

Fully Convolutional Network による整形外科手術の診断技術獲得

関村 匠斗¹ 加藤 徹¹ 高橋 弘毅¹ 土井 章男¹ 馬渡 太郎² 一戸 貞文³¹ 岩手県立大学ソフトウェア情報学部² 浜の町病院整形外科³ 岩手医科大学付属花巻温泉病院整形外科

1. はじめに

急激な高齢化により、骨粗鬆症による骨折や擦り減りによる変形性関節症等の発生病数が増加している。治療には、主に骨切り術や人工関節置換術が行われる。しかしながら、手術の難易度が高いため、入念に術前計画を立案する必要がある。術前計画策定では CT, MRI 画像から骨・軟骨・筋肉の抽出や骨切り線・面の設定が必要であり、現状では対話作業が中心で、その自動化は困難であった。これらの自動化を行うためには、3次元画像の自動画像認識や骨切り術全般の知識の蓄積が必要不可欠である。そこで本研究では Fully Convolutional Network (FCN) を用いて CT データからの腰骨と大腿骨の抽出を行う。

2. 先行研究

骨の抽出を対象とした研究では、判別分析法を用いた、骨領域を抽出する手法が提案されている [1]。この手法では CT 画像に対して判別分析法を複数回適用することで、骨領域の抽出に必要な閾値を求め、骨の抽出を行っている。この手法では閾値による 2 値化で抽出を行うため、骨を分類したセグメンテーションは不可能である。また単純な閾値による処理であるため、軟骨部と硬骨部を同時にセグメントすることが難しい。本研究では FCN を用いたセマンティックセグメンテーションにより行い、腰骨と大腿骨の分類とセグメンテーションを行った。

3. 提案手法

3.1 FCN によるセグメンテーション

本手法では FCN を用いて腰骨と大腿骨のセグメンテーションを行う。

Acquisition of diagnostic technology for orthopedic surgery by Fully Convolutional NetworkSekimura Shoto¹ Kato Toru¹ Takahashi Hiroki¹ Doi Akio¹ Mawatari Taro² Ichinohe Sadafumi³¹ Iwate Prefectural University Faculty of Software and Information Science² Hamano Town Hospital Orthopedic Surgery³ Iwate Medical University attached Hanamaki Onsen Hospital Orthopedic Clinic

FCN は Convolutional Neural Network から全結合層を排除しすべて畳み込み層で構成される。FCN はすべて畳み込み層で構成されているおり、位置情報を保持することが可能となるため、セマンティックセグメンテーションに利用される。

本手法では FCN を適用する際に腰骨および大腿骨の含まれるマルチスライス CT の 3 次元ボクセルデータを学習用データとし、腰骨、大腿骨、その他の部分にセグメントされた 3 次元ボリュームデータをラベルデータとして用いた。

提案手法では FCN により、腰骨、大腿骨およびその他の部分に属する確率をボクセルレベルで求める腰骨、大腿骨およびその他の部分に属する確率のうち、最も大きいラベルに属すると判断する。

3.2 FCN のネットワーク構成

提案手法では encoder-decoder 型と呼ばれる FCN の構造を用いる。ネットワークの構造は同じ特徴マップのサイズで処理を行ういくつかの階層に分かれている。ネットワークの前半部分で特徴抽出を行いつつ、大域的な特徴を考慮するためにダウンサンプリングを行う。本手法では pooling の代わりに stride 2 の $2 \times 2 \times 2$ フィルタを採用している。FCN を用いたセマンティックセグメンテーションではボクセルごとにラベルづけを行うために、特徴マップのサイズを元に戻す必要がある。そのためネットワークの後半部では transposed convolution を使いアップサンプリングする。FCN を用いたセマンティックセグメンテーションではボクセルごとにラベルづけを行うため、局所的な特徴が重要となる。しかしダウンサンプリングした際に局所的な特徴は失われる。そのためネットワークの前半部分の特徴マップをネットワーク後半部分の特徴マップに連結することで局所的な特徴をネットワーク後半部に伝えている。また本手法では勾配消失を防ぐために各層の出力に入力を加えることで残差学習を行う [2]。ネットワークの前半部分では $7 \times 7 \times 7$ フィルタを使用し、畳み込み後の活性化関数には Parametric ReLU を使用した。ネットワーク後半部では 3 次元化した Global

Convolutional Network(GCN)を使用した[3]. GCNは、畳み込みをx方向,y方向,z方向に分割して行うことでパラメータ数を減らしつつ、より大きなカーネルサイズのフィルタを使用することが可能となる.GCNを使い大きなカーネルサイズのフィルタを使うことで、密度の高いセグメンテーションが可能になる.

本手法ではダイス係数に基づいた損失関数を使用する[4]. 使用した損失関数を(1)に示す.

$$D = \frac{2 \sum_i^N p_i g_i}{\sum_i^N p_i^2 + \sum_i^N g_i^2} \quad (1)$$

ここで p_i はFCNによるセグメンテーションの予測結果であり、各ボクセルが各ラベルに属する確率を示す. g_i はラベルデータであり、各ボクセルが属しているラベルでは1であり、属していないラベルでは0を保持する.

4. 評価

CTにより撮像された腰骨と大腿骨を含むボクセルデータ16症例で学習を行い. また16症例それぞれに対して、x,y,z方向に対して、鏡像反転を行い学習データの水増しを行った. 学習は確率的勾配降下法の一つであるAdamを用いて行った. 3次元画像のFCNの学習はメモリの消費が多いため、データを1つずつ読み込む、オンライン学習で行った.



図1 元画像




図2 正解画像




図3 FCNによるセグメント結果

本手法では4症例でテストを行った. 図1は

テスト画像の元画像である. 図2は腰骨と大腿骨のセグメンテーションの正解画像である. 図3はFCNによるセグメンテーションの結果である. 図3では腰骨と大腿骨の境界付近でセグメンテーションがうまくいかず、大腿骨の領域が腰骨の領域に浸食されている. また大腿骨頭のセグメンテーションがうまくいかず、形状が正解画像と比べ委縮している. 示した症例以外でもこれらの傾向がみられた.

表1 セグメンテーションの正答率 (%)

部位	正答率 (%)
腰骨	67.05
大腿骨	76.84
その他の領域	91.84

テストデータ4症例に対して正答率を計算し、4症例の平均を計算しまとめたものを表1に示す. 正答率は各ラベルについて正解したボクセル数を、各ラベルのボクセル数で割ることで求められる. 正答率は腰骨において67.05%、大腿骨において76.84%であり、低くなっている. 原因として学習に用いた症例数が少ないことが考えられる.

5. 終わりに

FCNを用いた腰骨と大腿骨のセグメンテーション手法を提案した. 今後の課題として、症例数の増加があげられる. また、腰骨と大腿骨の境界付近のセグメント結果の改善があげられる.

参考文献

- [1]川崎将吾, 中口俊也, 落合信靖, 津村徳道, 三宅洋一: 上腕骨頭3次元形状の左右間比較による欠損定量化, Medical Imaging Technology, Vol. 24, pp262-269, 2006.
- [2] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun: Deep residual learning for image recognition. arXiv preprint arXiv:1512.03385 (2015)
- [3] Chao Peng, Xiangyu Zhang, Gang Yu, Guiming Luo, Jian Sun: Large Kernel Matters—Improve Semantic Segmentation by Global Convolutional Network arXiv:1703.02719(2017)
- [4] Fausto Milletari, Nassir Navab, Seyed-Ahmad Ahmadi: V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation arXiv:1606.04797(2016)