

Communication of the Imaging Group of the JSRT

画像通信

2021 年 10 月

Vol.44 No.2(通巻 87)

☆ 第 90 回画像部会『深層学習のイロハ』

教育講演

「画像研究最前線 ～深層学習から Radomics まで～」

熊本大学大学院 生命科学研究部 内山 良一

シンポジウム

1. 「検出」

2. 「分類」

3. 「推定」

4. 「作る」

大分大学 理工学部 畑中 裕司

広島国際大学 保健医療学部 診療放射線学科 山本めぐみ

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 吉田 瑞希, 藤田医科大学 医療科学部 放射線学科 寺本 篤司

☆ 寄稿:

「“Image Science”から学ぶウィーナススペクトルの次元変換」

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

シカゴ大学・群馬県立県民健康科学大学 土井 邦雄

☆ 技術紹介:

「MR guided online adaptive radiotherapy 海外研究動向 - 画像系の研究を中心に -」

エレクトラ株式会社リサーチフィジックス 依田 潔

☆ 読者のページ:

①「オンライン 医用画像処理プログラミングセミナー～おうちで学ぶ初めてのディープラーニング～を受講して」

JCHO 四日市羽津医療センター 放射線部 磯部 好孝

②「オンライン 医用画像処理プログラミングセミナー～おうちで学ぶ初めてのディープラーニング～を受講して」

岡崎市民病院 医療技術局 放射線室 尾木 洋之

☆ 専門部会講座(入門編):「医用画像で用いられている画像処理」聖マリアンナ医科大学病院 画像センター 田沼 隆夫

☆ 専門部会講座(入門編):「圧縮センシングの基礎」広島国際大学 保健医療学部 診療放射線学科 大倉 保彦

☆ 大学/研究室/研究会紹介:

「つくば国際大学 柳田研究室の紹介」

つくば国際大学 医療保健学部 診療放射線学科 柳田 智

☆ 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(胸部腫瘍陰画像)の紹介

☆ 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 91 回 画像部会予告

日 時：2022 年 4 月 15(木)～18 日(日) 第 78 回日本放射線技術学会総会学術大会期間中 予定

会 場：パシフィコ横浜，他(予定)

内 容：「深層学習の研究をして評価する(仮題)」

教育講演：

「未定」

シンポジウム：

- 1) 深層学習でのソフトとハードの特徴 (仮題)
- 2) 画像データベース，正解の集め方 (仮題)
- 3) 学習と手法のセレクト (仮題)
- 4) 深層学習の評価 (仮題)
- 5) 失敗に学ぶ研究 Tips (仮題)

画像部会委員 氏名・所属・電子メール

篠原 範充 (画像部会長)

	岐阜医療科学大学保健科学部放射線技術学科	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.ritsumeit.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>

画像研究最前線 ～深層学習から Radiomics まで～

熊本大学大学院生命科学研究部 内山 良一

1. はじめに

医療は、病変の検出、鑑別、治療の順番で行われる。これまでのコンピュータ支援診断 (Computer-Aided Diagnosis, CAD) に関する研究では、画像から病変を検出する技術や良悪性を鑑別する技術が提案されてきた。よって、CAD は、医療の前半を支援する人工知能 (Artificial Intelligence, AI) システムと分類・整理できる。それに対して Radiomics は、病変が発見されたあと、つまり、医療の後半のプロセスを支援する AI システムであり、至適治療法の選択に繋がる分子分類や予後予測を行う技術が開発されている[1]。近年、注目されている深層学習は、CAD システムの性能向上や開発期間の短縮といった効果をもたらし、より多くの疾患に CAD の適用範囲を広げるなど第 3 次 AI ブームを牽引している。また、Radiomics では、がんの遺伝型や予後に関する情報が画像に含まれていることを示す成果が報告され、画像診断の新しい価値を創造している。このように画像研究は、医療の順番の縦軸（検出や鑑別の性能向上）と横軸（治療への応用）の方向に大きく発展しているのが現状である。本稿では、画像の AI 研究に関する最近の動向について概観する。

2. 人工知能研究の流れ

人間の知的行動をコンピュータに行わせる技術のことを「人工知能」と呼ぶ。「人工知能」という言葉は、1956 年のダートマス会議で考案された。この会議では、当時の一流の数学者や心理学者が集まり、人間のような行動や思考をするコンピュータの可能性を 1 ヶ月も議論した。この会議で提唱された神経回路を模倣した計算機モデルや自動翻訳などの多くの概念が、現在では実用化されていることを考えると歴史的な会議であったことが分かる。このダートマス会議から 65 年が経過したことからも分かるように、AI の歴史は意外にも古く、夢の時代と失望の時代を繰り返し、現在は 3 回目の AI ブームと言われている。

まず、1960 年から 1970 年代の第 1 次 AI ブームでは、迷路問題をコンピュータで解く技術などが開発された。しかし、当時のコンピュータの性能が低いこともあり、おもちゃの問題はうまく解けたが、病気の治療法などの社会の現実問題は解けないことが露呈して冬の時代を迎えることになった。続く 1980 年から 2000 年代の第 2 次 AI ブームは、ファイゲンバウムによる知識工学が火付け役になった。知識工学では、「知識の記憶方法」と「知識の利用方法」が学問として整理されている。知識工学の技術はいくつかあるが、そのなかでも If-then ルールで知識の記憶と推論を行うエキスパートシステムが有名である。医学の分野では、感染症の診断と治療のコンサルテーションを行う MYCIN が開発された。このシステムは、「はい/いいえ」と「文章」で答える If-then ルールを作成することで、確率の高い細菌名のリストと推奨する薬物療法のコースを提案する。このシステムの性能は細菌感染の非専門医よりも高かったが、現場で使われるこ

とはなかった。これは、コンピュータが間違っただけで判断を下した場合に、誰が責任を取るのかという倫理や法律の面での問題が大きかったこと、人間の専門家がそのようなシステムを受け入れることへの抵抗があったと言われている。

第2次 AI ブームの特筆すべき成果は、1998 年の CAD システムの実用化である。CAD では、コンピュータの解析結果を参考に最終的な診断は医師が行うという考え方が提案された。あくまで「第二の意見」として自動診断とは異なる概念であるで一線を引くことで、上記の倫理面などの問題を解決して実用化に結びつけた功績は大きい。技術的には、知識工学で用いられた「記号処理的アプローチ」ではなく、「脳型アプローチ」がおもに採用された。エキスパートシステムの If-then ルールの説明から容易に想像できるように、記号処理的アプローチでは知識の入力に多くの手間がかかる。これに対して脳型アプローチは、人間の脳の学習を模倣したものであり、知識を数値で表現する非記号的処理が用いられている。例えば、人間の脳が物体認識をする際には、①一次視覚野で線や頂点を取り出し、②高次視覚野で取り出した情報を統合して物体が何であるかを認識する。これをコンピュータでモデル化するためには、①フィルター処理を用いて大きさ、形状、濃度などの画像特徴量を取り出し、②ニューラルネットワークを用いて病変を識別する。図1に乳房 X 線写真から石灰化陰影を検出する例を示す。フィルター処理で陰影のパターンを大きさや濃度などの数値で表現し、ニューラルネットワークの学習によって石灰化陰影とその他を区別する識別関数（識別境界）を生成することで知識として記憶して利用するのが脳型アプローチである。この脳型アプローチを用いることによって、乳がん、肺がん、大腸がんなどの CAD システムが実用化された。しかし、ニューラルネットワークを用いれば複雑な識別境界が生成できるものの、病変検出の性能向上のためには、病変とその他を区別する画像特徴量の設計が重要であって、その設計に莫大な時間を費やす問題があった。また、このアプローチでは、比較的単純な病変しか識別することができないことも明らかになり、第2次 AI ブームは終焉していった。




図1 脳型アプローチによる乳房 X 線写真の石灰化陰影の検出（文献[2]の図を改変）

3. 深層学習とは

2010 年から 2020 年代に入り，深層学習が火付け役となり，第 3 次 AI ブームを迎えている．図 2 に，ニューラルネットワークと深層学習の違いを示す．深層学習では，層が多層になり深くなっていることが分かる．人間の脳の神経細胞数は，大腦だけで 160 億個と言われているから，ニューラルネットワークのニューロン数（図 2 の丸印の個数）を増やせば，人間の脳に近づき性能が向上するのではないかというアイデアは容易に浮かぶ．そのため，ニューラルネットワークでニューロン数を増やす方法が検討されてきた．それらは，①中間層のニューロン数を増やす，②3 層以上の多層にするである．①中間層のニューロン数を増やした場合は，図 1 の識別境界がより複雑な形状を表現できるようになるが，データが少ない状態で学習を進めると過学習になる問題があった[3]．②多層にした場合は，学習が進まない問題があった．ニューラルネットワークの学習は，誤差逆伝播法を用いて，出力層から入力層に向かってニューロン間の重みを最適化することで行われる．しかし，層を深くすると入力層に向かうにしたがって重みが消失し，学習が上手く進まなかった．




図2 ニューラルネットワークと深層学習の違い（文献[3]の図を改変）

ところが，この重みの消失問題を解決する手法が考案され，層の数を深くすることが可能になったのである．層を深くした深層学習では，モデルの非線形性が強くなり表現力が高くなるため，より複雑で多くのものを学習することが可能になる[3]．実際に，自然画像から人，犬，机などを認識するコンテストでは，学習データに 120 万枚もの画像が用いられている．さらに，深層学習のモデルの構造にも改良が加えられ，2015 年には人間よりも優れた識別性能を得るに至った．このような Computer Vision の分野の成果もあって，医用画像においても深層学習が応用された．図 3 に，従来の CAD 技術と深層学習による技術の違いを示す．深層学習のモデルでは，層の前半で画像特徴量の抽出も自動で行われるため，これまで多くの時間を費やした画像特徴量の設計コストが大幅に下がった．また，ソニーの Neural Network Console のように，学習画像と答えを用意してネットワークの構造を記載すれば，誰もが容易に深層学習が行える環境が整ったことも大きな変化である．これによって，医用画像と答えのセットさえ用意できれば，専門的

な知識やプログラミングの技術が無くても、誰もが容易に様々な疾患の検出や鑑別のシステム開発に参画することが可能になったのである。




図3 従来CAD技術と深層学習の違い

深層学習は、①病変検出、②良悪性鑑別、③臓器のセグメンテーションに応用されている。深層学習を医療に応用する際の問題点は、学習データが少ないことである。自然画像の学習の際には120万枚もの画像が使われたことを上述した。インターネットから自然画像を取得することは比較的容易であるが、医用画像では病変がある画像を120万枚も集めることは容易ではない。そのため、病変検出や良悪性鑑別では、深層学習のモデルの表現力を活かしきれず、大幅な性能向上が見られていないのが現状である。ただし、医用画像と答えのセットさえ用意すれば、従来のCADシステムと同等かそれ以上の性能のシステムを短い開発期間で構築できることは大きな進歩であると言える。この少ない学習データの問題に対しては、敵対的生成ネットワーク(GAN)などを用いて病変を自動的に生成することでデータの水増しを行う技術が開発されている。一方、臓器のセグメンテーションに関しては、深層学習によって大きな進歩が見られた。これは、臓器のセグメンテーションは画素単位で行われるため、大量の学習データが取得できるからである。例えば、U-Netでは画像を入力した後に畳み込み演算が行われる。畳み込み演算とは、フィルター処理のことであり、画像の左上から右下までフィルターを移動させながらラスタスキャンすることによって、画像特徴量の抽出が行われる。この際に、臓器のセグメンテーションでは、注目画素の周りの情報を用いて、注目画素がある臓器か否かの判別が行われる。このようにフィルターが移動する回数分、画素単位で学習データと答えのセットが取得できる。したがって、肝臓など、ある一定以上の大きさを持つ臓器のセグメンテーションでは、深層学習のモデルの表現力を活かすことが可能であり、従来法と比較して飛躍的な性能向上が見られた。

4. Radiomics とは

ヒトゲノム計画でヒトの塩基配列(AGCTの並び)が決定されて以降、様々な疾患と遺伝子の関係性が明らかになってきた。その知識を利用した分子標的薬なども開発され、個別化医療が行われている。Radiomicsとは、画像を表すRadioと遺伝子やタンパク質などを表すOmicsを統合した造語である。Radiomics研究が目指すものは、画像所見(病変の表現型)と分子・遺伝型の関係性を解明し、画像診断の新しい価値を創造することである[4-6]。これまで、がんの診断は病理画像に基づく組織分類によって最終診断名が決定されてきた。しかし、腫瘍形成のメカニズムが明らかになるに連れて、遺伝型に基づく分子分類も行われるようになった。組織分類から分

分子分類に舵を切った理由は、客観的な遺伝子情報を用いることで生物学的な分類が可能になること、分子診断と分子標的薬などがセットになった患者群の層別化が可能であることが挙げられる。しかしながら、分子分類を行うためには、腫瘍細胞の採取に侵襲的な外科処置が必要である。また、遺伝子解析にコストと時間が掛かるなどの問題がある。そこで、非侵襲で簡便な画像検査で、がんの分子分類ができないかというのが Radiomics 研究のひとつの目的である[4]。放射線医学分野では、病理・病態と画像所見の関係は多く研究され、教科書にまとめられてきた。しかし、腫瘍の分子・遺伝型と画像所見の関係分析は進んでいない。そこで、乳がん、肺がん、脳腫瘍の遺伝型を推定する Radiomics 研究が行われ、遺伝子変異、共欠失、エピゲノムなどの情報が、画像所見に“ある程度”表れていることが明らかになってきた[4-8]。もし、分子分類が高精度で行えるようになれば、画像検査で至適治療法の選択が可能になると期待されている。

Radiomics 研究のもうひとつの目的は、再発・転移や予後の予測である[9-12]。CAD は「現在の画像」から「現在の状態」を推定するものであるが、予後予測の Radiomics 研究では「現在の画像」から「将来の状態」を予測する点が異なる。これまでの Radiomics 研究の成果によって、画像には患者の将来を予測する情報が含まれている可能性があることが示唆されている。このような予後予測に関する研究の共通の課題は、どのような情報を医師に提供すれば、診断の支援になるのかということである。病変検出の CAD では、医師はコンピュータの出力をもとに画像を再確認し、そこに本当に病変があるのかを判断する。コンピュータの結果を参考にすることによって、医師が自身の病変の見落としやコンピュータの誤検出に気が付くため、医師とコンピュータの共同作業で診断の正確度が向上する。しかし、予後予測は、現在の画像から将来の状態を推定するものであるため、医師がコンピュータの予測結果を信じて利用することが難しい。このことを天気予報に例えると直感的に理解しやすい。明日の天気が「晴れです」「雨です」と言われても、それを利用できるかどうかは別問題である。そのため、どのような情報をどのような形で医師に提供すれば診断支援に繋がるかを明らかにすることは、CAD 研究よりも格段に難しく、今後の大きな課題であると言える。




図4 画像検査と遺伝子変異の組合せ

遺伝子は、がん細胞の遺伝子（体細胞遺伝子変異）と個人の遺伝子（生殖細胞遺伝子変異）に大別される。上記の Radiomics 研究は、体細胞遺伝子変異と画像の組合せであるが、生殖細胞遺伝子変異と画像の組合せも考えられる（図 4）。個人の遺伝子を利用すれば、罹患しやすい病気を予測することができる。例えば、*APOE* 遺伝子の型が $\epsilon 4$ である人はアルツハイマー型認知症になりやすいことが知られている。このようなリスクが高い人は定期的な検査が必要である。*APOE* $\epsilon 4$ の群と *APOE* $\epsilon 3$ の群で、MR 画像を用いて脳萎縮の形成過程を調べたところ違いが見られることが分かった[4, 13]。この研究成果は、個人の遺伝型と画像診断を組合せることによって、「未病」から「発病」への病態変化を早期に発見する新しい概念の CAD 研究が展開できることを示唆している。

5. おわりに

これまでの第 1 次・第 2 次 AI ブームと現在の第 3 次 AI ブームの大きな違いは、産業としての AI が育っていることである。深層学習や様々な AI 学習ツールの構築によって、医療に限らず多くの AI システムが実用化されている。自動車産業では、自動運転技術の開発が始められるなど、AI システムの運用に関する倫理的なハードルも低くなりつつある。このように産業としての AI が育てば、新しい AI システムの開発コストが捻出できる良い循環が生まれているため、今回の第 3 次 AI ブームは終焉を迎えることなく、このまま AI の発展が継続するのではないかと期待されている。どのような未来になるのか、今後の展開に注目したい。

参考文献

- [1] 内山良一, 第 22 章 医用画像と Radiomics, 医療 AI とディープラーニングシリーズ はじめての医療画像ディープラーニング (藤田広志, 監修), オーム社, 2020.
- [2] 内山良一, 6 章 画像認識, よくわかる医用画像情報学 (石田隆行, 監修), オーム社, 2018.
- [3] 内山良一, 第 2 章 DNN, 医療 AI とディープラーニングシリーズ 放射線治療 AI と外科治療 AI (藤田広志, 他, 監修), オーム社, 2020.
- [4] 内山良一, 脳疾患における Radiogenomics, *Medical Imaging Technology*, 38(1), 15-20, 2020.
- [5] 内山良一, Radiomics による分子分類と治療戦略, *医学物理*, 40(1), 19-22, 2020.
- [6] 内山良一, 肺がんの Radiomics 研究, *医用画像情報学会雑誌*, 38(2), 59-60, 2021.
- [7] 甲斐千遥, 石丸真子, 内山良一, 白石順二, 篠原範充, 藤田広志, Radiogenomics によるトリプルネガティブ乳癌の鑑別における特徴量の決定, *日本放射線技術学会雑誌*, 75(1), 24-31, 2019.
- [8] 和田菜摘美, 内山良一, Radiomics 特徴量と乳がんサブタイプの関係性を抽出するための画像データマイニング, *医用画像情報学会雑誌*, 37(2), 28-33, 2020.
- [9] 近藤雅敏, 幸野佑光子, 金子沙世, 内山良一, 遺伝子と画像特徴量を用いた膠芽腫の予後予

- 測, 医用画像情報学会雑誌, 35(1), 12-16, 2018.
- [10] 吉岡拓弥, 内山良一, Random Survival Forest を用いた肺がん患者の予後予測, 医用画像情報学会雑誌, 36(2), 93-97, 2019.
- [11] 吉岡拓弥, 内山良一, Radiomics による肺がん患者の再発リスクの予測 -パターン認識アプローチの適用限界-, 医用画像情報学会雑誌, 37(1), 5-10, 2020.
- [12] 吉岡拓弥, 内山良一, 白石順二, Radiomics による生存時間解析を用いた肺がん患者の再発リスクの推定, 日本放射線技術学会雑誌, 77(2), 153-159, 2021.
- [13] C. Kai, Y. Uchiyama, J. Shiraishi, H. Fujita, K. Doi, Computer-aided diagnosis with radiogenomics: Analysis of the relationship between genotype and morphological changes of the brain magnetic resonance images, Radiological physics and technology, 11:265-273, 2018.

検出

大分大学理工学部 畑中 裕司

1. はじめに

社会全般での異常検出は、医療における読影、工業やセキュリティでも古くから行われている。いずれの分野においても人による検査が最も容易であり、確実である。しかし、人には疲労による視力や判断能力の低下が生じることがあり、いつも同じ異常検出の能力を発揮することは困難である。医療における読影においても、病変の見落としや判断ミスゼロにすることは困難である。例えば、マンモグラフィにおける病変の見落とし (False Negative) が 20% [1]、胸部単純X線画像の肺疾患 (Nodule) の検出率が 30% 程度 [2] との報告がある。そこで、コンピュータ支援診断 (Computer-aided Diagnosis: CADx) やコンピュータ支援検出 (Computer-aided Detection: CADe) を基本概念とした人工知能 (AI) 開発が行われている。近年は、畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) が検出のために積極的に導入されている。

2020 年開催の第 87 回画像部会で「深層学習を放射線技術研究に利用する」の企画が実施され、深層学習の基礎となる CNN や敵対的生成ネットワーク (Generative Adversarial Network: GAN) について解説されている [3]。本稿では、第 87 回の内容と完全に重複しないように深層学習を用いた検出について述べる。

2. 深層学習を用いた異常検出

異常検出の方法は、正常データと異常データの分類に基づく「教師あり学習」と、正常データのみを学習させる「教師なし学習」のアプローチに大別できる。例えば、画像特徴量とルールベースを組み合わせた病変検出は、病変が検出できるようにルールを設定するので、教師ありの手法といえる。一方で、工業製品の生産における画像検査の場合は、正常製品の特徴分布から外れた製品を異常として検出するので、検査の判別器を構築する際に異常データを用いない教師なし学習となる（正常にクラス分類されたデータを用いるという意味では「教師あり学習」ともいえる）。深層学習を用いた異常検出において、CNN から発展した R-CNN (Regional with CNN features) [4] を用いる場合には異常データが必要であり、自己符号器 (AutoEncoder: AE) を用いる場合は異常データを必要としないアプローチとなる。ここで、教師あり学習が良いのか、教師なし学習が良いのかという疑問が生ずるでしょう。病変を異常として検出する場合、多くの病変データを収集できるでしょうか？病変の種類は多くありませんでしょうか？異常データを集められない場合は、教師なし学習を検討すべきでしょう。

一方で、造影検査画像における異常検出を実施する場合、正常データの収集は困難でしょうから、教師あり学習を考えて良いでしょう。

3 教師あり学習に基づく異常検出

3.1 領域抽出と CNN による異常検出

深層学習を用いた画像検査では、CNN による画像分類を基本とした手法が展開されてきた。例えば、画像から病変を検出する場合は、病変候補を抽出し、それを病変と正常にクラス分類にする 2 段階の処理が考えられる。深層学習では R-CNN がこれに該当する。R-CNN の大まかな処理の流れを図 1 に示すが、入力画像から Selective Search[5]で領域候補 (Region Proposal) を抽出し、各領域の大きさをリサイズして、CNN で特徴抽出し、SVM で検出対象の有無を判定する。ここで、Selective Search とは、セグメンテーションベースの物体検出器である。R-CNN の発展形として、Fast R-CNN や Faster R-CNN が提案されている。また、入力画像から物体探索を行わずに複数の物体を検出する YOLO (You Only Look Once) [6]も提案されている。本節の詳細については、文献[3]で解説されているので、参照されたい。




図 1 R-CNN の概要

3.2 CNN の学習データ

CNN を用いて異常検出する場合は、多くの検出対象となる異常画像が必要になる。ただし、筆者は経験上、学習用の画像は多ければ多いほど良いとは言えないと考えている。まずは、検出対象データの分布が正規分布に近いことが必要であり、実在する異常パターンが学習データに含まれないことを避ける必要があると考えている。例えば、GAN で異常画像を生成して学習データを増強する方法があるが、似たような画像ばかりを生成して学習データを増やしても、CNN の学習にはあまり貢献しないでしょう。また、データの分布に関係するが、データの平均が実際の検出対象からかけ離れないことに注意すべきである。つぎに、学習データを難しくしすぎないことが必要である。特

異な異常を検出させようとして学習データに含めてしまうと、現実離れしたデータ分布になってしまう。

正常画像と異常画像を用いて CNN を学習させる場合、両者の枚数を同数にする必要がある。一般的には正常データに比べて異常データは少ないが、現実 に即したデータの割合で CNN を学習させると、十分な性能を発揮しないからである。なお、Affinity Loss などの損失関数を工夫することによって、不均衡データの問題を改善しようとする研究が取り組まれているので、必要に応じて学んでいただきたい。

3.3 筆者らの研究事例

放射線画像分野ではないが、眼底画像に対して筆者の研究室で実施した研究の事例を紹介する。失明の主要因である糖尿病網膜症において、初期に現れる毛細血管瘤を CNN ベースの処理で自動検出する研究である[7]。毛細血管瘤は網膜の広域に出現する可能性があり、その大きさは数画素～十数画素である。したがって、R-CNN のように病変が出現しそうな領域を先に抽出することが困難であるので、画像をラスタスキャンしながら CNN で局所領域ごとに正常・異常の判別を行う方針を立てた（パッチベース CNN）。つぎに、毛細血管瘤を含む領域を切り出して CNN を学習させようとしたが、図 2 に示すように毛細血管瘤は小さくて低コントラストであるため、病変を強調するような畳み込み層が構築されない問題が生じた。この研究では、学習に用いられる毛細血管瘤が 246 個しか用意できず、回転や平行移動などのデータオーギュメンテーション




図 2 眼底画像における毛細血管瘤と強調処理




図 3 毛細血管瘤の検出の概略

ョンを行っても、CNN の学習には不十分であったと考えている。試行錯誤の結果、図 2 の右に示すような筆者らが別のアプローチで検討していた毛細血管瘤の強調処理[8]を施してから CNN を学習すると、CNN の判別性能が大きく向上することがわかった。ただし、CNN だけでは過学習になるため、筆者らが別のアプローチで行っていたテクスチャ特徴や形状特徴を 3 層パーセプトロンで毛細血管瘤を判定する方法と組み合わせて、最終的な検出結果としている（図 3）。

画像の前処理を行わず、CNN の学習によって画像の特徴抽出を行うことが理想である。しかし、医用画像のように多くの異常画像をそろえられない場合は、前処理などを工夫すべきでしょう。前処理の方法としては、病変以外の領域をブランク（画素値 0）にしてから CNN を学習するような方法もある。また、R-CNN のような領域抽出がうまくいかないときは、ラスタスキャンと CNN を組み合わせてもよいでしょう。

4 正常データの理解に基づく異常検出

4.1 自己符号器による異常検出

検診目的で異常検出を行う場合、正常画像（症例）の収集は容易であっても、異常画像の収集が困難になりがちであり、CNN の学習に十分な数の異常画像や病変画像を確保できない。この場合は、自己符号器（AE）を異常検出に適用できる可能性がある。

AE は、符号化器（Encoder）と復号化器（Decoder）で構成され、入力された画像の特徴をエンコーダで抽出しながら次元圧縮し、次元圧縮したものをデコーダが復元して画像出力するしくみである。ここで、Encoder と Decoder をそれぞれ畳み込みによって構築した AE は、Convolutional Autoencoder（CAE）と呼ばれることがある。正常画像を学習した CAE の Encoder は、正常に関する特徴抽出を期待でき、Decoder は正常画像の再構成が期待できる。この CAE に異常画像を入力しても病変などの異常部位をうまく再構成できないことを利用して、異常部位の検出に利用することができる（図 4）。正常データとの変異を検出することから、Variational Autoencoder（VAE）と呼ばれている。VAE は胸部 X 線写真の異常検出などにも適用されている[9]。




図 4 VAE による異常検出（異常画像は上手く再構成できない）

4.2 1 クラスニューラルネットワーク

データ分類器の代表としてサポートベクターマシン (Support Vector Machine: SVM) が知られている。SVM は正常データと異常データのマージンを最大化するように分類境界を決定する手法であるが、正常データとそのデータ空間の原点のマージンを最大化するように境界を決定する One Class SVM を用いると、正常データだけで異常検出することが可能となる。この 1 クラス学習の概念をニューラルネットワークに適用した One Class Neural Network が提案され、さらに深層学習モデルを利用した Deep Features for One-Class Classification (DOC) [10]が提案されている。DOC の詳細については割愛するが、異常検出の対象となる 1 クラスの正常画像 (Target data) と、ImageNet などの全く別の参照画像 (Reference data) を用いて、図 5 に示すような 2 つの CNN を同時に学習させていく方法である。ここで、参照画像のネットワーク R における損失を l_d 、対象画像のネットワーク S における損失を l_c 、全損失 L を $L = l_d + \lambda l_c$ としている。 l_c は、特定の 1 クラスのデータセットにおける平均類似度で表され、同一クラス内の異なる画像の特徴の類似性を高める役割を担う。一方、 l_d は ImageNet などの外部のマルチクラスデータセットの交差エントロピーで表され、各クラスの異なる特徴表現を大きく分離する損失関数となる。文献[10]では $\lambda = 0.1$ として学習させているので、参照画像の CNN の学習を基本としながら対象画像の CNN の学習を進めていくようなイメージとなる。なお、検出の際は参照ネットワークと第 2 ネットワークの出力を分類器に入力して (図 5 の全損失の位置に相当する) 判別結果を得る。なお、マンモグラムデータセット InBreast に DOC を適用し、ROC 解析における AUC (Area Under the Curve) が 0.84 であったとの報告がある [11]。




図 5 Learning Deep Features for One-Class Classification(DOC)の学習の概念図

4.3 GAN を用いた異常検出

GAN は主に人工的な画像生成に用いられるが、異常検出に用いることも可能であり、AnoGAN (Anomaly GAN) と呼ばれている[12]。正常画像を用いて GAN を学習させ、正常画像を生成する Generator を構築する。つぎに、図 6 に示すように Generator の入力側に全結合層を追加し、GAN の学習に用いた画像を用いて正常画像が生成できるよう

に重みを調整する．そして，対象画像を入力して画像を生成し，両者の差が大きいために異常と判断する．OCT 画像からの網膜異常の検出において，敵対的畳み込みオートエンコーダ（adversarial convolutional autoencoder）を適用したときの AUC が 0.73 のデータセットに対して，AnoGAN では 0.89 であることが報告されている[12]．

AnoGAN では，生成画像と対象画像の差が小さくなるように誤差逆伝搬法で全結合層の重みを更新して行くため，計算時間が長くなってしまう．そこで，画像からノイズ生成器となる Encoder が追加された Bidirectional GAN (BiGAN) を異常検出に用いた Efficient-GAN が提案された[13]．図 7 に示すように，BiGAN を正常画像を用いて学習しておく．異常検出するときは，図 8 のように画像 x を Encoder に入力してノイズ $E(x)$ を生成し， $E(x)$ を Generator に入力することによって画像 $G(E(x))$ を生成する．入力画像 x と生成画像 $G(E(x))$ を識別器 D で判断することで異常度 $A(x)$ を求める構造となっている．乳房超音波画像で正常組織，良性腫瘍および異常腫瘍を分類するために




図 6 AnoGAN の概念図




図 7 Bidirectional GAN の学習




図 8 Efficient-GAN による異常検出

Efficient-GAN を適用した手法が報告されている[14]。腫瘍（良性＋悪性）と正常画像を対象としたときの AUC が 0.936、悪性腫瘍のみを検出の対象にしたとき（正例は正常画像＋良性腫瘍）の AUC が 0.863 であることが報告されている。

4.4 VAE・GANに基づく異常検出について

医用画像の研究では、データ収集の段階で正常と異常データの数が不均衡になってしまう問題があるため、正常画像のみで学習できる VAE や GAN を基本とした異常検出は、医用画像に適しているように考えられる。しかし、現時点では解決すべき課題がある。

例えば、VAE は Encoder で情報圧縮した際に、細かな信号が消失してしまう可能性があり、Decoder を経由した再構成画像がぼやけてしまいがちであるので、現状は細かな異常部位の検出には適さないと考える。一方で、GAN は Discriminator の判別能力が高くなる学習が行えれば本物に近い画像が生成され、VAE よりも細かな信号に対応できる可能性がある。しかし、GAN にはモード崩壊（mode collapse）の問題があり、mode collapse が生じると、GAN が局所解に陥って特定のパターンの画像ばかり生成されてしまったり、解に収束せずに発散してしまったりすることがある。高精細で多様画像を生成するために、さまざまな GAN が登場しており、異常検出のために有用な GAN を筆者も検討していきたい。

5 おわりに

本稿では述べられなかったことのひとつに深層距離学習 (Deep Metric Learning) による異常検出がある。CVPR2020 では深層距離学習を用いた多くの論文が採択されており、異常検出のホットな技術と言える。深層距離学習とは、クラスが同じデータ間距離は小さく、クラスが異なるデータ間距離を大きくするように学習する手法である。データ分類法としては、大津の方法がよく知られているように、異常検出の精度向上のためには、CNN 等で抽出した異常に関する情報をいかに良く分類できるかが重要であり、読者がさまざまな最新技術の適用を試み、学会などでの成果報告を期待したい。

参考文献

- [1] M.L. Giger: Computer-aided diagnosis, in Syllabus: A Categorical Course in Physics, Technical Aspects of breast imaging, 283-298, 1993
- [2] K. Suzuki, J. Shiraishi, H. Abe, et al.: False positive reduction in computer-aided diagnostic scheme for detecting nodules in chest radiographs by means of massive neural networks, Academic Radiology, 12(2), 191-201, 2004
- [3] 第 87 回画像部会「深層学習を放射線技術研究に利用する」, 画像通信, 43(1), 1-33, 2020

- [4] R. Girshick, J. Donahue, T. Darrell, et al.: Rich feature hierarchies for accurate object detection and semantic segmentation, in IEEE Conf. Computer Vision and Pattern Recognition (CVPR), 5, 580–587, 2014
- [5] K.E.A. van de Sande, J.R.R. Uijlings, T. Gevers, et al.: Segmentation as selective search for object recognition, in 2011 Intl. Conf. Computer Vision, 1879–1886, 2011
- [6] J. Redmon, S. Divvala, R. Girshick, et al.: You Only Look Once: Unified, real-time object detection, arXiv:1506.02640, 2015
- [7] 宮下充浩, 畑中裕司, 小郷原一智, 他: 畳み込みニューラルネットワークを用いた眼底画像における毛細血管瘤の自動検出, Medical Imaging Technology, 36 (4), 189–195, 2018
- [8] Y. Hatanaka, T. Inoue, K. Ogohara, et al.: Automated microaneurysm detection in retinal fundus images based on the combination of three detectors, J. Medical Imaging and Health Informatics, 8(5), 1103–1112, 2018
- [9] 黒滝紘生, 中山浩太郎, 上原雅俊, 他: 深層学習による胸部 X 線写真からの診断補助, 2017 年度人工知能学会全国大会, 2B1-3, 2017
- [10] P. Perera and V.M. Patel: Learning deep features for one-class classification, IEEE Trans. Image Processing, 28(11), 5450–5463, 2019
- [11] Q. Wei, Y. Ren, R. Hou, et al.: Anomaly detection for medical images based on a one-class classification, in Proc. SPIE Medical Imaging 2018: Computer-Aided Diagnosis, 10575, 105751M, 2018
- [12] T. Schlegl, P. Seeböck, S.M. Waldstein, et al.: Unsupervised anomaly detection with generative adversarial networks to guide marker discovery, in Intl. Conf. Information Processing in Medical Imaging, 146–157, 2017
- [13] H. Zenati, C.S. Foo, B. Lecouat, et al.: Efficient gan-based anomaly detection, in Intl. Conf. Learning Representations, 2018
- [14] T. Fujioka, K. Kubota, M. Mori, et al.: Efficient anomaly detection with generative adversarial network for breast ultrasound imaging, Diagnostics (Basel), 10(7), 456, 2020

分類

広島国際大学 保健医療学部 診療放射線学科 山本 めぐみ

1. はじめに

画像部会のテーマ「深層学習のイロハ〜分類」について述べる。

一般に公開されている学習モデルは大規模なデータセットで学習されており、分類できる数も多く、分類精度も非常によい結果が得られている。そこで公開されている学習モデルを利用、改良することで、自分で1からモデルを作成しなくても、効率的にかつ高性能で研究を進めて行くことができる。そこで今回は主に画像分類で使われる学習モデルについて紹介する。

2. 学習モデルの歴史

現在の深層学習による AI ブームのきっかけとなったのは、AlexNet[1]である。トロント大学の Hinton らのグループにより提案されたモデルである。畳み込みニューラルネットワーク (CNN) を用いることで、認識精度を大幅に改善することに成功した。2012 年の ILSVRC (ImageNet Large Scale Visual Recognition Challenge) で優勝している。以下は代表的なモデルを紹介する。2014 年オックスフォード大学の VGG (Visual Geometry Group) チームにより VGG[2]が開発された。VGG は VGG-16, 19 の学習済みモデルがよく使用されている。2014 年の ILSVR で 2 位となった。基本的には AlexNet に近いが、AlexNet と異なる点はコンボリューション層のフィルタのサイズが 3×3 のみで構成され、CNN の総数が多い点とコンボリューション層の次に ReLU による活性化関数をおく点である。続いて Inception V3 は 2014 年の ILSVRC で優勝した GoogleNet[3] (Inception v1) を改良したモデルである。このモデルは長年にわたり複数の研究者によって多くのアイデアが出され、開発されたものである。GoogleNet の構造は AlexNet と大きく異なる。GoogLeNet は 1 つの入力画像に対し、複数の畳み込み層 (1×1 , 3×3 , 5×5) を並列に適用し、それぞれの畳み込み計算の結果を最後に連結することで作業をまとめる Inception モジュールと呼ばれる構造を取り入れている。この Inception モジュールを取り入れることで層を深くすることを可能とした。Residual Network (ResNet)[4]は Microsoft Research の Kaiming He 氏が 2015 年に考案したニューラルネットワークのモデルである。2015 年の ILSVRC で 1 位となった。特徴としては、従来の CNN と比較して圧倒的に総数が多く 152 層もの層を重ねることに成功している。それまで、VGG が 16 層または 19 層、GoogleNet が 22 層であったことから各段に総数が増えたことがわかる。「スキップコネクション」構造が最大の特徴である。その後、ResNet を元に DenseNet[5]や ResNet-RS (re-scaled ResNet) [6]が開発されている。

また、スマホなどのモバイル端末や小型端末にも使えるように計算負荷を軽くしたモデルである MobileNet(v1,v2,v3)が 2017 年に誕生した. この他モバイル用には ShuffleNetv2, ResNeXt, MNASNet, EfficientNetV2 などが開発されている.

3. 画像分類の流れ

流れの概要を図 1 に示す。まず Keras, MATLAB, Pytorch などの環境を整える。

続いて、分類したい画像を準備してラベルを付ける。本格的に研究を始める前の段階であれば、画像部会 HP「研究情報サイト」(図 2) (<http://imgcom.jsrt.or.jp/research/>)に掲載されている医用画像データを参照するとよい。胸部(単純X線), CT, Breast, Radiomics に利用できる公開データベース, CT colonography, その他の画像データダウンロードサイトが紹介されている。標準デジタル画像データベース(胸部腫瘍陰画像)については画像通信に毎回掲載されているページを参照のこと。

次に、学習モデルを作成する。学習モデルは一から自分で構築する方法と、既存のモデルを使用、改良して用いる方法がある。また、学習済みモデルを用いる方法もある。多くの有名な学習モデルや学習済みモデルは Keras, MATLAB, Pytorch などの各種フレームワークで用意されている。

最後に学習・バリデーションテスト、推論という流れで画像分類を行う。




図 1 画像分類の流れの概要



図 2 画像部会 HP (黄色矢印が研究サイト (2021 年 9 月現在))

4. 学習モデルによる画像分類の比較

画像部会 HP にある日本放射線技術学会の「標準デジタル画像データベース[胸部腫瘍陰影像]」MINIJSRT_DATABASE を用いて胸部 X 線画像の性別分類 (male/female の 2 クラス分類) (図 3) を行い, 学習モデルによる比較を行った. フレームワークは Pytorch, プログラミング言語は Python, Linux (Ubuntu) を用いた. 学習モデルは代表的な LeNet, AlexNet, ResNet を使用した. 使用した 3 つのネットワーク構造は元論文とほぼ同じものを用いた. epoch 数 50 回までと Loss 値のグラフを図 4 に示す. ResNet-50 の収束が格段に速く, AlexNet, LeNet と開発された順番に収束した結果となった.



図 3 使用した画像データ (<http://imgcom.jsrt.or.jp/minijsrt/db/>)




図 4 モデル別の Epoch 数と Loss 値の関係

5. 最新の話題

2019 年以降、画像認識モデルにおいては EfficientNet, Big Transfer, Vision Transformer[] など多くのモデルが提案されている。画像認識は、画像の中に何が写っているのか識別する技術で検出や分類が用いられている。EfficientNet[7]の改良版である EfficientNetV2[8]が 2021 年に発表された。注目されているモデルである。最近のモデル Vision Transformer と同様の計算機を使って 5 倍から 11 倍高速かつ 2%高性能化したと報告されている。この他 VGG を改良した Rep - VGG [9] が, EfficientNet を超えるスピードと精度を達成した報告されている。

6. おわりに

画像分類の学習モデルについて紹介した。最新の学習モデルを簡単に試してみたい場合、ネット検索で「学習モデルの名前と計算環境, GitHub」を検索ワードに入れると自分の環境に合わせたプログラムコードを見つけることができる。そのプログラムを自分の計算環境のプログラムコードをコピーして貼り付ける事で簡単に使用できる。深層学習のイロハの「分類」という事で、これから研究を始めて行くためポイントの概要を紹介した。詳細は当日会場にて補足する。

参考文献

- [1] Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton. ImageNet classification with deep convolutional neural networks. NeurIPS. 2012.
- [2] Karen Simonyan, Andrew Zisserman. VERY DEEP CONVOLUTIONAL NETWORKS FOR LARGE-SCALE IMAGE RECOGNITION. ICLR. 2015
- [3] Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, Andrew Rabinovich: Going Deeper with Convolutions, arXiv:1409.4842. 2014
- [4] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun :Deep Residual Learning for Image Recognition . arXiv:1512.03385. 2015
- [5] Gao Huang, Zhuang Liu, Laurens van der Maaten, Kilian Q. Weinberger: SDensely Connected Convolutional Networks, CVPR 2017
- [6] J. Redmon, S. Divvala, R. Girshick, et al.: You Only Look Once: Unified, Real-Time Object Detection. arXiv:1506.02640. 2015
- [7] Mingxing Tan, Quoc V. Le : EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. International Conference on Machine Learning. 2019

- [8] Mingxing Tan, Quoc V. Le : EfficientNetV2: Smaller Models and Faster Training. International Conference on Machine Learning. 2021
- [8] Xiaohan Ding, Xiangyu Zhang, Ningning Ma, Jungong Han, Guiguang Ding, Jian Sun : RepVGG: Making VGG-style ConvNets Great Again, CVPR. 2021

推定

立命館大学理工学部 檜作 彰良

1. はじめに

畳み込みニューラルネットワーク（CNN：Convolutional Neural Networks）で扱われるタスクとしては、主に分類と回帰である。本テーマである“推定”は、この分類と回帰のいずれにも密接に関わっている。分類問題である病変の良悪性分類の場合、CNN は各クラス（良性と悪性）に属する確率を推定し、その確率が高い方を最終的な分類結果として出力する。一方、回帰問題として扱われる画像の高解像度化では、低解像画像から高解像画像を推定する。また、物体検出の場合は、医用画像上で病変が存在する位置（座標）の推定を行う。これらのタスクにおいて、CNN のネットワークは基本的に同じような構成であるが、損失関数が異なる。分類問題で用いる損失関数は主に交差エントロピー[1]、回帰問題では平均二乗誤差（MSE：Mean Squared Error）[2]などが用いられる。

本稿では、はじめに、分類問題と回帰問題を対象とした CNN の基本的なネットワーク構成に関して簡単に説明する。シンポジウムでは、本稿の推定の前に“分類”に関する講演があるため、ここでは回帰問題にターゲットを絞り、画像超解像と物体検出（病変の位置座標推定）を対象とした CNN のネットワーク構成及び損失関数について説明する。最後に、5 章では、まとめを述べる。

2. 分類問題と回帰問題を対象とした CNN の基本的なネットワーク構成

Fig.1 に、分類問題（病変分類）を対象とした CNN のネットワーク構成の例を示す。分類問題を対象とした CNN では、入力層、畳み込み層、プーリング層、全結合層、出力層から構成される[3-4]。畳み込み層は、入力された画像に対してフィルタ処理を適用し、画像の特徴を抽出する。ここで、畳み込み層により抽出されたデータは、特徴マップと呼ばれる。次のプーリング層では、畳み込み層により抽出された特徴マップのサイズを縮小する。これにより、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ことができる。そして、全結合層では、重み付き結合を求め、それを ReLU（Rectified Linear Unit）などの活性化関数に通しユニット値を得る。全結合層に入力する特徴マップが 2 次元の場合、1 次元ベクトルに展開してから入力する。最後の

出力層では、ソフトマックス関数を用いて各クラス確率（例えば、病変の良悪性分類の場合、良性の確率と悪性の確率）を出力する。分類問題を対象とした CNN の学習の際、損失関数としては、交差エントロピー（Cross Entropy）が主に用いられている。ここで、交差エントロピーは、次式で定義される。

$$CE = - \sum_{c=1}^C g_c \ln y_c \quad (1)$$

C , g_c , y_c はそれぞれ、クラス数、正解のラベル、CNN により推定したラベルである。




Fig.1 分類問題を対象とした CNN の基本的なネットワーク構成

Fig.2 に、回帰問題（画像の高解像度化）を対象とした CNN のネットワーク構成の例を示す。このネットワークは SRCNN (Super-Resolution Convolutional Neural Network) [5] と呼ばれており、CNN を初めて画像の高解像度化に応用したネットワークである。SRCNN はシンプルなネットワーク構成で、入力層、3 つの畳み込み層、出力層より構成される。ここで、各畳み込み層の後には、ReLU 活性化関数を用いられている。画像の高解像度化を目的とした CNN では、プーリング層や全結合層が用いられることは少ない。この要因としては、プーリング層を用いることにより、位置情報や情報の欠落を招くからである。SRCNN の損失関数としては、MSE が用いられており、次式で定義される。

$$MSE = \frac{1}{hw} \sum_{y=1}^h \sum_{x=1}^w \|g(y, x) - y(x, y)\|^2 \quad (2)$$

ここで、 h, w は画像の高さと幅である。また、 g と y はそれぞれ、教師画像（高解像度画像）と CNN が推定した画像を表している。CNN は、MSE が小さくなるようにネットワークの重みを調整する。




Fig.2 回帰問題（画像の高解像度化）を対象とした CNN のネットワーク構成の例（SRCNN）

3. 回帰問題の事例 1：画像超解像

Fig.3 に、画像の高解像度化で用いられている VDSR (Very Deep Super Resolution) [6] のネットワーク構成を示す。この VDSR は、20 個の畳み込み層と ReLU (Rectified Linear Unit) 活性化関数より構成されている。ここで、全ての畳み込み層のフィルタサイズとフィルタ数はそれぞれ、 3×3 、64 である。この VDSR では、入力された低解像度画像と教師画像 (高解像度画像) との残差画像 (高周波成分) を推定するように学習を行う。ここで、VDSR の損失関数としては、MSE が使用されている。そして、低解像度画像の高解像度化では、学習した VDSR に低解像度画像を入力し、高周波成分を推定する。最後に、入力低解像度画像に推定した高周波成分を加算することで高解像度化画像を生成する。VDSR により生成された高解像度化画像は、SRCNN と比較して、ボケが低減された画像が生成できることが示されている。

また画像の高解像度化を目的とした CNN の損失関数として、MSE に代わり、Perceptual loss が使われることもある。この Perceptual loss[7]は、CNN の生成画像と教師画像を VGGNet[8]に入力し、それらの画像から得られる中間層の特徴マップの MSE で定義される (式 (3))。

$$Perceptual\ loss = \frac{\alpha}{n} \sum_{i=1}^n (\phi(t) - \phi(y))^2 \quad (3)$$

ここで、 $\phi(\cdot)$ は教師画像である高解像度画像 t と CNN により生成した高解像度化画像 y を VGGNet に入力し、VGGNet の中間層から出力される特徴マップである。また α, n はそれぞれ、重み係数、特徴マップ数である。この Perceptual loss を用いた CNN により、ボケを抑制した鮮明な画像が生成できる。




Fig.3 VDSR のネットワーク構成

4. 回帰問題の事例 2：物体検出

Fig.4 に、物体検出モデルである Faster R-CNN を示す。物体検出とは、画像に含まれる病変などの物体を取り囲む矩形領域 (バウンディングボックス) の座標を推定するタスクである。Faster R-CNN では、矩形領域の座標推定に加え、その矩形領域に含まれる物体のクラス (物体 or 背景など) も推定する。

このネットワークでは、まず、事前学習済みの CNN モデル (AlexNet, VGG16, GoogLeNet など) を用いて入力画像から特徴マップを抽出する。次に、領域提案ネットワーク (RPN : Region Proposal Network) が、特徴マップの局所領域ごとに、複数のバウンディングボックスを推定する。CNN モデルにより抽出された特徴マップのサイズが $W \times H$ の場合、各局所領域で事前に形状が決められた k 個のアンカーボックスを使用するので、RPN は合計 $W \times H \times k$ 個のバウンディングボックス (t_x, t_y, t_w, t_h) を出力する。最後に、これらを分類ネットワークと回帰ネットワークに入力し、各ボックス内の情報が物体か背景かを分類し、物体の場合、正解の物体の位置座標とボックスのズレを学習する。

このネットワークの損失関数としては、次のように定義される。

$$\mathcal{L}(p_i, t_i) = \frac{\lambda_1}{N_{class}} L_{class}(p_i, p_i^*) + \frac{\lambda_2}{N_{regression}} P_i^* L_{regression}(t_i, t_i^*) \quad (4)$$

ここで、 p_i, p_i^*, t_i, t_i^* はそれぞれ、推定したボックスが物体である確率、推定したボックスの正解ラベル、推定したボックスの位置と大きさ、推定したボックスの正解の位置と大きさである。また N_{class} はミニバッチサイズ、 $N_{regression}$ は特徴マップに対するアンカーボックス数、 λ_1 と λ_2 は重み係数である。更に、 L_{class} と $L_{regression}$ は、次のように定義される。

$$L_{class}(p_i, c) = -\log p_{ic} \quad (5)$$

$$L_{regression}(t_i, t_i^*) = \sum_{j \in \{x, y, w, h\}} S_{L_1}(t_{ij} - t_{ij}^*) \quad (6)$$

$$S_{L_1}(x) = \begin{cases} 0.5x^2 & \text{if } |x| < 1 \\ |x| - 0.5 & \text{(otherwise)} \end{cases} \quad (7)$$

ここで、 $L_{class}(\cdot)$ は、クラス分類に関する損失関数である。また、 $L_{regression}(\cdot)$ は、各アンカーボックスの出力 t_i と正解 t_i^* の差に対する回帰損失である。Faster R-CNN では、分類損失と回帰損失の合計値が小さくなるようにネットワークの重みを調整する。




Fig.4 Faster RCNN のネットワーク構成

5. おわりに

本稿では、回帰問題にターゲットを絞って、CNN のネットワーク構成と損失関数に関して述べた。分類問題、及び回帰問題で用いられる CNN のネットワークは、基本的に同じような構成であり、損失関数が異なる。タスクごとに様々な損失関数が提案されているため、必要に応じて論文等を参照して頂きたい。

本稿で掲載した全ての胸部 X 線画像は、miniJSRT_database[10]に含まれている画像である。

参考文献

- [1] Zhang Z, Sabuncu M.R.: Generalized cross entropy loss for training deep neural networks with noisy labels. In 32nd Conference on Neural Information Processing Systems (NeurIPS), 2018.
- [2] Wang Z, Bovik A.C.: Mean squared error: Love it or leave it? A new look at signal fidelity measures. IEEE signal processing magazine, 26(1), 98-117, 2009.
- [3] LeCun Y, Bengio Y, Hinton G.: Deep learning. nature, 521(7553), 436-444, 2015.
- [4] Fujita H.: AI-based computer-aided diagnosis (AI-CAD): the latest review to read first. Radiological physics and technology, 13(1), 6-19, 2020.
- [5] Dong C, Loy C.C., He K., Tang X.: Image super-resolution using deep convolutional networks. IEEE transactions on pattern analysis and machine intelligence, 38(2), 295-307, 2015.
- [6] Kim J, Lee J.K., Lee K.M.: Accurate image super-resolution using very deep convolutional networks. In Proceedings of the IEEE conference on computer vision and pattern recognition, 1646-1654, 2016.
- [7] Johnson J, Alahi A, Fei-Fei L: Perceptual losses for real-time style transfer and super-resolution. In European conference on computer vision, 694-711, Springer, Cham, 2016.
- [8] Simonyan K, Zisserman A: Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556, 2014.
- [9] Ren S, He K, Girshick R, Sun J: Faster R-CNN: towards real-time object detection with region proposal networks. IEEE transactions on pattern analysis and machine intelligence, 39(6), 1137-1149, 2016.
- [10] 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.

作る

藤田医科大学大学院 保健学研究科 修士課程 2 年 吉田 瑞希

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

様々な分野で用いられている Deep learning は、分類や領域抽出、推定、画像変換などを行うことができる。近年、注目されている Deep learning 技術として、画像生成・画像変換を行うことができる、敵対的生成ネットワーク（GAN: Generative Adversarial Networks）がある。本稿では、GAN の原理や医療分野における応用例について解説する。

2. 画像生成・画像変換技術について

画像生成・画像変換とはノイズから画像を生成したり、画像から画像を生成したりする技術である。生成モデルのなかでも注目されている技術の一つとして GAN がある。GAN はデータから特徴を学習することで、実在しないデータを生成したり、存在するデータの特徴に沿って変換したりすることができる。図 1 のように実際に存在しない人の顔を生成することもできる。GAN はそのアーキテクチャの柔軟性から、アイデア次第で広範な領域に適用でき、画像・音声・自然言語など各分野で成果が上がっている。応用研究や理論的研究も急速に進んでおり、今後の発展が大いに期待されている。GAN の応用は医療分野においても進んでおり、画質改善や画像再構成、画像生成などの課題に対する研究が報告されている。



図 1. 実際には存在しない顔の画像[1]

3. GAN の原理

GAN (Generative adversarial network) は、学習データと似たデータを生成するネットワークモデルで、2014 年に I.J. Goodfellow らによって提案された[2]。GAN は、正解データを与えることなく特徴を学習する「教師なし学習」の一手法として注目されており、「機械学習分野において、この 10 年で最も面白いアイデア」と評されている。

図に示すように GAN は生成器と識別器の 2 つのネットワークの学習によって画像を生成するモデルである。生成器は、生成データの特徴となるランダムノイズを入力とし、本物のデータと類似性がある偽物のデータを生成するネットワークで、識別器は生成器が生成した偽物のデータか本物のデータかを識別するネットワークである。GAN では、識別器と生成器が交互に学習を行う。識別器の学習では生成器のパラメータを固定し、偽物のデータに対しての識別率を向上させるように学習を行う。偽物のデータを本物のデータであると誤った確率をもとに誤差を求め、誤差を逆伝播してパラメータの更新を行う。次に、識別器のパラメータを固定し、生成器の学習を行う。識別器で行われる学習と反対に、生成器は識別器に偽物のデータが本物のデータであると誤って識別されるようにパラメータの更新を行う。パラメータの更新を交互に繰り返すことで、生成器は損失が小さく、識別器は損失が大きくなるように学習し、このような 2 つのネットワークの競合的な関係によってデータの生成が行われる。学習が進むにつれて、最終的に生成器は本物のデータと区別がつかないほど精度の高い画像を生成することができるようになる。




図 2. GAN の構造



(a) 学習回数 10 回

(b) 学習回数 20 回

(c) 学習回数 50 回

図 3. GAN による画像生成例[3]

4. 医用画像を用いた研究におけるデータ収集

Deep learning はデータの特徴を学ぶため、一般的に多くのトレーニングデータが必要となる。しかし、医用画像を対象とした場合、大量のデータを収集することは非常に難しい。学習データが少ないことによる影響として過学習があげられる。過学習では未知のデータに対して汎化性能が低下してしまう。過学習を抑制するための解決策の一つとして頻繁に行われるのがデータ拡張である。データ拡張では、既にある画像に対し、回転や拡大縮小、コントラストの変換やノイズの付与などにより一定の変化を与える。しかし、データ拡張では病変や目的とする構造物の性質は大きく変わらない。また、医用画像においてはデータ拡張をする際に実際にはありえないような画像を作り出さないように注意が必要である。そこで、GAN によりバラエティーに富んだシミュレーション画像を生成し、学習に用いることが提案されている。また、撮影のワークフローやコストの改善などを目的として、撮影されなかった画像を擬似的に生成し、診断に利用することも提案されている。

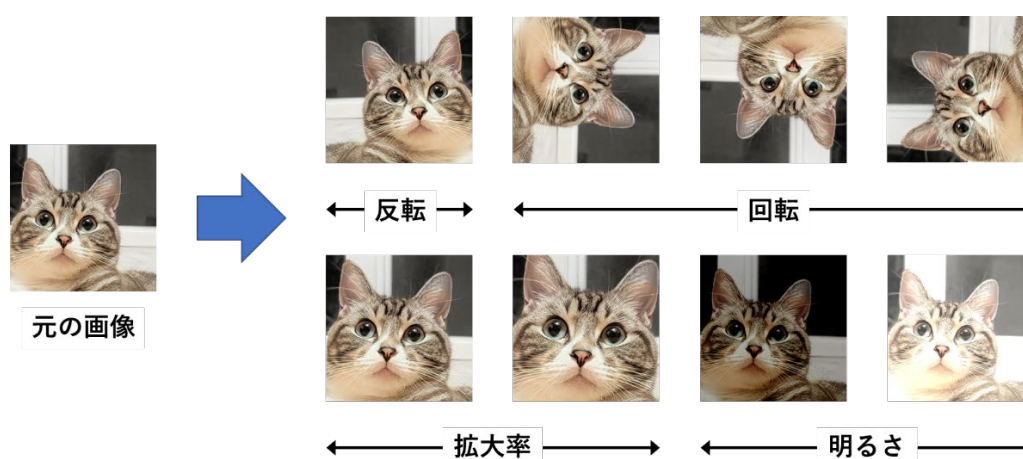


図 4. データ拡張例

5. GANの派生技術とその医療応用

5.1. WGAN

従来までの GAN 手法では、Generator と Discriminator の構造に DCNN を使用する GAN (DCGAN) が用いられてきた[4]。従来の GAN 法では、2 つの確率密度間の距離を表すために、JS divergence を使用して学習が行われる。この方法では、勾配消失問題と同様の画像の生成に伴うモード崩壊によって、トレーニングプロセスが不安定になる可能性がある。これらの問題に対処するために WGAN が導入された[5]。WGAN では、損失関数は JS divergence の代わりに Wasserstein distance を使用して定義される。discriminator の役割が、「本物データか偽物データか識別する」というものから「本物データと生成データの Wasserstein distance を推定する」というものに代わっている。したがって、勾配は最適パラメータ値の近くで消えず、トレーニングプロセスが安定する。

WGAN の医療応用例として、肺結節の生成を行い分類処理に応用する研究がある[6]。図の(c)、(d)ではそれぞれ(a)、(b)の結節の特徴をつかんだ画像が生成されている。この生成された結節を良悪性分類のプレトレーニングに用いることで、分類精度の向上が報告されている。




図 5. WGAN による結節生成例[6]

5.2. Pix2Pix

Pix2Pix は、図 6 のように画像から画像への変換を行う GAN で、画像変換において最も基本となる学習アルゴリズムである[8]。1 対 1 のペアの画像の変換を行うため、正解ペアを大量に用意できるケースに適している。同図の各左側が入力画像で、右側が出力画像を示している。

Pix2Pix では 1 対 1 で対応する 2 つのドメインの画像を入力とする。ここでは 2 つのドメインを X 、 Y とし、入力画像を x 、それに対応するペアとなる画像を y とする。Pix2Pix ではドメイン X の画像を入力し、ドメイン Y の画像へと変換できるように学習を行う。学習方法として、まず、Generator: G は学習画像 x をもとに、生成画像 $G(x)$ を出力する。Discriminator: D は「学習画像 x と本物画像 y のペア」と「学習画像 x と生成画像 $G(x)$ のペア」がそれぞれ本物かどうかを識別する。この構造によって、Generator が学習画像から本物のような画像を生成できるように画像ペアの関係を学習する。また、Pix2Pix では Generator に U-Net を採用している。U-Net は Encoder-decoder 方式の各層にスキップ接続を追加したもので、各層で得た特徴量をエンコーダーからデコーダーへと伝えられるようになっている。このようにして入力画像の特徴を維持しながら画像生成するための Generator が定義される。しかし、この構造では類似した画像が生成されやすいため、Dropout を導入し、出力画像のバリエーションを増やす工夫が施されている。また、従来の GAN では、二値交差エントロピーを損失関数として用いられてきた。しかし、画像変換問題では、本物らしさだけでなく入力画像と出力画像の一致具合を測る指標が必要となる。そこで、Pix2Pix では Discriminator の損失関数に L1 損失関数というものが加えられている。L1 損失関数を生成画像の低周波成分の正確さを測る指標として使用し、条件画像と生成画像の全体像が一致するよう学習させる。さらに、Discriminator に PatchGAN を採用し、よりリアルな画像生成が可能となっている。

医療分野での応用例として、MR 画像から CT 画像への変換が行われている[9]。Pix2Pix による画像変換が行われることによって、MR 画像と CT 画像で位置のそろった画像を取得することができる。また、放射線治療計画の際、MR 画像のみでワークフローを行うことができるようになれば、治療計画のためだけに CT 検査を行わなくても良いため、被ばく低減につながる技術となり得る。




図 6. Pix2Pix による画像変換例[8]




図 7. Pix2Pix の構造




図 8. Pix2Pix による MR 画像から CT 画像への変換[9]

5.3. CycleGAN

CycleGAN (Cycle-consistent Adversarial Networks) は GAN の応用型であり、Pix2Pix と同じく、画像から画像への変換を学習するモデルである[10]。CycleGAN は 2 種類の画像群 X, Y の画像 x, y を学習画像とし、以下の図に示すように画像群 X から Y の画像変換を学習する Generator: G と Y から X の画像変換を学習する Generator: F の 2 つの Generator をもつ。また、画像群 Y の学習画像 y と画像群 X の画像から変換された画像 $G(x)$ を識別する Discriminator: D_y 、もう一方の Generator: F に対応する Discriminator: D_x をもつ。これら 2 組の Generator と Discriminator を用いて 2 つの画像間の関係性を学習し、画像の書き換えを行う。さらに、CycleGAN では図に示すように変換後の画像を再び変換して得られる復元画像 $F(G(x))$ と、元の入力画像 x を比較し、その差が小さくなるように学習を行う。

Pix2Pix では画像変換の入力画像、出力画像に相当する 2 つの画像の対応関係を学習することで、変換アルゴリズムを獲得できるが、その学習には 1 対 1 に対応したペアデータが大量に必要だった。CycleGAN では、2 つの画像の対応する各ピクセルの関係を学習するのではなく、2 つの画像データセット同士の domain の関係を学習して画像変換を実現している。これによって、CycleGAN は大量のペア画像を用意しなくても、2 つの違う画像データセットからその関係を学習して、画像変換アルゴリズムを獲得することができる。

CycleGAN を用いた研究例には図 11 に示すように CycleGAN を用いて異常画像から正常画像を生成し、ラベル画像を作成する研究がある[11]。




図 9. CycleGAN の構造




図 10. Cycle-consistency loss




図 11. CycleGAN による生成画像を用いたラベル画像の作成[11]

6. まとめ

本稿では、画像生成・画像変換に関して、GANの原理やGANの派生技術の研究事例の紹介をおこなった。Deep learning の発展により、様々な GAN の派生技術が開発されており、精巧な画像生成が可能となってきた。医療分野においては生成される画像のモダリティや対象とされる部位も頭部や腹部、整形など多くの分野への応用がなされている。現段階では GAN で生成された画像は Deep learning の学習における Data augmentation として使用されることが多いが、今後、生成された画像の臨床への応用を期待したい。そのためには、生成された画像の評価方法の確立が必要になると思われる。

参考文献

- [1] Tero Karras, Timo Aila, Samuli Laine, Jaakko Lehtinen, “Progressive Growing of GANs for Improved Quality, Stability, and Variation,” ICLR, 2018. arXiv:1710.10196.
- [2] Ian Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, Yoshua Bengio, “Generative Adversarial Nets,” Advances in Neural Information Processing Systems 27 (NIPS 2014), pp.2672–2680, 2014.
- [3] Chengcheng Li; Zi Wang; Hairong Qi, “Fast-Converging Conditional Generative Adversarial Networks for Image Synthesis,” 2018 25th IEEE International Conference on Image Processing (ICIP), pp. 2132–2136, 2018. doi: 10.1109/ICIP.2018.8451161.
- [4] A. Radford, L. Metz, and S. Chintala, “Unsupervised representation learning with deep convolutional generative adversarial networks,” 2015, <https://arxiv.org/abs/1511.06434>.
- [5] Martin Arjovsky, Soumith Chintala, Léon Bottou, “Wasserstein Generative Adversarial Networks,” Proceedings of the 34th International Conference on Machine Learning, PMLR 70:214–223, 2017.
- [6] Onishi Y, Teramoto A, Tsujimoto M, Tsukamoto T, Saito K, Toyama H, Imaizumi K, Fujita H, “Automated pulmonary nodule classification in computed tomography images using a deep convolutional neural network trained by generative adversarial networks,” BioMed Res Int 2019;6051939.
- [7] Chen X, Duan Y, Houthoofd R, Schulman J, Sutskever I, Abbeel P, “Interpretable representation learning by information maximizing generative adversarial nets,” Adv Neural Inf Process Syst 29:2180–2188, 2016.
- [8] Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, Alexei A. Efros, “Image-To-Image Translation With Conditional Adversarial Networks,” IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 1125–1134, 2018.
- [9] Kévin N D Brou Boni, John Klein, Ludovic Vanquin, Antoine Wagner, Thomas Lacornerie, David Pasquier, Nick Reynaert, “MR to CT synthesis with multicenter data in the pelvic area using a conditional generative adversarial network,” Physics in Medicine & Biology, Volume 65, Number 7,

2020.

- [10] Jun-Yan Zhu, Taesung Park, Philip Isola, Alexei A. Efros, “Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks,” IEEE International Conference on Computer Vision (ICCV), pp.2223–2232, 2017.
- [11] L. Sun, J. Wang, Y. Huang, X. Ding, H. Greenspan and J. Paisley, “An Adversarial Learning Approach to Medical Image Synthesis for Lesion Detection,” in IEEE Journal of Biomedical and Health Informatics, vol. 24, no. 8, pp. 2303–2314, 2020. doi: 10.1109/JBHI.2020.2964016.

“Image Science”から学ぶウィーナスpekトルの次元変換

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

シカゴ大学・群馬県立県民健康科学大学 土井 邦雄

1. はじめに

ノイズウィーナスpekトル (WS: Wiener Spectrum)あるいはノイズパワースpekトル(NPS: Noise Power Spectrum)は, MTF(Modulation Transfer Function)と並んで画質評価の2大評価指標であり, その理論や測定方法についてはアナログ時代から多くの研究成果が報告されている [1]-[3]。本稿ではNPSではなく, ノイズウィーナスpekトル (WSと略記) という表記を採用する [4]。この指標は元々NPSとして時間方向の1次元電気信号からパワー(電力)を評価するのに使用されていたが, 2次元空間の医用画像に拡張適用されたので, 2次元WS (2DWS)を使用することが趨勢となっている。今後は3次元画像を扱うことも多くなると考えられ, 3DWSも研究対象になってくる。そうすると, 次元の異なるWS間の関係を把握することが研究遂行上きわめて有用であると考えられるので, WSの次元変換に関わる基本情報を提供することを本稿の目的とする。本稿は学術論文ではなく解説記事なので, 全体を通してできるだけ簡素な表現を心掛けた。

まず広く知られているように, 2DWSは画像を直接2次元フーリエ変換することで容易に計算できる。最近のMATLAB等の使い勝手の良いプログラムを使えば, わずか1行で実行できるので, フーリエ変換自体に深く立ち入らなくても容易に答は得られる。しかし2次元データは表示するのに多少の煩雑さを伴うので, その1次元代用物である中心断面が好んで使用される。中心断面というのは, 中心(原点)を通る断面のことで, 周波数変数を u, v とすれば, 例えば u 軸に沿った断面, v 軸に沿った断面, あるいは2DWSが周波数の絶対値のみに依存するような回転対称形の場合は円周方向に平均した値を使う, 等々である。

では, その中心断面はどうすれば求まるだろうか。まず, 空間座標を (x, y) , 対応する周波数変数を (u, v) とくと, 平均値がゼロであってトレンド補正済の, 入射線量に対して線形化されたノイズ画像 $f(x, y)$ の2DWSは以下のように計算される。

$$2DWS(u, v) = \frac{1}{4XY} \left| \int_{-X}^X \int_{-Y}^Y f(x, y) e^{-2\pi i(ux+vy)} dx dy \right|^2 \quad (1)$$

上式において, $2X, 2Y$ はそれぞれ画像の縦横の長さを表す。定義上 $X, Y \rightarrow \infty$ の極限を取るのが望ましいが, 有限サイズの医用画像を取り扱う関係上, この極限表記は省略する。

NOTE 1: WS は、フィルム濃度等の、入射線量に対して線形化されていない物理量を使っても定義できる^{[5]-[7]}、線形化された物理量を使っても定義できる^{[8][9]}が、表記を簡単にするために本稿では線形化データを使うこととする。両者は特性曲線を使えば容易に相互変換できる。

NOTE 2: $f(x, y)$ として、入射線量絶対値に直接比例する量にする場合^{[8][9]}と、入射線量平均値で規格化された相対線量にする場合^{[5]-[7]}があり、前者では線量増加と共に WS 値は上昇するが、後者では反対に低下する。しかし、どちらの場合にも以下の WS 次元変換についての議論は全て適用可能なので、本稿では特に両者の区別はしない。

NOTE 3: WS は CT 画像にも適用されるが、その場合には通常 $f(x, y)$ として、トレンド補正済で平均値ゼロの CT 値空間分布を取る^[10]。CT 値自体には線量依存性がないが、CT 値のゆらぎである WS には線量依存性があり、線量増加により WS 値は低下するので、CT の WS は **NOTE 2** の相対線量の場合に近いと考えられる。

(1)式において、2DWS の u 軸に沿った中心断面 ($v=0$ の断面) を求めるために $v=0$ とおくと、

$$\begin{aligned} 2DWS(u, 0) &= \frac{1}{4XY} \left| \int_{-X}^X \int_{-Y}^Y f(x, y) e^{-2\pi i u x} dx dy \right|^2 \\ &= \frac{1}{4XY} \left| \int_{-X}^X \left[\int_{-Y}^Y f(x, y) dy \right] e^{-2\pi i u x} dx \right|^2 \\ &= \frac{(2Y)^2}{4XY} \left| \int_{-X}^X \left[\frac{1}{2Y} \int_{-Y}^Y f(x, y) dy \right] e^{-2\pi i u x} dx \right|^2 \\ &= 2Y \cdot \frac{1}{2X} \left| \int_{-X}^X f_{syn}(x) e^{-2\pi i u x} dx \right|^2 \end{aligned} \quad (2)$$

となり、これは $f(x, y)$ を y 方向に加算平均した関数である

$$f_{syn}(x) = \frac{1}{2Y} \int_{-Y}^Y f(x, y) dy \quad (2)'$$

について計算した $1DWS_{syn}(u)$ に y 方向の長さ $2Y$ を掛けたものである。すなわち、

$$2DWS(u, 0) = 2Y \cdot 1DWS_{syn}(u) \quad (3)$$

$f_{syn}(x)$ を求めるということは、アナログ系で言うところの“仮想スリット”を使うことに相当する。中心断面を正確に求めるには、アナログ系でもデジタル系でも仮想スリットの長さを十分長く取るようにとの記述が多くなされてはいるが、上で見たようにスリット長は、理論的には単純に実現可能な最大値を取ればよい。

ところで、1DWS と言えもう 1 種類考えられる。それは、 $f_{syn}(x)$ のように y 方向に加算平均したデータではなくて、1 行のみのデータから計算される WS である。例えば $y = y_j$ である x 方向データから計算される 1DWS を考えると、

$$1DWS_j(u) = \frac{1}{2X} \left| \int_{-X}^X f(x, y_j) e^{-2\pi i u x} dx \right|^2 \quad (4)$$

となる。ここでは特定の y_j を指定したが、均一な画像であればどの j であっても同一の WS となる。この $1DWS_j(u)$ と中心断面 $2DWS(u, 0)$ との関係はどうなっているだろうか。もちろん両者は同じではないはずだが、どういう関係であるのかを仮想スリット法と同様な方法で直接的に示すことはできない。

2. 古典から学ぶ 1DWS と 2DWS の関係

実は、上記の答は過去の古典の中に見出せる次式を使えばわかる。

$$1DWS'(u) = \int_{-\infty}^{\infty} 2DWS(u, v) |T(u, v)|^2 dv \quad (5)$$

この式は、アナログ時代にマイクロデンシトメーターを使って、 $T(u, v)$ という伝達関数を持つ開口（アパーチャー）で、真の $2DWS$ が $2DWS(u, v)$ である画像を x 方向にスキャンした時に得られる $1DWS$ を表す式である。通常は細長いスリット状の開口を使うので、伝達関数は長方形形状をフーリエ変換したものになる。この式は、まず Jones^[11] によって示唆され、続いて Doi^[12] が証明し、更に Dainty & Shaw^[13] の *Image Science* という書籍において別方法で証明された。証明自体は少し込み入っているので本稿では深入りしないが、(5)式の正しさと有用性は次節で述べる事例での検証を待つまでもなく明らかである。(5)式は、この *Image Science* という書籍が教科書的な存在としての地位を固めたことで定着した式である。*Image Science* と同等な内容が内田ら^[14]や小寺ら^[2]に参照されることによって日本でも普及が進んだと思われる。

(5)式の応用としてまず、仮想スリットとして y 方向の長さ L 、 x 方向の幅 a であるスリットを想定すれば、このような仮想スリットの開口形状（点像分布関数）とその伝達関数はそれぞれ

$$h(x, y) = \frac{1}{aL} \text{rect}\left(\frac{x}{a}\right) \cdot \text{rect}\left(\frac{y}{L}\right), \quad T(u, v) = \text{sinc}(au) \cdot \text{sinc}(Lv)$$

と表せるので、これを(5)式に代入し、 a は極小、 L は長大という条件を課して計算すると、

$$\begin{aligned} 1DWS'(u) &= 1DWS_{syn}(u) = \int_{-\infty}^{\infty} 2DWS(u, v) \text{sinc}^2(au) \text{sinc}^2(Lv) dv \\ &\cong \text{sinc}^2(au) 2DWS(u, 0) \int_{-\infty}^{\infty} \text{sinc}^2(Lv) dv \cong \frac{2DWS(u, 0)}{L} \end{aligned} \quad (6)$$

が得られ、 u 軸に沿った中心断面が得られる。上記計算では、 $\text{sinc}^2(au)$ はほとんど u に依存せず 1 であり、 $\text{sinc}^2(Lv)$ の積分値は $1/L$ となることを利用している。この積分はパーシバルの定理を使えば容易に計算できる。(6)式は、 $L=2Y$ という条件では(3)式と全く同一であり、両者の結果は完全に一致していることが確認出来る。

NOTE 4: 細長い開口形状を表す極限表現として $h(x, y) = \delta(x)$, $T(u, v) = \delta(v)$ としても良いが、こうすると $|T(u, v)|^2 = \delta^2(v)$ となり、デルタ関数の 2 乗は計算不能であることから、この表現は避けた。

次に、仮想スリットとして「点状」のスリットを使ってみる。これはデジタル画像においては、1画素のデータを x 方向にスキャンすることに相当する。このような仮想スリットは $h(x,y) = \delta(x)\delta(y)$, $T(u,v) = 1$ と表せるので、これを(5)式に代入すると容易に

$$1DWS'(u) = 1DWS_j(u) = \int_{-\infty}^{\infty} 2DWS(u,v) dv \quad (7)$$

が得られる。これが、前節で求めようとしていた答である。すなわち、1行の画像データから計算される 1DWS は、2DWS の v 方向積分で与えられる。どの行でも同じ答になる。以上をまとめて図で表すと、図 1 のようになる。

Image Science 自身には、WS に限らず線形システム理論全般について多くの先駆的記述が見られる。線形システムの定義から始まって、コンボルーション定理から MTF, DQE まで、線形システムのほぼ全域を網羅している名著である。多くの先進的論文で引用文献として参照されて来たが、出版後 50 年近く経過しており、残念ながら現在では絶版となっているようだ。大学等の図書館には蔵書として備えられている場合もあるが、どちらかというアナログ時代の古い本ということで忘れ去られようとしている。しかし、デジタル時代にも通用する(5)式のような重要な記述が含まれており、今後も古典としての重要視されるべき書籍である。

3. コンピュータシミュレーションでの確認

理論式は上で述べたとおりだが、実際の画像でその正しさを確認してみよう。実際の X 線画像を用いるといろいろ実用上の細々とした配慮が必要となる [8][15] ので、本稿ではコンピュータ上に作成した画像で実験を実施した。

画像実験はデジタル画像を使用するため、前節で述べた内容を離散データに適用できる形にしなければならない。まず、(1)式に対応する離散データでの 2DWS は、通常次の (8)(9)式で与えられる [8]。

$$2DWS(u_n, v_k) = \frac{\Delta x \Delta y}{N_x N_y} |F(u_n, v_k)|^2 \quad (8)$$

$$F(u_n, v_k) = \sum_{l=1}^{N_x} \sum_{j=1}^{N_y} f(x_l, y_j) e^{-2\pi i(u_n x_l + v_k y_j)} \quad (9)$$

$\Delta x, \Delta y$ は画素間隔、 N_x, N_y は画素数を表す。実用的には、ばらつきを抑えるために、多数の ROI から求めた(8)式の 2DWS について平均を取る操作が必要となるが、ここでは簡単のためにその表記は省略した。IEC の定義では $f(x_l, y_j)$ は入射線量絶対値に直接比例する量になっているが、NOTE 2 でも述べたように、 $f(x_l, y_j)$ を入射線量平均値で規格化された相対線量としても、ここでの議論に全く影響はない。

NOTE 5: $f(x_l, y_j)$ のフーリエ変換は (9) 式で与えられるのが普通で、この時に (8) 式は正しい表現となる。MATLAB や EXCEL では (9) 式の定義で計算される。しかし、規格化方式を変えてフーリエ変換を次の (10) 式で定義する場合もあり^[9]、その時は (8) 式の形も変化してしまうので、どの定義を採用しているか注意が必要である。本稿では (9) 式を使う。

$$F'(u_n, v_k) = \frac{1}{N_x N_y} \sum_{l=1}^{N_x} \sum_{j=1}^{N_y} f(x_l, y_j) e^{-2\pi i(u_n x_l + v_k y_j)} \quad (10)$$




図1 2次元WSと1次元WSとの関係（理論）

この時、2DWS の u 軸に沿った中心断面は、次の(11)式で与えられる。

$$\begin{aligned}
 2DWS(u_n, 0) &= \frac{\Delta x \Delta y}{N_x N_y} \left| \sum_{l=1}^{N_x} \sum_{j=1}^{N_y} f(x_l, y_j) e^{-2\pi i u_n x_l} \right|^2 = \frac{\Delta x \Delta y}{N_x N_y} \left| \sum_{l=1}^{N_x} e^{-2\pi i u_n x_l} \sum_{j=1}^{N_y} f(x_l, y_j) \right|^2 \\
 &= \frac{\Delta x \Delta y}{N_x N_y} \left| \sum_{l=1}^{N_x} e^{-2\pi i u_n x_l} N_y f_{syn}(x_l) \right|^2 = N_y \Delta y \frac{\Delta x}{N_x} \left| \sum_{l=1}^{N_x} e^{-2\pi i u_n x_l} f_{syn}(x_l) \right|^2 = \frac{1}{\Delta v} \cdot 1DWS_{syn}(u_n) \quad (11)
 \end{aligned}$$

ここで、 $f_{syn}(x_l) = 1/N_y \sum_{j=1}^{N_y} f(x_l, y_j)$ 、 $N_y \Delta y = 1/\Delta v$ を使用した。

$N_y \Delta y = 1/\Delta v$ は y 方向の長さ $2Y$ であることに注目すれば、(11)式は(3)式と完全に等価な表現になっている。

また、2DWS と 1 行のみのデータから計算される 1DWS との関係は、(11)式と同様の考えを適用して、次のように計算される。

$$\sum_{k=1}^{N_v} 2DWS(u_n, v_k) = \frac{1}{\Delta v} \cdot 1DWS_j(u_n) \quad \text{for any } j \quad (12)$$

ここで $1DWS_j(u_n)$ は、 j 行目のデータのみから計算される 1DWS である。

実際の実験は以下のように実施した。乱数で作成したランダム画像に 2 次元ガウシアンフィルタをかけて画素間相関を発生させ、この画像について各種 WS を計算した。使用した画像の画素数は 64×64 、 $\Delta x = \Delta y = 0.1 \text{ mm}$ 、 $\Delta u = \Delta v = 0.1563 \text{ mm}^{-1}$ 、画素値の平均値はゼロで分散は 13.2 である。結果を図 2 にまとめて示す。 $1DWS_j(u)$ は、一画像内 64 行のデータからそれぞれ 1DWS を計算し、これらの平均を取った。さらに、ばらつきを抑えるために、全ての WS は 256 枚の独立な画像から計算した WS をそれぞれ画像間平均して求めた。

WS の性質上、その積分値は元画像の分散値 σ^2 に一致する [3][14]。シミュレーション実験ではこの点も数値的に確認し、図 2 中に結果を示した。すなわち、元画像の分散 ($\sigma^2 = 13.2$) は $2DWS(u_n, v_k)$ の体積に正確に一致し、同時にそれは $1DWS_j(u_n)$ の面積にも一致した。




図2 2次元WSと1次元WSとの関係（コンピュータシミュレーションでの確認結果）

4. 2次元WSと3次元WSの関係

Image Science では触れていないことだが、(5)式は1DWSと2DWSの関係を示すだけでなく、容易に2DWSと3DWSの関係を示すように拡張可能である。3次元画像は今後CTで増々利用が進むであろうし^[16]、X線画像においても動画解析では3次元画像を扱うこととなる^[17]ので、この関係を把握しておくことは重要である。

2次元から3次元への拡張は、極めて直接的に実現できる。3次元系の変数を (x, y, z) , (u, v, t) , (X, Y, Z) とすると、(5)式は次の(5)'式に変換される。

$$2DWS'(u, v) = \int_{-\infty}^{\infty} 3DWS(u, v, t) |T(u, v, t)|^2 dt \quad (5)'$$

ここで $3DWS(u, v, t)$ は、以下の式で定義される3DWSである。

$$3DWS(u, v, t) = \frac{1}{8XYZ} \left| \int_{-X}^X \int_{-Y}^Y \int_{-Z}^Z f(x, y, z) e^{-2\pi i(ux+vy+tz)} dx dy dz \right|^2 \quad (1)'$$

また、(6)式と(7)式はそれぞれ(6)', (7)' 式に変換される。

$$2DWS'(u, v) = 2DWS_{syn}(u, v) = \frac{1}{2Z} \cdot 3DWS(u, v, 0) \quad (6)'$$

$$2DWS'(u, v) = 2DWS_{z=z_p}(u, v) = \int_{-\infty}^{\infty} 3DWS(u, v, t) dt \quad (7)'$$

ここで $2DWS_{syn}(u, v)$ は、3次元画像を z 方向に加算平均した2次元画像についての2DWSであり、 $2DWS_{z=z_p}(u, v)$ は、 $z = z_p$ (p は任意)における (x, y) 平面画像についての2DWSである。

謝辞

本稿の内容に関し有益な議論をしていただいた帝京大学福岡医療技術学部の桂川茂彦博士に感謝いたします。

参考文献

- [1] Doi K, Helje G, Loo LN, et al. “MTF’s and Wiener spectra of radiographic screen-film systems”, *HHS publication FDA* **82-8187** 14-38 (1982)
- [2] 小寺吉衛, 大久敏弘, 田中勲, 他, “放射線像の粒状性の測定法 (I)”, 日放技学誌 **43(12)** 1743-1768 (1988)
- [3] 桂川茂彦 編著, *医用画像情報学*, 南山堂 (2002)
- [4] 土井邦雄, “ウィーナースペクトル研究の歴史的背景 ～カンタムモトル研究の始まり～”, 日放技学誌 **68(3)** 329-332 (2012)
- [5] Giger ML, Doi K, Fujita H, “Investigation of basic imaging properties in digital radiography. 7.Noise Wiener spectra of II-TV digital imaging systems”, *Med. Phys.* **13(2)** 131-138 (1986)
- [6] 山崎達也, “ディジタルウィーナースペクトルの実践的測定法”, *Innervision*, **18(12)** 40-46 (2003)
- [7] 朝原正喜, “Noise Power Spectrum - デジタルラジオグラフィの物理的画質評価方法 -“, 日放技学誌 **65(12)** 1671-1679 (2009)
- [8] IEC 62220-1-1, “Medical electrical equipment – Characteristics of digital x-ray imaging devices – Part 1-1: Determination of the detective quantum efficiency - Detectors used in radiographic imaging”, International Standard, (2015)
- [9] Dobbins III JT, “Image Quality Metrics for Digital Systems,” in *Handbook of Medical Imaging*, edited by Beutel, J., Kundel, H. L., and van Meter, R. L., (SPIE, Bellingham, WA), Vol. 1, Chap. 2. (2000)
- [10] 市川勝弘, 原孝則, 丹羽伸次, 他, “CT 画像におけるノイズパワースペクトル算出方法の比較評価”, 医用画像情報学会誌 **25(2)** 29-34 (2008)
- [11] Jones RD, “New Method of Describing and Measuring the Granularity of Photographic Materials”, *J. Opt. Soc. Amer.* **45** 799-808 (1955)
- [12] Doi K, “Scans in Measuring Wiener Spectra for Photographic Granularity”, *Japan. J. appl. Phys.* **5(12)** 1213-1216 (1966)
- [13] Dainty JC, Shaw R, *Image Science*, Academic Press (1974)
- [14] 内田勝, 金森仁志, 稲津博, *放射線画像情報学*, 日本放射線技術学会(1980)
- [15] 國友博史, “ディジタル画像データの物理特性の基礎”, 日放技学誌 **65(8)** 1085-1093 (2009)
- [16] 西丸英治, 市川勝弘, 原孝則, 他, “逐次近似法を応用した CT 画像の新しい Noise Power Spectrum 測定方法の検討”, 日放技学誌 **68(12)** 1637-1643 (2012)
- [17] 西木雅行, “動画像の画質評価 総論”, 画像通信 **44(1)** 1-9 (2021)

MR guided online adaptive radiotherapy 海外研究動向

- 画像系の研究を中心に -

エレクタ株式会社リサーチフィジックス 依田 潔

1. はじめに

MR guided online adaptive radiotherapy (MRgOART) は、MR 画像を用いてオンラインで日々の腫瘍や注意臓器の位置、形状を基に治療計画を毎回立案しながら、注意臓器の有害事象を増やすことなく、その日の腫瘍と注意臓器の距離に応じて、腫瘍線量をできるだけ増加させる放射線治療を指すことが多い。通常のリニアックの場合、コーンビーム CT 画像で十分なコントラストがつかない場合は、adaptive radiotherapy は難しいが、例えば 1.5 T の MR 画像を用いると最小 2 mm 程度のリンパ節も観測できるため、精密な放射線治療が可能になると言われている¹⁾。MR 画像座標系とリニアック座標系がずれるリスクがあると精密な治療が難しくなるため、MR 装置とリニアック装置を一体化した装置 MR linac を使うことが望ましい。本解説では、主として 1.5 T MR と 7 MV リニアックを一体化した装置である Elekta 社の MR linac Unity (Fig. 1) に関する海外の研究動向、特に画像系の研究を紹介する。




Fig. 1 1.5 T MRI linac の構造²⁾

2. 3D シネイメーシング技術

2D シネイメーシングは、すでに広く普及しており、同一時間当たりの画像の S/N が最も高いとされる balanced SSFP シーケンスを用いて、例えば撮像周期 200 msec でスライス厚 5 mm、ピクセルサイズ 1.2 mm を達成している³⁾。オランダのユトレヒト大学医療センターでは、治療ビーム照射時間が 10 分を超える将来の超寡分割照射（分割回数 1-2 回など）を見据えて、照射中に腫瘍や注意臓器のベースラインシフトが生じて、最小のマージンを維持できるように、照射中の実時間治療計画アルゴリズムを研究してい

る。3次元MRイメージング、輪郭抽出、線量最適化などの実時間処理が必要になるが、いずれも簡単ではない。最近、ユトレヒトから提案された実時間3次元イメージング⁴⁾について、そのアイデアを説明する。あらかじめ、参照用の3次元画像を取得し、次にその各ボクセルの移動ベクトルを反復計算することにより、4次元画像データを求める。特徴的なことは、移動ベクトル $\mathbf{d}$ をMRの時間領域の信号 s から推定したことである。フーリエ変換によるイメージングでは、スピン密度 $\rho(\mathbf{r})$ のフーリエ変換で時間領域の信号 s が得られる。 $\rho(\mathbf{r})$ の各ボクセルがベクトル $\mathbf{d}(\mathbf{r})$ だけ移動した $\rho(\mathbf{r}+\mathbf{d})$ に対する時間領域の信号はフーリエ変換で定式化できるが、その逆変換を解析的に解くことはできない。そこで、各臓器は移動のみで圧縮・拡大しないという正則化条件を課して、反復計算で逆問題を解く手法が提案された⁴⁾。その性能評価結果を静的な図で説明することは難しいので、興味ある読者は是非論文の supporting information としてアップロードされた動画を見ていただきたい。この方法の利点は、画像再構成が不要になるため、3次元MRイメージングを超高速度で実現できることである。論文によれば、毎秒8フレーム程度で3次元移動ベクトルを計算できたようである。まだ、使用しているハードウェア、ソフトウェアの制約があり、システム全体の実時間演算には至っていないが、今後は、GPU, deep learning も適用して、実時間処理を実現する計画で⁴⁾、今後の研究の発展が期待される。

3. Automatic Gating における画像処理技術

米国ウィスコンシン医科大学の研究者は、エレクトラ社と共同で、サジタル、コロナルの2方向の2Dシネ画像と参照3次元画像のテンプレートマッチングにより腫瘍の平行移動量を計算し、3次元の呼吸性移動を伴う腫瘍のゲーティング照射を実現するための研究を推進している³⁾。このアイデアのポイントは実時間で得られる画像はスライス画像であるが、スライド画像では、そのスライス面に直交する方向の呼吸性移動量を把握できないので、直交2方向のスライス画像を用いると共に、そのスライス画像内の腫瘍の3次元座標を治療計画用の参照3次元画像とのマッチングで実時間検出する点にある。本論文では、位置決め誤差の標準偏差はファントムで 0.6 mm、ボランティアによる脾臓・肝臓については、2.1 mm と記述されている³⁾。なお、今年の AAPM の抄録には、脾臓、腎臓の主要なデータに対して、位置決め誤差の標準偏差とレンジが SI, LR, AP 方向に対してそれぞれ 1.08 mm (0.31-1.9 mm), 1.07 mm (0.33-1.68 mm), and 0.76 mm (0.37-1.24 mm) と報告されている⁵⁾。3次元の呼吸性移動を伴う腫瘍のゲーティング照射が実現すれば、照射マージンを大幅に低減できるため、従来と同じ注意臓器に対する線量制約の下で、腫瘍線量を増大可能になる。最近、呼吸性移動の有無にかかわらず、BED10 ($\alpha/\beta=10$ を仮定した場合の生物学的等価線量) を 100 Gy 以上とすれば、生存率が向上するという臨床試験結果が多数報告されている。

4. MR 機能イメージング技術

昨年の ESTRO で、高リスク前立腺がんに対する GTV(gross target volume)ブースト照射により、5年後の生化学的再発率が 15%から 8%に減少したという画期的な臨床試験結果 FLAME trial が報告され、すぐに論文も出版された⁶⁾。前立腺の GTV 定義には、マルチパラメトリック MRI が用いられたが、その中の1つは ADC(Apparent Diffusion Coefficient)である。ADC は分割照射中の腫瘍の放射線応答と関連することが多くの論文で報告されているが⁷⁾、まだ十分確立した技術ではないと考えられている。そこで、Elekta Unity の施設間で、プロトコルを共通化しながら、毎回の治療セッション内で ADC map を取得し、データ

を蓄積する機運が高まっている⁸⁾。他方、悪性脳腫瘍に対して、CEST(chemical exchange saturation transfer)を始めとする分子イメージング技術を適用する研究がカナダの Sunnybrook 研究所で精力的に展開されている。彼らは従来不可能だと考えられていた 1.5 T の磁場で CEST 画像を得る特殊なシーケンスを開発し、MT(magnetization transfer)画像と組み合わせることにより、グリオブラストーマの放射線治療中の腫瘍応答をモニタリングする技術を開発中である⁹⁾。MR linac による治療時間は 30 分ないし 45 分であるため、そのセッション中に種々の機能画像を取得することが可能である。一連の治療コース内で、治療方針を患者ごとに最適化できる日を待ち望んでいる研究者は多い。

5. 少数転移に対する超寡分割照射

個々の少数転移をイメージングして GTV を定義し、1 回ないし 5 回の分割で定位照射することにより、良好な局所制御率が得られたことが報告されている¹⁰⁾。現在、日本では 5 個までの少数転移に対する体幹部定位照射が保険収載されているが、これは SABR-COMET trial¹¹⁾ の良好な試験成績を反映したものであると考えられる。Palma らは、すでに 10 個までの多発転移に対する SABR-COMET-10 のプロトコルを発表しており¹²⁾、いずれ成績が公表されることになろう。今後重要になることは、ADC map では検出しにくい小さい転移性腫瘍を位置決めする技術であろう。ここでは、これまで報告された 2 つの手法を紹介する。

(1) 超常磁性酸化鉄ナノ粒子による MR イメージング

超常磁性酸化鉄ナノ粒子(superparamagnetic iron oxide, SPIO)を静脈に注入すると、24 時間後に正常なリンパ節組織だけに移行することが報告されている¹³⁾。鉄のナノ粒子は MRI 信号を局所的に消失させるため、注入前後の MR 画像の差分演算で正常なリンパ節だけを画像化できるため、転移性リンパ節を位置決めできることになる。MRI 用肝臓造影剤(粒子径 57 nm)を皮下注射して、乳癌センチネルリンパ節転移診断に用いた論文が国内施設から出ている¹⁴⁾。静脈注射の場合は、粒子径 30 nm 以下のナノ粒子(ultrasmall superparamagnetic iron oxide, USPIO)の方が肝細胞への過度の集積がないこと、2014 年時点では国内未承認であることが報告されている¹⁵⁾。USPIO の国内承認状況、副作用に関する調査が望まれる。

(2) PET/MR と MR linac の組み合わせ

2 mm 程度のリンパ節に対する転移の有無を調べるために PET が使われるが、PET 座標をリニアック座標に正確にマッピングすることは難しい。そこで、オランダのユトレヒト大学医療センターは、MR/PET の PET 画像でリンパ節転移を検出し、一体化された MR 装置の座標系に変換後、MR linac の MR 画像と MR to MR の画像マッチングを実行することで、最終的に MR linac で小さいリンパ節転移を高精度照射する研究を推進している^{16,17)}。ユトレヒトの研究者は将来的には体幹部における初期のリンパ節転移、遠隔転移を高精度照射することを目指している¹⁶⁾。

6. まとめ

MRgOART に関する海外の研究動向、特に、画像系の研究について最近の動向を紹介した。この分野は今後大きく発展することは間違いない。国内でも MRgOART に関する画像系の研究が進むことが期待される。

参考文献

- 1) Winkel D, Werensteijn-Honingh AM, Kroon PS, et al. Individual lymph nodes: "See it and Zap it". Clin Transl Radiat Oncol. 2019;18:46-53. <https://doi.org/10.1016/j.ctro.2019.03.004>.
- 2) <https://indico.cern.ch/event/522875/contributions/2324914/>
- 3) Keiper TD, Tai A, Chen X, et al. Feasibility of real-time motion tracking using cine MRI during MR-guided radiation therapy for abdominal targets. Med Phys. 2020;47:3554-3566. <https://doi.org/10.1002/mp.14230>.
- 4) Huttinga NRF, Bruijnen T, van denBerg CAT, Sbrizzi A. Nonrigid 3D motion estimation at high temporal resolution from prospectively undersampled k-space data using low-rank MR-MOTUS. Magn Reson Med. 2021;85:2309-2326. <https://doi.org/10.1002/mrm.28562>
- 5) Jassarl H, Tail A, Chen X et al. Real-time motion tracking based on orthogonal cine MRI for abdominal tumors on 1.5T MR-linac, AAPM 2021 abstract <https://w4.aapm.org/meetings/2021AM/programInfo/programAbs.php?sid=9269&aid=57278>
- 6) Kerkmeijer LGW, Groen VH, Pos FJ, et al. Focal Boost to the Intraprostatic Tumor in External Beam Radiotherapy for Patients With Localized Prostate Cancer: Results From the FLAME Randomized Phase III Trial. J Clin Oncol. 2021;39:787-796. <https://doi.org/10.1200/JCO.20.02873>.
- 7) Romesser, PB, Tyagi, N, Crane, CH, Magnetic Resonance Imaging-Guided Adaptive Radiotherapy for Colorectal Liver Metastases. Cancers 2021, 13, 1636. <https://doi.org/10.3390/cancers13071636>
- 8) Kooreman ES, van Houdt PJ, Keesman R, et al. ADC measurements on the Unity MR-linac - A recommendation on behalf of the Elekta Unity MR-linac consortium. Radiother Oncol. 2020;153:106-113. <https://doi.org/10.1016/j.radonc.2020.09.046>.
- 9) Chan RW, Chen H, Myrehaug S, et al. Quantitative CEST and MT at 1.5T for monitoring treatment response in glioblastoma: early and late tumor progression during chemoradiation. J Neurooncol. 2021;151:267-278. <https://doi.org/10.1007/s11060-020-03661-y>.
- 10) Mercier C, Claessens M, Buys MSc A, et al. Stereotactic Ablative Radiation Therapy to All Lesions in Patients With Oligometastatic Cancers: A Phase 1 Dose-Escalation Trial. Int J Radiat Oncol Biol Phys. 2021;109:1195-1205. <https://doi.org/10.1016/j.ijrobp.2020.11.066>
- 11) Palma DA, Olson R, Harrow S, et al. Stereotactic Ablative Radiotherapy for the Comprehensive Treatment of Oligometastatic Cancers: Long-Term Results of the SABR-COMET Phase II Randomized Trial. J Clin Oncol. 2020;38:2830-2838. <https://doi.org/10.1200/JCO.20.00818>
- 12) Palma DA, Olson R, Harrow S, et al. Stereotactic ablative radiotherapy for the comprehensive treatment of 4-10 oligometastatic tumors (SABR-COMET-10): study protocol for a randomized phase III trial. BMC Cancer. 2019;19:816. <https://doi.org/10.1186/s12885-019-5977-6>.
- 13) Harisinghani MG, Barentsz J, Hahn PF, et al. Noninvasive detection of clinically occult

lymph-node metastases in prostate cancer. N Engl J Med. 2003;348:2491-9.

<https://doi.org/10.1056/NEJMoa022749>

- 14) Motomura K, Izumi T, Tateishi S, et al. Correlation between the area of high-signal intensity on SPIO-enhanced MR imaging and the pathologic size of sentinel node metastases in breast cancer patients with positive sentinel nodes. BMC Med Imaging. 2013;13:32.
<https://doi.org/10.1186/1471-2342-13-32>.
- 15) 齊藤元、水戸部一孝、南谷佳弘、磁性体を用いた癌診療、Drug Delivery System 2014;29, 304-314
<https://doi.org/10.2745/dds.29.304>
- 16) Andre S, Bart S, Beijst C, The design of an MR-PET for radiotherapy treatment simulation. The search for small tumour volumes, ESTRO 2020 abstract.
<https://www.estro.org/Congresses/ESTRO-2020/309/posterhighlights18ph-mriguidance/357/thedesignofanmr-petforradiotherapytreatmentsimulation>
- 17) Branderhorst W, Steensma BR, Beijst C, et al. Evaluation of the radiofrequency performance of a wide-bore 1.5 T positron emission tomography/magnetic resonance imaging body coil for radiotherapy planning. Phys Imaging Radiat Oncol. 2020;17:13-19.
<https://doi.org/10.1016/j.phro.2020.12.002>.

オンライン 医用画像処理プログラミングセミナー ～おうちで学ぶ初めてのディープラーニング～を受講して

JCHO 四日市羽津医療センター 放射線部 磯部 好孝

今回、画像部会で開催された「オンライン医用画像処理プログラミングセミナー～おうちで学ぶ初めてのディープラーニング～」に参加しました。この記事が今後、参加する方や参加を悩んでいる方に参考になればと思いながら報告させていただきます。

近年、身近な電化製品、放射線関連機器でもディープラーニングや人工知能(AI)についての記載をよく見ます。CT ではすでに装置に搭載されており画像処理、被曝低減技術に使われています。私自身のプログラミングに関する知識は乏しく、小学校のころMSXのパソコンでプログラムを組んで初歩的なゲームを作った経験くらいしかありません。「自分でもできるのでは?」「自分の中に眠っている可能性が何かあるのでは?」と微かな期待もあり、過去には本セミナーの参考書でもある「標準 医用画像のためのディープラーニング入門編」を購入し、独学で処理にチャレンジしましたが、本の通りに進まず挫折してしまっていました。今から思えば、本も詳しく書かれている手順を自己流で進めてしまっており、勝手に自分には合わないと思い込んでいたところがありました。そんなとき、技術学会の会誌で本セミナーの案内を見つけ、もう一度挑戦してみようと思いエントリーさせていただきました。

今回のプログラミングセミナーは画像識別、領域抽出といった処理をSONYのNeural Network Console(以下 NNC)を用いて体験できるものでした(図1)。事前準備として案内が届きました。案内には深層学習の基礎、NNC インストール、データベースの準備の手順の動画用 URL と QR コードが書いてありました。医用画像プログラミングセミナー接続テストの時間も設けられており、事前準備が大事だと思いました。わかりやすい説明の動画を見てインストールも順調にいました。ネット環境、PC のスペックについてのアンケートを記入し事前の接続テストに参加しました。接続テストでは顔合わせの様な感じで、当日の確認、質問なども受け付けていました。

当日 Web 開催ということでラフな服装でコーヒーを準備して参加しました。過去に参加した画像の物理評価の演習時には古いノート PC を持って会場まで行ったのですが、Web 開催だとノート PC よりも処理性能の高いデスクトップ PC が使えます。自宅にあるデスクトップ PC は 2 画面になっているのでセミナー当日の説明スライドを表示させ、もう片方の画面には Slack を表示させました。Slack は Microsoft Teams の様な使い方ができるビジネス用のメッセージングアプリです(図2)。Slack はグループでチャットもできます。事前に当日の連絡や当日わからないことがあればそこに書き込んでいました。初めて使ったのですが Slack で PDF 資料(図3)、画面のキャプチャも共有もできとても便利なアプリでした。インストールすれば使用経験がない人でも使える簡単なものでした。

演習では胸部 X 線画像の画像分類とセグメンテーションについて学習しました。説明をしてもらいながら進行していき、途中でうまくいかない時は発言をして止まってもらいました。どこで止まっているのかを伝えるため、自分の PC の表示画面をキャプチャして Slack で送り、何が原因で止まっているか確認してもらい、先生方から指示を仰ぎました。途中で実行を押した時に error の表示が出たときは、ダメだった。と悲しくなりましたが Slack では他の受講者も同じ error が表示されている様で、先生らの指示に従って確認し実行すると結果を出すことができました。お陰様で、参加者全員が全ての演習課題を終えることができました。講師の先生はもちろん、講師の先生以外からのバックアップがしっかりしているので、とても心強かったです。

予定のプログラム終了後にオンライン懇親会があり、希望者が参加できるようになっていました。懇親会では雑談も交えながら個々の感想が聞かれ、研究に関する質問もすることができました。普段聞くことができない講師の先生の話もあり、講師の先生を前に少し緊張しましたが貴重な時間でした。セミナー終了してから Slack の方でも受講者から感謝の言葉やどのように学習していくのがいいかなど質問がありました。その質問にも講師の先生が丁寧に返事を記入されていて今後の学習や研究を行っていくのに良いアドバイスを貰えたのではないかと思います。

私は頑張ってプログラムやネットワークを組んで実行ボタンを押し、結果が出た時の感動を味わってほしいです。色々なことを言い訳にして挑戦してこなかった人がいたら一度、参加をしてもらいたいです。挑戦し結果がでれば次もやってみようと思いが湧いてきます。成長していけます。楽しくなります。挫折してしまったらまた専門の先生、成功している人に聞けば教えてくれます。今後は放射線科の学校でもプログラミングが必須になってくるのではないのでしょうか。学んでこなかった卒業生も学ぶいい機会が今回の様に今後もあると思います。年齢とともに今さら頑張って無理と思う事もあるかもしれませんが年齢等も関係ないです。カーネル・サンダースが成功したのは 65 歳。ミュージシャンのスクヤットマン・ジョンが歌手としてメジャーデビューしたのは 52 歳です。今私は 44 歳ですが頑張ってみようと思っています。年齢を理由に頑張ることをあきらめる必要はないと思います。

主催者の先生方は事前準備、企画など大変お世話になりました。今後ともよろしくお願いします。今後もこの様なセミナーが続くことを祈っております。

オンライン 医用画像処理プログラミングセミナー [Ⓔ]	
～おうちで学ぶ初めてのディープラーニング～ [Ⓔ]	
	[Ⓔ]
9:45	Webex 接続開始 [Ⓔ]
10:00	開会 [Ⓔ]
10:10	講師、受講者 自己紹介 [Ⓔ]
10:30	NNC の概要説明 [Ⓔ]
11:00	講義 ディープラーニングの研究方法論 [Ⓔ]
11:30	昼食 [Ⓔ]
12:30	演習1 胸部 X 線画像の向きを自動検出 [Ⓔ]
13:40	演習2 セグメンテーション [Ⓔ]
15:00	閉会 [Ⓔ]

図1 セミナーのプログラム



図2 Slack

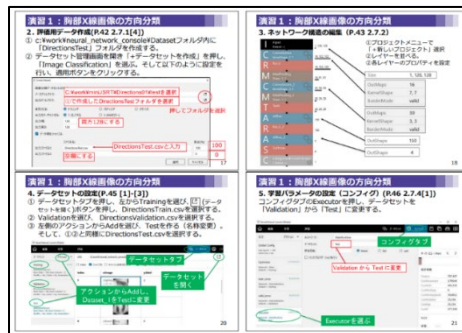


図3 配布資料

オンライン 医用画像処理プログラミングセミナー ～おうちで学ぶ初めてのディープラーニング～を受講して

岡崎市民病院 医療技術局 放射線室 尾木 洋之

今や誰もが至る所で耳にしているであろう「AI」や「人工知能」という言葉。東京 2020 オリンピック・パラリンピックに於いてもそれらの最新技術が随所で駆使されているそうです。（開会式のピクトグラムパフォーマンスは大分アナログでしたが。）私は以前よりこの分野に興味があり「自分でもやってみたい」と思っていました。書店に足を運べば非常に多くの関連書籍が並んでいるので独学で習得しようと今迄幾度も挑戦してきました。ところがいざ始めると初学者の私にとっては困惑することばかり。書籍も多過ぎて内容も多岐に渡り、インターネットで検索すれば大量の情報が溢れ、どれが今の自分に適したものかさえよく分かりません。数学的理論やプログラミング言語の理解にも難渋するし、なんとかプログラムを実行してみるものの思い通りに走らず、呆気無くエラーに跳ね返される等、幾つもの壁に阻まれるうちに「興味<苦難」の不等式が成立し、典型的な挫折に至るという過程を何度も繰り返してきました。情けないの一言ですが、この様な状況に陥っているのは私だけではないのではないのでしょうか。

日本放射線技術学会の学術大会プログラム等に於いてプログラミングセミナーの存在は以前から知っていましたが、なかなか抽選に当たらず受講出来ずにいましたが、今回、幸運にも受講の機会を頂くことが出来ました。定員が大変少ないのですが、実際に受講してみるとそれも領ける内容です。先ずセミナーに先立って受講者には講義動画が配布され、自分のペースで事前学習をすることが出来ます。当日は SONY の Neural Network Console (NNC) を使用するのですが、アプリケーションのインストールやサンプルデータの準備等の手順についても大変分かりやすく解説されています。またオンライン開催ということもあり、Web 会議システムの接続トラブルで当日困ることの無いように、接続テストまで講師の先生方がわざわざ前もって実施して下さいました。この様にハードもソフトも脳内も事前準備バッチリの状態でいざ当日を迎えます。

セミナーは午前中にディープラーニングの研究方法論に関する講義を受け、午後にハンズオンというプログラムでした。ハンズオンでは上述の NNC を用いて胸部 X 線画像の方向分類とセグメンテーションを、受講者各自が自宅の PC で自らの手で体験しました。「プログラミング」という単語がセミナータイトルに入っていますが、一からプログラムを一字一句記述するというものではなく、予め用意されているオブジェクトを組み合わせでディープラーニングの過程を構築し、各パラメータを適宜調整するというものでした。Web ページで言えば HTML や CSS を直接打ち込むのではなく、コードを意識せずに作成出来るアプリケーションを使うようなイメージです。Web 会議システムで講師の先生がリアルタイムに一つ一つのステップを分かりやすく指示して下さい、全員がディープラーニングを完遂することが出来ました。

私は途中でミスをしておりプログラムがエラーで止まってしまい、原因が分からず一時困ったのですが、講師の先生は決して置いてけぼりにすることなく、丁寧にアドバイスして下さいました。会場でのハンズオンセミナーと違い、オンラインでは各受講者のPC画面を個々に見ることが出来ない為、状況把握は大変だったと思います。

ディープラーニングを自分の手で実行出来た瞬間はまさに感動的でした。初学者でない方にとってはNNCでは恐らく物足りないと思いますが、私の様な悩める初学者にとって、本セミナーは階段を一つ上がる為に背中を押してくれる救いの手となりました。この初速度が減衰しないうちに更なるステップアップへと繋げていきたいです。

セミナープログラムには明記されていませんでしたが、セミナー終了後にオンライン懇親会の時間を設けて下さいました。講師の先生方を含むセミナースタッフの方々、そして全国各地の受講者と自由に話すことが出来、実空間ではかなり離れているのに各々がとても身近に感じましたし、自分の居場所が自宅ということもあり、初対面の緊張感+away感と自宅に居るリラックス感+home感とが混在した不思議な感覚のひとつでした。自由参加ではありましたが、オンラインセミナーでは受講者間の繋がりは希薄なことが多いので、稀有な機会であり非常に楽しかったです。

この様に本セミナーは受講前からセミナー終了まで懇切丁寧な指導を受けることが出来る大変有意義なセミナーであり、この分野に興味をお持ちの方には是非お勧めします。テキストとして用いたシリーズ書籍の様に、セミナーについてもシリーズ化を期待してしまうのは私だけでしょうか。

最後に、本セミナーを開催するにあたり大変な御苦労が有ったと思いますが、講師の先生方をはじめ、企画・運営して頂いた皆様、サポートして下さいました学生の方々に心より御礼申し上げます。

医用画像で用いられている画像処理

聖マリアンナ医科大学病院 画像センター 田沼 隆夫

1. はじめに

良質な画像を医師に提供することは、正確な診断、治療につながる。現在、医用画像の多くはデジタル化されており、画像処理は欠かせない存在である。ユーザーが画像処理の原理や特徴を理解することは、画質改善による診断価値の向上、または被ばく低減につながる。本稿では、主に単純 X 線画像に用いられている基本的な画像処理と、近年多くの施設で導入されている散乱線補正処理など、実臨床で使われている画像処理を紹介するとともに、ユーザーの注意点などを示す。また今後の動向として、Deep Learning を用いたノイズ低減処理について簡単に紹介する。

2. 医用画像の画像処理

2.1 鮮鋭化処理

画像のボケが強い時、構造物の輪郭（エッジ）をはっきり見えるように改善したいと考える。鮮鋭化処理は画像のエッジ部分を調整し、強調するパラメータである。単純 X 線画像では、計算量が比較的少なく高速な表示が可能なボケマスク処理が頻繁に使われている。また、多くの医用画像処理の基本となっており、ここを理解すると全体の理解も早い。ボケマスク処理の原理を図 1 に示す⁽¹⁾。① 近傍画素との平均化による平滑化処理でボケ像（Sus）の作成、② 原画像（Sorg）とボケ像を減算することでエッジ画像（Sorg-Sus）の作成、③ エッジ画像と原画像を加算することでエッジが強調される。





図1 ボケマスク処理の原理

FCR 画像処理解説書 第4章画像処理(周波数処理) 図4.2 より転載

2. 2 ダイナミックレンジ圧縮処理 (Dynamic Range : DR 圧縮処理)

黒すぎて (白すぎて) 見にくい部分がある場合, 黒い部分は白めに, 白い部分は黒めに調整したいと考える. DR 圧縮処理はそのような黒つぶれや白抜けを補い, 広い診断可視領域を表現するためのパラメータである. DR 圧縮処理の原理を図 2 に示す⁽²⁾. ① 原画像(a)を平滑化処理し, ボケ画像(b)の作成, ② 低濃度, または高濃度を圧縮する関数(c), (d)をボケ画像(b)にかけることで, 補正係数 $f(S_{us}(x, y))$ の取得, ③ $f(S_{us}(x, y))$ を原画像に加算することで, 低濃度が圧縮された画像(e), または高濃度が圧縮された画像(f), が得られる.



$$S_D(x, y) = S_{org}(x, y) + f(S_{us}(x, y))$$

$S_D(x, y)$: DR 圧縮処理後の画像

$S_{org}(x, y)$: 原画像

$S_{us}(x, y)$: マスクサイズの範囲で平均化された画像

$f(S_{us}(x, y))$: S_{us} に依存した補正係数

図 2 DR 圧縮処理の原理

医療科学社 医用画像情報学 3.1.2 ダイナミックレンジ圧縮処理 数式(1) 図 3 より転載

一方で, DR 圧縮処理を強くかけすぎると, 白い部分の低濃度圧縮では黒くなり, 黒い部分の高濃度では最高濃度が下がってしまうこともあるため, ユーザーは注意が必要である.

2. 3 マルチ周波数処理

2.1 の鮮鋭化処理は単一のボケマスクを用いて特定の周波数領域を強調するため, アンダーシュートなどのアーチファクトで違和感が生じやすい欠点がある. そこで, より自然にバランスの良い画像にしたいと考える. 複数の周波数領域をそれぞれ強調し, より自然な画像作成を可能にしたのがマルチ周波数処理である. 富士フィルムのマルチ周波数処理は, 式 1 で表されるように周波数強調処理と DR 圧縮処理を統合した画像処理であるが, ここでは周波数強調処理を扱う.

$$S_{proc} = S_{org} + \beta(S_{org}) \times \sum_{m=0} f_m(SB_m) + D(S_{org} - \sum_{m=0} g_m(SB_m))$$

周波数強調機能

DR圧縮機能

S_{org} : 原画像
 S_{proc} : 処理画像
 $\beta()$: 濃度依存強調関数
 $D()$: DR圧縮フィルタ関数
 $f_m()$: 周波数強調用非線形関数
 $g_m()$: DR圧縮用非線形関数
 SB_m : 差分画像 ($SB_m = Sus_m - Sus_{m+1}$: バンドパス信号)
 Sus_m : 空間周波数特性の異なる平滑化画像 (但し、 $Sus_0 = S_{org}$: 原画像)
 M : 利用する平滑化画像の数

式1 マルチ周波数処理の式

FCR 画像処理解説書 第4章 画像処理(マルチ周波数処理) 4.5.6 画像処理の流れ より転載

マルチ周波数処理（周波数強調処理）の原理を図4に示す⁽³⁾。① 重みづけ平均（マスクサイズの異なった平滑化処理）によりボケ画像を複数作成（図4左下）、② 差分し、各周波数帯からなるバンドパス信号を抽出（図4右下）、③ 複数の周波数領域をそれぞれ強調し、加算画像の取得、④ 加算画像をさらに原画像に加算することで、低周波成分から高周波成分までバランスの取れた強調ができる。




図4 マルチ周波数処理のブロック図と平滑化信号のレスポンス

FCR 画像処理解説書 第4章 画像処理 (マルチ周波数処理) 図4.9 4.11 4.12 より転載

一方で、過度な強調により衣類のシワやズボンのゴムなどの体外構造物が目立つこともあるため、画像処理強度の調整や更衣の基準を見直すなど、ユーザーは注意が必要である。

2. 4 ノイズ低減処理

粒状性の悪い画像に対してノイズの影響を少なくしたいと考える。一般的な平滑化処理でも一定の効果はあるが、同時に信号のレスポンスも低下してしまう。信号の低下をできる限り抑制し、粒状を改善するのがノイズ低減処理（Flexible Noise Control(FNC)：富士フィルム）である。

ノイズ低減処理の原理を図 5 に示す⁽⁴⁾。①複数の平滑化画像 Sus_n から差分画像 ($Sus_{n-1} - Sus_n$) を作成，② 差分画像にノイズ成分抽出処理 $F(Sus_{n-1} - Sus_n)$ を施し，周波数帯域ごとのノイズ成分を抽出，③ ノイズ成分を加算し，原画像 $Sorg$ と差分することで，ノイズ低減処理画像 $Sproc$ を得る。

$$Sproc = Sorg - \beta \times \sum_{n=1}^N \{ \alpha_n \times F(Sus_{n-1} - Sus_n) \} \quad \text{式1}$$

ここで、 $Sorg$: 原画像、 Sus_n : 平滑化画像、 $F()$: ノイズ成分抽出処理、 α_n : 周波数依存係数(0.0～1.0)、 β : 濃度依存係数(0.0～1.0)である。 n は平滑化レベルである。




図 5 FNC の流れ

FCR 画像処理解説書Ⅱ 第 1 章ノイズ抑制処理 FNC 図 1 より転載

一方で、ノイズ低減処理は線量や他の画像処理によって効果が変化するため、単体で調整せずに他の画像処理と並行して検討すべきである。また、最近のノイズ低減処理はより複雑なパターンも認識でき、人体構造の消失は少ないと言われているが、過信は禁物である。処理の強度にもよるが、『3.Deep Learning を用いたノイズ低減処理』に示すように、原画像とノイズ低減処理後の画像を減算すると、わずかにエッジ部分が視認される。つまりノイズ低減以外の変化があると考えられ、ユーザーは注意が必要である。

2. 5 散乱線補正処理

ポータブルなどでグリッドレス撮影した画像に対し、画質も担保したいと考える。散乱線による画質の劣化が懸念されるが、これを画像処理で補うのが散乱線補正処理である。富士フィルムの散乱線補正処理（Virtual Grid : VG）の原理を図 6 に示す⁽⁵⁾。① 散乱線算出処理と ② グリッド効果算出処理で画像コントラスト改善を、③ 粒状改善処理でノイズ低減をすることで、散乱線による画質の劣化を補っている。




図6 VG技術 上：プロセスのフロー 左下：被写体厚の推定 右下：グリッド効果の算出
新画像処理「Virtual Grid 技術の開発」:X線検査の画質と作業性の向上 Fig.4,5,6 より転載

一方で、条件次第では処理がうまくいかないこともある。例えば、撮影時の距離が設定した焦点-受像器間距離よりも短い場合、ディテクタが受け取るX線はVGの想定よりも多くなるため、体厚が薄いと判断してコントラストは低くなる。VG設定と撮影条件などの乖離に、ユーザーは注意が必要である。

3. Deep Learning を用いたノイズ低減処理

海外の情報ではあるが、Deep Learning を用いたノイズ低減処理 (Smart Noise Cancellation(SNC) : Carestream Health, Inc) が2021年5月にプレスリリースされた。SNCの原理を図7に示す⁽⁶⁾。① 原画像をU-Netを利用したモデルに入力してノイズ画像を作成、② 原画像からノイズ画像を減算することで、ノイズ低減画像を作成することができる。SNCの基本的な技術フローは従来型と同様であるが、原画像から減算するノイズ画像の作成方法が異なり、平滑化処理を用いていない。




図7 Deep Learning を用いたノイズ低減処理(SNC)の原理

平滑化画像を基本とした従来のノイズ低減処理と原画像を差分すると、わずかにエッジ部分が視認されるため、処理によってディテール部分が変化しているのかもしれない。一方で、SNCは図8に示すように差分画像にエッジ部分はほぼ視認できない。




図8 従来のノイズ画像と Deep Learning を用いたノイズ低減処理の違い

下図 Carestream Health, Inc, White Paper. Smart Noise Cancellation Processing より転載

4. おわりに

基本的な画像処理が理解できたら、次は実際に触ってみてほしい。パラメータを動かし、画像がどのように変化するか体感することで、さらに理解が深まるであろう。ただし、『きれいな画像』を作ることだけに注視してはならない。過度な画像処理によって原画像に含まれる診断に必要な情報が損なわれる可能性を、我々ユーザーは意識すべきである。また、画像処理はあくまでも視認性を改善するための道具であり、原画像に『情報としてないもの』は改善できない。どんなに画像処理が良くなったとしても、撮影条件やポジショニングなど、基本的な撮影技術が重要なのは今も（恐らく未来も）変わらないのである。

参考文献

- (1) 富士フイルム株式会社. FCR 画像処理解説書, 第4章 画像処理(周波数処理). 2013 : 32-34.
- (2) 星野修平, 関根紀夫, 乳井嘉之, 他. 医用画像情報学, 第2章 画像 3.画像処理 3.1.2 ダイナミックレンジ圧縮処理. 医療科学社, 東京. 2010 : 77-79.
- (3) 富士フイルム株式会社. FCR 画像処理解説書, 第4章 画像処理(マルチ周波数処理). 2013 : 40-44.
- (4) 富士フイルム株式会社(発行). FCR 画像処理解説書Ⅱ(第1版 第1刷), 第1章 ノイズ抑制処理 FNC 2 FNC の原理. 2013 : 1-6.
- (5) 川村 隆宏, 内藤 慧, 岡野 佳代, 他. 新画像処理「Virtual Grid(バーチャルグリッド)技術」の開発 : X線検査の画質と作業性の向上. FUJIFILM RESEACH & DEVELOPMENT. 2015 ; No.60.
- (6) Karin Toepfer, Lori Barski, Jim Sehnert, et al. Smart Noise Cancellation Processing: New Level of Clarity in Digital Radiography. Carestream Health, Inc, White Paper.
http://www.carestreamblog.com/blog/wp-content/uploads/2021/05/white_paper_smart_noise_cancellation_ltr_lowres_202104.pdf(2021-8-26)

圧縮センシングの基礎

広島国際大学 保健医療学部 診療放射線学科 大倉 保彦

1. はじめに

観測データ数が標本化定理で得られるよりも少ない場合、一般には元の信号を復元できない。しかし、元の信号の性質を利用することで、復元が可能なのではないか。これを実現する技術のひとつが圧縮センシングとよばれる技術である。本稿では圧縮センシングの基礎として、簡単な例を示しながら解説を試みる。

2. 圧縮センシングの基礎

圧縮センシングを簡単にいえば、「もし元の信号がほとんど 0 であるなら、元の信号が推定できる」といえる。「ほとんど 0(ゼロ)」という状況を意味する単語の「スパース(sparse)」を用いて、これはスパース性とよばれる性質である。また、圧縮センシングは「スパースモデリング」とよばれる領域の技術である。元の信号を復元する再構成技術とあわせて、不足した観測データから元の信号を高い確度で得ることができる。

ここで、圧縮センシングを用いた方法で、簡単な例を解いてみる。つぎの式があるとする。

$$2x_1 + x_2 = 1$$

式は 1 つ、求める変数は 2 つなので、解は不定である。劣決定系とよばれる系である。当然ながら、このままでは解を一意に得ることはできない。式を満たすあらゆる x_1 と x_2 の組合せはすべて解となる。そこで、「解はスパースである」という性質を利用することにする。すなわち、ほとんど 0 である、とする。ここでは、変数は 2 つなので、どちらかが 0 のとき、スパースであるとする。スパース性が高いとき、解のベクトル（ここでは、 x_1 、 x_2 ）の大きさが小さくなるはずである。ベクトルの大きさをあらわす値として、 L_1 ノルムをつかうことにする。 L_1 ノルムとは、ベクトルの要素の絶対値の和である。すなわち、 L_1 ノルムは次の式で表すことができる。


元の式を変形して、 L_1 ノルムは、
$$\|x\|_1 = |x_1| + |x_2|$$

となる。
$$\|x\|_1 = |x_1| + |-2x_1 + 1|$$


絶対値記号をはずすために、場合分けをすると、

$$\begin{cases} 3x_1 - 1 & \frac{1}{2} \leq x_1 \\ -x_1 + 1 & 0 \leq x_1 < \frac{1}{2} \\ -3x_1 + 1 & x_1 \leq 0 \end{cases}$$

となるので、 L_1 ノルムをグラフに描くと次のようになる。



最小値は(0.5, 0)、すなわち $x_1=0.5$, $x_2=0$ となり、めでたくスパースな解が得られることになる。 L_1 ノルムの単位球とともにグラフに描くと、



となり、 L_1 ノルムに接する点である(0.5, 0)が、解として選ばれていることがわかる。

実際に観測され得られるデータは高次元（画像データであれば 256×256 次元など）であるので、多くの変数を設定し、圧縮センシングの技術を使ってもとの信号を復元するには「再構成アルゴリズム」とよばれるテクニックが必要である。FISTA(Fast Iterative Shrinkage Thresholding Algorithm)や、Bregman 反復法(Bregman iterative method)などがある。詳細は当日会場にて補足する。

参考文献

- [1] 酒井智弥, 圧縮センシングの基礎原理と画像再構成アルゴリズムの進歩, Medical Imaging Technology, Vol.34, No.4, September, 2016
- [2] 町田好男, 森一生, MRI 高速撮像の進展～画像化の原理から圧縮センシングまで, 医用画像情報学会雑誌, Vol.30, No.1, p7-11, 2013
- [3] Michael Lustig, David Donoho, John M. Pauly, Sparse MRI: The Application of Compressed Sensing for Rapid MR Imaging, Magnetic Resonance in Medicine 58:p.1182-1195, 2007

つくば国際大学 医療保健学部 診療放射線学科 および柳田研究室の紹介

つくば国際大学 医療保健学部 診療放射線学科 柳田 智

1. つくば国際大学について

つくば国際大学は、1994年に学校法人霞ヶ浦学園によって茨城県土浦市に開学された私立大学です。つくば国際大学のある土浦市は、東に琵琶湖に次いで2番目に大きい湖である霞ヶ浦、西には万葉の世から名峰と謳われた筑波山を望む、水と緑に恵まれた中核都市です（図1）。土浦市には多くの観光名所があり、毎年10月には日本三大花火の一つともいわれ、大正14年から続く土浦全国花火競技会があります。また、土浦市は自転車の町でもあり、市内にはサイクリングロードが整備されています。このような自然豊かな土浦市の中で、四季折々の筑波山の様子を近くに見ることができるような環境につくば国際大学のキャンパスはあります。現在では理学療法士、看護師、保健師、管理栄養士、栄養士、診療放射線技師、臨床検査技師、臨床工学技士など保健・医療分野で活躍できるスペシャリストを養成する1学部6学科を有する大学です。

2. 診療放射線学科について

診療放射線学科は2013年に新たに開




図1：つくば国際大学と筑波山、霞ヶ浦の位置
(Google Map より)



写真1：診療放射線学科棟



**写真 2 : 3 階まで吹き抜けのエントランス
と木目調と白壁の廊下**

設された学科で、まだ卒業生を 4 期生しか輩出してない新しい学科です。診療放射線学科の学び舎である診療放射線学科棟は第一キャンパスに位置します。正面から見た学科棟は、ガラス張りの特徴的なエントランスで、採光の良い透明感のあふれる 3 階建ての校舎になっています。学科棟の正面入り口の自動ドアを通ると 3 階まで吹き抜けとなっており、とても明るく開放的な空間になっています。廊下は木目のデザインになっており、白地の壁と合わせて清潔感あふれる作りになっています（写真 2）。1 階には放射線治療計画実習室、超音波検査実習室、無散瞳眼底検査実習室、画像情報学習室、X 線撮影実習室があります。2 階には 4 部屋の講義室と理工学・基礎医学実習室と PC コーナーがあり、3 階には 4 部屋の講義室と基礎科学実習室と PC コーナーがあります。1 階の X 線撮影実習室には、乳房 X 線撮影装置、一般撮影 X 線装置、X 線 TV 装置、X 線



**写真 3 : 間接変換方式フラットパネルディテクタ
Canon CXDI70CWireless**



写真 4 : 斬新的なフォルムの MRI 棟



**写真 5 : 1.5T MRI 装置
PHILIPS Ingenia Prodiva**

CT 装置を備えております。昨年には、乳房撮影の読影力を養うために 5M ピクセルの高精細医用モニタを備えたビューを 5 セット、高感度の蛍光体である CsI:Tl を使った最新の間接変換方式フラットパネルディテクタを導入しました（写真 3）。さらには、診療放射線学科棟とは別棟に斬新的なフォルムの MRI 棟が建設され 1.5T の MRI 装置を導入し、学内で行える実習の幅が広がりました（写真 4, 5）。

診療放射線学科の学生は 2021 年 9 月現在 435 名が在籍しており、出身は茨城県を中心に関東から東北圏が多いのですが、その他にも日本全国各地の出身の学生が在籍しています。専任の教員は 21 名（教授：8 名、准教授：5 名、講師：4 名、助教：2 名、助手：2 名）います。本学科のひとつの特徴として、臨床経験が豊富な専任教員が多く、診療放射線技師または医師のライセンスを持った教員が 16 名在籍し臨床に沿ったきめ細かい教育が行われています。

3. 柳田研究室の紹介

本学では、すべての 4 年生が国家試験対策と卒業研究（選択）を兼ねて、研究室に配属されています。柳田研究室では、FPD を使った研究で主に卒業研究を行っております。過去には「FPD の最適キャリブレーション方法についての研究」などをテーマにした研究を行って来ました。昨年度は残念ながらコロナ禍の影響により、卒業研究を行うことを断念せざるえ

ない状況におかれましたが、今年度は 7 名の 4 年生が研究室に在籍しており、全員が卒業研究に取り組んでおります。今年度の研究テーマは、「異なる蛍光体物質の間接変換方式 FPD における物理特性の比較」、「円背被写体の胸部正面 X 線撮影における線量指標値の変動」、「標準体型における DRLs2020 と EI の関係」、「ワイヤレス FPD の接続方式の違いによる X 線曝射ディレイタイムの研究」、「後方散乱線が持つ特性から遮蔽材に必要な条件の検討」などさまざまなテーマで、研究に取り組んでいます。コロナ禍で学内への立ち入りが禁止されている中でも、オンラインで研究室内検討会を行い卒業研究発表会に向けた準備を進めています（写真 6）。さらには、すべての研究テーマを 2021 年 11 月 27 日～28 日に神奈川県横浜市にて開催される日本放射線技術学会第 68 回関東支部研究発表大会にエントリーして、研究発表に備えております。国家試験対策に関しても、オンラインにより研究室内で協力し合って進めております。




写真 6：柳田研究室 オンライン卒業研究発表検討会の様子

4. 最後に

つくば国際大学医療保健学部診療放射線学科は、まだまだ歴史の浅い診療放射線技師の養成校です。卒業生の中には大学院を目指す学生もおりますので、他大学の先生方に於かれましてはご支援、ご配慮のほどをよろしくお願い申し上げます。また、卒業後は臨床現場や企業で活躍できるような技師を育成できるよう努力してまいります。学生には、診療放射線技師は生涯研鑽が必要であると指導しております。卒業生が数多く日本放射線技術学会や海外学会で学会発表や論文発表をすることを願っております。

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。

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】 腫瘍陰影像 154 画像, 非腫瘍陰影像 93 画像
1 画像容量約 8MB, Dicom データ, 2048 x 2048 マトリクス,
0.175mm ピクセルサイズ, 4096(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. Imag: 7, *J Dig Imag*: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

画像部会入会のご案内

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

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

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

【入会資格】 日本放射線技術学会の会員 であること。

【入会方法】 Web 上 (<https://www.jsrt.or.jp/data/procedure/bunka-01/>) から、お申し込み下さい。

【年会費と会員特典について】

1. 専門部会の会員登録システムと年会費の変更について

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

す。例えば、画像部会、撮影部会、計測部会の3つに登録する場合、これまでは $2,000 \text{ 円} \times 3 = 6,000 \text{ 円}$ でしたが、2015 年度より $2,000 \text{ 円} + 1,000 \text{ 円} \times 2 = 4,000 \text{ 円}$ 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

通常であれば、オリンピック中心に記載にしたいところであるが、このビックイベントを打ち消す勢いで感染が拡大している。「With コロナ」と言われて久しくなり、あまり聞かないワードとなった。それは、残念ながら、すでに我々自身の生活において Covid-19 が簡単に切り離せなくなったことを意味しているように思う。Covid-19 により我々の生活は大きく制限されたのであるが、逆に以前は懸念していたWEBを使用した会議・講演など、今では何の心配もなく実施することができる。このように不便の中で新たに発展する分野があり、正にイノベーションを感じる期間でもあった。

筆者としては教育を生業にしているが、教育現場もまた、オンライン授業やストリーミング配信など新たなツールの導入で、対面授業の補完に余りある知識の提供が可能となった。しかし、やはり教育における知識の提供は、その息遣いと情熱を肌で伝え、コミュニケーションを行う事が必要であると痛感している。松下幸之助は「塩の辛さ、砂糖の甘さは学問では理解できない だが、なめてみればすぐ分かる」と述べており、教育は、知識だけでなく体験・経験のセッでなくてはいけない。小中高大学生の教育機会が少なくなっており、若者の教育機会の減少は社会全体の減退にもつながりかねない。我々大人も学習機会が減っており、学習することが億劫になる人も少なくない。しかし、私は、「大人は、知りたいという心さえあればどんなところでも学ぶことができ、学習こそが未来を引き開く切符になる！」と言うことを若者に示さなくてははいけない。

そんな学びの場の提供も学会として重要な役割であるため、会員の皆様のために多くのセミナー・講演会が企画されることを節に願っている。

(NS 記)

画像通信 Vol.44 No.2(通巻'87)

発行日 2021 年 10 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

通卷八七号

VOL. 44 No2
AUTUMN 2021