

Communication of the Imaging Group of the JSRT

画像通信

2020年4月

Vol.43 No.1(通巻 84)

☆ 第 87 回画像部会 『深層学習を放射線技術研究に利用する』

Educational Lecture

「AI 時代において医療画像診断チームの担う役割」

東北大学大学院 植田 琢也

Intellectual Discussion

1. 「深層学習を用いた医用画像上の病変分類」
2. 「物体検出技術について」
3. 「推定する」
4. 「医療 AI を作る(超解像と画像生成)」

立命館大学理工学部 檜作 彰良
 藤田医科大学大学院 保健学研究科 魚住 春日
 愛知県立大学 情報科学部 神谷 直希
 原田学園 平原 大助

☆ 技術紹介:

- ①「X 線動画解析ワークステーション「KINOSIS」の特長と臨床応用の可能性」 コニカミノルタ株式会社 村岡 文到
- ②「新たな断層撮影手法ユニバーサルトモシンセシス」 株式会社 島津製作所 医用機器事業部 技術部 宮島 隆大
- ③「富士フィルム AI 技術「REILI」と AI 活用するためのプラットフォーム「SYNAPSE SAI viewer」について」 富士フィルム株式会社 久永 隆治

☆ 読者のページ:

- ①「第 12 回 ROC セミナーを受講して」 兵庫医科大学病院 放射線技術部 桐木 雅人
- ②「第 12 回 ROC セミナーを受講して」 聖マリアンナ医科大学附属プレスト&イメージングセンター 古谷 悠子
- ③「第 12 回 ROC セミナーを受講して」 福岡大学病院 放射線部 田畑 成章
- ④「第 20 回 DR セミナーに参加して」 産業医科大学病院放射線部 大田 哲
- ⑤「第 20 回 DR セミナーを受講して」 東京医科大学八王子医療センター 放射線部 大野 敦

☆ 専門部会講座(入門編):「線形システムの基本と逆フィルターについて」

国際医療福祉大学 保健医療学部 放射線・情報科学科 西木 雅行

☆ 専門部会講座(入門編):「デジタル X 線画像技術のこれまでの進化について」

徳島文理大学 保健福祉学部 診療放射線学科 本田 道隆

☆ 大学/研究室/研究会紹介:

「金沢大学 医薬保健研究域 保健学系田中研究室の紹介」

金沢大学医薬保健研究域保健学系 田中 利恵

☆ 国際会議案内・報告:

- ①「RSNA2019 参加報告」 済生会熊本病院 丸野 達也
- ②「RSNA2019 参加報告」 熊本大学病院 医療技術部 診療放射線技術部門 後藤 淳
- ③「RSNA2019 参加報告」 鳥取大学医学部附属病院 放射線部 太田 雄大

☆ 画像部会 HP「研究情報サイトの紹介」

岐阜大学 教育学部技術教育講座 福岡 大輔

☆ 標準デジタル画像データベース(胸部腫瘍陰影像)の紹介

☆ 2020 年度事業計画・2019 年度事業報告

☆ 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 88 回 画像部会予告

日 時：2020 年 10 月 15 日(木)～17 日(土) の第 48 回日本放射線技術学会秋季学術大会期間中 予定
会 場：東京ファッションタウン (TFT) ビル (東京都)
内 容：「画像評価(仮題)」

医用画像処理プログラミングセミナーの開催予定

第 41 回医用プログラミングセミナー 2020 年 7 月 11 日(土), 12 日(日) 会場:藤田医科大学

臨床画像評価セミナーの開催予定

第 7 回臨床画像評価セミナー 2020 年 7 月 4 日(土), 5 日(日)会場：国立がん研究センター中央病院

DR(デジタルラジオグラフィ)セミナーの開催予定

第 21 回 DR セミナー 2020 年 9 月 19 日(土), 20 日(日) 会場：大阪急性期・総合医療センター

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	shinohara@u-gifu-ms.ac.jp
小野寺 崇	東北大学病院診療技術部放射線部門	onodera@rad.hosp.tohoku.ac.jp
田中 利恵	金沢大学医薬保健研究域保健学系	rie44@mhs.mp.kanazawa-u.ac.jp
寺本 篤司	藤田医科大学医療科学部	teramoto@fujita-hu.ac.jp
中山 良平	立命館大学理工学部	ryohei@fc.ritsumei.ac.jp
東出 了	鈴鹿医療科学大学保健衛生学部	raryo@suzuka-u.ac.jp
柳田 智	つくば国際大学医療保健学部	s-yanagita@tius.ac.jp
山本 めぐみ	広島国際大学保健医療学部	m-yamamo@hirokoku-u.ac.jp
由地 良太郎	東海大学医学部付属八王子病院	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 87 回画像部会プログラム

日時：2020 年 5 月 15 日（金）～ 6 月 5 日（金）Web 開催

1. Educational Lecture :

司会 岐阜医療科学大学 篠原 範充

「AI 時代において医療画像診断チームの担う役割」

東北大学大学院医学系研究科 保健学専攻 植田 琢也

2. Intellectual Discussion :

「深層学習を放射線技術研究に利用する」

司会 立命館大学 中山 良平

東海大学医学部附属八王子病院 由地 良太郎

1. 分ける

立命館大学 檜作 彰良

2. 検出する

藤田医科大学 魚住 春日

3. 推定する

愛知県立大学 神谷 直希

4. 作る

原田学園人工知能教育・研究開発チーム 平原 大助

各種セミナーのご案内

- ・**専門部会講座（画像）入門編** 5月15日（金）～6月5日（金）Web開催
「線形システムの基本と逆フィルターについて」 国際医療福祉大学 西木 雅行
- ・**専門部会講座（画像）入門編** 5月15日（金）～6月5日（金）Web開催
「デジタル X 線画像技術のこれまでの進化について」 徳島文理大学 本田 道隆

AI 時代において医療画像診断チームの担う役割

東北大学大学院医学系研究科 植田 琢也

現在、機械学習・人工知能（AI）の医療分野への応用が急速に進んでいる。とりわけ医用画像診断領域は深層学習のひとつである畳み込みニューラルネットワーク（CNN）との親和性が高く、画像認識や高画質化などへの積極的な導入が行われている。医療診断支援への期待が高まる一方で、過度に期待するあまり魔法のツールであるような誤った認識も広まりつつある。

現在の AI はもっぱらある特定の機能に特化した“狭い AI”であり、IBM Watson で提唱されている Artificial Intelligence（人工知能）というよりも Augmented Intelligence（拡張知能）という考え方がふさわしい。よって、医療においてどのようなニーズを AI に託せば、効率的に人間のサポートしてくれるのかという臨床学的視点の理解が特に重要となることになる。医療者が必ずしもプログラミングや数理に熟知する必要はないが、その手法の概要を正しく理解することで有効な使用法への道筋を提示できると考える。

AI の画像診断研究への応用が急速に進む一方で、データセット構築の難しさ・施設間での適応による精度確保の困難さ（ドメインシフト）の問題など様々な問題も浮き彫りになってきている。

今後我々画像診断を担う医療者が AI と正しくつきあうための道しるべとして一助となれば幸いである。

深層学習を用いた医用画像上の病変分類

立命館大学工学部 檜作 彰良

1. はじめに

近年、特に画像認識分野において、深層学習 (Deep Learning) [1]が大きな注目を集めており、国内外の学会において、深層学習に関する基礎研究やその応用に関して活発に議論されている。この深層学習が世に知れ渡るきっかけとなったのは、2012 年に開催された一般物体認識のコンテスト、ImageNet Large Scale Visual Recognition Challenge (ILSVRC) [2]であろう。この ILSVRC コンテストでは、画像を 1,000 クラスのどのクラスに該当するかを自動分類させ、エラー率を競う。2012 年以前の ILSVRC では、SIFT (Scale Invariant Feature Transform) [3]などの職人芸的に設計された画像特徴量と、サポートベクターマシン[4]などの識別器を組み合わせた手法が主流であり、毎年数パーセントのエラー率の向上であった。一方、2012 年の ILSVRC において、トロント大学の研究者が提案した深層学習の一つである畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) [5-11]が、従来手法と比較して約 10%のエラー率の向上を達成し、世間に大きなインパクトを与えた。これをきっかけに、現在、世界中の多くの研究者により深層学習 (特に、畳み込みニューラルネットワーク) に関する研究が行われており、これらの技術は画像認識のデファクトスタンダードになっている。この畳み込みニューラルネットワークの利点としては、膨大な学習データから、目的に応じて適切な特徴を自動抽出することが可能な点である。

医用画像解析においても、畳み込みニューラルネットワークは、病変の検出、分類、セグメンテーション、超解像など、様々なタスクに応用されており、高い精度が得られている。本稿では、まず、畳み込みニューラルネットワークについて説明する。次に、畳み込みニューラルネットワークの応用事例に関して述べる。

2. 畳み込みニューラルネットワーク(CNN)

CNN は、畳み込み層 (Convolution layer)、プーリング層 (Pooling layer)、全結合層 (Fully connected layer) などから構成されている。この CNN は、画像認識、自然言語処理、音声認識などの分野で優れた成果を挙げている。図 1 に、分類問題を対象とした CNN のネットワーク構成の例を示す。

CNN では、入力層で画像を入力した後、畳み込み層でフィルタ処理により目的に適した特徴 (特徴マップ) が抽出される。抽出された特徴マップは、次の畳み込み層に送られ、目的に適した特徴マップに変換されていく。そして、通常、CNN の最後に設置された全結合層で特徴マップが統合される。CNN は、従来のニューラルネットワークと異なり、特徴抽出から特徴の統合までを学

習により自動で最適化することができる。したがって、入力画像の専門知識がなくても、簡便に精度の高い結果を得ることが可能となる。以下で、各層の役割に関して述べる。




図 1 CNN のネットワーク構成の例

2.1 畳み込み層

畳み込み層では、畳み込み演算と呼ばれるフィルタ処理により、画像の特徴を抽出する。図 2 に、畳み込み演算の例を示す。通常、2次元入力データ（画像など）に対して、フィルタも2次元の係数を有する。フィルタ係数として最初は乱数が与えられ、CNNの学習により、目的に適した特徴が抽出できるような係数が自動で最適化されていく。入力データに対して、フィルタを一定の間隔でストライドさせ、各位置で入力データとフィルタ係数の積和を計算する。その結果を対応する位置へ格納することにより得られたデータを、特徴マップと呼ぶ。畳み込み層ではパラメータであるフィルタ係数の他にバイアスを持つため、フィルタ処理後、バイアス項を特徴マップの全ての要素に加算する必要がある。

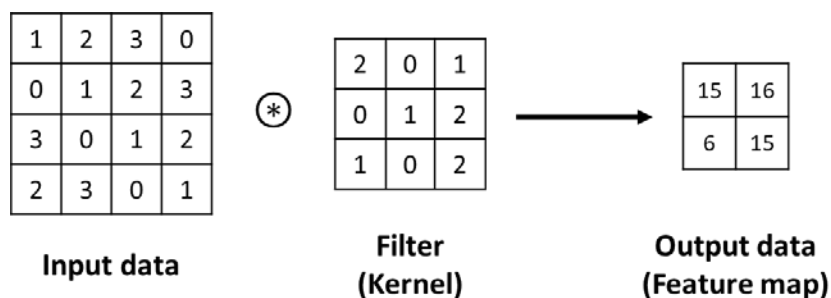


図 2 畳み込み演算の例

2.2 パディング

パディングとは、畳み込み層の処理を行う前に、入力データの周囲に任意の幅の余白を追加することで、出力サイズを調整する処理である。通常、余白には画素値0が与えられ、ゼロパディングと呼ばれる。ここで、畳み込み演算のパディング処理を図3に示す。図3では、幅1のゼロパディングにより、4x4画素の入力データは、6x6画素となる。これに対し、3x3のフィルタを

適用することにより，出力サイズは4×4画素となる．通常，畳み込み演算により，データの空間的なサイズが縮小するが，事前にパディング処理を行うことで，空間的なサイズを変更することなく，次の層へデータを伝送することができる．図3の例では，パディング幅を1と設定し処理を行なっているが，パディング幅を他の整数に変更することも可能である．





図3 ゼロパディング処理後の畳み込み演算

2.3 スライド

スライドとは，畳み込み層におけるフィルタ処理の適用間隔のことである．スライドを変化させることにより，出力される特徴マップのサイズも変化する．図4に，スライド2の畳み込み演算の例を示す．図4の例のように，入力サイズが7×7画素のデータに対して，スライド2でフィルタを適用すると出力サイズは3×3となる．スライドを大きくすると，出力サイズは小さくなる．一方，上述したようにパディングを大きくすると，出力サイズは大きくなる．入力サイズを $H \times W$ ，フィルタサイズを $FH \times FW$ ，出力サイズを $OH \times OW$ ，パディング幅を P ，スライドを S としたとき，出力サイズ $OH \times OW$ は次式により計算される[7]．

$$OH = \frac{H + 2P - FH}{S} + 1 \tag{1}$$

$$OW = \frac{W + 2P - FW}{S} + 1 \tag{2}$$






図4 スライド2の畳み込み演算の例

2.4 プーリング層

プーリング層では、特徴マップのサイズを縮小することにより、微小な位置変化に対する頑健性の向上、計算コストの削減を行う。最大値で縮小するのが最大プーリングであり、平均値で縮小するのが平均プーリングである。図5に、最大プーリングと平均プーリングの処理結果の例を示す。プーリング層の特徴として、畳み込み層と異なり、学習で更新されるパラメータを有していない。また、チャンネルごとに独立して計算が行われるため、入力データと出力データのチャンネル数が変化しない特徴がある。

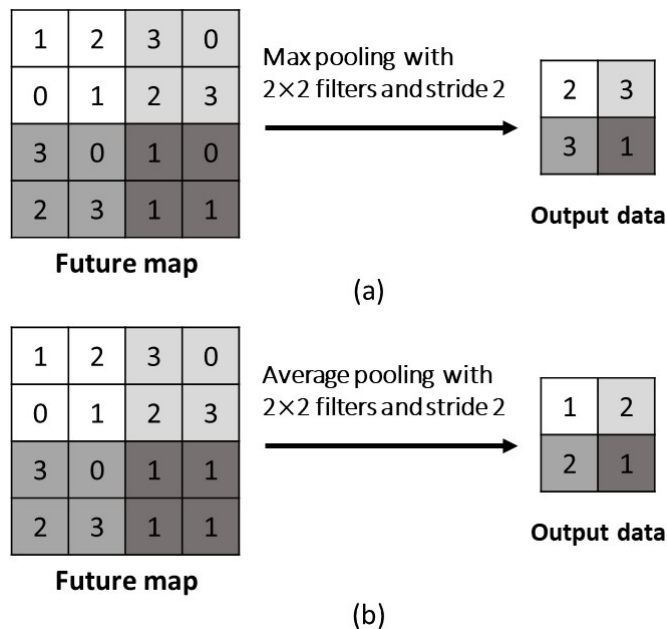


図5 最大プーリング(a)と平均プーリング(b)の例

2.5 全結合層

全結合層とは、畳み込み層やプーリング層などより抽出された特徴マップを一つのニューロンに全て結合する層である。各全結合層では、ニューロン数を変更することで、全結合層の出力数を任意に決定することができる。CNN では出力層の直前に、全結合層を設置することが多い。図 6 に全結合層の例を示す。




図 6 全結合層の例

2.6 ドロップアウト

CNN の学習の際、学習データに対して過剰に適合してしまう過学習が問題となっている。過学習の場合、CNN の汎化性能が低いことが報告されている。そこで、この問題を改善するために、ドロップアウトが提案されている[7]。図 7 に、ドロップアウトの例を示す。ドロップアウトでは、CNN を学習する際、重みの更新毎に中間層のノードを一定の割合で無作為に無効化する。Hinton らは、このドロップアウトを用いることで、過学習を抑制し汎化性能の向上が可能であることを示した[12]。




図 7 ドロップアウトの例

2.7 出力層

出力層では、各クラス確率を出力する。例えば、畳み込みニューラルネットワークを用いて病変を良性と悪性に分類する場合、出力ユニットは2個となる（クラス数は2）。これらのユニットの値は、ソフトマックス関数により各クラス確率を表す。ここで、出力層は、全結合層と同じ構造である。クラス c の確率 $prob_c$ は、次式により計算される。

$$prob_c = \frac{\exp(u_c)}{\sum_{k=1}^N \exp(u_k)} \quad (1)$$

ここで、 N は全クラス数、 u_k は前層の値に対して結合重みを乗じて総和した値である。そして、確率（ $prob_c$ ）が最大となるクラスを分類結果として出力する。

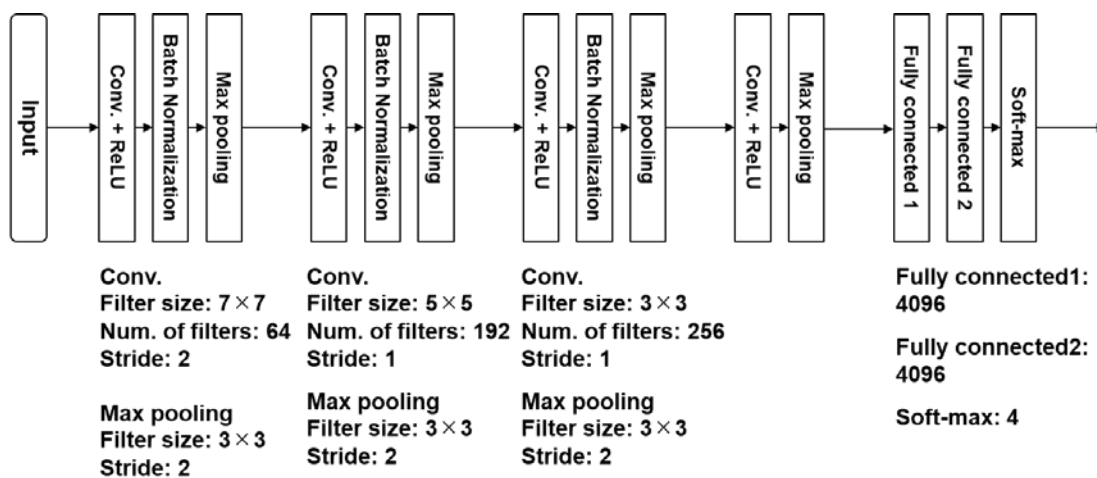


図 8 腫瘍病変の病理組織型の分類に用いた CNN のネットワーク構成

3. 畳み込みニューラルネットワークを用いた病変分類

乳房超音波画像における腫瘍病変の病理組織型の分類を対象とした事例に関して説明する。ここでは、腫瘍病変を4つのクラス（浸潤がん、非浸潤がん、線維腺腫、嚢胞）に分類を行っている。CNNを用いた手法を説明する前に、まず、従来手法（CNNを用いない方法）に関して述べる。従来手法では、研究者が設計した画像特徴量（ハンドクラフト特徴量）と識別器の組み合わせにより、腫瘍病変の病理組織型の分類が行われていた[13]。ハンドクラフト特徴量の抽出では、医師が腫瘍病変を診断する際に着目している9個の画像特徴量を腫瘍病変より抽出した。これらの9個の画像特徴量は、縦横比、境界の不明瞭さ、内部エコーの均一性、内部エコーレベル、後方エコーレベル、形状情報（円形、多角形、分葉形、多角形）である。そして、これらの9個の画像特徴量を用いた重判別分析法により、腫瘍病変を4つの病理組織型に分類を行った。従来手法では良好な分類結果が得られたが、臨床現場に導入するには更なる精度向上が不可欠であった。精度向上の一つの方法として、新たな特徴量の追加が考えられる。しかし、病変分類に有効な新たな特徴量の設計には、多くの時間がかかる。

一方、腫瘍病変の病理組織型の分類を CNN により行う場合、腫瘍病変に対する特徴量の設計は不要であり、学習データより分類に最適な特徴量を自動抽出できる。CNN の学習の際、乳房超音波画像より腫瘍病変の全体を含む ROI を切り出し、これを CNN の入力層に入力する。図 8 に、腫瘍病変の病理組織型の分類に用いた CNN のネットワーク構成を示す[14]。この CNN は、4つの畳み込み層、3つの正規化層、4つの最大プーリング層、2つの全結合層より構成されている。ここで、エポック数とミニバッチサイズは、15 と 128 である。この CNN を 578 枚の乳房超音波画像に適用した結果、浸潤がん 87.6% (190/217)、非浸潤がん 85.7% (60/70)、線維腺腫 83.9% (151/180)、嚢胞 85.6% (95/111) が得られた。

この CNN は、従来手法（ハンドクラフト特徴量と識別器の組み合わせ）と比較して高い分類精度が得られたが、問題点があった。CNN ベースの手法では、腫瘍病変を含む ROI のサイズを、CNN の入力層のサイズに合うようにリサイズ処理を行い入力する必要がある。しかし、この ROI のリサイズ処理を行うことにより、腫瘍病変の形状情報やテクスチャ情報を CNN が正確に学習できない可能性がある。したがって、CNN 特徴量に加えて、形状情報などの形態的特徴量も追加することにより、分類精度が向上する可能性がある。そこで、國枝らは[15]、ROI より 1,024 個の CNN 特徴量と 8 個の形態的特徴量（円形度、縦横比、辺縁の不明瞭度など）を抽出し、それらの特徴量を用いた SVM により、腫瘍病変を 4つの病理組織型に分類する手法を提案した。ここで、CNN 特徴量は、GoogLeNet[16]の最終プーリング層から抽出した 1,024 個の画像特徴量として定義した。國枝らの手法（CNN 特徴量と形態的特徴量の組み合わせ）の有効性を確認するために、従来手法である事前学習された GoogLeNet、形態的特徴量のみを用いた SVM、CNN 特徴量のみを用いた SVM との比較実験を行った結果、提案手法の分類率は従来手法よりも高い値が得られた。この結果より、CNN の入力層に合わせて ROI のサイズをリサイズしなければならない場合、CNN 特徴量に加えて形態的特徴量も追加する方が、分類精度が向上する可能性が示唆された。

4. まとめ

本稿では、畳み込みニューラルネットワークの各層の役割とその応用事例に関して解説した。今後、深層学習を用いた医用画像解析がより一層発展し、早い段階での臨床応用を期待したい。

参考文献

- [1] LeCun Y., Bengio Y., Hinton G., “Deep learning”, nature, 521(7553), 436-444, 2015.
- [2] Russakovsky O., Deng J., Su H., Krause J., Satheesh S., et.al., “Imagenet large scale visual recognition challenge”, International journal of computer vision, 115(3), 211-252, 2015.
- [3] Panchal P.M., Panchal S.R., Shah S.K., “A comparison of SIFT and SURF”, International Journal of Innovative Research in Computer and Communication Engineering, 1(2), 323-327, 2013.

- [4] El-Naqa I., Yang Y., Wernick M.N., Galatsanos N.P., Nishikawa R.M., “A support vector machine approach for detection of microcalcifications”, *IEEE transactions on medical imaging*, 21(12), 1552-1563, 2002.
- [5] Hijazi S., Kumar R., Rowen C., “Using convolutional neural networks for image recognition”, *Cadence Design Systems Inc. : San Jose, CA, USA*, 1-12, 2015.
- [6] 藤吉弘亘, 山下隆義, “深層学習による画像認識”, *日本ロボット学会誌*, 35(3), 180-185, 2017.
- [7] 岡谷貴之, “深層学習”, *講談社*, 2015.
- [8] 岡谷貴之, “画像認識のための深層学習”, *人工知能学会誌*, 28(6), 962-974, 2013.
- [9] 藤田広志, “医用画像ディープラーニング入門”, *オーム社*, 2019.
- [10] 山下隆義, “イラストで学ぶ ディープラーニング 改訂第2版”, *講談社*, 2018.
- [11] 檜作彰良, 中山良平, “病理組織画像解析の研究動向”, *医用画像情報学会雑誌*, 36(2), 53-58, 2019.
- [12] Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R., “Dropout: a simple way to prevent neural networks from overfitting”, *The journal of machine learning research*, 15(1), 1929-1958, 2014.
- [13] Hizukuri A., Nakayama R., Kashikura Y., Takase H., Kawanaka H., Ogawa T., Tsuruoka S., “Computerized determination scheme for histological classification of breast mass using objective features corresponding to clinicians’ subjective impressions on ultrasonographic images”, *Journal of digital imaging*, 26(5), 958-970, 2013.
- [14] Hizukuri A., Nakayama R. “Computer-aided diagnosis scheme for determining histological classification of breast lesions on ultrasonographic images using convolutional neural network”, *Diagnostics*, 8(3), 48, 2018.
- [15] 國枝紳也, 檜作彰良, 中山良平, “CNN 特徴量と形態的特徴量を用いた乳房超音波画像における腫瘍病変の病理組織型の分類法”, *信学技報*, vol. 119, no. 399, MI2019-76, pp. 53-55, 2020年1月.
- [16] Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., et.al., “Going deeper with convolutions”, *In Proceedings of the IEEE conference on computer vision and pattern recognition* pp.1-9, 2015.

物体検出技術について

藤田医科大学大学院 保健学研究科 修士課程1年 魚住 春日

1. はじめに

近年放射線医学においても大きな注目を集めている“人工知能(AI)”、“深層学習(Deep learning)”。昨年12月に開催されたRSNA2019では“AI Showcase”が設けられ、多くの企業・研究機関がAIの医療応用に向けた技術開発に取り組んでいる。本稿ではDeep learningによる画像処理技術の中でも“物体検出”に注目し、物体検出技術の発展について解説する。

2. 物体検出とは

“物体検出”とは字のごとく画像内に存在する物体を検出する技術であり、図1に示すように物体の種類(クラス)と位置を推定し、物体に対して外接矩形(Bounding box)を介して出力する。身近な例としては、自動運転における車両検出やデジタルカメラの顔認証などがある。現在この顔認証技術を利用したカメラアプリが数多く存在し、生活に根付いた身近な技術といえる。しかし顔認証をはじめ物体検出技術は、Deep learningが大きく注目された2012年以降の技術ではない。世界最古のコンピュータ支援診断(CAD)はWinsbergらが1967年にRadiologyにて発表した乳房X線画像から腫瘍を検出するというものである[1]。このように医用画像においても“検出”という技術は古くから用いられており、Deep learningに特化した技術ではない。しかし現在の物体検出はDeep learningを用いた手法が主流である。この要因は何なのか、Deep learning登場前の従来手法とDeep learningによる手法に分けて各技術を紹介するとともに、優れている点や課題について考える。



図1 物体検出の例

3. 物体検出手法の変遷

3-1. 従来手法

従来の物体検出技術は、画像に対するコントラストを基に取り出した特徴量を用いて物体を検出する。従来手法で用いられてきた主要な特徴量に Haar-like 特徴量[2]と HOG 特徴量(Histogram of oriented gradients)[3]がある。Haar-like 特徴量は物体の明暗差を表す特徴量で、図2に示すように線成分やエッジなどの特徴を把握することが可能である。この Haar-like

特徴量を用いて脊椎の溶骨性病変を検出する研究が発表されている[4]。図3に示すように axial、sagittal、coronal の3断面において溶骨性病変が正確に検出されている。

HOG 特徴量は、図4に示すような物体の輝度勾配を表し Haar-like 特徴量に比べ、輪郭情報を高精度に捉えることができるといわれている。HOG 特徴量を用いて腰椎の4つの角を検出し、その4つの点をもとに ROI を設定するというアプローチで腰椎を検出している[5]。図5に検出結果を示す。

従来手法は線成分やエッジなどといった人間の知識やルールに基づいた特徴量を算出しているため、1枚の画像の中に複数の物体が存在した場合、マルチに検出することが難しく、検出の多様性という面で課題が残る。



(a)入力画像 (b)線成分の認識 (c)エッジの認識

図2 Haar-like 特徴量による顔認識




図3 Haar-like 特徴量を用いた溶骨性病変の検出結果



(a)入力画像 (b)HOG 特徴量

図4 HOG 特徴量

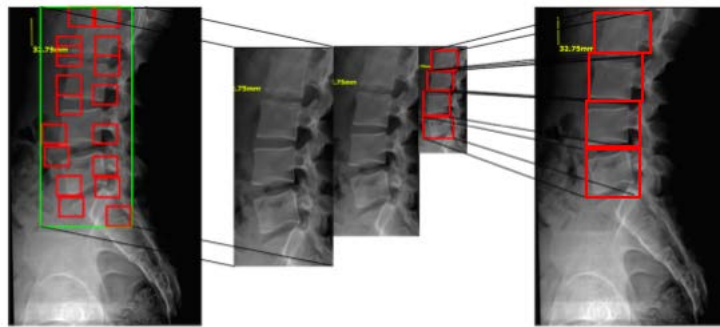


図 5 HOG 特徴量を用いた腰椎の検出

3-2. Deep learning による手法

前述したような検出の多様性に対する課題の他にも、図 6 に示すような画像に対する物体のスケールや、ポーズ、明るさなどの撮影条件といったクラス内の変動も多様性検出の課題である。この課題を解決するため、画像の特徴抽出が重要となる。そこで多様な画像特徴を抽出することができる畳み込みニューラルネットワーク (CNN) による手法が考案されてきた。

Deep learning を用いた物体検出は大きく 2 つに分けて考えることができる。1 つは画像の中から物体が存在する可能性が高い物体候補領域を抽出し、その後物体のクラスや Bounding box の座標を推定するという 2 段階のプロセスに分けて検出を行う two-stage detector である。two-stage detector の代表例に R-CNN (Regions with CNN features) [7]、Fast R-CNN [8]、Faster R-CNN [9] があり、速度はやや劣るが、精度が高いという特徴がある。

もう 1 つは 1 組の CNN で物体のクラスと Bounding box の位置を直接推定するという one-stage detector である。代表例に YOLO (You Only Look Once) [10] や SSD (Single Shot Multibox Detector) [11] があり、two-stage detector よりも精度が劣るが高速な処理となる。精度と速度はトレードオフの関係にあり、精度は Faster R-CNN > SSD > YOLO、速度は YOLO > SSD > Faster R-CNN という関係がある。

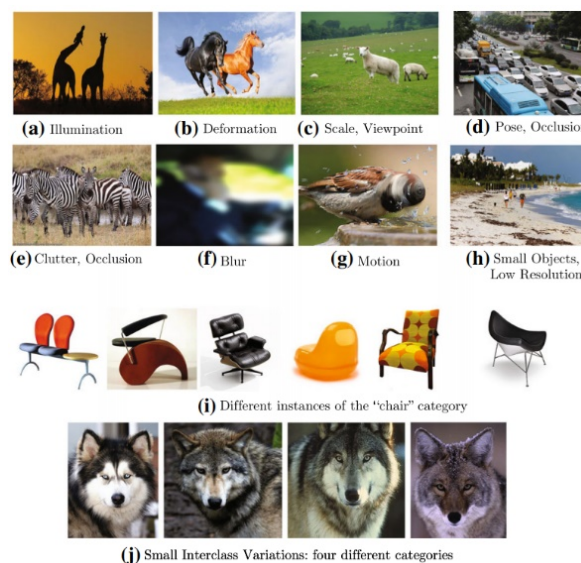


図 6 物体の多様性[6]

3-2-1. R-CNN

Deep learning を用いた物体検出技術のベースとなっているのが R-CNN である。入力画像に対し、画像内のテクスチャ、色、強度を解析し、似ているピクセル同士をつなぎ合わせ、画像内の物体をグループ分けし、物体らしい領域(物体候補領域)を見つけていく。物体候補領域を一定の大きさにリサイズし、CNN に入力することで様々な特徴量を取り出す。取り出した特徴量を識別器である SVM(support vector machine) [12] によって、物体の種類を識別し、物体候補領域を再計算、微調整し正確な位置を推定する。しかしこの手法では、検出した物体候補領域を 1 つずつ CNN に入力し、特徴を取り出すため、処理時間が非常に遅く、効率が悪いという問題点がある。

R-CNN の医療応用例として、腹部 CT 画像から大腸炎を自動検出する研究が行われている [13]。


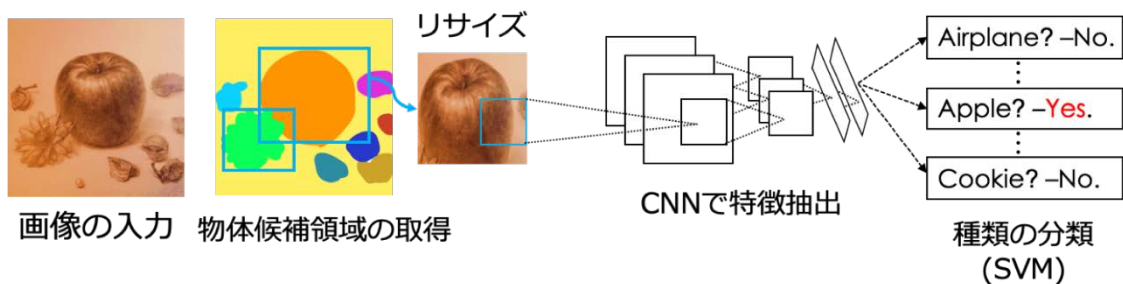


図 8 R-CNN による大腸炎の検出

3-2-2. Fast R-CNN

R-CNN の非効率性を改良したモデルが Fast R-CNN である。R-CNN のように物体候補領域を 1 つずつ CNN に入力するのではなく、図 9 に示すように画像全体を 1 度に CNN に入力し、特徴マップを得る。この時同時に R-CNN と同様のグルーピング処理によって物体候補領域を見つけ、特徴マップを物体候補領域で切り出す。切り出された特徴マップを単にリサイズすると特徴が失われてしまうため、RoI プーリングという処理によって一定の大きさにする。例えば図 10 のカップとケーキのような大きさが異なる物体が物体候補領域として出力されたとする。これらを分類するために、カップとケーキを同じ大きさにする必要がある。そのために物体候補領域によって切り出された特徴マップをいくつかのブロック(この場合は 4 ブロック)に分け、各ブロックに存在する最大値を反映させる。この RoI プーリングという手法によって、特徴を大きく損なうことなく一定の大きさにすることができる。その後 R-CNN 同様の手法で Bounding box の位置を推定する。CNN への入力が 1 度になり、効率化した一方で、特徴の抽出、物体の種類の識別、Bounding box の座標の指定の 3 パートに対する学習を個別に行う必要があるという課題が残る。

Fast R-CNN を用いた医療応用例として、低温電子顕微鏡法で撮影された試料からたんぱく質を検出するという研究が報告されている[14]。低温電子顕微鏡法は低温化での解析であるため、氷の干渉で偽陽性が増えることが課題であった。図 11 の(b)の画像中の青い Bounding box は氷(偽陽性)を意味しており、(a)ではその箇所にも多くの偽陽性が生じていることがわかる。しかし、Fast R-CNN を用いた(c)では、偽陽性が大幅に減っていることがわかる。

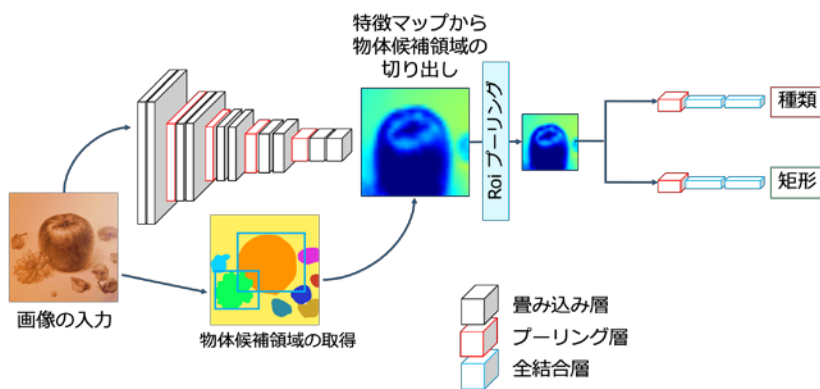


図 9 Fast R-CNN のアルゴリズム




図 10 RoI pooling




図 11 Fast R-CNN によるたんぱく質の検出

3-2-3. Faster R-CNN

R-CNN、Fast R-CNN では特徴の抽出、物体の種類識別、Bounding box の座標の指定の 3 つのパートをそれぞれ個別に学習を行ってきたが、Faster R-CNN では Deep Learning による End-to-End な学習が初めて実現し、一連の流れでこの 3 パートの学習が可能となった。図 12 に Faster R-CNN のアルゴリズムを示す。Fast R-CNN 同様、CNN によって画像の特徴マップを取得し、これまでピクセルごとのグルーピング処理によって得ていた物体候補領域を、Faster R-CNN では CNN 構造の Region Proposal Network (RPN) を用いて取得する。RPN は特徴マップ上に注目点を設け、注目点を中心に、あらかじめ設定した大きさやアスペクト比の矩形を組み合わせ、探索しながら物体候補領域を取得していく。その後、矩形の内部が物体か背景かを学習し、物体であった場合どれだけずれているか教師データを用いて学習させることで精度の高い Bounding box を設定することが可能となる。

Faster R-CNN を用いた研究例には、マンモグラフィの画像から良性腫瘍と悪性腫瘍を検出するという研究がある [15]。図 13 (A) の結果より石灰化を含む腫瘍など様々な腫瘍が検出されていることがわかる。(B) は検出できなかった例を表し、(C) は偽陽性を表す。大胸筋付近の腫瘍や低濃度腫瘍の検出は不良であることがわかる。

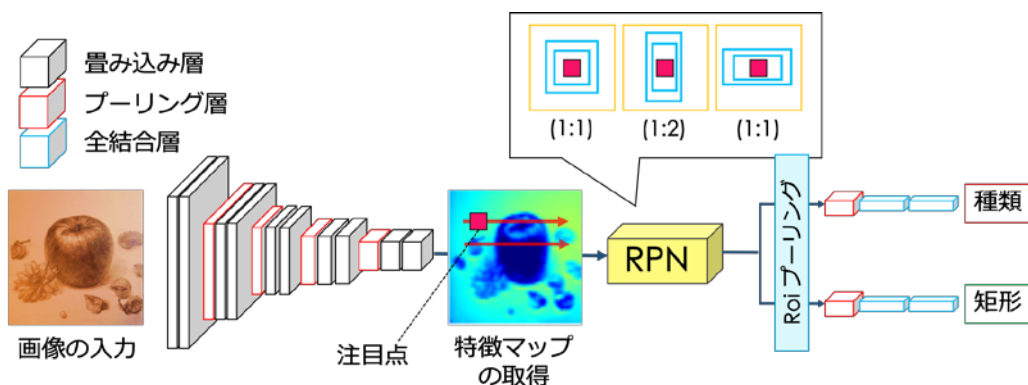


図 12 Faster R-CNN のアルゴリズム




図 13 Faster R-CNN を用いた乳房腫瘍検出

3-2-4. YOLO

前述してきた two-stage detector は、種類と位置の推定が別のプロセスであるため、検出速度が遅くなってしまいます。しかし YOLO などの one-stage detector は種類と位置の推定を同時に行うことが可能になるため、高速な物体検出が可能となった。YOLO のアルゴリズムを図 14 に示す。入力画像を $S \times S$ のグリッドに分割して、グリッドごとに教師データの Bounding box と比べながらより精度が高くなるように学習を行う。同時に、グリッドごとでその物体である確率を表したクラス確率マップを作成する。これらをもとに物体検出と種類の識別が同時に行われる。同時に処理され、一度見ただけで認識できるという意味合いから “You Only Look Once” と名付けられた。

YOLO を用いた研究として、図 15 に示すような腎臓の自動検出が報告されている。A と B のような強度が違う画像でも正確に検出されている [16]。C、D は嚢胞のある腎臓で、F のような腫瘍性の腎臓も正確に検出されている。しかし、E のような肥大性の腎臓は検出されなかった。

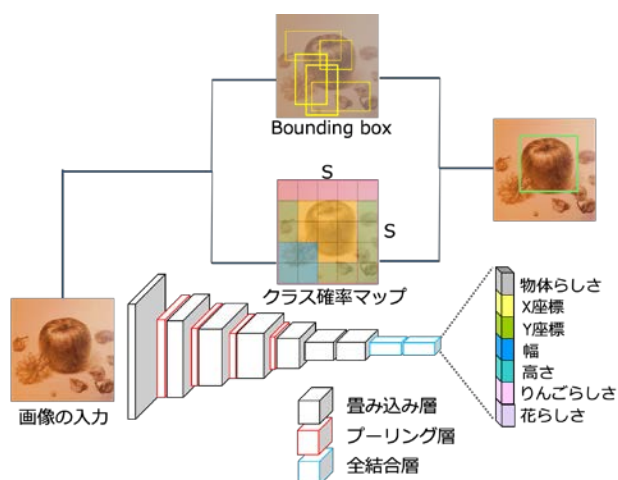


図 14 YOLO のアルゴリズム




図 15 YOLO による腎臓検出

3-2-5. SSD

SSD も YOLO と同様に物体の検出と種類の識別が同時に行われる。図 16 に SSD のアルゴリズムを示す。YOLO と異なる点は、これまで一定の大きさにしてから識別処理を行わなければならないという制約が取り去られ、様々な大きさの特徴マップを用いて処理を行うことができるようになった。物体の候補領域の検出についても、Faster R-CNN と同様に各特徴マップで矩形を定義し、矩形ごとに物体の種類、Bounding box を推定することで効率よく検出している。各サイズの特徴マップのセルに対し、様々な矩形が設定されるため、物体 1 つに対して膨大な物体候補領域が出力される。同じ種類として検出された Bounding box の重なりを計算し、最も適した Bounding box を選別して最終結果とする。

SSD を用いた医療応用に造影 CT 画像から肝病変を検出するという研究が報告されている [17]。図 17 に検出結果を示す。黄色の Ground truth に対して精度良く赤色のよう

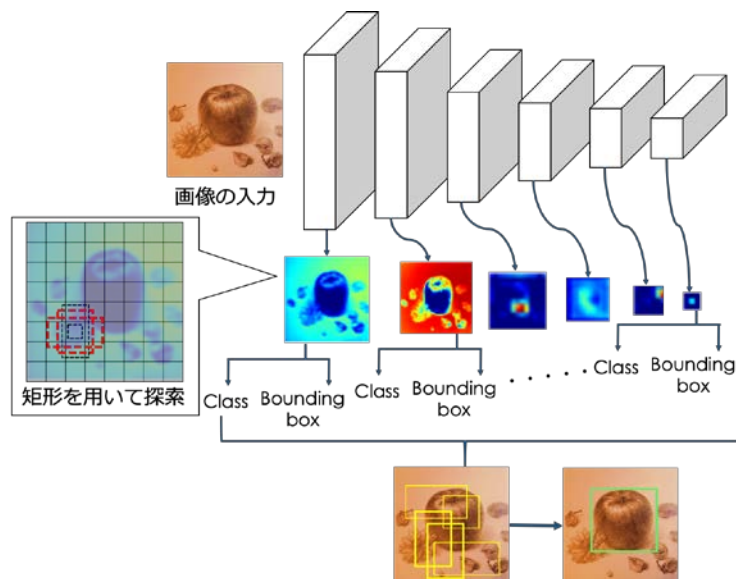


図 16 SSD のアルゴリズム




図 17 SSD による肝病変の検出

4. まとめ

物体検出技術について歴史をたどるとともに様々な手法および研究事例の紹介をした。物体検出は古くから行われており、近年 Deep learning により、多くの種類を検出できるようになった他、高速かつ高精度な物体検出が実現した。前述したように精度と速度はトレードオフの関係にあるため、放射線医学での研究や製品化に向けて、対象とする手技、疾患に応じて選択する必要がある。今後さらに Deep learning を用いた技術・製品が臨床へ導入されることが予想されるが、使用者として原理から理解し、特性の把握や評価をしていくことが重要であると感じた。

参考文献

- [1] Winsberg F, Elkin M, Macy Jr J, Bordaz V, Weymouth W: Detection of radiographic abnormalities in mammograms by means of optical scanning and computer analysis; Radiology89; 211-215, 1967
- [2] Viola P, Jones M. J.: Robust real-time face detection: International journal of computer vision57; 137-154, 2004
- [3] Dalal N, Triggs B.: Histograms of oriented gradients for human detection: IEEE computer society conference on computer vision and pattern recognition (CVPR' 05)1; 886-893, 2005
- [4] Wels M, Kelm B. M, Tsymbal A, Hammon M, Soza G, Sühling M, Comaniciu D: Multi-stage osteolytic spinal bone lesion detection from CT data with internal sensitivity control; Medical Imaging 2012: Computer-Aided Diagnosis. International Society for Optics and Photonics; 831513, 2012
- [5] Sa R, Owens W, Wiegand R, Chaudhary V: Fast scale-invariant lateral lumbar vertebrae detection and segmentation in X-ray images; 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society(EMBC); 1054-1057, 2016
- [6] Liu L, Ouyang W, Wang X, Fieguth P, Chen J, Liu X, Pietikäinen M: Deep learning for generic object detection: A survey; International Journal of Computer Vision128; 261-318, 2020

- [7] Girshick R, Donahue J, Darrell T, Malik J.: Rich feature hierarchies for accurate object detection and semantic segmentation: The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)5; 580-587, 2014
- [8] Ross Girshick.: Fast R-CNN; The IEEE International Conference on Computer Vision (ICCV); 1440-1448, 2015
- [9] Ren S, He K, Girshick R, Sun J.: Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks: NIPS; 91-99, 2015
- [10] Joseph Redmon.: You Only Look Once: Unified, Real-Time Object Detection: The IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 779-788, 2016
- [11] Liu W, Anguelov D, Erhan D, Szegedy C, Reed S, Fu C.Y, Berg A. C.: SSD: Single Shot MultiBox Detector: Lecture Notes in Computer Science9905; 21-37, 2016
- [12] Tsochantaridis I, Joachims T, Hofmann T, Altun Y.: Large margin methods for structured and interdependent output variables: Journal of machine learning research6; 1453-1484, 2005
- [13] Liu J, Lay N, Wei Z, Lu L, Kim L, Turkbey E, Summers R. M: Colitis detection on abdominal CT scans by rich feature hierarchies; Medical Imaging 2016: Computer-Aided Diagnosis. International Society for Optics and Photonics; 97851N, 2016
- [14] XIAO, Yifan, YANG, Guangwen: A fast method for particle picking in cryo-electron micrographs based on fast R-CNN; AIP conference proceedings1836, 020080, 2017
- [15] Ribli D, Horváth A, Unger Z, Pollner P, Csabai I: Detecting and classifying lesions in mammograms with deep learning; Scientific reports8, 1-7, 2018
- [16] Lemay A: Kidney Recognition in CT Using YOLOv3. arXiv preprint arXiv:1910.01268, 2019
- [17] Lee, S. G., Bae, J. S., Kim, H., Kim, J. H., & Yoon, S. (2018, September). Liver lesion detection from weakly-labeled multi-phase CT volumes with a grouped single shot multibox detector. In International Conference on Medical Image Computing and Computer-Assisted Intervention, 693-701, 2018

推定する

愛知県立大学 情報科学部 神谷 直希

1. はじめに

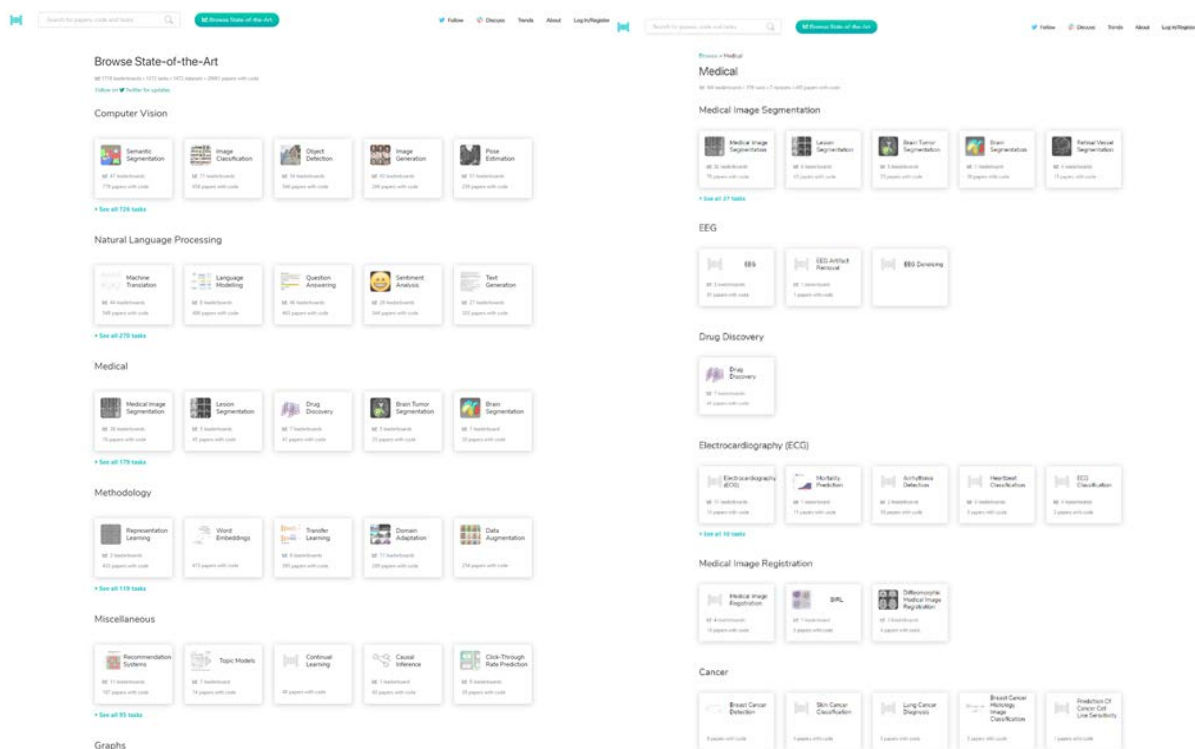
「深層学習を放射線技術研究に利用する」ことを考えたとき、深層学習を使いどのようなことが実現できるかについて知っておくことは重要である。ここでは、深層学習を用いて「推定する」という切り口から、放射線技術研究に利用可能な推定技術の一部を紹介する。以下で取り上げる内容についてより詳細を知りたい方は、参考文献に挙げた書籍、「医療 AI とディープラーニングシリーズ No.1~3」を参照していただきたい^{1)~3)}。これらの書籍では、第1巻において、医用画像とAIを俯瞰することができ、第2巻において、GUI (Graphical User Interface) (同書では、“プログラミングを行わずに”と書かれている)による深層学習の実現、第3巻において、比較的簡単なプログラミングによる実装方法が示されており、様々な推定技術を読者の方々の問題に適用することを考えた場合に、おおいに手助けとなるであろう。

2. 何を「推定する」か

次に、私が与えられたテーマは、深層学習の中でも「推定する」という話題である。シンポジウムの順に原稿が掲載されるならば、この原稿の前に、「分ける」、「検出する」があり、本原稿の「推定する」に続き、「作る」というテーマで構成されるはずである。さて、私の担当の「推定する」技術であるが、先に述べたその他のテーマとも非常に関係が深いことを述べておく。例えば、医用画像中における物体（病変、臓器など）の「検出」では、正解領域の「位置」が必要であろうし、位置が分かればその領域をセグメンテーションするなどにより「分ける」必要性も生じるであろう。さらに、それらの学習過程や画像入力時には「作る」処理により、画像の生成も必要となるであろう。このように、それぞれのテーマは密接に関連する。特に、上記では、「位置」を検出する、と述べたが、実際に深層学習では、「位置の“推定”」が行われており、これは回帰問題として扱うことができる。そして、面白いことに、この「回帰問題」で扱われる regression CNN は、「分類」で扱われる深層学習において、主に出力層の loss 関数を変更することで利用可能な点である。

以上のように、深層学習を放射線技術研究に“ツールとして”用いる場合、ツールである深層学習は多くの場合、既存のモデルを用いることになるであろうが、分類、検出、推定などのタスクに合わせて loss 関数を意識して（問題に対して間違えた選択をしないように）選択すれば比較的簡単に深層学習を適用可能である。

では、どのように「推定」に関する深層学習の手法を選択するのか。特に、深層学習を用いた研究分野は非常に研究のアップデートが早い。私自身は、Papers With Code というサイトを利用している⁴⁾。図 1(a)にサイトのトップ画面を示す。このサイトは、深層学習を用いた様々な



(a) Browse State-of-the-Art ⁴⁾

(b) Medical ⁵⁾

図1 執筆時(2020年2月20日)のPapers With Codeのサイト

テーマの論文が紹介されているだけでなく、ソースコードがGitHubで公開されているもののみが表示される。つまり、動くものだけが掲載されているわけである。さらに、分野ごとに課題がまとめられており、各課題をクリックすると、データセットに対する最もスコアの高い論文とソースコードがセットで把握することができる。そのため、枯れた手法から最新の手法まで簡単にテストすることができるのである。

本原稿の執筆時(2020年2月20日)では、大分類として、「Computer Vision」、「Natural Language Processing」、「Medical」、「Methodology」、「Miscellaneous」、「Graphs」、「Playing Games」、「Speech」、「Time Series」、「Audio」、「Robots」、「Music」、「Computer Code」、「Knowledge Base」、「Reasoning」、「Adversarial」の16項目があり、その中にさらにサブタスク分類がされている。試しに、同サイトのMedicalタスク⁵⁾を見ると、159のタスク、7つのデータセット、465のペーパーが挙げられている。この中を眺めるだけでも、放射線技術に関する動向をつかめるだけでなく、新たな研究テーマ検討にも十分使用可能である。ここで、画像関係に関するタスクに深層学習の利用を考えている場合には、Medicalタスクの中だけでなく、先に示したState-of-the-Artの中から、Computer Visionの分類もクリックして欲しい。収集可能なデータ数の違いなど、医用画像特有の問題はあるものの、画像を扱うならば、やはり、Computer Visionにおける最新動向もチェックすべきである。図2にComputer Vision内のImage Classificationのサイトキャプチャを示す。やはり、Computer Visionは画像収集が比較的容易で、チャレンジしや

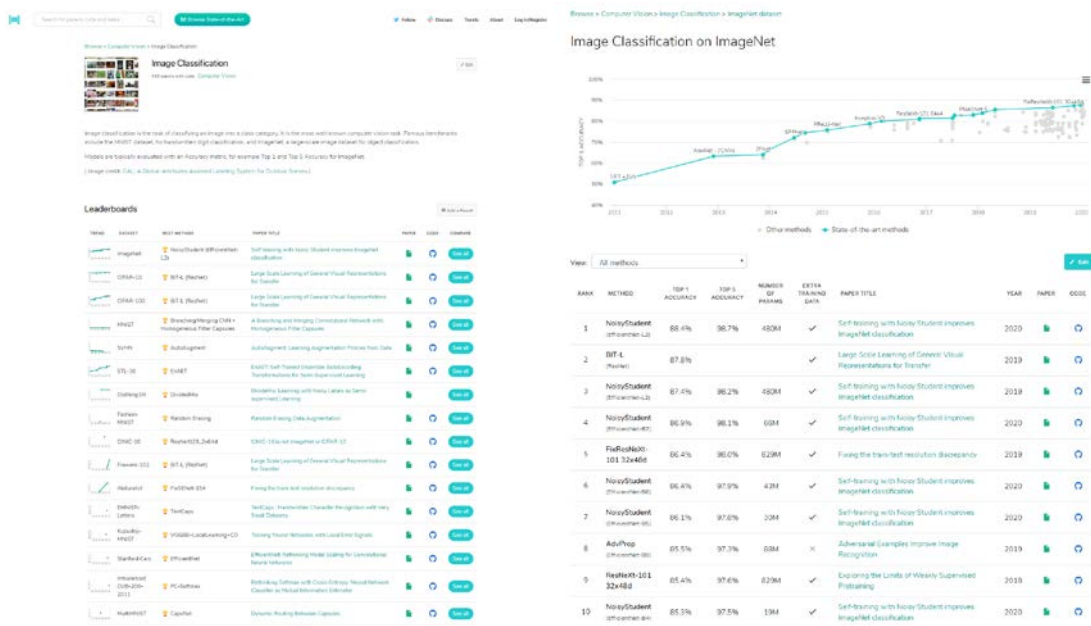


図2 執筆時(2020年2月20日)のPapers With Code内のImage Classification

すいたため、新しい論文やソースコードの公開も早い。同図に示すように、どのデータセットにおいてどの手法の精度が高いか一目瞭然である。

以上のように、どのような課題にどのような手法を使うのか(すでに課題や手法が明確であれば、それとComputer Vision分野で取り扱われている問題の違い(画像の違いではなく、本質の違いは何か))を効率よく把握し、実装する(といってもソースコードが公開されていることが多いため、入力と出力を自身の入力画像と欲する出力に合わせる)だけで、深層学習に触れることができる。そして、筆者の実感からしても、これまでのハンドクラフト特徴量による実装よりも容易に(あくまで実装の話である)ある程度のパフォーマンスが得られるであろう。

3. 筆者らの研究例から考える「推定」技術

前節では、深層学習における「推定」は、検出、分類、認識などの手法と同じく、技術的には少しの作業(変更)で実装できることを述べ、Computer Vision分野などの動向から得られるヒントを示した。実際、筆者はコンピュータ支援診断(CAD: Computer-aided Diagnosis)研究を15年以上続けているが、筆者の研究室に配属された学生に、従来のハンドクラフト特徴量に基づく画像処理演習の後に深層学習を用いた画像処理演習を行うと、驚異の実装スピードで高パフォーマンスをあげる(パラメータチューニングを計算機にお任せする訳なので当然であるが)。

図3に筆者らが行き組む筋骨格系のCAD研究と「推定」に関わる深層学習技術の関係を示す。赤の破線は深層学習手法によるもので、黒の破線はハンドクラフト特徴量による画像処理手法であり、オーバーラップしているテーマはこれまでにハンドクラフト特徴量による画像処理手法であったものに対し、深層学習をテストしている段階である。我々の筋骨格のテーマでは、まず、大域的な構造認識として、骨や筋、体腔などの大域的な領域認識をU-Netベースの手法

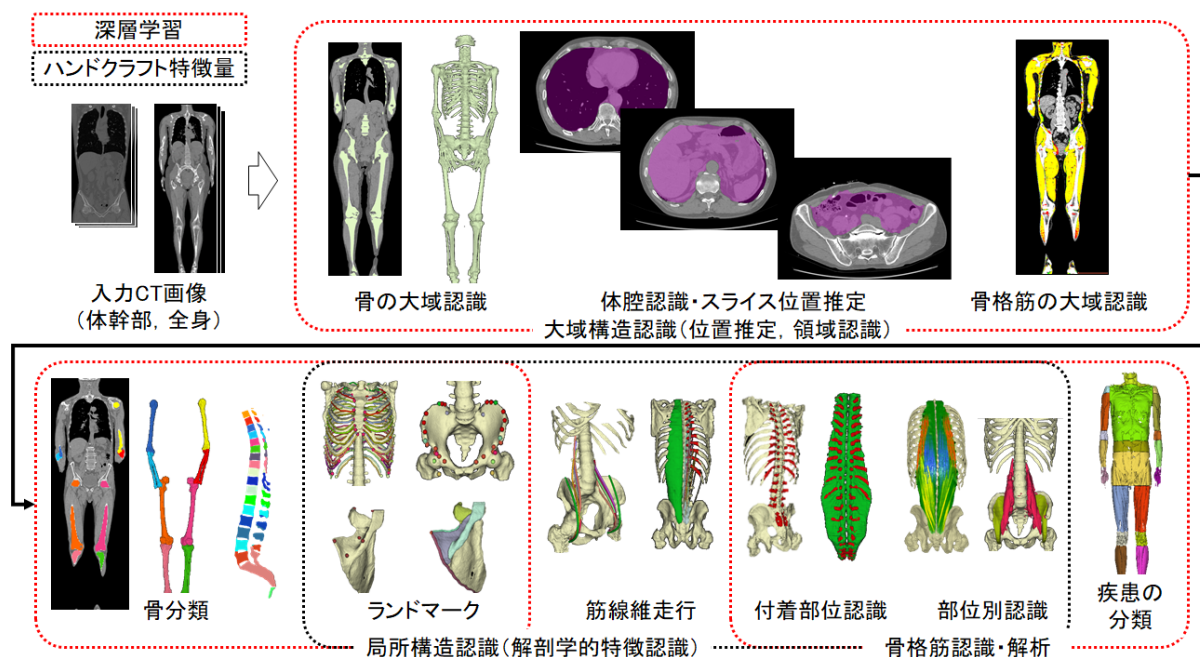


図3 筆者の研究室における筋骨格研究

で実現し、同時に、後半の局所的な筋の認識や解析のための基本的な解剖学的情報の取得として、スライス位置の自動推定を VGG ベースの手法で実現している。後半では、大域的に認識された組織を局所的に認識する。これも U-Net ベースの手法で、骨の分類や筋の部位別認識、筋附着部位の認識を行っている。また、萎縮を伴う筋疾患間の画像分類も行っており、これは ResNet により実現している。この図からもおわかりいただけるかもしれないが、正解画像であるアノテーションが現実的な領域では深層学習は効果的に機能しているが、アノテーションデータの作成が難しく、筋をどれぐらいの解剖学的定義まで細かく認識するか、という点では、従来のモデルベース手法との併用により、アノテーションの負担を抑えながら目的を実現する手法の開発に現在取り組んでいる。

以上のように、筋骨格研究の中でも、対象により「分ける」、「検出する」、「推定する」の技術を使い分けており、すべてが深層学習に置き換わっているわけではない。ここでは、領域推定、位置推定を示したが、その他にも、レジストレーションや疾患リスク推定など推定だけでも様々なテーマが考えられる。

4. おわりに

ここでは、「推定する」をテーマに、深層学習を用いた推定に関する技術について、他の深層学習手法との違いを（実装上の難易度の差はあまり無いということも含めて）示し、Papers With Code サイトの紹介により、最新かつソースコードが公開された、実装が容易な手法の情報収集法を示した。深層学習を画像処理に用いる場合には、医用画像分野だけでなく、Computer Vision の分野における手法や精度を感覚として掴んでおくことは、医用画像研究を行うにおい

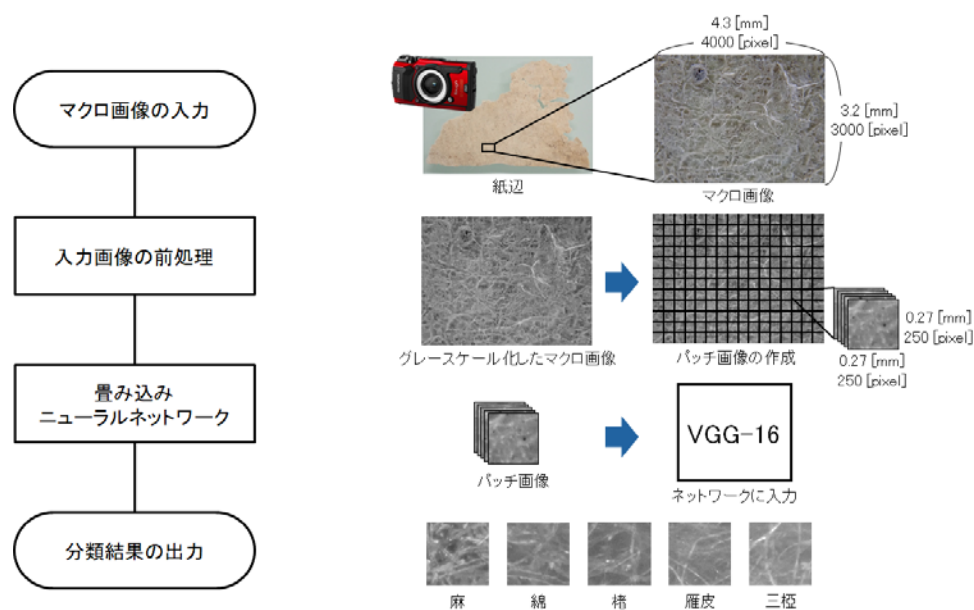


図 4 推定技術を用いたデジタルカメラによるマクロ紙解析

でも損ではない。実際、筆者は医用画像処理の研究室であるが、マンモグラフィ等の高精細な画像を扱っていることから、芸術大学から声がかかり、デジタルカメラで紙片を撮影した、マクロ顕微鏡画像の画像分類と内包物推定に取り組んでいる。図 4 に概要を示すが、基本的な深層学習技術は同じであり、その活用範囲（研究テーマ）は思わぬところにあるものである。

謝辞

本原稿執筆にあたり図を提供してくれた、愛知県立大学大学院情報科学研究科大島あみ氏（骨格筋大域認識）、同情報科学部の若松祐一氏（筋骨格部位別認識）、前田泰良氏（体腔認識）、山田理華子氏（スライス位置推定）、川合悠介氏（骨分類）、そして予想もしていなかったと思うが、快く図の提供に協力いただいた生田亜裕氏および北村知寛氏（ともにマクロ紙解析）に感謝します。

参考文献

- 1) 藤田広志監修，藤田広志編，医療 AI とディープラーニングシリーズ 1 医用画像ディープラーニング入門，オーム社，2019.
- 2) 藤田広志監修，福岡大輔編，医療 AI とディープラーニングシリーズ 2 標準 医用画像のためのディープラーニング-入門編-，オーム社，2019.
- 3) 藤田広志監修，原 武史編，医療 AI とディープラーニングシリーズ 3 標準 医用画像のためのディープラーニング-応用編-，オーム社，2019.
- 4) Papers With Code, “Browse State-of-the-Art,” <https://paperswithcode.com/sota>, Feb 2020.
- 5) Papers With Code, “Medical,” <https://paperswithcode.com/area/medical>, Feb 2020.

医療 AI を作る(超解像と画像生成)

学校法人原田学園 経営企画室 人工知能教育・研究開発チーム

学校法人原田学園 鹿児島医療技術専門学校 兼任講師

聖マリアンナ医科大学 大学院医学研究科

医療情報処理技術応用研究分野 技術研究員

平原 大助

1. はじめに

2006年、「AIのゴッドファーザー」と呼ばれるジェフリー・ヒントンにより、オートエンコーダを利用したディープラーニング(深層学習)が発明された。深層学習は、機械が学習により特徴量を抽出できる。こうして人間による知識表現の必要が無くなったことが、第三次人工知能ブームのきっかけとなった。

深層学習の発明は、長らく暗黒時代が続いていたコネクショニズムを突如として復活させるものであり、同時に記号接地問題も解決に導いた。今日では、画像分類に関して、深層学習は人間の能力を凌駕するところとなった。これは医療分野において朗報である。

私たち診療放射線技師が専門とする画像検査は、患者に負担をかけるものである。また技師も同様に被ばくしている。これら被ばくや軽度の侵襲性がある検査や治療過程において、患者や技師の負担や被ばくの軽減を目的に、深層学習の応用が期待される。

本稿では、深層学習の中でも超解像やノイズ除去など、画像生成することで課題を解決するアルゴリズムについて紹介する。

2. 医用画像 + 人工知能

深層学習の登場という画期的な出来事を経て、以降は様々な分野で人工知能(Artificial intelligence: 以下 AI)が研究開発され、社会実装が進んでいる。この項では、医用画像とAIを組み合わせることで解決される課題にはどのようなものがあるかを確認していく。

まず、よく用いられる以下の三種のネットワークを紹介したい。

- CNN : 畳み込みニューラルネットワーク(Convolutional neural network)
- U-Net : CNNにデコーダとスキップコネクションを追加してU字型の構造にしたもの
- GAN : 敵対的生成ネットワーク(Generative Adversarial Network)

これらが医用画像の分野でどのように役立つのであろうか。例として画像品質の向上を期待できる点を挙げたい。

医療検査においては、画像劣化はできる限り避けたい事態である。その画像劣化の原因として始めに思いつくものにノイズがある。深層学習はノイズ除去も可能にしている。方法としては、CNNやU-NetやGANなどを使いノイズ除去を実行する手法が考えられる。

ノイズ除去の次は、高画質化である。CNNやU-NetやGANなどを使い、画像の分解能を向上させる超解像技術を利用することで、画素を細かくして画質を向上させる手法も考えられる。他にも、U-NetやGANなどを使い、病変を不明瞭化する不要信号(アーチファクトなど)を除去し、診断能を向上させる手法が考えられる。

次に、深層学習でよく利用される構造(各ネットワーク)について詳しく紹介していく。

2.1 CNN

画像分野で最も利用される深層学習は、この畳み込みニューラルネットワーク (CNN) である。CNN は、画像の特徴を抽出する「畳み込み層」と、得られた特徴以外の情報を圧縮する「プーリング層」という二つの特殊なレイヤを持っている。この二つを組み合わせることで、画像分類のタスクで優れた成績を得ることができる (図 1)。

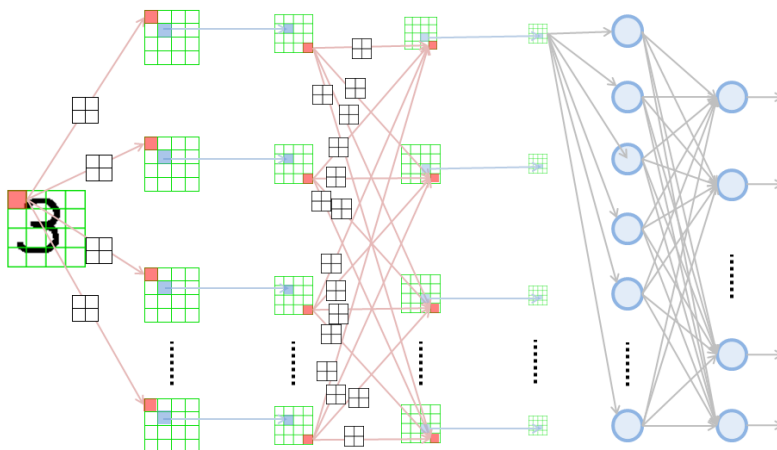


図 1 CNN のイメージ図

(<http://nkdccmbr.hateblo.jp/entry/2016/10/06/222245> より転載)

では、どのように二つの特殊なレイヤが働いているのか、CNN における「畳み込み層」の計算例を図 2 に示す。元画像から、抽出したい特徴量の畳み込みカーネルを用いて畳み込み演算を行わせることで、カーネルと一致した特徴だけを次のネットワークに送ることができるのである。このような畳み込みカーネルを複数準備し、それぞれのノードで計算させることで、画像の特徴を複数抽出していき、特徴マップを作成することができる。




図 2 畳み込み処理の例

次に「プーリング層」の計算例を図 3 に示す。ここでは、指定したブロックサイズで平均値や最大値を計算させ、情報を圧縮させている。図 3 では、8×8 の画像サイズの特徴マップに、2×2 の最大値カーネルを通すことで、形の特徴をほとんど保った 4×4 の出力が得られていることがわかる。この「プーリング層」を設置することで、特徴がない部分の次元削減が行われ、

層が進むごとに特徴だけが残りやすくなっていき、結果として高レベルの特徴マップを作ることが可能になる。




図 3 最大値プーリングの例

図 4 では、CNN の全体像をまとめた。入力層から中間層までは、「畳み込み層」で特徴を抽出し、それを線形から非線形へと「活性化層」で変換。「プーリング層」で次元削減して、特徴マップを更新する。こうして高レベルの特徴マップが完成した後、終盤層で「全結合層」という次元に並び替える層を利用し、最終層で必要なクラス分類をさせることが可能になる。また CNN は回帰問題にも対応可能である。その場合はクラス分類数を 1 にすることで利用できる。

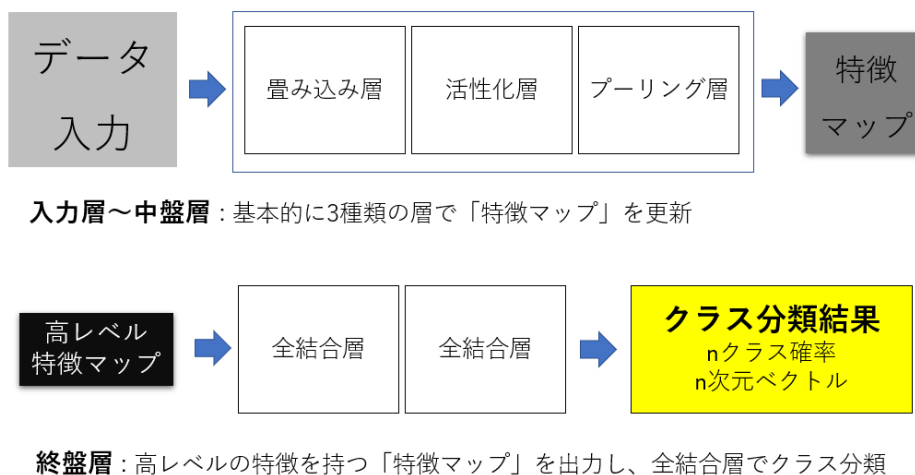


図 4 CNN の学習

2.2 U-Net

次に U-Net というネットワークを紹介する。U-Net は、画像のセグメンテーションで利用されることが多く、医用画像の研究でもよく用いられる。U-Net は、CNN と同じように特徴マップを作るが、最終層の前に全結合層を持たない。

CNN は、特徴を抽出し高レベルの特徴マップを作り全結合層で目的の結果を予測させる。しかし U-Net では、エンコードして得られた高レベルの特徴マップにデコード処理を加えて画像を復元するものである。このとき、セグメンテーション、ノイズ除去、教師データで学習したピクセル値の変換などのタスクを行うことができる。単に復元するだけでは上手く構造が戻らない問題があることから、デコードするときエンコードの情報を参照させる（スキップコネクション）ことで、構造の復元精度を高めている（図 5）。




図 5 U-Net
(arXiv:1505.04597 の Fig1 より転載)

2.3 GAN

最後に GAN を紹介する。GAN は「データを分類するモデル」であり「データを生成/変換するモデル」を鍛え上げる手法である。

図 6 にあるように、ノイズから（贋作職人である）ジェネレータがデータを生成し、そのデータを（鑑定士である）ディスクリミネータが本物か偽物かを判断するのが GAN の基礎となる働きである。このとき、鑑定士は生成データを教師データと比較している。

贋作職人の生成データを、教師データを知っている鑑定士が判定する。この流れを繰り返すことで、贋作職人も鑑定士もレベルが上がり、やがて本物そっくりのデータが生成できるようになるのである。鍛えに鍛え抜くことで、一流の鑑定士/贋作職人が誕生する。こうして、一流の鑑定士が見破れない贋作を生成できる、優秀な画像生成モデルが完成する。

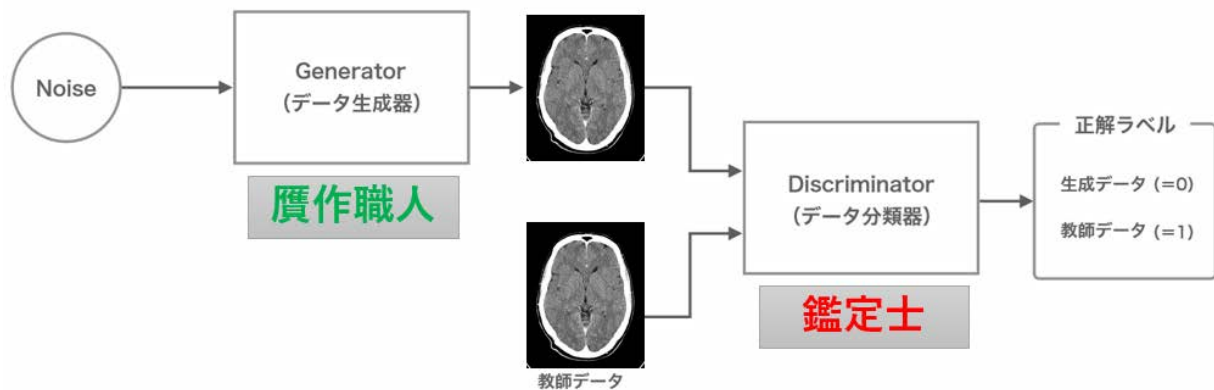


図 6 GAN の構造

3. ノイズ除去

前項では、医用画像の課題解決に利用できる主要なニューラルネットワークモデルを紹介した。ここからは、これらを用いた画像加工結果の事例をいくつか紹介し、医用画像における課題が AI で解決できる可能性があるのかを紐解いていく。

まず本項では、画像において欠くことができない「ノイズ除去」の事例を紹介する。

医用画像から不要なノイズの除去が可能になれば、画像を高画質にすることができるが、期待される効果はそれだけに限らない。検査時間短縮や、患者の負担軽減も考えられる。そして手術や検査においての、医師や技師の被ばく量の低減も可能になる。

まずはノイズ除去事例として、U-Net を使い、2020 年の改定で保険収載される予定の DWIBS (=Body DWI) 画像でノイズ除去の可能性を検証した。

この事例では MRI 画像を用いたが、X 線など放射線を用いた検査においては、一人の患者で標準画像とノイズ画像を取得することなどを目的とした複数回の検査は、倫理的な意味で実行できない。そこで本検証では、「複数のノイズを付与した画像を生成しトレーニングさせ、ノイズ画像のみからノイズ成分を学び画像をきれいにする Noise2Noise モデル^{※1}」と、「標準画像を教師データとしてノイズ画像をきれいにする Noise2Clear モデル」の二つを作成し、比較した。

図 7 に、Noise2Noise の論文に記載されているノイズパターンを転載する。



図 7 自然画像における Noise2Noise の結果

図 7 の自然画像に対し、ガウシアンノイズ、ポアソンノイズ、ベルヌーイノイズのどれにおいても、良好な成績が得られていることがわかる。

次に図 8 に、DWIBS 画像の結果を示す。どちらのモデルでも十分なノイズ除去が実現していることが、SSIM(画質の評価に用いられる指標)から定量的に確認できる。特に Noise 2 Noise モデルでは SSIM も高く、小さくはあるがキャラクタが元画像より鮮明になっていることがわかる。

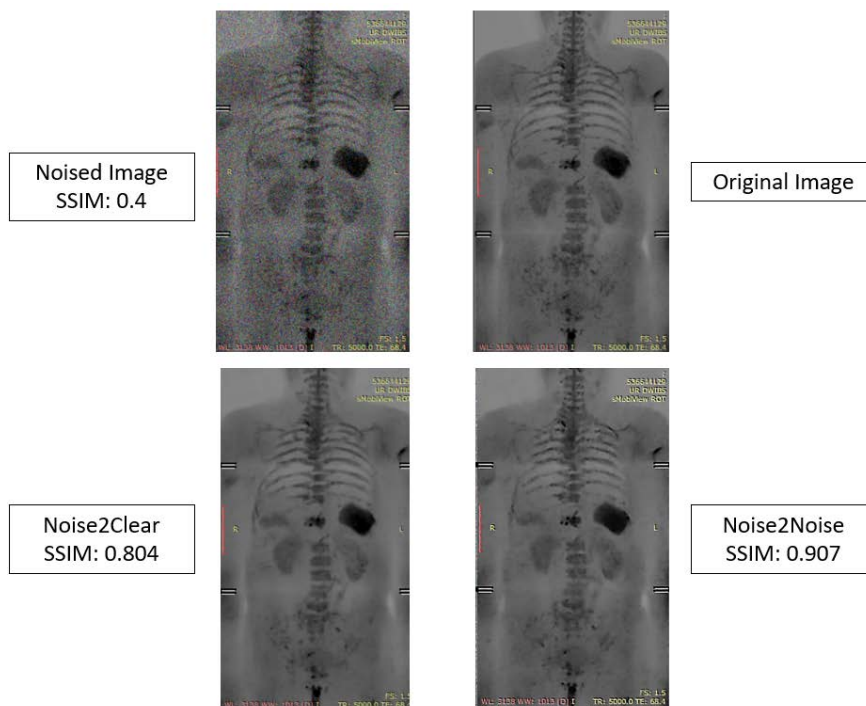


図 8 DWIBS 画像のノイズ除去結果

4. 超解像

深層学習によるノイズ除去の可能性を見て頂いたところで、次に超解像技術について確認していきたい。「超解像技術」も、検査時に低解像だったものを通常の画質に変換できる可能性があり、有用なツールになり得る。超解像ネットワークにより検査時に解像度を下げられれば、ノイズ除去と同様に、被ばく低減や検査時間短縮が可能になるのである。

血管造影検査や透視検査では、デジタル化により、光電子増倍管の時代とは違い、インチサイズ変更による画像拡大ができなくなった。デジタル方式の装置では、画素補間法によるデジタルズームで画像を拡大している。デジタルズームはどうしてもピクセルが目立つことから、超解像で自然な補間で拡大することで、画質低下の問題を解決できる可能性がある。図 9 は猫のひげの部分拡大した超解像ネットワークモデルを比較したものである^{※2}。

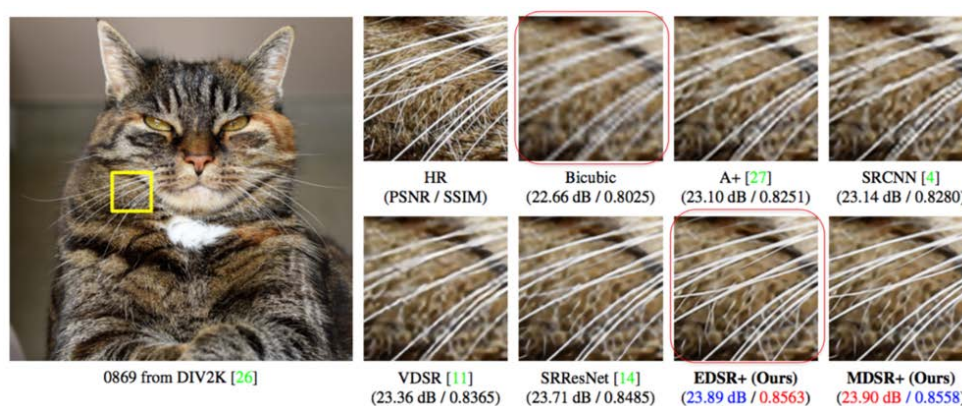


図 9 超解像アルゴリズム比較
(参考文献 2 より転載)

図9を確認すると、デジタルズームで用いられている画素補間法(Bicubic)と比較して、最新のCNN(SRResNet など)は非常に解像力が高いことが明らかである。続いて、超解像の事例として、血管造影画像に対してGANを利用したSRGAN^{*3}を用いて、超解像が医用画像でも使えるかを検討した(図10)。




図10 SRGANの結果

図10の右側に記載されたSRGANでは、画素補間法であるbicubic(図10中央)よりはっきりと、解像力が改善していることがわかる。これらの実証の結果、超解像の事例も、医用画像の課題解決に利用できる可能性が高いと言えるだろう。

5. 不要信号除去

最後の事例としてアーチファクト除去や病変に重なった不要信号除去が可能かを確認するためU-Netを用いてDWIBS画像から脾臓信号を除去するモデルを作成した(図11)。




図11 DWIBS画像の脾臓信号除去結果

拡散強調画像で高信号になる脾臓信号がU-Netにより低信号になり見やすくなっている。除去前には重なって見づらかった高信号がはっきりと確認できるようになっている。この事例を通して、不要信号除去が診断能の向上に寄与する可能性が示唆された。

6. おわりに

本論文では、医用画像とAIを組み合わせることで診断能力が向上する可能性があることを、事例を通して確認した。

深層学習と医療分野に関する国外の話題として、2020年1月17日、医用画像の専門家や診療放射線技師などからなる専門家団体 American Society of Radiologic Technologists (ASRT: 米国放射線技師協会)は、AIが医用画像や放射線領域の専門家に及ぼす影響に関してまとめたホワイトペーパーを公開した。ここでは内容を詳述しないが、簡単にまとめると「画像診断装置と機械学習や教育を受けた専門家が組み合わさることで、患者ケアを充実した上で、診療放射線技師がよりスマートに働けるようになる」とAIの利用推進を促している。

ICTの進歩やiPhoneから始まったスマートフォンの普及など、近年の技術革新による変化の速度は著しい。医用画像の世界においても、アナログからデジタルへの変化で、医師や診療放射線技師の働き方やアウトプットに大きな変化があったことを著者と同様に実感した方も多くいるはずである。「人工知能が仕事を奪う」と恐怖心を煽るようなマスメディアの取り上げ方により、距離をおいてしまう方もいるだろうが、ガラケーからスマホ、アナログからデジタルを体感した世代は、AIが医用画像の画質を向上し、医療従事者の負担軽減や患者の健康寿命を延伸する有益なツールになることを信じられるだろう。今後、AI導入に関わる機会があったとき、本論文が導入の参考になれば幸いである。

参考文献

1. J. Lehtinen, J. Munkberg, J. Hasselgren, S. Laine, T. Karras, M. Aittala, T. Aila, "Noise2Noise: Learning Image Restoration without Clean Data", International Conference on Machine Learning (ICML), 2018
2. Si Lim et al., Enhanced Deep Residual Networks for Single Image Super-Resolution, <https://arxiv.org/abs/1707.02921>
3. Ledig et al., Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network, <https://arxiv.org/abs/1609.04802>

X線動画解析ワークステーション「KINOSIS」の特長と 臨床応用の可能性

コニカミノルタ株式会社 村岡 丈到

1. はじめに

現在の情報社会が証明しているように、動画は静止画に対し圧倒的に多くの情報量を含み、効率良く多角的な情報を伝え得ることが可能なことから、企業や個人の情報発信やコミュニケーション等に欠かせないコンテンツとなっている。

これまでX線動画撮影によるモダリティはX線TVを代表として幾つか存在するが、特別な装置や固有の設置場所など様々な導入条件がある。このような「動画撮影には個別モダリティが必要」との常識を打ち破るべく、コニカミノルタは、診療上のプライマリ画像診断検査として広く利用されている単純X線撮影装置に着目し、同モダリティ内での動画撮影技術を確認させた。これにより静止画から得られる画像情報の枠を超え、診療の初期段階で取得する情報量を大幅に増大させることが可能となる。

一昨年末に市場展開したX線動画解析ワークステーション KINOSIS [1]は、X線動画に含まれる肺野内組織の動きを解析し、呼吸器および循環器に関連した生体生理機能を視覚化・定量化することを可能とした。また、動画撮影法から得られる動きの様子を如実に観察することが可能なことから、整形分野への活用も期待されている。ここでは、単純X線動画撮影法から得られる情報に対し、当社独自の画像解析技術により新たに創造される画像診断の臨床的価値、また動画像独自が広げる次世代イメージングへの可能性について紹介する。

2. デジタルX線動画撮影システムおよび画像解析技術

このデジタルX線動画撮影システムは、X線動画解析ワークステーション KINOSIS と可搬型デジタルX線撮影装置 AeroDR fine[2]で構成されており、従来の単純X線撮影の様に一般X線撮影装置を用いて撮影ができる。一般X線撮影室にて共通のコンソール (CS-7H) から静止画と動画の撮影を制御することが可能であり、静止画撮影は従来の撮影法で行い、動画撮影時にはパルス状 (15frame/sec) のX線が照射され、得られる連続した複数の画像をアニメーションと同じ原理で時系列的に表示する。また、本システムは任意のポジションでの撮影を可能とするため、CT や MRI において臥位の状態で撮影するのに対し、日常生活における自然な体勢に近い状態を観察できるという利点があり、臨床的にも期待されている。

撮影された動画像が CS-7H から KINOSIS に転送されると、各解析処理が順次自動的に施行される。オリジナルの動画像および解析画像は KINOSIS や KINOSIS から転送される KINOSIS クライアントで閲覧でき、さらに URL 連携機能により院内端末からもアクセスが可能のため、院内環境においてシームレスな運用も構築可能である。本項では KINOSIS に搭載された当社独自の画像処理技術について述べ、次項ではその画像から得られる価値と可能性について紹介する。

(1) “動き”の視覚化

静止画で提供している「Bone Suppression 処理」や「カテ先・ガーゼ強調処理」をそれぞれ動画像に応用した、肺野内の鎖骨と肋骨成分を減弱表示する「BS-MODE（胸部骨減弱処理）」、ならびに解剖学的構造のエッジ部分を強調する「FE-MODE（周波数強調処理）」により、肺野内の視認性を向上させ動きの観察し易さを追求している[3]。

(2) “動き”の定量化

横隔膜の上下運動のような解剖学的構造の動きの様子をグラフ表示させる「DM-MODE（特定成分追跡処理）」では、動きの定量化から視認性を高めることで、従来の静止画から異なる視点による症状推定や、生理機能評価を可能とする[3]。また、肺野領域の面積を自動的に測定することで、呼吸器病変による左右肺の面積値遷移や呼吸に伴う面積変化率の算出結果から、呼吸運動を定量化することも可能である。

(3) 肺組織の“動き”に伴う信号値変化の抽出

肺胞や肺血管など肺組織の運動に伴う微小な信号値変化を捉えディスプレイ上に表示する「PH-MODE（相互相関計算処理）」、「PL-MODE（基準フレーム比計算処理）」では、CTやMRIなどの高度な撮影技術を要する検査前に行うスクリーニング的な単純 X 線検査でも一定の機能評価ができる可能性があり、実臨床での活用が期待されている[3]。

3. 動画解析の臨床応用例および将来展望

(1) 胸壁等への癒着検出

取得したオリジナル画像に対し、KINOSIS に搭載された解析処理を施行することで呼吸運動における胸壁と血管影等の位置関係から癒着や浸潤の検出に対する可能性は既報の通りである[4]。

DM-MODE で得られる横隔膜の上下運動を示すグラフから振幅の程度を確認し、左右差が認められた場合は広範囲の癒着・浸潤による呼吸運動の低下がその一要因であることを示唆することがわかっており、また、FE-MODE にて組織の伸縮運動の視認性を向上させ特異的な動きの様子を観察することで、胸壁部への癒着・浸潤の有無や程度の推察が可能である。KINOSIS の「構造物観察モード」では、図 1 のように DM-MODE のグラフと FE-MODE の画像が 1 画面上に表示されるため、相互のアプローチから癒着や浸潤の観察をサポートすることが可能である。




図 1 「構造物観察モード」画面

従来、術前の術式計画における癒着観察は、一般的に静止画となる CT 等では観察困難であり、X 線動画画像により呼吸に伴う肺野内の動きを連続的に観察することで組織動態の不自然さが確認できる。術前での癒着の有無と範囲推定に対する呼吸器外科医からの要求の声は多く、それを可能とすることで術式アプローチや戦略、選定器具の最適化、また手術時間の見積もり精度を向上させることに繋がり、時間超過や 1 日の手術件数の最適化など経済的効果も大いに期待できると考える。

(2) 呼吸器疾患の治療効果確認

X 線動画撮影の特性を活かすことで、客観的な COPD 診断の精度向上に寄与する可能性が報告されている [4]。

KINOSIS の「動態画像評価モード (図 2)」では、X 線動画撮影システムから得られた動画画像において呼吸に伴う横隔膜変位や肺野面積を自動で計測し、最大・最小面積値・面積変化率を算出して記録できる。経時変化グラフにより過去計測値から現在までのトレンドを表示し、継時的観察により病態を客観的に評価することが可能となる。精密呼吸機能検査を行う専用装置で得られる数値との相関関係についても研究が進められており、従来よりも低侵襲かつ患者負担が少ない簡便な手技にて治療経過や投薬効果確認を定量的に観察し効果的な診断が可能になると期待されている。



図 2 「動態画像評価モード」画面

(3) 肺血流の状態評価

拍動に伴う肺動脈血流変化の信号解析結果が肺血流シンチグラフィと良好な相関関係が示され、肺血流の正常・血流低下などの異常評価が可能となる報告がされている [4]。

この実用性が高まることで臨床分野におけるスクリーニングレベルは飛躍的に向上すると考えられ、実臨床での利用に向け進められている研究の一例として慢性血栓塞栓性肺高血圧症 (CTEPH) の鑑別診断がある。肺高血圧症は、①肺動脈性肺高血圧症 (PAH)、②左心疾患による PH、③呼吸器疾患および/または低酸素血症による PH、④慢性血栓塞栓性肺高血圧症 (CTEPH)、⑤原因不明および/または複合的要因によるもの、の 5 つに大きく分類され、これらの鑑別診断にあたり、最近、肺換気血流シンチグラフィによる CTEPH の早期スクリーニングが重要視されている [5]。CTEPH の鑑別診断に関する研究では、図 3

にある通り、肺血流シンチグラフィで観察される特徴的な区域性の欠損領域が KINOSIS による画像解析結果でも観察できる可能性が示されている[6]。一般 X 線撮影システムの延長である動画撮影システムから得られる動画像を用いることで、低侵襲かつ患者負担が少ない簡便な手技が CTEPH の鑑別診断に寄与すると期待される。




図 3 (a) 99mTc-MAA 血流シンチグラフィ

図 3 (b) PH-MODE 解析結果

(4) 整形分野への活用展望

X 線動画像は、生体の動きそのものを捉えられるその特徴から、呼吸に伴う肺組織運動の可視化の他にも様々な臨床分野から期待されつつある。代表的な領域として整形分野がある。

KINOSIS では、動画像を記録し再生することが可能なため、一定の動作を繰り返し確認することができる。例えば関節の可動過程の観察においては、これまで触診をしながら患者に指示し姿勢を取らせていた複数回の単純撮影が、一定の屈曲等の運動動作の指示や痛みを伴う患者の動きの様子について、一度の撮影のみでその状態の把握を可能にすると考えられる。また、人工関節手術後の曲げ伸ばし動作における中間的位置の観察や、経年的な状態確認を容易に行うことが期待される。他にも人工骨頭置換術後の経年変化による大腿骨との間隙の有無や程度観察は従来 CT で行われることが多いが、CT 値は装置の限界がありアーチファクトを生じて観察困難になる報告が散見される。2次元の X 線画像は、アーチファクトなくどのフェーズで間隙が生じ痛みなどを伴うか等、簡便かつ Retrospective に評価可能となる。

4. おわりに

我々、ユニカミノルタは、医療のフロントラインであるプライマリ・ケアの領域で、当社独自の技術を用いた低侵襲で高診断能をもたらす技術、またそれらが構成するシステムを提供することを通じて、社会課題である健康寿命の延命と医療費の抑制に寄与するべく、研究、開発を行っている。

今回、当社が展開する X 線動画撮影システム・X 線動画解析ワークステーション KINOSIS の特長と、それらが有する臨床価値の可能性について紹介した。「単純 X 線検査は静止画撮影」という従来の常識の枠を超えるデジタル X 線動画撮影システムが、患者にベネフィットをもたらす有用性の高い画像診断法として多くの臨床現場で評価され、またスクリーニング検査での診断精度向上に寄与することで日常の診療として認知・臨床応用される画像診断機器となるよう、臨床価値の創出・検証および機器開発を通じ、更なる医療の質の向上に貢献していく所存である。

参考

- [1] X線動画解析ワークステーション KINOSIS [販売名:画像診断ワークステーション コニカミノルタ DI-X1 (製造販売認証番号:230ABBZX00092000)]
- [2] AeroDR fine [販売名:デジタルラジオグラフィイー SKR 3000 (製造販売認証番号:228ABBZX00115000)]
- [3] 松谷哲嗣, :” 動態解析による生理機能の視覚化・定量化 ～単純 X 線撮影の Next Stage～” , JIRA テクニカルレポート; 29: 30-35, 2019 ;
- [4] 松谷哲嗣, :” X線動態解析が目指す胸部生理機能の視覚化・定量化” , 画像通信, 42: 25-33, 2019
- [5] Frost, A., et al. : “Diagnosis of pulmonary hypertension” , Eur. Respir. J ., 53: 1801904, 2019.
- [6] “第2回 X線動態画像セミナー 〈第3部〉 実臨床における有用性の報告:ディスカッション” , INNERVISION: 35, 2020

新たな断層撮影手法ユニバーサルトモシンセシス

株式会社 島津製作所 医用機器事業部 技術部 宮島 隆大

1. はじめに

トモシンセシスは連続した複数枚の投影像から断層像を再構成する技術であり、当社の製品においては、X線TVシステム「SONIALVISION™ G4」および一般撮影システム「RADspeed™ Pro EDGE package」に搭載されているアプリケーションである。トモシンセシスを用いることで、骨や組織の重なりを避けて画像を得ることができ、単純撮影では確認が難しい骨折線が観察しやすくなる。当社では、このトモシンセシスの有用性を広く普及することを目指し、X線画像診断装置ワークステーション用プログラム「UT-Station™」および、被写体と一緒に撮影する位置決め用治具「UT-ファントム」を用いることで、トモシンセシス撮影専用の機構を持たないX線撮影装置でも断層像を取得可能にする「ユニバーサルトモシンセシス」を開発した。

2. ユニバーサルトモシンセシス

2.1. 概要

トモシンセシスは連続した複数枚のX線撮影画像から断層画像を再構成・取得する技術であり、骨折線の観察や、人工関節置換術後の経過観察など整形分野を中心に有用性が認められている。ユニバーサルトモシンセシス撮影を行うために必要なものは、UT-ファントム(図1)、X線画像診断装置ワークステーションプログラム UT-Station(図2)、UT-Stationをインストールし画像閲覧や再構成処理に用いるワークステーション用PCの3つである。これらはX線診断装置とは独立しているため、既設のX線撮影装置にも組み合わせが可能である。ユニバーサルトモシンセシス撮影の概要を図3に示す。なお本撮影は、呼吸動のない四肢・股関節における骨折の評価を主なターゲットとしている。



図1 UT-ファントム



図 2 UT-Station™

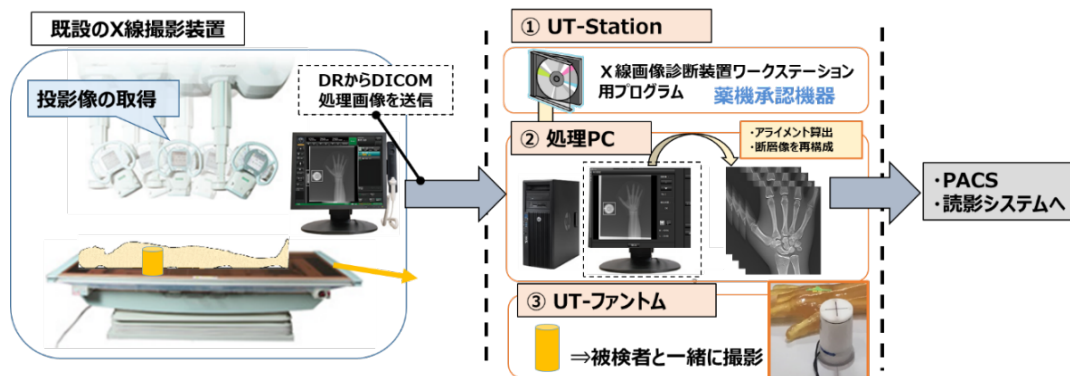


図 3 ユニバーサルモーションセンシングの概要

2.2. UT-ファントム

断層像再構成の際に必要な撮像系の位置情報を得るために、UT-ファントムと被写体が一緒に映るように投影像を撮影する。UT-ファントム内部には金属球が複数配置されており、UT-Stationにて投影像上の金属球の位置を検出し、撮像系の位置情報としてFPDパネルの中心を原点としたX線管球焦点の位置座標を算出する。なお、UT-ファントム底面には吸盤が取り付けられており、これにより天板だけでなく、立位スタンドにも固定が可能である。このUT-ファントムを被写体と同じ照射野に設置して複数枚撮影を行い、撮像像をUT-Stationに送信する。

2.3. UT-Station

UT-Station では前述の撮像系位置情報の推定および断層像の再構成処理を行う。ユニバーサルトモシンセシスでは、一般撮影用に広く用いられている撮影間隔の長い FPD を使用して投影像を取得することを想定して、5~7 枚程度の少ない撮影像での再構成にも対応したアルゴリズムを用いている。断層像再構成に使用する撮影像の枚数が少なくなると、皮質骨などのエッジ構造が本来存在している断層面以外の断層面にも映り込むリップルアーチファクト(以下、リップル)と呼ばれるひだ状のアーチファクトが発生しやすい。そのため、UT-Station ではこのアーチファクトを低減するために逐次近似法を応用したアルゴリズムを使用している。再構成像からリップル源となる領域を特定し、その領域のリップル源の信号を低減した投影像から逐次近似再構成を行い、リップルとエッジの影響を低減させたもう一つの断層画像を作成する。そして、その断層画像と元の断層画像を位置に応じ割合で重みづけし画像を合成することで、リップルを低減した断層画像を出力する。

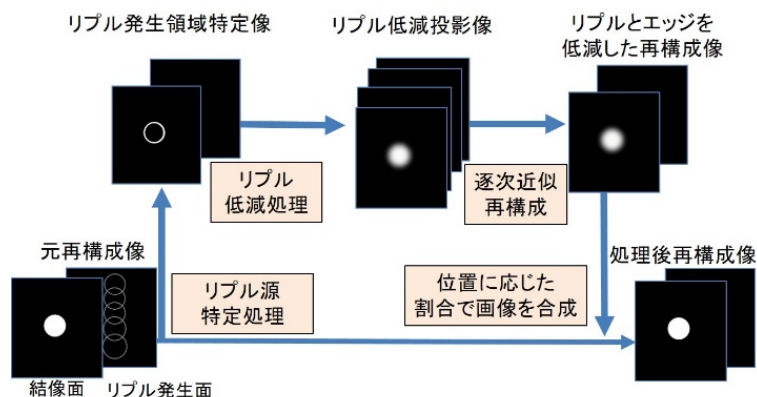


図 4 リップル低減処理の概要

3. 撮影ワークフロー

3.1. プロトコル選択

検査登録時に、画像処理パラメータや送信先などをユニバーサルトモシンセシス用に事前に設定したプロトコルを撮影枚数分選択する。

3.2. 被写体と UT-ファントムのセッティング

検査体位を定め、正面で照射野を設定する。次に、照射野ラインを目安に、UT-ファントムを設置する。ユニバーサルトモシンセシス撮影は、複数枚の撮影に1分程度の時間を要する。その間、被写体が動いてしまうと、断層画像のボケにつながるため、被写体は動かないことが望ましい。固定具や砂袋などで被写体を固定することで、動きボケがなく、より鮮明で骨折線が見やすい断層像を得ることができる。

3.3. 撮影

1 枚目の撮影は、UT-ファントム内部の金属球が重なっていないか、照射野からはみ出していないかなどを確認しやすいように、被写体の真上から撮影することが望ましい。2 枚目以降は、手動またはオートポジショニング機能等の方法により X 線管球を移動させてから撮影を行う。

3.4. 画像送信・再構成

デジタルラジオグラフィー用コンソールから、画像処理が行われた撮影像を UT-Station に送信する。画像の受信を確認したら、断層像再構成に用いる撮影像を選択して、再構成を開始する。

3.5. 画像確認、PACS への送信

作成された断層像を確認し、問題がなければ、PACS 等へ転送する。

4. 画質

ユニバーサルモシシスの 5 枚の撮影によるトータルの照射線量は、一般撮影での 1 枚当たり線量と同等程度である。手ファントムを用いた一般撮影像(図 5(a))と UT-Station での断層画像(図 5(b))の例を示す。図 5(a)の小菱形骨の高さに合わせた断層画像であり、末節骨など実際には断層高さには含まれていない高さに位置する構造物から生じるリプルアーチファクトが僅かに見られるが、小菱形骨においては、リプルアーチファクトの影響も見られず、一般撮影画像では重畳してしまう骨構造を分離して視認可能である。



(a)一般撮影像(手ファントム)



(b) UT-Station 断層像(手ファントム)

図 5 手ファントムの一般撮影像(a)と UT-Station 断層像(b)

5. むすび

位置決め用治具 UT-ファントムと専用ソフトウェア UT-Station により、専用の機構を持たない X 線撮影装置でも、少数の撮影像から断層像の作成を可能にする手法「ユニバーサルトモシンセシス」を開発した。

富士フィルム AI 技術「REiLI」と AI 活用するためのプラットフォーム「SYNAPSE SAI viewer」について

富士フィルム株式会社 久永 隆治

1. はじめに

現在、AI (Artificial Intelligence) の分野は、ディープラーニング (深層学習) の登場により、飛躍的に発展している。その結果、様々な産業において AI 技術の活用が検討されている。医療業界においても同様であり、中でも画像診断の分野においては、画像診断機器の高精度化、多様化に伴い画像診断医の読影量が増加しているため、画像診断医に対する効率的な画像診断支援の解決策として、AI 技術への期待が高まっている。

当社は医師の画像診断を支援すべく、CR (Computed Radiography) に始まり、医用画像情報システム (PACS) および 3D ワークステーションなど、様々な画像診断装置・システムに画像処理技術および画像認識技術を搭載してきた。これらの技術に最新の AI 技術を組み合わせることで、従来よりも高いレベルの診断支援を実現することが期待できるため、AI 技術を活用した装置・システム開発を進めている。

本稿では、当社の AI 技術「REiLI (レイリ)」の開発の方向性と、AI 技術を活用するためのプラットフォームとして開発された「SYNAPSE SAI viewer (シナプス サイ ビューワ)」(*1)に関して、技術的な特徴を述べる。



図 1. SYNAPSE SAI Viewer

*1 SYNAPSE SAI viewer

販売名：画像診断ワークステーション用プログラム FS-V686 型

認証番号：231ABBZX00028000

SYNAPSE SAI viewer 用画像処理プログラム

販売名：画像処理プログラム FS-AI683 型

認証番号：231ABBZX00029000

2. 富士フィルムのAI技術「REiLI（レイリ）」

AI技術に関しては、様々なアプローチが存在している。当社のAI技術「REiLI」は、以下の3つのアプローチを軸に開発を進めている。これらのアプローチを組み合わせることで各種エンジンを開発し、組み合わせることによってソリューションを構成していく。

(1) 臓器認識技術（セグメンテーション）

撮影された画像から全身の各臓器およびその副構造を病態に依らず正確に認識する技術であり、後段の技術の性能のベースとなる。

(2) 個々の疾患の検出および鑑別

腫瘍や出血、炎症など様々な疾患の検出、計測を行い、見落とし防止や経時変化の定量化など、画像診断のワークフローに即した技術を検討している。

(3) ワークフロー支援

放射線科に向けては読影レポートを半自動で生成する技術、鑑別する際に参考に用いる類似症例画像の検索など、画像解析結果を効果的に活用するための機能を開発している。

3. AIを効果的に活用するためのプラットフォーム「SYNAPSE SAI viewer」

AI技術をワークフローの中で効果的に活用するためには、医用現場で使用されているプラットフォームの検討も重要となる。当社は読影ワークフローを支援すべく、「SYNAPSE SAI viewer」の提供を開始した。今後このSYNAPSE SAI viewerで利用可能な機能を開発していくが、現在提供されている機能を以下に紹介する。

(1) 臓器セグメンテーションおよびラベリング機能

CT画像から肝臓・腎臓・脾臓などの臓器構造を自動で抽出し、個人差により形状が異なる臓器も自動で抽出する（図2）。さらに、頸椎、胸椎、腰椎、肋骨に対しては、各々自動で抽出し、医師が疾患の場所などを指し示す際に引用する「骨番号」を自動的に付与し、CT画像の上に重ねて表示する。これにより、骨が見分けにくい画像での番号の振り間違いの抑制や医師の作業負荷軽減という形で読影ワークフローを支援することができる。




図 2. セグメンテーションの例（左：肝臓、右：肺野）

(2) 骨経時サブトラクション機能

過去画像と現在画像に対して、セグメンテーション技術によって抽出した脊椎の位置合わせを行った上で、過去画像と現在画像の差分処理を適用する。この処理によって算出された骨濃度の差分を可視化した画像を提供することで、骨の経時的変化の観察を支援する。

また、ラベリング機能により椎体の番号も自動でラベル付けされるため、医師のレポート入力作業に対する効率化が可能となる。図 3 に骨転移症例画像に対する本機能の適用結果を示す。




図 3. 骨経時サブトラクション機能

(3) Virtual Thin Slice 機能

一般的な読影に使用されるスライス厚 5mm 程度の CT 画像「Thick スライス」から、スライス厚 1mm 程度の CT 画像「Thin スライス」を仮想的に生成する。この機能により、過去に撮影された画像が Thick スライスであっても、Thin スライスと近い条件で比較読影を行うことができ、サジタル像や coronal 像における骨の構造や血管走行の観察の支援が可能となる。図 4 に本機能の適用したサジタル画像、VR 画像を示す。




図 4. Virtual Thin Slice 機能

4. おわりに

当社は、画像診断ワークフローの様々なシーンにおいて作業の効率化や質の向上を目指している。今後も画像情報を起点に診療支援 AI 技術の開発をさらに加速していく。また、これらの技術によって開発された機能を本ビューワに搭載していき、画像診断における医師の業務を支援し、画像診断ワークフロー全体の効率化を実現するソリューションの提供を目指す。

第 12 回 ROC セミナーを受講して

兵庫医科大学病院 放射線技術部 桐木 雅人

2019 年 9 月 7, 8 日に大阪急性期・総合医療センターにて開催されました第 12 回 ROC セミナーに参加させていただきました。

以前に、第 5 回臨床画像評価セミナーに参加させていただいたことがあり、その時に教えていただいた ROC 解析の知識をもとに現在では研究および論文作成を行っている最中でした。しかし、ソフトの動作や出力された結果の解釈の仕方などで悩む部分が多々ありました。そんな時に幸運にも関西で ROC セミナーが開催されるという知らせを聞きまして、分からない部分が聞けるチャンスだと思い、気が付いたらセミナー募集期間開始日の 0 時ちょうどに WEB ページにアクセスし ROC セミナーに応募していました。その思いもありまして当日は気合を入れて参加させていただきました。

2 日間の講義内容としましては、手計算および解析ソフトによる ROC/FROC 実験の他に、一対比較法を使用した観察者実験の講義といった盛り沢山の内容でした。ROC viewer/analyzer は実験結果をすぐに出力してくれるため、解析に費やす時間と労力が格段に少なくなり、実験がスムーズに進めることができる画期的なソフトであると思いました。また、ソフト上ではファイルを入力したらすぐに結果が出力されるため、どのような理論で計算されているか分からなかった部分でも、手計算による ROC/FROC 実験の講義のおかげで一つひとつステップを踏んで解析していくため計算過程が分かり、より理解を深めることができました。この手計算による ROC/FROC 実験は、我々の研究活動だけでなく新人や実習生などに向けた教育材料としても使用できる内容なので、今後も院内で活用させていただきたいと思います。

情報交換会では、短い時間ではありましたが白石先生をはじめとする講師の方々とお話することができ、講義中には時間の関係で聞けなかった内容の質問ができ、充実した時間を過ごすことができました。また、ROC 解析を使用した研究を行っている他施設の受講者様とも研究についての熱い語り合うことができ、自身の今後の研究活動を行っていく上でのモチベーションにも繋がりました。今回学ばせていただきました内容を今後の研究活動に取り入れ、学会発表や論文執筆に生かしていきたいと思います。

また、セミナー後に実際に ROC, FROC, 一対比較法をそれぞれ取り入れた複数の研究を同僚とともに計画し、早速 ROC viewer/analyzer を使わせていただいております。ソフトの動作がうまくいかないことがあり、福岡先生に図々しくもメールにてファイルを送り付けてしまい大変ご迷惑をおかけしました。しかし、福岡先生は早急かつ丁寧にご対応していただき、2~3 回のやり取りのもとその日のうちに問題が解決しました。本当にありがとうございました。こういったセミナー後のご対応も迅速にいただけるため、非の打ちどころがないセミナーであると感じました。

最後になりますが、本セミナーを企画・運営して下さいました日本放射線技術学会画像部会の講師の方々、会場設備を担当して下さいました日本放射線技術学会近畿支部のスタッフの皆様にご心より感謝申し上げます。

第 12 回 ROC セミナーを受講して

聖マリアンナ医科大学附属プレスト&イメージングセンター 古谷 悠子

2019年9月7,8日に大阪で開催された第12回ROCセミナーに参加させていただきました。

私がROCを初めて知ったのは当然学生時代ですが、就職してからは業務で手一杯であり研究などしていなかったため、正直ROCのことなどすっかり忘れておりました。その後、論文等でROCを目にする機会はあったものの、研究のプロが行うものという感覚でしかありませんでした。そんな折、2017年に日本放射線技術学会の『乳がん画像診断における診療放射線技師レポートの有用性の検証』という班研究に班員として参加する機会を得たことが、ROCが身近な存在となった大きなきっかけです。この研究内容は、医師によるマンモグラム読影において、技師レポート参照が医師の読影結果に与える影響をFROC観察者実験で検証し、技師レポートの読影の補助としての有用性を証明するというものでした。私は主に観察者という立場で携わり、観察者実験の準備から解析は白石先生が行っていただきましたが、この研究を通じて、もしかして私達でもROC実験ができるかもしれない！という大きな期待を抱いたことは今でも忘れられません。このご縁をきっかけに、白石先生にご指導いただきながら、私の専門分野であるマンモグラフィにおいて、FROC観察者実験を用いた研究を行うことができました。しかし、望んでいたスタイルの研究ができたことは非常にうれしく、研究の幅も大きく広がりましたが、解析などについてはほとんど理解できておらず、次の研究では準備から解析まで自分の力でやりたいと強く思い、本セミナーを受講する運びとなりました。

今回のセミナーは、ROC解析の基礎や一対比較法、観察者実験の計画法などの講義と、手計算によるROC曲線の作成や、ROC解析用ソフトウェアを用いたROC実験と統計的有意差検定等の演習という内容でした。2日間という限られた時間の中で行うには非常にタイトなスケジュールでしたが、私が習得したかったことはほとんど網羅されており、そして「知る」、「学ぶ」、「経験する」という3本柱でのセミナー構成によって、使える技術を身につけることができ、非常に充実した楽しい時間を過ごすことができました。また、講師の先生方は非常に丁寧に指導して下さり、セミナーを通して、「教える」のではなく、「使えるようになってほしい！」という熱い思いが伝わってきたのが印象に残っています。

日々病院で勤務する私のような技師にとって、時間等のさまざまな制約の中、業務と研究を両立することは簡単ではありませんが、臨床の経験が研究の材料となり、研究の成果を臨床に還元できることは技師にとって非常にうれしいものです。今回習得したことを是非今後の研究に活かしていきたいと思えます。

最後に、セミナーの企画・運営をしていただいた日本放射線技術学会画像部会の皆様、講師の白石先生、田中先生、福岡先生に心より感謝申し上げます。

第12回 ROC セミナーを受講して

福岡大学病院 放射線部 田畑 成章

この度、平成31年9月7日、8日に大阪府で開催されたROCセミナーに参加させていただきました。昨年度は北九州で開催されたDRセミナーに参加させていただき、物理評価を学びました。今年度は視覚評価についても学び、自分の研究スキルを増やしたいと考え申し込みました。

1日目は、概論から始まりました。セミナーの心構え、視覚評価とはどんなものか、講師の先生方が今回学んで欲しいこと等わかりやすく説明していただきました。概論から入ることで、学生時の知識を思い出すとともに、これから学ぶ内容が明確化され、2日間の目標を定めることができました。

概論を終えると早速ROCについての講義、実習が始まりました。講義、手計算による実習、ソフトウェアを用いた実習の順になっており、初心者でも理解しやすい手順となっていました。手計算による解析を行うことで評定者、計画者の立場を体験することができ、試料作りのポイント等を理解することができました。ソフトウェアにおいても、参加者がエラーを起こすことなく、実習をすることができており、作成された先生方の技術力には驚くばかりでした。チューターの先生方も沢山回ってきていただき、全員がついてこれているか確認しながら実習が進んでいきます。そのため『実習についていけないかもしれない』と不安がある方も安心してセミナーに参加することができると思います。

セミナー1日目の後には懇親会にも参加させていただき、セミナー中では聞くことのできなかつた質問を先生方にすることができたり、お話しする機会の少ない九州以外の方の話聞くことができとてもよい刺激になりました。

2日目からも同様の手順で演習が進みました。最後には田中利恵先生が初めてROCセミナーに参加した際にどの様なことを感じ、施設に帰った際にどんなところで苦勞をしたかを話してくださいました。セミナーの内容だけでなく、セミナーを終えてからどのように臨床、研究に生かしていけばよいのかを考えることができました。

今回のROCセミナーでは、内容を理解するのは勿論のこと、実際の手技、自施設に持ち帰った際のデータ作成の方法までじっくり教えていただきました。そのため、セミナー開始時には内容についていけないか不安がありましたが、終了時には早く帰って実践してみたい気持ちになりました。『セミナーに行ってみたくて、怖い』と思う方でも行ってほしいセミナーでした。

最後になりますが、このような貴重なセミナーを準備して下さった、白石順二先生、田中利恵先生、福岡大輔先生、その他スタッフの皆様へ深く感謝申し上げます。

第 20 回 DR セミナーに参加して

産業医科大学病院放射線部 **大田 哲**

この度、令和元年 12 月 7 日、8 日に群馬県高崎市、群馬パース大学で開催された第 20 回 DR(デジタルラジオグラフィ)セミナーに参加させていただきました。今回私が本セミナーに参加させていただいたのは、診療放射線技師として働き始め 2 年が経ち、臨床の知識だけでなく物理的な知識も身につけてはならないと感じたことがきっかけでした。実際、CR から DR へと移行していく施設が増えていく中で検出器の物理特性を測定し、画質の品質の確認や向上、被ばくの低減に努めていくことは診療放射線技師の重要な仕事であると感じます。

本セミナーでは、入出力特性から始まり解像特性、NNPS、DQE と講義を受けた後、演習をおこなう流れで進行していきました。各特性は大学の講義や国家試験で聞き覚えのある単語でしたが、理解はできていませんでした。丁寧に講義をしてくださり、実際に演習をおこなうことで理解を深めることができました。各特性の算出は、用意していただいた試料から Image J で得られた値をもとに計算用の Excel シートを用いておこなっていきました。疑問に感じたこともすぐに講師の方に質問できる環境にあったこと、参加者の進行状況を確認しながら演習がおこなわれていくことから置いて行かれるなどの心配はありませんでした。今回は試料が用意されていましたが今後は自身で試料を集める必要があります。データの取得方法についての講義では、試料を集める実際の映像を見ながら解説していただき、試料集めにおける注意点も聞くことができました。

本セミナーに参加して感じたことは、本セミナーは講師の方々の測定してきた苦勞を含めた経験がすべて詰まっているということです。用意していただいた試料も Excel シートもすべて、なるべく簡単に特性を算出できるように作成されています。ここで重要なのは参加したで終わるのではなく、試料集めから特性の作成まで実際におこなってみることであったと感じました。本セミナーで学んだことを活かして物理特性の測定に取り組んでいきたいです。今後もこのようなセミナーが開催されることを希望いたします。

最後になりますが、このような貴重なセミナーを開催して下さった東出 了先生、柳田 智先生、小野寺 崇先生、由地 良太郎先生、その他スタッフに皆様に深く感謝申し上げます。

第 20 回 DR セミナーを受講して

東京医科大学八王子医療センター 放射線部 大野 敦

近年 FPD の普及が進み、当院においても来年度 CR システムから FPD システムに更新される予定になっている。そこで物理特性を深く理解し、適切な撮影条件を設定できればと思っている。また透視装置にも興味があり、物理評価深く理解し活用することで、透視画像の改善につながるのではと思い、第 20 回 DR セミナーを受講した。

このセミナーは画像解析ソフト imageJ と Microsoft excel を使い画像解析をする。教材は「標準デジタル X 線画像計測学」を使い、入出力特性・MTF・NNPS・DQE の物理特性について学ぶことができる。

セミナーは講義・演習の流れになっており、講義で各物理特性を学び、演習を行うので理解が深まり、実践的なスキルを習得することができた。また実際に自施設で行うために、データの取得方法を動画でジオメトリの解説や注意点などの説明があった。

入出力特性については log システム（一般撮影）とリニアシステム（マンモグラフィー）の入出力特性を行った。log システムとリニアシステムの違いを理解することができた。

MTF についてはエッジ法・チャート法から算出した。MTF を得るために MTF デバイスを傾けて Presampled MTF で評価する。そして excel を使いエッジ法・チャート法から MTF を算出する過程を学ぶことができた。

NNPS については、NNPS を算出するまでの過程を学ぶことができた。また NNPS は解析を数十回と行わないとなめらかな曲線を描くことができない、かなり時間のかかる作業であることが分かった。そこで講師の先生が開発したプログラムを使い瞬時に NNPS を求め、なめらかな NNPS 曲線を描くことができた。

DQE は検出器の性能評価が出来る。MTF・NNPS から算出し、今回の線質 RQA5 の photon 数から DQE が算出される。今回はリニアシステムの DQE を算出した。

このセミナーは非常に講師・チューターの距離が近く、講義内容などの疑問は講義の合間や空いている時間に聞く事が可能で、理解が深まり非常に有意義な時間を過ごすことができる。私個人として自施設の FPD 化に向け、CR システムのデータ収集など今やるべきことが明確になった。またこのセミナーで imageJ マクロを使ったことで、自分でもマクロが組めるようにプログラミングに興味を持ち学ぼうと思った。二日間、DR セミナーに参加し、非常に刺激のある充実した時間を過ごすことが出来た。講師・チューターの皆様に感謝を申し上げたいと思う。

線形システムの基本と逆フィルターについて


国際医療福祉大学 保健医療学部 放射線・情報科学科 西木 雅行

1. はじめに

医用画像の形成過程は線形システム (linear system) で良く近似でき、それによって有用な数学的解析手段が使えることもあり、linear system は広く利用されてきた。Linear system 理論を医用画像に最初に応用したのは、**Dainty and Shaw**[1] が嚆矢とされており、引き続き **Burrett and Swindell**[2] で詳述され、以後さまざまな論者 [3] [4] によって解説されてきたので、今更ここで繰り返すこともないかもしれないが、せっかくの機会なので筆者の理解している手順で解説してみることとする。解説は主に文献[2]の記述に沿う形で進める。

2. Linear system

Linear system の定義 : 下図で a と b は x に依存しない定数とする。



図で、例えば x は検出器上の位置で、 $f(x)$ はその位置に入射する X 線強度、 $g(x)$ は検出器のデジタル出力と考えれば良い。Linear system の出力は、個々の入力に対する個々の出力の和になるということである。検出器出力が X 線強度に比例すれば、この検出器は問題なく linear system と考えてよいが、例えば対数変換して出力する検出器なら、linear system とはならない。何故なら、

$$g_1(x) = \text{Log}[f_1(x)], g_2(x) = \text{Log}[f_2(x)] \quad \text{で、}$$

入力が $a \cdot f_1(x) + b \cdot f_2(x)$ なら、出力は

$$g(x) = \text{Log}[a \cdot f_1(x) + b \cdot f_2(x)] \quad \text{となるが、これは } a \cdot g_1(x) + b \cdot g_2(x) \quad \text{とはならないからである。}$$

Log 変換して出力される FPD や CR の画像で linear system の恩恵である MTF などを使おうと思ったら、まず何より先に線形化 (linearization) を実行しなければならない。他の例として、

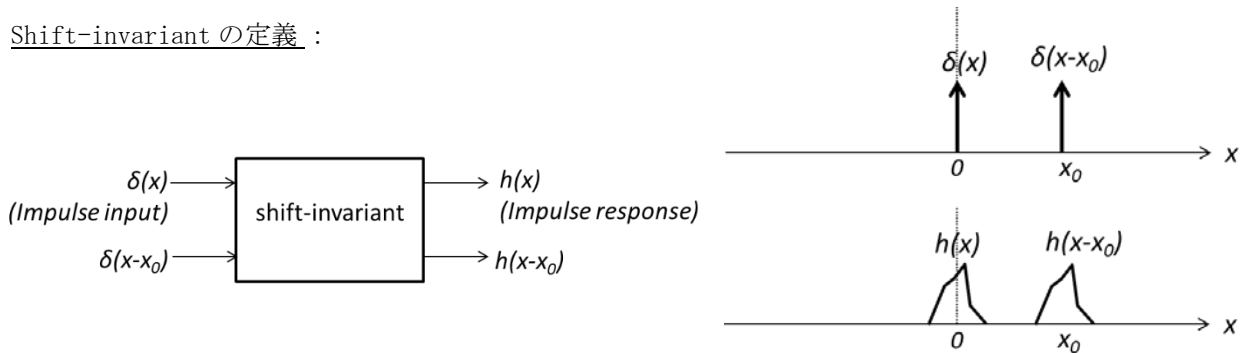
$$g(x) = p \cdot f(x) + q \quad (q \neq 0) \quad \text{の時、} g(x) \text{ と } f(x) \text{ は直線関係にあるので linear system だと思ってしまう}$$

かもしれないが、一般には上の定義に合わず、linear system とはならない。また逆の例として、入力を微分して出力するシステム $g(x) = d/dx[f(x)]$ を考えると、これは linear system となる。これらの証明は練習問題として残しておきます。

3. Shift-invariant system

さて、linear であるだけではまだ大して役に立たない。Linear であることに加えて、shift-invariant でなければ、後で述べる convolution が使えないからである。文献[1]では stationary という語がつかわれているが、後の文献では shift-invariant という語で統一されている。Shift-invariant には様々な邦訳がなされており、例えば、位置不変性、移動不変性、定常性、不変性、等々があり、統一感がないので、ここでは shift-invariant と記すことにする。

Shift-invariant の定義 :




$\delta(x)$ はデルタ関数である。入力 $\delta(x)$ である時の出力 $h(x)$ を IR (Impulse Response) あるいは PSF (Point Spread Function) と呼ぶ。一般に IR は入力位置によって形状が異なるが、特別な場合として形状が不変で、入力位置に応じた移動だけが起こる場合を shift-invariant と言う。すなわち、入力 $\delta(x-x_0)$ に対して出力が $h(x-x_0)$ であるということである。通常のアナログフィルムシステムは shift-invariant と言えるが、デジタル X 線システムは厳密には shift-invariant ではない。デジタル検出器は有限の画素サイズを持つので、画素内のどの位置に X 線粒子が入射したのかに応じて出力形状が異なってしまうからである。この困難はデジタル系の MTF を求める際に際立ってくるので、通常は oversampling の手法の導入によって解消を図るのが一般的である [5]。

shift-invariant ではないシステムの例として、I. I. -TV システムが挙げられる。I. I. -TV では、中心部と周辺部では IR 形状が異なっている。

4. Linear shift-invariant system : LSI system

Linear と shift-invariant の両方が備わっているシステムが、以後の議論の対象となる。以後このシステムを LSI (Linear shift-invariant) システムと呼ぶ。



上図は、IR が $h(x)$ である LSI システムでの入出力を表している。最下段の積分 $\int_{-\infty}^{\infty} f(x') \cdot \delta(x-x') dx'$ は、入力が無数のデルタ関数の和である場合を示し、linear system であるからその出力は個々の入力に対する個々の出力の和である積分 $\int_{-\infty}^{\infty} f(x') \cdot h(x-x') dx'$ になることを単に示しているに過ぎない。ところが、デルタ関数の性質より $\int_{-\infty}^{\infty} f(x') \cdot \delta(x-x') dx' = f(x)$ となる。デルタ関数のこの性質は sifting property と呼ばれ、適当な訳は見当たらない。sift には「ふるいにかける」という意味があり、shifting と似ているが別の語であるから、混同しないように注意が必要である。一般に sifting property は $\int_{-\infty}^{\infty} f(x') \cdot \delta(x'-x) dx' = f(x)$ と書かれるが、デルタ関数は偶関数であるので $\int_{-\infty}^{\infty} f(x') \cdot \delta(x-x') dx' = f(x)$ も成り立つ。ここまででわかったことは、LSI システムでは入力が $f(x)$ の時、出力は $\int_{-\infty}^{\infty} f(x') \cdot h(x-x') dx'$ になるということである。この式は $f(x)$ と $h(x)$ の convolution になっているので、これが求めている重要な性質である。

LSI システムの出力は、入力と Impulse Response の convolution となる。

更にもう一歩進んで、LSI システムの別の重要な性質を見てみよう。それは、LSI システムへの入力が指数関数 $e^{2\pi i u x}$ という特別な場合である。この時の出力は、 $\int_{-\infty}^{\infty} e^{2\pi i u x'} \cdot h(x-x') dx'$ となるが、 $x-x'=x''$ と変数変換することにより、

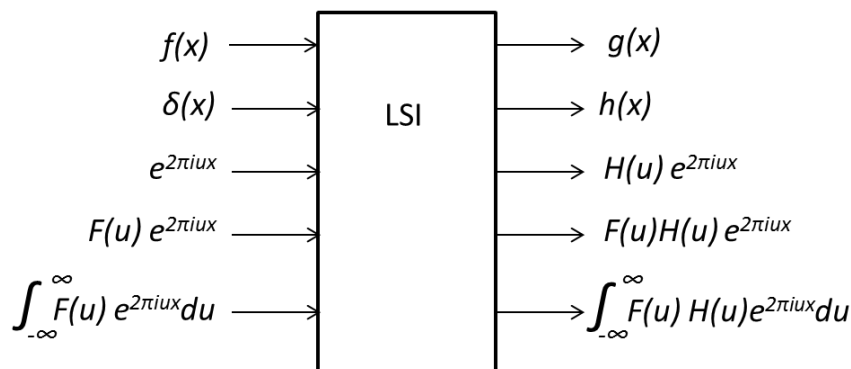
$$\int_{-\infty}^{\infty} e^{2\pi i u x'} \cdot h(x-x') dx' = \int_{-\infty}^{\infty} e^{2\pi i u (x-x'')} h(x'') dx'' = e^{2\pi i u x} \int_{-\infty}^{\infty} e^{-2\pi i u x''} h(x'') dx'' = e^{2\pi i u x} H(u)$$

ここで $\int_{-\infty}^{\infty} e^{-2\pi i u x} h(x) dx = H(u)$ と置いた。これは $h(x)$ のフーリエ変換となっている。変数 u は空間周波数を表している。というわけで、LSI システムの重要な性質として以下が得られる。

LSI システムに指数関数 $e^{2\pi i u x}$ が入力しても出力は同じ形をしており、ただその強さのみが変わる。

強さの変化は $H(u)$ で表されるので、これは transfer function と呼ばれる。 $H(u)$ は一般には複素数である。 $h(x)$ と同様に、入力 $f(x)$ についてもフーリエ変換 $F(u)$ は $F(u) = \int_{-\infty}^{\infty} e^{-2\pi i u x} f(x) dx$ と定義できる。今度は LSI システムへの入力が $F(u)e^{2\pi i u x}$ の場合を考えてみる。LSI システムにとって $F(u)$ は単なる定数

に過ぎないので、この時の出力は単純に $F(u)H(u)e^{2\pi iux}$ となるのは当然である。ならば、入力がいこれらの和（積分） $\int_{-\infty}^{\infty} F(u)e^{2\pi iux} du$ である場合の出力はどうなるであろうか。LSI システムであるから、出力は個々の入力に対する出力の単なる和（積分） $\int_{-\infty}^{\infty} F(u)H(u)e^{2\pi iux} du$ となる。ここまですを図示すると下図のようになる。



図中の最下段の積分であるが、 $\int_{-\infty}^{\infty} F(u)e^{2\pi iux} du$ は $F(u)$ の逆フーリエ変換であるから、これは $f(x)$ である。 $f(x)$ に対する出力が $g(x)$ であるから、 $\int_{-\infty}^{\infty} F(u)H(u)e^{2\pi iux} du$ は $g(x)$ でなければならない。式で書くと、

$g(x) = \int_{-\infty}^{\infty} F(u)H(u)e^{2\pi iux} du$ であるが、同時にこの式は $F(u)H(u)$ の逆フーリエ変換の式でもある。 $g(x)$ のフーリエ変換を $G(u)$ と置くと、 $g(x) = \int_{-\infty}^{\infty} G(u)e^{2\pi iux} du$ と書けるので、ここから次の重要な結果が導かれる。

LSI システムでは $G(u) = H(u)F(u)$ が成り立つ。

ここで使った指数関数 $e^{2\pi iux}$ は複素数であり、医用画像を考える限り複素数入力などあり得ない訳だが、ここは単に数学的な便利さを利用するためであると割り切れれば良い。この便利さを追求した結果、フーリエ変換という大変有用な数学的手段が得られるわけなので、複素数使用には確かに意味がある。あるいは、例えば現実の実数入力である $\cos(2\pi ux)$ は、 $\cos(2\pi ux) = 1/2(e^{2\pi iux} + e^{-2\pi iux})$ と複素指数関数の一次結合で表せるので、LSI システムでの出力が簡単に計算出来る。しかも IR が実数なら出力も確実に実数になるので、複素数だからと言って怯むことはない。

5. LSI system の応用

$G(u) = H(u)F(u)$ の重要性は計り知れない。u は空間周波数を表し、transfer function : $H(u)$ は u の関数なので、 $H(u)$ を見れば LSI システムの周波数応答がわかる。ただ、 $H(u)$ は一般に複素数なので、取り扱いが面倒である。そこで、入力信号の強度（振幅）が出力にどれだけ伝達されるかを表す実数値の指標として $\frac{|H(u)|}{H(0)}$ が使われ、これは MTF (Modulation Transfer Function) と呼ばれる。ここで、 $H(0)$

は定義から確実に実数なので絶対値記号を使っていない。また、 $\frac{H(u)}{H(0)}$ は OTF (Optical Transfer Function)

と呼ばれ、これは複素数なので、振幅変調と共に位相変調も表現している。

$G(u) = H(u)F(u)$ はまた、逆フィルターの設計にそのまま使える。例えば $H(u)$ がボケを起こす IR である場合、このボケを回復するには単純に $G(u)/H(u)$ を計算して逆フーリエ変換すれば良い。但し、理論的にはこの通りで良いのだが、現実にはノイズ処理等の問題があってそう単純ではない。本来この稿は逆フィルターの設計にまで踏み込む予定だったが、紙数が尽きたのでそれは別の機会としたい。

参考文献

- [1] J. C. Dainty and R. Shaw, "Fourier Transforms," in *Image Science* (Academic Press, London, 1974)
- [2] H. H. Barrett and W. Swindell, "Theory of Linear Systems," in *Radiological Imaging: The Theory of Image Formation, Detection, and Processing* (Academic Press, San Diego, CA, 1981)
- [3] I. A. Cunningham, "Applied Linear-Systems Theory," in *Handbook of Medical Imaging*, edited by Beutel, J., Kundel, H. L., and van Meter, R. L., (SPIE, Bellingham, WA, 2000), Vol. 1, Chap. 2.
- [4] 石田隆行, 桂川茂彦, 藤田広志, "医用画像ハンドブック", (オーム社, 2010)
- [5] Fujita H, Tsai D Y, Itoh T, Doi K, Morishita J, Ueda K and Ohtsuka A, "A simple method for determining the modulation transfer function in digital radiography" *IEEE Trans. Medical Imaging* **11.1** 34-39 (1992).

デジタル X 線画像技術のこれまでの進化について

徳島文理大学 保健福祉学部 診療放射線学科 本田 道隆

1. はじめに

1895年に X 線が発見された数年後、つまり 1900 年頃にはすでに X 線の医用応用が行われていたとの記録がある。その後 1940 年頃に回転陽極 X 線管や間接撮影など X 線動画診断の基礎となる撮影技術が臨床診断に応用され、1960 年頃には X 線テレビにより電子技術を使用する臨床動画診断がスタートした。さらに 1980 年頃にはデジタル時代の端緒となるデジタル X 線画像診断装置が登場した。そして丁度 21 世紀の開始とほぼ同時に平面検出器が X 線診断に使用され始め、2000 年という年は X 線技術を語る上でも区切りの良い年となったが、実は、この年の前後には線質フィルタやエッジ保存型ノイズ低減処理など現在のデジタル X 線診断画質に大きな進化を与えている技術も製品化されていた。このように、振り返ると約 20 年という間隔で X 線診断分野に大きな基盤技術のブレークスルーがあり、そこで生まれた技術は現在も重要なベース技術として現在の X 線診断を支えている。ちなみに、この周期で進化が続くとすれば 2020 年の今年も画期的な基盤技術が生まれる期待があるわけだが、最近の一大ブームを築いている AI 技術の X 線画像診断応用や、X 線エネルギー情報を診断情報に取り入れることが可能となるフォトンカウンティング技術がそれに該当するかもしれない。これらの研究が実用化のフェーズに入りここ数年のうちに広く臨床応用されるようになれば 20 年ごとのブレークスルーとしてまた新たな記録が刻まれる期待が高まる。

さて、今回の画像部会入門講座では、現在のデジタル X 線診断技術がどのように構築されてきたかを、20 年前に行われた「平面検出器」「線質フィルタ」「エッジ保存型ノイズ低減」といったキーワードを中心に振り返ってみようと思う。温故知新という言葉もあるように、これまでの重要なブレークスルーを振り返ることにより若い方々からさらに新しい知見が生まれることも期待したい。詳細な内容は当日に譲るが、ここでは以下にその概要を述べる。

2. 平面検出器について

一般に、X 線の検出器は図 1 に示すように 2 つの過程で成り立っており、過程 1 は X 線検出素材の“物性”、過程 2 はいわゆる人工的なテクノロジーで性能が決定される。平面検出器は、過程 1 について、平面上での検出膜結晶を厚くできるため DQE が向上したことなどの利点がよく解説されるが、現時点に立って強く思うのは過程 2 についての特に大きな転機である。それまでの代表的なデジタル X 線検出器である CR やイメージインテンシファイアは医用機器特有の技術が使われていたため、専門メーカーだけが開発する一種の閉鎖的な産業構造であった感が強い。しかし、平面検出器の過程 2 では液晶テレビや CMOS カメラなどとの共通点が極めて多く、そのようなイメージ

ング産業の技術進化とともに開発を進化させることが可能になった。例えば大型液晶TV で使われるシームレスタイリング技術や各種 IT 技術などはすでに応用されて久しいが、今後も 4K,8K テレビ技術等にみられる高精細、高速度化などの要素技術が X 線検出器の解像度やパフォーマンス向上に関係してくる可能性もあり、他産業とのオープンな技術共有化の恩恵を受けやすくなったことは X 線検出器の大きな転機であったといえる。また、このオープン化はイメージング技術に強みを持つ多くのメーカ

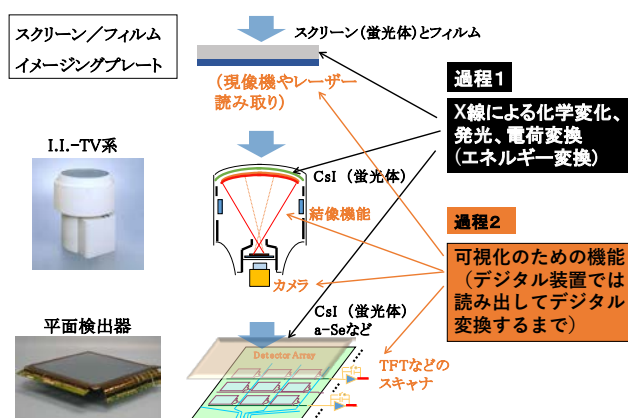


図1 X線検出器の2つの過程

の参入も可能にしており、価格、供給、付加価値追求など多くの面でデジタル X 線検出器としての合理的な姿になった。今後、フォトンカウント検出器などのさらなる進化に向けた研究が進行しているが、分野を超えた幅広い開発研究に基づく有力な技術が応用される期待もあり、当時の平面検出器の登場は大きなブレークスルーであったと改めて振り返る次第である。

なお、平面検出器の画質性能については、これまでに各所で多くの解説が行われてきたので本稿では割愛するが、講座では要点についてレビューを加える予定である。

3. 線質フィルタ (付加フィルタ、ビームフィルタ) について

この“フィルタ”の目的は、X 線画像信号への寄与が少なく人体に有害な成分を文字通り濾し取って X 線を照射し、低被ばくで画質の良い画像を得ることにある。X 線物性に基づけば、X 線低エネルギー成分 (軟線成分) をできるだけ選択的に低減させればよいことが理論的にもはっきりしているため、適切な材質と厚みの発見を目的とした研究がかなり以前から継続的に行われていた。この研究そのものはデジタル画像とは直接関係はないが、デジタル化が進み、コンピュータ上でノイズや CNR の計測が容易になると加速した。特に 1980 年半ば頃からは合金、重金属を含めた多種金属の組み合わせなど、様々な評価が報告されている。

この線質フィルタ研究は 1990 年台後半になって一応の落ち着きがみられた。IVR 透視など特に被ばくが多いとされた臨床検査や治療において銅の被ばく低減効果が臨床施設から報告され始めたこと、それを受けて銅を「付加フィルタ」として製品化する動きが出始めたこと、などによるものだったと振り返るが、その背景には IVR の急速な普及にともなって X 線管がパワーアップしてきた時期でもあったことが関係する。すなわち、銅が付加フィルタとして効果を発揮するのは数百ミクロン以上の厚みがあるときであり、十分な X 線量を X 線管から出力して十分に軟線を濾過したものを被写体に照射することで効果が現れることがわかってきた。現在、銅は重要な付加フィルタとして多くの製品に標準搭載されるようになったが、当時の低被ばくニーズ、デジタルシステムで

の画質評価機能、X線管パワーアップなどの条件がそろったことによりこのような基礎技術が生み出されたといえる。

さて、1995年頃に行われていた研究の一部をここで紹介する。図2は、グラフ中に示す金属を線質フィルタとして管電圧110kV、被写体表面が500 μGy になるようなmAs値設定で照射したX線スペクトルをシミュレーションで計算した結果である。被写体表面を(A)、

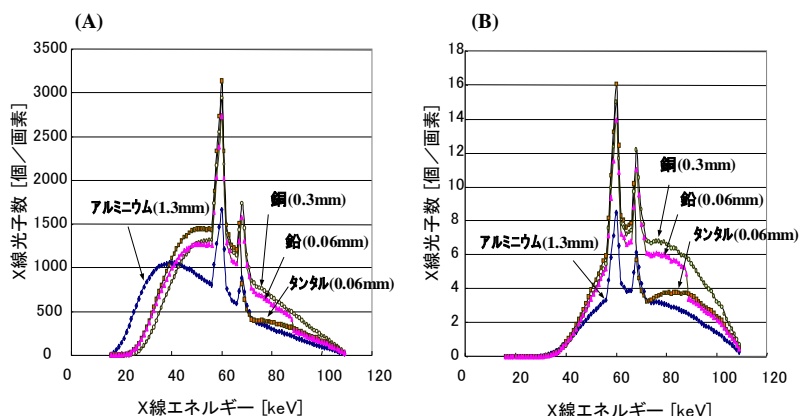


図2 各種金属の効果の比較

被写体透過後の直接線スペク

トルを(B)に示す。この図から、アルミニウムでは20~40keVの軟線スペクトルが被写体に照射される一方、その他の金属ではこの成分が効果的に削減されて被ばく低減効果が生まれることがわかる。中でも銅は入手しやすく変形もしにくいいため有力な付加フィルタとして現在使用されているが、重金属のタンタルも実は興味深い性質を持っており、67keVにあるK-edgeのためそれ以上の高エネルギー成分を低減させる効果を合わせ持つ。そのため散乱線が低減し、特に厚い被写体でCNRが改善されることが実験でも確かめられた。タンタルはレアメタルであり入手や価格の点で一般には使いにくいですが、さらなる研究により解決されていくことを期待したい。講座では、このような特徴のあるフィルタについてこれまでに得られた知見をもう少し詳しく紹介する予定である。

4. エッジ保存型ノイズ低減処理手法

X線画像のデジタル化が始まって間もない1980年前半にアンシャープマスク処理やDSAなどが製品化されるとデジタル画像処理がX線画像観察の支援技術として広く研究されるようになった。その後、線形空間フィルタおよび画像加減算を主とする時間(テンポラル)フィルタがハードウェア技術の進歩に伴い高速化され、動画を含むX線画像全般で使用されるようになり、しばらくはこの組み合わせや診断目的に沿った処理パラメータの適正化などが続いた。しかし、このようなフィルタは本質的に効果の限界がある。たとえば線形空間フィルタではエッジや細かい信号の強調とランダムノイズ低減を同時に行うことができない。工学系大学などではこの限界に対して1970年代後半から効果的な手法が研究されていたが、医用画像系においても1990年代から臨床画像応用を目的とした「エッジ保存型ノイズ低減処理」の報告が目立ち始めた。この処理法は字義通り、エッジ部(信号の高周波成分を意味するため細かい信号を含むこともある)の鮮鋭度やコントラストを劣化させずにランダムノイズ成分を低減させる作用を意味する。具体的な手法は様々であるが、大別すると、フィルタ演算内にノイズと信号を弁別する機能を持ちそれぞれで個別に処理を行うタ

イプ、パターン認識などで識別対象とする信号を抽出してその信号領域とそれ以外の領域で独立した線形処理を行うタイプ、の2種類の報告が多いような印象がある。そして、この処理は2000年頃から特にIVRに使われるアンギオシステムを中心に、透視画質やデジタルシネ画質改善の有力手法として多用されるようになった。

図3はこの処理の一例である。IVRにおいて、ガイドワイヤを視認しやすくする目的で研究されている例であり、左側の原画像内を上下に走行しているガイドワイヤのコントラストをそれほど劣化させることなくランダムノイズを低減させようとしている。この例では、線状陰影の検出を行うパターン




図3 エッジ保存型ノイズ低減処理の例（右側が処理後）

ン認識でガイドワイヤ領域を抽出し、ガイドワイヤ領域にはその走行方向に沿った方向に平滑化、ガイドワイヤ以外の領域には通常の平滑化を行うような処理が行われている。平滑化処理の平滑化の度合い（強さ）はパターン認識の抽出の確からしさに応じて変化させている。

このようにエッジ部や細かい陰影のコントラストを劣化させずにノイズを低減させる処理は、次第に応用範囲を広げ、現在ではすべてのデジタルX線画像診断装置で使用される画像処理技術になってきている。近年では、この処理技術においてノイズと信号の弁別を行う目的でAIが用いられるようになってきており、今後、弁別精度がさらに向上してより効果的な画像処理に進化していく期待が大きい。

この処理に加え、画像の明るい部分（肺野など）と暗い部分（縦郭など）の極端な濃度差を縮めて背景濃度を平坦にしたうえで細かい信号を強調する「ダイナミックレンジ圧縮処理」もほぼ同時並行で製品化が進んできた。講座ではこの処理も含め2000年頃から現在に発展したデジタル画像処理技術の進展を紹介する。

5. おわりに

2000年から今日までの20年間におけるデジタル画像技術の変化のスピードは当時の想像を超えるものがあつた。この勢いで進むと次の20年間にはどのような姿になるのか全く浮かんでこないが、変化のスピードに惑わされることなく技術の進歩を医療の進歩に確実に結び付けることが放射線技術学の使命であることを忘れずにフォローしていきたいものである。

金沢大学 医薬保健研究域 保健学系

田中研究室 の紹介

金沢大学医薬保健研究域保健学系 **田中 利恵**

2017年4月、前身の真田研究室から「新たな医用画像検査法の開発とその評価」の看板を引き継ぎ、田中研究室が発足しました。長年取り組んできた①X線動態撮影法の開発（金沢大学附属病院，ユニカミノルタとの共同研究）を主軸に，②バーチャルファントムを用いた仮想臨床試験（デューク大学との共同研究）や，③大規模肺がんCT検診データベースを用いた未病のコンピュータ支援診断の開発（石川県予防医学協会，金沢医科大学，金沢大学附属病院，熊本大学との共同研究）など，世界的にユニークな研究プロジェクトを展開しています。2018年11月には，共同研究先の企業からX線動態撮影装置と動画解析ワークステーションが実用化されました。今後は保険収載を目標に，本学附属病院の医師らと臨床試験を展開していく予定です。さらに，2020年4月1日からは，本学に新設されるAIホスピタル・ユニバーサルヘルスケア研究開発センター（AIセンター）所属となり，AI画像データ・AI診断の研究を展開していく予定です。

そんな田中研究室ですが，2019年9月，改修工事で一新された校舎に引っ越しました。現在は，お掃除ロボットが室内美化に務めてくれる研究室で，大学院生5名と学部生3名が日々切磋琢磨しています（写真1）。週1回のペースで開催する研究室ゼミ（写真2）と，個別の研究進捗報告とで，舵取りしつつされつつ，学部生は地方支部大会での発表を，大学院生は国際大会での発表を目標に，各自の研究テーマに取り組んでいます。卒業研究の開始が4年生の4月からなので，半年ちょっとで支部大会の抄録を作成することになります。メンバー全員の誕生日ごとにホールケーキ（今年は8個）でのお祝いと，食べ放題のケーキバイキング（今年は8名で96個）をエネルギー源にがんばってもらっています（ある意味すごく高燃費なのかも）。研究室の活動報告をブログで報告していますので，お手すきの際に「田中研究室」をGoogleって，御覧いただけましたら幸いです（<http://tanakalab.w3.kanazawa-u.ac.jp/>）（写真3）。

さて，ここからは社会人院生の受け入れについてです。当研究室では，画質評価・画像処理・シミュレーション研究等，画像に関連する研究テーマで，社会人院生を受け入れ可能です。特に，X線動態撮影に関する研究を得意としています。2001年から（真田研究室時代から），撮影条件や撮影時の合図の出し方の検討といった「画像を作る」ところから，X線動画像に投影されている機能情報を定量化・可視化する「動態解析技術の開発」，そして開発手法の診断能を評価するための「動物実験」や「臨床研究」まで，新しい画像診断体系の開発に必要なプロセスを一貫して行ってきたことから，X線動態撮影に関するノウハウ・解析ツール・リソースを多く有してい

ます。X線動態撮影は、その画像診断体系の構築が急務であることから、研究テーマの宝庫と言えます。『所属施設にX線動態撮影装置が導入されたので、何か研究を始めたい！』という方は、長期履修制度（※）もありますので、まずはお気軽にご相談ください。

当研究室では、臨床の先生方や企業の方々との協力体制のもと、X線動態検査をはじめとする新しい医療技術の開発にチャレンジし続けます。アイデアを形にするために必要な、分析力・計画力・行動力、そしてチームを束ねる人間力 etc... 当研究室では、臨床のニーズをいち早くキャッチし、実用化に向けた初期開発ならびに臨床評価において、中心的な役割を担える人材育成を目指しています。開設からまだ3年目と若い研究室ではありますが、今後ともよろしく願いいたします。

※ 長期履修制度とは？

通常の修業年限（博士前期課程2年，博士後期課程3年）において支払う授業料の総額を，長期履修期間として認められた期間（博士前期課程は最長4年，博士後期課程は最長6年）に学期毎に均分して支払うことができる。



写真1 新しい研究室でのお誕生会の様子



このときはピカチュウのアイスケーキでした



写真2 ある日の研究室ゼミの様子



写真3 研究室ホームページ

<http://tanakalab.w3.kanazawa-u.ac.jp/>

RSNA2019 参加報告

済生会熊本病院 **丸野 達也**

毎年冬のシカゴで開催される、放射線関連で世界最大級の国際学会である北米放射線学会 (Radiological Society of North America: RSNA)2019 に参加しました。学会参加までの流れと現地での体験、自身の演題内容について報告します。

RSNA への演題登録は、発表カテゴリー毎に詳細は異なりますが、指定された様式の抄録と要点スライド、研究や COI に関する質問への回答が必要となります。4 月初旬頃に募集が締め切られ、約 2 ヶ月後に採択されたかどうかの通知が届きます。そこから開催日までは約 5 ヶ月の期間があるので、パスポートの用意や英会話、スライド作成 (提出は 10 月末まで) 等、やるべきことは沢山ありますが個人的には余裕を持って準備出来たと思います。滞在するホテルは学会のホームページから予約を行うことが可能で、それらホテルの周囲には会場までの無料シャトルバスが行き来します。また会場の近くには、シカゴ美術館やフィールド自然史博物館、ウィリスタワー (地上 412m から絶景が見渡せます)、ミレニアムパークなど、いくつもの観光名所があり非常に魅力的でした。ただしこの時季のシカゴは、ミシガン湖から吹く冷たい風が高層ビル群と相まってかなり強く吹くため、防寒対策は必須です。気温は日中でも 3 度ほどで夜は氷点下になります。日本からは成田空港を 13 時に出発し、目的地のシカゴオヘア空港への到着は現地時間の同日 15 時過ぎでした (飛行時間は約 13 時間に及びます)。到着時はあいにくの雨でしたが、晩には雪へと変わっていました。



ウィリスタワーからのシカゴの夜景

現地での食事は、なんといってもシカゴピザがインパクト大です。正式名称を Deep Dish Pizza と呼び、その名の通り深い鉄製の鍋で作られるピザは非常にボリュームがあります。そのほかではスペアリブステーキがとて柔らかく、ケチャップベースの甘辛ソースで味付けされていて絶品でした。会場内にはカフェやフードコートがいくつもあり、手軽に食事を済ませることができます。夜はメーカーが主催する日本人向けのレセプションパーティーに参加しました。日本のご高名な先生方と多くの情報交換ができ、とても有意義な時間を過ごすことができました。

今回、私は Education exhibits に 2 演題が accept されました。発表形式はデジタル or 紙のポスターを選択可能で、私はデジタルを選択しました。開催日の約 1 ヶ月前までに所定のサイトへアップロードする形式だったので、データや紙ポスターを日本から持参する必要が無いのは助かりました。肝心の演題内容ですが、ひとつは“Novel Contrast Agent Determination Method Using CT Images Only”という演題で、患者ごとの正確な造影剤量が決定できる指標として注目されている除脂肪体重を、体組成計ではなく CT 画像から取得する方法を紹介しました。体脂肪率は腹部の Ax 画像から求められる体脂肪面積率と高い相関があります。CT 画像から高い精度で体脂肪率を推定出来ることで、従来の体組成計使用に係る煩雑な作業が省略できるほか、寝たきりやペースメーカーが埋め込まれている体組成計が使用出来ない方に対しても、除脂肪体重が算出できるというメリットがあります。さらに本手法の計算に必要なソフトウェアは、体脂肪面積測定アプリだけなので、多くの Workstation や CT 装置に搭載されていて、多数の施設で実施可能なことも特長のひとつです。もうひとつは“CT Imaging of the Tendon with Model-based Iterative Reconstruction: Can it be Completely Visualized?”という演題で、逐次近似再構成が腱を正確に描出できるか？という点を主題として、撮影条件と画像作成の標準化について言及しました。使用した逐次近似再構成法(Canon 社製 FIRST)は優れた空間分解能を有しており、従来の FBP 法では描出しきれなかった腱の微細構造の画像化を可能とします。また腱は人体の中では珍しく、CT 値が管電圧の影響をほとんど受けない特性を持っているため、高管電圧で撮影を行うことで筋組織の CT 値が低下し、腱とのコントラストが増加して画像作成に有利に働きます。そして得られる画像は検査

担当者の能力または検査への馴れや不慣れによって差が出てはなりませんので、誰が検査を担当しても常に同じクオリティーの画像を提供可能にするための、検査マニュアルとスタッフへの教育についてもスライドの中で紹介しました。幸運にも本展示は、Educations Awards の中の Certificate of Merit 賞を受賞しました。この演題は日常の業務に取り組む中で改善したいと思ったことに対して、当院で実践している実験・評価・標準化というプロセスを、分かりやすくスライド化しただけのもので、そのような内容を評価して頂けたことは大変に光栄に思います。



会場ではミュージシャンがギター片手に弾き語りをしたり、多くの人が行き交うグランドコンコースに即席のダンスホールが作られ華麗なボールルームダンスが披露されたりと、至る所で日本とはひと味違ったユーモア溢れる催しが開催されていたことも印象的でした。

末筆になりますが、RSNA 参加に当たり業務不在を支えていただいた済生会熊本病院中央放射線部の皆さまに感謝申し上げます。

RSNA2019 参加報告

熊本大学病院 医療技術部 診療放射線技術部門 後藤 淳

1. はじめに

2019年12月1日から12月6日に開催されたRSNA2019の参加報告の機会をいただきましたので、学会での体験や自身の発表内容について報告させていただきます。私にとっては初めての海外国際学会でした。

2. 演題内容と発表

今回、私は”Virtual Magnetic Resonance Lumbar Spine Images Generated from Computed Tomography Images Using Conditional Generative Adversarial Networks”というタイトルでScientific presentationのdigital posterというカテゴリーでアブストラクトを提出しました。演題登録の締め切りは4月の上旬で、7月下旬に採択通知が来ました。提出した後に電子ポスターから口述発表へ変更されること、またその逆もあるようです。研究の内容はDeep Learningのconditional generative adversarial networks(conditional GANs)という手法を用いて、CTの腰椎サジタル画像を元に仮想のMRIの腰椎サジタルT2強調画像を作成するというものでした。何らかの理由でMRI検査を受けられない場合に、CT画像から作成したMRI画像が何かの補助になればという目的があります。電子ポスターでは30分間の質疑応答時間が設けてあり、決められた時間は自分のポスターの場所に立っておく必要があります。時間になるとそのセッションの座長から出席の確認がありました。電子ポスターのスライドは事前に確認することができ、質問やコメントを発表者に送っておくことができます。私の演題には事前に質問はありませんでしたので、質疑応答の時間も質問はないかと思っていましたが、時間が近くなると自分のモニターの前に何人か集まっていました。ポスター発表での質疑応答時間も英語での会話に慣れていない私にとってはかなりプレッシャーに感じました。3人から全部で15分ほど質問がありましたが内容は細かいところを知りたいというよりは、興味がある自分もやってみたいという内容の比較的優しい質問が多かったのでどうにか理解できました。しかし語彙力・会話力不足の課題は残り、この経験でさらに英語学習への意欲が湧きました。

3. 移動と観光

移動の日程としましては11月30日の19時頃成田空港出発し、現地時間の11月30日15時半ごろにシカゴのオヘア空港につきました。オヘア空港から宿泊先であるThe Congress Plaza Hotelまではタクシーで移動しました。帰りは鉄道(CTAトレイン blue line)でオヘア空港まで移動して12月6日9時半発、日本時間の12月7日14時頃成田空港に到着し、熊本の自宅についたのは23時頃でした。現地でのホテルの予約はRSNAのホームページからでもできますが、私の場合は航空機も一緒に国際学会出張を取り扱っている旅行会社を通して予約しました。シカゴの緯度は北海道の函館とほぼ同じで、かなり寒いことを予想していましたが、開催期間中は最低気温でも-2℃ほどでした。しかし翌週は-10℃ほど

になっていて今回の開催期間だけが比較的暖かかったようです。風はとても冷たく、体がよろめくほどの強風の日もありました。

観光のほとんどは夕方以降で徒歩圏内、もしくはRSNAのシャトルバスで移動可能な範囲で行いました。シカゴ観光は初めてでしたので、シカゴシティパスという観光パスを使って主要な観光地をまわりました。シカゴシティパスは108ドルで主要な観光地5か所に入場することができます。3か所まわれば通常の入場料よりも安くなりますし、シカゴシティパス優先の入場口がありますのでほとんど並ばずに入ることができます。夕食はDeep Dish Pizza（シカゴピザ）、ハンバーガー、リブステーキ、フィッシュアンドチップスとシカゴらしいものを食べました。大学時代の研究室の恩師と同級生も参加していて一緒に食事ができたのはとても幸運でした。Deep Dish Pizzaは分厚く、焼きあがるまでにかかなり時間がかかるので、最初に注文して他の物を食べながら待つのがおすすめです。昼食は会場内のカフェなどを利用しました。今回はホットドッグを食べ損ねたので次回の目標にしたいと思います。

4. RSNAの参加をとおして

発表の準備を含めてRSNAへの参加は大変貴重な経験になりました。発表の傾聴、質疑応答、セミナーや機器展示、観光などどの場面においても語学力の必要性を感じました。国際学会参加を有意義なものにするために語学力の向上にも努力していきたいと思えます。

末筆になりますが、この度RSNA参加期間中、業務を支えてくださった熊本大学病院中央放射線部の皆様、また研究に際してご指導いただいた技師・先生方に深く感謝申し上げます。



電子ポスター発表中の著者



大学時代の同級生と恩師と著者

RSNA 参加報告

鳥取大学医学部附属病院 放射線部 太田 雄大


この度はRSNA2019の参加報告について機会を頂きましたので、そこでの体験について書かせていただきたいと思います。2019年12月1日から6日にかけてアメリカ イリノイ州 シカゴのMcCormick Placeで開催された北米放射線学会RSNA2019は世界最大級の放射線学会として世界各国から参加者が集まります。今回、私は電子ポスター発表を持ち込んで、職場の先輩と2人でシカゴまで行ってきました。私は海外への渡航歴がほとんどなく、アメリカ大陸は初上陸ということで不安と緊張で押し潰されそうでしたが、RSNA 参加経験のある先輩と一緒にだったので、すぎる思いで付いて行きました。長時間のフライトを終えてシカゴに到着した際は、入国手続きで手惑うこともありましたが空港を出てから電車に揺られること40分、無事にシカゴの街にたどり着くことが出来ました。シカゴの街並みは摩天楼がそびえ立ち、様々な建造物が軒を連ね、その壮大なスケールに感動し、そのころには緊張はどこかへ飛んでいました。ホテルに荷物を預け、学会前日の会場に足を運ぶと、まずその巨大な会場に驚かされました。これまで横浜の総会学術大会ですら大きいと思っていた私ですが、比にならないMcCormick Placeの収容力、ポスター会場もとても広く、巨大な機器展示ブースは南北で2カ所！？口述発表の会場は数えられません。調べると170部屋を越えるとか。スーツに革靴を履いて、会場の端から端まで歩くとそれだけで疲れてしまいそうでした。前日は参加登録と会場の下見をした後、会場の地下にあるシカゴ名物のピザを食べて会場を後にしました。

次の日から学会がスタートしました。まず大ホールでオープニングセレモニーに参加しました。その後は先輩と別れて各々興味のある発表を聞いて、食事の時間に集合しました。学会が始まって感じたことは、人がとても多く、しかもほぼ外国人です。国際学会なので当たり前ですが、非日常のその状況は私にとってとても刺激的でした。口述発表もポスター発表も、もちろん英語なので最初は頑張って見聞きしましたが、半日もしたら頭がパンクしそうになりました。自分の英語スキルの低さを痛感しました。2, 3日目からはポスター発表なら自分のペースでゆっくり読めることに気付き、ポスターを中心に研究発表を見ました。ちなみに私の発表は電子ポスターで、解説もしなくていい形式だったためとても気が楽でした。質問があればメールを送ることが出来るというシステムで、とても画期的だと感じました。今後は口述発表にも挑戦していきたいと思っております。

夜にはネオンの輝く街でおいしい食事を堪能しました。学会期間中はRSNA参加者が街に多くいますので、日本人同士の出会いもありました。私は、行きの飛行機で隣だった日本人男性と再会して、飛行機では会話はありませんでした。セミナーで出会った際に話しかけられて放射線技師だと知り、連絡先を交換して最終日には一緒に食事をしました。とても素晴らしい出会いが

出来て、シカゴに来て良かったと改めて感じました。また、一緒に来ていた先輩の研究室の先生やその知り合いの先生方と食事をする機会もあり、“学び”も大事ですが“出会い”も学会参加の醍醐味だと思いました。

RSNAに参加して、日本以外の多くの国々が医療放射線画像研究に取り組んでいるということを実感すると同時に、自分も今後もっと研究を積み重ねて、またRSNAに発表演題を持ち寄って参加したいと思いました。また、今回のRSNAでは全体としてDeep Learningの研究が多く、医療機器の画像再構成やノイズ除去にもそれらの技術が搭載されてきており、ユーザーとしてはきちんと原理などを理解して使用したほうがいいのかと思いました。今回の学会参加を通して多くの課題や目標を見つけることができたので、これを糧に今後の研究活動に対する姿勢を見つめ直そうと思いました。



シカゴの街並み摩天楼



シカゴの夜景

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する初学者の、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。

標準デジタル画像データベース(胸部腫瘍陰影像) 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「標準デジタル画像データベース(胸部腫瘍陰影像)」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、特定のソフトウェ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瘍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、コンピュータ支援診断(CAD)の研究やデジタル画像の評価など、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。

【標準デジタル画像データベース[胸部腫瘍陰影像] 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】 腫瘍陰画像 154 画像, 非腫瘍陰画像 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(12bit)グレイスケール

【参考文献】

- 1) 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* 174:71-74, 2000.

【標準デ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 Trans. 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
 - 7) 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
 - 10) 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 postero-anterior 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

2020 年度 画像部会事業計画

1) 第 87 回画像部会の開催(第 76 回総会学術大会時)

開催日:2020 年 5 月 15 日(金)~6 月 5 日(金)Web 開催

(1) Educational Lecture

司会 岐阜医療科学大学 篠原 範充

「AI 時代において医療画像診断チームの担う役割」

東北大学大学院医学系研究科 保健学専攻 植田 琢也

(2) Intellectual Discussion

「深層学習を放射線技術研究に利用する」

司会 立命館大学 中山 良平

東海大学医学部附属八王子病院 由地 良太郎

① 分ける

立命館大学 檜作 彰良

② 検出する

藤田医科大学 魚住 春日

③ 推定する

愛知県立大学 神谷 直希

④ 作る

原田学園人工知能教育・研究開発チーム 平原 大助

2) 第 88 回画像部会の開催(第 48 回秋季学術大会時)

開催日:2020 年 10 月 15 日(木)~17 日(土) 会場:東京ファッションタウン(TFT)ビル

テーマ:「画像評価」(仮題)

3) 医用画像プログラミングセミナーの開催(教育委員会, 中部支部共催)

第 40 回医用画像処理プログラミングセミナー (愛知県 豊明市)

開催日時:2020 年 7 月 11 日(土)~12 日(日)

会場:藤田医科大学

4) DR(デジタルラジオグラフィ)セミナーの開催(教育委員会, 近畿支部共催)

第 21 回 DR セミナー(教育委員会, 近畿支部共催)

開催日時:2020 年 9 月 19 日(土), 20 日(日)

会 場:大阪急性期・総合医療センター(大阪市)

5) 臨床画像評価セミナーの開催(教育委員会, 東京支部共催)

第 6 回臨床画像評価セミナー(東京都 築地)

開催日時:2020 年 7 月 3 日(土), 4 日(日)

会 場:国立がん研究センター中央病院

6) ROC セミナーの開催

2020 年度開催せず, e-learning を作成と教材整備を行う

7) グループ活動・Metz's ROC Software Users Group

ユーザーズグループのホームページの維持・管理, ならびに最新情報の提供を行う.

8) 部会誌(画像通信)の発行

Vol.43 No.1(通巻 84 号)(2020 年 4 月), Vol.43 No.2(通巻 85 号)(2020 年 10 月)

9) 部会委員会の開催 年 5 回(横浜, 東京, 東京, 名古屋, Web 開催の予定)

2019 年度 画像部会事業報告

1) 第 85 回画像部会の開催(第 75 回総会学術大会時)

開催日:2019 年 4 月 12 日(金) 会場:パシフィコ横浜(横浜市)

(1)Educational Lecture

司会 熊本大学大学院 白石 順二

「AI による画像研究の基礎」

岐阜大学 原 武史

(2)Intellectual Discussion

「はじめてみよう深層学習による画像研究」

司会 広島国際大学 山本 めぐみ

① Neural Network Console ではじめる深層学習と画像研究

広島国際大学 川下 郁生

② Digits ではじめる深層学習と画像研究

秋田県立脳血管研究 センター 高橋 規之

③ 深層学習を用いた画像研究をはじめするための基礎知識

岐阜大学 福岡 大輔

④ 深層学習を用いた画像研究をはじめました

岐阜医療科学大学 篠原 範充

2) 第 86 回画像部会の開催(第 47 回秋季学術大会時)

(1) Educational Lecture

司会 金沢大学 田中 利恵

「深層学習の医用画像研究の最前線」

名古屋大学 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

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

- 3) 医用画像処理プログラミングセミナーの開催
40 回医用画像プログラミングセミナー（教育委員会, 画像部会, 九州支部共催）
開催日:2019 年 6 月 15 日(土), 16 日(日)
会 場:熊本大学医学部保健学科 参加人数:19 名
- 4) DR(デジタルラジオグラフィ)セミナーの開催
第 20 回 DR セミナー（教育委員会, 画像部会, 関東支部共催）
開催日:2019 年 12 月 7 日(土), 8 日(日)
会 場:群馬パース大学 参加人数:13 名
- 5) ROC セミナーの開催
第 12 回 ROC セミナー（教育委員会, 画像部会, 近畿支部共催）
開催日:2019 年 9 月 7 日(土), 8 日(日)
会 場:大阪府立急性期・総合医療センター 参加人数:29 名
- 6) 臨床画像評価セミナーの開催
第 6 回臨床画像評価セミナー(教育委員会, 画像部会, 東京支部共催)
開催日:2019 年 7 月 6 日(土), 7 日(日)
会 場:国立がんセンター中央病院 参加人数:25 名
- 7) 中高生対象メディカルサイエンス講座の開催
2019 年度 中高生対象メディカルサイエンス講座(広報・渉外委員会, 画像部会, 東京支部共催)
開催日時:2019 年 8 月 3 日(土)
会 場:東京工業大学キャンパスキャンパス・イノベーションセンター 参加人数:57 名(一般 30 名)
- 8) 部会誌(画像通信)の発行
Vol.42 No.1(通巻 82 号)(2019 年 4 月), Vol.42 No.2(通巻 83 号)(2019 年 10 月)
- 9) 部会委員会の開催
第 1 回委員会 4 月 11 日(横浜)
第 2 回委員会 5 月 11 日(東京)
第 3 回委員会 10 月 19 日(大阪)
第 4 回委員会 12 月 22 日(名古屋)

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いたします。

【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×3=6,000円でしたが、2015年度より2,000円+1,000円×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。

編集後記

この数年を振り返ると、ディープラーニングによる第3次 AI ブーム、西日本豪雨、平成から令和への改元、北九州北部豪雨、そして新型コロナウイルス(COVID-19)による感染症の出現とこの短時間で技術の発展から災害まで色々な事が起きた。AI ブームは今も続いており、研究や開発が飛躍的に進歩している。

特に新型コロナウイルスは今まで経験した SARS や MERS、新型インフルエンザの時の状況と大きく異なり、日本では大規模イベントへの自粛、学校の休校、時差出勤、テレワーク、WEB 会議と人をオフィスに集中させることなく自宅などから仕事のコミュニケーションを行いながら仕事を行う感染予防と生産性の向上を図る方向への移行が行われ働き方も大きく変化しつつある。また、世界では WHO のパンデミック宣言、各国の緊急事態宣言や国境封鎖、入国制限や中止、国境封鎖、外出禁止令などが出ている。またこれに伴う世界経済への影響はリーマンショックに匹敵もしくはそれ以上と言われている。

テレワークは働き方改革によりワーク・ライフ・バランスの向上のため導入が推奨されており、注目も高いものであるが普及している職場は少しであった。これを機に開始した会社も多くみられた。逆に設備の導入コストやセキュリティの問題なども明らかになっている。また大きな声では言えないが今まで不要不急の書類や会議に多くの時間を費やしていた事が明らかになったのではないだろうか。個人のライフスタイルに合わせた働きやすい社会に変わるチャンスの時でもある。

これから先、良いことも悪いことも何が起こるか分からないが、その時々々の状況に応じた行動と考え方ができる柔軟性が求められる。私自身が歳を重ねても型にはまった考え方にとらわれて暴走することのないように今回書いた編集後記の内容を忘れずにいたい。

(MY 記)

画像通信 Vol.43 No.1(通巻'84)

発行日 2020年4月1日

発行所 公益社団法人 日本放射線技術学会

〒600-8107 京都市下京区五条通新町東入東鋸屋町 167

TEL075-354-8989 FAX075-352-2556 e-mail: office@jsrt.or.jp

発行者 公益社団法人 日本放射線技術学会 画像部会 部会長 篠原 範 充

图像通信 通卷八四号

VOL. 43 No.1 SPRING 2020