

大規模 CT データ及び読影レポートを用いた疾患異常検出モデルの開発

佐藤 淳哉

大阪大学 大学院医学系研究科

1. はじめに

CT 画像をくまなく検索し異常を検出・診断することは放射線科医にとって日常的に行われる業務である。CT は救急外来や手術後の経過観察等で頻繁に撮影され、特に本邦では他の先進国と比較しても撮影件数が多い[1]。それに伴い診断する医師の負担は増加傾向で、医師の見落としを防ぎ治療方針の決定に役立つコンピュータ診断支援システム (CAD) の需要が高まっている (図 1)。

深層学習の発展により多くの疾患で疾患検出精度の高い CAD が開発されているが、そのほとんどが単一の臓器、疾患に限られた手法である。くまなく異常を検出すべき状況では、広範囲を探索し網羅的に異常を拾い上げる CAD を開発する必要がある。

上記の背景の下、本研究では 3 施設で日常的に撮影されている腹部 CT 画像を収集し、多臓器の異常所見を検出する深層学習モデルの学習を試みた。複数臓器での疾患検出を行うために、まず大規模計算機で学習させた高精度セグメンテーションモデルを用いて腹部 CT 画像全体から各臓器領域の情報を取得する。その後、臓器の画像と疾患情報と対応させる学習を行う。医療画像における深層学習モデルは学習に用いる教師データ作成の負担が大きいことが課題であるが、本手法では CT 画像に付属する読影レポートを構造化し疾患情報を抽出し教師データとして利用する。これにより学習コストを低減し、大量のデータを用いた学習を試みる。

2. 大規模計算機での高精度セグメンテーション

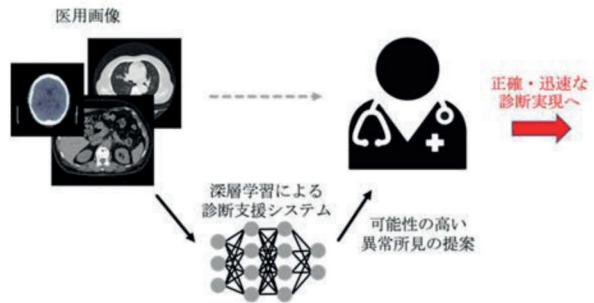


図 1：医用画像診断支援システムの概念

本節では、多臓器疾患検出モデルに不可欠な臓器セグメンテーション手法を紹介する。CT 画像は人体に多方向から X 線を照射し、減衰の程度を検出して作成される 3 次元断層画像である。そのため画像サイズが大きく、一般的な自然画像と比較し学習の際に計算機による制約(必要メモリや計算時間の増加)を強く受けていた。特に臓器セグメンテーションでは、臓器と周囲との解剖学的位置関係を把握することが重要であるため、可能な限り大きな画像をモデルに入力することが望ましい。そこで本研究では生命科学画像セグメンテーションモデルの第一選択となっている nnUNet[2]に改良を加え、学習のパラメータである patch size (モデルに入力する画像領域)と batch size を通常より大きく設定し SQUID を用いた多ノード並列計算を実施した[3]。この手法は医療画像処理及びコンピュータ支援外科の分野の国際学会である MICCAI (Medical Image Computing and Computer Assisted Intervention) 主催の臓器セグメンテーションの精度を競う AMOS (Abdominal Multi-Organ Segmentation) challenge[4]で入賞し、大規模計算機を用いた本手法の有効性を示すことができた。

3. 読影レポート構造化モデル

本節では、画像検査に付随する読影レポートから臓器ごとに疾患情報を抽出する構造化モデルを紹介する。医療画像における教師データは作成に高い専門性が必要で、大量に用意することが困難である。深層学習による高い診断精度をもつモデルを作成するために、既存の医療資源から疾患情報を抽出し学習に用いる研究が活発に行われている[5]。

放射線画像読影レポートは CT や MRI などの画像検査に対して放射線科医が作成する検査報告書である。レポートには臓器ごとに異常があればその部位や性状、考えられる疾患が詳細に記述されている。本邦における読影レポートは特定の記入規則を持たない自由記述式が大半であり、教師データとして深層学習へ応用することは困難であった。そこで、杉本らは自由記述式のレポートを構造化し疾患に関する特定の情報を得るためにデータ構造（情報モデル）を提案した[6]。図 2 に構造化モデルで表現されたレポートの例を示す。画像から読み取った観察物及びその部位やサイズ、性状、経時的な変化などの情報、総合的に疑われる臨床所見を関連付けて表示することができる。本研究ではこのレポート構造化モデルを利用することで教師データ作成の負担を低減し、より多くの画像を使用可能とした。

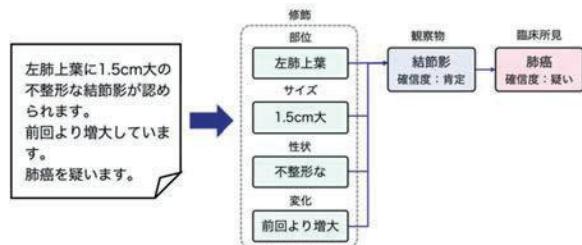


図 2 : 構造化モデルで表現されたレポートの例

4. 多臓器異常検出モデル

本節では、前節までで紹介した臓器セグメンテーションモデル及びレポート構造化モデルの結果を用いて異常所見モデルを学習させ、評価した結果を紹介する。

4.1 多臓器疾患検出モデル pipeline の概要

図 3 にモデルの概要を示す。CT 画像は前述の通り画像サイズが大きく全体像をそのまま入力することは不可能である。そこでまず、腹部 CT 画像から各臓器の領域を抽出し、また読影レポートから放射線科医による各臓器の解釈を抽出する。これにより、複数の臓器と疾患情報のセットを作成することができる。

4.2 使用データセット

学習に使用したデータセットは J-MID (日本医用画像データベース) を利用した。このデータベースにはビッグデータや人工知能等を利用した構造改革を推進することを目的に全国 10 施設の大学病院で日常的に撮影されている CT 及び MRI を収集したものである。初期検討のため、今回は 3 施設から 14116 症例、31449 シリーズの腹部 CT 画像を学習に用いた。

4.3 臓器画像と疾患情報の学習

本研究の異常検出モデルは、「異常あり」及び「異常なし」の 2 値分類器とした。臓器画像を人体の上下方向に 5 スライスごとに CNN (convolutional neural network) に入力し、得られた出力をさらに LSTM (long-short term memory) に入力、スライスごとの情報を統合させ最終的な出力を得た。損失関数は binary cross entropy を用いた。初期検討として、今年度は肝臓のみで学習した。

4.4 異常検出精度の比較

大量のデータを用いる本手法の有効性を評価するために、学習に使用するデータ数の割合を変化させ、精度に及ぼす影響を調べた。具体的には、用意した 31449 シリーズの画像全てを学習に用いたモデル (Full size) 及びランダムに選んだ 600、2000、3000、10000 シリーズを用いたモデル (Partial)、従来と同様に放射線医によって作成された教師データ 600 シリーズ (Human) で比較

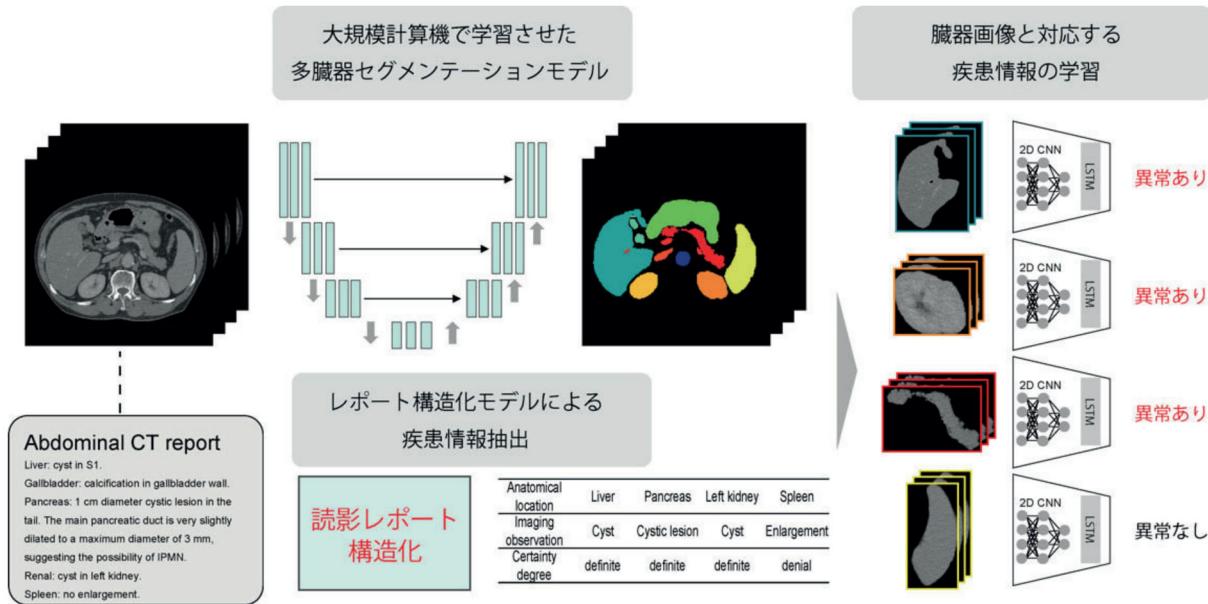


図 3：多臓器疾患検出モデルの pipeline

を行なった。評価指標は AUC (area under the curve) とした。図 4 に結果の ROC (receiver operating characteristic) 曲線及びそれらの AUC を示す。学習に使用した画像が多いほど、AUC が高くなる傾向があった。また画像数が同一の場合には、放射線科医により作られた教師データとレポート構造化モデルとの間に有意な差を認めなかつた。以上より、レポート構造化モデルを用い大量の画像を学習させる本手法の有用性を示すことができた。

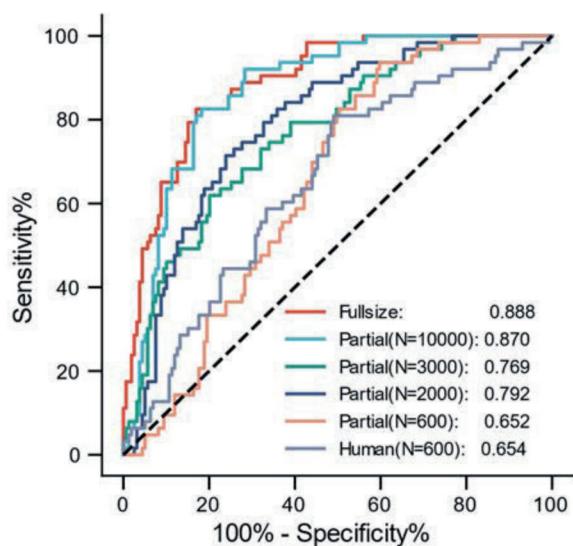


図 4：ROC (receiver operating characteristic) 曲線と AUC

5. セグメンテーションの所要時間

本研究で提案した臓器の疾患検出モデルの開発は 2 節でも述べた通り、大規模計算機によるセグメンテーションが不可欠である。事前に CT 画像を全てセグメンテーションする必要があり、データが大量になれば計算にかかる所要時間も増加する。本研究で nnUNet を用いて予測にかかる時間を計算したところ、SQUID 1 ノード (NVIDIA A100 GPU × 8) で 1 症例あたり約 4 分を要した。3 万件程度の予測には 1 ノードで約 3 ヶ月もの期間を要すると試算できる。さらに高い精度を達成するにはより多くの画像が必要になると推測されるため、多ノードでの並列計算が効率の良い予測に必要である。

6. おわりに

腹部 CT 画像の網羅的な異常所見検出のために、多臓器疾患検出モデルの開発を試みた。今回は資源の都合上肝臓のみを用いた初期検討を行なつたが、今後は他の施設からも画像を収集することでデータを増やし、肝臓以外の臓器でも同様の学習を実施する。また、疾患の有無の 2 値分類から発展させ、異常の種類ごとに多クラス分類学習も試みる。

CT 画像から病変を検出する CAD は医療において活発に深層学習が適用されている分野である。しかし学習データが少なく、施設も限られることから、臨床応用に足る精度に達しないことや多様な施設環境への適用できないことが問題となっている。国レベルでのデータの利用環境の整備が進む中で、本手法のような大規模データを最大限に活用できるシステムの需要は今後さらに高まっていくだろう。

謝辞

本手法の中核となる読影レポートの構造化に関して大阪大学医学系研究科医療情報学の杉本賢人氏に協力頂き、使用に関する助言を頂きました。深く感謝致します。本研究の一部は大阪大学次世代挑戦的研究者育成プロジェクト及び JSPS 科研費 21H03840

及びの助成を受けたものです。

また、大阪大学サイバーメディアセンターの公募利用による支援を受け SQUID 上で実施されました。

参考文献

- (1) OECD (2015), Health at a Glance 2015: OECD Indicators, OECD Publishing, Paris,
- (2) Isensee, Fabian, et al. 2021. Nature Methods 18 (2): 203–11.
- (3) Sato, Junya, and Shoji Kido. 2022. arXiv. <http://arxiv.org/abs/2210.13364>.
- (4) Ji, Yuanfeng, et al. 2022. arXiv. <http://arxiv.org/abs/2206.08023>.
- (5) Pons, Ewoud, et al. 2016. Radiology 279 (2): 329–43.
- (6) Sugimoto, Kento, et al. 2021. Journal of Biomedical Informatics 116 (April): 103729.