

Communication of the Imaging Group of the JSRT

画像通信

2022年4月

Vol.45 No.1(通巻 88)

☆ 教育講演

「ディープラーニングの今とこれから」

東京大学医学部附属病院放射線科 花岡 昇平

☆ 第91回画像部会『実践ディープラーニング研究』

1. 「ディープラーニング手法の選択方法」
2. 「性能評価の方法」
3. 「データベース構築および利用方法」
4. 「失敗例から学ぶディープラーニング研究の進め方」

山口大学医学部附属病院医療情報部 平野 靖
立命館大学工学部 中山 良平
大分大学工学部 畑中 裕司
藤田医科大学 医療科学部 寺本 篤司

☆ 技術紹介

①「乳房構成解析ソフトウェア「Breast Density Assessment」の紹介」

コニカミノルタ株式会社 南 寛威

②「フレキシブル TFT を採用したカセット DR について～FUJIFILM DR CALNEO Flow の紹介～」

富士フイルムメディカル株式会社 MS 事業部 石井 伸英

☆ 読者のページ

①「第22回 DR セミナー(オンライン)～おうちで学ぶ超初心者のための物理評価～を受講して」

松江市立病院 放射線部 岩坂 徹

②「第22回 DR セミナー(オンライン)～おうちで学ぶ超初心者のための物理評価～を受講して」

兵庫医科大学病院 放射線技術部 濱 康彦

☆ 専門部会講座(入門編):「フィルタ処理の基礎」

広島市立大学大学院情報科学研究科 青山 正人

☆ 専門部会講座(入門編):「デジタル画像の基礎」

八戸市立市民病院 医療技術局 放射線科 下沢 恵太

☆ 大学/研究室/研究会紹介:「中部支部画像研究会の紹介」

鈴鹿医療科学大学 東出 了

☆ 国際会議案内・報告

①「AOCMP-2021 に参加して」

市立四日市病院 倉谷 洋佑

②「IEEE EMBC2021 参加報告」

藤田医科大学大学院 村木 亮介

③「RSNA 2021 参加報告」

藤田医科大学大学院 山城 滉斗

☆ 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

☆ 2021年度事業報告・2022年度事業計画

☆ 画像部会入会案内



JAPANESE
SOCIETY
OF
RADIOLOGICAL
TECHNOLOGY

公益社団法人 日本放射線技術学会
画像部会

第 92 回 画像部会予告

日 時：2022 年 10 月 7 日(金)～9 日(日) の第 50 回日本放射線技術学会秋季学術大会期間中 予定
会 場：国際ファッションセンター (東京都)
内 容：「画像評価」

臨床画像評価セミナーの開催予定

第 8 回臨床画像評価セミナー :2022 年 7 月 23 日(土), 24 日(日) (予定)
会場：国立がん研究センター中央病院 (東京都築地)

ROC セミナーの開催予定

未定

DR(デジタルラジオグラフィ)セミナーの開催予定

第 23 回 DR セミナー :日時未定 会場：北海道・未定

医用画像処理プログラミングセミナーの開催予定

第 45 回医用プログラミングセミナー:日時未定 会場:Cisco Webex によるオンライン実施

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	東海大学医学部附属八王子病院	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91回画像部会プログラム

日時：2022年4月16日（金）15:45～18:45

会場：パシフィコ横浜 会議センター F201+202室

1. 教育講演：

「ディープラーニングの今とこれから」

司会 藤田医科大学 寺本 篤司
東京大学医学部附属病院 花岡 昇平

2. 画像部会 『実践ディープラーニング研究』：

1. ディープラーニング手法の選択方法
2. 性能評価の方法
3. データベース構築および利用方法
4. 失敗例から学ぶディープラーニング研究の進め方

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
山口大学医学部附属病院 平野 靖
立命館大学 中山 良平
大分大学 畑中 裕司
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
「フィルタ処理の基礎」 4月15日（金）8：00～8：45（F201+202室）
広島市立大学大学院 青山 正人
- ・専門部会講座（画像）入門編
「デジタル画像の基礎」 4月17日（日）8：00～8：45（F201+202室）
八戸市立市民病院 下沢 恵太

ディープラーニングの今とこれから

東京大学医学部附属病院放射線科 **花岡 昇平**

1. はじめに

ディープラーニングが出現し、それまでの機械学習の性能をさまざまな分野、応用で上回るようになったのはこの10年のことである。8層のディープラーニング AlexNet が ILSVRC' 12 のコンテストで1位を取ったのがまさに2012年のことであるからだ。本稿では、ディープラーニングの今の状態と、これからの展望について、放射線科医として、そして医用画像工学者としての立場から私見を述べさせていただけたらと思う。

2. ディープラーニングは、もはや

ディープラーニングの始まりの時代は、まだ caffe などの C++ の実装が使われていたし、Theano と呼ばれる自動微分ができるフレームワークがやっと出現してきたところであった。歴史を語るのは控えめにしたいが、今のディープラーニングの隆盛はおおむね、コンピュータ言語である Python、自動微分やディープラーニングを効率的に実装するライブラリである Tensorflow や PyTorch、そして NVIDIA などのハードウェア (GPGPU)、などの多くの技術的進歩とともに進展してきた。

そのうえで、ディープラーニングは、もはや、特別な技術ではなくなったというのが筆者の感じるところである。つまり、それは工具箱の一番優秀な工具となった、ということである。使えることが特別であるようなものではない、コモディティ化した道具であるということである。

実際、JSRT の皆様でもそうだろうし、JRS の放射線科医にしても、自分でディープラーニングを駆使して活躍しておられる方がたくさんいらっしゃるわけで、今や、さまざまな分野で同じようにディープラーニングの波が来ているといえる。多くの分野では、ヒトの能力をはるかに超える性能がいかに発揮されている状態にまでなっている。

しかしながら、相対的には医用画像処理分野はディープラーニングが医師やコメディカルを置き換えるところまでは行っていない。なぜだろうか。

3. 双子の巨大化

ディープラーニングが初めて、一般画像認識分野で脚光を浴びたのは先述の通り、10年前のことであったが、その原因の一つとして言われているのが巨大なデータベースの出現であった。ImageNet と呼ばれるデータベースはその後さらに充実化された。現在は画像処理のみならず自然言語、動画など、さまざまな巨大なデータセットが公開されており、ディープラーニングの学

習に広く使われている。

それに伴って生じたのがニューラルネットワーク(モデル)そのものの巨大化である。学習において最適化されるモデルのパラメータの数は、AlexNet で 6000 万であったところが、最近の自然言語のモデルである GPT-3 では 1750 億に達している。GPT-4 はその 500 倍になるとの噂である。もちろん巨大なモデルをまともに学習させるためにはいくつもの技術的ブレークスルーが必要であったが、それと同じぐらいに、巨大なデータベースが欠かせないものであった。

医用画像においても同様のことが起こると、当初は予想されていた。

4. Hinton、Ng の予想

Geoffrey Hinton 氏、Andrew Ng 氏はそれぞれ、ディープラーニングの隆盛に大きな功績をなした人物である。そしてどちらも、放射線科医の未来について否定的な意見を出した人物でもある。Hinton 氏の、「放射線科医として働いている人は、すでに崖の端を超えているが、まだ下を見ていないので、自分の下に地面がないことに気づいていないコヨーテのようなものだ。今すぐ放射線科医の育成をやめるべきだ。5 年以内に、深層学習が放射線科医よりも優れた能力を発揮することは、まったくもって明らかだ」という発言はあまりにも有名である。一方の Ng 氏も、「高度な訓練を受けた専門的な放射線科医は、今や自分の高級秘書よりも、機械にとって代わられる危険性が高いかもしれない」と述べている。

Hinton 氏の発言は 2016 年のことである。それから 6 年たった。現状では Hinton の予言は外れているように見えるが、それはなぜだろうか。

5. 医用画像処理分野における壁

その原因はいろいろあるだろうが、少なくとも理由の一つであろう点は、医用画像の入手のしにくさ、公開しにくさにあつただろう。もう一つの理由は、正解情報の作成に極めて高いコストがかかる点にあつた。

個人情報保護は 1995 年の EU データ保護指令から端を発した厳重化の流れのなかにあり、日本でも個人情報保護法の整備が進んだ。その結果として、医用画像は病院外への持ち出しや公開が非常に制限されることとなった。それ以前の問題として、医療は非常に多数の疾患を相手にし、均一でない事象の集合体を相手にするものであるから、たとえば数の少ない疾患の症例を全世界から集めても、ディープラーニングが要求する学習データの量に達しないということもあつたかもしれない。いずれにせよ、万を超えるような医用画像のデータセットは限定的にしか存在しない。

正解情報についてはさらに少ない。画像ひとつに対して病変のあるなしが入力されていることが最低限要求されるだろうが、それが満足でないこともしばしばある。ましてや、病変の部位、形状までしっかりと医師により入力されているデータセットは相当に稀少なものである。この点は現在も変わらない。

では、これらの壁があるかぎり、放射線科医や診療放射線技師は安泰なのだろうか？

6. BERT の衝撃

ディープラーニングの歴史のなかで十指に入るであろう出来事に、BERT と呼ばれる技術の出現があった。この BERT は自然言語処理を行うディープラーニングのモデルである。その詳細は省くが、これが歴史上重要である理由は 2 つある。1 つ目は、BERT によって、超巨大なデータベースを使って自然言語処理のディープラーニングを教師なし学習することが可能となったこと。すなわち、人の手による教師情報なしに 2 つの事前学習タスクを学習させることができるようになったということである。

2 つ目は、その抜きんできた性能と汎用性にある。GLUE と呼ばれる、8 つの自然言語処理タスクのベンチマークの集合体で評価されたとき、BERT はその 8 分野すべてでそれまでの全ての手法を超え 1 位を叩き出した。それも、ベースは前述の事前学習で学習させた共通の BERT で、である。まさに game changer であった。

BERT は自然言語処理の話であった。では画像処理はどうか。

7. 自己教師あり学習

自己教師あり学習という用語は前述の BERT の事前学習に対しても使われることがあるが、より一般に、人工的なデータの加増・変形などを通して、ヒトによる正解を使わずに事前学習するアプローチのことを指す。

この自己教師あり学習が、この 3 年ほどで、画像処理分野でもどんどん進化してきている。Contrastive learning と呼ばれる手法が主流であり、そのなかで SimCLR、BYOL、SwAV、などの手法が出現、発展してきたが、それらを理論的に統合する SimSiam と呼ばれる手法も提案されてきている。これらの手法を用いることにより、ヒトが入力した正解情報はごくわずかに使うだけであっても、先述の ImageNet における画像分類性能がほとんど教師あり学習に匹敵するような性能が得られるに至ってきている。

では、そのことと医用画像の壁との間に何の関係があるのだろうか。

8. 大統一

以下、萩原正人氏の有料ブログ「ステート・オブ・AI ガイド」(<https://ja.stateofaiguide.com/>)から引用する。

「大規模データから事前学習され、様々なタスクに適用できる汎用モデルである『基盤モデル』。BERT など自然言語処理の分野でポピュラーになった手法が、コンピューター・ビジョン分野にも進出しています。」

「また同時に、AI では分野の『大統一』が進みつつあります。」

その結果として、AI の分野では言語・ビジョン・音声などの垣根がどんどん無くなっていくと萩原氏はいう。

「あと数年のうちに、超巨大な化け物のようなモデルが現れ、人間の知覚に関するほとんどの問題は、この超巨大なモデルを微調整するだけでほとんど解けてしまう、というような時代が来る

と思います。」

医用画像もそうなるのであろうか。それについては、先述の Ng 氏が近年提唱する Data-centric AI の考え方が参考になる。

9. Data-centric AI

Ng 氏の提唱する data-centric AI というのは(<https://spectrum.ieee.org/andrew-ng-data-centric>)、ざっくりとえば、良いモデルを得ようとするより、良いデータを得ようとするほうが有効・効率的である、というものだ。その発言を引用すると、

「より多くのデータを収集することは役立つが、すべてについてより多くのデータを収集しようとする、それは非常に高価な活動になる。」

「巨大なデータセットが存在しない多くの産業では、ビッグデータからグッドデータへと焦点が移っていく。ニューラルネットワークに何を学習させたいかを説明するには、工学的に熟考された 50 の例題があれば十分でありうる。」

ということである。これは先述の自己教師あり事前学習とか、大統一のような技術を前提として言っているものと思われる。

医用画像に言い換えると、「50 の熟考された医学的な例があれば、ニューラルネットワークに何を学習させたいかを説明するのに十分である」ような世界がすぐそこにある、ということである。

そこにはもう壁はない。

10. これから

自己教師あり学習と大統一の末に、医用画像処理分野を囲んでいた壁は消失しようとしている。ごく多量の CT や MRI 画像を使って事前学習した巨大ネットワークが公開され、そこに教科書とネットで得られる程度の「少量の、熟考された医学的な例」を食わせてやれば、すぐに研修医並みのことはできるようになる AI が出来上がる、そんな時代が 5 年以内にはやってくると考える。

もちろん、天才である Hinton や Ng も外した未来予知を、筆者が成功するという保証はない。しかし、筆者のような凡才でも思いつくようなことを考えている人間は世界に多数いるだろう。多少の遅延はあれ、医用画像の壁は 10 年後には取り払われていると考えるべきだ。筆者は半年前までは、GAFAM のような巨大企業が医用画像分野でも成長して「壁」を破壊すると考えていたが、今では GAFAM ではなく新たに出現した技術が、壁を取り払うのであろうと思っている。

Blue ocean が red ocean になろうとしているまさに最前線で、少しでも自分もできることをしたいと考えている次第である。

ディープラーニング手法の選択方法

山口大学医学部附属病院医療情報部 平野 靖

1. はじめに

ディープラーニングは、非常にパワフルなツールであり、高い性能で非常に幅広い分野のタスクを実行することができる。特に画像を入力あるいは出力とするディープラーニングでは、物体認識、物体検出、物体認識、セグメンテーション、回帰分析、画像生成などを実行することができる。また、数多くの研究者がそれぞれのタスクに適した手法を開発し、それぞれの研究者のWebページやGitHub[1]などで公開している。一方で、ディープラーニングのできるタスクが多すぎ、しかも特定のタスクに対して開発された手法の数が多すぎることから、自分が行いたいタスクに対してどの手法が適しているのかが分かりづらい。もちろん、自分自身で0からプログラムを作成することもできるが、公開されているプログラムを参考にした方が効率が良い。そこで、本稿では、ディープラーニングのできることと、それを実現するための手法を紹介する。なお、数多くの手法が提案されているので、本稿ではこれらの手法のうち、基本的な手法のみを紹介する。なお、同じタスクのための手法が複数存在するが、どのような種類の画像を対象とするかや、精度と計算速度のどちらを優先するか、などで最適な手法が異なる。

また、よく知られているように、ディープラーニングの学習には、多大な計算コストがかかる。これを解決するために、個々の手法のバックボーンとなるネットワークに対して、大規模な画像データベースで学習した重みが公開されており、自由に使用することが可能である。このような学習済みネットワークに対して、胸部 X 線像や CT 画像などを用いて学習しなおす(ファインチューニング)ことによって、計算コストを大幅に削減することができる。これによって、セグメンテーションや画像生成などの手法の精度が飛躍的に向上する。本稿では、このような学習済みのバックボーンについても簡単に紹介する。

2. 各手法の概略

現在、画像処理の分野で使用されるディープラーニングは、物体認識・分類、物体検出、セグメンテーション、特徴抽出、回帰分析、画像生成、予測根拠の可視化などを目的とすることが一般的である。これらのタスクについて、簡単に説明する。

- 物体認識・分類：画像や、画像中の特定の領域に写っている物体のクラス分類を行う。
- 物体検出：画像中にある対象物体の位置を特定(localization)する。例えば、対象物体をバウンディングボックスで囲むことによって物体の位置や大まかな大きさを特定する(図1)。




図1 YOLO[2]による物体検出

- セグメンテーション(領域抽出)：画素ごとのクラス分類を行う。結果として、ある程度の大きさを持った領域内の画素が同じクラスに属することになり、領域が抽出される。セグメンテーションのうち、セマンティック・セグメンテーション(semantic segmentation)では異なる物体であっても同じクラス(同じ種類の物体)に属する場合には同じラベルを与える(図2)。一方、インスタンス・セグメンテーション(instance segmentation)では、同じクラスであっても異なる物体であれば別のラベルを与える(図3)。




図2 U-Net[3]によるセマンティック・セグメンテーション
原画像(左)とセグメンテーション結果(右)、黄色い線は正解の領域の輪郭を表す




図3 Mask R-CNN[4]によるインスタンス・セグメンテーション

- 特徴抽出：画像を，その画像の特徴を表現する数値群(特徴ベクトル)に変換する．得られた特徴ベクトルを使用して画像のクラス分類や検索，物体の検出などを行う．
- 回帰分析：画像を連続的な数値に変換する．出力される数値としては，入力された画像が特定のクラスに属する尤度や，連続値で表現される被写体の属性(顔写真から年齢を予測するなど)である．
- 画像生成：画像生成は，ノイズから画像を生成するものと，画像を変換して別の画像を生成するものの2つに分けられる．さらに後者は，ドメイン変換(図4)，ノイズ低減，特定領域内の画素値変換，高解像度化(図5)などが含まれる．ここで，ドメイン変換とはある種類の画像を別の種類の画像へ変換すること，特定領域内の画素値変換とは胸部 X 線像における肋骨領域の濃度値低減や結節影の強調などである．




図4 CycleGAN[5]によるドメイン変換



図5 SRGAN[6]による高解像度化
原画像(左)と原画像を4倍の画像サイズに変換した結果(右)

- 予測根拠の可視化：CNNなどで画像のクラス分類を行った際に、通常はどのような過程を経てクラスが決定されたか分からない。XAI(説明可能なAI, explainable AI)によってクラス分類に寄与した箇所を可視化することが可能である(図6)。



図6 Grad-CAM[7]によるクラス分類の根拠の可視化

3. 代表的な手法

3.1 物体認識・分類

画像を2次元あるいは3次元のまま扱う場合には、Convolutional Neural Network(CNN)を使用し、クラス数と同数の出力ノード(ユニット)を設定することが一般的である。

画像を1次元ベクトルに変換してからDeep Neural Network(DNN)で処理する場合もあるが、CNNを用いた方が高性能であることが多い。物体認識・分類以外のタスクについても同様であるが、ディープラーニングでは、十分な数の学習データがあれば、層の数を増やすほど性能が向上するとされるが、実問題では用意できる学習データの数は限られており、層を増やしすぎると過学習(Overfitting)という現象が起こり、学習データに対してのみ高い性能を示すことになる。過学習を抑制する方法として、学習データの増加、層数の削減、Dropout[8]の導入などがある。また、層を増やしすぎることによるもう一つの問題として、勾配消失問題がある。これは活性化関数の勾配が非常に小さな値になることによって重みの修正ができなくなる現象である。勾配消失問題を解決する方法として、ReLU(Rectified Linear Unit)[9]やResidual Block[10]の導入などがある。

3.2 物体検出

R-CNN, SSD(Single Shot Multibox Detector)[11], YOLO(You Only Live Once)[2], およびこれらから派生したネットワーク(Pelee など)やEfficientDet[12], M2Det[13]が代表的である。YOLOやSSDでは、まずCNNで特徴抽出を行い(図7)、得られた特徴量を用いて物体検出と物体検出処理で得られたバウンディングボックス内の物体のクラス分類を同時に行う。SSDはYOLOに比べて精度は高いが、計算速度は遅い傾向にある。なお、現時点でのYOLOの正統な最新版としてはYOLOv4[14]がある。YOLOv4ではネットワークの構造をバックボーン、ネックおよびヘッドに分割し、それぞれの部分で複数のネットワークのうちの1つを選択することができるようになってきている(図8)。また、従来の物体検出手法に比べて、高速かつ高精度で物体検出が可能となった。

なお、検出対象が複数あり、それらのサイズが大きく異なる場合には、Feature Pyramid Networks (FPN) [15]などを用いてマルチスケールに対応させる必要がある。





図7 SSDとYOLOの構造の比較[11]. SSDではバックボーンとしてVGG16を採用している。



Input: { Image, Patches, Image Pyramid, ... }

Backbone: { VGG16 [68], ResNet-50 [26], ResNeXt-101 [86], Darknet53 [63], ... }

Neck: { FPN [44], PANet [49], Bi-FPN [77], ... }

Head:

Dense Prediction: { RPN [64], YOLO [61, 62, 63], SSD [50], RetinaNet [45], FCOS [78], ... }

Sparse Prediction: { Faster R-CNN [64], R-FCN [9], ... }

図8 YOLOv4[14]の構造と各部分で選択できるネットワーク

3.3 セグメンテーション(領域抽出)

前述の通り、セグメンテーションには、セマンティック・セグメンテーションとインスタンス・セグメンテーションの2つがある。例えば、CT画像中の肺結節をセグメンテーションしたいのであればセマンティック・セグメンテーションで十分であるし、複数の肺結節をセグメンテーションし、個々の肺結節に異なるラベルを付けたいのであればインスタンス・セグメンテーションを適用する必要がある。なお、セマンティック・セグメンテーションを行った後にラベリング処

理を行うことで、個々の肺結節に異なるラベルを付けられる可能性があるが、セマンティック・セグメンテーションの結果、複数の肺結節が接触して1つの領域として抽出されている場合には、これらの肺結節にラベリング処理によって異なるラベルを付けることができないので、インスタンス・セグメンテーションを適用する必要がある。

セマンティック・セグメンテーションとインスタンス・セグメンテーションの代表的な手法には以下のものがある。

- セマンティック・セグメンテーション

医用画像に対して多く使われている手法としてU-Net[3]があり(図9), U-Net++やR2U-Net, 3D U-Netなどの派生版も数多く提案されている。U-Netは後述のAutoencoderと関連性が深い構造となっているが、大きな違いは複数の層をバイパスするように接続されたスキップコネクションである。一般的に多数のConvolution層を適用されていくうちに画像サイズは小さくなり、物体や画像特徴の位置情報が失われていく。スキップコネクションによって出力層に近いConvolution層に位置情報を提供することによって位置情報の損失を防ぐことができる。




図9 U-Net[3]の構造

- インスタンス・セグメンテーション

代表的な手法の1つにMask R-CNN[4]がある。この手法は物体検出手法であるFaster R-CNNのネットワークにセグメンテーションのための分岐を追加したものである。複数のタスク(ここでは、物体検出とセグメンテーション)を同時に行う処理のことをマルチタスクという。

Mask R-CNNを改良する形で、マルチスケール化した手法やマスクの信頼度を採用した手法などとして、Path Aggregation Network(PAN)やMask Scoring R-CNNなども提案されている。また、マスクの表現方法を再考することにより、TensorMask, BlendMask, SOLOなどの手法も提案されており、高い精度でのインスタンス・セグメンテーションを実現している。

3.4 特徴抽出

特徴抽出器としては、従来から CNN をベースにした手法が物体認識や物体検出などのネットワークの前半部として用いられている。また、様々なタスクのバックボーンとして利用されることが多い VGG や ResNet, EfficientNet など CNN をベースとした特徴抽出器である。これらのネットワークの学習時にはクラス分類が行われ、特徴抽出器として使用する際には後半部の全結合層を削除する。一方で、原画像と同じ画像を出力するように学習するタイプの特徴抽出器としては、Autoencoder (AE) [16] (図 10) や Variational Autoencoder (VAE) [17] などがある。これらのネットワークは、前半部がエンコーダ、後半部がデコーダと呼ばれ、エンコーダの入力ノードの数に比べて、エンコーダとデコーダの接続部のノード数が非常に少ないのが特徴である。エンコーダの出力として特徴量が得られる。なお、AE では特徴量の分布を制御することができないことが問題である。VAE では、エンコーダの入力となる原画像が与えられたときの特徴量を入力画像の潜在変数とみなし、その確率分布の形を指定することによって特徴量の分布を制御することができる手法である。




図 10 AE[16]の構造

3.5 回帰分析

分類問題に使用される CNN や DNN の出力層のノード数を 1 つにした構造が最も簡単なものである。例えば結節が悪性であれば 1、良性であれば 0 を出力するように学習させると、予測時には 0 から 1 の連続値が出力されるようになる。これを「結節が悪性である確率」として扱う。広い意味では、後述の画像変換も回帰の一種と考えることもできる。

3.6 画像生成

画像を生成するタイプのモデルのことを、生成モデルという。これには Generative Adversarial Network (GAN) [18] のようにノイズから画像を生成するものと、画像を別の画像に変換するものに大別される。

GAN は、2 つのネットワーク (Generator と Discriminator) が敵対するように学習を行うことでデータ生成能力と、生成されたデータか実データであるかの鑑別能力を高める手法である。これによって、高いデータ生成能力を持ったネットワークを構築することができる。この手法を画像に適用したものが、Deep Convolutional Generative Adversarial Networks (DCGANs) [19] である。DCGANs の問題点として、解像度が高い画像を生成しようとするとき、生成された画像と教師画像の区別が容易になり、学習が不安定になるという問題があった。これを解決するために、Progressive Growing GAN (PGGAN) や BigGAN などが提案されている。また、複数のクラスの物体を含む画像を生成できるネットワークを生成し、そのうちの指定したクラスの画像を生成する

ための手法として Conditional GAN が提案されている。

画像変換手法としては、ある種類の画像を別の種類の画像に変換(ドメイン変換)する CycleGAN が有名である。前述のように、U-Net はセマンティック・セグメンテーション手法として提案されたが、教師画像として入力画像をコントラスト変換した画像や肋骨領域などの濃度を低減した画像、あるいは結節領域などを強調した画像などを与えることによって画像変換手法として使用することができる。また、低解像度画像から高解像度画像を得る処理である超解像をディープラーニングで行う SRGAN[6]という手法も提案されている。

3.7 予測根拠の可視化

予測根拠を可視化する手法は、活性化ベース手法(Activation-based Methods)と領域ベース手法(Region-based Methods)に大別することができる。前者は Grad-CAM(Gradient-weighted Class Activation Mapping)[7]に代表される手法でクラス分類の過程で得られる各 Convolution 層の勾配からそのクラスに分類する際に重要視した箇所を顕著性マップ(saliency map)として可視化することができる。後者の手法は、活性化ベース手法がノイズ的な勾配の変化に影響を受ける場合があるという問題点を解決したもので、Score-CAM などが代表例である。一方でこの手法は計算コストが高いという問題がある。両者の欠点を解決した手法としては、Group-CAM がある。この手法では、まず Grad-CAM と同じように出力されたクラスに対応する各層の各チャンネルの重要度を計算した上でノイズの影響を低減し、顕著性マップを生成するものであり、Grad-CAM や Score-CAM に比べてノイズ的に顕著性が高くなる領域を削減できる。

4. バックボーンネットワーク

高性能のネットワークを構築するためには層数を多くする必要があるが、実際には教師データの数が足りず、過学習が起こることが多い。そこで、ImageNet[20]や COCO[21]などの非医用画像の大規模画像データベースで学習した深いネットワークをバックボーンとなる特徴抽出器として利用することが多くなってきた。なお、医用画像以外の画像で学習されたネットワークであっても、最終的に実際に対象となる医用画像でファインチューニングを行うことによって、使用目的に特化したネットワークを構築することができる。バックボーンとして使用されるネットワークには、DenseNet, VGG, ResNet, EfficientNet などであり、これらを学習済みのネットワークをダウンロードして使用することができる。例えば、Tensorflow 2 であれば文献[22]から、PyTorch であれば文献[23]からダウンロードすることができる。

5. おわりに

本稿では、ディープラーニングで実行可能なタスクと代表的な手法の例を挙げた。参考文献を挙げていない手法も多いが、インターネットを検索すれば論文や解説などが見つかるはずである。最適な手法は入力画像の種類や必要となる精度などによって異なる。上記の手法を実現するプログラムのほとんどは GitHub など公開されているので、実際にプログラムを動かして最適な手法を見つけ出しただけであれば幸いである。

参考文献

- [1] <https://github.com/> (2022/2/22 閱覽)
- [2] J. Redmon, S. Divvala, R. Girshick and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016
- [3] O. Ronneberger, P. Fischer, T. Brox: U-net: "Convolutional networks for biomedical image segmentation" , MICCAI, 2015
- [4] K. He, G. Gkioxari, P. Dollar, et al.: "Mask r-cnn" , IEEE International Conference on Computer Vision (ICCV), 2017
- [5] J-Y Zhu, T. Park, P. Isola, et al.: "Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks" , IEEE International Conference on Computer Vision (ICCV), 2017
- [6] C. Ledig, L. Theis, F. Huszar et al.: "Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network" , IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017
- [7] R. R. Selvaraju, M. Cogswell, A. Das, et al.: "Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization" , IEEE International Conference on Computer Vision (ICCV), 2017
- [8] N. Srivastava, G. Hinton, A. Krizhevsky, et al.: "Dropout: A Simple Way to Prevent Neural Networks from Overfitting" , Journal of Machine Learning Research, Vol.15, No.56, pp.1929-1958, 2014.
- [9] V. Nair, G. Hinton: "Rectified Linear Units Improve Restricted Boltzmann Machines" , International Conference on Machine Learning (ICML), 2010
- [10] K. He, X. Zhang, S. Ren, et al.: "Deep Residual Learning for Image Recognition" , IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016
- [11] W. Liu D. Anguelov, D. Erhan, et al.: "SSD: Single Shot MultiBox Detector" , European Conference on Computer Vision (ECCV), 2016
- [12] M. Tan, R. Pang, Q. V. Le: "EfficientDet: Scalable and Efficient Object Detection" , IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2020
- [13] Q. Zhao, T. Sheng, Y. Wang et al.: "M2Det: A Single-Shot Object Detector based on Multi-Level Feature Pyramid Network" , AAAI Conference on Artificial Intelligence (AAAI-19), 2019
- [14] A. Bochkovskiy, C.-Y. Wang, H.-Y. M. Liao: "YOLOv4: Optimal Speed and Accuracy of Object Detection" , arXiv, 2018
- [15] T.Y. Lin, P. Dollar, R. Girshick, et al.: "Feature pyramid networks for object detection" , IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017

- [16] Geoffrey E. Hinton, R. R. Salakhutdinov: “Reducing the Dimensionality of Data with Neural Networks” , Science, Vol 313, pp.504–507, 2006
- [17] D. P. Kingma, M. Welling: “Auto-Encoding Variational Bayes” , International Conference on Learning Representations (ICLR), 2014
- [18] I. Goodfellow, J. Pouget-Abadie, M. Mirza, et al.: “Generative Adversarial Nets” , Advances in Neural Information Processing Systems (NIPS), 2014
- [19] A. Radford, L. Metz, S. Chintala: “Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks” , International Conference on Learning Representations (ICLR), 2016
- [20] <https://www.image-net.org/> (2022/2/22 閱覽)
- [21] <https://cocodataset.org/> (2022/2/22 閱覽)
- [22] https://www.tensorflow.org/api_docs/python/tf/keras/applications
- [23] <https://pytorch.org/hub/research-models>

性能評価の方法

立命館大学理工学部 中山 良平

1. はじめに

ディープラーニングでは、まず、何かを入力し、その入力に基づいて何らかの予測を出力するモデル（ネットワーク、アルゴリズム）を構築する。次に、入力データとその正解値の組み合わせからなる多くのデータを用意し、入力データに対するモデルの予測値が正解値に近づくようにモデルを学習させる。学習は、モデル内の入力と出力の関係性を示す重みを最適化する作業に相当する。そして、学習で使用していないデータを学習したモデルに入力し、モデルの性能を評価する。本稿では、モデルの学習、評価方法を簡単に説明し、学習や評価において用いられる指標（関数）を解説する。

2. モデルの学習と評価

2. 1. データセットの準備

機械学習では、実験試料を学習用と評価用に分け、学習用データを用いてモデルの学習を行い、評価用データを用いてモデルの性能評価が行われる。学習用データは、さらに訓練データと検証データに分けられ、訓練データはモデルの重みの学習に、検証データはモデルの学習が順調に進んでいるか、訓練データに過剰に適合していないか（過学習）を検証するために用いられる。実験試料のデータ数に左右されるが、全データの60%~80%を学習用データ、20%~40%を評価用データ、そして学習用データの80%を訓練データ、20%を検証データとすることが多い。

2. 2. モデルの学習

モデルの学習では、上述したように、入力データに対するモデルの評価値が正解値に近づくように、モデル内の重みが最適化される。最適化の流れは、まず、モデルの予測値と正解値にどれくらいの損失（誤差）があるかを計算するための損失関数を定義する。損失関数には様々なものがあり、後述するが「二乗和誤差」や「交差エントロピー誤差」が有名である。そして、勾配降下法と誤差逆伝播法を用いて、損失関数が最小となる最適な重みを探す。ここでは、損失関数を重み変数で偏微分




図1 損失関数とモデルの最適化

し、接線の傾きを求め、傾きが負であれば重みを少し増加、正であれば少し減少する。この操作を繰り返すことにより、重みを損失関数の最小値に近づける。

損失関数を定義する上で、重要なのは、微分がゼロにならない指標を選択することである。例えば、分類問題では、一般に、モデルの正答率を高くすることが目的である。したがって、正答率を損失関数として定義すれば、最も目的に沿うと考えられる。しかし、重みを少し




図2 正答率の損失関数

変えた程度では正答率は変化しないので、損失関数の偏微分値（傾き）がほとんどの場所でゼロになってしまう。また、図2で示すように、損失関数が不連続となり微分を計算できず、勾配降下法が使用できなくなる。したがって、重みの少しの変化でも数値が変わる指標を損失関数として用いる必要がある。

モデルの学習時に使われる関数として、損失関数、誤差関数、コスト関数、目的関数がある。誤差関数は損失関数と同じと考えて良い。コスト関数は損失関数に過学習抑制のための正則化項を加えたものである。また、モデルを最適化する意味で、損失関数、誤差関数、コスト関数をすべて含め目的関数と呼ばれる。

2. 3. モデルの評価

モデルの評価では、学習で使用していないデータを学習したモデルに入力し、モデルの性能を評価する。ここでは、モデルの予測値と正解値にどれくらいの損失（誤差）があるかを計算するための評価関数を定義する。学習と評価で「二乗和誤差」や「交差エントロピー誤差」など同じ指標を用いた場合も、学習時は損失関数、評価時は評価関数と呼ばれる。損失関数は、重みの少しの変化で数値が変わる指標により定義する必要があるが、評価関数にはそのような制約はない。

3. 主な損失関数

3. 1. 回帰問題

出力が恒等関数である回帰問題でよく用いられる損失関数を以下に示す。

- 平均二乗誤差（MSE : Mean Squared Error）

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2$$

n はデータ数、 y_i はモデルの予測値、 t_i は正解値を示す。MSE は回帰問題の損失関数として広く用いられる。MSE は誤差を二乗するため、誤差が大きいデータがより強く重みの更新に影響を与える特徴がある。したがって、外れ値に過敏に反応し、過剰適合することもあるので注意が必要である。また、 $1/n$ を外すと二乗したL2ノルムと等しくなる。したがって、二乗したL2ノルムはL2損失とも呼ばれる。

- 平均絶対誤差 (MAE : Mean Absolute Error)

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - t_i|$$

n はデータ数, y_i はモデルの予測値, t_i は正解値を示す. MAE は誤差を二乗しないため, 誤差が大きいデータも小さいデータも同じスケールの影響を重みの更新に与える特徴を持つ. MAE は絶対値により正と負の分岐点で不連続となってしまうことから, 微分不可能になるので, 損失関数として用いるときは注意が必要である. また, $1/n$ を外すと L1 ノルムと等しくなる. したがって, MAE は L1 損失とも呼ばれる.

- 平均二乗対数誤差 (MSLE : Mean Squared Logarithmic Error)

$$\text{MSLE} = \frac{1}{n} \sum_{i=1}^n (\log(1 + y_i) - \log(1 + t_i))^2$$

n はデータ数, y_i はモデルの予測値, t_i は正解値を示す. MSLE は, $\log(0) = -\infty$ を避けるため, $+1$ されていることに注意されたい. したがって, 予測値 y_i や正解値 t_i は -1 より大きくなければならない. MSLE は MSE 同様, 誤差を二乗するが, 対数により誤差が大きいデータの重みの更新に対する過剰な影響を抑制できる (図 3 参照). したがって, 外れ値にも対応することが可能である. しかし, 予測値 y_i と正解値 t_i の差が同じでも, $y_i < t_i$ のときの方が $y_i > t_i$ のときより, 重みの更新に対する影響が大きい特徴がある. 例えば, $t_i = 100$, $y_i = 80$ のとき, $\text{MSLE} \cong 0.0487$ であるが, $t_i = 100$, $y_i = 120$ のとき, $\text{MSLE} \cong 0.0326$ である. したがって, 予測値が正解値よりも低く出力されることを抑制し易い.




図3 $y = \log(1+x)$ のグラフ

3. 2. 分類問題

出力がソフトマックスである分類問題でよく使われる損失関数を以下に示す.

- 交差エントロピー誤差 (Cross Entropy Error)

$$2 \text{ クラス分類用 : CEE} = -\frac{1}{n} \sum_{i=1}^n (t_i \log(y_i) + (1 - t_i) \log(1 - y_i))$$

n はデータ数, y_i はモデルの予測値, t_i は正解値を示す. t_i には正解クラスを示す 0 か 1 が与えられる.

$$\text{多クラス分類用 : CEE} = -\frac{1}{n} \sum_{i=1}^n t_i \log(y_i)$$

n はデータ数, y_i はモデルの予測ベクトル, t_i は正解ベクトルを示す. t_i は正解クラスを1, 他クラスを0とする one-hot 表現のベクトルが与えられる. CEE は正解値 t_i の確率分布と予測値 y_i の分布の違いを示し, 分類問題の損失関数として最も頻繁に用いられる. 例えば, 正解値 $t = [0 \ 1 \ 0]$, 予測値 $y = [0.2 \ 0.6 \ 0.2]$ のとき,

$$CEE = -(0 \cdot \log 0.2 + 1 \cdot \log 0.6 + 0 \cdot \log 0.2) \cong 0.511$$

となる. 正解値が1のクラスに対応する予測値が1に近い数値を出力できていれば CEE は小さく, 予測値が0に近い誤った数値を出力していれば CEE は大きくなる. 図4に示すように, 正解値が1のクラスに対応する予測値が大きく乖離している(0に近い)場合, 誤差が非常に大きくなることから学習が速く進む特徴がある. また, セマンティックセグメンテーションは各画素がどのクラスに属するか分類するので, CEE は分割問題でも多用される.




図4 $y = -\log(x)$ のグラフ

- 重み付き交差エントロピー誤差 (Weighted Cross Entropy Error)

$$WCEE = -\frac{1}{n} \sum_{i=1}^n w t_i \log(y_i)$$

n はデータ数, y_i はモデルの予測ベクトル, t_i は正解ベクトル, w は各クラスのデータ数に基づく重みベクトルを示す. CEE に基づく学習では, データ数が多いクラスのカテゴリ精度が高くなるようにモデルが学習し, データ数が少ないクラスのカテゴリ精度が低くなる傾向がある. そこで, WCEE ではクラスに含まれるデータ数の偏りに基づく重みを CEE に付与することにより, クラス間のデータ数の違いが重みの更新に与える影響を均等にしている.

4. 主な評価関数

4.1. 回帰問題

損失関数で紹介した平均二乗誤差 (MSE), 平均絶対誤差 (MAE), 平均二乗対数誤差 (MSLE) も評価関数として用いられるが, MSE や MSLE は誤差を二乗する処理を行うため, 単位が変わる. 二乗した誤差の単位を元に戻すために, MSE, MSLE の平方根を取った下記2指標も提案されている.

- 平均平方根二乗誤差 (RMSE : Root Mean Squared Error)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2}$$

- 平均平方根二乗対数誤差 (RMSLE : Root Mean Squared Logarithmic Error)

$$\text{RMSLE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\log(1 + y_i) - \log(1 + t_i))^2}$$

n はデータ数, y_i はモデルの予測値, t_i は正解値を示す.

一般に, MSE, MAE, MSLE のいずれかを損失関数として用いた場合, それぞれ RMSE, MAE, RMSLE が評価関数として使用される. 通常, 回帰問題の評価では, RMSE または MAE を用いればよい.

上述した誤差指標は, いずれも絶対評価であるため, 元データの値を理解していなければ解釈が難しい. そこで, 正解値からの誤差がどの程度がパーセントで示す相対評価による指標も提案されている.

- 平均平方根二乗パーセント誤差 (RMSPE : Root Mean Squared Percentage Error)

$$\text{RMSPE} = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - t_i}{t_i} \right)^2}$$

- 平均絶対パーセント誤差 (MAPE : Mean Absolute Percentage Error)

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - t_i}{t_i} \right|$$

n はデータ数, y_i はモデルの予測値, t_i は正解値を示す.

RMSPE や MAPE は相対評価で示すことが出来るため, 専門外の人にも理解しやすい利点がある. 正解値にゼロがある場合, 使用できないことに注意されたい.

4. 2. 分類問題

2クラス分類問題の場合には, 真陽性 (TP : True Positive), 真陰性 (TN : True Negative), 偽陽性 (FP : False Positive), 偽陰性 (FN : False Negative) に基づく評価がよく用いられる. TP は陽性を正しく陽性と予測した数, TN は陰性を正しく陰性と予測した数である. 一方, FP は陰性を誤って陽性と予測した数, FN は陽性を誤って陰性と予測した数を示す. これらの基本となる評価指標をまとめた表が混同行列 (Confusion Matrix) である (表1 参照).

表1 混同行列

		モデルの予測	
		Positive	Negative
正解クラス	Positive	TP	FN
	Negative	FP	TN

- 正解率, 正答率 (Accuracy)

$$\text{Accuracy} = \frac{\text{正解数}}{\text{総データ数}} = \frac{TP + TN}{TP + FP + TN + FN}$$

正解率は最も基本的な評価関数であり, 必ず評価すべき指標である. しかし, 正解率は期待した評価が出来ていない場合があることに注意が必要である. 例えば, 検診で疾患の発見率が 0.1%であったとする. このとき, 常に検診データを正常と出力するモデルの正解率は 99.9%である. 正解率は高いが, そのようなモデルは, 論外である.

- 適合率 (Precision) , 陽性的中率 (Positive Predictive Value)

$$\text{Precision} = \frac{\text{陽性の正解数}}{\text{陽性と予測されたデータ数}} = \frac{TP}{TP + FP}$$

モデルが陽性と予測したデータのうち、実際に陽性だった割合である。Precision は FN よりも FP を出来るだけ低く抑えたい場合に有用となる指標である。

- 陰性的中率 (Negative Predictive Value)

$$\text{NPV} = \frac{\text{陰性の正解数}}{\text{陰性と予測されたデータ数}} = \frac{TN}{TN + FN}$$

モデルが陰性と予測したデータのうち、実際に陰性だった割合である。NPV は FP よりも FN を出来るだけ低く抑えたい場合に有用となる指標である。

- 再現率 (Recall) , 感度 (Sensitivity)

$$\text{Recall} = \frac{\text{陽性の正解数}}{\text{陽性のデータ数}} = \frac{TP}{TP + FN}$$

陽性データのうち、モデルが陽性と正しく予測した割合である。

- 特異度 (Specificity)

$$\text{Specificity} = \frac{\text{陰性の正解数}}{\text{陰性のデータ数}} = \frac{TN}{FP + TN}$$

陰性データのうち、モデルが陰性と正しく予測した割合である。

感度と特異度はトレードオフの関係にあり、感度を上げれば特異度が下がり、特異度を上げれば感度が下がる。

- F 値 (F-score)

$$\text{F-score} = \frac{2 \cdot \text{PPV} \cdot \text{Sensitivity}}{\text{PPV} + \text{Sensitivity}} = \frac{2 \cdot TP}{2 \cdot TP + FP + FN}$$

適合率 (Precision) と再現率 (Recall) のトレードオフに着目した両指標の調和平均である。例えば、検診においては疾患を見落としたくないため、Sensitivity (Recall) が重要視される。一方、精密検査においては、正常患者に治療を施すのは避けたいため PPV

(Precision) が重要視される。この両指標のバランスを良くしたい場合に F 値は有用となる。

- ROC 曲線下の面積 (Area Under the Receiver Operating Characteristic Curve)

上述した指標はモデルの予測値に閾値 (カットオフポイント) を設定し、閾値よりも予測値が高ければ陽性、低ければ陰性と評価される。閾値を変えると評価値も変わるので、モデ

ルの性能の比較が困難となる。AUCは閾値に左右されずに汎用的な性能評価が可能である。AUCは図5に示すROC曲線下の面積である。ROC曲線は縦軸に真陽性率（True Positive Fraction），横軸に偽陽性率（False Positive Fraction）を取ったグラフに描かれる。真陽性率は再現率（Recall）と等しく，偽陽性率は1-特異度（Specificity）である。ROC曲線は，閾値を細かく変化させながら真陽性率と偽陽性率をプロットし，それらを線でつないだものである。ROC曲線が左上に近づくほど，性能が高いことを示す。




図5 ROC曲線

陽性と陰性のデータ数が明らかに不均衡である場合，ROC曲線が綺麗な曲線を描かない可能性があることに注意されたい。例えば，陽性データが陰性データよりも極端に少なかった場合，陽性データから算出する真陽性率は，偽陽性率よりも閾値の変化に過剰に反応し，S字カーブを描くことがある。したがって，陽性と陰性のデータ数がある程度等しい場合にAUCは用いるべきである。

・ 適合率-再現率曲線下の面積（Area Under the Precision-Recall Curve）

陽性と陰性のデータ数が明らかに不均衡である場合は，陽性データに着目して算出されるPR-AUCを検討すると良い。PR-AUCもAUC同様，閾値に左右されずに性能評価が可能である。PR-AUCは図6に示すようなPrecision-Recall曲線下の面積である。

Precision-Recall曲線は，閾値を細かく変化させながらPrecisionとRecallをプロットし，それらを線でつないだものである。Precision-Recall曲線が右上に近づくほど，性能が高いことを示す。PR-AUCは，陽性と陰性のデータ数の割合により，評価値が変わってくるので，比較する際は注意が必要である。




図6 Precision-Recall曲線

多クラス分類問題の場合には，各クラスに対する正解率（Accuracy），適合率（Precision），再現率（Recall），F値（F-score）がよく用いられる。

4. 3. 分割(セマンティックセグメンテーション)問題

分割問題では、各画素に対する分類問題に等しいとの観点から、分類問題の評価指標が用いられる。図7に、分割問題における TP, FP, FN の関係を示す。分割精度は TP, FP, FN から算出される適合率 (Precision) , 再現率 (Recall) , F 値 (F-score) , そして、IoU (Intersection over Union) で評価される。適合率, 再現率, F 値は上述した算出方法と同じである。




図7 分割問題における TP, FP, FN

適合率 (Precision) は FN を考慮しないため、正解領域の多くが分割されていなくても、予測された分割領域がすべて正解領域内にあった場合、100%の精度となる。したがって、誤検知の低さを示す指標と考えることができる。

再現率 (Recall) は FP を考慮しないため、正解領域外が多く分割されていても、正解領域すべてが予測された分割領域内に含まれる場合、100%の精度となる。したがって、見落としの低さを示す指標と考えることができる。

F 値 (F-score) は Dice 係数とも呼ばれる指標である。F 値 (F-score) は FN, FP ともに考慮するため、Precision と Recall のバランスを考慮した指標である。分割したい領域がある程度、分割できているかを評価する際に用いられる。

IoU (Intersection over Union) は、Jaccard 係数とも呼ばれる。

$$\text{IoU} = \frac{TP}{TP + FP + FN}$$

正解領域と予測された分割領域の重なりを重視した評価した指標である。分割したい領域の境界部分まで詳細に分割できているかを評価する際に用いられる。

5. まとめ

本稿では、ディープラーニングでよく使用される損失関数、評価関数について解説した。適切な損失関数を使わなければ、モデルの学習が効果的に進まない。また、適切な評価関数を使わなければ、正確なモデルの性能評価ができない。先行研究論文に記載の損失関数、評価関数を理解せずに使用するのではなく、実験試料、目的に合う関数を適切に選択してもらいたい。

データベース構築および利用方法

大分大学工学部 畑中 裕司

1. はじめに

医用画像の研究を行うためのデータ収集は、所属施設で行う場合、他施設で行う場合、インターネットなどで行う場合などがある。筆者のように医療機関に所属しない研究者のデータ収集は他力本願となるが、本稿ではその経験を元にして述べる。さらに、収集したデータをディープラーニングの研究に用いる際に知っておくべきことについても述べる。

2. 医用画像を扱う際の注意事項

医用画像は人を対象にしているため、原則として「人を対象とする生命科学・医学系研究に関する倫理指針」[1]に従う必要がある。特に、医療施設でデータ収集を行う場合は、原則として収集する医療施設および所属する組織の研究倫理審査委員会（IRB: Institutional Review Board）等に事前申請し、研究実施の承諾を得ておく必要がある。詳細は所属の研究倫理審査委員会等の基準に照らし合わせて頂きたいが、倫理審査の承認後に撮影される画像を収集する場合はオプトイン（インフォームド・コンセントあり）、撮影済みの画像を収集する場合はオプトアウト（患者の同意を得る必要はない）となるのが一般的である。

一方で、オープンデータなどの構築済みのデータベースを用いる場合は、一般的には倫理審査は不要であるため、基礎研究の実施が容易となる。ただし、Web やクラウドなどのインターネットサービスにて入手できるデータであっても、研究計画書を含めた利用申請の場合は、倫理審査が必要となるであろう。迷う場合は、所属の研究倫理審査委員会に事前相談されたい。

最後に、研究発表や論文投稿を行う場合は、データの収集元や収集方法、倫理審査の承認済みであることを明示する必要があることに注意されたい。

3. データベース作成のポイント

ディープラーニングでは、学習時にネットワークの各パラメータ調整が行われる。ネットワーク構造が複雑になるほど、調整すべきパラメータ数が増えるため、学習にはよ

り多くの画像が必要になる。筆者の経験によるデータベース作成時に注意すべき点を以下に述べる。

3.1 画像枚数

学習に必要な画像枚数は、ディープラーニングの対象やネットワークの構造に影響されるため、目安の明示は難しい。実際には、学習時の Accuracy や Validation Loss の状況を見て、学習用の画像枚数が十分であるかを判断するべきである。ただし、同じような特徴を持つ画像ばかりを大量に集めても、良い学習を行えないであろう。様々な特徴を持つ、バリエーションに富んだ画像データベースを構築することが重要である。一方で、回転や平行移動などの画像処理によるデータ拡張（データオーギュメンテーション、データの水増し）が有効に機能する場合もあるので、多くの画像を収集できないからといって、研究を諦める必要は無い。

3.2 データ数のバランス

ここでは例として、良悪性などの 2 クラス分類を考える。実社会では、良悪性の患者数や画像枚数の比率は 1:1 とはならないが、ディープラーニングの学習では、できるだけ良悪性の比率に片寄りが無いようなデータセットにすべきである。例えば、良性:悪性が 99:1 であれば、全て良性と出力するネットワークを構築すれば、Accuracy は 0.99 となるが、Sensitivity（感度）が 0% になり、現実的には役に立たない分類ネットワークになってしまう。少ない側のクラスの画像をデータ拡張することを検討しても良いでしょう。

3.3 データの難易度と正解データについて

教師あり学習の場合は、正解データが必要になる。自身で教師データを作成する場合は、判断基準を事前に決めておいて、正解データの作成中に判断基準がぶれないことが重要である。人間の判断がぶれるような対象の場合、その症例の判断を複数回実施して、多数決で決定する方法がある。あるいは、複数人で判断を行い、多数決で行う方法もある。筆者の経験ではあるが、多数決を行うような判断の難しい症例を用いてネットワークの学習を行うと、不安定な学習になる傾向があるので、学習用のデータから除外することを検討しても良いだろう。

4. インターネットサービスからの画像データの入手

近年は、Web やクラウドなどのインターネットサービスから医用画像を入手することが可能であり、医用画像研究を開始する敷居が低くなってきている。例えば、日本放射線技術学会は、胸部 X 線写真データベースを標準デジタル画像データベースと称して、画像部会のホームページで公開している [2, 3]。

医用画像を公開する目的は様々であろうが、CAD などの基礎研究を発展させるために公開されたもの、研究成果を公表するために公開されたもの、コンペティション目的で公開されているものなどがある。一方で、2 でも触れているが、研究計画書の添付に

よるデータの利用申請によって使用できるデータベースはオープンデータとは見なされないことである。筆者の経験では、NIH 米国立医学図書館が作成した人体の解剖構造データベースである Visible Human Project [4]（現在は利用申請は不要である）、その韓国プロジェクトである Visible Korean [5]（データは外付け HDD 等の送付で入手する）は研究計画書を提出して、審査の上で利用可能であった。

4.1 標準デジタル画像データベース [胸部腫瘍陰画像] 【DICOM 版】 [2, 3]

肺結節の検出用のデータベースであり、14 の医療施設から収集された肺結節を含む胸部 X 線写真 154 枚（悪性 100, 良性 54）と含まない写真 93 枚で構成されており、画像部会の Web ページでダウンロード可能である [3]。また、本データベースを基にした MINIJSRT_DATABASE も公開されている。医用画像に関するディープラーニングの研究用に作成されており、画像の方向と性別分類、セグメンテーション、年齢推定、超解像処理、ノイズ低減、オートエンコーダ（教師なし学習）の研究用に再構築されている。教師データの信頼性の観点や画像枚数の観点から、初期的な研究用であろう。

さらに、SCR database (Segmentation in Chest Radiographs) のような本学会以外の研究グループがアノテーションしたデータを公開している [6]。このアノテーションデータは、胸部単純 X 線写真における肺、心臓、鎖骨 の領域分割に関する研究を比較するために開発されており、2 人の観察者がマウスで領域分割したデータが提供されている。なお、SCR の Web ページでは、複数の手法によって領域分割された結果が、画像、重複度、過抽出率、輪郭長で評価されている。

4.2 Web で入手可能なデータベース例

以下に、非商用の研究用途で利用可能なデータベースを紹介する。ただし、利用時には、必ず各 Web ページに記載の利用規約を遵守されたい。

NIH issues huge database of CT scans for AI testing [7] : NIH による AI 開発用の公開データベースであり、約 4,400 人、約 10,600 スキャンの CT データである。肺結節、拡大リンパ節、肝腫瘍などの多数の放射線所見が含まれている。ユーザアカウントの作成だけで利用可能である。

LIDC-IDRI [8] : 米国の肺画像データベースコンソーシアムによって収集された被験者 1,010 名分の胸部 CT 画像データベースである。

NIH Chest X-rays [9] : 約 3 万人の胸部 X 線写真 11 万枚から構成されるデータセットであり、14 種類の胸部疾患が分類されている。

DDSM [10] : 検診デジタルマンモグラフィのデータベースであり、2,620 症例が公開されている。

4.3 Kaggle データベース紹介

Kaggle はデータサイエンスや機械学習の技術を争うコミュニティサイトであるが、ディープラーニングの研究を始めるために役立つデータベースを見つけることが可能

である。Kaggle で実施されたコンペ Diabetic Retinopathy Detection [11]は、眼底画像から糖尿病網膜症の重症度を 5 段階に分類するコンペで、医用画像が Kaggle で認知された切っ掛けの一つである。被験者の両目の眼底画像が用意されており、学習用 17,563 症例 35,126 枚、26,788 症例 53,576 枚の画像から構成されている、大規模なデータベースである、これだけでも本格的なディープラーニングの研究の実施が可能である。他にも、NIH Chest x-rays も Kaggle のサイトでデータの入手が可能である。

Kaggle でデータベースを検索する際は、トップページの「Datasets」のリンクに進み、「Search datasets」のボックスに任意のキーワードを入力して検索すると良いであろう。例えば、「chest x-ray」をキーワードにして検索すると、2022 年 2 月 28 日現在では、図 1 のように 123 のデータセットがヒットする。「Search datasets」の右端の Filters をクリックすると条件設定のダイアログが表示されるので、データセットの絞り込ができる。例えば、4GB 以上に設定すると、19 のデータセットに絞り込める。参考までに、検索結果の一つである「Chest Xray Masks and Labels」というデータセットアクセスすると、肺疾患のデータセットであった。説明文章から、2 つの学術論文で用いられたデータセットであることも把握できる。一括でダウンロードする場合は、ページのタイトルの右下の「Download」をクリックする。

また、Kaggle の「Search」からもデータセットを検索することも可能である。キーワード「chest x-ray」で検索すると、2022 年 2 月 28 日現在では 4,454 件がヒットする。左側に絞り込用の項目が表示されるので、必要な項目をチェックする。図 2 の例では、Dataset Size を Large, Dataset File Type を画像ファイルである png と jpeg に




図 1 Kaggle の検索画面




図 2 Kaggle の検索結果とその絞込

チェックしており、46 件に絞り込んでいる。

Kaggle では、データセットを入手できるだけでなく、そのデータセットを用いたプログラムのコードを参照したり、サイエンティストらの議論を読んだりすることも可能である。ディープラーニングの研究を始めようとする者にとっては、コードも貴重な資料となるであろう。

4.4 データベースサイト

インターネットの検索サイトで検索すれば、オープンデータベースを見つけることが可能である。コンペ用のデータセットを探す場合は、「Challenge」等のキーワードを加えて検索するとよい。医用画像に限定すると、ANCER IMAGING ARCHIVE [12]がわかりやすい。トップページの「ACCESS THE DATA」から検索可能である。筆者が確認した際は、COVID-19-NY-SBU や COVID-19-AR 等のデータセットを検索可能であった。

5 画像の前処理

放射線画像の場合、自身で収集下際の画像フォーマットは DICOM 形式が殆どである。一方で、眼科などのカラー画像、自然画像、動物画像、工業用画像では JPEG, PNG, TIFF 形式の画像が多く用いられており、GitHub などで見られるコードの多くも DICOM 形式の画像を考慮していない。ただし、現在は、DICOM を扱うために高度なコードを書く必要は無く、Python で開発する場合は pydicom を用いる方法があり、また、Tensorflow を用いる場合は、tensorflow_io の「tfio.image.decode_dicom_image」を用いる方法などがある。

筆者の場合、研究の対象の多くがカラー画像という状況もあり、事前に DICOM 形式ファイルを PNG や JPEG に変換している。ただし、DICOM 形式を 8 ビットに変換する際の階調処理では、固定したパラメタで行うことに注意しておく。この際に、画像のマトリックスサイズ（画素数）も研究に合わせて変換している。例えば、本学会の標準デジタル画像データベースの胸部 X 線画像は 2048 × 2048 pixels であるが、このままネットワークに入力すると、メモリ容量の問題や、ネットワークが大きくなることなどの問題が生ずるので、縮小処理を行う。事前に 128 × 128 pixels や 256 × 256 pixels 等に縮小した JPEG 形式などにしておくと、画像ファイルの読み込み時間と計算時間を短縮できる。また、学習データとテストデータを別のフォルダ（ディレクトリ）に別けておくと、学習に用いた画像を誤ってテストに用いたりするミスを防げる。クラス分類する場合は、さらにフォルダ分けしておくとうまいであろう。

6 ネットワークの学習について

自然画像のデータセットの ImageNet [13] は 1400 万枚以上のカラー画像で構成されているが、医用画像でこの規模のデータセットを構築することは極めて困難である。このため、医用画像の場合は、様々な工夫をしてネットワークの学習を行う必要がある。

6.1 データ拡張

ひとつ目の工夫は、画像のデータ拡張である。画像を水増しして枚数を増やし、過学習の危険性を減らすことである。データ拡張には、オフライン拡張とオンライン拡張がある。前者は図 3 のようにデータセットに存在する画像に画像処理を施して画像の枚数を増やす方法であり、前節で述べた画像の前処理の段階で行っておくとよいでしょう。後者はオンザフライ拡張と呼ばれることもある方法で、図 4 のようにミニバッチ学習の際にバッチ内画像に画像処理などを施して、同じミニバッチでも異なるミニバッチに見せかける方法である。オフライン拡張の場合は、データ拡張した分だけ画像ファイルが増えるが、オンライン拡張の場合は、学習の中での処理であるため、画像ファイル数を増やさずに過学習の危険性を下げられる効果を期待できる。




図 3 オフライン拡張のイメージ




図4 オンライン拡張のイメージ

データ拡張の基本的な画像処理法は、画像の回転、上下左右の平行移動、上下左右の反転、拡大・縮小、せん断（矩形から平行四辺形への変換）、画素補間、濃度変換（明るさの変更）、チャンネルシフト（カラー画像の場合）等が知られている。ただし、現実には存在しない変換を行わないように注意する必要がある。例えば、胸部 X 線画像では、通常は腹部が画像の上部に位置することはないため、画像の上下反転や 180 度回転は問題が生ずる。

他のデータ拡張法として、敵対的生成ネットワーク（GAN）を用いて画像を人工生成し、学習用のデータセットに加える方法が成果を挙げている。ただし、GAN にはモード崩壊という問題点が知られており、GAN の生成器（Generator）の学習に失敗してしまい、同じような画像ばかり生成されてしまうと、データ拡張としては役立たないことに注意する必要がある。

6.2 転移学習とファインチューニング

転移学習とファインチューニングは、自然画像などで学習された優秀なネットワークを活用する方法である。転移学習は、既に学習されたネットワークの重みを変えずに他の用途に転用することである。ImageNet で学習された VGG16 の学習済みネットワークが公開されており、医用画像の分類などに利用できる。一方で、ファインチューニングは、学習済みネットワークの一部を微調整することである。

例として、インターネットで公開されている ImageNet で学習済みの VGG16 を医用画像の 2 クラス分類に利用することを考えてみよう。ImageNet は 1000 クラス分類であるので、VGG16 の出力側の全結合層を 2 クラス分類に置き換える必要がある。医用画像の学習データセットを用いてこの全結合層を学習させると、ImageNet 用の VGG16 を利用できることになる。この操作を転移学習という。この際に、医用画像の学習データセットが多めに用意できるのであれば、ネットワークの全部分の重みを微調整しても良く、この操作がファインチューニングとなる。十分な枚数のデータベースを構築できない場合は、転移学習やファインチューニングの適用を検討しても良いでしょう。

7 おわりに

医用画像にディープラーニングを用いた研究が活発に行われているが、まだまだ手つかずの研究テーマが存在しているはずである。新たな挑戦ができるよう、データ収集から積極的に始めるなど、一步を踏み出して欲しい。

参考文献

- [1] 文部科学省・厚生労働省・経済産業省：人を対象とする生命科学・医学系研究に関する倫理指針， <https://www.mhlw.go.jp/stf/seisakunitsuite/bunya/hokabunya/kenkyujigyou/i-kenkyu/>
- [2] 日本放射線技術学会・画像部会：標準デジタル画像データベース(DICOM 版)， <http://imgcom.jsrt.or.jp/download/>
- [3] J. Shiraishi, S. Katsuragawa, J. Ikezoe, et al.: 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, American journal of roentgenology, 174, 71-74 (1), 2000
- [4] Visible Human Project: https://www.nlm.nih.gov/research/visible/visible_human.html
- [5] Visible Korean. <http://vkh3.kisti.re.kr/>
- [6] SCR database. <http://www.isi.uu.nl/Research/Databases/SCR/index.php>
- [7] NIH issues huge database of CT scans for AI testing. <https://www.auntminnie.com/index.aspx?sec=sup&sub=cto&pag=dis&ItemID=121354>
- [8] LIDC-IDRI. <https://wiki.cancerimagingarchive.net/display/Public/LIDC-IDRI>
- [9] NIH Chest X-rays Dataset. <https://www.kaggle.com/nih-chest-xrays/data/>
- [10] DDSM. <http://www.eng.usf.edu/cvprg/Mammography/Database.html>
- [11] Kaggle: Diabetic retinopathy. <https://www.kaggle.com/c/diabetic-retinopathy-detection>
- [12] ANCEER IMAGING ARCHIVE. <https://www.cancerimagingarchive.net/>
- [13] ImageNet. <https://image-net.org/>

(Web サイトは全て 2022 年 2 月 28 日アクセス)

失敗例から学ぶディープラーニング研究の進め方

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

ディープラーニング(DL)技術に関する技術が発達し、技術資料や簡単に動作させることができるソフトウェアも整備されつつある。それに伴い、この放射線技術領域でも DL の研究に取り組む研究者も増えてきている。しかし、学会における発表や投稿論文、研究室で学生が取り組む様子などをみると、データベースの不備、手法選択や学習・評価の誤りが疑われるものが多い。また、そもそも本当にそれは DL ではないと実現できないのか？従来手法ではいけないのか？などの疑問が生じることもある。そこで本稿では、筆者が運営する研究室の経験に基づき、DL 研究で陥りやすい事柄やその解決法や進め方のコツについて解説する。

2. DL 研究の基本的な流れ

画像を対象とした DL 研究を図 1 に示すようにデータ収集から成果の発表までを 4 つのステップに分け、それぞれのステップで注意すべき事項について述べる。



図 1 DL による画像認識処理研究の主な流れ

3. データ収集・加工

3-1. データの混在

本特集の別稿でも述べられているはずだが、DL 研究においては、DL モデルの学習に必要なデータ(学習データ)とは別に、未知のデータに対する処理能力を評価するための評価データを設ける必要がある。ここで注意したいのがデータの混在である。CT 画像を用いた研究を例にとると、同じ患者から得た撮像位置の異なる複数の CT スライス画像が DL モデルの学習や評価に利用できる。ここでもし同じ患者のスライス画像が学習データと評価データに分散していたとすると、たとえスライスの位置が異なっていたとしても学習データと類似した画像が評価に利用されることとなり、正しい評価が行えない(処理性能が実際よりも高めに出現)。DL 用ソフトウェアの中には、用意した画像をランダムに学習データと評価データに振り分ける機能があるが、同じ患者の画像が混在しないように振り分ける機能は搭載されていない。1つの症例に複数の画像が含まれる場合は、症例の単位で振り分けができる専用プログラムを作成するか、手作業で画像を割り振る必要がある。

3-2. データの偏り

DL は与えられたデータを用いて内部の最適化が行われるため、その性能は学習時に与えたデータに大きな影響を受ける。データを複数のクラスに分ける分類問題の場合、特定のクラスのデータ数が多く、クラス間のデータ数に偏りがある場合、データが多いクラスを正しく分類するように学習が進むことが多い。例えば、画像を正常と異常に分類する処理において、正常症例が90例、異常症例が10例あり、分類処理の結果は全ての症例が正常に分類されたとする。この場合、トータルの分類正解率だけを求めると 90%と非常に高いのだが、異常症例を全く認識できておらず良好な結果とはいえない。初歩的なことなのだが、正解率だけでなく感度や特異度、F スコアなどを用いて総合的に評価する必要がある。

もしデータ数の偏りがある条件で処理性能が芳しくないとき、まずはデータの偏りを緩和する取り組みが必要であるが、データを偏りなく集めることは実際には難しい。データ数の偏りの影響を緩和する方法の一つの方法として、データ拡張(Data augmentation)がある。画像に対して回転や拡大縮小、画質の調整等によってデータ数を増加させる技術である。単純な画像加工を施してデータを水増しするだけなのだが、データ数の偏りが緩和することによって処理が安定することがある。また、DL のライブラリによっては分類する際のクラスウェイトやサンプルウェイトといったパラメータが用意されているので、活用すると良い。

画像セグメンテーション処理を行う場合も偏りの影響を受ける。例えば面積の大きい対象物が学習データに多く含まれている場合、面積の小さいものに対するセグメンテーション精度が低くなることが多く、その逆も生じる。さまざまなバリエーションのパターンが学習データや評価データに含まれるようにしたい。

3-3. データの数

データ駆動型の処理技術である DL は多くのデータを必要とする。それではどの程度データが集まれば良いのだろうか。データ数が多いほど良好かつ安定した結果が得られたという報告はあるが、与えられた処理に対して必要な学習データ数を導くことはできない。

現在公開されている胸部 X 線画像や全身 CT 画像は数万症例を超えるものもあり、膨大な画像データを用いた処理が一般的になりつつある。しかし筆者の研究成果も含め、50～100例程度の症例数を対象とした研究論文も多い。少数のデータを対象とする場合は処理性能のばらつきが大きいので、繰り返し評価を行い、正解率などの平均値と標準偏差を求めて安定性を確認することが必要である。また、少数データを DL で処理する際には与えられたデータを有効に活用するため、交差検証法で評価を行ったほうが良い。

4. 手法選択

4-1. 不必要な DL 利用

画像認識処理において DL は優れた性能を示すことが多い。しかし、必ずしも DL が必要ではないことも多い。手法選択の失敗例として、無駄な DL 利用について紹介したい。

まず、DL ではなく既存の枯れた技術でも十分な性能が発揮できるタスクに DL は不要である。例えば、輪郭検出処理は古くから用いられているエッジ検出処理(ラプラシアンフィルタによるものや Canny

エッジ法など)で十分実用になり、直線を検出したい場合はハフ変換という確立した手法がある。DL を使用することを目的とせず、目的とするタスクに最適な手法を選択すべきである。

DL は層数の多いニューラルネットワークを用いた技術を指すが、処理内容によっては多くの層数は必要なく、従来の3層のニューラルネットワークでも十分な性能が得られる処理も多い。例えば、入力するデータの種類の数が10数種類と少なく、学習に利用できるデータ数も少ない場合などは層数が少ないネットワークや従来の機械学習法が適している。データの種類の数に合わせた手法選択が重要である。

4-2. 不可能な DL 利用

DL の登場によって、これまでに解明されてこなかったことが明らかになることもある。しかし、DL は魔法の杖ではない。DL 研究を進めても思うような性能が得られないとき、どのように検討を進めれば良いだろうか。

DL に限らず一般的なことであるが、うまくいかない理由は(1)研究者の技量の限界(=他の研究者なら達成できる可能性が高い)(2)現在の技術レベルの限界(=今は無理でも将来はできる可能性がある)(3)そもそも無理な問題だった(=現在の条件設定では無理)などが考えられる。

(1)であれば、自らの研鑽で克服したり、身近な研究者やインターネットなどでアドバイスを受けたりすることなどにより問題解決が可能である。(2)は自らが新しい技術を生み出して解決することもできるし、世界中の研究者に共通する問題が根底にあれば誰かが解決してくれる場合もある。とにかく時間が必要である。(3)については条件設定(与えるデータや対象疾患などを変更する)を行うことで問題が易化することもあるが、それが困難な場合は諦める勇気も必要である。

問題は研究がうまくいきそうか見極めるタイミングである。従前は限られたデータ量で試しに処理して振る舞いを観察する予備実験を行い、その後しっかりした条件にて本実験を行うほうが良いとされてきた。しかし、上述したように DL は多くのデータを必要とするため、予備実験が困難になっている。そのため期待した性能が得られず原因も解明できないままお蔵入りする研究は多いと思われる。自力で解決することが難しそうな場合は、より経験値の高い研究者にアドバイスを求めることをお勧めする。インターネット上の掲示板では DL に携わる研究者が盛んに議論を行っており、比較的気軽に質問できるようになっているので活用いただきたい。

5. 処理・評価

DL の処理結果を評価する方法については別稿に任せたいが、ここでは DL 研究の評価結果を示す際の問題点に関して私見を述べたい。

5-1. 数値の過信

まず、画像研究を対象とした場合には、画像を評価結果として載せるべきである。分類処理の場合は分類成功した結果、分類失敗した結果を示し、どのような特徴をもつものは正しく分類され、逆に失敗する画像にみられる特徴はどのようなものか示すべきである。DL や Radiomics 研究の口頭発表や論文の中には、まったく画像が登場せず分類精度のみが示されるケースが散見される。医学研究の場合、どの

ような症例が正しく処理できてどのようなものは難しいか知ることは、手法の特性を知る上で非常に重要である。何より画像処理の研究で画像が全く示されないのはナンセンスであると考えている。もし画像の示されていない論文の査読に筆者に回ってきたときには、信頼性が欠如しているとしてリジェクトにすることが多い。画像を示すのは画像処理を手がける研究者としての義務であるとして強く主張しておきたい。

5-2. 比較の重要性

失敗例ではないが、DL 研究に限らず新規性・有効性を示すためには比較評価が必要不可欠である。もし単一の方法のみで導いた内容で研究発表や論文投稿を行なうと、「他の State-of-art な手法との比較は実施しないのか？」という質問やコメントが寄せられることが多い。研究が仕上がったあとに別のモデルを試すことはロスが非常に大きくなるため、できれば検討初期の段階で複数の DL モデルを比較評価し、良好な性能を示す DL モデルに対して解析・考察を加えるべきである。

6. 成果の公表

進めてきた研究がこれまでに行われていない新しいものであったり、従来よりも良好な結果が得られたりした場合には、その成果を口頭発表や論文投稿し、広く公表することが望ましい。しかし、DL 研究は世界中で行われているため、完全な新規の研究は少なくなっている。自分たちが最初に取り組んだと思っていても、文献検索すると同じような研究が発見されることも少なくない。誰もが必要とするような重要な研究テーマは多くの研究者が既に取り組んでいるものである。発表は早い者勝ちなので、発表できそうな結果が出たら躊躇せず早めに発表や論文投稿していくことが重要である。詳細を詰めてから発表しようと考えていたらタイミングを逃すこととなる。また、類似する研究が存在していた場合、自身の検討した内容の良いところや新しいところを見つけ出す努力が必要となる。

7. 最後に

本稿では、DL の初学者が失敗しそうな項目を取り上げ、対処方法について述べた。今後さらに DL 研究が進み、多くのノウハウが蓄積されていけば、本稿で取り上げたような失敗は少なくなっていくであろう。放射線技術領域における DL 研究の成熟を期待したい。

乳房構成解析ソフトウェア 「Breast Density Assessment」の紹介

コニカミノルタ株式会社 南 寛威

1 はじめに

乳がんは、日本人女性のかかるがんの中で最も罹患率の高いがんであり、その罹患数は年々増加している。現在、乳がん検診では、死亡率の減少が証明されている唯一の検査であるマンモグラフィー検査が基本とされている。マンモグラフィー検査は、乳腺組織の多寡によって病変の検出感度が異なることが知られており、乳腺が発達している方の場合は、検出感度が低下することが問題となっている。この乳腺が発達した乳房を「高濃度乳房」と呼び、検診のあり方を考える上で近年関心が高まっている。

マンモグラフィー検査と相補的な機能を持つ検査として、超音波検査がある。超音波検査は、マンモグラフィー検査では乳腺に隠れて描出できない病変の検出を補う有力な検査法であることが示されている[1]。そのため、高濃度乳房に対して、マンモグラフィー検査と超音波検査を併用して行うことを推奨する動きが国内で活発になってきている。しかしながら、超音波検査の追加要否を決定する高濃度乳房の判定は、医師のマンモグラフィー画像における視覚評価により行われ、読影者間や読影者内の判定結果の再現性確保が課題となっている。

コニカミノルタは、この課題に対してマンモグラフィー画像から乳房構成を客観的な指標で判定する乳房構成解析ソフトウェア「Breast Density Assessment (Bda)」を開発した。本稿では、乳房構成解析ソフトウェアのアルゴリズム、システムの特徴、および医師の視覚評価との比較結果について紹介する。

2 乳房構成と主観評価における課題

乳房は乳腺組織と脂肪組織によって構成され、マンモグラフィー検査では、乳腺は白く、脂肪は黒く描画される。また、病変は白く描画されるため、高濃度乳房の場合は病変が乳腺に隠れて見えづらく、病変の判別が難しいことが課題となっている。この病変が正常乳腺に隠されてしまう可能性の程度を示す指標が、“乳房構成”である。

乳房構成の判定方法は、日本乳がん検診精度管理中央機構（以下、精中機構）によって定められており[2]、乳腺組織の割合が少ないものから順に、脂肪性、乳腺散在、不均一高濃度、極めて高濃度の4つに分類される（図1）。このうち、病変の検出が難しいとされる不均一高濃度と極めて高濃度を併せて“高濃度乳房 (dense breast)”と呼んでおり、超音波検査を追加する判断のひとつとなりつつある。

乳房構成の判定は、読影者の定性的な視覚評価により行われている。視覚評価は、簡便な判定方法である一方、主観的な判定となり、普遍性と客観性に乏しく、判定結果が読影者や読影条件等によって異なることが知られている。このような人の目や経験では再現性高く判断することが難しい微妙な乳房構成の違いについて、客観的に判定し再現性を担保することが乳房構成を評価する上での重要な課題となっている。




図1 乳房構成とマンモグラフィー検査における病変検出率

3 乳房構成解析ソフトウェアの処理概要

本ソフトウェアの処理フローは、精中機構のガイドラインの考え方[2]に基づき、乳腺組織がもともと存在していた領域を抽出するプロセスと乳腺が現存する領域を抽出するプロセスから構成される。

乳腺組織がもともと存在していた領域は、皮下脂肪と大胸筋部分、および、あきらかな乳腺後隙の脂肪のみの部分を除いた領域で決定される(図2のb領域)。一方、乳腺領域(図2のc領域)は、処理済み画像を入力画像としているために起こり得る画像処理条件をはじめとした、受診者の個体差、撮影手技といった外部因子の影響を除いた計算領域(図2のd領域)の情報を参照して抽出する。特にスキンライン付近は、乳房圧迫厚に未達の領域(乳房が圧迫板にも撮影台にも接触していない領域)となるため、上述の外部因子の影響が顕著に画像として表現される。そこで、当該領域を除いた領域を計算領域として利用することにより、ロバスト性を確保した乳腺領域の抽出を行う設計とした。




図2 乳房構成の評価方法

乳房構成のカテゴリーは、乳腺組織がもともと存在していた領域(図2のb領域)における乳腺領域(図2のc領域)の割合を乳腺割合とし、乳腺割合から4段階のカテゴリーを算出している。また、本ソフトウェアでは乳房構成を瞬時に把握できるように、算出した4段階のカテゴリーをKMDC(konica minolta density category)スコア(脂肪性を1、散在性を2、不均一高濃度を3、極めて高濃度を4)で表現している(図3)。




図3 乳腺割合と乳房構成カテゴリーの関係性

4. システムの特徴

4.1 視認性を重視した判定結果の出力設計

乳房構成は”脂肪性”から”極めて高濃度”まで連続的なものであり、その程度を提示することが判定結果の確認時や受診者への説明時に重要と我々は考えている。本ソフトウェアの判定結果の表示形式は直感的な視認性を重視した設計であり、読影の効率化をサポートする。表示の右部に、左右乳房に対する乳房構成の判定カテゴリー（図4（a））とそれらの乳腺割合（図4（b））をグラフィカルに表示する。また、画像中央には左右の乳房構成のうち、より高濃度の判定カテゴリー結果を表示する（図4（c））。

このような表示方法により、乳房構成の判定結果を瞬時に把握でき、さらに出力結果の詳細を確認することで、左右の乳房構成に関する情報を直感的に捉えることができる。




図4 乳房構成解析結果の出力例

4.2 フレキシブルな導入システム

本ソフトウェアは、既存の画像診断システム（PACS等）とのフレキシブルな接続を行うために当社の画像処理機能搭載ゲートウェイである Senciafinder（センシアファインダー）に搭載される。乳房X線撮影装置で撮影された画像処理後のデータを Senciafinder が受信すると、図4に示す表示スタイルで処理結果を出力する。DICOM Secondary Capture Statement 形式で処理結果を出力することより、一般的な読影端末で表示が可能であり、施設運用に合わせたフレキシブルなシステム提案が可能なることから、導入への障壁が低いことも特徴である。図5にシステムの構成例と Viewer での出力例を示す。




図5 システムの構成例と Viewer での出力例

5 医師の視覚評価との比較

医師の視覚評価の結果と本ソフトウェアの結果に画像処理が与える影響について笠井ら[3]の報告がある。笠井らは、58 症例（116 乳房）に対して画像処理 A とコントラストおよび鮮鋭度を強調した画像処理 B を適用し（図 6）、それらの中で乳腺科医 1 名の判定結果と本ソフトウェアの判定結果の変化を確認する評価実験を行った。評価の結果、画像処理 A から画像処理 B に画像処理条件が変化することによって、医師の判定結果と本ソフトウェアの判定結果はともに“脂肪性寄り”に変化することが報告されている（表 1）。




図 6 画像処理違いの画像

医師の判定結果	画像処理A	画像処理B	差
乳腺含有率の平均値	55.4%	47.8%	▼7.6%
4分類判定の平均値	2.72	2.4	▼0.32
ソフトウェアの判定結果	画像処理A	画像処理B	差
乳腺含有率の平均値	45.2%	43.3%	▼1.9%
4分類判定の平均値	2.64	2.59	▼0.05

表 1 医師とソフトウェアの乳房構成の判定結果

上記結果より、本ソフトウェアは画像処理条件が異なる症例についても、適切に乳房構成の判定ができることが確認された。また、読影者の感覚に合う納得性のある乳房構成の判定ができていることから、医師の読影を支援できる可能性が示唆されている。

6 おわりに

マンモグラフィ画像から乳房構成を客観的な指標で判定する乳房構成解析ソフトウェア「Breast Density Assessment (Bda)」を開発した。本ソフトウェアを利用することにより、従来困難であった再現性の高い乳房構成の判定が可能となり、各人の乳房の特徴に合わせた乳がん検診、すなわち「個別化検診」の実現に貢献できると考える。

コニカミノルタは、今後も個別化検診をサポートすることで、一人ひとりにとって乳がん検診をよりよいものにし、乳がんの早期発見と治癒率向上に貢献していく所存である。

●参考文献

- [1] Narumi Harada-Shoji, Akihiko Suzuki, Takanori Ishida, Ying-Fang Zheng, Yoko Narikawa-Shiono, Akiko Sato-Tadano, Rie Ohta, Noriaki Ohuchi, “Evaluation of adjunctive ultrasonography for breast cancer detection among women aged 40-49 years with varying breast density undergoing screening mammography: A secondary analysis of a randomized clinical trial”, JAMA Network Open, 4(8):e2121505, (2021)
- [2] 日本乳がん検診精度管理中央機構 お知らせ 「乳房構成の判定方法」
<https://www.qabcs.or.jp/news/20200206.html> (2021.10.21)
- [3] 笠井聡、甲斐千遥、櫻井典子、南寛威、勝原慎介、児玉直樹、「マンモグラムを用いた乳房構成解析における画像処理の影響調査」、日本放射線技術学会誌、77(9)、1044 (2021)


フレキシブル TFT を採用したカセット DR について

～FUJIFILM DR CALNEO Flow の紹介～

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、X線を読み取るセンサーパネルに軽量の薄型フィルムの TFT 基板（以下、フレキシブル TFT）を採用し、当社画像読取技術と組み合わせてさらなる軽量化と高感度化を実現したカセットサイズデジタル X 線画像診断装置（以下、カセット DR）「FUJIFILM DR CALNEO Flow（カルネオ フロー）」を、2020 年 12 月に発売した。今回、「FUJIFILM DR CALNEO Flow」の技術を紹介する。



【FUJIFILM DR CALNEO Flow G47】 【FUJIFILM DR CALNEO Flow C47】

図 1 : FUJIFILM DR CALNEO Flow

2. 軽量・高感度化

カルネオシリーズは、低線量で高画質な X 線撮影を実現するカセット DR として、2009 年の発売以降、多くの医療現場で高い評価を得ている。これまでのカルネオシリーズは、ガラス素材の TFT 基板をセンサーパネルに搭載していたが、「CALNEO Flow」には、最新のスマートフォンやタブレットなどに使用されているフレキシブル TFT を採用した。2011 年に発売した第 1 世代のワイヤレスカセット DR と比べ、重量を約 40% 減と大幅に軽量化。GOS シリーズの 14x17 インチサイズは約 1.8kg（バッテリーを除く重量）で、軽量化によりカセット DR の取り回し性が向上し、さまざまな X 線撮影現場で快適に利用できる。



図 2：フレキシブル TFT による軽量化

3. 低線量・高画質化

X線が入射するセンサーパネルの表面から光信号を効率良く読み取る当社 ISS（Irradiation Side Sampling）方式を継承。ISS方式は従来型の FPD と反対側の X線照射面側にセンサーを配置し、X線の照射面側より X線から変換された光信号を読み取る方式である。フレキシブル TFT の採用で、ISS方式の特長であるシンチレータ層の X線エネルギーの減衰や拡散の影響を低減する効果はそのままに、従来機と比較して X線エネルギーの透過性が向上した。これにより、CsI シリーズにおいて DQE が従来機から 4 ポイントアップの 58%（1Lp/mm・1mR）を達成した。

ISS方式とフレキシブル TFT の組み合わせは、さらなる軽量化と高感度化を実現し、フレキシブル TFT のメリットを最大限に引き出すことができた。また、フレキシブル TFT をカセット DR に採用するには大型サイズでの製造が難しいという課題があるが、当社は写真フィルムの生産で培ってきた生産技術によって、高品質な大型のフレキシブル TFT および X線検出器の安定的な生産を可能とし、カセット DR への搭載を実現した。




図 3：フレキシブル TFT の採用でボケの少ないシャープな画像を提供

4. タフネス設計

近年、カセット DR の使用用途が災害現場や在宅診療分野へも拡大していることを受け、さらなるタフネス化を実現した。従来の X 線検出器にはガラス素材の TFT 基板を採用していたため、衝撃によるガラス割れがあり、重量も重くなっていた。「CALNEO Flow」はフィルム素材の TFT 基板を採用しており、従来のガラス割れの心配がない。また、カセット DR の内部フレームに、新たに Mg-Li（マグネシウム-リチウム）合金の鍛造フレームを採用し、軽量ながら耐荷重 310kg を実現した。さらに、防塵・防水の保護規格 IP56（*1）に準拠しており、より安心して使用いただける。カセット側面がラウンド形状のため、カセットを持ち上げる際に指がかかりやすく、撮影時に患者とベッド間の挿入性の向上にも寄与している。

（*1）「IP（侵入への保護）」とは「IEC（国際電気標準会議）」によって定められている防水・防塵の保護規格。IP5X は防塵 5 級を指し、「粉塵が内部に侵入せず、若干侵入しても正常運転を阻害しない」ことを示す。IPX6 は防水 6 級を指し、「あらゆる方向からノズルによる強力な噴流でも有害な影響がない」ことを示す。



図 4：防塵・防水の保護規格（IP56）に準拠

5. 清潔性

当社の抗菌コート技術「Hydro Ag」でカセット DR の全面に抗菌コーティングを施した。塗布膜表面の銀イオン濃度が高くなり、従来の抗菌コートと比べて約 100 倍の抗菌性能を実現し、さらに、その効果が長期間持続する。銀系抗菌剤を含有した超親水性膜により、カセット表面に付着した汚れも拭き取りやすく、清潔で衛生的に使用いただける。（*2）

（*2）抗菌規格 JIS Z 2801 に適合、国際規格 ISO22196 に対応した SIAA（抗菌製品技術協議会）登録商品。




図5: 抗菌規格 JIS Z 2801 に適合、国際規格 ISO22196 に対応

6. おわりに

富士フィルムは、今後もさまざまな医療現場のニーズに応え、医療従事者のワークフロー効率化・医療の質の向上、人々の健康維持増進に貢献していく。

品名

「FUJIFILM DR CALNEO Flow」

販売名 デジタルラジオグラフィ DR-ID 1800 / 認証番号: 302ABBZX00021000 号

構成品

[1] フラットパネルセンサ

14×17 インチサイズ

CsI タイプ: FUJIFILM DR CALNEO Flow C47 (DR-ID 1811SE)

GOS タイプ: FUJIFILM DR CALNEO Flow G47 (DR-ID 1831SE)

17×17 インチサイズ

CsI タイプ: FUJIFILM DR CALNEO Flow C77 (DR-ID 1812SE)

GOS タイプ: FUJIFILM DR CALNEO Flow G77 (DR-ID 1832SE)

10×12 インチサイズ

CsI タイプ: FUJIFILM DR CALNEO Flow C12 (DR-ID 1814SE)

[2] 画像処理ユニット (DR-ID 300 の構成品 DR-ID 300CL、認証番号: 第 221ABBZX00151000 号)

「第 22 回 DR セミナー（オンライン）～おうちで学ぶ 超初心者のための物理評価～を受講して」

松江市立病院 放射線部 岩坂 徹

2021 年 12 月 12 日に開催された JSRT 画像部会主催の DR セミナー（オンライン）お家で学ぶ超初心者のための物理評価を受講しました。私も 44 歳になり、大学を卒業し 22 年経過しました。日々の臨床業務に追われて、基礎的な物理評価や画像評価から離れて、何となく導入された機器を使う日々を送ってきました。その中で当院も 2005 年に導入したフジフィルムメディカルの FCR からユニカの FPD にシステムが変わることになりました。システムが変更され、仮想グリッドなどの新しい技術が導入され、このシステムでの物理グリッドと仮想グリッドでの画質の違いは？必要な線量はどのくらい違うの？システムでのノイズは CR と比べてどのくらい違うのか？空間分解能が高いとは言うのだけどどのくらい高いのか？今の自分の知識では物理評価の知識はフィルムスクリーン系の知識しかもっていなかったため、そろそろ知識の更新が必要だと感じました。しかし、当院の立地は都市部から離れており、なかなか imageJ の使い方や、物理評価のセミナー等を受講する機会もほぼ無く、広島や岡山、大阪まで出向く必要がありました。そんな時にこのオンラインハンズオンセミナーの存在を知りました。

せっかくのセミナーでしたが申し込みは抽選という事で祈る気持ちで発表を待ち、受講当選がわかった時には踊りだしたいほどの喜びに見舞われました。



図 1 受講環境

受講前に「Slack」を用いたやり取りはメールでのやり取りよりも非常にスピーディーでわかりやすかったです。また、ImageJ の環境構築や資料の事前配布のやり取りも簡便でとても分かりやすかったです。

受講はデジタル X 線画像計測の内容を分かりやすく、ハンズオンの内容に沿った講習と実際のデータを用いた解析のハンズオンの実施講習とのパートに分かれていました。

NPS は ImageJ による試料の抽出からトレンド除去しフーリエ変換したパワースペクトルを求め、テキスト抽出をし、エクセルの計算シートを用いて空間周波数ごとの NPS を求めるという流れを行いました。この受講を受けるまでは？しか浮かばない内容でしたが、初学者にもわかりやすい授業の説明と、ハンズオンでの指導。またエクセルの計算シートがあつて 44 歳の初学者のおじさんでも受講で習得することが可能でした。

MTF の測定は矩形波チャート法しか理解していなかったのですが、エッジ法の説明も非常にわかりやすく、わかりやすいだけでなく、ハンズオンでその測定技術を難なく取得することができました。リアルタイムの進行についていけな

い、または何らかのトラブルについていけない方にはサポートの方が画面共有ツールを使用したサポートで解決してくれるために皆が最後までついていくことができ、本当に助かりました。

本来なら今回の講習のためのデータ取得等のハンズオンがあればいいなと感じていました。具体的にはタイムスケール法の設定レイアウトや、エッジ法のための試料取得等をハンズオンがあればもっと…と思いました。これは Web ではなかなか難しいのでこのコロナのご時世が終わったらぜひ機会があれば参加したいと思います。

講習後に当院のシステムについて若者たちと一緒にになってなんとか計測を行い、自分なりに自施設のFPD、CRの物理評価を行いました。これも今回の講習があつての賜物と思っております。

20代の若い世代にはぜひ一度受講をしてもらい、自施設の画像評価を行ってみてほしいと思います。その為には40台のおっさんも、未取得の方は是非受講していただきたいと思います。下にやれと言ってもなかなか聞いてくれないという方も多くいると思います。だからこそおっさんも一緒に受講して若者と知識を共有し、学術発表につなげるいい機会だと思います。この記事最後まで読んでくれたあなた、このハンズオンは初学者にも、多少は知っているのだけど、独学で人に教えるまでは…というあなたも、ぜひ一度受講をしてみたいと思います。いくつになっても新しい知識を得るという事は非常に気持ちがいいものだと感じました。最後に今回のハンズオンを運営していただいた篠原画像部会長、小野寺先生、東出先生、柳田先生、由地先生他画像部会理事各位に改めてお礼申し上げます。ありがとうございました。

「第 22 回 DR セミナー（オンライン）～おうちで学ぶ 超初心者のための物理評価～を受講して」

兵庫医科大学病院 放射線技術部 濱 康彦

日頃の研究では、DRセミナーで使用しているオーム社の「標準デジタル X 線画像計測」の教科書を読みながら、もしくは先輩方にご指導いただきながら一般撮影の実験を行っておりました。実際にデータ取得や解析のことについて詳しく受講したことがなかったため、2021 年 12 月 12 日に開催された「オンライン DR セミナー ～ おうちで学ぶ超初心者のための物理評価～」に参加させていただきました。

今回のセミナーはオンラインにて行われました。講習内容は事前学習として「入出力特性」、当日の「MTF」、「NNPS」の講義・演習でした。どの講義においても先生方の講義は分かりやすく説明していただけており、教科書を読んでも曖昧な理解で終わってしまった部分をより深く理解できたと思います。当日の演習においては、画像データ、Excel シート、ImageJ を使用して実際にデータ解析を行いました。演習の過程で、その操作は何を意味しているのか、どのような注意点があるのか、を解説しながら進めていただけたので、講義で教えていただいた内容とリンクさせながら演習を行えました。演習途中で macro が起動しない等のエラーが起こった受講生に対しては、個別で指導を行い、解決してから合流するという流れで対応しており安心してオンラインでも演習を受けることができました。

また、講師の方たちが実際にデータを取得している様子を動画で見せていただきました。X 線管球が FPD へ垂直に入射している事を確認するために鏡を使用しておられましたが、当院で実験する際に使用したことは無かったため今後実験する際には活用させていただこうと思います。

他に印象に残った話としては、NNPS を評価する際の基準線量を FPD の感度に合わせて減らしてもよいのではないか、という考えです。どのように基準やルールが変化していくかを知るためにも、今後も勉強会、講習会には積極的に参加していこうと思いました。

今回のオンライン講習会では貴重な経験をさせていただきました。しかし、対面での講習の良さもたくさんあると思いますので、今後対面での講習会が行われる際には、ぜひ参加させていただきたいと思います。最後になりましたが、今回、我々受講生のための分かりやすい資料づくり、当日はスムーズな進行をしていただき、主催者、講師の方々には大変感謝しております。

フィルタ処理の基礎

広島市立大学大学院情報科学研究科 青山 正人

1. はじめに

画像に対する基本的な処理であるフィルタ処理は、処理を適用する領域（実空間領域か空間周波数領域）の違いにより空間フィルタリングと空間周波数フィルタリングに大別される。本稿では、実空間領域でのフィルタ処理である空間フィルタリングを対象にその基礎的な内容[1]について述べる。

2. 空間フィルタリング

空間フィルタリングでは入力画像の注目画素に対応する出力画素値を、注目画素の周囲の画素値も参照して計算する。例えば、図1左に示す入力画像と用いるカーネルにおいて、カーネル中央の斜線画素の出力をフィルタ係数と入力画像の積和演算を用いて計算するものである。このときに用いる計算式が線形で表現できるフィルタを線形フィルタ、表現できないフィルタを非線形フィルタと呼ぶ。




図1：空間フィルタリング

線形フィルタとは、出力画像の画素値が以下の式で計算できるものである。

$$dst(i, j) = \sum_{n=-\ell}^{\ell} \sum_{m=-k}^k src(i + m, j + n)h(m, n) \quad \dots(1)$$

式(1)において、 src 、 dst はそれぞれ入力画像、出力画像、 h はサイズが $(2k + 1) \times (2\ell + 1)$ のフィルタカーネル、 (i, j) は画素の座標（左上が $(0, 0)$ ）を表している。図1は、 $i = 3, j = 2, k = \ell = 1$ 、フィルタ係数をすべて1としたときの計算例（出力値220）を示している。

2-1. 微分フィルタ

画像の明るさの変化（エッジ）を検出するために使われるフィルタ処理である。エッジ検出の方法として画像の微分が用いられる。

一次の偏微分の考え方に基づいたフィルタの代表的なものとして、図2に示すソーベルフィルタがあり、式(1)の計算により x 方向、 y 方向の二方向の勾配が求められる。求められた勾配をそれぞれ $\Delta x(i, j)$ 、 $\Delta y(i, j)$ とすると画像全体での勾配の大きさを表す勾配強度画像は $\sqrt{\{\Delta x(i, j)\}^2 + \{\Delta y(i, j)\}^2}$ 、方向を表す勾配方向画像は $\arctan \frac{\Delta y(i, j)}{\Delta x(i, j)}$ で計算できる。図3の入力画像（ 2048×2048 画素、4096階調の画像[2]を 512×512 画素、256階調に変換した画像）に対して求めた x 方向、 y 方向、画像全体の勾配強度画像をそれぞれ図4(a)、(b)、(c)に示す。エッジの強度が画像の輝度に対応している。

-1	0	1
-2	0	2
-1	0	1


-1	-2	-1
0	0	0
1	2	1

(a) x 方向 (b) y 方向


図2：ソーベル




図3：入力画像



(a) x 方向



(b) y 方向



(c) 画像全体

図4：勾配強度画像

二次の偏微分の考え方に基づいた微分フィルタとして図 5 に示すラプラシアンフィルタがある。画素 (i, j) に対し、カーネル中央と上下左右 (4 近傍) 方向の画素値を参照する (a) のフィルタ係数とさらに対角線 (8 近傍) 方向の画素値も参照する (b) のフィルタ係数などが使われる。図 3 に対して図 5 (b) のカーネルを適用した結果を図 6 に示す。図 6 では、ラプラシアン出力値 0 が 256 階調の中央である 128 となるようにオフセットを加えている。出力画像から肋骨のエッジに対応する部分が強調されていることが視覚的に確認できる。

0	1	0
1	-4	1
0	1	0

1	1	1
1	-8	1
1	1	1

(a) 4 近傍 (b) 8 近傍

図 5 : ラプラシアン

0	-1	0
-1	5	-1
0	-1	0

-1	-1	-1
-1	9	-1
-1	-1	-1

(a) 4 近傍 (b) 8 近傍

図 7 : 鮮鋭化




図 6 : 図 5 (b) によるラプラシアン




図 8 : 図 7 (b) による鮮鋭化

2-2. 鮮鋭化フィルタ

画像のエッジに対応する部分を強調するフィルタ処理である。信号処理の観点からみれば、空間周波数が高い成分を強調することに相当するが、空間フィルタリングを用いても実現しやすい。微分フィルタで紹介したラプラシアンフィルタでは、処理結果がスカラで得られるため、図 7 に示すように、元の画像 (カーネル中央のフィルタ係数のみ 1、その他の係数は 0) からラプラシアンのフィルタ係数を引いたカーネルによって実現できる。図 3 の入力画像に対して図 7 (b) を適用した結果を図 8 に示す。図 3 に対して図 6 の結果を引いた処理 (鮮鋭化) を行うことで、エッジに対応する部分が入力画像 (図 3) より鮮明になり捉えやすくなっている。


2-3. 平滑化フィルタ

入力画像からノイズ除去を行うために用いられるフィルタ処理である。ガウシアンフィルタはフィルタ係数として式(2)に示す、平均値 0、標準偏差 σ の二次元の等方的なガウス関数を用いる。ガウス関数は


定義式に標準偏差 σ を含んでおり、この σ をパラメータとして平滑化の度合いを調整できるという特徴を持っている。

$$G(x,y) \equiv \frac{1}{2\pi\sigma^2} \exp\left\{-\frac{x^2+y^2}{2\sigma^2}\right\} \quad \dots(2)$$


図 9(a)、(b)、(c)に $\sigma = 1.0, 3.0, 5.0$ としたときのそれぞれの式(2)のグラフとガウシアンフィルタを入力画像（図 3）に適用した結果を示す。処理結果より、 σ の値が増加するにつれて平滑化の度合いが強くなっていることが視覚的に確認できる。ただし、ガウシアンフィルタを適用する場合は、カーネルサイズに注意が必要である。図9のグラフの形状から σ を大きくするとカーネルで参照すべき範囲も大きくなり、グラフに示した x, y の範囲では、ガウス関数の「すそ」の部分まで十分に含まれていないことが分かる((b)、(c))。もし、「すそ」の部分まで適切に含むようなサイズのカーネルを用いなかった場合は、ガウス関数による正しい平滑化は行えていない。



ガウス関数のグラフ



ガウス関数のグラフ



ガウス関数のグラフ



処理結果
(a) $\sigma = 1.0$



処理結果
(b) $\sigma = 3.0$



処理結果
(c) $\sigma = 5.0$

図 9 : ガウシアンフィルタ

【参考文献】

- [1] 田村秀行 編著：“コンピュータ画像処理”，オーム社，2002
- [2] 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

デジタル画像の基礎

八戸市立市民病院 医療技術局 放射線科 下沢 恵太

1. はじめに

X線画像がデジタル化し、画像処理により様々な濃度・コントラスト調整などの画像処理が可能となった。アナログでは表現が難しい画像も、撮影後に何度でも調整可能になり大きなメリットである。このような処理を行うためには、アナログの情報であるX線情報をデジタル信号に変換が必要である。その過程では様々な処理が行われているが、臨床現場で意識する場面は多くはないと思われる。今回はデジタル画像がどのような処理過程を経て画像化されているかを復習する。

2. CRとFPD

デジタル撮影システムとして、CR(Computed Radiography)やFPD(Flat Panel Detector)が用いられている。CRは輝尽性蛍光体を塗布したIP(Imaging Plate)に被写体を透過したX線を蓄え、IPにレーザー光を当て輝尽性発光を起し、その光を電気信号、デジタル信号に変換することで画像化するシステムである。一方FPDには直接変換型と間接変換型の2種類ある。名前の通り、X線を直接的に電気信号に変換するか、間接的に変換するかの違いである。直接変換方式は、X線がアモルファスセレンと呼ばれる光電導体によってX線強度情報が電気信号に変換され蓄積コンデンサに一時的に蓄えられ、順次取り出される。間接変換方式は、GOSやCsIなどのシンチレータでX線強度情報を一度可視光に変換される。その光をフォトダイオードで電気信号に変換して取り出される。取り出された信号はコンソールに送られ様々な画像処理が施され画像となる。

3. 線形システム

線形システムとは、あるシステムにおいて入力と出力の結果が比例関係になるシステムの事を言う。比例関係にならないシステムは非線形システムという。

一般撮影システムにはLogシステムとリニアシステムが存在する。一般的にCRシステムはLogシステムであり、出力のデジタル値は入力の露光量の対数値に比例するシステムである。一方FPDはリニアシステムであり、出力のデジタル値は露光量に比例する。

4. 標本化

アナログ信号は位置、濃度とも連続的な変化をする信号であり、デジタル信号は位置、濃度とも離散的な値を取る信号である。アナログの連続な信号を一定間隔で区切るのが、標本化である。一定間隔に区切る点を標本点、標本点と標本点の間隔を標本化間隔やサンプリング間隔という(図1)。標本化間隔は、CRでは読み取り間隔、FPDでは画素サイズが相当する。

標本化で重要なのが、どの程度の間隔で区切るかということである。どの程度で区切れれば信号を再現できるかを証明しているのが標本化定理である。標本化定理によれば、「最高周波数 f_{max} の元の信号を再現するためには、サンプリング周波数を $2f_{max}$ 以上で標本化する必要がある。」と述べられている。ここで、サンプリング周波数は標本化間隔の逆数で表される。サンプリング周波数の逆数は標本化間隔になる。




図1 アナログ信号の標本化




図2 標本化定理の例

例として図2のようなアナログ信号の標本化を考える。このアナログ信号の最高周波数は 6.0 cycles/mm である。標本化定理からこの信号を再現するためには、12.0 cycles/mm 以上のサンプリング周波数が必要である。サンプリング周波数 24.0 cycles/mm で行くと、標本化間隔は 0.04 mm になり、図2左のような位置での標本化になり、元の信号を再現できることがわかる。サンプリング周波数 8.0 cycles/mm の場合、標本化間隔は 0.125 mm になり、図2右のような位置での標本化となる。この場合は標本化定理を満たしていないため、元の信号を正確に再現できていない。

実際の X 線画像で標本化数を変えた画像を図3に示す。標本化数を小さくすると、モザイク状となり肺紋理など細かな解剖学的構造を認識できなくなる。忠実に解剖学的構造を再現するには、細かな標本化が必要だが、必要以上に細かな標本化はデータ量の増加などの問題もあり、臨床に耐えうる標本化が求められる。




図3 標本化数の違いによる画像の変化

4. エイリアシング

標本化において標本化定理を満たす条件で標本化を行うことで信号を再現できるが、標本化定理を満たさない条件ではどのようなことが起きるか考えてみる。

先ほどの例で、再現信号をフーリエ変換し周波数スペクトルを見ている(図4)。標本化定理を満たす条件で再現された信号の周波数ピークは 6.0 cycles/mm に表れており、元の信号を再現できていることがわかる。一方、標本化定理を満たさない例では、再現信号の周波数ピークは 2.0 cycles/mm に表れており元の信号より低周波数の信号となり再現できていないことがわかる。

サンプリング周波数で再現できる最高周波数をナイキスト周波数といい、サンプリング周波数の逆数で表され

る。元の信号の周波数ピークとナイキスト周波数を比べると(図5), 標本化定理を満たす場合はナイキスト周波数より低周波側に元の信号の周波数ピークがあるため, 再現可能である。一方標本化定理を満たさない場合は, 元の信号のピークより低周波数側にナイキスト周波数があるため, 元の信号を再現することは不可能である。ナイキスト周波数を越えた周波数成分は正確に再現できず, 元の信号より低周波数の信号として再現される。これをエイリアシングまたは折り返しと呼ぶ。エイリアシングはナイキスト周波数を境に低周波側に現れる(図6)。これは画像上では, モアレなどのアーチファクトとして現れるため, ナイキスト周波数以上をローパスフィルターなどでカットする必要があ

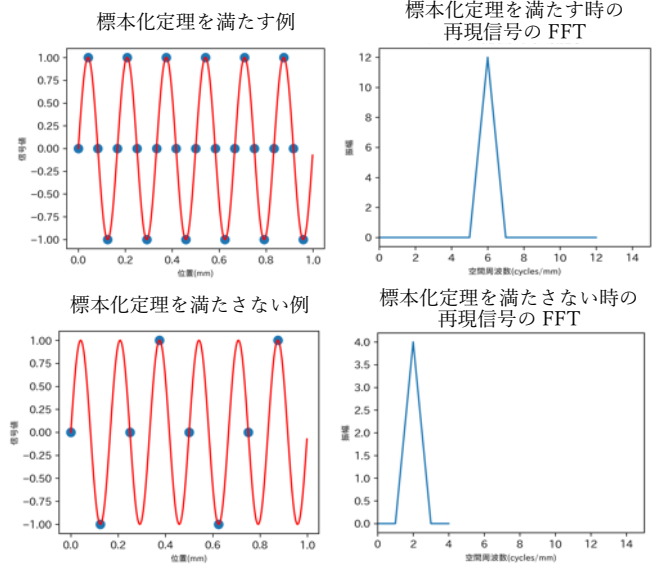


図4 再現信号のフーリエ変換

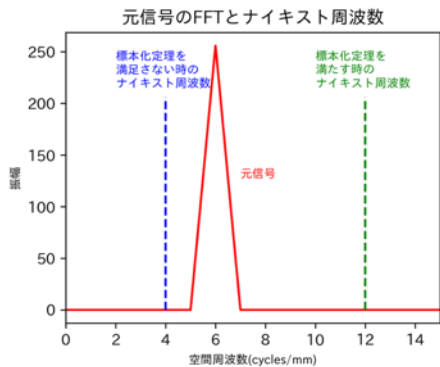


図5 元の信号とナイキスト周波数の関係




図6 ナイキスト周波数とエイリアシングの関係

る。

5. 量子化

標本化された信号は位置情報のデジタル化はされたが, 濃度情報はアナログ信号のままである。デジタルで




図7 量子化前後の比較




図8 量子化レベルの違いによる画像の変化

信号値は整数値でしか表現できないため、デジタルで濃度表現を行うためには連続的な濃度情報を整数値に変換する必要がある。この変換の作業を量子化という(図7)。位置情報のデジタル化が標本化に対し、信号値のデジタル化が量子化である。

標本化同様、取得した信号値をどの程度の細かさでデジタル値に振り分けるかが重要になる。細かく振り分ければアナログに近い濃度表現が可能となる。この細かさを量子化レベルと呼び bit で表現される。10 bit では濃度を 1024 階調で表現できる。人間の目には 7 bit 以上あれば不自然さは感じられないと言われており最低限この程度の量子化レベルが必要である。より高精度な濃度表現が求められる医用画像では一般的に 10 bit 以上が用いられている。

量子化レベルを変更した例を図8に示す。階調数が少なくなるにつれ、細かな濃度表現ができなくなり油絵のようなベタツとした画像になる。このように細かな濃度表現ができなくなるのは量子化誤差によるものである(図9)。量子化誤差とは、連続したアナログの濃度とデジタルの整数値との誤差である。この誤差を小さくするためには量子化レベルを大きくすれば良いが、データ量も増加する。




図9 量子化誤差

6. アパーチャ効果

標本化定理における標本点は、微小な標本点を想定した理論である。しかし、現実的には微小な標本点の実現は技術的な問題などで困難である。そのため実際にはある程度の幅を持った標本点となっている。その幅を開口幅(アパーチャ)という(図10)。

開口幅が変化した時ときの周波数特性は図11のようになる。開口幅が 0.00mm の時は高周波数にかけて応答は落ちない。少し開口幅が広がった 0.07mm では、高周波数にかけて応答が低下していく。0.15mm では高周波数に対する応答がさらに低下していく。このように開口幅が広がるにつれて高周波数成分に対する応答が低下し、細かな構造物やエッジなどの描出能が低下する。




図10 開口幅の例




図11 開口幅の周波数特性

アパーチャ効果の影響を再現した画像を図12示す。元画像が 512×512 マトリックスの画像を 1/4 のマトリックスに変換し、変換後の画素値を決定する際の補完方法の違いで再現した。理想的な標本化である標本点が微小な点の場合(NEAREST)は、図12中央のようになり元画像にはなかったギザギザとしたアーチファクト(ジャギー)が目立っている。ある程度の幅がある標本点の場合(AREA)は図12右のようになり、元画像よりボケは目立つがギザギザとしたアーチファクトは目立たなくなる。ジャギーは折り返しアーチファクトの一つであり、ナイキスト周波数を

超えた成分が折り返りアーチファクトとして表れる. ある程度の幅がある標本点では, 開口幅に含まれる信号を平均化するため, 高周波成分が抑制されアーチファクトは目立たなくなる.

元画像に変換後のナイキスト周波数以上をカットするローパスフィルタをかけてから変換を行った例を図13示す. 理想的な標本化では, ナイキスト周波数をカットする前で目立っていたアーチファクトが目立たなくなっている. これを見ても先ほどのアーチファクトはエイリアシングの影響であったと考えられる. 一方, ある程度の幅での標本化では, ナイキスト周波数カット前と大きな差は見られない.

前述した通り微小な標本点を実現することは困難であり, ある程度の開口幅を持った標本点での標本化になる. 開口幅に応じた画像のボケが生じるが, エイリアシングの原因となる高周波数成分を抑制する効果もある. しかし, 標本化対象がどの程度の周波数成分を持っているかをあらかじめ知ることは困難なため, 装置のナイキスト周波数以上を予めカットするようにローパスフィルタが施されている(図14).



図12 リサンプリングによるアーチファクトの再現




図13 ナイキスト周波数以上をカットしてからリサンプリング




図14 開口幅 0.15mm の時の周波数応答

7. まとめ

アナログ信号をデジタル信号へ変換する過程を解説した. これらの過程は普段の臨床現場で意識することは少ないと思われるが, この理解がデジタル画像の理解への一歩であると思われる. 今回の内容がその一助になれば幸いである.

参考資料

- 船橋正夫監修 関西地区 CR 研究会編著 「CR 超基礎講座」 医療科学社
- 日本放射線技術学会監修 市川勝弘 他編著 「標準 デジタル X 線画像計測」 オーム社
- 岡部哲夫 他編集 「医用画像工学 第2版」 医歯薬出版株式会社
- 藤田広志監修 「Python による医用画像処理入門」 オーム社

中部支部 画像研究会の紹介

鈴鹿医療科学大学 東出 了

1. 中部支部 画像研究会の活動と役割

中部支部画像研究会は、平成2年(1990年)に発足し、現在(2022年)まで30年以上の研究会活動を続けています。本研究会では、画像評価、画質に影響を与える撮影装置や機器の原理や特性、線量と画質の最適化、画像処理に関する内容を中心にテーマを決めています。これまで、アナログシステムであるフィルムスクリーン系の画像評価から始まり、ROC解析、CADの理論、デジタルシステムであるCRやFPDの原理や画質評価、デジタルシステムの物理評価法、CTの原理や画質評価、モニタの構造や特徴、モニタの評価方法や画質評価など多岐に渡る範囲をテーマとして研究会を開催してきました。特に、ハンズオンセミナーとして開催された「デジタルシステムの物理評価」、「一般撮影に用いられる画像処理」に関する内容では開催までに非常に多くの準備を要しましたが、中部支部の会員だけでなく、関西支部・関東支部・九州支部などの遠方からも受講者が集まりました。デジタルシステムの物理評価は、現在のDRセミナーに発展し、中部支部だけでなく、日本放射線技術学会へも大きな貢献ができたと感じています。

現在は、デジタルシステムの画質と線量の最適化を目的として、2019年度から一般撮影を対象とした線量や画質の理解が深まる内容をシリーズ化して研究会を開催しています。これまでに「線量の初歩」、「X線画像の成り立ちと画質」を実施して、今後は「線量指標」、「画質評価」、「散乱X線除去用グリッドの効果」などを予定しています。中部支部画像研究会として画質と線量の最適化に必要な知識や考え方を今後も発信していきます。

また、中部支部画像研究会では研究会で知識を深めるだけでなく、研究会終了後には名古屋や金沢の美味しい食事とお酒を中心に多くの人との交流や人材育成も大切にしています。私も若手時代に研究会へ参加した際には、内容の濃い勉強(講演)にプラスして他施設の先輩方や同年代の方とモチベーションを高められる場に大きな魅力を感じました。中部支部だけでなく他支部からの参加者とも研究会後の懇親会で親交を深められるのは、非常に大きな楽しみとなっています。ただし、ここ数年は新型コロナウイルス感染の影響により懇親会も開催できず、本研究会の魅力の1つを失っていることを実感しています。現在は再開できることを心待ちにしており、新型コロナウイルスの収束や終息を期待しています。

2. 画像研究会の活動方針・活動目的

- ・ 医用画像に関わる放射線技術学の基礎や応用の研究、および勉強会の開催。
- ・ 臨床現場へのフィードバック。
- ・ 学問の進歩・普及に貢献し、学術の発展に寄与する。

3. 令和3年度(2021年度)の研究会の活動

新型コロナウイルスの感染状況を考慮して、WebexによるWeb開催にて実施。

- ・ 第65回 画像研究会 2021年5月20日(木) 19:00~20:35
「X線画像の成り立ちと画質 ー基礎編ー」 参加者数 74名
- ・ 第66回 画像研究会 2021年6月10日(木) 19:00~20:35
「X線画像の成り立ちと画質 ー実践編ー」 参加者数 93名

令和3年度は、新型コロナウイルスの感染状況を考慮した上でWebにて研究会を開催しました。Web開催により、中部支部の会員以外の受講者数も大幅に増えており、研究会の内容をより多くの方に伝えることができた点は大きなメリットといえます。また、演者や受講者にとって移動時間を要しないため、平日開催が可能となりました。一方で、人との交流、講演後の会場や懇親会での質問や意見交換など対面開催の旨味や楽しみを得ることができないデメリットも感じました。

4. 中部支部 画像研究会の世話人メンバー

世話人の一覧(所属は2022年3月時点)を以下に記載します。病院勤務や学校勤務の方、経験豊富な方から中堅や若手と幅広い世代で世話人を構成しています。全国でも活躍するメンバーも多く、今後も中部圏だけでなく全国での画像研究に貢献していきたいと考えています。

代表世話人	東出 了	鈴鹿医療科学大学
代表世話人	市川 勝弘	金沢大学
世話人	服部 真澄	各務原リハビリテーション病院
世話人	國友 博史	名古屋市立大学病院
世話人	澤田 道人	東海医療技術専門学校(非常勤), 株式会社ムツダ(顧問)
世話人	南 修平	金沢大学病院
世話人	鈴木 省吾	刈谷豊田総合病院
世話人	川嶋 広貴	金沢大学
世話人	鈴木 崇宏	藤田医科大学病院
世話人	西脇 祐太	名古屋市立大学病院
世話人	山田 雅人	名古屋市立大学病院
世話人	野田 千鶴	ナゴヤガーデンクリニック
世話人	藤本 真一	福井大学医学部附属病院
世話人	大竹 崇仁	名古屋市立大学病院

5. まとめ

中部支部画像研究会として、2021年度で第66回画像研究会の開催ができました。30年以上に渡って研究会を開催できている理由は、歴代の代表世話人や世話人の方々の努力だけでなく、会員の皆様のご理解と期待によって成り立っていると考えています。今後も対面開催とWeb開催のメリットとデメリットを考慮しながら、社会情勢に合わせた開催方法の検討をしていく予定です。また、講演形式だけでなく、セミナー形式の研究会開催の必要性も感じています。今後も研究会開催だけでなく、名古屋や金沢の美味しい食事とお酒を中心に多くの人との交流や人材育成も大切にしていきたいと考えています。私もこれまでの研究会活動を通して成長する多くの機会を得ることができました。このため、研究会の若手世話人や若い会員を育成する上でも対面開催の必要性も感じています。中部支部の研究会であるため、対面開催による人材育成も重要な役割であると認識しています。

会員の皆様には中部支部のホームページから本研究会の活動を確認して頂けることを期待しています。是非とも中部支部画像研究会にご参加してください。世話人一同、今後も多くの会員の皆様に有益であり、興味を持って頂ける研究会の開催に努めていきます。

最後に、このような機会を与えてくださった篠原画像部会長と画像部会委員の先生方に感謝いたします。

AOCMP-2021 に参加して

市立四日市病院 倉谷 洋佑

1. はじめに

2021年12月10-12日にアジア・オセアニア医学物理学術大会（AOCMP : Asia-Oceania Congress of Medical Physics）2021 が開催されました。本大会はアジア・オセアニア医学物理学会連合（AFOMP : Asia-Oceania Federation of Organizations for Medical Physics）が共催している国際学会であり、毎年アジア地域で主催国を変えて催されています。過去には日本で開かれたこともあります。今年はバングラデシュにて開催されましたが、COVID-19 の流行に伴い、Web 上と現地を合わせたハイブリッド開催となりました。日本より Web 参加した所感について報告いたします。

2. 学会の概要

AOCMP2021 はバングラデシュ医学物理学会（BMPS : Bangladesh Medical Physics Society）が主催となりバングラデシュの首都ダッカにあります UIU（Universal International University）にてハイブリッド開催されました。会議のテーマは「放射線医学のための科学」です。

当日オープンしたアドレスにアクセスしてみると、Web 上に現地を模したバーチャル会場が現れました。外観から入口をクリックして会場内に入ると A ホールと B ホール、Cホールがありました。Aホールはメインホールとされ、招待講演や表彰式などが、Cホールでは主にポスターセッションが行われていました。また機器展示様のメーカーのブースもあり、問い合わせができるインフォメーションも設けられていました。各ホールでは発表スライドが表示されるのですが、スライド画面周囲には学会会場のように舞台が表現されており聴講者も描かれているなど、見た目から会場へ行ったかのように感じさせてくれ、興味深かったです。

3日間に渡って様々な講演がなされました。まず Kiyonari Inamura 記念講演として Tae Suk Suh 氏が画像誘導放射線治療の発展について医学物理の基礎から講演されました。その後3つの会場に分かれ会議、セッション、ミニシンポジウム、招待講演、口述発表、ポスター発表がなされました。口述発表としては AI や COVID-19 の研究など話題のものから、医学物理学会ということもあってか放射線治療や被ばく計測の研究発表が多くみられました。日本・中国・インド・ネパール・マレーシア・イラン・オーストラリアなど様々な国からの参加がありましたが、2021年はバングラデシュ独立50周年と重なる年で現地

スピーカーも多く、熱気や気合が感じられました。バングラデシュは国から研究助成があり、BMPS も研究者育成に力を入れているそうです。日本もそうなるとういよいなと思ひました。

3. Web 口述発表での参加

抄録を添付して申込みをしたところ、Web 口述発表で演題採択されました（スライド発表 10 分＋質疑応答 2 分の持ち時間）。大会運営の遅延防止のため、事前に音声収録したスライドが流れる形式でした。

まず事前に、スライドのデザインが送られてきました。全員のスライドデザインを合わせることで大会としての統一感を出す狙いです。スライドは収録時の顔が映るよう zoom を使用して録画し、完成したら Drop Box で学会側と共有されました。不慣れな参加者にも配慮がなされており、音声スライド作成マニュアルが配布されました。音声収録をした経験がなかったため私自身も良い経験になりました。スライド量が多く、かつ慣れない英語口述発表であったので何度も何度も収録し直して完成しました。今回スライドを制限時間内に納めるのに大変苦慮したのですが、学会当日は時間超過する演者が続出して全日程で押していました。この辺りは自分の考えの狭さを知ると共に、他国のおおらかさと文化の違いを感じました。

参加登録も不慣れなため苦労しました。当初学会は参加登録費の入金を振込でしか受け付けていませんでした。外国送金の手続きをとりましたが銀行から承認が下りるまで 2 週間程度かかりました。銀行に行かなければと思っていた矢先、クレジットカードでの手続きが追加され、無事に入金を済ませることができました。

アクシデントも少しありました。大会開催前日に私の元へ「あなたのパワーポイントファイルが開けるけど音声が開けない。」と運営委員会よりメールが届いたのです。再度送り直しましたが、さすがに大会前は忙しいのか返信は来ませんでした。「当日はライブで口述発表するしかない。」と思ひ、前日夜に急いで読み原稿を作成しました。発表当日も昼から職場を早退して準備を進めました。予想していなかった英語口述発表に緊張しつつ、本番を迎えたのですが、いざその時になると問題なくスライドが流れるではありませんか！後から送り直したものが再生できたのか、元々大丈夫だったのかは不明ですが、発表が終わり安堵しました。質疑応答では一つ質問を頂いたのですが、質問者が大変流暢な英語で、ゆっくり言い直してもらってもまったく聞き取れず、目が泳ぎまくって頭の中も真っ白に。長い沈黙のさなか、共同演者の先生が質問内容の和訳を送ってくれました。お釈迦様から垂らされた糸のおかげでなんとか質疑応答を終えることができました。

大会 3 日目には授賞式があつたのですが、Radiology/imaging 部門で口述発表 2nd Award を頂けました。日頃から支えてくださる先生方や同僚の皆様、家族のおかげです。「これからも研究活動頑張ろう。」と決意を新たにしつつ、「英会話を勉強しなければ。」と心に刻む経験となりました。

IEEE EMBC2021 参加報告

藤田医科大学大学院 保健学研究科 医用放射線科学領域 2年 村木 亮介

1. はじめに

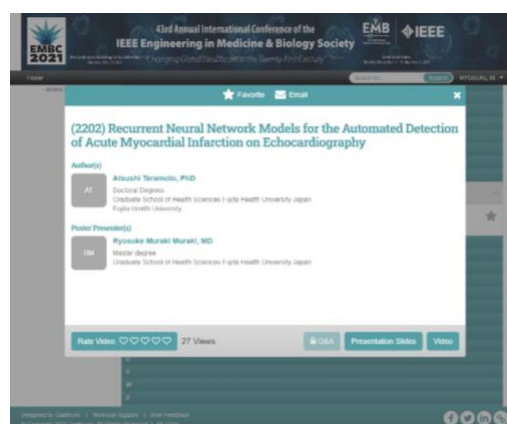

2021年10月30日～11月5日に開催された43rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC2021)に参加しましたので報告します。

2. IEEE EMBC2021 のオンライン開催について

EMBC2021はメキシコにて開催される予定でしたが、コロナウイルスの影響により昨年度と同様にオンライン開催となりました。開催方式は、用意された特設サイトにアクセスし演題の発表動画に対して自由に閲覧・質問をする形式でした。演者は事前に抄録を7月に提出し、8月にアクセプトを頂きました。その後、5～10分の発表動画を専用クラウドに提出し、開催日当日を迎えました。

3. 発表内容

私は「Recurrent neural network models for the automated detection of acute myocardial infarction on echocardiography」というタイトルで一般演題として発表しました。心エコー動画像上の急性心筋梗塞に対して時系列解析が可能なDeep learning技術を用いて自動検出を行う研究で、本学会ではその成果を発表しました。



図：EMBC2021 開催の様子

4. 最後に

リアルタイムの発表は無かったものの、独自のオンライン開催形式により演題の閲覧や質疑応答を活発に行えることが出来たと感じました。オンラインならではの手軽さにより様々な研究を見ることが出来たため得たものは非常に多く、本学会がもたらす数多の研究者への恩恵は計り知れないと感じました。また、本学会は演題の検索機能が優れており、著者やジャンル等で目的としている研究発表が他のオンライン学会よりも検索しやすくなっている印象がありました。現地開催が行えない中で主催者が練り上げた開催方式・システムは、コロナ渦における今後の学術集会の在り方に大きな影響を与えると感じました。

今回の学術発表会で得た知識を今後の研究活動に活かしていきたいと考えています。また、このような特殊な学術集会に参加したという経験を自身が所属する組織に還元し、貢献できるよう努力します。

RSNA2021 参加報告

藤田医科大学大学院 保健学研究科 医用放射線科学領域 修士2年 **山城 滉斗**

1. はじめに

2021年11月28日(日)～12月2日(木)にWEBで開催された、RSNA2021(第107回北米放射線学会)に教育展示の演者として参加いたしましたので、ここに報告いたします。

2. RSNA

RSNAは世界最大の放射線医学専門の国際学会であり、毎年、世界中の放射線科医をはじめとする放射線に関するエキスパートが5万人以上参加しています。昨年度はCOVID-19の影響でRSNA史上初めて、バーチャルミーティングのみでの開催となりましたが、今年度はシカゴのMcCormick Placeとバーチャルの両方でのハイブリッド開催となりました。RSNAは講演と研究発表で構成されており、研究発表には口述発表、デジタルポスター、教育展示が含まれています。今年度のRSNAでは5月初旬にAbstractを提出し、7月中旬にWebページから採択通知を確認しました。そして10月中旬までに発表用スライドの作成・登録を行いました。

教育展示を含めた発表は開催期間中に加えて4月下旬までサイト上で閲覧可能であり、分野やキーワードを用いて検索することも可能でした。スライドの閲覧画面ではチャットを用いてコメントや質問が可能であり、関連する発表も表示されていました。また、気になるスライドはブックマークすることで後日見直すこともできました。発表の検索サイトとスライドの閲覧ページを図1、2に示します。




図1 発表の検索サイト




図2 スライドの閲覧ページ

3. 発表内容

私は「Tips And Tricks For Application Development Using Pretrained Medical AI Models」というタイトルで発表を行いました。近年、医用画像の解析においてディープラーニングを用いた研究が多く行われています。しかし、ディープラーニングモデルを構築する際には、医用画像データの入手の困難さなどが問題となります。そこで私の発表ではそれらの問題を解決するための技術である転移学習や、NVIDIA 社の Clara プロジェクトを紹介しました。スライドの後半においては Clara プロジェクトの学習済みモデルを使用した、私の研究も発表しました。

4. 最後に

まずは RSNA2021 への参加において多くの支援をしてくださった寺本篤司教授に深く感謝申し上げます。今年度の RSNA はハイブリット開催であったため、私は現地へは渡航せず、オンラインで参加しました。しかし、チャットを用いたコメントや質問などにより発表に関する議論も行われました。さらにサイト上では興味のある分野やキーワードを用いて、興味のある分野を探すことで自身の知見を広げることができました。そのため、これまでの現地開催と同様にとっても有意義な時間になりました。今後もバーチャルやハイブリット開催の学会等への参加する際には今回の学会参加で得た経験を生かしていきたいと考えています。

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。

2021 年度 画像部会事業報告

1) 第 89 回画像部会の開催(第 77 回総会学術大会時)

開催日:2021 年 4 月 16 日(金)15 時 45 分～ 会 場:パシフィコ横浜 (横浜市) F203+204 室

(1) 教育講演

司会 岐阜医療科学大学 篠原 範充

「動画の画像評価 総論」

国際医療福祉大学 西木 雅行

(2) 第 89 回画像部会

「動画の画像評価」

司会 つくば国際大学 柳田 智・鈴鹿医療科学大学 東出 了

① IEC 622201-1-3 の解説

金沢大学 田中 利恵

② IEC 622201-1-3 に沿った画像評価

九州大学病院 倉本 卓

③ 血管撮影装置における透視画像の視覚評価

大阪大学医学部附属病院 日高 国幸

④ 非参照型マトリクスを用いた動画の物理評価

大阪市立大学医学部附属病院 片山 豊

2) 第 90 回画像部会の開催(大 49 回秋季学術大会)

開催日:2021 年 10 月 16 日(土)9 時 20 分～ 会 場:熊本城ホール (熊本市) 第 1 会場

(1) 教育講演

司会 岐阜医療科学大学 篠原 範充

「画像研究最前線 ～深層学習から Radiomics まで～」

熊本大学 内山 良一

(2) 第 89 回画像部会

「深層学習のイロハ」

司会 藤田医科大学 寺本 篤司・東北大学病院 小野寺 崇

- ① 「検出」 大分大学 畑中 裕司
- ② 「分類」 広島国際大学 山本 めぐみ
- ③ 「推定」 立命館大学 檜作 彰良
- ④ 「作る」 藤田医科大学 吉田瑞希, 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

44 回医用画像プログラミングセミナー (教育委員会, 画像部会共催)

2021 年 7 月 25 日(日) 10:00 ~ 15:00

会 場: Cisco Webex によるオンライン・藤田医科大学大学(本部)

受講生人数: 18 名

4) DR(デジタルラジオグラフィ)セミナーの開催

第 22 回 DR セミナー (教育委員会, 近畿支部, 画像部会共催)

開催日: 2021 年 12 月 12 日(日) 9:00 ~ 15:40

会 場: Cisco Webex によるオンライン・岐阜医療科学大学(本部)

受講生人数: 20 名

5) ROC セミナーの開催

第 14 回 ROC セミナー 感染拡大に伴い中止した.

6) 臨床画像評価セミナーの開催

第 8 回臨床画像評価セミナー 感染拡大に伴い中止した.

7) 部会誌(画像通信)の発行

Vol.44 No.1(通巻 86 号)(2021 年 4 月), Vol.44 No.2(通巻 87 号)(2021 年 10 月)

8) 部会委員会の開催

第 1 回委員会	5 月 25 日	WEB
第 2 回委員会	9 月 13 日	WEB
第 3 回委員会	10 月 16 日	WEB
第 4 回委員会	12 月 25 日	WEB

2022年度 画像部会事業計画

1) 第91回画像部会の開催(第78回総会学術大会時)

開催日:2022年4月15日(金) 会場:パシフィコ横浜

(1) 教育講演

司会 藤田医科大学 寺本 篤司

「ディープラーニングの今とこれから」

東京大学 花岡 昇平

(2) 画像部会

「実践ディープラーニング研究」

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 「ディープラーニング手法の選択方法」

山口大学 平野 靖

② 「性能評価の方法」

立命館大学 中山 良平

③ 「データベース構築および利用方法」

大分大学 畑中 裕司

④ 「失敗例から学ぶディープラーニング研究の進め方」

藤田医科大学 寺本 篤司

2) 第92回画像部会の開催(第50回秋季学術大会時)

開催日:2022年10月7日(金)～9日(日)(予定) 会場:国際ファッションセンター(東京都)

画像評価

(1) 教育講演 未定

(2) 画像部会 未定

3) 医用画像プログラミングセミナーの開催(教育委員会)

第45回医用画像処理プログラミングセミナー

開催日時:未定

会場: Cisco Webex によるオンライン実施 セミナー本部: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, 北海道支部共催)

第 23 回 DR セミナー(北海道, 未定)

開催日時: 未定

会 場:北海道内またはオンライン実施

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 9 回臨床画像評価セミナー(東京都 築地)

開催日時:2022 年 7 月 23 日(土), 24 日(日)

会 場:国立がん研究センター中央病院(東京都築地)

6) ROC セミナーの開催

未定

7) 部会誌(画像通信)の発行

Vol.45 No.1(通巻 88 号)(2022 年 4 月), Vol.45 No.2(通巻 89 号)(2022 年 10 月)

8) 部会委員会の開催 年 5 回(横浜, Web, Web, 東京, 名古屋の開催予定)

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

「〇型人才」って言葉、聞いたことありますか？これは、専門性を縦の軸、幅広い領域への理解を横の軸として人材を分類するものです。さて、あなたは何人材でしょうか？

- I型人材： スペシャリストのこと。縦棒が上下に伸びるように特定の分野に秀でている。
一型人才： ゼネラリストのこと。さまざまな分野に浅く広く精通している。
T型人材： I型、T型両方の側面を持ち、一つの専門分野に精通しつつ広い知識もある
II型人材： 2つの専門分野を持つT型人材のこと
H型人材： 深い専門スキルと広い知識を基盤として、他のT型人材とのつながりを仕事に活用できるT型人材のこと。異分野融合によるイノベーションを起こすことができる。
J型人材： 専門性がトップレベルの深さまで到達することによって地下水脈で他の専門家とつながる人材のこと。専門外の分野について学び育てることができる。

専門分野がまだ確立できていない一型人才の場合は、専門性を獲得してT型人材を目指すことでスペシャリストとして活躍できるようになり、一方、専門分野を確立したI型人材の場合は、視野を広げてT型人材になれば問題解決力をUPできるかもしれません。すでにT型人材に至っている場合は、専門分野を増やしてII型人材を目指す、対人スキルを高めてH型人材を目指す、専門性を深めてJ型人材を目指すなどの道があります。

さて、ここからが本題です。本学会では今年度から専門部会費が無償化されました！これは自身の専門性の縦展開と横展開を図る絶好の機会です。画像部会では、モダリティに縛りのない立ち位置で、画像の物理的/視覚的評価、画像処理、医用画像処理プログラミングなど、医用画像に関する様々な知見を広め・深めるためのセミナーやシンポジウム・教育講演を企画しています。

みんなで画像について語りましょう！！皆様の積極的な参加を心よりお待ちしております。

(RT 記)

画像通信 Vol.45 No.1(通巻'88)

発行日 2022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

画像通信 通卷八八号

VOL. 45 No.1 SPRING 2022