIR システム実現のための重要な要素として，3 次元畳み込み自己符号化器（3D convolutional autoencoders: 3D-CAE）を用いた脳 MRI 画像のための新しい圧縮方法を提案した．結果は，様々な定量的評価を行うと共に，神経放射線学において豊富な経験を有する神経科医による視覚的な評価を行った．

2. 方法

2.1. データセットと前処理

3D-CAE の学習および評価に 3 次元脳 MRI のデータセットである ADNI2[6]を使用した. 学習には， amyloid-positive Alzhiemer’s disease (AD)112 例と amyloid- negative cognitively normal (CN)146 例を，評価には Early Mildly Cognitive Impairment（EMCI）と診断された患者 152 例を使用した. また, MRICloud（www.MRICloud.org）を使用することで，強度の不均一性を修正し，空間への直交変換を行った [7]．また, 3D-CAE の処理を効果的に行うためにゼロパディング処理を施し，データサイズを 150×184×140 から 160×192×160 への変換を行った．

2.2. 3 次元畳み込みオートエンコーダ

本研究では，入力画像から診断に実用的である特徴を保存しながら圧縮が可能である 3D-CAE に注目した．設計した 3D-CAE は脳 MRI 画像を入力とし，視覚的特徴を保存したまま，任意の低次元表現に圧縮する．オートエンコーダ(AE)は，入力と再構成された出力との間の損失関数を最小化することで，入力を表現する潜在的特徴を学習する教師なし学習アルゴリズムであり，エンコーダと呼ばれる圧縮工程と，デコーダと呼ばれる復元工程により構成される．エンコーダでは入力$\mathrm{x} \in R^D$を特徴表現 $\mathrm{y} \in R^d (D \gg d)$ に写像し，デコーダでは$z = \hat{\mathrm{x}} \sim R^D$への逆写像を行う．

ここで注目すべき点は，デコーダはエンコーダによって圧縮された特徴表現のみを用いて入力を再構成することである．したがって，学習した AE により元の入力画像 x との類似性を有する再構成データ x が得られた場合，低次元の特徴表現 y は元の入力画像 x を表す特徴を十分に保持しているとみなすことが可能である．CAE は AE の概念を継承し，さらに 2 次元画像認識分野で最先端の精度を有することで知られている CNN の構成要素である畳み込み層とプーリング層から構成されるアーキテクチャである．また，それらの処理を拡張することで 3 次元入力に対応させたものが 3D-CAE である．

2.3. 正則化

一般的に，オートエンコーダにより学習されるパラメータに制約を設けることで，自由度を抑制し，未知のデータへの汎化性能が高まることが知られている．本研究では，デコーダのフィルタ上の各重みを集合とみなし，これらの集合を有する行列を転置し，エンコーダの対応する層と共有することで重みの共有を行った．この処理により，疑似的な Tied-Weight 構造を実現した．

3. 実験

本実験では，層数の異なる 5 つの 3D-CAE を構築することで獲得する特徴表現の次元を変更し，それぞれで入力と再構成された出力の二乗誤差（RMSE）と信号対雑音比（SNR）を算出することで再構成の性能を評価した．

各 3D-CAE は得られる特徴表現の次元数dがそれぞれ 614,000, 76,800, 9,600, 1,200, 150 となるように設計した．

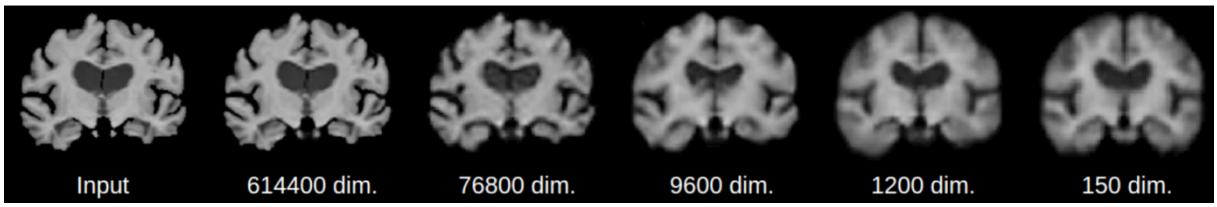

図 1 特徴表現次元数に伴う再構成画像の変化

表 1 圧縮次元と RMSE の関係

層	次元数d	RMSE [%]		SNR [dB]	
		AD+CN	EMCI	AD+CN	EMCI
1	614,400	1.91	1.95	25.23	25.01
2	76,800	4.60	4.57	15.90	15.91
3	9,600	6.18	6.14	13.19	13.22
4	1,200	7.49	7.66	11.03	10.63
5	150	7.86	8.45	10.64	9.72

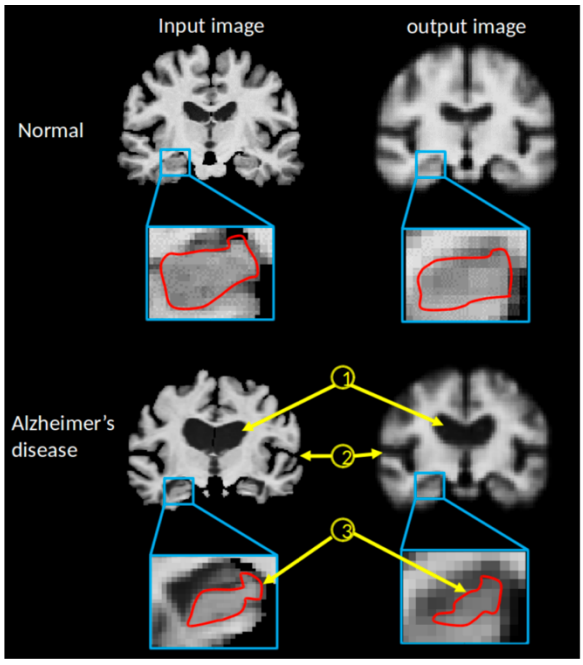

図 2 放射線科医によるスライス画像の視覚的評価

表 1 は再構成された出力の RMSE および SNR であり，次元数 d の減少に伴い RMSE の増加および SNR の値が低下することが分かる．

図 1 は，入力画像と，次元数dの特徴表現を用いて再構成した体積データをグレースケールの 256 階調に変換し，その一部断面を視覚化したものである．次元数 d の減少に伴い再構成画像が不明瞭なものになり，9,600 次元以下では脳の輪郭特徴が顕著ではなくなっていることが分かる．

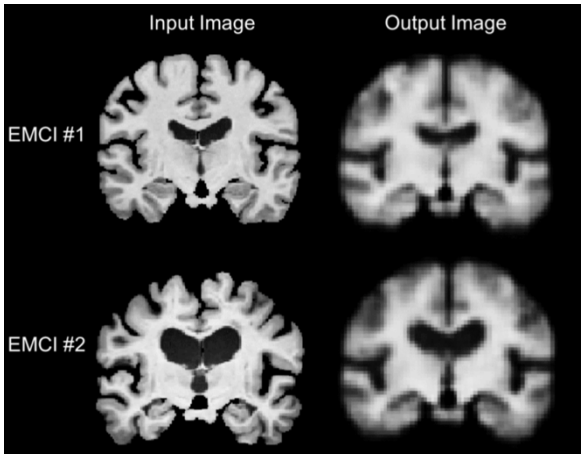

図 3 学習に未使用なデータ（EMCI）の再構成画像

特徴表現の利用目的はクラスタリングや検索タスクであるため，可能な限り小さな次元に圧縮することが望ましい．そのため，最小寸法の特徴表現の妥当性をさらに評価するために，可視化した画像を用いた神経学者による視覚的評価を行った．図 2 は，上段が CN，下段が AD のデータの代表的な結果を示す．150 次元から再構成された画像（右列）は，例えば（1）心室拡大，（2）ルビウス裂の拡大，（3）海馬縮小など，アルツハイマー病に関連する解剖学的特徴が十分に保存されていることを示している．一方で，個人に固有の特徴が表れやすい皮質の領域は不明瞭であることが分かる．

さらに，3D-CAE はネットワークの学習に使用していない未知データに対する汎化性能も有することが確認された．図 3 は，二人の EMCI 患者の再構成画像を示し，上段は認知的に正常な患者の脳と視覚的に類似した症例を，下段は萎縮症状が見られる症例を示す．

結果より，モデルは未知データの入力の固有特徴を抽出することが可能であることが示された．

表 2 選択した特徴量を用いた二値分類結果

選択特徴次元数	識別精度 [%]
5	68.18
100	78.51
150	58.64

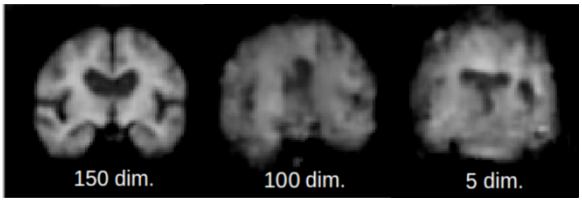

図 4 識別に寄与する特徴のみを使用した再構成画像

また，本研究では取得した特徴表現のうち，アルツハイマー病の診断に関わる特徴量の分析とその可視化を試みた．表 2 は AD の症例から取得した 150 次元の特徴表現のうち AD と CN の分類に寄与する特徴量を stepwise 法により 100 次元，もしくは 5 次元を選択し，生成した重回帰分析を用いて AD か CN かの識別を行い leave-one-out 交差検証により評価した結果である．図 4 は選択した特徴量を使用して再構成を行った結果である．識別精度は高い場合でも 8 割弱であり，また，放射線科医による図 4 の視覚的評価では，選択された特徴量のみを用いた再構成画像からアルツハイマー病の特徴が認識できるとは言えず，特定の病例に関わる領域を提示する手法としては不十分な結果となった．

結果より，圧縮した特徴量を用いた特定病例の診断および注目領域の可視化の精度には改善の余地があることが示された．

4. 結論

本研究では，3D-CAE を用いた次元削減手法を提案し，診断時に放射線科医が留意する特徴を保存しつつ, 入力次元を 4,915,200 から 150 にまで削減した．そして，定量的評価と視覚的評価によりモデルを評価し，妥当性を確認した．また，画像の潜在的特徴を用いた医療用 CBIR システムの実現可能性を示した一方で，技術的な改善点も確認された．

謝辞

本研究は文部科学省（基礎研究（C）,17K8033, 2017-2020)および Department of Radiology Johns Hopkins University School の Fakhri Rad Brite Star 賞の助成を受けたものです.

文　献

［1］ J.J.Sejvar, “Global burden of neurological disease: whats in a name,”*Lancet Neurology*, vol.16, no.11, pp.858-859, 2017.

［2］ N.Huang, W.Yang, M.Yu et al., “Retrieval of Brain Tumors with Region-Specific Bag-of-Visual-Words Representations in Contrast-Enhanced MRI Images,” *Computational and Mathematical Methods in Medicine*, no. 280538, 2012.

［3］ S.Murala, Q.M.J.Wu, “Local Mesh Patterns Versus Local Binary Patterns: Biomedical Image Indexing and Retrieval,” *IEEE Journal of Biomedical and Health informatics*, vol.18, no.3, pp.929-938, 2014.

［4］ K. He, X. Zhang, S. Ren and J. Sun, “Deep Residual Learning for Imagenet Recoginition,” *Proc. International Conference on Computer Vision and Pattern Recognition (CVPR2016)*, pp. 770-778, 2016.

［5］ E. Hosseini-Asl, R. Keynto and A. El-Baz, “Alzheimer’s disease diagnostics by adaptation of 3d convolutional network,” *International Conference of Image Processing (ICIP)*, pp. 126130, 2016.

［6］MR Image Data, ADNI - USC Mark and Mary Stevens Neuroimaging and Informatics Institute, 2018, http://adni.loni.usc.edu/datasamples/ mri/

［7］ X. Tang, K. Oishi, AV. Faria et al., “Bayesian Parameter Estimation and Segmentation in the Multi-Atlas Random Orbit Model,” *PLoS One* 8(6), 2013.

利益相反の有無

「なし」

Template for IJCARS Special Issue of JAMIT2017 & 2018

Preliminary Study of Applying Convolutional Neural Network to Detect Brain Metastases in MRI: Using Radiation Dose Profile as Ground Truth

Masaki MURATA[*1], Shouhei HANAOKA[*2], Yukihiro NOMURA[*1], Tomomi TAKENAGA[*1], Takahiro NAKAO[*3], Wataru TAKAHASHI[*2], Kanabu NAWA[*2], Takeharu YOSHIKAWA[*1], Naoto HAYASHI[*1], Osamu ABE[*2,*3]

Abstract

Recently, computer-assisted detection (CAD) for disease attracts a lot of medical researchers as well as technologists and physicists. Most of state-of-the-art CAD utilizes convolutional neural networks (CNNs). The purpose of this study is to apply CNNs for detecting brain metastases in MRI. In contrast to the standard CAD, where the ground truth is prepared by medical experts, we used radiation dose profile to define the ground truth of brain metastases. 348 contrast-enhanced brain MR images including 993 brain metastases were used in this study. The ground truth of brain metastases was defined by the region where the radiation dose is greater than 20 Gy. Among 348 cases, 214 cases were used for training CNNs, while the remaining cases were equally assigned to validation and test sets. Through random search with respect to hyperparameters of CNNs, including the number of convolutional layers and filter numbers, we obtained sensitivity 0.70 with 8.4 FPs/case for the test set. This result suggests that radiation dose profile has the potential to develop CAD systems.

Keywords：CAD, radiation dose, CNN

1. Purpose

Brain metastasis is a common disease for patients with cancer. One of the standard treatment for brain metastasis is stereotactic radiosurgery performed with the Gamma Knife (GK). For the treatment with the GK, computer-assisted detection (CAD) is expected to help physicians to identify tumors correctly and urgently. The recent success of CAD systems depends on convolutional neural networks (CNNs) [1]. Although CNNs have been providing superior CAD systems, training of CNNs typically demands a large number of the ground truth data inputted by medical experts. The process to prepare a sufficient number of the ground truth is a heavy workload for medical experts and is slowing the development of CAD systems.

The purpose of our research is to use radiation dose profiles of the GK treatment to set the ground truth of brain

*1 Department of Computational Diagnostic Radiology and Preventive Medicine, The University of Tokyo Hospital,

*2 Department of Radiology, The University of Tokyo Hospital

*3 Radiology and Biomedical Engineering, Graduate School of Medicine, University of Tokyo

metastases. Since the radiation dose data is accumulated by routine medical care, we can accelerate the step of making ground truth.

2. Method

This study was approved by the ethical review board of our hospital. The MR images were acquired for the treatment planning of the GK by 1.5-Tesla MR scanners (Siemens Magnetom Vision, GE Signa HDx/HDxt) with a contrast-enhanced T1-weighted 3D gradient echo sequence. To make the ground truth of brain metastases, we used the radiation dose profile recorded in a format of DICOM RT Dose. Since the prescription dose to the brain metastases in our hospital is 20 Gy, the brain metastases are defined by the regions where the radiation dose is greater than or equal to 20 Gy.

The workflow to detect brain metastases is illustrated in Fig.1. At the beginning, we applied three preprocessing schemes to improve the quality of detection; adjusting the voxel size, extracting the head, normalizing the voxel value. The first preprocess, adjusting the voxel size, was to normalize the MR images to the three-dimensional isotropic images with 0.94 mm of voxel size through the tricubic interpolation. To reduce the computation time for CNNs, we used an average filter to work with 1.88 mm of the voxel size. The second preprocess was to extract head regions. In each MR image, we extracted the regions where the voxel values are greater than the average value. As well as the head region, the structures to fix patient's head for the GK treatment were also extracted. The head region was obtained by selecting the largest connected region among the extracted connected regions. The third preprocessing procedure was to normalize the MR images with a linear transformation such that the average and the standard deviation were 0 and 1 respectively.

For a voxel in the extracted head region, we set 15^3 cube volume of interest (VOI) surrounding the voxel. Through a CNN, each VOI was transformed into a two-dimensional unit vector whose components are regarded as the probabilities that the central voxel in the VOI belongs to a tumor and normal tissue respectively. To find the best architecture of CNN, we have used random search with respect to the number of convolutional layers (1,2,…,12), the optimizer (SGD, Adam), the learning rate (10^{-6},10^{-5},…,10^{-1}), the batch size (2^5,2^6,…,2^{10}), the filter numbers (8,9,…,64), the sizes of convolutional filters (2,3,…,the half width of input), the number of dense layer (1,2), and the number of dense units (2,3,…,255). To train CNNs, 214 cases were randomly selected from the total 348 cases, while the remaining cases are equally divided into validation and test sets.

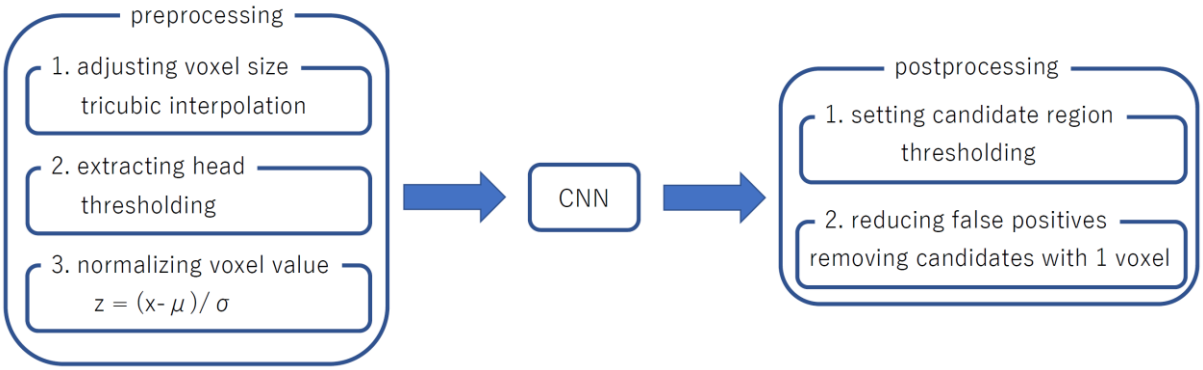

Fig.1: Flow to detect brain metastases. The three preprocessing schemes are applied before the CNN, and the two postprocessing schemes are applied after the CNN.

For the output of CNN, we adopted two postprocessing schemes; setting candidate regions and reducing false positives (FPs). The first postprocess was to set the candidate regions, which are the connected regions obtained by binarizing the output of CNN with a threshold. A candidate region is judged as a true positive when the center of the candidate region is in a region of a tumor. If more than two candidates place in a single tumor, only the candidate having the largest output value of the CNN is regarded as the true positive and the other candidates are regarded as the FPs. The threshold is optimized with respect to the sensitivity for the validation set. The final process was to reduce the FPs by removing the candidate regions with just one voxel.

The computation has been done by a supercomputer system (Reedbush-H) with NVIDIA Tesla P100 and with Python 2.7.5 and Keras 2.0.5 installed.

3. Results

The best model obtained through the random search scores the sensitivity 0.70 with 8.4 FPs/case for the test set. Let us emphasize that the ground truth for the test set is given by the radiation dose profile as well as the training set. Fig.2 shows the examples of true positives, false negatives (FNs), and FPs. It turns out that it is difficult to detect metastases which are not enough contrast-enhanced. In addition, the voxel in and near some organs such as vessels and eyes are wrongly detected since these voxels are contrast-enhanced.

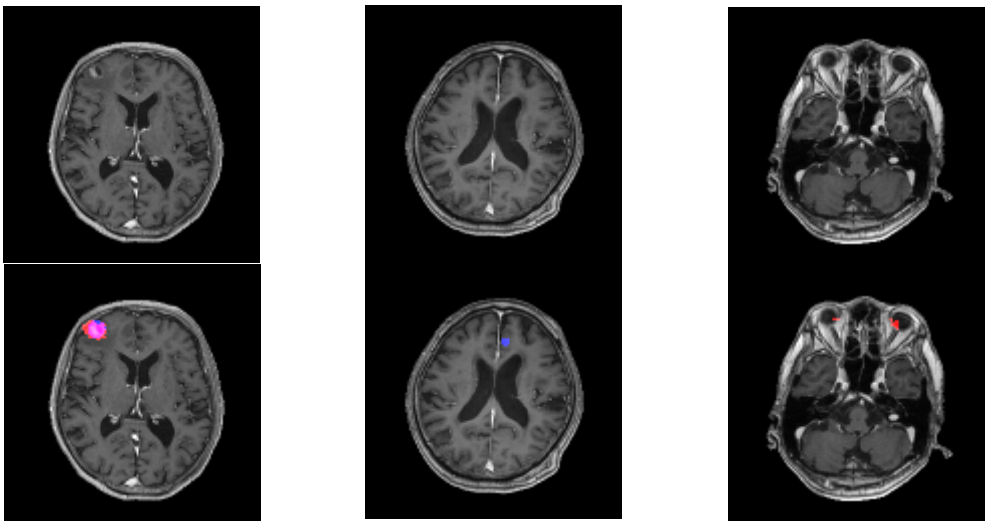

Fig.2: Examples of a true positive (left), a FN (middle), and a FP (right). The upper row shows the MR images and the lower row shows the same MR images where the voxels detected by the CNN are colored in red, while the voxels where the radiation dose ≥ 20 Gy are colored in blue.

4. Conclusion

By using the radiation dose profile as the ground truth for CNN, we produced the CAD system automatically detecting brain metastases. In spite that our preliminary result is less accurate than a previous work [2], we believe that

we can obtain the better accuracy by working with 0.94mm of voxel size, which is the half of the current size. On the one hand using radiation dose profiles allows us to access the plenty of data, on the other hand there are possibilities to reduce the quality of CAD systems. A possibility to reduce the precision is the difference between the tumor regions defined by radiation dose profiles and the true tumor regions. To avoid this, it is worth to use the Gross Tumor Volume (GTV), the segmentation of tumor for radiotherapy, if there is a sufficient number of cases with the GTV. In conclusion, this work sheds light on the possibility to develop CAD systems with the data associated with radiation treatment plans.

Competing interests

The authors declare no conflicts of interest with regard to the present study.

Acknowledgements

This work is supported by "Joint Usage/Research Center for Interdisciplinary Large-scale Information Infrastructures" and "High Performance Computing Infrastructure" in Japan (Project ID: jh170036-DAH), and Japan Society for the Promotion of Science (JSPS) KAKENHI Grant Number 18K12096.

References

[1] Charron O. et al: Automatic detection and segmentation of brain metastases on multimodal MR images with a deep convolutional neural network. Comput Biol Med **95**: 43-54, 2018.

[2] Takenaga T. et al: Computer-aided detection of metastatic brain tumors in magnetic resonance images, Nihon Hoshasen Gijutsu Gakkai Zasshi **69**:632-640, 2013.

ＳＶＭを用いた嚥下時Ｘ線サジタル透視動画における舌骨体の追跡

八板　駿平[*1]　滝沢　穂高[*2]　目片　幸二郎[*1, *3]　工藤　博幸[*2]

要旨

嚥下時 X 線サジタル透視動画 (Videofluorography, VF) における嚥下フェーズは舌骨体の位置および運動方向によって同定される．本報告では SVM を用いて舌骨体を自動追跡する手法を提案する．まず VF の各フレームに，判別分析法とモルフォロジ演算，RANSAC を適用し，舌骨体の可動予測領域を求める．その可動予測領域にパッチベースの SVM を適用し，舌骨体の候補領域を抽出する．一般に，舌骨体の候補領域は各フレームで複数抽出されるので，候補領域のフレーム間の連続性を考慮して偽陽性領域を削除し，舌骨体を限定する．本手法を 10 症例の実画像に適用した結果，抽出した舌骨体と正解座標との距離は平均 3.0mm，x と y 座標の相関係数は 0.953 と 0.852 という結果を得た．

キーワード：X 線サジタル透視動画，舌骨体，嚥下，SVM，RANSAC

1. はじめに

嚥下障害が起こると誤嚥，むせといった症状が発生し，栄養低下，肺炎，脱水などを引き起こすことがある．嚥下障害の主な原因として加齢や脳血管障害が知られている[1]．また，頸椎の手術により嚥下障害が発症した例や，症状が悪化した例も報告されている[2, 3]．しかし，嚥下障害の発生メカニズムの全容は未だ解明されていない．我々は嚥下時Ｘ線サジタル透視動画 (Videofluorography, VF) における頸部構造物の動態解析から嚥下障害の解析を試みている[4, 5, 6]．

*1 筑波大学大学院システム情報工学研究科コンピュータサイエンス専攻
〔〒305-8573 つくば市天王台 1-1-1〕
*2 筑波大学システム情報系〔同上〕
*3 神戸赤十字病院
〔〒651-0073 神戸市中央区脇浜海岸通 1-3-1〕

舌骨は頸部構造物の 1 つで，臨床においては，その位置や運動方向を基準にして口腔期や咽頭期などの嚥下フェーズが同定される．嚥下時の舌骨の運動を調査した研究は既に行われており，喉の奥下から前方上方に移動し，最大挙上位置で停滞した後，初期位置に戻ることが知られている[7, 8]．舌骨は馬蹄形をなしており，舌骨体はその中央部に位置する長楕円扁平の骨板である．

VF から舌骨体を追跡する手法はいくつか提案されている．Kellen らはエッジ抽出とテンプレートマッチングによる舌骨体追跡を提案した[9]．Hossain らは Haar 特徴量に基づく識別器を用いて舌骨体の近傍領域を抽出し，テンプレートマッチングにより舌骨体を追跡する手法を提案した[10]. Lee らはエッジ抽出や LBP/MLBP 特徴量を使用して舌骨体を抽出，追跡する手法を提案した[11]．これらの手法では，最初のフレームにおいて舌骨体や頸椎などの位置を手動で指定する必要があった．本報告では SVM を用いて舌骨体を自動

で抽出，追跡する手法を提案する．

2. 舌骨体の可動予測マスクの作成

VF の各フレームで舌骨体の可動領域を予測したマスクを作成し，SVM で舌骨体を学習・予測する際に使用する．

2.1. 背景重心線・首中心線の算出

VF の各フレームに判別分析法を適用して 2 値化し，画素値の高い領域を抽出し，Opening による領域整形を行い，面積の大きい 2 つの領域を抽出し，背景領域とする．背景領域のそれぞれの重心を通る直線を求め，背景重心線とする．非背景領域に距離変換を適用し，背景領域からの距離を算出する．画像の上辺と下辺からそれぞれ 1 画素を順番に選択し，それらを通る直線群を生成し，直線上の距離値の総和が最大となる直線を選び，首中心線とする．図 1 は VF のあるフレーム，図 2 は背景領域，図 3 の赤線は背景重心線，図 4 の赤線は首中心線である．

図 1：原画像

図 2：背景領域

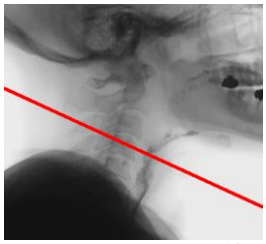

図 3：背景重心線

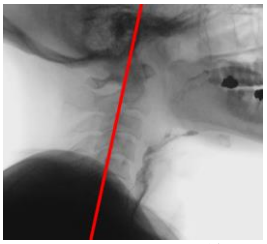

図 4：首中心線

2.2. 下顎および頭蓋骨底部の境界線の抽出

背景領域の境界画素の内，背景重心線より下の画素を削除する．残った境界画素を首中心線の前後で 2 つのグループに分割する．前部のグループは下顎のライン，後部のグループは頭蓋骨底部のラインを表す．各グループの画素列の左右両辺縁部は，下顎および頭蓋骨底部の実際の境界線とのずれが大きくなるので，両側 d_{cut} 画素を削除する．d_{cut} は初期値を d_0 とし，残留画素が N_C 以上になるまで減少させて決定する．抽出された境界画素に RANSAC[12]を用いた放物線当てはめを行う．当てはめる放物線は下に凸とし，直線は許容する．選択する 3 点は一方のグループから 2 点，他方のグループから 1 点とする．2 点選択するグループを変更し，それぞれ N_R 回ずつ，合計 $2N_R$ 回放物線を当てはめる．得られた放物線のインライヤの総和を評価値とし，評価値が最も高い放物線を下顎および頭蓋骨底部の境界線とする．図 5 の紫色画素は背景領域の境界画素，図 6 の青色画素は前部のグループに，緑色画素は後部のグループに属する分割後の境界画素，図 7 は各グループの画素列の左右両辺縁部を削除した境界画素，図 8 の赤線は下顎および頭蓋骨底部の境界線である．

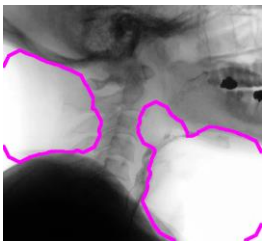

図 5：背景領域の境界画素

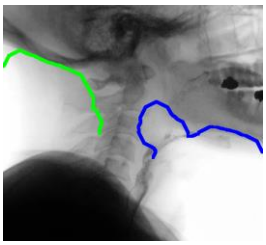

図 6：分割後の境界画素

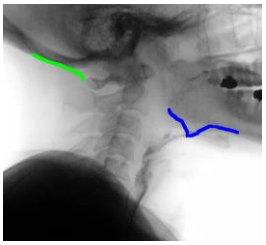

図 7：辺縁部を削除した境界画素

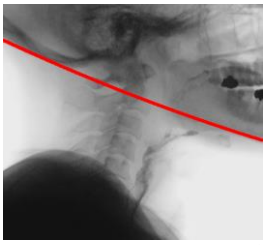

図 8：下顎および頭蓋骨底部の境界線

2.3. 可動予測マスクの抽出

背景重心線，首中心線，下顎および頭蓋骨底部の境界線により囲まれた領域を抽出し，判別分析法を適用して 2 値化し，頸椎に相当する画素値の低い領域を除去する．残った領域に判別分析法を N_D 回適用して背景に相当する画素値の高い領域を除去し，Opening と

Closing を適用して領域整形する. 最終的に抽出された領域を舌骨体の可動領域を予測したマスクとする. 図 9 は背景重心線, 首中心線, 下顎および頭蓋骨底部の境界線により囲まれた領域, 図 10 は舌骨体の可動予測マスクである.

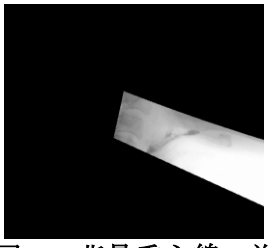

図 9 : 背景重心線，首中心線，下顎および頭蓋骨底部の境界線により囲まれた領域

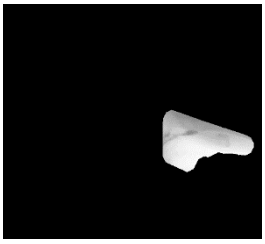

図 10 : 舌骨体の可動予測マスク

3. SVM による舌骨体候補領域の抽出

SVM の学習段階では, 学習画像の舌骨体の輪郭を手動で抽出し，その輪郭上の画素を中心とする $N_p \times N_p$ のパッチをベクトル化し，平均 0 かつ分散 1 になるように正規化し，正クラスデータとする．負クラスデータは，可動予測マスク内でしかも正クラスデータのパッチ外から画素をランダムに選択し，ベクトル化，正規化し，生成する．ただし，負クラスデータの個数は正クラスデータの個数と同じとする．上記の方法を全学習画像に適用して得られた 2 つのクラスのデータを SVM に学習させる. 図 11 の赤色画素は正クラスとして学習させた画素を表す.

予測段階では，テスト画像の可動予測マスク内の全画素でパッチをベクトル化，正規化し，学習済み SVM で 2 つのクラスへの帰属確率を計算する. 正クラスへの帰属確率が 0.5 以上である画素を舌骨体の候補領域とする. 図 12 の赤色画素は抽出された舌骨体の候補領域である.

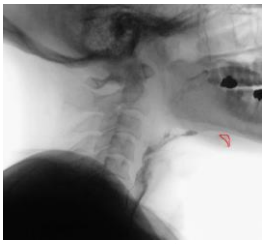

図 11：舌骨体クラス

図 12：舌骨体の候補領域

4. 候補領域のフレーム間での連続性を考慮した舌骨体の抽出

一般に舌骨体の候補領域は各フレームで複数抽出され，舌骨体とそれ以外の構造物が混在している．これらの領域の中で，舌骨体は大きめの領域として抽出されることが多いが, 抽出に失敗するフレームもある．以上を考慮し，次の手順で偽陽性領域を削除し，舌骨体を抽出する.

1. 最初のフレームから最後のフレームまでを 3 次元画像とみなし，候補領域に 3 次元ラベリングを適用し，体積の大きい上位 N_L 個の領域のみを抽出する.
2. フレーム毎に 2 次元ラベリングを適用し, さらに各フレームの各領域をP_0ピクセルだけ膨張させる．膨張した領域を探索領域と呼ぶ.
3. $t = t$ のフレームのある候補領域の探索領域と，$t = t + 1$ のある候補領域が重なった場合，この 2 つの候補領域をリンクする. ただし, $t = t$ のある領域が $t = t + 1$ のいずれの候補領域ともリンクしない場合は，その候補領域と探索領域を $t = t + 1$ のフレームにコピーし, さらにコピーした探索領域を P_0 ピクセルだけ膨張させる.
4. 最初のフレームから最後のフレームまでリンクされた一連の候補領域をリンクパターンと呼ぶ．全てのリンクパターンの中で，候補領域の面積の和が最大のものを選ぶ．選ばれたリンクパターン上の候補領域の内，コピーされたものは動きが不連続になるため，その中心位置を

前後の候補領域で線形補間し，移動する．このリンクパターン上の候補領域を舌骨体とする．

図 13 は領域のリンクの例を表している．実線の箱図は SVM で抽出された候補領域を，髭線はその探索領域を表している．点線の箱図はコピーされた候補領域を，髭線はその探索領域を表している．この例では 5 つのリンクパターン {1,1,1,1,2,1}, {1,1,1,1,2,2}, {1,2,2,2,1,2}, {2,3,3,3,1,2}, {2,3,3,3,3,3} が得られ，面積和が最大となる第 2 パターン上の候補領域が舌骨体として抽出される．図 14 は図 12 に対して舌骨体抽出を行った結果，図 15 は抽出された舌骨体領域の下端座標で，その座標を追跡座標と呼ぶ．

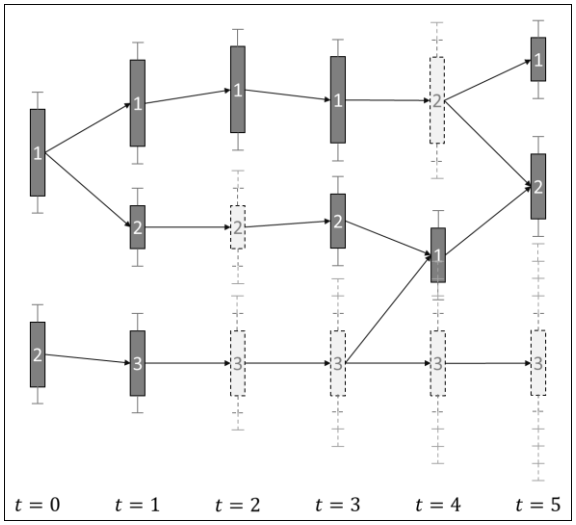

図 13：領域のリンクの例

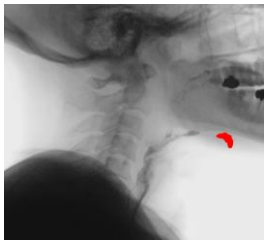

図 14：舌骨体抽出

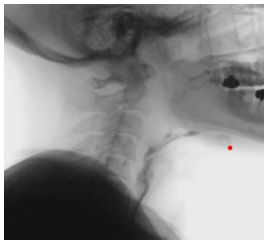

図 15：追跡座標

5. 実験

5.1. 実験条件

10 症例の VF を使用して，leave-one-out による舌骨体の追跡実験を行った．嚥下造影は日本摂食・嚥下リハビリテーション学会が作成したマニュアル[13]に従った．なお，実験参加者には事前に研究内容を説明し，参加の同意を得た．VF の録画は 30fps で，解像度は 0.5mm/px である．VF には頸部，舌骨の全体と下顎，頭蓋骨，肩部の一部が写っている．追跡性能の評価には手動で抽出した舌骨体領域の下端の画素を使用し，距離と相関係数による 2 通りの評価を行った．距離は正解座標と追跡座標のユークリッド距離をフレーム毎に求め，相関係数は正解座標と追跡座標の x と y 座標の全フレームの値から求める．

使用するパラメータは $d_0 = 50, N_C = 50, N_R = 1000, N_D = 3, N_p = 31, N_L = 5, P_0 = 4$ とした．SVM で使用するカーネルは放射基底関数 (RBF) とし，学習パラメータ (C, γ) の調整にはグリッドサーチと交差検証を使用した．交差検証の分割数は 5 とし，グリッドサーチの探索範囲は $2^1 \leq C \leq 2^5$, $2^{-8} \leq \gamma \leq 2^{-6}$ で，いずれも指数部を 1 ずつ変化させた．

5.2. 実験結果

表 1 は症例ごとの距離の平均，標準偏差，最大値，最小値である．表 2 は症例ごとの x, y 座標の相関係数を表す．図 16, 17, 18 はそれぞれ，No.3, 8, 9 症例での追跡結果を示しており，青色の点線（四角）が正解座標，赤色の実線（丸）が追跡座標を表す．全症例での平均値は，平均距離 6.0px (3.0mm)，x, y 座標の相関係数は 0.953, 0.852 となった．

表 1：距離による評価結果

症例	平均	標準偏差	最大値	最小値
No.1	5.2	1.6	10.4	2.0
No.2	3.0	1.8	9.8	0.0
No.3	5.9	1.7	11.4	1.0
No.4	4.6	1.6	12.0	1.4
No.5	4.9	3.1	15.0	1.0
No.6	6.5	3.9	23.3	1.4
No.7	2.8	2.1	9.5	0.0
No.8	17.3	17.7	54.4	3.2
No.9	6.6	2.4	12.2	2.2
No.10	3.0	2.1	9.9	0.0
平均	6.0	3.8	16.8	1.2

表 2：相関係数による評価結果

症例	x	y
No.1	0.993	0.979
No.2	0.987	0.992
No.3	0.994	0.988
No.4	0.994	0.985
No.5	0.972	0.931
No.6	0.953	0.904
No.7	0.937	0.870
No.8	0.853	0.032
No.9	0.997	0.967
No.10	0.852	0.869
平均	0.953	0.852

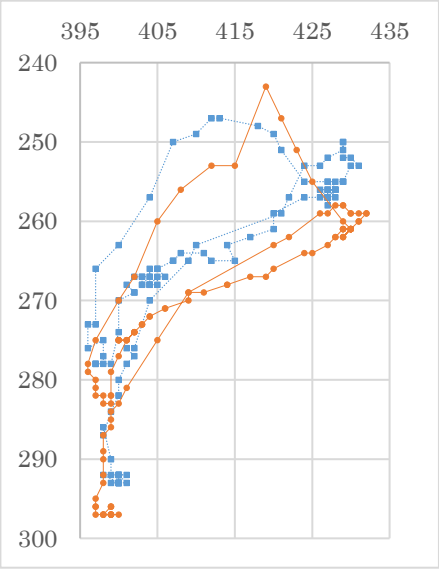

図 16：No.3 の追跡結果

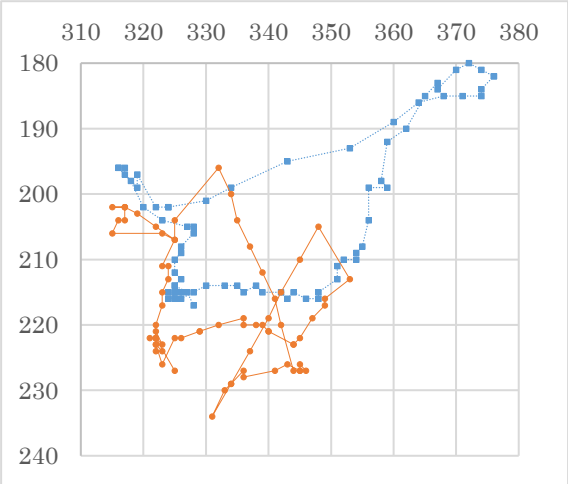

図 17：No.8 の追跡結果

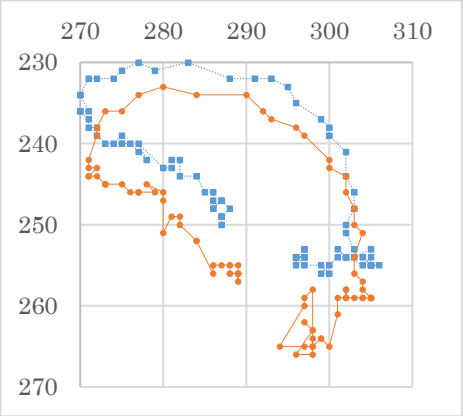

図 18：No.9 の追跡結果

6. 考察

従来の手法では最初に手動で舌骨体などの位置を指定する必要があったが，本手法では機械学習を用いるため，未知症例に対しても全自動で舌骨体追跡が可能である．

Kellen らや Hossain らの手法は舌骨体が一部でも顎の骨に隠れる場合には追跡できない．また，Lee らの手法は顎の骨に隠れても追跡可能であるが，撮影時にランドマークが必要となる．これに対して，本手法は舌骨体が顎の骨に一部隠れても追跡可能である．

本実験では No.8 症例において，舌骨最大挙上位置を正しく捉えることができなかった．これは最大挙上時に舌骨体が顎の骨に完全に隠れてしまうことが原因であった．本手法では可動予測マスクを作成する際に，下顎および頭蓋骨底部に放物線を当てはめ，それより下の領域でのみ舌骨体の抽出，追跡を行っているため，舌骨体が顎領域に完全に埋没する（下顎の境界線より上になる）と，舌骨体を抽出することができない．

No.9 症例では舌骨体追跡を比較的安定して行うことができているが，最大挙上位置を特定することは困難となっている．これは嚥下時に患者が頭部を前傾したため，舌骨体の画像座標が大きく変動したことが原因であった．今後は，下顎や頭蓋骨，肩部を基準とした新たな座標軸の設計が必要になる．

7. まとめ

本報告では嚥下時X線サジタル透視動画から舌骨体を自動追跡する手法を提案した．本手法を 10 症例の実画像に適用し，手動で抽出した正解座標との距離および相関係数による評価を行った．その結果，平均距離 3.0mm，相関係数 0.953，0.852 となり，おおむね正しく追跡することができた．今後の課題は，舌骨体が顎の骨に完全に隠れる症例や，患者が大きく動く症例での精度向上である．

謝辞

研究遂行にあたり貴重なご協力を賜った京都大学大学院医学研究科人間健康科学系専攻リハビリテーション科学コース 松林潤氏，岡山大学整形外科 瀧川朋亨氏，神戸赤十字病院整形外科 戸田一潔氏，神戸赤十字病院整形外科 伊藤康夫氏に感謝致します．

利益相反の有無

「なし」

文　献

［1］ World Gastroenterology Organisation: Dysphagia: http://www.worldgastroenterology.org/guidelines/global-guidelines/dysphagia

［2］ 平山三智子，西川光一：頚椎後方手術後に脳神経麻痺による嚥下障害を生じた 3 症例． 日本臨床麻酔学会誌，Vol.32, No.7, 943-947, 2012

［3］ 林寿光，水田啓介，青木光広，他：頸椎手術後に悪化した嚥下障害例に対する手術治療経験． 耳鼻と臨床, Vol.54, No.2, 152-156, 2008

［4］ 目片幸二郎，滝沢穂高，松林潤，他：テンプレートマッチングを用いた嚥下時X線サジタル透視動画における頸椎棘突起の追跡．日本コンピュータ外科学会論文誌, Vol.19, No.2, 83-88, 2017

［5］ 目片幸二郎，滝沢穂高，松林潤，他：嚥下時 VF における頸椎の運動解析に関する基礎的検討． 第 36 回日本医用画像工学会大会予稿集, 321-323, 2017

［6］ 齋藤祐季，目片幸二郎，滝沢穂高，他：ＳＶＭを用いたＸ線透視画像における椎間板抽出の基礎的検討． 第 36 回日本医用画像工学会大会予稿集, 292-294, 2017

［7］ 中原学：嚥下時における舌骨運動の X 線学的研究． 日本耳鼻咽喉科学会会報，Vol.90, No.5, 669-679, 1987

［8］ 金子功：嚥下における舌骨運動の X 線学的解析． 日本耳鼻咽喉科学会会報，Vol.95, No.7, 974-987, 1992

［9］ P. M. Kellen, D. L. Becker, J. M. Reinhardt, et al.: Computer-Assisted Assessment of Hyoid Bone Motion from Videofluoroscopic Swallow Studies. Dysphagia, Vol.25, 298-306, 2010

［10］ I. Hossain, A. Roberts-South, M. Jog, et al.: Semi-automatic assessment of hyoid bone motion in digital videofluoroscopic images. Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization, Vol. 2, No. 1, 25–37, 2014

［11］ Jun Chang Lee, Kyoung Won Nam, Dong Pyo Jang, et al.: A Supporting Platform for Semi-Automatic Hyoid Bone Tracking and Parameter Extraction from Videofluoroscopic Images for the Diagnosis of Dysphagia Patients. Dysphagia, Vol.32, No.2, 315-326, 2017

［12］ M. A. Fischler, R. C. Bolles: Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography. Communications of the ACM, Vol.24, No.6, 381-395, 1981

［13］日本摂食嚥下リハビリテーション学会医療検討委員会：https://www.jsdr.or.jp/wp-content/uploads/file/doc/VF18-2-p166-186.pdf

Tracking of bodies of hyoid bones in videofluorography by use of SVM

Shumpei YAITA[*1], Hotaka TAKIZAWA[*2], Kojiro MEKATA[*1, *3], Hiroyoki KUDO[*2]

*1 Department of Computer Science, Graduate School of Systems and Information Engineering, University of Tsukuba

*2 Faculty of Engineering, Information and Systems, University of Tsukuba

*3 Kobe Red Cross Hospital

Swallowing phases are defined on the basis of the positions and the moving directions of bodies of hyoid bones (BHBs) in videofluorography (VF). In this report, we propose an automatic tracking method of BHBs by use of SVM. First, the movable prediction areas of BHBs are determined by applying discriminant analysis, morphology operations, and RANSAC techniques to frame images in VF. Then, a patch-based SVM is applied to the movable prediction areas to extract the candidate regions of BHBs. In general, several candidate regions are unintentionally extracted in each frame. The false positives are eliminated by considering the continuity of the candidate regions between frame images. The proposed method was applied to actual ten cases, and the tracking accuracy was evaluated on the basis of (1) distances between the extracted and truth regions, and (2) the correlation coefficients of x and y coordinates of these regions. The mean distance was approximately 3.0 mm, and the correlation coefficients were 0.953 and 0.852 in the x and y coordinates, respectively.

Key words: videofluorography, bodies of hyoid bones, swallowing, SVM, RANSAC

非局所トータルバリエーションを用いたスパースビューCT画像再構成の画質改善

金 鎔采[*1] 工藤 博幸[*1]

要 旨

スパースビューCTの画像再構成において、非局所トータルバリエーション（TV）を用いた手法はTV項に付加する重みを適切に計算することで、通常のTVと比較して滑らかな濃度変化やテクスチャーを保存しやすく、画質性能に優れる。本研究では、非局所TVの画質性能を更に向上させるため以下の考え方に基づく改良手法を提案する。画像再構成反復計算の各反復回数で、最新の再構成画像からストリークアーティファクトが強く発生している画素を同定して、非局所TV項の重みを計算する際にアーティファクト画素に通常より大きい重みを割り当てて強く平滑化を行う。キーになるアーティファクト画素の同定は、データ項のみによる更新画像と平滑化項のみによる更新画像の差の絶対値を画素毎に計算してその大小で決定する。本手法は様々な反復法と組み合わせ可能な一般性を持つが、著者らが用いている近接スプリッティングに基づくRow-Action型画像再構成法に組み込んで医療用CT実画像を用いたシミュレーション実験を行った結果、特に少ない反復回数における顕著な画質改善（ストリークアーティファクトの低減）が実現できることが明らかになった。

キーワード: Sparse-view CT, Non-local TV, Non-local means, Streak Artifact, Row-Action, Proximal splitting, Swing-by

1．はじめに

近年、通常のX線CTより、被曝量および撮影時間を1/10以下に減らせる「スパースビューCT」と呼ばれるCT装置構成が注目されている[1]。

スパースビューCTでは、少数方向による角度欠損の影響で発生するStreak Artifact(SA)と呼ばれる特徴的なノイズを効率よく除去し、通常CT同等の高画質を実現しなければならない課題がある。

このスパースビューCT分野で、最も広く研究されている既存のTotal Variation法は、スパース性の評価において、隣接画素のみを評価対象とするため、滑らかな濃度変化に対し、階段状に近似してしまい、再構成画像にPatchy Artifact(PA)が発生する。

そこで、隣接画素だけでなく、離れた画素の差分も考慮することで、既存のTV法のPA問題を解決できるNon-local Total Variation(NLTV)が、第2世代圧縮センシングとして提案された[2]。

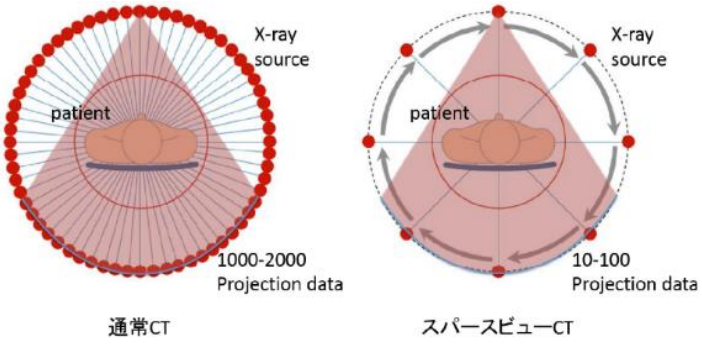

図1 通常CTとスパースビューCT

NLTVは、TV項に付加する重みの大小で平滑化の強さが決定されるため、ノイズの性質を考慮してその重みを適切に制御すれば、大きな画質改善が期待できる。

そのような原理から、圧縮センシングの各反復で、SAを正確に検出し、SAが強く発生する画素に対してピンポイントに強く平滑化を行えば、効率よくSAを除去することができる。

しかし、SAを一般画像の特徴抽出のように一つの画像のみで検出しようとすると、ハイコントラスト実現に必要な画像のエッジ成分まで検出してしまい、その誤差によって、再構成画像がぼやけてしまう潜在的リスクがある。

[*1] 筑波大学大学院システム情報工学研究科コンピュータサイエンス専攻

〔〒305-8573 つくば市天王台1-1-1〕

e-mail: kim@imagelab.cs.tsukuba.ac.jp

投稿受付：2018年5月15日

そこで、提案手法は、少数方向による不良設定問題:ill-posed problems が直接発生する圧縮センシングのデータ項に着目し、「データ項で更新後の画像」と「データ項で更新前の画像」の二つの画像の差を用いることで SA 検出の精度を高める。

提案手法は、様々な反復法と組み合わせができる一般性をもっているが、本研究では、近接スプリッティング[3-4]に基づく Row-Action 型画像再構成に組み込んで、圧縮センシングの初期反復での SA 除去性能を評価する。

２．Non-local TV の重み

最近、高画質のために、NLTV の重みとして、Non-local means フィルタの重みが使われることが多い。

Non-local means フィルタは、バイラテラルフィルタの拡張版として、2004 年に提案[5]された。バイラテラルフィルタの強度カーネルに、さらにテンプレートを使って、テンプレート間の画素値の平均を計算した重みを用いることで、従来の非線形フィルタと比べ、驚くほどのノイズ除去性能をもっている。

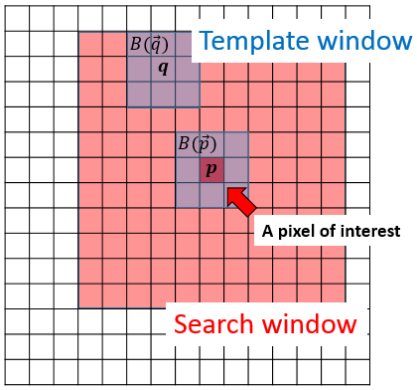

図２ Non-local means フィルタのカーネル

$$out(\vec{p}) = \sum_{\vec{q}\in S} \omega(\vec{p},\vec{q})\, in(\vec{q}) \qquad (1)$$

$$\omega(\vec{p},\vec{q}) = \frac{exp(-max(\|B(\vec{p}) - B(\vec{q})\|_2^2 - 2\sigma^2, 0)/h^2)}{\sum_{\vec{q}\in S} exp(-max(\|B(\vec{p}) - B(\vec{q})\|_2^2 - 2\sigma^2, 0)/h^2)}$$

ここで、$\|B(\vec{p}) - B(\vec{q})\|_2^2$は、$\boldsymbol{p}$と$\boldsymbol{q}$を中心とするテンプレート間のユークリッド距離の平均である。

本論文では、上式の Non-local means フィルタの重み$\boldsymbol{\omega(\vec{p},\vec{q})}$を NLTV の重みとする。

３．Non-local TV

Non-local TV は、TV 法の拡張版として、隣接画素の差分だけでなく、Window 内の広い範囲の離れた画素の差分も考慮して計算の対象にする手法である。

TV 項に付加する重み$\boldsymbol{\omega(p,q)}$は、**式(1)**の Non-local means フィルタの重みと同様なものが使われるが、NLTV では、一つの画素対の差分に対する離散的な重みで解析する。

NLTV は、この重みが大きくなると、強く平滑化され、重みが小さくなると、弱く平滑化される仕組みである。問題の定式化は、以下となる。

$$\underset{\vec{x}}{\boldsymbol{argmin}}\, \boldsymbol{F(\vec{x})} = \|A\vec{x} - \vec{b}\|_2^2 + \beta \sum_{(p,q)\in S}\sum \omega(p,q)\,|x_p - x_q| \qquad (2)$$

$S = \{(p,q)|$"*A set of separated pixel pairs in window*"$\}$

$\omega(p,q)$は、再構成される画像から毎回計算する

本研究では、微分不可能なペナリティ関数(L1 ノルムの正則化項)を含む評価関数の最小化問題に対して、近接スプリッティングに基づく Row-Action 反復法に組み込んだ。

データ項$\boldsymbol{F_1(\vec{x})}$と正則化項$\boldsymbol{F_2(\vec{x})}$を以下の部分関数とし、近接スプリッティングによる最小化を行う。

$$F_1(\vec{x}) = \|A\vec{x} - \vec{b}\|_2^2$$
$$F_2(\vec{x}) = \beta \sum_{(p,q)\in S}\sum \omega(p,q)\,|x_p - x_q| \qquad (3)$$

データ項$\boldsymbol{F_1(\vec{x})}$の更新解は、以下となる。

$$\vec{x}^{(n+1,N)} = \vec{x}^{(n,i)} - 2\alpha \sum_{i\in R_{[N]}} (A^i)^T\left(A^i\vec{x}^{(n,i)} - b^i\right) \qquad (4)$$

A^iは１方向のシステム行列、b^iは１行の計測データ

$R_{[N]}$は、方向数Nにおけるランダム順のSubsets

データ項の更新で、このようなランダム Subsets を用いた Row-Action 構造は、初期反復において非常によい収束性をもっている。

また、正則化項$\boldsymbol{F_2(\vec{x})}$の更新解は、以下となる。

$$x_p^{n+1} = \begin{cases} x_p^n - \alpha\beta\omega(p,q) & if\ x_p^n - x_q^n > \alpha\beta\omega(p,q) \\ x_p^n + \alpha\beta\omega(p,q) & if\ x_p^n - x_q^n < -\alpha\beta\omega(p,q) \\ x_q^n & (otherwise) \end{cases}$$
$$x_q^{n+1} = \begin{cases} x_q^n + \alpha\beta\omega(p,q) & if\ x_p^n - x_q^n > \alpha\beta\omega(p,q) \\ x_q^n - \alpha\beta\omega(p,q) & if\ x_p^n - x_q^n < -\alpha\beta\omega(p,q) \\ x_p^n & (otherwise) \end{cases} \qquad (5)$$

注目画素のみを更新することも可能ではあるが、本研究では、より高い収束性とノイズ除去効果を目指して、注目画素$\boldsymbol{x_p}$と離れた画素$\boldsymbol{x_q}$を同時更新する。そうすることで、カーネル内の全ての画素が更新される。

また、Step size $\boldsymbol{\alpha}$は、解の更新量を意味するパラメータであり、解の収束性を保証するために、以下のように反復回数と連動して徐々に減らしていく。

$$\alpha^{n+1} = \frac{\alpha^0}{1+\varepsilon n} \tag{6}$$

α^0は、Step size の初期値

εは、Step size の減少速度

既存の NLTV の Row-Action 反復法を以下に示す。

Algorithm 1 Proximal splitting based Row-Action

Input: Projection data $\vec{b}$ (size:$M \times N$);

number of views N; random subsets $R_{[N]}$;

step-size control parameters (α^0, ε);

integer span parameter NUP;

algorithm tolerance $tol > 0$;

Output: Reconstructed image $\vec{x}$ (size:$M \times M$);

$\vec{x}^{(k,0)} \leftarrow 0, k \leftarrow 0$

while $\min_{1 \le j \le M \times M} \left\{ \left| x_j^{(k+1)} - x_j^{(k)} \right| \right\} > tol$ **do**

$\vec{x}^{(k,i)} = \vec{x}^{(k)}, \ \alpha^{n+1} = \frac{\alpha^0}{1+\varepsilon n}$

for (i=0; i<N; i++) **do**

$$\vec{x}^{(n,i+1)} = \vec{x}^{(n,i)} - 2\alpha (A^i)^T \left(A^i \vec{x}^{(n,i)} - b^i \right)$$

if (i>0 & i % NUP = 0) **do**

for all pixels j in the image **do**

$$x_p^{(n,i+1)} \leftarrow \begin{cases} x_p^{(n,i+1)} - \alpha\beta\omega(p,q) & if\ x_p^{(n,i+1)} - x_q^{(n,i+1)} > \alpha\beta\omega(p,q) \\ x_p^{(n,i+1)} + \alpha\beta\omega(p,q) & if\ x_p^{(n,i+1)} - x_q^{(n,i+1)} < -\alpha\beta\omega(p,q) \\ x_q^{(n,i+1)} & (otherwise) \end{cases}$$

$$x_q^{(n,i+1)} \leftarrow \begin{cases} x_q^{(n,i+1)} + \alpha\beta\omega(p,q) & if\ x_p^{(n,i+1)} - x_q^{(n,i+1)} > \alpha\beta\omega(p,q) \\ x_q^{(n,i+1)} - \alpha\beta\omega(p,q) & if\ x_p^{(n,i+1)} - x_q^{(n,i+1)} < -\alpha\beta\omega(p,q) \\ x_p^{(n,i+1)} & (otherwise) \end{cases}$$

end for all

end if

end for $\vec{x}^{(k+1)} = \vec{x}^{(k,N)}$

end while

return $\vec{x}^{(k+1)}$

４．提案手法

以下は、８０方向の投影データを FBP 法で再構成した SA の例である。

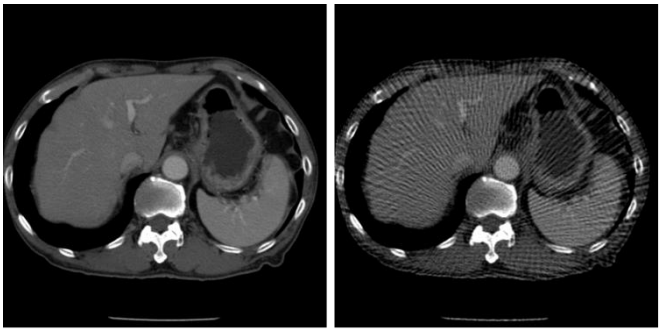

原画像　　Streak Artifactの例（８０方向）

図３ Streak Artifact の例

SA 画素に対する重み$\boldsymbol{\omega(p,q)}$を強調するために、圧縮センシングの各反復で SA を検出し、SA のある場所を同定しなければならない。

提案手法は、「データ項で更新後の画像」と「データ項で更新前の画像」の二つの画像の差の絶対値を用いて SA を検出する。

ここで、「データ項で更新前の画像」は、「反復(k-1)回目の正則化項で更新後の画像」と同じである。

４．１　Streak Artifact(SA)の検出

データ項で更新後と更新前の画素の差をC_jとして、次のように$\boldsymbol{F_3(\vec{x})}$と定義する。

$$F_3(\vec{x}) = \delta \sum_{j=1}^{J} \left| (\text{データ項で更新後の画素})_j - (\text{データ項で更新前の画素})_j \right| = \delta \sum_{j=1}^{J} |C_j| \tag{7}$$

SA 検出画像$\vec{C}$の更新解は以下となる。

$$C_j^{n+1} = \begin{cases} C_j^n - \alpha\delta & if\ C_j^n > \alpha\delta \\ C_j^n + \alpha\delta & if\ C_j^n < -\alpha\delta \\ 0 & (otherwise) \end{cases} \tag{8}$$

ここで、キーポイントは、0 にならない$\boldsymbol{C_j^{n+1}}$の値を外れ値（SA や孤立点）と解析することである。

その 0 にならない値を１にすることで、SA 検出画像$\vec{C}$は、「0 か１」の 1bit の画素値をもつバイナリ MAP$\vec{M}$になる。

$$M_j^{n+1} = \begin{cases} 1, & if\ C_j^{n+1} \neq 0 \\ 0, & (otherwise) \end{cases} \qquad (9)$$

$$(\text{ただし、} \vec{M}^0 = 0)$$

上式の変換によるバイナリ MAP$\vec{M}$は、外れ値のある場所の画素値が 1 になる。ただし、バイナリ MAP$\vec{M}$の初期値$\vec{M}^0$は 0 にする。

4．2　Non-local TV の重み$\omega(p,q)$の制御

バイナリ MAP$\vec{M}$の情報から、以下のように SA 画素に対する重み$\omega(p,q)$ を強調する。

$$\omega^{SA}(p,q) = (1 + \gamma M_q)\omega(p,q) \qquad (10)$$
$$(\text{ただし、} \gamma > 0)$$

ここで、γは、重み$\omega(p,q)$にどのぐらいの重みをつけるかというパラメータである。

離れた画素qに SA がある（$M_q = 1$）場合は、$\omega^{SA}(p,q)$が大きくなり、そうではない場合（$M_q = 0$）は、$\omega^{SA}(p,q) = \omega(p,q)$となる。

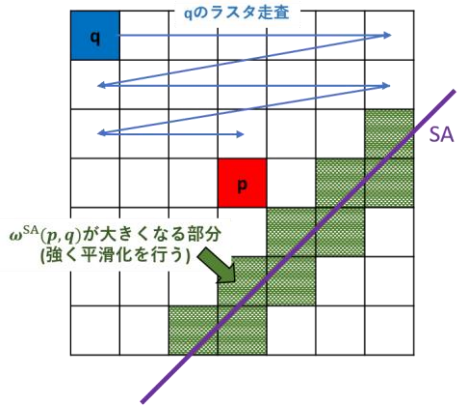

図４ Non-local TV の重みカーネルの内部反復

最終的に、提案手法の正則化項$F_2(\vec{x})$の更新解は、以下となる。

$$x_p^{n+1} = \begin{cases} x_p^n - \alpha\beta\omega^{SA}(p,q) & if\ x_p^n - x_q^n > \alpha\beta\omega^{SA}(p,q) \\ x_p^n + \alpha\beta\omega^{SA}(p,q) & if\ x_p^n - x_q^n < -\alpha\beta\omega^{SA}(p,q) \\ x_q^n & (otherwise) \end{cases}$$
$$x_q^{n+1} = \begin{cases} x_q^n + \alpha\beta\omega^{SA}(p,q) & if\ x_p^n - x_q^n > \alpha\beta\omega^{SA}(p,q) \\ x_q^n - \alpha\beta\omega^{SA}(p,q) & if\ x_p^n - x_q^n < -\alpha\beta\omega^{SA}(p,q) \\ x_p^n & (otherwise) \end{cases} \qquad (11)$$

提案手法は、「データ項で更新後の画像」と「データ項で更新前の画像」の差(エネルギーの差)を 0 に近接させながら、そのエネルギーの差を外れ値(SA や孤立点)除去の加速に用いる「Swing-by 制御」である。

提案手法の Row-Action 反復法を以下に示す。

Algorithm 2 Proposed method

Input: Projection data $\vec{b}$ (size:$M \times N$);
number of views N; random subsets $R_{[N]}$;
step-size control parameters (α^0, ε);
integer span parameter NUP;
algorithm tolerance $tol > 0$;
Swing-by control parameters (δ, γ);
Output: Reconstructed image $\vec{x}$ (size:$M \times M$);

$\vec{x}^{(k,0)} \leftarrow 0, \vec{M}^{(k,0)} \leftarrow 0, k \leftarrow 0$
while $\min_{1 \le j \le M \times M} \left\{ \left| x_j^{(k+1)} - x_j^{(k)} \right| \right\} > tol$ **do**

$\vec{x}^{(k,i)} = \vec{x}^{(k)}, \quad \alpha^{n+1} = \frac{\alpha^0}{1+\varepsilon n}$

for (i=0; i<N; i++) **do**

$$\vec{x}^{(n,i+1)} = \vec{x}^{(n,i)} - 2\alpha(A^i)^T\left(A^i\vec{x}^{(n,i)} - b^i\right)$$

for all pixels j **in the image do**

if (k>0) **do**

$$C_j^{(n,i)} \leftarrow \begin{cases} (x_j^{(n,i+1)} - x_j^{(n,i)}) - \alpha\delta & if\ (x_j^{(n,i+1)} - x_j^{(n,i)}) > \alpha\delta \\ (x_j^{(n,i+1)} - x_j^{(n,i)}) + \alpha\delta & if\ (x_j^{(n,i+1)} - x_j^{(n,i)}) < -\alpha\delta \\ 0 & (otherwise) \end{cases}$$

$$M_j^{(n,i)} = \begin{cases} 1, & if\ C_j^{(n,i)} \neq 0 \\ 0, & (otherwise) \end{cases}$$

end if

$$\omega^{SA}(p,q) = \left(1 + \gamma M_q^{(n,i)}\right)\omega(p,q)$$

if (i>0 & i % NUP = 0) **do**

$$x_p^{(n,i+1)} \leftarrow \begin{cases} x_p^{(n,i+1)} - \alpha\beta\omega^{SA}(p,q) & if\ x_p^{(n,i+1)} - x_q^{(n,i+1)} > \alpha\beta\omega^{SA}(p,q) \\ x_p^{(n,i+1)} + \alpha\beta\omega^{SA}(p,q) & if\ x_p^{(n,i+1)} - x_q^{(n,i+1)} < -\alpha\beta\omega^{SA}(p,q) \\ x_q^{(n,i+1)} & (otherwise) \end{cases}$$
$$x_q^{(n,i+1)} \leftarrow \begin{cases} x_q^{(n,i+1)} + \alpha\beta\omega^{SA}(p,q) & if\ x_p^{(n,i+1)} - x_q^{(n,i+1)} > \alpha\beta\omega^{SA}(p,q) \\ x_q^{(n,i+1)} - \alpha\beta\omega^{SA}(p,q) & if\ x_p^{(n,i+1)} - x_q^{(n,i+1)} < -\alpha\beta\omega^{SA}(p,q) \\ x_p^{(n,i+1)} & (otherwise) \end{cases}$$

end if

end for all

end for $\vec{x}^{(k+1)} = \vec{x}^{(k,N)}$

end while

return $\vec{x}^{(k+1)}$

以下に、上記の Algorithm2 を分かりやすく簡略化した提案手法の手順を示す。

反復回数 k=1,2,3,...　　反復1回目は、[Step2]と[Step3]を除外

[Step1]データ項で画像を更新

[Step2]以下の計算で外れ値(SAや孤立点)を判定

$$\delta\sum_{j=1}^{J}|C_j| = \delta\sum_{j=1}^{J}|(\text{データ項で更新後の画素})_j - (\text{データ項で更新前の画素})_j|$$

$$C_j^{n+1} = \begin{cases} C_j^n - \alpha\delta & if\ C_j^n > \alpha\delta \\ C_j^n + \alpha\delta & if\ C_j^n < -\alpha\delta \\ 0 & (otherwise) \end{cases} \qquad M_j^{n+1} = \begin{cases} 1, & if\ C_j^{n+1} \neq 0 \\ 0, & (otherwise) \end{cases}$$

(ただし、$\vec{M}^0 = 0$)

[Step3]各画素対(p,q)に対応するNon-local TVの重みを計算

$$\omega^{SA}(p,q) = (1 + \gamma M_q)\omega(p,q), \qquad (\text{ただし、}\gamma > 0)$$

[Step4]Non-local TVの正則化項で画像を更新

図５　提案手法の手順

以下に、各反復 k における SA 検出結果$\vec{C}^{(k,N)}$とバイナリ MAP$\vec{M}^{(k,N)}$の変化を示す。(ただし、この結果は、$\gamma = 0$にして、カーネル内の全て Non-local TV の重みを$\omega^{SA}(p,q) = \omega(p,q)$と固定した場合である。)

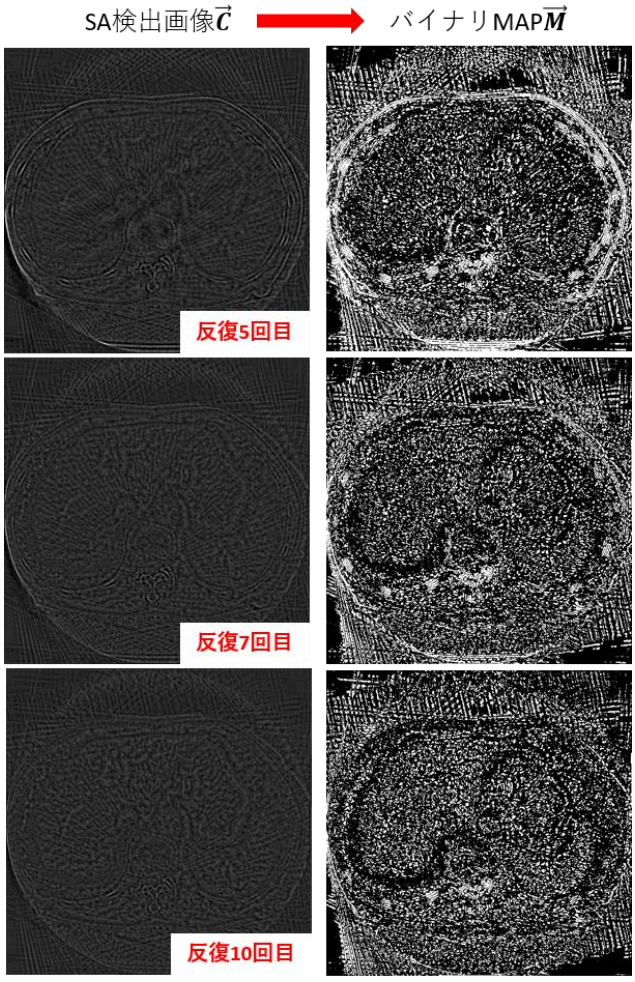

図６　SA 検出画像$\vec{C}$とバイナリ MAP$\vec{M}$($\gamma = 0$の時)

５．実験

画像のサイズは 512X512 であり、80 方向で実験を行った。

また、以下の図７のように、Parameter 調節を簡単にするために実験画像の画素値の範囲がなるべく 0 から 255 の間になるようにスケーリングした。

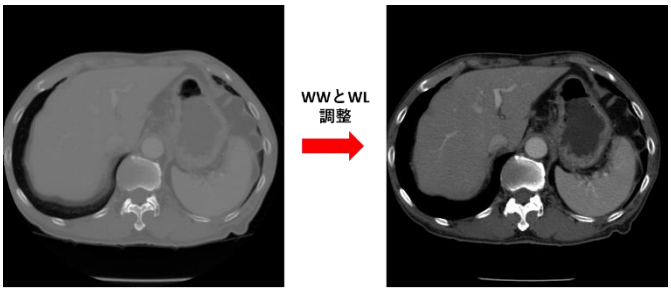

スケーリング後の画像$\vec{S}$
Dynamic range: 0～221.1940

表示画像
Display range: 81.5～138.5

図７　原画像のスケーリングとその表示

５．１　定量的評価

RMSE、PSNR, SSIM を用いて定量的評価を行う。

以下は、RMSE である。

$$RMSE = \sqrt{\frac{\sum_{i=1}^{N}(True_i - x_i)^2}{N}} \tag{12}$$

$True_i$:原画像、x_i:復元画像、N:全体画素数

以下は、PSNR である。

$$PSNR = 10\,log_{10}\frac{DR^2}{MSE}$$

DRは、表示画像のDisplay range($DR = DR_{MAX} - DR_{MIN}$)　(13)

$$MSE = \frac{\sum_{i=1}^{N}(True_i - x_i)^2}{N}$$

以下は、SSIM である。

$$SSIM = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}$$

μ_x(原画像)とμ_y(復元画像)は、局所領域の画素値の平均

σ_xとσ_yは、局所領域の標準偏差

σ_{xy}は、共分散　(14)

$$c_1 = (0.01 * DR)^2$$

$$c_2 = (0.03 * DR)^2$$

DRは、表示画像の$Display\ range$($DR = DR_{MAX} - DR_{MIN}$)

５．２　パラメータ

データ項の更新量$\boldsymbol{\alpha}$は十分大きくして、収束スピードを速くしたという前提で、反復回数 20 回以内で収束するものとする。

また、公平性のために、既存の NLTV と提案手法の両手法のパラメータは、同じく設定した。

表１　実験のパラメータ

Non-local TV		提案手法	
α	0.1	α	0.1
β	3	β	3
$\varepsilon(Step\ size)$	0.001	$\varepsilon(Step\ size)$	0.001
Search window size	21x21	Search window size	21x21
Template window size	11x11	Template window size	11x11
h^2	3	h^2	3
$2\sigma^2$(80方向FBP画像基準)	27.482757	$2\sigma^2$(80方向FBP画像基準)	27.482757
		δ	7.5
		γ	2.5

表１のように提案手法で追加されたパラメータは、$\boldsymbol{\delta}$と$\boldsymbol{\gamma}$だけである。

５．３　バイナリ MAP$\vec{M}$の変化に関する実験

式(7-11)の SA 検出モデルが正しく収束するものであれば、各反復で同定されるバイナリ MAP$\vec{\boldsymbol{M}}$の 1 の画素値は、反復回数が増えていくほど、0 になる。

以下は、提案手法の**表１**のパラメータによる実験結果である。

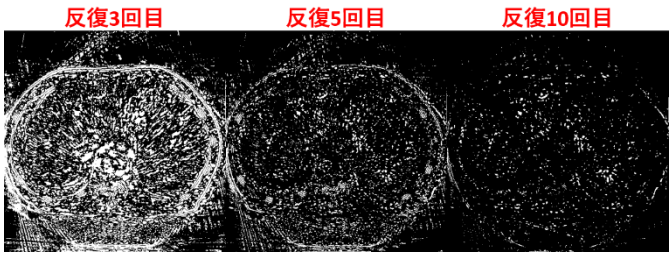

図８　バイナリ MAP$\vec{\boldsymbol{M}}$($\boldsymbol{\gamma}$ = 2.5の時)の変化

反復１０回目以降には、外れ値(SA や孤立点)が、ほぼ検出されないことが分かる。

これは、「データ項で更新後の画像」と「データ項で更新前の画像」の差(エネルギーの差)が、ほぼ正しく外れ値 (SA や孤立点) 除去に使われたということを示している。

５．４　実験結果

特に少ない反復回数における SA 除去において、提案手法の有効性を確認するために、以下の図ように反復 2 回目、５回目、10 回目、20 回目における既存の NLTV と提案手法の比較検証結果を示す。

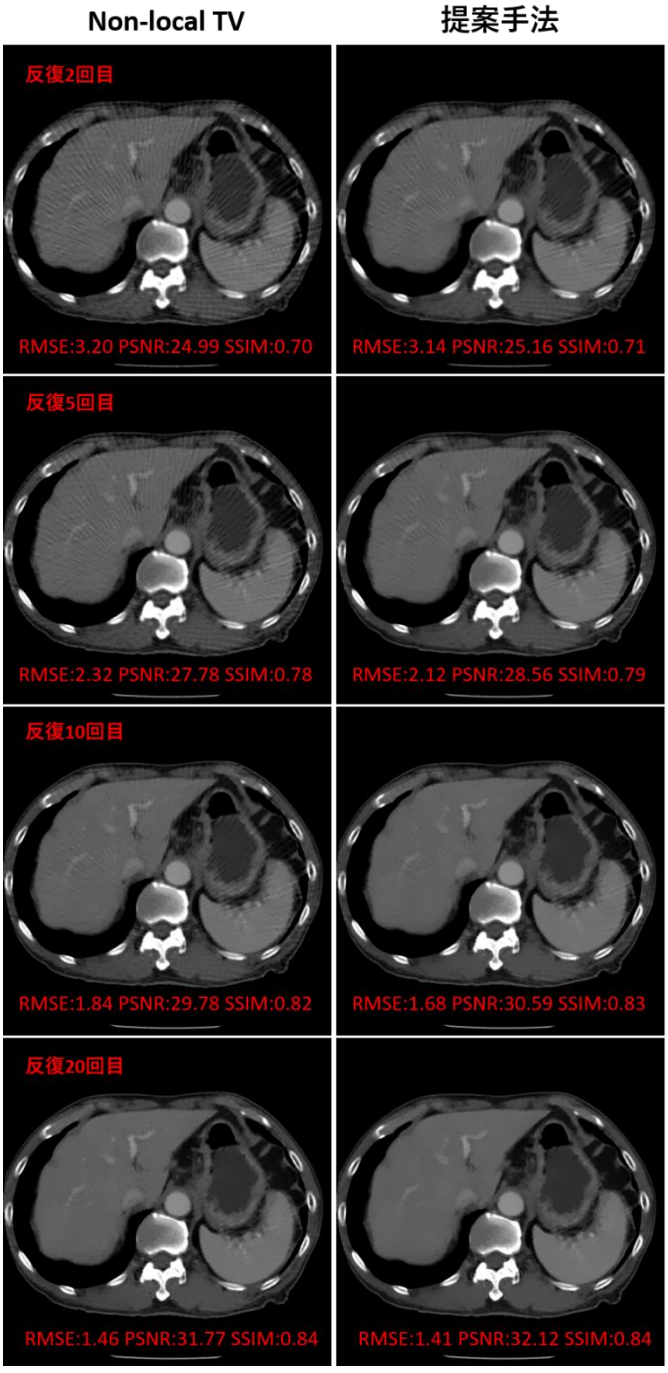

図９　実験結果

提案手法は、既存の NLTV より初期反復での SA 除去性能がよい。

また、収束時(反復 20 回目)の画質は、両手法がほぼ同じであることが分かる。

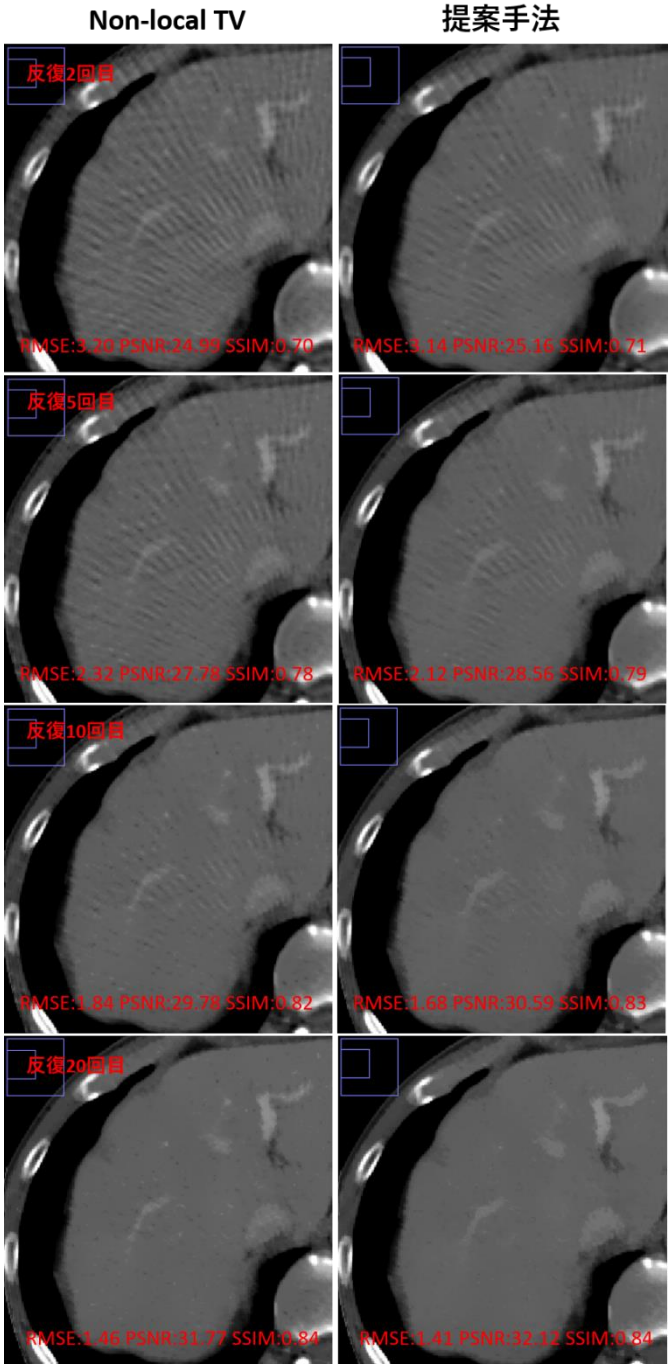

図１０　「図９の実験結果」の拡大画像

提案手法は、既存の NLTV と比べ、SA や孤立点が少ないことが分かる。

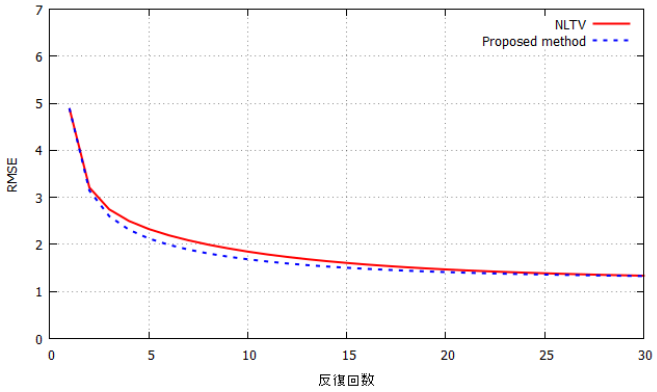

図１１　反復回数における RMSE の変化

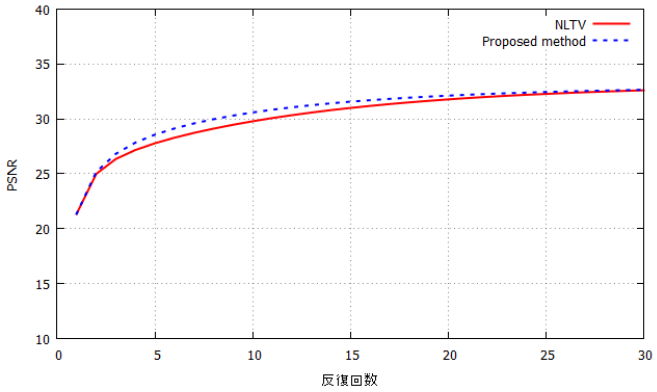

図１２　反復回数における PSNR の変化

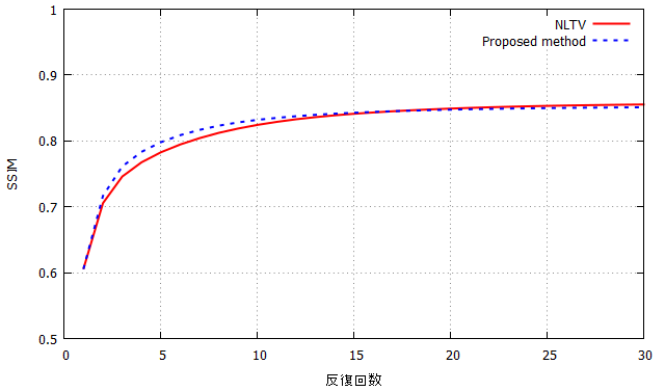

図１３　反復回数における SSIM の変化

RMSE と PSNR の両方とも、提案手法の方がよいことが分かる。

提案手法より既存の NLTV の収束時の SSIM が若干高い理由は、孤立点の影響によって、局所領域の共分散$\boldsymbol{\sigma_{xy}}$が大きくなってしまうからである。

６．まとめ

実験により、特に少ない反復回数で SA を効率よく除去できることが明らかになった。

また、**式(2)**の定式化は、NLTV を用いるどの反復法にも共通するため、本研究で用いた近接スプリッティングに基づく Row-Action 以外に、座標降下法や Chambolle's アルゴリズムなどの様々な反復法と組み合わせができる。

さらに、提案手法は、本研究で用いた NLTV と多少なりとも類似したノイズ除去の仕組みをしている既存の TV 法や Non-local means フィルタを用いた「NLF-CS[6]」と呼ばれる別の正則化に対応できる柔軟性があると考えられる。

今後の課題として、既存の TV 法や NLF-CS に対し、提案手法をどのように対応させるか、またどのような効果があるかを検証しなければならない。

利益相反の有無

なし

参考文献

[1] H. Kudo, “新方式コンピュータトモグラフィーと圧縮センシング”, 精密工学会誌, Vol.82, No.6, 2016

[2] Xavier Bresson, “A Short Note for Nonlocal TV Minimization”, Technical Report, 2009

[3] PL. Comettes, J.-C. Pesquet, “Proximal splitting method in signal processing”, Fixed Point Algorithms for Inverse Problems in Science and Engineering, 2010

[4] J. J. Moreau, “Fonctions convexes duales et points proximaux dans un espace hilbertien”, CR Acad. Sci. Paris Ser.A Math, 255, pp.2897-2899, 1962

[5] A Buades, B. Coll, and J. Morel. On image denoising methods.Technical Report 2004-15, CMLA, 2004

[6] Jian Dong and Hiroyuki Kudo,” Investigation of image quality difference between total variation and nonlinear sparsifying transform based compressed sensing, SPIE Medical Imaging 2017, Paper No. 10132-109, 2017

Image quality improvement of sparse-view CT image reconstruction using non-local total variation

Yongchae KIM[*1], Hiroyuki KUDO[*1]

[*1]*Graduate School of Information and Systems, University of Tsukuba*

In the field of image reconstruction for sparse-view CT, by approximately calculating the weight added to the TV term, non-local total variation(TV) works better at preserving smooth contrast change and low-contrast texture than normal TV, and ultra-high image quality can be obtained. In this research, we propose an improved method based on the following idea. The proposed method can detect the pixels from strong streak artifacts. The weight of the non-local TV term can be calculated from the latest reconstructed image, and then the weights needed to apply for pixels with artifacts can be obtained accordingly. The key point is that the size of weight is determined by the absolute difference between the updated image obtained from the data term and the updated image obtained from the regularization term. The proposed method has a very high degree of generality and flexibility, which can be combined with various iterative methods. In our research, we did some simulation experiments using medical CT images by combining proposed method with Row-Action type image reconstruction method based on proximal splitting. From the results of our experiments, it is clear to see that remarkable improvement of image quality (reduction of streak artifacts) can be achieved within extremely small number of iterations.

Key words: Sparse-view CT, Non-local TV, Non-local means, Streak Artifact, Row-Action, Proximal splitting, Swing-by

---

金　鎔采（きむ　よんちぇ）

2016 年筑波大・情報・情報メディア創成卒. 現在, 同大学院・システム情報・博士前期課程在学中.

工藤博幸（くどう　ひろゆき）

1985 年東北大・工・通信卒. 1990 年同大学院博士課程了. 現在, 筑波大・システム情報・教授. 1990 年電子情報通信学会論文賞, 1991 年・2001 年・2006 年・2008 年日本医用画像工学会論文賞, 2006 年・2008 年国際雑誌『Inverse Problems』High Lights 受賞, 2008 年国際雑誌『Physics in Medicine and Biology』High Lights 受賞, 2018 年文部科学大臣表彰科学技術賞受賞. 工博. CT と PET を中心とした医用イメージング, 画像処理の研究に従事. IEEE, SIAM, 各会員. 電子情報通信学会フェロー. 日本医用画像工学会副会長.

*　　*　　*

深層学習による放射型 CT の画像補正

鈴木　朋浩[*1]　工藤　博幸[*1]

要旨

PET/SPECT などの放射型 CT 画像再構成では，統計雑音が多く減弱補正が必要なため主として逐次近似再構成法が用いられるが，計算コストが大きい問題点がある．近年では，CT/MRI 画像を利用した減弱補正も行われているが，比較的複雑な処理を必要とする．本論文では，フィルタ補正逆投影(FBP)法で画像再構成した雑音が多く減弱補正されていない PET/SPECT 画像に対して，後処理として畳み込みニューラルネットワーク(CNN)を用いて雑音除去と減弱補正を同時に行う手法を提案する．放射能分布画像と減弱係数分布画像の原画像からシミュレーションにより作成した投影データを補正なしの単純 FBP 法で再構成して，それと原画像とのペアを教師データとして CNN の学習を行った．更に，その際に単純 FBP 法画像に加え CT 画像(マルチモダリティ画像)を入力チャネルに用いることで，より良好な補正結果が得られることが明らかになった．本手法により，逐次近似画像再構成を行わずに短時間で減弱補正と雑音除去が可能となる．

キーワード：放射型 CT，深層学習，画像再構成，画像補正，マルチモダリティ画像

1. はじめに

現在，病気診断の目的に PET(Positron Emission Tomography)／SPECT(Single Photon Emission CT)などの放射型 CT が用いられている．これらの装置では，被写体内部の放射線源の濃度分布を知ることで，代謝や臓器の生理学的機能に関する情報が得られる．しかし，撮影にあたって放射線源を体内に取り込むため，内部被曝や撮影後長時間にわたる放射などの問題点があり，放射線源濃度のより低い条件にて撮影を行うことが望ましい．また，被写体内部から発生される放射線は，被写体自身により減弱されるため，定量性を確保するには減弱の影響を考慮した画像再構成法が必要である．

現在，放射型 CT の画像再構成法としては雑音の統計的性質や減弱補正を考慮して高画質の画像を得ることが可能な ML-EM 法などの逐次近似再構成法が主流であるが，計算コストが大きい問題点がある．また，放射型 CT の減弱補正を行う手法として， CT／MRI などの装置で得られた形態画像を利用する手法も使用される[1],[2]．しかし，これらの手法では，対象部位や撮影条件により異なるアルゴリズム実装やパラメータ選定が必要であるため，広い撮影対象に対して簡便に良い補正結果を得ることは難しい．また，アルゴリズムや実装が比較的複雑であり計算コストが大きい問題点がある．

そこで，本論文では，撮影条件や被写体を問わず適用可能で，かつ高速に処理結果を得ることが可能な新しい補正手法として，畳み込みニューラルネットワーク(Convolutional Neural Network, CNN)を，放射型 CT 再構成画像における雑音と減弱の補正に用いる手法を提案する．提案手法では，計測投影データに対して減弱補正と平滑化を行わない単純フィルタ補正逆投影（Filtered Backprojection, FBP）法で画像再構成を行い，それを CNN に入力して補正を行った出力画像を得る．CNN の学習は，シミュレーションで人工的に作成した入力画像と正解画像ペアからなる教師データ

*1 筑波大学大学院システム情報工学研究科コンピュータサイエンス専攻
〔〒305-8573 つくば市天王台 1-1-1〕
e-mail: suzukitokyon@gmail.com

を利用して行い，最適な画像補正を行う過程を CNN に学習させる．SPECT を想定したシミュレーション実験を行い，提案手法の有効性を示す．

2. 提案手法

2-1 深層畳み込みニューラルネット

ニューラルネット（Neural Network, NN）とは，式(1)のように入力ベクトル$\boldsymbol{x}$に対するアフィン変換と活性化関数と呼ばれる非線形演算fの合成

$$\boldsymbol{x}_{i+1} = f(W_i \boldsymbol{x}_i + \boldsymbol{b}_i) \tag{1}$$

を繰り返し適用して複雑な関数を実現する数学的枠組みである．ここで，添え字iは適用繰り返し回数を表し各iに対応する演算は層(Layer)と呼ばれる．非線形演算fとしては，例えば式(2)で表される ReLU が用いられる．

$$f(\boldsymbol{x}_{in}) = Max(\boldsymbol{0}, \boldsymbol{x}_{in}) \tag{2}$$

式(1)における関数の各パラメータW_i，$\boldsymbol{b}_i$を与えられた教師データ(入力画像と正解画像のペア)に対してフィッティングさせること（学習・訓練）で，NN に回帰・分類などの処理を行わせることができる．式(1)におけるW_iは重み，$\boldsymbol{b}_i$はバイアスと呼ばれる．学習に用いる最適化手法としては，単純な確率的勾配法や適応的に学習率を変化させる Adam などの手法が用いられる[3]．また，複数の教師データをまとめて学習に利用するミニバッチ処理も，勾配安定化や学習高速化を目的に用いられる．

CNN とは，式(1)の行列演算が畳み込み演算

$$\boldsymbol{x}_{u,v} = \sum_{p=-s}^{s} \sum_{q=-s}^{s} w_{p,q} x_{u-p,v-q} \tag{3}$$

で表される NN を指し，これらを多数積層した DCNN(Deep CNN) は画像認識・画像生成・画像変換などのタスクにおいて優れた性能を示すことが知られている．DCNN の医用イメージングへの応用研究として，低線量 CT やスパースビューCT における雑音やアーティファクトの除去に CNN を用いる研究[4],[5]や，正則化項つき画像再構成における近接写像の近似として CNN を利用する研究[6]などがある．

本論文では，DCNN による画像変換を放射型 CT 画像再構成における雑音除去と減弱補

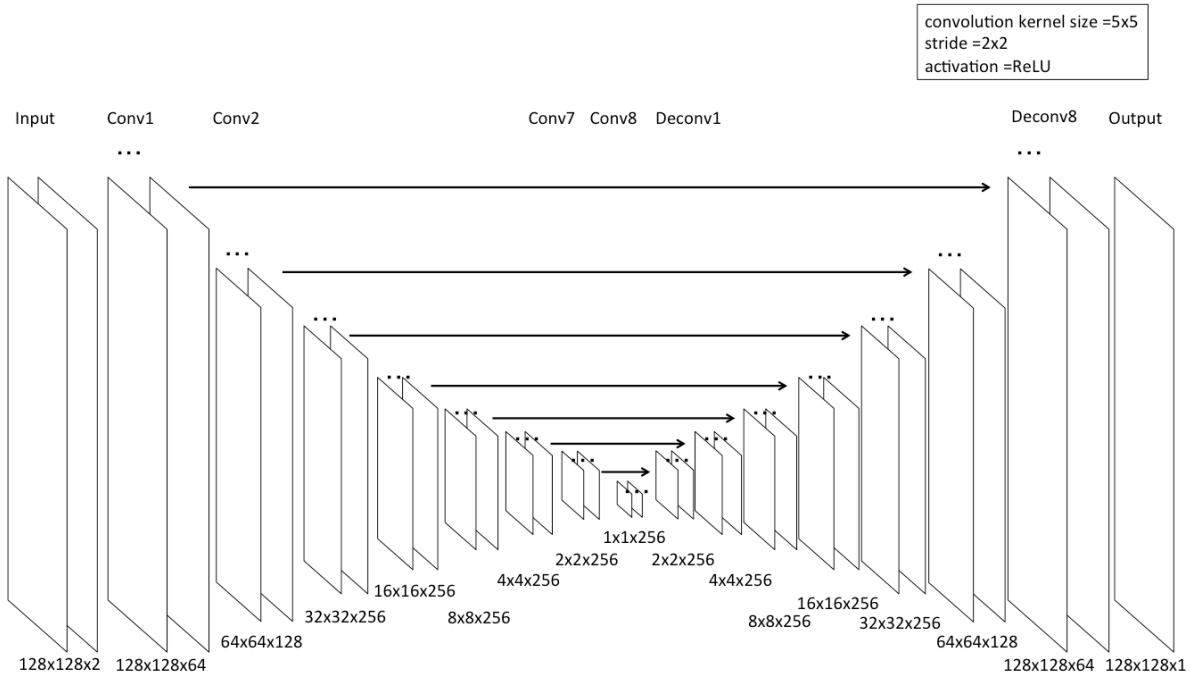

図 1 実験に用いた DCNN の構造

正に適用することを提案して，その実装と実験を行った. 実験に用いる DCNN は**図 1** の構造であり，画像変換などによく用いられる U-net と呼ばれる NN を基礎としている[7]. U-net は，**図 1** に示すように，畳み込み層の繰り返しにより得られた画像特徴量から再び画像を生成する逆畳み込み層に，対応するサイズの畳み込み層のチャネルをバイパスして入力として追加する構造を加えたものである. このバイパス構造により，医用画像に重要な画像細部を保存する変換結果が得られると考えられ, 本論文では U-net を採用した. また，各層の後段には，Batch Normalization [8]と呼ばれる出力をミニバッチ毎の 1 次，2 次モーメントで正規化することで勾配消失の問題を回避して学習の収束性を向上させる層を置いている. この DCNN に対して入力・正解画像のペアを学習データとして与え，出力画像と正解画像の誤差を最小化するパラメータを求め，フィルタベースの入力画像を所望の出力画像に補正する画像変換を実現する.

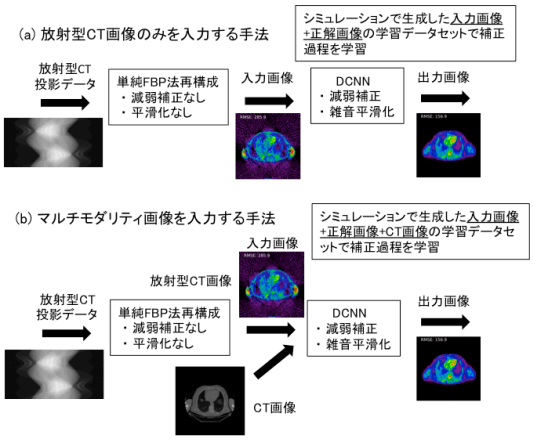

図 2 提案手法の構造

2-2 提案手法

上述の DCNN を用いて, 本論文では放射型 CT において簡便に減弱と雑音の影響を補正して高画質の画像を再構成する手法を提案する．**図 2** に提案手法の構造を示す．まず，**図 2**(a)の手法では，計測した投影データに対して, 減弱補正と平滑化を行わない単純 FBP 法で画像再構成を行う．そして，この画像を DCNN に入力して減弱補正と平滑化を行った高画質の出力画像を得る．CNN の学習は，シミュレーションで人工的に作成した入力画像と正解画像ペアからなる教師データを利用して行い，最適な雑音と減弱に対して画像補正を行う過程を CNN に学習させる．一方，**図 2**(b)の手法では，DCNN に単純 FBP 法の再構成画像に加え別チャネルに補足的に同一患者の CT 画像を入力して，放射型 CT 画像を出力画像として得る．マルチチャネル画像として用いた CT 画像は, DCNN 内部で放射型 CT 画像の減弱と雑音の補正精度を向上させる形で利用されると考えられ，精度が向上する．この手法は，放射型 CT の減弱補正や雑音除去に CT／MRI の形態画像を利用する従来研究[1],[2]との整合性も良く，実際に大きな精度改善につながることを以降の実験で示す.

DCNN を用いる際に重要な点として，入力して学習・処理を行うデータ単位を画像から切り出したパッチにするか 2 次元画像全体にするかがある．減弱のアーティファクトは場所依存性が大きく類似した濃度変化を持つパッチでも画像のどの位置に存在するかで減弱補正を大きく変える必要がある. したがって，本論文で扱う減弱補正への適用では 2 次元画像全体で学習・処理を行うのが適切と考え，DCNN に 2 次元画像全体を入力する CNN 構成で実装と実験を行った.

3. 実験方法

提案手法を実装して SPECT における画像補正に適用して, 評価実験を行った. 実験は，1) シミュレーションによる学習データの作成，2) それらを用いた DCNN の学習，3) 学習済 DCNN のテスト画像への適用, の 3 段階から構成される．以降では詳細を述べる.

3-1 学習データの作成

DCNN の学習には大量の教師データが必要となる．本論文では，SPECT 撮影過程のシミュレーションにより，人工的に学習に用いる教師データを生成した．ECT-CT の正解画像

として，TCIA(The Cancer Image Archive)で公開されている Philips 社の PET-CT 同時撮影の再構成画像セットを利用した[9]．まず，SPECT 撮影を模擬したシミュレーションにより統計雑音と減弱の影響を含む投影データを生成し，それらを Shepp-Logan フィルタを用いた FBP 法で再構成することで，DCNN の入力画像を作成した．ただし，FBP 再構成においては，投影データ空間での前処理などによる減弱補正と平滑化による雑音除去は一切行わない．よって，シミュレーションで得られる入力画像は低品質である．正解画像は，上述のように PET で撮影された放射能分布画像であるが，撮影機器・撮影条件に最適化された手法による再構成が行われており定量性や画質が高く，本実験における正解画像として用いた．

シミュレーション過程で投影データに加える雑音は，同一患者の CT 画像から得られる減弱係数の分布に基づき，投影データ上の各検出器において検出される光子計数値の期待値を平均とするポアソン分布により加えた(式(4))．

$$\hat{p}_i = \mathrm{Poisson}(\sum_r a_{i,r} x_r e^{-\sum_s c_s a_{i,s}}) \qquad (4)$$

ただし，c_sは画素sの減弱係数，$a_{i,s}$はi番目の光線が画素sを横切る長さである． 撮影時のコリメータは，検出器面に対し垂直に入射する 1 次光子のみを計数するものを想定し，検出器アレイは 512 画素で，128 方向から投影データを計測する設定でシミュレーションを行った（**図 3**）．撮影条件は，正解である放射能分布画像の計数値を 1/10 程度まで削減して，更に放射光子のエネルギーを低くすることで減弱の度合いを大きくし，投影データの計数値を低く設定している．この投影データに対して，上述の雑音と減弱の補正を行わない単純 FBP 法による再構成画像を作成して，入力画像とした．以上のシミュレーションと画像再構成法は全て C++言語で実装した．シミュレーションにより生成した入力画像の例を，**図 4** に示す．

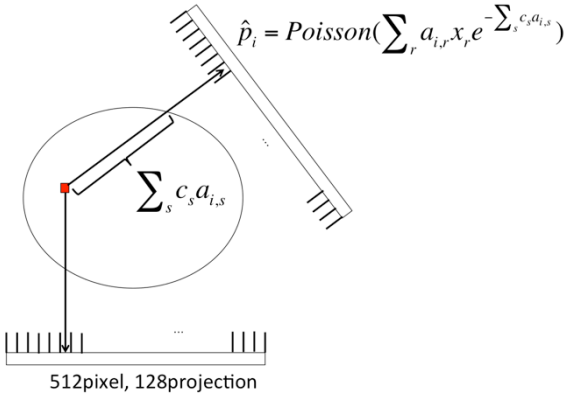

図 3 SPECT 撮影系の概略

単純 FBP 法画像と正解画像の間には以下にまとめる相違が存在する．

① FBP 法は ML-EM 法と比較し雑音特性が悪く，画像に雑音が多い．
② 減弱補正を行っていないため，同一領域内の濃度値が平坦でなく強いカッピングアーティファクトが存在する．
③ 投影データの方向数が少ない場合や計数値が小さい低 S/N 比の場合，ストリーク状アーティファクトが発生する．

DCNN の学習に用いるデータセットは，撮影に利用する放射線のエネルギーと入力に用いる画像種類を変化させ，**表 1** に示す計 4 組（A1,A2,B1,B2）の条件のものを作成した．各組のデータセットは 13,000 セットの画像データ（入力画像+正解画像(+CT 画像)）から構成され，これらを学習データ約 12,000 セット・検証用データ約 500 セット・テスト用データ約 500 セットに分けて実験に使用した．

最後に，SPECT は PET と撮影方式・検出器幾何学系の違いはあるが，本論文で実験を行った単純 FBP 法再構成画像に対する DCNN による補正手法は，PET の投影データに対しても同様に適用可能と考えられる．

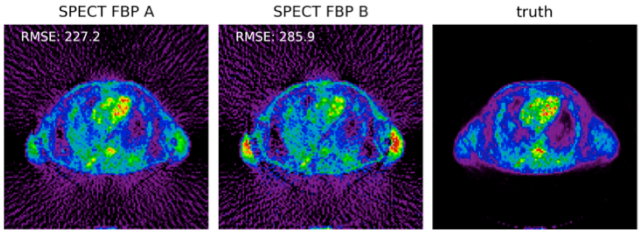

図 4 シミュレーション画像
(左 120keV, 中 100keV)と正解画像(右)

表 1 実験に用いたデータセットの組

データセット	放射線エネルギー	入力画像種類
A1	120keV	SPECT(単純 FBP)
A2	120keV	SPECT(単純 FBP)+CT
B1	100keV	SPECT(単純 FBP)
B2	100keV	SPECT(単純 FBP)+CT

3-2 DCNN の学習とテストデータの処理

DCNN の実装は Google 社のオープンソースソフトウェアである Tensorflow[10]を用いて Python で実装し，実行には NVidia 社製の GPU である Tesla K80 を 1 基用いた．データセット中の全ての画像は，入力時に画素値の範囲が[-1,1]に収まるように濃度を正規化した．また，回転や拡大縮小などによる Data Augmentation は行っていない．学習の損失関数としては，正解画像 truth と出力画像 DCNN($\boldsymbol{x}$)の L^2 誤差

$$\mathrm{Loss}(\mathrm{DCNN}(\boldsymbol{x}), \mathrm{truth}) = \|\mathrm{DCNN}(\boldsymbol{x}) - \mathrm{truth}\|_2 \quad (5)$$

を用い，学習の最適化手法には Adam を学習率 0.001，$\beta = 0.5$で用いた．学習は検証用データセットに対する損失関数の値の変化が概ね飽和するまで 10 エポック程度繰り返し，各組のデータセットに対して約 10 時間程度の計算時間を必要とした．学習済の DCNN による画像補正の計算時間は，ファイルの読み込を含め平均して画像 1 枚あたり約 0.1 秒程度で完了する程度に高速であった．

4. 結果

上述の 4 組のデータセット(A1,A2,B1,B2)で学習を行った各組に対応する DCNN について，対応するテスト用データを入力して補正画像を求め，評価を行った．

A1,A2,B1,B2 いずれの結果についても，減弱を考慮しない単純 FBP 法再構成画像である入力画像(**図 5,6** 各 2 段目)に見られる周辺部のカッピングやストリーク状アーティファクトが DCNN により上手く補正されており，出力画像(**図 5,6** 各 3 段目)と正解画像の平均 2 乗誤差平方根(RMSE)値は，入力画像との RMSE 値と比較して大きな改善が見られた．特に，撮影条件が悪いほど顕著な RMSE 値の改善があった．**表 2** は約 500 セットの画像の入出力画像と正解画像の画素当たりの 2 乗誤差の平均値である．

また，SPECT 画像に加え CT 画像(**図 5,6** 各 1 段目)を別チャネルの補助入力に用いた場合（**図 5,6** 各 4 段目）は，特に空洞部領域の放射能分布に顕著な改善が見られた．**表 3** は，**図 7** に白丸でマーキングした組織部(領域 1)と空洞部(領域 2)における CNR(Contrast Noise Ratio)値（式(6)）を，正解画像・入力画像である単純 FBP 法再構成画像・A1, A2,B1,B2 の出力画像について評価した結果である．

$$\mathrm{CNR} = \frac{\mathrm{Mean1} - \mathrm{Mean2}}{(\mathrm{SD1} + \mathrm{SD2})/2} \quad (6)$$

単純 FBP 法再構成画像及び CT 画像を入力に用いない A1,B1 の出力画像は，アーティファクトの影響により CNR 値が低いのに対して，CT 画像を入力チャネルに用いた A2,B2 の出力画像は CNR 値が正解画像にかなり近く改善されている．

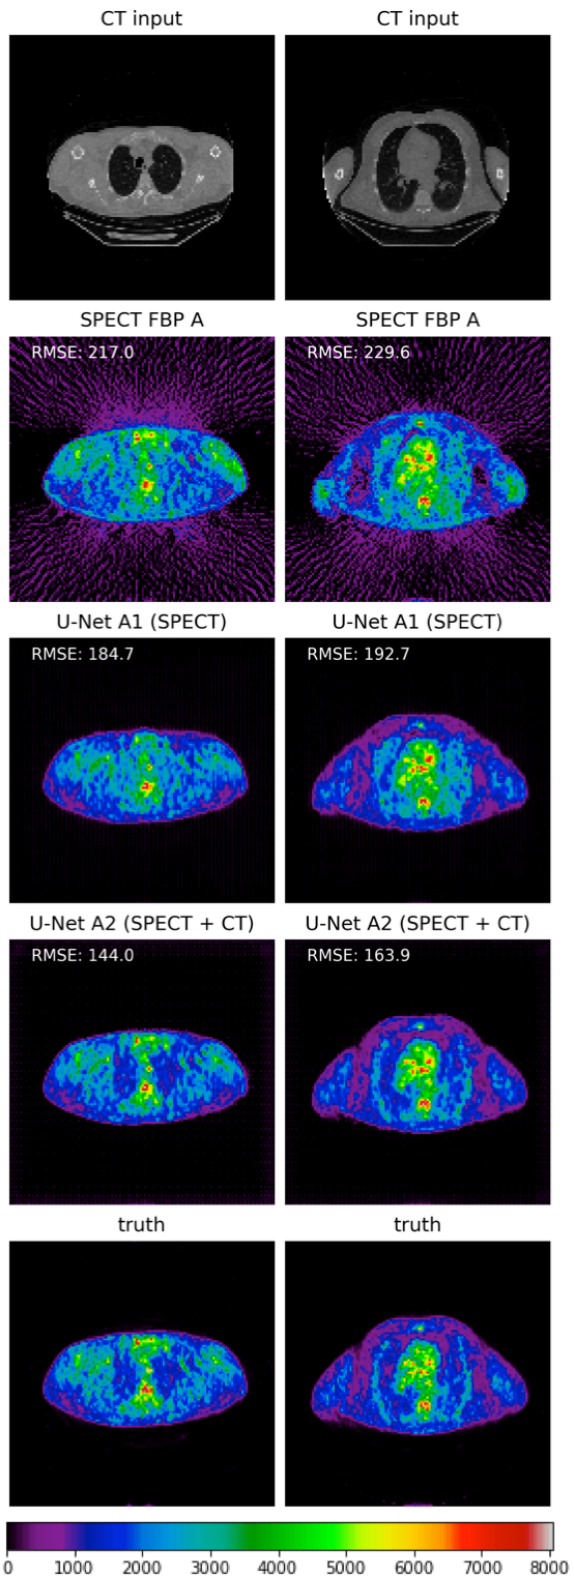

図 5 データセット A1,A2 の入力(1,2 段目)，補正結果(3,4 段目)，正解画像(5 段目)

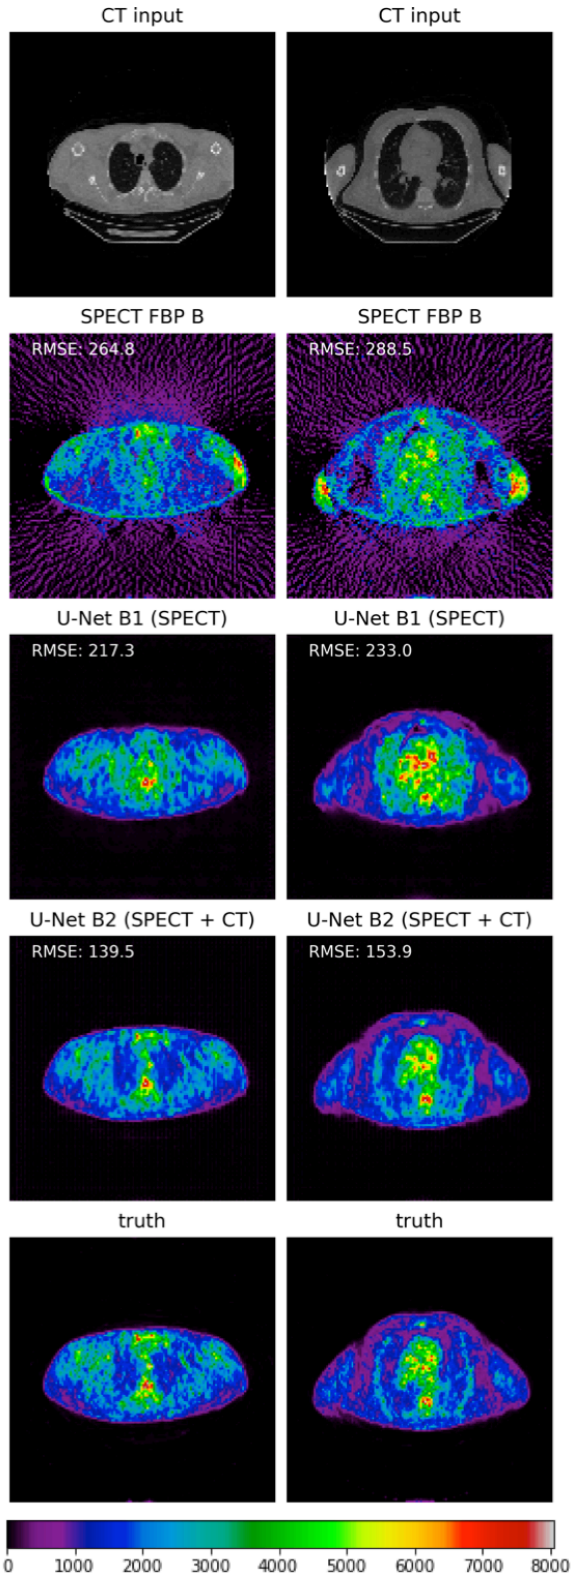

図 6 データセット B1,B2 の入力(1,2 段目)，補正結果(3,4 段目)，正解画像(5 段目)

表 2 入出力画像と正解画像の画素あたりの 2 乗誤差の平均値

対象	画素あたり 2 乗誤差
SPECT FBP A(入力)	2.89
U-Net A1(出力)	1.48
U-Net A2(出力)	**1.18**
SPECT FBP B(入力)	3.40
U-Net B1(出力)	1.97
U-Net B2(出力)	**1.38**

表 3 出力画像の**図 7** に示す空洞部と組織部における CNR 値

	Mean1	SD1	Mean2	SD2	CNR
FBP A	185	23.0	97	19.0	4.19
A1	159	30.1	76	17.4	3.52
A2	164	25.0	52	11.7	**6.10**
Truth	154	24.5	38	11.4	6.46
FBP B	176	19.7	122	15.6	3.10
B1	184	30.4	100	19.2	3.44
B2	157	25.1	57	12.0	**5.40**
Truth	154	24.5	38	11.4	6.46

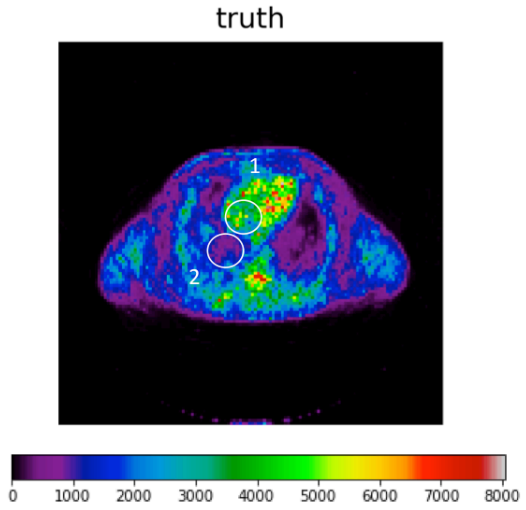

図 7 CNR 値を評価した部位

5. まとめ

シミュレーションにより作成した雑音と減弱の影響を含む放射型 CT 投影データを補正なしの単純 FBP 法で再構成した画像と正解画像のペアからなる教師データで学習させた DCNN を用いて，低品質な放射型 CT の FBP 再構成画像に対して高速に雑音と減弱によるアーティファクトを低減する効果を比較的簡便に得ることができた．更に，CT 画像を補足的に入力チャネルに用いることで，(被写体内部の空洞部における)放射能分布の推定精度が向上した．学習後の DCNN による画像補正は，逐次近似計算を必要としないため高速に実行できる．CT 画像を用いない補正では，画像中における減弱に起因するカッピングやストリークなど特徴的なパターンの雑音除去はできたが，空洞部と組織部の境界など細部について十分な補正が行われなかった．一方，CT 画像を入力チャネルに加えた場合には，空洞部と組織部の境界も高精度で復元され，被写体の解剖学的構造を反映した補正が行えていることが分かった．

今後，現実の撮影機で発生する他の物理現象(例えば，検出器のコリメータ開口特性や散乱)を考慮したシミュレーションによる学習データ作成を行い提案手法の精度を改善し，更に実データを用いて実用性の検討を行う予定である．

利益相反の有無

無し

文　献

［1］ Kinahan PE, Townsend DW, Beyer T, Sashin D: Attenuation correction for a combined 3D PET/CT scanner. Med Phys **25**: 2046-2053, 1998

［2］ Patton JA, Turkington TG: SPECT/CT physical principles and attenuation correction. J Nucl Med Tech **2008**: 1-10, 2008

［3］ Kingma DP, Ba J: Adam: A Method for stochastic optimization, arXiv: 1712.05877, 2017

［4］ Chen H, Zhang Y, Zhang W, et al.: Low-dose CT via deep neural network. Biomed Opt Express **8**: 679-694, 2017

［5］ Jin KH, McCann MT, Froustey E, Unser M: Deep convolutional neural network

for inverse problems in imaging. IEEE Trans Image Process **26**, 4509-4522, 2017

［6］ Adler J, Öktem O: Learned primal-dual reconstruction, arXiv: 1707.06474, 2017

［7］ Ronneberger O, Fischer P, Brox T: U-Net: Convolutional networks for biomedical image segmentation. Medical Image Computing and Computer-Assisted Intervention **9351**: 234-241, 2015

［8］ Ioffe S, Szegedy C: Batch normalization: accelerating deep network training by reducing internal covariate shift. arXiv: 1502.03167, 2015

［9］ Clark K, Vendt B, Smith K, et al.: The cancer imaging archive (TCIA): maintaining and operating a public information repository. Journal of Digital Imaging 26: 1045-1057, 2013

［10］ Abadi M, Agarwal A, Barham P, et al.: TensorFlow: large-scale machine learning on heterogeneous distributed systems. arXiv: 1603.04467, 2016

Compensation of image degradations in emission computed tomography by deep learning

Tomohiro SUZUKI[*1], Hiroyuki KUDO[*1]

*1 Department of Computer Science, Graduate School of Systems and Information Engineering, University of Tsukuba, Japan

To reduce image artifacts originating from statistical noise and photon attenuation in emission CT, iterative image reconstruction algorithms have been widely used. However, these methods require high computational costs. Furthermore, in recent years, attenuation correction methods using anatomical CT/MRI images have been investigated, but these methods tend to require rather complicated computations. In this paper, we propose use of Convolutional Neural Network (CNN) for the image correction in the emission CT. In this method, we input an FBP reconstructed PET/SPECT image with no smoothing and no attenuation correction into the CNN, which is processed by the CNN to obtain a final corrected image. We also investigated to input a pair of an FBP degraded image and a corresponding CT image (multimodality image) into the CNN. The learning of CNN was performed by using a set of images constructed through simulating image formation process of the emission CT. The simulation results demonstrate that the CNN-based method enables noise reduction and attenuation correction simultaneously without iterative computational algorithms. Also, the results demonstrate that inputting a CT image in addition to an emission CT image further improves accuracy in the image correction.

Key words: Emission CT, Deep Learning, Image Reconstruction, Image Correction, Multimodality Imag

著者紹介

鈴木　朋浩　（すずき　ともひろ）
東京大学工学部システム創成学科卒業．同大学院工学系研究科原子力国際専攻修士課程修了．筑波大学システム情報工学研究科コンピュータサイエンス専攻博士課程後期在籍

工藤　博幸　（くどう　ひろゆき）
1985 年東北大・工・通信卒．1990 年同大大学院博士課程了．現在，筑波大・システム情報系・教授．1990 年電子情報通信学会論文賞，1991 年・2001 年・2006 年・2008 年日本医用画像工学会論文賞（4 回），2006 年・2008 年国際雑誌『Inverse Problems』High Lights，2008 年国際雑誌『Physics in Medicine and Biology』High Lights，『新方式 CT の構成方式と画像再構成法に関する先駆的研究』により平成 30 年度文部科学大臣表彰科学技術賞（研究部門）受賞．工博．CT を中心とした医用イメージング，画像処理の研究に従事．IEEE, SIAM, IPEM, 各会員．電子情報通信学会フェロー．2011～2016 年，日本医用画像工学会誌 Medical Imaging Technology 編集長．2016 年～，日本医用画像工学会副会長．2018 年，第 37 回日本医用画像工学会大会（JAMIT2018）大会長．2008 年に CT の未解決問題であるインテリア問題の安定な厳密解法を発見し，2 つの論文が国際雑誌『Physics in Medicine and Biology』と『Inverse Problems』の 2008 High Lights を受賞．

管電流変調と bow-tie フィルタの X 線 CT 画像上の雑音分散への効果

梅田　祐司[*1]　池田　充[*1]　田之上　和矢[*1]

藤井　啓輔[*1]　川浦　稚代[*1]　今井　國治[*1]

要旨

これまで我々は，雑音を量子雑音に限定した場合における X 線 CT 画像の関心領域内の雑音分散の（アンサンブル領域の）期待値を解析的な式によって与えることについての検討を行ってきたが，管電流変調と bow-tie フィルタが同雑音分散に与える影響については未検討であった．そこで今回，管電流変調を適応した場合と bow-tie フィルタを設定した場合について，雑音分散に対する影響とこれらを考慮して解析的に計算した雑音分散の精度に関する検討を仮想的な X 線撮影系に対するシミュレーションによって実施した．その結果，管電流変調を適応した場合と bow-tie フィルタを設定した場合においても，解析的に計算した期待値はシミュレーション画像からの推定値とよく一致し，解析的に計算した期待値の精度が高いことが示された．さらに，解析的に計算した期待値から，管電流変調を適応した場合と bow-tie フィルタを設定した場合，雑音分散値の変動は減少することを予測できることも示された．

キーワード：CT，画質評価，被ばく線量

1. はじめに

X 線 Computed Tomography (CT)検査は，現在様々な診断に用いられるようになっており,その画像診断の役割はますます大きくなっている．その中で同画像の画質に関する評価も数多く行われており，中でも均一な CT 値を有すると期待される画像領域における CT 値の変動に関する分散を測定する方法は，X 線 CT 画像における雑音の評価方法の最も基本的なものである．これまで我々は，雑音を量子雑音に限定した場合における，この X 線 CT 画像の関心領域内の（「空間平均」の意味での）雑音分散の値の［「集団（集合）平均」の意味での］期待値を，文献[1, 2]と同様な方法を使用して解析的な式によって与えることについての検討を行い，同式の精度がよいことを確認した[3]．ただし，これらの検討では，現在臨床において用いられている bow-tie フィルタと管電流変調の影響を考慮しておらず，両者を使用した場合での解析的な式の精度については未検討であった．

そこで今回，管電流変調を適応した場合と bow-tie フィルタを設定した場合について，雑音分散に対する影響とこれらを考慮して解析的に計算した（「空間平均」の意味での）雑音分散の［「集団（集合）平均」の意味での］期待値の精度に関する検討を，仮想的な X 線撮影系を使用したシミュレーションによって実施したので，同雑音分散に対する bow-tie フィルタと管電流変調の影響とともに報告する．

*1 名古屋大学大学院医学系研究科
〔〒461-8673 名古屋市東区大幸南一丁目 1 番 20 号〕
e-mail: umeda.yuuji@e.mbox.nagoya-u.ac.jp

2. 方法

2.1. 仮想的な X 線 CT 撮影系

今回の検討では，投影はファンビーム方式であるものとし，各 X 線ビームにおける雑音に関する性状は同一，各 X 線ビームの雑音間には相

関がないものとした．また，直接的なフィルタ補正逆投影（filtered back projection: FBP）法によって画像再構成するものとした．撮影条件は，焦点検出器間距離を 60 cm とし，ファン角 26°，ノンヘリカルスキャン，再構成の画素数 512 × 512 pixels，検出器数 391 個，撮影野（field of View: FOV）を直径の 19.2 cm の円に相当するものとした．また，X 線の入射光子数については，bow-tie フィルタを設定した場合では 10^6 個を 0°～360°の間を 0.5°の間隔で照射するものとした．ここで，管電流変調を適応した場合については，同じ角度ごとに照射するものとしたが，これらの平均入射光子数が約 9.87×10^5 個となるように設定した．

2.2. 解析対象画像

今回，管電流変調を考慮した際に解析の対象とした画像は，水で満たされた長径が 16 cm,短径が 4 cm の楕円柱に相当する数値ファントムを被写体とし，上記の仮想的な X 線 CT 撮影装置で撮影した際の再構成画像を解析対象画像とした．一方，bow-tie フィルタを設定した際に解析の対象とした画像は，水で満たされた直径が 15.3 cm の円柱に相当する数値ファントムを被写体とし，上記の仮想的な X 線 CT 撮影装置で撮影した際の再構成画像を解析対象画像とした．

2.3.1. 管電流変調モデル

今回の検討では，管電流変調を使用しない時の入射光子数 N_i に対して，管電流変調を使用した時の入射光子数 N_i^{TCM} を以下のようにモデル化した[2].

$$N_i^{TCM} = N_i e^{(g(\lambda)-g(\lambda_0))} \tag{1}$$

ここで，$g(\lambda)$は角度λの X 線管からのファンビーム投影の中心の透過光子数$N_0(\lambda)$から$\ln\left[\frac{N_i}{N_0(\lambda)}\right]$によって得られる投影データであり，$g(\lambda_0)$は基準となる角度$\lambda_0$の X 線管からの同様な投影データを表現している．

2.3.2. bow-tie フィルタの形状に関する推定

bow-tie フィルタの形状は X 線 CT 撮影装置を提供している企業が公表していないため，素材や形状の詳細は知られていないことが多い．このような事情のため，シミュレーションを行う際により実測に近い状態を再現するために，bow-tie フィルタの形状を推定する方法がいくつか提案されている．今回の検討では，Boo 等の考案した方法[4, 5]を応用した方法によって推定した bow-tie フィルタの形状を用いて検討を実施した．

2.4. 関心領域の設定

今回の検討では，既述の各数値ファントム内に，下記のように設定した関心領域内の（「空間平均」の意味での）雑音分散の値について検討した．

1) 管電流変調を適応した場合について，再構成画像の中心から等距離の位置に 4 箇所，および，ファントム辺縁部の左側方部と右側方部の各 1 箇所の計 6 箇所に 11 × 11pixels の関心領域を設定した．
2) bow-tie フィルタを設定した場合について，再構成画像の中心を通る上下方向の直線状の 65 箇所に 5 × 5pixels の関心領域を設定した．

2.5. X 線 CT 画像における関心領域内の雑音分散の値の検討方法

X 線 CT 画像上の関心領域内の（「空間平均」の意味での）雑音分散（不偏分散に相当するものとする）の値の（「集団平均」の意味での）期待値は，関心領域内の確率変数としての「CT 値」の値を$X_i\ (i = 1, \cdots, N)$と表記した際に，以下のように与えられる．

$$\frac{1}{N}\sum_{i=1}^{N}\mathrm{Var}(X_i) - \frac{2}{(N-1)N}\sum_{i<j}^{N}\mathrm{Cov}(X_i, X_j) + \frac{1}{N}\sum_{i=1}^{N}\mathrm{E}^2(X_i) - \frac{2}{(N-1)N}\sum_{i<j}^{N}\mathrm{E}(X_i)\,\mathrm{E}(X_j) \tag{2}$$

ここで，$\mathrm{E}(X_i)$はX_iの期待値，$\mathrm{Var}(X_i)$はX_iの「集団平均」の意味での分散，$\mathrm{Cov}(X_i, X_j)$はX_iとX_jの「集団平均」の意味での共分散を表現するもの

とする．

雑音を量子雑音に限定した場合における関心領域における（「空間平均」の意味での）雑音分散の値について，既述の数値ファントムに対して同値の（「集団平均」の意味での）期待値を与える(2)式から文献[1, 2]と同様な方法を使用して計算するとともに，仮想的な X 線 CT 撮影系を使用して撮影した 300 個のシミュレーション画像から（bootstrap 標本数を 2000 とする）bootstrap 法による平均値と標準偏差を計算した．ここで，管電流変調を適応した場合については，仮想的な X 線 CT 撮影系で撮影した画像から得られる差分画像における値とした．この場合，解析的な計算では，(2)式中の各画素における CT 値の期待値の項を 0 として計算した．

3. 結果

3.1. 管電流変調を適応した場合

管電流変調を行った場合における，各関心領域の「空間領域」での雑音分散について，解析的に計算した（「集団平均」の意味での）期待値の値とシミュレーション画像から同期待値を推定した値を表 1 と表 2 に示す．ここで，上方部と下方部，左方部と右方部は，それぞれ，ほぼ同じ値であったため．例として上方部と左方部を示す．

表 1 管電流変調を考慮していない場合における各関心領域の雑音分散の期待値の計算結果

Positon of ROI	Analytical calculation	Simulation
Upper	14.05	14.02
Left (inside)	15.01	14.98
Left (outside)	11.42	11.12

表 2 管電流変調を考慮していない場合における各関心領域の雑音分散の期待値の計算結果

Positon of ROI	Analytical calculation	Simulation
Upper	11.88	12.04
Left (inside)	14.79	14.89
Left (outside)	12.39	11.93

3.2. bow-tie フィルタを設定した場合

bow-tie フィルタを設定した場合について，各関心領域の「空間領域」での雑音分散の（「集団平均」の意味での）期待値の計算結果を図 1 と図 2 に示す．解析的に計算した期待値とシミュレーション画像からの推定値との間のピアソンの積率相関係数は 0.99 と非常に高い値となった．また，bow-tie フィルタを設定することによって画像端からの距離に関わらず雑音分散の値が一定の値に近づく結果となった．

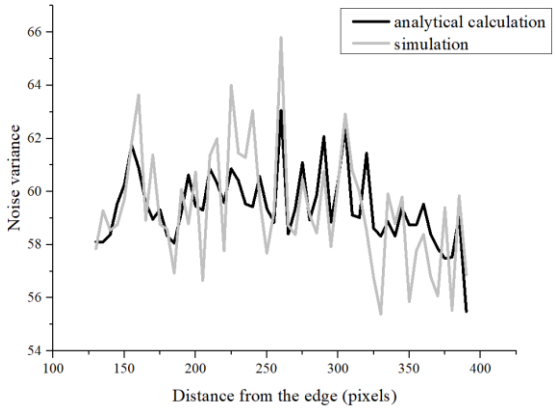

図 1 bow-tie フィルタを設定した場合における各関心領域内での雑音分散の期待値の計算結果

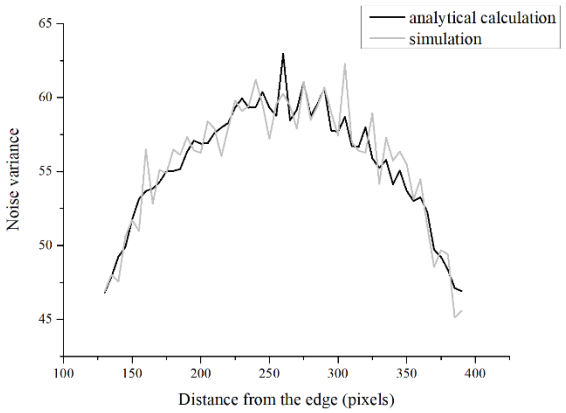

図 2 bow-tie フィルタがない場合における各関心領域内での雑音分散の期待値の計算結果

4. まとめ

今回，X 線 CT 画像の雑音を量子雑音に限定した場合において，bow-tie フィルタを設定した場合と管電流変調を適応した場合の関心領域内の（「空間平均」の意味での）雑音分散の（「集団平均」の意味での）期待値を解析的に計算する方法の精度について，シミュレーションによる検討を実施した．その結果，今回の検討の範囲内で，解析的な計算方法の精度は高いものと

言える結果となった．また，今回の検討結果から，bow-tie フィルタを設定した場合と管電流変調を適応した場合において，雑音分散値の変動が減少することを，解析的な計算によって予測できることも示された．

謝辞

本研究は，JSPS 科研費 18K07748［基盤研究(C)］の助成を受けたものです．

利益相反の有無

なし

文　献

［1］ Gore J C, Tofts P S: Statistical limitations in computed tomography. Phys Med Biol **23** (6): 1176-1182, 1978

［2］ Wunderlich A, Noo F: Image covariance and lesion detectability in direct fan-beam x-ray computed tomography. Phys Med Biol **53** (10): 2471-2493, 2008

［3］ 梅田祐司，池田充，西尾俊貴 他：X 線 CT 画像上の雑音分散に関する検討．平成 28 年度日本生体医工学会東海支部学術大会（予稿集）: A3-5,2016

［4］ John M. Boone: Method for evaluating bow tie filter angle-dependent attenuation in CT: Theory and simulation results. Med Phys **37** (1): 40-48, 2010

［5］ Adam C. Turner, Hyun J. Kim, John J. DeMarco et al: A method to generate equivalent energy spectra and filtration models based on measurement for multi detector CT Monte Carlo dosimetry simulations. Med Phys **36** (6): 2154-2164, 2009

Impact of tube-current-modulation and bow-tie filter on noise variance in X-ray computed tomography images

Yuuji Umeda[*1], Mitsuru Ikeda[*1], Kazuya Tanoue[*1]
Chiyo Yamauchi-Kawaura[*1], Keisuke Fujii[*1], Kuniharu Imai[*1]
*1 Department of Radiological and Medical Laboratory Sciences, Nagoya University Graduate School of Medicine

While we studied an analytical calculation method for the ensemble expectation of spatial noise variance in X-ray computed tomography (CT) images, under the assumption that noise was confined to the statistical fluctuations of X-ray photons, we did not treat the effects of X-ray tube current modulation (TCM) and bowtie filter upon this method. In this study, we have empirically investigated the impact of TCM and bowtie filter on the analytical calculation method for the ensemble expectation of spatial noise variance by the simulation studies of using a virtual X-ray CT system. The results of this study show that, when noise was confined to the X-ray photon fluctuations, the accuracy of the analytical calculation method for the ensemble expectation of spatial noise variance was also high for the case where each of TCM and bowtie filter was incorporated. Furthermore, the analytical calculation method was shown to predict how the fluctuation of spatial noise variances decreased when each of TCM and bowtie filter was implemented.

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

SDF 撮影法を用いた微小循環酸素飽和度推定の撮影深度補正

橋本　涼平[*1]　倉田　智宏[*2]　関根　雅[*3]　中野　和也[*3]

大西　峻[*3]　羽石　秀昭[*3]

要旨

毛細血管と細動脈および細静脈によって構成される微小循環領域での酸素状態の可視化は，疾患の状態の把握や機序の理解をする上で重要である．そこで，我々はこれまでに微小循環の観察と解析を目的に，Sidestream Dark-Field(SDF)カメラを試作し，さらに SDF 画像から酸素飽和度(SO_2)の推定を行う SDF オキシメトリを開発してきた．しかし，SDF オキシメトリの精度は組織表面から撮影対象までの深さ(撮影深度)に大きく依存している．本発表では光伝搬モンテカルロシミュレーションに基づく SDF オキシメトリの撮影深度補正手法を提案する．本手法では，血管部に対する光子の光路を 3 通りに分類した上で，血液の吸光特性に対する補正パラメータを撮影深度毎に求める．光学ファントム実験を実施し，取得した SDF 画像に対して提案手法を適用した結果，推定誤差が 25%から 3%に補正された．前述の実験から SDF オキシメトリに対する提案手法の有効性が示唆された．

キーワード：微小循環，酸素飽和度，モンテカルロシミュレーション

1. はじめに

毛細血管と細動脈および細静脈を総称して微小循環と呼ぶ．この領域は，生命維持において重要となる，血液中の赤血球の酸素を生体組織へ供給する役割を担う．そのため微小循環の酸素輸送機能を定量評価することは疾患の状態把握や機序の理解に有用である[1]．そこで，我々は生体組織表面の微小循環を非侵襲に観察可能な Sidestream Dark-Field (SDF)撮影法［2］を応用した酸素飽和度(Oxygen saturation, SO_2)推定法(SDF オキシメトリ)を開発してきた［3］．しかし，SDF オキシメトリは組織表面から撮影対象である血管までの深さ(撮影深度)に SO_2 の推定精度が大きく依存するという課題がある．そこで本発表では，SDF オキシメトリの撮影深度補正手法を提案する．

*1 千葉大学大学院融合理工学府
〔〒263-8522 千葉市稲毛区弥生町 1-33〕
e-mail: r_hashimoto@chiba-u.jp
*2 タカノ株式会社
*3 千葉大学フロンティア医工学センター

2. 手法

2. 1. SDF 撮影法

SDF 撮影法は，プローブ先端に同心円状に配置した照明から生体組織に光を入射させる．生体組織内部で繰り返し散乱・吸収されて，組織表面から出てきた拡散反射光をプローブ内部のカメラで撮像する技術である．ヘモグ

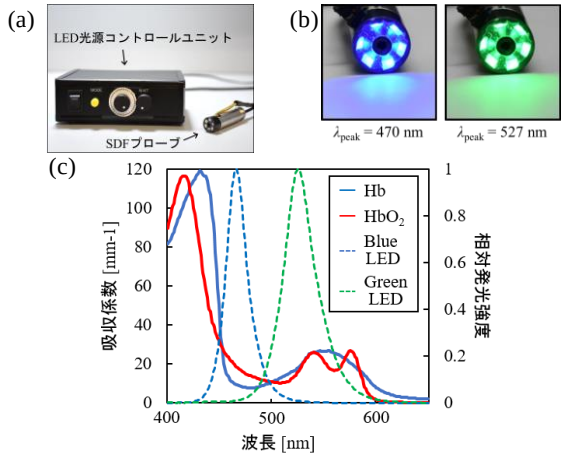

図 1 試作 SDF 撮影システム
(a) 装置の外観, (b) LED 照明(中心波長 λ_{peak} = 470 nm, 527 nm), (c) 使用 LED 照明の相対発光強度分布 a とヘモグロビンの吸収スペクトル

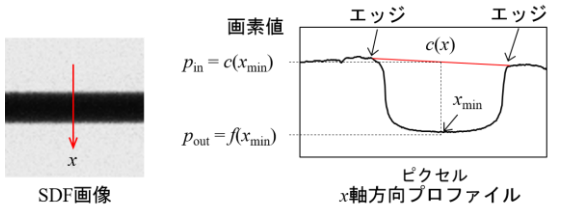

図 2 SDF 画像での透過光強度と入射光強度の定義

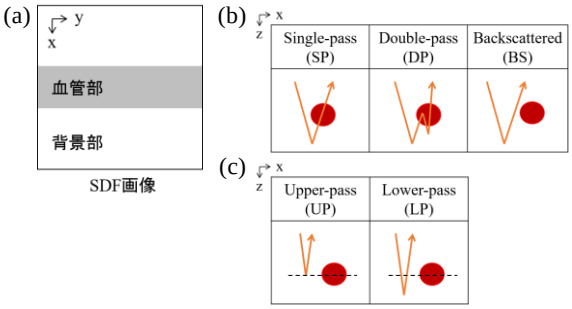

図 3 光子の光路の分類
(a) SDF 画像例, (b) 血管部画素値での分類, (c) 背景部画素値での分類

ロビンによく吸収される可視光の波長域を持つ照明を用いることにより，微小循環像を取得することができる．

我々が試作した SDF 撮影装置を図 1(a)に示す．図 1(b)に示すように，照明には LED チップ(SMLV56RGB1W, ROHM)を採用し，青色(中心波長 λ_{peak} = 470 nm)と緑色(λ_{peak} = 527 nm) の切り替えを可能にした．図 1(c)は各 LED 照明の相対発光強度分布とヘモグロビンの吸収スペクトル［4］である．イメージング用のカメラには CMOS モノクロカメラ(ID04MB-IP-U, iDule)を使用した．

2. 2. SDF オキシメトリ

SDF 画像から透過光強度 $I_{out}(\lambda)$と入射光強度 $I_{in}(\lambda)$が取得可能であると仮定すると，Lambert-Beer(LB)則に基づき次式が成立する．

$$I_{out}(\lambda_n) = I_{in}(\lambda_n)\cdot 10^{-\mu_a(\lambda_n)l}. \quad (1)$$

ここで，l は血管径，$\mu_a(\lambda_n)$は吸収係数:

$$\mu_a(\lambda_n) = \left[SO_2\cdot\varepsilon_{HbO2}(\lambda_n) + (1-SO_2)\cdot\varepsilon_{Hb}(\lambda_n)\right]\cdot c, \quad (2)$$

である．ε_{HbO2}，ε_{Hb} はそれぞれ酸素化ヘモグロビン，脱酸素化ヘモグロビンのモル吸収係数であり，c は総ヘモグロビン濃度である．2 波長 λ_1，λ_2 を用いることで SO_2 を求めることができる．

$$SO_2 = \frac{D(\lambda_2)\cdot\varepsilon_{Hb}(\lambda_1) - D(\lambda_1)\cdot\varepsilon_{Hb}(\lambda_2)}{D(\lambda_1)\cdot\Delta\lambda_2 - D(\lambda_2)\cdot\Delta\lambda_1}, \quad (3)$$

ただし，吸光度 $D(\lambda) = -\log[I_{out}(\lambda)/I_{in}(\lambda)]$，$\Delta\lambda_n = \varepsilon_{HbO2}(\lambda_n) - \varepsilon_{Hb}(\lambda_n)$である．

図 2 に SDF 画像と x 軸方向の強度プロファイル $f(x)$を示す．$c(x)$は血管部のエッジを結ぶ直線である．本研究ではここで求められる p_{out} と p_{in} をそれぞれ透過光強度と入射光強度と定義し，$D(\lambda)$の算出に用いる．

2. 3. 撮影深度補正手法

本手法では図 3 に示すように血液に対する光子の光路を分類［5］し SDF カメラの観測値をモデル化することで補正パラメータを求める．血管部画素値 I_{vessel} と背景部画素値 I_{back} を分類した光子の光路の強度値 I_{SP}，I_{DP}，I_{BS} および I_{UP}，I_{LP} を用いてそれぞれ次のように表す．

$$I_{vessel} = I_{SP} + I_{DP} + I_{BS}, \quad (4)$$

$$I_{back} = I_{UP} + I_{LP}, \quad (5)$$

ここで，I_{vessel} における I_{DP} と I_{BS}，I_{back} における I_{UP}はそれぞれ LB 則に基づく吸光度算出の誤差要因である．本手法では I_{vessel} を I_{SP} のみ，I_{back} を I_{LP} のみ考慮したものに補正する．補正

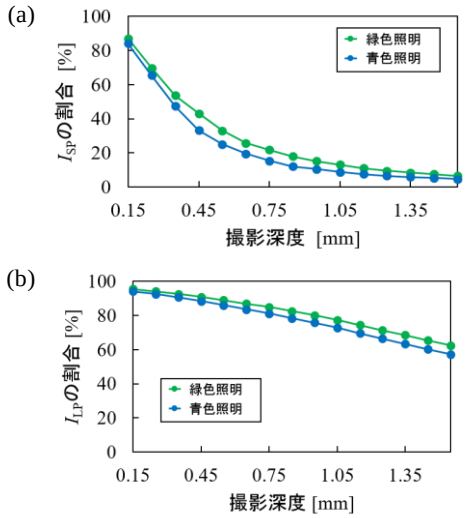

図 4 補正パラメータの推移
(a) I_{vessel} における I_{SP} の割合，(b) I_{back} における I_{LP} の割合

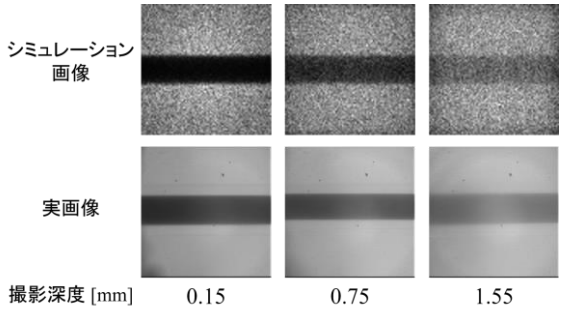

図 5 青色 LED 照明下での
生体模擬ファントムの SDF 画像

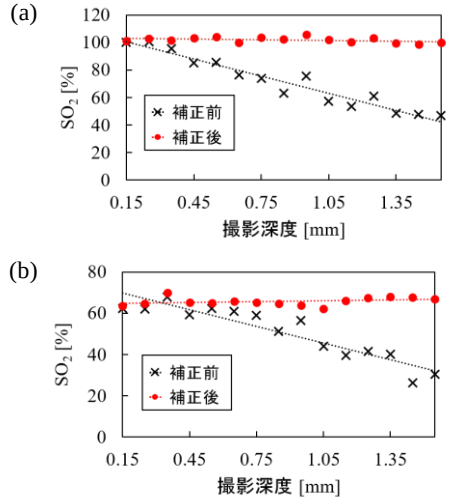

図 6 シミュレーション画像に対する SO_2推定結果
(a) 参照 SO_2値 100%，(b) 参照 SO_2値 60%

パラメータは光伝搬モンテカルロシミュレーション［6］により算出する．まず，シミュレーション上で，仮想イメージセンサで検出される光子の強度値 I_{SP}，I_{DP}，I_{BS}，I_{UP}，I_{LP} を予測する．そして，補正パラメータとなる I_{vessel} における $I_{SP}(\lambda)$の割合 r_{SP}，I_{back} における $I_{LP}(\lambda)$ の割合 r_{LP} をそれぞれ算出する．補正透過光強度 I_{out}，補正入射光強度 I_{in} はそれぞれ次のように表すことができる．

$$I_{out} = I_{vessel} \cdot r_{SP}(d), \tag{6}$$

$$I_{in} = I_{back} \cdot r_{LP}(d), \tag{7}$$

補正パラメータ r_{SP}，r_{LP} は撮影深度 d に合わせて適用する．

3. 実験と結果

脂肪乳剤を 0.1%混合した寒天にウシ血液を充填したガラス管を包埋させ，生体模擬ファントムを作製した．外径 0.30 mm, 内径 0.18 mm のガラス管を, 撮影深度 0.15 mm から 1.55 mm まで 0.1 mm 間隔で，計 15 本配置した．各ガラス管の SDF 画像を収集し，SO_2 推定を行った．充填した血液の SO_2 は血液ガス分析器(i-stat，扶桑薬品工業)を用いて計測した．

光伝搬モンテカルロシミュレーションにより補正パラメータ $r_{SP}(d)$と $r_{LP}(d)$を算出した．シミュレーションでは前述の生体模擬ファントムを再現したモデルを作成し，撮影深度毎に $r_{SP}(d)$と $r_{LP}(d)$を算出した．算出した結果を図 4 に示す．$r_{SP}(d)$と $r_{LP}(d)$のいずれも撮影深度方向に沿って減少することが確認できる．

図 5 はシミュレーションとファントム実験により取得した SDF 画像である．いずれも撮影深度に伴い，血管部画素値が大きくなり，画像コントラストの低下が確認できる．これは，強度の減衰が小さい Backscattered グループの光子の増加が影響していると考えられる．図 6 と表 1 にシミュレーション画像に対する SO_2 推定結果とその平均絶対誤差と最大絶対誤差を示す．補正前は撮影深度に伴い誤差が増大していたが，補正後は撮影深度依存が軽

表 1 シミュレーション画像に対する SO_2推定値の平均絶対誤差(Mean)と最大絶対誤差(Max)

参照値	100%		60%	
	Mean	Max	Mean	Max
補正前	29%	53%	11%	34%
補正後	2%	6%	6%	10%

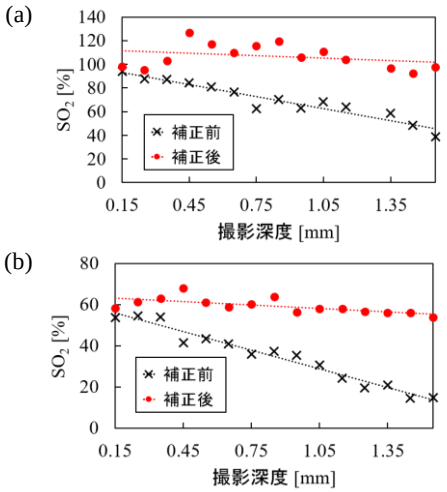

図 7 実画像に対する SO_2推定結果
(a) 参照 SO_2 値 100%，(b) 参照 SO_2 値 60%

表 2 実画像に対する SO_2推定値の平均絶対誤差(Mean)と最大絶対誤差(Max)

参照値	100%		60%	
	Mean	Max	Mean	Max
補正前	30%	61%	25%	46%
補正後	10%	27%	3%	8%

減された．実画像に対する SO_2 推定結果とその平均絶対誤差と最大絶対誤差を図 7 と表 2 に示す．シミュレーションと同様に概ね誤差が改善された．以上から光路の分類および補正パラメータの妥当性が示された．しかし，参照 SO_2 値 100%における実画像の推定結果では参照 SO_2 値 60%と比較して誤差が大きくなった．これは，作成した生体模擬ファントムに混合した脂肪乳剤の濃度や均一性とシミュレーションで設定した理想的な実験環境との間に差異が生じたことが要因であると考えられる．

4. まとめ

SDF オキシメトリの撮影深度による推定誤差補正手法を提案した．補正用パラメータは光伝搬モンテカルロシミュレーションにより算出した．補正手法をシミュレーション画像と実画像に対して適用した結果，SO_2 推定誤差が改善されることを確認した．今後は *in vivo* 実験を通して，生体への適用可能性を評価する．

謝辞

本研究の一部は文部科学省科学研究費補助金基盤研究(A) (課題番号：16H01855) により行われた．

利益相反の有無

なし

文　献

［1］ Lee J, Kozikowski R, Sorg B: In vivo microscopy of microvessel oxygenation and network connections. Microvascular research **98**: 29–39, 2015

［2］ Ince C: Sidestream dark field imaging: an improved technique to observe sublingual microcirculation. Critical care **9(1)**: P72, 2005

［3］ Kurata T, Li Z, Oda S et al: Impact of vessel diameter and bandwidth of illumination in sidestream dark-field oximetry. Biomedical optics express **6(5)**: 1616–1631, 2015

［4］ Faber D, Aalders M, Mik E et al: Oxygen saturation-dependent absorption and scattering of blood. Physical review letters **93(2)**: 028102, 2004

［5］ Smith H, Denninghoff R, Lompado A et al: Effect of multiple light paths on retinal vessel oximetry. Applied optics 39**(7)**: 1183–1193, 2000

［6］ Fang Q: Mesh-based Monte Carlo method using fast ray-tracing in Plucker coordinates. Biomedical optics express **1(1)**: 165–175, 2010

Depth-Oriented Error Correction in Oxygen Saturation Estimation of Microcirculation Using SDF Imaging

Ryohei HASHIMOTO[*1], Tomohiro KURATA[*2], Masashi SEKINE[*3], Kazuya NAKANO[*3], Takashi OHNISHI[*3], Hideaki HANEISHI[*3]

*1 Graduate School of Science and Engineering, Chiba University
*2 Takano Company Limited
*3 Center for Frontier Medical Engineering, Chiba University

Measuring microvascular oxygen saturation (SO_2) is effective for monitoring disease dynamics. We have proposed an SO_2 estimation method using sidestream dark-field (SDF) imaging (SDF oximetry). However, the accuracy of SDF oximetry largely depends on the depth of vessels. In this study, we proposed a depth correction method for SDF oximetry. We performed Monte Carlo photon propagation simulation to analyze the behavior of photons and obtained depth correction coefficients. A tissue-like turbid phantom was generated and the computer simulation corresponding to the phantom and the real SDF oximetry with a practical camera were performed in order to evaluate the effect of the depth correction method. The results showed that the mean absolute errors of SO_2 estimation decreased from 25% to 3%. In conclusion, we confirmed the effectiveness of the proposed depth correction method for SDF oximetry.

Key words: Microcirculation, Oxygen saturation, Monte Carlo simulation

非剛体変換を用いた低線量四次元 CT 画像からの肝腫瘍領域の描出精度

鈴木　健太郎[*1,2]　臼井　桂介[*3]　笹井　啓資[*3]

要旨

肝腫瘍に対する体幹部定位放射線治療法では，呼吸運動を反映した四次元(4D)CT 画像を撮影する必要がある． 320 列 CT 装置を用いて造影することにより，腫瘍領域の血流変化を反映した 4DCT 画像を撮影可能である．正確に肝腫瘍を描出するためには，腫瘍と正常組織間に高いコントラストが要求されるが，信号雑音比の向上には被ばく線量の増加が伴う．そこで 4DCT 画像に対して非剛体変換法を利用し各時相画像を加算平均することで，肝腫瘍領域のコントラスト向上と描出精度の改善を目指す．造影後の肝 4DCT 画像に対して雑音を付与し低線量で撮影した CT 画像を推定した後，これを用いて非剛体変換と加算平均を各時相画像に対して実施した．閾値処理にて肝腫瘍領域を描出し，原画像から描出される腫瘍領域との類似度をダイス係数と平均表面距離により評価した． 10%の照射線量を仮想した腫瘍領域のダイス係数は 0.82，平均表面距離は 1.7 mm であり，低線量画像に対する腫瘍輪郭の描出精度が向上した．

キーワード：非剛体変換，四次元 CT 画像，放射線治療，肝腫瘍，画質改善

1. はじめに

体幹部定位放射線治療法(Stereotactic body radiosurgery: SBRT)の治療計画では，呼吸に伴う腫瘍の移動量を治療計画に反映する必要があるため，一般に四次元CT(Four dimension computed tomography: 4DCT)を撮影する．従来，4DCTは呼吸波形を習得しながらヘリカルスキャンCTを撮影し，同一の寝台位置で収集した異なる呼吸位相の投影データを再構成することで四次元画像を取得する方法が用いられてきた．この方法は一般的なCT撮影法と比較して撮影時間が長く，同一の呼吸位相であっても異なるタイミングで撮影するため，ヨード造影剤を使用した血流の経時的変化を四次元画像に反映することが困難であった．一方，320列面検出器を有するCT装置は，寝台移動することなく連続的に投影データを取得することで，体軸方向に最大16 cmの4DCT画像を短時間で取得できるため，肝腫瘍に対するSBRTの治療計画では，ヨード造影剤を使用した血流の経時的変化を反映した4DCT画像を取得することができる．この際，肝腫瘍の輪郭を正確に描出するためには，腫瘍と正常組織との間に高いコントラストが求められる．そのため信号雑音比の向上が不可欠であるが，それには被ばく線量の増加が伴う．

*1 順天堂大学大学院 医学研究科
〔〒113-0033 東京都文京区本郷 2-1-1〕
e-mail: suzuki-k@juntendo.ac.jp
*2 済生会横浜市東部病院 放射線部
*3 順天堂大学医学部 放射線治療学講座

また，モーションアーチファクトの少ない4DCT画像の取得にはX線管球の回転速度をあげる必要があるため，X線量を十分に確保することができずCT画像の信号雑音比が低下する課題がある．ここで近年，放射線治療分野で使用される非剛体変換(Deformable image registration: DIR)手法を利用した信号雑音比改善処理を提案する．この手法は4DCTのある時相画像に対し，他の時相画像を非剛体変換することで位置のずれを補正し，さらに画像を加算平均することで，信号雑音比の向上，および従来法よりも低線量であっても肝腫瘍の輪郭描出の精度を改善できることが期待される．そのため本検討は，4DCTのDIRを利用した加算平均(DIR-M)処理の信号雑雑音比改善効果と腫瘍輪郭精度を定量することで有効性を明らかにした．

2. 方法

1) 非剛体変換のアルゴリズム

本検討では同一モダリティ間の画像の位置照合に広く使用されている demons 法を用いた[1,2]． demons 法では 2 画像間の各点の同じボクセル値から， 変位ベクトルを推定する． 移動物体の三次元的な運動を認識し，求められたベクトル場を用いて基準画像の輪郭を他方の画像の輪郭に伝播してマッチングするように反復処理により変形させる．この際，リサンプリングにより 3 段階の低解像度化をはかり，低解像度側より段階的に 100，50，25，10 回のマッチング処理をした．この際，変形ベクトルにガウスフィルタにより平滑化処理することで正則化を図った．

2）肝画像データ

原発性肝細胞癌に対する SBRT の治療計画に，320 列面検出器を有する CT 装置により造影 4DCT を撮影した症例のうち，腫瘍輪郭が明瞭に観察できた 5 名の患者データを用いた．いずれも造影 4DCT は，ボーラストラッキング法による動脈優位相の自然呼吸下で 10 秒間撮影した．また撮影条件は管電圧 120kV，管電流 450 mA，回転速度 0.275 秒/回転，再構成スライス厚 1.0 mm，再構成間隔 0.25 秒とし，40 時相の 4DCT 画像を取得した．この 4DCT 画像のうち，上下方向の振幅の中間となる画像に対し，他画像を非剛体変換処理することで位置のずれを補正し，これらの画像を加算平均することで信号雑音比を改善した．

3) 低線量画像のシミュレーション

X 線 CT 画像の信号雑音比低下の主な要因は，X 線量子モトルである．X 線量子モトルの統計的変動は X 線量の平方根で表され，X 線量が低下すると画像における変動成分の占める割合が増大する[3]．ここで X 線量子モトルに依存する雑音は，空間周波数における特性が白色雑音と異なることが知られており，これまで X 線量子モトルに依存する雑音を再現するため，様々な取り組みがなされてきた．本検討では，図 1 で示すように，白色雑音画像を二次元高速フーリエ変換し，空間周波数上で Modulation transfer function (MTF)画像と乗算した上で，逆二次元高速フーリエ変換した．これにより，X 線量子モトルに類似した雑音画像を作成した[4]．この雑音画像を造影 4DCT 画像に加算することで，撮影線量を 50%，および 10%に減少した低線量画像(D50%, D10%)を模擬した．

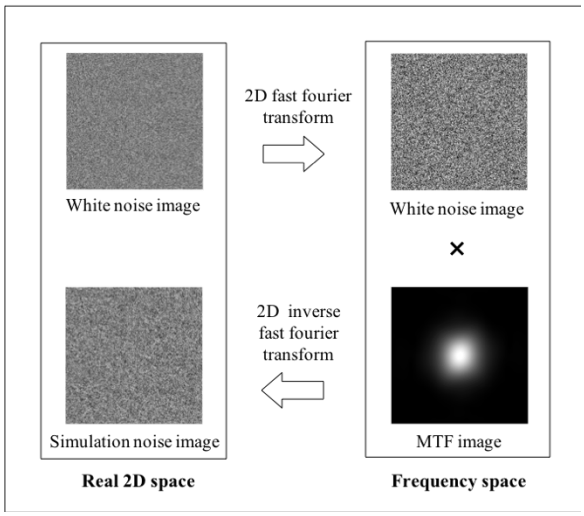

図 1　低線量雑音推定画像の作成方法

4) 信号雑音比改善効果の評価

DIR-M 処理の信号雑音比改善を評価するため，正常肝組織の標準偏差および次式で示す肝腫瘍-正常肝組織間の contrast noise ratio (CNR)を算出した[5].

$$CNR = \frac{ROI_T - ROI_L}{SD_L} \quad (2)$$

ここで ROI_T と ROI_L は肝腫瘍と正常肝組織の CT 値，SD_L は正常肝組織の CT 値の標準偏差である.

5) 腫瘍輪郭精度の評価

DIR-M 処理により描出した肝腫瘍輪郭の精度を評価するため，放射線治療計画装置(Pinnacle[3])を用いた自動閾値処理により，腫瘍輪郭を描出した．原画像から描出した腫瘍輪郭を基準とし，D50%，D10%，D50%の DIR-M 処理画像(D50%DIR)，D10%の DIR-M 処理画像(D10%DIR)から描出した腫瘍輪郭の一致度を定量的に解析するため，ダイス類似係数(Dice similarity coefficient: DSC)と平均表面距離(Mean distance of agreement: MDA)を算出した．DSC は 2 つの輪郭の合計体積に対する両者の重複する体積を 2 倍したものとして，式(3)で定義される[6].

$$DSC = \frac{2(V_{all} \sqcap V_{sel})}{|V_{all}| + |V_{sel}|} \quad (3)$$

ここで，V_{ori} は原画像から描かれた腫瘍輪郭の体積であり，V_{target} は D50%, D10%, D50%DIR, D10%DIR 画像か r 描かれた腫瘍輪郭の体積である．DSC は 1 に近いほど 2 つの輪郭が一致していることを表している.

また, MDA を算出するために, 一方の DICOM structure-set の点座標群から，もう一方の DICOM structure-set の点座標群までの最小距離を求め，すべての点座標の最小値の平均値を計算して，式(4)により定義した[6].

$$MDA = \frac{1}{2}\left[\bar{d}(S_{ori}, S_{target}) + \bar{d}(S_{targetl}, S_{ori})\right] \quad (4)$$

ここで，$(S_{ori} . S_{target})$は原画像により描かれた腫瘍輪郭から, D50%, D10%, D50%DIR, D10%DIR 画像により描かれた腫瘍輪郭までの最小距離の平均値であり，$(S_{target} . S_{ori})$は D50%, D10%, D50%DIR, D10%DIR 画像により描かれた腫瘍輪郭から，原画像により描出された腫瘍輪郭までの最小距離の平均値である．MDA では 0 に近いほど，2 つの輪郭が一致していることを示している.

3. 結果

1) 信号雑音比改善効果の結果

原画像と低線量模擬 CT 画像(D50%, D10%), および DIR-M 処理画像(D50%DIR, D10%DIR)の標準偏差，CNR を表 1, 表 2 に示す．D50%DIR および D10%DIR は共に標準偏差，CNR が著しく改善し，原画像より優れる結果となった.図 2 に患者番号 4 の原画像，D10%, D10%DIR を示す．腫瘍領域（矢印）と正常肝組織の境界は D10%では不明瞭であるのに対し，D10%DIR では明瞭に観察できる.

表 1 画像毎の標準偏差

Pt	Standard deviation (HU)				
	Original image	D50%	D10%	D50% DIR	D10% DIR
1	23.1	38.2	74.2	6.7	8.8
2	25.1	37.2	63.1	6.3	8.0
3	21.5	33.9	72.0	5.5	8.6
4	20.8	36.6	71.4	5.7	7.9
5	21.4	35.4	69.5	6.9	8.8

表 2　画像毎の CNR

Pt	Contrast noise ratio				
	Original image	D50%	D10%	D50% DIR	D10% DIR
1	1.8	1.1	0.6	5.3	4.1
2	1.7	1.2	0.8	7.8	6.3
3	3.0	2.0	0.9	11.8	7.5
4	2.9	1.8	0.9	10.7	7.6
5	0.9	0.6	0.3	3.6	2.8

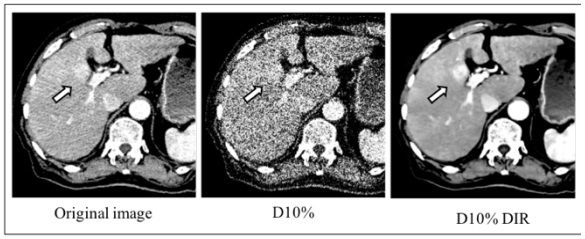

図 2 肝腫瘍領域の信号雑音比改善効果

2) 腫瘍輪郭精度の評価

DSC と MDA の結果を図 3 と図 4 に示す．平均 DSC は D50%で 0.78, D10%で 0.74, D50%DIR で 0.83, D10%DIR で 0.82 であった．次に平均 MDA は D50%で 2.1 mm，D10%で 2.6 mm, D50%DIR で 1.5 mm, D10%DIR で 1.7 mm であった．このように基準画像で作成した腫瘍輪郭との一致率は DIR-M 処理により向上した．

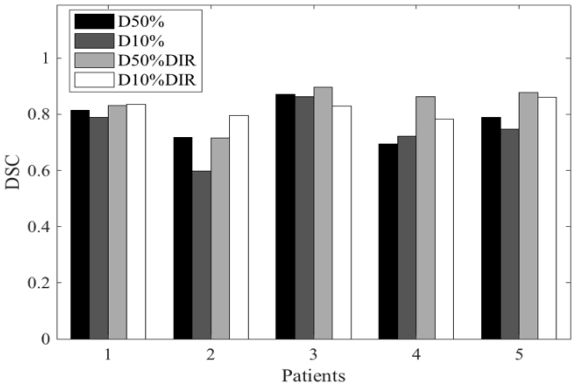

図 3 低線量 CT 画像と DIR-M 画像の DSC

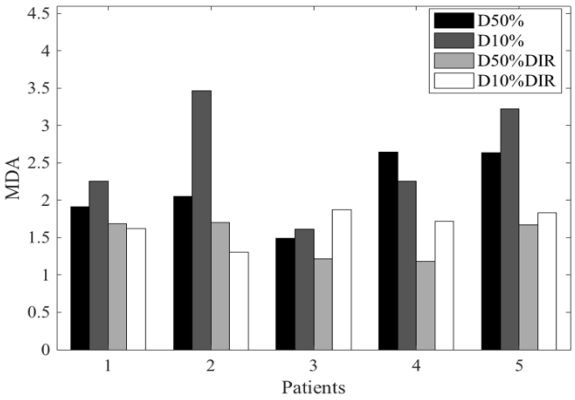

図 4 低線量 CT 画像と DIR-M 画像の MDA

4. 考察

本検討は造影 4DCT 画像の信号雑音比改善のために提案した DIR-M 処理の有効性を明らかにするため, 信号雑音比改善効果と腫瘍輪郭精度を評価した.

X 線 CT 画像の信号雑音比低下の主な要因は, X 線量子モトルである．X 線量子モトルに依存する雑音は 40 時相の画像データが加算されると，$1/\sqrt{40}$ 低減する. DIR-M 処理による正常肝組織の CT 値の標準偏差の低減は平均 $1/7.1$ であり, 両者は概ね一致したため, 信号雑音比の改善は量子モトルに依存する雑音が低減されたと考えられる.

また正常肝組織の CT 値の標準偏差の低下により, CNR が著しく向上した. その結果, 図 2 で示す患者番号 5 のように, 腫瘍輪郭が明瞭になるだけなく, 原画像では観察困難である微細な血管構造も D10%DIR では観察可能となった. このように DIR-M 処理により, 信号雑音比は著しく改善効果した. さらに少ない X 線量の撮影条件や, 肝腫瘍と正常肝組織間の CT 値差が小さく腫瘍輪郭が不明瞭な症例でも, DIR-M 処理により改善が考えられる.

DIR-M 処理は画像データを変形し, 加算平均するため， 処理画像によって描出された腫瘍領域が変形し異なる形状に見誤る可能性がある． そのため， DIR-M 処理前後で， 腫瘍輪郭の一致率を評価した． 本検討は同一症例で複数回にわたり腫瘍輪郭を作成する必要があり, 通常， 医師により手動で描出される腫瘍輪郭を， 繰り返しによるバイアスを低減するため放射線治療計画装置の自動閾値処理により描出した． DSC, MDA 共に DIR-M 処理により改善した. DSC では患者番号 3 では D10%DIR で DIR-M 処理により基準画像との一致率が低下したが， この症例では肝腫瘍内の CT 値が均一でなく， 中心部に CT 値の上昇が見られた. 肉眼的には明瞭に観察できた腫瘍辺縁であるが, 自動閾値処理による肝腫瘍輪郭作成の際， 基準画像より中心部を境界と認識したため類似度が低下したと考えられる． 患者番号 2 の D10%, 患者番号 4, 5 の D50%, D10%では原画

像で示された腫瘍輪郭より外側を輪郭として捉えたため DSC, MDA の一致度が低下した. D50%DIR と D10%DIR 間の腫瘍輪郭に大きな差はなかった. 本検討では低線量撮影を想定し, 推定した雑音を 4DCT 画像に付加したが, これは実際に低線量撮影した画像ではない. そのため実際の画像では結果が異なる可能性はあるが, DIR の精度に画像の雑音は影響が少ないとされる[7, 8]. そのため実際の低線量撮影画像でも良好な結果となると考えられる.

本検討の課題として, 腫瘍輪郭精度の評価をする際, 基準となる原画像の腫瘍輪郭の真値が不明なことである. 原画像における正常肝組織の CT 値の標準偏差は 22 HU 程度であり, 細かな腫瘍領域の描写には不十分であった. また DIR-M 処理は非剛体変換アルゴリズムの精度に依存する. 本検討では撮像時相が最大で 9.75 秒差が生じた. 非造影と造影間の DIR 処理は非造影間の DIR よりと比較して類似度の低下することが知られている[9]. そのため 4DCT の撮影タイミングによっては DIR 処理の精度が低下することが考えられる.

5. 結論

造影 4DCT の非剛体変換を利用した信号雑音比改善処理により, 信号雑雑音比は改善効果と腫瘍輪郭精度も向上した. することで有効性を明らかとなった.

利益相反の有無

なし

文 献

[1] J.-P. Thirion: Image matching as a diffusion process: an analogy with Maxwell's demons. Medical image analysis, 1998, pp 243–260

[2] T. Vercauteren, X. Pennec,A. Perchant et al; Diffeomorphic demons: efficient non-parametric image registration. NeuroImage, 2009,S61-S72

[3] 國友博史:放射線領域の画像ノイズの基礎, 画像通信, 35(1): 24-29, 2012

[4] 國友博史, 市川勝弘, 東出了 他：ディジタルノイズパワースペクトルの解析時の誤差要因の検討, 日本放射線技術学会雑誌, 66(7): 734-742, 2010

[5] 市川勝弘, 村松禎久: 標準 X 線 CT 画像計測, オーム社, 東京, 2009,pp119-120

[6] K. Brock, S. Mutic, Todd R. McNutt et al: Use of image registration and fusion algorithms and techniques in radiotherapy: Report of the AAPM Radiation Therapy Committee Task Group No. 132: Med. Phys, 44 (2017)

[7] X. Li, Y.Y. Zhang, Y.H. Shi, et al., Evaluation of deformable image registration for contour propagation between CT and cone-beam CT images in adaptive head and neck radiotherapy, Technol. Health Care, 24 Suppl 2 (2016) S747-755.

[8] M.J. Murphy, Z. Wei, M. Fatyga, et al., How does CT image noise affect 3D deformable image registration for image-guided radiotherapy planning?, Med. Phys., 35 (2008) 1145-1153.

[9] C. Hoffmann, S. Krause, E.M. Stoiber, et al., Accuracy quantification of a deformable image registration tool applied in a clinical setting, J. Appl. Clin. Med. Phys., 15 (2014) 4564.

Faster R-CNN を用いた子宮頸部細胞診における悪性細胞の検出

津森　太亮[*1]　木戸　尚治[*1]　平野　靖[*1]

森　正樹[*2]　稲井　邦博[*2]　今村　好章[*2]

要旨

子宮頸癌検診には細胞診が用いられるが，多数の正常細胞から有所見細胞を探しその中の悪性細胞を検出するため，煩雑で時間を要する．そのため Deep Learning による検査士の負担軽減と検査時間短縮を最終目的とし，有所見細胞の自動検出と判別が可能か検討した．

具体的には物体検出に使われる Faster R-CNN を用いて有所見細胞を検出し，次に子宮頸部細胞診で良悪性を分類するためのベセスダ分類に基づく有所見細胞を，臨床的観点から「正常群」，「内科的経過観察群」，「要外科的処置群」の 3 群に大別した．

5 分割交差検証を行い各クラスの Faster R-CNN の結果と検査士による診断結果を，F 値を用いて比較すると「正常群」は 47.9±9.0%に留まったが，「内科的経過観察群」，「要外科的処置群」はそれぞれ 75.0±8.6%, 82.3±2.9%に達した。「正常群」の低値は有所見細胞の全てに正答を付けることが困難なことに起因すると推察されたものの，高悪性度細胞の検出においては提案手法の有効性が示唆された．

キーワード：コンピュータ支援診断，深層学習，Faster R-CNN，細胞診

1. はじめに

子宮頸癌は子宮の入り口である子宮頸部に発生する上皮性の悪性腫瘍で，高度の腫瘍原性を有するヒトパピローマウィルス(Human papillomavirus ： HPV)の持続感染を背景に発症する.挙児希望が多い若年発症が稀でなく，また軽度であっても間質浸潤が認められる場合は子宮全摘となるため，検診で早期発見することが求められる．子宮頸癌検診は通常擦過細胞診という検査方法が用いられる[1]．まず子宮頸部を擦過して集められた細胞を，細胞検査士が顕微鏡で観察して有所見細胞を抽出後に，子宮頸部細胞の良悪性度の標準的分類法であるベセスダ分類[2]に従って分類し，細胞診専門医が最終的に診断を確定する[3]．細胞診の利点として，患者への負担が少なく何度も繰り返し検査を行えることが挙げられる．その一方で，細胞診は子宮頸がんの早期発見を目的としていることから多くの正常細胞の中から有所見細胞を抽出して，さらにその中の悪性細胞を探し出さなければならない．そのため診断には一定の時間が必要で，検体提出から結果報告までに要する時間は，各診療機関に所属する細胞検査士数に依存してお

*1 山口大学
〔〒755-8611 宇部市常盤台 2-16-1〕
e-mail: i053vg@yamaguchi-u.ac.jp
*2 福井大学
投稿受付：2018 年 5 月 15 日

り，細胞検査士の負担軽減は喫緊の課題である．そこで，本研究では多くの検体から細胞を探し出す手間を軽減することを目標に据え，Deep Learning を用いて医師が診断する有所見細胞を検出して，その悪性度を分類することが可能か否かを検討した．

具体的に，本研究では物体検出を行う手法として Faster R-CNN(Faster Region-based Convolutional Neural Network)[4]を用いた．Faster R-CNN 以前の R-CNN というアルゴリズムでは，物体候補領域を Deep Learning を用いずに既存手法で取り出した後，その領域の特徴から CNN(Convolutional Neural Network)と呼ばれるネットワークを用いて物体が何であるかを判別していた．しかし，R-CNN には，クラスの分類や物体を囲む矩形の回帰など複数の項目を独立して学習させなければならず，検出速度も遅いという問題があったため，R-CNN を改良した Faster R-CNN が開発された．Faster R-CNN では，物体候補の取り出しにも Deep Learning を用いているため，物体の検出とクラス分類の学習を一度で行えるようになり，R-CNN よりも高速に物体検出を行えるようになった[4].

2. 提案手法

本研究では，細胞の画像と，細胞検査士によりアノテーションされたラベルを基にデータセットを作成した後，Faster R-CNN の学習を行った．その後，各悪性度のクラスごとに AFROC 解析を用いて，学習したモデルを適用して得られた予測を採用するための閾値を決定した．

図 1 に提案手法のフローチャートを示し，手法の詳細を述べる．

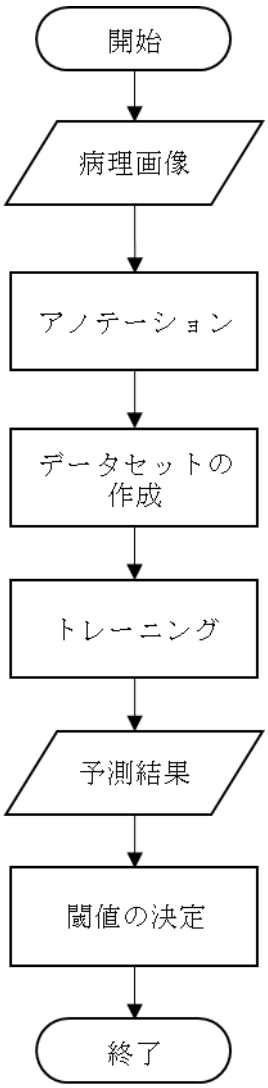

図 1 提案手法のフローチャート

1） アノテーション

細胞のアノテーションは，細胞検査士が MATLAB®を用いて，細胞の領域とベセスダ分類に基づく悪性度を入力した後で，領域の座標値と悪性度をテキストファイルに保存した．

図 2 にアノテーションされた画像の例を示す．

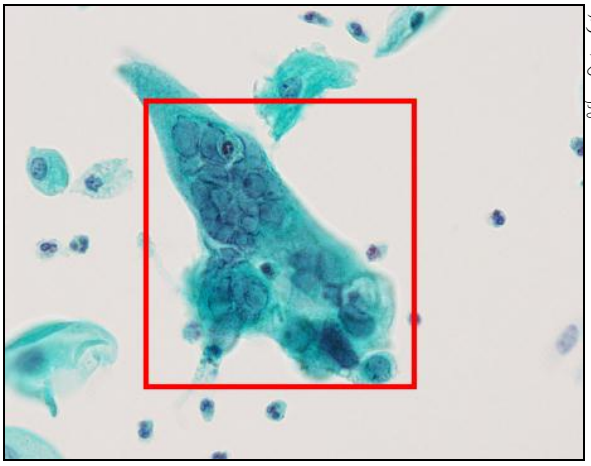

図 2 アノテーションされた画像の例

2） データセットの作成と分類方法

データセットは，子宮頸部の細胞の画像と細胞検査士によってアノテーションされた細胞の領域及びその細胞の悪性度から成る．その後，データセットを 5 分割し，4 つを訓練データとして，残りの 1 つをテストデータとして用いた．

今回の検討ではベセスダ分類を基に，病変の進行度とその治療方針から，HPV 感染以外の有所見細胞を「正常群」，一過性の HPV 感染が多く直ちに観血的処置を必要としない「内科的経過観察群」，及び高度の腫瘍原性を有する HPV の持続感染により，通常外科的処置が講じられる「要外科的処置群」に 3 分類した．

3） トレーニング

ディープラーニング用のフレームワークである Chainer と Chainer 向けに作られた画像認識用のライブラリである ChainerCV[5]を用いて，Faster R-CNN を実装し，トレーニングを行った．

Faster R-CNN のトレーニングには，物体候補を取り出すためのネットワークである RPN(Region Proposal Network)と RPN で取り出された候補領域を元に物体検出を行うネットワークのトレーニングがそれぞれ必要である．本研究では RPN の誤差と物体検出ネットワークの誤差を足して全体の誤差を求めた後、誤差逆伝播を行ってパラメータを更新した．これらの計算をすべての訓練データに行うことを 1 エポックとし，40 エポックに到達するまで続けた．

図 3 に本研究のトレーニングの流れを示す．

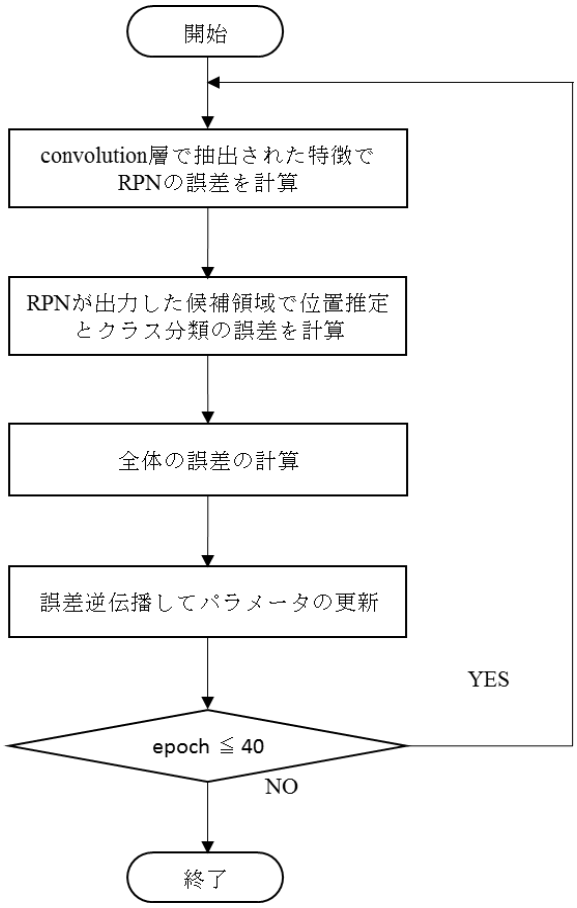

図 3 本研究のトレーニングの流れ

4） 閾値の決定

Faster R-CNN では，クラス分類を行う際に 0 から 1 までの予測確率が出力されるため，信頼度が低いラベルを取り除くために予測に最低限必要な確率を表す閾値を決定することが必要である．その一方で，閾値を高くし過ぎると本来検出できていた細胞を見逃すことにつながる．

本研究では，閾値を決定するために悪性度のクラスごとに AFROC 曲線[6]を用いた．AFROC 曲線は，複数の病変が存在する可能性がある検査の有効性を検討するために用いられる曲線であり，閾値を動かしながら縦軸

に TPR(True Positive Rate)，横軸に P(FPI)をプロットすることで描かれる．ここで，TPR は陽性を正しく陽性と診断した確率，P(FPI)は画像 1 枚あたりに陰性を陽性と誤って診断した数を表す FPI(False Positive per Image)をポアソン分布と仮定したときの 1 枚の画像に FP(False Positive)が生じる確率である．FP は，陰性を誤って陽性と診断した数を表す．

P(FPI)の算出方法を式(1)に示す．

$$P(FPI) = 1 - e^{-FPI} \tag{1}$$

AFROC 曲線を用いて閾値を決定するためには，左上隅の点からのユークリッド距離が最小の点を閾値とする方法などが用いられる．左上隅の点からのユークリッド距離が最小の点を閾値として用いるのは，左上隅の点が TPR = 1， P(FPI) = 0 となり，陽性のものをすべて診断し，陰性のものを誤って陽性とみなすこともないという理想的な診断を表しているためである．

図 4 に AFROC 曲線と閾値決定の例を示す．左上隅の点からのユークリッド距離を示した点 P が AFROC 曲線により決定した閾値を表す点である．

AFROC 曲線は，予測を尤度が高いものから順番に並べ，閾値を 1.0 から 0.1 ずつ下げながら TPR と P(FPI)を求めてプロットした．更に，各点の左上隅からのユークリッド距離も求めた．その結果，図 4 では P(FPI) = 0.090，TPR = 0.82 となる点 P が左上隅からのユークリッド距離が最小となる点となる．その場合の確率である 0.63 が閾値となっている．

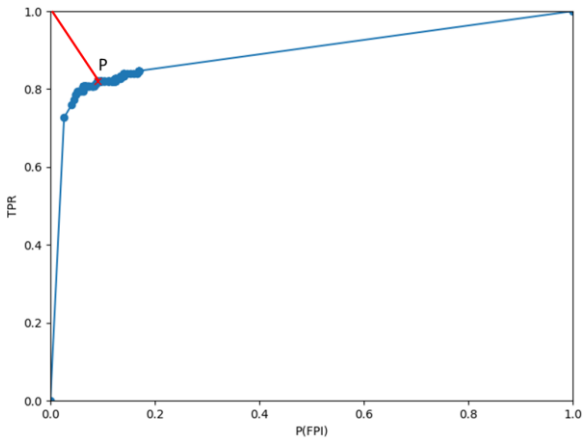

図 4 AFROC 曲線と閾値決定の例

3. 実験

1）対象データ

実験に用いたデータは，福井大学医学部附属病院で撮影された 264 枚の子宮頸部細胞の病理画像である．各画像には細胞検査士による診断を表すラベルが付けられている．対象データの詳細を以下に示す．

- 画像数:264 枚
- ラベルの個数
  - 要外科的処置群:150 個
  - 内科的経過観察群:76 個
  - 正常群:234 個

2）評価方法

細胞検査士による診断を表す正解ラベルとトレーニングの結果を適用して得られたラベルを比較して，精度を評価した．予測されたラベルが正解かどうか判断するために，2 つの領域の重なり度合いを表す IoU(Intersection over Union)を用いた．IoU の計算方法を式(2)に示す．

$$IoU = \frac{\text{重なっている領域}}{\text{2つの領域の合計}} \tag{2}$$

本研究においては，正解ラベルと予測されたラベルの間で IoU が 0.5 以上で悪性度のクラスが一致し，かつそのクラスである確率が AFROC 曲線で決定した閾値以上であるものを正しい予測とみなした。

予測の精度を評価するために各クラスの適合率，再現率及び F 値を求めた．適合率は予

測したラベルの正解率，再現率は正解ラベルを正しく予測できた割合，F 値は適合率と再現率の調和平均を表す．適合率，再現率，F 値の計算方法を式(3)から式(5)に示す．

$$適合率 = \frac{正しい予測の数}{予測したラベルの数} \tag{3}$$

$$再現率 = \frac{正しい予測の数}{正解ラベルの数} \tag{4}$$

$$F値 = \frac{2 \times 適合率 \times 再現率}{適合率 + 再現率} \tag{5}$$

また，検診で用いることを念頭に置いて，全画像に占める最も悪性度の高いクラスを 1 つでも正確に予測できており，より高いクラスの誤検出もない画像を診断に成功したとみなし，テストに用いた画像のうち診断に成功した画像の割合を診断成功率とした．診断成功率の計算方法を式(6)に示す．

$$診断成功率 = \frac{診断に成功した画像数}{テストに用いた画像数} \tag{6}$$

4. 結果

本実験の結果，AFROC 曲線で決定された閾値を表 1 に示す．

表 1 AFROC 曲線で決定された閾値

悪性度	閾値
要外科的処置群	0.63
内科的経過観察群	0.25
正常群	0.25

また，5 分割交差検証を行い，AFROC 曲線で決定した閾値を適用した結果得られた各クラスとすべてのクラスの平均の適合率，再現率及び F 値を求めた結果を表 2 に示す．

表 2 適合率，再現率，F 値を求めた結果

悪性度	適合率 [%]	再現率 [%]	F 値 [%]
要外科的処置群	83.3±4.9	81.6±4.2	82.3±2.9
内科的経過観察群	68.3±8.2	83.4±9.7	75.0±8.6
正常群	52.6±9.1	44.3±9.4	47.9±9.0
平均	66.1±3.1	62.8±6.3	64.3±4.6

(mean±SD)

更に，各クラスの診断成功率を求めた結果を表 3 に示す．

表 3 診断成功率を求めた結果

悪性度	診断成功率[%]
要外科的処置群	88.5±4.3
内科的経過観察群	71.5±7.6
正常群	49.7±16.6
平均	75.1±3.5

(mean±SD)

図 5 から図 8 に正解ラベルと得られた予測を比較した例を示す．ここで，赤い矩形で囲まれた領域は細胞検査士によりアノテーションされた領域，青い矩形で囲まれた領域は Faster R-CNN により予測された領域を表す．

正解ラベルと予測のクラスは，図 5 と図 8 では要外科的処置群，図 6 では内科的経過観察群，図 7 では全て正常群であった．

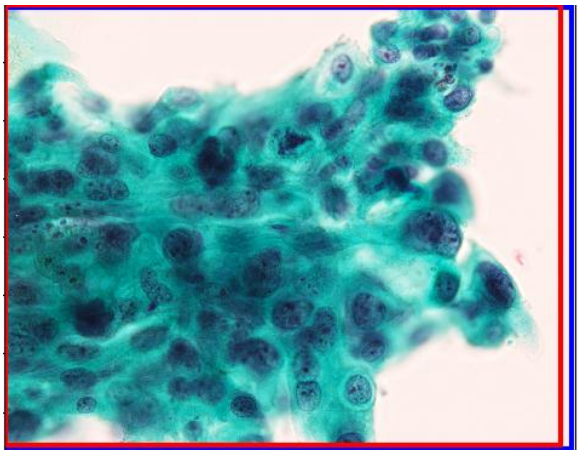

図 5 要外科的処置群の結果の例

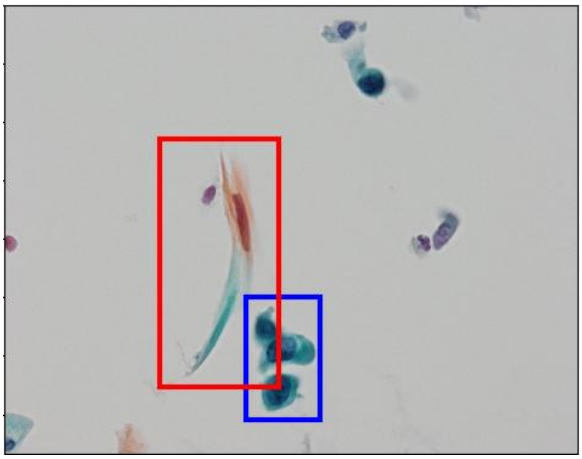

図 8 要外科的処置群の検出漏れの例

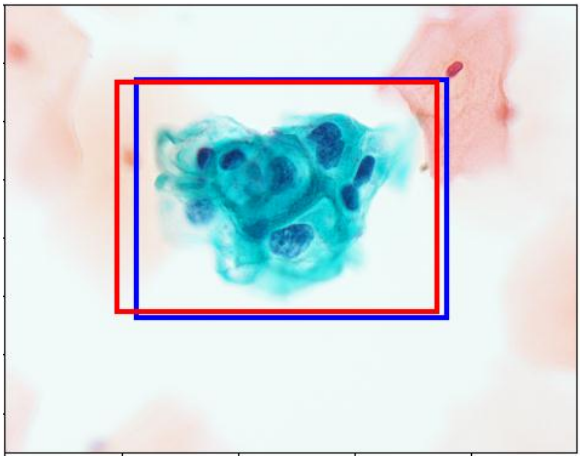

図 6 内科的経過観察群の結果の例

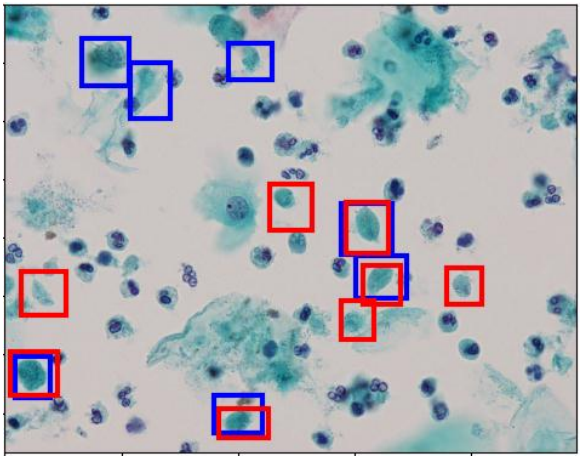

図 7 正常群の結果の例

5. 考察

本研究では，Faster R-CNN を用いて子宮頸部細胞を検出し，その悪性度を分類する方法を提案した．

悪性度のクラスごとに適合率，再現率，F 値及び診断成功率を求めた結果，悪性度の高い群に比べて正常群の精度が低かった．この原因として，悪性度の高いクラスの核の大きさ（核腫大）、色の濃さ（クロマチン凝集）や核と細胞質の比率（N/C 比）増大などの特徴を抽出できていると考えられ，図 5 や図 6 のような正確な予測ができている一方で，正常群は比較的軽度の細胞変化，炎症に伴い欠損した組織の再生変化，並びにカンジダ，クラミジアといった非腫瘍性感染症など多彩で比較的稀な病変もあり，特徴を一意に決定できないことが考えられる．また，正常群の画像では図 7 のように一枚の画像に多くの有所見細胞が存在していることが多かった．検査士はこれらの細胞の全てを有所見細胞と認識可能であるが，臨床現場ではこのような有所見細胞が複数個確認できれば最終診断に至る．そのため標本に含まれる全ての有所見細胞をアノテーションするのは現実的には困難で，それが今回正常群の F 値が低い結果となった要因と推定された．すなわち，検査士が臨床現場で提出される検体に含まれる全ての細胞に，アノテーションを行うことは困難であり，この点は細胞診において積極的に deep

learningを活用する意義がある点といえよう．また，細胞診では悪性度の高い細胞を見つけ出すことが最も重要で正常群の細胞検出の優先度は低いため，研究手法としては正常群の区分を無くすことも一手法として挙げられる．しかし，先に述べたカンジダやクラミジア感染症などでは抗菌化学療法が実施されることもあり，この群の正確な抽出は今後さらに検討していくべき課題と考えたい．

最も悪性度の高い要外科的処置群の細胞は核腫大，クロマチン凝集やN/C比増大などの形態学的特徴を持つことが多い．ただし，これらの特徴を有する細胞は，腫瘍細胞が上皮内に留まる最も病期の低い上皮内病変に多い．しかし，癌細胞が上皮から間質にまで進展する進行癌状態になると，図8のような紡錘状でオレンジの細胞質を有する分化型扁平上皮癌細胞も認められるようになる．子宮頸部細胞診の主たる目的は早期に子宮頸癌を発見することであり，幸いなことに図8に示すような進行癌で発見される症例は必ずしも多くない．そのため学習を有効に行うための画像の水増し方法の改善や，多施設からの新たな検体の確保が今後必要になってくると考えられる．

次に，AFROC 曲線を用いて求めた閾値について考える．内科的経過観察群と正常群ではともに閾値が0.25となっている一方で，要外科的処置群では閾値が 0.63 と他のクラスに比べて高い値をとっている．内科的経過観察群と正常群では，尤度が低いものの正しい予測が少なからずあるため閾値が低く設定されていると考えられるが，予測確率が低い誤検出を取り除くという本来の目的を十分に果たすためには閾値がより高い値になるようにする必要があると考えられる．実際，内科的経過観察群では再現率は要外科的処置群と同じような数値であるものの適合率は低く，尤度が低い予測を十分に取り除けていないことが原因の1つだと考えられる．そのため，今後は検出できる細胞の予測確率を向上させて閾値を適切に設定できるようにすることが必要であり，訓練データを増やすなどしてより多くの特徴を抽出できるようにすることや，精度の高い予測を実現できるネットワークの検討が求められる．

6.まとめ

本稿では，子宮頸部細胞診画像を用いて細胞の検出とその細胞のベセスダ分類に基づく悪性度の分類を行う手法を提案した．その結果，検出ができた細胞に対して悪性度が高い要外科的処置群と内科的経過観察群に対して良好な結果を得た．今後の課題として，悪性度が高いとはいえないものの，臨床的に無視できない正常群の取り扱いや､精度を上げるための手法の検討が挙げられる．

謝辞

本研究は日本学術振興会科学研究費補助金新学術領域研究(26108009)による支援を受けた．

利益相反の有無

「なし」

文　献

［1］ 国立がん研究センターがん情報サービス　子宮頸がん基礎知識：http://ganjoho.jp/public/cancer/cervix_uteri/index.html (2018年5月9日参照)

［2］ ステッドマン医学大辞典編集委員会編：ステッドマン医学大辞典 第5版，メジカルビュー社,2002,pp1753-1754

［3］ 日本臨床細胞学会 細胞検査士とは: http://jscc.or.jp/others/others2 (2018年5月9日参照)

［4］ S Ren, K He, R Girshick et al: Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks arXiv:1506.01497,2015

［5］ Niitani Y, Ogawa T, Saito S et al: ChainerCV a Library for Deep Learning in Computer Vision arXiv:1708.08169,2017

［6］ 日本医用画像工学会ハンドブック編集委員会 編:医用画像工学ハンドブック，日本医用画像工学会,2012, pp504-505

Detection of Malignant Cells in Cervical Cancer Cytology using Faster R-CNN

Taisuke TSUMORI[*1], Shoji KIDO[*1] Yasushi HIRANO[*1]
Masaki Mori[*2] Kunihiro INAI[*2] Yoshiaki IMAMURA[*2]

*1 Yamaguchi University
*2 University of Fukui

Cytological investigation is one of useful ways for exploring cervical cancer, while cytotechnologists are forced to find a few neoplastic cells from many normal cervical cells. Therefore, the purpose of this study is to propose a computer-based diagnostic method of cytopathology using deep learning.

In this study, we used Faster R-CNN for object detection. And by using it, we can detect malignant cells which have to be diagnosed and classified the grade of malignancy based on the Bethesda classifications which is used to diagnose cervical cancer cytology. We classified three classes in consideration of the policy of treatment.

We divided pathological data for training and test in order to do 5 cross-validation. We compared F-measures for detecting cells. As the result, the F-measure for the normal group was 47.9±9.0[%] . However, the F-measure for the group of surgical procedure was 82.3±2.9[%]. For the group of the internal medical observation, the F-measure was 75.0±8.6[%] . The low performance of the F-measure for the normal group suggested the difficulty of annotation of all cells. The results for high grade classes showed the effectiveness of the method we proposed.

Key words: Computer-Aided Diagnosis, Deep Learning, Faster R-CNN, Cytology

マウスの脳の二光子顕微鏡画像からの神経細胞認識処理の開発

君塚　涼[*1]　道川　貴章[*2]　竹本　智子[*2]　横田　秀夫[*2]

宮脇　敦史[*2]　清水　昭伸[*1]

要旨

計算機を用いた脳神経細胞の自動抽出は，生物学的解析の効率を高める面から求められているが，蛍光染色による違いや活動の有無から細胞体のコントラストが異なり，同時に認識することは難しい．本稿では，深層学習による脳神経細胞の自動認識処理を提案する．この処理では二光子顕微鏡で撮影されたマウスの脳組織画像を入力とし，U-net を用いて脳神経細胞の細胞体のセグメンテーションを行う．パッチベースの方法論を採用し，データオーグメンテーションを行った．損失関数は従来法の cross entropy の他，拡張した Dice 係数を用い，比較を行う．二光子顕微鏡画像を学習データ，バリデーションデータ，テストデータに分割し，細胞体について画素単位での一致度と，細胞体単位での検出率や拾いすぎ連結成分の数などを評価した．また，従来法である Boosting との比較を行い，本手法の有効性を示した．

キーワード：深層学習，Dice，二光子顕微鏡画像，細胞体抽出

1. はじめに

二光子顕微鏡により撮像されたマウスの脳の 3 次元画像は，脳機能解明のために重要な役割を果たしている．しかし，画像上の大量の神経細胞をマニュアルで認識・解析することは容易ではない．神経細胞の撮影は蛍光タンパク質を使用し[1]，その蛍光を光学顕微鏡で捉えるが，撮影部の深度や染色の違い，活動の有無などにより，細胞体のコントラストは大きく異なり（図 1 参照），単一の処理で同時に認識することは難しい．

Schmitz ら[2]は共焦点顕微鏡によって撮影された 3 次元マウスの脳画像に対して，FARSIGHT toolkit[3]による 3 次元細胞検出を検討し，細胞核の画素単位検出率として true positive rate（TPR）が 38～99%で false positive rate（FPR）が 3.6~82%であった．しかし，誤って抽出される画素数の増加も報告されている．伊藤らは[4]，MadaBoost を用い，低コントラスト細胞体と高コントラスト細胞それぞれについて識別器を構築し，抽出結果を統合することで細胞体の見落とし削減を目指したが，その精度は十分ではなかった．

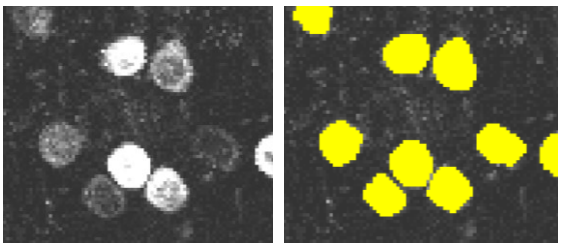

図 1　低コントラスト細胞体と高コントラスト細胞体の入り混じった例（左：原画像　右：原画像＋細胞体ラベル）

本稿では，U-Net[5] [6]を用いたマウスの脳神経細

*1 東京農工大学大学院工学研究院

[〒184-8588 東京都小金井市中町 2-24-16]

E-mail: s175637t@st.tuat.ac.jp

*2 国立研究開発法人理化学研究所

胞の細胞体抽出処理を提案する．また，実際の画像を用いて，性能を評価する．その際，学習の損失関数の違いや，データオーグメンテーションの有無による性能への影響についても評価する．

2. 手法

2. 1 ネットワーク構造

U-Net は Encode と Decode の構造を持つ Fully Convolutional Network(FCN)[7]に，スキップコネクションを追加した構造を持つ．コンボリューションによる Encode によって大域的で高次な特徴を集約し，デコンボリューションによる Decode の過程にスキップコネクションを通じて情報を渡すことで，局所的な特徴を正確に認識することができる．図 2 にネットワーク構造を示した．ネットワークの入力は原画像から切り出した部分画像（パッチ画像と呼ぶ），出力はそのパッチ画像に対する細胞体と背景の抽出結果である．ここでパッチ画像を用いたのは，GPU メモリの制約以外に，ネットワークの規模を抑えることで少数の画像で効率的に学習できるようにするためである．パッチ画像のサイズは，実際の細胞体を十分含むことと，図 2 の構造を採用した際に Encode 後のサイズ（一番サイズが小さくなった時）を考慮して 64×64×32[voxel]とした．図中の立方体は特徴マップを表し，立方体の上の数字は特徴マップ数，立方体の左の数字は画像サイズを表している．なお，今回はコンボリューション時に 0-padding を行っているため，画像サイズの縮小はない．Pooling のサイズは 2×2×2[voxel]とした．

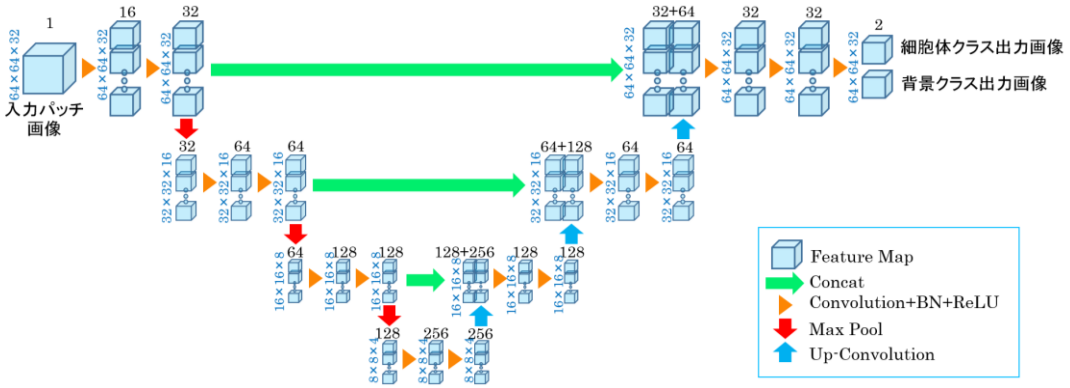

図 2　ネットワーク構造

2. 2　学習用パッチ画像作成方法

画像中には細胞体以外に樹状突起が存在する（図 3 参照）．

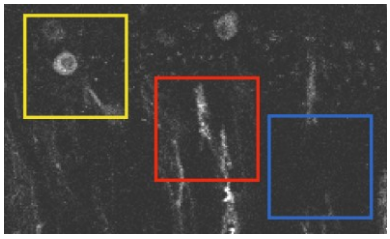

図 3　学習用パッチ画像の例（黄：細胞体，赤：樹状突起（背景），青：それ以外（背景））

今回，樹状突起は背景に含めているが，学習用パッチ画像生成時には，細胞体のパッチ画像数や構造物が存在しない背景のパッチ画像数以外に，樹状突起のパッチ画像数も重要であることが予備検討から分かったため，各々の数を以下の様にした．

・細胞体パッチ画像＝1000 画像
・樹状突起（背景）パッチ画像＝1500 画像
・それ以外（背景）パッチ画像＝200 画像

なお，それぞれのパッチ画像の切り出しは，学習用画像上を 64×64×32[voxel]のウインドウで走査し，中心の画素が該当するラベルに対応するすべての

パッチ画像の中からランダムに行った．ここで，ラベルの種類は細胞体，樹状突起，それ以外のラベルであり，あらかじめ手作業で作成した．

2．3 損失関数

ネットワークの重みの学習は，与えた損失関数を最小化するように進められるため，損失関数として何を与えるかが重要となる．今回は，クロスエントロピー（式（1））と拡張した Dice 損失（式（2））について検討をした．

$$Loss_{cross\ entropy} = -\frac{1}{N}\sum_{i}^{N}\sum_{k}^{K} t_{ki}\log(p_{ki}) \quad (1)$$

$$Loss_{Dice} = \frac{1}{\mathrm{K}}\sum_{k}^{K}\left(-\frac{2\sum_{i}^{N} p_{ki}t_{ki}}{\sum_{i}^{N} p_{ki} + \sum_{i}^{N} t_{ki}}\right) \quad (2)$$

$$p_{ki}(\mathbf{x}) = softmax(y_{ki}) = \frac{\exp\left(y_{ki}(\mathbf{x})\right)}{\sum_{k}^{K}\exp\left(y_{ki}(\mathbf{x})\right)} \quad (3)$$

ここで，Kは総クラス数（今回は 2），kはクラスの index，Nは全画素数，iは画素の index，y_kはネットワーク出力，t_kは正解ラベルである．

2．4 データオーグメンテーション

過学習を防ぎ，ネットワークの汎化性を向上させるために，データオーグメンテーションを行う．図 4 に座標軸とパッチ画像の関係を示したが，今回は，各軸方向に鏡像の画像を作成した．ただし，樹状突起は y 軸方向に伸びており，この軸に関する鏡像は細胞体と樹状突起の位置関係を変えてしまう．そのため，今回は，x 軸と z 軸に限って独立に鏡像を作成した．

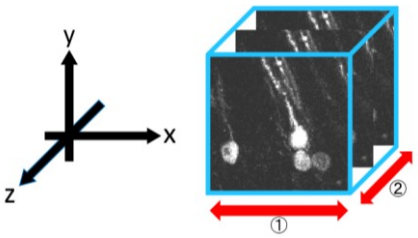

図 4　x 軸と z 軸の反転によるデータオーグメンテーション

3．実験条件と評価方法

試料画像は，マウスの小脳の lobule V を小脳皮質の表面から二光子励起レーザー顕微鏡で撮影した３次元画像である．蛍光シグナルは Yellow cameleon 2.60 に含まれる Venus の蛍光であり，プルキンエ細胞だけに発現させた[1]．症例数は 1，画像サイズは 1,502×1,008×112[voxel]である．この画像を 4 分割し，学習に分割後の２画像，バリデーション（学習回数などを決定）に１画像，テストに１画像使用した．分割画像から作成したパッチ画像数は以下のとおりである．

・細胞体パッチ画像＝50 画像
・樹状突起（背景）パッチ画像＝40 画像
・それ以外（背景）パッチ画像＝10 画像

テスト画像は最終的に構築された識別器の評価に使用したが，テストパッチ画像をラスタ走査順にスライドさせながらネットワークによって順番に処理し，最後にすべての出力画像を同じ順番にタイリングすることで画像全体の結果を求めた．ただし，出力画像の縁は 0-padding による影響を受けているため，中央の 28×28×12[voxel]のみをタイリングした．

画素単位の評価のために以下の評価値の定義をした．本実験では細胞体の抽出のみを行うため，細胞体と背景の２クラスを考える．細胞体の画素のうち細胞体として正しく抽出された画素数を true positive（TP），背景の画素のうち背景として正しく抽出された画素数を true negative（TF），細胞体の画素のうち背景として誤って抽出された画素数を false negative（FN），背景の正解画素のうち細胞体として誤って抽出された画素数を false positive（FP）とする．また，それらから計算される，false positive rate（FPR）（式（4）），true positive rate（TPR）（式（5））も用いる．

$$FPR = \frac{FP}{TN + FP} \quad (4)$$

$$TPR = \frac{TP}{TP + FN} \tag{5}$$

さらに，式（6）の Dice 係数も評価に用いた．

$$\mathrm{Dice} = \frac{2 \cdot \#(A \cap B)}{\#(A) + \#(B)} \tag{6}$$

ここで，A が正解領域の画素集合，B が抽出結果の画素集合，#(・)が集合に含まれる画素数である．

また，細胞体領域単位の評価も行った．そこでは，拾いすぎ連結成分数 FP_region，検出細胞体数 TP_region，および細胞体の検出率を定義する．FP_region は，細胞体と重なりを持たない連結成分（26 連結）の個数，TP_region は検出された細胞体の個数を表す．ここで検出されたか否かは，細胞体ごとに重複しているすべての連結成分（26 連結）を求め，その論理和領域と細胞体の間の Dice 係数がある一定値（今回は細胞体正解領域の観察者間変動 0.774）以上となった時を検出とした．また，検出率は式（7）で示される．なお，本実験のテスト画像中の細胞体数は 167 個である．

$$\text{細胞体の検出率} = \frac{\text{TP_region}}{\text{細胞体数}} \tag{7}$$

損失関数の違いとデータオーグメンテーションの有無による性能への影響の評価や，従来法[7]との比較のために，以下の（a）～（e）の５通りの実験を行った．

(a) U-Net : クロスエントロピー損失，データオーグメンテーションなし
(b) U-Net : Dice 損失，データオーグメンテーションなし
(c) U-Net : クロスエントロピー損失，データオーグメンテーションあり
(d) U-Net : Dice 損失，データオーグメンテーションあり
(e) MadaBoost, データオーグメンテーションなし

なお，比較手法として文献[8]の MabaBoost に注目し，それによる抽出結果との比較も行った．

4. 実験結果

上記の（a）～（e）の５つの識別器について，テスト画像のセグメンテーションを行った．まず，画素単位での評価のために，TPR=0.80 となるしきい値で U-Net の出力を二値化した場合の性能を表１に示した．オーグンメンテーション無しの(a)，(b)と比較し，有りの（c），（d）では，FPR，Dice の両方で評価が向上することが確認できた．

表１　画素単位の抽出精度評価

	TPR	FPR	Dice
(a)	0.800	0.000182	0.820
(b)	0.800	0.000172	0.824
(c)	0.800	0.000138	0.836
(d)	0.800	0.000137	0.837
(e)	0.800	0.001815	0.486

U-Net : クロスエントロピー損失，U-Net : Dice 損失，MadaBoost の出力を図 5 に示したが， Dice 損失によって学習した U-Net は，細胞体の縁を強調していることが確認できる．これは，エッジ部分の抽出精度に Dice 損失が大きく影響を受けるためだと考えられる．

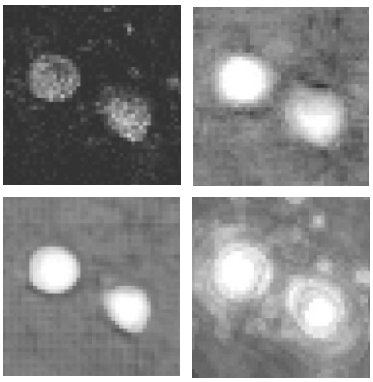

図５　U-Net と Boosting の出力（左上：原画像，右上：U-Net（クロスエントロピー），左下：U-Net（Dice），右下：MadaBoost）

これらの出力に対して，TPR=0.80 となるしきい

値で二値化処理によるセグメンテーション結果を図 6 に示した．緑色は TP，青色は FN，赤色は FP を表している．Dice 損失の U-Net は，クロスエントロピー損失の U-Net と比較し，特に輪郭付近の精度を改善することが確認できた．

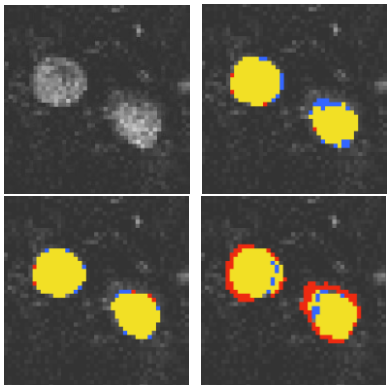

図 6　U-Net と Boosting のセグメンテーション結果（左上：原画像，右上：U-Net（クロスエントロピー），左下：U-Net（Dice），右下：MadaBoost）

次に，細胞体領域単位での評価のために，細胞体の検出率=0.75 となるしきい値でセグメンテーションを行った結果を表 2 に示した．ここで，MadaBoost は，各細胞体領域での Dice 評価が低く，検出率=0.75 となるしきい値が存在しなかったために空欄となっている．FP_region に注目すると，Dice 損失，データオーグメンテーションありで学習をした U-Net の結果が最良となり，上の画素単位での評価と最適なものが一致した．

表 2　細胞体領域単位の抽出精度評価

	TP_region	検出率	FP_region
(a)	126	0.754	1084
(b)	126	0.754	67
(c)	126	0.754	58
(d)	126	0.754	52
(e)	—	—	—

5. むすび

本稿では，マウスの小脳の二光子励起レーザー顕微鏡画像を対象とした，U-Net を使用した細胞体の検出処理について報告をした．実験では，損失関数の種類やデータオーグメンテーションによる効果を検証した．具体的には，クロスエントロピー損失と Dice 損失，データオーグメンテーションの有無の組み合わせで評価を行ったところ，画素単位と細胞体領域単位での評価の両方において，Dice 損失とデータオーグメンテーションありの U-Net が最良となった．

問題点としては，低コントラスト細胞体の抽出率がまだ不十分である点であり，今後は，ネットワーク構造の工夫や新しい損失関数の提案により，さらなる精度向上を目指す予定である．

謝辞

日頃から熱心にご討論いただく東京農工大学 清水昭伸研究室，国立研究開発法人理化学研究所の皆様に深謝致します．本研究の一部は，国立研究開発法人日本医療研究開発機構（AMED）の「革新的技術による脳機能ネットワークの全容解明プロジェクト」の支援と，文部科学省科研費（18H03255, 26108002）により行われました．

利益相反の有無

なし

文　献

［1］Yamada, Yoshiyuki, et al. : Quantitative comparison of genetically encoded Ca2+ indicators in cortical pyramidal cells and cerebellar Purkinje cells. Frontiers in cellular neuroscience 5 (2011): 18.

［2］Christoph Schmitz, Brian S.E, Susan J.Tappan, et al. : Current automated 3D cell detection methods

are not a suitable replacement for manual stereologic cell counting. Frontiers in neuroanatomy 8 ,2014

［3］ FARSIGHT Project:FARSIGHT Project Wiki. http://www.farsight-toolkit.org/wiki/Main_Page （2018 年 5 月 11 日閲覧）

［4］伊藤達也, 斉藤篤, 横田秀夫, 他.: 3 次元脳組織画像からの細胞体抽出処理に関する初期検討. IEICE technical report 115.401 (2016): 283-288.

［5］Ronneberger, Olaf, Philipp Fischer, and Thomas Brox. : U-net: Convolutional networks for biomedical image segmentation. International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer, Cham, 2015.

［6］Çiçek, Özgün, et al. : 3D U-Net: learning dense volumetric segmentation from sparse annotation. International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer International Publishing, 2016.

［7］Long, Jonathan, Evan Shelhamer, and Trevor Darrell. : Fully convolutional networks for semantic segmentation. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015.

［8］伊藤達也: 3 次元脳組織画像からの細胞体抽出処理の開発. 東京農工大学修士学位論文 2017

Automatic Detection of Image Quality Failure for the Practical Use of Whole Slide Imaging Scanner

Hossain MD SHAKHAWAT[*1], Tomoya NAKAMURA[*1,2], Fumikazu KIMURA[*3], Yukako YAGI[*4], Mashahiro YAMAGUCHI[*1]

Abstract

Whole slide imaging (WSI) scanner scans pathological specimens to produce digital slides to use in pathology practice, research and computational pathology which enables monitor-based diagnosis and image analysis. Sometimes, the scanner fails to produce adequate quality images. The current system has to rely on the operator for detecting a low-quality image that needs to be rescanned, which is time consuming and not reliable. Therefore, it is necessary to evaluate the scanned image to detect quality failure automatically. In this paper, we propose a method to evaluate scanned images and detect slides necessary to rescan. At first, tissue artefacts (i.e. air bubble, tissue fold) were detected from the low-resolution image using machine learning technique. Then the quality was estimated at high-resolution based on the sharpness and noise measurement of the image. The quality was estimated except the artefact affected regions. Proposed system enabled the detection of poor quality slides to rescan by eliminating artefacts. The validity of the proposed method was confirmed through the experiments using differently stained slides that contains various tissue organs.

Keywords：whole slide imaging scanner, image quality evaluation, pathology specimens

1. Introduction

The WSI scanner transforms the pathological specimens into digital images for image analysis and diagnosis in digital pathology. The success of analysis and diagnosis largely relies on the scanned image quality. However, the scanner sometimes failed to produce sufficient quality image. Poor images pose critical threat and it is necessary to detect the quality failure of scanned image to ensure effective analysis and diagnosis. Currently, the system has to rely on individuals to detect the failure. Therefore, it is necessary to detect the quality failure of scanned image automatically. In this paper, we propose a method to detect the quality failures of scanned image for the practical use of WSI scanner. Image quality failure is mainly caused by focus error and noise in WSI scanner. However, if the focus problem and noise is caused by tissue artefacts then it is worthless to detect. Tissue artefacts (i.e. air-bubble, tissue-fold) hide information and useless for analysis.

---

*1 School of Engineering, Tokyo Institute of Technology
〔4259-G2-28 Nagatsuta, Midori, Yokohama, Japan〕
e-mail: shakhawat.h.aa@m.titech.ac.jp

*2 PRESTO, Japan Science and Technology Agency, Japan

*3 Department of Biomedical Laboratory Sciences, Shinshu University, Japan

*4 Department of Pathology, Memorial Sloan Kettering Cancer Center, New York, USA

Examples of tissue artefacts, focus error and noise are shown in figure 1. Tissue artefacts are useless and should be avoided to judge image quality. We detected and eliminated tissue artefacts to evaluate the scanned image quality. For quality estimation, we relied on the referenceless quality evaluation method (RQM) by

Yagi.[1] RQM estimates quality based on sharpness and noise of the image.

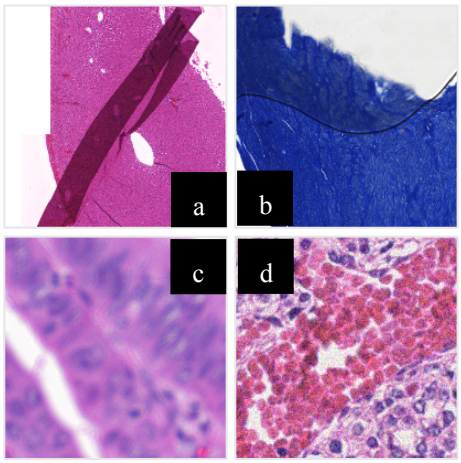

Fig. 1 Examples of (a) tissue fold, (b) air bubble, (c) focus error and (d) simulated noisy image.

2. Method

The schematic diagram of the proposed method for automatic detection of image quality failure is shown in fig. 2. Proposed method utilizes the low-resolution WSI image to detect tissue artefacts and then estimates quality from the high-resolution image. Artefacts were detected using the support vector machine (SVM) from 1x magnification image. SVM was trained to detect air-bubbles and tissue folds using the image features extracted from WSI images which includes 4-GLCM features (contrast, correlation, homogeneity and energy) and 3 other features specific to artefacts. The artefact detection result was used to eliminate artefacts for quality estimation. Image quality is estimated using RQM from the high-resolution image expect the detected artefacts. The quality was estimated from the non-overlapped image blocks extracted from the 20X WSI image excluding the artefact affected blocks and blocks that were mostly white. Finally, the quality of slide was derived from the quality indices of evaluated blocks.

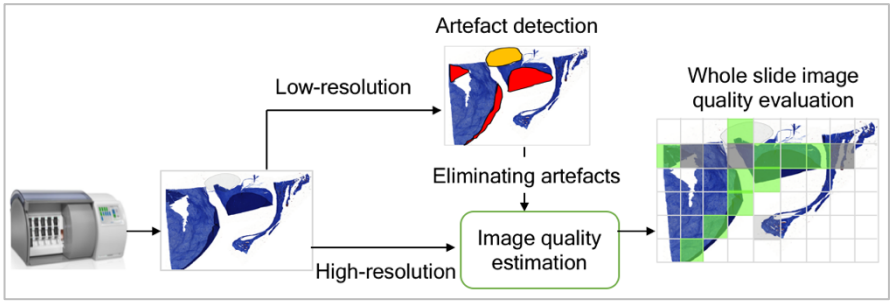

Fig. 2 Proposed method for automatic detection of image quality failure.

3. Results

Through the experiments using hematoxylin and eosin (HE), immunohistochemistry (IHC) and periodic acid-Schiff(PAS) stained samples of major tissue organs (i.e. heart, lung, intestine, brain, stomach), we confirmed the validity of the proposed method for WSI scanner. Figure 3 shows the color map of quality evaluation of WSI image scanned by HAMAMATSU NanoZoomer. Average classification accuracy for detecting artefacts was 99.19% in 4-fold cross-validation using SVM. Proposed method evaluated WSI quality by eliminating the detected tissue artefacts in order to detect quality failure. The method was demonstrated for different staining, slides with different organs and slides scanned by HAMAMATSU NanoZoomer and 3DHISTECH Pannoramic Desk Scanner. Table 1 shows the quality evaluation results of whole slides by proposed method.

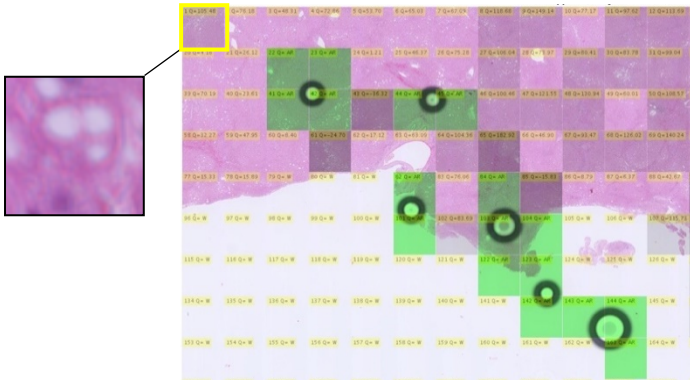

Fig. 3 Image quality failure detection: Dark, light, and no shade indicates poor, average and good quality blocks, accordingly. Green indicates artefact affected blocks and yellow rectangle indicates focus error (magnified view).

Table 1 Quality evaluation by proposed method.

SI	Slide dimensions in pixels	# of eliminated artefact affected blocks	# of poor blocks	Whole slide image quality	Area occupied by poor blocks in the whole slide (%)
1	18Kx14K	13	4	36.1	6.35
2	20Kx10K	7	3	37.3	6
3	40Kx20K	21	31	50.4	15.5
4	40Kx26K	7	69	58.0	26.53
5	26Kx14K	0	59	68.4	64.83
6	32Kx20K	5	95	70.0	59.37

In table 1 lower quality value indicates higher quality of the slide. Proposed method eliminated false detections due to artefacts and then estimated quality which enables practical judgement of slides to rescan. Slides necessary to rescan can be detected by applying threshold value on the quality or on the possession of poor blocks.

4. Conclusion

The proposed method detected artefacts firstly, then evaluated image quality by eliminating the detected artefacts. This primary analysis confirmed the effectiveness of the proposed method for detecting quality failure of whole slide images for practical use of WSI scanner. This system will be used in the hospitals and pathology departments for routine applications of WSI scanner. In future, this method can be enhanced and integrated within the scanner to select focus points for scanning slides.

Competing interests

None

References

[1] Hashimoto, N., Yamaguchi, M., Yagi, Y., Bautista, P., & Ohyama, N. (2012). "Referenceless image quality evaluation for whole slide imaging." Journal of Pathology Informatics,3(1), 9. doi:10.4103/2153-3539.93891

[2] Molin, J., Thorstenson, S., & Lundström, C. (2014). "Implementation of large-scale routine diagnostics using whole slide imaging in Sweden: Digital pathology experiences 2006-2013." Journal of Pathology Informatics,5(1), 14. doi:10.4103/2153-3539.129452

[3] Bautista, P., & Yagi, Y. (2009). "Detection of tissue folds in whole slide images." 2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. doi:10.1109/iembs.2009.5334529

[4] Palokangas, S., Selinummi, J., & Yli-Harja, O. (2007). "Segmentation of Folds in Tissue Section Images." 2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. doi:10.1109/iembs.2007.4353626

[5] Wang, M., Kothari, S., & Phan, J. (2013). "Eliminating tissue-fold artifacts in histopathological whole-slide images for improved image-based prediction of cancer grade." Journal of Pathology Informatics,4(1), 22. doi:10.4103/2153-3539.117448

[6] Gilbertson, J. R., Ho, J., Anthony, L., Jukic, D. M., Yagi, Y., & Parwani, A. V. (2006). "Primary histologic diagnosis using automated whole slide imaging: a validation study." BMC Clinical Pathology,6(1). doi:10.1186/1472-6890-6-4

深層学習器を用いた悪性黒色腫自動識別の識別根拠の評価

村林　誠也[*1]　彌冨　仁[*1]

要旨

悪性黒色腫（メラノーマ）の早期発見と高精度な診断実現のため，画像認識による自動診断手法の開発が行われている．近年の深層学習を用いた手法は，複雑な特徴量抽出・設計を伴うことなく専門医に匹敵する高い識別精度を実現しているが，識別根拠を提示できず改善の余地が残されていた．そこで本研究では，診断が確定した2146例の皮膚ダーモスコピー（皮膚科専用の拡大鏡）画像と深層畳み込みニューラルネットワーク（CNN）を用いて悪性黒色腫の自動識別器を構築するとともに，臨床で用いられる診断指標であるABCD-rule，7-point checklistに示される計15項目のダーモスコピー特徴に対して4人の皮膚科専門医の協力のもと得られた226症例を元に予測器を試作した．CNNによる悪性黒色腫識別能は感度88%，特異度96%であり，上記15項目の診断指標に基づく医師の診断精度の感度80%，特異度80%を上回った．一方，CNNが予測した15の診断指標結果に基づく診断精度は感度75%，特異度74%であった．診断指標予測の精度向上が必須であるが，人間にわかりやすい診断指標に基づく識別は純粋な機械学習に基づく手法より精度が悪化することが確認できた．

キーワード：ダーモスコピー，コンピュータ自動診断（CAD），深層学習，サポートベクター回帰分析

1. はじめに

皮膚がんの一種である悪性黒色腫（メラノーマ）は極めて悪性度が高く早期の発見が非常に重要となる．特に早期の段階におけるその様相は母斑に酷似しているため識別が非常に困難で，熟練の皮膚科専門医によるダーモスコピー画像の識別精度でも75%～84%に留まる．このため悪性黒色腫の早期発見と高精度な診断の実現を目的として，コンピュータ画像認識による自動診断支援の開発が行われてきた．とりわけ近年，その高い認識精度により画像認識分野で主流となっている深層学習を用いた手法では，数値の上では医師に匹敵，あるいは凌駕する高い識別精度を実現している［1］．深層学習では入力の画素値から自動的に特徴を学習することで特徴量抽出・設計といった複雑な処理を伴わず識別が可能なため，従来手法において特徴量抽出が困難であった症例も取り扱うことが可能となった．一方で識別に至る根拠を提示することが困難であり，改善の余地が残されていた．そこで本研究では，深層畳み込みニューラルネットワーク（CNN）を用いて悪性黒色腫診断を行うと共に，識別根拠提示の検討として，臨床で診断のために実際に使われている2つの主要な診断指標計15項目のダーモスコピー特徴の数値の推定を行った．

2. 方法

1）CNNによる特徴抽出と悪性黒色腫識別

本実験では，一般物体画像データセットであるImageNetで学習済みのVGG-19の重みを初期値として用い，conv5_1以降の畳み込み層および全結合層の重みを2,146例（良性1,426例，悪性720例）の診断の確定したダーモスコピー画像によりFine-tuningすることで識別器を構築した．

2）臨床で用いられる診断指標数値の推定

臨床で広く使用されている診断指標であるABCD-rule（8項目）［3］および7-point checklist（7項目）［4］に対して，CNNで得られた4096次元の中間表現を用いてサポートベクター回帰分析を行った．教師データにはあらかじめ

*1 法政大学大学院理工学研究科応用情報工学専攻〔〒184-8584 東京都小金井市梶野町3-7-2〕
e-mail:seiya.murabayashi.9j@stu.hosei.ac.jp

表 1　診断指標 15 項目の予測

	ID	項目（範囲） *A,B,C 以外は(0-1)	MAE	皮膚科専門医 ($\mu\pm\sigma$)
ABCD rule	A	軸の非対称性 (0-2)	0.570	1.320±0.440
	B	境界の明瞭性 (0-8)	2.062	4.876±2.270
	C	色の種類 (1-6)	0.654	2.830±0.570
	D1	網状の色素構造	0.427	0.569±0.202
	D2	枝状の色素構造	0.300	0.271±0.160
	D3	均一な構造	0.310	0.659±0.357
	D4	点構造	0.305	0.638±0.231
	D5	粒状構造	0.311	0.620±0.287
7-point check list	S1	不規則な網構造	0.381	0.404±0.250
	S2	青白い領域	0.279	0.300±0.209
	S3	不規則な血管パターン	0.135	0.063±0.072
	S4	不規則な枝状構造	0.262	0.220±0.154
	S5	不規則な色素沈着	0.336	0.395±0.297
	S6	不均一な点	0.321	0.477±0.250
	S7	色素抜け構造	0.254	0.207±0.148

表 2　15 の診断指標に基づく診断結果

評価指標	皮膚科		予測値	
(識別閾値)	SE(%)	SP(%)	SE(%)	SP(%)
TDS (4.75)	88.4	68.9	45.1	94.2
TDS (5.00)	85.6	75.4	58.2	88.5
TDS (5.25)	**79.8**	**80.3**	69.7	80.8
TDS (5.45)	76.0	83.6	**75.0**	**73.8**
TS (3)	76.0	80.3	42.3	95.1

4 人の皮膚科専門医によって同項目への評価がなされた 226 例のデータを用いた.

3）評価実験

CNN を用いた悪性黒色腫の識別能は, 感度(SE)・特異度(SP)で，診断指標 15 項目の予測については平均絶対誤差(MAE)で，それぞれ Leave-one-out 法により評価した．また診断指標の各数値から求められる診断精度を皮膚科医と予測値を元にした手法で比較を行った.

3. 結果と考察

CNN によるメラノーマ識別能は感度 88%, 特異度 96%であった．診断指標の各項目に対し，推定結果の MAE および 4 人の皮膚科医による評価の平均と分散を表 1 に示す.

また, 15 の診断指標に基づく 4 人の皮膚科医師の診断と CNN による診断の結果の感度・特異度を表 2 に示す．ただし ABCD-rule の重み合計値 TDS=1.3A+0.1B+0.5C+0.5D の識別閾値は指標の定義に基づき 4.75，5.00，5.25，5.45，7-point checklist の項目数 TS（ただし，S1～S3 は 2 倍）の識別閾値は 3 とし，これを越えたものを悪性とした.

診断指標 15 項目予測において，MAE は全体的に大きく，さらなる精度が求められると共に，診断指標の各数値から求められる診断精度は皮膚科医の診断に 10%程度以上劣る結果となった．これは，各項目を予測するための学習データの数が限られていたことが原因と考えられ，データの追加ならびに効果的な学習方法を検討する必要がある.

4. まとめ

深層学習手法における純粋な識別能は医師の診断精度を上回るが，人間にわかりやすい診断指標のみに基づく識別は限界があることが確認できた．今後，データ追加の他，診断指標に対しより有効な深層特徴抽出方法などの検討を行う.

利益相反の有無

なし

文　献

［1］ A. Esteva，B. Kuprel，R. A . Novoa et al: Dermatologist-level classification of skin cancer with deep neural networks. Nature 542, 115-118, doi:10.1038/nature21056, Feb. 2017.

［2］ K.Simonyan, A.Zisserman et al: Very deep convolutional networks for large-scale image recognition. arXiv:1409.1556.

［3］ W. Stolz, A. Riemann, A. B. Cognetta et al: ABCD rule of dermatoscopy:a new practi -cal method for early recognition of malignant melanoma. European Journal of Dermatology No.4 No.7, pp.521-527, Apr 1994.

［4］ G. Argenziano, G. Fabbrocini, P. Carli et al: Epiluminescence microscopy for the diagnosis of ABCD rule of dermatoscopy and a new 7-point checklist based on pattern analysis. Archives of Dermatology No.134, pp.1536-1570 1998.

テンプレート（全ての原稿の種類に共通） Ver. 2.1（2017.3.21 改訂）

クラス別学習による細胞画像セグメンテーション

松月　大輔[*1,a)]　堀田　一弘[*1]　平松　侑樹[*1]　松田　道行[*2]

寺井　健太[*2]　今西　彩子[*2]

要旨

今日，人工知能技術による処理の自動化が様々な所で進められており，細胞画像中の「細胞膜」や「細胞核」のセグメンテーションでも Deep learning を用いるのが主流になりつつある．一般に，画像のセグメンテーションでは 1 枚の画像中に複数のクラスが存在する．クラス数が増えた場合やクラス毎に出現頻度が異なる場合，セグメンテーションの精度が低下してしまう．そこで本論文ではクラス別に学習を行い，その結果を統合する方法を提案する．評価実験では，「細胞膜」，「細胞核」，「背景」を含むデータセットを用い，従来法である U-net と提案手法の精度比較を行った． Intersection over Union を用いた精度評価を行い，提案手法が従来法を上回ることを確認した．

キーワード：細胞画像，セグメンテーション，Deep Learning，クラス別学習，

1. はじめに

近年，人工知能技術の発達により様々な業界で人工知能による自動化が進められている．日本の医療分野では医療画像の解析や識別は研究者や医師による人的作業に頼ってきたが，人の負担が大きいことや人間の目では判断が難しいという問題がある．

そこで，本論文では画像から対象物体を解析，識別するために画像セグメンテーションを行う．物体認識の分野において，Convolutional Neural Network (CNN) [1]は高い精度を記録しており，ImageNet Large Scale Visual Recognition Challenge 2012[2]で CNN の再登場以降， CNN に基づく方法が主流となっている．画像セグメンテーションの分野では，画像をピクセル毎にクラス分けする必要があり，CNN のネットワーク構造を応用したものが多く見られる．Fully Convolutional Network(FCN)[3]は CNN を基にした画像セグメンテーション法である． SegNet[4] は Encoder 部分で VGG16[5]を用いた Encoder-Decoder CNN であり，車載画像からのセグメンテーションで高い有効性を示した．また，医療画像や細胞画像の分野でも画像セグメンテーションの応用が進み，医療画像に特化した構造[6,7,8]の有効性が確認されている．中でも U-net[7]は高い有効性を示しており，U-net をベースとした研究[9,10]は広く応用されている．

これら CNN に基づく画像セグメンテーションでは，専門家が識別対象となる部分をクラス分けしたものを正解画像とする．このとき，一枚の正解画像には複数の正解ラベルが含まれるのが普通である．しかし，一般に，識別するクラスが増えていくほどセグメンテ

a) Correspondence to: Matsuzuki Daisuke
e-mail: 140442123@ccalumni.meijo-u.ac.jp
*1 名城大学〔〒468-8502　愛知県名古屋市天白区塩釜口 1-501〕
*2 京都大学〔〒606-8501　京都府京都市左京区吉田近衛町〕

ーション精度は低下してしまう．そこで，本論文ではあるクラスとその他を識別するような学習を全クラスで独立に行い，その結果をさらに学習的に統合する方法を提案する．

実験では「細胞膜」と「細胞核」と「背景」に蛍光マーカーが発現するマウスの肝臓の専門家による正解付きの 50 枚の蛍光画像を使用した．従来法である U-net と提案手法の比較を行った結果，精度の向上を確認し，クラス別に学習してから統合することの有効性を示した．

本論文の構成は以下の通りである．まず，2 節で提案手法について述べる．次に，3 節で実験結果を示す．最後に結論として，まとめと今後の課題を 4 節で述べる．

2. 提案手法

従来は全クラスを一度に学習する方法であるが，本稿ではクラス別に学習を行い，その後，各クラスの結果を学習的に統合することにより，全クラスの結果を出力する方法を提案する．まず，提案手法では U-net[7]を複数用いることにより，各クラスとその他を識別するような学習を行い，それぞれ確率マップを出力する．その後，出力された確率マップを連結し，畳み込みを用いてそれらを統合してセグメンテーション結果を得るように学習する．図 1 に提案手法の概略図を示す．本論文では細胞画像データセットを使用し,「細胞膜」,「細胞核」,「背景」の全 3 クラスの内,「細胞膜」と「背景」を U-net1,「細胞核」と「背景」を U-net2 で学習し，それぞれ確率マップを得る．次に，得た確率マップを 1×1 および 3×3 の畳み込みを行い, それらの和により最終的な分類結果を得るように学習を行う．

提案手法で用いる U-net については 2.1 節で説明し，提案するクラス別学習に関する詳しい説明は 2.2 節で行う．

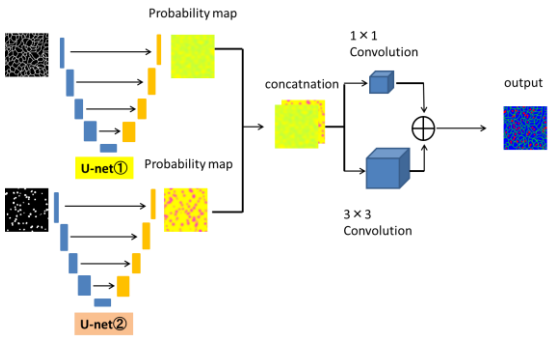

図 1 提案手法の概略図

2.1 U-net

CNN では畳み込み層が物体の局所的な特徴を抽出する役割を担い，プーリング層が物体の位置ズレに対応している．従って，深い層まで学習を行うと抽出される特徴の抽象度は高くなるが，対象の正確な位置や小さな対象の情報はしだいに失われてしまう．セグメンテーションのように画像の各画素を識別する必要がある場合は，このプーリング層で失われた情報を如何に復元するかが重要となる．これを解決したのが U-net である．

U-net は入力画像に対し，通常の CNN と同様に，畳み込みとプーリング層により深い層まで特徴を抽出する．次に，画像の解像度を上げる処理と畳み込みを行うことにより，入力画像と同じサイズのセグメンテーション結果を出力する．このようなネットワーク構造は Encoder-Decoder 構造と呼ばれる．U-net は Encoder 部と Decoder 部で同じ解像度の特徴マップを連結することにより，失われた位置情報や小さい対象の特徴を補正する．図 2 に本論文で用いた U-net の構造を示す．本稿では各解像度で 3×3 の畳み込みを 2 回行う．また, フィルタ枚数は 16 枚を初期値として解像度を下げる度に 2 倍にした．損失関数は画素毎にセグメンテーションの loss を算出できる Softmax cross entropy を採用した．

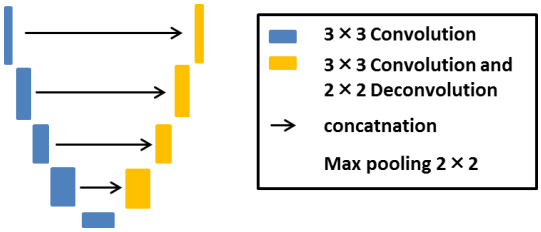

図 2 U-net 構造図

2.2 提案手法の詳細

提案手法は 2 つのステップに分類される. 1 つ目は，特定クラスとその他の学習を U-net を用いて全クラス数分行う．本論文では細胞データセットを使用した．細胞データセットでは「細胞膜」,「細胞核」,「背景」を含む 3 クラス識別を行うため，U-net を 2 つ用いて「細胞膜」と「背景」,「細胞核」と「背景」の 2 クラスを分類するように学習した．このとき U-net の出力を softmax 関数により確率として保存する．図 3 にクラス別に学習を行う概略図を示す.

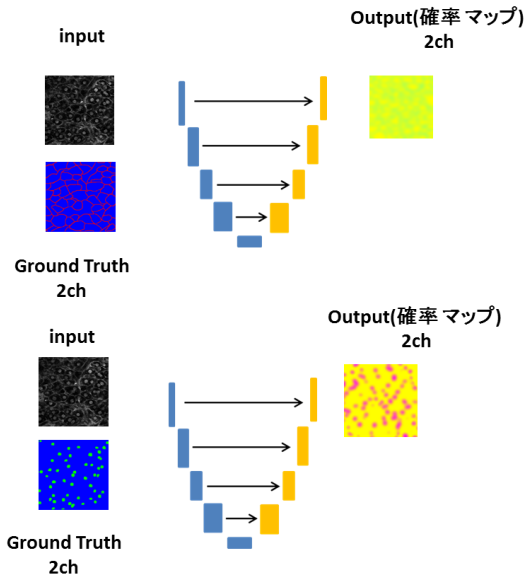

図 3 U-net によるクラス別学習

U-net により 2 つの確率マップが出力された後，畳み込みを行うことにより確率マップを統合し，最終的に分類したい 3 クラスの結果を得るように学習を行う．図 4 に統合部分の概略図を示す.

統合学習では，1×1 と 3×3 の畳み込みをそれぞれ行い，得られた結果を加算した．1×1 の畳み込みでは U-net で得られた確率間プを 1 画素単位で統合することになり，その画素でのクラス別学習の結果を強く反映したものになる．一方，3×3 の畳み込みでは入力となるクラス別学習の結果の確率マップから 3×3 の領域で重みづけ統合をするので，周辺の情報も利用したセグメンテーション結果が得られる．3×3 の畳み込みは，中心の 1 画素の識別結果が曖昧な場合に周辺から補正できる可能性がある. 最後に 1×1 の畳み込みの結果と 3×3 の畳み込みにより得られた特徴マップを加算する． 2 つの結果を加算することにより，場所毎にどちらかの統合法を重要視した識別が期待でき，その結果として識別精度が向上すると考えられる.

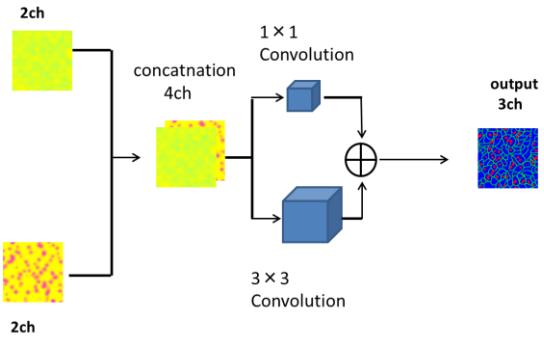

図 4 確率マップの統合学習

3. 評価実験

本節では細胞画像を用いた評価実験の結果を示す．3.1 節では使用したデータセットについて述べる．3.2 節では評価方法について説明し，3.3 節で評価結果を示す.

3.1 データセット

実験では京都大学松田研究室から頂いた細胞画像を用いる．これは顕微鏡により撮影された画像であり，「細胞膜」,「細胞核」,「背景」に蛍光マーカーが発現するマウスの肝臓の 50 枚の蛍光画像である. また画像サイズは最小 161×161 画素，最大 657×657 画素の不均一の画像サイズとなっている.

本実験では画像サイズを統一するために全50枚の画像を512×512画素にリサイズした．また，50枚のうち35枚を学習，5枚を検証，10枚をテスト用に分類し，またそこから左右90度ずつ回転および左右反転により，学習画像は280枚，検証画像は80枚，テスト画像を160枚とした．さらに学習時には，各エポックで128×128画素の領域をランダムに選択し，学習を行った．

3.2 評価方法

評価指標としてIntersection over Union(IoU)を採用した．IoUは画像の重なり率を指す指標であり，各クラスに対して画素毎に重なり率を導出するので，画像セグメンテーションにおいて適している．IoUは次のような式で表すことができる．

$$IoU = \frac{TP}{FP + FN - TP}$$

ここでFPはFalse Positive，FNはFalse Negative，TPはTrue Positiveを表す．

3.3 評価実験

評価実験では従来法であるU-netと提案するクラス別学習を比較する．表2に実験結果のIoUを示す．また，表1のMean IoUは各クラスのIoUの平均値である．

表2から分かるように，「細胞膜」，「細胞核」，「背景」及びMean IoUの全てにおいて従来手法であるU-netを越える数値を出すことができた．

表1 Mean IoU

	細胞膜 (%)	細胞核 (%)	背景 (%)	Mean (%)
U-net	33.32	59.39	66.81	53.17
提案手法	**33.82**	**60.59**	**67.62**	**53.91**

図5にU-netと提案手法による画像セグメンテーションの結果を示す．図5は左から入力画像，正解画像，U-netの結果，提案手法の結果である．また，図6に図5の結果の一部拡大画像を示す．図6の上の画像では提案手法が従来法のU-netのみによる学習に対し，細胞膜の形を正確に再現しようとしていることを示している．また，図6の下の画像では細胞核の誤検出に対応していることを示している．これはクラス別学習により，クラス毎の識別情報をうまく捕らえていることと，1×1と3×3の畳み込みの統合により，誤検出に対応できたと考えられる．

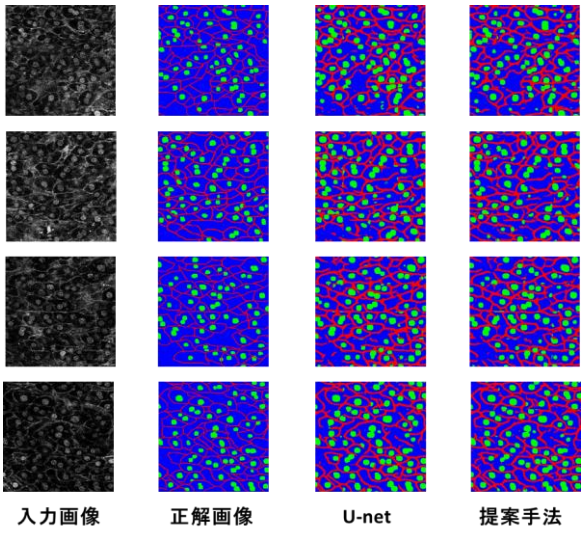

図5 セグメンテーション結果

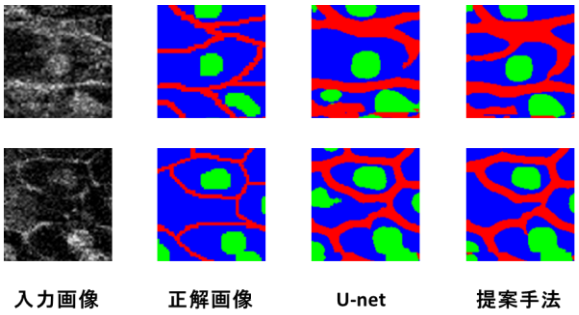

図6 結果の拡大図

4. おわりに

本論文ではクラス別の学習を行い，その結果を畳み込みにより学習的に統合する方法を提案した．その結果，従来法を上回るIoUが得られ，提案手法の有効性が確認できた．また，細胞膜の形の再現精度の向上と細胞核の誤検出の減少から，統合学習の有効性が確認できた．

しかし，セグメンテーションの精度としては未だ十分とは言えず，更なる精度の向上が

必要となる．現在はクラス別の学習を U-net のみで行っているが，U-net 以外の複数のモデルを使用して学習を行うことにより，扱う特徴量の種類が増え，統合が活かされるのではないかと考えている．

利益相反の有無

なし

文　献

［1］ LeCun,Y, Bottou,L, Bengio,Y, et al.: Gradient-Based Learning Applied to Document Recognition. Processing of the IEEE **86**: 2278-2324, 1998

［2］ Krizhevsky,A, Sutskever,I, Hinton.G,E.: ImageNet Classification with Deep Convolutional Neural Networks. Advances in Neural Information Processing Systems **25**: 1097-1105, 2012

［3］ Long,J, Shelhamer,E, Darrell,T.: Fully convolutional networks for semantic segmentation. Proc. IEEE Transactions on Pattern Analysis and Machine Intelligence **39**: 3431-3440, 2017

［4］ Badrinarayanan,V, Kendall,A, Cipolla R.: SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. IEEE Transactions on Pattern Analysis and Machine Intelligence **39**: 2481-2495, 2017

［5］ Simonyan,K, Zisserman,A.: Very Deep Convolutional Networks for Large-Scale Image Recognition. Computer Vision and Pattern Recognition**,** 2014

［6］ Milletari,F, Navab,N, Ahmadi,S,A.: V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation. In the International Conference on 3D Vision: 565-571, 2016

［7］ Ronneberger,O, Fischer,P, Brox,T.: U-Net: Convolutional Networks for Biomedical Image Segmentation. Proc. Medical Image Computing and Computer-Assisted Intervention: 234-241, 2015

［8］ Tseng, K,L, Lin,Y, Hsu,L, et al.: Joint Sequence Learning and Cross-Modality Convolution for 3D Biomedical Segmentation. IEEE Conference on Computer Vision and Pattern Recognition: 3739-3746, 2017

［9］ Chen,J, Yang,L, Zhang,Y, et al.: Combining Fully Convolutional and Recurrent Neural Networks for 3D Biomedical Image Segmentation. Advances in Neural Information Processing Systems: 3036-3044, 2016

［10］ Yuki,H, kazuhiro,H, Michiyuki,M, et al.: Cell Image Segmentation by Integrating Multiple CNNs. Computer Vision for Microscopy Image Analysis: 2018

著者紹介.

松月　大輔（まつづき　だいすけ）
平成 30 年 3 月名城大学理工学部卒業，平成 32 年同大学大学院博士前期課程修了予定．現在，細胞画像及び車載カメラ画像のセマンティックセグメンテーションの研究に従事

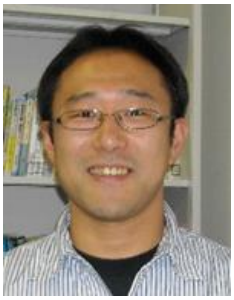

堀田　一弘　平成 9 年埼玉大学工学部卒．平成 11 年同大学院博士前期課程修了．平成 14 年同大学院博士後期課程修了．博士(工学)．平成 11 年~平成 14 年日本学術振興会特別研究員(DCI)．平成 14 年電気通信大学情報通信工学科助手，平成 19 年同大学助教，平成 22 年から名城大学理工学部電気電子工学科准教授．平成 30 年から同大学教授．平成 24 年メリーランド大学 Visiting Scholar．パターン認識，コンピュータビジョンの研究に従事．情報処理学会，映像情報メディア学会，IEEE Computer Society 各会員

平松　侑樹（ひらまつ　ゆうき）
平成 30 年 3 月名城大学理工学部卒業，平成 32 年同大学大学院博士前期課程修了予定．現在，複数ネットワークを用いた細胞画像のセマンティックセグメンテーションの研究に従事

松田　道行　1958 年生．1987 年 3 月東京大学大学院医学系研究科修了（医学博士）．同年，国立予防衛生研究所(現，感染症研究所)．2006 年京都大学大学院医学研究科教授，2007 年同生命科学研究科教授．蛍光顕微鏡を使った医学･生命科学研究に従事．

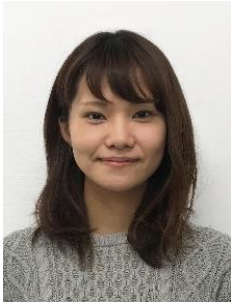

今西　彩子　平成 27 年大阪教育大学教育学部卒．平成 29 年京都大学大学院博士前期課程修了．現在同大学院博士後期課程にて「FRET マウスを用いた生体イメージング」に関わる多次元細胞解析のための新規トランスジェニックマウスの開発とその解析に従事．

寺井　健太　平成 14 年北海道大学医学部卒．平成 18 年大阪大学医学系研究科博士課程修了．博士(医学)．平成 18 年~平成 23 年バージニア大学 Research Associate．平成 23 年~平成 24 年国立循環器病センター研究所室員．平 成 24 年~平成 28 年東京大学分子細胞生物学研究所特任助教．平成 28 年~京都大学生命科学研究科准教授．光る生物学を模索中．

Cell Image Segmentation by Individual Class Learning

Daisuke Matsuzuki [*1], Kazuhiro Hotta [*1], Yuki Hiramatsu [*1], Michiyuki Matsuda [*2], Ayako Imanishi [*2], Kenta Terai [*2]

*1 Meijo University

*2 Kyoto University

In these days, automation of processing by artificial intelligence is progressed. In the field of cell biology, deep learning is used to segment objects in cell images. Generally, there are multiple classes in one image. When the number of classes increases or the appearance frequency changes, the segmentation accuracy decreases. Therefore, we propose to train individual classes, and the probability of each class is integrated by convolution automatically. In the experiment on segmentation of "cell membrane" and "cell nucleus", we compared the proposed method with the conventional U-net. By the evaluation using Intersection over Union, we confirmed that the proposed method outperformed the conventional method.

Key words: Cell image, Segmentation, Deep learning, Individual class learning

Automatic Segmentation of Tumors Using Z-score Image and Development of System for Cancer Therapy and Dose Measurement

Manami HAGA[*1], Takeshi HARA[*1], Satoshi ITO[*2],
Masaya KATO[*2], Masaki MATSUSAKO[*3], Xiangrong ZHOU[*1],
Tetsuro KATAFUCHI[*4], Hiroshi FUJITA[*1]

Abstract

Standardized Uptake Value (SUV) is a semi-quantitative measurement of FDG-PET. In FDG-PET examinations, a determination of therapeutic effect using Total Lesion Glycolysis (TLG) has been accepted in clinical situations. TLG is an indicator reflecting the degree of sugar metabolism and volume in tissue. The purpose of this study was to propose an automatic segmentation of tumors using Z-score image, which was obtained by the statistical image analysis, and to develop a computer-aided diagnostic system for cancer therapy and dose measurements. For the automatic segmentation of region of interest (ROI) around the lesions, we used CT images from PET/CT devices and applied our multiple organs segmentation method, which is based on a deep convolutional network approach. The organ and torso labels determined on the CT images were imposed on the PET image. The lesions on FDG-PET images were segmented based on the Z-score and SUV from FDG-PET image. Regions with small (<10 mm^3) or low SUV (<2.0 SUV) were eliminated as false-positives after the initial detection step. As a result of the performance evaluation for the detection scheme, 64.9% (124/191) of tumors in 34 cases were segmented correctly, but 38.4 false-positives per case were remained. Based on the automated detection results, the differences of volumes, SUVs, Z-scores and effective doses of lesions were annotated on the image. TLGs were also obtained from the two time different examinations of pre- and post-treatment FDG-PET/CT images.

Keywords：PET,CAD,SUV,Z-score

1. Purpose

The purpose of this study was to automatically segment tumors using a Z-score image and to develop a computer-aided diagnostic system for cancer therapy and dose measurements. In this study, we used 34 abnormal cases. These cases include tumors in lungs, liver and abdomen.

*1 Graduate School of Natural Science and Technology, Gifu University
〔1-1 Yanagido, Gifu, Gifu 501-1193, Japan〕
e-mail: manami@fjt.info.gifu-u.ac.jp
*2 Department of Radiology, Daiyukai General Hospital
*3 Department of Radiology, St. Luke's International Hospital
*4 Faculty of Health Science, Gifu University of Medical Science

2. Method

For the automatic segmentation of region of interest (ROI) around the lesions, we used CT images and applied the multiple organs segmentation method developed in our laboratory, which is based on a deep convolutional network approach [1]. Furthermore, we created torso label. For creating torso label, we set the threshold at 500 for CT value and binarized the CT image. After that, we deleted head, arms and legs area of the label. The shape information of organs was imposed on the PET image using generated organ and torso labels. Next, we automatically segmented tumors using Z-score image. Z-score is an index of statistical likelihood of abnormality of each pixel [2]. For creating a Z-score image, a normal model is created from the normal data group, and an average image and a standard deviation image of the normal model are created. Further, Z-score is calculated using the equation (1).

$$\mathrm{Z-score(x,y,z)} = \frac{deformedSUV(x,y,z) - mean(x,y,z)}{standerd\ deviation(x,y,z)} \qquad (1)$$

Next, we binarized the Z-score image and the PET image and labeling. We set the threshold at 1.5 for Z-score and SUV. Final, to delete false positives (FPs), FP regions was defined as areas of small (<10 mm^3) or low SUV (<2.0 SUV). We also deleted areas overlapping the heart, kidneys and bladder labels.

Based on the automated detection results, the differences of volumes, SUVs, Z-scores and effective doses of lesions were annotated on the image. The total lesion glycolysis (TLG) was also obtained from the detected regions. TLG is an indicator reflecting the degree of sugar metabolism and volume [3]. TLG is calculated based on maximum value of SUV (SUVmax). Furthermore, the therapeutic effect was determined by the rate of change in TLG.

3. Results

It was found that 64.9% (124/191) of tumors in 34 cases were segmented correctly. However, 38.4 FPs were reminded per case. The segmentation rate of each organ was 82.1% (32/28) in lungs, 19.2% (5/26) in liver and 70.0% (96/137) in abdomen. Fig.1 shows an example of beneficial case. We segmented tumors with appropriate size. On the other hand, there were cases in which the segmentation region included physiological accumulation. We could not segment tumors with low SUV. Physiological accumulation of bladder and intestine was liable to FP.

We developed a system for cancer therapy and dose measurement. Fig.2 shows an example of computerized system. The system can provide pre- and post-treatment PET/CT images, a difference SUV image and a difference Z-score image. Segmented tumor labels are also displayed in color on the PET image and the measured metabolic volume, TLG and the effective dose are also display.

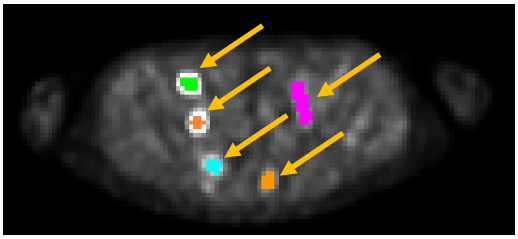

Fig.1 True-positive of abdomen

Fig.2 System viewer

4. Conclusion

In the automatic tumor segmentation method, 64.9% of tumors were segmented correctly but 38.4 FPs were reminded per case. The computerized system can provide the pre- and post-treatment PET/CT images and the measured MV, TLG, and effective dose value.

Acknowledgment

The authors thank members of the Fujita Lab. In Gifu University for their valuable discussions.

This study was supported in part by new academic research area (26108005) by the Ministry of Education, Culture, Sports, Science and Technology (MEXT).

References

[1] Zhou X, Takayama R, Wang S et al: Deep learning of the sectional appearances of 3D CT images for anatomical structure segmentation based on an FCN voting method. Medical Physics **44**: 5221-5233, 2017

[2] Takeda K, Hara T, Zhou X et al: Normal model construction for statistical image analysis of torso FDG-PET images based on anatomical standardization by CT images from FDG-PET/CT devices. International Journal of Computer Assisted Radiology and Surgery **15**: 777-787, 2017

[3] Kiyohara S, Nagamachi S, Wakamatsu H et al: Usefulness of Metabolic Volume and Total Lesion Glycolysis for Predicting Therapeutic Response in Cancer Therapy by ^{18}F-FDG PET/CT. 核医学 **47**: 453-461, 2010

3 次元 CT 画像を用いた じん肺の重症度診断基準の定量的評価

日野 公貴[*1]　松廣 幹雄[*2]　鈴木 秀宣[*2]　河田 佳樹[*2]　仁木 登[*2]
加藤 勝也[*3]　岸本 卓巳[*4]　芦澤 和人[*5]

要旨

じん肺は，粉じんを肺に吸入することによって生じる職業性呼吸器疾患である．我国において毎年 24 万人前後の粉じん労働者がじん肺健康診断を受診している．じん肺診断では胸部単純 X 線写真を用いているが近年では CT 画像を用いた定量的な診断法が検討されている。本報告では，じん肺 CT 画像の第 0 型 0/1，第 1 型 1/0，第 1 型 1/1，第 1 型 1/2，第 2 型 2/2 から 2 回のマニュアル処理と自動処理で粒状影を抽出し．じん肺 CT 画像データベースを作成する．このデータベースを用いて X 線写真の診断結果と粒状影の個数・大きさ・重症度別に解析・比較・評価を行う．

キーワード：CT，CAD，医用画像処理

1. はじめに

じん肺は，粉じんを肺に吸入することによって生じる職業性呼吸器疾患である。日本の粉じん作業従事労働者数は昭和 60 年をピークに減少し，平成 12 年で 35 万人であったが，近年は約 50 万人前後で推移しており増加傾向となっている．じん肺が進行すると肺結核・続発性気胸・肺がんなどの合併症に罹患しやすくなるため，健康診断で適切な診断・治療が必要である．

また，じん肺健康診断として胸部単純 X 線撮影や肺機能検査が実施されている．胸部単純 X 線写真によって第 0 型，第 1 型，第 2 型，第 3 型，第 4 型に分類され，第 1 型以上の患者は労災認定となるが第 0 型の患者は労災認定の対象とならないため正確に診断しなければならない．ここで，近年では胸部 CT 検査による定量的な診断法が検討されている．本報告では，じん肺 CT 画像の第 0 型 0/1，第 1 型 1/0，第 1 型 1/1，第 1 型 1/2，第 2 型 2/2 から 2 回のマニュアル処理と自動処理で粒状影を抽出し．じん肺 CT 画像データベースを作成する．このデータベースを用いて X 線写真の診断結果と粒状影の個数・大きさ・重症度別に解析・比較・評価を行う．

2. 撮影条件と手法

岡山ろうさい病院で診断されたじん肺 25 症例(0/1－5 例，1/0－5 例，1/1－5 例，1/2－5 例，2/2－5 例)を用いた．撮影条件を表 1 に示し，症例別の職業歴を表 2 に示す．これらの CT 画像に(1)粒状影のマニュアル抽出，(2) CAD を用いた結節の自動抽出，(3)粒状影の定量評価を適用した．

*1 徳島大学大学院先端技術科学教育部
〔〒770-8502 徳島県徳島市南常三島町 2-1〕
e-mail: c501738006@tokushima-u.ac.jp
*2 徳島大学大学院社会産業理工学研究部
*3 川崎医科大学
*4 岡山ろうさい病院
*5 長崎大学

表 1　撮影条件

装置	Aquilion PRIME
管電圧[kV]	120
管電流[mA]	240
スライス厚[mm]	1.0
画素間隔[mm]	0.625 , 0.781
再構成間隔[mm]	1.0
再構成関数	FC13-H,FC52

表 2　型区分と職業歴

病型区分	職業歴
第 0 型　0/1	窯業　3 症例 船舶製造業　1 症例 随道掘削　1 症例
第 1 型　1/0	窯業　5 症例
第 1 型　1/1	建設業　2 症例 採石業　2 症例 船舶製造業　1 症例
第 1 型　1/2	窯業　3 症例 セメント製造業　1 症例 採石業　1 症例
第 2 型　2/2	採石業　4 症例 採鉱業　1 症例

(1) 粒状影のマニュアル抽出

粒状影のマニュアル抽出は，WL500，WW1500 で設定し Axial 面で抽出する．右肺尖部，右肺底部，左肺尖部，左肺底部の順で抽出し，抽出は 2 回行い 1 回目と 2 回目の読影間隔は半年以上と 1 週間を置いた．1 回目と 2 回目の論理和をマニュアル抽出結果とする．

(2) CAD を用いた結節の自動抽出

本研究室で開発されている CAD の結節自動抽出結果とマニュアル抽出結果を重ね合わせ新たに見直し，未抽出の粒状影があればじん肺 CT 画像データベースに追加する．

(3) 粒状影の定量評価

粒状影が球であると仮定して，粒状影の大きさは体積から求められる直径で定義する．そして，じん肺の重症度を粒状影の個数，大きさ，体積によって評価する．

3. 結果

第 0 型 0/1 と第 1 型 1/0 の粒状影の抽出結果例を図 1 に示す．粒状影数を見ると診断結果と一致しない症例があった．図 2 に粒状影の直径と累積頻度の関係を示す．重症度に関わらず直径 3mm 以上の粒状影では指数関数的に数が増加しているが 3mm 以下になると緩やかになる傾向が見られた．

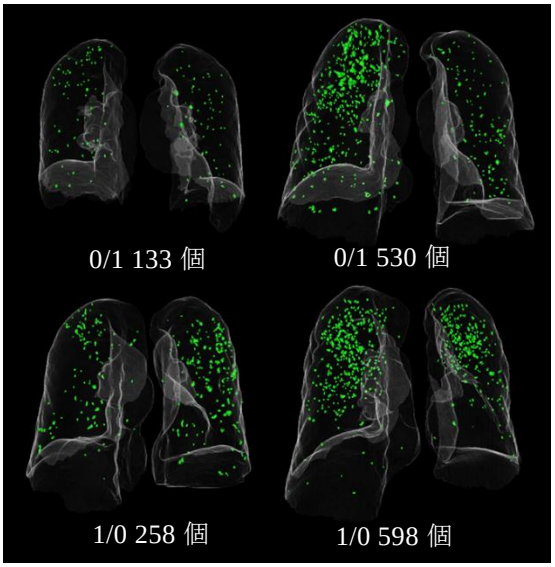

図 1　粒状影の抽出結果

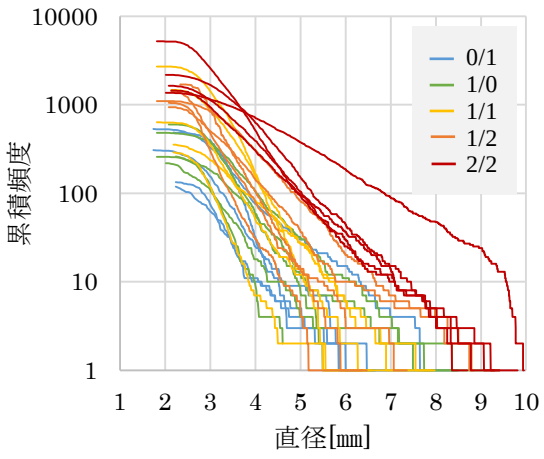

図 2　粒状影の直径と累積頻度

図 3 に X 線写真によって第 0 型 0/1，第 1 型 1/0 と診断された症例と CT 画像による定量評価結果（粒状影数）に基づいて第 0 型 0/1（CT），第 1 型 1/0（CT）と診断された症例について重症度別で平均粒状影数と標準偏差を求めた結果を示す．また，Mann-Whitney U 検定をそれぞれの診断結果に対して行った結果 X 線写真の診断結果では有意差はみられなかったが，CT 画像の定量評価結果に基づく診断結果では有意差が認められた．

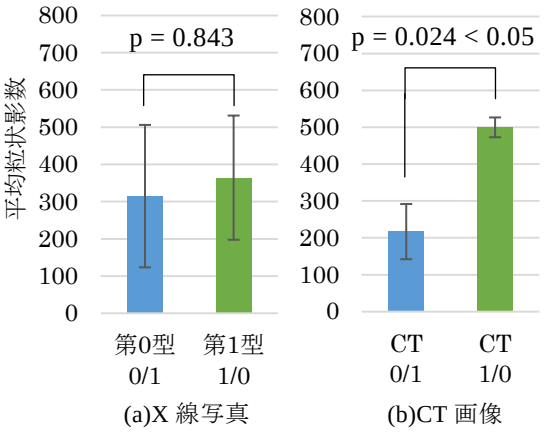

図 3　X 線写真の診断結果と CT 画像を用いた診断結果の評価

4. まとめ

じん肺 CT 画像から粒状影を抽出し，粒状影の定量評価を行った．CT 画像を用いた定量評価結果を提示することにより，より正確にじん肺の重症度を分類することが可能となり，診断精度の向上が期待できる．今後の課題として多症例に適用し，より正確なじん肺 CT 画像データベースの作成と高精度な粒状影自動抽出法について検討する．

利益相反の有無

なし

文　献

[1] H. Suzuki, Y. Kawata, N. Niki, et al: Computer aided diagnosis for severity assessment of pneumoconiosis using CT images, Proc. SPIE Medical Imaging, Vol.9785, pp.978531-1-6, 2016.

[2] K. Kanazawa, Y. Kawata, N. Niki, et al: Computer-aided diagnosis for pulmonary nodules based on helical CT images, Comput. Med. Imag. Graphics, vol. 22, no. 2, pp. 157–167, 1998.

[3] Y. Kawata, N. Niki, H. Ohmatsu, et al: Quantitative classification based on CT histogram analysis of non-small cell lung cancer: Correlation with histopathological characteristics and recurrence-free survival, Medical Physics, vol.39, no.2, pp.988-1000, 2012.

[4] 松廣幹雄，鈴木秀宣，河田佳樹，他：胸部マルチスライス CT 画像における葉間裂抽出法，電子情報通信学会論文誌，Vol.J.96-D，no.4，pp.834-843，April，2013.

[5] 滝島任，中村雅夫，千代谷慶三：じん肺患者の呼吸機能検査ハンドブック．真興交易医書出版部，1991，P3-10

[6] 永井厚志編：呼吸器疾患　第 3 版．日本医事新報社，2015，P241-250

[7] K. Hino, M. Matsuhiro, H. Suzuki, et al: Quantitative assessment for pneumoconiosis severity diagnosis using 3D CT images, Proc. SPIE Medical Imaging, Vol.10575, pp.105753J-1-6, 2018.

Quantitative assessment for pneumoconiosis severity diagnosis using 3D CT images

Koki Hino[*1], Mikio Matsuhiro[*2], Hidenobu Suzuki[*2],Yoshiki Kawata[*2],Noboru Niki[*2]
Katsuya Kato [*3], Takumi Kishimoto [*4] , Kazuto Ashizawa [*5]

*1 System Innovation Engineering Graduate School of Advanced Technology and Science The University of Tokushima
*2 Tokushima University
*3 Kawasaki Medical School
*4 Okayama Rosai Hospital
*5 Nagasaki University

Pneumoconiosis is an occupational respiratory illness that occur by inhaling dust to the lungs. 240,000 participants are screened for diagnosis of pneumoconiosis every year in Japan. Radiograph is used for staging of severity rate in pneumoconiosis worldwide. CT imaging is useful for the differentiation of requirements for industrial accident approval because it can detect small lesions in comparison with radiograph. In this paper, we extracted lung nodules from 3D pneumoconiosis CT images by two manual processes and automatic process, and created a database of pneumoconiosis CT images. We used the database to analyze, compare, and evaluate visual diagnostic results of radiographs and quantitative assessment (number, size and volume) of lung nodules. This method was applied to twenty five pneumoconiosis patients. Initial results showed that the proposed method can assess severity rate in pneumoconiosis quantitatively. This study demonstrates effectiveness on diagnosis and prognosis of pneumoconiosis in CT screening.

Key words: X-ray image, CT, Medical image processing

Automatic nodule detection in chest CT images using HoTPiG image features

Shouhei Hanaoka[*1], Yukihiro Nomura[*2], Tomomi Takenaga[*2], Masaki Murata[*2], Takahiro Nakao[*3], Soichiro Miki[*2], Takeharu Yoshikawa[*2], Naoto Hayashi[*2], Osamu Abe[*1], Akinobu Shimizu[*4]

Abstract

We have developed a novel image feature set named HoTPiG (histogram of triangular paths in graph) which can extract features of bifurcating structures such as blood vessels. It has been proven that the HoTPiG feature set is useful in detecting cerebral aneurysm in MRI images. In this study, we applied HoTPiG to detect lung nodules in chest CT datasets. Firstly, the lung fields are extracted automatically. Then, the nodules and lung vessels are jointly extracted by a simple filtering and thresholding so that the nodules and vessels are extracted as a binary volume. Using this binary volume, HoTPiG image feature set is calculated for each voxel. After that, a linear-SVM-based classifier is applied and lung nodules are detected. The proposed method was tested with 300 datasets and showed the sensitivity of 80% where the false positives are three per case.

Keywords：HoTPIG, lung CT, Nodule detection, computer-aided detection

1. Purpose

HoTPiG is an image feature set which is based on 3-D histogram of triangular paths in the given graph structure. Usually it is calculated from a given 3-D binary image and one feature vector is defined at each point (voxel) in the foreground region. In our previous study [1], HoTPiG was applied to cerebral aneurysm detection task in MR angiography datasets. Protruding structures (aneurysms) within the cerebral artery network were successfully detected by HoTPiG.

The purpose of this study is to detect lung nodules in lung CT datasets. Our hypothesis is that HoTPiG can discriminate the bifurcation of vessels and true lung nodules with sufficient accuracy. We use both of HoTPiG features and classic image features (shape index and dot-enhancing filters [2]), which are expected to work complementarily.

2. Method

The proposed method is composed of five components: 1) lung field extraction, 2) foreground mask

*1 Dept. of Radiology, Univ. of Tokyo Hospital
〔7-3-1 Hongo, Bunkyo-ku, Tokyo 113-8655, Japan〕
e-mail: hanaoka-tky@umin.ac.jp
*2 Dept. of Computational Diagnostic Radiology and Preventive Medicine, Univ. of Tokyo Hosptial
*3 Radiology and Biomedical Engineering, Graduate School of Medicine, University of Tokyo
*4 Institute of Engineering, Tokyo University of Agriculture and Technology

extraction, 3) HoTPiG feature calculation, 4) shape index and dot enhancement filter calculation, 5) voxel-based linear SVM classifier. The details of four components, as well as the experimental settings, are described below.

1) Lung field extraction

Firstly, the given volume is resampled by tricubic interpolation so that the voxel size becomes $1.0 \times 1.0 \times 1.0$ mm. The method for extracting the bilateral lung fields is the same as in our previous method [3]. As the result, the lung fields are extracted as 3-D binary volumes. The following calculation is performed only in these volumes. Also,

2) Foreground mask extraction

At first, the inhomogeneity of the CT values in the lung fields is compensated by applying the following filter:

$$I_{new}(\mathbf{x}) = I(\mathbf{x}) - \frac{I(\mathbf{x}) \otimes G_\sigma}{b_{mask}(\mathbf{x}) \otimes G_\sigma}, \qquad (1)$$

where I is the original image function (i.e. the grayscale value at the point $\mathbf{x}$), $b_{mask}(\mathbf{x})$ is a binary function which becomes 1 in the lung field, and G_σ is a Gaussian filter with $\sigma = 5.0$ voxels. Then, the foreground regions are extracted by a simple region growing method with the seed value of 100 HU and the threshold value of 50 HU.

3) HoTPiG feature extraction

The detail of HoTPiG feature extraction is described in [1]. In short, firstly the graph structure is built as a 26-neighborhood connection of the foreground voxels. Then, for each foreground voxel and for any pair of neighbor foreground voxels, the step lengths of the triangular paths (formed by the three foreground voxels) are enumerated and counted as 3-D histograms. Finally the bin counts of 3-D histograms are used as HoTPiG image feature vector.

4) Shape index and dot enhancement filter calculation

Apart from HoTPiG, two grayscale-based features are also calculated for each foreground voxel. The detail is available in [2]. Here, a multiresolutional approach is applied and total 10 features are extracted for each voxel.

5) Voxel-based linear SVM classifier

After feature vector calculation, each voxel is judged as positive (i.e. nodule) or negative by linear SVM classifier. Before application of SVM, we applied an explicit feature mapping technique [1] with an exponential-χ^2 kernel to the HoTPiG feature set. In the same manner, the explicit feature mapping technique with Gaussian kernel is also applied to grayscale-based features. These feature mappings allows the following linear SVM to work as the same as a kernel trick-based nonlinear SVM with low calculation cost.

Then, in the training phase, a linear SVM classifier is trained using the training datasets. Due to memory limitation, only 0.5% of all foreground voxels in the training datasets were used. In the test phase, the trained SVM classifier classifies all the foreground voxels in the given test volume.

After the voxel-wise classification, the classifier outputs are binarized with the threshold of 0, and then connective component analysis is applied. Finally, each connective component is outputted as a nodule candidate and its likelihood is determined as the maximal value of classifier outputs of voxels in the region.

6) Experimental settings

The proposed method was evaluated using 300 chest CT datasets. The original slice thickness is 1.25 mm. We used a three-fold cross-validation method. The ground truth nodule regions (greater than 5 mm in

diameter) were manually inputted by medical experts. Each nodule detection was judged as true positive if and only if the following criteria is satisfied; the distance between the detected point (e.g., the point where the classifier output becomes maximum) and the gravity center of the manually-inputted ground truth region is less than 0.75 × the diameter (along the longest axis) of the ground truth region. The detection successful rate was evaluated and an FROC (free-response receiver operative characteristic) curve was calculated.

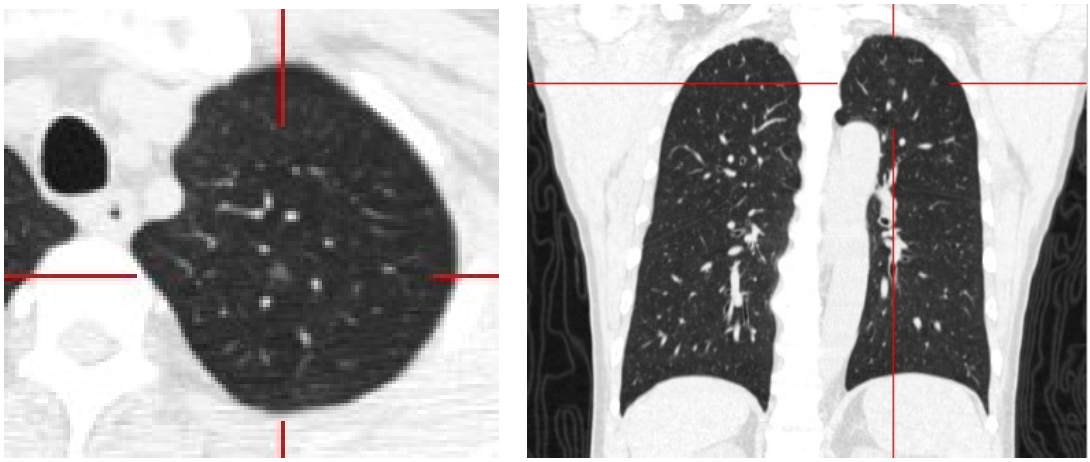

Fig. 1 Example of detection results.

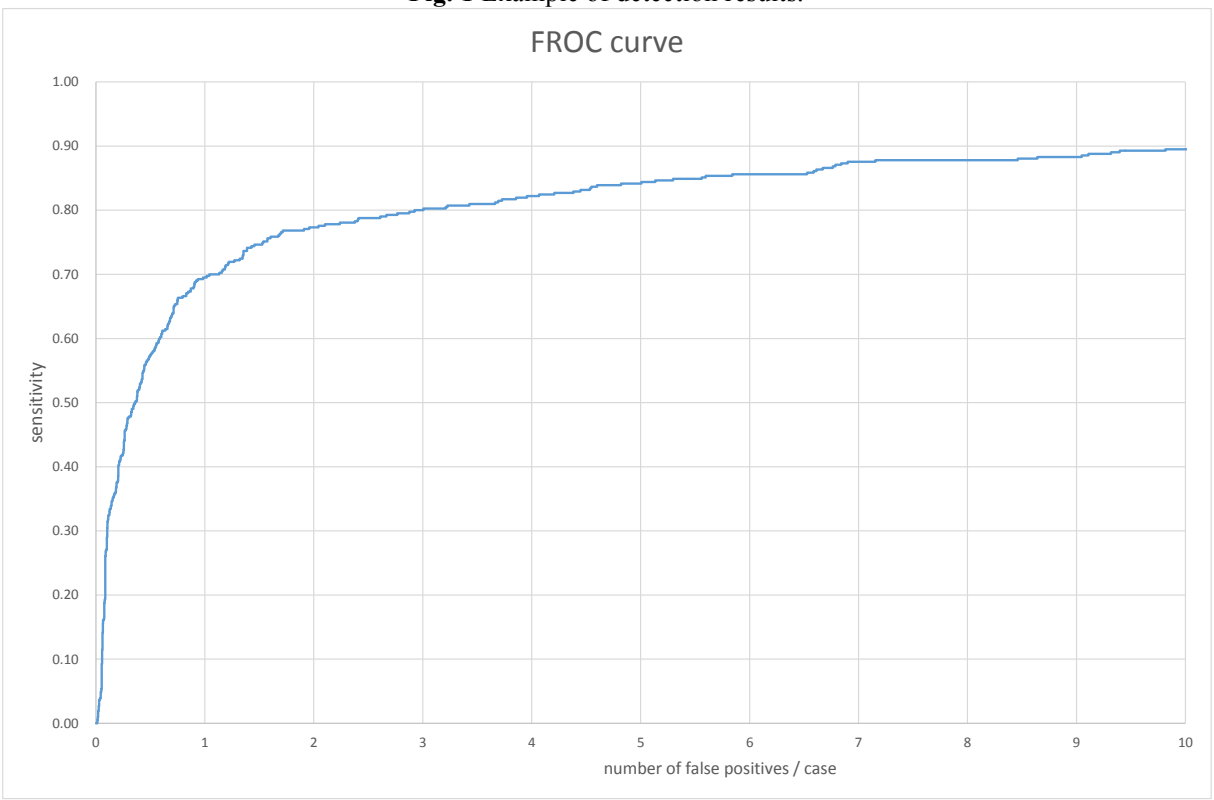

Fig. 2 FROC curve of the lung nodule detection result.

3. Results

An example of detection result is shown in Fig. 1. The FROC curve is shown in Fig. 2. As shown, our system achieved the sensitivity of 80% where the false positive rate was 3 per case.

4. Conclusion

A method for lung nodule detection using HoTPiG image features was presented. Although the accuracy was not as high as those of recent methods based on deep convolutional neural networks [4], it was almost the same compared to the other image feature-based methods such as [2] and [6]. Therefore, we believe that HoTPiG image feature set is effective in detecting nodule-like lesions and in discriminating nodules and vessel bifurcations.

Acknowledgement

This work was supported in part by JSPS KAKENHI Grant Number 17H05282, 15K19775 and 18K12095. All authors have no conflict of interest.

References

[1] Hanaoka S, Nomura Y, Nemoto M et al: HoTPiG: A Novel Geometrical Feature for Vessel Morphometry and Its Application to Cerebral Aneurysm Detection. In: Navab N, Hornegger J, Wells WM, Frangi A (eds) Medical Image Computing and Computer-Assisted Intervention -- MICCAI 2015, Cham, 2015. Springer International Publishing, pp 103-110

[2] Li Q, Li F, Doi K: Computerized detection of lung nodules in thin-section CT images by use of selective enhancement filters and an automated rule-based classifier. Acad Radiol. 2008 Feb;15(2):165-75. doi: 10.1016/j.acra.2007.09.018.

[3] Nomura Y, Nemotl M, Masutani Y et al: Reduction of false positives at vessel bifurcations in computerized detection of lung nodules. Journal of Biomedical Graphics and Computing Vol. 4, No, 3: 36-46, 2014

[4] https://luna16.grand-challenge.org/results/

[5] Teramoto A, Fujita H: Fast lung nodule detection in chest CT images using cylindrical nodule-enhancement filter. International journal of computer assisted radiology and surgery 8 (2):193-205, 2013.

CNNによる胸部CT画像からの経時的差分画像上の異常陰影の検出

長尾　充朗 [*1], 植村　知規 [*1], 三宅　徳朗[*1], 陸　慧敏 [*1], タン　ジュークイ [*1], 金　亨燮 [*1], 村上　誠一 [*2], 青木　隆敏 [*2], 平野　靖 [*3], 木戸　尚治 [*3]

要旨

近年，医療分野における画像診断はCTなどの技術の進歩に伴い，診断性能が格段と向上しているが，被験者一人あたりの画像枚数も増加している．このことから医師への負担軽減等を目的としたCADシステムの開発が進んでいる．一方，日本の平成28年度がんの部位別死亡者数において，肺がんは男女計で第1位を示しており，早期発見・早期治療が重要であると考えられる．また近年，機械学習の分野において注目を浴びているものに，深層学習がある．これは，多量の学習データを入力として与え，未知データからのパターン識別が可能で，人手の介在が少ないという利点がある．そこで本論文では，深層学習による胸部CT画像からの異常陰影の検出法を提案する．主な処理の流れとしては，経時的差分像技術による正常構造の除去を行い，差分像上の残った領域に対し，CNNによる識別を行う．提案法を25症例の同一被験者で構成される過去・現在画像に適用し，TPR:98.41[%]，FP:9.23[/case]，AUC:0.974という結果を得た．

キーワード：CAD，経時的差分画像，深層学習，CNN

1. はじめに

現在，日本におけるがんは年間の死亡者数において死因第1位となっている[1]．その中でも肺がんは，がんの部位別死亡者数において男性で第1位，女性で第2位を示している[2]．さらに，術後の5年実測生存率[3]において，病期が第Ⅰ期は83.8[%]，第Ⅱ期は50.1[%]，第Ⅲ期は22.4[%]，第Ⅳ期は4.8[%]を示している．そのため，早期発見・早期治療が必要であると考えられる．

一方，コンピュータ断層法(CT；Computed Tomography)などのディジタル画像技術の進歩やそれに伴う診断技術が向上している．しかし，これらの技術の発展に伴い，被験者一人当たりの画像枚数が増加し，医師の負担が大きくなる問題が生じている．また，医師の経験の差による未検出も問題となっている．そのため，医師の負担軽減や病変部検出精度の向上を目的としたコンピュータ支援診断(CAD；Computer Aided Diagnosis)システムへの期待が高まっている．CADシステムとは，コンピュータにより医用画像を処理・解析し，病変部の検出や検出された病変部の鑑別などを行うシステムで，医師が“第2の意見”として利用し診断することを目的としている．

胸部CT画像における異常陰影は，結節状陰影(Nodule)とすりガラス状陰影(GGO；Ground Glass Opacity)などがある．それぞれの陰影を検

*1 九州工業大学
〔〒804-8550 福岡県北九州市戸畑区仙水町1-1〕
*2 産業医科大学
〔〒807-8556 福岡県北九州市八幡西区医生ケ丘1-1〕
*3 山口大学
〔〒753-8511 山口県宇部市常盤台 2-16-1〕

出する方法は存在するが，両方を同時に抽出するのは困難であると考えられる．そこで，これらの病変を効率的に解析するため，経時的差分像技術[4]を用いる研究が行われている．経時的差分像技術とは，現在画像から過去画像を差分演算する技術のことで，血管などの正常構造を除去しつつ異常陰影などの変化があるものを強調することができる手法である．それにより，Nodule と GGO 両者をより高精度で抽出できると考えられる．

ところで近年，人工知能分野において深層学習(Deep Learning)[5]技術が注目されている．これは，教師なしニューラルネットワークを多層につなげたもので，学習・識別を行う手法である．特徴の設計をコンピュータが自動で行うため，客観性が保たれるという特徴がある．また，複雑な多クラス分類も行える．そのため本論文では，識別器として Deep Leaning 技術を用いる．すなわち，経時的差分画像上の初期候補から，最終的な異常陰影を検出するための画像処理手法の開発を行う．しかし，胸部 CT 画像上に残る陰影の多くが正常陰影となるため，入力画像が正常陰影に偏ってしまう可能性が高い．そのため，機械学習による識別結果も正常陰影に偏り，異常陰影の学習をうまく行えないという問題がある．そこで，本論文では段階的に深層畳み込みニューラルネットワーク(DCNN ; Deep Convolutional Neural Network)を用いることにより，学習データの偏りをなくし，そのデータセットを用いて最終識別を行う．

以上のことから本論文では，胸部 CT 画像からの異常陰影の自動検出法を提案する．手法としては，原画像から肺野領域を抽出し，経時的差分像技術を用いた初期候補陰影を決定する．次に，初期候補陰影を対象に，識別器を用い，Abnormal と Normal の 2 クラス分類を行う．本論文では，識別器に DCNN を用いる．提案手法を胸部 CT 画像 25 症例に適用し，識別器による分類を行い，その有用性を検証する．

2. 手法

本論文では，経時的差分像技術を用いた差分像生成後，多重閾値処理による初期候補陰影の決定を行い，最終的に DCNN による識別を行う．

2. 1 経時的差分技術[6-8]

胸部 CAD システムの開発および研究報告は数多く存在する．その中で経時的差分技術を用いた CAD システムの場合，画像読影の効率化や経時的変化を見ることができることから，良性・悪性の鑑別や経過観察などに応用可能である．

経時的差分画像の作成の流れは，画像前処理後に現在画像と過去画像を(ⅰ) Global Matching, (ⅱ) Local Matching，(ⅲ) 3-D Elastic Matching, (ⅳ)初期異常陰影の検出，そして(ⅴ) Voxel Matching により位置合わせを行う手法である．それぞれの手法について簡単に述べる．

(ⅰ)Global Matching

同一被験者の過去および現在画像に対し，肺野領域を剛体とみなし，その重心を用いた剛体位置合わせを行う．

(ⅱ)Local Matching

まず GGVF[6-8]を適用し，ベクトル場を形成する．GGVF とは，エッジマップの性質を保ちながらエッジから離れた位置や均質な領域にも勾配の影響を伝播する手法である．この GGVF のベクトル集中度を用い，シフトベクトルを算出する．

(ⅲ)3-D Elastic Matching[6-8]

隣り合う位置合わせ点のシフトベクトルは互いに整合が保たれる必要がある．そこで次式のエネルギー関数を最小化するようにシフトベクトルを逐次的に更新する．

$$E = \sum_{x \in V} \left(E_{int}(x) + E_{ext}(x) \right) \qquad (1)$$

ただし，V は位置合わせ点の集合である．また，E_{int}，E_{ext}はそれぞれ内部，外部エネルギーを表している．また，シフトベクトル$u(x)$とすると内部エネルギーは，以下の式となる．

$$E_{int} = \omega_1 \sqrt{\left|\frac{\partial u}{\partial x}\right|^2 + \left|\frac{\partial u}{\partial y}\right|^2 + \left|\frac{\partial u}{\partial z}\right|^2} + \omega_2 \sqrt{\left|\frac{\partial^2 u}{\partial x^2}\right| + \left|\frac{\partial^2 u}{\partial x^2}\right| + \left|\frac{\partial^2 u}{\partial x^2}\right|} \quad (2)$$

ただし，ω_1, ω_2は定数である．なお，内部エネルギーはシフトベクトルの空間の変化量の大きさに相当し，シフトベクトルの滑らかさにおける制約項となる．また，外部エネルギーはGGVFのベクトル集中度における相互相関値の負値で与えられる．つまり，画像間の類似度を表している．

(ⅳ)初期異常陰影の検出

初期異常陰影の検出を行う．これは，(ⅴ)の位置合わせの際に，淡い陰影が消滅することがあるため，初期陰影の消滅を回避し，陰影候補領域を残すことを目的に，(a)Iris Filter，(b)Super Voxel，(c)Graph Cut，(d)SVMによる領域選定を行う．それぞれについて簡単に説明する．

(a)Iris Filter[9]

このフィルタは球形フィルタとなっており，中心からN本の放射状に探索を行う．それぞれの点における中心からの位置ベクトルと勾配ベクトルのなす角の平均余弦値をこのフィルタの出力とする．いかにその式を示す．

$$c(x) = \frac{1}{N}\sum_{i=1}^{N} c_i \qquad c_i = \max_{0 \le l \le L} < \cos\theta(y) >_{R_i} \quad (3)$$

ただし，l は中心を原点としたときに放射状に探索している位置，L はフィルタの半径を表しており，放射状の探索する最大長を表す．また，<・>は放射状に探索している線R_iの集中度の平均値を表し，cosθはフィルタの中心からの位置ベクトルと勾配ベクトルのなす角の余弦値とする．このフィルタの出力に対して閾値処理を施すことにより，血管構造の除去を行う．

(b)Super Voxel[10]

格子状のvoxelでは，処理(c)において境界線があいまいになる場合があるため，周辺濃度情報を加味した本手法を用いる．Super VoxelはSLIC(Simple Linear Interactive Clustering)[10]を用いて作成する．本論文では評価式として以下の式を用いる．

$$D = \sqrt{\left(\frac{d_c}{m}\right)^2 + \left(\frac{d_S}{S}\right)^2 + \left(\frac{d_{con}}{C}\right)^2} \quad (4)$$

ただし，m ，S ，C はそれぞれ d_c，d_S，d_{con} の最大値を表す．また，d_{con} は各領域における Iris Filter の出力を表し，d_c，d_S は

$$d_c = \sqrt{(l_j - l_i)^2 + (a_j - a_i)^2 + (b_j - b_i)^2} \qquad d_S = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2 + (z_j - z_i)^2} \quad (5)$$

と表される．ただし，l，a，b はL*a*b表色系で表したものであり，x，y，z 座標の位置を表す．

(c)Graph Cut[11]

本論文では，Super Voxelに対してBvoykovらのアルゴリズム[11]による領域抽出を行う．

(d)SVM[12]

本論文では，病変部位候補を絞るために(c)の手法によって抽出した陰影に対し，SVMによる識別を行う．本論文で用いた特徴量は標準偏差，球形度，最大4位平均値，細長さそして最大ベクトル集中度の5つを用いた．これにより，病変候補とみなした領域以外の部位に対して(ⅴ)の処理を行う．

(ⅴ) Voxel-Matching[6-8]

上記(ⅳ)の処理後に(ⅰ)~(ⅲ)までの方法によって得られたシフトベクトルを用いて線形補間を行うことにより，すべてのボクセルのシフトベクトルを計算する．次に，現在画像の基準ボクセルに対応するシフトベクトルを用い，探索カーネル(3×3×3[voxels])を過去画像上に設ける．そのカーネル内から基準ボクセル値と等しいもしくはそれに近いボクセル値を探索し，カーネルの中心値と置き換える．この操作を過去画像の全ボクセルに適用し，現在の構造情報に合うような過去画像の変形量が得られ，これを用いた過去画像を変形し，ワーピング画像を得る．

2．2　多重閾値処理

経時的差分画像上では原画像と異なり異常構造が強調されるため，容易に処理が行える．また，NoduleやGGOは球形に近い形をしてお

り，二次元スライス画像上では円形に近い形を示す．そこで，経時的差分画像を二値化し，その画像に円形度などの特徴量やスライス間の連続性を考慮することにより，最終的な異常候補陰影として抽出する．

2．3　多段階 CNN[12]

本論文では，入力層，畳み込み層 2 層，プーリング層 2 層, 全結合層 2 層の CNN を用いる．層のパラメータについて表 1 に示す．

本論文では，入力画像のクラス間での枚数の偏りを解消するために先に述べたモデルを 3 段階に分けて用いる．まず，1 段階目において偏りのある画像を学習データとして入力し，識別器を作る．その後，その学習データをテストデータとしてその識別器に入力する．そこで得られる正常陰影であるという尤度の閾値により正常陰影クラスの画像を除去する．2 段階目においては，1 段階目で残った画像を用いて学習を行い，1 段階目と同様に異常陰影と正常陰影が同枚数になるような閾値処理を行う．その後，3 段階目において異常陰影と正常陰影が同数となった学習データを入力し，識別器を作成し，テストデータとして経時的差分画像上に残った陰影を入力し，識別を行う．

学習率はすべての段階において 0.0001 であり，学習回数は各段階において 20 回，50 回そして 100 回となっている．

3.　実験と結果

本実験で使用した画像は，産業医科大学病院で収集されたものでヘルシンキ宣言の倫理的原則に沿っており，倫理審査委員会の承認を得ている．

Nodule を 1 つ以上有する胸部 CT 画像に対し，計 25 症例に本手法を適用し，3 分割交差検証法を行った．また，異常陰影のデータセットが不十分であることから，LIDC(The Lung Image Database Consortium)[14]画像を利用し，画像の回転操作によるデータの水増しを行った．

精度の評価方法は以下の真陽性率(TPR)[%], 偽陽性率(FP)[/case]の式と AUC(Area Under the Curve)を用いる．

$$TPR = \frac{a}{a+c} \times 100 \tag{6}$$

$$FP = \frac{b}{e} \tag{7}$$

表 1　ネットワークの各層の詳細

層	カーネル	ストライド	活性化関数
input	―	―	―
conv1	5×5	1	ReLU
pool1	2×2	2	―
conv2	5×5	1	ReLU
pool2	2×2	2	―
fc3	―	―	ReLU
fc4	―	―	softmax

表 2 最終識別結果（ランダムは比較実験用の結果の平均を表す）

	TP[%]	FPR[%]	FP[/case]	AUC
Dataset1	100	15.79	13.13	0.969
Dataset2	95.24	17.33	13.00	0.961
Dataset3	100	5.78	1.56	0.992
平均	98.41	12.97	9.23	0.974
ランダム	96.03	18.52	12.57	0.967

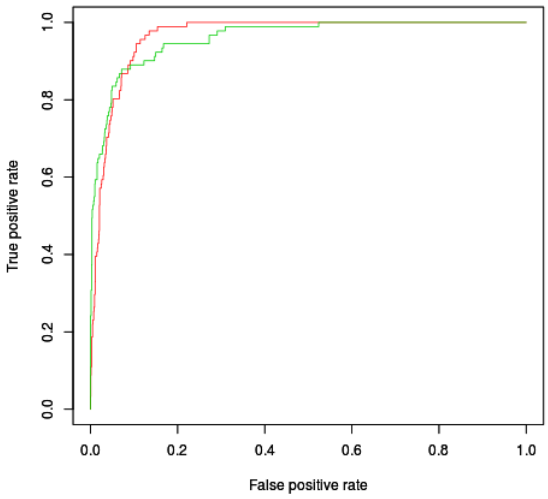

図 1　ROC 曲線（赤：提案手法，緑：ランダム選択）

(a) TP の取りこぼしの例

(b) FP の例

図 2　TP の取りこぼしと FP の例

ただし，*a* は正しく異常と識別された画像，*b* は正常を異常とした画像，*c* は異常を正常とした画像，*e* は全症例数を示す．

最終識別結果を表 2 に，ROC 曲線を図 1 に示す．ただし，Dataset1，2，3 の症例数はそれぞれ 8，8，9[症例]となっている．比較実験のために異常陰影と同数の学習データをランダムに選んだもので作成した識別器を使用している．

4.　考察

図 2 に TP の取りこぼしの例と FP の例を示す．淡く広がった胸壁，丸みを帯びた胸壁や太い血管分岐の多くが FP として誤認識している．また，FP に近い異常陰影を取りこぼす傾向にあった．これは，本論文で使用した CNN が比較的浅い層構造であるため，複雑な形状の学習がうまく行っていないことや識別器の作成の際に入力した学習データが異常に近い形状の陰影しか残っていないためだと考えられる．このことから，CNN のモデルをより深い構造のものにすることや 1, 2 段階目で除去された画像のうちランダムに選択したものを混入させる必要があると考えられる．

5.　まとめ

本論文では，胸部 CT 画像からの経時的差分

画像に対する異常候補陰影を自動抽出するための CAD システムの開発を行った.

手法としては，経時的差分像から得られる初期候補陰影に対し，多段階 CNN による識別を行った．提案法を 25 症例の同一被験者で構成される過去・現在画像に適用した結果, TP:98.41 [%]，FP:9.27[/case]，AUC:0.974 の識別性能を得た.

今後の課題としては，より深い層構造のモデルの適用やより正確な精度を算出するために症例数を増やすことと他手法との比較，さらに前段階の重みを用いた転移学習が必要であると考えられる.

謝辞

本研究は，文部科学省科学研究費補助金（26108009，17H02110，17K14694），文部科学省卓越研究員事業（16809746）の補助を受けている.

利益相反の有無

利益相反なし

文　献

[1] 平成 28 年 人口動態統計の年間推計：http://www.mhlw.go.jp/toukei/saikin/hw/jinkou/suikei16/dl/2016suikei.pdf (2018/01/11 access)

[2] がん登録・統計：http://ganjoho.jp/reg_stat/statistics/stat/annual.html (2018/01/11 access)

[3] 国立がん研究センターがん情報サービス：https://ganjoho.jp/public/cancer/lung/print.html (2018/04/23 access)

[4] 中村克己 他:胸部単純 X 線写真における経時的差分画像法の臨床的有用性，日本放射線技術学会雑誌，Vol.56，No.3，pp.496-502(2000)

[5] 岡谷貴之：深層学習，講談社，pp.79-98(2015)

[6] N.Miyake et al.： A Method for Reduction of Subtraction Artifacts on Temporal Subtraction Images by Use of Generalized Gradient Vector Flow Technique，Joint Meeting combining The 3rd meeting of Japanese Society of Pulmonary Functional Imaging and 5th International Workshop for Pulmonary Functional Imaging，p.162，2011

[7] 芳野由利子 他：GGVF とシフトベクトル平滑化による胸部 MDCT 画像の経時的差分法，映像情報メディア学会報告，38 巻，46 号，p.53-56，2014

[8] M.Nagao et al.：Detection of Abnormal Candidate Regions on Temporal Subtraction Images based on DCNN，ICCAS，pp.1444-1448，2017

[9] A.Shimizu et at. : Minimum directional difference filter for extraction of circumscribed shadows in chest X-ray images and its characteristics, Radiology and Nuclear Medicine, Vol.24, No.19, pp.241-249, 1993

[10] Radhakrishna et al. : SLIC Superpixels Compared to State-of-the-art Superpixel Methods, *Journal of Latex Class Files*, Vol.6, No.1, pp1-8，2011

[11] Y.Boykov et al. : An Experimental Comparison of Min-Cut/Max-Flow Algorithms for Energy Minimization in Vision, *IEEE Transactions on PAMI*, Vol.26, No.9, pp.1124-1137, 2004

[12] 小野田:サポートベクターマシン，オーム社, pp.34-56(2007)

[13] N.Japkowicz : Learning from Imbalance Data Sets : A Comparison of Various Strategies, AAAI2000 Workshop, Technical Report WS-00-05, pp.10-15, 2000

[14] Lung Image Database Consortium(LIDC) Cancer Imaging Program : https://wiki.cancerimagingarchive.net/display/Public/LIDC- IDRI(2017/04/27 access)

Detection of Abnormal Candidate Regions on Temporal Subtraction Images Based on CNN

Mitsuaki NAGAO[1], Tomoki UEMURA[1], Noriaki MIYAKE[1] Keibin LU[1],Joo Kooi TAN [1],
Hyoungseop KIM[1],Seiichi MURAKAMI[2], Takatoshi AOKI[2],Yasushi HIRANO[3],Shoji KIDO[3]

1 Kyushu Institute of Technology
2 University of Occupational and Environmental Health
3 Yamaguchi University

Recently, visual screening based on CT images become useful tools in the medical fields. However, due to the large number of images and the complexity of the image processing algorithms, image processing technique is still required a high screening cost. To overcome this problem, some computer aided diagnosis (CAD) algorithms are proposed until now. By the way, cancer is a leading cause of death Japan and worldwide.
Detection of cancer region in CT images is most important task to early detection. We have designed and developed a framework combining machine learning based on CNN and temporal subtraction techniques based on non-rigid image registration algorithm. Our main classification method can be built into three main steps; i) pre-processing for image segmentation, ii) image matching for registration, and iii) classification of abnormal regions based on machine learning algorithms. We performed our proposed technique to 25 thoracic MDCT sets and obtained true positive rates of 98.41 [%], false positive of 9.23[/case] and area under the curve of 0.974 were obtained.

Key words : Computer Aided Diagnosis, Temporal Subtraction Technique, Deep Leaning, CNN

著者紹介

長尾　充朗　(ながお　みつあき)
2017 年九州工業大学工学部機械知能工学科知能制御工学コース卒, 現在, 九州工業大学工学府機械知能工学専攻知能制御工学コースに在籍中.
日本医用画像工学会会員.

Improved method to determine fat volume using CT images

Ryo IDEUE[*1], Masatsugu HIRANO[*1], Katsuhito YAMASAKI[*2] et al.

Abstract

In this study, we develop a software program to determine the fat volume using computed tomography (CT) images. This software can automatically measure the volume of subcutaneous and visceral fat. By considering the muscle tissue between the subcutaneous and visceral fat as a guide, a fat boundary line is set on the two-dimensional CT slice image. Further, fat separation and measurement are performed on each image. However, the software incurs a problem because a reduction in the CT value of the muscle tissue generates a false positive regarding the position of the fat boundary. In the current study, we successfully mitigate the influence of this problem. We focus on those parts where the boundary line curves in an unnatural manner because this indicates the parts in which the boundary calculation incurs an error. We attempt to reduce this error by flattening the curve using linear interpolation. In particular, we centered on a simple spine-like shape that faces into the human body. This algorithm reduces the overall complexity of the spiky shape. Some errors are observed to remain in parts where the shape of boundary line is complex. Additionally, because this method ignores the structure of the body, we assume that, if the interval to be interpolated was long, it would affect the measured fat volume.

Keywords: computer-aided diagnosis (CAD), computed tomography, visceral adipose tissue, subcutaneous adipose tissue

1. Purpose

Improvements in the performance of computed tomography (CT) imaging devices have ensured that we can obtain detailed information using the resulting CT images. Attempts have been made to measure the volume of subcutaneous adipose tissue (SAT) and visceral adipose tissue (VAT) in the human body using CT images. For these measurements of adipose tissue, both the types of adipose tissue must be identified. However, manual separation of these tissues into SAT and VAT on each CT slice is extremely time consuming.

To overcome this problem, we have developed a software program that can measure the fat volumes. Methods for segmenting and quantifying the adipose tissue have been proposed by Kim et al. [1] and Lee et al. [2]. In the current study, we aim to develop a software program that would be capable of accurately measuring the subcutaneous and visceral fat volumes using the CT images of obese patients.

---

*1 National Institute of Technology, Niihama College

〔7-1 Yagumo, Niihama, Ehime 792-0805, Japan〕

e-mail: hirano@ele.niihama-nct.ac.jp

*2 Eikokai, Ono Hospital

〔973 Tenjin, Ono, Hyogo 675-1316, Japan〕

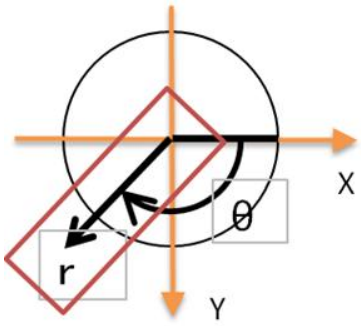

Fig. 1 The polar coordinate system on a CT slice image

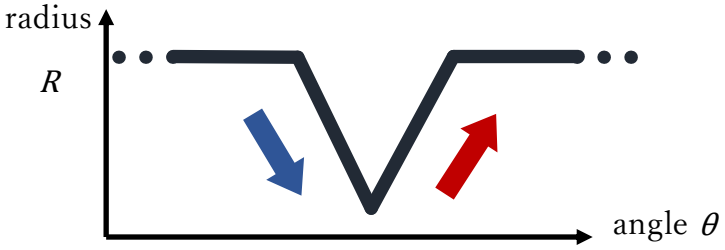

Fig. 2 Change in the radius value

2. Method

The newly developed software determines the fat boundaries based on the location of a muscle tissue in a CT image and calculates the volumes of the SAT and VAT. The fat boundary line is a closed curve that separates the adipose tissue into the SAT and VAT. The boundary line can be obtained by drawing a closed curve along the muscle tissue that exists between the SAT and VAT. This line can be obtained as follows:

1. consider a polar coordinate system (Fig. 1) with the origin at the center of the two-dimensional CT image;
2. extract a sequence of CT values from a half line that radially extends at a certain angle from the origin of the polar coordinates;
3. inspect the CT values obtained from an element that extends from a point outside the human body to a point inside the human body; further, determine the positions of the air, adipose tissue, muscle tissue, and other tissues based on the CT values;
4. once the position of the muscle tissue is obtained, consider this position to be a boundary point.

The process of placing boundary points is performed over 360° at fixed-angle intervals. The closed curve that is formed by connecting all the boundary points is defined as the boundary line that separates the adipose tissue into subcutaneous and visceral adipose tissue. The area within the boundary line is considered to be the VAT, whereas the outside area is considered to be the SAT. Using this sequence, fat separation can be performed for each two-dimensional CT image; further, the fat volume can be measured.

The sum of measured values is calculated for each CT slice.

However, this software incurs a problem that any reduction in the CT value of the muscle tissue will generate a false positive regarding the position of the fat boundary. We attempted to mitigate the influence of the boundary line error on the measured values by ignoring the boundary line at the inaccurate position and by obtaining a smooth boundary line by linear interpolation in that interval. Several boundary errors are observed because some of the boundary points shift to the inside of the human body. Upon drawing lines to connect points, including those that are shifted in an inward direction, the curvature of the boundary line will change in an abrupt manner. In terms of polar coordinates, the change is observed to be an abrupt change in the radius (Fig. 2). The radius abruptly decreases upon entering a section that incorporates an error; however, the radius rapidly increases beyond that section. By focusing on this change, any position where there is a sharp decrease is considered to be the start position of an interpolation section, whereas the subsequent position where there is a sudden increase is considered to be the end position. Linear interpolation can be performed within the interval based on the values on both the sides, adjacent to the set interval. The resulting closed curve, smoothed partially by linear interpolation, is considered to be the boundary line that separates the two types of adipose fat.

Apart from smoothing the boundary line, we are also considering ways to improve the recognition of the muscle tissue. When the software inspects a sequence of CT values to determine the position of the muscle tissue, a determination is made by comparing with the fixed CT value threshold. However, while making a judgment based on the threshold value, it is not possible to handle fluctuations in the CT values of the adipose tissue, as described previously. While examining a sequence of CT values, we considered whether the boundary points could be set at appropriate positions by assuming that a muscle tissue will exist at any position where the value is observed to be the local maximum.

3. Results

We examined the efficacy of our proposed method using 10 CT image sets (1680 images). The angular interval of the half lines that are used to extract a sequence of CT values was set to 3°. The CT value (in Hounsfield units (HU)) of the adipose tissue was set to fall between −200 and −10, whereas that for muscle tissue was set to fall between 30 and 60. We examined the results that were obtained when linear interpolation was applied and not applied and compared the number of slices with the erroneous boundary lines. When interpolation processing was not performed, boundary errors were observed to occur in an average of 87.2% of the slices. When interpolation processing was performed, however, boundary errors were observed to occur in an average of 30.7% of the slices.

4. Conclusion

Our results exhibited that our improved method was effective to mitigate the errors that were incurred during fat separation. However, the interpolation range may not be optimally set in certain cases in which the boundary line assumed a complicated form, and boundary errors remained in an average of approximately 31% of the slices when interpolation processing was performed. The use of linear interpolation processing is easy; however, it does not consider the structure of the human body. If excessively long interpolation intervals were to be set, the measured value may deviate from the actual value.

References

[1] Kim YJ, Park JW, Kim JW et al: Computerized Automated Quantification of Subcutaneous and Visceral Adipose Tissue From Computed Tomography Scans: Development and Validation Study. JMIR Med Inform. 2016 Jan-Mar; 4(1): e2.

[2] Lee SJ, Liu J, Yao J et al: Fully automated segmentation and quantification of visceral and subcutaneous fat at abdominal CT: application to a longitudinal adult screening cohort. The British Journal of Radiology [28 Mar 2018:20170968]

Improvement of the SLAM-based Bronchoscope Tracking Using Adjacent Reconstruction

Cheng WANG[*1], Masahiro ODA[*2], Yuichiro HAYASHI[*2], Hirotoshi HONMA[*3], Hirotsugu TAKABATAKE[*4], Masaki MORI[*3], Hiroshi NATORI[*5], Kensaku MORI[*2,6,7]

Abstract

This paper presents an improved bronchoscope tracking method based on the SLAM. Bronchoscope navigation provides additional location information of the bronchoscope for physicians during bronchoscopic examination. Previous navigation systems utilized the registration of video and pre-operative CT volumes for tracking, which was not able to deal with many unexpected scenes. We improve the bronchoscope tracking by using the SLAM. In the SLAM, bronchoscopic posture is obtained using the 3D reconstructed feature points in previous frames. The tracked frames are used to create more points to track new frames. However, tracking may fail due to the insufficient number of 3D reconstructed points. We utilize adjacent frames to reconstruct more 3D points by triangulating the matched points in adjacent frames if the number of reconstructed points is lower than a threshold. Phantom experiment showed that the proposed method tracked more frames than the previous method. The position RMSE between the proposed method and ground truth was 0.405 mm.

Keywords：surgical navigation system, ORB-SLAM, bronchoscope tracking

1. Introduction

Lung disease is becoming one of the most highly death leading disease in recent years according to the survey [1]. If we find suspicious regions on X-ray images or CT images, physicians try to diagnose the lung disease by using a bronchoscope. However, physicians may be confused about the current location because the bronchus has a complex tree structure. Therefore, endoscopic navigation system, which provides bronchoscope location, is useful for physicians during bronchus examination.

Bronchoscope navigation system needs to track the bronchoscope posture. Traditional method obtained

*1 Graduate School of Information Science, Department of Media Science, Nagoya University
〔Furo-cho, Chikusa-ku, Nagoya, 464-8601, Japan〕
e-mail: chwang@ mori.m.is.nagoya-u.ac.jp
*2 Graduate School of Informatics, Department of Intelligent Systems, Nagoya University
*3 Sapporo Kosei General Hospital
*4 Sapporo Minami Sanjo Hospital
*5 Keiwakai Nishioka Hospital
*6 Information Technology Center, Nagoya University
*7 Research Center for Medical Bigdata, National Institute of Informatics

the bronchoscope posture by registering bronchoscope video and pre-operative CT volumes [2] or by using additional sensors such as electromagnetic (EM) sensor [3]. However, video-CT registration based method needs continuous registration, which requires huge computation. Furthermore, the EM sensor is easily influenced by metal instruments in an operation room.

To overcome the aforementioned shortcomings of the previous methods, pure image based method: simultaneous localization and mapping (SLAM) is used to obtain the bronchoscope posture [4]. However, according to the reference [5], SLAM may easily fail to track due to the decrease of trackable map points caused by sudden rapid motion.

This paper aims to increase the number of tracked frames in SLAM based bronchoscope tracking. During the tracking procedure, SLAM projects part of map points (trackable map points) onto the current frame. Then it estimates the camera posture by minimizing the reprojection error of projected map points. We use adjacent reconstruction to reconstruct new map points, which can detect more trackable map points and use them for tracking. Tracking lost due to sudden rapid motion can be reduced by using the proposed method.

2. Method

SLAM uses bronchoscope video as input and estimates the camera pose of one frame by using a pre-built map. The pre-built map contains 3D reconstructed points and selected frames and is built by triangulating the matched points in selected frames [4]. We use the pre-built map and the frame at time t as the input of the tracking and increase the reconstruction point using the following steps: (1) Posture estimation using pre-built map; (2) Decide whether adjacent reconstruction is needed or not; (3) Adjacent reconstruction.

(1) **Posture estimation** The camera posture of the frame t is calculated by minimizing the reprojection error of found map points in this frame. If the camera posture of frame t has been obtained, the number of feature points used for posture estimation is counted, and is denoted as N^t.

(2) **Decide whether adjacent reconstruction is needed or not** If the number of used map points N^t is smaller than a threshold m (m = 150), we perform the adjacent reconstruction to create new map points.

(3) **Adjacent reconstruction** Since we have obtained the posture of frame t and the previous frames before frame t, the transformation between two frames can be calculated and is used to find the corresponding feature points between frame t and the previous frame. The corresponding points are triangulated and tested with several conditions as in literature [4]. If the triangulated points pass the tests, they will be added into maps and used to track new frames.

Different from the previous methods, we create new map points after the posture of frame t is obtained. This method ensures enough correspondence between new frame and pre-built map. The tracking procedure can be enhanced to track more frames.

3. Experiments and Results

We recorded two ex-vivo videos by capturing the bronchus phantom (shown in Fig. 1 (a)) with a bronchoscope (BF-P260F, Olympus, Tokyo). These videos lasted from 30s to 50s@29fps with a resolution of 362×370 pixels. Bronchoscope posture is recorded using an EM sensor (Ascension Technology Corporation, USA) as the ground truth of the bronchoscope trajectory for its high accuracy. The intrinsic parameter of the bronchoscope is obtained using the camera calibration [6].

1) Evaluation of tracking

Table 1 shows the tracked frame numbers of different methods. The position RMSE between the

Table 1 Comparison of the number of tracked frames by different methods

	All frames (frames)	Original SLAM [4] (frames)	Proposed method (frames)
Video 1	973	228	278
Video 2	670	456	477

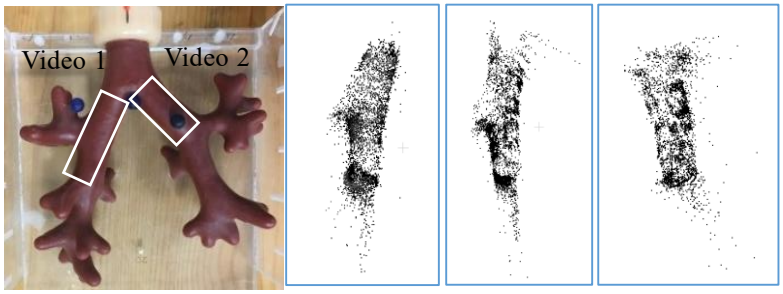

(a) (b) (c) (d)

Figure 1 Bronchus phantom and the estimated map points (Bronchus in rectangle were the captured area). (a) Bronchus phantom (b) ORB-SLAM (video 1) (c) proposed method (video 1) (d) proposed method (video 2)

proposed method and EM sensor was 0.405 mm by using the ICP for calculation.

2) Comparison of reconstruction results

We obtained the reconstructed bronchus for comparison. Figure 1 (b) and (c) showed the reconstruction results obtained from video 1. Figure 1 (d) showed the reconstruction results obtained from video 2. The proposed method reconstructed 5,277 points while the original SLAM reconstructed 4,090 points.

4. Discussion and conclusion

We used the adjacent frames whose posture had been estimated to find more trackable points to increase the number of tracked frames in the SLAM-based bronchoscope tracking. Experimental results showed that the trajectory of the proposed method was longer with higher accuracy. The proposed method causes more outliers that may result in reduction of tracking accuracy. In the future, we need to consider using more constraint to remove the outliers. The registration between the reconstructed bronchus shape and the bronchoscope shape obtained from segmented CT slices also should be considered to build the bronchoscope navigation system. Validation of in-vivo scenes are also needed.

Competing interests

No

Acknowledgement

Parts of this study were supported by JSPS KAKENHI (Grant Numbers 26108006, 17K20099 and 17H00867), and the JSPS Bilateral International Collaboration Grants.

References

[1] Outline of Health, Labour and Welfare Statistics by Ministry of Health, Labour and Welfare, Japan: http://www.mhlw.go.jp/toukei/saikin/hw/jinkou/kakutei16/index.html

[2] Merritt S, Khare R, Bascom R, Higgins W: Interactive CT-Video Registration for the Continuous Guidance of Bronchoscopy. IEEE Trans Med Imag **32** (8): 1376-1396, 2013

[3] Luo X, Mori K: Robust Endoscope Motion Estimation Via an Animated Particle Filter for Electromagnetically Navigated Endoscopy. IEEE Trans Biomed Eng **61** (1): 85-95, 2014

[4] Mur-Artal R, Montiel J, Tardos J: ORB-SLAM: A Versatile and Accurate Monocular SLAM System. IEEE Trans Robot **31** (5): 1147–1163, 2015

[5] Wang C, Oda M, Hayashi Y et al: Study on Robustness of ORB-SLAM Based Outlier Elimination in

Bronchoscope Tracking. IEICE technical report **117** (281): 47-52, 2017
[6] Zhang Z: A flexible new technique for camera calibration. IEEE Trans Pattern Anal Mach Intell **22** (11): 1330-1334, 2000

隣接再構成を用いたSLAMベースの気管支鏡追跡の改善

王成 [*1]，小田昌宏 [*2]，林雄一郎 [*2]，本間裕敏 [*3]，高畠博嗣 [*4]，
森雅樹 [*3]，名取博 [*5]，森健策 [*2, *6, *7]

*1 名古屋大学大学院情報科学研究科メディア科学専攻

*2 名古屋大学大学院情報学研究科知能システム学専攻

*3 札幌厚生病院

*4 札幌南三条病院

*5 恵和会西岡病院

*6 名古屋大学情報基盤センター

*7 国立情報学研究所医療ビッグデータ研究センター

要旨:本稿では，SLAM に基づく気管支鏡の追跡方法の改良について述べる．気管支鏡ナビゲーションでは，気管支鏡検査中の医師に気管支鏡現在位置を提供する．従来のナビゲーションシステムでは，ビデオ画像および術前CT画像をレジストレーションすることにより，気管支鏡の位置を追跡していたが，動きが大きい場面では追跡失敗することがあった．我々はSLAMを使用して気管支鏡の追跡を改善する手法を提案した．SLAMでは気管支鏡姿勢は今まで追跡したフレームまでに3次元復元された特徴点を用いて計算する．その後，次フレーム以降での気管支鏡姿勢に用いるために3次元復元点を生成する．この時，3次元復元された点の数が少ないと，気管支鏡姿勢の追跡に失敗することがある．そこで，3次元復元される点が少ない時に3次元復元点増加する処理を追加した．ファントム実験では，提案手法は従来手法より多くのフレームを追跡できることが示された．提案手法で追跡したカメラ位置のRMSEはground truthに対して0.405 mmであった．

キーワード：手術ナビゲーションシステム，ORB-SLAM，気管支鏡追跡

テンプレート（全ての原稿の種類に共通） Ver. 2.1（2017.3.21 改訂）

加重積算による肝臓の ADC 精度向上

西原　崇[*1]　瀧澤　将宏[*1]　白勢　竜二[*1]　村瀬　毅倫[*1]

磯部　正幸[*1]

要旨

[背景/目的]肝臓 DWI では，肝左葉の ADC 値が不正に増加する問題がある．肝臓 DWI は複数積算で撮像する場合が多く，本報告では加重積算することで ADC 値の精度を向上させる方法を検討した．
[方法]撮像対象は健常ボランティアとした．息止めで b 値=1000 の DWI を 12 回撮像し，ピクセル毎に信号値を①全 12 積算を加算平均，②中央値以上を加算平均，③最大値のみ，の 3 パターンで加重積算して領域毎に ADC 値と SNR を比較した．
[結果/結論]ADC 値は，拍動の小さい肝下部に対して肝左葉が①1.35 倍，②1.14 倍，③1.06 倍であり，SNR は①22.0，②21.7，③15.4 であった．健常ボランティアでは各領域の ADC 値はほぼ一定と予想されることから，加重積算で精度が向上していることが分かるが，SNR を加味すると②程度が最適と考える．

キーワード：拡散強調，ADC，肝臓

1. はじめに

肝臓の Diffusion weighted image (DWI)は腫瘍の検出に広く用いられているが，体動により肝臓の一部，特に肝左葉の信号が低下すること，及び Apparent diffusion coefficient (ADC)値が不正に上昇することが知られている[1][2]．これらは当該組織の淡い病変を見逃す可能性が高くなるだけではなく，頭部や前立腺では診断基準に用いられている ADC 値による定量評価を妨げる要因となっている[3]．心電同期を併用することにより肝左葉の信号低下が改善することも報告されているが[1]，撮像時間の延長が問題となるため広くは使われていない．また，複数回撮像しておき視覚的に信号が低下した画像を除外して加算平均する方法や，複数積算時にピクセル毎に加重積算することで肝左葉の信号を改善させる方法が報告されている[4]．

本報告では，肝臓の信号が欠損する原因と ADC 値に対する影響の評価，及び加重積算による ADC 値の改善効果について評価したので報告する．

2. 肝左葉の信号低下の原因調査

文献[1]にあるように、肝左葉の信号低下の原因が拍動であるか調べるため，息止め撮像した DWI の信号欠損と R 波の関係を確認する．以下に示す撮像条件で，健常ボランティアの腹部を息止めで 4 回撮像した．本研究計画は日立グループ倫理審査委員会で審査済みであり，本研究のデータは全ての被験者からインフォームド・コンセントを得た上で取得した．

TR/TE=7500/70ms, FOV=400mm, Thickness /Interval=5.0/5.0mm, Slice#=30, Freq# /Phase#= 96/192, b value=1000, MPG Direction=Single,

*1 株式会社日立製作所 ヘルスケアビジネスユニット
〔〒277-0804 千葉県柏市十余二 2-1〕
e-mail: takashi.nishihara.nb@hitachi.com

MPG Mode=Complex, Acceleration Factor=1.0. 取得した b=0 及び b=1000 の元画像に対して肝臓に信号欠損のないスライス（図 1a）と欠損のあるスライス（図 1b）を視覚的に評価した．尚，取得した画像の内，評価対象としたのは肝臓が写っているスライスのみとした．

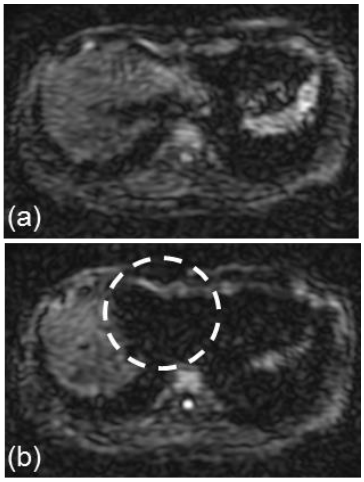

図 1 肝 DWI 撮像結果
(a) 信号欠損なし，
(b) 点線部分に信号欠損あり

また，撮像中にボランティアの心電波形を ECG センサで取得し，各スライスデータ取得時の R 波からの Delay（図 2）を計測した．

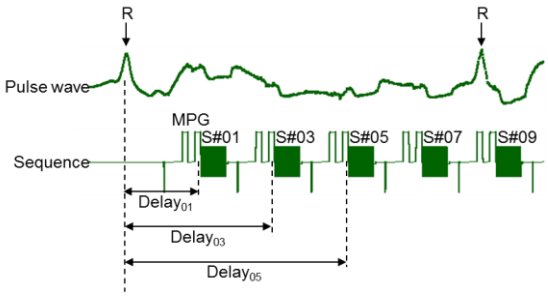

図 2 各スライスデータ取得時の Delay
R 波のピークから各スライスのデータ取得開始までの時間を Delay とした．

縦軸を欠損したスライスと欠損していないスライスの数，横軸を R 波からの Delay とした結果を図 3 に示す．b=0 で信号が欠損しているスライスは存在せず，欠損したのは b=1000 のみであった．また，信号が欠損しているのは R 波から 100ms から 300ms 程度に顕著に多くみられた．

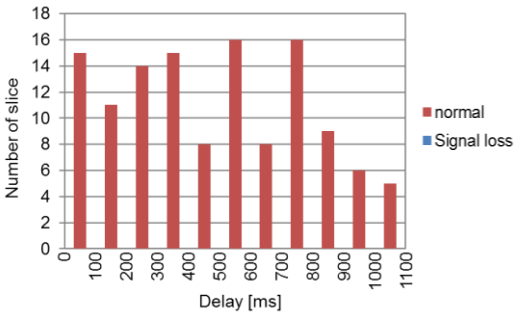

(a) b=0

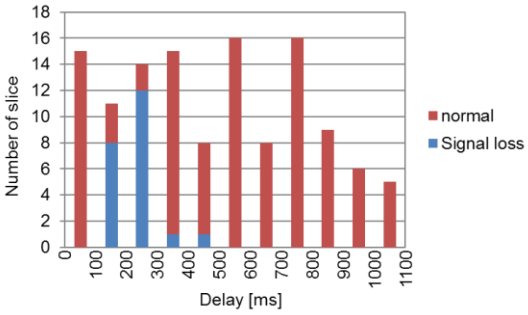

(b) b=1000

図 3 Delay-信号欠損の関係

b=0 で信号が欠損せずに b=1000 で信号が欠損していることから，MPG が影響していることが分かる．MPG で信号が欠損する要因としては MPG 印加中の体動が考えられ，腹部における体動としては主に呼吸動と拍動がある．今回は息止めで撮像しているので呼吸動が信号欠損の原因である可能性は低く，更に拍動と信号欠損のタイミングが相関していることから信号欠損の原因は文献[1]記載のように拍動であると考えられる．拍動が原因であれば心電同期が有効である可能性があるが，信号欠損の発生する Delay は血流速などの個人差により一定しない可能性が高く，前述したように撮像時間の問題もあり心電同期だけでは ADC 値の精度向上に限界があると予想される．

3. ADC 値に対する影響

b=1000 における信号欠損の ADC 値に対する影響を確認する。2 章で撮像した 4 回分の b=0，b=1000 それぞれの画像を加算平均した結果から ADC マップを作成し，図 4 に示した左葉上部(L/S)，右葉上部(R/S)，右葉中部(R/C)，右葉下部(R/I)の 4 つの領域に血管などの構造物を避けて複数の小さな ROI を設定し，各領域の ADC の平均値と SD を計測した．結果を表 1 に示す．

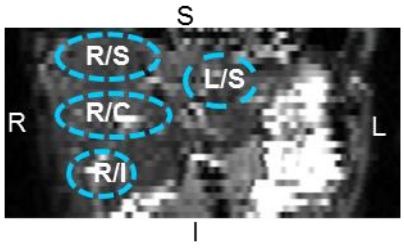

図 4 ROI 設定位置
左葉上部(L/S)，右葉上部(R/S)，
右葉中部(R/C)，右葉下部(R/I)

表 1 肝臓各領域の計測結果．

部位	ADC 値	SD
左葉上部	0.00149	0.00011
右葉上部	0.00123	0.00010
右葉中部	0.00119	0.00005
右葉下部	0.00110	0.00006

左葉上部の ADC 値（0.00149）は，右葉下部の ADC 値（0.00110）に対して 1.35 倍程度高くなっており，SD も 2 倍程度高くなっていた．健常ボランティアであれば，いずれの部位でも ADC 値はほぼ一定になると予想されることから，拍動の影響により ADC 値の精度が低下している可能性がある．

4. 加重積算による ADC 値の精度改善

2 章と同じ条件で健常ボランティアを息止めで 12 回撮像し，b=1000 のデータをピクセル毎に以下に示す 3 パターンで加重積算する．

(a) 全 12 積算を加算平均（12 積算）
(b) 中央値以上を加算平均（6 積算）
(c) 最大値（積算なし）

尚，図 3 で信号欠損が生じているのが R-R 間隔のうち長くても半分以下であったため，本検討では(b)を中央値以上とした．加重積算して領域毎に信号値，SNR と ADC 値を比較した． b=1000 の元画像をそれぞれの方法で加重積算し，ADC マップを作成した．

5. 結果

それぞれの方法で加重積算した b=1000 の画像を図 5 に示す．全 12 積算とした場合（図 5a）に比べて中央値以上（図 5b），最大値のみ（図 5c）共に SNR が低下しているが，肝左葉の信号値が加重積算により増加していることが分かる．

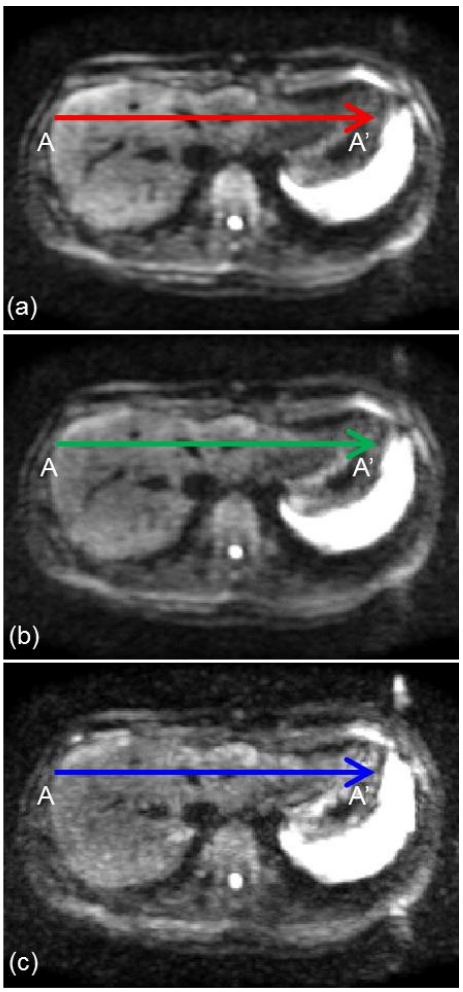

図 5 加重積算の結果（b=1000）
(a) 全 12 積算，(b) 中央値以上（6 積算），
(c) 最大値（積算なし）

図 5 における図中矢印のラインプロファイルを図 6 に示す. 全 12 積算とした場合(図 6a), 左葉（A’）の信号が右葉（A）の 1/3 程度低下しているが，最大値（図 6c）では同程度まで改善していることが分かる.

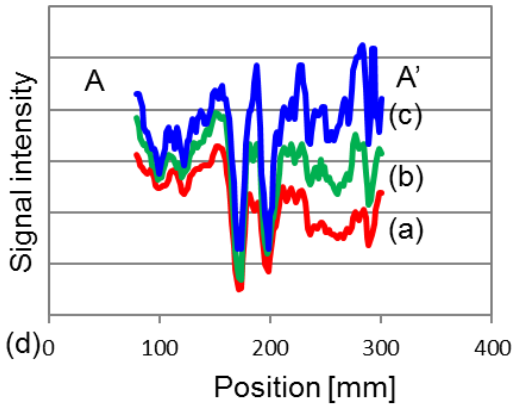

図 6 加重積算の結果（b=1000）
(a) 全 12 積算，(b) 中央値以上（6 積算），
(c) 最大値（積算なし）

図 5 の血管などの構造物のない領域に ROI を設定して SNR を計測した結果, (a) 22.0, (b) 21.7, (c) 15.4 であった．尚，本検討では SNR は，設定した ROI 内の平均値/SD とした.

図 5 に示した加重積算の b=1000 画像を用いて作成した ADC マップを図 7 に示す．全 12 積算とした場合（図 7a）に比べて中央値以上（図 7b），最大値のみ（図 7c）共に肝左葉における ADC の増加が改善していることが分かる．また ADC マップにおける SNR の低下は，最大値（図 7c）では視認できる程度だが，中央値以上（図 7b）では視認できない程度であった． 図 4 と同じ領域かつ同じ ROI で ADC 値と SD を計測した結果を図 8 に示す. SD はエラーバーとして表示した．全 12 積算とした場合（図 8a），右葉下部に比べて左葉上部は 1.35 倍程度高い ADC 値になっているが，中央値以上（図 8b）では 1.14 倍程度に改善し，最大値のみ（図 8c）では 1.06 倍でほぼ一定にまで改善している.

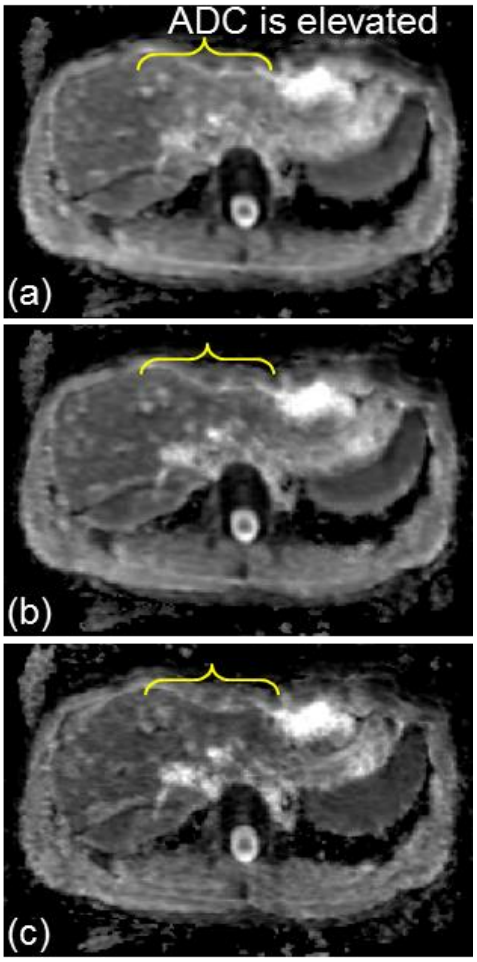

図 7 加重積算した b=1000 を用いて作成した ADC マップ
(a) 全 12 積算，(b) 中央値以上（6 積算），
(c) 最大値（積算なし）

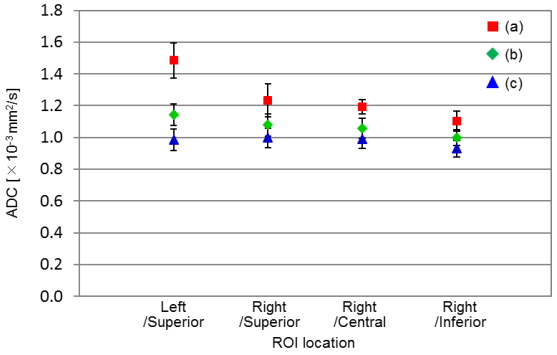

図 8 ADC 値の計測結果
(a) 全 12 積算，(b) 中央値以上（6 積算），
(c) 最大値（積算なし）

5. 考察

臨床で多く用いられるのは b=0 と b=1000 から作成した Trace 画像であり，今回検討した加重積算を用いた場合、全加算平均と比較して SNR が低下すると考えられる. 加重積算の重みを中央値以上とした場合の SNR 低下は視認できない程度であり数値的にも 5%と非常に軽微であったが，最大値とした場合は視覚的に SNR 低下が顕著であり, 数値的にも 30%程度低下した．SNR と ADC 値の両方を加味すると加重積算の重み付けは，中央値以上が最適と考えられるが, Trace 画像は中央値以上とし, ADC マップでは最大値にするなど異なる閾値にしても良いと考える.

本稿では腹部の ADC 値に対して評価を行ったが, 頭部でも CSF フローなどにより部位毎に異なる方向に拍動していることが報告されている[5]．また，近年は GC スリューの向上もあり, Flow Compensated MPG の検討も進んでいるが[6][7]，IVIM など複数 b 値の画像を用いて解析する場合には⊿や δ を一致させる必要があり適用が困難な場合もある．本手法は撮像シーケンスに対する制限が少ないこともあり，高 b 値を用いる拡散強調の解析である頭部の IVIM や DKI などに対しても有効である可能性がある．また，加重積算の重み付けによる SNR 低下が重篤であるかは, 元画像の SNR にも依存する. 今後は元画像の SNR から重みを最適化する方法なども検討が必要と考える.

6. まとめ

撮像後の後処理として加重積算を行うことにより，肝臓 DWI の ADC 値の精度を向上させることが可能であった．本方法は肝臓の定量評価に有効であると考えられる．今後は本手法により ADC 値など定量評価の精度を向上させた場合に臨床的に有用であるか検討を進めたい.

利益相反の有無

なし.

文　献

［1］ Thomas C. Kwee, Taro Takahara, Tetsu Niwa, et al: Influence of cardiac motion on diffusion-weighted magnetic resonance imaging of the liver. Magn Reson Mater Phy, **22**: 319–325, 2009

［2］ Pippa Storey, Fred J. Frigo, R. Scott Hinks, et al: Partial k-Space Reconstruction in Single-Shot Diffusion-Weighted Echo-Planar Imaging. Magn Reson Med **57**: 614–619, 2007

［3］ Katsuhiro Nasu, Yoshifumi Kuroki, Ryuzo Sekiguchi, et al: Measurement of the apparent diffusion coefficient in the liver: is it a reliable index for hepatic disease diagnosis?. Radiation Medicine **24**: 438–444, 2006

［4］ 野崎敦，若山哲也，椛沢宏之，他: Magnitude-Based Weighted NEX を用いた肝臓 DWI : 肝左葉の信号低下抑制を目指した基礎検討. 第 43 回日本磁気共鳴医学会大会予稿集，東京, 2015, P-1-052

［5］ D. Greitz, R. Wirestam, A. Franck, et al: Pulsatile brain movement and associated hydrodynamics studied by magnetic resonance phase imaging. Neuroradiology, **34**: 370–380, 1992

［6］ Andreas Wetscherek, Bram Stieltjes, Frederik Bernd Laun, et al: Flow-Compensated Intravoxel Incoherent Motion Diffusion Imaging. Magn Reson Med, **74**: 410–419, 2015

［7］ Eric Aliotta, Holden H Wu, Daniel B Ennis, et al: Motion Compensated Diffusion -Weighted MRI in the Liver with Convex Optimized Diffusion Encoding (CODE). Proc In 23th ISMRM, Singapore, 2016, #0728

Improvement of ADC Precision in Liver by Weighted Averaging

Takashi NISHIHARA[*1], Masahiro TAKIZAWA[*1], Ryuji SHIRASE[*1], Masayuki ISOBE[*1]

*1 Hitachi, Ltd. Healthcare Business Unit

We confirm the signal loss of liver DWI was induced by cardiac motion that the delay is 100-300 ms. And we evaluate the post-process method using weighted averaging method to reject these signal loss pixels. The weighted averaging was using following three conditions. 1) Averaging all pixel value (12 data sets), 2) Averaging pixel value which has over the median value (6 data sets), 3) Selecting maximum pixel value (1 data sets). The signal intensity, SNR and the precision of ADC were improved by the weighted averaging method 2) and 3). For SNR and precision of ADC, the average more than the median was optimal threshold.

Key words: Diffusion, DWI, ADC, Liver

著者紹介

和文でも英文でも可。

西原　崇（にしはら　たかし）
2004 年，横浜市立大学大学院・総合理学研究科・博士前期課程了．同年（株）日立メディコ技術研究所入社．2015 年より（株）日立製作所ヘルスケアビジネスユニット，現在に至る．MRI の研究開発に従事．日本医用画像工学会，日本磁気共鳴医学会，各会員．

瀧澤　将宏（たきざわ　まさひろ）
1994 年，横浜市立大学文理学部物理学課程卒，（株）日立メディコ技術研究所入社．2015 年より（株）日立製作所ヘルスケアビジネスユニット，現在に至る．MRI の開発研究に従事．2013 年，千葉大学大学院工学研究科博士課程了，博士（工学）．医用画像工学会論文賞受賞．日本医用画像工学会，日本磁気共鳴医学会，日本放射線技術学会，ISMRM 各会員．

白勢　竜二（しらせ　りゅうじ）
1991 年　北海道大学医療技術短期大学部放射線技術学課程卒．同年札幌医科大学附属病院放射線部勤務．2015 年より（株）日立製作所ヘルスケアビジネスユニット，MRI の研究開発に従事．診療放射線技師，磁気共鳴専門技術者．日本放射線技術学会，日本磁気共鳴医学会，各会員．

村瀬　毅倫（むらせ　たけのり）
2009 年立命館大学情報理工学部知能情報学課程卒．同年（株）日立メディコ入社．2015 年より（株）日立製作所ヘルスケアビジネスユニット．MRI の研究・開発に従事．日本磁気共鳴医学会会員

磯部　正幸（いそべ　まさゆき）
1992 年名城大学大学院工学研究科電気電子工学専攻修士課程了．同年（株）日立メディコ入社．2015 年より（株）日立製作所ヘルスケアビジネスユニット．MRI の研究・開発に従事．

機械学習を用いた腹部動脈血管名自動命名における臓器情報および多血管相互関係利用方法の検討

鉄村　悠介[*1]　Holger Roth[*1]　林　雄一郎[*1]

小田　昌宏[*1]　三澤　一成[*2]　森　健策[*1, 3, 4]

要旨

本稿では，3 次元腹部 CT 像から抽出した腹部動脈領域に対する機械学習による血管名自動命名について，条件付き確率場モデルにおいて考慮する特徴量を改良することで精度向上を図った．外科手術において患者の血管構造を正確に把握することは重要であり，これまで腹部動脈領域に対して機械学習を用いて血管名自動命名を行う手法がいくつか提案されてきた．しかしこれらの手法では，ある血管そのものがもつ特徴や，ある血管と一対一に対応する血管との関係性の利用に重きを置いており，高度な血管構造の把握が困難であった．そのため複雑な分岐構造をもつ血管で精度が低くなる問題があった．そこで本稿では，自動抽出臓器と血管との関係性や，ある血管と複数の血管との関係性を活用することにより問題の解決，精度の向上を図った．その結果，複雑な構造をもつ肝動脈の命名精度が大幅に向上し、腹部動脈 22 種類の命名精度は最大で 95.5%となった．

キーワード：血管，3 次元 CT 像，解剖学的名称認識，血管構造解析

1. はじめに

外科手術において患者の血管構造を術前 CT 像から正確に把握することは重要である．これまで術前 CT 像から得られた腹部動脈領域に対して自動命名を行う手法がいくつか提案されてきた．近年では北坂らが，血管に対する解剖学的名称自動命名を，木構造として表現された血管領域全体にわたる各血管枝の血管ラベル推定問題として捉え，確率的グラフィカルモデルに基づく構造学習により自動で行った［1］．しかしこの手法では，ある血管そのものがもつ特徴や，ある血管と一対一に対応する血管との関係性の利用に重きをおいており，複雑な血管構造の把握が不十分であり，自動命名精度が低くなる問題があった．そこで本稿では，自動抽出臓器と血管との関係性や，複数の血管間の関係性を活用することで精度の向上を図る．

2. 手法

本手法における学習から推定までの一連の流れは，文献［1］に示される構造学習に基づく血管名自動命名手法と同一である．本手法ではより高度な構造学習を可能にするため，（1）自動抽出臓器と血管との相対位置情報の導入，（2）隣接関係を考慮するより高次元の項の導入の，2 種類の改良を取り入れる．（1）では，既存の臓器領域自動抽出手法［2］を用いて自動抽出した肝臓，脾臓，右腎，左腎，胃，胆嚢，膵臓の 7 つの臓器と，血管の各枝とのユークリッド距離および方向ベクトルを学習のための特徴量に用いる．（2）では，注目している枝とその親，兄弟の 3 つのラベルを同時に考慮する項を確率モデルに追加する．

*1 名古屋大学大学院情報学研究科
〔〒464-8601 名古屋市千種区不老町〕
e-mail: ytetsumura@mori.m.is.nagoya-u.ac.jp
*2 愛知県がんセンター
*3 名古屋大学情報基盤センター
*4 国立情報学研究所
医療ビッグデータ研究センター

3. 実験と結果

本稿では，従来手法［1］との血管名自動命名の精度の比較実験を行った．

本実験で命名対象とする血管は，早期胃がん腹腔鏡下手術において重要な 22 種類の腹部動脈である．実験では，3 次元腹部 CT 像 50 症例から半自動で抽出した血管領域画像に対して血管名自動命名を行った．Leave-one-out 法により血管枝ごとに自動命名の再現率，適合率，F 値を算出した．提案手法による肝動脈および全動脈の自動命名精度を表 1 ならびに表 2 に示す．また提案手法による血管名自動命名例を図 1 に示す．

4. 考察

提案手法では，従来手法［1］と比較して肝動脈の自動命名精度が大幅に向上し，それに伴い全体の精度も向上した．これは，特徴量として臓器情報を加えることで各動脈の全体に対しての位置づけが明確になったためである．また隣接関係を考慮する高次元の項を導入したことにより，分岐を含めたより複雑な動脈構造を学習できるようになったことも関係していると考えられる．これに関して，本手法では考慮する関係性を注目枝と親，兄弟に固定していたが，今後さらに有用な関係性を実験により模索する必要がある．

5. まとめ

本稿では，3 次元腹部 CT 像から抽出した動脈領域に対する自動命名について，臓器情報および多血管相互関係の利用により精度が向上することを示した．今後は多血管間の関係性利用方法について詳細に検討することで精度の向上を図る．さらに，全自動抽出血管に本手法を適用することでその有用性を確認し，半自動抽出血管に適用したものと同程度の精度で命名可能となる手法の構築を目指す．

謝辞

日頃から熱心に御討論頂く名古屋大学森研究室の諸氏に感謝する．本研究の一部は MEXT・JSPS 科研費 17H00867，17K20099，26560255，26108006，JSPS 二国間交流事業によった．

利益相反の有無

なし．

文　献

［1］ Kitasaka T, Kagajo M, Nimura Y, et al: Automatic anatomical labeling of arteries and veins using conditional random fields. Int J CARS: 1-8, 2017

［2］ Roth H, Oda H, Zhou X, et al: An application of cascaded 3D fully convolutional networks for medical image segmentation. CMIG: 90-99, 2018

表 1　提案手法による肝動脈の自動命名精度

	再現率	適合率	F 値
従来手法［1］	74.8%	80.0%	77.4%
提案手法	**83.8%**	**83.6%**	**83.7%**

表 2　提案手法による全動脈の自動命名精度

	再現率	適合率	F 値
従来手法［1］	91.1%	91.5%	91.3%
提案手法	**95.2%**	**95.8%**	**95.5%**

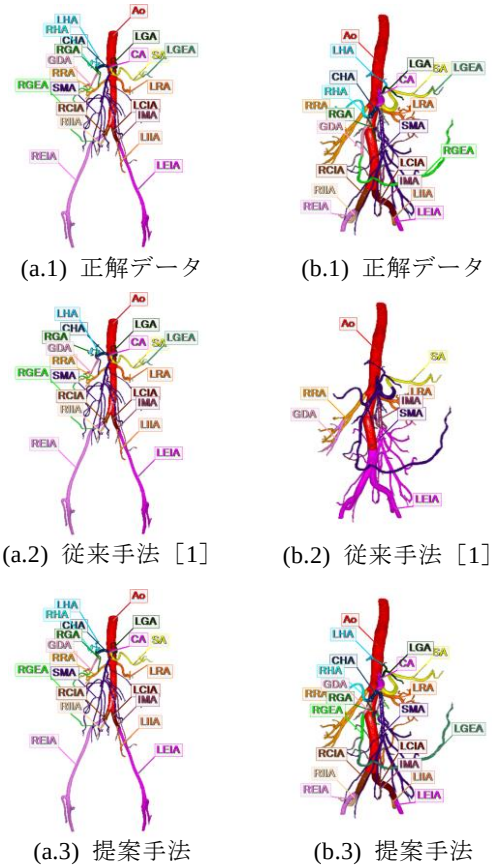

(a.1) 正解データ　(b.1) 正解データ

(a.2) 従来手法［1］　(b.2) 従来手法［1］

(a.3) 提案手法　(b.3) 提案手法

図 1　提案手法による血管名自動命名例(2 例)

Study on Automated Anatomical Labeling of Abdominal Arteries Using Machine Learning with Organ Information and Multi-vessel Relationship

Yusuke TETSUMURA[*1], Holger ROTH[*1], Yuichiro HAYASHI[*1],
Masahiro ODA[*1], Kazunari MISAWA[*2], Kensaku MORI[*1, 3, 4]

*1 Graduate School of Informatics, Nagoya University
*2 Aichi Cancer Center Hospital
*3 Information Technology Center, Nagoya University
*4 Research Center for Medical Bigdata, National Institute of Informatics

Abstract:
In this paper, we improve automated anatomical labeling accuracy for the abdominal arteries by introducing new features used in conditional random fields. It is very important to understand the blood vessel structure of a patient accurately in surgery. Several blood vessel labeling methods using machine learning techniques have been proposed. However, it is difficult to grasp blood vessel structures in detail since these methods place importance on utilization of the features of a target blood vessel and the relationships between blood vessels only on a one-to-one basis. Therefore, their labeling accuracy tends to be low among blood vessels having complicated branching structure. In this paper, we solved the problem and improved accuracy by utilizing relationships between automatically extracted organs and blood vessels and relationships between a target and the other blood vessels. In our experiments, labeling accuracy of the 22 abdominal arteries was 95.5% at the maximum.

Key words: blood vessel, CT volume, anatomical names recognition, blood vessel structures analysis

造影マルチスライス CT 画像における
大腸がんの転移性リンパ節解析

坂東　佳祐[*1)]　鈴木　秀宣[*2)]　河田　佳樹[*2)]　仁木　登[*2)]　飯沼　元[*3)]

要旨

大腸がんは高い死亡率を占める疾患である.遠隔転移のない大腸がん病期診断で最も重要な要素はリンパ節への転移有無である.一般に径が大きいリンパ節ほど転移の可能性が上がるが,径の小さいリンパ節にも転移が確認される場合がある.本研究は,造影マルチスライス CT 画像(動脈相,門脈相,平衡相)からリンパ節を抽出し,時相間の CT 値の比較を行うことで転移性リンパ節の特徴を明らかにすることである.

キーワード:CT, リンパ節, 大腸がん, 多時相

■　背景, 目的

日本の大腸がんの死亡率は年々増加傾向にあり，男性で 3 位,女性で 1 位と高くなっている(2016 年). 大腸がんは早期に発見･切除することで 5 年生存率を 80%以上にできる[1]. 遠隔転移のない大腸癌患者の病期診断で最も重要な要素はリンパ節転移の有無であると言われている.一般に径が大きいリンパ節ほど転移の可能性が上がるが,径が小さいリンパ節にも転移が確認される場合があり,大きさ以外の診断材料が必要である.本研究は造影マルチスライス CT 画像(動脈相,門脈相,平衡相)からリンパ節抽出と解析を行い,転移性リンパ節固有の特徴を明らかにすることを目的とする.

*1 徳島大学大学院先端技術科学教育部システム創生工学専攻
〔〒770-8506 徳島県徳島市南常三島 2-1〕
e-mail:c501738022@tokushima-u.ac.jp
*2)徳島大学大学院社会産業理工学研究部
*3)国立がん研究センター中央病院放射線診断部

■　CT 画像 撮影条件

国立がん研究センター中央病院で行われた大腸癌術前 CT 検査の画像を用いた．これらの画像は，横隔膜から下腹部までの腹部全体を撮影している．動脈相の画像はボーラストラッキング法で撮影されており,撮影時間は 22 秒~32 秒である.門脈相,平衡相の撮影時間はそれぞれ 60 秒,180 秒である.

■　手法

本手法は多時相(動脈相,門脈相,平衡相)でのリンパ節抽出,転移性リンパ節分類,時相によるリンパ節の CT 値の遷移調査からなる.(図 1) 多時相のリンパ節抽出は,血管の 2cm 以内に存在する CT 値-20~150[H.U.]程度の楕円状の塊をマニュアル抽出する(血管は腹大動脈,上腸間膜動脈系,下腸間膜動脈系,腸骨動脈系を対象にする) (図 2).転移性リンパ節分類は原発巣に対する所属リンパ節を支配血管に従って分類を行う.時相によるリンパ節の CT 値の遷

移の調査は,個々のリンパ節の中心座標を算出し,近傍 26 画素を加えた計 27 画素の CT 値平均を算出して解析を行う.

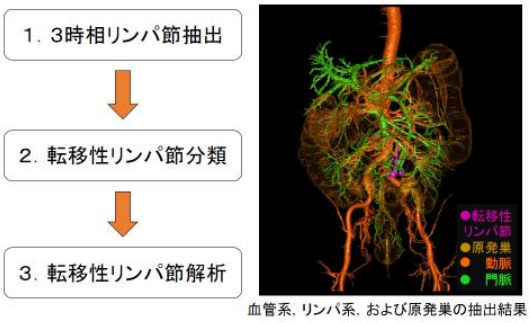

図 1.転移性リンパ節　解析手法

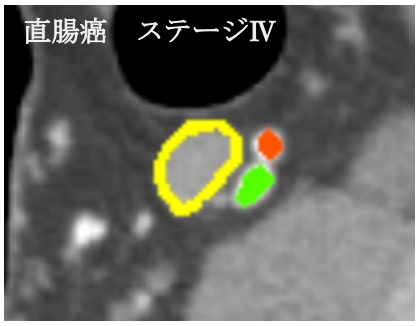

黄色:リンパ節,赤色:動脈,緑色:門脈

図 2.リンパ節抽出法

■　結果

リンパ節をマニュアル抽出,分類を行い, CT 値によるレインボースケールで可視化した.(図 3)時相によるリンパ節中心の CT 値を三次元グラフ表示し,各時相での CT 値を確認した.(図 4)軽度な症例ではリンパ節径も小さく,門脈相で最大の CT 値となるリンパ節が多い傾向にあった. しかし重症度が増すと造影剤注入後の時間経過で CT 値が上昇する傾向がみられた.

■　まとめ

造影マルチスライス CT 画像からリンパ節をマニュアル抽出し, 時相によるリンパ節の CT 値の遷移の調査を行った.転移性リンパ節は造影剤注入後の時間経過で CT 値が上昇する傾向がみられた.今後の課題として,症例数を増やすことや病期ごとのより詳細な解析が挙げられる.

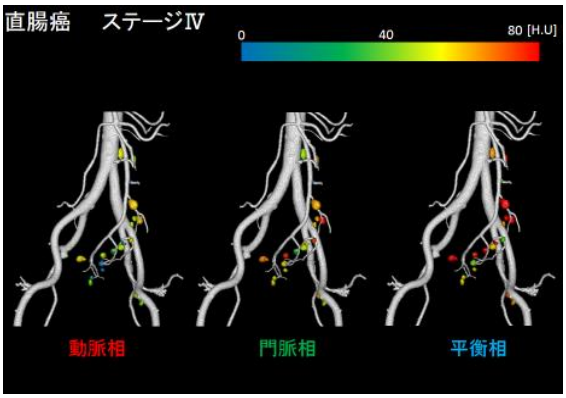

図 3.リンパ節中心 CT 値濃度可視化結果

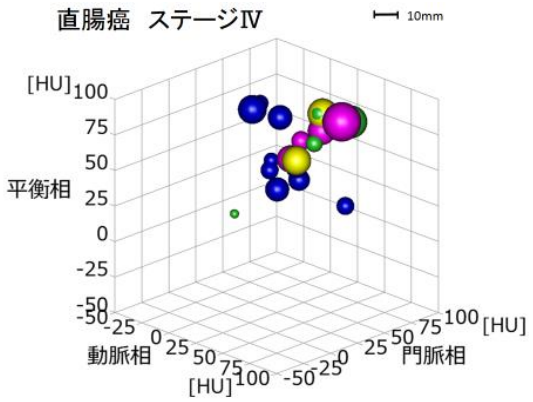

青色:腸管傍リンパ節,緑色:中間リンパ節,黄色:主リンパ節,ピンク色:リンパ節[転移有]

図 4. 動脈相・門脈相・平衡相リンパ節 CT 値濃度グラフ

利益相反の有無

なし

文　献

[1] 吉田 広行 “CT コロノグラフィによる大腸癌スクリーニングとポリープのコンピュータ支援検出” 電子情報通信学会論文誌.D, 情報・システム J91-D(7) , no.3 , pp.1730-1743, 2008.

[2] 坂東 佳祐,多時相造影 CT における大腸がんの転移性リンパ節解析,日本生体医工学会 中四国支部会,2017/10/7

Metastatic Lymph Node Analysis of Colorectal Cancer in Contrast-enhanced Multi-slice CT images

Keisuke Bando[*1)] Hidenobu Suzuki[*2)] Yoshiki Kawata[*2)] Noboru Niki[*2)] Gen Iinuma[*3)]

*1 System Innovation Engineering , Graduate School of Advanced Technology and Science, The University of Tokushima

*2 The University of Tokushima

*3 Radiology Division, National Cancer Center Hospital

Colorectal cancer is a disease that accounts for high mortality. The greatest factor in predicting the prognosis of colorectal cancer patients without distant metastasis is the presence or absence of metastasis to lymph nodes. In general, the lymph node with the larger diameter increases the possibility of metastasis, but the metastasis may be confirmed in lymph nodes with small diameters in some cases. This study is to extract lymph nodes from contrast-enhanced multi-slice CT images (arterial phase, portal vein phase, equilibrium phase) and to compare CT values between time phases to clarify features of metastatic lymph nodes.

Key words: CT, Lymph nodes, Colorectal Cancer, Multi-phase

教師なし深度推定を利用したRGB-D特徴抽出に基づくポリープのトリナリサイズ推定

伊東 隼人 [*1], Holger Roth[*1], 三澤 将史 [*2], 森 悠一 [*2],
小田 昌宏 [*1], 工藤 進英 [*2], 森 健策 [*1,3,4]

要旨

大腸内視鏡検査におけるポリープの大きさ情報 (サイズ情報) は診断において重要な役割りを果す. 5 mm 以下の小さなポリープ, 10mm 以上の大きなポリープ, それ以外のポリープといった 3 カテゴリに関するサイズ推定（トリナリ推定）は治療計画を立てる上で特に重要とされる. しかし内視鏡画像のみに基くサイズ推定は熟練の専門医にとっても難しい. そこで内視鏡画像ならびに動画像からポリープのサイズ推定を行う CAD システムが望まれている. 内視鏡画像には 3 次元情報が欠如しており, 2 次元画像からの精密なサイズ推定は不良設定問題である. 本研究ではこの不良設定問題をトリナリサイズ推定へと緩和し, 内視鏡画像からポリープのサイズ推定に有用な特徴を深層学習によって抽出, そして分類する手法を提案する. 特徴抽出においては教師無し学習による深度推定を利用する. 提案手法により高精度のトリナリサイズ推定を達成した.

キーワード: 内視鏡検査, ポリープサイズ推定, 深度情報推定, 深層学習

1. はじめに

大腸内視鏡検査におけるポリープのサイズ（大きさ）情報は診断において非常に重要な情報 [1, 2] である. 例えば, 10mm 以上のポリープは Advanced noeplasia として扱われ, 主要なサーベイランスガイドラインにおいては検査間隔を短縮せねばならない. ポリープのサイズ計測法には内視鏡観察時にスネアや鉗子などのデバイスの大きさを参考に目測する内視鏡計測と, ポリープ摘出後にプレパラートに貼り付けて固定した上でノギス計測する病理計測が存在する. 内視鏡計測を補助する目的の CAD システム構築に向け, 本稿では画像の見えのみに基いたポリープのサイズ推定方法を提案する.

2. トリナリサイズ推定問題

内視鏡画像を高さ H および幅 W である RGB 画像を $\mathcal{X} \in \mathbb{R}^{H\times W\times 3}$ とするとき, もっとも直接的なポリープサイズ s の推定を行う関数 $f(\mathcal{X})$ を考える. L_2 ノルム $\|\cdot\|_2$ および真値 s^* を用いて定義された次式

$$\|s - s^*\|_2 \text{ w.r.t. } s = f(\mathcal{X}), \tag{1}$$

を最小化する関数 f を求める回帰問題として定義できる. しかし, これは不良設定問題である. ポリープの画像上での見かけの大きさはあくまで画像面上に限れたものである. 物理的な大きさを推定するためには画像中心からの深度情報を表す深度画像が必要である. さらに, 実際の診察で重用視されるのはある閾値以下であるかどうかである.

そこでトリナリ値 $s_T, s_T^* \in \{0, 1, 2\}$ ならびに深度画像 $\boldsymbol{D}^* \in \mathbb{R}^{H\times W}$ を用いた次式

$$\|s_T - s_T^*\|_2 \text{ w.r.t. } s = f(\mathcal{X}, \boldsymbol{D}^*) \tag{2}$$

を最小化する関数

$$f(\mathcal{X}, \boldsymbol{D}^*) = \begin{cases} 0 & \text{if } s^* \in [1, 5], \\ 1 & \text{if } s^* \in [6, 9], \\ 2 & \text{otherwise,} \end{cases} \tag{3}$$

を求めることによってサイズ推定を行う. ここで s_T^* はポリープサイズの真値であり, 単位は mm とする.

[*1] 名古屋大学大学院情報学研究科知能システム専攻
[〒 464-0822 名古屋市千種区不老町]
e-mail: hitoh@mori.m.is.nagoya-u.ac.jp
[*2] 昭和大学横浜市北部病院消化器センター
[*3] 名古屋大学情報基盤センター
[*4] 国立情報学研究所医療ビッグデータ研究センター

3. サイズ推定手法

トリナリサイズ推定を行う深層学習による手法を提案する. 図 1 は 2 つの convolutional neural network(CNN) からなる提案手法の構成を示す. 1 つめの Depth CNN [3, 4] では入力画像 $\mathcal{X}$ から深度画像 $g(\mathcal{X})$ の推定を行う. Depth CNN は教師なし学習によって深度推定のモデルを学習する. フロベニウスノルム $\|\cdot\|_{\mathrm{F}}$ で正規化された $\boldsymbol{D}_N = \boldsymbol{D}^*/\|\boldsymbol{D}^*\|_{\mathrm{F}}$ に対する次式

$$\|g(\mathcal{X}) - \boldsymbol{D}_N\|_{\mathrm{F}} \tag{4}$$

を最小化して得られる情報は画像内の相対的な深度情報である. 2 つめの RGB-D CNN では入力画像に深度画像を加えた RGB-D 画像に対し、畳み込み層とプーリングを繰返して特徴量を抽出し, 3 層の全結合層によってトリナリサイズ推定を行う. RGB-D CNN は 4 チャンネルに拡張した CNN [5–7] である.

4. 実験

IRB 承認済である 73 名分の内視鏡検査動画像から, 白色光下で観察されたポリープを写したフレームのみを抽出し, これらを実験用の学習ならびにテスト画像とした . 静止画像数はそれぞれ 34,396 枚および 13,093 枚であり, これらは総計で約 150 個のポリープを多視点から撮影した画像である. 学習データとテストデータの間には患者レベルで重複がないようにした.

Depth CNN の学習においては連続する 3 つの静止画像を 1 セットとして時系列構造を利用して学習を行った。RGB-D CNN の学習においては Adam を利用し, 畳み込み層および全結合層にはバッチ正規化と Dropout をそれぞれ適応した.

図 2 は入力画像と Depth CNN の出力した深度画像を示す. 内視鏡の方向に伸びたポリープに該当する部分の輝度値が高いことが確認できる. 推定した深度画像を用いた RGB-D CNN によるトリナリサイズ推定の正診率は 73.6%であった. 深度画像を用いない場合による 63.7%であり, 提案手法の有効性が確認できた.

5. まとめ

内視鏡画像からポリープのサイズ推定問題をトリナリサイズ推定問題に緩和し, 深層学習に基くトリナリサイズ推定手法を提案した. 実験では 73 人に患者から取得したポリープの写った動画像ならびに静止画像を用いて提案手法の評価行った. 実験結果より推定した深度情報を用いた特徴量抽出の有効性が確認できた.

謝辞 本研究の一部は JSPS/MEXT 科研費 (No. 26108006, No. 17H00867) および AMED8K 等高精細映像データ利活用研究事業（課題番号 18hs0110006h0002) によった.

利益相反 なし

文献

[1] Rex D K, et al.: The American Society for Gastrointestinal Endoscopy PIVI (Preservation and Incorporation of Valuable Endoscopic Innovations) on real-time endoscopic assessment of the histology of diminutive colorectal polyps, Gastrointestinal Endoscopy, **73**: 419-422, 2011.

[2] Winawer S, et al.: Guidelines for colonoscopy surveillance after polypectomy: a consensus update by the US Multi-Society Task Force on Colorectal Cancer and the American Cancer Society, Gastroenterology, **130**: 1872-1885, 2006.

[3] Mayer N, et al.: A Large Dataset to Train Convolutional Networks for Disparity, Optical Flow, and Scene Flow Estimation, Proc. of CVPR: 2016.

[4] Zhou T, et al.: Unsupervised Learning of Depth and Ego-Motion from Video, Proc. of CVPR: 2017.

[5] Lecun Y, et al.: Gradient-based learning applied to document recognition, Proc. of IEEE, **86**: 2278-2324, 1998.

[6] Krizhevsky A, et al.: ImageNet Classification with Deep Convolutional Neural Networks, Proc. of NIPS, **1**: 1097-1105, 2012.

[7] Simonyan K, Zisserman A: Very Deep Convolutional Networks for Large-Scale Image Recognition, Proc. International Conference on Learning Representations: 2015.

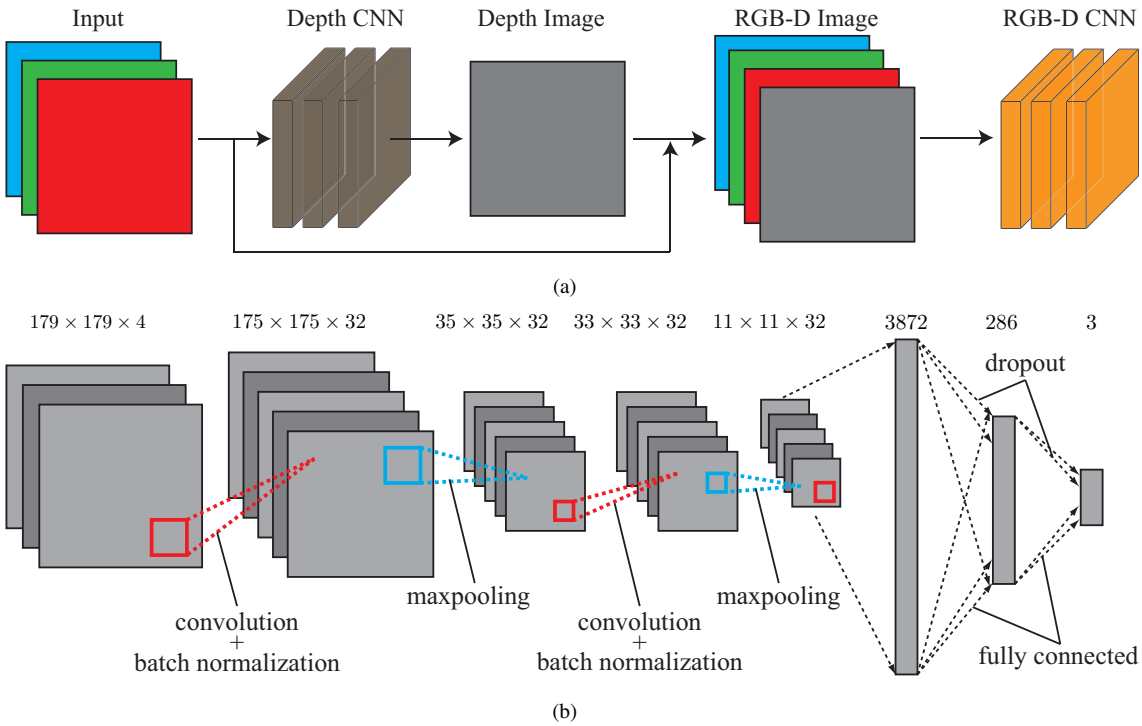

図 1 サイズ推定ネットワークの構成. (a) 全体の構成. 入力画像から深度画像を推定したのち, 入力および深度画像より特徴量抽出そしてサイズ推定を行う. (b) RGB-D CNN の構成.

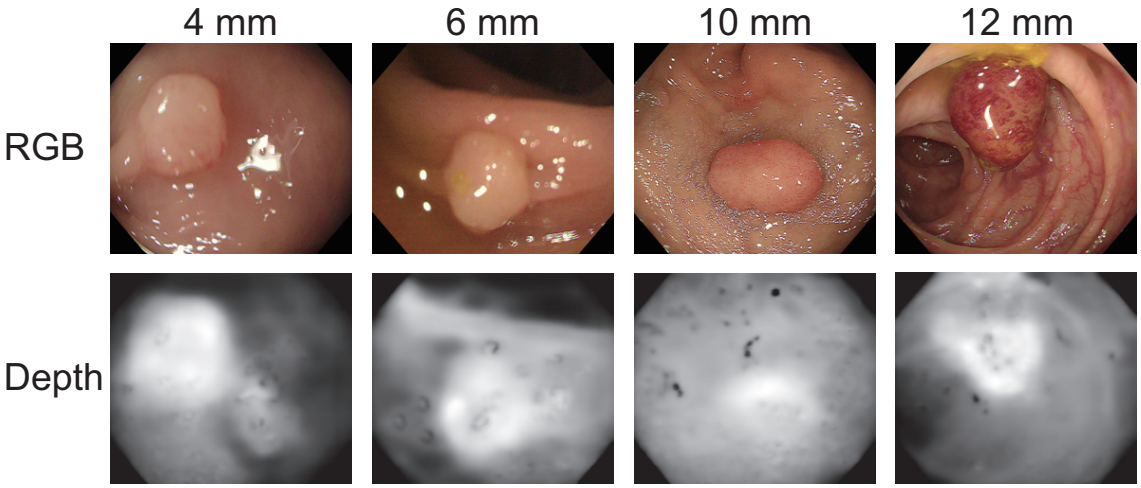

図 2 Depth CNN による内視鏡画像の深度推定結果. 上段: 異るサイズのポリープを写した内視鏡画像（RGB の 3 チャンネル画像）. 下段: 上段の内視鏡画像を入力として Depth CNN が出力した深度画像. 深度画像中の輝度値の大きな部分が内視鏡画像中で手前に突出したポリープ部分を表している.

Trinay Polyp-Size Estimation based on RGB-D Feature Extraction using Unsupervised Learning

Hayato Itoh[*1], Holger Roth[*1], Masashi Misawa[*2],
Yuichi Mori[*2], Masahiro Oda[*1], Shin-Ei Kudo[*2], Kensaku Mori[*1,3,4]

[*]1 Graduate School of Informatics, Nagoya University
[*]2 Digestive Disease Center, Showa University Northern Yokohama Hospital
[*]3 Information Technology Center, Nagoya University
[*]4 Research Center for Medical Bigdata, National Institute of Informatics

Abstract

Polyp size information is essentially important for diagnosis in colonoscopy. Three categories: 1-5mm, 6-9mm and over 10mm, are significantly important treatment plan. However, estimation of polyp size by using only colonoscopic image is really difficult even for expert colonoscopists. Therefore, CAD system that achieves robust and accurate polyp-size estimation is required. Precise polyp-size estimation from single colonoscopic image is fundamentally ill-posed problem due to the lack of information in three-dimensional space. We relax the precise polyp-size estimation to trinary-size estimation problem, and solve it by our deep learning based method. The proposed method estimates the depth map (depth image) from an input image. This depth estimation is achieved through unsupervised learning with colonoscopic movies. The proposed method extracts useful features from the four-channel image, which are consists of the input RGB and the estimated depth images, and estimates the trinary size of a polyp. The experimental results showed that the proposed method has achieved higher estimation accuracy with depth estimation strategy than the one without estimated depth information.

Keywords: Colonoscopy, polyp-size estimation, depth estimation, deep learning

3 次元 Residual networks (ResNets)を用いた 大腸 CAD における偽陽性陰影の識別

植村　知規[*1]　陸　慧敏[*1]　金　亨燮[*1]　橘　理恵[*2]

弘中　亨[*3]　Näppi　Janne [*3]　吉田　広行 [*3]

要旨

近年, 高い感度での病変検出が可能な支援診断（CADe）システムが多く提案されている. 一方で, 大腸 CADe システムでは，現在でも病変と共に疑陽性陰影も多く検出される傾向にある．そこで本論文では，疑陽性陰影の識別に焦点を当て，畳み込みニューラルネットワーク(CNN)を用いた新たなモデルである 3 次元 ResNet モデルを提案し，大腸 CADe における疑陽性陰影の識別を試みた．提案モデルは，2 層の 3 次元畳み込み層に 3 層の 3 次元残差ブロックを加えて深層化を行うことにより，腹部 CT 等の 3 次元データに対し，より深い CNN による解析を可能とする．実験では，仰臥位/伏臥位からなる腹部 CT 40 症例を用い，提案モデルと 2 次元 ResNet との比較実験を行った．実験では，両モデルの偽陽性の識別能を ROC 曲線下面積(AUC)として求め，AUC 値の統計的有意差を t 検定にて検定した．結果として 3 次元 ResNet は AUC: 0.970，2 次元 ResNet は AUC: 0.959 を示し，P=0.03 であることから，3 次元 ResNet が有意に偽陽性を高い精度で識別できることが示された.

キーワード：畳み込みニューラルネットワーク，支援診断システム，大腸ポリープ

1. はじめに

世界的に見て大腸がんは主要ながんの 1 つである. 2012 年の先進国でのがんによる死亡者数予測では，大腸がんは 4 位に位置する．1 位は乳がんであるが，乳がんが全体の約 13%，大腸がんが約 12%(図 1 参照) [1]であり, 数値的な差は非常に小さい．また本国における 2016 年のがん死亡者数予測を見ても，女性 1 位，男性 3 位[2]であることから，大腸がんが主要ながんの 1 つであることが理解できる.

このような背景から大腸 CADe (Computer Aided Detection) システムが多く提案されている．CADe は読影医の負担低減を目的としており，高感度かつ高特異度のシステムが望ましい. 多くの大腸 CADe は高感度での病変検出が可能である一方，特異度が低い，すなわち偽陽性陰影を多く検出する傾向にある．そこで本論文では，大腸 CADe 偽陽性陰影の識別に焦点を当てる.

本稿では，従来の畳み込みニューラルネットワーク(CNN: Convolutional Neural Network) に

*1 九州工業大学 機械知能工学 知能制御工学
〔〒804-8550 北九州市戸畑区仙水町 1-1〕
e-mail: uemura.tomoki820@mail.kyutech.jp
*2 大島商船高等専門学校
〔〒742-2193 山口県大島郡周防大島町大字小松 1091-1〕
*3 Massachusetts General Hospital and Harvard Medical School
〔55 Fruit Street Boston, MA 02114〕

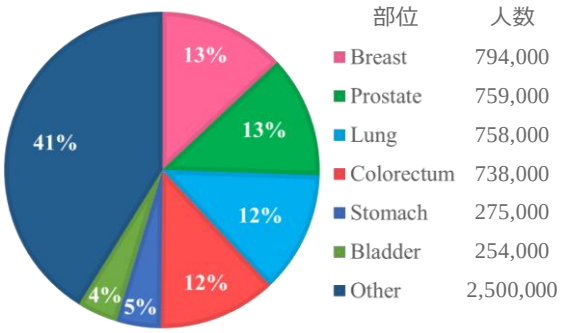

図 1 2012 年の先進国におけるがん部位別死亡者数予測．1 位: 乳がん，2 位: 前立腺がん，3 位: 肺がん，4 位: 大腸がんの順であり，これら 4 部位で全体の約 50%を占める．

おける畳み込み層の拡張を行った 3D-CNN と，ネットワークの深層化を可能とする ResNet を組み合わせることにより，モデルの識別性能が向上すると予測する．従って，CNN を用いた新たなモデルである 3 次元 Residual Network (3D-ResNet) モデルを提案し，大腸 CADe における偽陽性陰影の識別を試みる．実験では，40 症例の腹部 CT に提案法を適用し，ROC 曲線化面積 (AUC: Area Under the ROC Curve)によるモデルの性能評価と，提案モデルと従来の ResNet モデル (2D-ResNet)の AUC 値に対する t 検定による有意差検定を行った．

2. 手法

2.1. 3D-CNN

一般画像処理分野においては 2 次元フィルタカーネルを持った CNN (以下, 2D-CNN) が一般的に用いられる．一方，CT/MRI 画像といった医用画像は 3 次元データで構成されており，病変や組織は濃度分布等において空間的な特徴を持つ．従って，医用画像の解析には 3 次元のフィルタカーネルの畳み込みを行い，空間的な特徴を獲得する必要がある．そこで本論文では，2D-CNN における畳み込みカーネルの次元を 1 次元拡張し，3 次元データへの畳み込みを可能とする 3 次元 CNN (3D-CNN) を用いる．

2.2. ResNet

一般に，CNN の表現力は層の深さに依存し，深くなるほど表現力が増すとされている[3-5]．一方で，単純に畳み込み層を積み重ねることで CNN の層の深層化を図った場合，過学習に依らない性能低下を引き起こすことが知られている[6, 7]．ResNet [8]はこの問題を回避し，より深い CNN の構築を可能とする．

ResNet は Residual Block と呼ばれる特徴的なネットワーク構造を持つ(図 2)．ある入力xに対する Residual Block の出力を$H(x)$とし，2 つの畳み込み層により表現される非線形写像関数を$F(x)$とする．Residual Block では，$F(x)$は次式のように入力と出力の残差を学習する．

$$F(x) = H(x) - x \tag{1}$$

式(1)の変形により，Residual Block の出力$H(x)$は次式で表される．

$$H(x) = F(x) + x \tag{2}$$

従って，Residual Block は入力xを$F(x)$に加算する (Skipping Connection と呼ばれる) ことにより表現可能となる．Residual Block は，$F(x)$で表される畳み込み層が入力 x との残差を学習するため，深い層が識別に影響を与えない場合には，この畳み込み層の重みを 0 に近づけることにより出力$H(x)$が恒等写像を獲得する．これにより，深層化に伴う性能低下の問題を回避することが可能となる．

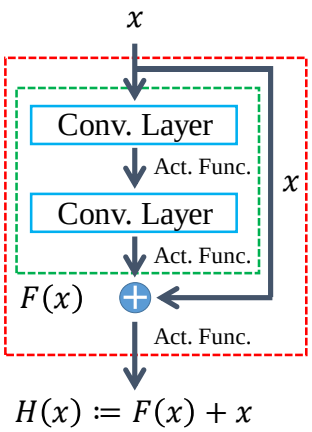

図 2 Residual Block の概要．2 つの畳み込み層によって表現される非線形写像関数$F(x)$への入力xを出力に加算することで表現される．

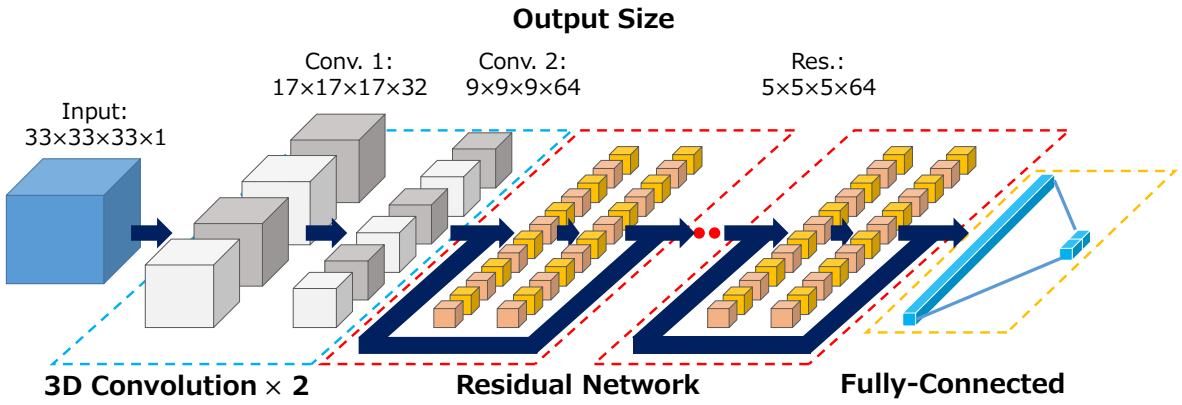

図 3 3D-ResNet の概形．2 層の 3D-CNN により局所特徴の抽出を行い，複数の Residual Block にて大局的特徴の抽出を行う．識別部には全結合層による ANN を用いる．

2.3. 3D-ResNet

本論文では，3D-CNN を用いることにより，従来の 2D-CNN と比較し識別精度が向上すると予測する．また， Residual Block を用いたネットワークの深層化により，さらに精度が向上すると予測する．

従って本稿では, 3D-CNN と ResNet を組み合わせた新たな CNN モデルである 3D-ResNet を提案する．提案モデルは 2 層の 3 次元畳み込み層と複数の Residual Block を持つ．図 3 に提案モデルの概形を示す．

提案モデルは，最初の 2 層の畳み込み層にて局所的な画像特徴の抽出を行う．その後，複数の Residual Block にて大局的特徴を捉え，最後の識別部にて全結合層による ANN (Artificial Neural Network)を用いて識別を行う．

3. 利用データ

3.1. CT データセット

本稿では, CT Colonography データセットを用いた．このデータセットには 20 症例の腹部 CT データが含まれており，それぞれ，仰臥位・伏臥位の 2 体位で撮影されている．本論文では，異なる 2 体位を独立した CT データとして扱い，合計 40 症例の CT データとした. 本データセットは，6mm 以上のポリープ病変を 65 個，5mm 以下の病変を 12 個含んでいた．

3.2. 関心領域の取得

モデルの学習および検証は，上記データセットから生成された VOI (Volume of Interest) により行った. VOI のサイズはすべて$33 \times 33 \times 33$とした．

真（True）のクラスラベルに属する大腸ポリープの VOI は，ポリープの中心位置が VOI の中央に一致するよう，手動での切り出しを行ない，計 77 個のポリープに関する VOI を得た．偽（False）のクラスラベルに属する偽陽性陰影の VOI は, 既存の CADe によって検出された点を VOI の中心に一致させ, やはり手動にて切り出しを行うことで，1 ケース当たり約 163 個，計 6,519 個の偽陽性陰影に関する VOI を得た．

3.3. データ拡張

・拡大による拡張

スケールの異なるデータを用い学習することにより，スケール変化に対し頑健なモデルが構築可能であると考えられる．そこで，$33 \times 33 \times 33$のサイズを持つ VOI 以外に，$9 \times 9 \times 9$, $17 \times 17 \times 17$のサイズでの VOI 生成も行う(図 4). これらを線形補完により基準サイズである$33 \times 33 \times 33$へ拡大し，データ拡張を行う．

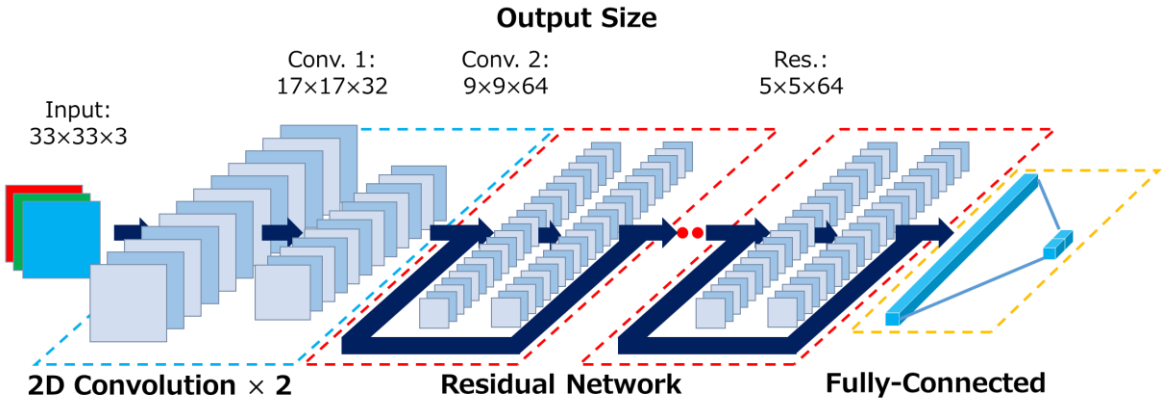

図 5 2D-ResNet の概形．図 3 に示される 3D-ResNet モデルにおける 3 次元構造(入力，畳み込み)を，全て 2 次元に置き換えることで表現される．

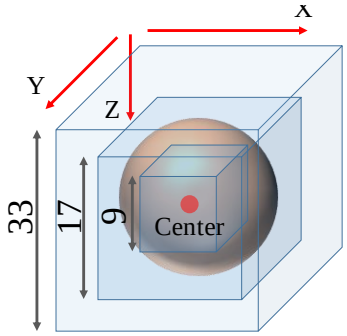

図 4 異なるサイズでの VOI の生成．注目点を中心として33^3，17^3，9^3 のサイズで切り出す．

・回転による拡張

ポリープと偽陽性に関する VOI の数におよそ 100 倍の差が存在するため，データ数を均衡に保つためにポリープの VOI に対して回転によるデータ拡張を行った．VOI の中心を回転の中心として，各軸 40 度間隔で回転を行い，81 倍に拡張を行った．

3.4. 学習・検証データセット

上記のデータ拡張後，ポリープに関して 21,021 個，偽陽性に関して 19,557 個の VOI が得られ，これらを CNN モデルの学習・検証用データとして利用した．

4. 実験方法

実験では，提案モデルである 3D-ResNet の有効性の確認のため，2 次元 ResNet (2D-ResNet) を構築して学習および検証を行った．加えて，5 分割交差検証によってモデルの精度評価を行った．

4.1. 2D-ResNet

ResNet の 3 次元拡張による有効性の検証を目的とし，従来の ResNet モデルである 2D-ResNet を構築した．本モデルは，3D-ResNet における入力を 2 次元画像とし，さらに全ての畳み込み層を 2 次元の畳み込みに置き換えたモデルである(図 5) ．

モデルへの入力となるカラー画像は，上記データセットの各 VOI の中心から取り出した Axial /Sagittal/ Coronal の 3 断面像をカラー画像における R/G/B チャンネルにそれぞれ割り当てることで生成した[9].

4.2. 学習パラメータ

CNN モデルの最適化手法として Adam[10]を用いた．Adam に関するパラメータは，学習率 lr: 0.0002，β_1: 0.5，β_2: 0.999 とした．また，学習は 10 epoch 行い，バッチサイズは 16 とした．

5. 結果と考察

5.1 実験結果

Residual Block のブロック数を変化させた場

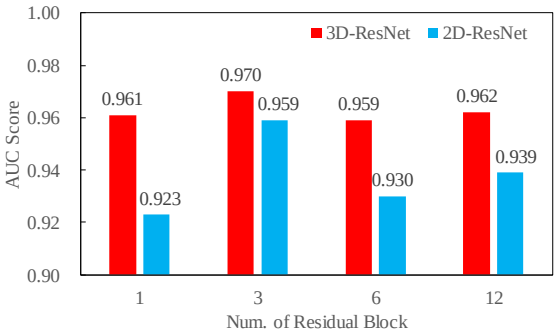

図 6 3D/2D-ResNet における Residual Block の数に対応するモデルの AUC 値.

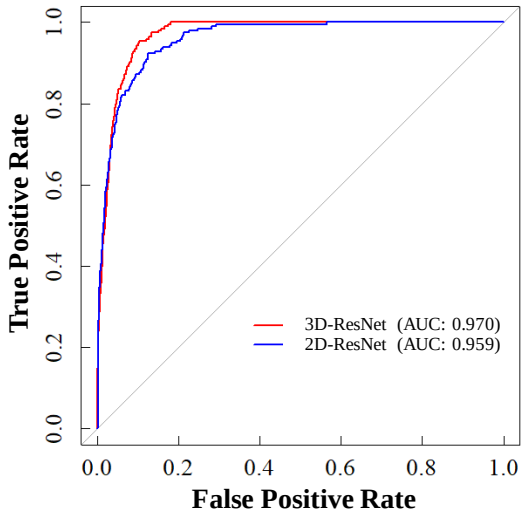

図 7 3D/2D-ResNet の ROC 曲線．3D-ResNet は AUC: 0.970，2D-ResNet は AUC: 0.959.

表 1 3D vs .2D-ResNet の各ブロック数での P 値

Num. of Blocks	1	3	6	12
P-value	4.09×10^{-7}	3.02×10^{-2}	1.91×10^{-5}	1.69×10^{-3}

合における AUC 値を図 6 に示す．図 6 より，3D-ResNet に関しては，ブロック数が 3 の場合において AUC 値が最高値を示した．また，すべてのブロックの組み合わせにおいて 3D-ResNet が 2D-ResNet よりも高い AUC 値を示した．

図 7 に，ブロック数を 3 とした場合における 3D-ResNet および 2D-ResNet の ROC (Receiver Operating Characteristics) 曲線を示す．3D-ResNet の ROC 曲線は 2D-ResNet よりも左上に位置し，3D-ResNet が 2D-ResNet よりも性能が高いことを示している．

また，AUC 値の統計的有意差を t 検定により検定を行った結果の P 値を表 1 に示す．すべての組み合わせにおいて$P < 0.05$であったため，2D-ResNet と比較して提案法の 3D-ResNet が優位に偽陽性陰影を識別可能であることが示された．また図 7 より，3D-ResNet の ROC 曲線は 2D-ResNet の ROC と交わることなく左上に近づいているため，両者には明確な性能差があることが分かる．

以上のことから，3D-ResNet は 2D-ResNet と比較して優れた性能を示し，モデルの 3 次元への拡張が有意であることが示された．

6. まとめ

本研究では偽陽性陰影の識別を目的とした新たな CNN モデルである 3D-ResNe を提案した．提案モデルは t 検定により，有意に偽陽性陰影を識別可能であることが示された．提案手法である 3D-ResNet を用いた CADe システムを構築し性能評価を行うことが，今後の課題である．

謝辞

本研究は，文部科学省卓越研究員事業(16809746)，日本学術振興会科研費(17K14694)および，NIH/NCI グラント UH2CA203730，R01EB023942，R01CA212382 の補助を受けている．

利益相反の有無

利益相反無し．

文　献

[1] J. Ferlay et al.: Cancer incidence and mortality worldwide: Sources, methods and major patterns in GLOBOCAN 2012. *Int. J. Cancer* **136**: E359–E386, 2015

[2] 国立がん研究センターがん情報サービス「がん登録・統計」. 厚生労働省大臣官房統計情報部, https://ganjoho.jp/data/reg_stat/statistics/dl/cancer_mortality(1958-2016).xls (アクセス: 2018.4.28)

[3] O. Delalleau et al.: Shallow vs. Deep Sum-Product Networks. in *Advances in Neural Information Processing Systems 24*: 666–674, 2011

[4] M. Telgarsky: Benefits of depth in neural networks. in *29th Annual Conference on Learning Theory* **49**: 1517–1539, 2016

[5] M. Raghu, et al.: On the Expressive Power of Deep Neural Networks. in *Proceedings of the 34th International Conference on Machine Learning* **70**: 2847–2854, 2017

[6] K. He, et al.: Convolutional Neural Networks at Constrained Time Cost. in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*: 5353–5360, 2015

[7] R. K. Srivastava, et al.: Highway Networks. arXiv:1505.00387, 2015.

[8] K. He, et al.: Deep Residual Learning for Image Recognition. in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*: 770–778, 2016

[9] 植村知規 他: 転移深層学習畳み込みニューラルネットワークを用いたCTコロノグラフィ候補陰影からのポリープ分類法. 医用画像情報学会雑誌 **34**: 80–86, 2017

3D Residual Networks (ResNets) for Discrimination of False Positives in Computer-aided Detection of Colonic Polyps

Tomoki UEMURA[*1], Huimin LU[*1], Hyoungseop KIM[*1], Rie TACHIBANA[*2],
Toru HIRONAKA[*3], Janne NÄPPI[*3], Hiroyuki YOSHIDA[*3]

*1 Kyushu Institute of Technology
*2 Institute of National Colleges of Technology
*3 Massachusetts General Hospital and Harvard Medical School

Several computer-aided detection (CADe) systems have been proposed to support the interpretation of medical images. Although the use of CADe has showed significant improvements in the detection of polyps in CT colonography, current CADe systems tend to prompt too many false-positive detections. Convolutional neural networks (CNNs) have recently demonstrated ability to reduce the number of false-positive CADe detections. However, current CNN architectures are largely based on 2D image analysis whereas CT colonography is a 3D imaging modality. In this study, we propose to use a novel 3D-ResNet CNN for excluding false-positive polyp detections in colon CADe. In our 3D-ResNet, we employed two 3D-convolutional layers and several residual blocks. We hypothesized that the combination of 3D-convolutional layers and residual blocks significantly improves the ability of a CNN to discriminate between true polyps and false positives as compared with a conventional 2D-ResNet. We evaluated the discrimination performance of the proposed 3D-ResNet and a conventional 2D-ResNet on CADe detections from 40 supine and prone CT colonography datasets of 20 patients. The figure of merit for the discrimination performance was the area under the receiver operating characteristic curve (AUC). Preliminary evaluation yielded an AUC value of 0.970 for the 3D-ResNet and an AUC value of 0.959 for the 2D-ResNet. A two-tailed t-test showed that the difference between the AUC values was statistically significant ($p = 0.03$). Therefore, our 3D-ResNet reduces the number of false-positive CADe detections more effectively than a conventional 2D-ResNet, and therefore it has potential to substantially improve the detection of polyps in colon CADe.

Key words: Convolutional Neural Networks, Computer Aided Detection, Colorectal Polyps

CNN を用いた自己進化型 CAD システムの提案

安倍　和弥[*1]　武尾　英哉[*1]　永井　優一[*2]　縄野　繁[*3]

要旨

近年，CAD の研究分野にも CNN が積極的に用いられるようになった．一般的に，機械学習には様々なバリエーションを持った症例画像を網羅的に与えて学習を行うことで，汎用的で高性能な判別器を設計する．これは，学習に含まれていない画像はうまく検出ができないと考えられるからである．実際に比較的典型的な症例のみを使って学習した CNN と症例を網羅して学習した CNN では後者の方が性能が高いことが確認された．これは CAD のリリース時にも同様のことが考えられる．開発時に用いる症例は，実際に運用する病院での症例を網羅しているとは限らないからである．

そこで本論文では，再学習機能を組み込んだ自己進化型 CAD システムを提案する．従来の CAD システムはリリース後に判別器を更新することはできなかった．そこで，CAD システムに読影レポート情報（電子カルテ）を利用した誤認識訂正機能を持たせ，ある一定のデータを適用した後に再学習を行うことで判別器を更新する仕組みを提案する．本機能により，再学習を行わない場合と比べて性能の向上が見られた．また，複数回の再学習によって段階的な性能向上も見られ，その病院にマッチした CAD に進化していく過程も確認された．

キーワード：乳がん，腫瘤影，CNN，自己進化型 CAD，再学習

1. はじめに

近年，医療の現場では CT や MRI など撮影装置の高精細化により生成される医用画像の量が増大している．撮影される画像の枚数は患者一人あたり数百枚にもおよび，それを読影する医師の負担も急増している．そのため診断の補助を行うコンピュータ画像支援診断（Computer Aided Diagnosis/Detection : CAD）の開発が非常に重要視されている．

その CAD の研究分野においても人工知能，AI を用いた研究が進められている．その中でも画像認識手法である CNN（Convolutional Neural Network）は積極的に用いられるようになった[1]．一般的に，機械学習には様々なバリエーションを持った症例画像を網羅的に与えて学習を行うことで，汎用的で高性能な判別器を設計する．これは，学習に含まれていない画像はうまく検出ができないと考えられるからである．これは CAD のリリース時にも同様のことが考えられる．開発時に用いる症例は，実際に運用する病院での症例を網羅しているとは限らないからである．また，特にマンモグラフィの場合は，各病院で様々な撮影系にて行われているため，画質が異なることがある．このような場合施設特有の画像へ CAD がマッチしていくことは有用と考えられる．そこで本論文では，再学習機能を組み込んだ進化型 CAD システムを提案する．

CNN を用いた乳がん腫瘤影の検出は Al-masni ら[2,3]や Tan ら[4]などが行っているが，これらは開発と評価に用いるデータを同一のデータベースから分ける形で使用している．そのため画質が異なる場合のあるマンモグラフィにおいては，実際のリリース時にも

*1 神奈川工科大学工学部電気電子情報工学科
〔〒243-0292 厚木市下荻野 1030〕
e-mail: abex0930@ele.kanagawa-it.ac.jp
*2 国立がん研究センター東病院
*3 国際医療福祉大学三田病院

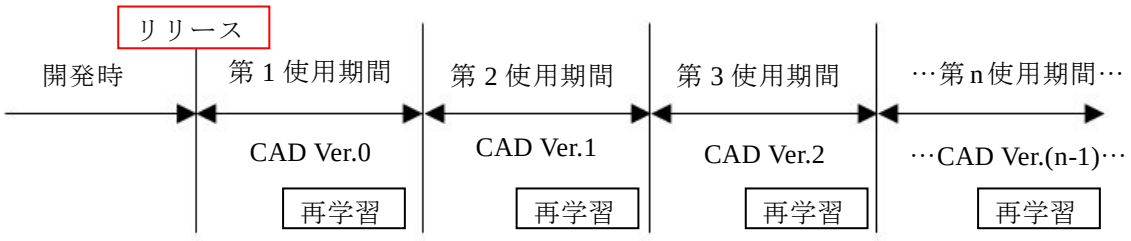

図 1　CAD システムの進化の流れ

すべての施設の画像で同様の結果となるとは保証できない.

自己進化型 CAD システムは，評価を行った症例を追加して再学習を行うことにより，学習回数が上がるにつれて使用する施設の症例に最適な判別器に進化することが可能である. 再学習の流れを図 1 に示す. 開発時の CAD を一定期間使用し（第 1 使用期間），その後に集まった症例を追加して再学習(Ver.1)．Ver.1 を一定期間使用し（第 2 使用期間），集まった症例を追加して再学習(Ver.2)．このように一定期間ごとに再学習を行い，より使用施設に最適な CAD へと進化させる.

一方，CNN の特性として，データの質による性能の低下も考えられる．再学習の際に誤りデータなどが混入した場合の性能低下も考えられる．そのため，追加症例の質による性能変化の検討も併せて行う.

本論文のポイントを以下に示す.

① 再学習時の追加症例の質の検討

② 自己進化型 CAD システムの検討

本論文では，2 章で学習データセットの質的検討，3 章で自己進化型 CAD システムの検討・評価の結果を示す．4 章にて考察，5 章にて本研究のまとめについて述べる.

2. 学習データセットの質的検討

2.1　乳がん腫瘤影判別用 CNN

乳がん腫瘤影判別の CNN は Al-masni らの手法[2]や藤田らの書籍[5]を参考に yolo[6]を用いて作成した．OS は ubuntu16.04，cuda8.0 を用いて GPU を利用した学習を行っている.

2.2　症例の質による CNN の性能変化

自己進化型 CAD の開発にあたって学習データセットの質の検討を行った．自己進化型学習を行う場合, CAD にて評価した画像を一定量貯めた後，学習データとして追加して再学習を行う．この追加する症例の質による CNN の性能変化を検討した.

開発時の CNN はがん症例 40 例で学習，第 1 使用期間後の評価としてがん症例 40 例，非がん症例 40 例を使用した．その後，評価に使用した画像を, FP 率が 10%の時の検出結果を基に誤認識訂正を行う場合と行わない場合での 2 通りで画像を追加し再学習を行い，質の違いによる性能の変化を調べた．誤認識訂正を行った場合の追加数は，がん症例 40 例，行わなかった場合は, がん症例 15 例と非がん症例 4 例が追加されている.

結果の ROC グラフを図 2 に, Az(ROC グラフの下面積)を表 1 に示す．ROC は学習用とは別に用意したテストデータ，がん症例 40 例, 非がん症例 40 例を使用して評価している.

表 1　誤認識訂正の有無による評価の比較

	Az	
	誤認識訂正を行う場合	誤認識訂正を行わない場合
開発時	0.75	
再学習 1 回目	0.90	0.84

表 1 及び図 2(a)(b)より初期学習の CNN と誤認識訂正を行った CNN を比較すると判別性能が著しく向上しているのが見てとれる.

一方，図 2(a)(c)より誤認識訂正を行わなかった場合においても性能は上昇したが，訂正を行った場合ほどの向上は見られなかった．また，再学習の回数が増加するにつれて非がん症例の個数も増加していくため，回数が増えるにつれ性能が低下する傾向が見られた．よって進化型 CAD には誤認識を訂正する機能が求められる．

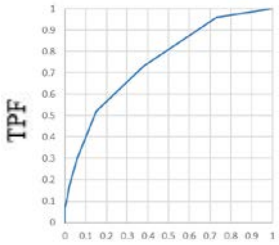

(a) 開発時の CNN

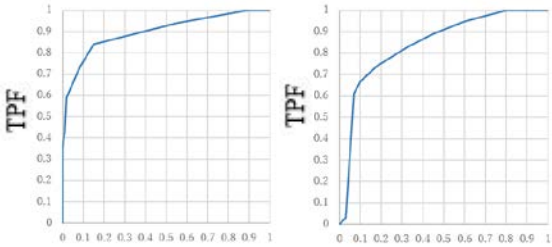

(b) 誤認識訂正あり　(c) 誤認識訂正なし

図 2　追加症例の質の評価

2.3　誤認識訂正機能

現在の医療現場において読影レポート情報（電子カルテ）はほぼ全ての現場にて使用されている．電子カルテには医師の所見を書き込むシェーマ機能があり，乳がん腫瘤影においても実際の乳房の形状を基にスケッチを行える（図 3）．そのスケッチ情報を読み込み，医師のマーク座標から正解座標を算出する．CAD の検出した腫瘤影の座標と正解座標を比較して誤検出領域の除去と検出ミスの領域の拾い直しを行う．このような電子カルテの情報を利用した学習型 CAD を作成することにより，誤認識訂正を行っての再学習が可能となる．

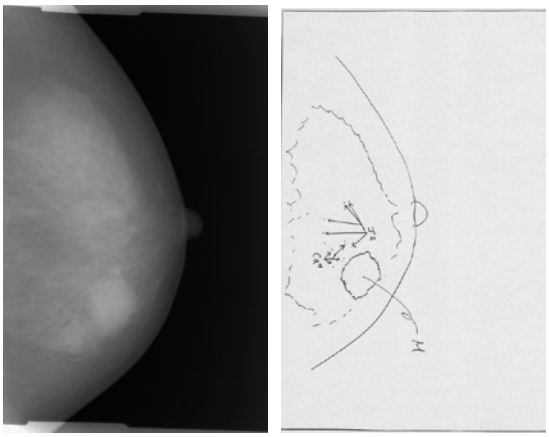

図 3　シェーマ図

3. 自己進化型 CAD システムの性能評価

2 章の結果より，自己進化型 CAD は誤認識症例の訂正を行うことで性能の上昇が確認された．

本章では 2 章と同様に初期の CNN を作成，以降段階的に症例データを追加し CNN の再学習による性能向上についての検討を行った．

評価にあたり，用意した学習データを腫瘤影の大小と，腫瘤内と辺縁での濃淡の差を基に次の A～D の 4 等分に分割した．

・A：サイズ 5cm 以上，濃淡差が 80 以上
・B：サイズ 5cm 以上，濃淡差が 80 未満
・C：サイズ 5cm 未満，濃淡差が 50 以上
・D：サイズ 5cm 未満，濃淡差が 50 未満

開発時の学習を A のみ 40 例で学習した CNN と ABCD を各 10 例ずつの 40 例で学習した CNN を作成した．これは，症例の偏りを使用施設による症例画像の質の違いに見立てて検討を行うためである．以降の再学習は ABCD 各 10 例の 40 例を追加する形で，計 3 回追加を行い性能の評価を行った．

各々の結果の ROC グラフを図 4，図 5 に，Az(ROC グラフの下面積)を表 2 に示す．ROC は学習用とは別に用意したテストデータ，がん症例 100 例，非がん症例 100 例を使用して評価している．

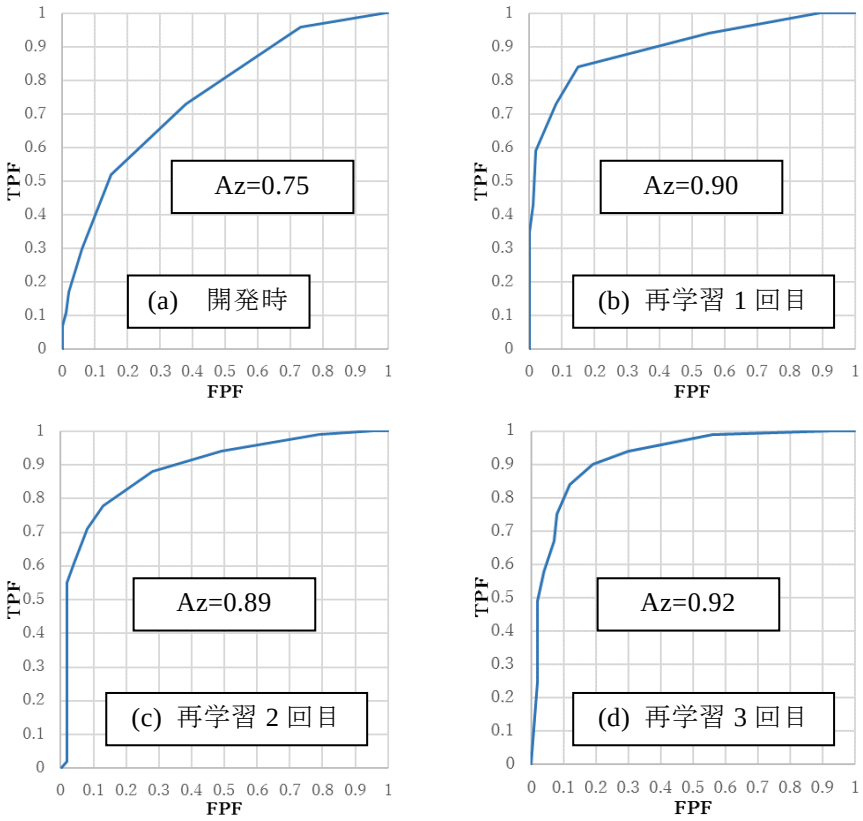

図 4　A のみで開発した CNN の進化

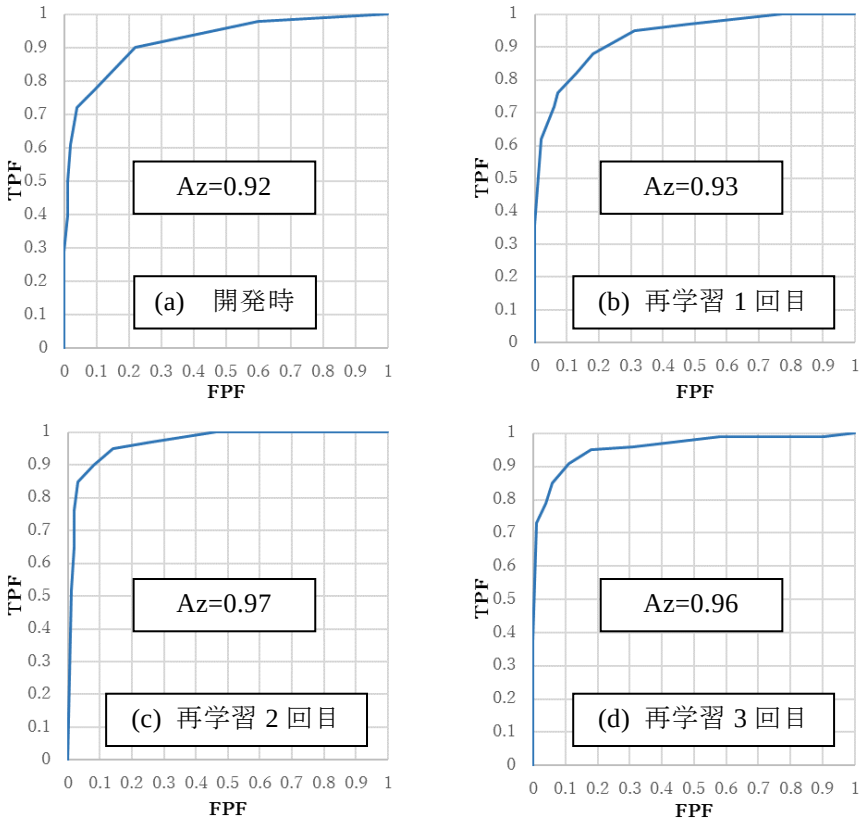

図 5　ABCD 網羅で開発した CNN の進化

表 2　再学習による最適化

	Az	
	A のみで学習	ABCD を網羅
開発時	0.75	0.92
再学習 1 回目	0.90	0.93
再学習 2 回目	0.89	0.97
再学習 3 回目	0.92	0.96

表 2 及び図 4, 図 5 より A のみでの開発時, ABCD での開発時の両 CNN ともに性能向上が見られる．再学習 3 回では A のみからの学習でも Az が 0.92 以上，ABCD 網羅からでは Az が 0.96 以上と高性能の CNN に進化していることが確認できる．A のみで開発した CNN では著しく検出性能が向上しており，再学習によって実際に使用する施設の症例により適応した CNN に進化していると示唆できる．また，ABCD を網羅して開発した CNN においても上り幅こそ緩やかではあるか向上が見られる．これらの結果より，施設による症例画像の質の偏りに影響されることなく，再学習によって検出性能の向上が見込めることが確認できる．

4. 考察

2 章の表 1 より，CNN に追加する症例の質の重要性が確認できる．また，自己進化型 CAD では再学習の際に追加する症例の質により性能が低下する可能性が確認された．非がん症例が少数でも加わってしまうと Az が大きく低下する．これに対して誤認識訂正機能を導入し，誤認識を訂正した場合では検出性能の向上が見られた．この誤認識訂正機能は，ほぼすべての病院で導入されている電子カルテの情報を組み込むことにより可能であると考えられる．

3 章の表 2 より，自己進化型 CAD は再学習を行うことにより性能が向上することが確認できた．また，開発機関の持つ症例データと実運用を行う施設での症例に差があった場合においても，再学習ごとに性能が向上し，より使用する施設に最適な CNN へと進化することが確認できた．ABCD を網羅した CNN では途中で性能が飽和しているように見えるが，低性能での飽和ではないため再学習における CAD の性能保障になると考えられる．ABCD を網羅した CNN の再学習 3 回目時の FROC を図 6 に示す．これまでに示した ROC グラフは CAD システムの判別処理（腫瘤影候補検出後の FP 除去処理）の性能についてのものである．一方，CAD システム全体の性能を検討するために，候補検出処理を含めた検出性能を FROC で示した．図 6 では，過去に筆者らによって開発された候補検出処理[7]を含めた CAD システム全体を FROC として示したものである．なおこの手法では，乳がん腫瘤影の候補領域を，適応リングフィルタを用いて検出を行っている．FP 数が 0.5[個/image]で約 90%の TP 率となった．現在の一般的な乳がん CAD が同 FP 数で約 85%程度であるため，本 CAD は良好な検出結果であったいえる．

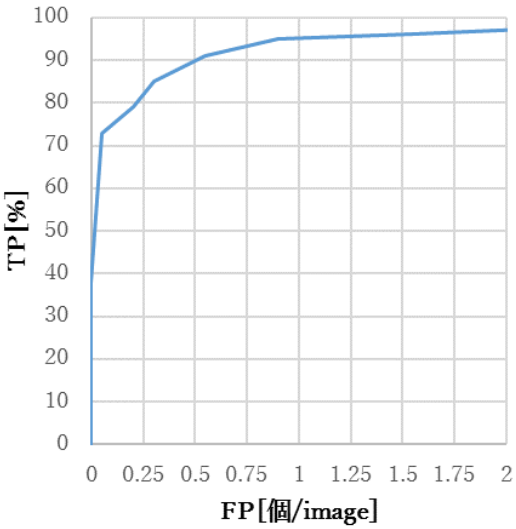

図 6　システム全体の FROC 性能

5. まとめ

本論では，学習に用いるデータデットの質の検討，およびそれを用いた再学習による自己進化型 CAD システムについての提案と検

討を行った．その結果，CNN はやはり矛盾が起こるデータを少数でも加えてしまうと性能が著しく低下することが確認できた．それに対し電子カルテ情報を利用した誤認識訂正機能を組み込むことにより，再学習における矛盾データの混入を防ぐ手法を提起した．
さらに，開発機関と実運用を行う施設で症例データに差があった場合においても，複数回再学習を行うことにより段階的な精度向上が見られることが確認できた．また，意図的に網羅した症例での CNN においても，上り幅は緩やかではあったものの再学習による性能の向上は確認できた．

本提案システムは，国内薬事（薬機法）や FDA 認可時には問題が発生する懸念がある．認可の審査時の性能が再学習を行った際に保証されない可能性があるためである．本論での実験においては開発時性能と比較しての再学習による検出性能の低下は見られなかったが，可能性としては否めないものである．

利益相反の有無

利益相反　なし

倫理規範の順守

本研究にて使用した患者の症例データは，すべての患者の初診時に撮影画像の研究利用も含めた「包括的合意」にサインを受け，また各病院にて稟議を通したうえで提供を受けたものを使用している．

文　献

［1］ Robertson S, Hartman J, Robertson S et al: Digital image analysis in breast pathology-from image processing techniques to artificial intelligence. Translational Research Vol.194, pp.19-35, 2018

［2］ Al-masni M. A., Al-antari M. A., Park J et al: Simultaneous detection and classification of breast masses in digital mammograms via a deep learning YOLO-based CAD system. Computer Methods and Programs in Biomedicine Vol.157, pp.85-94, 2018

［3］ Al-masni M. A., Al-antari M. A., Park J et al: Detection and classification of the breast abnormalities in digital mammograms via regional Convolutional Neural Network. IEEE Conf Proc. No.EMBC. pp.1230-1233, 2017

［4］ Tan Y. J., Sim K. S., Ting F. F: Breast cancer detection using convolutional neural networks for mammogram imaging system. IEEE Conf Proc. No.ICORAS. pp.1-5, 2017

［5］ 藤田一弥，高原歩：実装ディープラーニング．オーム社，東京，2016, pp150-167

［6］ Joseph R, Santosh D, Ross G et al: You Only Look Once: Unified, Real-Time Object Detection. Computer Vision and Pattern Recognition, arXiv:1506.02640, 2015

［7］ 武尾英哉，志村一男，今村貴志，他：乳房 CR 画像を用いた異常陰影検出システムの開発と性能評価．Med Imag Tech **22**(4): 201-214，2004

Proposal for self-evolving CAD system using CNN

Kazuya ABE[*1], Hideya TAKEO[*1], Yuuichi NAGAI[*2], Shigeru NAWANO[*3]

*1 Kanagawa Institute of Technology

*2 National Cancer Center Hospital East

*3 International University of Health and Welfare, Mita Hospital

In recent years, convolutional neural networks (CNN) have found active application in the field of computer-aided diagnosis (CAD). Typically, general-purpose, high performance detectors are designed by conducting machine learning provided with comprehensive sets of case images having different kinds of variations. The reasoning behind this is that images not included in learning are not expected to be successfully detected. In fact, a comparison of CNN trained using only relatively typical cases and CNN trained using a comprehensive set of cases showed superior performance by the latter. Such is also expected to be the case in the commercial release of CAD. This is because the cases used in development may not encompass the cases at the medical facilities that will actually operate the system.

In response to this situation, this paper proposes a self-evolving CAD system that incorporates a relearning function. It is not possible to upgrade the detectors of previous CAD systems following their commercial release. As a remedy, we propose a mechanism for upgrading the detector, accomplished by endowing the CAD system with a misrecognition correction function that uses interpretation report information (i.e., electronic medical records), and performing relearning after certain data is applied. This function provided improved performance compared to when relearning is not performed. Moreover, multiple relearning resulted in gradual improvements, demonstrating a process by which the system evolved into a CAD system matched to the involved medical facility.

Key words: Breast Cancer, Tumor Mass, CNN, Self-evolving CAD, Relearning

著者紹介

安倍　和弥（あべ　かずや）
2010年神奈川工科大工学部電気電子工学科卒，2012年同大大学院博士前期課程修了，2015年同大博士後期課程修了．2015年同大日本人客員研究員．現在同大バイオメディカル研究センターのポスト・ドクター．博士（工学）．医用画像・細胞培養画像などの画像工学の研究に従事．第6回および第8回JAMIT-CADコンテスト優勝．本学会会員．

武尾　英哉（たけお　ひでや）
1984年神奈川大工学部卒，1986年同大大学院修士課程了．同年富士フィルム株式会社に入社．医用画像処理システムに関する研究・開発に従事．2005年東京農工大大学院博士後期課程了．博士（工学）．2006年神奈川工科大工学部助教授．現在同大教授．医用・フォト・シネマ映像などの画像工学の研究に従事．2004年度本学会論文賞．第6回および第8回JAMIT-CADコンテスト優勝．本学会，映像情報メディア学会，画像電子学会，電子情報通信学会，医用画像情報学会各会員．

永井　優一（ながい　ゆういち）
1991年中央医療技術専門学校夜間部卒．1991年より国立療養所松戸病院放射線科，1992年より国立がんセンター東病院放射線部，2006年より国立がんセンター中央病院（現独立行政法人国立がんセンター中央病院）放射線診断部消化器官撮影主任，2015年より東埼玉病院放射線科副診療放射線技師長，中央医療技術専門学校非常勤講師（画像工学），全国国立病院療養所放射線技師会常任理事，2017年より国立がんセンター東病院放射線部放射線診断技術室副放射線診断技術室長，現在に至る．診療放射線技師．医用画像解析の研究に従事．日本放射線技術学会会員．

縄野　繁（なわの　しげる）
1981年千葉大学医学部卒，同年千葉大学医学部付属病院放射線科研修医．1982年同助手．1986年国立がんセンター病院放射線診断部医員．1992年7月1日国立がんセンター東病院放射線部医長．2002年4月1日同部長．2007年4月1日国際医療福祉大学三田病院放射線診断センター教授．日本医用画像工学会，日本医学放射線学会専門医，日本核医学会専門医，日本磁気共鳴医学会，北米放射線学会，CT・MRIの診断，消化管X線診断．

第 37 回日本医用画像工学会大会（JAMIT2018）
大会役員委員会名簿

五十音順・敬称略

大会長	
工藤　博幸	筑波大学
大会長補佐	
滝沢　穂高	筑波大学
プログラム委員会	
委員長	
目加田慶人	中京大学
委　員	
有村　秀孝	九州大学
伊藤　聡志	宇都宮大学
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	熊本大学
小田　昌宏	名古屋大学
小尾　高史	東京工業大学
河田　佳樹	徳島大学
北坂　孝幸	愛知工業大学
北村　圭司	株式会社島津製作所
木戸　尚治	山口大学
金　　亨燮	九州工業大学
木村　裕一	近畿大学
佐藤　嘉伸	奈良先端科学技術大学院大学
椎名　　毅	京都大学
清水　昭伸	東京農工大学
周　　向栄	岐阜大学
庄野　　逸	電気通信大学
菅　　幹生	千葉大学
杉本　直三	京都大学
滝沢　穂高	筑波大学
武田　　徹	北里大学
田中　利恵	金沢大学
陳　　延偉	立命館大学
中口　俊哉	千葉大学
中田　典生	東京慈恵会医科大学
根本　充貴	近畿大学
野村　行弘	東京大学
花岡　昇平	東京大学
羽石　秀昭	千葉大学
原　　武史	岐阜大学
平野　　靖	山口大学
本谷　秀堅	名古屋工業大学
増谷　佳孝	広島市立大学
宮崎　　靖	日立製作所
森　　健策	名古屋大学
八上　全弘	京都大学
山谷　泰賀	量子科学技術研究開発機構
湯浅　哲也	山形大学

業務委員会	
委員長	
原口　　剛	コニカミノルタ

日本医用画像工学会（JAMIT）
役員名簿
（平成30年5月15日現在）

五十音順・敬称略

	氏名	所属
会　長	尾川　浩一	法政大学
副会長	工藤　博幸	筑波大学
	佐藤　嘉伸	奈良先端科学技術大学院大学
	羽石　秀昭	千葉大学
常任幹事	小尾　高史	東京工業大学
	清水　昭伸	東京農工大学
	中田　典生	東京慈恵会医科大学
	原　武史	岐阜大学
	原口　剛	コニカミノルタ
	花岡　昇平	東京大学
	宮崎　靖	日立製作所
	目加田慶人	中京大学
	山谷　泰賀	量子科学技術研究開発機構
	湯浅　哲也	山形大学
幹　事	石垣　武男	名古屋城北放射線科クリニック
	伊藤　聡志	宇都宮大学
	上村　幸司	国立循環器病研究センター
	大松　広伸	網走刑務所
	岡田　知久	京都大学
	掛川　誠	浜松ホトニクス
	勝俣健一郎	国際医療福祉大学
	北坂　孝幸	愛知工業大学
	木戸　尚治	山口大学
	黒木　嘉典	新村病院、博愛会 HPN 東京
	真田　茂	小松短期大学
	篠川　毅	島津製作所
	杉本　直三	京都大学
	滝沢　穂高	筑波大学
	武田　徹	北里大学
	陳　延偉	立命館大学
	土居　篤博	富士フイルム
	縄野　繁	国際医療福祉大学
	仁木　登	徳島大学
	西原栄太郎	キヤノンメディカルシステムズ
	長谷川純一	中京大学
	畑中　裕司	滋賀県立大学
	平野　靖	山口大学
	藤田　広志	岐阜大学
	細羽　実	京都医療科学大学
	増谷　佳孝	広島市立大学
	森　健策	名古屋大学
	森　雅樹	札幌厚生病院
監　事	安藤　裕	埼玉メディカルセンター
	川岸　将実	キヤノン