

11. 体幹部定位放射線治療におけるAIの応用

河原 大輔 広島大学病院放射線部

stereotactic body radiation therapy (SBRT) は、限局性腫瘍に対して高線量を少分割で投与することで高い局所制御率を得る治療法として普及している。従来の放射線治療に比べて幾何学的精度や急峻な線量勾配が求められるため、腫瘍輪郭の一貫性、治療計画、品質保証など、治療全体のワークフローにおいて高精度化と標準化が不可欠である。しかし、これらのプロセスは人的資源への依存度が高く、施設間差や作業効率の問題が顕在化している。特に輪郭作成や治療計画は、時間と労力を要し、観察者間のバラツキが治療精度や臨床試験の信頼性に影響を与える可能性がある。現在、研究レベルではあるが、治療効果予測に人工知能 (AI) が多く活用されている。こうした背景の下、AI技術の導入は、作業負担の軽減と標準化を同時に実現する手段として期待されている。

本稿では、SBRTにおけるAI活用の現状ならびに今後の課題と展望を示すことで、SBRTの精度向上と効率化におけるAIの役割を明らかにする。

SBRT ワークフローにおけるAI活用

SBRTのワークフローは以下に分けられる。

- ① 輪郭作成
- ② 治療計画
- ③ 品質保証 (QA)
- ④ 治療効果予測

AI技術の導入を中心に、ワークフローごとのAIの活用状況を概説する。

1. 輪郭作成 (auto-segmentation)

放射線治療における輪郭作成は、標的および周囲の危険臓器 (organs at risk : OAR) の定義を行うきわめて重要な工程である。特にSBRTでは、小体積領域に高線量を投与しつつ周囲臓器への線量を厳格に制御する必要があるため、輪郭の一貫性と精度が治療成績を左右する。従来行われていた自動輪郭手法として、CT値の閾値法やエッジ検出、アトラスベースの手法などが用いられてき

たが、これらはノイズや低コントラスト領域に弱く、施設間で精度にバラツキが生じやすいとされてきた。

近年では、深層学習 (deep learning : DL)、特に畳み込みニューラルネットワーク (convolutional neural network : CNN) を利用した自動輪郭が急速に商用化され、多施設で実用化が進んでいる。NRG Oncologyのレビューでは、自動輪郭の技術は「強度解析・形状モデリング、アトラスベース、機械学習ベース、深層学習ベース」に整理され、それぞれの特徴、利点、欠点が明示されている (表1)¹⁾。CNNを利用した手法は、大規模な臨床データから特徴を学習し、OARや腫瘍輪郭を高い再現性で抽出できる点が最大の特長である²⁾。実際、商用ツール [Mirada RTx (Mirada Medical社), MIM Maestro (MIM Software社), Limbus AI (AMG Medtech社), Contour+ (Mvision AI社), AutoContour (Radformation社), ART-Plan (TheraPanacea社), AI-Rad Companion (シーメンス社) など] はすべてCNNベースで設計されており、多

表1 自動輪郭作成手法

| 手 法 | アルゴリズム | 利 点 | 欠 点 |
|--------------|---------------------------------|---|---|
| 強度解析・形状モデリング | 閾値処理、エッジ検出、アクティブ輪郭、アクティブシェイプモデル | <ul style="list-style-type: none"> ・計算が単純で説明可能性が高い ・少数データでも適用可能 ・失敗パターンが明確 | <ul style="list-style-type: none"> ・画像品質や臓器境界の明瞭さに依存 ・解剖学的文脈を反映できない ・軟部組織のセグメンテーションには不向き |
| アトラスベース | 変形画像レジストレーション | <ul style="list-style-type: none"> ・既存のレジストレーション技術を活用 ・数十例のアトラス構築で運用可能 | <ul style="list-style-type: none"> ・解剖変動や体形差への適応が限定的 ・大規模解剖変化に弱い |
| 機械学習ベース | ランダムフォレスト、SVM、k-means クラスタリング | <ul style="list-style-type: none"> ・幾何学的文脈をモデルに組み込み可能 ・数十～百例程度で訓練可能 | <ul style="list-style-type: none"> ・データが増えても性能向上は限定的 ・特徴量選択が難しく、失敗要因が不明瞭になりやすい |
| 深層学習ベース | CNN (U-Net系など) | <ul style="list-style-type: none"> ・解剖学的文脈を頑健に学習可能 ・数千例以上の大規模データにも対応可能 | <ul style="list-style-type: none"> ・学習には高性能GPUなど計算資源が必要 ・数百万以上のパラメータでモデル最適化が困難 ・「ブラックボックス性」により説明可能性が低い |