

クラスタリングと追加学習を用いた

少数の超音波動画からの動脈・静脈の検出

Detection of Arteries and Veins from a Small Number of Ultrasonic Video Images Using Clustering and Incremental Learning

平川 恵輔[†] 上野 春毅[†] 塚本 容子[‡] 小松川 浩[†]
 Keisuke Hirakawa Haruki Ueno Yoko Tsukamoto Hiroshi Komatsugawa

1. はじめに

近年、機械学習手法の発展に伴い、医療支援に役立つ研究が盛んである。特にエコー穿刺による検査では、超音波動画から血管の静脈・動脈の状態を観察する。形状の変化を時系列的に観察し、動脈と静脈を熟練者が識別する。機械学習手法を用いて識別するには、動画での検出が求められる。医療分野においてディープラーニングを用いた画像解析の研究やシステム開発は多数行われているが、その多くは静止画を対象としたものである。[1]一方、医療データは一般的に個人情報に絡む内容であり、大量に集めることが困難であることが多い。特に、超音波動画は画質が不明瞭であり、血管の位置や大きさには個人差が大きく、少量のデータから汎用的に検出することは困難である。そこで、データ特性毎にクラスタリングをしてデータセットの構築を行なった。そして、3D U-Net [2]の学習（追加学習）と血管の特徴に応じた後処理を行い、検出精度の向上を目指した。

2. 本研究で扱うデータセット

本研究で用いる超音波動画は北海道医療大学の協力のもと、公立千歳科学技術大学情報システム工学科の学生 8 名を対象に収集を行なった。収集した動画を 1 秒あたり 5 フレームで静止画像を抽出し、10 枚の 2 次元画像を積み重ねて 1 つの 3 次元動画画像として構成した。

2.1 クラスタリング

本研究では血管の相対的な位置関係に着目し、データを以下の 2 パターンにクラスタリングした。

- ・パターン A：動脈と静脈が明確に離れており、物体間の境界線が識別しやすいデータ
- ・パターン B：動脈と静脈が隣接しており、境界線が識別しにくいデータ

このような分類を行なった理由は、セグメンテーションにおいて、境界線の識別が精度に大きな影響を与えるためである。各パターンの被験者数は 4 名ずつを割り当て、4 分割交差検証法により実験を行った。

3. 提案手法

本研究では、超音波動画画像から動脈及び静脈の検出精度向上を目的として、クラスタリングと追加学習を組み合わせた 3D U-Net ベースのセグメンテーション手法を提案する。本研究における追加学習とは、クラスタリングによって分類された部分データセットで一度学習を行った後、す

べてのデータを用いて再度モデルを学習させる手法であり、初期学習によって得られた特徴抽出能力を活かしつつ、モデルの汎化性能を高めることを目的とする。はじめに、クラスタリングにより特性の異なるデータセットを分類し、初回学習を行う。その後、全データを用いた追加学習を通じてモデルの汎化性能を向上させる。さらに、推論結果に対して、小領域除去の後処理を実施し、誤検出を低減する。

3.1 提案モデル

本研究の提案手法の全体構成を図 1 に示す。クラスタリングにより構築された部分データセットを用いて初回学習を行い、その後全データを用いて追加学習を実施する。最終的に後処理として小領域の除去を行うことで、精度向上と誤検出の低減を図る。1 回目の学習では、クラスタリング後のデータセットを利用する。学習パラメータは、エポック数 10、バッチサイズ 8、最適化手法に Adam、学習率を 2×10^{-2} に設定した。次に、全データを利用して追加学習を行う。学習パラメータは、エポック数 15、バッチサイズ 8、最適化手法に Adam、学習率を 2×10^{-3} に設定した。




図 1：提案手法の全体構成

後処理として、各クラスのセグメンテーション結果から領域面積を算出し、累積面積が全体の 95%以上となる主要領域のみを残して小領域を削除した。追加学習による検出精度の向上を検証するために、事前学習を行わず、全データセットを用いて直接学習した場合との比較を行った。

3.2 評価方法

本研究で用いた評価指標を式 (1) ~ (4) に示す。

式 (1) では、サイズ $i \times j$ の画像の各ピクセルについてアノテーション済みの場合は $n_{c,l,k}(i,j) = 1$ 、そうでない場合は $n_{c,l,k}(i,j) = 0$ とする。これに対応する予測確率 $S_{c,l,k}(i,j)$ を掛け合わせてスコア $\phi_{c,l,k}$ を算出する。

$$\phi_{c,l,k} = \frac{\sum_{i=1}^N \sum_{j=1}^M S_{c,l,k}(i,j) n_{c,l,k}(i,j)}{\sum_{i=1}^N \sum_{j=1}^M n_{c,l,k}(i,j)} \quad (1)$$

式 (2) では、式 (1) で求めたスコアの総和を、クラス数 C と 1 データセットあたりの画像枚数 L で正規化し、データセット毎の平均精度 $\bar{\phi}_k$ を求める。

$$\tilde{\phi}_k = \frac{1}{C} \frac{1}{L} \sum_{c=1}^C \sum_{l=1}^L \phi_{c,l,k} \quad (2)$$

式 (3) では、データセット毎に平均精度 $\tilde{\phi}_k$ が閾値を上回っていたら $\psi_k = 1$ とする。

$$\psi_k = \begin{cases} 0 & \tilde{\phi}_k < \theta \\ 1 & \tilde{\phi}_k \geq \theta \end{cases} \quad (3)$$

式 (4) では、全てのデータセット K における ψ_k の平均を取ることで全体の平均精度 Ψ を求める。

$$\Psi = \frac{1}{K} \sum_{k=1}^K \psi_k \quad (4)$$

4. 実験結果・考察

4.1 実験結果

実験結果を表 1 及び図 2 に示す。図 2 は動脈 (白) と静脈 (赤) の検出結果の一例である。評価は 4 分割交差検証法により行い、各条件における平均検出精度を算出した。閾値が 0.25 の時、追加学習を行わない場合の平均検出精度が 79.5%、パターン A で学習後に追加学習を行った場合は 89.7%、パターン B で学習後に追加学習を行った場合は 91.4% であった。

表 1: 閾値 0.25 の場合の平均検出精度

条件	平均検出精度
追加学習を行わない場合	79.5%
パターン A → 追加学習	89.7%
パターン B → 追加学習	91.4%




図 2: 検出例 (動脈: 白、静脈: 赤)

次に、閾値が 0.5 の場合の平均検出精度を表 2 に示す。追加学習を行わない場合の平均検出精度が 27.7%、パターン A で学習後に追加学習を行った場合は 32.7%、パターン B で学習後に追加学習を行った場合は 37.5% であった。

† 公立千歳科学技術大学 Chitose Institute of Science and Technology

‡ 北海道医療大学 Health Sciences University of Hokkaido

表 2: 閾値 0.5 の場合の平均検出精度

条件	平均検出精度
追加学習を行わない場合	27.7%
パターン A → 追加学習	32.7%
パターン B → 追加学習	37.5%

4.2 考察

表 1、表 2 の結果より、クラスタリングによる事前学習を行った上で追加学習を行うことで、いずれの閾値設定においても精度向上を確認することができた。特に、パターン B で学習後に追加学習を行った場合は最も高い検出精度を示している。これは、パターン B のような識別困難なデータを初期学習に含めることで、モデルがより多様な特徴を学習し、汎化性能が高まったためと考えられる。一方で、閾値を 0.25 から 0.5 に引き上げると、平均検出精度は約 50% 以上低下している。これは、モデルが大まかな血管位置は捉えているが、確信度の高い予測が難しいことを示している。さらに、クラスタごとの学習効果を確認するため、パターン A および B のみで学習を行った場合の検出精度を表 3 に示す。この結果から、パターン B はパターン A に比べて輪郭や位置の曖昧さによりモデルが特徴を掴みにくい傾向があるといえる。しかしながら、パターン B を初期に学習し、さらに全体データで追加学習を行った場合には最も高い精度を達成している。これは、難易度の高いクラスタに対して十分な学習時間を確保することで、特徴量の抽出性能が向上したと考えられる。

表 3: 閾値 0.5、クラスタ単独学習時の平均検出精度

条件	平均検出精度
パターン A のみで学習を行った場合	21.8%
パターン B のみで学習を行った場合	13.3%

5. おわりに

本研究では、動脈・静脈検出におけるデータ特性に基づいたクラスタリングによるデータセットの構築と 3D U-Net を用いた追加学習手法の提案を行なった。また、誤検出を抑制するための小領域削除による後処理も導入した。その結果、追加学習を行うことで精度向上できることが確認できた。実験の結果、提案手法によって従来手法と比較して検出精度の大幅な向上が確認された。特に、識別困難なクラスタ (パターン B) に対する初期学習とその後の全体学習の組み合わせが効果的であることが明らかとなった。一方で、検出確信度の閾値を高く設定した場合には、依然として精度が大きく低下する課題が残る。

参考文献

- [1] 井上謙一 “CNN+VisionTransformer を用いた全自動超音波検査による自動診断の検討”, https://www.jstage.jst.go.jp/article/pjsai/JSAI2022/0/JSAI2022_2P1G_S1003/_pdf/-char/ja (参照日 2025.6.12).
- [2] Özgün Çiçek, Ahmed Abdulkadir, Soeren S. Lienkamp, Thomas Brox, Olaf Ronneberger, “3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation”, <https://arxiv.org/abs/1606.06650> (参照日 2025.6.12).