

骨の生体計算モデル構築のための イメージセグメンテーション手法の開発

小野 景子[†] 川北 陽唯人[‡] 田原 大輔[§]
 龍谷大学理工学部[†] 龍谷大学理工学部[‡] 龍谷大学理工学部[§]

1 はじめに

X線画像やMRI画像に代表される医療画像から臓器や骨、腫瘍などを自動的に抽出する技術開発に近年、ますます注目が集まっており、深層学習の登場によりその開発スピードが加速している [2]。本研究で注目する骨のセグメンテーション（画像の各ピクセルを対応する物体にラベリングする技術）はROIなどの画像特徴量により注目する骨領域の境界を抽出する手法 [3] や、比較的抽出が簡単な大腿骨を既存のソフトウェアを用いて抽出する手法 [1] などが提案されているが、骨の応力解析に必要な骨のモデリングに利用可能な緻密な骨の自動セグメンテーション技術は完成していない。深層学習を用いた手法も提案されているが、対象問題ごとの膨大な学習画像を用意する必要があり、普及には至っていない。そこで本研究では数理最適化手法を用い、学習画像の作成を半自動にすることで大幅に作業負荷を軽減する手法を提案し、U-net を用いて背骨など複雑な形状を有する部位の精密なセグメンテーションを実現する。

2 提案手法

2.1 Ground Truth(GT) の作成

本研究は、DICOM形式のX線画像に対し、図1に示すように解析ソフトにより得られた

色ごとに分けられた背骨の概形より、各部位の抽出を目的とする。背骨は複数の骨から成り、




図1 サンプル画像の例

一つのX線画像 I には最大3種類の椎体が断面に現れる、また、骨の概形の境界に重なりがあることが多いため、画像ピクセルの隣接関係を用いて図2に示すような学習画像を生成することができない。また、緻密なGTが必要であるためハフ変換などの近似手法は適さない。そこで、本研究では画像 I に含まれるピクセル




図2 サンプル画像(左)の提案法により求めたGT

ル $p_k \in I, k = 1, \dots, K$ に対し次のアルゴリズムを用いて学習データを生成する。 p_k はRGB情報と画像の位置情報を持っており、 p_k はRGB情報を、 $p_k(x, y)$ は位置情報を表す。画像 I はX線画像のRGB値と骨の概形の M 種類のマーカーのRGB値 (c_1, \dots, c_M) から成る。

2.2 Unet の構造

本研究で用いるネットワーク構造を図3に示す。断面での骨は最大3つの部位に分かれ、骨以外の背景を含む4つのラベルを推定するため、出力が3になる。

Image Segmentation for Biomechanical Modeling of Bone

[†] Keiko Ono, Ryukoku University

[‡] Bito Kawakita, Ryukoku University

[§] Daisuke Tawara, Ryukoku University

Algorithm 1 Generate Ground Truth

```

n ← 1
Cm = ∅, m = 1, ..., M
while n ≤ N
  if pk is cm
    Add pi = pi(x, y) ∈ Cm
    n = n + 1
min. ∑i∈Cm ∑j∈Cm dijxij, dij = |pi - pj|
s.t. ∑j=1|Cm| xij = 1 (∀i ∈ Cm),
     ∑i=1|Cm| xij = 1 (∀j ∈ Cm),
     ∑i∈S ∑j∈Cm\S xij ≥ 1 (∀S ⊂ Cm, S ≠ ∅),
     xij ∈ {0, 1} (∀i, j ∈ Cm).
    
```

Draw countours by the optimized C_m and Fill by using cv::fillPoly




図3 U-net の構造

3 性能評価

評価は一般に背景を含めた Dice 係数を用いることが多いが、背景部分が多いため (図2 参照), 本研究は背景を含めた Dice 係数 (*Dice_a*) と骨のみの Dice 係数 (*Dice_b*) で評価する. ここで, C₀ は背景ピクセルを, * は U-net の学習で得た集合. I は学習画像の画素集合を表す.

$$Dice.b = \frac{2 * \sum_{k=1}^3 |C_k \cap C_k^*|}{|(I \setminus C_0) \cup C_1 \cup C_2 \cup C_3|}$$

医療機関から提供された DICOM データから作成した 512*512 の RGB 画像をテスト画像を 15 枚とし, 学習画像を表1のように変化させた場合のテスト画像の推定精度を表1に示す. この結果, *Dice_a* は画像を削減した場合においても 9 割以上の精度を得ており, また, *Dice_b* は 200 枚程度の画像を用いた場合, 性能が高いことが確認できた.

表1 推定精度

教師画像数	<i>Dice_a</i>	<i>Dice_b</i>
376	0.996	0.813
188	0.996	0.943
126	0.988	0.411

4 まとめ

本研究では, 形状が複雑である背骨の緻密なセグメンテーションを実現するため, GT 画像を半自動で生成し, U-net により骨の部位を推定する手法を提案した. Dice 係数の結果より, 緻密な推定が可能であるといえる.

謝辞

本研究は JSPS 科研費 JP19H02032 の助成を受けたものです.

参考文献

- [1] Patient-specific finite element computer models improve fracture risk assessments in cancer patients with femoral bone metastases compared to clinical guidelines. *Bone*, Vol. 130, p. 115101, 2020.
- [2] Mohammad Hesam Hesamian, Wenjing Jia, Xiangjian He, and Paul Kennedy. Deep learning techniques for medical image segmentation: Achievements and challenges. *Journal of digital imaging*, pp. 1–15, 2019.
- [3] André Klein, Jan Warszawski, Jens Hillengaß, and Klaus H Maier-Hein. Automatic bone segmentation in whole-body ct images. *International journal of computer assisted radiology and surgery*, Vol. 14, No. 1, pp. 21–29, 2019.