



|                     |                                                                                                 |
|---------------------|-------------------------------------------------------------------------------------------------|
| Title               | 深層学習を用いた医用画像データからの患者体重推定に関する研究                                                                  |
| Author(s)           | 市川, 翔太                                                                                          |
| Degree Grantor      | 北海道大学                                                                                           |
| Degree Name         | 博士(保健科学)                                                                                        |
| Dissertation Number | 甲第15817号                                                                                        |
| Issue Date          | 2024-03-25                                                                                      |
| DOI                 | <a href="https://doi.org/10.14943/doctoral.k15817">https://doi.org/10.14943/doctoral.k15817</a> |
| Doc URL             | <a href="https://hdl.handle.net/2115/94393">https://hdl.handle.net/2115/94393</a>               |
| Type                | doctoral thesis                                                                                 |
| File Information    | Shota_Ichikawa.pdf                                                                              |



# 学位論文

深層学習を用いた医用画像データからの  
患者体重推定に関する研究

市川 翔太

北海道大学大学院保健科学院  
保健科学専攻保健科学コース

2023年度

# 目次

|                                                 |        |
|-------------------------------------------------|--------|
| 論文要旨 .....                                      | - 4 -  |
| 第 1 章 緒論.....                                   | - 7 -  |
| 1.1 X 線 CT 検査における患者体重の重要性と課題 .....              | - 7 -  |
| 1.2 患者体重推定に関する先行研究と本研究の位置づけ .....               | - 11 - |
| 1.3 本論文の目的と構成 .....                             | - 12 - |
| 1.4 参考文献.....                                   | - 14 - |
| 第 2 章 深層学習の概説と畳み込みニューラルネットワークの基本構造.....         | - 17 - |
| 2.1 深層学習の概説 .....                               | - 17 - |
| 2.2 畳み込みニューラルネットワークの基本構造 .....                  | - 17 - |
| 2.3 Visual Geometry Group (VGG) -16 の基本構造 ..... | - 21 - |
| 2.4 参考文献.....                                   | - 21 - |
| 第 3 章 深層学習による CT 位置決め画像を用いた患者体重推定手法の提案.....     | - 23 - |
| 3.1 はじめに.....                                   | - 23 - |
| 3.2 方法 .....                                    | - 24 - |
| 3.2.1 対象と X 線 CT 撮影 .....                       | - 24 - |
| 3.2.2 データセットの構築と前処理 .....                       | - 25 - |
| 3.2.3 体重推定モデルの構造と学習 .....                       | - 26 - |
| 3.2.4 構築した CNN モデルの評価 .....                     | - 27 - |
| 3.2.5 統計解析 .....                                | - 28 - |
| 3.3 結果 .....                                    | - 29 - |
| 3.3.1 患者背景.....                                 | - 29 - |
| 3.3.2 推定体重の精度 .....                             | - 30 - |
| 3.3.3 推定誤差と実測体重の関係 .....                        | - 33 - |
| 3.3.4 処理時間.....                                 | - 34 - |
| 3.4 考察 .....                                    | - 34 - |
| 3.5 結論 .....                                    | - 37 - |
| 3.6 参考文献.....                                   | - 37 - |

|                                            |      |
|--------------------------------------------|------|
| 第4章 深層学習を用いた患者体重推定手法の胸部単純 X 線写真への応用 .....  | 40 - |
| 4.1 はじめに.....                              | 40 - |
| 4.2 方法 .....                               | 41 - |
| 4.2.1 対象.....                              | 41 - |
| 4.2.2 胸部単純 X 線撮影および前処理.....                | 42 - |
| 4.2.3 深層学習による体重推定手法 .....                  | 42 - |
| 4.2.4 構築した CNN モデルの評価と統計解析.....            | 43 - |
| 4.3 結果 .....                               | 44 - |
| 4.3.1 実測体重と推定体重の関係 .....                   | 44 - |
| 4.3.2 許容誤差に関する分析.....                      | 44 - |
| 4.3.3 Bland-Altman 分析 .....                | 45 - |
| 4.3.4 評価指標の比較 .....                        | 45 - |
| 4.3.5 臨床例と深層学習モデルが着目した領域の可視化.....          | 45 - |
| 4.4 考察 .....                               | 50 - |
| 4.5 結論 .....                               | 52 - |
| 4.6 参考文献.....                              | 52 - |
| 第5章 CT 横断像を用いた患者体重の推定：断面積測定法と深層学習の評価 ..... | 55 - |
| 5.1 はじめに.....                              | 55 - |
| 5.2 方法 .....                               | 56 - |
| 5.2.1 対象と撮影方法 .....                        | 57 - |
| 5.2.2 断面積を用いた線形回帰モデル .....                 | 59 - |
| 5.2.3 深層学習モデル .....                        | 60 - |
| 5.2.4 体重推定精度の検証.....                       | 61 - |
| 5.2.5 実験環境.....                            | 61 - |
| 5.3 結果 .....                               | 61 - |
| 5.3.1 線形回帰モデルの係数と適合度 .....                 | 61 - |
| 5.3.2 線形回帰モデルと深層学習モデルにおける推定精度.....         | 63 - |
| 5.4 考察 .....                               | 68 - |
| 5.5 結論 .....                               | 70 - |
| 5.6 参考文献.....                              | 70 - |

|                                            |      |
|--------------------------------------------|------|
| 第6章 X線 CT 検査における体重不詳患者の被ばく線量管理 .....       | 74 - |
| 6.1 はじめに.....                              | 74 - |
| 6.2 方法 .....                               | 76 - |
| 6.2.1 対象.....                              | 76 - |
| 6.2.2 X線 CT 検査 .....                       | 76 - |
| 6.2.3 深層学習を用いた体重推定手法 .....                 | 76 - |
| 6.2.4 患者体重と $CTDI_{vol}$ および DLP の関係 ..... | 78 - |
| 6.2.5 患者体重と SSDE の関係 .....                 | 78 - |
| 6.2.6 統計解析.....                            | 79 - |
| 6.3 結果 .....                               | 80 - |
| 6.3.1 推定体重の精度 .....                        | 80 - |
| 6.3.2 患者体重と $CTDI_{vol}/DLP$ の関係 .....     | 81 - |
| 6.3.3 患者体重と SSDE の関係 .....                 | 84 - |
| 6.4 考察 .....                               | 86 - |
| 6.5 結論 .....                               | 88 - |
| 6.6 参考文献.....                              | 88 - |
| 第7章 総括.....                                | 91 - |
| 謝辞.....                                    | 94 - |
| 業績リスト .....                                | 95 - |

# 論文要旨

患者体重は、X 線 computed tomography (CT) 検査の被ばく線量管理や造影剤投与量の決定において重要な指標である。しかしながら、救急医療を中心として、体重計を使用した測定や問診時に患者から聴取することが困難な場合がある。また、体重測定に要する僅かな時間の損失が患者の予後に大きく影響し、体重測定にともなう医療従事者の負担は救急医療のマンパワー不足を加速させる恐れがある。このような状況に対応するため、臨床現場では医療従事者が目視で推定した体重が代わりに用いられているが、その精度は十分ではない。そこで、画像診断のために取得された医用画像を副次的に活用し、深層学習を用いて高精度かつ即時に患者体重を推定することを着想した。本論文では、深層学習を用いた医用画像からの患者体重推定およびその応用に関する以下の 4 つの研究を実施した。

## 1) 深層学習による CT 位置決め画像を用いた患者体重推定手法の提案

CT 位置決め画像は、撮影範囲の決定、読影の際のスライス位置の確認、照射線量を変調させて線量低減を図る技術である CT automatic exposure control で使用する被写体情報の収集を目的に撮影される画像である。胸部および腹部の CT 位置決め画像と実測した患者体重を対として教師あり学習を行い、CT 位置決め画像から患者体重を直接推定できる深層学習モデルを構築した。結果として、平均絶対誤差 (mean absolute error : MAE) が胸部 CT 位置決め画像で 2.75 kg、腹部 CT 位置決め画像で 4.77 kg となった。実測体重から  $\pm 5$  kg 以内の誤差であった受診者の割合は、胸部 CT 位置決め画像で 82.3%、腹部 CT 位置決め画像で 56.7%であり、腹部 CT 位置決め画像を用いる場合よりも胸部 CT 位置決め画像を用いた場合のほうが、高い推定精度が得られることが明らかになった。

## 2) 深層学習を用いた患者体重推定手法の胸部単純 X 線写真への応用

胸部単純 X 線写真は、画像診断の中でも最も普及している検査法である。単純 X 線写真と CT 位置決め画像はどちらも身体の前後面方向を透過した X 線減弱の程度を平面画像に表したものであるという点で類似しており、深層学習による体重推定手法を胸部単純 X 線写真へ応用することで、提案手法の汎用性の向上を目指した。また、性差による X 線減弱特性の違いを考慮し、男女別モデルと男女混合モデルの 2 種類のモデルを作成し、精

度を比較した。結果として、男女混合モデルの MAE は女性に対して 2.69 kg、男性に対して 3.14 kg であった。一方、男女別モデルの MAE は女性に対して 2.63 kg、男性に対して 3.35 kg であった。以上の結果から、深層学習を用いた医用画像データからの体重推定手法は、胸部単純 X 線写真に対しても応用可能であること、モデル構築の際に性別を考慮する効果は小さいことが明らかになった。

### 3) CT 横断像を用いた患者体重の推定：断面積測定法と深層学習の評価

単一の CT 横断像を用いて、身長や体重などの形態学的指標、皮下脂肪や内臓脂肪などの体組成を評価する試みが行われてきた。患者体重に関しては、第三腰椎レベル中央の CT 横断像で手動により計測された断面積を入力とする線形回帰により、推定可能であることが報告されている。しかし、この線形回帰モデルの適用は第三腰椎レベルの CT 横断像に限定されるため、腹部 X 線 CT 検査または躯幹部 X 線 CT 検査を受けた患者にのみ適用可能である。また、手動による計測は臨床応用の観点から望ましくない。そこで、躯幹部 CT のさまざまなスライス位置の横断像に対して、断面積を自動的に算出する画像処理方法を提案し、スライス位置ごとに体重推定用の線形回帰モデルを求めた。同時に、1) および 2) で検証した深層学習を用いた手法も検証した。結果として、線形回帰モデルを用いた場合は、第五胸椎レベルの CT 横断像における断面積を入力とした場合の MAE が 5.39 kg であり、最も精度が高かった。一方、深層学習モデルを用いた場合は、第五腰椎レベルの CT 横断像を入力した場合の MAE が 6.72 kg であり、最も精度が高かった。以上の結果より、断面積を入力とする線形回帰モデルと、CT 画像から直接患者体重を推定する深層学習モデルにおいて、患者体重を推定するための最適なスライス位置が明らかになった。

### 4) X 線 CT 検査における体重不詳患者の被ばく線量管理

X 線 CT 検査の被ばく線量管理において、深層学習を用いて医用画像データから算出した推定体重が、実測体重の代替として使用可能であるかについて検討した。具体的には、深層学習を用いて胸部 CT 位置決め画像から算出した推定体重と実測体重に基づいた体重群別に胸部 X 線 CT 撮影の線量指標を比較したところ、実測体重を用いた場合と推定体重を用いた場合で同等の結果が得られた。また、個々の患者の線量評価をより正確に行うために、患者の体格を考慮した SSDE (size-specific dose estimates) の使用が推奨されている

が、SSDE を用いた線量評価のためには専用の被ばく線量管理ソフトウェアを使用する必要がある点や、患者の体輪郭が有効視野外となるような場合には、SSDE の算出に必要な実効直径や水当量直径を正確に求めることが困難になる点が課題として残されている。そこで、実測体重または推定体重と実効直径の換算式を作成し、SSDE 算出の簡略化を試みたところ、実測体重を用いた場合と推定体重を用いた場合で同等の SSDE を算出可能であることが示された。

以上、本研究の成果は、深層学習を用いることで画像診断のために取得された医用画像データから患者体重という新たな情報を引き出すことができることを明らかにしたものであり、医用画像データに付加価値をもたらすものである。算出された推定体重は、胸部 X 線 CT 撮影における被ばく線量管理において、実測体重の代替と成り得ることが示された。提案手法は、体重情報が不詳である成人患者の体重を高精度かつ即時に推定可能であり、臨床現場における X 線 CT 検査の被ばく線量管理や造影剤投与量の決定に活用されることが期待される。

# 第 1 章 緒論

## 1.1 X 線 CT 検査における患者体重の重要性と課題

体重情報は健康状態の評価や投薬量の算出、術後や慢性疾患の体液管理などに利用され、医療において不可欠な指標である。健康状態の評価として最も一般的であるのは、健康診断における体重測定である。これは肥満や栄養状態の把握、疾患リスクの評価に役立つ重要な手段である。投薬量の算出として、患者体重は画像診断における造影剤や放射線医薬品、抗がん剤、鎮静薬の投与量を決める際の基準として用いられている。さらに、慢性疾患における体重管理の重要性は、多くの研究で裏付けられている。例えば、心不全で入院を繰り返す患者では、体重変化が院内死亡率と関連していることが明らかにされている<sup>1</sup>。また、慢性疾患との関わりが強いフレイルの診断基準には、意図しない体重減少が採用されている<sup>2,3</sup>。このように、体重情報は医療の多岐にわたる領域や段階で重要な指標であり、本論文が対象とする X 線 computed tomography (CT) 検査においても例外ではない。

図 1.1 は X 線 CT 検査の動作原理概要である。X 線管から出力された X 線はコリメータによって薄い板状のビームに切り出され、直進しながら患者の体の中で減弱する。減弱した X 線の強度分布は、反対側の X 線検出器にて測定され、投影データが得られる。X 線管と X 線検出器を対にして患者の周囲を回転させることにより、投影データが多方向から収集され、収集した投影データから数理的に断層像が算出される。得られた断層像は X 線減弱係数の分布図であり、X 線減弱係数が高い組織は白く、低い組織は黒く表示される。X 線 CT 検査では通常、診断用の断層像を撮影する前に位置決め画像（X 線管位置を固定して寝台を動かして得る平面画像）が取得される。位置決め画像は、撮影範囲の決定、読影の際のスライス位置の確認、照射線量を変調させて線量低減を図る技術である CT automatic exposure control (CT-AEC) で使用する被写体情報の収集を目的に撮影される。X 線 CT 検査では、位置決め画像、単純 CT 画像の撮影に続いて、造影 CT 検査が施行される場合がある。造影 CT 検査はヨード造影剤を静脈から注入して撮影するものであり、造影剤により組織コントラストが上昇し、疾患や各種臓器の血流の状態、血管の情報を得ることが可能になる。




図 1.1 X 線 CT 検査の動作原理

X 線 CT 検査において体重情報が重要である理由として、第一に、患者体重は X 線 CT 検査における造影効果に影響を与える要因の一つであるということが挙げられる<sup>4-7</sup>。体重と循環血液量には関連があり、大柄な患者は小柄な患者よりも血液量が多いため、血液中に投与された造影剤は大柄な患者のほうが小柄な患者よりも多く溶出する。その結果、血液中の造影剤濃度は低下する。つまり、ある一定の造影剤投与量に対する造影効果は、患者体重の増加にともなって低下する（図 1.2）。そのため、一般的に造影剤投与量は、患者体重と 1 : 1 の比例関係に基づいて調整されることが多い<sup>5</sup>。患者体重に基づいて造影剤投与量を調整する方法は、多くの研究で有用性が示されており<sup>8-11</sup>、実臨床においても標準的なプロトコルとして使用されている。また、造影剤投与量と造影剤腎症

（contrast-induced nephropathy : CIN）のリスクの関係について、経動脈的に造影剤を投与する心臓カテーテル検査においては、造影剤投与量の減量は CIN 発症のリスクを低減させるという十分なエビデンスが確立されているが<sup>12,13</sup>、経静脈的投与である造影 CT 検査に対する報告は少ない。しかしながら、「腎障害患者におけるヨード造影剤使用に関するガイドライン 2018」では、CIN を発症するリスクが高い患者に対して造影 CT 検査を施行する場合には、診断能を保つことのできる範囲内で最小限の造影剤投与量とすることが推奨されている<sup>14</sup>。したがって、造影 CT 検査を実施する際には、患者の体重情報に基づいて必要最小限の投与量を選択することが重要である。




図 1.2 大動脈における体重別の造影効果シミュレーション

薬物動態解析<sup>15, 16</sup>を用いて、成人男性（62 歳，身長 170 cm）の体重を変化させた（50, 75, 100, 125 kg）場合の大動脈の造影剤濃度変化をシミュレーションした．造影剤の注入時間および注入量が一定であれば，患者体重の増加にともなって造影剤濃度は低下する．

第二に，体重情報は X 線 CT 検査の被ばく線量管理においても重要である．2020 年 4 月に施行された医療法施行規則の改正により，各施設は医療被ばくの管理と記録を義務付けられた．線量管理において参考にするべきガイドラインの一つが，医療被ばく研究情報ネットワーク（Japan Network for Research and Information on Medical Exposure : J-RIME）が公開している診断参考レベル（diagnostic reference level : DRL）である．DRL は，患者が診療によって受ける線量について，診断や治療の目的を担保した上で最適化するためのツールである．2015 年に本邦で初めてとなる診断参考レベル（DRLs 2015）<sup>17</sup>が公表され，2020 年には改訂版である診断参考レベル 2020（DRLs 2020）<sup>18</sup>が公表された．X 線 CT 検査においては，CT dose index volume（CTDI<sub>vol</sub>）と dose-length product（DLP）が管理すべき線量指標として使用され，全国的な線量調査結果の 75 パーセンタイル値を参考にして定められている．DRLs 2020 において，成人の X 線 CT 検査に対する DRL 値は，被検者の標準体格を 50–70 kg として定められている．また，小児の X 線 CT 検査に対する DRL 値は，年齢と体重によって区分されている．各施設では，DRL を活用して線量管理を行う．具体的には，施設で用いている典型的な線量を調査し，その中央値が DRL 値を超えている場合，臨床的に正当な理由がない限り線量最適化のための見直しを行う必要がある．

一般的には用いている機器の性能やプロトコルなどを調査し、高線量の原因を特定し、適切な対策を講じた後、再度施設の典型的な線量を調査し、DRL 値と比較するという流れである。一方、施設で用いている典型的な線量が DRL 値よりも低い場合は、最適化のプロセスにおいて、線量よりも画質や診断能が十分であることを優先して検討する必要がある。患者の体重や体格によって標準的な体型の患者よりも高いまたは低い線量が必要とされる場合があるため、DRL は個々の患者に適用されるものではない。そのため、患者の体重情報を活用することで、体格の違いを考慮した線量評価が可能になる（図 1.3）。具体的には、患者体重を横軸、線量指標（CTDI<sub>vol</sub>、DLP）を縦軸にプロットし、散布図を作成する。その際に、他の観測値から大きく外れた症例について、X 線 CT 検査時の患者体位やプロトコルに問題がないかを確認し、線量最適化につなげることができる。以上のように、自施設の代表的な線量値を抽出し DRL 値と比較する、あるいは患者の体格を考慮した線量評価を行うためには、CT 装置側で手入力された体重情報を取得する必要がある。別の方法として、Modality Worklist Management（MWM）により取得された体重情報を Radiation Dose Structured Reports（RDSR）や Digital Imaging and Communications in Medicine（DICOM）データより取得することも可能である。しかしながら、体重情報が誤っている場合や何かしらの理由で体重情報が入力されていない場合、その検査は統計には用いないようにするか、別の手段で患者体重を取得する必要がある。




図 1.3 低線量胸部 X 線 CT 撮影における患者体重と CTDI<sub>vol</sub>および DLP の関係

他の観測値から大きく外れた症例（図 1.3 における赤枠で囲まれたプロット）について、X 線 CT 検査時の患者体位やプロトコルに問題がないかを確認することで、線量最適化につなげることが可能になる。

OECD の公開データ（2020 年）によると、本邦の X 線 CT 装置台数は人口 100 万人当たり 115.7 台と世界トップであり<sup>19</sup>、日々膨大な検査数が施行されていると想定される。膨大な検査数が施行される X 線 CT 検査の場合、線量管理を目的としてすべての患者に対して事前の体重測定を行うことは現実的ではない。医療のマンパワー不足や測定時の患者の転倒リスクなどを考慮すると、より効率的な方法が求められている。また、救急医療では、患者の意思疎通が困難であり、体重計を使用した測定や問診による情報収集が難しい場合もある。一部のベッドやストレッチャーには体重測定機能が搭載されているが、これらは高価であり、臨床現場での使用は限られた場合のみである。また、体重測定に時間を要することは、診断や治療の遅延を引き起こす可能性がある。そのため、診療の流れを妨げずに患者体重を即時に把握できる手法の確立が求められている。

## 1.2 患者体重推定に関する先行研究と本研究の位置づけ

先行研究において、体重情報を取得できない場合のいくつかの代替手法が提案、検証されている。最も簡便な手法は、医療従事者が目視で推定する方法であるが、その精度は良好でない<sup>20-22</sup>。Menon らの救急患者を対象にした前向き観察研究によると、実測体重から 10%以内の誤差で推定できたのは、看護師の推定では 78%、医師の推定では 59%であった<sup>22</sup>。Buckley らは、救急医療における正確な投薬量の算出を目的として、ベッドサイドで測定した腹囲や大腿周囲径を用いて体重を推定する回帰式を作成した<sup>23</sup>。この方法を 99 名（男性 55 名、女性 44 名）で検証した結果、男性患者の 51%、女性患者の 68%で実測体重に対する推定体重の誤差が 5 kg 以上であった。Buckley らの手法は、腹囲や大腿周囲径の計測に時間や労力がかかるという課題がある。

さらに別の手法として、診断用 CT スキャンデータを用いた手法が報告されている。Geraghty らは、第一腰椎レベルの CT 横断像から横径、縦径、椎体径などを測定し、性別ごとに重回帰分析を行い、体重推定式を求めた<sup>24</sup>。Zopfs らは、第三腰椎レベルの CT 横断像で測定した断面積のみを用いた回帰直線により、患者体重を推定できることを明らかにした<sup>25</sup>。しかし、これらの径や断面積を手動で計測することは、ワークフローの観点から日常臨床では現実的ではない。また、それぞれの研究で解析対象としたスライス位置は 1 断面であり、体重推定に最適なスライス位置は不明である。Gascho らは、死後 CT として撮影された躯幹部 CT の mAs 値から患者体重を推定する回帰式を作成した<sup>26</sup>。しかし、

この手法は臨床プロトコルでの検証が行われておらず、躯幹部全体の撮影にしか適用できないという課題がある。さらに、CT-AECの機構がベンダーごとに異なるため、単一ベンダーにしか適用できないという課題も有する。診断用CTスキャンデータを用いたこれらの手法は良好な精度を示しているが、救急医療の特殊性を考慮すると汎用性の観点においても十分とはいえない。救急医療では、単純CT画像の撮影を事前に行わずに造影CT画像を撮影する場合があるからである。そのような状況下では、これらの診断用CTスキャンデータを用いた患者体重推定手法は適用できず、造影剤投与量を算出することは不可能である。

上記の課題を踏まえて、高精度かつ迅速に患者体重を推定可能な手法を開発する上で考慮すべき点は以下の3点である。一つ目は、患者体重推定手法の自動化である。これにより、救急医療も含めた日常臨床への導入が実現される可能性がある。二つ目は、診断用CTスキャン前にも適用できるなど、特定のタイミングに限定されない患者体重推定手法の開発が必要である。これにより、患者の状態や状況に応じて柔軟に患者体重を推定することができ、提案手法の汎用性が向上する。三つ目は、患者体重推定に適した画像の種類やスライス位置を探索する必要がある。適切な画像の種類や解析位置が明らかになることで、より精度が高い患者体重推定手法の実現が期待される。

近年、人工知能技術が注目を集め、医用画像分野においては肺結節の検出<sup>27</sup>、脳動脈瘤の検出<sup>28</sup>、脳出血の検出<sup>29</sup>、画像ノイズの低減<sup>30</sup>などの技術が実用化されている。医用画像解析への人工知能技術の応用は、高い精度のみならず、即時性をもたらすことが期待される。特に人工知能技術のひとつである畳み込みニューラルネットワーク（convolutional neural network：CNN）は、人間の手を介さずネットワークの学習を通して画像特徴量を自動抽出できるという利点がある。そこで本論文では、高精度かつ迅速に患者体重を推定可能な手法の開発を目指し、CNNを用いて既存の医用画像から患者体重を推定することを試みた。

### 1.3 本論文の目的と構成

本論文は、画像診断のために取得された医用画像から深層学習を用いて患者体重を推定する手法を提案し、高精度かつ迅速で汎用的な患者体重推定システムの実現を目指すものである。本論文の主な目的は、以下の通りである。

- 1) 画像診断のために取得された医用画像（胸部単純 X 線写真，CT 位置決め画像，CT 横断像）を副次的に活用し，深層学習を用いて患者体重を高精度に推定可能であるのかを検証する．
- 2) CT 横断像からの体重推定について，患者体重を高精度に推定するために適したスライス位置を明らかにする．
- 3) 提案手法による推定体重が，X 線 CT 検査の被ばく線量管理において実測体重と代替可能か検討し，提案手法の臨床応用の可能性を評価する．

本論文は，本章を含めて 7 章から構成される．

第 1 章では，X 線 CT 検査における体重情報の重要性，患者体重が不詳で測定が困難である場合の推定方法に関する先行研究をまとめ，本研究の動機を明確にした．

第 2 章では，本研究の根幹となる技術である CNN の基本的な構造や理論をまとめ，本論文で使用した深層学習のモデル構造について述べる．

第 3 章では，深層学習を用いて胸部および腹部の CT 位置決め画像から患者体重を推定し，実測体重と比較することで推定体重の精度を評価する．これにより，診断用 CT スキャンの前に，人の手を介在しない形で患者体重を推定する方法を確立する．

第 4 章では，胸部 CT 位置決め画像と胸部単純 X 線写真の類似性を考慮し，第 3 章で構築した手法を胸部単純 X 線写真へ応用して推定体重の精度を評価する．胸部単純 X 線写真は画像診断の中で最も数多く撮影される画像であり，提案手法が胸部単純 X 線写真に対して適用可能であれば，提案手法の汎用性向上が期待される．

第 5 章では，躯幹部 CT のさまざまなスライス位置の横断像に対し，従来の断面積を用いて患者体重を推定する手法と深層学習を用いて患者体重を推定する手法を適用し，精度が最も良好であるスライス位置を探索する．これにより，CT 位置決め画像や単純 X 線写真から患者体重を推定するという本研究の独創的な試みに対してだけでなく，断層像から患者体重を推定するという従来のアプローチにおいても精度向上を試みる．

第 6 章では，深層学習を用いて胸部 CT 位置決め画像から推定した患者体重を胸部 X 線 CT 検査の被ばく線量管理に活用し，実測体重と代替可能であるのかを検証する．これにより，深層学習を用いて既存の医用画像から患者体重を推定するという提案手法の臨床応用の可能性を探索する．

第 7 章では，本論文の総括と今後の展望を述べる．

## 1.4 参考文献

- 1 Konishi M, Kaneko H, Itoh H, et al. Association of weight change and in-hospital mortality in patients with repeated hospitalization for heart failure. *J. Cachexia. Sarcopenia Muscle* 2023; 14(1): 642–652.
- 2 Fried LP, Tangen CM, Walston J, et al. Frailty in older adults: evidence for a phenotype. *J. Gerontol. A. Biol. Sci. Med. Sci.* 2001; 56(3): M146–156.
- 3 Satake S, Arai H. The revised Japanese version of the Cardiovascular Health Study criteria (revised J-CHS criteria). *Geriatr. Gerontol. Int.* 2020; 20(10): 992–993.
- 4 Kormano M, Partanen K, Soimakallio S, Kivimäki T. Dynamic contrast enhancement of the upper abdomen: effect of contrast medium and body weight. *Invest. Radiol.* 1983; 18(4): 364–367.
- 5 Heiken JP, Brink JA, McClennan BL, Sagel SS, Crowe TM, Gaines M V. Dynamic incremental CT: effect of volume and concentration of contrast material and patient weight on hepatic enhancement. *Radiology* 1995; 195(2): 353–357.
- 6 Platt JF, Reige KA, Ellis JH. Aortic enhancement during abdominal CT angiography: correlation with test injections, flow rates, and patient demographics. *AJR. Am. J. Roentgenol.* 1999; 172(1): 53–56.
- 7 Bae KT. Intravenous contrast medium administration and scan timing at CT: considerations and approaches. *Radiology* 2010; 256(1): 32–61.
- 8 Yamashita Y, Komohara Y, Takahashi M, et al. Abdominal helical CT: evaluation of optimal doses of intravenous contrast material--a prospective randomized study. *Radiology* 2000; 216(3): 718–723.
- 9 Awai K, Hori S. Effect of contrast injection protocol with dose tailored to patient weight and fixed injection duration on aortic and hepatic enhancement at multidetector-row helical CT. *Eur. Radiol.* 2003; 13(9): 2155–2160.
- 10 Yanaga Y, Awai K, Nakayama Y, et al. Pancreas: patient body weight tailored contrast material injection protocol versus fixed dose protocol at dynamic CT. *Radiology* 2007; 245(2): 475–482.
- 11 Bae KT, Tao C, Gürel S, et al. Effect of patient weight and scanning duration on contrast

- enhancement during pulmonary multidetector CT angiography. *Radiology* 2007; 242(2): 582–589.
- 12 Cigarroa RG, Lange RA, Williams RH, Hillis LD. Dosing of contrast material to prevent contrast nephropathy in patients with renal disease. *Am. J. Med.* 1989; 86(6 Pt 1): 649–652.
  - 13 Brown JR, Robb JF, Block CA, et al. Does safe dosing of iodinated contrast prevent contrast-induced acute kidney injury? *Circ. Cardiovasc. Interv.* 2010; 3(4): 346–350.
  - 14 日本腎臓病学会. 腎障害患者におけるヨード造影剤使用に関するガイドライン2018. *日本腎臓学会雑誌* 2019; 61(7): 933–1081.
  - 15 Bae KT. Peak contrast enhancement in CT and MR angiography: when does it occur and why? Pharmacokinetic study in a porcine model. *Radiology* 2003; 227(3): 809–816.
  - 16 Yamaguchi I, Hayashi H, Suzuki M, Kidoya E, Higashimura K. Estimation of aortic time-enhancement curve in pharmacokinetic analysis: dynamic study by multi-detector row computed tomography. *Nihon Hoshasen Gijutsu Gakkai Zasshi* 2007; 63(6): 621–627.
  - 17 Japan Network for Research and Information on Medical Exposure (J-RIME). Diagnostic reference levels based on latest surveys in Japan -Japan DRLs 2015-. 2015.
  - 18 Japan Network for Research and Information on Medical Exposure (J-RIME). National diagnostic reference levels in Japan (2020) -Japan DRLs 2020-. 2020.
  - 19 Health equipment - Computed tomography (CT) scanners - OECD Data.  
<https://data.oecd.org/healtheqt/computed-tomography-ct-scanners.htm>
  - 20 Fernandes CMB, Clark S, Price A, Innes G. How accurately do we estimate patients' weight in emergency departments? *Can. Fam. Physician* 1999; 45: 2373–2376.
  - 21 Hall WL, Larkin GL, Trujillo MJ, Hinds JL, Delaney KA. Errors in weight estimation in the emergency department: comparing performance by providers and patients. *J. Emerg. Med.* 2004; 27(3): 219–224.
  - 22 Menon S, Kelly A-M. How accurate is weight estimation in the emergency department? *Emerg. Med. Australas.* 2005; 17(2): 113–116.
  - 23 Buckley RG, Stehman CR, Dos Santos FL, et al. Bedside method to estimate actual body weight in the Emergency Department. *J. Emerg. Med.* 2012; 42(1): 100–104.
  - 24 Geraghty EM, Boone JM. Determination of height, weight, body mass index, and body

- surface area with a single abdominal CT image. *Radiology* 2003; 228(3): 857–863.
- 25 Zopfs D, Theurich S, Große Hokamp N, et al. Single-slice CT measurements allow for accurate assessment of sarcopenia and body composition. *Eur. Radiol.* 2020; 30(3): 1701–1708.
- 26 Gascho D, Ganzoni L, Kolly P, et al. A new method for estimating patient body weight using CT dose modulation data. *Eur. Radiol. Exp.* 2017; 1(1): 23.
- 27 Lee JH, Sun HY, Park S, et al. Performance of a deep learning algorithm compared with radiologic interpretation for lung cancer detection on chest radiographs in a health screening population. *Radiology* 2020; 297(3): 687–696.
- 28 Ueda D, Yamamoto A, Nishimori M, et al. Deep learning for MR angiography: automated detection of cerebral aneurysms. *Radiology* 2019; 290(1): 187–194.
- 29 Seyam M, Weikert T, Sauter A, Brehm A, Psychogios M-N, Blackham KA. Utilization of artificial intelligence-based intracranial hemorrhage detection on emergent noncontrast CT images in clinical workflow. *Radiol. Artif. Intell.* 2022; 4(2): e210168.
- 30 Nakamura Y, Higaki T, Tatsugami F, et al. Deep learning-based CT image reconstruction: initial evaluation targeting hypovascular hepatic metastases. *Radiol. Artif. Intell.* 2019; 1(6): e180011.

## 第2章 深層学習の概説と畳み込みニューラルネットワークの基本構造

### 2.1 深層学習の概説

高度な情報処理の実現を目指し、生物の神経回路網を模倣した人工ニューラルネットワークが長年研究されている。多層のニューラルネットワーク、すなわちディープニューラルネットワークが、2011年には音声認識のタスクで優勝、2012年には ImageNet Large Scale Visual Recognition Challenge (ILSVRC) という画像認識のコンテストで圧勝するなど、音声認識や画像認識のベンチマークテストにおいて高い性能を示した。特に、後述の ILSVRC 2012 の画像分類を対象としたコンペティションでは、Hinton らのグループが深層学習の技術を使って、他のグループがエラー率 26% 台の攻防を繰り返す中、16% という脅威のエラー率を達成して勝利を収めた<sup>1</sup>ことは、驚きをもって迎えられた。深層学習は、その後応用範囲を急速に広げ、現在においても画像、音声、自然言語の分野を席卷している。医用画像処理の分野も例外ではなく、画像分類、病変検出、領域抽出、画像変換、超解像、画像生成など、深層学習の医用画像への応用は多岐に及んでいる。

### 2.2 畳み込みニューラルネットワークの基本構造

深層学習の中でも、本研究で用いた CNN は、画像認識の分野における代表的なネットワークである。分類・回帰型の CNN は、入力層の後ろに畳み込み層、プーリング層が複数配置され、それらに続いて全結合層を持つ構造を基本とする（図 2.1）。




図 2.1 畳み込みニューラルネットワークの構造例

## 畳み込み層

畳み込み層では、画像から輪郭などの特徴を抽出するために、畳み込み演算と呼ばれる処理を行う。濃淡値を各画素に格納したグレースケール画像を考え、画像サイズは  $W \times H$ 、画素のインデックスは  $(i, j)$ 、画素  $(i, j)$  の画素値は  $x_{ij}$ 、フィルタのサイズは  $W_f \times H_f$ 、フィルタの画素のインデックスは  $(p, q)$ 、その画素値は  $h_{pq}$  と表すと、画像の畳み込みとは、画像とフィルタの間で定義される次の積和計算となる。

$$u_{ij} = \sum_{p=0}^{W_f-1} \sum_{q=0}^{H_f-1} x_{i+p, j+q} h_{pq} \quad (2.1)$$

図 2.2 に畳み込み演算の例を示す。畳み込み演算の結果をみると、入力画像においてフィルタの濃淡構造と類似の構造を持つ部分に、強い反応があることがわかる。式 (2.1) のように畳み込み演算は、画像にフィルタを重ねたときに、画像とフィルタの重なり合う画素同士の積を求めて、それらの和を求める計算である。したがって、本来フィルタは、画像からフィルタがはみだすような位置、すなわち入力画像の外周画素に配置できない。この影響を緩和するための方法として、出力画像のサイズが元の入力画像と同サイズになるように、パディングがよく用いられる。一般的には、入力画像の周りに 0 を代入した画素を増設（ゼロパディング）することで、フィルタが入力画像内のすべての画素で処理できるようになる。非線形な要素を入れるため、畳み込み層の後に活性化関数が挿入される。挿入される活性化関数は、関数への入力値が 0 以下の場合には出力値が常に 0、入力値が 0 より上の場合には出力値が入力値と同じ値となる Rectified Linear Unit (ReLU) <sup>2</sup> が導入されることが多い。深層学習では層を深く重ねることが特徴であるが、ReLU は、従来の sigmoid 関数のような活性化関数では、層が深くなるにつれ勾配が小さくなっていくのでうまく学習できないという勾配消失問題を解決し、CNN の精度向上に寄与した。

## プーリング層

プーリング層は、畳み込み層の後ろに配置され、画像内の特徴量の位置変化に対する不変性を生み出す。プーリング層は一般的に 2 つの役割を果たし、1 つは入力のある各位置で、その局所領域の値を要約することであり、もう 1 つは入力の空間解像度を下げるダウンサンプリングの実行である。図 2.3 にプーリング層の例を示す。  $W \times H \times C$  の入力画像上




図 2.2 画像に対するフィルタの畳み込み演算例

で画素  $(i, j)$  を中心とする  $W_f \times H_f$  の領域をとり、この中に含まれる画素の集合を  $P_{ij}$  で表す．この  $P_{ij}$  内の画素について、チャンネル  $c$  ごとに独立に、 $W_f \times H_f$  個の画素値から 1 つ画素値  $u_{ijc}$  を選択する．このとき、画素値の最大値を選択すれば **max pooling** (式 2.2)，平均値を選択すれば **average pooling** (式 2.3) となる．

$$u_{ijc} = \max_{(p,q) \in P_{ij}} z_{pqc} \quad (2.2)$$

$$u_{ijc} = \frac{1}{W_f H_f} \sum_{(p,q) \in P_{ij}} z_{pqc} \quad (2.3)$$

## 活性化関数

畳み込み層でよく用いられる **ReLU**，全結合層で用いられる **softmax** 関数などの活性化関数は、ニューラルネットワーク中の 1 つのニューロンにおいて、複数ノードの和を入力として、その出力を最終決定する関数である．活性化関数の導入により複雑な非線形表現を学習でき、モデル全体の表現力が増す．図 2.4 に、ニューラルネットワークの中間層で用いられる代表的な活性化関数を示す．以前の 3 層パーセプトロンの時代には、**sigmoid** 関数や **tanh** 関数が主に中間層の活性化関数として使われていた．現在、CNN の中間層における活性化関数として **ReLU** が定番化したのは、正の範囲で微分値がすべて 1 となるように設計されていることから学習の収束時間が早くなることにある．CNN の層の数が多くなると、**sigmoid** 関数や **tanh** 関数では勾配が 0 に飽和して学習が進行しなくなるが、**ReLU** では勾配消失が生じないという利点があり、層数を増やしやすくなる．




図 2.3 プールサイズ  $2 \times 2$  における max pooling および average pooling の例




図 2.4 中間層で用いられる代表的な活性化関数

CNN は、これまでに説明した畳み込み層、プーリング層、全結合層を基本要素とするが、実際には新しい構造が探求され、無数の複雑なモデルが考案されている。CNN の教師あり学習では、入力データと教師データを与え、ネットワークの出力値と教師データの誤差が最小となるように、ノード間の結合の重みづけを更新する。学習によってネットワーク内部の重みやハイパーパラメータの調整が終了し、学習に使用していない画像データを入力すると、未知のデータに対して処理が実行される。

## 2.3 Visual Geometry Group (VGG) -16 の基本構造

現在までに、さまざまな CNN モデルが登場しているが、本論文では VGG16 モデル<sup>3</sup>を基本として、患者体重推定モデルを作成した。VGG モデルは、Oxford 大学の Visual Geometry Group によって開発されたモデルであり、ILSVRC 2014 で 2 位という成績を収めた。VGG16 は深層学習のブレイクアウト初期に発表されたモデルで比較的シンプルな構造であるが、現在でも多くの研究で用いられており、高い精度が報告されている<sup>4,5</sup>。図 2.5 に、VGG16 の基本構造を示す。VGG16 は、畳み込み層 13 層と全結合層 3 層の計 16 層から構成される。出力のクラス数は、ILSVRC におけるクラス分類タスクで題材として用いられた ImageNet データセットのクラス数 (1,000 クラス) に対応している。本論文では、画像分類タスクではなく回帰タスクを扱うことから、VGG16 の元的全結合層を取り除いて、出力ユニット数が 1 となる新たな層を追加し、転移学習あるいはファインチューニングを行った。




図 2.5 画像分類タスクにおける VGG16 の構造

Conv : 畳み込み層, ReLU : Rectified Linear Unit, FC : 全結合層

## 2.4 参考文献

- 1 Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. Commun. ACM 2017; 60(6): 84–90.
- 2 Glorot X, Bordes A, Bengio Y. Deep sparse rectifier neural networks. Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics 2011; 15:

- 315–323.
- 3 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. arXiv preprint 2014. <https://arxiv.org/abs/1409.1556>
  - 4 Mobini N, Codari M, Riva F, et al. Detection and quantification of breast arterial calcifications on mammograms: a deep learning approach. *Eur. Radiol.* 2023; 33(10): 6746–6755.
  - 5 Klontzas ME, Vassalou EE, Spanakis K, et al. Deep learning enables the differentiation between early and late stages of hip avascular necrosis. *Eur. Radiol.* 2023; Epub ahead of print.

## 第3章 深層学習による CT 位置決め画像を用いた患者体重推定手法の提案

本章は以下の学術論文の内容に基づいて記した.

*Ichikawa S, Hamada M, Sugimori H. A deep-learning method using computed tomography scout images for estimating patient body weight. Sci Rep. 2021; 11(1): 15627.*

### 3.1 はじめに

患者体重は、X 線 CT 検査において、造影剤投与量の算出<sup>1</sup>、被ばく線量の管理<sup>2,3</sup>、撮影管電圧の選択<sup>4</sup>を行う上で、不可欠な情報である。しかしながら、臨床では、患者の状態や転倒リスク、ワークフローの観点から、X 線 CT 検査時に正確な患者体重を把握することは必ずしも容易ではない。特に救急医療では、患者との意思疎通が難しく、体重計を使用した測定や患者からの情報収集が困難であることが多い。このような状況下で、医療従事者は患者体重を目視で推定することがあるが、目視で推定した体重の信頼性は高くない<sup>5-7</sup>。ベッドサイドで測定した腹囲や大腿周囲径を用いた回帰式から患者体重を推定するという代替手法も提案されているが<sup>8</sup>、この手法の精度も十分ではなく、身体計測にも時間を要するという課題がある。

患者体重を推定する別のアプローチとして、診断用 CT スキャンデータを用いた手法が先行研究で報告されている<sup>9,10</sup>。Geraghty らは、第一腰椎レベルの CT 横断像から横径、縦径、椎体径を測定して患者体重との関連を調べ、患者体重を推定するための回帰式を作成した<sup>9</sup>。しかし、日常臨床において、これらの径を手動で計測することは現実的でない。Gascho らは、躯幹部 X 線 CT の mAs 値と体重の関係を調べ、この関係から高精度に患者体重を推定することができる回帰式を報告した<sup>10</sup>。ただし、この手法は躯幹部全体の撮影にしか適用できないことに加えて、CT-AEC の機構がベンダーごとに異なるため、単一ベンダーにしか適用できないという課題がある。さらに、診断用 CT スキャンデータを必要とするこれまでの手法は、単純 CT 画像の撮影を事前に行わずに造影 CT 画像を撮影する場合には、造影剤投与量を算出するために利用することはできない。つまり、診断用 CT スキャンの前に、高精度かつ迅速に患者体重を推定できる方法は、現在のところ存在しない。

い.

通常の X 線 CT 検査では、診断用 CT スキャンの撮影範囲を決定するために、最初に「スカウト」または「ローカライザー」と呼ばれる CT 位置決め画像を取得する。本論文では、この CT 位置決め画像から患者体重を推定することが可能であれば、体重不詳の患者においても、診断用 CT スキャンの撮影前に患者体重を把握し、適切な造影剤投与量を算出する、被ばく線量管理に活用する、適切な検査プロトコルを設定することなどが可能になると考えた。近年、医用画像処理の分野では、深層学習は革新的な成果をあげており、注目を集めている。特に、CNN の活用は、病変や解剖構造の検出<sup>11,12</sup>、病変のセグメンテーション<sup>13,14</sup>、画像の分類<sup>15,16</sup>、骨密度や骨年齢の推定<sup>17,18</sup>など、さまざまなタスクで良好な結果をもたらしている。そこで本章では、CNN を用いて胸部および腹部の CT 位置決め画像から患者体重を推定し、その精度を評価することを目的とする。

## 3.2 方法

### 3.2.1 対象と X 線 CT 撮影

対象は、肺がん検診のために 2019 年 6 月から 2020 年 10 月の期間に胸部 X 線 CT 検査を受けた受診者 1,868 人および内臓脂肪面積測定のために 2019 年 6 月から 2020 年 12 月の期間に腹部 X 線 CT 検査を受けた受診者 526 人である。このうち、胸部 X 線 CT 検査を受けた 37 人と腹部 X 線 CT 検査を受けた 7 人は、X 線 CT 検査と同日に身長と体重の測定が行われておらず、除外した。除外基準の設定においては、金属装具や体内埋込みデバイスの有無は考慮しなかった。最終的に、胸部では男性 1,330 人、女性 501 人の合計 1,831 人（年齢範囲：24 歳から 92 歳）、腹部では男性 291 人、女性 228 人の合計 519 人（年齢範囲：25 歳から 92 歳）を解析対象とし、CT 位置決め画像と身体計測データを収集した。

X 線 CT 装置は体軸方向に 80 列の検出器を有する Aquilion Prime（キヤノンメディカルシステムズ株式会社、大田原、日本）を使用し、胸部および腹部の正面位置決め画像を管電圧 120 kVp、管電流 10 mA で撮影した。なお、本研究は倉敷中央病院の医の倫理委員会の承認を得て実施された（承認番号：3627）。

### 3.2.2 データセットの構築と前処理

図 3.1 に、本研究の概要を示す．本研究では，胸部および腹部の CT 位置決め画像を入力データとし，患者体重を教師データとして教師あり学習を行い，患者体重を推定するための CNN モデルを構築した．収集したデータは，モデルの訓練および検証に用いる訓練／検証データ（80％）と，モデルの評価に使用するテストデータ（20％）に分割した．つまり，胸部 CT 位置決め画像の総枚数は 1,831 枚であり，モデルの訓練と検証には 1,464 枚の画像を使用し，残りの 367 枚の画像でモデルの評価を行った．同様に，腹部 CT 位置決め画像の総枚数は 519 枚であり，モデルの訓練と検証には 415 枚の画像を使用し，残りの 104 枚の画像でモデルの評価を行った．




図 3.1 研究の概要

収集したデータは，CNN モデルの訓練および検証のための訓練／検証データ（80％）と，構築した CNN モデルを評価するためのテストデータ（20％）に分割した．収集した訓練データの偏りによる影響を減少させるため，5 分割交差検証を行い，5 つのモデルを構築した．テストデータにおける推定体重は，交差検証により作成された 5 つのモデルの出力値の平均値とした．




図 3.2 画像サイズの正規化

CNN の転移学習を行うためには、画像サイズの正規化が必要である。このため、画像の上下の領域にゼロパディングを施し、また、画像全体を縮小させることで、マトリクスサイズが  $224 \times 224$  になるように変換した。

CT 位置決め画像は、DICOM 形式から Joint Photographic Experts Group (JPEG) 形式に変換した。変換時には、DICOM 画像の画素値は、DICOM タグに設定されているウィンドウ幅およびウィンドウレベルを用いて 8-bit (256 階調) にウィンドウ処理を行った。CT 位置決め画像の幅は 552 ピクセルで一定であったが、高さは撮影者が X 線照射を停止するタイミングによって異なるため、画像サイズの正規化を行った (図 3.2)。具体的には、画像のアスペクト比は保持しながら、画像の上下にゼロパディングを施し、画像の高さを 552 ピクセルに調整した。その後、CNN の転移学習のために、マトリクスサイズが  $224 \times 224$  になるように変換した。

### 3.2.3 体重推定モデルの構造と学習

CT 位置決め画像から患者体重を推定するために、ImageNet データベース<sup>19</sup>で事前学習済みの VGG16 モデル<sup>20</sup>を活用し、新たな回帰モデルを作成した。図 3.3 に、本研究で使った回帰モデルを示す。元の VGG16 モデルは、畳み込み層 13 層、ReLU 関数とドロップアウトを含む全結合層 3 層で構成されている。本研究では、元の VGG16 モデルの全結合層を取り除き、出力ユニット数が 1 となるように 3 つの新しい層を追加して回帰モデルを作成した。学習時には、新たに追加した層以外の重みは固定し、新たに追加した全結合層の重みのみを更新した。損失関数には平均二乗誤差を使用し、最適化アルゴリズムとして Adam<sup>21</sup>を選択した。初期学習率は 0.001 に設定し、過学習を避けるために、3 エポック




図 3.3 本研究で用いた体重推定回帰モデルの構造

VGG16 モデルをベースに，出力ユニット数が 1 となる回帰モデルを作成した．学習時は，全結合層のみ重みを更新する転移学習を行った．

ごとに学習率を 10 分の 1 に減衰させた．最大エポック数は 40 で，バッチサイズは 32 に設定した．

CNN モデルの学習と検証には，5 分割交差検証を使用した．つまり，訓練／検証データセットを 5 つのサブセットに分割し，そのうち 4 つのサブセットを使用してモデルを学習し，残りの 1 つのサブセットでモデルの性能を検証した．これをすべての組み合わせに対して行った．CNN の構築環境は以下の通りである．

- CPU : Intel Core i7-9700F
- GPU : NVIDIA GeForce RTX 2070 Super 8GB
- フレームワーク : Keras 2.3.1 with TensorFlow backend (ver.2.0.0)
- プログラミング言語 : Python 3.7.10

### 3.2.4 構築した CNN モデルの評価

構築した回帰モデルの最終的な評価は，胸部 CT 位置決め画像と腹部 CT 位置決め画像それぞれのテストデータを用いて行った．テストデータにおける推定体重は，交差検証により作成された 5 つのモデルの出力値の平均値とした．まず，横軸を実測体重，縦軸を推

定体重とする散布図を作成した．次に，実測体重と推定体重の差を求めた．許容誤差は，先行研究<sup>7</sup>を基に $\pm 5$  kg および $\pm 10$  kg と定義し，許容誤差内の画像数を算出した．また，実測体重と推定体重の一致性を評価するため，Bland-Altman 分析を行った．さらに，以下の式に従って平均絶対誤差（mean absolute error : MAE）および二乗平均平方根誤差（root mean squared error : RMSE）を計算した．

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (3.1)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (3.2)$$

ここで， $N$  は画像の総数， $y_i$  は実測体重， $\hat{y}_i$  は推定体重である．

### 3.2.5 統計解析

統計解析は，R version 3.5.1（R Foundation for Statistical Computing, Vienna, Austria）を使用して行った．Shapiro-Wilk 検定により，身長や体重等の患者背景が，正規分布に従わないことが明らかになった．したがって，連続変数の統計値は中央値（四分位範囲）で表記した．また，患者背景について，訓練／検証データとテストデータの間に統計的に有意な差異があるかどうかを調べた．このため，連続変数については Mann-Whitney U 検定を，カテゴリ変数についてはカイ二乗検定を使用した．実測体重と推定体重の関係は，スピアマンの順位相関係数（ $\rho$ ）を算出して評価した．また，誤差（推定体重-実測体重）の大きさに基づいて 3 つのグループ（過小評価：誤差  $< -5$  kg，許容範囲：誤差  $\leq \pm 5$  kg，過大評価：誤差  $> 5$  kg）に分類し，Kruskal-Wallis 検定を用いて実測体重を比較した．事後検定には，Steel-Dwass 検定を用いた．すべての検定において，有意水準は両側 5% とした．

## 3.3 結果

### 3.3.1 患者背景

表 3.1 に、胸部と腹部のデータセットに対する患者の背景情報を示す。胸部データセットでは対象の年齢は 24 歳以上、腹部データセットでは 25 歳以上であり、構築したモデルの適用対象は成人に限定される。胸部データセットでは、訓練／検証データとテストデータの間で患者背景に統計的に有意な差は認められなかった。腹部データセットでは、テストデータの年齢 ( $p = 0.019$ ) および body mass index (BMI) ( $p = 0.006$ ) が、訓練／検証データよりも高値を示した。体重に関しては、腹部データセットにおいても統計的に有意な差は認められなかった ( $p = 0.228$ )。

表 3.1 訓練／検証データとテストデータにおける患者背景の比較

| 部位 | 項目                      | 訓練／検証データ            | テストデータ              | $p$   |
|----|-------------------------|---------------------|---------------------|-------|
| 胸部 | データ数                    | 1464                | 367                 | –     |
|    | 性別（男性／女性）               | 1059/405            | 271/96              | 0.608 |
|    | 年齢（歳）                   | 61 (52–69)          | 61 (52–69)          | 0.852 |
|    | 体重（kg）                  | 64.5 (57.2–72.0)    | 64.0 (57.2–72.1)    | 0.691 |
|    | 身長（cm）                  | 166.8 (160.2–172.0) | 166.5 (159.8–172.0) | 0.514 |
|    | BMI（kg/m <sup>2</sup> ） | 23.3 (21.4–25.3)    | 23.3 (21.4–25.6)    | 0.643 |
| 腹部 | データ数                    | 415                 | 104                 | –     |
|    | 性別（男性／女性）               | 232/183             | 59/45               | 0.967 |
|    | 年齢（歳）                   | 57 (48–68)          | 60 (52–69)          | 0.019 |
|    | 体重（kg）                  | 63.8 (56.8–72.3)    | 65.3 (57.4–73.8)    | 0.228 |
|    | 身長（cm）                  | 164.4 (155.8–171.6) | 163.2 (154.5–171.3) | 0.378 |
|    | BMI（kg/m <sup>2</sup> ） | 23.8 (21.8–25.9)    | 24.9 (22.9–26.3)    | 0.006 |

BMI: body mass index.

### 3.3.2 推定体重の精度

構築した回帰モデルの性能評価のため、胸部と腹部のデータセットについて MAE および RMSE を計算した。その結果、胸部データセットに対する MAE は 2.75 kg, RMSE は 3.62 kg となり、腹部データセットに対する MAE は 4.77 kg, RMSE は 5.97 kg であった。図 3.4 に、テストデータにおいて、実測体重を横軸に、推定体重を縦軸にプロットした散布図を示す。実測体重と推定体重の間には、強い相関関係（胸部： $\rho = 0.947$ ,  $p < 0.001$  および腹部： $\rho = 0.869$ ,  $p < 0.001$ ）が認められた。図 3.5 に、実測体重と推定体重の差のヒストグラムを示す。実測体重から $\pm 5$  kg と $\pm 10$  kg の誤差を許容範囲とし、誤差内に収まる受診者数（%）を算出したところ、実測体重から $\pm 5$  kg 以内の受診者数（%）は、胸部データセットで 302/367 人（82.3%）、腹部データセットで 59/104 人（56.7%）であった。また、実測体重から $\pm 10$  kg 以内の受診者数（%）は、胸部データセットで 361/367 人（98.4%）、腹部データセットで 95/104 人（91.3%）であった。図 3.6 に、実測体重と推定体重の Bland-Altman プロットを示す。腹部 CT 位置決め画像より胸部 CT 位置決め画像を用いた場合のほうがバイアスは小さく、推定精度が優れていた。図 3.7 に、複数のテストデータにおける体重推定例を示す。




図 3.4 実測体重と推定体重の関係

(a) は胸部 CT 位置決め画像, (b) は腹部 CT 位置決め画像の結果を示す。




図 3.5 実測体重と推定体重の差のヒストグラム

(a) は胸部 CT 位置決め画像, (b) は腹部 CT 位置決め画像の結果を示す.






図 3.6 Bland-Altman プロット

(a) は胸部 CT 位置決め画像, (b) は腹部 CT 位置決め画像の結果を示す. 腹部 CT 位置決め画像より胸部 CT 位置決め画像を用いた場合のほうがバイアスは小さく, 推定精度が優れていた.



(a)



(b)

図 3.7 CT 位置決め画像からの体重推定例

(a) は胸部 CT 位置決め画像，(b) は腹部 CT 位置決め画像の結果を示す．また，各画像における上段の数値は実測体重を，下段の数値は推定体重を表す．

### 3.3.3 推定誤差と実測体重の関係

表 3.2 および表 3.3 に、推定誤差（推定体重-実測体重）の大きさに基づいて分類した 3 つのグループの間に、実測体重を比較した結果を示す。推定体重が過小評価されたグループでは、胸部および腹部のデータセットにおいて、実測体重が許容範囲内のグループよりも重かった ( $p < 0.001$ )。また、推定体重が過大評価されたグループでは、腹部データセットにおいて、実測体重が許容範囲内のグループよりも軽かった ( $p < 0.001$ )。一方、胸部データセットでは、推定体重が過大評価されたグループと許容範囲内のグループとの間には、統計的に有意な差は認められなかった ( $p = 0.178$ )。

表 3.2 推定誤差の大きさに基づくグループ間の実測体重の比較

| 部位 | グループ | データ数 | 実測体重 (kg)        | $p$     |
|----|------|------|------------------|---------|
| 胸部 | 過小評価 | 26   | 76.5 (71.7–83.4) | < 0.001 |
|    | 許容範囲 | 302  | 63.8 (57.0–70.8) |         |
|    | 過大評価 | 39   | 59.5 (55.0–66.5) |         |
| 腹部 | 過小評価 | 16   | 81.1 (71.0–93.8) | < 0.001 |
|    | 許容範囲 | 59   | 65.3 (61.5–72.6) |         |
|    | 過大評価 | 29   | 56.9 (52.2–61.7) |         |

表 3.3 事後検定の結果

| 部位 | ペア            | $t$   | $p$     |
|----|---------------|-------|---------|
| 胸部 | 過小評価 vs. 許容範囲 | 4.990 | < 0.001 |
|    | 過小評価 vs. 過大評価 | 4.533 | < 0.001 |
|    | 許容範囲 vs. 過大評価 | 1.776 | 0.178   |
| 腹部 | 過小評価 vs. 許容範囲 | 4.359 | < 0.001 |
|    | 過小評価 vs. 過大評価 | 4.767 | < 0.001 |
|    | 許容範囲 vs. 過大評価 | 3.764 | < 0.001 |

### 3.3.4 処理時間

画像の読み取りから推定体重を表示するまでの時間は、1 画像あたり 6.7 秒であった。

## 3.4 考察

患者体重は、造影剤や治療薬の適切な投与量の算出、正確な被ばく線量管理のために不可欠な指標である。本研究では、胸部および腹部 CT 位置決め画像に深層学習技術を用いて患者体重を推定した。構築した CNN モデルによる推定体重は、比較的小規模なデータセットによる学習にもかかわらず、実測体重と強い相関があり、胸部と腹部の両データセットにおいて MAE が 5.0 kg 以内の精度を示した。

患者体重推定を目的としたこれまでの報告では、腹部 X 線 CT 検査の横断像から求めた形態学的指標<sup>9</sup>や躯幹部 CT の mAs 値<sup>10</sup>を入力とする回帰式を作成していた。深層学習技術を用いて CT 位置決め画像から直接患者体重を推定する試みは、本研究が初めてのものである。提案手法は、CT 位置決め画像を使用することにより、単純 CT 画像が存在しない場合でも患者体重を推定することが可能である。実臨床においては、CT 位置決め画像を撮影した後、単純 CT 画像を撮影することなく造影 CT 検査を施行する場合がある。そのため、提案手法は、先行研究の手法よりも多くの症例に適用できる可能性がある。

Fernandes らによると、体重計の使用が不可能である場合、患者自身が推定する体重のほうが、医師や看護師による推定よりも正確であることが報告されている<sup>7</sup>。しかし、救急医療では、患者が自身の体重を申告することは困難な場合が多い。Buckley らが提案した大腿周囲径および腹囲を用いた推定手法は、医師や看護師の目視による体重推定よりも高い精度を示したが、それでも男性患者の 15%、女性患者の 27%において、測定体重から $\pm 10$  kg を超える乖離が生じた<sup>8</sup>。Gascho らは、診断用 CT スキャンの mAs 値に基づいた回帰式を用いた推定方法を提案し、死後 4 日未満の死者における検証で、実測体重と推定体重の間に強い相関 ( $r = 0.969$ ) があることを示した<sup>10</sup>。本研究では、実測体重と推定体重の乖離が $\pm 10$  kg 以上となる症例は、胸部データセットではわずか 1.6%、腹部データセットでは 8.7%であった。また、実測体重と推定体重の間に強い相関が認められた。これらの結果から、CNN を用いた提案手法は、体重不詳である患者の体重を高精度に推定するのに有用であるといえる。

本研究において、CNN の入力として胸部 CT 位置決め画像を用いた場合、腹部 CT 位置

決め画像を使用した場合よりも高い精度が示された。その背景には、腹部 CT 位置決め画像のデータセットが胸部 CT 位置決め画像のものよりも小さかったことが考えられる。一般的に、大規模で高品質な学習データセットが存在すると、深層学習モデルの性能が向上することが知られている<sup>22-24</sup>。一方、Fukunaga らの先行研究では、患者体重と X 線 CT 画像から算出された実効直径との関係は、腹部 X 線 CT 検査に比べて胸部 X 線 CT 検査でより強い相関があることが示されており<sup>2</sup>、本研究と同様の傾向である。また、Boos らは、胸部 X 線 CT 検査において、患者体重と実効直径の相関が BMI と実効直径の相関よりも優れている一方、腹部 X 線 CT 検査においては BMI と実効直径の相関が患者体重と実効直径の相関よりも強いことを示している<sup>3</sup>。以上の結果を考慮すると、X 線 CT 検査の撮影範囲に胸部が含まれる場合、患者体重の推定においては腹部よりもむしろ胸部の画像データを使用するほうが望ましいといえる。

CNN による患者体重の推定において、推定誤差（推定体重-実測体重）の大きさに基づいて分類した 3 つのグループの間で実測体重を比較することにより、過小評価あるいは過大評価となった症例の分析を行った。この分析により、胸部および腹部データセットの両方で過小評価となった症例の実測体重は、許容範囲内の症例の実測体重よりも重かったことが明らかになった。一方、過大評価となった症例の実測体重は、腹部データセットにおいてのみ、許容範囲内の症例の実測体重よりも軽かったという結果が得られた。つまり、胸部と腹部の両データセットにおいて、体重が比較的重い症例では実際の体重よりも軽く見積もられる傾向がある一方、腹部データセットにおいては、体重が軽い症例は実際の体重よりも重く見積もられる傾向があることが示唆された。この傾向は、本研究で CNN の学習に用いたデータセットの患者体重が、不均衡な分布を持っていることに起因すると考えられる。体重分布が均衡しているより大規模な訓練データを用いて学習を行うことにより、CNN モデルの性能向上が期待される。

本研究の限界点をいくつか示す。第一に、訓練用データセットのサイズが小さくならないよう、CNN モデルの学習時に性別を考慮しなかった点が挙げられる。前述のように、訓練用データセットのサイズが小さいと、深層学習モデルの性能が低下する可能性がある。医用画像解析において深層学習モデルを構築するのに十分とされるデータ数については、これまでも検討されてきたが<sup>22, 25</sup>、本研究も他の先行研究<sup>11-14, 17</sup>と同様に数百から数千枚の画像を使用して実施した。Gascho らは、診断用 CT スキャンの mAs 値に基づいた推定を行う際、性別を考慮して回帰式を作成している<sup>10</sup>。CT 位置決め画像を撮影する際に

人体を透過する X 線の減弱は、たとえ同一体重の患者であっても、性差による体組成の影響を受けると考えられる。したがって、性別を考慮して CNN モデルを構築することで、推定精度が向上する可能性がある。第二に、本研究では健康診断受診者の CT 位置決め画像のみを用いて CNN モデルの訓練と評価を行った。そのため、本研究における結果はすべての症例に対して一般化できるものではない。例えば、外傷患者では、X 線 CT 検査時に腕の挙上を取りやめられることがある。さらに、実臨床では、上下肢、心臓、脊椎などの体内に金属製のインプラントや医療デバイスが埋め込まれている患者もいる。これらのバリエーションを反映した画像データは、本研究で用いた訓練用データセットに含まれていないため、CNN モデルを適用した際の精度は不確定である。最後に、本研究は単一施設のデータを使用して遡及的に行われたものであり、異なる X 線 CT 装置や施設で撮影された CT 位置決め画像に、構築した CNN モデルを適用した場合の精度は不明である。CT 位置決め画像を取得する際の管電流、再構成カーネル、ウィンドウ条件などの撮影条件は、ベンダーや施設により異なるものであり、これらの違いがモデルの性能に影響を及ぼす可能性がある。一般的に、深層学習モデルの性能は、学習データに存在しない特徴量や異なる特徴量を持つ画像に対しては悪化する傾向がある。そのため、異なるベンダーや施設の装置で撮影された画像を用いてファインチューニングすることで、撮影条件の違いが CNN モデルの性能に及ぼす影響を軽減できる可能性がある<sup>26</sup>。

このような限界点はあるが、本研究は CT 位置決め画像から迅速に患者体重を推定する方法の開発に寄与するものである。提案手法は、救急医療において意識がなく自身の体重を申告することができない患者に対して、造影剤投与量を算出するために使用することができる。実用的な観点では、X 線 CT 装置に CNN モデルを追加モジュールとして組み込むことで、本手法の臨床応用が可能であると考えられる。これにより、CT 位置決め画像が取得された際に、放射線科医師や診療放射線技師がコンソール上ですぐに推定体重を確認し、推定体重を基に造影剤投与量を算出することが可能となる。さらに、本手法を独立したソフトウェアとして展開することにより、過去に撮影された CT 画像を遡及的に解析して患者体重を取得することが可能となる。このようなソフトウェアの導入は、個々の患者に対する X 線 CT 被ばく線量管理を推進させることができる。

### 3.5 結論

本研究では，胸部および腹部 CT 位置決め画像を活用し，CNN を用いて患者体重を推定する手法を提案し，評価した．提案手法による推定体重は臨床的に許容可能な精度を示し，画像の読み込みから推定体重を出力するまでの時間効率にも優れていた．これにより提案手法は，将来的に臨床現場での実用化が期待され，体重が不詳である成人患者の造影剤投与量の算出や X 線 CT 検査における被ばく線量管理において有用である可能性がある．

### 3.6 参考文献

- 1 Bae KT. Intravenous contrast medium administration and scan timing at CT: considerations and approaches. *Radiology* 2010; 256(1): 32–61.
- 2 Fukunaga M, Matsubara K, Ichikawa S, Mitsui H, Yamamoto H, Miyati T. CT dose management of adult patients with unknown body weight using an effective diameter. *Eur. J. Radiol.* 2021; 135: 109483.
- 3 Boos J, Lanzman RS, Heusch P, et al. Does body mass index outperform body weight as a surrogate parameter in the calculation of size-specific dose estimates in adult body CT? *Br. J. Radiol.* 2016; 89(1059): 20150734.
- 4 Ghafourian K, Younes D, Simprini LA, Weigold WG, Weissman G, Taylor AJ. Scout view X-ray attenuation versus weight-based selection of reduced peak tube voltage in cardiac CT angiography. *JACC. Cardiovasc. Imaging* 2012; 5(6): 589–595.
- 5 Hall WL, Larkin GL, Trujillo MJ, Hinds JL, Delaney KA. Errors in weight estimation in the emergency department: comparing performance by providers and patients. *J. Emerg. Med.* 2004; 27(3): 219–224.
- 6 Menon S, Kelly A-M. How accurate is weight estimation in the emergency department? *Emerg. Med. Australas.* 2005; 17(2): 113–116.
- 7 Fernandes CMB, Clark S, Price A, Innes G. How accurately do we estimate patients' weight in emergency departments? *Can. Fam. Physician* 1999; 45: 2373–2376.
- 8 Buckley RG, Stehman CR, Dos Santos FL, et al. Bedside method to estimate actual body weight in the Emergency Department. *J. Emerg. Med.* 2012; 42(1): 100–104.
- 9 Geraghty EM, Boone JM. Determination of height, weight, body mass index, and body

- surface area with a single abdominal CT image. *Radiology* 2003; 228(3): 857–863.
- 10 Gascho D, Ganzoni L, Kolly P, et al. A new method for estimating patient body weight using CT dose modulation data. *Eur. Radiol. Exp.* 2017; 1(1): 23.
  - 11 Thian YL, Li Y, Jagmohan P, Sia D, Chan VEY, Tan RT. Convolutional neural networks for automated fracture detection and localization on wrist radiographs. *Radiol. Artif. Intell.* 2019; 1(1): e180001.
  - 12 Sugimori H, Kawakami M. Automatic detection of a standard line for brain magnetic resonance imaging using deep learning. *Appl. Sci.* 2019; 9(18): 3849.
  - 13 Arab A, Chinda B, Medvedev G, et al. A fast and fully-automated deep-learning approach for accurate hemorrhage segmentation and volume quantification in non-contrast whole-head CT. *Sci. Rep.* 2020; 10(1): 19389.
  - 14 Duong MT, Rudie JD, Wang J, et al. Convolutional neural network for automated FLAIR lesion segmentation on clinical brain MR imaging. *AJNR. Am. J. Neuroradiol.* 2019; 40(8): 1282–1290.
  - 15 Fang X, Harris L, Zhou W, Huo D. Generalized radiographic view identification with deep learning. *J. Digit. Imaging* 2021; 34(1): 66–74.
  - 16 Sugimori H, Hamaguchi H, Fujiwara T, Ishizaka K. Classification of type of brain magnetic resonance images with deep learning technique. *Magn. Reson. Imaging* 2021; 77: 180–185.
  - 17 Yasaka K, Akai H, Kunimatsu A, Kiryu S, Abe O. Prediction of bone mineral density from computed tomography: application of deep learning with a convolutional neural network. *Eur. Radiol.* 2020; 30(6): 3549–3557.
  - 18 Halabi SS, Prevedello LM, Kalpathy-Cramer J, et al. The RSNA pediatric bone age machine learning challenge. *Radiology* 2019; 290(2): 498–503.
  - 19 Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. *Commun. ACM* 2017; 60(6): 84–90.
  - 20 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint* 2014. <https://arxiv.org/abs/1409.1556>
  - 21 Kingma DP, Ba J. Adam: A method for stochastic optimization. *arXiv preprint* 2015. <https://arxiv.org/abs/1412.6980>

- 22 Cho J, Lee K, Shin E, Choy G, Do S. How much data is needed to train a medical image deep learning system to achieve necessary high accuracy? arXiv preprint 2015.  
<https://arxiv.org/abs/1511.06348>
- 23 Larson DB, Chen MC, Lungren MP, Halabi SS, Stence N V, Langlotz CP. Performance of a deep-learning neural network model in assessing skeletal maturity on pediatric hand radiographs. *Radiology* 2018; 287(1): 313–322.
- 24 Sugimori H. Evaluating the overall accuracy of additional learning and automatic classification system for CT images. *Appl. Sci.* 2019; 9(4): 682.
- 25 Figueroa RL, Zeng-Treitler Q, Kandula S, Ngo LH. Predicting sample size required for classification performance. *BMC Med. Inform. Decis. Mak.* 2012; 12: 8.
- 26 Alis D, Yergin M, Alis C, et al. Inter-vendor performance of deep learning in segmenting acute ischemic lesions on diffusion-weighted imaging: a multicenter study. *Sci. Rep.* 2021; 11(1): 12434.

## 第4章 深層学習を用いた患者体重推定手法の 胸部単純 X 線写真への応用

本章は以下の学術論文の内容に基づいて記した。

*Ichikawa S, Itadani H, Sugimori H. Prediction of body weight from chest radiographs using deep learning with a convolutional neural network. Radiol Phys Technol. 2023; 16(1): 127–134.*

### 4.1 はじめに

放射線医学の分野において、患者体重は極めて重要な指標である。X 線 CT 検査における被ばく線量の管理<sup>1,2</sup>や造影剤投与量の算出<sup>3,4</sup>は、患者体重に基づいて行われる。また、magnetic resonance imaging (MRI) 検査においては、比吸収率 (specific absorption rate : SAR) を推定するためには、患者体重を MRI 装置に入力する必要がある<sup>5</sup>。しかしながら、第1章、第3章で述べたように、医療現場において正確な患者体重を把握することは、必ずしも容易ではない。救急医療では、患者との意思疎通が難しく、患者自身が体重を申告することができない場合が存在する。外来診療においても、杖や車椅子を使用する高齢者など転倒の危険性がある患者に対しては、体重計の利用が制限されることがある。患者自身が体重を把握していない場合や、意図的に体重を過少申告する場合もある。患者体重を把握できない状況では、医療従事者の負担やワークフローの観点から、目視によって患者体重が推定されることがある。目視による推定は迅速である一方、その信頼性には課題がある<sup>6-8</sup>。

胸部単純 X 線撮影は、画像診断の中で最も広く普及している検査法であり、肺の状態を確認するために入院時や手術前には必ず撮影される。胸部単純 X 線撮影は、健康診断の一環としても行われ、特に疾患がない健康な人でも画像データが存在する。第3章では、CT 位置決め画像から CNN を用いて患者体重を推定できることを示した。単純 X 線写真と CT 位置決め画像の類似性を考慮すると、同様の手法が胸部単純 X 線写真にも適用可能であると仮定した。提案手法が胸部単純 X 線写真に対して応用可能であれば、画像データから患者体重を推定する手法の汎用性が向上することが期待される。具体的には、頭頸部や四肢のように胸部や腹部の CT 位置決め画像が撮影されない場合においても、患者体

重を推定することが可能になる．胸部単純 X 線写真からの患者体重の推定が実現することにより，体重不詳の患者に対して，診療放射線技師が X 線 CT 検査や MRI 検査前に適切な造影剤投与量を決定する際の支援や，X 線 CT 装置や MRI 装置への患者情報の登録時に患者体重を同時に入力することが可能になる．また，X 線 CT 検査や MRI 検査のために体重計測を行う医療従事者の負担の軽減や，計測に要する時間の削減も期待される．そこで本章では，第 3 章で提案した CNN を用いた体重推定手法を胸部単純 X 線写真に応用し，胸部単純 X 線写真から患者体重を正確に推定できるかを検証することを目的とする．

## 4.2 方法

### 4.2.1 対象

対象は，倉敷中央病院で 2019 年 7 月から 2021 年 7 月の期間に健診を受けた 86,357 人の受診者である．このうち 508 人の受診者は，体重か身長，またはその両方が胸部単純 X 線撮影と同日に測定されていなかったため，本研究から除外した．最終的に，85,849 人の受診者の胸部 X 線写真と身体計測データを収集した．収集したデータは，訓練データ ( $n = 68,679$ )，検証データ ( $n = 8,585$ )，およびテストデータ ( $n = 8,585$ ) の 3 つの別々のサブセットにランダムに分類した．なお，本研究は倉敷中央病院の医の倫理委員会の承認を得て実施された（承認番号：3627）．

表 4.1 に，各データセットにおける患者の背景情報を示す．受診者の年齢は 16 歳から 98 歳で，小児患者は含まれておらず，本手法の対象は成人に限定される．訓練データと検証データは，女性 40,726 人と男性 36,538 人から構成され，テストデータは，女性 4,155 人と男性 4,430 人から構成された．訓練／検証データにおける患者体重の中央値（四分位範囲）は，女性は 53.6（48.5–59.9）kg，男性は 67.7（61.5–75.2）kg であった．テストデータでは，女性は 53.4（48.3–59.4）kg，男性は 67.7（61.8–75.2）kg であった．

表 4.1 訓練／検証データとテストデータにおける患者背景

| 項目                      | 訓練／検証データ            | テストデータ              |
|-------------------------|---------------------|---------------------|
| データ数                    | 77264               | 8585                |
| 性別（男性／女性）               | 40726/36538         | 4155/4430           |
| 年齢（歳）                   | 52 (44–62)          | 53 (44–62)          |
| 体重（kg）                  | 60.3 (52.4–69.2)    | 61.1 (52.9–69.7)    |
| 身長（cm）                  | 162.7 (156.7–169.6) | 163.7 (157.3–170.5) |
| BMI（kg/m <sup>2</sup> ） | 22.6 (20.5–25.0)    | 22.6 (20.5–25.0)    |

BMI: body mass index.

#### 4.2.2 胸部単純 X 線撮影および前処理

胸部単純 X 線写真は、診断用 X 線装置 MRAD-A50S（キヤノンメディカルシステムズ株式会社、大田原、日本）を用いて撮影した。画像サイズは 14 × 14 インチあるいは 14 × 17 インチであり、画素サイズは 0.15 mm、階調数は 16-bit であった。取得した画像は、DICOM 形式から Portable Network Graphics (PNG) 形式に変換した。DICOM 画像の変換では、DICOM タグに設定されたウィンドウ幅とウィンドウレベルを用いて、画素値を 8-bit (256 階調) に調整するウィンドウ処理を行った。次に、画像サイズの正規化を行った。具体的には、ゼロパディングを適用し、画像のアスペクト比を保持しながら、マトリクスサイズが 224 × 224 になるように変換した。

#### 4.2.3 深層学習による体重推定手法

最先端の深層学習モデルが数多く提案されている中で、本研究では VGG16 モデル<sup>9</sup>を基に、胸部単純 X 線写真から患者体重を推定するための回帰モデルを構築した。VGG16 を選択した理由の 1 つは、胸部単純 X 線写真を用いた先行研究において、VGG16 モデルが優れた結果を示しているからである。VGG16 モデルは、比較的単純な畳み込みブロックを使用したモデルでありながら、胸部単純 X 線写真の病変分類において高い性能を発揮したと報告されている<sup>10-12</sup>。また、VGG16 モデルは、第 3 章で述べたように、胸部 CT 位置決め画像という胸部単純 X 線写真に類似した性質を持つ画像データから、患者体重

を高精度に推定することが可能であることも示されている<sup>13</sup>。したがって、VGG16 モデルは、胸部単純 X 線写真から患者体重を推定するための適切なモデルであると考えた。

人体を透過する X 線の減弱特性は、同一体重の患者であっても、性差による体組成の違いによる影響を受けると考えられるため、本研究では男女混合モデルと、性別ごとに訓練した男女別モデルの 3 つの回帰モデルを構築した。回帰モデルは、元の VGG16 モデルから全結合層を取り除き、以下の 4 つの層を追加して作成した：(1) 線形層（出力サイズ：512）、(2) ReLU 関数、(3) ドロップアウト ( $p = 0.4$ )、(4) 線形層（出力サイズ：1）。ネットワークは ImageNet データベース<sup>14</sup>で事前学習されたものを利用したため、入力画像は ImageNet の画像の平均値 (0.485, 0.456, 0.406) および標準偏差 (0.229, 0.224, 0.225) で正規化した。学習時には、全層の重みを更新するファインチューニングを行った。損失関数として平均二乗誤差を使用し、最適化アルゴリズムには Adam<sup>15</sup>を使用した。初期学習率は 0.001 に設定し、過学習を避けるために early stopping をコールバックとして設定した。最大エポック数は 50 で、バッチサイズは 128 に設定した。また、CNN モデルがどのように画像を評価したかを可視化するために、勾配加重クラス活性化マップ (gradient-weighted class activation mapping : Grad-CAM)<sup>16</sup>を利用してヒートマップを生成した。

CNN モデルの構築環境は以下の通りである。

- CPU : Intel Core i7-9700F
- GPU : NVIDIA GeForce RTX 2070 Super 8GB
- フレームワーク : PyTorch Lightning 1.5.9
- プログラミング言語 : Python 3.8.12

#### 4.2.4 構築した CNN モデルの評価と統計解析

統計解析は、R version 3.5.1 (R Foundation for Statistical Computing, Vienna, Austria) を使用して実施した。構築した回帰モデルの評価は、テストデータを対象に行った。まず、横軸を実測体重、縦軸を推定体重とする散布図を作成した。実測体重と推定体重の関係は、スピアマンの順位相関係数 ( $\rho$ ) を算出して評価した。次に、実測体重と推定体重の差を求めた。許容誤差は、 $\pm 5$  kg および  $\pm 10$  kg と定義し、許容誤差内に該当する画像数を算出した。また、実測体重と推定体重の一致性を評価するため、Bland-Altman 分析を行った。

さらに、以下の式に従って MAE および RMSE を算出した。

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (4.1)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (4.2)$$

ここで、 $N$  は画像の総数、 $y_i$  は実測体重、 $\hat{y}_i$  は推定体重である。

## 4.3 結果

### 4.3.1 実測体重と推定体重の関係

図 4.1 に、実測体重を横軸に、推定体重を縦軸にプロットした散布図を示す。混合モデルにおける実測体重と推定体重の相関は、女性に対して  $\rho = 0.915$  ( $p < 0.001$ )、男性に対して  $\rho = 0.922$  ( $p < 0.001$ )、男女全体で  $\rho = 0.954$  ( $p < 0.001$ ) であった。また、男女別モデルにおいても強い相関が認められた（女性： $\rho = 0.917$ ,  $p < 0.001$ ；男性： $\rho = 0.915$ ,  $p < 0.001$ ）。

### 4.3.2 許容誤差に関する分析

図 4.2 に、実測体重と推定体重の差のヒストグラムを示す。混合モデルにおいて、実測体重から  $\pm 5$  kg 以内の受診者数 (%) は、女性で 3,628 / 4,155 (87.3%)、男性で 3,581 / 4,430 (80.8%) であった。また、男女別モデルにおいて、実測体重から  $\pm 5$  kg 以内の受診者数 (%) は、女性で 3,647 / 4,155 (87.8%)、男性で 3,476 / 4,430 (78.5%) であった。混合モデルにおいて、実測体重から  $\pm 10$  kg 以内の受診者数 (%) は、女性で 4,123 / 4,155 (99.2%)、男性で 4,334 / 4,430 (97.8%) であった。また、男女別モデルでは、実測体重から  $\pm 10$  kg 以内の受診者数 (%) は、女性で 4,124 / 4,155 (99.3%)、男性で 4,310 / 4,430 (97.3%) であった。

### 4.3.3 Bland-Altman 分析

図 4.3 に、実測体重と推定体重の Bland-Altman プロットを示す。女性患者においては、男女別モデル（95%信頼区間：-6.44, 6.72）における推定体重の変動は、男女混合モデル（95%信頼区間：-6.70, 6.78）の変動よりも小さくなった。一方、男性患者においては、男女混合モデル（95%信頼区間：-8.43, 7.68）における推定体重の変動が、男女別モデル（95%信頼区間：-8.87, 8.29）の変動よりも小さくなった。

### 4.3.4 評価指標の比較

男女混合モデルの MAE は女性に対して 2.69 kg，男性に対して 3.14 kg であった。一方，男女別モデルの MAE は女性に対して 2.63 kg，男性に対して 3.35 kg であった。また，男女混合モデルの RMSE は女性に対して 3.44 kg，男性に対して 4.13 kg であり，男女別モデルの RMSE は女性に対して 3.36 kg，男性に対して 4.39 kg であった。

### 4.3.5 臨床例と深層学習モデルが着目した領域の可視化

図 4.4 は、男女別モデルによる体重推定の例である。多くの単純 X 線写真において、CNN モデルは横隔膜周辺に注目していることが観察された。また、低体重の患者に対しては、CNN モデルは頸部周辺に注目していることが示された（図 4.4 (a), (c)）。一方で、高体重の患者においては、CNN モデルは腋窩部（図 4.4 (b), (d)）に注目する傾向にあった。




図 4.1 実測体重と推定体重の関係

(a) は女性に対する男女混合モデルの推定結果を、(b) は男性に対する男女混合モデルの推定結果を示す。(c)、(d) はそれぞれ男女別モデルの女性、男性に対する推定結果を示す。




図 4.2 実測体重と推定体重の差のヒストグラム

(a) は女性に対する男女混合モデルの推定結果を、(b) は男性に対する男女混合モデルの推定結果を示す。(c)、(d) はそれぞれ男女別モデルの女性、男性に対する推定結果を示す。




図 4.3 Bland-Altman プロット

(a) は女性に対する男女混合モデルの推定結果を、(b) は男性に対する男女混合モデルの推定結果を示す。(c)、(d) はそれぞれ男女別モデルの女性、男性に対する推定結果を示す。女性患者では、男女別モデルにおける推定体重の変動は、男女混合モデルよりも小さくなった。一方、男性患者では、男女混合モデルにおける推定体重の変動が、男女別モデルよりも小さくなった。




図 4.4 男女別モデルによる胸部単純 X 線写真からの体重推定例

(a) と (b) は女性患者，(c) と (d) は男性患者である．各症例において，左は元画像を，右は Grad-CAM に基づくヒートマップを示している．

## 4.4 考察

体重不詳の患者に対する体重の推定は、X 線 CT 検査の被ばく線量管理や造影剤投与量の算出、MRI 検査での SAR の推定のために不可欠である。しかし、目視による体重推定は正確性に欠ける。画像診断の中でも胸部単純 X 線写真は、入院時や手術前の肺野の状態を確認するために必ず撮影される主要なモダリティである。本研究では、CNN を用いて、胸部単純 X 線写真から患者体重を推定可能であるかについて検証した。結果として、推定体重の MAE は 5.0 kg 以内であり、推定体重は男女両方で実測体重と強い相関を示した。これらの結果は、CNN を用いた提案手法が患者体重を推定するのに有用な手段であり、造影剤を使用する画像診断の安全性向上を促進する可能性があることを示唆している。特に重症患者の場合、X 線 CT 検査や MRI 検査を行う際の体重計測は、医療従事者にとっても負担が大きく、時間を要する業務である。提案手法は体重計測にともなう労力を軽減し、救急医療におけるワークフローの改善に寄与する可能性がある。

目視による推定に代わる方法として、Buckley らは腹囲と大腿周囲径を活用した推定式を提案したが、この方法では男性患者の 15%、女性患者の 27%において測定体重から  $\pm 10$  kg を超える乖離が生じた<sup>17</sup>。診断用 CT スキャンデータを用いた患者体重の推定手法も、いくつか報告されている。Geraghty らは、第一腰椎レベルの CT 横断像から横径、縦径、椎体径などを測定し、性別ごとに重回帰分析を行い、体重推定式を求めたが<sup>18</sup>、これらの径を手動で計測することは、時間と労力を要する。Gascho らは、死後 CT として撮影された躯幹部 CT の mAs 値から患者体重を推定する回帰式を作成し、実測体重と推定体重の間に強い相関 ( $r = 0.969$ ) があることを示した<sup>19</sup>。しかしながら、この推定式は全身の躯幹部 CT が撮影される外傷患者などに適用が限定される。一方、第 3 章で報告したように、CNN を用いて胸部 CT 位置決め画像から患者体重を推定した場合、MAE は 2.75 kg、実測体重と推定体重の相関は  $\rho = 0.947$  という非常に良好な結果が得られた<sup>13</sup>。ただし、この研究では、CNN モデルの学習に用いられた訓練データにおける体重分布が不均衡であったため、体重が重い患者に対する推定体重が、実測体重よりも軽く見積もられる傾向がみられた。

深層学習を用いて胸部単純 X 線写真から患者体重を推定する試みは、本研究が初めてのものである。胸部単純 X 線写真から患者体重を推定することにより、放射線科医師や診療放射線技師は X 線 CT 検査や MRI 検査の前に、患者体重を把握することが可能にな

る．これにより，適切な造影剤投与量の算出，患者情報の装置への登録時に体重情報を同時に入力できる利点がある．患者情報の装置への登録時に体重情報を入力することにより，患者体重が DICOM ヘッダーに記録され，被ばく線量管理を含む後方視的な解析においても有益な情報となる．

回帰モデルの学習において，性差による体組成の違いにより生じる X 線の減弱特性の違いを考慮し，女性患者と男性患者の混合モデルだけでなく，男女別のモデルも構築した．しかし，男女別モデルは，男女混合モデルと比較して必ずしも推定精度を向上させるものではなかった．女性患者においては，男女別モデルの推定精度は混合モデルの推定精度に比べてわずかに向上した．反対に，男性患者においては，男女別モデルの推定精度は，混合モデルの推定精度よりも劣っていた．これらの結果は，より単純な男女混合モデルが性別に関わらず適用できることを示しており，これは提案手法の臨床応用の観点からも望ましいことである．

Grad-CAM を用いた分析により，CNN が患者体重を推定するにあたり横隔膜付近の領域に着目していることが明らかになった．CNN が着目する領域は，人間が判断する際に用いる画像特徴と必ずしも一致するわけではない．また，CNN モデルは低体重の患者では頸部周辺の領域を，高体重の患者では腋窩周辺の領域に着目する傾向にあった．これらの領域は脂肪や筋肉の発達によって患者の体格に依存すると考えられ，この傾向は一般的に受け入れられるものであると思われる．しかしながら，Grad-CAM は単に CNN が出力の根拠とした入力データの領域を強調するに過ぎず，なぜこれらの領域が患者体重の推定に影響したのかを詳細に説明することは，現段階の技術では困難である．

提案手法の臨床応用に関して，考慮すべき潜在的な課題が残されている．第一に，本研究では大多数が正常所見を示す健康診断受診者の画像を用いて CNN モデルの訓練および評価を行ったため，呼吸器疾患を有する患者におけるモデルの性能は不明である．しかしながら，Grad-CAM の分析結果によると，肺野領域は体重推定においてはあまり影響しないと想定される．第二に，本研究で構築した CNN モデルは立位撮影の画像を対象にしており，移動型 X 線装置で撮影する場合のような胸部単純 X 線写真の AP (Anterior-Posterior view) 像には適用できない．医用画像からの体重推定は，立位での撮影が困難であり，座位あるいは仰臥位の状態で胸部単純 X 線撮影が行われる場合により有益であると考えられる．しかし，AP 撮影と PA (Posterior-Anterior view) 撮影では画像の幾何学的拡大率が異なる．さらに，CT 撮影における全肺の容積は，仰臥位よりも立位や座位で大

きくなることがわかっており<sup>20</sup>，推定精度に影響を与える可能性がある．しかしながら，胸部単純 X 線写真の PA 像が撮影できない場合においても，胸部単純 X 線写真の PA 像は最も一般的な画像検査であることから，過去に取得した画像が picture archiving and communication systems (PACS) に保存されている確率も高く，過去画像から患者体重を推定することも可能であると考ええる．第三に，本研究は単一の医療機関の画像データを用いてモデルを構築した．他の施設や装置で撮影された画像に対して構築した CNN モデルが適用可能であるかは明らかではなく，複数施設のデータを用いたさらなる検証が必要である．最後に，体重推定モデルの構築は古典的な VGG16 モデルを用いて行ったため，最新のモデルを活用することで精度向上が期待できる可能性がある．ただし，本研究の目的は最良の深層学習モデル構造を探索することではなく，深層学習を用いて胸部単純 X 線写真から患者体重を推定できる可能性を示すことである．VGG16 を用いたモデルでも十分な精度が得られており，最新のモデルを導入する効果は限定的であると考ええる．

## 4.5 結論

深層学習を適用することで，胸部単純 X 線写真から患者体重を推定することが可能であった．提案手法は，体重が不詳である患者に対する X 線 CT 検査の被ばく線量管理や造影剤投与量の算出，MRI 検査での SAR の推定など，放射線医学の多岐にわたる領域で活用できる可能性がある．

## 4.6 参考文献

- 1 Fukunaga M, Matsubara K, Ichikawa S, Mitsui H, Yamamoto H, Miyati T. CT dose management of adult patients with unknown body weight using an effective diameter. *Eur. J. Radiol.* 2021; 135: 109483.
- 2 O'Neill S, Kavanagh RG, Carey BW, Moore N, Maher M, O'Connor OJ. Using body mass index to estimate individualised patient radiation dose in abdominal computed tomography. *Eur. Radiol. Exp.* 2018; 2(1): 38.
- 3 Bae KT. Intravenous contrast medium administration and scan timing at CT: considerations and approaches. *Radiology* 2010; 256(1): 32–61.
- 4 Awai K, Hori S. Effect of contrast injection protocol with dose tailored to patient weight

- and fixed injection duration on aortic and hepatic enhancement at multidetector-row helical CT. *Eur. Radiol.* 2003; 13(9): 2155–2160.
- 5 Seo Y, Wang ZJ. Measurement and evaluation of specific absorption rate and temperature elevation caused by an artificial hip joint during MRI scanning. *Sci. Rep.* 2021; 11(1): 1134.
  - 6 Fernandes CMB, Clark S, Price A, Innes G. How accurately do we estimate patients' weight in emergency departments? *Can. Fam. Physician* 1999; 45: 2373–2376.
  - 7 Hall WL, Larkin GL, Trujillo MJ, Hinds JL, Delaney KA. Errors in weight estimation in the emergency department: comparing performance by providers and patients. *J. Emerg. Med.* 2004; 27(3): 219–224.
  - 8 Menon S, Kelly A-M. How accurate is weight estimation in the emergency department? *Emerg. Med. Australas.* 2005; 17(2): 113–116.
  - 9 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint* 2014. <https://arxiv.org/abs/1409.1556>
  - 10 Tang Y-X, Tang Y-B, Peng Y, et al. Automated abnormality classification of chest radiographs using deep convolutional neural networks. *NPJ Digit. Med.* 2020; 3: 70.
  - 11 Keidar D, Yaron D, Goldstein E, et al. COVID-19 classification of X-ray images using deep neural networks. *Eur. Radiol.* 2021; 31(12): 9654–9663.
  - 12 Usman M, Zia T, Tariq A. Analyzing transfer learning of vision transformers for interpreting chest radiography. *J. Digit. Imaging* 2022; 35(6): 1445–1462.
  - 13 Ichikawa S, Hamada M, Sugimori H. A deep-learning method using computed tomography scout images for estimating patient body weight. *Sci. Rep.* 2021; 11(1): 15627.
  - 14 Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. *Commun. ACM* 2017; 60(6): 84–90.
  - 15 Kingma DP, Ba J. Adam: A method for stochastic optimization. *arXiv preprint* 2015. <https://arxiv.org/abs/1412.6980>
  - 16 Selvaraju RR, Cogswell M, Das A, Vedantam R, Parikh D, Batra D. Grad-CAM: Visual explanations from deep networks via gradient-based localization. *arXiv preprint* 2016. <https://arxiv.org/abs/1610.02391>

- 17 Buckley RG, Stehman CR, Dos Santos FL, et al. Bedside method to estimate actual body weight in the Emergency Department. *J. Emerg. Med.* 2012; 42(1): 100–104.
- 18 Geraghty EM, Boone JM. Determination of height, weight, body mass index, and body surface area with a single abdominal CT image. *Radiology* 2003; 228(3): 857–863.
- 19 Gascho D, Ganzoni L, Kolly P, et al. A new method for estimating patient body weight using CT dose modulation data. *Eur. Radiol. Exp.* 2017; 1(1): 23.
- 20 Yamada Y, Yamada M, Chubachi S, et al. Comparison of inspiratory and expiratory lung and lobe volumes among supine, standing, and sitting positions using conventional and upright CT. *Sci. Rep.* 2020; 10(1): 16203.

## 第 5 章 CT 横断像を用いた患者体重の推定：

### 断面積測定法と深層学習の評価

本章は以下の学術論文の内容に基づいて記した．

*Ichikawa S, Sugimori H. Estimating body weight from measurements from different single-slice CT levels: An evaluation of total cross-sectional body area measurements and deep learning. J Comput Assist Tomogr. (in press).*

#### 5.1 はじめに

患者体重は、臨床現場において極めて重要な指標であり、多くの医療処置において正確な情報が必要である．救急医療では、患者体重を正確に把握することにより、緊急の投薬治療や造影剤を使用した画像検査において、正確な投与量を算出することが可能になる<sup>1-3</sup>．しかし、救急医療では、患者の意識が不明瞭なことが多いため、体重測定は容易ではない．また、体重情報は X 線 CT 検査の被ばく線量管理<sup>4-6</sup>やフレイルのスクリーニング<sup>7,8</sup>にも用いられているが、来院したすべての患者に対して体重計を用いて測定することは、ワークフローの観点から現実的ではない．

診断用 CT スキャンの単一スライスの解析は、身長や体重などの形態学的指標<sup>9</sup>、皮下脂肪、内臓脂肪、骨格筋指数、骨密度などの体組成<sup>10-12</sup>の評価に用いられている．通常、医用画像を用いた体組成の評価は、第三腰椎（L3）レベルの単一スライスを用いて実施される<sup>13-15</sup>．体組成に関する一部の研究では、適応が腹部 X 線 CT 検査に限定されないよう、胸部<sup>16,17</sup>および頸部<sup>18</sup>のスライスの解析により体組成を正確に評価できる可能性が示されている．

一方、患者体重に関する過去の報告においては、62 人の未治療の悪性黒色腫の成人患者を対象に、L3 レベル中央の CT 横断像で手動により計測された断面積のみを使用して、正確な患者体重を推定できることが示されている<sup>19</sup>．ただし、この手法は L3 レベルの CT 横断像を対象にしているため、腹部 X 線 CT 検査または躯幹部 X 線 CT 検査を受けた患者に適用が限定される．さらに、先行研究でも言及されているように、この結果は限られた 62 人の患者に関するものであり、断面積の自動計測を導入し、より大規模な集団で

検証を行う必要がある。そのため、L3 レベル以外のさまざまなスライス位置にも適用可能で、自動計測により医療従事者の労力を要しない体重推定手法を開発する意義は大きいといえる。

第3章では、診断用 CT スキャンではなく、位置決め画像から患者体重を推定する利点を強調したが、従来から、単一の CT スライスを用いた形態学的指標や体組成の評価が行われてきたことを考慮すると、CT 横断像も対象にして、患者体重をより高精度に推定するための方法を探求する必要がある。体重情報を被ばく線量管理やフレイルのスクリーニングなど後方視的に利用する場合には、画像の種類はあまり重要ではなく、単に精度が重要である。そこで本章では、大規模コホートを対象に、2つの手法を用いてさまざまなスライス位置の CT 横断像から患者体重の推定を試みた。一つ目の手法は、閾値処理によって計測された断面積を入力変数とする線形回帰モデルを適用する方法である。二つ目の手法は、深層学習を用いて CT 横断像から直接患者体重を推定する方法である。後者は、第3章や第4章で検証した結果<sup>20, 21</sup>や、他の研究グループの報告<sup>22</sup>において、深層学習を用いて医用画像から患者体重を高精度に推定できる可能性が示唆されたため検討に加えた。本章の目的は、1) さまざまなスライス位置の CT 横断像を対象に、2つの手法を用いて推定した患者体重と実測体重との関係性を評価すること、2) 体重推定に最適なスライス位置を決定することである。

## 5.2 方法

図 5.1 に、本研究の概要を示す。10ヵ所のスライス位置において、断面積を利用した線形回帰モデルと深層学習モデルの2つの体重推定手法を評価した。公開データベースの医用画像を利用したため、本研究の実施には倫理委員会による承認は不要であった。




図 5.1 研究の概要

10 ヶ所のスライス位置の CT 横断像を用いて、断面積を利用した線形回帰モデルと深層学習モデルの 2 つの体重推定手法を評価した．線形回帰モデルと深層学習モデルの構築と評価には、10 分割交差検証を使用した．つまり、収集したデータを 10 つのサブセットに分割し、そのうち 9 つのサブセットを使用してモデルを学習し、残りの 1 つのサブセットでモデルの性能を検証した．これをすべての組み合わせに対して行った．

### 5.2.1 対象と撮影方法

本研究では、MICCAI AutoPET II challenge 2023 (<https://autopet-ii.grand-challenge.org/>) で公開されている PET/CT 検査の CT 画像を使用した<sup>23</sup>．この公開データセットには、900 人の患者に対する 1,014 件の PET/CT 検査データが含まれており、その内訳は悪性リ

ンパ腫，黒色腫，非小細胞肺癌の患者に対する 501 検査と PET/CT 検査で悪性所見が認められなかった患者に対する 513 検査である．本研究では，900 人の患者のうち，PET/CT 検査の撮影範囲に頸部から大腿部までが含まれていた 862 人の CT 画像を解析対象とし，撮影範囲が不十分であった 35 人，検査中の体動によるアーチファクトが著しい 1 人，重度の側弯があった 1 人は除外した．診断用 CT スキャンは臨床用 PET/CT 装置である Biograph mCT (Siemens Healthineers, Knoxville, USA) を用いて，標準化された以下のプロトコルで撮影された：管電圧：120 kV，管電流時間積：200 mAs (CT-AEC 使用)，スライス厚：2–3 mm．撮影体位は両腕を挙上した状態であり，呼気で撮影された．患者体重は，DICOM ヘッダーのタグ情報から取得した．図 5.2 に，本研究の対象患者における実測体重のヒストグラムを示す．患者体重の中央値（四分位範囲）は，77.0 (66.0–88.0) kg であった．

解析に用いた CT 横断像は，矢状面および冠状面を参照して各患者から 10 ヶ所のスライス位置（第一・第三・第五・第七・第九・第十一胸椎，第一・第三・第五腰椎，恥骨）の中心から選択した．本章では，これらのスライス位置を T1, T3, T5, T7, T9, T11, L1, L3, L5, Pubis と定義した．次に，スライス位置ごとに，2 つの方法を用いて体重推定モデルを構築した．2 つの方法を用いて構築したモデルの評価には，10 分割交差検証を使用した．




図 5.2 対象患者における実測体重のヒストグラム

## 5.2.2 断面積を用いた線形回帰モデル

図 5.3 に、各 X 線 CT 画像における断面積の自動測定方法を示す。まず、CT 画像を -600 Hounsfield Unit (HU) の閾値で 2 値化し、空気を除いた全身の領域が抽出されるようにした。次に、2 値化された画像に対してラベリングを行い、面積が最大となる領域のみを抽出した。最後に、抽出した領域に対して輪郭抽出を行い、抽出された領域内の断面積 ( $\text{cm}^2$ ) を算出した。ラベリングと輪郭抽出は OpenCV (<https://opencv.org/>) を用いて実施した。

先行研究によると、患者体重は、断面積のみを入力とした線形回帰モデルにより高精度に推定可能であることが示されている<sup>19)</sup>。したがって、本研究においても、scikit-learn パッケージ (<https://scikit-learn.org/stable/>) を使用して、自動計測した断面積を入力とする線形回帰モデルを構築した。線形回帰モデルの適合度は、 $R^2$  値を算出して評価した。




図 5.3 CT 横断像における断面積の自動計測

### 5.2.3 深層学習モデル

深層学習モデルを構築する前に、X 線 CT 画像に対して以下の前処理を行った。まず、自然画像の RGB 構造を模倣するために、グレースケール画像を 3 チャンネルに割り当て、X 線 CT 画像を DICOM 形式から 8-bit (256 階調) の PNG 形式に変換した。変換の過程で、CT 値は腹部ウィンドウ条件 (ウィンドウレベル: 50 HU, ウィンドウ幅: 350 HU) に基づいて変換した。次に、CNN の転移学習のために、マトリクスサイズが  $224 \times 224$  になるように調整した。さらに、データ拡張のため、訓練データの X 線 CT 画像を  $-10^\circ$  から  $10^\circ$  の範囲で回転させ、訓練データ数が 5 倍になるようにした。

深層学習モデルの構築は、各スライス位置における CT 横断像を入力データ、患者体重を教師データとして、VGG16<sup>24</sup> の転移学習を利用した教師あり学習を行った。第 4 章で良好な結果が得られたモデル構造に従い、元の VGG16 モデルから全結合層を取り除き、以下の 4 つの層を追加した: (1) 線形層 (出力サイズ: 512), (2) ReLU 関数, (3) ドロップアウト ( $p = 0.4$ ), (4) 線形層 (出力サイズ: 1)。ネットワークは ImageNet データベース<sup>25</sup> で事前学習されたものを利用したため、入力画像は ImageNet の画像の平均値 (0.485, 0.456, 0.406) および標準偏差 (0.229, 0.224, 0.225) で正規化した。学習時には、全層の重みを更新するファインチューニングを行った。損失関数として平均二乗誤差を使用し、最適化アルゴリズムには Adam<sup>26</sup> を使用した。初期学習率は 0.001 で、バッチサイズは 64 に設定した。最大エポック数は 100 とし、過学習を避けるために early stopping をコールバックとして設定した。

## 5.2.4 体重推定精度の検証

2つの手法による患者体重の推定精度は、MAE および RMSE を用いて評価した（式 5.1 および式 5.2）.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (5.1)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (5.2)$$

ここで、N は画像の総数、 $y_i$  は実測体重、 $\hat{y}_i$  は推定体重である.

また、実測体重と推定体重の関係性は、スピアマンの順位相関係数（ $\rho$ ）を求めて評価した. 実測体重に対する推定体重の許容誤差は、 $\pm 5$  kg および  $\pm 10$  kg と定義し、許容誤差内の画像数を算出した.

## 5.2.5 実験環境

実験環境は、以下の通りである.

- CPU : Intel Core i7-9700F
- GPU : NVIDIA GeForce RTX 2070 Super 8GB
- フレームワーク : PyTorch Lightning 2.0.4
- プログラミング言語 : Python 3.11.3

## 5.3 結果

### 5.3.1 線形回帰モデルの係数と適合度

表 5.1 に、各スライス位置における断面積を入力変数とした線形回帰モデルの係数および  $R^2$  値を示す. 最も線形回帰モデルの適合度が高かったのは、T5 レベルであった（ $R^2 = 0.851$ ）. 表 5.1 に示した線形回帰モデルの係数は、将来的に別の研究で利用できるように

データセット全体に対して算出した値である．本研究では，表 5.2 に示した交差検証の各 fold において訓練データから求めた係数を用いて患者体重を推定し，評価した．

表 5.1 断面積を用いた線形回帰モデルの係数と適合度

| 項目             | T1    | T3     | T5     | T7     | T9    | T11    | L1     | L3     | L5     | Pubis  |
|----------------|-------|--------|--------|--------|-------|--------|--------|--------|--------|--------|
| 傾き             | 0.116 | 0.122  | 0.109  | 0.106  | 0.102 | 0.095  | 0.089  | 0.080  | 0.082  | 0.119  |
| 切片             | 1.136 | -6.009 | -0.660 | -1.394 | 2.344 | 10.744 | 16.784 | 23.384 | 20.819 | -4.458 |
| R <sup>2</sup> | 0.731 | 0.827  | 0.851  | 0.837  | 0.796 | 0.797  | 0.806  | 0.800  | 0.765  | 0.763  |

表 5.2 各 fold における線形回帰モデルの係数と適合度

| Fold | 項目             | T1    | T3     | T5     | T7     | T9    | T11    | L1     | L3     | L5     | Pubis  |
|------|----------------|-------|--------|--------|--------|-------|--------|--------|--------|--------|--------|
| 1    | 傾き             | 0.117 | 0.122  | 0.109  | 0.105  | 0.101 | 0.094  | 0.089  | 0.080  | 0.082  | 0.119  |
|      | 切片             | 1.100 | -6.222 | -0.578 | -1.185 | 2.847 | 11.051 | 16.539 | 23.481 | 20.772 | -4.606 |
|      | R <sup>2</sup> | 0.731 | 0.825  | 0.850  | 0.836  | 0.794 | 0.795  | 0.810  | 0.804  | 0.770  | 0.767  |
| 2    | 傾き             | 0.116 | 0.121  | 0.109  | 0.106  | 0.102 | 0.095  | 0.089  | 0.080  | 0.082  | 0.118  |
|      | 切片             | 1.218 | -5.792 | -0.839 | -1.687 | 2.320 | 10.626 | 16.653 | 23.082 | 20.586 | -4.424 |
|      | R <sup>2</sup> | 0.734 | 0.825  | 0.851  | 0.836  | 0.793 | 0.794  | 0.806  | 0.801  | 0.767  | 0.762  |
| 3    | 傾き             | 0.114 | 0.120  | 0.107  | 0.103  | 0.100 | 0.093  | 0.088  | 0.079  | 0.080  | 0.116  |
|      | 切片             | 2.534 | -4.651 | 0.842  | 0.193  | 4.015 | 11.820 | 17.612 | 24.324 | 22.085 | -2.845 |
|      | R <sup>2</sup> | 0.720 | 0.819  | 0.843  | 0.827  | 0.779 | 0.779  | 0.789  | 0.780  | 0.743  | 0.749  |
| 4    | 傾き             | 0.118 | 0.122  | 0.109  | 0.106  | 0.102 | 0.095  | 0.089  | 0.080  | 0.082  | 0.118  |
|      | 切片             | 0.095 | -6.270 | -1.048 | -1.890 | 2.205 | 10.566 | 16.724 | 23.263 | 20.771 | -4.240 |
|      | R <sup>2</sup> | 0.735 | 0.828  | 0.853  | 0.840  | 0.796 | 0.799  | 0.811  | 0.808  | 0.776  | 0.761  |
| 5    | 傾き             | 0.116 | 0.122  | 0.109  | 0.105  | 0.102 | 0.094  | 0.088  | 0.080  | 0.082  | 0.119  |
|      | 切片             | 1.568 | -5.974 | -0.610 | -1.190 | 2.638 | 10.999 | 16.987 | 23.449 | 20.880 | -4.519 |
|      | R <sup>2</sup> | 0.733 | 0.832  | 0.852  | 0.837  | 0.795 | 0.799  | 0.802  | 0.791  | 0.756  | 0.757  |

| Fold | 項目             | T1    | T3     | T5     | T7     | T9    | T11    | L1     | L3     | L5     | Pubis  |
|------|----------------|-------|--------|--------|--------|-------|--------|--------|--------|--------|--------|
| 6    | 傾き             | 0.116 | 0.123  | 0.110  | 0.107  | 0.103 | 0.096  | 0.089  | 0.080  | 0.082  | 0.118  |
|      | 切片             | 1.505 | -6.613 | -1.304 | -2.057 | 1.594 | 9.924  | 16.340 | 22.980 | 20.672 | -3.877 |
|      | R <sup>2</sup> | 0.729 | 0.828  | 0.854  | 0.842  | 0.802 | 0.803  | 0.812  | 0.805  | 0.769  | 0.761  |
| 7    | 傾き             | 0.116 | 0.122  | 0.109  | 0.106  | 0.102 | 0.095  | 0.088  | 0.080  | 0.082  | 0.119  |
|      | 切片             | 0.926 | -6.410 | -0.836 | -1.421 | 2.482 | 10.764 | 16.870 | 23.322 | 20.542 | -4.891 |
|      | R <sup>2</sup> | 0.726 | 0.828  | 0.854  | 0.841  | 0.799 | 0.799  | 0.807  | 0.801  | 0.768  | 0.757  |
| 8    | 傾き             | 0.118 | 0.123  | 0.110  | 0.107  | 0.104 | 0.095  | 0.089  | 0.080  | 0.082  | 0.120  |
|      | 切片             | 0.441 | -6.378 | -1.382 | -2.152 | 0.669 | 10.567 | 16.766 | 23.220 | 20.449 | -5.211 |
|      | R <sup>2</sup> | 0.734 | 0.828  | 0.855  | 0.839  | 0.814 | 0.799  | 0.809  | 0.805  | 0.771  | 0.769  |
| 9    | 傾き             | 0.117 | 0.122  | 0.109  | 0.105  | 0.102 | 0.095  | 0.088  | 0.080  | 0.082  | 0.120  |
|      | 切片             | 1.099 | -5.837 | -0.330 | -1.144 | 2.573 | 10.748 | 16.916 | 23.531 | 20.965 | -5.126 |
|      | R <sup>2</sup> | 0.738 | 0.829  | 0.849  | 0.834  | 0.794 | 0.801  | 0.810  | 0.800  | 0.765  | 0.771  |
| 10   | 傾き             | 0.117 | 0.122  | 0.109  | 0.106  | 0.103 | 0.095  | 0.089  | 0.080  | 0.082  | 0.119  |
|      | 切片             | 0.917 | -5.887 | -0.452 | -1.349 | 2.137 | 10.420 | 16.466 | 23.214 | 20.511 | -4.808 |
|      | R <sup>2</sup> | 0.732 | 0.828  | 0.851  | 0.838  | 0.797 | 0.799  | 0.809  | 0.803  | 0.769  | 0.770  |

### 5.3.2 線形回帰モデルと深層学習モデルにおける推定精度

表 5.3 に、MAE, RMSE, スピアマンの相関係数の値を示す。線形回帰モデルにおいて、T5 レベルの推定体重が実測体重と最も強い相関を示した (MAE, 5.39 kg ; RMSE, 7.01 kg ;  $\rho = 0.912$ )。一方、T1 レベルにおける推定精度は、最も低かった (MAE, 7.18 kg ; RMSE, 9.43 kg ;  $\rho = 0.846$ )。深層学習モデルに関しては、L5 レベルが最も高い精度を示し (MAE, 6.72 kg ; RMSE, 8.82 kg ;  $\rho = 0.865$ )、T1 レベル (MAE, 7.54 kg ; RMSE, 9.95 kg ;  $\rho = 0.839$ ) が最も低い精度を示した。表 5.4 に、許容誤差内に収まる受診者数 (%) を算出した結果を示す。線形回帰モデルと深層学習モデルの両方の結果を統合すると、T5 レベルの線形回帰モデルを使用した場合、最も精度良く患者体重を推定可能であった。

図 5.4 および図 5.5 に、線形回帰モデルと深層学習モデルのそれぞれで、最も精度が高かったスライス位置と最も精度が低かったスライス位置において、実測体重と推定体重を比較した散布図と Bland-Altman プロットを示す。


表 5.3 各スライス位置における線形回帰モデルと深層学習モデルの推定精度

| 位置    | モデル  | MAE (kg)    | RMSE (kg)   | $\rho$       |
|-------|------|-------------|-------------|--------------|
| T1    | 線形回帰 | 7.18        | 9.43        | 0.846        |
|       | 深層学習 | 7.54        | 9.95        | 0.839        |
| T3    | 線形回帰 | 5.67        | 7.56        | 0.889        |
|       | 深層学習 | 7.36        | 9.67        | 0.841        |
| T5    | 線形回帰 | <b>5.39</b> | <b>7.01</b> | <b>0.912</b> |
|       | 深層学習 | 7.11        | 9.37        | 0.860        |
| T7    | 線形回帰 | 5.70        | 7.34        | 0.903        |
|       | 深層学習 | 6.89        | 9.05        | 0.864        |
| T9    | 線形回帰 | 6.25        | 8.21        | 0.883        |
|       | 深層学習 | 7.46        | 9.70        | 0.841        |
| T11   | 線形回帰 | 6.32        | 8.18        | 0.883        |
|       | 深層学習 | 6.98        | 8.96        | 0.864        |
| L1    | 線形回帰 | 6.09        | 7.98        | 0.890        |
|       | 深層学習 | 6.99        | 9.18        | 0.860        |
| L3    | 線形回帰 | 6.32        | 8.13        | 0.880        |
|       | 深層学習 | 6.84        | 9.08        | 0.871        |
| L5    | 線形回帰 | 7.03        | 8.80        | 0.848        |
|       | 深層学習 | 6.72        | 8.82        | 0.865        |
| Pubis | 線形回帰 | 7.17        | 8.86        | 0.846        |
|       | 深層学習 | 6.93        | 9.13        | 0.863        |


MAE: mean absolute error, RMSE: root mean squared error.

表 5.4 線形回帰モデルと深層学習モデルにおける許容誤差範囲内の症例数


| 位置    | モデル  | ±5 kg 以内   |             | ±10 kg 以内  |             |
|-------|------|------------|-------------|------------|-------------|
|       |      | 症例数        | 割合 (%)      | 症例数        | 割合 (%)      |
| T1    | 線形回帰 | 396        | 45.9        | 642        | 74.5        |
|       | 深層学習 | 377        | 43.7        | 630        | 73.1        |
| T3    | 線形回帰 | 479        | 55.6        | 715        | 82.9        |
|       | 深層学習 | 391        | 45.4        | 632        | 73.3        |
| T5    | 線形回帰 | <b>479</b> | <b>55.6</b> | <b>734</b> | <b>85.2</b> |
|       | 深層学習 | 386        | 44.8        | 642        | 74.5        |
| T7    | 線形回帰 | 455        | 52.8        | 720        | 83.5        |
|       | 深層学習 | 399        | 46.3        | 667        | 77.4        |
| T9    | 線形回帰 | 420        | 48.7        | 698        | 81.0        |
|       | 深層学習 | 369        | 42.8        | 627        | 72.7        |
| T11   | 線形回帰 | 405        | 47.0        | 695        | 80.6        |
|       | 深層学習 | 389        | 45.1        | 657        | 76.2        |
| L1    | 線形回帰 | 396        | 45.9        | 642        | 74.5        |
|       | 深層学習 | 396        | 45.9        | 644        | 74.7        |
| L3    | 線形回帰 | 424        | 49.2        | 692        | 80.3        |
|       | 深層学習 | 406        | 47.1        | 663        | 76.9        |
| L5    | 線形回帰 | 353        | 41.0        | 658        | 76.3        |
|       | 深層学習 | 419        | 48.6        | 667        | 77.4        |
| Pubis | 線形回帰 | 351        | 40.7        | 634        | 73.5        |
|       | 深層学習 | 409        | 47.4        | 666        | 77.3        |




(a)



(b)



(c)



(d)

図 5.4 推定精度が最も高いまたは低いスライス位置における実測体重と推定体重の関係  
線形回帰モデルは、T5 レベルで最も高い精度を示し (a)，T1 レベルで最も低い精度を示した (b)。深層学習モデルは、L5 レベルで最も高い精度を示し (c)，T1 レベルで最も低い精度を示した (d)。




図 5.5 推定精度が最も高いまたは低いスライス位置における Bland-Altman プロット  
 線形回帰モデルは、T5 レベルで最も高い精度を示し (a)，T1 レベルで最も低い精度を示した (b)。深層学習モデルは、L5 レベルで最も高い精度を示し (c)，T1 レベルで最も低い精度を示した (d)。

## 5.4 考察

患者の意識が不明瞭な状況で、緊急の造影 CT 検査や薬剤投与を行うために体重情報が必要である場合、患者体重を迅速に測定することは容易ではない。患者体重と X 線 CT 画像における形態的な特徴量との関連性は、L1 または L3 レベルの CT 横断像を対象とした画像解析により既に明らかにされているが<sup>9, 19</sup>、これらの方法は形態的な特徴量を手動により計測する必要がある。また、これらの方法は撮影範囲に腹部が含まれている場合にのみ適用可能であり、他のスライス位置で同様の解析を行った場合に患者体重を推定できるかは明確ではない。したがって、さまざまなスライス位置の CT 横断像から、高精度かつ簡便な手法で患者体重を推定する方法が必要とされている。そこで本研究では、さまざまなスライス位置において、患者体重を推定するための断面積を利用した線形回帰モデルと深層学習モデルの 2 つの手法を評価した。さらに、患者体重を正確に推定するために最適なスライス位置を調査した。その結果、どちらの手法も検証したすべてのスライス位置において、推定体重は実測体重と比較的良好な相関関係にあることが示された。特に、T5 レベルの CT 横断像に線形回帰モデルを適用した場合、最も精度が優れていた。以上より、本研究で提案した体重推定手法および体重推定に最適なスライス位置に関する知見は、救急医療やフレイルのスクリーニング、既に終了した前向き研究に対する遡及的な体重評価など、さまざまな臨床的・科学的な状況で有用であると考えられる。

先行研究によれば、断面積のみを入力変数とする線形回帰モデルを用いることで、患者体重を高い精度で推定できることが示されており、本研究でもその傾向が確認された。Zopfs らは、L3 レベルにおける線形回帰モデルの傾きは 0.080、切片は 18.351 であったと報告している<sup>19</sup>。一方、本研究における線形回帰モデルの傾きは 0.080、切片は 23.384 となり、これらの係数は類似している。体組成分析に関しては、胸部 CT スキャンにも適用可能な胸椎レベルの代替案が提案されているが<sup>27-29</sup>、体重推定用の代替レベルについての報告はない。そのため、本研究ではさまざまなスライス位置に対する体重推定用の線形回帰モデルを検討し、その結果、典型的な L3 レベルよりも T5 レベルの CT 横断像を用いることで、患者体重をより正確に推定できることが示された。これらの結果から、X 線 CT 検査の撮影範囲に胸部が含まれる場合、線形回帰モデルを用いて患者体重を推定する際には、L3 レベルではなく、T5 レベルの CT 横断像を利用することが推奨される。

深層学習を用いて既存の医用画像から患者体重を推定する試みは、これまで胸部・腹

部の CT 位置決め画像<sup>20</sup>、胸部単純 X 線写真<sup>21</sup>、頭部 CT 位置決め画像<sup>22</sup>を対象に行われている。胸部・腹部 CT 位置決め画像や胸部単純 X 線写真を用いた場合には、MAE が 5.0 kg 以内という高い精度が得られており<sup>20, 21</sup>、これは CT 横断像に深層学習を適用した本研究の精度よりも高い精度を示している。データセットの対象やサイズが異なるため、直接的な比較は困難であるが、このような結果が得られた理由のひとつとして、CT 位置決め画像や単純 X 線写真は、身体の Z 軸方向（頭尾方向）の一定範囲における X 線減弱に関する情報を有しているのに対して、CT 横断像は非常に狭い範囲での X 線減弱に関する情報しか有していないことが挙げられる。

第 3 章および第 4 章で述べたように、CT 位置決め画像や単純 X 線写真を利用して患者体重を推定する利点として、診療放射線技師や放射線科医師は、診断用 CT スキャンを撮影する前に患者体重を把握できることが挙げられる。これにより、単純 CT 画像が存在しない状況においても、造影剤投与量を算出するなどの用途に活用できる。また、装置コンソールでの患者情報の登録時に患者体重も同時に入力することで、DICOM ヘッダーに体重情報を記録することが可能になる。しかし、深層学習を用いた CT 位置決め画像からの推定は、X 線 CT 検査のポジショニング時に生じるオフセンターの影響を受けやすいことに留意が必要である。さらに、臨床ではしばしば、撮影した CT 位置決め画像に異物が写りこむ場合がある。したがって、不正確なポジショニングによる画像の拡大率の影響や、位置決め画像における異物の写りこみの影響が想定される場合には、診断用の CT 横断像から患者体重を推定したほうが望ましい場合もあると考える。また現在、CT 位置決め画像から患者体重を推定するために公表されている方法は、本論文で提案した深層学習を用いる方法のみであり、臨床で利用できるシステムが実現するには時間を要する。一方、CT 横断像から推定する場合には、本章で検証したように深層学習を用いる方法だけでなく、断面積を利用した線形回帰モデルも提案されている。本研究では、断面積は画像処理により自動的に求めたが、先行研究と同様に手動で求めることも可能である。つまり、線形回帰モデルを利用した手法では、CT 横断像から断面積さえ求めることができれば、表 5.1 に示した係数を用いることで、すぐに患者体重を推定することができるという利点がある。

推定精度という観点では、CT 横断像に対して深層学習を適用して患者体重を推定する利点は、それほど大きくはない。しかし、L5 や Pubis など一部のスライスレベルにおいて、深層学習モデルを用いた場合の精度は、線形回帰モデルよりも優れていた。一般的に、

深層学習モデルの性能は、大規模で高品質な訓練データを使用し<sup>30</sup>、モデル構造を最適化することで劇的に向上する。したがって、深層学習モデルと断面積を用いた線形回帰モデルの両方が、日常臨床やさまざまな研究で活用される可能性があると考えている。

本研究では、いくつかの限界点がある。第一に、解析対象としたさまざまなスライス位置の CT 横断像は、手動で選択した点があげられる。しかし、深層学習を用いて特定のスライス位置の CT 横断像を自動で選択する技術が既に開発されており<sup>31</sup>、このような技術を組み合わせることで、CT 画像データから人の介入を必要としない形式で体重推定が可能になると期待される。第二に、対象としたデータセットには PET/CT 検査で悪性病変がある患者とない患者の両方が含まれていたが、悪性病変の有無が体重推定の精度に与える影響は考慮されていない。ただし、このデータセットは、第 3 章および第 4 章で対象としたデータがほとんど健常人であるのと比較して、より臨床に近い状況を反映していると考えられる。最後に、本研究は単一の公開データベースの X 線 CT 画像を用いた遡及的研究であり、本研究で構築したモデルが他のデータベースに適用できるかどうかは不明である。今後、異なる疾患を有する患者データにおいて、追加の検証が必要である。

## 5.5 結論

本章では、さまざまなスライス位置の CT 横断像を用いて、患者体重を簡便かつ正確に推定するための 2 つの手法の精度を評価した。断面積を入力とする線形回帰モデルと、CT 画像から直接患者体重を推定する深層学習モデルの両方が、良好な精度を示した。特に、T5 レベルの断面積を入力変数とする線形回帰モデルは、最も正確に患者体重を推定できることが示された。

## 5.6 参考文献

- 1 Buckley RG, Stehman CR, Dos Santos FL, et al. Bedside method to estimate actual body weight in the Emergency Department. J. Emerg. Med. 2012; 42(1): 100–104.
- 2 Bae KT, Tao C, Gürel S, et al. Effect of patient weight and scanning duration on contrast enhancement during pulmonary multidetector CT angiography. Radiology 2007; 242(2): 582–589.
- 3 Gascho D, Ganzoni L, Kolly P, et al. A new method for estimating patient body weight

- using CT dose modulation data. *Eur. Radiol. Exp.* 2017; 1(1): 23.
- 4 Boos J, Lanzman RS, Heusch P, et al. Does body mass index outperform body weight as a surrogate parameter in the calculation of size-specific dose estimates in adult body CT? *Br. J. Radiol.* 2016; 89(1059): 20150734.
- 5 Fukunaga M, Matsubara K, Ichikawa S, Mitsui H, Yamamoto H, Miyati T. CT dose management of adult patients with unknown body weight using an effective diameter. *Eur. J. Radiol.* 2021; 135: 109483.
- 6 Ichikawa S, Itadani H, Sugimori H. Deep learning-based body weight from scout images can be an alternative to actual body weight in CT radiation dose management. *J. Appl. Clin. Med. Phys.* 2023; 24(8): e14080.
- 7 Fried LP, Tangen CM, Walston J, et al. Frailty in older adults: evidence for a phenotype. *J. Gerontol. A. Biol. Sci. Med. Sci.* 2001; 56(3): M146-156.
- 8 Satake S, Arai H. The revised Japanese version of the Cardiovascular Health Study criteria (revised J-CHS criteria). *Geriatr. Gerontol. Int.* 2020; 20(10): 992–993.
- 9 Geraghty EM, Boone JM. Determination of height, weight, body mass index, and body surface area with a single abdominal CT image. *Radiology* 2003; 228(3): 857–863.
- 10 Greco F, Quarta LG, Grasso RF, Beomonte Zobel B, Mallio CA. Increased visceral adipose tissue in clear cell renal cell carcinoma with and without peritumoral collateral vessels. *Br. J. Radiol.* 2020; 93(1112): 20200334.
- 11 Shafaat O, Liu Y, Jackson KR, et al. Association between abdominal CT measurements of body composition before deceased donor liver transplant with posttransplant outcomes. *Radiology* 2023; 306(3): e212403.
- 12 Pickhardt PJ, Graffy PM, Perez AA, Lubner MG, Elton DC, Summers RM. Opportunistic screening at abdominal CT: use of automated body composition biomarkers for added cardiometabolic value. *Radiographics* 2021; 41(2): 524–542.
- 13 Shen W, Punyanitya M, Wang Z, et al. Visceral adipose tissue: relations between single-slice areas and total volume. *Am. J. Clin. Nutr.* 2004; 80(2): 271–278.
- 14 Noumura Y, Kamishima T, Sutherland K, Nishimura H. Visceral adipose tissue area measurement at a single level: can it represent visceral adipose tissue volume? *Br. J. Radiol.* 2017; 90(1077): 20170253.

- 15 Schweitzer L, Geisler C, Pourhassan M, et al. What is the best reference site for a single MRI slice to assess whole-body skeletal muscle and adipose tissue volumes in healthy adults? *Am. J. Clin. Nutr.* 2015; 102(1): 58–65.
- 16 Tong Y, Udupa JK, Torigian DA, et al. Chest fat quantification via CT based on standardized anatomy space in adult lung transplant candidates. *PLoS One* 2017; 12(1): e0168932.
- 17 Nemec U, Heidinger B, Sokas C, Chu L, Eisenberg RL. Diagnosing sarcopenia on thoracic computed tomography: quantitative assessment of skeletal muscle mass in patients undergoing transcatheter aortic valve replacement. *Acad. Radiol.* 2017; 24(9): 1154–1161.
- 18 Zopfs D, Pinto Dos Santos D, Kottlors J, et al. Two-dimensional CT measurements enable assessment of body composition on head and neck CT. *Eur. Radiol.* 2022; 32(9): 6427–6434.
- 19 Zopfs D, Theurich S, Große Hokamp N, et al. Single-slice CT measurements allow for accurate assessment of sarcopenia and body composition. *Eur. Radiol.* 2020; 30(3): 1701–1708.
- 20 Ichikawa S, Hamada M, Sugimori H. A deep-learning method using computed tomography scout images for estimating patient body weight. *Sci. Rep.* 2021; 11(1): 15627.
- 21 Ichikawa S, Itadani H, Sugimori H. Prediction of body weight from chest radiographs using deep learning with a convolutional neural network. *Radiol. Phys. Technol.* 2023; 16(1): 127–134.
- 22 Kondo T, Umezu M, Kondo Y, Sato M, Kanazawa T, Noto Y. Development of a new body weight estimation method using head CT scout images. *J. Xray. Sci. Technol.* 2023; 31(5): 1079–1091.
- 23 Gatidis S, Hepp T, Früh M, et al. A whole-body FDG-PET/CT Dataset with manually annotated Tumor Lesions. *Sci. data* 2022; 9(1): 601.
- 24 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint* 2014. <https://arxiv.org/abs/1409.1556>
- 25 Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional

- neural networks. Commun. ACM 2017; 60(6): 84–90.
- 26 Kingma DP, Ba J. Adam: A method for stochastic optimization. arXiv preprint 2015.  
<https://arxiv.org/abs/1412.6980>
- 27 Cho YH, Do KH, Chae EJ, et al. Association of chest CT-based quantitative measures of muscle and fat with post-lung transplant survival and morbidity: a single institutional retrospective cohort study in Korean population. Korean J. Radiol. 2019; 20(3): 522–530.
- 28 Hong JH, Hong H, Choi YR, et al. CT analysis of thoracolumbar body composition for estimating whole-body composition. Insights Imaging 2023; 14(1): 69.
- 29 Dabiri S, Popuri K, Cespedes Feliciano EM, Caan BJ, Baracos VE, Beg MF. Muscle segmentation in axial computed tomography (CT) images at the lumbar (L3) and thoracic (T4) levels for body composition analysis. Comput. Med. Imaging Graph. 2019; 75: 47–55.
- 30 Cho J, Lee K, Shin E, Choy G, Do S. How much data is needed to train a medical image deep learning system to achieve necessary high accuracy? arXiv preprint 2015.  
<https://arxiv.org/abs/1511.06348>
- 31 Ha J, Park T, Kim H-K, et al. Development of a fully automatic deep learning system for L3 selection and body composition assessment on computed tomography. Sci. Rep. 2021; 11(1): 21656.

## 第 6 章 X 線 CT 検査における体重不詳患者の 被ばく線量管理

本章は以下の学術論文の内容に基づいて記した.

*Ichikawa S, Itadani H, Sugimori H. Deep learning-based body weight from scout images can be an alternative to actual body weight in CT radiation dose management. J. Appl. Clin. Med. Phys. 2023; 24(8): e14080.*

### 6.1 はじめに

X 線 CT 検査は、患者のスクリーニング、診断、治療方針の決定において極めて重要な役割を果たしている。しかし、同時に放射線誘発悪性腫瘍の潜在的リスクから、放射線被ばくの増加が懸念されている。2020 年 4 月以降、本邦では医療法施行規則が一部改正され、医療被ばくの安全管理が義務付けられた。これにより、X 線 CT 検査を受ける患者の被ばく線量を適切に記録し、管理することが求められており、医療施設では線量管理システムの導入が進められている。

X 線 CT 装置からの出力である CTDI<sub>vol</sub> および DLP は、臨床で広く使用されている線量指標である。患者の撮影線量を最適化するための基準である DRL は、X 線 CT 検査におけるこれらの線量指標を集計し、標準的な線量を調査して定められたものである<sup>1-4</sup>。

DRL の設定において、患者の体格を標準化するために、従来から患者体重に基づいて調整が行われてきた<sup>5</sup>。本邦の DRLs 2020 において、成人 CT の DRL 値は、被検者の標準体型を 50-70 kg として定められている<sup>1</sup>。しかしながら、線量は患者の体格に依存するため、単に標準体型に基づいて設定された DRL 値だけでは十分ではない<sup>6</sup>。X 線 CT 検査の線量最適化を促進するために、施設で用いられている典型的な線量を調査し、DRL 値と比較したり、患者の体格ごとに異なる DRL 値を設定したりするためには、正確な患者の体重情報が必要になる。

近年、米国医学物理学会（American Associations of Physicist in Medicine : AAPM）は、個々の患者の線量評価をより正確に行うために、患者の体格を考慮した SSDE（size-specific dose estimates）の使用を推奨している<sup>7,8</sup>。これは、CTDI<sub>vol</sub> が特定の大きさのアク

リルファントムを用いた測定値であり、個人の患者の線量を表すものではないためである

9. SSDE は、 $CTDI_{vol}$  に実効直径や水当量直径に関連した変換係数を乗じて求める。実効直径は、体幹部の長径と短径から計算される実質的な被検者の直径であり、水当量直径は、体幹部の断面積および HU 値に基づいて求められる<sup>8</sup>。AAPM Report No.220 では、ベンダー間で患者サイズと SSDE の算出方法を統一化し、算出した値を DICOM ヘッダーあるいは RDSR に格納することを推奨している<sup>8</sup>。ただし、臨床現場ではまだこれらの指標が RDSR に含まれておらず、SSDE を用いた線量評価のためには専用の被ばく線量管理ソフトウェアを使用する必要がある。また、肥満患者あるいは心臓や筋骨格系の X 線 CT 検査でしばしば生じるように、患者の体輪郭が有効視野外となるような場合には、実効直径や水当量直径を正確に求めることが困難になる。このため、いくつかの研究では、実効直径や水当量直径と体重あるいは BMI との関連性を考慮して、SSDE の算出方法を簡略化する試みが行われている<sup>10-14</sup>。

以上のような状況から、患者の体重情報は X 線 CT 検査の被ばく線量管理を推進するためには不可欠な要素であるといえる。しかしながら、これまでの章でも述べたように、特に救急医療においては、X 線 CT 検査の前に患者体重を正確に測定することが難しいことが多々ある。そのため、患者体重が DICOM ヘッダーや RDSR に記録されず、後から体重情報を用いた被ばく線量管理を行うのに支障が生じる。具体的には、施設の代表的な線量と DRL 値を比較することや、体重不詳の患者に対して患者の体格に応じた適切な線量が照射されたかどうかを評価することが困難になる。

体重が不詳である患者の X 線 CT 検査の被ばく線量管理を目的として、患者体重の代替指標が提案されている。Fukunaga らは、患者体重と実効直径の関係を調べ、実効直径が患者体重の代替指標として利用できることを示した<sup>15</sup>。Li らは、患者の体格を T シャツのサイズで表し、T シャツのサイズ別に線量基準値を提示した<sup>16</sup>。これらの提案は非常に興味深い試みであるが、実効直径や T シャツのサイズは体重と比較して直観的で理解しやすいものではない。第 3 章から第 5 章では、深層学習を用いて医用画像データから患者体重を推定できることを示した。そこで、医用画像データから推定した体重を実測体重の代替として使用することにより、体重が不詳である患者の被ばく線量管理を、より直観的な方法で実行できる可能性を考えた。本章では、深層学習を用いて胸部 CT 位置決め画像から算出した推定体重が、X 線 CT 検査の被ばく線量管理において、実測体重の代替となり得るかについて検証することを目的とする。

## 6.2 方法

### 6.2.1 対象

対象は、以下の条件に合致する健康診断の受診者である。

- 1) 2019年6月から2022年5月の期間に、健康診断を目的として胸部単純CT検査を受けた方。
- 2) X線CT撮影の同日に測定された体重データが利用可能な方。
- 3) 線量管理ソフトウェア Radimetrics (Bayer HealthCare, Whippany, New Jersey, USA) 上で線量指標データが利用可能な方。

これらの3つの条件を満たす全3,601件のCTスキャンデータを収集し、収集したデータを無作為に訓練データ ( $n=2,520$ )、検証データ ( $n=360$ )、テストデータ ( $n=721$ ) の3つのサブセットに分割した。表 6.1 に、本研究で対象とした患者の背景情報を示す。なお、本研究は倉敷中央病院の医の倫理委員会の承認を得て実施された (承認番号: 3627)。

### 6.2.2 X線CT検査

X線CT装置は体軸方向に80列の検出器を有する Aquilion Prime (キヤノンメディカルシステムズ株式会社, 大田原, 日本) を使用し、胸部の正面位置決め画像に続き、胸部の診断用スキャンを撮影した。胸部の正面位置決め画像は、管電圧 120 kVp, 管電流 10 mA, 有効視野 500 mm で撮影した。胸部の診断用スキャンは、管電圧 120 kVp, 管電流 CT-AEC (スライス厚 5 mm, 再構成関数 FC03, 管電流 10–150 mA), 再構成関数 FC03 および FC52, 再構成方法 AIDR-3D, コリメーション 1.0 mm  $\times$  40 rows, ピッチファクタ 1.475, スライス厚 5 mm で撮影した。有効視野は 320 mm を基本とし、患者の体格に合わせて調整した。体重推定はCT位置決め画像のみを用いて実施し、線量管理の対象となる線量指標は、診断用スキャンから算出された値を使用した。

### 6.2.3 深層学習を用いた体重推定手法

深層学習を用いたCT位置決め画像からの体重推定手法は、第3章で提案した手法に基づくものである<sup>17</sup>。具体的には、CT位置決め画像を入力データとし、患者体重を教師データとして教師あり学習を行い、患者体重を推定するためのCNNモデルを構築した。図

6.1 に、本研究の概要を示す。患者体重を推定するための回帰モデルは、VGG16 モデル<sup>18</sup> を基にして構築した。元の VGG16 モデルの最終層を、以下のように変更した：（１）線形層（出力サイズ：512）、（２）ReLU 関数、（３）ドロップアウト（ $p = 0.4$ ）、（４）線形層（出力サイズ：1）。損失関数として平均二乗誤差を使用し、最適化アルゴリズムには Adam<sup>19</sup> を使用した。初期学習率は 0.001 に設定し、過学習を避けるために early stopping をコールバックとして設定した。最大エポック数は 50 で、バッチサイズは 128 に設定した。使用した GPU は、NVIDIA GeForce RTX 3090 Ti 24 GB であり、フレームワークは PyTorch Lightning 1.6.4 を使用した。

回帰モデルは、訓練データおよび検証データを用いて学習し、残りのテストデータを用いて患者体重の推定精度を評価した。その後、推定体重を被ばく線量管理に適用する妥当性を検証した。

表 6.1 訓練データ、検証データ、テストデータにおける患者背景

| 項目                      | 訓練データ               | 検証データ               | テストデータ              |
|-------------------------|---------------------|---------------------|---------------------|
| データ数                    | 2520                | 360                 | 721                 |
| 性別（男性／女性）               | 1800/720            | 262/98              | 513/208             |
| 年齢（歳）                   | 60.9 (51.9–69.7)    | 60.9 (52.1–70.2)    | 60.5 (49.3–69.2)    |
| 体重（kg）                  | 64.1 (56.9–72.1)    | 63.9 (57.2–72.3)    | 64.1 (56.5–72.4)    |
| 身長（cm）                  | 166.7 (160.0–171.9) | 166.8 (160.2–172.4) | 167.1 (160.3–171.7) |
| BMI（kg/m <sup>2</sup> ） | 23.2 (21.3–25.4)    | 23.2 (21.3–25.5)    | 23.2 (21.2–25.5)    |

BMI, body mass index.




図 6.1 本研究の概要

## 6.2.4 患者体重と $CTDI_{vol}$ および DLP の関係

診断用スキャンにおける  $CTDI_{vol}$  と DLP は、RDSR から収集した．被ばく線量管理において推定体重が実測体重の代替となり得るか検証するため，実測体重と  $CTDI_{vol}/DLP$  の関係，推定体重と  $CTDI_{vol}/DLP$  の関係を評価した．さらに，冠動脈 CT を除く X 線 CT 検査における標準体型を 50–60 kg の範囲と定義した旧版の DRL<sup>20</sup> を考慮し，患者を 10 kg 間隔で 5 つの体重別グループ ( $\leq 50$ , 50–60, 60–70, 70–80,  $\geq 80$  kg) に分類した．DRL の旧版を考慮したのは，標準体型と定義される範囲が現行版 (50–70 kg) に比べて狭かった (50–60 kg) ためである．各体重グループにおいて，実測体重に基づく群と推定体重に基づく群の間で， $CTDI_{vol}$  および DLP を比較した．

## 6.2.5 患者体重と SSDE の関係

SSDE は， $CTDI_{vol}$  に患者サイズを示す実効直径 ( $D_{eff}$ ) に基づいた変換係数 ( $f_{D_{eff}}$ ) を乗じて算出した (式 6.1)．

$$SSDE = CTDI_{vol} \times f_{D_{eff}} \quad (6.1)$$

CTDI<sub>vol</sub> の SSDE への変換係数 ( $f_{\text{Def}}$ ) は, AAPM Report 204<sup>7</sup> に準じ, 式 6.2 より求めた.

$$f_{\text{Def}} = 3.704369 \times e^{-0.03672 \times D_{\text{eff}}} \quad (6.2)$$

式 6.2 において, 実効直径 ( $D_{\text{eff}}$ ) の基準値は, 線量管理ソフトウェア Radimetrics を用いて CT 位置決め画像の横径から自動的に算出された結果である. この値は以後,

$D_{\text{eff\_reference}}$  と定義する. さらに, 先行研究で報告されている手法<sup>11</sup>と同様に,  $D_{\text{eff\_reference}}$  と実測体重,  $D_{\text{eff\_reference}}$  と推定体重の関係を表す回帰式を作成し, 作成した回帰式に実測体重または推定体重を代入することにより, 代用の  $D_{\text{eff}}$  を算出した. このとき, 実測体重から算出された値を  $D_{\text{eff\_actual}}$ , 推定体重から算出された値を  $D_{\text{eff\_predicted}}$  と定義する. 続いて, 式 6.2 から  $D_{\text{eff\_reference}}$ ,  $D_{\text{eff\_actual}}$ ,  $D_{\text{eff\_predicted}}$  のそれぞれに対応する変換係数 ( $f_{\text{Def}}$ ) を求め, 式 6.1 より求めた変換係数から SSDE の基準値 ( $\text{SSDE}_{\text{reference}}$ ) および代用値

( $\text{SSDE}_{\text{actual}}$  および  $\text{SSDE}_{\text{predicted}}$ ) を算出した. 代用値である  $\text{SSDE}_{\text{actual}}$  および  $\text{SSDE}_{\text{predicted}}$  を, 基準値の  $\text{SSDE}_{\text{reference}}$  と比較することにより, 実測体重だけでなく推定体重を用いた場合でも SSDE の算出方法を簡略化することが可能であることを検証した.

## 6.2.6 統計解析

統計解析は, R version 3.5.1 (R Foundation for Statistical Computing, Vienna, Austria) を使用して実施した. すべての検定において, 有意水準は両側 5% とした. 統計解析にあたり, データが正規分布に従うか否かを確認するため, Shapiro–Wilk 検定を実施した. Shapiro–Wilk 検定により, 患者の背景情報や線量指標は正規分布に従わないことが明らかになったため, 連続変数の統計値は中央値 (四分位範囲) で表記した.

推定体重の精度は, MAE, RMSE, スピアマンの順位相関係数 ( $\rho$ ) を算出して評価した. 患者体重と線量指標 (CTDI<sub>vol</sub> および DLP) の関係, 患者体重と実効直径 ( $D_{\text{eff}}$ ) の関係は, 線形回帰モデルを用いて推定した. 指標間の相関関係は, スピアマンの順位相関係数 ( $\rho$ ) を算出して評価した. 3 つの線量指標 (CTDI<sub>vol</sub>, DLP, SSDE) の群間比較では, Wilcoxon 順位和検定を用いた. さらに, 推定体重に基づく群の線量指標が実測体重に基づく群の線量指標と同等であるかどうかを評価するために, 同等性検定を行った. 同等性検定では, 同等性のマージンをデータの標準偏差内に設定した.

## 6.3 結果

### 6.3.1 推定体重の精度

テストデータにおける実測体重の中央値（四分位範囲）は 64.1（56.5–72.4）kg であった。同一症例における推定体重の中央値（四分位範囲）は 64.0（56.3–72.2）kg であった。図 6.2 に、実測体重を横軸に、推定体重を縦軸にプロットした散布図を示す。図 6.3 に、実測体重と推定体重の差のヒストグラムを示す。推定体重の MAE は 4.41 kg，RMSE は 5.64 kg であった。実測体重と推定体重の相関係数は、 $\rho = 0.892$  ( $p < 0.001$ ) であった。




図 6.2 実測体重と推定体重の関係





図 6.3 実測体重と推定体重の差のヒストグラム


### 6.3.2 患者体重と $\text{CTDI}_{\text{vol}}$ / DLP の関係

図 6.4 に、実測体重と  $\text{CTDI}_{\text{vol}}$  / DLP、および推定体重と  $\text{CTDI}_{\text{vol}}$  / DLP の関係を示す散布図を示す。  $\text{CTDI}_{\text{vol}}$  に対する相関係数は、実測体重で  $\rho = 0.792$  ( $p < 0.001$ )、推定体重で  $\rho = 0.771$  ( $p < 0.001$ ) であった。 DLP に対する相関係数は、実測体重で  $\rho = 0.792$  ( $p < 0.001$ )、推定体重で  $\rho = 0.770$  ( $p < 0.001$ ) であった。


表 6.2 に、実測体重と推定体重に基づいた体重群別の  $\text{CTDI}_{\text{vol}}$  および DLP を比較した結果を示す。すべての体重群で  $\text{CTDI}_{\text{vol}}$  と DLP に有意な差は認められなかった。表 6.3 に、同等性検定の結果を示す。同等性検定において、実測体重に基づく群と推定体重に基づく群の  $\text{CTDI}_{\text{vol}}$  および DLP は、すべての体重群において同等であることが確認された ( $p < 0.001$ )。




(a)



(b)



(c)



(d)

図 6.4 実測体重と CTDI<sub>vol</sub>/DLP および推定体重と CTDI<sub>vol</sub>/DLP の関係

(a) および (b) は実測体重の結果であり, (c) および (d) は推定体重の結果である.

表 6.2 体重群別の CTDI<sub>vol</sub> と DLP の比較

| CTDI <sub>vol</sub> ／DLP  | 実測体重群 |                  | 推定体重群 |                  | <i>p</i> |
|---------------------------|-------|------------------|-------|------------------|----------|
|                           | n     | 中央値（四分位範囲）       | n     | 中央値（四分位範囲）       |          |
| CTDI <sub>vol</sub> (mGy) |       |                  |       |                  |          |
| 体重 ≤ 50 kg                | 65    | 0.9 (0.8–1.0)    | 64    | 0.9 (0.8–1.1)    | 0.334    |
| 体重 50–60 kg               | 192   | 1.2 (1.0–1.3)    | 202   | 1.2 (1.0–1.3)    | 0.652    |
| 体重 60–70 kg               | 222   | 1.4 (1.2–1.6)    | 228   | 1.4 (1.2–1.6)    | 0.393    |
| 体重 70–80 kg               | 168   | 1.7 (1.4–1.8)    | 158   | 1.7 (1.5–1.8)    | 0.299    |
| 体重 ≥ 80 kg                | 74    | 2.0 (1.8–2.2)    | 69    | 1.9 (1.8–2.2)    | 0.490    |
| DLP (mGy·cm)              |       |                  |       |                  |          |
| 体重 ≤ 50 kg                | 65    | 36.2 (31.7–42.2) | 64    | 37.5 (32.0–43.3) | 0.519    |
| 体重 50–60 kg               | 192   | 49.3 (41.2–56.0) | 202   | 48.8 (40.7–56.0) | 0.865    |
| 体重 60–70 kg               | 222   | 59.6 (49.9–66.1) | 228   | 59.7 (50.7–67.7) | 0.484    |
| 体重 70–80 kg               | 168   | 70.8 (58.7–75.5) | 158   | 71.0 (60.9–77.5) | 0.255    |
| 体重 ≥ 80 kg                | 74    | 84.4 (76.3–88.6) | 69    | 82.6 (71.5–88.6) | 0.255    |

CTDI<sub>vol</sub>, volume computed tomography dose index; DLP, dose–length product.

表 6.3 体重群別の CTDI<sub>vol</sub> と DLP に対する同等性検定の結果

| CTDI <sub>vol</sub> /DLP  | 同等性マージン | 95%信頼区間      | <i>p</i> |
|---------------------------|---------|--------------|----------|
| CTDI <sub>vol</sub> (mGy) |         |              |          |
| 体重 ≤ 50 kg                |         | -0.090–0.018 | < 0.001  |
| 体重 50–60 kg               |         | -0.030–0.046 | < 0.001  |
| 体重 60–70 kg               | 0.375   | -0.061–0.018 | < 0.001  |
| 体重 70–80 kg               |         | -0.073–0.014 | < 0.001  |
| 体重 ≥ 80 kg                |         | -0.034–0.124 | < 0.001  |
| DLP (mGy·cm)              |         |              |          |
| 体重 ≤ 50 kg                |         | -3.443–1.149 | < 0.001  |
| 体重 50–60 kg               |         | -1.471–1.757 | < 0.001  |
| 体重 60–70 kg               | 16.248  | -2.560–0.822 | < 0.001  |
| 体重 70–80 kg               |         | -3.379–0.378 | < 0.001  |
| 体重 ≥ 80 kg                |         | -1.259–6.309 | < 0.001  |

CTDI<sub>vol</sub>, volume computed tomography dose index; DLP, dose–length product.

### 6.3.3 患者体重と SSDE の関係

図 6.5 に、実測体重と D<sub>eff\_reference</sub> の関係、推定体重と D<sub>eff\_reference</sub> の関係を示す散布図を示す。実測体重と D<sub>eff\_reference</sub> の間には強い相関が認められた ( $\rho = 0.927$ ,  $p < 0.001$ )。推定体重と D<sub>eff\_reference</sub> の間にも強い相関が認められた ( $\rho = 0.880$ ,  $p < 0.001$ )。D<sub>eff\_reference</sub>, D<sub>eff\_actual</sub>, D<sub>eff\_predicted</sub> の中央値（四分位範囲）はそれぞれ、270.8（254.4–285.4）mm, 268.8（255.2–283.6）mm, 269.4（255.6–284.1）mm であった。

表 6.4 に、代用値である SSDE<sub>actual</sub> および SSDE<sub>predicted</sub> と基準値の SSDE<sub>reference</sub> を比較した結果を示す。SSDE<sub>reference</sub>, SSDE<sub>actual</sub>, SSDE<sub>predicted</sub> の中央値は、それぞれ 1.90（1.62–2.19）mGy, 1.90（1.61–2.20）mGy, 1.91（1.61–2.21）mGy であった。SSDE<sub>actual</sub> と SSDE<sub>predicted</sub> はともに、SSDE<sub>reference</sub> と有意差は認められなかった ( $p = 0.447$ ,  $p = 0.410$ )。表 6.5 は、同等性検定の結果である。同等性検定の結果、代用値である SSDE<sub>actual</sub> および SSDE<sub>predicted</sub> は、基準値の SSDE<sub>reference</sub> と同等であった ( $p < 0.001$ )。




図 6.5 実測体重と実効直径および推定体重と実効直径の関係

(a) は実測体重, (b) は推定体重の結果である.

表 6.4 代用 SSDE と基準値との比較

| SSDE                      | 中央値 (四分位範囲)<br>(mGy) | <i>p</i> |
|---------------------------|----------------------|----------|
| SSDE <sub>reference</sub> | 1.90 (1.62–2.19)     | –        |
| SSDE <sub>actual</sub>    | 1.90 (1.61–2.20)     | 0.447    |
| SSDE <sub>predicted</sub> | 1.91 (1.61–2.21)     | 0.410    |

SSDE, size-specific dose estimates.

表 6.5 代用 SSDE と基準値の同等性検定の結果

| SSDE                                                 | 同等性マージン | 95%信頼区間      | <i>p</i> |
|------------------------------------------------------|---------|--------------|----------|
| SSDE <sub>reference</sub> –SSDE <sub>actual</sub>    | 0.376   | -0.036–0.031 | < 0.001  |
| SSDE <sub>reference</sub> –SSDE <sub>predicted</sub> |         | -0.038–0.030 | < 0.001  |

SSDE, size-specific dose estimates.

## 6.4 考察

本研究では、深層学習を用いて胸部 CT 位置決め画像から得られた推定体重は、X 線 CT 検査の被ばく線量管理に利用可能であるかについて検討した。結果から、推定体重と実測体重は強い相関関係が認められ、さらに、線量指標 ( $CTDI_{vol}/DLP$ ) の比較や体重情報を利用した SSDE の算出方法の簡略化において、実測体重を用いた場合と推定体重を用いた場合で同等の結果が得られた。これらの結果は、深層学習による推定体重が、X 線 CT 検査の被ばく線量管理において、実測体重の代替となり得ることを示唆している。

救急医療などの特定の状況下では、体重計の利用が制限される、患者の意識が不明瞭であるなどの理由から、患者の体重情報を正確に把握することが困難な場合がある。そのため、自施設の線量値と DRL 値を比較する際に、体重が不詳である患者の CT スキャンデータは除外しなければならない。また、体重が不詳である個々の患者に対して、体格に応じた適切な線量が照射されたかどうか確認することが困難になる。このような課題を解決するために、医用画像から推定した患者体重を DICOM ヘッダーに記録することで、X 線 CT 検査の被ばく線量管理を促進できる可能性がある。具体的には、体重が不詳である患者の被ばく線量データを除外する必要がなくなり、より正確な被ばく線量管理や体格に応じた DRL 値の設定が可能になる。さらに、提案手法は推定した患者体重を用いることからより直観的な被ばく線量管理を行うことが可能である。また、深層学習の利用により手動での測定を必要しないという利点がある。これにより、診療放射線技師や放射線科医師は、診断用 CT スキャンの前に患者体重を把握し、患者の体格に応じて適切な画質が得られる検査プロトコルが計画されていることを検証することが可能になる。診断用 CT スキャンの前に患者サイズを正確に把握できることにより、撮影管電圧の選択<sup>21</sup>や個別の患者ごとに最適化された CT 検査プロトコルの立案<sup>22</sup>に役立てることができる。さらに、CT 位置決め画像は、一般的に診断用 CT スキャンに比べて大きな有効視野で撮影されるため、トランケーションエラーの影響を受けにくいという利点がある。

推定体重と実測体重の関係について、本研究における実測体重と推定体重の決定係数 ( $R^2 = 0.795$ ) は、X 線 CT 検査の mAs 値を入力とする回帰式を提案した Gascho らの先行研究 ( $R^2 = 0.938$ )<sup>23</sup> に比べ、低値となった。この結果は、Gascho らが全身の診断用 CT スキャンデータを利用したのに対し、提案手法では診断用 CT スキャンの前に患者の体重情報を取得することを目的として、胸部の CT 位置決め画像のみを使用したことに起

因していると考えられる。一方で、推定精度の観点では先行研究に及ばなかったにもかかわらず、実測体重と推定体重に基づいた体重群別の  $CTDI_{vol}$  および DLP は同等であった。さらに、実測体重と  $CTDI_{vol}/DLP$  の間、推定体重と  $CTDI_{vol}/DLP$  の間にも同等の相関関係が認められた。したがって、患者の体格を考慮した X 線 CT 検査の被ばく線量管理を実行する上で、推定精度は十分であるといえる。

患者体重と実効直径の関係に関して、本研究の結果は（実測体重と推定体重でそれぞれ  $p = 0.927$  と  $p = 0.880$ ,  $p < 0.001$ ）は先行研究と同様の傾向を示した。先行研究では、Boos らは、胸部および腹部 X 線 CT 検査において、患者体重と実効直径が有意に相関していることを明らかにした ( $r = 0.84$ ,  $p < 0.05$ )<sup>11</sup>。Fukunaga らも、胸部 X 線 CT 検査 ( $r = 0.920$ ,  $0.929$ ,  $p < 0.05$ ) および腹部 X 線 CT 検査 ( $r = 0.805$ ,  $p < 0.05$ ) において、患者体重と実効直径の間に強い相関があることを示した<sup>15</sup>。Kritsaneeapaiboon らも、胸部および腹部 X 線 CT 検査において、患者体重と実効直径の間に強い相関 ( $r = 0.943$ ,  $p < 0.001$ ) があることを報告した<sup>13</sup>。本研究の結果と先行研究の知見から、患者体重は実効直径を算出する際の代替パラメータとして有用であり、医用画像から推定した患者体重を利用して SSDE を簡便に計算する手法は実用的であるといえる。

本研究にはいくつかの限界点がある。第一に、提案手法の検証は胸部領域に限定された。しかし、第 3 章で述べたように、深層学習を用いた CT 位置決め画像からの体重推定は、胸部領域だけでなく腹部領域でも可能であった<sup>17</sup>。したがって、推定体重を用いた X 線 CT 検査の被ばく線量管理は、躯幹部全体に適用できる可能性がある。第二に、本研究では単一施設の患者の X 線 CT 画像のみを用いて、提案手法の有用性を検討した。したがって、異なるメーカーの装置を用いて他施設で撮影された X 線 CT 画像に本手法を適用できるかどうかは不明である。しかし、深層学習モデルの学習に必要な医用画像と教師データとなる患者体重が存在すれば、他施設のデータに対しても同様の手法を用いることは容易である。最後に、本研究で用いたデータセットには小児患者が含まれておらず、提案手法の対象は成人患者に限定される。一般に、小児患者の放射線被ばくは成人患者よりも懸念される。既にいくつかの研究では、小児患者を対象として患者サイズごとの DRL 値を設定している<sup>1, 24, 25</sup>。したがって、将来的には小児患者のデータを深層学習モデルの訓練データに含め、小児患者の X 線 CT 検査の被ばく線量管理における提案手法の有用性を検討する必要がある。

## 6.5 結論

本章では、深層学習を用いて胸部 CT 位置決め画像から患者体重を推定し、推定体重が X 線 CT 検査の被ばく線量管理に利用可能かどうかについて評価した。その結果、推定体重は線量指標 ( $CTDI_{vol}/DLP$ ) の比較や体重情報を利用して SSDE の算出方法を簡略化する試みにおいて、実測体重の代替となり得ることが示された。以上より、深層学習を用いた医用画像からの体重推定は、体重が不詳である成人患者の X 線 CT 検査の被ばく線量管理に有用である。

## 6.6 参考文献

- 1 Japan Network for Research and Information on Medical Exposure (J-RIME). National diagnostic reference levels in Japan (2020) -Japan DRLs 2020-. 2020.
- 2 Kanal KM, Butler PF, Sengupta D, Bhargavan-Chatfield M, Coombs LP, Morin RL. U.S. diagnostic reference levels and achievable doses for 10 adult CT examinations. Radiology 2017; 284(1): 120–133.
- 3 Shrimpton, PC, Hillier MC MS and GS. Doses from computed tomography (CT) examinations in the UK – 2011 review. Public Health England Report PHE-CRCE- 013. <https://www.gov.uk/government/publications/doses-from-computed-tomography-ct-examinations-in-the-uk>
- 4 Lee KL, Beveridge T, Sanagou M, Thomas P. Updated Australian diagnostic reference levels for adult CT. J. Med. Radiat. Sci. 2020; 67(1): 5–15.
- 5 Vañó E, Miller DL, Martin CJ, et al. ICRP publication 135: diagnostic reference levels in medical imaging. Ann. ICRP 2017; 46(1): 1–144.
- 6 Moghadam N, Lecomte R, Mercure S, Rehani MM, Nassiri MA. Simplified size adjusted dose reference levels for adult CT examinations: A regional study. Eur. J. Radiol. 2021; 142: 109861.
- 7 American Association of Physicists in Medicine (AAPM). Size- Specific, Size-specific dose estimates (SSDE) in pediatrics and adult body CT examinations: the report of AAPM Task Group.204. 2011.
- 8 American Association of Physicists in Medicine (AAPM). Use of water equivalent

- diameter for calculating patient size and size- specific dose estimates (SSDE) in CT: the report of AAPM Task Group. 220. 2014.
- 9 McCollough CH, Leng S, Yu L, Cody DD, Boone JM, McNitt-Gray MF. CT dose index and patient dose: they are not the same thing. *Radiology* 2011; 259(2): 311–316.
  - 10 Khawaja RDA, Singh S, Vettiyil B, et al. Simplifying size-specific radiation dose estimates in pediatric CT. *AJR. Am. J. Roentgenol.* 2015; 204(1): 167–176.
  - 11 Boos J, Lanzman RS, Heusch P, et al. Does body mass index outperform body weight as a surrogate parameter in the calculation of size-specific dose estimates in adult body CT? *Br. J. Radiol.* 2016; 89(1059): 20150734.
  - 12 O’Neill S, Kavanagh RG, Carey BW, Moore N, Maher M, O’Connor OJ. Using body mass index to estimate individualised patient radiation dose in abdominal computed tomography. *Eur. Radiol. Exp.* 2018; 2(1): 38.
  - 13 Kritsaneepaiboon S, Eng-Chuan S, Yoykaew S. Can patient’s body weight represent body diameter for pediatric size-specific dose estimate in thoracic and abdominal computed tomography? *J. Clin. Imaging Sci.* 2019; 9: 24.
  - 14 Iriuchijima A, Fukushima Y, Nakajima T, Tsushima Y, Ogura A. Simple method of size-specific dose estimates calculation from patient weight on computed tomography. *Radiat. Prot. Dosimetry* 2018; 178(2): 208–212.
  - 15 Fukunaga M, Matsubara K, Ichikawa S, Mitsui H, Yamamoto H, Miyati T. CT dose management of adult patients with unknown body weight using an effective diameter. *Eur. J. Radiol.* 2021; 135: 109483.
  - 16 Li X, Steigerwalt D, Rehani MM. T-shirt size as a classification for body habitus in computed tomography (CT) and development of size-based dose reference levels for different indications. *Eur. J. Radiol.* 2022; 151: 110289.
  - 17 Ichikawa S, Hamada M, Sugimori H. A deep-learning method using computed tomography scout images for estimating patient body weight. *Sci. Rep.* 2021; 11(1): 15627.
  - 18 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint* 2014. <https://arxiv.org/abs/1409.1556>
  - 19 Kingma DP, Ba J. Adam: A method for stochastic optimization. *arXiv preprint* 2015.

<https://arxiv.org/abs/1412.6980>

- 20 Japan Network for Research and Information on Medical Exposure (J-RIME). Diagnostic reference levels based on latest surveys in Japan -Japan DRLs 2015-. 2015.
- 21 Ghafourian K, Younes D, Simprini LA, Weigold WG, Weissman G, Taylor AJ. Scout view X-ray attenuation versus weight-based selection of reduced peak tube voltage in cardiac CT angiography. *JACC. Cardiovasc. Imaging* 2012; 5(6): 589–595.
- 22 Salimi Y, Shiri I, Akhavanallaf A, et al. Deep Learning-based calculation of patient size and attenuation surrogates from localizer Image: Toward personalized chest CT protocol optimization. *Eur. J. Radiol.* 2022; 157: 110602.
- 23 Gascho D, Ganzoni L, Kolly P, et al. A new method for estimating patient body weight using CT dose modulation data. *Eur. Radiol. Exp.* 2017; 1(1): 23.
- 24 Bibbo G, Brown S, Linke R. Diagnostic reference levels of paediatric computed tomography examinations performed at a dedicated Australian paediatric hospital. *J. Med. Imaging Radiat. Oncol.* 2016; 60(4): 475–484.
- 25 Kanal KM, Butler PF, Chatfield MB, et al. U.S. Diagnostic reference levels and achievable doses for 10 pediatric CT examinations. *Radiology* 2022; 302(1): 164–174.

## 第 7 章 総括

本論文は、深層学習を使用して医用画像データから患者体重という新たな情報を引き出し、X 線 CT 検査において正確な患者体重が得られないことにともなう臨床的課題の解決に貢献するものである。X 線 CT 検査において、患者体重は造影剤投与量の算出や被ばく線量管理に活用される重要な指標である。しかしながら、外来や救急を問わず、X 線 CT 検査前に体重が測定されているとは限らず、この課題に対する解決策が多くの医療機関で模索されている。

第 1 章では、X 線 CT 検査における体重情報の重要性に焦点を当て、患者体重が不詳で測定が困難である場合の推定方法に関する先行研究を概説し、本研究の動機を明示した。

第 2 章では、提案手法の根幹となる技術である CNN の基本的な構造や理論について詳細に説明し、本論文で使用した深層学習モデル構造の仕組みを解説した。

第 3 章では、胸部および腹部の CT 位置決め画像を入力とし、患者体重を教師データとして利用して深層学習モデルを構築し、医用画像データから体重情報を推定する可能性を検証した。結果として、胸部および腹部どちらの位置決め画像を入力とした場合においても、MAE が 5 kg 以内となった。特に、腹部 CT 位置決め画像を用いる場合よりも胸部 CT 位置決め画像を用いた場合のほうが、高い推定精度が得られることが判明した。本章により、深層学習を用いることで、診断用 CT スキャンの前に人の手を介在しない形で患者体重を推定できることが示された。

第 4 章では、CT 位置決め画像と胸部単純 X 線写真の類似性および胸部単純 X 線写真が画像診断の中で最も広く普及している検査法であることに着目し、胸部単純 X 線写真を用いて深層学習による患者体重推定手法を検証した。第 3 章での提案手法を胸部単純 X 線写真に応用することにより、躯幹部 X 線 CT 検査のみならず、頭部や四肢の X 線 CT 検査、MRI 検査の SAR 推定などにも推定体重が活用できる可能性をもたらしたといえる。また、体重推定モデルの構築は、性差による X 線減弱特性の違いを考慮し、男女別モデルと男女混合モデルの 2 種類のモデルを作成した。しかし、胸部単純 X 線写真から患者体重を推定するのに際して、性別ごとにモデルを作成する効果は見られなかった。

第 5 章では、躯幹部 CT のさまざまなスライス位置の横断像に対して、患者体重を推定するために従来の断面積を用いた手法と深層学習を用いた手法を適用し、最も精度の高い

スライス位置を探索した。以前から、躯幹部 CT における断面積と患者体重の関係が報告されていたが、手動で測定された断面積の値が用いられ、測定に最適なスライス位置についても未検証であった。断面積を用いたアプローチでは、断面積を自動測定するための画像処理手法を提案し、また、スライス位置として、体組成解析でよく用いられる L3 レベルよりも T5 レベルが適することが示された。一方、深層学習を用いて患者体重を直接推定するアプローチでは、L5 レベルが最も高い精度を示した。深層学習による推定手法の臨床応用には時間を要すると予想され、本章で提示した CT 横断像における断面積を入力とする体重推定用の直線回帰式は、精度の観点から十分に代用できるものであると考えられる。

第 6 章では、深層学習を用いて胸部 CT 位置決め画像から推定した患者体重を胸部 X 線 CT 検査の被ばく線量管理に活用し、実測体重と代替可能かについて検証した。体重群別の線量指標 ( $CTDI_{vol}/DLP$ ) の比較や体重情報を利用した SSDE の算出方法の簡略化において、実測体重を用いた場合と推定体重を用いた場合で同等の結果が得られた。以上より、深層学習を用いて医用画像データから患者体重を推定する試みは、体重が不詳である成人患者の X 線 CT 検査の被ばく線量管理に有用であることが示された。

本論文では、画像診断のために取得された CT 位置決め画像、CT 横断像、単純 X 線写真などの医用画像を副次的に活用し、深層学習を用いて患者体重を高精度に推定可能であることを明らかにした。体重不詳患者における体重推定手法の確立は、特に X 線 CT 検査による被ばく情報の記録を全国規模で活用できる体制を構築する契機となり、わが国の医療被ばくの低減に向けた活動を支援するものである。X 線 CT 検査を受けた患者の線量情報と体重情報を合わせた統計を全国規模で収集することで、現在は標準体型に対してのみ規定されている DRL 値を患者の体格ごとに設定することが可能になる。DRL が体重情報に基づいて細分化されることで、各施設は患者の体格に応じた X 線 CT プロトコルの見直しが必要になり、線量の最適化が促進されることが期待される。しかし、今後の課題として、提案手法を小児患者にも拡張する必要性が挙げられる。一般的に、小児患者の放射線被ばくは成人患者よりも懸念されるため、体重情報に基づいた被ばく線量管理は、より厳格さが求められるものである。将来的には、小児の画像データを収集し、全年齢層にわたって X 線 CT 画像と体重情報が結びつく体制の構築を目指したい。別の課題として、救急医療での実用化を考える際、より即時性を考慮したシステムの実現が求められる。具体的には、救急医療で造影剤投与量を算出する際、PACS に転送された画像を用いて体重推定

する手法では時間を要し，造影検査や治療の遅延が懸念される．そのため，スマートフォンなどのエッジデバイス上で，X 線 CT コンソールに表示された医用画像を直ちに検出し，検出した画像から患者体重を迅速に推定できるシステムの構築を計画している．本研究や今後の発展研究の成果が，臨床現場において体重情報が容易に得られない場合の代替手法の確立や，X 線 CT 検査にともなう医療被ばくの低減，救急医療に関わる医療従事者のワークフロー支援に貢献することを期待する．

# 謝辞

本研究を遂行するにあたり，主たるご指導ならびにご鞭撻を賜った北海道大学大学院保健科学研究所 保健科学部門 医用生体理工学分野 杉森博行 准教授に心から御礼申し上げます．研究に対する有益なご助言をいただいたことに加えて，学部時代から学問や教育への情熱を高め，研究者になるための土台を築いてくださいました北海道大学大学院保健科学研究所 保健科学部門 医用生体理工学分野 神島保 教授に衷心より感謝申し上げます．また，研究に対する貴重な示唆やご助言をいただきました北海道大学大学院保健科学研究所 保健科学部門 健康科学分野 小笠原克彦 教授，北海道大学大学院保健科学研究所 保健科学部門 健康科学分野 吉村高明 助教，北海道大学大学院医学研究所 内科系部門 放射線科学分野 唐明輝 特任助教に深甚なる謝意を表する．最後に，日々の研究の進捗確認やディスカッションを通じて，多くの知識と示唆を頂戴しました，杉森研究室の皆様，倉敷中央病院 放射線技術部の皆様，新潟大学 医学部保健学科放射線技術科学専攻の皆様にも深く感謝する．

# 業績リスト

## 学会誌又は学術雑誌への論文掲載

1. **Ichikawa S**, Sugimori H. Estimating body weight from measurements from different single-slice CT levels: An evaluation of total cross-sectional body area measurements and deep learning. J Comput Assist Tomogr. 2024; in press.
2. Ozaki M, **Ichikawa S**, Fukunaga M, Yamamoto H. Improving the depiction of small intracranial vessels in head computed tomography angiography: A comparative analysis of deep learning reconstruction and hybrid iterative reconstruction. Radiol. Phys. Technol. 2023; Epub ahead of print.
3. Sakaida M, Yoshimura T, Tang M, **Ichikawa S**, Sugimori H. Development of a mammography calcification detection algorithm using deep learning with resolution-preserved image patch division. Algorithms 2023; 16(10): 483.
4. Inomata S, Yoshimura T, Tang M, **Ichikawa S**, Sugimori H. Estimation of left and right ventricular ejection fractions from cine-MRI using 3D-CNN. Sensors 2023; 23(14): 6580.
5. **Ichikawa S**, Itadani H, Sugimori H. Deep learning-based body weight from scout images can be an alternative to actual body weight in CT radiation dose management. J. Appl. Clin. Med. Phys. 2023; 24(8): e14080.
6. Usui K, Yoshimura T, **Ichikawa S**, Sugimori H. Development of chest X-ray image evaluation software using the deep learning techniques. Appl. Sci. 2023; 13(11): 6695.
7. **Ichikawa S**, Sugimori H, Ichijiri K, Yoshimura T, Nagaki A. Acquisition time reduction in pediatric 99mTc-DMSA planar imaging using deep learning. J. Appl. Clin. Med. Phys. 2023; 24(6): e13978.
8. **Ichikawa S**, Itadani H, Sugimori H. Prediction of body weight from chest radiographs using deep learning with a convolutional neural network. Radiol. Phys. Technol. 2023; 16(1): 127–134.
9. **Ichikawa S**, Itadani H, Sugimori H. Toward automatic reformation at the orbitomeatal line in head computed tomography using object detection algorithm. Phys. Eng. Sci. Med. 2022; 45(3): 835–845.

10. **Ichikawa S**, Hamada M, Sugimori H. A deep-learning method using computed tomography scout images for estimating patient body weight. *Sci. Rep.* 2021; 11(1): 15627.
11. **Ichikawa S**, Yamamoto H, Morita T. Comparison of a Bayesian estimation algorithm and singular value decomposition algorithms for 80-detector row CT perfusion in patients with acute ischemic stroke. *Radiol. Med.* 2021; 126(6): 795–803.
12. **Ichikawa S**, Hamada M, Watanabe D, Ito O, Moriya T, Yamamoto H. Optimal slice thickness of brain computed tomography using a hybrid iterative reconstruction algorithm for identifying hyperdense middle cerebral artery sign of acute ischemic stroke. *Emerg. Radiol.* 2021; 28(2): 309–315.
13. Fukunaga M, Matsubara K, **Ichikawa S**, Mitsui H, Yamamoto H, Miyati T. CT dose management of adult patients with unknown body weight using an effective diameter. *Eur. J. Radiol.* 2021; 135: 109483.
14. **Ichikawa S**, Yamamoto H, Ito O, Fukunaga M. Pulmonary artery/vein separation using single-phase computed tomography: feasibility and the influence of patient characteristics on vessel enhancement. *J. Thorac. Imaging* 2020; 35(3): 173–178.
15. 福永正明, 松原孝祐, 竹井泰孝, 光井英樹, 亀井山弘晃, 田中孝尚, **市川翔太**. 移動型整形外科用イメージング装置を用いた腰椎後方固定術時における室内散乱線量分布の測定. *日本放射線技術学会雑誌* 2020; 76(6): 572–578.
16. Kato K, Yasojima N, Tamura K, **Ichikawa S**, Sutherland K, Kato M, Fukae J, Tanimura K, Tanaka Y, Okino T, Lu Y, Kamishima T. Detection of fine radiographic progression in finger joint space narrowing beyond human eyes: phantom experiment and clinical study with rheumatoid arthritis patients. *Sci Rep.* 2019; 9(1): 8526.
17. Kobayashi Y, Kamishima T, Sugimori H, **Ichikawa S**, Noguchi A, Kono M, Iiyama T, Sutherland K, Atsumi T. Quantification of hand synovitis in rheumatoid arthritis: Arterial mask subtraction reinforced with mutual information can improve accuracy of pixel-by-pixel time-intensity curve shape analysis in dynamic MRI. *J. Magn. Reson. Imaging* 2018; 48(3): 687–694.
18. Okino T, Kamishima T, Sutherland K, Fukae J, Narita A, **Ichikawa S**, Tanimura K. Radiographic temporal subtraction analysis can detect finger joint space narrowing progression in rheumatoid arthritis with clinical low disease activity. *Acta Radiol.* 2018;

59(4): 460–467.

19. Kato K, Kamishima T, Kondo E, Onodera T, **Ichikawa S**. Quantitative knee cartilage measurement at MR imaging of patients with anterior cruciate ligament tear. Radiol. Phys. Technol. 2017; 10(4): 431–438.
20. **Ichikawa S**, Kamishima T, Sutherland K, Fukae J, Katayama K, Aoki Y, Okubo T, Okino T, Kaneda T, Takagi S, Tanimura K. Computer-based radiographic quantification of joint space narrowing progression using sequential hand radiographs: validation study in rheumatoid arthritis patients from multiple institutions. J. Digit. Imaging 2017; 30(5): 648–656.
21. Fujimori M, Nakamura S, Hasegawa K, Ikeno K, **Ichikawa S**, Sutherland K, Kamishima T. Cartilage quantification using contrast-enhanced MRI in the wrist of rheumatoid arthritis: cartilage loss is associated with bone marrow edema. Br. J. Radiol. 2017; 90(1077): 20170167.
22. **Ichikawa S**, Kamishima T, Sutherland K, Kasahara H, Shimizu Y, Fujimori M, Yasojima N, Ono Y, Kaneda T, Koike T. Semi-automated quantification of finger joint space narrowing using tomosynthesis in patients with rheumatoid arthritis. J. Digit. Imaging 2017; 30(3): 369–375.
23. Hatano K, Kamishima T, Sutherland K, Kato M, Nakagawa I, **Ichikawa S**, Kawauchi K, Saitou S, Mukai M. A reliability study using computer-based analysis of finger joint space narrowing in rheumatoid arthritis patients. Rheumatol. Int. 2017; 37(2): 189–195.
24. **Ichikawa S**, Kamishima T, Sutherland K, Okubo T, Katayama K. Radiographic quantifications of joint space narrowing progression by computer-based approach using temporal subtraction in rheumatoid wrist. Br. J. Radiol. 2016; 89(1057): 20150403.
25. **Ichikawa S**, Kamishima T, Sutherland K, Okubo T, Katayama K. Performance of computer-based analysis using temporal subtraction to assess joint space narrowing progression in rheumatoid patients. Rheumatol. Int. 2016; 36(1): 101–108.

#### 学会発表

1. 境田みう, 吉村高明, 唐明輝, **市川翔太**, 杉森博行. マンモグラフィにおける石灰化識別のための半教師あり学習の適用と評価. 日本放射線技術学会北海道支部学術大会第 79 回秋季大会, 札幌, 2023.11.

2. 猪股壮一郎, 吉村高明, 唐明輝, 市川翔太, 杉森博行. 造影心臓 CT 画像を用いた深層学習による大動脈弁自動抽出法の検討. 日本放射線技術学会北海道支部学術大会第 79 回秋季大会, 札幌, 2023.11.
3. 猪股壮一郎, 吉村高明, 唐明輝, 市川翔太, 杉森博行. 深層学習によるセグメンテーションを用いた造影心臓 CT 画像から大動脈弁自動推定法の検討. 第 51 回日本放射線技術学会秋季学術大会, 名古屋, 2023.10.
4. Inomata S, Yoshimura T, Tang M, Ichikawa S, Sugimori H. Estimation of left and right ventricular ejection fraction from cine-MRI using 3D-CNN. The 6th FHS International Conference, Sapporo, 2023.10.
5. 市川翔太, 尾崎誠, 杉森博行, 近藤世範. 頭部 CT-Perfusion における深層学習を用いたトランケーションアーチファクト補正. 医用画像情報学会 197 回大会, 札幌, 2022.10.
6. Ichikawa S, Sugimori H, Ichijiri K, Yoshimura T, Nagaki A. Reducing acquisition time in pediatric 99mTc-DMSA planar imaging using deep learning. European Congress of Radiology 2023, Vienna Austria, 2023.3.
7. Ichikawa S, Itadani H, Sugimori H. Deep learning-based body weight from chest CT radiographs serves as a size metric in CT dose management. The 22nd International Society of Radiographers and Radiological Technologists (ISRRT) World Congress, Bangkok Thailand, 2022.12.
8. 市川翔太, 杉森博行, 市尻航輝, 吉村高明, 長木昭男. 小児核医学検査における腎静態シンチグラフィの深層学習を用いた短時間収集での画質改善. 第 1 回北海道大学医療 AI シンポジウム, 札幌, 2022.11.
9. 尾崎誠, 市川翔太, 福永正明, 守屋隆史, 伊藤修, 山本浩之. 頭部 CT Angiography における Deep learning 画像再構成法を用いた血管描出能の評価. 第 50 回日本放射線技術学会秋季学術大会, 東京, 2022.10.
10. 杉原智洋, 福永正明, 山本浩之, 伊藤修, 市川翔太, 山口雄貴. Deep Learning Reconstruction を用いた頭部単純 CT 撮影の物理特性評価. 第 18 回中四国医療技術フォーラム, 松山, 2022.10.
11. 市川翔太, 山本浩之, 板谷英樹, 杉森博行. 頭部単純 CT 撮影における物体検出技術を用いた多段面再構成画像の自動生成. 第 78 回日本放射線技術学会総会学術大会, 横浜, 2022.4.

12. 市川翔太, 山本浩之, 杉森博行. 畳み込みニューラルネットワークを用いた胸部 CT スカウト画像からの性別・体格推定. 第 17 回中四国医療技術フォーラム, online, 2021.12.
13. Ichikawa S, Yamamoto H. Usefulness of Bayesian estimation algorithm for simulated low-dose cerebral computed tomography perfusion in patients with acute ischemic stroke. European Congress of Radiology 2020, online, 2020.7.
14. Ichikawa S, Matoba S, Ogasahara T, Nakagawa K. Repeatability and feasibility of amide proton transfer imaging of brain. 第 76 回日本放射線技術学会総会学術大会, online, 2020.5-6.
15. Ichikawa S, Yamamoto H. Impact of image noise on quantitative perfusion analysis using simulated low-dose CT in patients with acute ischemic stroke. 第 76 回日本放射線技術学会総会学術大会, online, 2020.5-6.
16. 市尻航輝, 福永正明, 市川翔太, 宮田潤也. 小児胸部 X 線撮影における金属付加フィルタによる線量低減. 第 15 回中四国放射線医療技術フォーラム, 高知, 2019.9.
17. 山口雄貴, 福永正明, 市川翔太, 山本浩之, 長木昭男, 光井英樹. 2 つの線量計算ソフトウェアにおける CT 線量指標および臓器線量の比較. 第 15 回中四国放射線医療技術フォーラム, 高知, 2019.9.
18. 市川翔太, 山本浩之. 肺癌術前患者における 3D-CT による肺容積測定ソフトウェアの比較. 第 35 回日本診療放射線技師学術大会, 大宮, 2019.9.
19. 日村栞菜, 市川翔太, 山本浩之, 渡辺大輝, 熊代正行. 当院における CT 読影補助の現状分析と異常所見学習ツールの作成. 第 35 回日本診療放射線技師学術大会, 大宮, 2019.9.
20. 福永正明, 松原孝祐, 光井英樹, 亀井山弘晃, 市川翔太, 竹井 泰孝. 移動型脊椎外科用イメージングにおける室内散乱線分布の測定. 第 75 回日本放射線技術学会総会学術大会, 横浜, 2019.4.
21. Ichikawa S, Yamamoto H, Ito O, Fukunaga M. Effect of patient characteristics at 3D-CT for pulmonary artery/vein separation. 第 75 回日本放射線技術学会総会学術大会, 横浜, 2019.4.
22. 市川翔太, 山本浩之. 頭部 CT Perfusion における自作ソフトウェアを用いた体動補正処理の臨床的有用性. 第 34 回日本診療放射線技師学術大会, 下関, 2018.9.
23. Ichikawa S, Yamamoto H, Fukunaga M. Infarct core estimation according to cerebral blood flow using CT perfusion in acute stroke patients. 第 74 回日本放射線技術学会総会学術大

- 会, 横浜, 2018.4.
24. 宋戸駿, 神島保, 加藤一樹, 市川翔太, 近藤英司, 小野寺智洋. Assessment of knee cartilage volume using an original software for conventional MRI. 第 45 回日本放射線技術学会秋季学術大会, 広島, 2017.10.
  25. 田中悠貴, 千葉拓貴, 神島保, 市川翔太, 沖野太一, 深江淳, 青木悠子, 谷村一秀. Quantitative assessment of joint space narrowing progression in the feet of rheumatoid arthritis patients using a computer-based temporal subtraction method. 第 45 回日本放射線技術学会秋季学術大会, 広島, 2017.10.
  26. Kobayashi Y, Kamishima T, Sakashita T, Sugimori H, Ichikawa S, Noguchi A, Kono M, Iiyama T, Atsumi T. Simplified approach to quantification for hand synovitis in rheumatoid arthritis using dynamic contrast enhanced MRI: pixel-by-pixel time intensity curve shape analysis. ISMRM 25th Annual Meeting & Exhibition, Honolulu, 2017.4.
  27. Ichikawa S, Kamishima T, Sutherland K, Okubo T, Katayama K. Reliability of computer-based roentgenographic approach for assessing joint space narrowing progression in rheumatoid arthritis wrist. 第 72 回日本放射線技術学会総会学術大会, 横浜, 2016.4.
  28. Ichikawa S, Kamishima T, Sutherland K, Okubo T, Katayama K. Computer-based temporal subtraction analysis of joint space narrowing in rheumatoid patients: validation study in carpal joints. The Radiological Society of North America 2015, Chicago USA, 2015.12.
  29. 市川翔太, 神島保, Sutherland Kenneth, 大久保学宣, 片山耕. 単純 X 線写真における経時差分技術を用いた関節裂隙狭小化定量評価－関節リウマチ罹患関節における検証. 医用画像情報学会 173 回大会, 札幌, 2015.10.
  30. Ichikawa S, Kamishima T, Sutherland K, Okubo T, Katayama K. The usefulness of computer-based method using temporal subtraction to assess joint space narrowing progression in rheumatoid patients. The 2nd FHS International Conference, Sapporo, 2015.7.
  31. Ichikawa S, Kamishima T, Sutherland K, Okubo T, Katayama K. Computer-based analysis of joint space narrowing using temporal subtraction in rheumatoid patients: validation study in carpal joints. 第 71 回日本放射線技術学会総会学術大会, 横浜, 2015.4.
  32. 市川翔太, 神島保, 佐々木亮祐, Sutherland Kenneth, 大久保学宣, 片山耕. 単純 X 線写真に対する経時差分技術を用いたリウマチ患者の関節裂隙狭小化評価－手根部関節への応用. 第 42 回日本放射線技術学会秋季学術大会, 札幌, 2014.10.

33. 佐々木亮祐, 神島保, 市川翔太, Sutherland Kenneth, 大久保学宣, 片山耕. 単純 X 線写真におけるリウマチ患者の関節裂隙狭小化の変化—経時差分技術を用いた検討. 第 42 回日本放射線技術学会秋季学術大会, 札幌, 2014.10.

#### その他（研究助成）

1. 深層学習を用いた医用画像データからの体格指標予測法の開発. 公益財団法人大原記念倉敷中央医療機構 臨床医学研究所 2022 年 4 月.
2. 人工知能画像解析による救急医療を想定した患者体重即時推定システムの構築. 日本学術振興会 科学研究費助成事業 研究活動スタート支援 2023 年 8 月–2025 年 3 月.