Communication of the Imaging Group of the JSRT

画像通信 2019年10月

Vol.42 No.2(通巻 83)

☆ 第86回画像部会『深層学習による画像研究の実践編』

Educational Lecture

「深層学習を用いた医用画像処理研究の最前線」

Intellectual Discussion

「JSRT データベースではじめる Deep Learning」

1「JSRT データベース紹介」

2. 「畳み込みニューラルネットワークによる肺結節良悪性鑑

別「畳み込みニューラルネットワークによる胸部画像領域抽出処理」

4. 「畳み込みニューラルネットワークによる肺結節検出処理」

名古屋大学大学院情報学研究科 小田 昌宏

岐阜大学 教育学部 技術教育講座 福岡 大輔 立命館大学 理工学部 中山 良平

茨城県立こども病院 放射線技術科 本元 強 藤田医科大学 医療科学部 放射線学科 寺本 篤司

☆ 技術紹介:

①「FUJIFILM の動画 X 線システムについて~ 静止画から動画へ ~」 富士フイルムメディカル株式会社 MS 事業部 石井 伸英 ②「被ばく低減に貢献する Deep Learning を用いた新しい CT 画像再構成技術」

キヤノンメディカルシステムズ株式会社 CT 営業部 アドバンスト CT プロモーション担当 岡部 貴浩

☆ 読者のページ:

①「第 40 回プログラミングセミナーを受講して」

②「第 40 回医用画像処理プログラミングセミナーを受講して」

③「第6回臨床画像評価セミナーを受講して」

④「第6回臨床画像評価セミナーに参加して」

九州大学病院 医療技術部 放射線部門 酒井 友貴 大分県立病院 放射線技術部 西嶋 康二郎

浜松医科大学医学部附属病院 放射線部 福岡 通大

紀南病院 放射線科 山崎 純

☆ 専門部会講座(入門編):「モニタ評価入門」

名古屋第二赤十字病院 医療技術部放射線科 新美 孝永

☆ 専門部会講座(入門編):「SNR, NEQ, DQE」

東海大学医学部付属八王子病院 診療技術部 放射線技術科 由地 良太郎

☆ 大学/研究室/研究会紹介:

①「藤田医科大学 医療科学部 放射線学科 寺本研究室の紹介」

藤田医科大学 医療科学部 放射線学科 寺本 篤司 広島国際大学 保健医療学部 診療放射線学科 山本 めぐみ

②「中高生対象メディカルサイエンス講座の紹介」

☆ 国際会議案内·報告:

熊本大学 保健学教育部 和田 菜摘美

①「国際会議参加報告書 CARS2019」 ②「CARS 参加報告」

帝京大学大学院 保健学研究科 診療放射線科学専攻 博士前期課程 村上 理映

☆ 新委員紹介:

①「画像部会委員に就任して」

藤田医科大学 医療科学部 放射線学科 寺本 篤司

立命館大学 理工学部 中山 良平

②「画像部会委員に就任して」 ③「画像部会委員に就任して」

東海大学医学部付属八王子病院 診療技術部 放射線技術科 由地 良太郎

☆ 画像部会 HP「研究情報サイト」の紹介:「画像部会『研究情報サイト』のご案内」 岐阜大学 オ

岐阜大学 教育学部 技術教育講座 福岡 大輔

☆ 標準ディジタル画像データベース(胸部腫瘤陰影像)の紹介

☆ 画像部会入会案内



公益社団法人 日本放射線技術学会 画 像 部 会

第87回 画像部会予告

日 時:2020年4月10(金)~12日(日)第76回日本放射線技術学会総会学術大会期間中予定

会 場:パシフィコ横浜

テーマ「深層学習を放射線技術研究に利用する」(仮題)

Educational Course:

「医療画像診断と深層学習 放射線技師,技術者に医師が期待する事(仮題)」

Intellectual Discussion:

- 1) 分類「わける」(仮題)
- 2) セグメンテーション「検出する」(仮題)
- 3) 超高解像度「推定する」(仮題)
- 4) GAN「作る」(仮題)

画像部会委員 氏名・所属・電子メール

篠原 範充 (画像部会長)

岐阜医療科学大学保健科学部放射線技術学科

小野寺 崇 東北大学病院診療技術部放射線部門

田中 利恵 金沢大学医薬保健研究域保健学系

寺本 篤司 藤田医科大学医療科学部

中山 良平 立命館大学理工学部

東出 了 鈴鹿医療科学大学保健衛生学部

柳田 智 つくば国際大学医療保健学部 山本 めぐみ 広島国際大学保健医療学部

由地 良太郎 東海大学医学部付属八王子病院

shinohara@u-gifu-ms.ac.jp

onodera@rad.hosp.tohoku.ac.jp

rie44@mhs.mp.kanazawa-u.ac.jp

teramoto@fujita-hu.ac.jp ryohei@fc.ritsumei.ac.jp

raryo@suzuka-u. ac. jp

s-yanagita@tius.ac.jp

m-yamamo@hirokoku-u.ac.jp

ryotaro.yuji@gmail.com

画像部会についてご意見やご希望等がありましたらご連絡ください. 画像部会に関する情報は、以下の web ページをご利用ください.

日本放射線技術学会: http://www.jsrt.or.jp

画像部会: http://imgcom.jsrt.or.jp

第86回画像部会プログラム

日時: 2019年 10月15日(土)8:50~11:50

会場:グランキューブ大阪(大阪府立国際会議場) 第6会場

テーマ「深層学習による画像研究の実践編」

1. Educational Lecture:

司会 金沢大学 田中 利恵

「深層学習を用いた医用画像処理研究の最前線」

名古屋大学院 小田 昌宏

2. Intellectual Discussion:

「JSRT データベースではじめる Deep Learning」

司会 岐阜医療科学大学 篠原 範充 広島国際大学 山本 めぐみ

1. JSRT データベース紹介

岐阜大学 福岡 大輔

2. 畳み込みニューラルネットワークによる肺結節良悪性鑑別

立命館大学 中山 良平

3. 畳み込みニューラルネットワークによる胸部領域抽出処理

茨城県立こども病院 本元 強

4. 畳み込みニューラルネットワークによる肺結節検出処理

藤田医科大学 寺本 篤司

各種セミナーのご案内

•専門部会講座(画像:入門編) 「SNR, NEQ, DQE」

10月17日(木) 14:00~14:50 第8会場

東海大学医学部付属八王子病院 由地 良太郎

・専門部会講座(画像:入門編) 「X 線画像のノイズ特性」 10月19日(土) 13:00~13:50 第8会場

名古屋第二赤十字病院 新美 孝永

部会長挨拶

画像部会長 篠原 範充

この度,第8代画像部会長の白石順二先生(熊本大学)の後を受け,第9代画像部会長を拝命いたしました篠原範充です。画像部会は,1977年に内田勝先生より創設された日本放射技術学会(以下,本学会)で最初の専門部会です。これまで部会長は,山下一也先生,小寺吉衞先生,藤田広志先生,桂川茂彦先生,杜下淳次先生,石田隆行先生,白石順二先生がご担務されており,本学会を代表する錚々たる先生方ばかりです。

画像部会は,画像分野に留まらず,「放射線技術学」とはどうあるべきかを牽引してきました. 例えば,研究者としての意識,論文や発表方式のコンセンサスの普及,海外留学や国際学会での 発表など国際化への寄与など、放射線技術学における学術的基盤を担ってきました. その中に自 分の名前が入ることを非常に光栄に思いつつも, その責任の重さに身が引き締まる思いです. そ の意味からも放射線技術学における画像部会の役割をよく考え運営する必要があります.では、 放射線技術学とは何なのか?私の考える放射線技術学とは、医学、工学(情報、電気、画像)、 理学(放射線,物理,化学,生物),看護学,倫理学などの学問を統合した複合学問と考えてい ます. 逆に考えると複数の視点から、物事を捉えることが求められます. ただし、複数の視点を 生かすためには、自分自身の主要な視点が必要となり、画像部会におけるこの主要な視点が画像 解析・評価,画像処理など画像を対処とした研究となります.例えば,本学会の研究テーマとし て、線量・被ばくの適正化アプローチのような計測分野や防護分野のテーマ、至適撮影条件、動 画などの撮影分野のテーマ, 圧縮技術, データ容量など医療情報分野のテーマなどが考えられま すが, その研究の多くで画像または臨床画像を評価することが有効になります. さらに核医学や 放射線治療などにおいても画像と切り離して議論することは少ないと考えられます. つまり, 画 像部会は, これまでも, そしてこれからも放射線技術学研究において中心的かつ先進的な役割と 他の研究を彩る役割担う必要があります.これら大きな責務に対して,私を含めて9名の画像部 会委員で連携し活動して参りたいと思いますので,多くの会員の皆様のご支援とご協力をよろ しくお願いいたします.

新しい画像部会では、臨床現場の皆様に興味を持っていただける「臨床で役に立つ画像の評価、技術、画像処理技術」に加えて、専門家にも興味を持っていただける「ちょっと先の先進技術」を両輪に進めていくことを私の画像部会長としての目標にして参りたいと考えております。微力ながら画像部会、本学会、皆様の研究のお役に立てるように尽力して参りますので、どうぞよろしくお願いいたします。

深層学習を用いた医用画像処理研究の最前線

名古屋大学大学院情報学研究科 小田 昌宏

1. はじめに

人体の疾病の予防や治療を目的として医学研究が行われている. 適切な治療を行うためには診断において患者の状態を詳細に観察する必要があるが,かつては体内の状態を観察するのは困難だった. そこで工学と医学が連携し,放射線画像撮像装置や内視鏡等の体内観察装置が開発された. 現在は多くの医療機関で日常的に CT 像等が撮影されている. これにより一人の患者から大量の画像が撮影される状態となり, 読影する医師の負担が増加している. 医師の疲労による判断のばらつきや地域格差が患者にとっての不利益となる. この状況を打開するために情報学と医学が連携し, コンピュータによる画像診断支援技術の開発が進められている. 常に一定のパフォーマンスの判断が可能なコンピュータを使用することで, 医師の誤りや見落としを軽減することが期待される.

コンピュータを用いた画像診断支援の研究開発が長く行われているが、これまでの方法は判断ルールやアルゴリズムの性能が開発者の能力に強く依存すること、症例間の幅広い個人差に対応可能な判断アルゴリズム構築が困難であることなどが問題だった。これに対し、コンピュータ画像診断支援に深層学習を導入することで、自動判断の精度が大幅に向上したという報告が多数登場している。深層学習ではデータを基に判断の仕組みを構築する。多くの学習用データを与えるほど、患者間の個人差や撮影条件の違いに対応した汎化性能の高い判断が構築されるという性質がある。これによりデータから高性能な画像診断支援を実現することができる。

深層学習を用いた医用画像処理は、ノイズ削減等の画質改善、病変等を発見する検出、臓器等の領域を 選択するセグメンテーション、臓器の動き等の時系列解析、可視化等の幅広い対象に適用されている.本 稿では、医用画像処理における深層学習の様々な適用例を紹介する.

2. 画質改善

画像に含まれるノイズの削減、画像の解像度を向上させる超解像、非造影 CT 像からの造影 CT 像の推定等に深層学習が利用される.

ノイズ削減では、主に畳み込み層から構成される Fully convolutional network (FCN) を利用してノイズ を含む画像からノイズを削減した画像の生成を行う. ノイズ削減を行う FCN として、Denoising CNN[1]、Wide Inference Network[2]等が提案されている. Wide Inference Network[2]を用いて CT 像の Axial スライス 像のノイズ削減を行った例を図 1 に示す (ノイズは人工的に付与).

超解像でも FCN が利用され、低解像度画像から高解像度画像を推定可能としている. 超解像を行う FCN

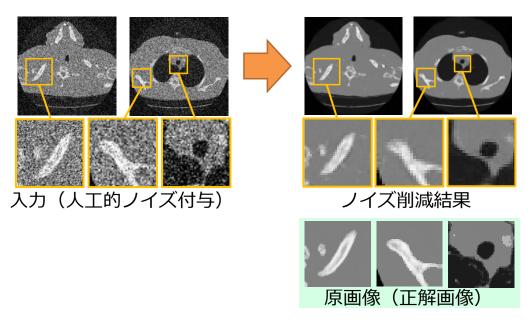


図 1 Wide Inference Network[2]を用いて CT 像 Axial スライス像のノイズ削減を行った例. 入力 画像に存在したノイズが効果的に削減されている.

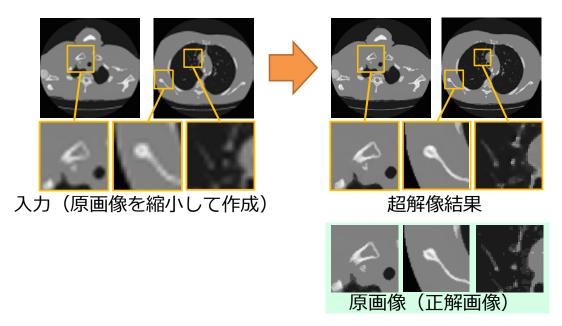
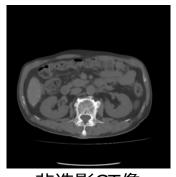


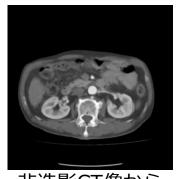
図 2 Deep Denoising Super Resolution CNN[4]を用いて CT 像 Axial スライス像の超解像を行った例. 入力画像は低解像度であり詳細な解剖構造観察に向かないが、超解像結果の画像は解像度が向上して解剖構造が明瞭に観察可能となった.

として, Super Resolution CNN[3], Deep Denoising Super Resolution CNN[4]等が提案されている. Deep Denoising Super Resolution CNN[4]を用いて Axial スライス画像の超解像を行った例を図 2 に示す (低解像 度画像は人工的に生成).

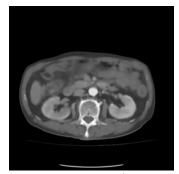
非造影 CT 像からの造影 CT 像の推定にも FCN が用いられる[5,6]. 非造影 CT 像を Axial スライス単位



非造影CT像



非造影CT像から 生成した推定造影CT像



造影CT像

図3 深層学習を用いた非造影 CT 像からの造影 CT 像推定結果の例. 左に示す非造影 CT 像を FCN に入力すると中央の推定造影 CT 像が得られる. 推定造影 CT 像における血管等の濃度値は右に示す造影 CT 像と類似している.

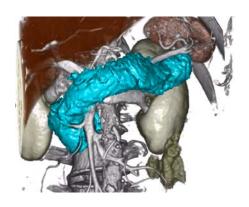


図4 CT像に含まれる膵臓(青色)と周辺臓器の形状.

で FCN に入力すると、血管等の濃度値が上昇し造影 CT 像と近い状態となった画像が推定できる.推定を行った例を図3に示す.この図から分かるように、非造影 CT 像では各臓器の濃度値が低いが、推定造影 CT 像では大動脈や腎臓等の血流豊富な臓器の濃度値が上昇し、造影 CT 像と近い画像が得られている.

3. セグメンテーション

セグメンテーションでは画像から対象臓器や病変等を画素単位で識別し、対象物の領域情報を得る. 現在最も活発に深層学習の適用が進められている領域であり、深層学習登場以前と比較して自動セグメンテーション精度が大幅に向上している. 適用対象として X 線透視像、CT 像、眼底画像、内視鏡像からの病変や臓器セグメンテーションが挙げられる.

腹部 CT 像に着目すると、その中には胃や肝臓等多くの臓器が含まれる。その中でも膵臓は個人間の位置・形状のばらつきが大きく、自動セグメンテーションは難しかった。図 4 に腹部臓器と膵臓の例を示す。深層学習が広まる前は統計的形状アトラス(臓器の位置・形状・濃度値等の平均や分散を表現したモデル)を用いたセグメンテーション手法が多く、その一つである手法[7]では膵臓を 69.1%の精度を達成していた。その後機械学習の Regression forests を用いた臓器位置推定を利用する方法が提案され、手法[8]

では75.1%の精度を得ている. その後深層学習を用いたセグメンテーション手法が登場し,3D FCN を用いた手法[9]は82.2%,手法[10]は89.7%の精度を達成した. このように深層学習によって臓器セグメンテーションの精度大きく向上した.

深層学習を用いたセグメンテーションにおいて最も多く用いられる FCN は U-Net[11]である. 様々なセグメンテーション用 FCN が提案されているが、そのほとんどは U-Net をセグメンテーション対象に合わせてカスタマイズしたものである. U-Net は Encoder-decoder スタイルのネットワーク構造を持つ. 前半の Encoder 部分で入力画像からセグメンテーションに有用な特徴量の抽出を行う. ここでは画像の情報を徐々に削減しながら、判断に寄与する特徴量を絞り込む. そしてネットワーク後半の Decoder 部分で特徴量からセグメンテーション結果を復元する. この Encoder-decoder の処理において画像情報が一度絞り込まれる際に、画像の空間的情報が大きく失われる. 空間的情報を Decoder 部分で適切に復元するために、Encoder と Decoder の間に複数の Skip connection が配置されている. 特徴量と Skip connection からの空間的情報を統合し、U-Net はセグメンテーション結果を生成する.

4. 時系列解析

深層学習では Recurrent Neural Network (RNN) を用いて時系列変化の解析が可能である. 例えば, 時系列 X 線透視画像からの臓器動き解析, 内視鏡下治療時の臓器の動き解析, ビデオ映像からの認識理解等を行うことができる.

時系列解析の例として、大腸内視鏡下治療における内視鏡ナビゲーションを挙げる. 大腸内視鏡を用いた治療時に医師を病変位置へとナビゲーション (誘導) することができれば治療の効率化に結びつく. コンピュータによるナビゲーションを実現する上で、大腸内の内視鏡位置を正確に把握する必要があるが、大腸は柔軟な臓器であり大きく変形するため位置把握が困難である. そこで、RNN の一種である Long Short-term Memory (LSTM) を用いて、内視鏡の状態から大腸の形状を推定する方法が提案されている[12]. この方法では、推定の手掛かりとなる内視鏡形状の時系列変化を用い、LSTM 層を持つ CNN で大腸形状を推定する. この方法により、ナビゲーションを正確に実施することが可能となっている.

5. 可視化

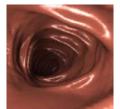
CT 像はボリュームレンダリングを用いて 3 次元的に可視化が可能である. この可視化は臓器や病変の位置・形状を観察する上で有用であるが,色情報の無い CT 像を基にしているため,臓器や病変表面の色やテクスチャ(模様)は実際のものと大きく異なる. レンダリングにおいてテクスチャマッピング等を用いて疑似的に表面の色や模様を付与することができるが,やはり現実感が欠如する. 3 次元可視化画像の現実感の欠如が解剖構造理解の妨げとなり,例えば手術シミュレータではトレーニング効果に悪影響を生じる.

この問題を軽減するため、深層学習を用いてボリュームレンダリングによる 3 次元可視化画像の現実 感増強が可能である[13,14]. 現実感増強では Unpaired data からの学習が可能な CycleGAN[15]を用いて現 実感増強 FCN の学習を行い、学習後の FCN を用いてボリュームレンダリング画像を現実的な画像へと 変換する. 現実感増強手法[14]を用いて大腸内のボリュームレンダリング画像を変換した結果を図 5 に示す. この図から分かるように、臓器表面の光沢や模様が変化して現実感が非常に高い画像が生成されてい







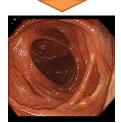




ボリュームレンダリング画像











現実感増強変換によって得られた画像

図 5 大腸内のボリュームレンダリング画像 (CT 像から生成) に対する現実感増強の例. 現実感増強 FCN は上段の画像から下段の画像を生成する. 生成画像では臓器表面の光沢や模様が現実的となっている.

る.この現実感増強手法を 3 次元可視化機能のある画像診断支援システムや手術シミュレータで利用することで,仮想と現実画像の間に存在する人間の知覚の隔たりを減少させ,より現実的な状況での診断や 治療支援が可能となると期待される.

6. むすび

本稿では医用画像処理研究における深層学習利用の背景と、深層学習によって性能向上または実現された技術を紹介した.主に CT 像を対象とした画質改善、セグメンテーション、時系列解析、可視化について、深層学習技術の概説と具体例を示した.深層学習に関する研究は現在も活発に行われており、今後も継続的に新たな成果が得られると期待される.

参考文献

- [1] Zhang K., et al.: Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising, arXiv:1608.03981, 2016
- [2] Liu P., Fang R.: Wide Inference Network for Image Denoising via Learning Pixel-distribution Prior, arXiv:1707.05414, 2017
- [3] Dong C, et al.: Learning a Deep Convolutional Network for Image Super-Resolution, in Proceedings of European Conference on Computer Vision (ECCV), 2014
- [4] Mao X.-J., et al.: Image Restoration Using Convolutional Auto-encoders with Symmetric Skip Connections, arXiv:1606.08921, 2016
- [5] Oda M., Kumamaru K. K., Aoki S., Mori K.: Non-contrast to contrasted abdominal CT volume regression using fully convolutional network, International Journal of Computer Assisted Radiology and Surgery, 2019, 14(1),

103-104

- [6] 小田昌宏, 隈丸加奈子, 青木茂樹, 森健策: Generative Adversarial Frameworks を用いた腹部 CT 像における非造影像からの造影像の推定, 第38回日本医用画像工学会大会(JAMIT) 予稿集, 2019, OP3-07
- [7] Chu C., Oda M., Kitasaka T., Misawa K., Fujiwara M., Hayashi Y., Nimura Y., Rueckert D., Mori K.: Multi-organ segmentation based on spatially-divided probabilistic atlas from 3D abdominal CT images, MICCAI, 2013, 8150, 165-172
- [8] Oda M., Shimizu N., Karasawa K., Nimura Y., Kitasaka T., Misawa K., Fujiwara M., Rueckert D., Mori K.: Regression forest-based atlas localization and direction specific atlas generation for pancreas segmentation, MICCAI, 2016, 9901, 556-563
- [9] Roth H.R., Oda H., Hayashi Y., Oda M., Shimizu N., Fujiwara M., Misawa K., Mori K.: Hierarchical 3D fully convolutional networks for multi-organ segmentation, arXiv:1704.06382, 2017
- [10] Roth H.R., Oda M., Shimizu N., Oda H., Hayashi Y., Kitasaka T., Fujiwara M., Misawa K., Mori K.: Towards dense volumetric pancreas segmentation in CT using 3D fully convolutional networks, arXiv:1711.06439, 2018
- [11] Ronneberger O., Fischer P., Brox T.: U-Net: Convolutional Networks for Biomedical Image Segmentation, MICCAI, 2015, 9351, 234-241
- [12] Oda M., Roth H.R., Kitasaka T., Furukawa K., Miyahara R., Hirooka Y., Goto H., Navab N., Mori K., Colon shape estimation method for colonoscope tracking using recurrent neural networks, MICCAI, 2018, 11073, 176-184
- [13] Oda M., Tanaka K., Takabatake H., Mori M., Natori H., Mori K., Realistic endoscopic image generation method using virtual-to-real image-domain translation, MIAR|AE-CAI|CARE Joint Workshop @ MICCAI, 2019 (accepted)
- [14] 小田昌宏,田中聖人,高畠博嗣,森雅樹,名取博,森健策:画像ドメイン変換を用いた現実感の高い仮想内視鏡画像生成,日本コンピュータ外科学会誌 第 28 回日本コンピュータ外科学会大会特集号 (JSCAS), 2019 (投稿中)
- [15] Zhu J.-Y., Park T., Isola P., Efros A. A.: Unpaired image-to-image translation using Cycle-consistent adversarial networks, arXiv:1703.10593, 2017

著者略歴

2004年名古屋大学工学部卒業. 2009年同大大学院情報科学研究科博士課程後期課程了. 同大大学院工学研究科予防早期医療創成センター 特任助教,同大情報連携統括本部情報戦略室 特任助教を経て,2011年より現職. コンピュータによる医用画像処理を通した診断支援及び治療支援に関する研究に従事. 電子情報通信学会,日本医用画像工学会,日本コンピュータ外科学会,情報処理学会,各会員.

JSRT データベース紹介

岐阜大学 教育学部 技術教育講座 福岡 大輔

1. はじめに

近年,医用画像処理におけるディープラーニングが果たす役割は大きくなりつつあり,その利用範囲も,超解像,ノイズ除去などの画質改善や,画像分類,領域抽出,回帰,異常検知など多岐にわたっている.ディープラーニングが登場した当初に比べ,ディープラーニングのための環境構築も比較的容易に行えるようになってきた.しかし,初学者にとっては,ディープラーニングに用いる大量の画像データの加工や,教師データの作成は,ディープラーニングを使った研究をはじめる上で障壁となっている.

本稿では、日本放射線技術学会が公開している 「標準ディジタル画像データベース(胸部腫瘤陰



図 1 ディープラーニング用データベース miniJSRT_database のサイト

影像)[1]」(以下, JSRT Databaseと呼ぶ)と,それから派生し,ディープラーニング用に作成されたデータベースである miniJSRT_database[2]について紹介する.

2. 標準ディジタル画像データベース(胸部腫瘤陰影像): JSRT Database

JSRT Database は 1998 年 1 月に配布されたデータベースで,全 247 枚(腫瘤陰影像 154 画像,非腫癌陰影像 93 画像)を収録している. データベースに含まれる画像は,画像フォーマットは RAW 形式(濃度分解能は 12bit(4096 階調),画像サイズ 2048 \times 2048,ピクセルサイズ 0.175mm となっている. また,Clinical Information として,腫瘤が存在する症例については,難易度,腫瘤サイズ,年齢,性別,腫瘤座標,良悪性などの付加情報が収録されている. データベースはオリジナル(RAW 形式)版[3],オリジナル版をもとに作成された DICOM 版[4]が公開されている.

3. ディープラーニング用データベース: miniJSRT_database

miniJSRT_database は、ディープラーニングを用いた医用画像研究を始めてみようという初学者の方を対象に作成されたデータベースで、日本放射線技術学会の医用画像処理プログラミングセミナーでの教材利用を目的に作成された経緯がある。miniJSRT database は、前節で紹介した「標準ディジタル画像デ

ータベース(胸部腫瘤陰影像)」から派生したデータベースとなっており、画像のクラス分類、領域分割、回帰問題、超解像、ノイズ除去、異常検知など目的別にデータセットが収録されている.

データベースに収録される画像は、さまざまなディープラーニングフレームワークで取り扱いやすいように、JPG 形式、PNG 形式など一般的な画像フォーマットが採用されており、マトリックスサイズも128x128、256x256pixel 程度の画像サイズとなっている。また、ディープラーニングの学習処理に使用するアノテーションデータも、データセットごとにテキスト形式または画像として収録されている。

以下に、miniJSRT_database に収録されている各データセットについて解説する.

3.1 画像のクラス分類

(1) 画像の方向分類 【Directions01 データセット】

図1に示すように、画像を方向ごとに4クラスに分類する問題を想定し、1枚の画像について0°(Up)、90°(Right)、180°(Down)、270°(Left)回転させた、 全988 (247×4) 枚の画像を収録している。各方向画像 (247枚) を、学習用 237枚 (train)、評価用 10枚(test)をそれぞれフォルダに分け、trainフォルダと test フォルダは Up 、Down、Right、Left の4つのフォルダで構成されている。



図 1 画像のクラス分類(画像方向: Up / Right / Down/ Left)

(2) 性別分類 【Gender01 データセット】

Gender01 データセットは、胸部 X 線画像から男性/女性の 2 クラスに分類する問題を想定し、学習用ファイル (list_test.txt) には、画像ファイル名とクラス名 (male / female) の記述が含まれている.

3.2 領域抽出

(1) 2 領域を抽出 (肺野:255/肺野外:0) 【Segmentation01 データセット】

Segmentation 01 データセットは、図 2 に示すように、肺野領域を領域ラベル番号 255、肺野外領域を 0 とした、2 つの領域を抽出する問題を想定しデータセットが構成されている。 JSRT Database の 60 枚の画像を使用し、org_train フォルダ内には学習用画像 50 枚、label_train フォルダ内には学習用ラベル画像 50 枚、org_test フォルダ内には評価用画像 10 枚、label_test フォルダ内には評価用ラベル画像 10 枚を収録している。

(2) 4 領域を抽出(肺野:255/心臓:85/肺野外:170/体外:0) 【Segmentation02 データセット】

Segmentation02 データセットでは、図 3 に示すように肺野領域を領域ラベル番号 255, 心臓領域を 85, 肺野外領域を 170, 体外領域を 0 とした 4 つの領域を抽出する問題を想定している. JSRT Databese の 247 枚の画像を使用しており、org_train フォルダ内には学習用画像 199 枚、label_train フォルダ内には学

習用ラベル画像 199 枚,org_test フォルダ内には評価用画像 48 枚,label_test フォルダ内には評価用ラベル画像 48 枚を収録している.

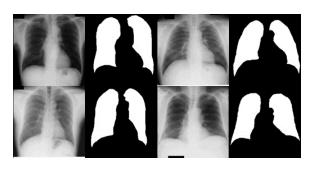


図2 肺野領域抽出 (領域ラベル数:2) 左:原画像,右:ラベル画像

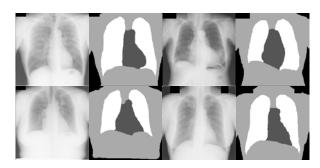


図3 肺野領域抽出(領域ラベル数:4) 左:原画像(階調反転),右:ラベル画像

3.3 年齢推定【AgeO1 データセット】

Age01 データセットは、胸部 X線画像から年齢を推定する回帰問題を想定し、アノテーションデータとして、画像ファイル名とその年齢を CSV ファイルに収録している.

3.4 超解像(低解像の画像からの復元) [SuperResolution01 データセット]

SuperResolution01 データセットは、図 4 に示すように低解像画像から高解像画像を生成する超解像処理を想定したデータセットとなっている。低解像画像はマトリックスサイズ 256×256 の画像を、幅と高さを 1/3 に平均画素法で縮小し、その後、元の 256×256 にバイキュービック補間(4×4 近傍領域)で拡大した画像となっている。このデータセットは本来の超解像処理ではなく、疑似的に生成された低解像画像から元画像(高解像)を復元するような問題であることに注意を要する。

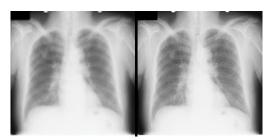


図 4 低解像画像からの復元(左:低解像画像,右:元画像)

3.5 ノイズ低減処理【Denoise01 データセット】

Denoise01 データセットは、オートエンコーダを用いたノイズ低減処理を想定し、図 5 に示すように、画像加工により人工的なノイズを付加した画像と原画像が収録されている。人工的なノイズ付加画像は、原画像に正規分布に従う平均 0、標準偏差 50 のノイズを加算した画像となっている。

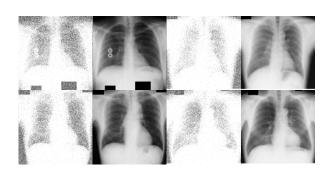
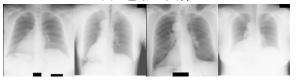


図 5 ノイズ低減処理 左:ノイズ付加画像,右:原画像



(a) 通常の画像



(b)左右反転画像(異常画像) 図 6 異常検知(左右反転)

3.6 異常検知(左右反転)【AutoEncoder01 データセット】

AutoEncoder01 データセットは、オートエンコーダを用いた教師なし学習による異常検知の問題を想定し、図 6(a)に示すような通常画像と同図(b)のような左右反転画像が収録されている(本稿では階調反転画像として掲載している).

4.まとめ

医用画像に関するディープラーニングを用いた研究開発を行う上で、ニューラルネットワークの学習に用いるデータセットを準備することは非常に重要であるとともに、時間を要する作業である. JSRT Database から派生し作成された、mini JSRT_database は、ディープラーニング用に画像データセットがあらかじめ準備され、アノテーションデータも付加されているため、ディープラーニングの機能や、その効果を学ぶ上で非常に有用なデータセットとなっている。ディープラーニングによるクラス分類や領域抽出、ノイズ低減など、基本的な機能の例示を網羅している。今後、さらにデータセットのバリエーションを拡充する取り組みが期待される.

参考文献

- [1] Shiraishi J, Katsuragawa S, Ikezoe J, Matsumoto T, Kobayashi T, Komatsu K, Matsui M, Fujita H, Kodera Y, and Doi K.: Development of a digital image database for chest radiographs with and without a lung nodule: Receiver operating characteristic analysis of radiologists' detection of pulmonary nodules. AJR 174; 71-74, 2000
- [2] "MINIJSRT_DATABASE", 日本放射線技術学会画像部会: http://imgcom.jsrt.or.jp/minijsrtdb/ (最終アクセス日: 2019.9.1)
- [3] "JSRT Database", 日本放射線技術学会: http://db.jsrt.or.jp/eng.php (最終アクセス日: 2019.9.1)
- [4] "標準ディジタル画像データベース(DICOM 版)", 日本放射線技術学会画像部会: http://imgcom.jsrt.or.jp/download/(最終アクセス日: 2019.9.1)

畳み込みニューラルネットワークによる肺結節良悪性鑑別

立命館大学 理工学部 中山 良平

1. はじめに

近年,人工知能(Artificial Intelligence)の一つである深層学習(Deep Learning)に基づく技術を医療現場に導入することにより,診断の質の向上,業務の効率化を目指した研究が世界中で活発に進められている[1-5]. 医用画像上の病変を良性/悪性に分類したり,各病理組織型に分類したりする画像認識の分野においては,畳み込みニューラルネットワーク(CNN: Convolutional Neural Network)による深層学習を用いた手法が主流となっており,多くの研究成果が報告されている。CNN は,基本的に従来のニューラルネットワークに畳み込み層(Convolution Layer)と呼ばれる画像処理のフィルタ演算を実行する層が追加されたものである.畳み込み層では応用目的に適した特徴抽出が自動で行われ,抽出された特徴に基づき,画像を分類する.本稿では,CNN の概要を解説し,胸部単純X線画像上の結節状陰影の良悪性鑑別への応用例を示す.

2. 畳み込みニューラルネットワークの構成

図1のようにCNN は畳み込み層やプーリング層,全結合層などの特徴的な機能を有する層を何段も積み上げることで構成され、画像分類だけでなく、様々な分野で活用されている.以下、画像分類を目的としたCNNにおいて、一般に用いられる層を紹介する.

2. 1. 入力層

入力層(Input Layer)は、ネットワークに入力データを与える層である。CNN の入力層には画像全体またはパッチと呼ばれる画像を分割した小領域を入力し、通常、入力データの正規化

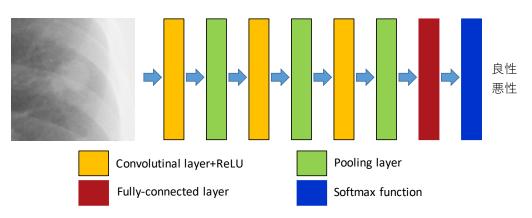


図1: 結節状陰影の良悪性鑑別CNNの例

$\frac{1}{9}$	$\frac{1}{9}$	$\frac{1}{9}$		$\frac{1}{16}$	$\frac{2}{16}$	$\frac{1}{16}$	-1	
$\frac{1}{9}$	$\frac{1}{9}$	$\frac{1}{9}$		$\frac{2}{16}$	$\frac{4}{16}$	$\frac{2}{16}$	-2	
$\frac{1}{9}$	$\frac{1}{9}$	$\frac{1}{9}$		$\frac{1}{16}$	$\frac{2}{16}$	$\frac{1}{16}$	-1	
	(a)		•		(h)			(

-1	0	1	
-2	0	2	
-1	0	1	
	(c)		

0	1	0
1	-4	1
0	1	0
	(d)	

図2: 画像処理で用いられるフィルタ例. (a)平均化フィルタ, (b)加重平均化フィルタ, (c)ソーベルフィルタ, (d)ラプラシアンフィルタ

が適用される. 入力層のサイズは、入力データの高さ、幅、カラーチャネル数で決定される. 本稿で対象とする胸部単純X線画像は高さ 512 画素、幅 512 画素、カラーチャネル数はグレースケール画像であるため 1 チャネルである. したがって、胸部単純X線画像を入力する場合は、入力層のサイズは $512 \times 512 \times 1$ となる.

2. 2. 畳み込み層

畳み込み層(Convolution Layer)[6]は、前の層の出力を入力データとし、画像処理のフィ ルタ演算を実行する層である。フィルタ演算は、入力データに沿って、垂直方向および水平方 向にフィルタを移動させ、入力データとフィルタ係数の積和演算を行い、入力データを畳み込 む.通常の画像処理では、目的に応じ、事前に適切なフィルタ係数を決定し、与える必要があ る. 例えば、画像に含まれる信号の大まかな変化を抽出したい場合には平均化フィルタ(図 2a) や加重平均化フィルタ (図 2b) , 明るさが急に変化する箇所を抽出したい場合にはソーベ ルフィルタ (図 2c) やラプラシアンフィルタ (図 2d) が用いられる. 一方, CNN の畳み込み層 では、フィルタ係数として最初に乱数が与えられ、学習により、目的に有用な特徴が抽出でき るようにフィルタ係数が更新される.畳み込み層は1つだけでなく、多数が用意され、入力層 から進むにつれて、より複雑な特徴を抽出する.一般に、初めの畳み込み層ではエッジや穴な どの局所的な特徴が、それからパターンなどの特徴が、そして最後は分析対象の形状などの大 局的な特徴が抽出される.また、各畳み込み層は複数のフィルタを有し、フィルタの数だけ異 なる特徴を抽出する. したがって、各畳み込み層のハイパーパラメータとして、フィルタサイ ズ,フィルタ数,そして,フィルタ適用時の移動幅であるストライド,畳み込み層の出力サイ ズを調整するパディング幅(通常、入力データの周囲にパディング幅のゼロが挿入されるゼロ パディングが実行される)を事前に与える必要がある.図3に、パディング幅を1としたとき のフィルタ演算の例を示す.

フィルタの要素間にゼロを挿入することにより、拡張したフィルタで畳み込みを行う膨張畳み込みもある。膨張畳み込みは、学習で更新するフィルタ係数の数や計算量を増やすことなく、層で解析可能な領域(受容野)を広げることが可能である。膨張畳み込みでは、フィルタのアップサンプリング係数となる膨張係数を事前に与える必要がある。例えば、膨張係数 [22]のサイズ 3×3 のフィルタは、要素間にゼロが挿入された 5×5 のフィルタと等価となる。

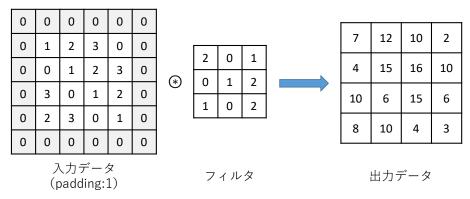


図3: フィルタ演算の例

2. 3. プーリング層

プーリング層は、前の層からの入力データを矩形のプーリング領域に分割し、各領域の最大値(最大プーリング層)または平均値(平均プーリング層)により、ダウンサンプリングを実行する層である。通常、プーリング層は畳み込み層の後に結合し、ダウンサンプリングにより、後続の層で学習されるパラメータ数を減少する。これは、過適合(over fitting)の抑制にも役立つ。プーリング層では学習は行われない。プーリング層のハイパーパラメータとして、プーリング領域サイズ、プーリング領域の移動幅であるストライドを事前に与える必要がある。通常、プーリング領域サイズとストライドは等しく与え、プーリング層の入力データのサイズを $H\times W$ 、プーリング領域サイズを $h\times W$ としたとき、プーリング層の出力は $H/h\times W/W$ となる。最近は、ストライドを調整した畳み込み層でプーリング層を代用することも多い。

2. 4. ドロップアウト層

ドロップアウト層は、与えられた確率で無作為に入力データの要素をゼロと設定する層である。学習の度に、無作為に選択されたユニットとそのユニットへの入力となるすべての結合を、一時的に無視する。これは毎回異なるネットワークを学習していることに相当し、最終的に複数のネットワークの解析結果を統合するアンサンブル学習とみなすことが出来る。また、特定のユニットとその結合に依存しないため、過適合を抑制する働きももつ。ドロップアウト層もプーリング層同様、学習で更新されるパラメータはない。ドロップアウト層のハイパーパラメータとして、無視するユニットの割合であるドロップアウト率を与える必要がある。

2. 5. バッチ正規化層

通常,深層学習では、1回の学習に全ての学習データを用いるのではなく、学習データをミニバッチに分割し、ミニバッチごとにパラメータの更新を行うミニバッチ学習が行われる.バッチ正規化層は、ネットワークを伝播する活性化と勾配をミニバッチで正規化する層である.バッチ正規化は、学習中にネットワークのパラメータが更新されることにより、ネットワークの活性値の分布が変化する内部共分散シフト(internal covariance shift)を抑制することが

目的である.ここでは,まず,ミニバッチの平均値を減算し,ミニバッチの標準偏差で除算することにより,各チャネルの活性化を正規化する.さらに,入力データを学習可能なオフセット β でシフトし,学習可能なスケール係数 γ でスケーリングする.これらの β , γ も学習により更新されるパラメータである.この正規化により外れ値などの影響を減少することができ,安定した学習が可能となる.したがって,学習率を増やし,学習時間の短縮を図ることが可能である.また,乱数で与えられるネットワークの初期値の影響を減少する働きもある.学習エポックごとに,学習データをシャッフルすると,正規化がより効果的となる.

2. 6. 残差結合

層のシンプルなシーケンスで構成されるネットワークは、多くの用途に対応可能である. しかし、ネットワークの層を深くし過ぎると、上手く学習できずに性能が大きく低下する問題があった. この問題を解決するために提案されたのが残差(残渣)結合である.

残差結合は、ある層への入力データをバイパスし、その層の出力データに加えるものである。これにより、学習時のパラメータの勾配がネットワークの出力層から入力層に向かって、よりスムーズに伝播するため、勾配の消失や発散を防ぐことができ、より深いネットワークの学習を可能にする。ある層への入力データが、その層の出力データに加えられるだけなので、パラメータ数や計算量が増加することはない。

2. 7. 全結合層

全結合層は、入力データに重み行列を乗算し、バイアスベクトルを加算する層である. 通常、最後の畳み込み層(またはプーリング層)の後に、1つ以上の全結合層が結合される. 全結合層のすべてのユニットは前の層にあるすべてのユニットに結合する. 分類問題の場合、最後の全結合層が特徴を組み合わせてイメージを分類する. したがって、最後の全結合層の出力サイズは、データセットのクラス数と等しくなる.

2. 8. 出力層

結節状陰影の良悪性鑑別のような分類問題に応用する場合,出力層はソフトマックス層と分類層で構成され,ネットワークの最後の全結合層の後に結合される.ソフトマックス層は,入力データに下式のソフトマックス関数を適用する.

$$y_r(x) = \frac{\exp\bigl(a_r(x)\bigr)}{\sum_{i=1}^k \exp\bigl(a_i(x)\bigr)}$$

ここで、 $0 \le y_r \le 1$ 、 $\sum_{i=1}^k y_i = 1$ である。分類層は、ソフトマックス関数の出力を入力とし、1 対 K 符号化方式の下式の交差エントロピー関数により、各入力データを K 個の互いに排他的なクラスのうちの 1 つに割り当てる。

$$loss = -\sum\nolimits_{i=1}^{N} \sum\nolimits_{j=1}^{K} t_{ij} \ln y_{ij}$$

ここで、Nは標本数、Kはクラス数、 T_{ij} はi番目の標本がj番目のクラスに属することを表すインジケーターを示す。また、 y_{ij} はクラスjの標本iを入力層に入力したときの出力で、ソフトマックス関数からの出力値である。つまり、ネットワークがi番目の標本をクラスjに関連付ける確率となる。

3. 実験

3.1. 実験試料

実験試料は、日本放射線技術学会の「標準ディジタル画像データベース [胸部腫瘤陰影像]」[7]の結節を含む胸部 X線画像 153 枚を用いた. 各画像には 1 個の結節が存在し、悪性 100 症例、良性 53 症例である. これらの画像サイズは 2048×2048、空間分解能は 0.7mm/画素、濃度分解能は 4096 階調(12bit)である. 本研究では、結節の重心を中心とした関心領域に切り出し、学習用として悪性 80 症例/良性 33 症例、評価用として悪性 20 症例/良性 10 症 例を用いた.

3. 2. CNN の構成

本稿では、AlexNet[8]と ResNet18[9]の構成をベースとした CNN を用いた。両者ともに、 ILSVRC(International Large Scale Visual Recognition Challenge)で良好な成績をおさめ たモデルである。ただし、胸部 X 線画像はグレースケール画像であるため、入力層のサイズ は、AlexNet が $227 \times 227 \times 1$ 、ResNet18 が $224 \times 224 \times 1$ である。入力層から出力層までにある 畳み込み層と全結合層の数は、AlexNet が 8、ResNet18 が 18 であり、ResNet18 はバッチ正規化層や残差結合を有する。これらの CNN の学習において、最適化には Adam を用い、初期学習率は 1.0×10^{-4} 、最大エポック数は 500 とした。

3.3.結果

表 1 に AlexNet と ResNet18 による結節状陰影の良悪性鑑別の結果を示す. ResNet18 による分類の結果, 正答率83.3% (25/30), 感度85.0% (17/20), 特異度80.0% (8/10), 陽性予測度89.5% (17/19), 陰性予測度72.3% (8/11) が得られ, いずれも AlexNet より高い結果となった. これらの結果より, ResNet18 が有するバッチ正規化層や残差結合が, 良悪性鑑別において, 効果的に寄与することが示唆された.

	AlexNet	ResNet18
正答率	73.3% (23/30)	83.3% (25/30)
感度	75.0% (15/20)	85.0% (17/20)
特異度	70.0% (7/10)	80.0% (8/10)
陽性予測度	83.3% (15/18)	89.5% (17/19)
陰性予測度	58.3% (7/12)	72.3% (8/11)

表1: 良悪性鑑別結果の比較

4. まとめ

本稿では CNN の概要を解説し、胸部単純 X 線画像上の結節状陰影の良悪性鑑別への応用例を示した. 良悪性鑑別への応用では、ResNet18 の構成をベースとした CNN を用いて、比較的高い

正答率が得られた. しかし、ResNet18、AlexNet ともに、ImageNet データベース[10]のカラー画像を 1000 のオブジェクトカテゴリに分類するために最適化されたモデルである. したがって、グレースケール画像である胸部単純 X 線画像の結節状陰影の良悪性鑑別に適したモデルを提案することにより、正答率を改善できる可能性がある.

5. 参考文献

- [1] Nensa F, Demircioglu A, Rischpler C. "Artificial Intelligence in Nuclear Medicine." J Nucl Med. 60(Suppl 2): 29S-37S, 2019.
- [2] Zhu G, Jiang B, Tong L, Xie Y, Zaharchuk G, Wintermark M. "Applications of Deep Learning to Neuro-Imaging Techniques." Front Neurol. 14;10:869, 2019.
- [3] Munir K, Elahi H, Ayub A, Frezza F, Rizzi A. "Cancer Diagnosis Using Deep Learning: A Bibliographic Review." Cancers (Basel). 23;11(9), 2019.
- [4] Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, van der Laak JAWM, van Ginneken B, Sánchez CI. "A survey on deep learning in medical image analysis. Med Image Anal. 42:60-88, 2017.
- [5] Suzuki K. "Overview of deep learning in medical imaging." Radiol Phys Technol. 10(3):257-273, 2017.
- [6] Murphy KP. Machine Learning: A Probabilistic Perspective. Cambridge, Massachusetts: The MIT Press, 2012.
- [7] Shiraishi J, Katsuragawa S, Ikezoe J, Matsumoto T, Kobayashi T, Komatsu K, Matsui M, Fujita H, Kodera Y, Doi K. "Development of a digital image database for chest radiographs with and without a lung nodule: receiver operating characteristic analysis of radiologists' detection of pulmonary nodules." AJR Am J Roentgenol. 174(1):71-4, 2000.
- [8] Krizhevsky A, Ilya S, Geoffrey EH. "ImageNet Classification with Deep Convolutional Neural Networks." Advances in neural information processing systems. 2012.
- [9] Kaiming FE, Zhang X, Ren S, Sun J. "Deep residual learning for image recognition." In Proceedings of the IEEE conference on computer vision and pattern recognition, 770-778, 2016.
- [10] ImageNet. http://www.image-net.org

畳み込みニューラルネットワークによる 胸部画像領域抽出処理

茨城県立こども病院 放射線技術科 本元 強

1. はじめに

近年,深層学習(Deep Learning、以下ディープラーニング),特に畳み込みニューラルネットワーク(Convolutional Neural Network: CNN)は,医用画像を解析するための最適な選択方法となっている。本稿では,畳み込みニューラルネットワークによる胸部画像領域抽出処理について,日本放射線技術学会「標準ディジタル画像データベース[胸部腫瘤陰影像]」にもとづいて作成された mini JSRT_database の画像,及び「医療 AI とディープラーニングシリーズ No. 1-3」(オーム社)を参考文献として内容を進めていく。また,医用画像解析におけるディープラーニングの応用として、Neural Network Console と DIGITS の環境構築について簡単に紹介する。

2. 深層学習の技術分野の分類

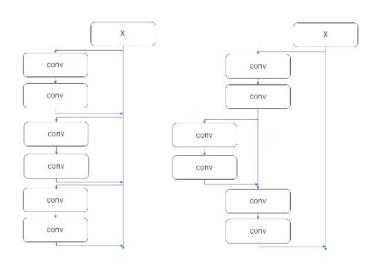
ディープラーニングとは、人工知能 (Artificial Intelligence) の分野の中の、さらに機械 学習 (Machine Learning) の一分野である. 医療画像分野でのディープラーニングを技術分野 別に分けると、「分類」「検出」「回帰」「セグメンテーション」「レジストレーション」「そ の他 (検索・生成/変換・超解像)」などに分類できる. 本稿では「セグメンテーション」(領 域抽出)について説明していく.

・セグメンテーションと日本放射線技術学会「標準ディジタル画像データベース[胸部腫瘤陰影像]の紹介」

セグメンテーション (領域抽出) とは、画像に対してディジタル画像の最小単位である画素 (ピクセル) レベルでクラス分類を行う問題である. ピクセル単位でオブジェクトごとに色付けされた教師データを用いて学習を行う. そして推論の際には、入力画像のすべてのピクセルに対してクラス分類を行う. 医療画像を用いて教師データを作成するのは、正しい医療知識が必要となり作成の時間もかかる. そこで今回は、日本放射線技術学会の標準ディジタル画像データベース [胸部腫瘤陰影像] にもとづいて作成された mini JSRT_database の画像を用いて処理を行っていくこととする.

· U 字型ネットワーク

ここでは、多層ネットワークを実現するために、U字型のショートカット構造を持つU字型ネットワークを用いる(Fig 1). このU字型ネットワークを基本として、途中の畳み込み層の画素数を減少させることにより、入力データの抽象化を行っている.プーリング層で画素数を減少、アップサンプリング層で画素数を増大(バイリニア補間による拡大)させ2つの層を同じ大きさにして、マージしている.このネットワークの最後に全結合層がないのは、画像全体を出力データとするためであり、出力層は出力値を整えている.全結合層を持たないこのようなモデルはFCN(Fully Convolutional Network)と呼ばれている.FCNのFully Convolutional Networkを訳すと「すべてが畳み込み層から構成されるネットワーク(全層畳み込みネットワーク)」という意味である.このU字型ネットワーク構造を持ったモデルにはU-Net(Fig 2)がある.セグメンテーションではこのU-Netが良く用いられており、医用画像発のネットワークである.U-NetはFCNの進化版であり、Encoderーdecoder構造を持つ畳み込みネットワークである.U-Netはケメンテーションを用いるコンテストでは主流となっており、例えばMICCAI2017においては、多数の発表で「U-Net と他手法の組み合わせ」のネットワークが使用されていた.性能は非常に高く、タスクによっては人間並みの性能を発揮する.



(a) 直列型 (b) U 字型 Fig 1 構造モデルの例

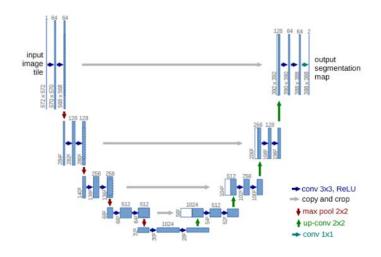


Fig 2 U-Net のモデル

出典: https://arxiv.org/abs/1505.04597

・システムの制度評価

セグメンテーションの評価は、一致度として Intersection over Union (IoU) または Jaccard index や、Dice coefficient が頻繁に用いられる.

3. 環境構築

上記のようなディープラーニングを用いた本格的な医療画像解析を行うには、多数の学習画像と高性能なコンピュータが必要となる。しかし、多数の同一症例の画像を集めるのは非常に困難であり、高性能なコンピュータは非常に高価である。そこで、「医療 AI とディープラーニングシリーズ No. 1-3」を参考にしながら、初学者向けに簡単な機械学習・深層学習の環境構築方法について説明していく。まずハードウエアについて説明する。本格的な研究を行う際には、処理速度の速い CPU (Central Processing Unit) が望ましく、さらに別途 NVIDIA の GPU (Graphics Processing Unit) を用いて処理の高速化が必要になる。今回の対象 OS (Operating System) はマイクロソフト社の Windows 10 での説明をしていく。

• Neural Network Console: NNC

プログラミングを必要としないディープラーニングツールとして、データ分析用のツールである NNC を紹介する. NNC はプログラミングなしにディープラーニングを graphical user interface: GUI 環境で実施できるツールである. NNC はソニーネットワークコミュニケーションズからリリースされており、Windows アプリバージョンは無償で利用できる. また GPU も使用可能である. 特徴としてバージョンアップが多く (執筆時のバージョンは 1.5.0)、最新の機能が

追加されている. ここでは, U-Net (Fig 4) を使ってセグメンテーションを行った. また処理結果を Fig 5 に示す.

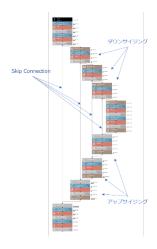


Fig 4 NNC での U-Net 作成例

Index	x:image	y:label	y'
1	C:\neural_se_	C:\neural_natwork_coisole_150\ c. 256, 256	.\0_0000\0.549 c, 256, 256
2	C:\neural = 50\ c 256, 256	C:\neural_n_xtwefk_squsole_150\ c.256,256	.\0_0000\1.ang c. 256, 256
1	C\neural sole_150\ c, 256, 256	C:\neural_na/	.\0_0000\2.029 c, 256, 256
	C\neura 50 07 07 sole_150\ c. 256, 256	C:\neural_nxwerx_xeasole_150\ c; 256, 256	.\0_0000\\$.prig c, 256, 256
	C:\neural sole_150\ c. 256, 256	C:\neural_nakwe/K_seasole_150\ c, 256, 256	.\0_0000\4.57g c, 256, 256
•	C:\neural_mentork = 61sole_150\ c. 256, 256	C:\neural_national(_cassole_150\ c_256,256	.\0_0000\5.533 c, 256, 256
,	C/\neura sole_150\ c_256,256	C:\neural_name(x) cossole_150\ c, 256, 256	.\0_0000\6.999 c; 256, 256
ı	C:\neural_10	C:\neuralLnctwork_Satisole_150\ c, 256, 256	.\0_0000\7,0mg c, 256, 256

(a) Input: (b) Gold Standard: (c) Output:

Fig 5 NNCでの処理結果

DIGITS

プログラミングを必要としないディープラーニングツールとして、もうひとつ NVIDIA 社が提供する DIGITS を紹介する. DIGITS も GUI 環境で実施できるツールであり、Web ブラウザ (Google 社のブラウザ Crome にて動作確認) 画面上で操作できる (Fig 6). OS は Windows10 と Ubuntu で使用可能であり、GPU も使用可能である. 今回は FCN-AlexNet を用いたセグメンテーションを行った. FCN-AlexNet は、AlexNet をベースとしたネットワークとなっている. Fig 7 は学習回数による変化を示す. 学習回数が多いほど、より正確に肺野を認識できているのがわかる.

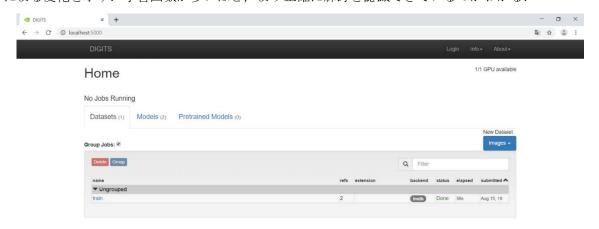


Fig 6 DIGITS

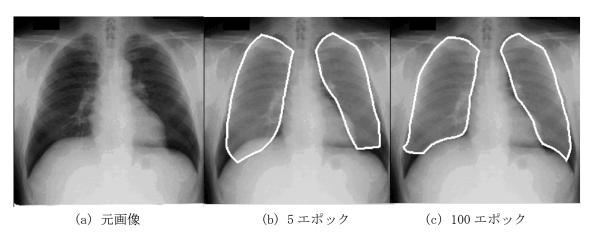


Fig 7 学習回数による領域の変化

4. 最後に

ディープラーニングを用いたセグメンテーションについて、非常に簡単ではあるが説明を述べた. NNC と DIGITS の導入方法や、画像の作成方法など説明が不足している点が多いが、「医療 AI とディープラーニングシリーズ No. 1-3」(オーム社)を別途参照にして頂くことをお勧めする.

参考文献

- [1] Shiraishi J, Katsuragawa S, Ikezoe J, Matsumoto T, Kobayashi T, Komatsu K, Matsui M, Fujita H, Kodera Y, and Doi K.: Development of a digital image database for chest radiographs with and without a lung nodule: Receiver operating characteristic analysis of radiologists' detection of pulmonary nodules. AJR 174; 71-74, 2000Ross Girshick, et al., "Rich feature hierarchies for accurate object detection and semantic segmentation", Proceedings of the IEEE conference on computer vision and pattern recognition, pp.580-587, 2014.
- J.Long, E.Shelhamer and T. Darrell, "Fully convolutional networks for semantic segmentation," 2015
 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 3431-3440, 2015.
- [3] O.Ronneberger, P.Fischer, T.Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," Lecture Notes in Computer Science, 9351, pp.234-241, 2015.

畳み込みニューラルネットワークによる肺結節検出処理

藤田医科大学 医療科学部 放射線学科 寺本 篤司

1. はじめに

画像を対象とした深層学習処理で主に用いられる畳み込みニューラルネットワーク (Convolutional neural network, 以下 CNN) は、画像に写っている物を見分ける(分類)、画像に写っている物の範囲を抽出する(領域抽出、セグメンテーション)、そして画像中の物体がどこにあるか見つける(物体検出)などの処理を行うことができる。本稿では、最後の"物体検出"に関して、その原理や JSRT の標準ディジタル画像データベースを用いた結節検出の処理方法について解説する.

2. "物体検出"とは

"物体検出"という言葉自体は、非常に広い意味を指す一般的なものである。ところが深層学習の世界では、「画像中から目的とする対象物を見つけ、その外接矩形や領域を導出すること」を指していることが多い。なお、対象とする物体は1種類ではなく複数の種類でも良く、認識したものの確からしさも得ることができる。物体検出は画像分類処理と比較した場合、どこにどのような物体がいくつ存在するか導かないといけないため、処理の難易度が高くなり処理時間も掛かる。一方、セグメンテーションと比較すると、物体を囲む矩形の形状を求める(この矩形はBounding box ともよばれる)だけで良いため、処理時間が短い傾向にある。医用画像に応用する場合、臓器がどの位置にあるのかを特定したり(図1(a))、病変の有無や病変の位置を表示(図1(b))したりする処理が考えられる。

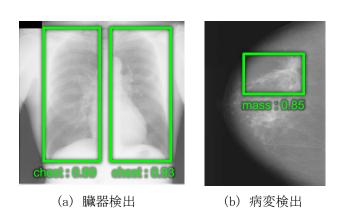


図1 物体検出の例

(矩形が認識した物体の Bounding box を表し、その下の数値が確率を表す.)

3. 物体検出アルゴリズム

これまでに CNN を利用した多くの手法が提案されているが、基本的な処理手順は次に述べる 2つのステップで行われている. ①画像全体から物体がありそうな領域の候補をたくさん取り 出す. ②見つけた領域に物体が有るか、有る場合は何が写っているか (カテゴリー) を分類する.

自然画像を処理対象として開発され、高い性能を有することが確かめられている物体検出手法として、以下にあげる手法がよく用いられている。これらの方法は医用画像への応用例もいくつか報告されており、本稿で紹介する結節検出にも応用可能である。

1) R-CNN 系の手法

2013 年に Ross Girshick らによって開発された R-CNN (Region-based CNN) [1] は、与えられた 画像に様々な矩形を当てはめ、物体の候補になる領域を数千個ピックアップした後、CNN とサポートベクタマシンを利用して正確な物体の有無と種類を決定する。この方法は、個々の候補 領域に CNN を適用する必要があったため演算量が多く、処理時間が長いという課題があった. そこで処理時間を短縮するため、候補領域の抽出効率を改善した Fast R-CNN[2]、Faster R-CNN[3]などが次々と提案され、リアルタイムで物体検出できるようになった.

2) YOLO 系の手法

2015年8月に、Joseph Redmon らによって YOLO (You only look once) [4]が発表された.これまでに述べてきた手法では、何らかの方法で候補領域を取得し、CNN により候補の絞り込みや分類を行っていたが、YOLO ではあらかじめ入力画像を細かく分割し、各領域に物体の種類とBounding box を設定するという手法をとることで前述の R-CNN よりも精度は劣るものの、かなり高速な処理が可能となった。2016年には YOLO の改良作として SSD (Single shot multibox detector) [5]が Wei Liuらによって発表され、YOLO よりも高速で、かつ R-CNN に近い高い精度が得られるようになった。

3) 物体検出とセグメンテーションを同時実行: Mask R-CNN

Mask R-CNN は、分類、物体検出、セグメンテーションを同時に高精度で行うことができ、コンピュータビジョンに関する国際学会である ICCV 2017 において Best Paper に選出された手法である[6]. Mask R-CNN は新たなネットワークを導入するのでなく、既存の Faster R-CNN と物体セグメンテーション手法を組み合わせることで、一度対象物を検知したうえで領域を抽出するという、人間の視覚処理に近い自然な処理が可能となった.

4) 分類処理・セグメンテーション技術の利用による物体検出

物体検出は上述した方法以外の CNN でも行うことができる. 例えば, 画像分類処理を物体検 出に利用する場合, 画像を細かく分割し, それぞれの分割された画像(画像パッチとよぶ)に 物体が含まれるかどうかを CNN で分類させることによって対象物のある場所と大きさなどを検出できる. 処理の概念図を図2に示す.

また, Fully convolutional network (FCN) [7]や U-Net [8] などのセグメンテーション技術は 画像内の物体を塗りつぶした画像を出力することができるため,物体検出にも利用できる. しかし,物体の位置,サイズ,個数は把握できないため,それらを把握したい場合にはセグメンテーションした後にラベリング等の従来の画像処理を適用し,物体を弁別する処理を行う必要がある.

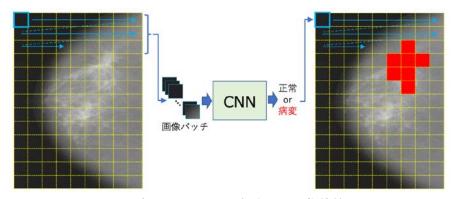


図2 パッチベースの分類を用いた物体検出

4. JSRT 標準ディジタル画像データベースによる処理例

物体検出処理を JSRT の標準ディジタル画像データベースで実施する手順や結果を紹介する. 物体検出手法については, 前節 2) で紹介した SSD[5], 3) で紹介した Mask R-CNN[6] について, 処理例を紹介する.

1) 画像の準備

対象となる JSRT 標準ディジタル画像データベースや, 深層学習処理が行いやすいように予め 加工されたデータは画像部会のホームページ(http://imgcom.jsrt.or.jp/download/, http://imgcom.jsrt.or.jp/minijsrtdb/)から入手できる.

2) アノテーション

胸部 X 線画像から結節を検出する場合,正解となる結節の情報(結節の Bounding box や結節 領域を塗りつぶした画像など)を与える必要がある.必要な情報や形式は物体検出手法によって異なるが,現在はアノテーション情報を作成するためのツールが多数公開されている.例えば,Labelbox (https://labelbox.com), Visual Object Tagging Tool (VoTT) (https://github.com/microsoft/VoTT)や,LabelImg (https://github.com/tzutalin/labelImg)などがある.筆者らのグループはアノテーションツールとして,主にLabelboxを用いて行っている.Labelboxは,ローカルならびにクラウド上の画像データを対象として物体の Bounding box 設

定や,対象領域の輪郭トレースなどを Web ブラウザ上で行うことができる(図3). 入力した アノテーション情報は csv 形式や json 形式など、多くの物体検出処理で取り扱いやすい形式で 取り出すことが可能である.



図3 Labelbox による結節領域のアノテーション

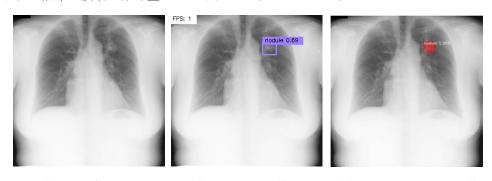
3) SSD による結節検出

SSD の処理には、TensorFlow と Keras を用いて開発されたプログラム (https://github.com/ rykov8/ssd keras)を利用し、JSRT の JSRT 標準ディジタル画像データベースを用いて結節位置 を個々に登録したアノテーションファイルを用いて学習を行った. SSD による結節検出結果の 例を図4(a)に示す. 結節領域が正しく矩形で囲われていることがわかる.

4) Mask RCNN による結節検出

Mask RCNN の処理には、Matterport 社が GitHub で公開しているプログラム(https:// github.com/matterport/Mask_RCNN) を利用した. こちらも SSD と同様に TensorFlow と Keras を利用して動作するようになっている. GitHub からダウンロードしたファイルには,人物や一 般的な物体を検出するサンプルプログラムや、自分のデータで学習させるためのサンプルプロ グラムが入っており、筆者は後者のプログラムを一部改変して結節検出処理に利用した.

実際に JSRT データベースを利用して Mask RCNN の学習を行い、結節を自動検出した結果を図 4(b)に示す. 結節の領域が赤く塗りつぶされていることがわかる.



(a) 原画像

(b) SSD による検出 (c) Mask RCNN による検出

図4 JSRT 標準ディジタル画像データベースを用いた結節検出処理例

5. さいごに

本稿では、CNNによる物体検出処理に関して、その原理や JSRT の標準ディジタル画像データベースを用いた結節検出の処理方法について解説した。ディープラーニングにより可能な処理のうち、医用画像に対して一番難易度が高いのは、この物体検出処理だと思われる。それはプログラムやデータ構造が複雑であること、サンプルプログラムやアノテーションツールの整備がまだ十分ではないこと等が原因と思われる。また、医用画像のような3次元画像を対象にした物体検出処理は研究事例が少ない。この記事をきっかけにチャレンジされる方が増えることを期待したい。

参考文献

- [1] R.Girshick, et al., "Rich feature hierarchies for accurate object detection and semantic segmentation," Proceedings of the IEEE conference on computer vision and pattern recognition, pp.580–587, 2014.
- [2] R.Girshick, "Fast R-CNN," Proceedings of the IEEE international conference on computer vision, pp.1440-1448, 2015.
- [3] S.Ren, et al., "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," Advances in neural information processing systems, Vol.28, No.1, pp.91–99, 2015.
- [4] J.Redmon, "You Only Look Once: Unified, Real-Time Object Detection", Proceedings of the IEEE conference on computer vision and pattern recognition, pp.779–788, 2016.
- [5] W.Liu, "SSD: Single Shot MultiBox Detector," Lecture Notes in Computer Science, Vol.9905, No.1, pp.21–37, 2016.
- [6] K.He, et al., "Mask R-CNN", Proceedings of the IEEE international conference on computer vision, pp. 2961–2969, 2017.
- [7] J.Long, et al., "Fully convolutional networks for semantic segmentation," 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 3431–3440, 2015.
- [8] O.Ronneberger, et al., "U-Net: Convolutional Networks for Biomedical Image Segmentation," Lecture Notes in Computer Science, 9351, pp.234–241, 2015.

技術紹介

富士フイルムメディカル株式会社 MS 事業部 石井 伸英

1. はじめに

富士フイルムは CR (コンピューテッド・ラジオグラフィ) を 1981 年に世界で初めて開発・実用化した。 富士フイルムのデジタル技術はこの時より始まり、2009 年には 間接変換型 FPD を実用化、そして 現在に 至っている。今回、富士フイルムの DR を支える FPD 技術と、それを基礎とした新しい動画 X 線システム を紹介する。

2. 間接変換型 FPD の技術

富士フイルムのカセッテ DR シリーズは間接変換型 FPD を搭載している。間接変換型 FPD は、X 線を可 視光に変換するシンチレータと、可視光を検出するフォトダイオードを配列した TFT 基盤を組み合わせ た構造を持ち、X 線を光に変換した後、その光をフォトダイオードで電気信号に変換しデジタル化する方 式である。そして、その構造は一般的に採用されている X 線の入射側(被写体側)にシンチレータ層、出 射側に TFT パネル(検出器)を配置する方式とは異なり、入射側に TFT パネル、出射側にシンチレータを 配置する「ISS(Irradiation Side Sampling)方式」を採用している。

パネルに入射した X 線はシンチレータ層内で吸収されて減衰していくため、シンチレータの X 線入射面側で発光強度が大きく、出射側で小さい。また、X 線が入射して可視光に変換された光は等方的な発光強度を持ち、拡散してしまうため、光の発生場所が TFT パネルから遠いほど光の広がりが大きく、ボケが生じる。ISS 方式はこれらの欠点を解決するために採用され、最も強い光は TFT パネルの最も近い部分で発生するため、光の強度が強く、ボケが少ない画像を得ることが可能になった。(図 1)

このように、ISS 方式は間接変換型 FPD では解像度に支配的である光のボケを抑えつつ、高感度が実現できる技術であり、画素サイズが大きな場合でも ISS 方式によって鮮明な画像が得られる。

3. 静止画像技術を動画領域へ応用

整形外科や血管外科などの外科的手術では、外科用Cアームが広く使用されている。外科用Cアームで得られる X 線動画像は、体内に挿入した処置具の位置や患部の様子が把握できるよう、高鮮鋭であることが求められる。また、近年被ばくへの関心が高まっており、長時間の X 線透視を行う治療や手術においては、X 線動画撮影時のさらなる低線量化が求められている。

富士フイルムは、2017年4月に長年X線静止画像で培ってきた画像技術を応用し、ノイズを抑えた高鮮鋭なX線動画像を表示することができるX線動画技術を開発した。2018年に発売した外科用Cアーム

型デジタル透視システム「COREVISION 3D」(図 2)は、当社の X 線動画技術と、X 線動画全体のコントラストを最適化する画像処理技術「Dynamic Visualization 2(ダイナミック処理)」で構成される新 X 線動画処理エンジン「DCE: Dynamic Core Engine(ダイナミックコアエンジン)」の搭載により、高鮮鋭かつ高コントラストな X 線動画像を提供する。動画像を構成する一枚一枚のフレームにノイズ低減処理を施し、さらに患者の体の動きを高精度に検出して前後のフレームを重ね合わせることで、ノイズを低減しながらも処置具や患部の対象物を鮮明に描出する。さらに、対象部位の X 線吸収量の違いにより発生する白つぶれや黒つぶれをダイナミック処理により抑制しバランスの良いコントラストを実現した(図 3)。画像処理は高速に行われるため、最大 25 フレーム/秒の高フレームレートでも、実際の動きと動画上の動きのタイムラグを抑えて、X 線動画を鮮明に描出する。Dynamic Core Engine と組み合わせることで、同エンジンを使わない場合と比べて、約半分の X 線量でも、同等の画像を実現する。

「COREVISION 3D」は、静止画のデジタル X 線画像診断で多くの実績と高い評価を得ている ISS 方式を採用した FPD を搭載。 FPD は外科用 C アームでは最大級の $31 \,\mathrm{cm}\, x \, 31 \,\mathrm{cm}\, x \,$ で、椎体など観察対象が広範囲の観察が可能である。 また、 ISS 方式による高感度高鮮鋭度の両立によって $150 \,\mu\, \mathrm{m}\,$ 画素サイズにおいて解像度と信号ノイズ比を最適化することに成功した。 $150 \,\mu\, \mathrm{m}\,$ 画素サイズにより、細いカテーテルなどの視認性を向上させている。

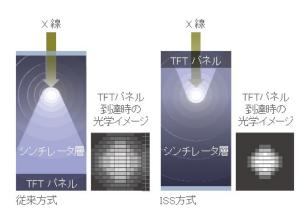


図 1: ISS 方式



図 2: COREVISION 3D





図3:従来処理(左)とダイナミック処理(右)

4. 高画質術中 3D を実現する「SmartScan」

「COREVISION 3D」は、術中に対象部位を180°相当スキャンする「SmartScan」を搭載。2D動画だけでなく、3D画像を描出することが可能である。

SmartScan は C アームの 4 軸電動駆動により、回転スキャン+リニアスキャンを組み合わせ 180° 相当のスキャンを行い(図 4)、3D ボリュームデータの構築を行なう(図 5)。3D の構築には逐次再構成アルゴリズムを使用しており、金属アーチファクトを抑制した高画質 3D ボリュームデータを提供する。整形外科領域で椎体間固定術や人工関節置換術において、体内に挿入したインプラントの位置など、従来の 2D 動画だけでは見えにくいものをさまざまな角度から確認することが可能となる。また S SmartScanにより C アーム本体をコンパクトにすることが可能となっている。

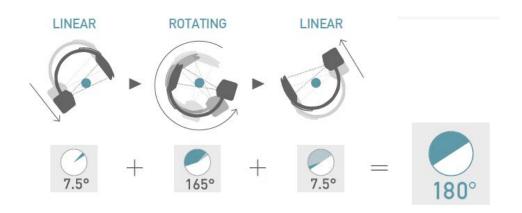


図 4: SmartScan

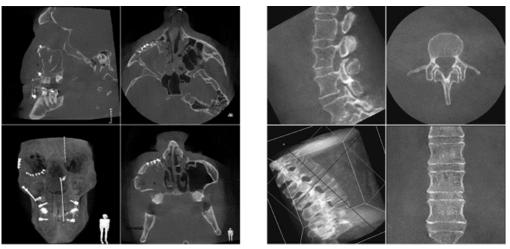


図 5: SmartScan による 3D ボリュームデータ

5. おわりに

富士フイルムは、医療現場で急速に高まる X 線画像の高画質化や低被ばく化のニーズに、先進の技術をもって取り組んできた。今後は、X 線動画の分野においても、当社技術を活かし、さらなる医療の質の向上に貢献していく。

COREVISION 3D (販売名:X線透視診断装置 COREVISION 3D/認証番号:第230ABBZX00033000号)」

技術紹介

被ばく低減に貢献する Deep Learning を用いた 新しい CT 画像再構成技術

キヤノンメディカルシステムズ株式会社 CT 営業部 アドバンスト CT プロモーション担当

岡部 貴浩

1. はじめに

Lancet へ医療被ばくのリスクについて論文が掲載されたことや、福島原発事故に伴う放射線被ばく報告など、被ばく低減への重要性が議論されてきた。2015年に日本医学放射線学会からCT 撮影の診断参考レベルの設定が発表され、2020年4月1日からはCT装置等で照射した線量の記録と管理が求められるようになる(1-2). 社会的に被ばく線量の最適化が重要視される中で、X線診断装置にはより低線量でも診断に耐えうる画像の提供が求められる.

当社は「CT による医療被ばくを半減したい」というスローガンのもと、CT 被ばく半減プロジェクトを進めている. 低被ばく検査を実現するためのハードウェアとソフトウェアの両方から被ばく低減技術の開発に取り組んでいる(図 1). 本稿では、AI(Artificial Intelligence)技術を用いて CT の画像再構成を行う全く新しい再構成法 Deep Learning Reconstruction "AiCE (Advanced intelligent Clear-IQ Engine)"の原理や特長について述べる.

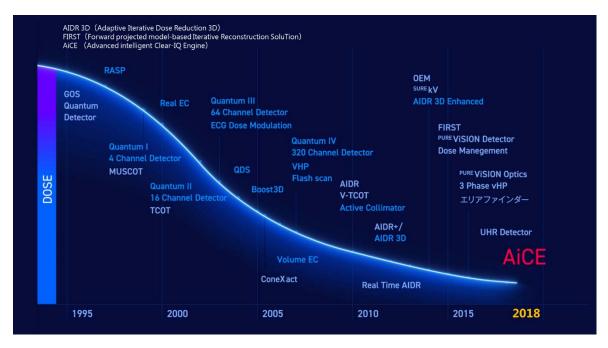


図1:キヤノンメディカルシステムズの CT 被ばく低減技術の歴史

2. キヤノンメディカルシステムズの画像再構成技術の歴史

現在 CT で一般的に使用されている再構成法である FBP (Filtered Back Projection) は、再構成関数を用いて目的に合わせた画像を高速に再構成できる. 従来のシングルスライス CT から現行のマルチスライス CT まで長い間用いられてきたが、被写体や撮影条件等に依存したアーチファクトやノイズ等が課題とされていた.

再構成関数を用いながらも、投影データ上と画像データ上の二段階でノイズ低減処理を行う再構成法である Hybrid-IR は、高速でありながら効果的にノイズ除去を行うことができる。当社は、AIDR 3D (Adaptive Iterative Dose Reduction 3D)、AIDR 3D Enhanced を開発し、AIDR 3D についてはすべての現行販売機種に"標準搭載"することを実現した。

しかし、これまでの再構成関数を用いる再構成法は、一般的にノイズと空間分解能にトレードオフの関係があった。当社が開発した FIRST (Forward projected model-based Iterative Reconstruction SoluTion) は、MBIR (Model Based Iterative Reconstruction) と呼ばれる再構成法であり、再構成関数からの脱却とモデルベースの投入により、ノイズ低減と空間分解能向上の両立を可能にした(3). FIRST は、収集した投影データから逆投影して得られた画像を順投影し、その差異をフィードバックしながら真値画像との差異が収束するよう演算する. 大幅な被ばく低減に加え分解能の向上が可能であるが、演算時間の長さが課題である.

3. AI 技術の一つである Deep Learning

現在,人工知能 AI 技術の一つである深層学習 (Deep Learning) が革新的な技術として注目されている. 近年の AI 技術の普及が進む背景には、この Deep Learning 技術が飛躍的に進歩したことが大きいとされている.

Deep Learning は,入力層と出力層を複数の中間層で結んだニューラルネットワークを形成する.このニューラルネットワークは,学習によって問題解決能力を持つようなモデルである.ニューラルネットワーク研究の歴史は長く,1957年にパーセプトロンという考え方が考案され,第一期,第二期を経て,現在は第三期を迎えている.ニューラルネットワークの計算コストの問題解決に,近年のビッグデータの活用や,強力な並列計算を実現した GPU(Graphics Processing Unit)の普及が貢献している.

Deep Learning 技術は、音声、画像認識、自動車、ロボットなどのさまざまな社会インフラで応用・期待されている。さらに、コンピュータ支援診断 CAD (Computer-Aided Diagnosis) による病変部の自動検出やセグメンテーション、ビッグデータ解析による類似データの検索等の放射線画像診断への応用事例も急速に増加している (4-6).

4. Deep Learning を用いた画像再構成技術

キヤノンメディカルシステムズが開発した AiCE は CT 画像のデノイジングに Deep Learning 技術を応用した Deep Learning Reconstruction という全く新しい再構成法である. Deep Learning を用いることでノイズ成分とシグナル成分を識別し、空間分解能を維持したままノイズを選択的に除去することが可能である.

AiCE は革新的な技術である DCNN (Deep Convolutional Neural Network) を用いている。DCNN は膨大な畳み込みフィルタ (convolution filter) と多層のニューラルネットワークを組み合わせ、さまざまな条件下でトレーニングすることで、正確なノイズ推定が可能となる頑健なネットワークが形成できる。画像のエッジやテクスチャ等の特徴量を人間と同程度の高い精度で認識できると報告がある (7).

5. AiCE の原理

AiCE のアルゴリズムは学習パートと再構成パートに分かれている(図2).

①AiCE の学習

AiCE のモデル DCNN 構築は開発段階で行われており、装置導入後に個々の施設で新たな学習や更新ができないことをまず述べておきたい. 学習は入力データを教師データに近づけるように DCNN を最適化することが目的であるが、精度は学習データに大きく依存するうえに、膨大な入力データ・高品質な教師データが求められる.

学習で最も重要な要素は、教師データに高品質なデータを用いることである。AiCE は教師データに、製品レベルの FIRST に対して "更に"iteration 回数の強化・改良し、1症例1症例ごとにパラメータを最適化した高品質なデータ (Advanced MBIR) を用いている。入力データとしても数十万枚の膨大なデータ (様々なノイズレベル、部位、体格等を含む)を用い、ロバスト性の高い DCNN を構築した。

②AiCE の再構成

装置に組み込まれた学習済みの DCNN を用いて再構成を行う. 装置で収集されたデータは DCNN を介することで,ノイズが選択的に除去され,最終画像として高品質な AiCE 画像が出力される. 学習済みの DCNN は FIRST のモデルも学習しているため,空間分解能の向上などの恩恵を受けることができ,さらに MBIR で課題とされていた計算時間の問題もクリアしている.

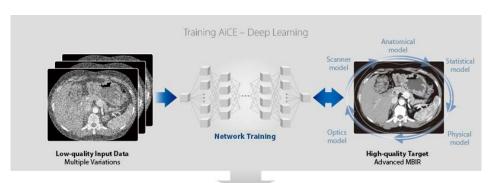




図2: AiCE のアルゴリズム

5. AiCE の特長

①高いノイズ低減と空間分解能の向上

AiCE は大幅なノイズ低減効果と空間分解能の向上を実現する. 特に通常の MBIR では困難であった低コントラスト領域における高いノイズ低減効果や粒状性の維持効果が高く, 低線量領域での安定した画質向上を実現する.

②再構成高速化

MBIR では膨大な計算が必要であったのに対し、AiCE は MBIR の特長を保ちながら計算量の低減が可能である。 再構成アルゴリズムに組み込まれた DCNN を介するだけで、高画質データが生成される。また、ハード面においても、複数の GPU を搭載することで、ルーチン検査でストレスのない使用を可能とした(図3)。 ソフト、ハードのアプローチにより、Aquilion ONE / GENESIS Edition に搭載した AiCE は、秒間 40 枚程度の再構成速度を実現している。

③ワークフロー向上

撮影プロトコルに AiCE を組み込んでスキャン連動で再構成することで、AiCE の被ばく低減効果を見込んだ撮影条件を設定することが可能である. 具体的には、Volume EC(Volume Exposure Control)で再構成モードを AiCE に設定し、さらに AiCE 強度を選択すると強度に応じた X 線の管電流が算出され、被ばく低減が可能となる. これは AIDR 3D や FIRST と同じ操作性であり、従来のワークフローを変えることなく AiCE の使用を可能にする.

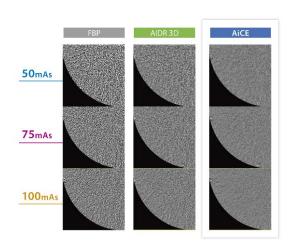


図3: Aquilion ONE / GENESIS Edition に搭載した GPU

6. AiCE の物理特性

①ノイズ特性

Aquilion Precision で直径 32 cm の水ファントムを各線量(50 mAs, 75 mAs, 100 mAs)で撮影し、各種再構成法で比較した 4 Axial 画像と NPS(noise power spectrum)を図 4、図 5 に示す. 図 4 より,従来の FBP と AIDR 3D は線量が低くなるほど粒状性が劣化するが、AiCE では低線量下である 50 mAs においても、粒状性を維持していることが確認できる。図 5 より,AiCE は FBP と AIDR 3D と比較して、すべての線量帯で画像ノイズ量を示す NPS カーブ下面積が最も小さく、高いノイズ低減効果を示す。また、AiCE は今まで難しいとされていた低周波ノイズに対しても効果が確認できる。 さらに、AiCE の NPS 形状に着目すると、すべての線量帯における NPS 曲線が重なっていることで粒状性維持効果が高いことを示している。従って、幅広い線量帯でも安定した画像ノイズ改善効果を有している。



HR mode, 120kvp, 52, 0.5sec/rot., 1024matrix, ReconFOV 400mm Water phantom(240mm) / 1mm

AIDR : Adaptive Iterative Dose Reduction AICE : Advanced intelligent Clear-IQ Engine

図 4: 水ファントムの Axial 画像比較

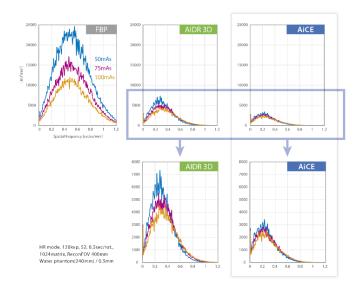
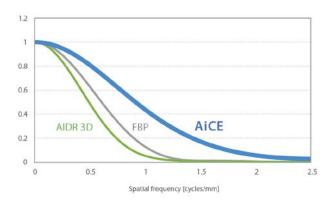


図 5:NPS 比較

②空間分解能(XY 面内)

Aquilion Precision で Catphan® 600 CTP404 (Phantom Laboratory 社製) を撮影し、各種再構成法で Teflon モジュールより算出した TTF (task transfer function) を図 6 に示す (8). 図 6 より、AiCE は FBP と AIDR 3D と比較して、TTF が優れている結果を示しており、更なる空間分解能向上に期待できる.



HR mode, 120kvp, 75mAs, S2, 0.5sec/rot., 6.5mGy, 1024matrix, ReconFOV 200mm Catphan600 (CTP404 / Teflon (850HU))

図 6. TTF 比較

③低コントラスト検出能

Aquilion Precision で Catphan® 600 CTP515 (Phantom Laboratory 社製)を撮影し、各種再構成法で比較した Axial 画像を図7に示す。図7より、AiCE は粒状性を維持しながら高いノイズ低減効果により、低コントラスト検出能が向上していることがわかる。また、細かい粒状性を維持しながらノイズ低減を可能とする AiCE の特性を活かすことで、ノイズに埋もれやすい微小物体の描出能向上が期待できる(図7矢印:ロッド 2mm 径、3mm径)。

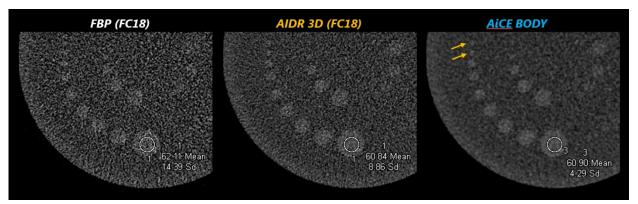


図7:低コントラスト検出能の比較

7. 臨床への展開

AiCE は実臨床での使用も始まっており、すでに複数の文献で評価されている.

①腹部領域

広島大学の赤城先生らより、腹部領域において Aquilion Precision を用いて、AIDR 3D、FIRST、AiCE でそれぞれ再構成し、画像 SD(standard deviation)、CNR(contrast-to-noise ratio)、視覚評価(読影医 2 名による 5 段階評価)を実施した結果、AiCE では、動脈相と平衡相共に、画像 SD は大幅に改善され CNR は優位に高い結果を示し、視覚評価でも全体的な画質として最良な結果と報告されている(9).

図8はAquilion Precisionで撮影されたデータに対して、各手法で画像再構成した同一患者における 多発嚢胞の比較画像である.スライス厚が0.5mmのため、AIDR 3DとFIRSTではノイズが多いが、AiCEでは嚢胞境界の鮮鋭度やコントラストを維持しつつ、ノイズを大幅に低減できており、腹部領域における微小病変の検出能向上の可能性が示唆されている.



図8:多発嚢胞(左:AIDR 3D,中:FIRST,右:AiCE)

②心臟領域

冠動脈 CTA においても、広島大学の立神先生らによると、Aquilion ONE を用いて、AIDR 3D、AiCE でそれぞれ再構成した結果、AiCE による画質は AIDR 3D と比較し、画像 SD、CNR、CT 値プロファイル、視覚評価(読影医 2 名による 4 段階評価)、すべての結果で優位に優れており、更に AIDR 3D よりも 36%の線量低減の可能性が報告されている(10)。本文献で使用した AiCE は製品化前のプロトタイプであった。

図 9 は心機能評価のために心電図同期にて R-R 間隔を 1 心拍連続撮影したデータをレトロスペクティブに用いて,通常線量と低線量(通常の 20%線量)における AIDR 3D と AiCE の比較画像である.通常線量と 20%線量の AIDR 3D を比較すると, 20%線量は通常線量よりノイズの粒状性が粗く,ノイズも多いことが確認できる.しかし, 20%線量の AiCE では通常線量の AIDR 3D とほぼ同等の画質が得られていることが分かる. AiCE の使用により,画質を担保したまま大幅な被ばく低減の可能性に期待できる.

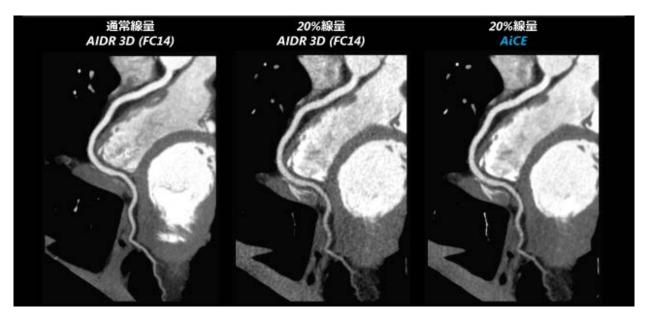


図 9: 低線量冠動脈 CTA (左:通常線量 AIDR 3D, 中:20%線量 AIDR 3D, 右:20%線量 AiCE)

③胸部領域

図 10 は Aquilion ONE による低線量肺がん CT 検診 $(1.5\,\mathrm{mGy})$ のデータを各手法で再構成した画像である. AIDR 3D や FIRST でも画質が向上しているが、AiCE が最もノイズ低減効果が高く、肺野内のコントラストも良好である.

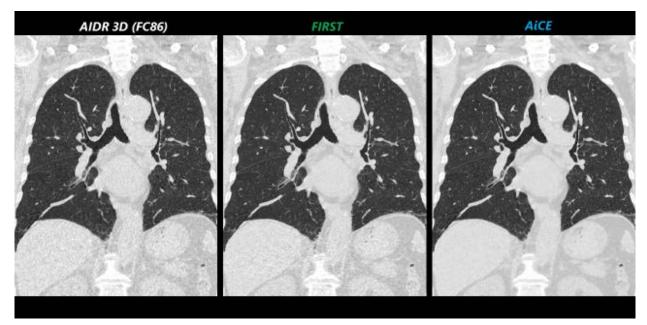


図 10:低線量肺がん CT 検診 (左: AIDR 3D, 中: FIRST, 右: AiCE)

8. 結語

Deep Learning Reconstruction "AiCE"は、従来の画像再構成とはまったく異なる画像再構成技術であり、画期的なAI技術や学習要素を取り入れることで、CT装置が持つ最大限の空間分解能を引き出しながら、飛躍的なノイズ低減効果を実現した。

2019 年 8 月現在, 高精細 CT U-HRCT (Ultra-High Resolution CT) Aquilion Precision, 320 列エリアディテクタ CT (Area Detector CT) Aquilion ONE / GENESIS Edition へ搭載している。今後の発展として, 部位ごとのパラメータ最適化や他機種展開について準備をし, キヤノンメディカルシステムズは今後も更なる高画質と被ばく低減を実現するために, より良い技術開発を続けていく所存である。

参考文献

- 1. Berrington de González A, et al.: Risk of cancer from diagnostic X-rays. Lancet., 363 (9406), 345-35, 2004.
- 2. 公益社団法人日本医学放射線学会:エックス線 CT 被ばく線量管理指針. 2015.
- 3. 近藤 玄: Area Detector CT 『Aquilion ONE/ViSION FIRST Edition』 ~逐次近似再構成技術を臨床現場へ~. 映像情報メディカル, 47 (11), 165-168, 2015.
- 4. Doi K.: Overview on research and development of computer-aided diagnostic schemes. Semin Ultrasound CT MRI., 25 (5), 404-10, 2004.
- 5. Suzuki K.: Overview of deep learning in medical imaging. Radiological Physics and Technology., 10 (3):257-273, 2017.
- 6. Bradley J, et al.: Machine Learning for Medical Imaging. RadioGraphycs., 37 (2):505-515,

2017.

- 7. Yaniv T, et al.: Deep Face: Closing the Gap to Human-Level Performance in Face Verification. CVPR. 2014 IEEE Conference on Computer Vision and Pattern Recognition, Columbus, OH, 2014, pp. 1701-1708.
- 8. Richard S, et al.: Towards task-based assessment of CT performance: System and object MTF across different reconstruction algorithms. Med Phys., 39 (7), 4115~4122, 2012.
- 9. Akagi M, et al.: Deep learning reconstruction improves image quality of abdominal ultrahigh resolution CT. Eur Radiol., 2019.
- 10. Tatsugami F, et al.: Deep learning-based image restoration algorithm for coronary CT angiography. Eur Radiol., 2019.

Aquilion Precision、Aquilion ONE、AiCE マークはキヤノンメディカルシステムズ株式会社の登録商標です。 Catphan®はPhantom Laboratoryの商標登録です。

第40回プログラミングセミナーを受講して

九州大学病院 医療技術部 放射線部門 酒井 友貴

この度は、熊本で開催された第 40 回プログラミングセミナーを受講し原稿を執筆する機会をいただきましたので個人的な感想を述べます. "ディープラーニング研究を自分のものにしよう"と題したセミナーのコンセプトが私の関心に合致していたため、高い意識で受講することができました. 2 日間のセミナーでは、Neural Network Console と Python の 2 つの方法でディープラーニングを経験しました. 受講して感じたセミナーの利点を 3 つの観点から述べていきます.

1つ目の利点は、ディープラーニングを理解し自分で動作できたことです。これまで、独学であったため正確に理解できているか不明で、理解度を確認しないまま学習していました。自分で動作することで理解できていたことと誤って理解していたことを明確にできました。参考書を読むインプットだけではなく、自分で動作させることの重要性を理解しました。

2つ目の利点は、低価格で安心感のあることです。企業主催のディープラーニングセミナーと比較して、本セミナーでは10分の1以下の費用で受講することができます。非常に良心的な価格で、かつ医用画像に特化したセミナーを受講できるのは日本放射線技術学会の会員である強みだと思いました。また、受講者30名ほどに対して複数の先生方がいらっしゃいましたので、演習中に躓いても先生方に援助をしていただけました(Figure)。いつも学会上でお見かけする著名な先生方に丁寧に教えていただけたので、その安心感は想像に難くないと思います。

3つ目の利点として、懇親会が開催されることです. 懇親会では先生方や受講者とお話することができました. ディープラーニング研究を志す仲間が増えたようで心強く感じました. 普段, 先生方と近

い距離でお話することができないため、懇親会は先生方とお話できる貴重な機会だと感じました。セミナーで十分に理解できなかったことや普段感じていた疑問を質問させていただき、大変助かりました.

私がセミナーを受講して感じたことを述べさせていただきました. 同様のセミナーが今後開催されるなら,ぜひ参加したいと思います. ディープラーニングに興味を持っているが,何をすればよいかわからない,あるいは一歩踏み出せない方がいらっしゃれば,セミナーに参加することを強くお勧めいたします!最後に,セミナーで丁寧にご教授いただいた先生方にこの場を借りして感謝申し上げます.



Figure 中山先生(右) と指導を受ける筆者(左)

第40回医用画像処理プログラミングセミナーを受講して

大分県立病院 放射線技術部 西嶋 康二郎

2019年6月15から16日の2日間、熊本大学医学部保健学科にて第40回医用画像処理プログラミングセミナーが「ディープラーニング研究に備える」をテーマに開催されました。2019年4月の第75回日本放射線技術学会総会学術大会にて開催されたディープラーニングハンズオンセミナーに参加できなかった私は、本セミナーの受講登録が開始されるとすぐに申し込むほどに楽しみにしていたセミナーでした。私の参加動機は、今年3月に開催されたECR2019に参加した際にAIに関する講演・発表の多さと注目度の高さに驚き、今ディープラーニングを学ばなければこれからの技術革新においていかれるのではないかと危機感を抱いたためです。

本セミナーは、放射線技術学におけるディープラーニング研究を始めるために必要な環境設定や、画像識別・領域抽出といったプログラムを自分で動作させることで理解することを目的とされており、1日目はNeural Netwaork Cosole を使用した GUI でのディープラーニング演習、2日目はTensorflow+Keras を用いて Python によるコーディングを使用したディープラーニング演習をおこないました。両日ともにほぼ同じ処理を演習としておこなったのですが、1日目の Neural Netwaork Cosole の講義でディープラーニングのネットワーク構造を視覚的に理解することができたため、2日目のPython によるコーディングが何をしているかがイメージしやすくなりました。内容が濃く情報量の多いセミナーでしたが、講師の先生方のわかりやすい資料と親切な説明により何とかついていくことができました。また、研究をおこなうための環境作りへのアドバイスもいただき、実りの多い2日間となりました。丁寧に教えていただいたこのディープラーニングの基礎・基本を忘れてしまわないように資料を読み返しつつ、今後の研究活動に活用させていただきます。

最後になりましたが、本セミナーにご尽力いただいた講師の先生はじめ関係者の方々に厚く御礼申し上 げます。



第6回臨床画像評価セミナーを受講して

浜松医科大学医学部附属病院 放射線部 福岡 通大

お恥ずかしい話、入職してから簡単な検討はしてきたものの、研究というものは行ってきませんでした。年功序列で一般撮影部門の主任となり、何かしら始めたいと思っていたところ、タイミング良く装置更新があり、さらに異なるメーカーの FPD を導入するこができました。最高の環境となりましたが、知識が全くない状態でした。まず FPD の物理評価からと思い、講習会を探していたところ DR セミナーを発見し、昨年 DR セミナーを受講しました。臨床画像についてどのような比較・評価方法があるかどうやっていこうかと思っていたところ、受講した DR セミナーで本セミナーのことを知り、受講しようと思いました。

前もって受講内容である ROC・FROC について勉強しようと思い色々調べましたが、正直なところよく分かりませんでした。そのような状態での受講は不安でいっぱいでした。しかし、講習は講義を聞いて実習の流れで得た知識をすぐ使うという具合でした。また実習で躓いたときにはスタッフの方が手早くフォローしてくださり大変恵まれた環境でした。

セミナーは1日半で行われ、1日目は臨床評価概論から始まりました。臨床画像の比較・評価法とは「画質+診断の正確さ」評価ということを知りました。また「診断の正確さ」について知ることができました。 次は物理評価で入出力特性・NNPS・MTF・NEQ・DQE についての講義・実習でした。DR セミナーと重複する 内容もありましたが、自分が理解できなかったことを改めて聞くことができ、再確認することもできました。 その次は ROC の解析ソフトウエアについての説明で、Viewer にて比較である観察者実験を行い Analyzer で解析を行うことを学び、その後一対比較法の講義・実習で初めて ROC ソフトウエアを使用しましたが、その性能に大変驚きました。2日目は ROC・FROC についてでした。ROC 曲線を手計算で作成しましたが、結構大変でその後 ROC ソフトウエアを使用しましたが、改めてその便利さを知ることができました。

1日目のセミナー終了後は懇親会がありました。私はお酒を飲めません。正直飲み会の場を盛り下げて しまうタイプの人間と思っていますが、何かしらのつながりを持てればと思い、そのことを顧みず参加さ せていただきました。講師の先生方の話は大変おもしろく、また多施設の近況も聞くこともできました。

1 日半の本セミナーはかなり濃密な内容です。復習し実際にやってみないと身につかないと思います。 私も現在研鑽中です。興味のある方は若い方からベテランまで受講して損しないセミナーと思います。受 講することをお勧めします。

最後に本セミナーを企画・開催して頂きました日本放射線技術学会画像部会および東京支部の皆様に 心より感謝申し上げます。

第6回臨床画像評価セミナーに参加して

紀南病院 放射線科 山﨑 純

令和元年、年号が改正されて初めての画像部会セミナーということで、7月5、6日の二日間にかけて、東京都の国立がん研究センター中央病院で開催されました第6回臨床画像評価セミナーに参加致しました。冒頭ではありますが、大変貴重な経験をさせて頂きましたことお礼申し上げます。

今回参加させて頂いたのは、自施設の一般撮影装置が、CR装置からFPD装置へと更新され、撮影条件の見直しが急務となりました。そこで、参考図書を片手に感度と画質の評価をするべく作業をしておりましたが、自身の知識・技術の乏しさに頓挫しておりました。その折に、物理評価法と視覚評価法を一度に学べるこのセミナーを知り参加させて頂くことになりました。

セミナーは測定法と評価法の講義・演習が交互に行われるため、内容がよく理解できました。 一日目は白石先生の挨拶と講義からはじまりました。臨床画像評価の概論として、「画質と診断の正確さ」を実践するための手法についての全体像をつかんだあとは、東出先生と柳田先生による入出力特性、presampled MTF、NNPS、NEQ、DQEの講義・演習と続きました。IEC62220-1線質決定についての新バージョンと旧バージョンの違いにもふれて頂き、また、入出力測定法の低露光域に関して、タイムスケール法と距離法のデータを得るための苦労話は非常に参考になりました。

二日目は白石先生、福岡先生、田中先生による ROC・FROC の講義・演習でした。ROCViewer による観察者実験をして ROCAnalyzer で解析を行う流れで進みました。ソフトは非常に使いやすくなっていますが、精度の高い結果を得るためには、観察者の事前トレーニングや試料の選定、試料数や時間に関しても適切であることが重要とのことでした。

セミナーでは、もう一つの楽しみとして懇親会に参加させて頂きました。講師の先生から受講生、部会、支部の皆様を囲んだ各テーブルでは、乾杯の音頭とともに第二幕がはじまりました。その中でお聞きできた話は、技師としての歩みや研究に対しての思い、経験されてきたこと、学生に思うことなど、僕にとってはモチベーションの高まる話ばかりでした。楽しい時間はあっという間に過ぎ、僕はすっかり酔いがまわってしまいました。酒豪の先生方におかれましては、夜半まで熱いディスカッションが続いたようです。

二日間を通して、撮影条件の検討や応用する術を学ぶ良い機会となり、自分の足りない部分を 補間し理解を深めることができました。演習途中は行き詰まってしまうこともありましたが、 チューターの方々にサポートして頂き最後までフォローして頂けました。そして、講師の先生 方には研究についてのご質問や初歩的な質問をぶつけていまいましたが、快くお答えいただき ましたこと深く感謝しております。

最後になりますが、臨床画像評価セミナーを開催し運営頂きました日本放射線技術学会画像部会および東京支部の先生方、会場となりました国立がん研究センター中央病院の先生方には心よりお礼申し上げます。

モニタ評価入門

名古屋第二赤十字病院 医療技術部放射線科 新美 孝永

1. はじめに

画像診断がフィルムからモニタに移行し医師の診断プロセスや診療放射線技師の業務形態も大きく変わった。しかしながら、画像を読影することや画像を評価することには何ら変わりはない。本稿では、私がこれまで実践してきたいくつかのモニタ評価の中でも教科書的で臨床現場ですぐに役に立つと思われるものを抜粋し紹介する。評価の原点は、日常的に診断医から問われるモニタ画像に関する問題の解決である。例えば「モニタの最高輝度がどれくらい劣化すれば診断に影響が出てくるのか?」や「電子カルテ閲覧用モニタでは肺がんの診断はできないのか?」あるいは「2MP と 3MP のモニタではどれくらい検出能が異なるのか?」という素朴な質問に対して文献や研究会等で学んだ知識を集結して納得する回答を導くことである。画像診断は、結果次第で患者の人生を左右する重大な要因となるため、我々技術者は一般論ではなく明確な根拠を持ったデータの提示が必要となる。本稿が臨床現場におけるモニタ評価の入門編として役立てば幸いである。

2. モニタ評価事例紹介

2.1 Contrast detail (C-D)解析を用いた評価事例

質問) モニタの最高輝度がどれくらい劣化すれば診断に影響が出てくるのか?

実験)当院で稼働する医療用モニタ(EIZO GX220)は、輝度、階調等の基本特性が測定可能な内蔵センサ(EIZO Built-In Swing Sensor)を各自が所有している。最高輝度は、メーカ推奨値を参考に 450cd/m²に設定し、階調は、人間の識別域を考慮して作成された Grayscale Standard Display Function (GSDF)

を用い設定輝度内における特性を管理している[1]。輝度は、長時間使用することで低下し診断能に影響を及ぼすことが知られている。今回、毎日の目視試験では確認が出来なかったが月1回の定期点検にて100台の内の1台に最高輝度が450cd/m²から300cd/m²へ低下していることが判明した。そこで、150cd/m²の輝度低下により信号検出能にどのような影響が出るのか評価を実施した[2]。

(方法) Fig. 1 に示す Contrast detail (C-D) ファントム (Convex 10 type, Kyotokagaku, Kyoto, Japan) 画像を用いて評価を実施した。 C-D 画像の輝度, 階調レベルは肺野内の病変を想定して X 線曝射により作成した。観察は、GX220 にて照度 201x (読影室) と 5001x (病棟)の環境下で診療放射線技師 11 名により実施した。

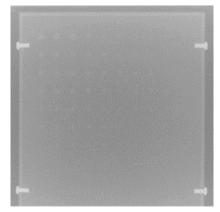


Fig.1 C-Dファントム画像

(結果) Fig. 2 は、 輝度の低下がどの程度検出能に影響を及ぼすのかを示す C-D 曲線を示す。照度 201x の読影室では最高輝度 $450cd/m^2$ と $300cd/m^2$ では全体的に $450cd/m^2$ の検出能が高く、 輝度の低下とともに 検出能が低下することが確認できた(p<0.05)。しかしながら 5001x の環境では、最高輝度 $450cd/m^2$ と $300cd/m^2$ の間に有意な差は確認できなかった(p>0.05)。

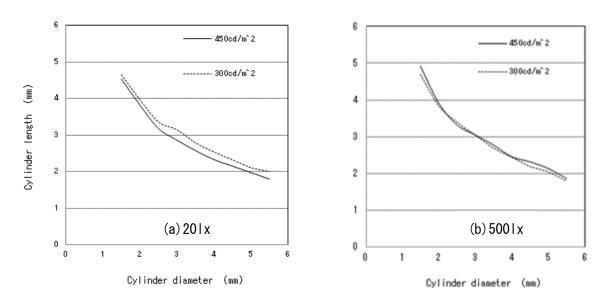


Fig. 2 最高輝度と信号検出能: 照度(a) 201x, (b) 5001x

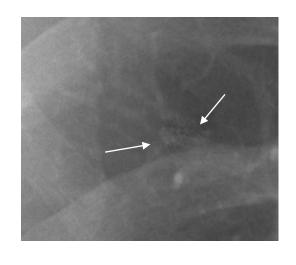
(結論) 読影環境では、450cd/m²から 300cd/m²の輝度低下により信号検出能には有意な差が出る。また、輝度の低下の影響と共に環境照度の影響も大きい。通常の医用モニタではここまでの急激な輝度低下はみられない (9200 時間の使用で約 40cd/m²の低下[3]) が定期的な管理、評価が必要である。

2.2 Receiver Operating Characteristic analysis (ROC) 解析を用いた評価事例 質問) 電子カルテ閲覧用モニタ (PC モニタ) では肺野病変の診断はできないのか?

実験) 診断に用いるモニタの性能が画像診断に与える影響を検証するために実際の臨床診断に近い状況で PC モニタと医療用モニタ (EIZO GX220) で比較を実施した。

(方法) 可搬媒体 (CD) に記録した同一のテスト画像を 6 人の診療放射線技師で観察し、機種の違いが診断能に与える影響を ROC 解析により評価した。実験には、肺非結核性抗酸菌症の中でも比較的判定が容易な病変部分を抜き取り、それを正常画像に埋め込んだものを観察試料とした(病変有り 25 枚、なし 25 枚、解析ソフトは ROCKIT)。Fig. 3 に実験に使用したテスト画像の一部を示す。使用モニタは、通常読影で使用する GX220 とその真横に設置してある PC モニタであり、観察は照度 201x の読影環境で実施した。

(結果) Fig. 4 は、PC モニタと GX220 の ROC 曲線を示す。この結果、医療用モニタ GX220 は、肺野病変の検出において PC モニタに比較して明らかに高い検出能を示した (p<0.05)。



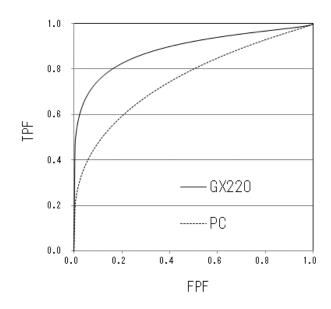


Fig. 3 病変を付加した観察画像例

Fig.4 モニタ検出能の違い

(結論) PC モニタでの肺野病変の読影は誤診の可能性が非常に高く使用は控えることが明確となった。

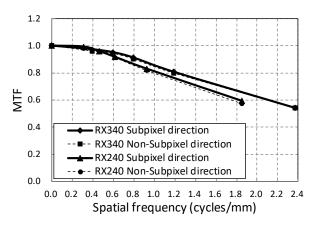
2.3 モニタの物理的評価: MTF と NPS を用いた評価事例

質問)2MPと3MPの医療用モニタではどれくらい検出能が異なるのか?

実験) 診断に用いるモニタ解像度の違いが画像診断に与える影響を検証するために2MPのモニタRX240 (EIZO) と3MPのモニタRX340 (EIZO) の空間周波数特性(以下、MTF: modulation transfer function) とノイズ特性(以下、NPS: noise power spectrum) を測定した[4]。

(方法) MTF は、十分小さな画素を持つデジタルカメラ (Nikon D100) でバーパターンを水平 (非サブピクセル方向) および垂直方向 (サブピクセル方向) で撮影し、波形再生による補間処理と周波数解析することで測定した。使用したバーパターンは 1、2、3、4、6 ピクセル幅のバーパターンが各 5 サイクルずつの 5 つのセグメントから構成される。 NPS は、同様にデジタルカメラを用いて一様な画面領域を撮影する。そのデータから水平および垂直方向に 1 次元ノイズプロファイルを解析し、得られた 1024 点のデータ点にハニング窓を適用し、フーリエ変換により NPS を測定した [5]。

(結果) Fig. 5 は、RX240 および RX340 の水平、垂直方向の MTF の測定結果を示す。水平、垂直方向共に RX340 に比較して RX240 の MTF は、明確に低下していた。Fig. 6 は、RX240 および RX340 の水平方向の NPS の測定結果を示す。水平方向の NPS は、低周波領域では RX340 が若干優れた値であったが高周波領域では ITを表に見られなかった。垂直方向の NPS は、水平方向と同等の結果であった。



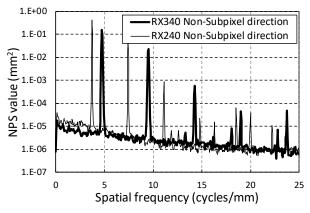


Fig. 5 モニタの MTF

Fig. 6 モニタの NPS

(結論) モニタの検出能の違いを評価する場合は、物理的特性を把握した上で主観的評価を行う必要がある。

3. おわりに

本稿において紹介した 3 例の評価事例のうち最初の 2 例は、画像工学の基本的な知識を利用した簡易的で誰でも実践可能なものである。しかしながら、簡易的な実験であっても臨床において大変有用な情報が多く含まれていると考えられる。実際、当院においてはこれらの実験結果を利用することで診断医と共に医療用モニタの選定や設置場所の決定を実施した経緯がある。今後、多くの仲間が画像評価に興味を持ちモニタに関する研究が活発になることを期待する。

(参考文献)

- [1] 新美孝永. 臨床現場から見たモノクロ医用画像表示用モニタRadiForce GX220の有用性. Rad Fan 7(4): 52-53, 2009
- [2] 新美孝永, 他. フィルムレス時代における診療放射線技師の役割: フィルムからモニタ管理へ. 日赤医学 59(2): 435-439, 2009
- [3] 新美孝永. 名古屋第二赤十字病院におけるモニタ品質管理の考え方とノウハウ. INNERVISION 23(12): 64-65, 2008
- [4] 市川勝弘, 他. バーパターンを用いた医用画像ビューアのMTF測定法, 日本写真学会誌 67(2):184-190, 2004
- [5] 市川勝弘. 医療用ディスプレイの画質評価および 超高解像度ディスプレイの開発. MEDICAL IMAGING TECHNOLOGY 30(5): 236-241, 2012

SNR, NEQ, DQE

東海大学医学部付属八王子病院 診療技術部 放射線技術科 由地良太郎

1.はじめに

一般撮影領域におけるディジタル化は CR が登場してから急速に進み、現在では CR から FPD への完全移行も進んできている。装置更新などにより検出器が変わる際、我々放射線技師が留意する点は線量と画質であり、装置の持つ能力や特徴の評価が重要である。医用 X 線画像の評価方法として検出量子効率 (detective quantum efficiency: DQE)や雑音等価量子数 (noise equivalent quanta: NEQ)の算出方法は国際電気標準会議 (International Electrotechnical Commission: IEC) から発表された IEC 62220-1 にも記載されており、近年では DR セミナーや論文により物理評価の方法や理論を学習しやすい環境である。そのため DQE は X 線撮影装置の評価項目として多くの施設で算出されており、近年では X 線検出部の評価として用いられる NEQ を算出している施設も多い。この 2 つの評価項目は信号雑音比(signal-to-noise ratio: SNR)や入力と出力のゆらぎの概念から導かれた尺度であり、本稿では数字だけが一人歩きしないよう意味も踏まえて理解が深まるよう述べていきたいと考える。

2.DQE,NEQ の定義

DQE は医用画像で広く用いられている雑音に対する信号の割合を表す SNR で定義され、入力と出力の SNR の二乗で定義される。また、NEQ は出力の SNR の二乗で定義されている。

$$DQE = \frac{(S/N)_{out}^2}{(S/N)_{in}^2} \quad NEQ = (S/N)_{out}^2$$

また、Fig. 1 に示すように画像システムを介して得られる SNR の二乗の比が DQE とも考えることもできる。定義にあるように DQE, NEQ を理解するには、まず SNR の理解が必要不可欠である。画像システムにおいては入力と出力があるが、まずはそれぞれを分けて述べていく。

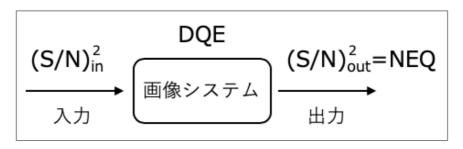


Fig.1 DQE,NEQ の定義の概念図

2-1.入力の SNR

放射線画像システムにおいて Fig. 1 の入力に当たるのは X 線フォトンそのものである。 X 線の発生は時間的にも空間的にもゆらぎがあり、ポアソン分布に従うと言われている。ポアソン分布とは二項分布の極限であり、確率が小さく、数が多い場合に起きる確率分布である。ポアソン分布は「単位時間(空間) あたりに平均 λ 回起こる現象が、単位時間(空間)に k 回起こる確率」を表すのに用いられ、以下の式で表せられる。

$$P(k) = \frac{\lambda^k e^{-k}}{k!}$$

ポアソン分布の特徴としては平均値(期待値)と分散が λ になることである。ここで SNR の概念に戻ると信号値は平均値、雑音は分散の平方根である標準偏差となるため SNR は $\sqrt{\lambda}$ となる。

$$S/N = \frac{\text{信号值}}{\text{標準偏差}} = \frac{\lambda}{\sqrt{\lambda}} = \sqrt{\lambda}$$

つまり、 λ が大きいほど SNR は大きくなるということになる。

放射線に置き換えて考えると、単位面積当たりにカウントされるフォトン数が q であった場合、その量子のゆらぎである分散は q となり、標準偏差は \sqrt{q} となる。SNR における信号値はフォトン数であり、雑音は分散の平方根である標準偏差であるため、SNR の二乗はフォトン数と同じになる。

$$(S/N)_{in}=rac{$$
入力の信号値 $}{$ 入力の標準偏差 $}=rac{q}{\sqrt{q}}=\sqrt{q}$ $(S/N)_{in}^2=q$

よって、入射してくる X 線すなわち入力の SNR の二乗はフォトン数と一致することがわかり、フォトン数が大きいほど SNR は大きくなり、雑音の割合は少なくなっていくため、良好な SNR を得るにはある程度のフォトン数が必要であることが理解できる。

2-2.出力の SNR

次に出力の SNR について述べる。放射線画像システムにおいて出力に当たるのは画素値であり、出力の SNR は入力時と同様に平均値と標準偏差の比で定義される。ここで注意すべき点として画素値は画像システムによりディジタル化された段階でフォトン数とは全く異なる数字となるため、のちのDQE を定義する上で問題が生じる。そのため、画素値をそのまま扱うのではなく、入出力特性を用いて露光量に変換する必要がある。

$$(S/N)_{out} =$$
出力の信号値
出力の標準偏差

$$\left(S/N
ight)_{out}^2 = \left(rac{$$
出力の信号値 $}{$ 出力の標準偏差 $}
ight)^2 = \left(rac{$ 露光量の平均値 $}{$ 露光量の標準偏差 $}
ight)^2$

ここで、出力である X 線画像のノイズ特性の評価で用いられている NNPS (normalized noise power spectrum) を考える。NNPS は「信号値を 1 に規格した場合のノイズゆらぎ成分の標準偏差の二乗値」で定義されるため信号値と雑音の関係式となっており、一様領域で変動する画素値を露光量に変換した値の平均値とその単位面積あたりのゆらぎである標準偏差を用いて、以下の式で求められる。

露光量の平均値を平均フォトン数とし、露光量の変動をフォトンの変動と仮定したノイズ特性の指標となる。ここで出力の SNR の二乗と比較を行うと NNPS の逆数になっていることがわかる。また、画像から求める NNPS は MTF (modulation transfer function)によって変調された画素値に基づいており、NNPS は二乗の単位を持つため出力の SNR の二乗は以下の式のように表せられる。ここ示す MTF はpresampled MTF を表し、システムの解像特性の評価として用いられている指標である。

$$(S/N)_{out}^2 = \frac{MTF^2}{NNPS}$$

2-3.DQE,NEQ

定義に戻ると DQE, NEQ は入力と出力の SNR の二乗で表されるため、以下の式になる。

$$DQE = \frac{MTF^2}{q \times NNPS}$$
 $NEQ = \frac{MTF^2}{NNPS}$

本来は空間周波数の関数として表されるが、今回は省略している。上記式で気をつけるべきはあくまで算出するための式であることである。MTFやNNPSを用いるため解像特性とノイズ特性を兼ね備えた評価指標と思いがちであるが、本来の定義としてはSNRの二乗値であり、入力と出力のゆらぎ

を表している。また、入力のゆらぎがフォトン数になることから NEQ が出力のフォトン数を表し、DQE がフォトン数の伝達特性と勘違いすることがある。DQE は入力と出力のゆらぎの比であり、SNR の概念で考えた場合これまでの式が成り立つということである。画像システムにおいてはフォトン数そのものが画素値となるわけではなく、検出効率やノイズ因子によって入力とは異なる結果となる。入力の SNR では雑音はポアソン分布から考えられる量子ノイズのみを考慮したが、画像システムを介するため量子ノイズ以外の付加ノイズが加わりノイズ量が変化する。そのため DQE はあくまで量子ノイズのみを考慮した場合に成り立つため、実際の画像システムにおいては様々なノイズが発生するため、このような簡単な式にはならないとことに注意が必要である。

2.DQE,NEQ の測定方法

DQE や NEQ を算出するためには、先に述べたフォトン数、入出力特性、NNPS、MTF が必要である。過去の専門講座で述べられているため、簡単に述べる。

2-1.幾何学的配置

DQE や NEQ を算出するための規格として、IEC から発表された IEC 62220-1 に推奨される測定方法が記載されている。しかし、これは主にメーカーや研究所に出されたものであり、ユーザーサイドでの測定では実験配置など困難な場合がある。特に水平垂直のアライメントが重要になるため注意が必要である。

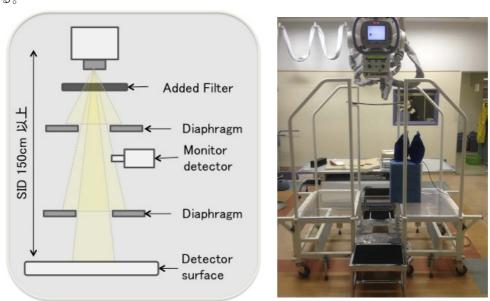


Fig.2 IEC62220-1 に記載されている幾何学的配置

3-1.フォトン数

DQE を算出する際に入力のゆらぎとしてフォトン数が必要であるが、画像システムによって X 線管の固有ろ過などが異なり、管電圧を同じにしても線質が異なる可能性がある。その場合 X 線スペクトルが異なりフォトン数を求めるのが困難になるため、IEC 62220-1 では線質を規定しており、

一般撮影領域で用いる4種類の線質に関しては単位面積単位線量あたりのフォトン数をテーブル化している(Table 1)。ここで注意すべき点は使用するX線管の管電圧は固定で、半価層が規定値になるように付加フィルタの厚みを増減させることである。付加フィルタに記載している厚みはあくまで参考値であり、X線管によっては異なることになる。この線質で入出力特性、MTF、NNPSを測定することでDQEを求める際、入力と出力のゆらぎを求めることが可能となる。

線質 (IEC61267規定)	管電圧[kV] (固定)	半価層[mm Al] (規定値)	付加フィルタ[mm Al] (増減させる)	フォトン数 [1/(mm²* μ Gy)]
RQA3	50	3.8	10.0	20673
RQA5	70	6.8	21.0	29653
RQA7	90	9.2	30.0	32490
RQA9	120	11.6	40.0	31007

Table1 IEC 62220-1 に規定された線質と単位面積単位線量あたりのフォトン数

3-2.入出力特性

物理評価の中で最も基本的であり、最も重要な項目である。検出部に到達した線量の相対値と出力画像のピクセル値の関係を示すものであり、線量と検出部の信号値(ピクセル値)との関係を確認するために必要である。これは後に説明する解像特性やノイズ特性を求める際にも必要であり、結果に影響するため重要である。ディジタルシステムにおける測定方法はタイムスケール法が主流である。入出力特性において注意すべき点はピクセル値についてである。一概にピクセル値といっても画像のデータ種によって値は異なってくる。臨床現場ではメーカーの協力を得ることが難しい病院もあり、画像データの取り出しには苦労する場合がある。現在ではメーカーによってはrawデータの取り出しが可能になるオプションもあるが、高価な場合が多い。そのため自施設における取り出し可能なデータがどんな種類であるのかを知ることが重要である。

3-3.MTF

一般的にディジタルシステムでは位置不変性が成り立たないため、実効サンプリング間隔を小さくすることで問題を回避し、A/D 変換前の解像特性を表した presampled MTF で評価されている。システムを介するとほぼすべての場合においてボケが生じるため、それに伴う応答特性をフーリエ変換等を用いて空間周波数領域で評価するものである。測定方法としてはスリット法、エッジ法、矩形波チャート法などがあり、それぞれ利点欠点が存在するため理解した上で測定する必要がある。

IEC 62220-1 においてはエッジ法が提案されているが、最も困難な事はどの方法も測定デバイスが必要であることであり、入出力特性の様に線量計があれば測定できるものではない。DQE や NEQ を求める際の注意点として MTF はなるべくノイズの影響を受けない状態での測定が必要であるため、高露光部のピクセル値がシステムの最高ディジタル値の約 50%~80%になるような線量で行う必要がある。そのため、NNPS を取得した画像の線量と異なることに注意が必要である。

3-4.NNPS

DR・CR におけるノイズ特性は単位面積当たりの入射 X 線量で正規化するため normaized NPS (NNPS) と表記されることが多い。システムの過程で様々なノイズやボケが生じるため、出力画像のピクセル値のゆらぎを評価したものである。測定方法は二次元フーリエ変換法が主流であり、IEC 62220-1 でも推奨されている。幾何学的配置は入出力特性と同様であり、線量計があればデータ取得可能である。ヒール効果の影響を受けやすいため撮影距離には注意が必要だが、入出力特性の画像データを用いることも可能である。DQE, NEQ の算出に関しては NNPS の測定時の照射線量によって結果が変わるため画像データだけでなく、線量の測定にも正確性が求められる。

4.おわりに

DQE と NEQ の定義に関してはこれまで多くの記事があるが、それぞれ 2 つの捉え方が存在する。ひとつは SNR という概念から算出式をもとに考えること、もうひとつはゆらぎとして考えること。この 2 つの捉え方は最終的には結果は同じになるが、 2 つを咀嚼することでより理解につながる。現在は物理評価ソフトやプログラムがあるため結果が先行して出てしまうことが多いため、意味を理解していなくても算出できる。そのため、結果が事実と異なっていても気付いていないケースが散見される。特に処理画像を用いた結果は本来の定義ではあり得ない数値が出ていることがある。相対値として出せばいいのではなく、その結果にはどのような因子が関わり結果として何を表しているのかを考察しなければ、誤った解釈を生む可能性があるため定義の意味を理解するのが必要だと考える。

藤田医科大学 医療科学部 放射線学科 寺本研究室の紹介

藤田医科大学 医療科学部 放射線学科 寺本 篤司

藤田医科大学

藤田医科大学は、1987 年4月に日本で初めて4年制の診療放射線技師養成校として開学し、今年度は33回生が入学しました。キャンパスは名古屋市緑区に隣接した愛知県豊明市にあります(私の居る研究室から数mで名古屋市です!)。総合大学ではありませんが、医学部・医療科学部・保健衛生学部といった大学群、大学病院、研究所などが同じ敷地内にあり、医療に関する学びをトータルでサポートできるようになっています。特に大学病院は単一の病院で国内最大の病床数を持ち、最新機器を利用した様々な疾患の診断治療が病院実習を通じて経験できるようになっています。また、教育病院は愛知県と三重県に合計3施設あり、2020 年4月には愛知県岡崎市に4つ目となる教育病院を開院予定です。

放射線学科には、約300名の学部生が在籍しており、教授6名、准教授7名、講師4名、助教3名、助手1名の21名の教員が学生の教育・研究の指導にあたっています。国家試験に十分対応できる学力を身に付け、医療現場で活躍できる人材を輩出するため、教員が一丸となって個々の学生の特性に合わせた教育指導を行っています。

大学院は修士課程と博士課程を設置しています。昼夜開講制となっており、そのまま内部から 進学する学生のほか、近隣の病院で勤務する社会人も受け入れています。現在修士課程は30名、 博士課程は3名が在籍しています。



図1 藤田医科大学豊明キャンパスの全景

寺本研究室

筆者は 2008 年 4 月に講師として就任し、研究室が与えられました。当初は 4 年生 2 名の配属でしたが、現在は 4 年生 9 名、大学院生 7 名、助手 1 名が在籍する、学科内で最大の研究室になりました。主な研究テーマは、特殊 CT 装置の開発とコンピュータ支援診断 (CAD) に関する研究となります。前者の CT 開発については、筆者が前職で開発していた高分解能のマイクロ CT を学内で製作し(図 2)、被曝低減や画質改善ならびに医療応用に関する研究を行っています。後者のCAD に関する研究については、筆者が学生時代(1990 年代)から人工知能(ニューラルネットワーク)やそれを利用した非線形画質改善フィルタの研究を行っていたこともあり、現在脚光を浴びているディープラーニングを CAD に応用する研究を 2014 年に着手しました。現在では医学部や近隣の病院と連携しながら研究室内で 25 テーマ以上の人工知能応用を進めています。ディープラーニングは演算量が膨大なため、GPU を搭載した高性能なマシンが必要になります。現在ディープラーニングの処理が可能な PC をトータル 16 台保有しており、学生は待ち時間なく処理ができるようになっています(図 3)。

研究対象として多いのは胸部疾患や乳腺疾患、頭部疾患の診断支援に関する研究ですが、救急や小児医療等に興味をもった学生も入ってくるため、学生の希望に合わせて対象部位やモダリティを決めるようにしています。そのため、新たに共同研究先を探すことや画像データの入手が必要なことが多いですが、研究テーマを学生が自分で決めて進めることはモチベーションを維持するためには重要だと考えています。

学生はテーマが決まり次第、先行研究の調査、新しい手法の開発、評価などを上級の大学院生や教員と進めていきます。週に1度のペースで行う研究室のゼミでは、各自の研究テーマに関する発表を行い、共同研究者や学生との活発なディスカッションが行われます。報告書には何回目の発表か分かるように通し番号を記させ、どれだけ精力的に研究を進めているか可視化できるようにしています。学生達はこのゼミを通じて研究遂行能力やプレゼンテーション能力を養います。また、画像研究で必要不可欠であり、かつ医療系学生にとって一番の難関となるものはプログラミングです。当研究室では初級のC言語やPythonのプログラミング演習を卒研配属初期に行い、画像処理や典型的なアルゴリズムを順に学び、個々の研究で必要な処理をプログラミングにより実現していきます。最近は良い画像処理ツールもたくさん出てきていますが、研究で使用する際には手作業が増えてしまう傾向にあります。学生には、単純な手作業が半日以上掛かるものはプログラミングで自動化するように指導しています。

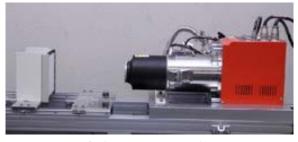


図2 実験用マイクロ CT 装置



図3 ディープラーニング用 PC

さいごに

今後、診療放射線技師に求められる能力は大きく変化していくと思います。当研究室では人工知能技術、画像処理技術に関する研究を通じて次世代の医療に対応できる人材を育成しており、他大学や病院からの大学院(修士・博士)への進学も歓迎しています。大学院の入試は9月と2月に行われます。修士課程の段階でRSNA等の国際学会発表や論文投稿が可能なレベルまで育成していますので、関心を持たれた方は下記の研究室ホームページを見て頂き、お問い合わせください。研究室スタッフ一同、お待ちしております。

寺本研究室ホームページ: http://www.fujita-hu.ac.jp/~teramoto/



図4 研究室のスタッフ一同

中高生対象メディカルサイエンス講座の紹介

広島国際大学 保健医療学部 診療放射線学科 山本 めぐみ

1. はじめに

2018年8月3日(金)に広島で中高生対象メディカルサイエンス講座が初めて開催され、今年度の2019年も第2回目の講座が東京にて開催されました。その講座について紹介いたします。

2. 講座の趣旨

現代の医療では、診療放射線技術が果たす診断や治療への役割は大きいです。しかし病院で放射線が使われている検査は一般に「レントゲン検査」の一言にまとめて表現され、診断や治療のために放射線技術がどのように使われているか、また診療放射線技師が高度な医療や技術に関する情報を医師に提供していること、日々の検査や治療と同じくらいに放射線装置の精度管理に努力を払っているか、多くの人にあまり知られていません。 その一方で国民の意識は病院で行われる放射線検査に対しての被ばくへの関心は高くなっており、医療被ばくの仕組みを知らないまま、なんとなく放射線検査に対して恐怖心を抱く人が少なくない状況です。日本放射線技術学会は、放射線技術学を専門に取りあつかう学術団体で、放射線技術に関する研究・調査や教育、知識の交換、学術の発展に寄与することを目的として活動を行っています。しかしながら、放射線技術学という学問は市民にはあまり知られておらず、放射線に対する恐怖心の方が心に残る場合が多い印象を受けます。そこで、画像部会では、次の世代で中心となって活躍する中学生・高校生を対象として、医療被ばくの仕組みについても正しい知識を持ってもらい、多くの病院で行われている「レントゲン検査」の内容を、医療画像に関係させながら、わかりやすく説明しました。また最近よく耳にする AI の技術を医用画像に活用した研究を紹介することで、放射線技術学に対する関心を高めることを目的としました。

3. 講座の内容

画像部会では 2018 年のテーマを、「医療画像の世界、もっと知りたい!」、2019 年度を「医療画像が人体を解剖する!」と設定しました。表 1 は講座のプログラムです。13:00 から 16:00 までの 4 時間に渡り、6 つの講義と体験講座を行いました。前半の 3 つは放射線と医療がどのように関係しているかという内容で、後半 3 つは医療画像に関する研究について(最近話題の AI を含む)の内容でした。また、体験講座は実際に超音波や画像処理装置一式、乳がんファントム、サーベイメータを中高生の皆様に実際に触って体験して、放射線と医療を身近に感じて頂く構成で行いました。

表1 プログラム

講義

- 1) レントゲン写真の昔と今 (柳田委員)
- 2) X 線検査って、どれくらい被ばくするの? (篠原現部会長)
- 3) 様々な X 線検査と医療画像の関係は? (東出委員)
- 4) 医療画像に関する研究ってどんなこと? (小野寺委員)
- 5) コンピュータで何かできるか? (熊大:内山先生)
- 6) 医療画像の未来予想図 (白石代表理事)

体験講座

- ・超音波画像で見えない物をみてみよう!
- ・最新の医療画像処理はすごい!
- ・乳がんを触ってみよう!
- サーベイメータを使ってみよう!
- ・プログラミングを体験してみよう(2018年度のみ)



図1 講義風景

トップバッターの柳田委員がこの日のため に磨き上げた話術とお NEW のケーシー(黒 色)で「レントゲン写真の昔と今」を講義し、 参加者の興味を惹きつけている様子。



図2 超音波体験の様子

果物入り食用ゼリーをフィルムで包み、ポータブル超音波装置を使って参加者にゼリーの果物を当ててもらい、身体の構造と原理関連付けて説明する篠原部会長と小野寺委員。ゼリーの一つに「びわ」を選ぶセンスが洗練されており輝いていました。



図3 サーベイメータで測定している様子

袋や筆箱などの中に、放射線源のマントルを 隠し、実際にサーベイメータを使ってどこに 線源があるか探している様子。参加者にアド バイスしながら見守る東出委員。



図4 プログラミング体験

白石代表理事が前でレクチャーし、参加者が 初めての画像処理プログラミングに熱中し ている風景。プログラムが動いた時は感動の 声があがりました。

この講座を開催して、多くの参加者から、「とてもよい講座なので続けて欲しい!」、「実際に体験できてよかった!」という声がありました。しかし実際には、この講座が開かれるという情報が学生さんや親御さんまで届いていないということがわかりました。どのように中高生の皆様にこの開催を知って頂くかという課題が見つかりました。学生さんに開催の情報を伝える事の難しさを関係者一同体験しました。この2年の参加者によるアンケートでは、「また参加したい」や「次は多くの知り合いに声をかける!」と好評な意見がほとんどでした。今後、参加者のからのロコミなどにより、この講座の認知度が高まっていくことを願います。

4. 最後に

広報委員の隅田先生、岩永先生、東京支部会の方々にこの講座のために多くの中学高や高校にお知らせを出して頂き、また学校訪問もして頂きました。また、後援として(株)AZE、(株)千代田テクノル、(株)富士メディカル、(株)GE ヘルスケアジャパンの方々に機材の提供をして頂きました。この場をお借りしてお礼申しあげます。(写真提供:田中委員)



国際会議参加報告書 CARS2019

熊本大学 保健学教育部 1年 和田 菜摘美

今回, 私は初めて国際学会に参加しました. 私が参加した学会は, フランス・レンヌで開かれた Computer Assisted Radiology and Surgery (CARS) 2019 です. CARS では, CAS (Computer Aided Surgery), CAR (Computer Assisted Radiology), CAD (Computer Aided Diagnosis), PACS (Picture Archiving and Communication Systems) など, コンピュータを用いた様々な分野に関する研究発表が行われていました. また, 同会場内にて医療機器メーカーの企業展示も行われていました. 今年は 2019 年 6 月 18 日 (火)から 2019 年 6 月 21 日 (金)まで, 4 日間開催されました. 37 か国以上からの応募があったそうです. 会場には日本人の参加者も多くいました.

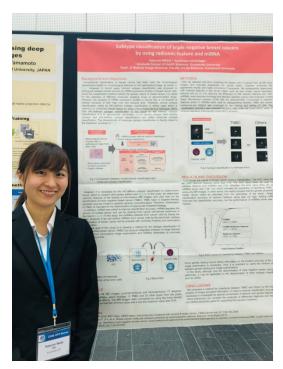
私は「Subtype classification of triple negative breast cancers by using radiomic feature and miRNA」という題目で,CAD のセッションでポスター発表を行いました.内容は,MR 画像から得られる Radiomics 特徴量と遺伝子情報である miRNA を組み合わせて,乳がんのサブタイプ分類を行うというものです.私は英語で発表するのは初めてでしたので,大学の研究室で練習していた時とは違い,不安と緊張でいっぱいでした.しかし緊張感が漂いつつも,リラックスした雰囲気があり発表しやすい場であったと思います.ポスター発表で聴講者との距離が近かったこともあり,私の発表に対し,さまざまな国の参加者の方から質問や感想を直に頂くことができました.専門分野で活躍されている先生から面白いとコメント頂いたことはすごくうれしく,これからの研究での活力になると思います.質疑応答では,自分でも思っていた課題点を指摘されたり,自分では思わなかったアプローチの仕方や解決策を提案していただいたりと,これからの研究につながる大変有意義な時間であったと思います.

私は自分の研究分野である CAD や Radiomics 特徴量に関連する発表に重点を置いて聴講しました. 特に気になったのが、私の研究と同じく乳がんを対象として超音波画像を用いて腫瘤を検出する R. F. Chang 先生の「Tumor detection for automated breast ultrasound using 3-D convolutional neural network」と、Radiomics 特徴量を用いて心臓画像から脳腫瘍を予測する M. Masias Bruns 先生の「Can one predict brain disease based on cardiac imaging data? A proof-of-concept study」です。発想、そしてそれを行う方法が面白く参考になりました。これからは、乳がん関連、Radiomics 関連の研究はもちろん、ほかの分野にも目を向けていきたいと思います。

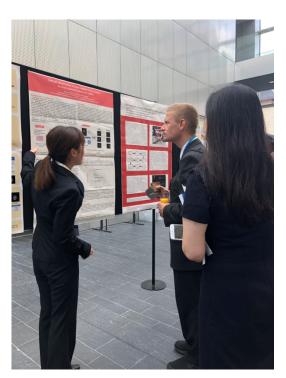
今回の経験を通して、自分の未熟さを知ることができました.特に質疑応答の際の英語で会話する能力不足や、自分の研究分野に対する知識不足などを痛感することができました.今後また機会があるときには、自分の思っていることをしっかり相手に伝わるように、どちらの能力も向上しておく必要があると感じました.会場には各専門分野で活躍されている先生方から、自分と同世代の学生まで多くの研究者がいました.そこで自分自身の研究内容を知ってもらい、意見を交えることができたことは私にとってすごく貴重な経験であったと思っています.今後も、自分の研究内容がどのように社会に貢献できるのか、どうすればより良い研究ができるのかなど、しっかりと考えながら研究を進めていきたいと思います.そして

これからも、積極的に学会に参加していきたいです.

最後になりましたが、CARS2019 への参加をサポートしてくださった熊本大学 内山良一先生に深く感謝申し上げます。今回の学会参加はすごく勉強になる機会であったと思っています。これからもこの経験を自分の糧にして頑張っていきたいと思います。



発表ポスターの前にて



発表中の様子

CARS 参加報告

帝京大学大学院 保健学研究科 診療放射線科学専攻 博士前期課程 2年 村上 理映

1. はじめに

2019 年 6 月 18 日から 4 日間、フランスのレンヌで Computer Assisted Radiology and Surgery (CARS) 2019 が開催されました。本学会に参加し、口述発表を行いましたので報告いたします。

2. CARS2019

CARS2019 では、Computer Assisted Radiology and Surgery (CARS) の括りの中で、Computer Assisted Radiology (CAR)、International Society for Computer Aided Surgery (ISCAS)、Computer-Aided Diagnosis and Artificial Intelligence (CAD-AI)、Computed Maxillofacial Imaging Congress (CMI) の分野で研究発表が行われ、160 題の口述発表および107 題のポスター発表がありました。また、メーカーによる医療機器の展示もあり、Intuitive Surgical 社の内視鏡下手術支援ロボット da Vinci の操作を体験することが出来ました。

3. 発表内容

胸部単純画像における高線量画像から低線量画像のシミュレーション技術の開発について発表しました。X線画像検査において、被ばく線量低減は重要な課題ですが、診断に有用な画質と線量の関係を評価する必要があります。そこで、低線量で取得した画像を評価する必要がありますが、画質評価のために追加被ばくを伴う低線量画像の取得は倫理的に受け入れられないため、シミュレーションによって低線量画像を取得する方法を提案しました。本手法は、標準線量で撮影した1枚の画像から、撮像システムの物理特性である入出力特性曲線、Dose-SD曲線、各線量のNPSを用いて任意の低線量画像を取得する手法です。本手法を用いて、1/2、1/4 および1/8 線量における被写体無し画像と胸部ファントム画像をシミュレーションした結果、被写体無し画像はSDの相対誤差5%、胸部ファントム画像はノイズSDの相対誤差3%以下でした。胸部ファントム画像は、同一条件の画像を2枚取得し、差分することでバックグランドを除去したノイズ画像を作り、SDの比較を行いました。本手法では、簡便かつ高精度に低線量画像を作成することが出来るため、低線量画像の診断価値の評価に利用可能であると考えられます。アーチファクトや画像処理による影響や本手法の今後の展開についての質問を頂きました。

4. 最後に

初めての海外での口述発表に加え、様々な研究者の方々とお話することができ、全てが初体験の連続で 刺激的な4日間でした。また、学会会場の周辺は、木組みと石作りの建造物が色とりどりに立ち並び、今 まで見たことのない美しい街でした(図 2)。国際学会を通して、その国の風景や文化、歴史にも触れる ことができ貴重な経験をさせて頂きました。



図1. 発表の様子



図 2. 会場周辺

画像部会委員に就任して

藤田医科大学 医療科学部 放射線学科 寺本 篤司

今年度より画像部会委員会を担当させて頂くことになりました藤田医科大学の寺本篤司です. 私は工学部で電気・電子・情報に関して学び、一般企業で10年ほど X 線を用いた非破壊検査技術に関する製品開発に携わった後、2008年に藤田医科大学に就任いたしました。現在は診療放射線技師を目指す学生を対象に電子工学、放射線画像工学、画像情報学、機器工学等の講義を担当しています。研究は、新しい CT イメージング技術とコンピュータ支援診断技術の開発を行っており、最近は人工知能を用いた医用画像処理に注力しています。

人工知能技術や診断・治療技術の著しい進歩にともない、診療放射線技師を取り巻く環境は大きく変化していくと思います。その変化は決して悲観的なものではなく、画像に関する知識が豊富な放射線技師がさらに広く活躍できるチャンスだと考えています。私は工学の立場から、放射線技術学会の会員の皆様と一緒に、この変化を楽しみながら学会を盛り上げていきたいと考えております。ご指導のほどよろしくお願いいたします。

画像部会委員に就任して

立命館大学 理工学部 中山 良平

今年度より、画像部会委員を担当させていただくことになりました立命館大学の中山良平です. 画像部会長の篠原先生をはじめ、部会委員の先生方のご指導をいただきながら、少しでも会員の皆様のお役に立てるように務めて参りたいと存じます.

私は博士取得後,三重大学医学部附属病院 中央放射線部で 10 年間助教 (1 年間,シカゴ大学 放射線科 客員助教) として,医用画像処理/解析の研究に従事してまいりました。私のような 工学系出身の人間にとって,三重大学勤務時代は,臨床現場での問題を目の当たりにすること ができ,医師,診療放射線技師の方々と相談しながら研究を進めることが出来る非常にありが たい環境でした。また,2009 年以降,客員教員を担当させていただいている鈴鹿医療科学大学 東京サテライト校では,診療放射線技師の方々とのディスカッションが,お互いに研究テーマ の発見や研究の推進につながっています。これらの経験から,現場で活躍されている医師や診療放射線技師の方々と工学系の人間がディスカッションしながら研究を進めることの必要性を いつも痛感しております。

現在,深層学習(deep learning)により,医療が大きく変革しようとしています.画像部会委員として私に与えられた任務は,様々なセミナー,そしてセミナー後の意見交換会を通して,新しい工学技術を会員の皆さまに分かり易くお伝えしていくことだと考えております.そして,そこで得た知識を皆さまの研究,業務に生かしていただければ幸いです.

どうぞよろしくお願いいたします.

画像部会委員に就任して

東海大学医学部付属八王子病院 診療技術部 放射線技術科 由地 良太郎

本年度より、画像部会の委員を務めさせていただきます東海大学医学部付属八王子病院の由 地良太郎です.歴史のある画像部会の委員ということで大きなプレシャーを感じておりますが、 諸先輩方の指導を仰ぎながら、私に与えられた責務を果たしていきたいと思っております。

私は大学卒業後大学病院に就職しましたが、当時は CR から FPD への移行時期であり、新人の時からアナログを経験することができませんでした。そのため撮影条件に曖昧な部分があり、評価項目や評価方法についても知識がありませんでした。そこで客観的評価が可能な物理特性を学んでみようということで、2007 年 6 月に岡山で開催されたディジタル画像評価セミナーに(現;DR セミナー)参加し、画像の世界に足を踏み入れました。このセミナーのおかげで画像に興味を持つことができ、多くの先生や諸先輩方と繋がることができたことが今日の私を形成したと言えます。本年度からは逆の立場になりますが、紙面には載っていない苦労や疑問を共有し、12 年前に私がしていただいたモチベーションを上げることが私に課せられた使命であり、お世話になった方々への恩返しになると考えています。私自身も勉強させていただき、皆様と切磋琢磨しながら現場に返せる知識を共有できるように精進していきたいと思いますので、今後とも何卒よろしくお願い申し上げます。

画像部会「研究情報サイト」のご案内

岐阜大学教育学部技術教育講座 福岡 大輔

1. はじめに

画像部会の部会ホームページでは、これまでに本誌「画像通信」において紹介されたトピックスや、各種医用画像データベースに関する情報、プログラミングに関する情報などを集約し情報提供を行う「研究情報サイト(http://imgcom.jsrt.or.jp/research/)」を2017年11月に開設いたしました(図1).

研究情報サイトは、画像研究に携わる研究者や、研究を始めてみようと考える初学者の、情報提供や情報 交換の場となることをめざしています.

2. 研究情報サイトの概要

研究情報サイトでは,図2のように画像研究に役立 つ情報として,本稿の執筆時点では,以下の3つのテ ーマについて情報提供を行っています.

(1) 医用画像データベースに関する情報

近年話題の深層学習をはじめとする画像研究においては、多くの画像から共通する特徴を抽出することによって成り立っており、画像データベースの必要性が高まっている。しかしながら、CAD(Computer-aided Diagnosis)システムの開発や性能評価の研究においては、研究に用いる医用画像データの収集や、付随する所見データの入手は、倫理上や個人情報の観点からも近年では難しくなっている。そこで、研究情報サイトでは、国内外の大学や政府機関、各種学会など公的な機関が公開するデータベースを紹介している。

例えば、胸部 X 線画像においては、日本放射線技術 学会標準ディジタル画像データベースをはじめ、NIH



図 1 画像部会 HP の「研究情報サイト」



図2「研究情報サイト」の掲載情報

Clinical Center の Ronald M. Summers 氏らの ChestX-ray8 データベースなどを紹介している. ChestX-ray8 データベースにおいては、症例数が患者数 30,000 で画像数も 100,000 画像と非常に豊富であるため、深層学習を用いた画像研究に有用なデータベースとなっている. また、画像通信 40(1)「Radiomics に関係した文献とデータベース等の紹介」において紹介された Radiomics 研究用のデータベースとして、The Cancer Imaging Archive (TCIA)の医用画像と遺伝子の情報セット (The Cancer Genome Atlas (TCGA))を研究情報サイト上で紹介している.

(2) プログラミングに関する情報

画像処理プログラミングに関する情報として、画像通信 35(2)に紹介された GUI (Graphical User Interface) による画像処理ソフトウェア開発の基本となる「C#プログラミングによる画像表示ソフトの作成(超初心者編)」のソースコード一式や、画像通信 35(2)において紹介されている OpenCV (Open source Computer Vision library)、画像通信 32(1)「CAD のための統計解析の資料」に紹介されている統計解析ソフトR (The R Project for Statistical Computing) を掲載している。また、医用画像を取り扱う上で必要となる DICOM フォーマットに関する情報として、ソフトウェア開発に有益な DCMTK(Dicom ToolKit)に関する情報と、日本画像医療システム工業会(JIRA)が公開している DICOM 規格書(日本語版)へのリンクを紹介している。

(3) 論文作成(文献検索など)に関する情報

画像通信 31(2)「論文作成に役立つサイトやソフト,書籍の紹介」において紹介された米国立医学図書館内の NCBJ がインターネット上で提供している生命科学分野の文献検索システム PubMed や, Google Scholar について掲載している.

3. 今後の活用と情報提供のお願い

「研究情報サイト」は、本誌「画像通信」の誌面に掲載される記事を、インターネット上のディジタルコンテンツとして補足する機能を担い、誌面上では提供できないソフトウェアの配布や、ソースコードなどの提供など、画像研究に役立つ情報を幅広く配信してゆきたいと考えています。また、医用画像データベースに関する情報など、医用画像に関する研究者の情報共有・提供の場として今後活用してゆきたいと考えています。

現在,サイト上に掲載されている掲載内容のほかにも有益な情報がありましたら,「研究情報サイト」 のページ下部にあるコメント欄に情報をお寄せください.

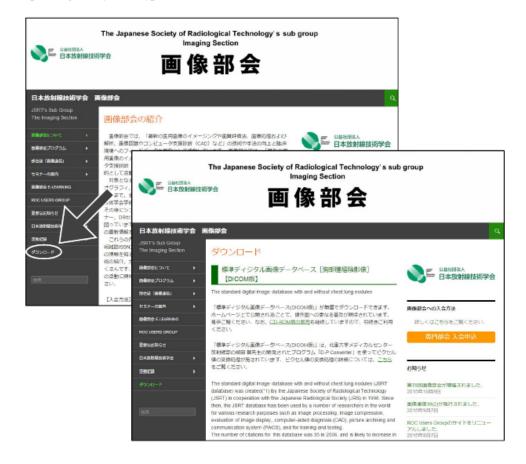
標準ディジタル画像データベース(胸部腫瘤陰影像) DICOM バージョンの配布開始について

1998年1月に配布を開始し、2008年3月からは、日本放射線技術学会のホームページから無償でダウンロード入手が可能となり、多くの研究者に利用されてきました「標準ディジタル画像データベース(胸部腫瘤陰影像)」ですが、収録されている画像のフォーマットが Raw データフォーマットであるため、通常の処理では画像を表示することができない、または、特定のソフトウエアや自作のプログラムでしか処理ができない、問題点がありました。今回、北里大学メディカルセンター放射線部の柳田 智先生のご尽力により、この画像データベースの DICOM バージョンが作成され、画像部会の HP から無償で部会員の皆様に提供できるようになりましたので、お知らせします。

この標準ディジタル画像データベースは、1995年4月より約3年の歳月をかけて、本学会学術委員会の学術調査研究班が、日本医学放射線学会の協賛により、日本および米国の医療施設からの症例提供の協力を受けて完成させたものです。配布開始から10年以上経過した現在でも、このように多くの腫癌陰影像を含む胸部単純X線像のデータベースは世界でも唯一のもので、コンビュータ支援診断(CAD)の研究やディジタノレ画像の評価など、に、世界中の研究施設で利用されています。今後もコンピュータ・プログラミングの学習や、ディジタル画像処理、CAD研究の素材として、より多くの方々に活用していただきたいと願っています。ぜひ、多くの研究にご利用ください。

【標準ディジタル画像データベース[胸部腫瘤陰影像] DICOM版 ダウンロード入手先】

URL: http://imgcom.jsrt.or.jp/download/ (画像部会 HP → ダウンロード)



【内容および仕様】 腫瘤陰影像 154 画像, 非腫癌陰影像 93 画像1 画像容量約 8MB, Dicom データ, 2048 x 2048 マトリクス,

0.175mm ピクセルサイズ, 4096(l2bit)グレイスケール

【参考文献】

1) Shiraishi J, Katsuragawa S, lkezoe J, Matsumoto T, Kobayashi T, Komatsu K, Matsui M, Fujita H, Kodera Y, Doi K: Development of a digital image database for chest radiographs with and without a lung nodule: Receiver operating characteristic analysis of radiologists' detection of pulmonary nodules. A jR 174:71-74, 2000.

【標準ディジタル画像データベースを用いた、または関連した研究】

- 1. 引用文献の概要(全 174 編, Scopus 調べ, 2016 年 1 月現在) Academic Radiology:6 AJR(American Journal of Roentgenology): 4, EJR: 4, IEEE Trand. Med. Img: 7, J Dig Img:4 Medical Image Analysis: 4, Medical Physics: 7, Radiology: 4, その他海外論文:17, その他国内論文: 2, Proceedings: 38
- 2. 主な海外論文
- 1) Li Q, Katsuragawa S, Doi K: Improved contralateral subtraction images by use of elastic matching technique. Medical Physics, 27: 1934-42, 2000
- 2) van Ginneken B, Ter Haar Romeny BM, Viergever MA: Computer-aided diagnosis in chest radiography: A survey. IEEE Transactions on Medical Imaging, 20: 1228-41, 2001
- 3) Baydush AH, Catarious Jr DM, Lo JY, et al.: Computerized classification of suspicious regions in chest radiographs using subregion Hotelling observers. Medical Physics, 28: 2403-09, 2001
- 4) Li Q, Katsuragawa S, Doi K: Computer-aided diagnostic scheme for lung nodule detection in digital chest radiographs by use of a multiple-template matching technique. Medical Physics, 28: 2070-76, 2001
- 5) Arimura H, Katsuragawa S, Li Q, Ishida T, Doi K: Development of a computerized method for identifying the posteroanterior and lateral views of chest radiographs by use of a template matching technique. Medical Physics, 29: 1556-61, 2002
- 6) Tsukuda S, Heshiki A., Katsuragawa S,et al.: Detection of lung nodules on digital chest radiographs: Potential usefulness of a new contralateral subtraction technique. Radiology, 223: 199-203, 2002
- Shiraishi J, Abe H, Engelmann R, Doi K: Effect of High Sensitivity in a Computerized Scheme for Detecting Extremely Subtle Solitary Pulmonary Nodules in Chest Radiographs: Observer Performance Study. Academic Radiology, 10: 1302-11, 2003
- 8) Rapp-Bernhardt U, Roehl FW, Gibbs RC, et al.: Flat-panel X-ray detector based on amorphous silicon versus asymmetric screen-film system: Phantom study of dose reduction and depiction of simulated findings. Radiology, 227: 484-492, 2003
- 9) Kakeda S, Moriya J, Sato H, et al.: Improved Detection of Lung Nodules on Chest Radiographs Using a Commercial Computer-Aided Diagnosis System. AJR, 182: 505-510, 2004
- Suzuki, K, Shiraishi, J, Abe H, et al.: False-positive reduction in computer-aided diagnostic scheme for detecting nodules in chest radiographs by means of massive training artificial neural network. Academic Radiology, 12: 191-201, 2005
- 11) Shiraishi J, Abe H, Li F,et al.: Computer-aided Diagnosis for the Detection and Classification of Lung Cancers on Chest Radiographs. ROC Analysis of Radiologists' Performance. Academic Radiology, 13: 995-1003, 2006

- 12) Usami H Ikeda M, Ishigakil T, Fukushima H, Shimamoto K: The influence of liquid crystal display (LCD) monitors on observer performance for the detection of nodular lesions on chest radiographs. European Radiology, 16: 726-732, 2006
- 13) Campadelli P, Casiraghi E, Artioli D: A fully automated method for lung nodule detection from posteroanterior chest radiographs. IEEE Transactions on Medical Imaging, 25: 1588-1603, 2006
- 14) Loog M, Van Ginneken B: Segmentation of the posterior ribs in chest radiographs using iterated contextual pixel classification. IEEE Transactions on Medical Imaging, 25: 602-611, 2006
- 15) Shiraishi J, Li Q, Suzuki K,et al.: Computer-aided diagnostic scheme for the detection of lung nodules on chest radiographs: Localized search method based on anatomical classification. Medical Physics, 33: 2642-2653, 2006
- 16) Pesce LL, Metz CE: Reliable and Computationally Efficient Maximum-Likelihood Estimation of "Proper" Binormal ROC Curves. Academic Radiology, 14: 814-829, 2007
- 17) Shi Y, Qi F, Xue Z.,et al.: Segmenting lung fields in serial chest radiographs using both population-based and patient-specific shape statistics. IEEE Transactions on Medical Imaging, 27: 481-494, 2008
- 18) Bessho Y, Yamaguchi M, Fujita H., Azuma M: Usefulness of Reduced Image Display Size in Softcopy Reading. Evaluation of Lung Nodules in Chest Screening. Academic Radiology, 16: 940-946, 2009
- 19) Aoki T, Oda N, Yamashita Y, Yamamoto K, Korogi Y: Usefulness of Computerized Method for Lung Nodule Detection in Digital Chest Radiographs Using Temporal Subtraction Images. Academic Radiology, 18: 1000-1005, 2011
- 20) Armato III SG, McLennan G, Bidaut L, et al.: The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): A completed reference database of lung nodules on CT scans.

このデータベースの問い合わせ先; 白石順二(熊本大学) j2s@kumamoto-u.ac.jp

画像部会入会のご案内

医療には、X 線画像、CT、MRI、US、核医学画像、そして放射線治療用画像など、様々な画像が利用されています。画像部会は、これら全ての画像を対象とし、そのイメージング技術、画像評価、画像処理・解析、コンピュータ支援診断 (CAD) に関する新しい知識や技術の習得を目的とした活動を行っています。よって、診断、治療、核医学などの専門領域を問わず、多くの学会員の皆さまに入会し、参加して頂くことができます。

春と秋に開催される学術大会においては、話題性が高く学術的価値の高い教育講演とシンポジウムを開催しています。このシンポジウムでは、企画されたテーマの第一線の研究者らに問題提起や話題提供をして頂いた上で、会員の皆さんを交えた討論を行い、新しい知識や技術の有用性や問題点を共有しています。その他、地方部会の協力を得ながら、医用画像処理プログラミングセミナー、DR セミナー、ROC セミナーおよび臨床画像評価セミナーを年に 5 回程度開催して、必要な基本知識と技術の普及を図っています。こういった活動を通して、会員の皆さんが画像研究の新しい風を肌で感じたり、学術レベルの向上や技術の臨床への還元をして頂けるようになります。また、活動案内や情報は、学術大会前にお届けしている画像部会雑誌「画像通信」(学術雑誌 ISSN コード付)に掲載しています。学術雑誌である「画像通信」には、教育講演やシンポジウムの内容、注目されている技術の紹介、専門家による文献紹介、日本各地の研究室や研究会の紹介、国際会議出席者の体験記など、参考になる記事が多数掲載されており、画像に興味を持つ会員にとって非常に魅力的な専門雑誌となっています。画像部会に入会することにより、毎年 2 回開催されている学術大会の前に画像通信の閲覧が可能になり、事前に画像部会の講演内容を学んだり、活動計画に関する最新情報を得たりすることができるようになります。また、セミナー参加費にも割引特典があります。

画像部会は医療で広く利用されている画像に関する理解を深め、医療の進歩に寄与したいと考えている方に入会して頂き、共に学んでいきたいと思っています。また、すでに会員の方も、是非画像にこだわりを持つ周辺の方々に声をかけて入会を促して頂けるようお願いします。

[入会資格] 日本放射線技術学会の会員 であること.

[入会方法] Web 上 (https://www.jsrt.or.jp/data/procedure/bunka-01/) から, お申し込み下さい.

[年会費と会員特典について]

1. 専門部会の会員登録システムと年会費の変更について

現在,登録されている各専門部会について,それぞれ年会費2,000円ですが,2015年度より,複数の専門部会に登録される場合,1つの専門部会分だけ年会費2,000円とし,それ以外は1,000円としま

す. 例えば、画像部会、撮影部会、計測部会の 3 つに登録する場合、これまでは 2,000 円 \times 3=6,000 円でしたが、2015 度より 2,000 円+1,000 円 \times 2=4,000 円となります。なお、複数登録された専門部会に順位はなく、同等の特典を得ることができます。また、シニア会員および学生会員については現行と同じで、1 つの専門部会につき年会費 1,000 円となります。

2. 専門部会誌の電子化について

現在,専門部会員の皆様に冊子体で届けている専門部会誌を,2015年3月発刊分より全面的に電子化します。電子化により印刷製本費や郵送費が軽減できますので,専門部会活動の充実に充てたいと考えています。なお,電子版の閲覧方法については,追ってお知らせします。

3. 専門部会員の特典について

(1) セミナーおよび講習会への参加費の割引

2015 年度より、登録されている専門部会が開催するセミナーや講習会の参加費を割引します. 割引額および対象となるセミナーや講習会は各専門部会で決定されますが、基本的には会員(該当する専門部会員でない正会員)参加費から 2,000 円程度の割引となります。ただし、他団体との共催分については割引は適用されません.

(2) 専門部会誌の優先閲覧

専門部会員の方は、春(4月)と秋(10月)に専門部会誌が出版されると同時に、登録されている専門部会の部会誌(電子版)が閲覧できます。なお、出版後3ヶ月を経過した後には、すべての正会員・学生会員について、すべての専門部会誌(電子版)が閲覧できます。

画像部会入会のご案内

医療には、X 線画像、CT、MRI、US、核医学画像、そして放射線治療用画像など、様々な画像が利用されています。画像部会は、これら全ての画像を対象とし、そのイメージング技術、画像評価、画像処理・解析、コンピュータ支援診断 (CAD) に関する新しい知識や技術の習得を目的とした活動を行っています。よって、診断、治療、核医学などの専門領域を問わず、多くの学会員の皆さまに入会し、参加して頂くことができます。

春と秋に開催される学術大会においては、話題性が高く学術的価値の高い教育講演とシンポジウムを開催しています。このシンポジウムでは、企画されたテーマの第一線の研究者らに問題提起や話題提供をして頂いた上で、会員の皆さんを交えた討論を行い、新しい知識や技術の有用性や問題点を共有しています。その他、地方部会の協力を得ながら、医用画像処理プログラミングセミナー、DR セミナー、ROC セミナーおよび臨床画像評価セミナーを年に 5 回程度開催して、必要な基本知識と技術の普及を図っています。こういった活動を通して、会員の皆さんが画像研究の新しい風を肌で感じたり、学術レベルの向上や技術の臨床への還元をして頂けるようになります。また、活動案内や情報は、学術大会前にお届けしている画像部会雑誌「画像通信」(学術雑誌 ISSN コード付)に掲載しています。学術雑誌である「画像通信」には、教育講演やシンポジウムの内容、注目されている技術の紹介、専門家による文献紹介、日本各地の研究室や研究会の紹介、国際会議出席者の体験記など、参考になる記事が多数掲載されており、画像に興味を持つ会員にとって非常に魅力的な専門雑誌となっています。画像部会に入会することにより、毎年 2 回開催されている学術大会の前に画像通信の閲覧が可能になり、事前に画像部会の講演内容を学んだり、活動計画に関する最新情報を得たりすることができるようになります。また、セミナー参加費にも割引特典があります。

画像部会は医療で広く利用されている画像に関する理解を深め、医療の進歩に寄与したいと考えている方に入会して頂き、共に学んでいきたいと思っています。また、すでに会員の方も、是非画像にこだわりを持つ周辺の方々に声をかけて入会を促して頂けるようお願いします。

[入会資格] 日本放射線技術学会の会員であること.

[入会方法] Web 上 (https://www.jsrt.or.jp/data/procedure/bunka-01/) から, お申し込み下さい.

[年会費と会員特典について]

1. 専門部会の会員登録システムと年会費の変更について

現在,登録されている各専門部会について,それぞれ年会費2,000円ですが,2015年度より,複数の専門部会に登録される場合,1つの専門部会分だけ年会費2,000円とし,それ以外は1,000円としま

す. 例えば、画像部会、撮影部会、計測部会の 3 つに登録する場合、これまでは 2,000 円 \times 3=6,000 円でしたが、2015 度より 2,000 円+1,000 円 \times 2=4,000 円となります。なお、複数登録された専門部会に順位はなく、同等の特典を得ることができます。また、シニア会員および学生会員については現行と同じで、1 つの専門部会につき年会費 1,000 円となります。

2. 専門部会誌の電子化について

現在,専門部会員の皆様に冊子体で届けている専門部会誌を,2015年3月発刊分より全面的に電子化します.電子化により印刷製本費や郵送費が軽減できますので,専門部会活動の充実に充てたいと考えています.なお,電子版の閲覧方法については,追ってお知らせします.

3. 専門部会員の特典について

(1) セミナーおよび講習会への参加費の割引

2015 年度より、登録されている専門部会が開催するセミナーや講習会の参加費を割引します. 割引額および対象となるセミナーや講習会は各専門部会で決定されますが、基本的には会員(該当する専門部会員でない正会員)参加費から 2,000 円程度の割引となります。ただし、他団体との共催分については割引は適用されません.

(2) 専門部会誌の優先閲覧

専門部会員の方は、春(4月)と秋(10月)に専門部会誌が出版されると同時に、登録されている専門部会の部会誌(電子版)が閲覧できます。なお、出版後3ヶ月を経過した後には、すべての正会員・学生会員について、すべての専門部会誌(電子版)が閲覧できます。