

# Deep learning を用いた 3D-MRI 上での壊死領域セグメンテーション

高嶋 和磨、安藤 渉、菅野 伸彦

(大阪大学大学院医学系研究科 運動器医工学治療学)

濱田 英敏、高尾 正樹

(大阪大学大学院医学系研究科 器官制御外科学)

松岡 拓未、日朝 祐太、Soufi Mazen、大竹 義人、佐藤 嘉伸

(奈良先端科学技術大学院大学 情報科学研究科)

我々は、特発性大腿骨頭壊死症患者の 3D-MRI を用いて、人工知能による壊死領域のセグメンテーションを試み、臨床応用への導入を目指している。Preliminary な結果であるが、これまでの成果について報告する。

## 1. 研究目的

近年、医療ビッグデータベースの重要性や、医用画像領域における Deep learning を活用した人工知能の発展が注目されている<sup>1-3)</sup>。本研究の目的は、特発性大腿骨頭壊死症(ONFH)患者の 3D-MRI を用いて、人工知能による壊死領域のセグメンテーションを試みることである。

## 2. 研究方法

骨頭圧潰を認めない班会議分類<sup>4)</sup>stage 1 または 2 と判定した、28 関節を対象とした。2 mm スライス厚 spoiled gradient-echo sequence 法で撮像した 1 mm スライス間隔 3D-MRI を用いて、班会議分類 type 及び Steinberg 分類<sup>5)</sup>grade を評価した。

28 関節の内、無作為に抽出した 10 関節の壊死領域マニュアルトレース画像を ground truth として、人工知能(convolution neural network, CNN)に学習させ、学習データを用いて、28 関節の 3D-MRI から壊死領域をセグメンテーションした。セグメンテーションの手法としては、第一に正規化した画像データより、骨盤及び壊死領域を含む大腿骨全体のセグメンテーションを行い、次いで、抽出した大腿骨全体より、壊死領域と健全領域のセグメンテーションを行った(図 1)。

マニュアルトレースとセグメンテーション結果の壊死部体積と Steinberg 分類 grade の合致率、平均表面間距離誤差(average symmetric surface distance, ASD) 及び DICE 係数を評価した。

班会議分類 type は A が 10 関節、B が 6 関節、C1 が 10 関節、C2 が 2 関節であった。Steinberg 分類 grade は A が 15 関節、B が 11 関節、C が 2 関節であった。マニュアルトレースとセグメンテーションより算出した壊死部体積の差は、1 関節で大きく外れ値(50%以上)を認めたものの、平均値 4%、中間値 2%で、25/28 関節(89%)で Steinberg 分類 grade が合致した(図 2)。班会議分類 type 別に評価した ASD は、骨盤、大腿骨ともに平均 1 mm 以下であり、壊死領域では、type C1/C2 は 1 mm 以下であった(図 3)。同様に DICE 係数は、大腿骨、骨盤ともに平均 0.9 で、壊死領域では、type A/B は 0.7 前後、C1/C2 では 0.8 以上であった(図 4)。代表例を図 5 に示す。




図 1 CNN を用いたセグメンテーション手法

## 3. 研究結果




図2 壊死部体積と Steinberg 分類 grade の差




図3 平均表面間距離誤差

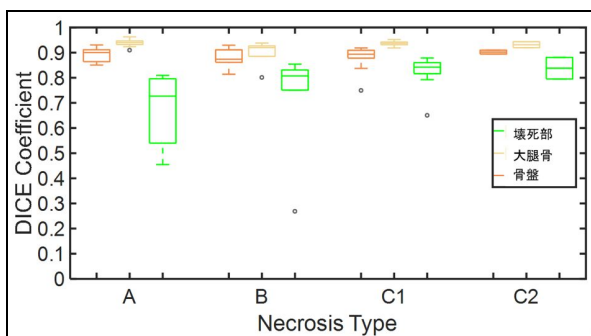


図4 DICE 係数




図5 代表症例

#### 4. 考察

特発性大腿骨頭壊死症患者の3D-MRIを用いて、人工知能による壊死領域のセグメンテーションを試み、マニュアルトレースとの比較では、Steinberg 分類 grade は89%で合致し、ASDは平均約1mm、DICE 係数は0.8程度であり、良好な結果であった。ONFHの予後予測や治療法の決定には、壊死領域の大きさと局在が重要であり、壊死部体積評価は詳細な予後予測が可能との報告があるが、測定には労力を要し、検者内・検者間誤差も危惧される<sup>6)</sup>。CNNを用いることで、簡便かつ再現性に優れた評価が可能である。一方で、図6に示すように、骨頭内信号変化を壊死領域としてセグメンテーションしてしまう場合や、図7に示すように、前方に大きく広がる壊死領域を有する際に、セグメンテーションが不確実になるケースがあった。今後の展望として、班会議分類への応用とともに、上記課題の克服を目指したい。




図6 平均表面間距離誤差が大きい症例

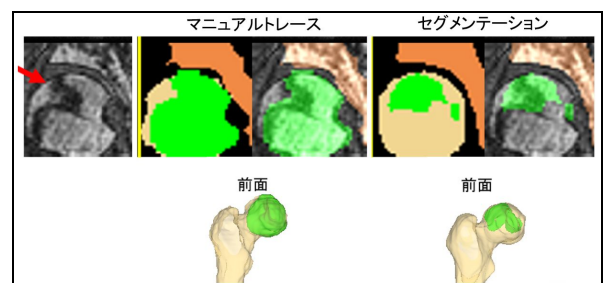


図7 セグメンテーションが不確実であった症例

## 5. 結論

CNNを用いた壊死領域のセグメンテーションを行い、Type C1/C2ではASDが1mm以下、DICE係数は0.8以上であり、高精度に壊死領域のセグメンテーションが可能であった。

## 6. 研究発表

1. 論文発表  
なし
2. 学会発表  
なし

## 7. 知的所有権の取得状況

1. 特許の取得  
なし。
2. 実用新案登録  
なし
3. その他  
なし

## 8. 参考文献

- 1) Cabitza F, Locoro A, Banfi G. Machine Learning in Orthopedics: A Literature Review. *Front Bioeng Biotechnol.* 2018;6:75.
- 2) Jones LD, Golan D, Hanna SA, Ramachandran M. Artificial intelligence, machine learning and the evolution of healthcare: A bright future or cause for concern? *Bone Joint Res.* 2018;7(3):223-225.
- 3) Bini SA. Artificial Intelligence, Machine Learning, Deep Learning, and Cognitive Computing: What Do These Terms Mean and How Will They Impact Health Care? *J Arthroplasty.* 2018;33(8):2358-2361.
- 4) Sugano N, Atsumi T, Ohzono K, Kubo T, Hotokebuchi T, Takaoka K. The 2001 revised criteria for diagnosis, classification, and staging of idiopathic osteonecrosis of the femoral head. *J Orthop Sci.* 2002;7:601-605.
- 5) Steinberg ME, Brighton CT, Steinberg DR, Too SE, Hayken GD. Treatment of avascular necrosis of the femoral head by a combination of grafting, decompression and electrical stimulation. *Clin Orthop Relat Res.* 1984;(186):137-153.

- 6) Takashima K, Sakai T, Hamada H, Takao M, Sugano N. Which classification system is most useful for classifying osteonecrosis of the femoral head? *Clin Orthop Relat Res.* 2018; 476(6): 1240-49.