

放射線治療における深層学習の産業応用 Industrial application of deep learning in radiotherapy

イーグロース株式会社 ○今西 勁峰

京都大学大学院情報学研究科 中尾 恵

京都大学大学院医学研究科 中村 光宏

Abstract 放射線治療の実施において、患者の臓器や腫瘍(以下、関心領域と呼ぶ)等に対する照射予定線量を評価するために、事前に各関心領域の三次元領域情報を定義する必要があり、その作業負担は専門医にとって大きい。これを軽減するため、深層学習による臓器抽出研究の試み、および研究や産業の活性化を促進するためのデータ解析フレームワーク開発について紹介する。

1. はじめに

高齢化社会ではがん撲滅が国民的課題となっており、がん治療の中でも高精度化や四次元治療が進みつつある放射線治療は低侵襲であることから、深層学習技術等も応用した活発的な研究活動が期待されている[1]。例えば、放射線治療を実施する上で、治療計画時に CT 画像上で病変と周辺臓器の輪郭を入力していく膨大かつ煩雑な作業が生じており、専門医の入力負担を軽減するため、深層学習による臓器抽出するアプローチ[2]が考えられている。しかし、研究施設において、放射線治療計画データ(DICOM-RT)を用いての深層学習、治療実績評価や新たな治療法検討等の高度研究に対し、研究を実施する際には下記の問題点があった。

① 医療施設ごとの DICOM-RT において、保有データの偏りや臓器輪郭の定義方針にばらつきがあり、他施設データで訓練された深層学習モデルを直ちに用いるには精度が不十分である可能性がある。その場合、各医療施設内にて、保有データから教師データを抽出して転移学習を実施し、精度を確保する必要がある。

② DICOM-RT データからタグ、画像情報を抽出するフリーソフトウェア[3]も提供されているが、抽出タグから簡単に画像情報や輪郭情報を三次元最構成(以下、再構成データと呼ぶ)できる手段が確立されていない。

③ 一部の放射線治療向け製品では MATLAB 言語等と連携したデータ抽出機能を提供しているが、ライセンス価格が高価(500~2,000 万以上)のため、研究実施する際に大きなハードルとなっており、資金が潤沢な研究施設のみに限定される。

④ 一部の製品ではデータの解析機能を提供しているが、組み込み機能であるため、研究者側が簡単に解析手法の変更や追加ができない。

⑤ 国内で放射線治療計画データを読み・表示用ソフトウェアエンジンを開発可能な企業はごく少数であるため、データ抽出・加工するための製品カスタマイズ依頼は容易でない上、リソース問題で加工コストが高くなりやすい。

本研究では、当社が開発した DICOM-RT 解析・表示用ソフトウェアエンジン内に、深層学習等でも幅広く採用されており、利用人口が飛躍的に増加している Python 言語の組込型連携基盤(以下提案基盤と呼ぶ)を導入し、Python 言語によって、DICOM-RT、CT または MRI の三次元医用画像データに対し、簡便かつ自由に研究目的に従ったデータ抽出を実現することを目指している(図 1)。プロセス間通信を用いて DICOM-RT 解析エンジン側と Python プロセス側のデータ交換を実現することで、医用画像データから研究用データを抽出できるのみでなく、医用画像データへ領域定義を反映して視覚的な評価も行える。例えば、CT に対し肺野輪郭を定義した上での目視確認や、DICOM-RT、PLY、STL 等フォーマットへのエクスポートをそれぞれ簡便な Python コードで行える環境を提案基盤によって実現した。また、提案基盤を介して、DICOM-RT データから抽出した CT の 3D 画像および臓器輪郭の三次元領域情報を用いて、深層学習による臓器抽出の研究を試み、有用性を確認したので報告する。

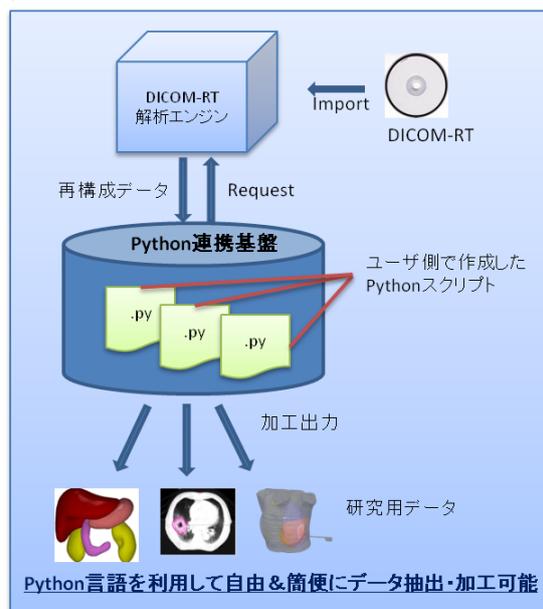


図 1 提案基盤:Python 連携基盤の導入による簡便な再構成データの抽出・加工環境の実現

2. 実現方法

本研究では、DICOM-RT 解析エンジンのプロセスと Python プロセス間にプロセス通信機構を導入しつつ、ユーザ側にはデータを簡便にアクセス可能な Python 言語 API(Application Programming Interface. 以下、本 API と呼ぶ)を提供している。本 API で指示された処理は DICOM-RT 解析エンジン側に伝達され、三次元データの再構成や加工処理は DICOM-RT 解析エンジン側で高速に処理された後、Python プロセス側へ処理結果が自動的に戻される。本 API を介して Python 言語で指示できる処理機能の一部を以下に示す。

- DICOM-RT/CT/MRI 読み込み
- 三次元ボリュームデータ(画像・臓器領域・線量分布)の取得
- 三次元メッシュのエクスポート(PLY/STL)
- 線形補間による三次元ボリュームデータのリサイズ処理
- DICOM-RT/CT/MRI への臓器領域の追加定義

ユーザはこれらを組み合わせ的に利用することが可能であり、煩雑なデータ再構成手法やプロセス通信の仕組みを知る必要なく、数行の Python 言語でデータの読み込みから三次元データ抽出・加工、データ書き出しまでをプログラマブルに行え、迅速に研究実施に移行できる。本 API を利用し、DICOM CT データの読み込みから三次元 CT 画像の取得、書き出しまでの Python コードの例を下記に示す。

```
grtv=pyGRTV()
grtv.readRTDir("testdata/")
ret,img=grtv.readGRTVRaw(grtv.GRTV_DATA_TYPE_IMAGE)
grtv.writeRaw("testdata_ct.raw",img)
```

3. 深層学習による臓器抽出

提案基盤の有用性を確認するため、本研究では、肝臓の輪郭を持つ DICOM-RT データ 239 症例を利用して検証を行った。239 症例のうち、192 症例の CT 画像および肝臓領域の三次元再構成データを提案基盤を介して抽出して肝臓領域の自動抽出に対する深層学習を行った。学習モデルは U-Net[4]を採用し、入力層には連続する 3 スライス画像をランダムに与え、出力層では入力された 3 スライスに相当する肝臓領域のラベル画像(0:肝臓領域外, 1:肝臓領域内)を出力するよう深層学習を実施した。

学習済みモデルを用いて、残りの 47 症例をテストデータとして、学習データと同様に提案基盤を介してその CT 画像を抽出した上で肺領域の自動抽出を実施し、Dice 係数を用いて精度評価を行った。評価の結果、47 症例のうち、最も精度の高かった症例の Dice 係数は 0.97 であり、

最も精度の低かった症例の Dice 係数は 0.85 であり、平均 Dice 係数は 0.94 であった(図 2)。また、その抽出結果例を図 3 に示す。本検証により、提案基盤を用いて抽出されたデータは深層学習にとって有用であることが分かった。本検証では 200 例程度に対して自動実行で抽出を行ったのみにとどまったが、症例数が増えるにつれ、抽出作業の自動実行は研究者の負担を大きく軽減可能である。

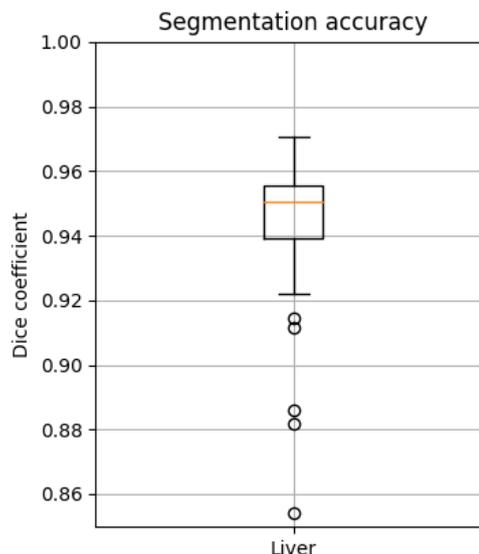


図 2 検証データ(47 症例)に対する肝臓の三次元領域の自動抽出精度結果

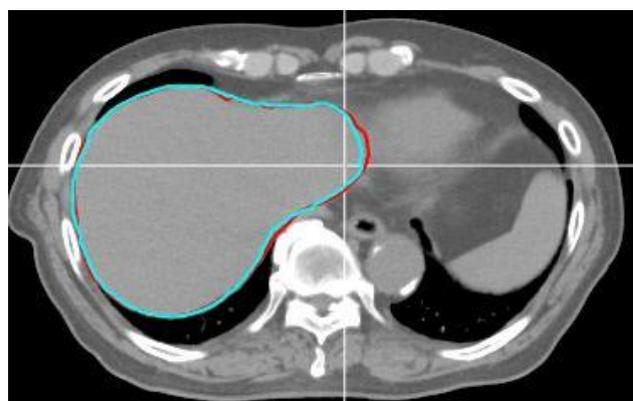


図 3 肝臓領域の抽出結果例。赤:正解輪郭。青:自動抽出領域に基づいて再構成された輪郭。

4. 他研究への応用

4.1. 臓器の呼吸性変位推定

放射線治療において、病変以外の正常組織への被曝軽減のため、動体追尾照射手法が取られている。X 線透視画像が不明瞭な臓器に対しても高精度な追尾照射を実施するために、岩井ら[5][6]は複数臓器の呼吸性変位を表現可能な統計的変位モデルを構築し、対象臓器の変位推定に関する研究が試みされている(図 4)。当該研究では各症例、各呼吸位相、各臓器ごとの三次元表面積

状メッシュを生成する必要があり、従来の DICOM-RT Viewer 製品等による手動データ書き出しでは他症例へ研究を展開する際に大きな負担となる。

提案基盤を用いれば、複数症例であっても、症例データ読み込みから再構成データ生成、メッシュ形状エクスポートまでをすべて自動化することができ、研究実施を迅速に開始できる。

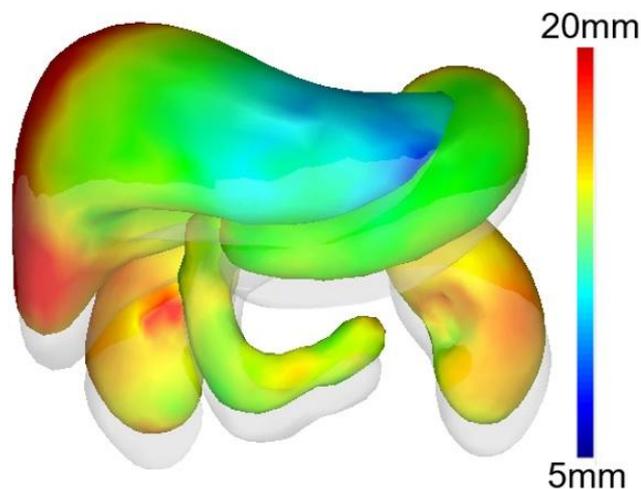


図 4 腹部臓器の統計変位モデル

4.2. 深層学習によるスライス補間

CT 撮像時の被曝減少や画像サイズ抑制のため、スライス間隔を比較的疎にしているデータも多い。そのようなデータでは、従来一般的に取られている線形補間によるスライス補間手法では、十分に臓器・骨等の三次元形状を表現できていないことや、三次元像を表示する際に不自然なジャギーが発生する問題が知られている。

この問題を軽減するため、我々は胸部 CT 画像 192 例に対し、提案基盤を利用して CT の三次元画像データを抽出後、深層学習を用いてスライス補間モデルの生成(図 5)を試みた。学習後のモデルを用いてテストデータ 48 例に対してスライス補間を行ったところ、すべての症例で線形補間の精度を上回った。従来の線形補間と深層補間による三次元表示像の比較を図 6 に示す。

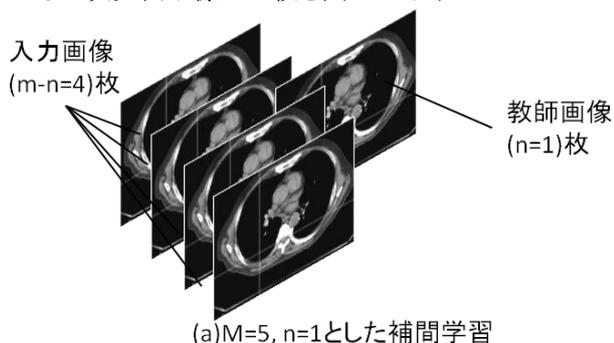


図 5 医用画像スライスに対する深層補間の学習

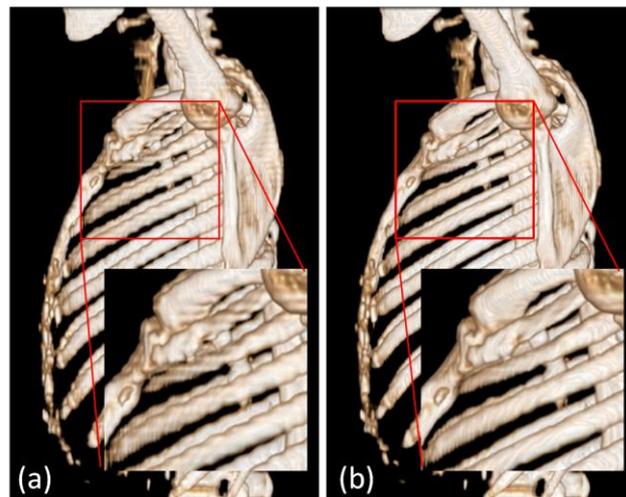


図 6 線形補間と深層補間による三次元像(ボリュームレンダリング)の違い。(a)線形補間法。(b)深層補間法。

5. まとめ

本研究では DICOM-RT 解析エンジンに対し Python 言語の組み込み型連携基盤を導入した。提案基盤の API を介し、数行の Python 言語によって、DICOM-RT、CT または MRI の三次元医用画像データを簡便に抽出・加工が行える。肝臓輪郭を持つ DICOM-RT に対し、提案基盤を介して深層学習用の三次元再構成データを抽出して肝領域の自動抽出を行ったところ、Dice 係数 0.94 の精度で抽出することができ、抽出データは深層学習に対して有用であることが確認された。また、他の研究に対しても、研究内容に応じて、本基盤の API を組み合わせることで研究に必要なデータ抽出が行える可能性を示せた。

研究実施者は専門的な知識が必要かつ煩雑なデータ再構成処理を提案基盤を介して DICOM-RT 解析エンジン側に委譲し、迅速に研究用データを取得可能であるため、研究実施の分業化、研究協力対象の拡大や競争の活発化に繋がり、放射線治療分野における高度研究開発実施に大きく貢献することが可能である。今後はさらなる機能拡張を行い、データ抽出・加工のみでなく、三次元再構成データに対して、深層学習の汎化性能を向上させるのに不可欠であるデータ拡張機能を備えられるよう改良を進める予定である。

謝辞

本研究は、平成 30 年度「京都発革新的医療技術研究開発助成事業」の助成による。

参考文献

[1] Berkman Sahiner, Aria Pezeshk, Lubomir M. Hadjiiski, Xiaosong Wang, Karen Drukker, Kenny H. Cha, Ronald M. Summers, Maryellen L. Giger, "Deep learning in medical

- imaging and radiation therapy", Medical physics 2018.
- [2] Ben-Cohen, A., Diamant, I., Klang, E., Amitai, M. and Greenspan, H. "Fully convolutional network for liver segmentation and lesions detection", Proceeding of International Workshop on Deep Learning in Medical Image Analysis, (2016), Springer, Quebec City, 77-85.
 - [3] DCMTK, <http://dicom.offis.de/>
 - [4] Olaf Ronneberger, Philipp Fischer, Thomas Brox : "U-Net: Convolutional Networks for Biomedical Image Segmentation", Medical Image Computing and Computer-Assisted Intervention(MICCAD), Vol. 9351, pp234-241, 2015.
 - [5] 岩井 泰児, 中尾 恵, 中村 光宏, 松田 哲也, "動体追尾放射線治療のための複数周辺臓器の多次元特徴量に基づく膵癌変位推定法", 電子情報通信学会技術報告 (MI), Vol. 118, No. 286, pp. 7-12, Nov 2018.
 - [6] 岩井 泰児, 中尾 恵, 中村 光宏, 松田 哲也, "呼吸性変位を表現可能な 複数臓器の統計的変位モデル構築の試み", 生体医工学, Annual 56, pp. 20-21, Jun 2018.