

椎体の形状変化に着目した単純 X 線画像による 骨粗鬆症性椎体骨折検出手法の検討

今村文香¹吉野孝¹寺口真年²¹ 和歌山大学システム工学部² 和歌山県立医科大学 整形外科

1 はじめに

骨粗鬆症による椎体骨折 (OVF) は、進行すると難治性の腰痛を引き起こすため、受傷後早期の新鮮 OVF の段階で治療介入が必要である。しかし、初期診断に用いられる一般的な X 線検査は安価で手軽な一方、CT や MRI と比較して精度が劣るため、骨折の見逃しが課題となっている。

また、新鮮 OVF の診断においては、患者の体位によって椎骨の形状が変化するという特徴がある。たとえば、立位と臥位で椎体の状態を比較し、立位で圧潰が確認されれば新鮮 OVF と判定する診断方法もある。

森川らは、診療現場での X 線画像読影の支援を目的として、U-Net を用いた新鮮 OVF の検出手法を検討した [1]。具体的には、医用画像に対して有用な複数の前処理手法を実装し、同じ椎骨同士の面積を比較することで分類を行った。結果として、一定の有用性がみられたものの、新鮮 OVF の分類精度には向上の余地があることが示された。

そこで本研究では、CNN の転移学習を利用して椎骨の検出精度を向上させるとともに、新たな特徴量を導入することで分類精度の向上を目指す。

2 関連研究

Yabu らは、磁気共鳴 (MR) 画像で新鮮 OVF を検出するために、9 種類の CNN を組み合わせたアンサンブル法を使用して最適モデルを構築した [2]。新鮮 OVF の患者 814 人が含まれており、新鮮 OVF 及び陳旧性 OVF を含む T1 強調 MR 画像 1624 スライスが使用された。CNN による診断と 2 人の脊椎外科医による診断の感度、特異度、精度が比較され、結果として、MR 画像からの新鮮 OVF の検出における CNN の成果は、2 人の脊椎外科医の成果に匹敵した。

本研究では、X 線画像を用いて、新鮮 OVF の形状変化を利用した分類手法を検討する。

3 手法

3.1 本手法の流れ

本手法は大きく二つの段階に分かれている。まず、機械学習を用いて、X 線画像から椎骨を骨折の有無にかかわらず全て検出する。次に、異なる体位のペア画像を、分類器にて新鮮 OVF 及びその他の椎骨を分類することで、段階的に新鮮 OVF を判定する。

3.1.1 検出

転移学習には、特徴抽出器としての利用とファインチューニングの 2 種類存在する。本研究では、ImageNet で訓練されたモデルの重みを初期値として、モデル全体を新しいタスクに適合させるファインチューニングを行う。

A Method for Detecting Osteoporotic Vertebral Fractures using Simple X-ray Images focusing on Vertebral Body Shape Changes
Ayaka Imamura¹ Takashi Yoshino¹ Masatoshi Teraguchi²
¹ Faculty of Systems Engineering, Wakayama University
² Department of Orthopaedic Surgery, Wakayama Medical University

3.1.2 分類

分類器では、XGBoost による学習を行う¹⁾。一つ抜き交差検証を 100 個の異なるシードで行い、平均値を評価することで、検証の信頼性を向上させている。

3.2 使用データ概要

本研究で使用するデータは、2017 年 8 月から 2020 年 10 月の期間に、和歌山県立医科大学附属病院紀北分院で脊椎疾患患者 71 人から撮影された 186 枚の単純 X 線画像であり、胸腰椎を撮影した側面像である。これらは、12bit の DICOM 形式の画像で保存されているため、8bit の JPEG 形式に変換し使用する。また形式変換の際に階調処理を行い、画素値の幅を 0 から 255 に変換する。また、画像内における疾患箇所特定は、専門医により診断された結果を使用する。訓練・テストデータの利用率を、Train : Test = 95 : 5 とした。本研究は和歌山県立医科大学の倫理委員会の承認を得て行っている。

3.3 正解データ

本研究では、MIT が開発した画像アノテーションツール LabelMe [3] を用いて、X 線画像に手動でセグメンテーションを行い、正解データを作成する。出力データは JSON 形式の座標データとして保存されるため、PNG 形式のマスク画像に変換して使用する。作成した正解画像は、専門医師 1 名によって、椎骨の手動セグメンテーションを正確に実施できていることを確認済みである。

3.4 画像の前処理

前処理にはアンシャープマスク法を用いた。これは、CR 装置などで画像の鮮鋭度を強調する手法として一般に利用されている。

アンシャープマスク法は、画像内のオブジェクトのエッジのコントラストを強化する手法であり、画像を平滑化し、元の画像との差分像を作成することで、画像の鮮鋭成分を抽出する。その差分像を原画像に加算することにより、画像の鮮鋭化を行う。

3.5 使用する CNN モデル

本研究では、DeepLabv3+[4] を用いて椎骨のセグメンテーションを行った。

DeepLabv3+は、画像の高次特徴を抽出するエンコーダと、空間的な詳細を復元するデコーダの構造を持つ深層学習モデルで、輪郭が不明瞭な領域や小さな構造を高精度にセグメンテーションできる。バックボーンには ResNet101 を使用している。

3.6 新鮮 OVF の分類

作成した正解画像をもとに新鮮 OVF 分類器を実装した。以下に分類手順を示す。

- (1) 作成した正解画像のうち、異なる体位のペアが存在しない画像を除去する。残った 170 枚の画像を対象とし、ペア画像をそれぞれ体位 1、体位 2 とする。
- (2) ペア画像中の対応する椎骨について、新鮮 OVF とそれ以外に分類する。そのとき、ペアになっている骨のみを分類対象とする。

¹⁾ Naive Bayes, Logistic Regression, Random Forest Classifier などを試したが、XGboost での精度が最も高かった。




図 1: DeepLabv3+における椎骨の予測画像
(左: 正解画像, 右: 予測画像)

- (3) 機械学習用の特徴量を作成し、ペアの骨を比較することで分類する。特徴量には、骨の面積や円形度、Hu モーメント、Zernike モーメントなど、計 101 個を導入した。

3.7 精度評価

本研究で転移学習を行った CNN モデルは、正解率、適合率、再現率、meanIoU(mean Intersection over Union) を用いて評価を行った。TP 値、FN 値、FP 値、TN 値はそれぞれの骨に対して評価を行い算出している。meanIoU とは、IoU のクラス平均の値であり、ここでの IoU とは、正解データとモデルによる予測結果のオーバーラップ率を表している。meanIoU は物体検出の分野において広く利用されている評価指標であり、本研究でも特に meanIoU を重視して評価を行う。

表 1: 平均混同行列

予測値 \ 正解値	新鮮骨折	それ以外
新鮮骨折	68.6%	31.4%
それ以外	2.8%	97.2%

4 結果と考察

4.1 椎骨検出の評価結果

表 2 に DeepLabv3+ の評価結果を示す。森川ら [1] の meanIoU の 87.9% に対し、同等の精度となった。

4.2 椎骨の予測画像

DeepLabv3+ における椎骨の予測画像を図 1 に示す。全体として、椎骨の位置および形状をある程度正確に検出できているように見える。しかし、図 1 の右下の画像のように形状が崩れ、椎骨の見逃しが起こっているものも見られた。原因としては、椎骨の手前に骨盤が重なっており、前処理を施しても境界が不明瞭なままであることが考えられる。

4.3 新鮮 OVF の分類結果

森川ら [1] が CNN の予測画像を用いて分類した結果は正解率 39.0% と低い精度となり、予測画像の精度の不足が原因であった。そこで、本研究では、分類器自体の性能を評価するため、まずセグメンテーションが完全な (精度 100%) の正解画像を用いて分類を行った。

表 1 に分類した結果の平均混同行列を示す。新鮮骨折の見逃しは目立つが、それ以外の骨を分類する能力は高い。

表 3 に重要度の高い特徴量の上位 10 項目を示す。Hu モーメント [5] とは画像の平行移動、拡大縮小、回転に不変な 7 つの特徴量であり、画像の類似度を測るのに用いられる。Zernike モーメント [6] とは円領域内について計算することで、より細かい違いを捉えられ、回転に対して不変である。本研究では、骨の輪郭の外接円を取得

表 2: 椎骨検出の評価結果

Accuracy	98.3%
Precision	85.6%
Recall	91.3%
meanIoU	86.7%

表 3: 重要度の高い特徴量 (上位 10 項目)

特徴量	重要度
体位 1 の Zernike モーメントの 4 番目の値	0.0955
体位 1 の Hu モーメントの 4 番目の値	0.0897
体位 1 の Hu モーメントの 3 番目の値	0.0876
体位 1 の Hu モーメントの 1 番目の値	0.0516
体位 2 の Zernike モーメントの 4 番目の値	0.0451
体位 2 の Hu モーメントの 3 番目の値	0.0415
体位 2 の Hu モーメントの 4 番目の値	0.0370
体位 2 の重心の y 座標	0.0224
体位 1 の重心の y 座標	0.0215
体位 1 の Zernike モーメントの 5 番目の値	0.0210

し、その円領域内について計算することで、平行移動と拡大縮小にも不変となるようにした。重心の x, y 座標は骨の厚みで正規化している。このように、画像の幾何学的変換に依存しない特徴量を導入したことで、分類精度が高くなったと考えられる。

5 おわりに

本研究では、CNN の転移学習を利用することで、先行研究と同等の検出精度を実現し、新しい特徴量を導入することで、新鮮 OVF の分類精度を大きく向上させることができた。

今後は、学習方法を更に検討し、より正確な椎骨のセグメンテーション結果の出力を目指す。また、偽陰性を減らす分類手法も検討する。

参考文献

- [1] 森川大翔, 吉野孝, 寺口真年: 骨粗鬆症性椎体骨折の形状特性に着目した CNN による疾患椎体の検出手法の検討, 研究報告コラボレーションとネットワークサービス (CN), Vol.2025-CN-124, pp.1-7(2025).
- [2] Yabu, et Al: Using artificial intelligence to diagnose fresh osteoporotic vertebral fractures on magnetic resonance images, The Spine Journal, 21(10), pp. 1652-1658 (2021).
- [3] Bryan C. Russell, Antonio Torralba, Kevin P. Murphy, William T. Freeman: LabelMe: a database and webbased tool for image annotation, International journal of computer vision, Vol.77.1, pp. 157-173 (2008).
- [4] Chen LC, Zhu Y, Papandreou G, Schroff F, Adam H.: Encoder-decoder with atrous separable convolution for semantic image segmentation, Proc. Eur. Conf. Comput. Vis., Vol.11211, pp. 833-851 (2018).
- [5] M.-K. Hu: Visual pattern recognition by moment invariants, IRE Transactions on Information Theory, 8, pp.179-187 (1962).
- [6] M.R. Teague: Image Analysis via the General Theory of Moments, J. Opt. Soc. Amer., 70, 8, pp.920-930 (1980).