

【大会論文 29-09】

膝 CT 画像から深層学習を用いた骨切ライン自動抽出法

佐藤 和輝<sup>+</sup> 関村 匠斗<sup>+</sup> 加藤 徹<sup>+</sup> 土井 章男<sup>+</sup> 馬渡 太郎<sup>++</sup> 一戸 貞文<sup>+++</sup>

岩手県立大学ソフトウェア情報学部<sup>+</sup> 浜の町病院<sup>++</sup> 岩手医科大学<sup>+++</sup>

1. はじめに

骨切り術の一つである Open Wedge HTO は X 脚または O 脚といった曲がった足を治療する為に行う手法である。現在は下肢全長の CT 画像から目測で骨切ラインの選定を行っており、医師への負担が多くなっている。そこで本論文では骨切ライン選定の効率化・定量化するために、膝 CT 画像から、脛骨外側から内側 5mm と脛骨内側角度変更点を自動検出する手法を提案する。骨切りラインは全体で 3 本あり、深層学習の FCN(Fully Convolutional Networks) を用いて、ライン①の自動抽出を行う。

2. 全体の処理の流れ

下肢全長の CT 画像に対して左膝、右膝に分けて各膝領域にクリッピングし、各 CT 画像から脛骨外側から内側 5mm、脛骨内側角度変更点を選択し、2 点の座標値を label データとして出力して、教師データの作成を行う。同様に骨切ライン②と③を設定する。全体の処理の流れを図 1 に示す。

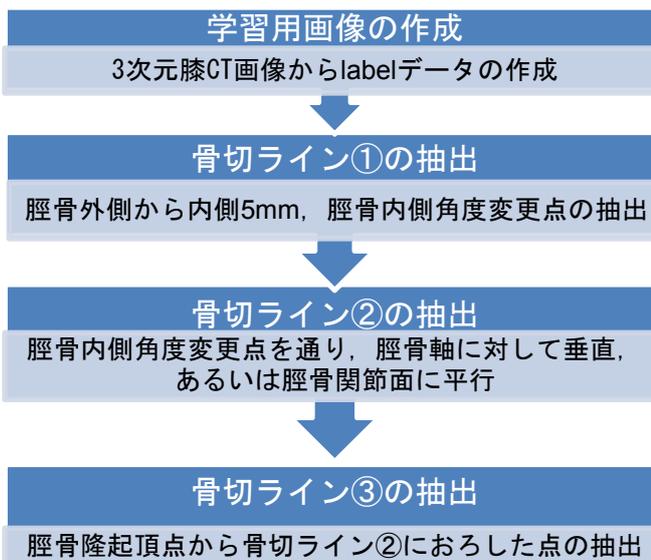


図 1 提案手法全体の流れ

図 2 に骨切ライン①～③を示す。赤線がライン①、緑線がライン②、ピンク線がライン③である。

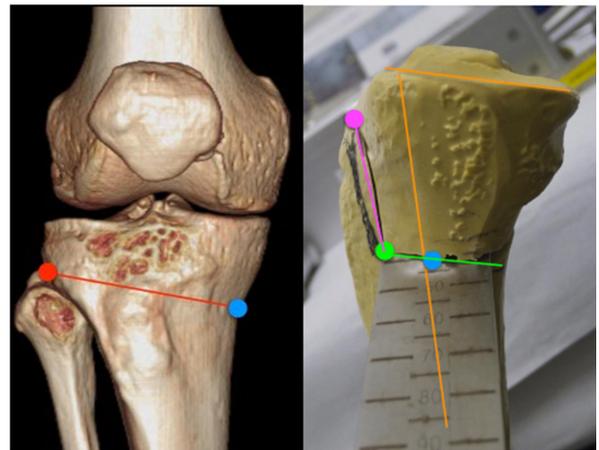


図 2 骨切ライン①～③

3. 学習用画像から label データを作成

学習用画像から FCN で使用する label データを作成する。骨ライン①の Label データは脛骨外側から内側 5mm,  $P_1 = (x_1, y_1, z_1)$ , 脛骨内側角度変更点,  $P_2 = (x_2, y_2, z_2)$  の座標値である。2 点の座標値は、CT 画像から  $P_1, P_2$  を結ぶラインで水平に切断した断面図から  $P_1, P_2$  の座標値を対話的に取得する。

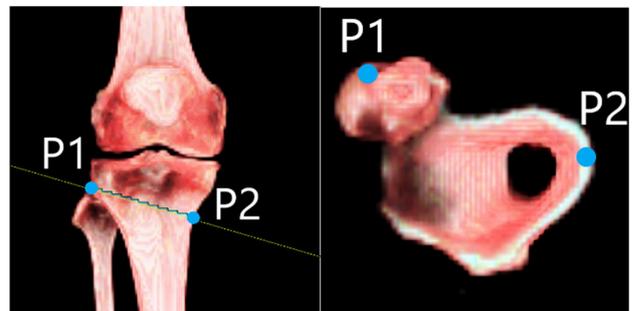


図 3 膝蓋骨正正面と断面図から見た  $P_1, P_2$

4. FCN を用いた学習方式

3 次元膝 CT 画像の中から脛骨外側から内側 5mm,

脛骨内側角度変更点の特徴点を自動で推定する。今回使用する FCN はすべてが畳み込み層で構成されているネットワークであり、位置情報を破棄することなく学習が可能となる。畳み込み後の活性化関数には Parametric ReLU を使用している<sup>[1]</sup>。損失関数は、骨切り線を定めるための座標点と label データに示される座標点 P との距離に応じて定める。まず、学習用画像と同一サイズであり、label データに示される座標点の数と同じチャンネル数をもつ画像 I を作成する。画像 I の各チャンネルは label データに示される座標点と対応し、骨切り線を定めるための座標点である確率を持っている。画像 I の各チャンネルは label データに示される座標点と対応している。画像 I 上の座標 C が骨切り線を定めるための座標点である確率は式(1)で表される。ここで、 $D_c$  は画像 I 上のある座標 C と label データに示される座標点との距離であり、 $D_n$  は画像 I 上の任意の座標 n と label データに示される座標点との距離である。また e はネイピア数であり、T は画像 I のボクセル数である。

$$\text{probability} = \frac{e^{-\frac{D_c^2}{4}}}{\sum_{n=1}^T e^{-\frac{D_n^2}{4}}} \quad (1)$$

すべてのチャンネルでの確率を計算することで画像 I を作成する。FCN の出力結果をチャンネルごと、ソフトマックス関数により確率に変換したものを S とする。損失は S と画像 I とのクロスエントロピーを計算し求める。クロスエントロピーは式(2)より計算する。

$$\text{Crossentropy} = -\sum_n^T I \log S \quad (2)$$

## 5. 症例データでの適用とその評価

今回用意した学習用画像は下肢全長データを左右の膝に分け、膝部分だけ取り出したものをそれぞれ 24 症例、合計 48 個のデータを作成した。学習では 20 症例を使用し、残り 4 症例は学習モデルに対し、性能評価の際に使用した。今回の学習試行回数は約 3000 回行い、評価の手法として損失関数の推移で判断する。損失関数の値「loss」が小さいほど与えた座標値に近い結果が得られる。結果としては step 1000

を超えたあたりで損失関数「loss」の値が 4 の値に収束した。この時点で与えた座標値との誤差は 1 ピクセル以下に収まっている。次に学習によって得られたモデルに対し、テストデータを使用してテストを行った。テストデータは学習に使用していない同じ形式の膝データ 4 つ、左右で 8 つのデータを使用する。結果としては学習モデルの loss 値が「4」で収束したのに対し、テストデータでは左膝の loss 値が「12~18」、右膝の loss 値が「7~10」という結果となった。この数値は label データと離れており、原因として、学習用画像数が少ないこと、学習モデルが最適化されていない等が想定される。特に、モデルの最適化方法として畳み込み層を増やす等して今後学習用画像を増加、または一つのデータから学習用画像を増加するなどの対策が考えられる。

表 1 テストデータでの損失関数「loss 値」

	Left21	Left22	Left23	Left24
Loss	18.0131	12.5206	14.9228	13.583

	Right21	Right22	Right23	Right24
Loss	10.4399	8.43199	7.39845	7.00637

## 6. おわりに

本論文では、3 次元膝 CT 画像に対して膝の Open Wedge HTO のための骨切ライン①の自動抽出を行った。FCN による学習は良好に進んだが、テストデータに対して十分な結果が出せなかった。その解決方法としては、新しい学習用画像の追加、FCN モデルの最適化を行う必要がある。また今後の課題としては骨切ライン①の学習結果を足掛かりに骨切ライン②、③の抽出自動化も検討していく必要がある。

## 参考文献

- [1] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun : "Delving Deep into Rectifiers: Surpassing Human Level Performance on ImageNet Classification" (ICCV), 2015, pp. 1026-1034