

<特集「医学物理士という仕事」>

放射線治療における人工知能（AI）の役割

梶 川 智 博*

京都府立医科大学大学院医学研究科放射線診断治療学

Role of Artificial Intelligence (AI) in radiotherapy

Tomohiro Kajikawa

*Department of Radiology, Kyoto Prefectural University of Medicine
Graduate School of Medical Science*

抄 録

がん医療において、放射線治療はがんの根治および疼痛などの症状緩和に重要な役割を担っている。一方で、放射線の照射方法の高精度化に伴い、人的および時間的なコストが増加しており、医師をはじめとした放射線治療に関与する臨床スタッフの負担が増大しつつある。人工知能はこの問題を効果的に解決できる可能性があり、近年、臨床における人工知能への期待が高まっている。放射線治療はデータを多く扱う性質上、人工知能の親和性が高い。例えば、実臨床において特に時間を要するプロセスである、腫瘍および正常臓器の輪郭描出や治療計画の作成にも非常に有用である。現在では、人工知能の臨床導入は世界的に進んでおり、今後も更なる新しいアルゴリズムおよびシステムの導入が進むことが予想される。本稿では、放射線治療に携わる医学物理士の観点から、機械学習の概要および放射線治療における機械学習の役割について述べさせていただく。

キーワード：放射線治療，人工知能，機械学習，深層学習，強化学習。

Abstract

In cancer care, radiation therapy plays a crucial role in the eradication of cancer and the alleviation of symptoms such as pain. However, with the increasing precision of radiation delivery methods, the human and time costs are rising, leading to an increased burden on clinical staff involved in radiation therapy, including physicians. Artificial intelligence (AI) has the potential to effectively address this issue, and expectations for AI in clinical practice are growing. Given the nature of radiation therapy, which involves handling large amounts of data, it has a high affinity with AI. For example, it can be extremely useful in the creation of treatment plans and the outlining of tumors and normal organs, processes that are particularly time-consuming in actual clinical practice. Currently, the clinical introduction of AI is progressing worldwide, and it is expected that new algorithms and systems will continue to be introduced in the future. In this paper, from the perspective of a medical physicist involved in radiation therapy, we will discuss an overview of machine learning and the role of machine learning in radiation therapy.

Key Words: Radiotherapy, Artificial Intelligence, Machine learning, Deep learning, Reinforcement Learning.

令和5年11月29日受付 令和5年12月3日受理

*連絡先 梶川智博 〒602-8566 京都市上京区河原町通広小路上ル梶井町465番地

tkjkw@koto.kpu-m.ac.jp

doi:10.32206/jkpum.133.02.117

はじめに

人工知能 (AI: Artificial Intelligence) は、年々我々の生活に取り入れられている。身近な例として、顔認証、迷惑メールの判定や EC サイトでのおすすめ商品の表示などが挙げられる。これらにより、日々の生活の質が格段に向上し、人工知能は我々の生活に無くてはならないものとなりつつある。最近では OpenAI 社の ChatGPT や Microsoft 社の Microsoft 365 Copilot を筆頭にした対話型 AI が注目されており、日常のニュースやインターネットで見ない日は無くなった。これらは、ユーザーがチャットボックスに入力した質問に対して人工知能が対話形式で回答を返答するものであり、文章の生成／翻訳や質疑応答、プログラミングコードの生成などの幅広いタスクに対応している。加えて、対話形式であるため、従来の専門的な知識が必要なものと異なり、人工知能の活用は非常に低い。このように、人工知能はますます我々の生活の一部になってきている。

人工知能とは、人間の知的行動の一部をソフトウェア上で人工的に再現し、経験から学ぶことで新たな入力に順応し、人間が行うように問題解決を行うことができる技術である。一方で、現状では、某アニメのネコ型ロボットのように、あらゆる問題に対応できる賢い人工知能 (強い AI) がすでに存在するわけではなく、特定の範囲が限定されたタスクに対応する人工知能 (弱い AI) が存在するだけである。現在巷で人工知能と言われているものは、一般的にこの弱い AI のことを指している。この人工知能の一つである機械学習は、最も一般的な手法であり、様々な分野で実用化されつつある。自然言語処理や画像処理をはじめとして、音声認識、ビッグデータの分析などで幅広く応用することができる。前述したように、機械学習は特定の領域のタスクに対し特化しているが故に、人間を遥かに凌駕する精度を発揮するケースがある。例えば、Google DeepMind 社により開発された囲碁プログラムである AlphaGo¹⁾ は、2015 年 10 月に人間のプロ囲碁棋士を互先ではじめて

破った。翌年の 2016 年 3 月には五番勝負で 4 勝 1 敗、2017 年 5 月には三番勝負で全勝と圧勝し、人間との対局から引退させられるに至った。非常に多くの局面 (およそ 10^{360} 通り) が存在する囲碁で人工知能が人間に対して勝利を収めたことは世界に非常に大きな衝撃を与えた。これが世界的 AI ブームの皮切りとなり、多くの分野における AI 技術の開発および導入が盛んとなった。

例に漏れず、医療領域においても AI 技術の進出が進んでいる²⁾。その中でも、放射線医療は臨床情報や画像情報などの大量のデータを有する分野であり、人工知能との親和性は非常に高い。特に放射線医療における人工知能のここ数年の発展は目覚ましく、AI を搭載したソフトウェア／ハードウェアが臨床現場にも普及している。人工知能の導入には多くのメリットを有する反面、情報活用能力が不十分な場合ではセキュリティリスクや出力ミスなどを引き起こす可能性がある。上記のようなリスクヘッジのため、研究者だけでなく臨床のスタッフにおいても、理解して使用することが重要である。そこで本稿では、放射線治療に携わる医学物理士の観点から、1) 機械学習の概要、2) 放射線治療における機械学習の役割、3) 放射線治療における実用例について述べさせていただく。本稿が医学に携わる者の人工知能への理解の一助となれば幸いである。

機械学習について

1. 機械学習とは

機械学習とは人工知能の一つであり、コンピュータが大量のデータを解析し、データの背景にあるルールや特徴パターンを学習し、与えられた情報 (入力データ) に対する予測や判断を実現する技術のことである。難解に思われるが、単に入力／出力に合った関数を完成させる処理がモデルの学習であり、 $f(x) = ax + b$ のような関数式 (x : 入力, $f(x)$: 出力) の $ax + b$ 部を複雑にしたものと感覚的には同じである。大量のデータから機械的に学習し、タスクごとに最適な予測モデルを構築することで、未知の

データに対しても予測できるようになる。これにより、統計解析だけでは難しかった問題に対する高精度な予測モデルを構築することが可能になる。

機械学習モデルの学習方法として、「教師あり学習」、「教師なし学習」、「強化学習」の3つに大別される。教師あり学習とは、入力と出力の既知の対となる正解データを用いて、モデルが新たな入力に対する出力を予測できるように学習する手法である。主にデータの分類(classification)や数値の予測(regression)に用いられる。対して、教師なし学習とは、正解データが存在しないが、与えられたデータからルールや特徴パターンを自動的に抽出することで、モデルを構築する手法である。主にデータの分類に用いられる。強化学習は前述した2つの学習方法とは異なる特性を持ち、人間が学習するように試行錯誤を繰り返すことで、タスクに対して最適な行動を模索するようにモデルを構築する手法である。これらの3つの学習方法は適用するタスクに応じて使い分けられる。本項では、最も一般的な機械学習の学習方法である、教師あり学習に対して述べていく。

2. 教師あり機械学習アルゴリズム

機械学習アルゴリズムとは、大量のデータを用いてモデルを学習させ、問題を高精度で解決できるようにモデルのパラメータを最適化する一連の手順を指す。機械学習アルゴリズムごとに性質が異なり、感覚的には前述した関数式 $f(x) = ax + b$ の右項が複雑化し、構造が変化していると考えることができる。未知のデータに対して期待通りの結果や適切な結果が得られるようにするには、タスクや入力／出力データの種類／数に応じて機械学習アルゴリズムを使い分けの必要がある。簡単にではあるが、現在の放射線治療にて最も注目されている深層学習および、その基礎となるニューラルネットワークについての概要を説明していく。

3. ニューラルネットワーク

ニューラルネットワークとは、生物の学習メ

カニズムを模倣し、人間の脳の神経回路の構造(神経細胞の集まり)を数学的に表現した手法である。人工的に模倣しているため、人工ニューラルネットワーク(ANN: Artificial Neural Network)とも呼ばれる。ANNは、1つの入力層、1つ以上の隠れ層、1つの出力層を含む、複数の層で構成される(図1右上)。最もシンプルな構造はパーセプトロン(図1右下)と呼ばれ、神経細胞(ノード)の一つに相当する。ニューラルネットワークにおいても、脳の構造と同様に、各ノードは別のノードに接続されている。また、神経細胞の情報伝達の仕組みに対応するパラメータ群(神経細胞間の接続強度: 重み w , 活動電位: 閾値 θ など)を持つ。個々のノードのいずれかの出力が、指定された閾値を超えると、そのノードが活性化され、次の層に情報が送信される。閾値を超えなければ、情報は次の層に渡されることはない。上記のパラメータ群は大量のデータを用いた学習により、タスクに応じて最適な値にチューニング(学習)される。この学習により、未知のデータに対して分類や数値の予測などが可能となる。

4. 深層学習

深層学習(DL: Deep Learning)とは、上記のニューラルネットワークを脳の動きに更に近づけるために多層構造にすることで複雑な関数が表現でき、より複雑な問題を解くことができるのではないかという考えから生まれたものである。多層構造、つまり層が深くなるということから深層学習と呼ばれる。上記のニューラルネットワークとの大きな違いは、より抽象的な入力データ(画像やテキスト、音声データなど)を直接扱うことができるという点である。入力する特徴量(注目すべきデータの特徴)を人間が決めるのではなく、アルゴリズム側がタスクに適するように自動的に決定するため、従来の機械学習アルゴリズムと異なり、人の手では指定しにくい特徴や人間が気付いていなかった特徴を捉えることができ、自らの判断基準を見つけてることができる。一般的に、何層もの隠れ層の中では、浅い層で部分的なミクロな特徴が、




図1：脳とニューラルネットワーク

図の一部は“<https://www.freepik.com>”を使用。

深い層でそれらを組み合わせたマクロな特徴が抽出される。

5. 畳み込みニューラルネットワーク

畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) は、一般的に画像認識に使われる深層学習アルゴリズムの一種である (図2)。CNNは画像の中からパターンを検出するのに特に有効である。それぞれの学習データに対して、解像度が異なる複数のフィルターを適用し、各畳み込み画像の出力がその次の層の入力として使用される。フィルター処理の適用、つまりフィルターの畳み込み演算処理を行うことから、これを畳み込みニューラルネットワークと呼ばれる。一般的にはCNNには数十から数百の層があり、各層が画像の様々な特徴を学習する。代表的な層としては、畳み込み層や活性化層、プーリング層、全結合層が挙げられる。畳み込み層は、入力データを一連の畳み込みフィルターに通すことで、それぞれのフィルターがデータの有する特徴を定量化する層であり、有用な特徴量を抽出する。活性化層は、前述したニューラルネットワークの活性化にあたる層であり、負の値をゼロにし

正の値を維持することで、活性化した特徴だけを次の層に引き継ぐことができるようにする。プーリング層は、重要な特徴を残しながらデータ量を削減する層であり、データを単純化することで処理の効率化に役立つ。全結合層は、上述したニューラルネットワークを用いて相互に結合させる層であり、データを一次元の数値にする。各々の層が持つパラメータがタスクに応じて最適化するパラメータ群であり、浅い層では明るさやエッジなどの非常に単純な特徴に始まり、深い層ではオブジェクトを一意に定義する複雑な特徴を扱うことができるように学習される。

放射線治療における人工知能の役割

放射線治療はがん治療の重要な治療法の一つであり、全世界のがん患者の約50%が放射線治療を受ける必要があるとされている³⁾。しかし、日本では約25%のがん患者のみが放射線治療を受けているだけであり⁴⁾、未だ十分に利用されていない。この普及率の差による伸びしろや国内のがん患者の増加も合わせ、患者数は年々増加の一途を辿っている。したがって、放射線治療の需要はさらに高まると予想される。




図2：一般的な畳み込みニューラルネットワーク（分類タスク）

放射線治療の需要が高まる一方で、その実施にはいくつかの課題が存在する。特に、近年の放射線治療の高精度化により、人的および時間的コストの削減が医療の質を維持するための課題の一つとなっており、早急な対策を要する。現在の放射線治療は以下の複雑なプロセスで構成されている。大きく分けて、1) 治療計画画像の取得、2) 標的・臓器輪郭の描出、3) 治療計画の作成、4) 治療計画の安全性検証、5) 放射線の照射、6) フォローアップで構築されており、それぞれが専門的な知識や経験を要する。そのため、臨床スタッフの不足や教育の遅れなどにより、放射線治療が実施可能な患者数が制限され、関与するスタッフの疲弊やそれに伴う医療の質の低下も懸念されている。人工知能の登場は上述した現状の課題を解決するだけでなく、上記の臨床ワークフローを変革し、各ステップにおいて関わるスタッフの役割を変える大きな可能性を秘めている⁵⁾。本稿では、現在の臨床で特に多大なコストを要する2つのステップ、①標的・正常臓器の輪郭描出、②放射線治療計画の作成における人工知能の活用に焦点を当てて解説していく。

1. 標的・正常臓器の輪郭描出

標的および正常臓器の正確な輪郭描出は、放射線治療計画作成の重要なステップである。

CT、MRIなどの医用画像から画像内の各ピクセルやボクセルにラベルを割り当てる（輪郭を描出する）ことで、コンピュータが標的や正常臓器の位置を特定できるようにする過程である。一般的には医師や医学物理士、診療放射線技師によって手動で輪郭を描出している。この手作業による輪郭描出は非常に時間を要する作業であるだけでなく、実施者間のばらつきが大きい⁶⁾⁷⁾。また、この輪郭描出のばらつきは、放射線治療の質（臨床的効果、毒性、患者の予後）に影響を与えうる要素の一つである⁸⁾⁹⁾。この作業の自動化により、輪郭描出の一貫性と効率の向上できることが報告されている。従来から研究や商用ソフトウェアの導入では、既知の輪郭情報を有する基準画像に基づくアトラスベースの手法¹⁰⁾が主に用いられてきた。この手法では、新規画像と基準画像との類似性（画像強度や勾配分析など）を元に変形量を算出し、基準画像での輪郭情報を新たな画像に写す。上手くいく場合もあるが、満足いく結果が得られない場合には大幅な人間の介入が必要であり、治療領域の全ての輪郭描出を自動で行うには不十分な精度である¹⁰⁾。

そこで近年、人工知能を用いた手法、特にCNNベースの手法が注目されている。画像と輪郭情報のペアデータを用いてCNNベースのモデルを学習することで、新たな画像を入力し

た際に自動で輪郭を描出することが可能となる（図3）。入力データとしてはCTやMRI、SPECTなどの基本的な画像モダリティを使用することが可能である。比較的容易な胸部をはじめとして、脳腫瘍¹¹⁾や頭頸部¹²⁾、腹部¹³⁾などの全ての領域の正常臓器¹⁴⁾の輪郭描出に用いられる。現在、正常臓器の輪郭描出においては、CNNベースのモデルは従来の自動輪郭抽出方法の精度を上回り、専門家が手動で行った

ものと同等の精度に達している¹²⁾¹⁴⁻¹⁶⁾。また、CNNベースの手法を用いることで、手動の微修正を加えても大幅な時間の短縮（1/7～1/2）が可能であることが報告されている¹⁴⁾。

このタスクにおいて最も重要なアルゴリズムは、CNNベースの「U-Net」¹⁷⁾であり、現在主流の多くのモデルのベースとなっている。このモデルは図4のように文字通りアルファベットの「U」のような形をしており、大きく分けて




図3：標的・正常臓器の自動描出




図4：一般的な U-Net モデル

エンコーダとデコーダで構築されている。エンコーダでは画像を何度か畳み込み、画像のサイズを小さくするとともに、画像の情報を圧縮することで画像の特徴マップを抽出する。デコーダではエンコーダで抽出された特徴から任意（学習した輪郭）の輪郭を描出する。また、CNN では位置情報が上手く捉えることができないため、各階層でのエンコーダの特徴マップをデコーダの特徴マップに連結することで、物体の位置情報を捉えやすくする工夫もされている。このモデル構造は、ある画像から輪郭の描出や別の画像に変換するタスクにしばしば用いられ、放射線治療においては非常に重要なモデル構造である。

2. 放射線治療計画の作成

放射線治療計画の主な目的は、処方線量を標的に正確に照射し、正常臓器への線量を許容線量以下に抑えることで、周囲の健康な組織への放射線の影響を最小限にすることである。強度変調放射線治療（IMRT: Intensity modulated radiation therapy）や強度変調回転照射（VMAT: Volumetric modulated arc therapy）は、その目的に適した照射方法の一つであり、放射線の照射中に照射野内の放射線の強さに強弱をつけることで、標的に対して集中的に照射を行うことができる技術である。この線量強弱の生成においては、最適化アルゴリズムを用いることで治療計画者が複雑な治療計画を作成できるようにする必要がある。そのため、体内の複雑な標的・臓器形状や治療法、機械の制限などを考慮する必要がある。望ましい線量目標を全て達成

できないことがよくある。この治療計画作成は、患者固有の正常臓器に対する線量制限がどの程度低くなるかを予測できないため、通常は標準プロトコルに基づいて初期制約を設定し、人間が試行錯誤を基に調整する。この作業には、治療計画者の経験や多大な労力／時間（数時間、場合によっては数日）を要し、人的エラーも生じうる¹⁸⁾¹⁹⁾。このため、人間の介入なしで臨床的に許容可能な治療計画の作成が目指されている。現在までには、過去の解剖学的情報が近い症例での治療計画を適用する手法²⁰⁾や治療計画者を模倣する手法²¹⁾などが開発されている。後者の手法は商用ソフトウェアにも実装されており、Auto-Planning（Philips Radiation Oncology Systems, Fitchburg, WI, USA）などが広く普及している。一方で、一部の症例では臨床的基準を完全に満たすことができないなどの課題が残されている。人工知能は前述した目的を達成する新たな手段であり、現在注目されている。アプローチ方法としては、1) 達成可能な線量の予測、2) 治療計画者の模倣（仮想治療計画者）の2つに大別されるが、ここでは現在主流の手法である1) 達成可能な線量の予測についてのみ述べていく。

達成可能な線量を予測する手法は、最適化の開始時に DVH（Dose Volume Histogram）や3次元線量分布などの達成可能な線量を予測することを目的としている（図5）。本手法を用いることで、試行錯誤を要せずに患者個々に対して適切な目標線量の設定が可能となる。この客観的な目標線量は治療計画者の経験に基づく主観的なパラメータよりも理想的なパラメータ




図5：達成可能な線量の予測

に近い、円滑に高品質な治療計画を作成することが可能となる。これらの方法は通常、知識ベース計画 (KBP: Knowledge-based planning) 方法と呼ばれ、過去の高品質な計画からの情報から様々なモデルを学習させ、新しい計画の達成可能な線量目標を予測する。例えば、標的と正常臓器との幾何学的位置関係などを特徴として学習させることで、DVH を予測する手法が開発されている²²⁾。この予測した DVH を用いる手法は商用ソフトウェアにも実装されており、RapidPlan (Varian Medical Systems, Palo Alto, USA) などが代表的である。また、前述した輪郭情報の描出と同様、U-Netなどのモデルを用いることで3次元線量分布を予測することも研究されている²³⁻²⁶⁾。これらの手法を用いることにより、治療計画時間の大幅な短縮 (数時間→数十分) が可能となる²⁶⁾。

人工知能の臨床導入の課題

前述したように放射線治療における人工知能導入は大きなメリットをもたらすが、アルゴリズムの性質やソフトウェア周りの知財の関係から、いわゆる「ブラックボックス」の側面が大きい。特に、人工知能モデルの学習は入力データの品質に大きく依存する。データの品質が低いと使用可能なデータが不十分になり、モデルの動作範囲 (適応できる症例) が狭くなる可能性がある。また、データの増しなどの手法により、データ不足を軽減できる可能性はあるが、全ての症例やシナリオに適応できるわけではない。そのため、学習元となるデータセットの整備は非常に重要である。一方で、その学習元のデータベースの作成も困難を極めている。データの標準化やプライバシーの課題により、異なる施設間のデータ共有が難しく、データの品質

の統一基準の作成が急務となっている。国内外で医療データベースは急速に構築されているが、データの品質が統一されていないものが多く、扱いには十分な注意が必要である。さらに、アルゴリズム自体の信頼性も重要である。また、多くの人工知能モデルは、人間の介入が必要な場合を判断するための信頼スコアを提供することができない。前述したように人工知能アルゴリズムの精度はモデルや学習データに依存するため、得られた結果が必ずしも正しいとは限らない。そのため、得られた結果が妥当なものかどうかを解釈するための知識や経験が必須である。臨床導入の際には、信頼性の高い/低い症例の検討を十分に実施する必要がある。

結 語

人工知能は我々の生活に普及し、必要不可欠な存在になりつつある。現在、多くの分野で AI 技術の開発および導入が盛んであり、医療領域も例外ではない。特に、放射線医療は臨床情報や画像情報などの大量のデータを有する分野であり、人工知能との親和性は非常に高い。放射線医療における人工知能のここ数年の発展は目覚ましく、AI を搭載したソフトウェアやハードウェアが臨床現場にも普及している。放射線治療においては時間的および人的コストの削減が可能となり、患者により良い治療を提供できるようになると考えられる。しかし、情報活用能力が不十分な場合では、セキュリティリスクや出力ミスなどを引き起こす可能性がある。リスクを回避するためには、十分に理解して使用することが重要である。

開示すべき潜在的利益相反状態はない。

文

- 1) Silver D, Huang A, Maddison CJ, Guez A, Sifre L, van den Driessche G, Schrittwieser J, Antonoglou I, Panneershelvam V, Lanctot M, Dieleman S, Grewe D, Nham J, Kalchbrenner N, Sutskever I, Lillicrap T, Leach M, Kavukcuoglu K, Graepel T, Hassabis D.

献

- Mastering the game of Go with deep neural networks and tree search. Nature, 529: 484-489, 2016.
- 2) Manco L, Maffei N, Strolin S, Vichi S, Bottazzi L, Strigari L. Basic of machine learning and deep learning in imaging for medical physicists. Phys

- Med, 83: 194-205, 2021.
- 3) Delaney G, Jacob S, Featherstone C, Barton M. The role of radiotherapy in cancer treatment: estimating optimal utilization from a review of evidence-based clinical guidelines. *Cancer*, 104: 1129-1137, 2005.
 - 4) Numasaki H, Nakada Y, Okuda Y, Ohba H, Teshima T, Ogawa K, Japanese Society for Radiation Oncology Database C. Japanese structure survey of radiation oncology in 2015. *J Radiat Res*, 63: 230-246, 2022.
 - 5) Huynh E, Hosny A, Guthier C, Bitterman DS, Petit SF, Haas-Kogan DA, Kann B, Aerts H, Mak RH. Artificial intelligence in radiation oncology. *Nat Rev Clin Oncol*, 17: 771-781, 2020.
 - 6) Van de Steene J, Linthout N, de Mey J, Vinh-Hung V, Claassens C, Noppen M, Bel A, Storme G. Definition of gross tumor volume in lung cancer: inter-observer variability. *Radiother Oncol*, 62: 37-49, 2002.
 - 7) Cui Y, Chen W, Kong FM, Olsen LA, Beatty RE, Maxim PG, Ritter T, Sohn JW, Higgins J, Galvin JM, Xiao Y. Contouring variations and the role of atlas in non-small cell lung cancer radiation therapy: Analysis of a multi-institutional preclinical trial planning study. *Pract Radiat Oncol*, 5: e67-75, 2015.
 - 8) Ohri N, Shen X, Dicker AP, Doyle LA, Harrison AS, Showalter TN. Radiotherapy protocol deviations and clinical outcomes: a meta-analysis of cooperative group clinical trials. *J Natl Cancer Inst*, 105: 387-393, 2013.
 - 9) Wuthrick EJ, Zhang Q, Machtay M, Rosenthal DI, Nguyen-Tan PF, Fortin A, Silverman CL, Raben A, Kim HE, Horwitz EM, Read NE, Harris J, Wu Q, Le QT, Gillison ML. Institutional clinical trial accrual volume and survival of patients with head and neck cancer. *J Clin Oncol*, 33: 156-164, 2015.
 - 10) Schipaanboord B, Boukerroui D, Peressutti D, van Soest J, Lustberg T, Dekker A, Elmpt WV, Gooding MJ. An Evaluation of Atlas Selection Methods for Atlas-Based Automatic Segmentation in Radiotherapy Treatment Planning. *IEEE Trans Med Imaging*, 38: 2654-2664, 2019.
 - 11) Xu F, Ma H, Sun J, Wu R, Liu X, Kong Y. LSTM multi-modal UNet for brain Tumor segmentation, *IEEE*, 236-240, 2019.
 - 12) Podobnik G, Stojan P, Peterlin P, Ibragimov B, Vrtovec T. HaN-Seg: The head and neck organ-at-risk CT and MR segmentation dataset. *Med Phys*, 2023.
 - 13) Weston AD, Korfiatis P, Philbrick KA, Conte GM, Kostandy P, Sakinis T, Zeinoddini A, Boonrod A, Moynagh M, Takahashi N, Erickson BJ. Complete abdomen and pelvis segmentation using U-net variant architecture. *Med Phys*, 47: 5609-5618, 2020.
 - 14) Chen X, Sun S, Bai N, Han K, Liu Q, Yao S, Tang H, Zhang C, Lu Z, Huang Q, Zhao G, Xu Y, Chen T, Xie X, Liu Y. A deep learning-based auto-segmentation system for organs-at-risk on whole-body computed tomography images for radiation therapy. *Radiother Oncol*, 160: 175-184, 2021.
 - 15) Sarria GR, Kugel F, Roehner F, Layer J, Dejonckheere C, Scafa D, Koeksal M, Leitzen C, Schmeel LC. AI-based auto-segmentation: advantages in delineation, absorbed dose-distribution and logistics. *Advances in Radiation Oncology*, 2023.
 - 16) Tian S, Wang C, Zhang R, Dai Z, Jia L, Zhang W, Wang J, Liu Y. Transfer Learning-Based Autosegmentation of Primary Tumor Volumes of Glioblastomas Using Preoperative MRI for Radiotherapy Treatment. *Front Oncol*, 12: 856346, 2022.
 - 17) Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation, Springer, 234-241, 2015.
 - 18) Nelms BE, Robinson G, Markham J, Velasco K, Boyd S, Narayan S, Wheeler J, Sobczak ML. Variation in external beam treatment plan quality: An inter-institutional study of planners and planning systems. *Pract Radiat Oncol*, 2: 296-305, 2012.
 - 19) Berry SL, Boczkowski A, Ma R, Mechalakos J, Hunt M. Interobserver variability in radiation therapy plan output: Results of a single-institution study. *Pract Radiat Oncol*, 6: 442-449, 2016.
 - 20) Sheng Y, Li T, Zhang Y, Lee WR, Yin FF, Ge Y, Wu QJ. Atlas-guided prostate intensity modulated radiation therapy (IMRT) planning. *Phys Med Biol*, 60: 7277-7291, 2015.
 - 21) Cilla S, Ianiro A, Romano C, Deodato F, Macchia G, Buwenge M, Dinapoli N, Boldrini L, Morganti AG, Valentini V. Template-based automation of treatment planning in advanced radiotherapy: a comprehensive dosimetric and clinical evaluation. *Sci Rep*, 10: 423, 2020.
 - 22) Wu B, Ricchetti F, Sanguineti G, Kazhdan M, Simari P, Jacques R, Taylor R, McNutt T. Data-driven approach to generating achievable dose-volume

- histogram objectives in intensity-modulated radiotherapy planning. *Int J Radiat Oncol Biol Phys*, 79: 1241-1247, 2011.
- 23) Nguyen D, Long T, Jia X, Lu W, Gu X, Iqbal Z, Jiang S. A feasibility study for predicting optimal radiation therapy dose distributions of prostate cancer patients from patient anatomy using deep learning. *Sci Rep*, 9: 1076, 2019.
- 24) Mashayekhi M, Tapia IR, Balagopal A, Zhong X, Barkousaraie AS, McBeth R, Lin MH, Jiang S, Nguyen D. Site-agnostic 3D dose distribution prediction with deep learning neural networks. *Med Phys*, 49: 1391-1406, 2022.
- 25) Kajikawa T, Kadoya N, Ito K, Takayama Y, Chiba T, Tomori S, Nemoto H, Dobashi S, Takeda K, Jingu K. A convolutional neural network approach for IMRT dose distribution prediction in prostate cancer patients. *J Radiat Res*, 60: 685-693, 2019.
- 26) Miki K, Kusters M, Nakashima T, Saito A, Kawahara D, Nishibuchi I, Kimura T, Murakami Y, Nagata Y. Evaluation of optimization workflow using custom-made planning through predicted dose distribution for head and neck tumor treatment. *Phys Med*, 80: 167-174, 2020.

著者プロフィール



梶川 智博 Tomohiro Kajikawa

所属・職：京都府立医科大学大学院医学研究科放射線診断治療学・助教

略 歴：平成29年3月 東北大学 医学部保健学科 放射線技術科学専攻 卒業

平成31年3月 東北大学大学院医学系研究科 医科学専攻 修士課程 卒業

令和5年3月 東北大学大学院医学系研究科 医科学専攻 博士課程 卒業

平成31年4月～現職

専門分野：放射線治療，画像処理，機械学習，深層学習

- 主な業績：1. Tomohiro Kajikawa, Noriyuki Kadoya, Yosuke Maehara, Hiroshi Miura, Yoshiyuki Katsuta, Shinsuke Nagasawa, Gen Suzuki, Hideya Yamazaki, Nagara Tamaki, Kei Yamada. "A deep learning method for translating 3DCT to SPECT ventilation imaging: First comparison with ^{81m}Kr - gas SPECT ventilation imaging." *Medical Physics* **49**, 7: 4353-4364, 2022.
2. Tomohiro Kajikawa, Noriyuki Kadoya, Shohei Tanaka, Hikaru Nemoto, Noriyoshi Takahashi, Takahito Chiba, Kengo Ito, Yoshiyuki Katsuta, Suguru Dobashi, Ken Takeda, Kei Yamada, Keiichi Jingu. "Dose distribution correction for the influence of magnetic field using a deep convolutional neural network for online MR-guided adaptive radiotherapy." *Physica Medica*, **80**: 186-192, 2020.
3. Tomohiro Kajikawa, Noriyuki Kadoya, Kengo Ito, Yoshiki Takayama, Takahito Chiba, Seiji Tomori, Hikaru Nemoto, Suguru Dobashi, Ken Takeda, Keiichi Jingu. "A convolutional neural network approach for IMRT dose distribution prediction in prostate cancer patients." *Journal of radiation research* **60**, 5: 685-693, 2019.
4. Tomohiro Kajikawa, Noriyuki Kadoya, Kengo Ito, Yoshiki Takayama, Takahito Chiba, Seiji Tomori, Ken Takeda, Keiichi Jingu. "Automated prediction of dosimetric eligibility of patients with prostate cancer undergoing intensity-modulated radiation therapy using a convolutional neural network." *Radiological physics and technology*, **11**: 320-327, 2018.