

Communication of the Imaging Group of the JSRT

# 画像通信

2024年4月

Vol.47 No.1(通巻 92)

## ☆ 教育講演

「Radiomics のためのエンジニアリング ～モデルの評価にまつわる話～」

東北大学病院 高屋 英知

## ☆ 第 95 回画像部会 『ピクセルから予後へ:臨床診断における Radiomics の革命』

1. 「臨床現場から見る個別化医療を見据えた医用画像の底力:Radiomics !」

山口大学医学部附属病院 椎木 健裕

2. 「がんの特徴を穴から見通す -トポロジー穴解析-」

九州大学大学院 有村 秀孝・児玉 拓巳

3. 「放射線診断医からみた Radiomics」

聖マリアンナ医科大学 原口 貴史

4. 「放射線治療医からみた Radiomics の有用性と今後の展望」

広島大学大学院 今野 伸樹

## ☆ 技術紹介

①「Radiomics 特徴計算ライブラリ:RadiomicsJ」

Visionary Imaging Services, Inc. 小林 達明

②「循環器領域における Spectral CT 7500 の有用性」

株式会社フィリップス・ジャパン 山口 優輝

## ☆ 読者のページ

①「第 44 回医用画像処理プログラミングセミナーを受講して」

金沢先進医学センター 武田 悟

②「オンライン 第 44 回医用画像処理プログラムセミナー ～PyTorch で深層学習入門～を受講して」

創聖健康保険組合診療所 遠藤 敦

③「第 24 回 DR セミナーを受講して」

秋田大学医学部附属病院 高橋 俊吾

④「第 24 回 DR セミナーを受講して」

日本赤十字社和歌山医療センター 野口 紫陽

☆ 専門部会講座(入門編):「胸部デュアルエネルギーサブトラクション(DES)法の原理と臨床での活用」

北里大学病院 関 将志

☆ 専門部会講座(入門編):「ROC 解析の理論と AUC による統計的検定」

鹿児島医療技術専門学校 馬場 祥吾

☆ 大学/研究室/研究会紹介:「関西乳房画像研究会」

大阪大学医学部附属病院 松澤 博明

☆ 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

☆ 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1回 日本放射線医療技術学術大会予告

日時：2024年10月31日(木)～11月3日(日)の第52回日本放射線技術学会秋季学術大会期間中  
会場：沖縄コンベンションセンター(予定)

## 画像部会関連企画

- JSRT 画像部会・JART 消化管画像分科会 合同企画  
テーマ：「透視検査における画質とノイズ低減技術の変遷～画像ノイズの理解と抑制～」(仮題)
- JSRT 撮影部会(一般分科会)・JSRT 画像部会・JART 骨間接撮影分科会 合同企画  
テーマ：「X線単純撮影の標準化を考える」(仮題)

## ROC セミナーの開催予定

第14回 ROC セミナー :2024年5月から6月(予定) 会場:オンライン実施

## 臨床画像評価セミナーの開催予定

第11回臨床画像評価セミナー :2024年未定 会場:国立がん研究センター中央病院(東京都築地)

## 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 :2023年9月8日(日) 会場:オンライン実施(予定)

## DR(デジタルラジオグラフィ)セミナーの開催予定

第25回 DR セミナー :2024年8月24日(土), 25日(日) 会場:久留米大学病院(予定)

## 画像部会委員 氏名・所属・電子メール

東出 了 (画像部会長)	鈴鹿医療科学大学保健衛生学部	raryo@suzuka-u.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
佐保 辰典	小倉記念病院	saho-t@kokurakinen.or.jp
篠原 範充	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
平原 大助	原田学園	rt.hirahara@harada-gakuen.ac.jp
山崎 明日美	大阪大学大学院	yamazaki-a@sahs.med.osaka-u.ac.jp
山崎 純	紀南病院	j_yamasaki@kinan-hp.tanabe.wakayama.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>

# Radiomics のためのエンジニアリング

## ～モデルの評価にまつわる話～

東北大学病院 高屋 英知

### 1. はじめに

Radiomics の分野では、医用画像から得られた様々な特徴量を解析することで疾患の診断や予後予測を試みる。このような解析において重要な役割を担うのは機械学習である。機械学習の初学者はそのアルゴリズムや実装方法に着目しがちであるが、特に重要と考えられるのは、「出来上がった機械学習モデルが本当に使えるものなのか」を適切に見積もるための評価方法である。本稿では、機械学習モデルの評価方法に焦点を当て、特に初心者が知っておくべきと思われる論点や、中・上級者であっても陥りがちな Leakage の問題について述べる。そして最後に、アカデミアに属する人間にとって避けることのできない論文執筆や査読時に気をつけるべき観点について議論する。

### 2. 機械学習モデルの評価方法

#### 2.1 ホールドアウト法、n 分割交差検証法

モデルの性能を評価する基本的な手法には、ホールドアウト法と n 分割交差検証法がある。ホールドアウト法では、データセットを訓練セットとテストセットに分割する（図 1）。そして、訓練セットで機械学習モデルのパラメータ調整すなわち学習を行い、テストセットで評価を行う。分割の割合は 8:2 や 9:1 などをよく見かけるが、データの総量などに応じて決めることが多い。

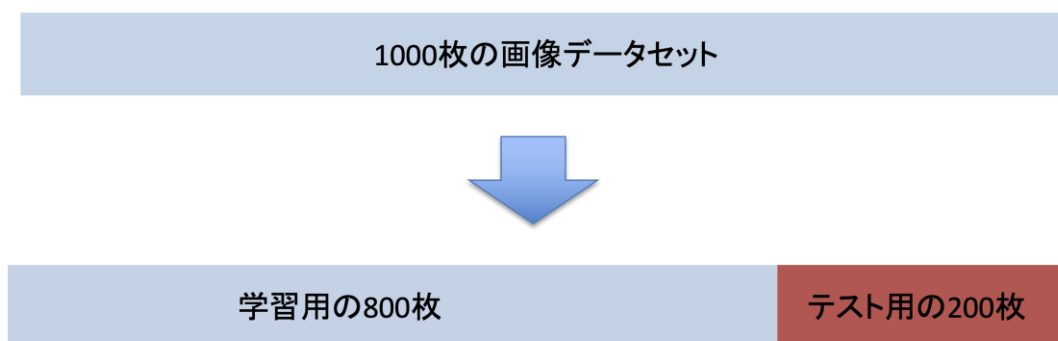


図 1 分割の例

n 分割交差検証法 (n-fold Cross validation) は、データセットを複数の小さなセットに分割し、それぞれのセットでモデルの学習と評価を行い、平均的な精度を確かめる方法である。特に利用可能なデータが少ない場合は、分割によって生まれるデータ分布の差に精度が左右されやすくなるため、複数の訓練とテストを繰り返すことで信頼性の高い結果を出すことができる。図 2 は 5 分割交差検証の例であ

る。n-foldのnの値は最大で全体のデータ数まで増やすことができ、その場合は一つ抜き交差検証法(Leave-one-out cross-validation)と呼ばれる。



図2 5分割交差検証

## 2.2 ハイパーパラメータ探索を伴う場合

機械学習モデルには、学習により調整されるパラメータの他に、事前に人手で調整しておく必要のあるパラメータが存在する。例えばランダムフォレストにおける決定木の数や深さ、ニューラルネットワークにおけるユニット数や層数などである。これらをハイパーパラメータと呼ぶ。ハイパーパラメータは機械学習ライブラリのデフォルト値をそのまま利用することもあるが、実験的に求めることも多い。その際は図3のように、上述した訓練セットからさらに検証用データを切り出し、様々なハイパーパラメータの組み合わせに対して検証用データにおける精度を見ながら調整する。

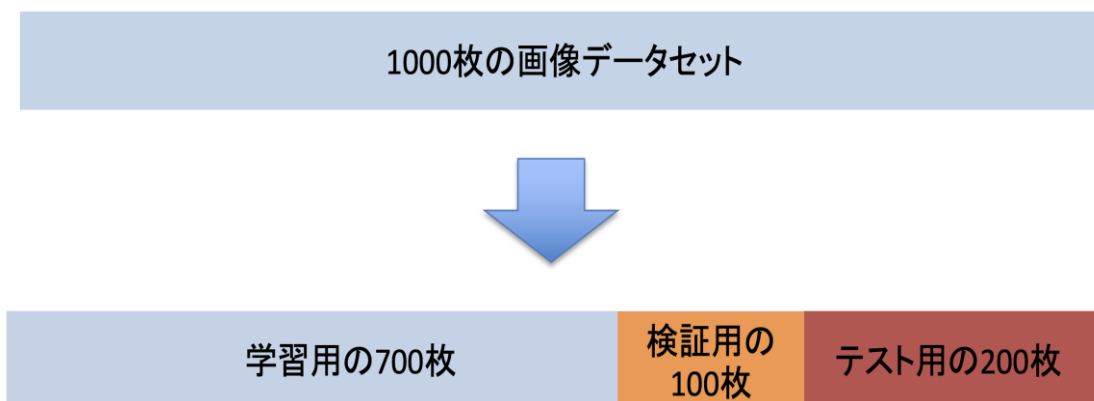


図3 検証用データの切り出し

注意すべきは、テストセットを用いてハイパーパラメータの調整をしてはならない点である。これを行ってしまうと、ハイパーパラメータの選択自体がデータセットに対して過適合してしまい、性能を過大評価してしまうおそれがあるためである。もともと汎化性能を見積もるために用意したはずのテストデータを検証用データとして使ってしまったことになるため、「別途テストデータを用意して評価すべし」というツッコミを受けることになる。

### 3. 評価における Leakage 問題

もうひとつ、機械学習モデルの評価に際して気をつけるべきポイントとして、Leakage 問題に触れる。Leakage とはその名の通り、テストセットの情報が訓練セットに「漏洩」してしまうことを意味する。ここでは医用画像解析における典型的な例を2つ紹介する。

#### 3.1 同一症例からの Leakage

CT や MR 画像などのボリュームデータを扱う場合、症例 1 件あたり 2 枚以上のスライスをデータセットに含めることも多い。このデータセットを訓練セットとテストセットに分割する際、何も考えずにシャッフルしてから分割してしまうと、訓練セットとテストセットそれぞれに同一症例の画像が含まれてしまうおそれがある（図 4）。両者は同一の正解ラベルを持っていることから、当該画像については実質的に答えを知った状態でテストに臨むことになってしまい、テストデータに対するモデル精度は過大評価されることになる。これを防ぐためには、訓練セットとテストセットの分割を症例単位で行うことが重要である。

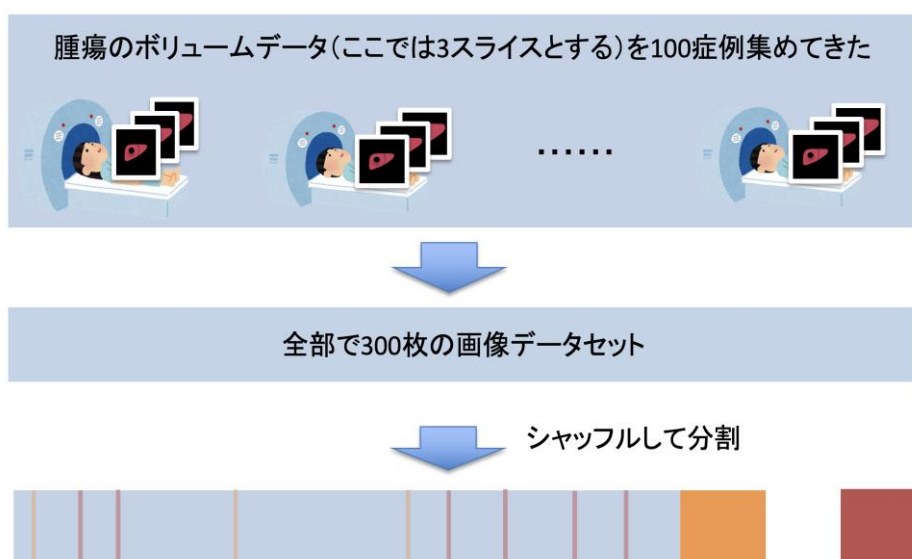


図 4 同一症例からの Leakage

#### 3.2 データ拡張に伴う Leakage

データ拡張は、機械学習を用いた画像解析でしばしば利用されるテクニックである。画像に回転や反転などの変換をかけることにより、擬似的にデータを拡張する（図 5）。これは、同一症例の画像が少

なくとも2枚以上に増えることを意味するため、上述した同一症例からの Leakage を引き起こすおそれがある。そのため、データ拡張を行う際には予め症例単位で訓練セットとテストセットに分割し、訓練セットの画像に対してのみ適用することが重要である。

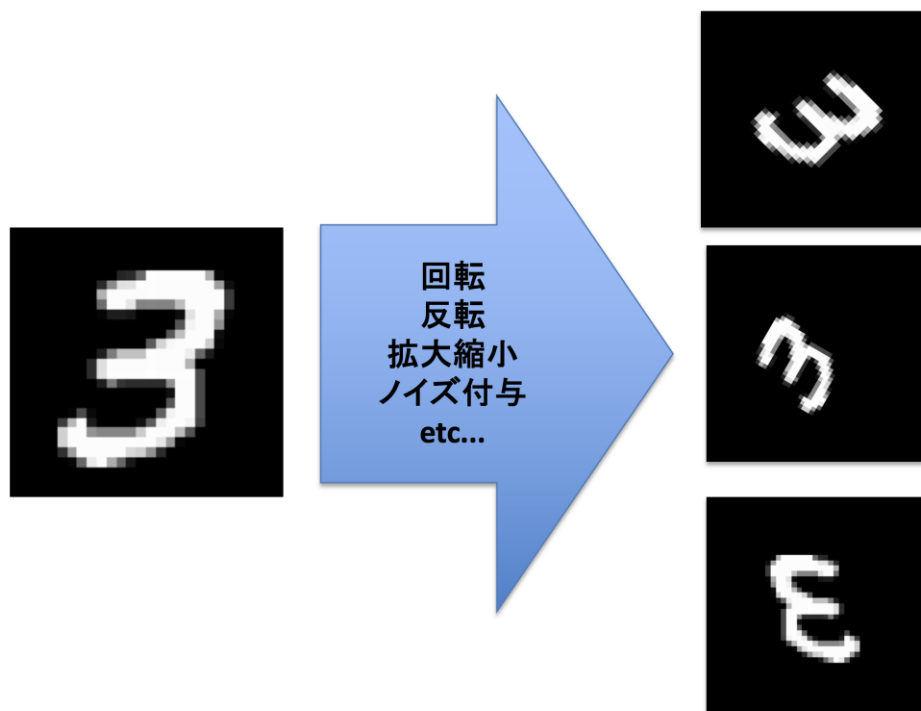


図5 データ拡張の例

#### 4. 論文執筆時や査読時の注意

ここまで延べてきたモデルの評価方法や Leakage について、注意を払わなければならないタイミングは実験や社会実装のときに限らない。特にアカデミアに属する人にとっては、論文執筆や査読の際にも注意を向ける必要がある。

例えば、教科書的な作法に基づけば「機械学習を行う際にはまず train/val/test に分けなければならない」のだが、特にパイロットスタディなど利用可能なデータが少ないケースでは、ハイパーパラメータの調整を行わずにデフォルト値でモデルの訓練を行い、交差検証の結果を報告することも多い。そのような論文を査読する場合に「3つに分けてないからダメ」と切り捨ててしまうことは建設的とはいえない。逆に論文作成者の立場からは、「今回は3つに分けてないけど、ハイパーパラメータ調整を一切行わずに交差検証で評価している」といった旨をきちんと記載しなければ、上記のような誤解に基づくコメントをもらってしまいかねない。

Leakage についても、査読者目線ではそれが起こっていないかどうか、実験のプロセスに関する記述にはよく目を光らせておく必要がある。論文作成者としては、分割の際にきちんと症例ごとに分割している旨や、訓練セットに対してのみデータ拡張を行った旨を記載する必要がある。

このように、自分あるいは筆者がどのような方針で評価を行っているのかをよく理解し、Leakage なく正しく評価できているかをチェックすることに努めるのが重要であろう。

## **略歴**

2016年に東京学芸大教育学部を卒業し、教員免許（小学校、中学校（社会科）、高等学校（地歴公民科））を取得。

大学院から情報学分野へと転向し、2018年電気通信大学大学院情報理工学研究科博士前期課程修了。

2019年より聖マリアンナ医科大学大学院医学研究科 研究技術員、2021年より東北大学病院 Smart Hospital 推進室 AI Lab 助手として、医療 AI 分野の教育と研究に従事。

主な研究テーマは少数データ環境における医用画像解析。

# 臨床現場から見る個別化医療を見据えた

## 医用画像の底力：Radiomics！

山口大学医学部附属病院 放射線治療部 椎木 健裕

### 1. はじめに

現在の医療は、バイオテクノロジーに基づき、患者の個別化診断と治療に影響を及ぼす因子を考慮し、多くの医療資源の中から個々に適した治療法を選択・提供する患者個別化医療へと進化している。それを支えるのがオミックス情報である。オミックスとは、遺伝子、転写、タンパク質、代謝系などの様々な網羅的な分子情報のことで、その一つにRadiomicsが注目されている。Radiomicsは、医用画像から定量的な特徴を抽出することに焦点を当てた研究分野であり、医用画像を高次元データに変換し、疾患プロセスの理解を深め、臨床上の意思決定を支援する生物学的情報を提供する可能性があるとされている。具体的な応用方法としては、疾患の検出、診断、治療応答の予測、及び患者の予後予測の改善が挙げられる。そのため、これまで日常臨床で蓄積された医用画像の解析を通じて、個別化医療をさらに推進する可能性を秘めている。本稿では、Radiomicsの基本的な解析方法と、放射線治療・診断分野における応用例について述べる。

### 2. Radiomicsの解析の主なステップ

Radiomicsのアプローチは、機械学習によるアプローチと深層学習によるアプローチがある（Figure 1）。基本的な解析ステップは、以下の通りである。

1. 研究目的と定義：研究の目的や仮説を明確に定義する。これには、特定の疾患の診断、予後予測、治療効果の評価などが含まれる。
2. 画像取得と前処理：高品質な画像データの取得（CT, MRI, PET など）と、ノイズの除去や標準化などの前処理が必要となる。
3. 領域選定（Region of interest の選択）：病変部や関心領域（ROI）を選定し、それらの領域に焦点を当てた解析を行う。
4. 特徴量抽出：関心領域からテクスチャ、形状、強度などの多様な定量的特徴量を抽出する。これらの特徴は、疾患の特性や進行度を反映することがある。具体的なRadiomics特徴量は、大きく以下のカテゴリーに分類される。

#### 4.1. 形状（Shape）特徴量

形状特徴量は、病変部や関心領域の幾何学的な形状とサイズに関する情報を提供する。これには、体積、表面積、周囲の長さ、複雑さ（表面の凹凸）、球状性（病変が球にどれだけ近いか）、



およびコンパクトさ（密度）などが含まれる。

#### 4.2. First Order 統計特徴量

First Order 統計特徴量は、画像のピクセル強度分布の基本的な統計的性質を示す。これには、平均値、標準偏差、歪度（分布の非対称性）、尖度（ピークの鋭さ）、ヒストグラムのエネルギー（一貫性のあるパターンの存在）、エントロピー（画像の不規則性や複雑さ）などが含まれる。

#### 4.3. テクスチャ (Texture) 特徴量

テクスチャ特徴量は、画像内のパターンや構造の複雑さを捉え、ピクセル間の関係を分析する。これらは、グレーレベル共起行列 (GLCM)、グレーレベルランレングス行列 (GLRLM)、グレーレベルサイズゾーン行列 (GLSZM)、グレーレベル依存度行列 (GLDM) など、様々な方法で計算される。テクスチャ特徴量には、コントラスト、相関、エネルギー、ホモジニティ（均一性）、エントロピーなどがある。

#### 4.4. 高次統計特徴量

高次統計特徴量は、テクスチャ特徴量をさらに洗練させ、フィルタリングや数学的変換を適用して算出される。これには、ウェーブレット変換によって得られる特徴量や、フーリエ変換を使用した特徴量などが含まれる。これらの特徴量は、画像のさらに微細なテクスチャ情報やパターンを捉える。

一方、深層学習によるアプローチの場合、畳み込みニューラルネットワークを用いることで、画像から直接、階層的な特徴を自動的に学習し、抽出することが可能である。

5. 特徴選択と分類：抽出された特徴の中から、最も診断や予後予測に有用な特徴を選択し、機械学習モデルを用いて分類器を構築する。
6. モデルの検証：独立したデータセットを用いて、構築されたモデルの性能を検証する。

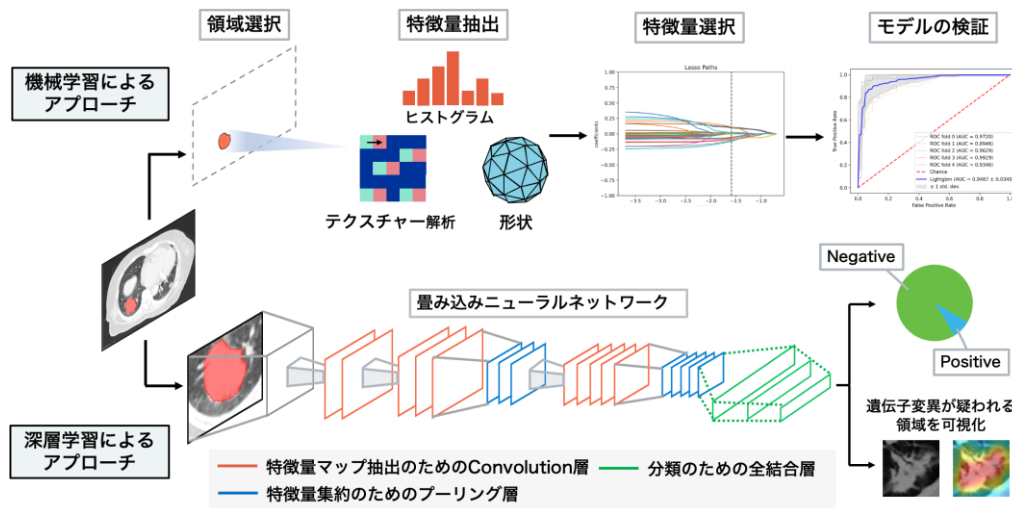


Figure 1. Radiomics 研究に対する機械学習と深層学習によるアプローチ ([1]の図を改変)

### 3. 放射線治療における Radiomics 研究

放射線治療は、放射線治療装置で立案される治療計画に基づいて実施される。治療計画は、放射線治療計画用CTを基に、治療標的(腫瘍)や危険臓器を設定し、その位置情報から照射方向・範囲を決定し、治療標的や危険臓器へ照射される線量を計算し、腫瘍に対する線量や危険臓器の線量を確認するという行程で行われる。この行程で得られる治療標的や危険臓器の情報は日常臨床で得られる情報である。また、治療計画で得られる放射線線量分布のパターンと特徴を定量的に分析する Dosiomics と呼ばれる研究も存在し、医用画像情報だけでなく、放射線線量の情報も予測モデルに組み込むことが可能である。Wu らは、頭頸部腫瘍に対して強度変調放射線治療を実施した患者に対し、CT や PET の radiomics 特徴量に線量分布の特徴量 (Dosiomics) を加えることで、局所再発の予測精度を改善したと報告している[2]。また、河原らは、進行肺癌に対する放射線治療の肺への照射線量分布を使い、肺領域を分割し、分割した肺領域から radiomics 特徴量を解析し、放射線肺炎のリスクを予測する研究を報告している[3]。

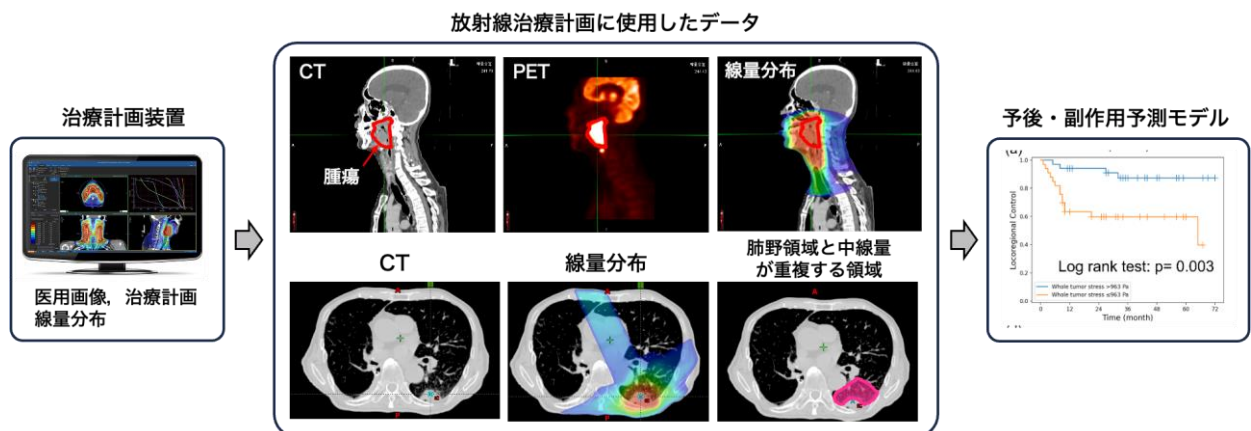


Figure 2. 頭頸部腫瘍に対する放射線治療計画で使用される医用画像と線量分布. 医用画像や線量分布から得られる特徴量を基に, 治療効果や副作用の予測を行う. また, 線量分布を用いて, 中線量を照射されている肺領域の特徴量を使用し, 放射線肺臓炎の予測を行う.

#### 4. 放射線診断における Radiomics 研究

がん治療の個別化医療では, 腫瘍の性格に応じて治療方針が決定される. 例えば, 肺腺がんの分子的特徴の一つに, 上皮成長因子受容体 (EGFR) の変異があり, これを標的とした分子標的薬を使用した治療が第一選択となることが多い. この遺伝子検査は, 生検サンプルを用いた遺伝子解析で行われることが一般的である. また, 肺がんの細胞表面に多く発現するタンパク質である Programmed death-ligand 1 (PD-L1) は, その発現量に基づき, これらのタンパク質を標的とする免疫チェックポイント阻害剤による治療が効果的であるとされている. PD-L1 の発現量についても, がん組織の生検サンプルを免疫組織化学検査により定量化することが多い. しかし, 腫瘍は不均質な組織のため, 生検組織を取る場所によって検査結果にばらつきが生じる問題がある. また, 検査結果が出るまでに時間がかかる. そこで, 肺がんの診断・治療で必ず行われる CT 検査の画像における腫瘍領域及び腫瘍周囲領域の Radiomics 解析を用いて, EGFR 変異や PD-L1 の発現量を予測し, モデルの精度改善を図る研究が報告されている[4-6].




Figure 3. 肺がんの EGFR 変異予測に起因する Radiomics 特徴量を可視化. EGFR 変異あるものとワイルドタイプで違いがあることが視覚化されている.

#### 5. その他の Radiomics の応用

放射線治療の行程は, 放射線治療計画の情報が治療機器に転送され, 治療が実施されるが, 治療機器の品質管理・品質保証が十分に行われていることが前提である. しかし, 近年の放射線治療は高精度化しており, その品質管理法も複雑化してきている. この品質管理を, 放射線治療機器に付属する画像誘

導装置で取得される画像に対して Radiomics 解析を行うことにより、治療機器のどの部位にエラーが生じているか（例えば、マルチリーフコリメーターのエラーや jaw の位置精度など）を予測する研究が行われている[8].

## 6. Radiomics の臨床応用の問題点

Radiomics の臨床応用するためには、多くの解決すべき問題点が存在する。

1. 画像取得と処理の標準化が欠けており、抽出された特徴の再現性と信頼性に影響を与える可能性がある。
2. 高品質な画像データが必要であり、堅牢な予測モデルを構築するためには大量のデータが必要となる。
3. 画像から抽出される特徴は複雑であり、臨床医にとって直感的に解釈しにくいことが、臨床導入の障壁となる。
4. 既存の臨床ワークフローに Radiomics を組み込むことは難しく、医療従事者の手順の変更とトレーニングが必要となる。
5. Radiomics に基づくツールの承認には規制上のハードルがあり、データプライバシーやアルゴリズムバイアスの可能性に関する倫理的な考慮が必要である。
6. 医療は日進月歩で、進化しているため、教師あり学習である Radiomics 研究は、新しい医療に関しては、力を発揮しにくい。

このように臨床応用には問題点も多く、個別化医療に対して、Radiomic 研究の利益を、確信を持って実証できるようになるために、体系的な評価の仕組みを確立する必要がある。（参考文献）

## 7. まとめ

本稿では、Radiomics 研究の基本的な解析方法から診断・治療における応用研究について述べた。医療が患者個別化に向かう中、医療画像を活用するにあたり、Radiomics は大きなポテンシャルを持っていると考えられる。しかし、臨床応用するためには超えるべきハードルが多いため、今後も研究を進める必要がある。

## 8. 謝辞

今回このような機会を頂きました画像部会の先生方、小倉記念病院の佐保辰典先生に感謝申し上げます。また、本稿で紹介させていただいた研究は、山口大学医学物理研究推進体 (<https://ds0n.cc.yamaguchi-u.ac.jp/~medphys/>) の成果であり、メンバーに感謝いたします。

## 9. 参考文献

- [1] 椎木 健裕, 田中 秀和. 医学物理の視点から見る Precision Medicine に向けた放射線治療 RadFan2020 年 12 月号

- [2] Wu A, Li Y, Qi M, et al. Dosiomics improves prediction of locoregional recurrence for intensity modulated radiotherapy treated head and neck cancer cases. *Oral Oncol.* 2020 May;104:104625.
- [3] Kawahara D, Imano N, Nishioka R et al. Prediction of radiation pneumonitis after definitive radiotherapy for locally advanced non-small cell lung cancer using multi-region radiomics analysis. *Sci Rep.* 2021 Aug 10;11(1):16232.
- [4] Kawazoe Y, Shiinoki T, Fujimoto K, et al. Comparison of the radiomics-based predictive models using machine learning and nomogram for epidermal growth factor receptor mutation status and subtypes in lung adenocarcinoma. *Phys Eng Sci Med.* 2023 Mar;46(1):395-403.
- [5] Kawazoe Y, Shiinoki T, Fujimoto K, et al. Investigation of the combination of intratumoral and peritumoral radiomic signatures for predicting epidermal growth factor receptor mutation in lung adenocarcinoma. *J Appl Clin Med Phys.* 2023 Jun;24(6):e13980.
- [6] Shiinoki T, Fujimoto K, Kawazoe Y, et al. Predicting programmed death-ligand 1 expression level in non-small cell lung cancer using a combination of peritumoral and intratumoral radiomic features on computed tomography. *Biomed Phys Eng Express.* 2022 Feb 1;8(2).
- [7] Sakai M, Nakano H, Kawahara D, et al. Detecting MLC modeling errors using radiomics-based machine learning in patient-specific QA with an EPID for intensity-modulated radiation therapy. *Med Phys.* 2021 Mar;48(3):991-1002.

# がんの特徴を穴から見通す -トポロジー穴解析-

1)九州大学大学院医学系学府保健学専攻医用量子線科学分野

2)九州大学大学院マス・フォア・イノベーション連係学府

有村秀孝<sup>1,2)</sup>, 児玉拓巳<sup>1)</sup>

**要旨** 蓮根には穴がたくさんあり、穴から先を見通せるということで縁起の良い食べ物で、著者も好きである。しかし、タイトルの穴は蓮根の穴ではなくトポロジーの穴で、「多次元の穴」である。「は〜？」と思った方が私の講演を聴講したかもしれない。著者はトポロジーに基づく穴の数（ベッチ数）を数えることによって、がん腫瘍をいくつかの特徴的なグループに分類することを試みている。がん腫瘍の画像特徴は、腫瘍細胞、壊死、血管新生などいくつかの要因に依存すると著者は考えている。腫瘍をトポロジー的に解析する場合、癌の画像特徴は3つの構造要素（3次元空間の場合）、すなわち、連結成分、穴、空洞に分解できると仮定する。本稿ではレディオミクスにおけるトポロジーに基づく「穴解析」について、基本的考え、穴解析の仮定、穴解析の理論、穴解析の研究例を含めて説明したい。

## 穴解析の基本的考え

蓮根は蓮の根ではなく、肥大した地下茎だそうで、泥の中で育つ。蓮根の穴は、蓮が水上の花や葉を通して酸素を取り込むためにあるらしい[1]。蓮根の大きな穴の数（小さいものは除く）は中央に1つで周りに約7-9個で合計10個程度である[2]。著者の知る限り、蓮根の穴の数と予後（変な表現ですね）との関係を調べた研究は無いが、蓮根の穴と応力（強度と関係する物理量）との関係を調べた研究[2]はあった。もし蓮根の穴の数と硬さに関連があると仮定すると、穴の数から硬い蓮根グループと柔らかい蓮根グループに分類できるかもしれない(図1上)。

穴解析の基本的考えは、ある対象の穴の数に従って、特徴的なグループごとに分類することである。特徴グループ内では穴の数が不変量となる。不変量とは特定の変形によって変わらない量と考える[3]。例えば、多角形で言えば、不変量は辺または頂点の数で、三角形なら3、四角形なら4となる(図1中)。これらの数は図形を変形しても同じである。つまり、蓮根で言えば、柔らかい蓮根では穴の数がいつも10個で、硬い蓮根はそれより少なくなるみたいなイメージである。著者が提案している穴解析[4]ではがん治




図1 硬さに関して穴の数で蓮根を分類 (上), 辺の数で図形を分類 (中), 予後に関して肺癌を穴の数で分類 (下)。

療におけるレディオミクス[5]を対象に、例えばある患者の肺がんの穴の数が多い場合、予後が悪いグループに、穴の数が少ない場合、予後が良いグループに分類する(図1下)。

### 穴解析の仮定

著者はがんの画像上の特徴は腫瘍細胞数、ネクロシス、血管新生などの要因に依存すると仮定している。これら要因は予後と関係あるという証拠はあるのか？腫瘍細胞数が多いほど全生存期間と無増悪生存期間が短くなるとの報告はある[6]。無増悪生存期間は治療中にがんが進行しなかった期間である[7]。ネクロシスと予後との関係は以前から一般的な知識として共有されている[8]。Oiwaらによると、ネクロシスが肺がんが存在すれば、全生存期間と無再発生存期間が短くなるが、壊死領域の割合は両期間に影響しない[9]。ネクロシス[9]は外因によって細胞が壊れることで起こる偶発的または事故的細胞死である。血管新生[10]はがんが増殖のための栄養血管を親血管から新たに作ることである。Bačićらによるとマイクロ血管密度が高い患者群は全生存期間が短くなるという[11]。これら要因の画像特徴が数、大きさ、構造の複雑さによって変化し、複数の要因が重なり合い、腫瘍は医療画像上で特徴的かつ不均一なピクセル値の分布となる。

腫瘍を穴解析する場合、がんの画像上の特徴(腫瘍細胞、ネクロシス、血管新生、その他の要因)は3つのトポロジー構造要素、つまり連結成分 (connected component)、外部と繋がった穴 (hole)、外部と繋がらない空洞 (cavity) に分解できると著者は仮定している[4]。連結成分、穴、空洞はそれぞれ0次元、1次元、2次元の穴で、それぞれ数は0次元、1次元、2次元のベッチ数となる。

### トポロジーに基づく穴解析の理論

穴解析では具体的な穴の形を考慮せず、多次元の穴の数を表すベッチ数に従ってがんを分類する。ベッチ数は、トポロジーにおけるホモロジー理論に従い、0次元、1次元、2次元のベッチ数を計算する。位相空間(形や図形の集合)  $X$  [12] の  $n$  次元ホモロジー群  $H_n(X)$  (図形の大域的なつながり具合を表すベクトル空間[13]) の階数(rank)を計算することで  $n$  次元の穴の数であるベッチ数を  $b_n = \text{rank}(H_n(X))$  から求める[14]。

### 穴解析の研究例

2次元ベッチマップを用いた放射線治療または放射線化学療法を受けた肺がん患者の予後予測[15]：Ninomiyaらは肺腫瘍内にネクロシスなどが原因で生じる穴が予後と関係する研究[16]に基づいて、穴解析のレディオミクスを用いて予後予測性能(全生存期間の高リスク群と低リスク群への分類)が向上することを示した。Ninomiyaらはベッチ数のマッピング画像(以下ベッチマップ。肺腫瘍の特徴をトポロジーの観点から可視化した画像)から求めたベッチ数特徴量は従来のテクスチャー特徴量や深層学習から求めた特徴量よりも予測性能が高いことを示した。

2次元反転ベッチマップを用いた定位体幹部放射線治療を受けた肺がん患者の再発予測[17]：Kodamaらは二値画像を反転させた画像から求めた反転ベッチマップがNinomiyaらのベッチマップとは異なる腫瘍特徴量を示す可能性があると仮定した。そこで定位体幹部放射線治療を受けた肺がんの再発予測法を研

究し、反転ベッチマップから求めた特徴量は従来の特徴量（テクスチャー解析と従来のベッチマップ）と比較し、局所再発と遠隔転移をより高い正確度で予測できることを示した。

2次元または3次元ベッチマップを用いた EGFR 変異のレディオゲノミクスモデル[18, 19] : Ninomiya らは、非小細胞肺癌（NSCLC）患者における上皮成長因子受容体（EGFR）変異の同定に、2次元ベッチマップを用いた頑強なレディオゲノミクスモデルを提案した。EGFR は細胞の増殖を促す細胞表面に存在する受容体であり、EGFR 変異のあるがんでは異常な細胞増殖を起こす。EGFR 変異の肺癌には空洞やバブル（空洞/泡状）などが画像に現れやすいことがわかっているため[20, 21]、穴解析が有効である可能性がある。提案した EGFR 予測モデルは、NSCLC 患者における EGFR 変異の同定において、CT 装置/撮影パラメータの変動に対するベッチマップの画像特徴量の頑健性が示唆された。さらに Ninomiya らは同じデータセットを用いて EGFR 変異のサブタイプ (Del19 と L858R 変異) を 3次元の空洞まで含めて特徴付けるために、3次元ベッチマップを用いた新しいレディオゲノミクスモデルを研究した。3次元ベッチマップ特徴量の EGFR 変異のサブタイプ分類性能は従来のレディオミクス特徴量よりも高いことを示した。

定位体幹部放射線治療後の放射線肺炎患者推定法[22] : Ninomiya らはベッチマップ特徴量と KL-6 バイオマーカーに基づいて定位体幹部放射線治療後に起こるグレード 2 以上の放射線肺炎を治療前に予測するレディオミクスモデルを開発した。放射線肺炎が起こりやすい肺の患者と起こりにくい肺の患者を穴解析で区別できると仮定した。図 2 に放射線肺炎になった患者とならなかった患者の肺野のベッチマップを示す。ベッチマップ特徴量と KL-6 バイオマーカーの相乗効果で、放射線肺炎を従来法よりも正確に予測できることを示し、その予測は治療計画に反映できる可能性がある。

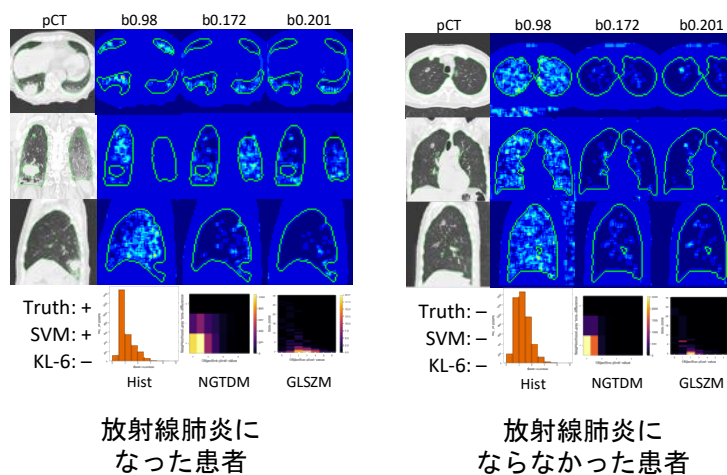


図 2 放射線肺炎になった患者とならなかった患者の肺野のベッチマップ。

MR 画像のベッチマップを用いた耳下腺がんの悪性度予測法[23] : 耳下腺がん（PGC）の悪性度は治療方針を決定する。しかし、PGC の悪性度の評価には侵襲的な fine-needle aspiration cytology (FNAC) が用いられている。そこで Ikushima らは磁気共鳴（MR）画像の T1 と T2 強調画像から求めたベッチマップ特徴量に基づいて非侵襲的な PGC の悪性度予測法を研究した。耳下腺がんは唾液を出す腺腔に発生するため、穴解析が有用であると考えられる。PGC の悪性度を非侵襲的に予測できることを示すことで MR 画像でも穴解析の有効性を示した。



パーシステントホモロジーを用いた頭頸部がんの予後予測[24]：頭頸部がん患者の PET/CT 画像から、パーシステントホモロジー (PH) [13]特徴量が、他の従来の特徴よりも腫瘍の代謝と形態に関するより本質的な情報を捉えることができるという仮説を立てた。The Cancer Imaging Archive (TCIA) の公開データセットから 207 例の PET/CT 画像と臨床情報のいくつかを選択した。PH 画像は、PET/CT 画像から得られたパーシステントダイアグラ

ムから生成した。PH 特徴量は、PH-PET/CT 画像から求めた。CT 画像、PET 画像、PH-CT 画像、PH-PET 画像の特徴量、臨床情報、特徴量と臨床情報の組み合わせから、学習症例においてシグネチャーを構築した。この結果は、PH 特徴が腫瘍の本質的な情報を捉え、頭頸部がん患者の予後を予測できることを示した。図 3 に全生存期間の良い患者と悪い患者の CT 画像、PET 画像、b0 の PH 画像を示す。

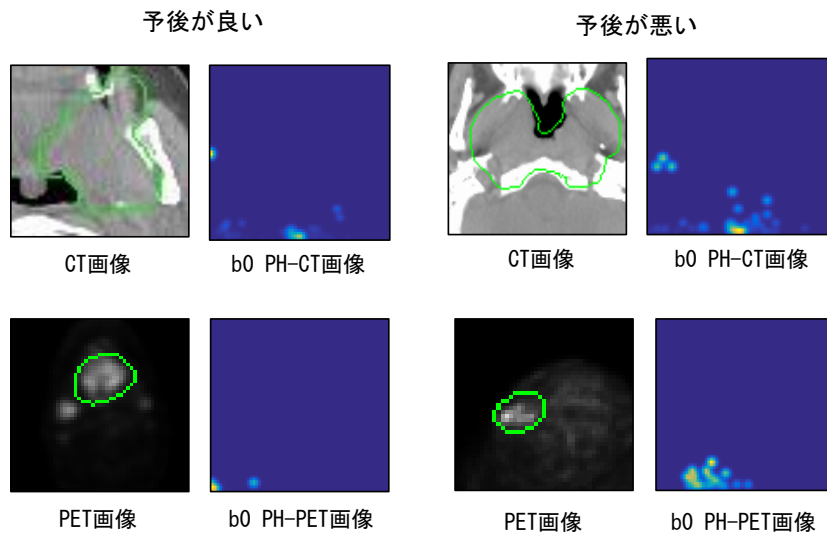


図 3 全生存期間の良い患者と悪い患者の CT 画像、PET 画像、b0 の PH 画像。

3次元ベッチマップを用いた転移性脳腫瘍原発部位予測のための MR 画像生検モデル[25]：Egashira らは転移性脳腫瘍の原発部位（肺がんまたはそれ以外）を予測するために MR 画像から求めた 3次元ベッチマップに基づく画像生検モデルを構築した。転移性脳腫瘍と膠芽腫の区別にネクロシス領域と微小血管が有用だったという研究結果[26]から穴解析が有用な可能性がある。ベッチマップと反転ベッチマップから求めた特徴量は画像生検モデル構築に有用だった。画像生検モデルは、3つの特徴選択方法で選択された有意な特徴を使用して構築され、7つの機械学習手法を用いて構築された。3次元ベッチマップ特徴量が転移性脳腫瘍の原発部位同定の性能を向上できることを示した。

## 最後に

がんの穴解析から予後を見通せるかもしれないことを解説した。ただ、実はがんの数理的解明には至っておらず、研究は始まったばかりで、“未解決の穴”が至る所で空いている。蓮のように綺麗な花が咲くのはいつの日になることやら。とにかく、本稿が皆様の研究や教育の役に立てば幸いである（あまり臨床には役に立たないと思いますが）。なお、本稿は文献[4]を改変することで執筆した。

略歴:1991年京都工芸繊維大学大学院修士課程電子情報工学専攻修了。1996年、同大学院博士課程で、X線画像ノイズとX線スペクトルとの関係に関する研究で博士（工学）取得。1991年～1996年島津製作所勤務。1996年～1998年東京女子医大放射線腫瘍学講座助手。1998年広島国際大学臨床工学科講師、2002

年診療放射線学科助教授。2002年 - 2004年、シカゴ大学（土井邦雄教授）の研究者としてコンピュータ支援診断の研究に従事。2004年から九州大学助教授，准教授を経て，2015年から教授（現在に至る）。現在の研究テーマは，がん治療における医療AIとレディオミクスの研究。特にがんの特徴に関連する数理モデルと穴解析（トポロジカルレディオミクス）。

## 文献

1. 松岡真澄. れんこんの あな. 月刊 かがくのとも 2011;513号.
2. Zhu Y, Wang CJ, Mynors D. Applications and Engineering Analysis of Lotus Roots under External Water Pressure. *Appl Bionics Biomech.* 2016;2016:2386982. doi: 10.1155/2016/2386982. Epub 2016 Dec 29. PMID: 28127228; PMCID: PMC5227306.
3. 石川勝巳. 不変量で見るトポロジー. 令和4年度（第43回）数学入門公開講座テキスト（京都大学数理解析研究所，令和4年8月1日～8月4日開催） 2022; <https://www.kurims.kyoto-u.ac.jp/~kenkyubu/kokai-koza/R4-ishikawa.pdf>（2024年2月24日にアクセス）
4. 有村 秀孝，兒玉 拓巳，二宮 健太，徳田 智紀. トポロジーでがんの特徴を数に変える-穴解析-. 医用画像情報学会雑誌 2023;40(4):79-84.
5. 有村秀孝，角谷倫之編. レディオミクス入門. オーム社；2021.
6. Lin S, Samsundar JP, Bandari E, et al.: Digital Quantification of Tumor Cellularity as a Novel Prognostic Feature of Non-Small Cell Lung Carcinoma, *Mod Pathol*, 36(3): 100055, 2023. doi: 10.1016/j.modpat.2022.100055.
7. がん情報サイト「オンコロ」 <https://oncolo.jp> (2024年2月28日アクセス)
8. Caruso R, Parisi A, Bonanno A, Paparo D, Quattrocchi E, Branca G, Scardigno M, Fedele F. Histologic coagulative tumour necrosis as a prognostic indicator of aggressiveness in renal, lung, thyroid and colorectal carcinomas: A brief review. *Oncol Lett.* 2012 Jan;3(1):16-18.
9. Oiwa H, Aokage K, Suzuki A, et al.: Clinicopathological, gene expression and genetic features of stage I lung adenocarcinoma with necrosis, *Lung Cancer*, 159:74-83, 2021. doi: 10.1016/j.lungcan.2021.07.001. Epub 2021 Jul16. PMID: 34311347.
10. Lee S, Kim S, Koo DJ, et al.: 3D Microfluidic Platform and Tumor Vascular Mapping for Evaluating Anti-Angiogenic RNAi-Based Nanomedicine, *ACS Nano*, 15(1): 338-350, 2021.
11. Bačić I, Karlo R, Zadro AŠ, Zadro Z, Skitarelić N, Antabak A. Tumor angiogenesis as an important prognostic factor in advanced non-small cell lung cancer (Stage IIIA). *Oncol Lett.* 2018;15(2):2335-2339. doi: 10.3892/ol.2017.7576.
12. 瀬山士郎. トポロジー：柔らかい幾何学. 日本評論社，東京，2016.
13. 平岡裕章. タンパク質構造とトポロジー —パーシステントホモロジー群入門—（シリーズ・現象を解明する数学）. 共立出版，東京，2013.
14. 荒井迅. 計算トポロジー —特集《計算》とは何か—. *数理科学* 698:14-21, 2021.
15. Ninomiya K, Arimura H. Homological radiomics analysis for prognostic prediction in lung cancer patients. *Phys Med.* 2020;69:90-100.

16. Koenigkam Santos M, Muley T, Warth A, de Paula WD, Lederlin M, Schnabel PA, Schlemmer HP, Kauczor HU, Heussel CP, Puderbach M. Morphological computed tomography features of surgically resectable pulmonary squamous cell carcinomas: impact on prognosis and comparison with adenocarcinomas. *Eur J Radiol.* 2014;83(7):1275-1281.
17. Kodama T, Arimura H, Shirakawa Y, Ninomiya K, Yoshitake T, Shioyama Y. Relapse predictability of topological signature on pretreatment planning CT images of stage I non-small cell lung cancer patients before treatment with stereotactic ablative radiotherapy. *Thorac Cancer.* 2022;13(15):2117-2126. doi: 10.1111/1759-7714.14483.
18. Ninomiya K, Arimura H, Chan WY, Tanaka K, Mizuno S, Muhammad Gowdh NF, Yaakup NA, Liam C-K, Chai C-S, Ng KH. Robust Radiogenomics Approach to the Identification of EGFR Mutations among Patients with NSCLC from Three Different Countries Using Topologically Invariant Betti Numbers. *PLoS One* 2021;16(1):e0244354. doi: 10.1371/journal.pone.0244354.
19. Ninomiya K, Arimura H, Tanaka K, Chan WY, Kabata Y, Mizuno S, Gowdh NFM, Yaakup NA, Liam CK, Chai CS, Ng KH. Three-dimensional topological radiogenomics of epidermal growth factor receptor Del19 and L858R mutation subtypes on computed tomography images of lung cancer patients. *Comput Methods Programs Biomed.* 2023;236:107544. doi: 10.1016/j.cmpb.2023.107544.
20. Liu Y, Kim J, Qu F, Liu S, Wang H, Balagurunathan Y, Ye Z, Gillies RJ. CT Features Associated with Epidermal Growth Factor Receptor Mutation Status in Patients with Lung Adenocarcinoma. *Radiology.* 2016;280(1):271-80. doi: 10.1148/radiol.2016151455.
21. Lee H, Choi E, Lee MK, Zhang Y, Kwon W. Morphologic Evaluation of Primary Non-Small Cell Lung Cancer by 3 Tesla MRI with Free-Breathing Ultrashort Echo Time and Radial T1-Weighted Gradient Echo Sequences: A Comparison with CT Analysis. *J Korean Soc Radiol.* 2019;80(3):466-476.
22. Ninomiya K, Arimura H, Yoshitake T, Hirose TA, Shioyama Y. Synergistic combination of a topologically invariant imaging signature and a biomarker for the accurate prediction of symptomatic radiation pneumonitis before stereotactic ablative radiotherapy for lung cancer: A retrospective analysis. *PLoS One.* 2022;17(1):e0263292. doi: 10.1371/journal.pone.0263292.
23. Ikushima K, Arimura H, Yasumatsu R, Kamezawa H, Ninomiya K. Topology-based radiomic features for prediction of parotid gland cancer malignancy grade in magnetic resonance images. *MAGMA.* 2023;36(5):767-777. doi: 10.1007/s10334-023-01084-0.
24. Le QC, Arimura H, Ninomiya K, Kodama T, Moriyama T. Can Persistent Homology Features Capture More Intrinsic Information about Tumors from <sup>18</sup>F-Fluorodeoxyglucose Positron Emission Tomography/Computed Tomography Images of Head and Neck Cancer Patients? *Metabolites.* 2022 Oct 14;12(10):972. doi: 10.3390/metabo12100972. PMID: 36295874; PMCID: PMC9610853.
25. Egashira M, Arimura H, Kobayashi K, Moriyama K, Kodama T, Tokuda T, Ninomiya K, Okamoto H, Igaki H. Magnetic resonance-based imaging biopsy with signatures including topological Betti number features for prediction of primary brain metastatic sites. *Phys Eng Sci Med.* 2023 Dec;46(4):1411-1426.
26. Heynold E, Zimmermann M, Hore N, Buchfelder M, Doerfler A, Stadlbauer A, Kremenevski N. Physiological MRI Biomarkers in the Differentiation Between Glioblastomas and Solitary Brain Metastases. *Mol Imaging Biol.* 2021;23(5):787-795.

# 放射線診断医からみた Radiomics

聖マリアンナ医科大学 原口 貴史

## 1. はじめに

近年、医療分野における技術革新が目覚ましい進展を遂げている。特に放射線医学の領域では、画像解析技術の進化が顕著である。その潮流の中で、放射線画像から得られる大量のデータを利用して、疾患の診断、治療効果の予測、予後評価などに役立てることを目指す新しい研究分野として、Radiomics は注目を集めている<sup>(1)</sup>。Radiomics は、放射線画像内の可視的な特徴だけでなく、肉眼では識別できない微細なテクスチャー情報までを定量化し、これらの情報を統合して疾患の特性をより深く理解することを可能にする<sup>(2)</sup>。

放射線診断医の私からみて、Radiomics の導入は単に新しい技術を取り入れること以上の意味を持っている。それは、診断プロセスにおける役割の変化、新たな技術習得、そして多職種連携の強化を必要としていることである。Radiomics によって抽出される豊富な情報は、放射線診断医が提供できる診断情報の質を高め、患者さん一人ひとりに最適な個別化医療の提供を可能にすると期待されている<sup>(3)</sup>。

本稿では、Radiomics が放射線診断医の視点からどのように捉えられ、医療現場でのその可能性と課題について述べる。Radiomics の進展は、放射線診断医だけでなく、多くの医療従事者にとって、診断と治療の新たな地平を開くものであり、その実現に向けた取り組みは、医療の質を向上させるための重要なステップとなる。

## 2. 診断プロセスにおける役割の変化

Radiomics の導入によって放射線診断医の診断プロセスにおける役割は、根本的に変化している。従来、我々放射線診断医は画像を直接視覚的に評価し、その経験と知識を基に診断を下していた。しかし、Radiomics 技術を活用することで、画像から抽出される大量の定量的データを分析し、疾患の診断や予後の予測に役立てることが可能になる<sup>(4)</sup>。放射線診断医は単に画像を解釈するだけでなく、抽出されたデータの意味を解析し、それを臨床的事象に結びつける必要がある。この変化は、放射線診断医が扱う情報の量と質の両方に影響を及ぼし、画像から得られる定量的特徴が示す生物学的特徴や疾患特性を理解することが含まれる。したがって、我々の役割は、画像解釈の専門家からデータ解析と臨床的意思決定を統合する専門家へと拡張される。この役割の変化により、放射線診断医は新たな知識と技術の習得が必要となる。

### 3. 新たな知識と技術の必要性

Radiomics の導入により、放射線診断医には従来の診断プロセスを超えた新たな技術習得が求められている。この技術革新は、専門性を拡張し、医療の質を向上させるための重要なステップである。以下に、習得すべき主要な新技術を概説する。

#### 3.1 データサイエンスと統計学

Radiomics は放射線画像から抽出される膨大なデータを基にしているため、新たな技術領域を理解し、活用するためには、以下に示すようなデータサイエンスと統計学の基本的な概念と技術を習得する必要がある。

放射線画像から得られる定量的データは、そのままでは分析に適さないことが多く、データの前処理が必要となる。ノイズの除去、正規化、標準化など、データを前処理することで、分析の精度と効率を高めることができる。放射線診断医は、これらの前処理技術を理解し、適切に適用する能力を身につける必要がある。

Radiomics で抽出される特徴量は数百から数千に及ぶことがあり、すべての特徴が有用であるとは限らない。過剰適合を避け、モデルの解釈性を高めるためには、特徴量選択や次元削減の技術が重要である。主成分分析 (PCA)、t-SNE (t-distributed stochastic neighbor embedding) を、LASSO 回帰などの手法を用いて、最も情報量の高い特徴を選択する方法を学ぶことが求められている。

データから医学的な意味を持つ結論を導き出すためには、統計的モデリングと推論の技術が不可欠である。回帰分析、分類アルゴリズム、生存分析など、さまざまな統計モデルを理解し、適切なモデルを選択してデータに適用する能力を身につける必要がある。また、モデルの性能評価や検証方法についても理解することが重要である。

以上のように、データの前処理、特徴量選択と次元削減、統計的モデリングと推論の技術など、データを扱う上での基本的な技術を理解し、適用する能力を身につける必要がある。

#### 3.2 機械学習と人工知能

Radiomics の分析には機械学習アルゴリズムや人工知能技術が広く用いられている。これらの技術を理解し、適切に活用することで、画像データからより精密な診断指標を導き出すことが可能となる。Radiomics に機械学習と人工知能を活用することで、診断精度の向上、治療計画の最適化、予後予測の精度向上に直接寄与できるようになる可能性を持っている。

機械学習は、データからパターンを学習し、予測や分類を行うアルゴリズムの集合体である。放射線診断医は、教師あり学習、教師なし学習、強化学習といった基本的な機械学習の種類を理解する必要がある。

ある。教師あり学習は、正解ラベル付きデータを使用してモデルを訓練し、新しいデータの正解ラベルを予測する。回帰と分類がこのカテゴリに含まれる。教師なし学習では、正解ラベルのないデータを使用して、データ内のパターンや構造を見つけ出すことが出来る。クラスタリングや次元削減が典型的な例である。強化学習は、環境からのフィードバックを基にして最適な行動を学習する。医療分野ではまだ初期段階だが、治療計画の最適化などに応用される可能性がある。

人工知能は、機械学習の技術を基にして、より複雑な問題解決や意思決定を行うことが出来る。Radiomicsにより抽出した微細なテクスチャー特徴やパターンを識別し、人工知能で解析することで、疾患の診断や予後予測に利用できる。さらに、患者の臨床データと画像特徴量を組み合わせることで、治療効果や生存率などの予測モデルを構築するが可能となる。

### 3.3 多職種連携

データサイエンスと統計学、機械学習と人工知能は、放射線診断医が単独で習得し活用するには難易度の高い専門的領域である。これらの技術を医療現場で有効に活用するためには、多職種の専門家との協力が不可欠である。さらに、Radiomicsでは、画像から高次元の特徴を抽出するために高度な画像解析技術が必要とされる。テクスチャー分析、形状分析、強度分析など、画像内の微細な情報を定量化するための技術が含まれる。これらの技術を最大限に活用するためにも、様々な職種の専門家との協力が必要になる。その専門家は、データサイエンティストや生物統計の専門家、コンピュータ科学者、人工知能専門家のことである。放射線医は、これらの専門家と協力し、自身の臨床知識を組み合わせることで、より精度の高い診断、個別化医療の提供、疾患の早期発見と予後予測の改善に貢献することができるようになる。多職種連携は、医療分野におけるイノベーションを推進し、複雑な医療課題に対する効果的な解決策を提供する鍵と言える。様々な職種の専門家が協力することで、医療の未来を形作ることができる。

## 4. 実践への課題

Radiomicsを臨床で実践することは多大な可能性を秘めている一方で、その実現には、技術的、臨床的、規制的な側面にわたり、大きな課題が存在している。

### 4.1 技術的課題

技術的課題として、放射線画像の取得プロトコルは施設ごとに異なり、これがRadiomics特徴量の抽出に影響を与える可能性がある。異なる機器やプロトコルから得られるデータの一貫性を確保するために、例えば、harmonizationの技術は非常に有用である<sup>(5)</sup>。harmonizationは、異なる撮影機器やプロト

コルによる影響を補正し、データセット全体の一貫性を高める。これにより、データの比較と統合が容易になり、多施設間での研究や大規模なメタ分析が可能になる。データの一貫性が向上することで、放射線画像から抽出される特徴量の信頼性も高まり、異なる研究や臨床試験で得られた結果の再現性を確保することができる。

別の技術的課題として、放射線科医の Radiomis の解析ツールへのアクセスが限られていることがある。この状況は、Radiomics の臨床応用を進める上で大きな障壁となり得る。病院内システムに Radiomics 解析ツールが組み込まれていない場合、画像データの解析を行うためには、外部のソフトウェアやサービスを利用する必要があるが、これには、データのセキュリティとプライバシー、データの転送と管理、解析結果の統合の課題が伴う。患者の画像データを外部の解析ツールに送信する際、データのセキュリティと患者のプライバシーを保護することが重要である。これには、適切な暗号化技術の使用や、データ保護規制の遵守が必要になる。大量の画像データを外部ツールで解析するために扱う場合、データの転送のために十分なインフラが必要になる。外部ツールで得られた解析結果を病院内システムや電子カルテシステムに統合するためには、システム間の互換性を確保する必要がある。

#### 4.2 臨床的課題

臨床的課題としては、大量のデータから得られる複雑な Radiomics 特徴量の利用が難しいことがある。放射線画像などの医療画像から抽出される特徴量は非常に多岐にわたり、それぞれが異なる側面を表しているが、抽出された特徴量は直感的に理解しにくい場合が多く、それぞれの特徴量が臨床的にどのような意味を持つのかを解釈することは容易ではない。この問題に対処すべく、Radiomics 特徴量の解釈のために Radiomics score を出すことは非常に有用な手段である<sup>(6)</sup>。Radiomics score は、放射線画像から抽出された複数の特徴量を統合して算出される数値であり、特定の臨床的アウトカムや疾患の特性を予測するために使用される。このスコアは、画像内の微細なパターンやテクスチャー情報を定量化し、それを臨床的意義のある単一の指標にまとめることで、診断、予後予測、治療効果の評価の分かりやすい指標とすることが出来る。

#### 4.3 規制的課題

Radiomics を実際に臨床現場へ導入するには、データのプライバシーや薬事承認プロセスの課題がある。

データのプライバシーの問題は、患者の個人情報の保護とデータの活用のバランスをどのように取るかということに集約される。次世代医療基盤法の制定は、データのプライバシーの問題への取り組みの一つである。次世代医療基盤法は、医療ビッグデータの活用基盤となり、医療データの利活用を促進

するとともに、その安全管理と個人のプライバシー保護を図ることを目的としている。この法律は、患者の医療情報を適切に扱うための枠組みを提供し、特に医療情報の電子化が進む中で、その利用と保護のバランスをどのように取るかという点に重点を置いている。

薬事承認プロセスの課題としては、時間とリソースの問題、資金の問題、公的保険の問題がある。薬事承認の審査とプロセスには時間がかかり、そのプロセスを進めるためには専門的な知識や人材が必要となる。また、薬事承認のプロセスには多額の費用がかかる。特に、海外市場での普及を目指す場合、EU、米国、その他の主要市場の規制当局から承認を得る必要があり、そのためには多額の資金が必要となる。そして、開発した医療機器が薬事承認を受けても、公的保険で診療報酬の加算対象にならない場合、病院での導入が難しいと問題がある。

これらの問題を解決するためには、製品開発の初期段階から規制の問題を考慮に入れ、適切なリソースと予算を確保することが重要である。また、公的保険の問題については、政策の改善や新たな報酬制度の導入が求められている。

## 5. 最後に

Radiomics の領域は、医療画像解析における革新的な進展を示している。この技術が持つ潜在的な価値は非常に大きく、診断、予後予測、治療計画の個別化医療において、医療提供の質を大幅に向上させる可能性を秘めている。しかし、その実現には、技術的、臨床的、規制的な課題の克服が必要である。これらの課題に対処するためには、放射線診断医を含む医療従事者、データサイエンティストや生物統計の専門家、コンピュータ科学者、人工知能専門家など、多職種の専門家の協力が不可欠である。放射線診断医としては、Radiomics の進展に伴う変化を受け入れ、新しい技術や知識を積極的に習得し、臨床実践に応用することが求められている。

### <References>

1. Tomaszewski, M. R. & Gillies, R. J. The Biological Meaning of Radiomic Features. *Radiology* 298, 505-516 (2021)
2. Shur, J. D. et al. Radiomics in Oncology: A Practical Guide. *Radiographics* 41, 1717-1732 (2021)
3. Lambin, P. et al. Radiomics: the bridge between medical imaging and personalized medicine. *Nat. Rev. Clin. Oncol.* 14, 749-762 (2017)



4. Najjar, R. Redefining Radiology: A Review of Artificial Intelligence Integration in Medical Imaging. doi:10.1186/s12909-021-02870-x
5. Horng, H. et al. Generalized ComBat harmonization methods for radiomic features with multi-modal distributions and multiple batch effects. *Sci. Rep.* 12, 4493 (2022)
6. Zheng, B.-H. et al. Radiomics score: a potential prognostic imaging feature for postoperative survival of solitary HCC patients. *BMC Cancer* 18, 1148 (2018)

# 放射線治療医からみた Radiomics の有用性と今後の展望

広島大学大学院医系科学研究科放射線腫瘍学

今野 伸樹

## 1. はじめに

がん治療においては、がんを正しく診断し、個々の患者最適な治療を実践し、正しく経過観察を行うことが重要である。この過程で医用放射線画像が果たす役割が大きく、医療者が様々な画像を有効に用いることで、診断、治療、経過観察を行う。Radiomics は、こうした人間が行っている医用放射線画像に対する判断をより高次元にデータを抽出し、病気の診断、治療計画、予後予測を行う手法である。

本稿では、はじめに Radiomics のがんの診断における応用例を概説する。画像データから抽出される特徴量が、患者背景や腫瘍の生物学的性質とどのように関連しているかに注目し、がん診療における Radiomics の意義を示す。次に、予後予測における Radiomics の導入事例を紹介し、その結果から得られる臨床的な意義について述べる。最後に、Radiomics 技術の現状と今後の展望について考察する。本稿では放射線治療医の視点から放射線治療における Radiomics のさらなる発展に向けた提案を行う。

## 2. 診断補助ツールとしての Radiomics

がん診療において、がんの診断を正しく行うことは非常に重要である。診断という点とまずは肺癌である、胃癌である、というような病名の診断が想像しやすいが、治療方針の決定にはより詳細な診断プロセスが必要である。まず病理診断により胃の腺癌、肺の扁平上皮がんといった組織型の診断を行う。組織型により最適な化学療法が異なるため組織診断は必須のプロセスである。さらに近年では、HER-2 陽性の胃がん、EGFR 遺伝子変異陽性の肺腺癌というように、遺伝子プロファイルに関する診断が治療方針の決定に重要となってきた。さらに、それぞれの癌で病期診断を行うことで、手術を行うのか、放射線治療を行うのか、化学療法を行うのか、最適な治療方針を決定することになる。この診断プロセスに関する Radiomics の報告に関していくつか具体例を挙げる。

Liu らは 486 例の肺癌患者の CT 画像を用いて、その組織型が小細胞肺癌であるか、非小細胞肺癌であるか、ROC 曲線の AUC:0.82 と高精度に予測できることを報告している [1]。また Zhu らは 129 例の非小細胞肺癌患者の CT 画像を Radiomics 解析することで腺癌であるか扁平上皮癌であるか、AUC:0.89 と高精度に予測できると報告している [2]。実際に肺癌患者の画像を見た際に、末梢性か中枢性か、リンパ節転移がどこに分布しているかなどの所見から、医療者の経験則でも組織型をある程度想像できることがあるが、これほどの精度ではないため Radiomics の技術が示された一例と考える。しかし、通常治療前には組織を採取してこれらの情報を得ることはほとんどの場合で可能であり、仮に組織が取れない場合においても、血液検査で得られる腫瘍マーカーからより高精度に組織を予測することは可能であるため、このような Radiomics 技術の活用が診断補助ツールとしての有用性が高いとは言い難い。

Wang らは 844 例の肺腺癌患者の CT 画像をもとに、分子標的薬の適応に関わる EGFR 遺伝子変異の

有無を AUC:0.81 と高精度に予測できることを報告している [3]。さらに Zhu らは免疫療法の効果を予測する PD-L1 の発現の程度を AUC:0.76-0.78 の精度で予測可能であることを報告している [4]。通常の組織診断と比べこのような分子病理診断は、遺伝子検査が高額であることもあり、治療方針の決定に重要な IV 期の患者では通常行われるが I-III 期の患者では必ずしも行われていない。また病理検体量の不足により IV 期の患者でも行えないこともある。そのような現状で分子病理診断が Radiomics 技術で高精度に行うことが可能であれば、治療方針の決定に役に立つ可能性がある。現状では治療方針の決定は組織検体の病理診断に基づく必要はあるが、再度侵襲的な検査を行うか等、治療方針の決定に重要な診断補助ツールとなる可能性があると言える。

こうした診断補助ツールとしての Radiomics が診療支援に最もつながるのは、病期診断と思われる。例えば、早期乳癌では乳房部分切除に加え、腋窩リンパ節転移の有無を確認するためセンチネルリンパ節生検で、腋窩リンパ節を摘出することが一般的であるが、腋窩リンパ節転移の有無を高精度に予測可能であれば、腋窩リンパ節の摘出を省略し、低侵襲な治療が実現できる可能性がある。Chen らは病理学的に腋窩リンパ節転移の有無が確定した 410 例の手術前 MRI 画像から腋窩リンパ節転移の有無を Radiomics 解析で予測し、Radiomics モデルで AUC:0.81、臨床因子と組み合わせた Combined model で AUC:0.86 と高精度に腋窩リンパ節転移の有無を予測できることを報告している [5]。このような予測技術は、現在低侵襲治療が開発される中で、腋窩リンパ節生検省略のための診断補助ツールとして治療方針の決定に大きく関与する可能性がある素晴らしい技術と考える。

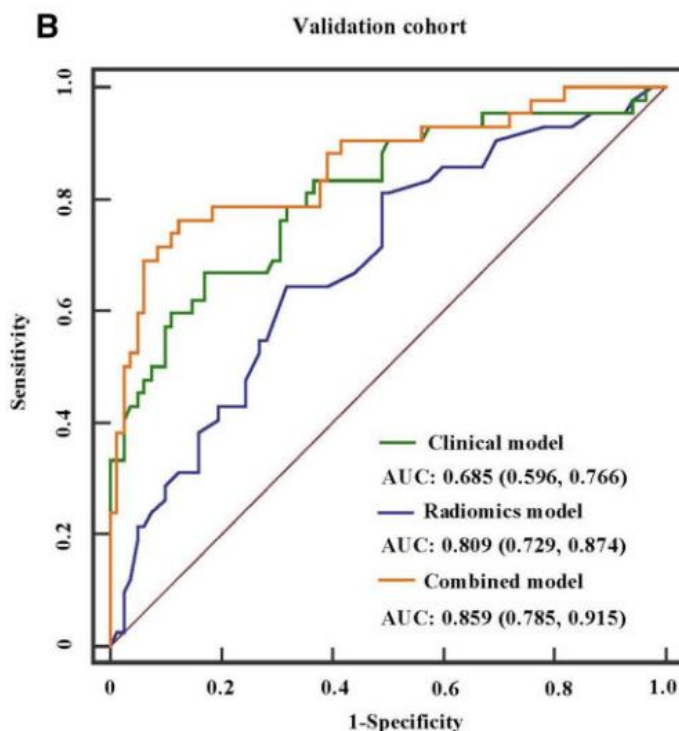


図 1. 早期乳がんの術前 MRI による腋窩リンパ節郭清の予測モデル

臨床因子のみで作成した Clinical モデルと比較して、Radiomics モデル、臨床因子と Radiomics を組み合わせた Combined model で高精度な予測が可能となっている。

### 3. Radiomics による予後予測

Radiomics と放射線治療の研究に関して現在最も多く報告されているのは Radiomics による予後予測の報告である。予後予測には再発予測や生存予測、有害事象予測があり、放射線治療に関連する報告も多く報告されている。再発予測に関する報告として Kawahara らは子宮頸癌に対する再発予測に関して 89 例の子宮頸癌患者の放射線治療前の MRI 画像を Radiomics 解析し、放射線治療後の再発を AUC:0.94 と高精度に予測できることを報告している [6]。生存に関する予測に関して、Yu らは 228 例の定位放射線治療を受けた早期肺癌患者の生存割合に関して治療前の PET/CT の Radiomics 解析を行い、生存割合を AUC:0.80 と高精度に予測できることを報告している [7]。有害事象に関する報告として、Kawahara らは根治的放射線治療を受けた肺癌患者 98 例の治療計画 CT 及び治療計画情報を用いて、Grade2 以上の肺臓炎の発症率に関して Radiomics 解析を行い、肺臓炎の発生を AUC:0.84 と高精度に予測できることを報告している [8]。本報告では、画像情報のみではなく放射線治療のターゲット情報や、線量に関する情報を解析に含め、多数の解析領域を同時に解析する Multi-region radiomic analysis という手法を用いることで従来の報告よりも高精度に肺臓炎を予測することを可能にしている。

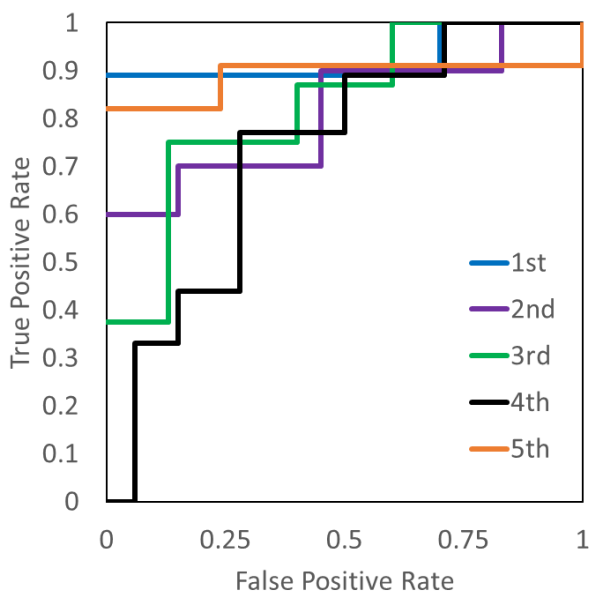


図 2. 局所進行肺癌の放射線治療前 CT 及び治療計画情報による肺臓炎予測モデル

CT 画像のみではなく放射線治療計画によるターゲットや線量の情報に基づく解析領域を作成し、多数の解析領域を Radiomics 解析する Multi-region radiomic analysis を用いて従来の肺臓炎より高精度に肺臓炎を予測することが可能となっている。

こうした再発予測、生存予測、肺臓炎予測に基づき、患者の予後を予測することができれば、治療強度の決定や、経過観察の頻度に関する有益な情報となる可能性がある。さらに直接的に治療方針の決定につながる可能性がある報告として、Murakami らは、術前化学放射線療法後に手術を受けた 98 例の食道癌患者の治療前 PET 画像を用いて Radiomics 解析を行い、手術時の病理学的な癌の消失を AUC:0.95 と高精度に予測できることを報告している [9]。このような病理学的な癌の消失を予測することが可能となれ

ば手術を回避することで食道を温存できる可能性があり、将来的にこのような技術が発展すれば治療方針の決定に大きく寄与する可能性がある。




図2. 食道癌の術前化学放射線治療前の PET による腫瘍消失の予測モデル

治療前の PET 画像から術前化学放射線量で病理学的に癌が消失するかを高精度に予測する報告である。さらなる検証を重ね有用性を示すことができれば、将来的に手術の回避につながる可能性がある。

#### 4. 治療支援ツールとしての Radiomics

正確な診断を行い、予後を正しく予測した上で、その次の課題は治療成績の向上である。上記で示したリンパ節転移を予測することで治療方針決定に携わるような報告、術前化学放射線療法で癌の病理学的な癌の消失を予測し、手術の回避ができる可能性がある報告等に関しては、今後の発展により治療方針の決定に大きく関わる可能性があり、これらの技術により低侵襲な治療を施行できる可能性がある。しかし、Radiomics により再発を低下させる、あるいは生存を改善させるという技術は現時点では実臨床に応用されていない。Radiomics の技術により、治療前の画像と放射線治療計画情報を解析することで、再発予測、生存予測が可能であるという技術があれば、画像と治療計画情報から、再発リスク、生存割合を予測し、より再発率が低い治療計画、より長期生存を実現させる治療計画を Radiomics の技術を用いて提案する事が可能になれば技術の大きな転換点になると考える。正確な診断や予後予測を行う現在の診断支援ツールとしての Radiomics から、治療成績改善のためのより良い治療を提案する治療支援ツールとしての Radiomics を開発することが次の Radiomics のゴールと思われる。

#### 5. おわりに

技術の発展は目覚ましく、Radiomics 技術を用いて、大量の情報から正確な診断、予後予測を行うことが可能になってきた。より正確な診断、予後予測のためには良質で大量なデータを用いることが重要であり、現在多くの施設で各々 Radiomics 解析が行われている状況であるが、最終的にはより統合的な Big data を構築し共同で精度の高い技術開発をすることが望ましいと考える。

がんの病期分類も全世界の予後に関わる膨大な情報を世界各国が共同で解析することで世界共通の病期分類が示されている。従来はがんの大きさやリンパ節転移の有無といった単純な尺度で病期分類が行われていたが、より精密な予測のために様々な因子が解析され、近年では遺伝子情報が組み込まれ始めている。Radiomics がこれほど正確に予後を予測するツールであるならば、病期分類に採用されないまでも、病期分類と並んで予後予測に欠かせない技術として位置づけられる可能性がある。

Radiomics 技術の今後の発展が世界の多くの患者に利益をもたらすためには、世界中の研究者が共同で技術開発を進めることが不可欠である。そして最終的には、治療方針の提案が可能な治療支援ツールとしての役割を果たすことに期待したい。

## 6. 参考文献

1. Liu S, Liu S, Zhang C, et al. Exploratory Study of a CT Radiomics Model for the Classification of Small Cell Lung Cancer and Non-small-Cell Lung Cancer. *Front Oncol.* 2020;10:1268.
2. Zhu X, Dong D, Chen Z, et al. Radiomic signature as a diagnostic factor for histologic subtype classification of non-small cell lung cancer. *Eur Radiol.* 2018;28(7):2772-2778.
3. Wang S, Shi J, Ye Z, et al. Predicting EGFR mutation status in lung adenocarcinoma on computed tomography image using deep learning. *Eur Respir J.* 2019;53(3):1800986.
4. Zhu Y, Guo YB, Xu D, Zhang J, Liu ZG, Wu X, Yang XY, Chang DD, Xu M, Yan J, Ke ZF, Feng ST, Liu YL. A computed tomography (CT)-derived radiomics approach for predicting primary co-mutations involving TP53 and epidermal growth factor receptor (EGFR) in patients with advanced lung adenocarcinomas (LUAD). *Ann Transl Med.* 2021 Apr;9(7):545.
5. Chen W, Lin G, Kong C, et al. Non-invasive prediction model of axillary lymph node status in patients with early-stage breast cancer: a feasibility study based on dynamic contrast-enhanced-MRI radiomics. *Br J Radiol.* 2024;97(1154):439-450.
6. Kawahara D, Nishibuchi I, Kawamura M, et al. Radiomic Analysis for Pretreatment Prediction of Recurrence Post-Radiotherapy in Cervical Squamous Cell Carcinoma Cancer. *Diagnostics (Basel).* 2022;12(10):2346.
7. Yu L, Zhang Z, Yi H, et al. A PET/CT radiomics model for predicting distant metastasis in early-stage non-small cell lung cancer patients treated with stereotactic body radiotherapy: a multicentric study. *Radiat Oncol.* 2024;19(1):10.
8. Kawahara D, Imano N, Nishioka R, et al. Prediction of radiation pneumonitis after definitive radiotherapy for locally advanced non-small cell lung cancer using multi-region radiomics analysis. *Sci Rep.* 2021;11(1):16232.
9. Murakami Y, Kawahara D, Tani S, et al. Predicting the Local Response of Esophageal Squamous Cell Carcinoma to Neoadjuvant Chemoradiotherapy by Radiomics with a Machine Learning Method Using 18F-FDG PET Images. *Diagnostics (Basel).* 2021;11(6):1049.

# Radiomics 特徴計算ライブラリ : RadiomicsJ

Visionary Imaging Services, Inc. **小林 達明**

## 1. はじめに

Radiomicsという概念は、2012年Lambinら [1]により提唱された。Radiomicsとは、放射線医学の「Radiology」と、生物学分野におけるデータを統合し網羅的に解析する研究領域を意味する「-omics」とを掛け合わせた造語である。組み合わせられた言葉の意味の通り、大量の医用画像から抽出した高次元の定量的な特徴を用いて網羅的な解析を行い、対象とする個体の遺伝子型 (genotype) や遺伝子型に基づいて発現する生物の形質-実際に観察できる形質-としての表現型 (phenotype) を読み解くことを目的とした研究分野である。手術や検査の非侵襲性の追求や、治療や診断の意思決定ワークフローの高効率化、個別化医療の発展などに寄与することが期待されている。対象を遺伝子型とした場合はRadiogenomicsとも呼ばれる。

具体的な事例として、Grade2,3脳腫瘍の1p/19q

共欠失分類を紹介する。Grade2,3の脳腫瘍では、染色体の1pと19qが共に欠失している場合に化学療法感受性が高いことが知られている。しかし、1p/19qの共欠失を調べるためには分子診断が必要となるため、腫瘍組織サンプルを採取(サンプリング)しなければならない、侵襲的であること、また、サンプリングの位置が適切でなかった場合には正確な診断ができないという課題がある。これに対して、腫瘍全体を巨視的に捉えることができるMR画像から1p/19q共欠失を高精度に推論できる予測器(モデル)が作成可能であるならば、MR画像のみから1p/19q共欠失を非侵襲的に予測可能になることが期待できる。このようにアプローチしていくのがRadiomicsの研究である。

次に、医用画像から抽出した“高次元の”定量的な特徴とは何かについて解説する。定量的な特徴には、最大値や最小値などの基本的な記述統計量、

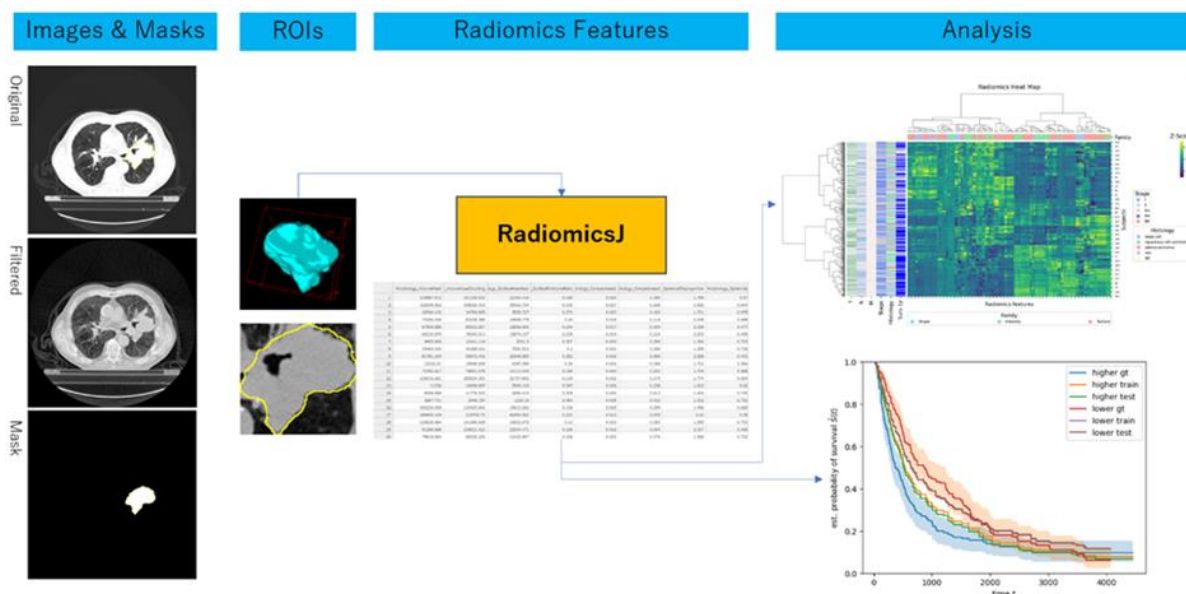


図1. Radiomics ワークフローイメージ

skewness や kurtosis などのヒストグラムから得られる特徴, 体積などのモルフォロジカルな特徴-形状から得られる特徴-, 見た目のパターンを定量化するテクスチャ特徴などがある. 一枚の画像あるいはスタック画像の関心領域から, 数百から数千の特徴が計算可能であることから, 一つの個体を説明するための特徴の次元が数百から数千あるという解釈ができる. これが高次元と呼ばれる所以である. 昨今では, Wavelet フィルターなどを用いた多様な画像フィルター特徴 [2], 深層特徴 [3], 構造的な情報を定量化するホモロジカルあるいはトポロジカルな特徴 [4]なども報告されている.

画像から得られる特徴は, 目的の遺伝子型や表現型に対して重要な予測因子 (radiomic signature) となる可能性を持つことから, 別名“イメージング・バイオマーカー” (imaging biomarker [5]), “画像バイオマーカー” (image biomarker [6]) と呼ばれる. 例えば, NSCLC (non-small-cell lung cancer, 非小細胞肺癌) の事例では, 予後予測因子として GLRLM (Gray Level Run Length Matrix) の Gray Level Non Uniformity という特徴が, 画像バイオマーカーになりうる事が報告されている [2]. リンパ節転移を対象とした Gray Level Co-occurrence Matrix による可視化マップなども転移の有無の診断に有用である可能性が示唆されている [7].

現状, Radiomics はオンコロジー領域で活発に研究が行われているが, がんだけでなく, 表現型の捉え方次第で様々な応用が可能である. 先に紹介した Grade2,3 脳腫瘍を対象とした 1p/19q 共欠失分類の場合, 当然ながら, 医用画像は MR 画像, 表現型は 1p/19q 共欠失の有無ということになるが, 表現型を柔軟に解釈すれば, 例えば, 骨粗しょう症のグレード分類 [8], 脳年齢の予測 [9] や認知症の予後予測 [10], 糖尿病のリスク評価 [11], 冠動脈プラークのリスク評価 [12], 慢性閉塞性肺疾患の肺機能評価予測 [13] など, 多岐に渡る応用

が可能である. 医療従事者であれば思い浮かぶような日常のクリニカル・クエスションからアイデアの着想を得ることができることも Radiomics の魅力の 1 つである.

一方で, 実践するための課題も存在する. Radiomics を実践するためのワークフロー (図 1) は複雑であり, 利用するモダリティやツールによって, 結果にばらつきが生じてしまうことが知られている [14]. このような課題に対処するために, Imaging Biomarker Standardisation Initiative (IBSI) という国際共同研究グループが, スイス国立科学財団 (Swiss National Science Foundation) とスイス個別化医療ネットワーク (Swiss Personalized Health Network) から主な支援を受け発足された. IBSI は, Radiomics を対象に, 画像バイオマーカーの抽出の標準化に取り組むことを目的として活動している. 具体的には, 画像バイオマーカーの定義, ベンチマークとなるデータセット, 画像処理や画像バイオマーカー計算を検証するためのベンチマーク値, その他ガイドラインを提供することを目的として, リファレンスを作成・公開している. 一般に知られている Medical Imaging Interaction Toolkit (特に Radiomics 特徴計算機能部分) や PyRadiomics などのツールは IBSI リファレンスによる検証結果を公開している. このようなツールのうちの 하나가, RadiomicsJ [15] である.

RadiomicsJ は, Radiomics 特徴計算ライブラリの選択肢を増やすこと, および医用画像研究コミュニティの科学探求における相互作用の活性化を主な目的として Visionary Imaging Services, Inc. により開発された IBSI Implementations ヘリストされた本邦初の Radiomics 特徴計算ライブラリである. 非推奨となっている特徴を除いて, IBSI にリストされているすべての特徴が計算可能であるだけでなく, IBSI にリストされていない Fractal 特徴 (2D/3D) も計算可能である. ソースコードは, 依存ライブラリを除いて, 100% Java で開発され



ており、Javaをはじめ、プログラミング技法が類似している C/C++、C#のユーザーコミュニティにとってのリソースとしても貢献することが期待される。RadiomicsJは画像処理のBackendとしてImageJを採用しており、8, 16, 32 bitの画像(すなわち、CT, MRI, PETなどの一般の放射線画像などを含めて、様々な画像を入力可能)を処理できる。画像フィルター特徴については、入力画像を事前に画像処理フィルターで処理しておくことで取得可能であり、ImageJに搭載されている豊富な画像処理フィルターを用いることができる。ImageJに標準搭載されていないWaveletフィルターは、ImageJプラグインを利用することで導入可能である。

## 2. Radiomics を実践するために

Radiomics を実践するためのパイプラインは、大きく、画像収集、画像前処理、特徴計算、機械学習に分けられ、それぞれのフェーズで適切なツールを用いる必要がある。

### ● 画像収集

臨床研究におけるワークフローを想定した場合、DICOM サーバへの Query Retrieve による効率的な画像収集、および、目的変数や臨床的な情報を表に整理する。初学者の場合は、Weka, Scikit Learn に含まれるサンプルデータや、The Cancer Imaging Archive (TCIA)データセットなどを用いて操作を体験しておくことで、自身で準備しなければならないデータセットの把握をしやすくなる。

### ● 画像前処理

DICOM ビューワやワークステーションを用いて画像サイズのリサンプリングやセグメンテーション、レジストレーションなどの前処理を行う。

### ● 特徴計算

特徴計算のための適切なハイパーパラメータを設定し、計算を実行する。例えば、特徴計算全般に影響する外れ値処理や、テクスチャの計算に影響

する離散化の方法などが挙げられる。また、テクスチャ特徴の場合は、離散化だけでなく、探索するボクセルの距離なども検討可能である。

### ● 機械学習

推論モデルを作成し、検証する。ツールとしては、Java では、Weka や SMILE(Statistical Machine Intelligence and Learning Engine)、Python では Scikit Learn や PyCaret などがよく利用されている。

## 3. 具体的な事例 (NSCLC-Radiomics)

TCIA から公開されている NSCLC-Radiomics データセット [16]を用いて生存時間解析を行った例を紹介する。データ収集は TCIA のデータリトリーバを使用し、データはローカル環境へダウンロードした。特徴計算は RadiomicsJ、生存時間解析は Scikit survival (Python)を用いた。Python が得意な方は、特徴計算に PyRadiomics を用いるのも効率的である。ただし、執筆時点(2024/2/29)で PyRadiomics は 2D/3D Fractal 特徴や Gray Level Distance Zone Matrix 特徴が実装されていないため、これらの特徴は計算できない。

RadiomicsJ は画像特徴を計算することを目的としているため、利用者にはプログラミングスキルが必要となる (Appendix A)。具体的なスクリプト例は GitHub (<https://github.com/tatsunidas/>) や ハンズオンにて公開・共有予定である。

それでは、抽出済みの画像特徴がどのようなデータになっているのかを確認していく。一般には、患者分布を、全体、訓練、検証、テストのデータセットごとに統計解析して提示するのが通例ではあるが、本記事では、視覚的に印象に残りやすいと考えられた Radiomics Heat Map (Radiomics Cluster Map)を紹介する(図2)。行方向は被験者、列方向は Radiomics 特徴に対応している。カテゴリーはそれぞれ、Family は特徴ファミリー、TNM 分類、がんのステージ、Histology-がんの組織タイ




図 2. Radiomics Heat Map (seaborn.clustermap 関数を利用)

プ-, 一年生存有無を表している。このクラスタマップがまったくランダムであれば、このデータセットに規則性がないということになるが、見ての通り、Radiomics 特徴が、上下、左右に分かれたクラスタの形成に役立っていることがわかる。

Hugo J. W. L. Aerts ら [2]は、このデータセットを用いて Cox proportional hazards regression model にて生存時間解析を行い、腫瘍内不均一性を定量化する 4 つの重要な予測因子(つまり、4 つの画像特徴)を報告している。本記事では、例として、この 4 因子のうちの一つである GLRLM Gray Level Non Uniformity に着目し、生存時間解析を行った結果を示す。腫瘍内不均一性を定量化する GLRLM Gray Level Non Uniformity が生存時間に関係しているとすれば、この数値の大小によって、被験者グループをよく層別化することに役立つ可能性がある。先駆者に倣い、この特徴のみを利用して Cox proportional hazards regression model を訓練し、特徴の中央値以上のグループと未満のグループとで層別化し、それぞれの予測結果を比較

した(図 3)。7 割を訓練、残り 3 割をテストに用いた。図 3 の higher gt は中央値以上グループの Ground Truth, higher train は中央値以上グループの訓練データ予測結果, higher test は中央値以上グループのテストデータ予測結果を示す。もう一方は、中央値未満グループに対応している。作成したモデルは、訓練データ(C-Index=0.60)、テストデータ(C-Index=0.54)の予測精度であった。層別化したデータを入力して得られた予測結果は、




図 3. 推論モデルによる Kaplan-Meier 曲線

両グループともに、Ground Truth の Kaplan-Meier 曲線から大きく外れていないことがわかる。中央値よりも高い群の方が低い群に比べて予後の伸びしろが長くみえるものの、低い群の方が、傾きが緩やかで予後が良い傾向が伺える ( $p < 0.05$ )。

以上、実践例の解説を試みたが、学際的な面白さを共感いただけただろうか。紙面の都合上、詳細を記載できていないことはご容赦願いたい。なお、NSCLC-Radiomics データセットは、radiation のみと concurrent chemoradiation の治療群に分けることができるはずであるが、公開されている Clinical データには記載が見当たらなかった。もしこれらのラベルがわかれば、比較をしてみると自己研鑽になるかもしれない。

ここでは生存時間解析例を示したが、良悪性分類、悪性度のカテゴリー分類、リスク評価、XX-RAD (例えば、BI-RADS, PI-RADS など) のスコア予測など、生存時間解析以外にもさまざまな課題にチャレンジできることを想像していただければ幸いである。

#### 4. GUI による操作

GUI(Graphical User Interface)による操作は、画像特徴の計算を目的とした場合にはほとんど利用されないと考えられるが、生データの絶対値がどのくらいの大きさであるかを把握しておきたい場合には有用な手段となる。RadiomicsJ は ImageJ プラグイン (Appendix B) として動作させることができ、処理結果を CSV 形式で保存可能である。図 4 は、左から CT 画像、マスク画像、RadiomicsJ プラグイン起動画面、図 4 下段中央は、処理結果の ResultsTable が表示されている。図 4 左下は WW/WL を MinMax レンジで自動コントラスト調整したクロップ画像例を示す。16 bit CT 画像を 8 bit にダウンスケールする際はコントラストに気を配る必要がある。

#### 5. コミュニティへの貢献

Radiomics には、学際的な面白さとは別のメリットがある。それは、主な成果物となる推論モデルをプログラム医療機器化できるという生産性を提供する点である。医療専門職による院内ワークフロー細分化により、診療放射線技師は、一般に、他の職種に比べ放射線医学画像データを扱うことに長けており、モダリティや画質についてはプロフェッショナルである。検査を提供することに加えて、医用画像を用いた医療 AI (または医用 AI) を検証する、開発する、あるいは、研究することができる人材としてのポテンシャルがある。この長所は、機械学習時のデータの収集・整理や標準化に適切に対応するための人材としての期待をもたらしている。また、近年ではリカレント教育のニーズが高まり、大学院で学ぶ環境も整いつつある。このようなアドバンテージを生かして Radiomics に取り組むテクノロジストが増えてほしい。そして、Radiomics に取り組む際は、RadiomicsJ のユーザーになっていただくと大変有難い。RadiomicsJ はオープンソースであり、無償で利用できる。

ライブラリとして改良すべき点が多いことは自覚している。特殊な画像フィルター特徴、3D テクスチャ特徴の多彩な集約方法、テクスチャ特徴の重みづけ、ホモロジカル/トポロジカルな特徴、深層特徴などは未実装である。開発者自身にとっても一番使いたいと思えるツールとなるように、ユーザビリティの向上や機能改良のための開発を継続していきたい。

#### 6. おわりに

Radiomics を通じた医療 AI の経済成長が、患者、医療機関・研究機関、アカデミア、企業などの全体にとってのアップストリームになることを期待している。

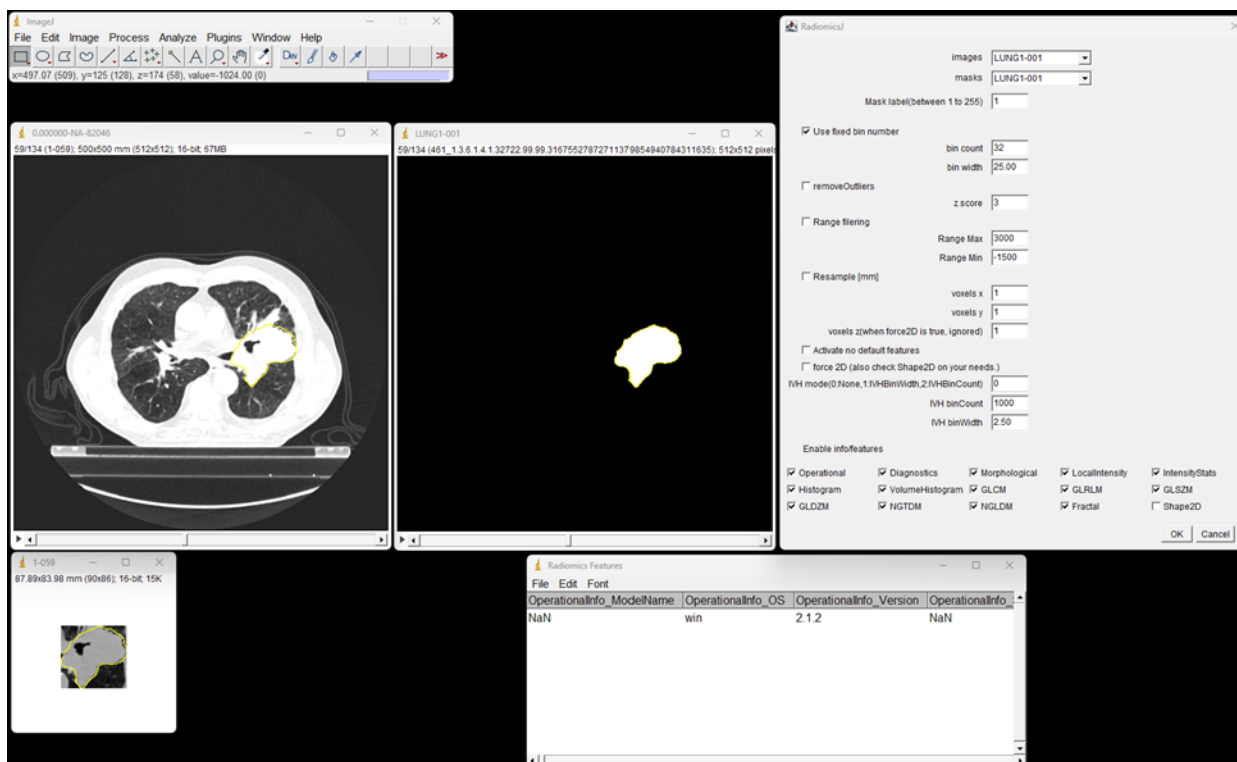


図 4. RadiomicsJ ImageJ プラグインの動作画面例

## 参考文献

- [1] Lambin P; Rios-Velazquez E; Leijenaar R. et al, "Radiomics: extracting more information from medical images using advanced feature analysis," *Eur J Cancer*, vol. Mar;48, no. 4, pp. 441-6, 2012.
- [2] HJ, Aerts; ER, Velazquez; RT, Leijenaar. et al, "Decoding tumour phenotype by noninvasive imaging using a quantitative radiomics approach," *Nat Commun*, no. 5, p. 4006, 3 Jun 2014.
- [3] Salmanpour MR; Rezaeijo SM; Hosseinzadeh M; Rahmim A., "Deep versus Handcrafted Tensor Radiomics Features: Prediction of Survival in Head and Neck Cancer Using Machine Learning and Fusion Techniques," *Diagnostics (Basel)*, vol. 13, no. 10, p. 1696, 11 May 2023.
- [4] Kodama T; Arimura H; Shirakawa Y; Ninomiya K; Yoshitake T; Shioyama Y., "Relapse predictability of topological signature on pretreatment planning CT images of stage I non-small cell lung cancer patients before treatment with stereotactic ablative radiotherapy," *Thorac Cancer*, 第 13 卷, 第 15, pp. 2117-2126, Aug 2022.
- [5] Sullivan DC; Obuchowski NA; Kessler LG; Raunig DL; Gatsonis C; Huang EP; Kondratovich M; McShane LM; Reeves AP; Barboriak DP; Guimaraes AR; Wahl RL; RSNA-QIBA Metrology Working Group., "Metrology Standards for Quantitative Imaging Biomarkers," *Radiology*, 第 277 卷, 第 3, pp. 813-25, Dec 2015.
- [6] Alex Zwanenburg; Stefan Leger; Martin Vallières; Steffen Löck., "Image biomarker

- standardisation initiative Reference Manual," *arXiv*, p. 1612.07003, 17 Dec 2019.
- [7] RJ, Gillies; PE, Kinahan; H, Hricak., "Radiomics: Images Are More than Pictures, They Are Data," *Radiology*, vol. 278, no. 2, pp. 563-77, Feb 2016.
- [8] Wang, J; Zhou, S; Chen, S. et al, "Prediction of osteoporosis using radiomics analysis derived from single source dual energy CT," *BMC Musculoskelet Disord*, vol. 24, no. 100, 2023.
- [9] M, Bretzner; AK, Bonkhoff; MD, Schirmer. et al, "Radiomics-Derived Brain Age Predicts Functional Outcome After Acute Ischemic Stroke.," *Neurology*, vol. 100, no. 8, pp. e822-e833, 21 Feb 2023.
- [10] Chaddad, A; Toews, M; Desrosiers, C; Niazi, T. et al, "Deep Radiomic Analysis Based on Modeling Information Flow in Convolutional Neural Networks," *IEEE Access*, no. 7, pp. 97242-97252, 2019.
- [11] Lu CQ; Wang YC; Meng XP. et al, "Diabetes risk assessment with imaging: a radiomics study of abdominal CT," *Eur Radiol*, vol. 29, no. 5, pp. 2233-2242, May 2019.
- [12] Polidori, T; De Santis, D; Rucci, C. et al, "Radiomics applications in cardiac imaging: a comprehensive review," *Radiol med*, no. 128, p. 922-933, 2023.
- [13] KJ, Lafata; Z, Zhou; JG, Liu; J, Hong; CR, Kelsey; FF, Yin., "An Exploratory Radiomics Approach to Quantifying Pulmonary Function in CT Images," *Sci Rep*, vol. 9, no. 1, p. 11509, 8 Aug 2019.
- [14] Zwanenburg A; Vallières M; Abdalah MA. et al, "The Image Biomarker Standardization Initiative: Standardized Quantitative Radiomics for High-Throughput Image-based Phenotyping," *Radiology*, vol. 295, no. 2, pp. 328-338, May 2020.
- [15] T.Kobayashi., "RadiomicsJ: a library to compute radiomic features," *Radiol Phys Technol*, vol. 15, no. 3, pp. 255-263, Sep 2022.
- [16] Aerts, H. J. W. L.; Wee, L.; Velazquez, Rios. et al, "Data From NSCLC-Radiomics (version 4) [Data set]," *The Cancer Imaging Archive*, 2014.

#### Appendix A: Maven プロジェクトからの利用方法

- Eclipse や IntelliJ を用いて Maven プロジェクトを作成する。
- Maven リポジトリの RadiomicsJ を pom.xml の依存関係に追加する。 ※適宜, 不足している依存関係ライブラリがあれば追加する。  

```
<groupId>io.github.tatsunidas</groupId>
<artifactId>radiomicsj</artifactId>
<!--最新バージョン推奨 -->
<version>2.1.3</version>
```

#### Appendix B: RadiomicsJ ImageJ プラグインの導入方法

- RadiomicsJ(<https://github.com/tatsunidas/RadiomicsJ>)にアクセスし, Releases から最新の RadiomicsJ{バージョン}.jar, および extenal-libs から jog-fat.jar を入手する。
- RadiomicsJ{バージョン}.jar および jog-fat.jar を ImageJ の plugins フォルダ内の jars フォルダへコピーする。
- GitHub の ImageJ プラグインソース (<https://github.com/tatsunidas/RadiomicsJ>)

[/blob/master/src/main/java/io/github/tatsunidas/ij/plugin/My\\_RadiomicsJPlugin.java](#))

を ImageJ の plugins フォルダの任意の場所 (例えば Examples フォルダ) へコピーし、ImageJ>Plugins>Compile and Run... からソースコードをコンパイルする。

- ImageJ を起動し、画像とマスクを開いた状態で、メニューの PlugIns>Examples から My\_RadiomicsJPlugin を実行する。



筆者略歴

小林 達明 (Tatsuaki Kobayashi)

*Radiological Technologist,*

*Oracle Java 11 Gold Programmer,*

*Visionary Imaging Services, Inc. CEO & Founder.*

2006 年 3 月に昭和大学附属診療放射線専門学校にて診療放射線技師免許を取得。2007 年から現在まで JSRT 会員。5 年間の臨床経験を経たのち、2013 年 3 月に北里大学大学院医療系研究科医科学修士を修了。2023 年 3 月に横浜国立大学情報環境専攻にて博士号 (情報学) を取得し、現在は会社経営、大学院講師 (非常勤: 予定)、クリニックでの放射線技師 (非常勤) を兼務。医用画像情報を専門として、DICOM ビューワや PACS の開発に取り組んでいる。

## 循環器領域における Spectral CT 7500 の有用性

株式会社フィリップス・ジャパン CT モダリティセールススペシャリスト **山口 優輝**

### 1. はじめに

フィリップスは2021年にSpectral CT 7500の販売を開始した(図1)。Spectral CT 7500は、2層検出器を搭載したスペクトラルCTである。スペクトラルCTでは、スペクトラルスキャンの事前オーダーは必要なく、全例で後ろ向きにスペクトラル画像が取得可能である。そのため、CT検査のワークフローを損なうことなく、スペクトラル画像のルーチン運用を実現する。また、スペクトラル画像の取得に伴う撮影条件の制限がないため、心電図同期撮影においても、エネルギーデータに時間的・空間的ミスレジストレーションのない高精度なスペクトラル画像が取得可能であり、循環器領域においても多くの臨床的有用性を有する。本稿では、Spectral CT 7500の循環器領域における有用性について紹介する。




図1:Spectral CT 7500

## 2. Spectral CT 7500 の特長

### ① 「NanoPanel Prism」

Spectral CT 7500 は2層検出器である「NanoPanel Prism」を搭載した。「NanoPanel Prism」(図2)はX線を検出するシンチレータが2層の異なる素材で構成されている。管球から連続X線が照射されると、上層のイットリウムベースのシンチレータがX線の低エネルギー成分を、下層のGOSベースのシンチレータが高エネルギー成分を検出する。これにより、連続X線のエネルギーを分光し、2種類のエネルギーデータを取得する。2層検出器は、X線管球側でエネルギーの異なる2種類の連続X線を照射する従来のDual Energy方式とは異なり、検出器側で照射された連続X線を分光する。そのため、特殊撮影や事前オーダーは不要であり、撮影条件の制限なく、スペクトラル画像の運用を可能とする。

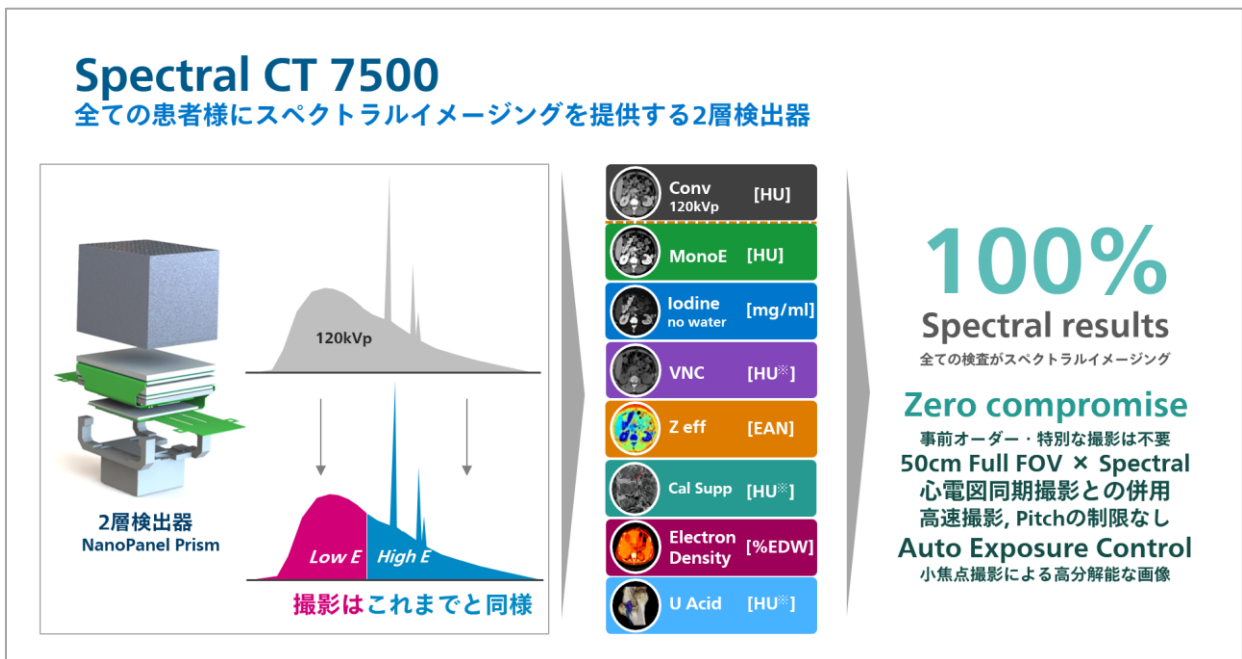


図2: 全ての患者にスペクトラルイメージングを提供する2層検出器

### ② 「Anti-Correlated Noise Reduction」

Spectral CT 7500 の画像再構成技術の中で最も重要な技術の1つが「Anti-Correlated Noise Reduction」である<sup>1)</sup>。一般的なDual Energy CT (DECT)の仮想単色X線画像は、X線管球が持つX線スペクトラムの平均エネルギー付近で最も画像ノイズが少なく、その平均エネルギーから低い、あるいは高



いエネルギー領域ではノイズが大きく増加する傾向を認める<sup>2)</sup>。図3にスペクトラル画像(SBI)の画像再構成のプロセスを示す。Spectral CT 7500では、Spectral Decompositionの計算過程において生じる特異的なノイズである「Anti-Correlated Noise」を、画像再構成段階で除去することで、ノイズの少ない基準画像(光電効果画像、コンプトン散乱)の取得が可能であり、仮想単色X線画像においても全てのエネルギーレベルにおいて臨床に対応可能なノイズの少ない画像が得られる。

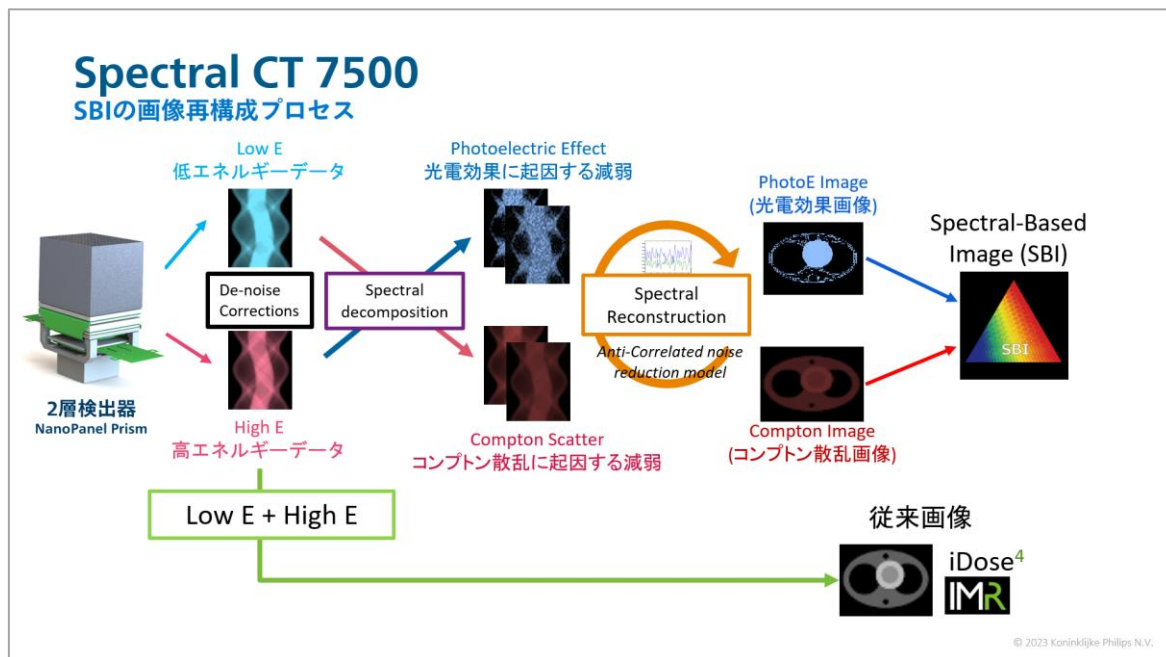


図3:SBIの画像再構成プロセス

### 3. 循環器領域におけるスペクトラル画像の有用性

#### ①造影剤量の大幅低減

虚血性心疾患の疑われる患者は高齢者が多く、腎機能が低下していることが少なくない。そのため、造影剤の使用量については、慎重に決定する必要がある。従来の Single Energy CT (SECT) において、造影剤を減量する場合、低管電圧撮影が一般的であるが、ノイズの増加によって画質の劣化が顕著となる。しかし、MonoE の低エネルギー画像は、低い画像ノイズを維持した上で、造影コントラストが向上できるため、画像コントラストを維持しながら、造影剤量の低減が可能となる<sup>3)~4)</sup>。図4に臨床症例を提示する。高齢患者であるため、造影剤量 9ml で心臓 CT 検査が実施されたが、MonoE の 50keV 画像を使用することで従来と同等の画像が得られた。




図 3: 造影剤使用量 9mL の心臓 CT 画像 (画像提供: みなみ野循環器病院)

## ②遅延造影・ECVによる心筋評価

日常臨床では、冠動脈の評価手法としては心臓 CT、心筋の評価手法としては心臓 MRI による遅延造影 (Late Gadolinium Enhancement: LGE) が広く用いられている。SECT による遅延造影 (Late Iodine Enhancement: LIE) は、120kV の撮影管電圧を使用する場合、LIE のコントラスト分解能の不足や、低管電圧撮影では、画像ノイズの増加の懸念を有する。しかし、前述した冠動脈評価時と同様に MonoE の低エネルギー画像やヨード密度画像では、ノイズを増加させることなく、造影コントラストを大きく向上させることができるため、LGE と同程度に線維化心筋を定性的に評価することができる<sup>5)</sup>。また、細胞外容積分画 (ECV) の算出においては、平衡相 1 相のヨード密度画像からヨード法で ECV の算出が可能であるため、高い精度で ECV 解析が可能であり、定性的な評価と同様に、心臓 MRI と同程度に評価することができる<sup>6)</sup>。図 4 に心アミロイドーシスの臨床症例を提示する。120kVp の従来画像ではコントラスト不足により十分な評価が難しいが、MonoE の低エネルギー画像やヨード密度画像では、ヨードの視認性が向上することでびまん性の LIE を認める。さらに、平衡相のヨード密度画像 1 相からの ECV マップも算出され、ECV 値はびまん性に著明な高値 (62.6~73.6%、基準値 23~28%) を認めた。




図 4:心アミロイドーシス(画像提供:熊本中央病院)

#### 4. おわりに

本稿では、Spectral CT 7500 の循環器領域における有用性を紹介した。Spectral CT 7500 は、心臓 CT にスペクトラル画像を適応することで、包括的な心臓 CT 検査を実現する。フィリップスは今後も、技術開発を通して、より確実性の高い循環器診断をサポートしていきたい。

#### <参考文献>

1. Kelvin M. Brown, et al. Impact of spectral separation in dual-energy CT with anti-correlated statistical reconstruction. Proceedings of the 13<sup>th</sup> international meeting on fully three-dimensional image reconstruction in radiology and nuclear medicine. 2015
2. J. Greffier, et al. Performance of four dual-energy CT platforms for abdominal imaging: a task-based image quality assessment based on phantom data. European Radiology. 2021
3. S Oda, et al. Low contrast material dose coronary computed tomographic angiography using

a dual-layer spectral detector system in patients at risk for contrast-induced nephropathy. The British Journal of Radiology. 2018

4. Xin Huang, et al. the optimal monoenergetic spectral image level of coronary computed tomography (CT) angiography on a dual-layer spectral detector CT with half-dose contrast media. Quantitative Imaging in Medicine and Surgery. 2020

5. S Oda, et al. Myocardial late iodine enhancement and extracellular volume quantification with dual-layer spectral detector dual-energy cardiac CT. Radiology: Cardiothoracic Imaging. 2019

6. T Emoto, et al. Myocardial extracellular volume quantification using cardiac computed tomography: a comparison of the dual-energy iodine method and the standard subtraction method. Academic Radiology. 2021

#### <薬事情報>

販売名：スペクトラル CT7500

医療機器認証番号：303AFBZX00042000

設置管理医療機器/特定保守管理医療機器/管理医療機器

## 第 44 回医用画像処理プログラミングセミナーを受講して

金沢先進医学センター PET 部門 武田 悟

はじめに、AI、Python、深層学習（deep leaning）などの文字が耳馴染みになり、学会でもその言葉が使われた内容が多くなり、なくてはならない状態に近づきつつある。一方、自分自身の知識のなかでは、いまいちわかっているかわかっていないかの狭間をさまよいつづけている状態である。そんな中、学会のお知らせ欄にプログラミング、画像処理の文字が目にとまり、スケジュールなど確認し自分にできるかできないかを自分に問いながら応募しました。

ここから、セミナー前や、セミナーで行ったこと、そこで得られた知識に対して記述し感想を書いています。なお、まだまだ知識の理解が足らず、誤解や、間違っていることを書いてるかもしれませんが、その点をご容赦願えたらと思います。

応募後、セミナーを有効に受講するための知識、環境整備のための案内メールが送られてきた。内容としては、セミナーのプログラムと、セミナーを受けるにあたっての環境整備と基礎知識や学習内容を記した資料とであった。セミナーを受けるにあたり環境として

- ① Python のダウンロードとインストール※バージョンの確認
- ② Colab (Google Colaboratory) の設定をする。

特徴

- Google がクラウド上で提供する開発・学習環境
- GPU が無料で利用可能（有料もあり）
- 必要なフレームワークが追加可能
- 他のユーザーが作成したコードを他の人と容易に共有できるため、コードレビューが容易にできる。

- ③ セミナーに必要なフォルダーをダウンロード※Google Drive の My drive に置く。
- ④ Slack を設定する※質問やコミュニケーションの場となる。

この環境整備は、Web 開催に合った環境だと思われた。従来の現地開催の欠点は、現地独特の雰囲気や使い慣れない PC を使うことである。それを Web で行うことで、気軽に周りの様子に気を取られることなく受講できたことである。質問も Slack で合図を送り web 環境下で個室を作り画面共有して指導を受けることができた。このことで講義に遅れることなくついていくことができた。

次に、4つの視聴動画が用意されていてセミナー当日まで個々で視聴学習をするものであった。

- ① Python の基礎
- ② 深層学習の基礎
- ③ Numpy の基礎
- ④ クラスの基礎

これらは、すでに経験や学習した人にとって知識を思い出すのに十分な内容であり、初めての人でも容易に理解できたと思われる。たとえ、理解できなくても当日には、聞いたことのある言葉であるので戸惑わず受講できたと思われた。

セミナーの内容としては、深層学習について理解を深めるために簡単な三層構造のものを使った。演習として、手書き文字認識、画像分類、超解像度とノイズ低減を行った。

深層学習には、PyTouch を使った。これは、機械学習ライブラリであり（プログラミング言語は Python）、Meta が開発したツールである。最近、これが多く使われており、使うことで最新の技術に触れたことにもなるようだ。その他、機械学習ライブラリの中に Google が開発した Keras、Tensorflow もある。

Python の基礎の復習で構文（if、for）と Class、関数の使い方、書き方と読み方を復習がおこなわれた。

深層学習学についても復習した。ニューラルネットワークは、3 層（入力層、中間層、出力層）から構成され全て結合している。

入力層では、多数の入力値に対して、適当な値で重み付けする。中間層では、入力値の和にたいして活性化関数を用いて計算し出力する。なお、中間層の階層数に規定はなく、扱う情報により階層を増やすことで複雑さを分析できるようになる。

今回の手書き文字分類と画像分類の演習で活性化関数は、畳み込み層とプーリー層に対して Linea 関数を使った。超解像度とノイズ低減の演習では、畳み込み層に Sigmoid 関数を使った。それぞれの関数の特徴は、次のものが挙げられる。Linea 関数は、入力値と出力値が同じになるようにする関数である。Sigmoid 関数は、入力値の強い値を押しつぶし、弱い値を 0-1 値に納めるようにして特徴を強調する関数である。

ここで分かったことは、手書き分類は特徴を出しやすく、3 層の階層でも特徴がとらえやすく教師データとの比較も容易である。しかし、画像になると複雑になりシルエットも複雑に変わるので活性化関数も複雑な信号に合わせて特徴を見出さなくてはならないことが解る。

つぎに出力層では、用意してあった教師データを使って出力値と比較を行って、損失関数を用いて誤差を求める。その誤差が最小になるように調整逆伝搬法（バックプロパケーション）で、重み付の微分値を求め最適化を行う。それを繰り返し行うことで結果を教師データに近づけ最適化を行う。

今回、手書き文字類と画像分類では損失関数に Cross Entropy を用いた。超解像度とノイズ低減では損失関数に平均二乗誤差を用いた。

Cross Entropy は、真の確率分布と推定した確率分布を比較するのに誤差の大きさを表す指標で分類をするとき用いられる。

平均二乗誤差は、真の確率分布と推定した確率分布を比較したとき、合っているときは値が最小になり、ズレが大きいときは強調される。ズレが強調されたデータが含まれると、予測結果が不安定になる。

最適化アルゴリズムは、Adam を使った。Adam とは、momentum SGD と RMS Prop のアイデアを融合した手法である。

これは、入力層で重み付けをしたが、教師データと比較したらズレが大きかった。だから、中間層、入力層での重みの割合を減らさなければならない、その減らす指標として勾配降下法を利用しようとする

るものである。これが示すところは、減らす割合が多いときは急降下の変化になり、減らす割合が少ないときは変化が緩やかになる具合を見るものであり、変化を早く収束させて教師データにたどり着こうとするものである。

ニューラルネットワークで勾配降下法により最適化する場合、データを1つ1つ用いて更新するのではなく、いくつかのデータをまとめて入力し、それぞれの勾配を計算した後、その勾配の平均値を用いてパラメーターの更新を行う方法のことをミニバッチ学習という。

データセットを10個のグループに分割してグループごとにミニバッチ学習を行う場合、1 epoch = 10 iterationとなる。したがって、データセットが120個あった場合、batch size が3個のとき、iteration が40回となり、epochは1回となる。

勾配降下法では、データを用いてパラメーターを一度更新することを1 iteration と呼び、データセット全体を使うことを1 epoch と呼ぶ。

これは、教師データにすぐにたどり着けば学習率はよくなり、離れていれば学習回数が多くなり学習率は悪くなることを表している。

ミニバッチ学習を用いた勾配降下法は確率的勾配降下法 (SGD : stochastic gradient descent) と表す。さらには、Momentum はSDGに「慣性」と「速度」の概念を付け足したアルゴリズムです。ここで示される「速度」は、学習率/勾配を表すことができる。この方法は、学習の勾配の最も大きな重みのベクトルに更新していくので最も早く損失関数の最小にたどり着くことができる。しかし、学習が進み勾配が小さくなると大きなベクトルを示す特性上、損失関数の最小になかなか収束せず、学習も収束しなかった。そこで、速度の遅いところでは0-1未満の計数をかけて、その時刻に速度をたすことで「慣性」を表し、ばらつきを抑えることができ学習も収束しやすくなった。

Adagard は、Momentum とは違い、学習が進むにつれて学習係数を小さくしていくやり方である。しかし、パラメーターごとに見かけの学習率を設けることで単調な減少になり、変化があっても変化を表せなくなる欠点があった。

RMS Prop は、Adagard に移動平均を導入することである。古い時間の情報に減衰率がかかり、過去の時間の影響がどんどん薄まっていくことである、そのため、プラトー状態で学習率が上がらなかったことから、過去の影響を排除することで見かけ上に学習率を上げることができた。

Adam は、Momentum の挙動のように早く学習が進む利点と、RMS Prop のように勾配の緩やかなところでも、とどまることなく学習が進む傾向を示す両方の良さを併せ持つ方法であるので、最適化法で選択されることが解った。

ここで学んだ知識を踏まえ演習問題を行った。さらに自己学習で感じたことや分かったことを述べていく。

## 演習問題

### 1. 手書き文字認識

0から9の手書きの数字を認識する深層学習を行っていきます。

MIST (modified National Institute of Standard and Technology) 分類

NST アメリカ国立標準技術研究所が保有  
手書き文字画像のデータから作成

特徴

- データセットの種類：クラス分類
- 0～9のどれかを認識するタスク
- 画像枚数（学習用）：60000枚
- 画像サイズ：28×28のグレースケール画像

誤差を計算する損失関数に Cross Entropy を設定します。

① このモデルの中間層のユニットの数を 100 個で実行し、最後の精度 (accuracy) が変わるでしょうか？

Epochs :	Loss :	Accuracy :
10	0.14235882759094237	95.61% (9561/10000)
20	0.08772546648979188	97.27% (9727/10000)
100	0.07883726954460143	98.19% (9819/10000)

② このモデルの中間層のユニットの数を 200 個で実行し、最後の精度 (accuracy) が変わるでしょうか？

Epochs :	Loss :	Accuracy :
10	0.14536468982696532	95.66% (9566/10000)
20	0.08656181693077088	97.38% (9738/10000)
100	0.07802448868751526	98.24% (9824/10000)

結果は、学習を繰り返すことで Accuracy の精度は上昇した。しかし、ユニット数を変えても Accuracy の精度は若干の上昇しか見られなかった。

データ拡張、オーグメンテーションは、データが少ない偏りがある場合データを水増し（画像を回転・反転・拡大縮小・画像変更（明るさ・ノイズ。ボケなど））して学習することで性能を向上させる方法である。  
⇒10%程精度が向上する

## 2. 画像分類

学会で提供されている胸部画像を用いて深層学習を行った。

日本放射線技術学会で提供している miniJSRT\_database を使って、「胸部 X 線画像の画像で画像の方向と 4 クラス分類と男女の性別の 2 クラス分類」を行います。

畳み込み層-プーリング層の組みを 2 層、全結合層を 3 層

損失関数は、Cross Entropy

最適化アルゴリズムは、adam

① 画像 1 枚をモデルに入力して、分類結果を表示します。



画像を回転させた画像 4 種類 : down、left、right、up

② epoch 数を変えても、正解が得られるのか

---

画像 1 枚の選択したモデル ” down ”				
Epochs :	down :	left :	right :	up :
5	-0.14247914	-0.08331006	-0.07771669	-0.03579415
30	1.6560695	-6.9116006	-14.153618	-21.11621
100	5.887036	-6.80217	-7.862767	-9.300333

---

画像 1 枚の選択したモデル ” left ”				
Epochs :	down :	left :	right :	up :
5	0.02114122	0.09534316	0.02102574	0.06798431
30	-7.5434804	3.073178	-9.339211	-11.6455
100	-23.554924	2.899344	-26.479017	-21.779037

---

① 画像 1 枚をモデルに入力して、分類結果を表示します。

胸部写真の男女の性別 : female、male

② epoch 数を変えても、正解が得られるのか

---

画像 1 枚のモデル ” female ”		
Epochs :	female :	male :
5	0.04229384	0.03970761
30	0.41891533	-1.1010346
100	13.476839	-12.81604

---

結果として、学習を繰り返すごとに画像分類が正確に行われること、方向を変えたとしても正確に行われることが確認できた。

### 超解像度

胸部単純画像をもとにして、低解像度画像と高解像度画像を使って超解像モデルの学習を行った。入力として低解像度データ、教師として高解像度データであった。なお、今回使用した学習用データは、

低解像度画像と高解像度画像それぞれ 197 枚あった。最終層にはシグモイド関数を入れて、出力が 0~1 になるように損失関数は「平均二乗誤差」、最適化法には Adam を設定します。

結果として、Epochs を 10、100、1000、5000 と変化させて学習させた結果が図 1 である。Epochs 10 では、解像度の向上はなく逆に低解像度画像となった、しかし 100、1000 は同じくらいの解像度向上が見られ、5000 になるとさらに解像度が向上した。しかし、ループ数が多すぎるとエラーとなり今回のニューラルネットワークの 3 層構造では 6500-7000 あたりで Error を起こし画像表示ができなかった。

#### ノイズ低減

ノイズなしを学習させ、ノイズがない画像が出力されるように学習モデルを作成してある。

最終層にはシグモイド関数を入れて、出力が 0~1 になるように、損失関数は「平均二乗誤差」、最適化法には Adam を設定します。

結果として、Epochs を 10、100、1000、3500 と変化させて学習させたところ、Epochs 10 でノイズ低減は、右胸ポート用では多少見られたが、100 以上の Epochs ではノイズ低減しなかった。また、ループ数が多すぎるとエラーとなり今回のニューラルネットワークの 3 層構造では 3500-4000 あたりで Error を起こし画像表示ができなかった。

#### 最後に

第 44 回医用画像処理プログラミングセミナーに参加して、深層学習、プログラム少し触る機会を得られたこと、大変うれしく思いました。この機会に深層学習をさらに学んで日々の実務に役立てたらと思います。そして、実行委員の皆様の企画力、バックアップ体制の構築などに対して感心と感謝の気持ちでいっぱいです。ありがとうございました。








図 1. 超解像度

a	b
c	d
e	



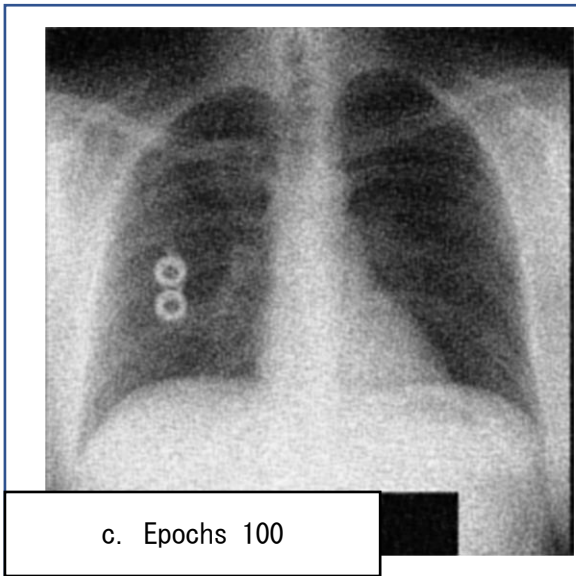




図 2. ノイズ低減

a	b
c	d
e	

## オンライン 第 44 回医用画像処理プログラムセミナー ～PyTorch で深層学習入門～を受講して

創聖健康保険組合診療所 放射線科 遠藤 敦

人工知能 (AI) という言葉はカッコいいし、使えたら面白そうだなと思いながらも重い腰があがりませんでした。本を検索しても膨大な数がヒットし、いったい何をどのような順番で学習すれば良いのか、それを考えているうちに数年が経ちました。そんなときに目にしたのがこのセミナーです。

エントリーして受講が許可されると、準備資料と練習用サンプルプログラム、セミナー当日用プログラム、予習動画 4 つの URL が送られてきます。準備資料にはセミナー当日までにやる作業の詳細が書いてあります。具体的には、当日使用する Google Colaboratory のインストールの方法、メール連絡や質問に使用する Slack のインストール方法などの説明があります。Google Colaboratory・・・何それ？という感じで、何も知りませんでした。機械学習や深層学習を快適に行うには、ある程度のメモリ容量と GPU が必須になるようです。つまり、それなりにお金がかかります。Google Colaboratory を使えば、それが一切必要ありません。Google Colaboratory は、Google 社が提供しているブラウザから直接 Python を実行できるサービスです。高速に計算処理を行う GPU が無料（一定の条件があります）で使用できます。予習動画は、①Python の基礎、②深層学習の基礎、③NumPy の基礎、④クラスの基礎です。え、4 本もあるの！と思いましたが、どれも 30 分以内に収まっており、初心者でも理解しやすいように工夫されております。また、Python の基礎を視聴してから、更に学習を深めたい方、もしくは疲れてしまった人のために、優先順位を付けて視聴する順番も提案してくれます。加えて（うれしい事に）、忙しくて予習動画を視聴することができない人向けに、これだけは見ておいてくださいという提案もあります。

セミナー当日、午前中の前半は Google Colaboratory の設定および動作確認を行います。その後、Python の復習となります。Python は予習動画の中で、午後の演習で特に必要なところの復習となります。続いて、深層学習の基礎を復習します。これも、予習動画で一度視聴した内容で、特に大事なところを重点的に復習します。休憩をはさんで午前中の後半は、PyTorch という深層学習に使われるフレームワークについて学びます。フレームワークとはプログラムを作る上でのひな形のようなもので、これを利用することにより、プログラムを一から作らなくて済みます。PyTorch は Python をベースにしていますが、他のプログラム言語として、MATLAB の紹介もありました。

お昼休みをはさんで午後からは画像分類と超解像度処理の実習になります。画像分類では、教師データとして日本放射線技術学会画像分科会が提供している画像を使います。画像は、上下左右、各 247 枚 × 4 方向 = 988 枚が収録されています。画像分類で使用するニューラルネットワークのモデルは、畳み込み層とプーリング層の組が 2 層、全結合層が 3 層を使います。畳み込み層は、畳み込み積分の値を次の層に伝達する層です。プーリング層は指定した領域の最大値や平均値などを次の層に伝達する層です。全結合層は、畳み込み層またはプーリング層の出力である 2 次元特徴マップを 1 次元に展開しま

す。次に、出力と教師データとの誤差を求め、その誤差を最小にしていくアルゴリズムを選択します。最適化アルゴリズムは様々あるようですが、今回の実習では Adam と呼ばれるアルゴリズムを使用しました。このモデルに教師データを使って学習させます。最後に検証用画像を使って分類できているか確認します。画像分類ができていたときには感動しました。やはり、実際やってみると、想像していたものとはずいぶん異なると思いました。次に、男女の胸部 X 線画像の分類、続けて超解像度の実習を行いました。プログラムはすべて提供されます。自分で色々やりたい人は、自分で教師データ用の画像を用意して、提供されたプログラムにその画像が格納されている場所を指定するなど、いくつかプログラムに変更を加えれば使えると思いました。但し、自施設で得た臨床画像を使う場合は、Web を介しての処理は倫理的に問題があるかもしれませんので、Python や PyTorch を自分の PC にインストールして、自前で GPU などを用意する必要があります。この点についても、セミナーで説明があります。

今回の実習の範囲では、誤差を小さくすることと処理時間がトレードオフの関係でした。具体的には、繰り返し学習する数（エポック数）を増やすと出力と教師データとの誤差は小さくなりますが、反面、処理に時間がかかります。これ以外にも、ニューラルネットワークモデルを何にするのか、中間層のユニット数をいくつにするのかなど、いくつも変数があり、組み合わせると膨大な選択肢があります。とても奥が深い分野だと実感できました。

セミナー終了後は、復習用の動画や資料として、本日のダイジェスト版や評価方法などが用意されます。終了後 2 か月ほど公開されていますので、その間、何度も繰り返して視聴できます。更に、9/2 のセミナー終了後から 9 月末まで、メールもしくは Slack で演習に関する質問も受け付けてくれます。演習が終わってから自分で色々試してみて、分からなくなったら質問ができるというのは、とても心強いサポートだと思いました。

私はセミナーを視聴する際、講義を視聴する PC と実際にプログラムを入力する作業用 PC の 2 台に別けて参加しました。1 台の PC で講義を視聴しながらの作業になると、作業スペースが小さくなり、作業スペースを大きくすると、こんどは視聴しづらくなることを避けるためです。この方法によって快適に実習を受けることができました。また、途中でつまづいた時に、別部屋で教えていただくことになりましたが、画面共有したほうが効率良く教えていただけるので、作業用 PC も Web 接続することをお勧めします。2 台でセミナーに参加し、作業用 PC は必要時以外、音声とカメラを切っておきます。

2023 年 11 月 27 日から同年 12 月 9 日まで、セミナー内容を復習したり自分なりにプログラムを変更したりして楽しんでおりました。この 14 日の間、読売新聞朝刊では 1 日も欠かさず AI という文言が掲載されておりました。そして、14 日間で 12 日間で AI に関する記事が掲載されておりました。中でも「AI 核なみの脅威になり得る」（『読売新聞』2023. 12. 3 朝刊）や「AI 社会支配の恐れ」（『読売新聞』2023. 12. 4 朝刊）など、決して穏やかではない見出しです。AI は教師データによって、いかようにもなると思いますので、使う側も、倫理観に裏付けされた責任ある使い方が求められると思いました。どこかで聞いた言葉ですが、近い将来、こちらの利用も最適化が必要になるのかもしれない。

最後に、今回のセミナーは人工知能のプログラムをやってみる！という切っ掛けになりました。セミナーを企画・運営していただいた画像分科会の先生方、陰で支えてこられたすべてのスタッフの先生方、忍耐強くサポートして下さった山本めぐみ先生、平原大助先生、佐保辰典先生に心から御礼申し上げます。

## 第 24 回 DR セミナーを受講して

秋田大学医学部附属病院 中央放射線部 高橋 俊吾

2023 年 11 月 18・19 日に開催された第 24 回 DR セミナー(会場：仙台市)に参加させていただきました。市販のテキストを使用しながら実測した経験はありましたが、今回機会を頂き、測定配置や方法についてさらに理解を深める目的で今回セミナーを受講しました。

セミナーは対面形式での開催で、講師・スタッフが数人いる状態で、わからないことがあれば個別に直ぐに質問可能でしたので、非常に学びやすく理解を深めることができる環境でした。

セミナーは入出力特性に始まり、解像特性・ノイズ特性、NEQ・DQE についての内容でした。それぞれについて解説・データを用いた演習を行い、考え方や解析時の注意点・コツについての説明もあり、一人でテキストのみで測定をしていた時よりも理解が深まりました。

セミナーの中で実際に設置・実測を行っている動画を見ることが出来ました。鉛絞りの形状はどのようなものなのか、立位システムにおいてはデバイスや鉛絞り等をどのように設置・固定すればよいのか(臥位システムにおける配置はテキストの配置図よりイメージ出来ました)など、曖昧だったことが、これらについて動画を見ることで解消できました。また、管球・検出器のアライメント確認のコツ(鏡を利用)などについても解説があり、実際の測定に役立てられる内容が多くありました。

両日とも講義終了後には質疑応答の時間が設けられ、エッジデバイスに適した物質(タングステン板が望ましいとのこと)や得られた NEQ・DQE などの測定値を臨床の条件にどのように反映させるかについて自分がこれまで疑問に思っていた部分を講師の方々に詳しく教えていただき、大変勉強になりました。

初日終了後には情報交換会も行われ、大半の受講者が情報交換会にも出席されていました。仙台市開催であったことから東北地区の方が多いようでしたが、関東・関西方面からも参加されており、普段あまり交流できない地域の方々とも交流を深められ、良い機会となりました。「装置更新の際の条件決定に役立つため」、「放射線治療分野の位置照合における撮影条件決定の補助とするため」等の目標からセミナーに参加されていた方がおり、自施設においても今回の内容を活かしていくべく更なる知識・技術の向上に努めていきたいと考えます。

次回セミナーは、実際の測定配置を含めた実機の講習が予定されているようです。受講することでテキスト上ではイメージしにくい部分について、より理解ができると思います。

最後となりましたが、今回セミナーを企画・講義いただきました講師の先生方、サポートスタッフの方々には心より感謝申し上げます。

## 第 24 回 DR セミナーを受講して

日本赤十字社和歌山医療センター 放射線診断科部 **野口 紫陽**

2023 年 11 月 18 日～19 日に仙台市で開催されました第 24 回 DR セミナーに参加させていただきました。画質評価に視覚評価だけでなく物理評価を行うことの重要性は理解しておりましたが、実際の測定方法や評価項目内容については知識不足でした。また、コロナによる人の行動制限が緩和され 4 年ぶりの対面形式ということで今回の第 24 回 DR セミナーを受講いたしました。

18 日は総論、入出力特性の講義・演習、MTF（エッジ法・矩形波チャート法）の講義・実習、NNPS の講義、データの取得方法で終了しました。19 日は NNPS の演習、DQE の講義・演習という内容でした。教材として利用する標準デジタル X 線画像計測学もわかりやすい内容でしたが、本セミナーの各講師の先生方の講義でさらに教材内容を深く理解することができました。また、測定方法の動画視聴や、Raw data の取得方法の注意事項など教材内容では知りえない知識を得ることができました。演習では Image J と Excel を用いて測定と解析を行いました。一つ一つの解析の過程を講義の内容と復習しながら行えるので知識の定着ができました。Image J の macro や Excel 利用することでどのような計算がされているのかを確認できるのも勉強になりました。本セミナーは対面式かつ参加者人数に対して講師の先生方の人数が手厚いため、演習途中でわからない点をすぐ聞くことができました。また、進捗状況もこまめに確認してくださるので、その都度質問することができました。

1 日目終了後の懇親会にも参加させていただきました。当センターでは物理評価に対する知識不足もあり、まず何からすべきなのか、どのようにすべきかなど多くの問題点について、参加者の方、先生方、メーカーの方と幅広く意見を交換することができました。

本セミナーに参加して物理評価に対する抵抗がなくなったように感じました。Image J と Excel を使って自施設のできる事から取り組みたいと思います。最後に、本セミナーを企画・開催した日本放射線技術学会画像部会の皆様、講師、チューターの方々に深く感謝申し上げます。



# 胸部デュアルエネルギーサブトラクション (DES) 法 の原理と臨床での活用

北里大学病院 関 将志

## 1. はじめに

肺がんによる罹患率・死亡率は年々増加しており、早期発見・治療において胸部 X 線写真の果たす役割は大きい。また低侵襲かつ簡便であり、情報量も多いことからスクリーニング検査に最も適している。しかし、肺野結節影は約 70%の病変で肋骨等の骨陰影に重複しているといわれており、骨、縦隔、血管などの重複が読影を困難にするため、小さな肺野結節影は見落とされる場合がある。



そこで、医師の読影を補助する画像処理としてデュアルエネルギーサブトラクションがある。デュアルエネルギーサブトラクションとは、2つの異なるエネルギースペクトルを有する X 線から得られた 2 枚の画像より、減弱係数の異なる物質(軟部および骨部組織)をそれぞれ画像化する方法である。

本講演では、胸部デュアルエネルギーサブトラクション法の原理とともに当院での臨床活用を紹介していく。

## 2. 日常での胸部 X 線検査

日常での胸部 X 線検査は「スクリーニング」あるいは「経過観察」を目的に施行される場合が多い。「スクリーニング」としての胸部 X 線検査は、臨床症状や検査所見から呼吸器を含む胸部疾患が疑われる患者や、呼吸器系の症状はないが患者の基礎特性から胸部疾患が疑われる患者、また、術前の患者や発熱等の原因検索を目的としている。つまり、何か疾患を疑っており、画像所見が「ある」ことを確認し次の診療につなげていきたい、または何も所見が「ない」ことを確かめるために依頼される。しかし、臨床現場では、スクリーニング目的の胸部単純 CT を依頼されることが度々ある。例えば、スクリーニングとして胸部 X 線検査を施行したが有意な所見を認めなかったため、症状も続くことから胸部単純 CT を施行し病変を発見したなど、経験したことがあるのではないだろうか。その場合、病変の発見から診断確定、治療開始までに時間がかかってしまう。

図1に胸部デュアルエネルギーサブトラクション画像を示す。骨に重なる病変が検出しやすいのがわかる。



左上:通常の胸部画像

右上:骨強調画像

左下:軟部強調画像

図 1. 胸部デュアルエネルギーサブトラクション画像

### 3. 胸部デュアルエネルギーサブトラクション法とは

胸部デュアルエネルギーサブトラクション法とは、2種類の異なるエネルギーから得られた2枚の画像より3種類の画像(通常の胸部画像、骨のみを表示した骨強調画像、骨を除去した軟部強調画像)を作成する手法であり、画像の取得方法としては、X線を1回照射するOne Shot法と2回照射するTwo Shot法がある。

One Shot法はComputed Radiography(CR)とFlat Panel Detector(FPD)で仕様が異なる。CRでは、2枚のイメージングプレート(IP)を使用し、IPの間に銅板を入れることで、銅板の前のIPより低エネルギー画像を、銅板

の後ろのIPより高エネルギー画像を取得している。FPDでは感度の異なる2種類のシンチレーター(Gd<sub>2</sub>O<sub>2</sub>S:TbとCsI:Tl)を1枚成形することで、1回照射のOne Shot法を達成している。

Two Shot法は、異なる管電圧で2回照射することでエネルギーの異なる画像を取得する。当院のシステムでは、1回の照射後、0.2秒後に2回目の照射を行う。管電圧として、低エネルギー側は60~80kVより選択、高エネルギー側は110~150kVより選択可能である。

ここで低エネルギー画像と高エネルギー画像の差分から軟部強調画像を作成してみる。例えば、図2のように低エネルギー画像のピクセル値を骨は150、軟部1は60、軟部2は30とする。これに対し高エネルギー画像のピクセル値を骨は100、軟部1は48、軟部2は24であったとする。単純にこのまま差分してしまうと、骨が50、軟部1は12、軟部2は6となり、骨を除去することができない。そのため、骨のピクセル値に着目し、画像に重みづけを試みる。図2では高エネルギー画像を1.5倍すると骨が150、軟部1は72、軟部2は36となる。そこで両者を差分することで、骨が0、軟部1は12、軟部2は6となり骨を除去することができる。

このようにデュアルエネルギーサブトラクション法では画像に重みづけし、減算することで骨強調画像、軟部強調画像を作成している。

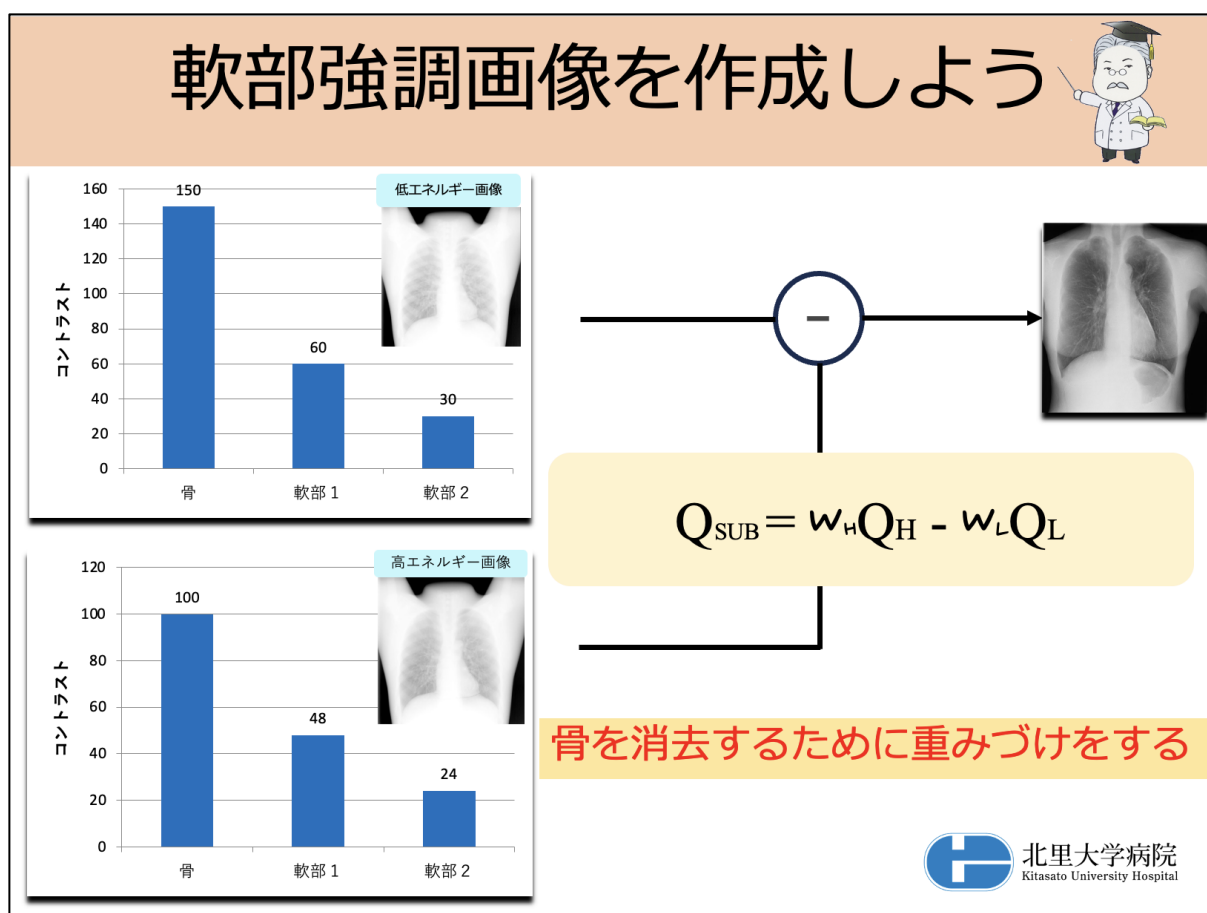


図2. 軟部強調画像を作成してみよう

#### 4. 胸部デュアルエネルギーサブトラクション法の問題点

胸部デュアルエネルギーサブトラクション法の問題点として、以下の3点が挙げられる。

- ・撮影できる装置が限られている

デュアルエネルギーサブトラクション法が活用できる装置として、One shot 法では、CR で XU-D1（富士フイルム社製）、FPD で CALNEO Dual（富士フイルム社製）がある。Two shot 法では、XR656 など GE Healthcare 社製の一般撮影装置、CALNEO HC（富士フイルム社製）がある。しかし、One shot 法については、現在販売されていない。

- ・One Shot 法では、高エネルギー画像のノイズ特性が劣化してしまう

CR を用いた One Shot 法では、2 枚の IP の間に銅板を挟むことでエネルギーの異なる 2 種類の画像を取得している。そのため、銅板を通過した高エネルギー画像ではノイズ特性が劣化する。また、低エネルギー画像とのエネルギー差が小さいため、Two Shot 法に比べ骨強調画像、軟部強調画像の画質が劣る。

- ・Two Shot 法では撮影線量が通常より増加してしまう、また、モーションアーチファクトが発生する

低管電圧、高管電圧の 2 回照射であるため、通常の胸部 X 線検査より被ばく線量が高い。当院で胸部ファントムを撮影した際の入射表面線量を表 1 に示す。CR による One Shot 法では 0.3mGy、FPD を用いた Two shot 法では 0.2mGy、FPD を用いた通常の胸部正面撮影では 0.1mGy であった。DRL2020 を超えてはいなかったが、CR に比べ低く、FPD を用いた通常の胸部正面撮影よりは高い結果であった。

表 1. 入射表面線量の比較

	ESD (kitasato univ HP)	AD*	DRL2020
One Shot (CR)	0.3		
Two Shot (FPD)	0.2	0.1	0.3
General Chest Xray (FPD)	0.1		

\*AD: 日本医学放射線学会修練機関データの中央値

単位：mGy

また、1 回の照射後、0.2 秒後に 2 回目の照射を行うためモーションアーチファクトが発生する可能性がある。アーチファクト画像を図 2 に示す。人の心拍数は平均で 60～70 回/分と言われており、1 秒間におおよそ 1 回鼓動を打つため、心電同期がない限り同じ位置での撮影は困難である。そのため、余程タイミングが良くない限り、心臓の辺縁には常にアーチファクトが発生する。




図 2. アーチファクト画像(左が骨強調画像、右が軟部強調画像)

## 5. 胸部デュアルエネルギーサブトラクション法の可能性と今後の展望

胸部デュアルエネルギーサブトラクション法の問題点を解決できる技術として、AI 技術を活用したエネルギーサブトラクション法も研究されている。AI 技術を活用し高管電圧画像から低管電圧画像を推定、作成し、作成された仮想低管電圧画像を用いてエネルギーサブトラクションを行う。この技術が実用化されれば、被ばく線量の低減や2回曝射によるモーションアーチファクトの低減に繋がる技術として期待する。

## 6. 最後に

胸部デュアルエネルギーサブトラクション法は、骨に重なる病変の検出に優れているだけでなく、骨強調画像を活用することで骨病変と鑑別することもできる。

また、AI を活用した研究も始まっており、胸部デュアルエネルギーサブトラクション法の問題点を解決できる方法として期待する。

最後になるが、胸部デュアルエネルギーサブトラクション法とは胸部 X 線写真の読影を補助する技術である。そのためには、正しくポジショニングすること、吸気で撮影すること、呼吸をしっかり止めることなど、アナログな部分を大切にすることこそデジタルの技が生かるとはのではないだろうか。

## 参考文献

[1] Asumi Yamazaki, Akane Koshida, Toshimitsu Tanaka et al.: Development of Artificial intelligence-Based Dual Energy Subtraction for Chest Radiography. Applied Sciences, 13(12), 7220, 2023.

# ROC 解析の理論と AUC による統計的検定

鹿児島医療技術専門学校 診療放射線技術学科 馬場 祥吾

## 1. はじめに

医療画像は体内の生体情報を画像化し、その画質が診断精度に大きく影響する。そのため、鮮鋭度、粒状性といった物理評価に加え、視覚評価を併せて行うことが多い。視覚評価は定量性と再現性に欠けるといった問題があったが、Receiver Operating Characteristics (ROC) 評価は心理的、主観的評価でありながら、客観性も兼ねた画質評価法として確立された。ROC 解析は、観察者の刺激に対する応答特性や人工知能などのコンピュータシステムより得られた予測結果を ROC 曲線や ROC 曲線下面積である Area Under the Curve (AUC) で定量化する方法である。ROC 解析を理解することで、医療画像分野における様々な研究に対して、より一層理解が深まるものとする。本稿では、ROC 解析の理論、および AUC による統計的検定方法について解説し、また、プログラミング言語 R と Python による実装例についても紹介する。

## 2. ROC 解析

ROC 解析は、レーダーシステムが飛来する敵の航空機を鳥などの群れと判別する際の性能を評価するために開発された信号検出理論であり、1960 年以降に放射線医学分野に導入され、応用が始まった。放射線医学分野では以下の目的に対して ROC 解析が用いられる。

- ・モダリティ間の診断能比較
- ・検査法または手技間の診断能比較
- ・観察者の診断能評価
- ・新しいモダリティ、検査法、手法の評価
- ・最適なカットオフ値の推定

また、近年ではディープラーニングや機械学習、コンピュータ支援診断システムの評価による研究分野の拡大より ROC 解析の重要性は増している。ここでは、ROC 解析の理解に必要な、実験手順や ROC 曲線、カットオフ値について解説する。

### 2-1. ROC 解析の実験手順

ROC 解析の実験手順は、以下の通りとなる。

1. 実験の目的を明確にする：ROC 実験に用いられる画像は、ROC 解析を用いて何を評価するかによって決定される。そのため、統計的に有用な画像枚数を確保するためにも、明確な実験目的を設定し、臨床画像もしくは擬似画像を準備しなければならない。
2. 実験の計画：観察試料の作成と選択に加えて観察者の種別と選択を行う。観察試料の枚数は統計的に多いほど有利となるが、観察者の目の疲労も考慮し、信号あり画像が 150～250 枚であれば、統計的誤差も 2～3%に抑えることができる。また、観察試料の難易度に偏りがあった場合、観察者の反応は正規分

布からかけ離れたものとなってしまう、統計的な有意性を示すことが困難となる。したがって、仮に観察者の判断基準が5段階評価で正規分布に従うとすれば、Fig.1のような観察試料の難易度を調整した選出もしくは作成が観察者実験を成功に導くために必要となる。また、観察者の選択では観察者個々の能力を把握して、目的に応じた選択が理想的である。観察者の人数も多ければ、統計的精度が向上するため、5～10名程度の確保が望ましい。

3. 学習：観察者が二者択一的な回答となることを避け、強い確信度の回答が全体の10%程度になるように説明する。また、学習用画像の選出では、観察者に無用なバイアスを与えないよう注意深く選出する。

4. 実験の実施：学習や実験条件、実験環境などが適正に整った下で実験を開始する。

5. 実験結果の解析：ROC 曲線より、カットオフ値やAUCの算出、また、AUCによる統計的検定などの分析を行う。

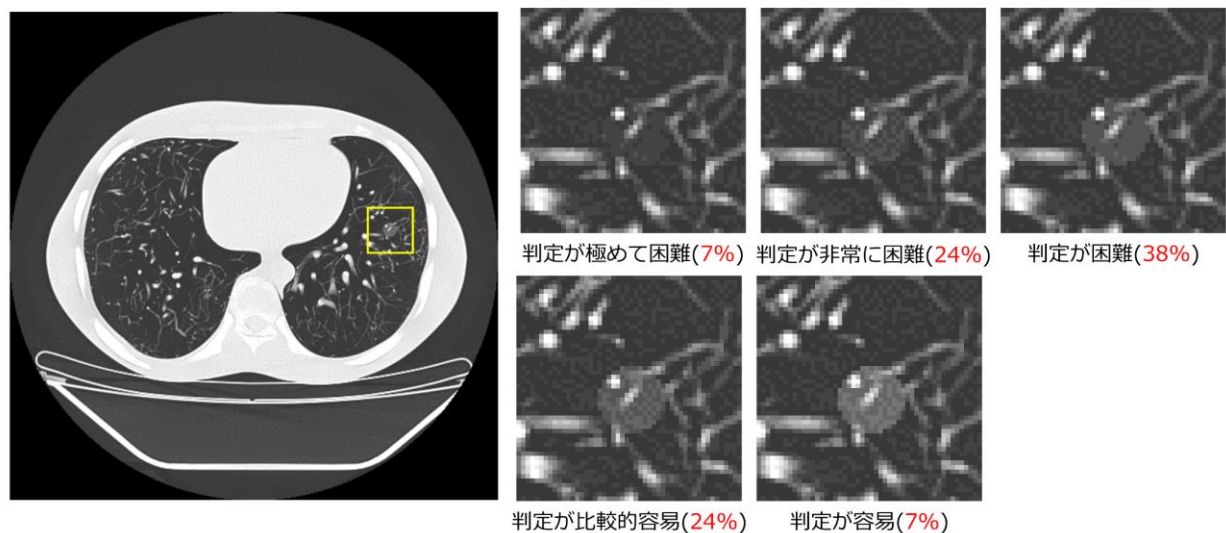


Fig.1 信号強度を調整した難易度別観察試料作成の例

括弧内の数値は観察試料の総枚数に対する含有率の目安を示す

## 2-2. 刺激 - 反応行列

ある画像を観察したとき、観察者にいくらかの幅があったとしても「陽性」と「陰性」のいずれかの応答を示す。また画像が「疾病あり」と「疾病なし」のいずれかとすれば、Table.1に示すような2×2の刺激-反応行列を示す。まず、診断結果が「疾病あり」で正しく「陽性」と判断した場合は真陽性 (True Positive : TP)，誤って「陰性」と判断した場合は偽陰性 (False Negative : FN)と呼ばれる。一方、診断結果が「疾病なし」で正しく「陰性」と判断した場合は真陰性 (True Negative : TN)，また、誤って「陽性」と判断した場合は偽陽性 (False Positive : FP)と呼ばれる。

ここで、感度 (Sensitivity)は疾病あり画像に対して診断結果が「陽性」である割合を指し、疾病あり画像の総枚数は TP と FN を足した数となるため、感度は  $TP/(TP+FN)$  で算出できる。対して、特異度 (Specificity)は疾病なし画像に対して診断結果が「陰性」である割合を指し、疾病なし画像の総枚数は

TN と FP を足した数となるため、特異度は  $TN / (FP + TN)$  で算出できる。

適中度は診断結果が実際に正しかった割合を指す。診断結果が「陽性」で観察試料が「疾病あり」であった割合を陽性適中率 (Positive Predictive Value : PPV)、診断結果が「陰性」で観察試料が「疾病なし」であった割合を陰性適中率 (Negative Predictive Value : NPV) という。PPV は  $TP / (TP + FP)$  で算出され、NPV は  $TN / (FP + TN)$  で算出される。

Table. 1 刺激反応行列の対応表

刺激 \ 反応	陽性	陰性
	信号あり (疾病あり)	真陽性 True Positive (TP)
信号なし (疾病なし)	偽陽性 False Positive (FP)	真陰性 True negative (TN)

### 2-3. ROC 曲線とカットオフ値

Table. 2 は、ある検査診断能の調査目的で、確実に肺がんと分かっている患者 30 人と確実に健常であることがわかっている 30 人に画像検査を実施し、1 人の観察者が「①腫瘍は絶対ない」、「②腫瘍は存在しないだろう」、「③どちらともいえない」、「④腫瘍は存在するかもしれない」、「⑤腫瘍は必ず存在する」の 5 段階評価を行った結果である。

Table. 2 肺がんの結果

	① 絶対ない	② 存在しない だろう	③ どちらとも いえない	④ 存在する かもしれない	⑤ 必ず存在する	計
肺がん	1	0	6	11	12	30
健常	9	2	11	8	0	30

カットオフ値とは、定量データを区切るために使用される基準値である。Table. 2 に対して、評価基準ごとにカットオフ値を設定した表を Table. 3~6 に示す。{①} を「腫瘍なし」、{②③④⑤} を「腫瘍あり」のカットオフ値で設定すれば Table. 3 のような表となり、{①②} を「腫瘍なし」、{③④⑤} を「腫瘍あり」のカットオフ値で設定すれば Table. 4 のような表となる。Table. 5, 6 も同様にカットオフ値を設定して得られた表となる。また、Table. 3 から感度と特異度を算出すると感度は  $29/30 = 0.97$ 、特異度は  $9/30 = 0.30$  となる。Table. 6 の感度は  $12/30 = 0.4$ 、特異度は  $30/30 = 1.0$  となり、Table. 4, 5 も同様に計算すれば感度と特異度が算出できる。一般的に、感度と特異度はトレード・オフの関係にあり、感度を高くしようとすると特異度は低くなり、特異度を高くしようとすると感度は低くなる。



Table. 3 {①} vs {②③④⑤}

	陽性	陰性	計
肺がん	29	1	30
健常	21	9	30

Table. 4 {①②} vs {③④⑤}

	陽性	陰性	計
肺がん	29	1	30
健常	19	11	30

Table. 5 {①②③} vs {④⑤}

	陽性	陰性	計
肺がん	23	7	30
健常	8	22	30

Table. 6 {①②③④} vs {⑤}

	陽性	陰性	計
肺がん	12	18	30
健常	0	30	30

Fig. 2 は、Table. 3～6 で算出された偽陽性率(1.0－特異度)を横軸、感度を縦軸にプロットした ROC 曲線である。また、Fig. 2 には (0, 0) と (1. 0, 1. 0) が追加してあるが、これは { $\phi$ } vs {①②③④⑤} と {①②③④⑤} vs { $\phi$ } でカットオフ値を設定した座標であり、強い確信度のカットオフ値といえる。

ROC 曲線より得られる AUC は 0. 5～1. 0 の範囲をとり、面積が大きいほど精度が高いと評価できる。また、検査結果による AUC の評価判定の基準は 0. 5～0. 7 が低い精度、0. 7～0. 9 が中程度、0. 9～1. 0 が高い精度と評価されることが多いが、診断目的や診断の難易度によって AUC に対する評価基準は変化する。




Fig. 2 Table. 2 より作成した ROC 曲線

#### 2-4. 最適なカットオフ値の設定

一般的に感度と特異度にはトレード・オフの関係性があり、カットオフ値の設定は対象とする疾患と目的を考慮して行う必要がある。カットオフ値を決定する方法は様々であるが、感度と特異度のバランスから決定する代表的な方法として、方法(1)：最も高い精度を表す ROC 曲線は座標 (0, 1. 0) に近づくという事

実から、座標(0, 1.0)から最短距離を算出する方法、方法(2) : 最も低い精度を表す座標(0, 0)と(1.0, 1.0)を結んだ直線(AUC=0.5)から最大距離(感度+特異度-1.0)を算出する Youden indexがある。

Code.1はプログラミング言語Rのライブラリ pROC を用いて、Table.2「肺がんの結果」を方法(1)、方法(2)で実装した例である。dataはread.csv関数でcsvファイルまでのパスを指定した変数である。roc関数の基本構文はroc(response ~ predictor, data)となり、responseは陽性もしくは陰性の診断結果を示し、predictorは観察者の予測結果を示す。また、plot関数の引数print.thres.best.methodで方法(1)であればclosest.topleft、方法(2)であればyoudenを指定すれば実装できる。Code.1の結果は方法(1)、方法(2)ともに同じカットオフ値が出力された(Fig.3)。

Code.1 : Rによる最適なカットオフ値の設定
<pre>library(pROC) data =read.csv ("C:/Users/---/---.csv") ROC &lt;- roc(response ~ predictor, data = data)  #ROC 曲線の描画(左上隅からの距離を用いた方法) plot(ROC, identity = TRUE, print.thres = "best",       print.thres.best.method = "closest.topleft", legacy.axes = TRUE)  #ROC 曲線の描画(youden indexを用いた方法) plot(ROC, identity = TRUE, print.thres = "best",       print.thres.best.method = "youden", legacy.axes = TRUE)</pre>




Fig.3 Code.1の出力結果

### 3. 視覚評価による統計的検定方法

ROC 解析は、観察者の読影に基づく評価法であるため、評価結果は必ずしも再現できるとは限らない。そのため、ROC 解析では統計的に解析する必要がある。ここでは、2つの診断能や検出能の差を評価する統計的検定方法について解説する。

#### 3-1. 検定の手順

2群間のパラメトリック検定の手順について述べる。なお、検定方法の選択については後述する。

1. 有意水準の設定：2つのデータ間に差があるかどうかの判断基準に有意水準 (Significance level) を設定して判定する。有意水準は通常 5% または 1% に定められるが、医学統計では 5% が多く用いられる。
2. 仮説の設定：「2群間に差がある」という仮説を証明するためには、その逆の「2群間に差がない」という仮説が矛盾することを証明する背理法を用いる。まず、「2群間に差がない」という仮定 ( $H_0$  : 帰無仮説) を設定し、本来の「2群間に差がある」という仮説 ( $H_1$  : 対立仮説) を設定する。
3. 統計量の計算：2群間の平均値を  $\bar{x}_1$ ,  $\bar{x}_2$  とすると、2群間の平均の差  $\bar{x}_1 - \bar{x}_2$  を統計量とする。この統計量は2群間の差を表すものであればなんでも良く、検定方法の違いは統計量の違いとなる。
4. 確率を求める： $H_0$  の下で統計量  $\bar{x}_1 - \bar{x}_2$  の生じる確率を求め、差の有意性を判定する。p 値は、 $\bar{x}_1 - \bar{x}_2$  の標準誤差で標準化すると、自由度  $df = n_1 + n_2 - 2$  の t 分布に従うことを利用して求める。

$$t = \frac{\bar{x}_1 - \bar{x}_2}{s \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$$

ここで、s は両群の分散  $s_1^2$ ,  $s_2^2$  から求めた合成分散  $s^2$  の平方根として求まる。

$$s = \sqrt{\frac{s_1^2(n_1 - 1) + s_2^2(n_2 - 1)}{n_1 + n_2 - 2}}$$

また、 $s \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$  が  $\bar{x}_1 - \bar{x}_2$  の標準誤差にあたる。

5. 判定：t 分布表より、自由度  $df$ 、有意水準  $\alpha$  の t 値 ( $t_\alpha$ ) を調べ、標本の t 値と比較する。

$|t| \leq t_\alpha$  のとき、差があるとはいえない ( $H_0$  を棄却できず、判定保留)

$|t| > |t_\alpha|$  のとき、有意差あり ( $H_0$  を棄却し、 $H_1$  を採用)

#### 3-2. 検定方法の選択

検定方法には大きく分けて、パラメトリック検定とノンパラメトリック検定があり、検定前に2群間の正規性と等分散性を確認する必要がある。統計学的に正規性を検定する方法はシャピロ・ウィルクの検定 (Shapiro - Wilk test) などが用いられ、帰無仮説に「データが正規分布に従う」と仮定する。つまり、p 値が有意水準よりも大きい ( $p > 0.05$ ) 場合、帰無仮説を棄却できないことから、「正規分布に従っている」と仮定する。また、統計学的に等分散性を検定する方法は F 検定などが用いられ、帰無仮説に「データの分散が等しい (等分散)」と仮定する。正規性の検定と同様に p 値が有意水準よりも大きい ( $p > 0.05$ ) の場合、帰無仮説を棄却できないことから、等分散性を仮定する。

独立 2 群間の検定とは、異なった 2 群の対象から得られたデータ間の統計的検定方法である。各群のデータの分布が正規分布に近似(パラメトリック)し、分散が等しい(等分散)場合、Unpaired t 検定を用いることができる。また、正規性はあるが等分散性を見なせない場合、自由度の値をコントロールして p 値と棄却域を調整する Welch の t 検定を用いることができる。データの正規性を確保できない場合、母集団の分布に対して、特別な仮定をおく必要のないノンパラメトリックな検定であるマン・ホイットニーの検定(Mann - Whitney test)が用いられる。

関連 2 群間の検定とは、同じ対象から得られた 2 群のデータ間における統計的検定方法であり、各群のデータの分布が正規分布に近似(パラメトリック)し、分散が等しい(等分散)場合、paired t 検定が用いられる。また、独立 2 群間の検定と同様、データの正規性を確保できない場合、母集団の分布に対して、特別な仮定をおく必要のないノンパラメトリックな検定であるウィルコクソン符号付順位和検定(Wilcoxon signed - ranks test)が用いられる。

### 3-3. Python による統計的検定方法

ここでは、Python による統計的検定方法の実装例を紹介する。解析に使用するデータは、観察者実験を仮定した AUC 値を Excel の乱数機能を用いて、正規分布に従った観察条件 A(平均: 0.75, 標準偏差: 0.05)と観察条件 B(平均: 0.85, 標準偏差: 0.05)を作成した(Table. 7)。また、Python の実装環境には、Google Colaboratory を使用した。Google Colaboratory は、Google アカウントを作成するだけで、実行環境を準備しなくても、クラウド環境で Jupyter Notebook が実装できる。自作データで分析する場合、Google ドライブにデータをドラッグ・アンド・ドロップでアップロードし、Google ドライブをマウントしなければならない。Google ドライブのマウントは「ドライブをマウント」、「Google ドライブに接続」の順にクリックすることで、Google ドライブにアクセスできる。また、分析対象のデータにカーソルを合わせ、右クリックするとパスをコピーできる(Fig. 4)。

Table. 7 AUC の結果

観察者	観察条件 A	観察条件 B
1. 観察者 a	0.76	0.91
2. 観察者 b	0.78	0.84
3. 観察者 c	0.72	0.79
4. 観察者 d	0.74	0.86
5. 観察者 e	0.76	0.88
6. 観察者 f	0.70	0.83
7. 観察者 g	0.77	0.81
8. 観察者 h	0.62	0.90
9. 観察者 i	0.73	0.81
10. 観察者 j	0.84	0.84

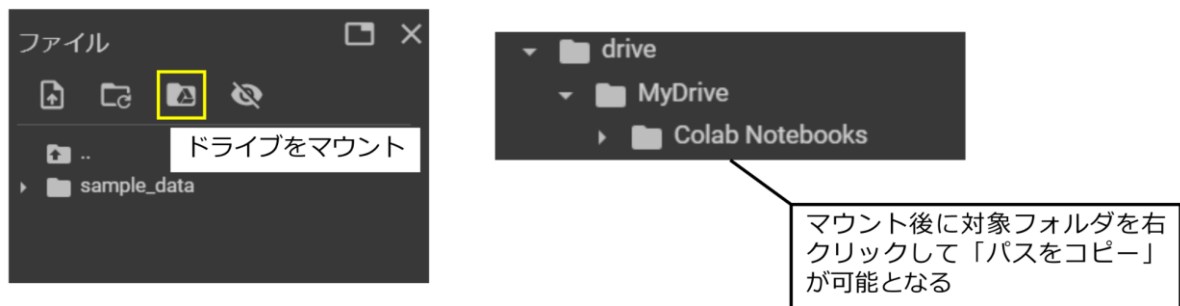


Fig. 4 Google Colaboratory のドライブのマウントとパスのコピー

Code. 2 はライブラリ Pandas をインポートし, Table. 7 が入力された csv ファイルまでのパスを data に格納する. また, csv ファイルの観察条件 A は A, 観察条件 B は B と変数を設定して実装した.

Python の統計処理には, scipy ライブラリの stats モジュールをインポートし, シャピロ・ウィルク検定の実装には stats.shapiro 関数を用いる. shapiro\_A は stats.shapiro 関数で data の A を指定し, シャピロ・ウィルク検定を実装する. また, print('A:', shapiro\_A) は実装結果を出力している. 同様に shapiro\_B も stats.shapiro 関数を用いて, data の B を指定して実装する.

**Code. 2 : csv ファイルの読み込みと正規性の検定**

```
import pandas as pd
data = pd.read_csv('/content/drive/MyDrive/---/---/---.csv')

#統計分析のライブラリの読み込み
from scipy import stats

#観察条件 A に対する正規性の検定
shapiro_A = stats.shapiro(data['A'])
print('A:', shapiro_A)

#観察条件 B に対する正規性
shapiro_B = stats.shapiro(data['B'])
print('B:', shapiro_B)
```

**Code. 2 の出力結果**

```
A: ShapiroResult(statistic=0.9454291462898254, pvalue=0.6148407459259033)
B: ShapiroResult(statistic=0.9522600173950195, pvalue=0.6952779293060303)
```

シャピロ・ウィルク検定の実装結果より、観察条件 A の pvalue=0.6148407459259033、観察条件 B の pvalue=0.6952779293060303 となった。したがって、有意水準 0.05 より大きい結果となり、帰無仮説を棄却することができないため、観察条件 A、B は共に正規性であると仮定できた。

Code.3 では、F 検定を `scipy.stats` の `bartlett` 関数を用いて実装した。`stats.bartlett` 関数は data の A と B の 2 つのデータ群を指定し、`print('bartlett:', bartlett_test)` で実装結果を出力している。

Code.3 : 等分散性の検定
<pre>bartlett_test = stats.bartlett(data['A'], data['B']) print('bartlett:', bartlett_test)</pre>

Code.3 の出力結果
<pre>bartlett: BartlettResult(statistic=1.097419292607716, pvalue=0.29483316004956184)</pre>

F 検定の実装結果より、pvalue=0.29483316004956184 となった。したがって、有意水準 0.05 より大きい結果となり、帰無仮説を棄却することができないため、観察条件 A と観察条件 B の分布が等しい(等分散)と仮定できた。

Code.4 では、前述したパラメトリックな統計的検定方法の Unpaired t 検定、Welch の t 検定、Paired t 検定の実装例を紹介する。本来の検定では、全ての統計的検定方法を行う必要はなく、正規性や等分散性の確認後に適切な検定方法を選択すれば問題ない。比較するデータ間に対応がなく、正規性と等分散を仮定することができた場合、Unpaired t 検定を用いることができる。Unpaired t 検定は、`stats.ttest_ind` 関数を使用し、data の A と B の 2 つのデータ群を指定して、引数 `equal_var` を TRUE とする。次に、比較するデータ間に対応がなく、正規性は仮定したが等分散性を仮定しない場合、`welch` の t 検定を用いることができる。Unpaired t 検定と同様に `stats.ttest_ind` 関数を使用し、引数 `equal_var` を FALSE と変更するだけで実装できる。また、比較するデータ間に対応があり、正規性と等分散を仮定することができた場合、`stats.ttest_rel` 関数で paired t 検定が使用できる。

引数 `alternative` は片側 p 値もしくは両側 p 値に棄却域を設定した検定方法である。`two-sided` であれば両側検定、`less` もしくは `greater` を選択すれば片側検定となる。医学統計分野では、帰無仮説を棄却しにくい(有意になりにくい安全な判定)という意味で、両側検定による統計的検定が一般的である。また、データの収集後に片側 p 値、両側 p 値を算出し、有利な方を採用するといった手順を行ってはず、客観的にエビデンスを引き出すには、検定の手順に従った解析に努めなければならない。Code.4 の出力結果は、引数 `alternative="two-sided"` を指定した両側検定の結果を示す。

Code.4 : 2 群間の統計的検定(パラメトリック)
<pre>#対応のない t 検定(Unpaired_test) unpaired_test = stats.ttest_ind(data['A'], data['B'], equal_var=True, alternative="two-sided") print('unpaired_test', unpaired_test)</pre>

```

# welch の t 検定
welch_test = stats.ttest_ind(data['A'], data['B'], equal_var=False, alternative="two-sided")
print('welch_test',welch_test)

#対応のある t 検定(Paired_test)
paired_test = stats.ttest_rel(data['A'], data['B'], alternative="two-sided")
print('paired_test', paired_test)

```

#### Code. 4 の出力結果

```

unpaired_test TtestResult(statistic=-4.73965634975656, pvalue=0.00016361030980722711, df=18.0)
welch_test TtestResult(statistic=-4.73965634975656, pvalue=0.0002198869196095998,
df=16.060375519856887)
paired_test TtestResult(statistic=-4.332993703790267, pvalue=0.0018967833236545664, df=9)

```

パラメトリックな 2 群間の統計的検定を実装した結果、全ての結果において  $p < 0.05$  となった。つまり、帰無仮説が棄却され、対立仮説が採択されたことで、観察条件 A と観察条件 B は有意に差があると示すことができた。しかし、前述したように全ての統計的検定を行う必要はない。実装した Table. 7 の観察条件 A と観察条件 B は、シャピロ・ウィルク検定と F 検定を行い、正規性と等分散性が仮定できたため Unpaired t 検定を適用した p 値の報告が望ましいと考えられる。

#### 4. おわりに

本稿では、ROC 解析の理論と AUC による統計的検定に加えて、統計分析で多用されるプログラミング言語 R と AI 開発分野で人気の高い Python によるプログラムの実装例について解説した。本稿で解説した ROC 解析や統計的検定は、観察者実験以外にも様々な研究結果をまとめていくうえで非常に有用な評価指標となる。本稿が医療画像を含めた医学分野の全てにおける研究や学会報告の一助となれば幸いである。

#### 5. 参考文献

- ・ 白石順二, 他., “第 2 章 ROC・FROC 解析の理論”, “第 3 章 ROC・FROC 観察者実験の実験計画”, 標準 医療画像の評価法, オーム社, 2020, p. 20-67.
- ・ 社団法人 日本放射線技術学会 出版委員, “2.2 観察資料の作成”, “2.3 評定実験の実際”, 放射線医療技術学術書(8) ROC 解析の基礎と応用, 1994, p. 15-19.
- ・ 柳川堯, 他., “第 6 章 検定”, バイオ統計の基礎, 近代科学社, 2010, p. 145-173.
- ・ 市原清志, “CHAPTER3 独立 2 群の差の検定”, バイオサイエンスの統計学, 2008, p. 72-114.

## 関西乳房画像研究会

大阪大学医学部附属病院 医療技術部 放射線部門 **松澤 博明**

### 1. はじめに

関西乳房画像研究会は、1996年10月に第1回を開催し約28年間活動しています。本年3月には第52回を迎える歴史ある研究会です。発足当時、乳がん検診へのマンモグラフィ導入の必要性が検討されはじめ、日本放射線技術学会や関連学会を中心に研究会や講演会などが全国的に開催されていました。欧米から入ってきた新しい技術や知識が全国的に普及していく中、初代代表世話人である寺田央氏が、関西エリアに情報発信・収集できる場を築けないかと立ち上げた研究会です。1996年から撮影分科会（現：撮影部会）の「乳房撮影ガイドライン・精度管理研修会」が全国展開され、ここでの受講者が中心的な世話役となり関西乳房画像研究会は動き始めました。

### 2. 活動について

記念すべき第1回の内容は「マンモグラフィアンケート調査結果報告」でした。まず、多くの乳腺診療にかかわる診療放射線技師に現状を知っていただいた上で、第2回「会場にX線装置を設置してのモデルによるポジショニングの実技」、第3回「現像処理と画質（現状とその問題点）」と当時のマンモグラフィに求められる技術を普及すべく企画されております。また並行して、「マンモグラフィと乳腺病理組織を対比しての読影基礎講座」や「石灰化病変を知る読影の基礎講座」を行い、第5回には「参加者による読影会とその解説および読影法の教育講演」と読影会を開催しており、当時の熱量を感じます。

当研究会では、アナログからデジタルへ、フィルム読影からモニタ診断への移行についても随所に取り上げ、時代の流れに対応すべく情報発信してきました。1995年の第6回ではCRをはじめとするデジタルマンモグラフィをいち早く取り上げ、モニタ診断についても数年おきに情報提供して参りました。1998年の第12回では「デジタルマンモグラフィ：現状と将来展望」というテーマで岐阜大学大学院の藤田広志先生に、CAD応用についてのご講演もいただいております。

医師による講演も多数行っており、特に東名古屋病院の遠藤登喜子先生には、第5回、16回、30回、40回と節目節目にご講演いただいております。その時代に即した乳がん診療についてご教授いただきました。乳腺外科医はもちろん、放射線科医、病理医の先生にも数多くご講演をいただきました。第17回では「乳腺病理のABC」、37回では「マンモグラフィと病理の対比」と題し乳腺病理の知識を深めました。また第35回では、より知見を広げるべく「遺伝性乳がんに関する乳腺診療の今」というテーマで、HBOCの基礎知識とカウンセリングなどについて学びました。

乳腺疾患の診断には欠かせない超音波の講演も数回開催されており、第39回では「マンモグラフィを超音波の総合判定」、最近の第50回では乳房用リング型超音波装置を取り上げました。



第 47 回、第 48 回は企画したものの、直前で新型コロナウイルスの影響で中止となりました。開催の判断が難しい時期でしたが、歩み続けるべく第 49 回は zoom を用いた web セミナーとして開催致しました。

直近では、2024 年 3 月に第 52 回研究会を「乳房画像の今とこれから ～変化に備えて知見を広げよう～」というテーマで開催致しました。乳腺診療の分野における AI の話を、前画像部会長の岐阜医療科学大学・篠原範充先生にお話しいただきました。篠原先生には、難しくなりがちな話を大変分かりやすくご解説いただきました。当研究会の参加者は、デジタル画像や AI などの最先端の話に明るい参加者ばかりではないため、優しくお話しただける篠原先生には厚かましくもまたお願いできればと思っております！



第 51 回 田口哲也先生

### 3. おわりに

当研究会は、今後、形を変えながらも情報収集の場であり続けていければと考えています。画像部会員のみなさんも是非ご参加いただき、また時には講師として画像に関する知識をご教授いただきますと幸いです。

よろしくお願いいたします！



第 52 回 篠原範充先生



第 52 回 村上典子先生

# 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。

## 2023 年度 画像部会事業報告

### 1) 第 93 回画像部会の開催(第 79 回総会学術大会時)

開催日:2023 年 4 月 14 日(金)15 時 30 分～18 時 30 分 会場:パシフィコ横浜(横浜市) F201+202 室

(1) 教育講演 司会 岐阜医療科学大学 篠原 範充  
「放射線科医目線の乳房画像を用いた興味ある研究」

獨協医科大学埼玉医療センター 久保田 一徳

### (2) 第 93 回画像部会

「乳房画像で一緒に画像研究を始めませんか」

司会 東北大学病院 小野寺 崇・東海大学医学部附属八王子病院 由地 良太郎

- ① 乳房画像を用いた画像研究 岐阜医療科学大学 篠原 範充
- ② 観察者研究による合成 2D マンモグラムの有用性の検証  
聖マリアンナ医科大学附属研究所 B&I 先端医療センター附属クリニック 後藤由香
- ③ 物理評価によるマンモグラフィの解析 国際医療福祉大学 西川 祝子
- ④ マンモグラフィ品質管理項目に基づく画像評価と線量の研究 東北大学病院 千葉 陽子
- ⑤ 乳腺密度計測へのディープラーニング技術の応用 近畿大学病院 山室 美佳
- ⑥ Radio(geno)mics による乳がん診断の可能性 新潟医療福祉大学 甲斐 千遥

### 2) 第 94 回画像部会の開催(第 51 回秋季学術大会)

開催日:2023 年 10 月 27 日(金)13 時 30 分～16 時 30 分 会場:名古屋国際会議場(名古屋市) 第 5 会場

(1) 教育講演司会 鈴鹿医療科学大学 東出 了  
「求める画質と線量の関係 - この明解なのに難解な関係を紐解く -」

金沢大学 市川 勝弘

### (2) 第 94 回画像部会

「画像評価から考える画質と線量」

司会 岐阜医療科学大学 篠原 範充・紀南病院 山崎 純

- ① 一般撮影の線量から考える画質 藤田医科大学 浅田 恭生
- ② 物理評価の有用性 名古屋市立大学病院 山田 雅人
- ③ 視覚評価の有用性 金沢大学 田中 利恵
- ④ 物理評価, 視覚評価で異なる結果が出る要因 東北大学病院 小野寺 崇
- ⑤ 物理評価, 視覚評価を生かすには 東海大学医学部附属八王子病院 由地良太郎

3) ROC セミナーの開催

第 13 回 ROC セミナー (教育委員会共催)

開催日:2023 年 5 月 10, 17, 24, 31 日, 6 月 7(水)の5日間

会 場: Cisco Webex によるオンライン (50 分単位で 5 回開催) 受講生人数:60 名

4) 臨床画像評価セミナーの中止

第 10 回臨床画像評価セミナー(教育委員会, 東京支部共催)

日時:2023 年 7 月 8 日(土), 9 日(日)

会場: 国立がん研究センター中央病院(東京都築地)

5) 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 (教育委員会共催)

2023 年 9 月 2 日(土) 10:00 ~ 15:00

会 場: Cisco Webex によるオンライン・広島国際大学 呉キャンパス(本部) 受講生人数:33 名

6) DR(デジタルラジオグラフィ)セミナーの開催

第 24 回 DR セミナー (教育委員会, 東北支部共催)

開催日:2023 年 11 月 18 日(日) 9:00 ~ 18:00, 19 日(日) 9:00 ~ 13:00

会 場: PARM-CITY 131 貸会議室 (宮城県仙台市) 受講生人数:23 名

7) 部会誌(画像通信)の発行

Vol.46 No.1(通巻 90 号)(2023 年 4 月), Vol.46 No.2(通巻 91 号)(2023 年 10 月)

8) 部会委員会の開催

第1回委員会 4月14日	横浜
第2回委員会 5月15日	WEB
第3回委員会 9月14日	WEB
第4回委員会 10月27日	名古屋
第5回委員会 12月23日	WEB

# 2024 年度 画像部会事業計画

## 1) 第 95 回画像部会の開催(第 80 回総会学術大会時)

開催日:2024 年 4 月 12 日(金) 会場:パシフィコ横浜(F201+202 室)

### (1) 教育講演

司会 鈴鹿医療科学大学 東出 了

「Radiomics のためのエンジニアリング ～モデルの評価にまつわる話題～」

東北大学 高屋 英知

### (2) 画像部会

「ピクセルから予後へ:臨床診断における Radiomics の革命」

司会:小倉記念病院 佐保 辰典, 原田学園 平原 大助

① 「臨床現場から見る個別化医療を見据えた医用画像の底力:Radiomics !」 山口大学 椎木 健裕

② 「がんの特徴を穴から見通す -トポロジー穴解析-」 九州大学 有村 秀孝

③ 「放射線診断医からみた Radiomics 研究」 聖マリアンナ医科大学 原口 貴史

④ 「放射線治療医からみた Radiomics の有用性と今後の展望」 広島大学 今野 伸樹

## 2) 画像部会関連企画の開催(第 1 回日本放射線医療技術学術大会, 第 52 回秋季学術大会時)

開催日:2024 年 10 月 31 日(金)～11 月 3 日(日)(予定) 会場:沖縄コンベンションセンター(宜野湾市)

(1) JSRT 画像部会・JART 消化管画像分科会 合同企画

「透視検査における画質とノイズ低減技術の変遷 ～画像ノイズの理解と抑制～」(予定)

(2) JSRT 撮影部会(一般分科会)・JSRT 画像部会・JART 骨関節撮影分科会 合同企画

「X 線単純撮影の標準化を考える」(予定)

## 3) ROC セミナーの開催(教育委員会共催)

第 14 回 ROC セミナー(オンライン)

開催日時:2024 年 5 月 8, 15, 22, 29 日, 6 月 5 日の 5 日間で開催

会 場:オンライン実施(50分単位で5回の開催を予定)

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,九州支部共催)

第24回DRセミナー

開催日時:2024年8月24日(土),25日(日)

会 場:久留米大学病院を予定

5) 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(オンライン)

開催日時:2024年9月8日(日)

会 場:オンライン実施 セミナー本部:小倉記念病院

6) 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11回臨床画像評価セミナー(東京都 築地)

開催日時:2024年未定

会 場:国立がん研究センター中央病院(東京都築地)

7) 部会誌(画像通信)の発行

Vol.47 No.1(通巻92号)(2024年4月), Vol.48 No.2(通巻93号)(2024年10月)

8) 部会委員会の開催 年5回(横浜,WEB,WEB,東京もしくは京都,WEB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

2022 年より専門部会の入会については、正会員・シニア会員は 1 つ目の年会費は無料ですが、2 つ目以降は各 1,000 円が別途必要です。学生会員は会費免除で全ての部会に自動的に登録されます。

#### 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。

## 編集後記

先日、所属大学の国際交流プログラムの一環で、海外の大学教員を対象に自身の研究内容をオンラインでプレゼンテーションする機会があった。英語でプレゼンテーションをすること自体が随分と久しぶりで、約1時間の英語でのプレゼンテーションは初めての経験であった。提示資料（スライド）や話す内容の準備は、ChatGPTの提案をかなり参考にした。最初の自己紹介から研究の詳細に話題を展開していく流れなど、普段日本語で講義する際は困ることはほとんどないポイントも、英語だとどのように話せば良いのか分からなかったが、ChatGPTに相談すると“I was engaged in...”や“Let’s delve into...”など今まで自分では使ったことのない言い回しを提案してくれ、非常に勉強になった。

また、プレゼンテーションの練習は独り小声で何度か行ったが、本番で声をしっかり出して話し始めると、イントネーションやアクセントが所々おかしくなってしまう、自身の練習不足を大いに反省した。この教訓を今後の英語プレゼンテーションに是非活かしていきたい。

(AY 記)

---

画像通信 Vol.47 No.1(通巻'92)

発行日 2024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 東出 了

---

画像通信 通卷九二号

VOL. 47 No1 SPRING 2024