

半教師あり学習を用いた光超音波画像 における体毛領域認識

吉川 亮^{1,a)} 関口 博之³ 津下 至³ 齊藤 晋³ 備瀬 竜馬^{2,3}

概要: 光超音波イメージング技術は、生体内の血管を非侵襲に三次元可視化できるとして注目を集めている新しいイメージング技術である。しかし、光超音波イメージングでは、観察対象である血管に加えて体毛も同時に可視化されてしまい、多数の体毛により血管の観察の弊害になるという問題がある。視認性の向上のためには、画像処理によって画像内から体毛領域のみを除去する必要がある。そこで本論文では機械学習を用いた、光超音波画像内の体毛領域の認識・除去手法を提案する。今回取り扱う光超音波画像は新デバイスによって撮影されるため絶対数が少なく、十分な数の学習用データセットを得ることは困難である。そこで、少数の教師あり学習データにおいて成果を出している半教師あり学習手法を利用する。また、本論文では画像内の局所領域において体毛の向きが類似しているという各画像に特有な特徴に着目し、「体毛の向きの揃い具合」という画像空間内の事前知識を導入した新しい半教師あり学習手法を提案し、その有効性を検証する。

1. はじめに

光超音波イメージング技術によって、生体内の血管を非侵襲に3次元可視化することができる技術であり、様々な疾病と関係が深い血管構造を立体的かつ鮮明に観察することができることから、早期診断・治療経過診断への応用が期待されている [1]。この技術は血液中のヘモグロビンが光を吸収して、熱膨張するとともに、音を発生する光超音波現象を利用しており、超音波を多数のセンサーで計測することで、血管をイメージングすることができる [2]。

しかし、光超音波イメージングでは、不必要な対象も撮像される場合がある。具体的には体毛も同様に光を吸収し超音波を発生するため、図1に示すように、血管に加えて体毛も同時に可視化されてしまい、多数の体毛により血管の観察の弊害となるという問題がある。そのため、視認性を改善するためには画像内の体毛を除去する必要がある。

このような問題を解決するために、機械学習を用いた、光超音波画像内の体毛領域の認識・除去手法を提案することで、医師の診断の援助をすることを目的とする。

本研究では新デバイスによって撮影された画像を取り扱っているため、大量のデータを取得するのは困難である。このような学習データが少ない場合において、教師あ




図 1: 光超音波画像

りデータで作成した識別器をラベルが付与されていない教師なしデータの特徴量空間における分布をうまく活用する半教師あり学習手法が提案されている。教師なしデータの分布も利用することにより、実データの分布に合わせるように識別器を更新する手法であり、有用であると考えられる。バイオ医療画像においては、対象に関する形状や構造を仮定できる場合が多く、セグメンテーションなどの認識処理に非常に有用であると考えられるが、従来の半教師あり学習では、このような対象の構造に関する事前知識は活用されていない。また、従来法では、特徴量はデータに共通する特徴を利用し、個々のテストデータ特有の特徴は利用されない。

本研究では、一般的な半教師あり学習が利用する特徴量空間におけるデータ分布に加えて、バイオ医療画像特有の

¹ 九州大学大学院システム情報科学府

² 九州大学大学院システム情報科学研究院

³ 京都大学医学部

a) ryo.kikkawa@human.ait.kyushu-u.ac.jp




図 2: 局所領域における体毛の向きの特性

対象構造に関する事前知識を積極的に利用した新しい半教師あり学習手法を提案する。具体的には、本研究課題で認識・除去する体毛は剃毛した皮膚下であるため、「近接する複数の体毛の向きは同方向を向いている。」という事前知識を活用する。体毛の向きはテストデータによって異なるため、この「体毛の向き」という事前知識を単純に特徴量として導入することはできない。そこで、本研究では、候補領域の特徴空間と「体毛の向きの分布」という対象構造に関する事前知識空間の2つの特徴空間を交互に学習する新しい半教師あり学習手法を提案する。提案手法により、テストデータ毎に異なる「体毛の向きの分布」に関する対象構造事前知識を有効に活用することができ、通常の機械学習手法より高精度で認識することができる。

2. 提案手法

医療画像において、画像における対象構造に関する事前知識を活用することは重要である。本課題においては、図2に示すように、画像内の局所領域において体毛はそれぞれ似通った方向に向いていることが多いことがわかっており、この「近接する体毛の向きの揃い具合」という対象構造に関する事前知識は有用であると考えられる。

本提案手法では、従来の半教師あり学習とは異なり、教師なし学習データの特徴量空間における分布に加えて、テストデータごとの「近接する体毛の向きの揃い具合」という対象構造事前知識を活用して識別器を更新する半教師あり学習手法を提案する。

2.1 学習のモデル

学習の大まかな流れを図3に示す。全データに共通して体毛識別に有用と考えられる特徴量空間を X とし、その空間における識別器を f とする。この識別器 f を教師なしデータ分布及び「体毛の向き」に関する対象構造事前知識を用いて更新していく。ここでは、「体毛の向き」のデータ分布を表現する空間を Y と定義し、「体毛の向きの揃い具合」の観点から「体毛らしさ」の尤度を算出する識別器 g とする。

まず学習データから特徴量空間 X のデータ分布を作成し、そのうち教師ありデータのみを用いて識別器 f を初期化し、その識別器を用いて教師なしデータの各サンプルの

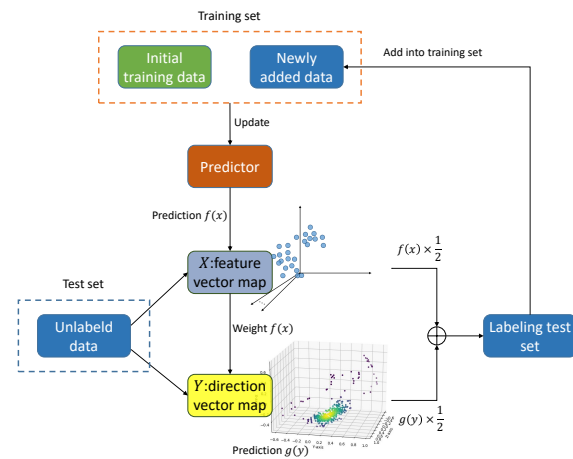


図 3: 半教師あり学習の流れ図

「体毛らしさ」尤度を求める。一方で教師データの各サンプルに対して「向き」を求めて構造事前知識空間 Y の分布を作成し、先ほど求めた尤度で各サンプルに重みをつける。さらに局所領域における周囲のサンプルとの向きの類似度を求める識別器 g を決定する。以上2つの識別器を用いて、「輝度特徴量」及び「体毛の向き」両方の観点から、教師なしデータの尤度を推定する。推定した尤度を用いて特徴量空間 X の教師なしデータの各サンプルの重みを決定し、重み付きデータを用いて識別器 f を更新する。以上をの操作を任意の回数繰り返す、最終的に教師なしデータ内の候補領域のラベルを決定する。

2.2 体毛の候補領域検出

体毛領域と血管領域は、「輝度分布が類似している」「筒状に輝度が高い部分が分布している」というように、局所的な輝度分布として類似した特徴を持つため、ボクセルレベルで認識するのは課題が残る。一方、領域全体として考えると輝度分布の違いなどの識別に有用な特徴を持つと考えられる。そこで本研究では、総じてオブジェクトレベルでの体毛の認識を目指す。本ステップでは、体毛の候補領域をなるべくすべての体毛領域を含むように冗長に抽出する[4]。体毛領域および血管領域は背景領域と比べ輝度が高いことから輝度値による閾値を用いて候補領域を抽出する。一部の体毛領域は血管領域に近接しており、その境界領域の輝度は背景領域より高く、その輝度値はばらつきがあるため、1つの閾値では血管と体毛領域が連結された状態で検出されてしまったり、一部の体毛領域が未検出になったりするなどの課題がある。そこで、複数閾値を用いて冗長に候補領域を検出することで、過検出ではあるが、候補領域集合の中にはほとんどの体毛領域が含まれている状態を実現する。

具体的には、図4のように最初は大きい閾値から段階的に閾値を段階的に下げていく、ここで連結成分の体積に下




図 4: 複数閾値による候補領域検出




図 5: 輝度値の分布の例 (左: 体毛領域, 右: その他領域)

限と上限を設け、図内の Step1 と Step4 を除外したうえで Step2 から 1 つ Step3 から 2 つ候補領域をそれぞれ検出する。体毛と血管の輝度分布は重なることから候補領域の中には、血管の一部の領域も含まれるため、以降のステップで候補領域が体毛か否かを推定する。本手法の目的は、体毛の認識・除去による画像の視認性向上のため、体毛の正確な形状を領域分割できていなくてもよい。

また、今回実験に用いた画像にはあらかじめ体毛と思われる領域の根元と毛先の 2 点にアノテーションを行っており、その 2 点を同時に含む領域を「体毛」領域とし、それ以外を「その他」領域としてラベル付けを行い、それぞれの候補領域を教師データとして用いることが可能である。

2.3 識別器 f の構成

トレーニングデータ内の教師ありデータ及び教師なしデータの両方に共通した特徴量を算出することで識別器 f の作成を行う。

本ステップでは、得られた候補領域が体毛か否かを識別するのに有用な特徴量の抽出を行う。体毛領域と血管領域のクラス間に差異があり、クラス内では類似している特徴として、「輝度値の分布」「輝度勾配値の分布」「光超音波スペクトラム特性」「形状特徴」の 4 つの特徴量を算出する。各特徴量についてそれぞれ下記に説明する。

2.3.1 輝度値の分布

第一の輝度値の分布について例を図 5 に示す。これは画像全体の輝度値を最大輝度値で割った後、ある候補領域内のピクセルの輝度値の頻度分布である。ビン数は 11 個の正規化した輝度値頻度分布を 11 次元の特徴量とした。一般的に体毛と血管の輝度値の分布は重なる部分もあるが、体毛の方が高い輝度値を持つことがわかる。

2.3.2 輝度勾配値の分布

第二の輝度勾配値の分布についても同様に例を図 6 に示す。こちらもビンの数は 11 個の輝度勾配値頻度分布を 11





図 6: 輝度勾配値の分布の例 (左: 体毛領域, 右: その他領域)



(a) 光波長 756nm (b) 光波長 797nm

図 7: 実験に用いた画像の例




図 8: 図 7(a) と図 7(b) の差分画像

次元の特徴量とした。境界部分のエッジは体毛の方が血管よりも強いため、体毛の方が高い輝度勾配値を持つことが期待されている。

2.3.3 光超音波スペクトラム特性

また光超音波現象は組織が吸収する光の波長による超音波強度が異なることが知られており、血管と体毛でその特性は異なる。具体的には体毛の方が光波長を変えたときの輝度値の変化量は大きいとされている。今回の実験では同時点、同一箇所において 2 つの光波長 756nm (図 7(a)) と 797nm (図 7(b)) で撮影した画像を用いて、各候補領域中の輝度差の分布を求める。具体的にはまず光波長 756nm の画像の輝度値と 797nm の画像の輝度値の差を求める。図 8 に差分画像を示す。血管領域よりも体毛領域の方が輝度値の変化量が大きいことが見て取れる。この画像からビンの数 11 個の輝度値頻度分布を求めてやり、11 次元の特徴量とした。




図 9: 連結成分の主成分分析 (図中の青色の部分が候補領域, 橙色の矢印が第一主成分ベクトル)

2.3.4 形状特徴

光超音波画像は撮影箇所を剃毛したうえで撮影されており, 皮膚の上からは見えず埋まっている体毛の部分が画像に写りこんでいるため, 個人差にもよるが体毛領域は比較的短く長さが統一されている場合が多い. 一方で血管領域はひとつなぎとなっているので, 長い連結成分が検出される場合が多い. これらの理由から各候補領域ごとに連結成分の座標を主成分分析し, 第一主成分の分散と第一主成分方向の連結成分の長さをそれぞれの候補領域の形状特徴として求めた. 図 9 に各候補領域における主成分分析の模式図を示す. 連結成分の長さを求める際は第一主成分軸上で最大の値を持つ端点 1 と最小の値を持つ端点 2 のそれぞれの画像内の座標を求め, その 2 点間のユークリッド距離を求める. また, 第一主成分分散も同時に求め, 計 2 次元の形状特徴長ベクトルを求める.

以上の 4 つの特徴量を 1 つの組計 35 次元のベクトルとし, それぞれの候補領域の特徴量ベクトルとする.

2.3.5 識別器の決定

次に特徴量ベクトルをマッピングした高次元特徴量空間内において, 各ベクトルを体毛領域とその他領域に分類する識別器を構成していく. 高次元特徴量空間内のラベル付きデータを教師データとして, ロジスティック回帰モデルを用いて, パターン x が生じた時, その時のクラスが体毛である確率を算出するロジスティック関数 $f(x)$ を定義する.

2.4 識別器 g の構成

次にトレーニングデータに追加する教師なしデータ特有の特徴として, 「向き」を算出し, 周囲のサンプルとの向きの類似度の観点から「体毛らしさ」を推定する識別器 g を構成していく.

2.4.1 スライディングウィンドウを用いた画像分割

候補領域の方向の類似度から体毛であるか予測する場合, 候補領域をとる領域のサイズを広くすればするほど, 方向のばらつきは大きくなってしまい, 体毛を予測することが困難になってしまう. 画像内の全候補領域から方向の類似度を算出するためには, 画像を狭い領域ごとに分割し, その領域ごとに得られた候補領域同士の方向を分析する必要

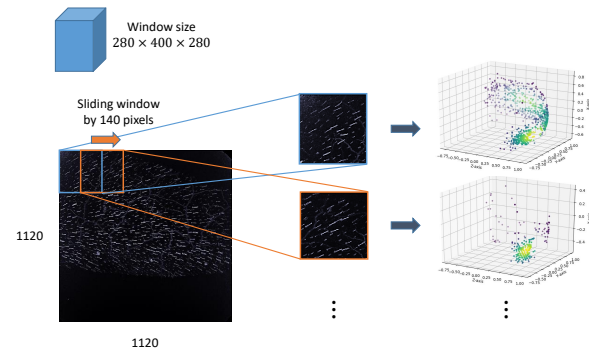


図 10: スライディングウィンドウを用いた局所体毛分布特徴量空間決定例 (左図: 領域全体の MIP 画像, 中図: 局所ウィンドウごとの MIP 画像, 右図: 局所ウィンドウごとの局所体毛向き特徴量空間)

がある.


そこで図 10 に示すように, 全体画像に対して, スライディングウィンドウの要領で画像を分割し, その画像ごとに検出した候補領域からそれぞれの方向の類似度を算出する識別器 $g = \{g_1, g_2, \dots\}$ を複数決定し, それぞれの候補領域に対応した識別器を選択し, 類似度を算出する. 具体的には, パッチの中心とそれぞれの候補領域との距離を求め, 一番距離が短かったパッチからその候補領域が検出されたときに算出した類似度を選択する.

2.4.2 向き特徴の算出及び識別器の決定

候補領域の体毛の向き分布は以下のように求める. 図 9 より端点 1 を (x_i, y_i, z_i) , 端点 2 を (x_j, y_j, z_j) として, 式 1 を用いて方向ベクトルを算出し, その集合 y を方向ベクトル空間 Y にマッピングする.

$$\text{Direction vector} : \frac{(x_i - x_j, y_i - y_j, z_i - z_j)}{|(x_i - x_j, y_i - y_j, z_i - z_j)|} \quad (1)$$

次に特徴量空間 X 内のそれぞれのベクトルに対してあらかじめ学習された識別器 f を用いてラベルを予測し, その確率 $f(x)$ を求める. その後各方向ベクトルにそれぞれ対応した $f(x)$ の値で重み付けを行い, 体毛らしさ $g(y)$ の値を求めていく. 具体的には, まず $f(x)$ の値に応じて各方向ベクトルの数を増やし, 得られた重み付き方向ベクトル空間から平均と共分散行列を求め, この分布が多変量正規分布に従うとみなし, 集合 y においてそれぞれ確率密度を求める. これをクラスが体毛領域であるという条件付きの y の生起確率 $P(y|hair)$ と定義する. 一方で $1 - f(x)$ の値においても同様に重み付けを行い, 得られた重み付き方向ベクトル空間から確率密度を求めたものをクラスがその他領域であるという条件付きの y の生起確率を $P(y|other)$ と定義する. またすべてのサンプルのうち $f(x)$ の値が 0.5 以上



(a) ID=1 (b) ID=2 (c) ID=3

図 11: 実験に用いた画像 (視認性のためコントラスト調整済み)

のものが占める割合を体毛領域クラスの生起確率 $P(hair)$ とみなすと、ベイズの定理 [6] より y が生起した時そのクラスが体毛領域である確率 $P(hair|y)$ について次の式 2 が成り立つ。

$$P(hair|y) = \frac{P(hair)P(y|hair)}{P(hair)P(y|hair) + P(other)P(y|other)} \quad (2)$$

これを候補領域の向きの類似度 $g(y)$ とみなす。局所空間において体毛の向きが周辺の体毛と同じ向きを向いているほど尤度 $P(hair|y)$ は高くなり、異なる方向を向いていると尤度は低くなる。

2.5 ラベル付け及び識別器の更新

最後に各ベクトルに対応した $f(x)$ と $g(y)$ を平均し、それぞれを体毛であるかどうかの尤度とみなす。この尤度をもとにラベルなしデータの疑似的ラベルを予測していく。尤度は 0 から 1 までの値で表現され、0.5 以上の候補領域に対しては体毛領域であるとみなしそれ以外をその他領域とする。また、尤度が 0、もしくは 1 に近いものほどラベルの確信度は高く、0.5 に近いものほど確信度は低いとしてそれぞれ重みとして付与したうえでラベルなしデータをトレーニングデータに追加し、識別器を更新する。これを任意の回数繰り返す、最終的に得た $f(x)$ と $g(y)$ の平均値で画像内から体毛領域の判別を行う。

3. 実験

本章の実験では $1120 \times 400 \times 1120$ 画素、756nm と 797nm の 2 つの光波長で人の大腿部を撮影した三次元ボリューム画像を 3 セット使用した。図 11 に実験画像を示す (図は Maximum Intensity Projection: MIP 画像)。3 つの画像にはあらかじめ体毛の根元と毛先の 2 点にをマニュアルでアノテーションを施し、候補領域をそれぞれ体毛クラスとその他クラスに分類し、ラベルありデータとして活用した。3 つの画像のうち 2 つを教師ありデータとして識別器を学習させ、残り 1 つを教師なしデータとみなして体毛領域を認識・除去処理する。これを 3 通り行い、それぞれの認識精度を定量的に評価し除去処理の前後の画像を目視で比較し視認性の定性的な評価も行う。

また、本実験では、2 パターンの実験を行う。1 つは単純な教師あり学習として識別器 f を用いて、教師ありデータ

表 1: 体毛認識実験の精度比較

	適合率 [%]	再現率 [%]	F 値
教師あり学習	90.8	95.8	93.0
提案手法	92.3	98.5	95.2

のみで学習させた識別器で体毛認識していく方法であり、一方は提案手法の通り、2 つの識別器を交互に学習させる半教師あり学習によって教師なしデータ内の候補領域から体毛領域を認識する。

以上の 2 つの実験結果を比較することで本提案手法の有効性を考察していく。

3.1 実験結果及び考察

はじめに従来型の教師あり学習のみで画像内の体毛領域認識した時と提案手法を用いて検証した時の認識精度の比較として、適合率、再現率、F 値を求め、それぞれ平均したものを表 1 に示す。次に提案手法によって体毛であると認識された候補領域に対して画像内から除去処理したものを図 12(b) から図 14(b) に示す。

2 つの結果を比較すると、どちらも高い精度で体毛を認識することができているが、すべてのスコアにおいて提案手法の方が高い数値を出している。また、体毛除去の前後の画像を見比べると血管領域を大きく欠如させることなく、体毛領域を除去することに成功しており、画像の視認性が格段に向上されたことが確認できた。


本実験の結果から、従来型の教師あり学習より提案した手法の方が高い精度で体毛領域を認識することが可能であることが確認できた。今回のケースのように、トレーニングデータが極端に少ない場合、教師ありデータのみでの学習ではそれぞれのデータ間の特徴量の揺らぎを十分にカバーすることは困難である。本手法では、教師なしのテストデータをうまく学習に追加することで特徴量の揺らぎの課題を克服し、過検出を抑えることができたと考えられる。

4. おわりに

本論文では、半教師あり学習を用いて光超音波画像内の体毛領域を認識・除去し、画像の視認性を向上させる手法を提案した。これにより血管観察の効率は格段に高まり、医師の診断の援助に繋がる。

本手法では教師ありデータに加え、認識対象である教師なしデータをトレーニングデータとして識別器を学習させることで認識精度を高めることを目指した。教師ありデータが極めて少ないため識別器の他データへの汎化性能が低いという弱点を補うべく、画像内の局所領域における体毛同士の向きは類似しているという事前知識を用いて、ラベルなしデータ特有の特徴を考慮することで半教師あり学習のモデル実現を可能にした。


ただし、光超音波イメージングの特性上画像にノイズが



(a) 検証用画像

(b) 体毛除去後


図 12: 提案手法による ID=1 の体毛除去実験 (視認性のためコントラスト調整済み)



(a) 検証用画像

(b) 体毛除去後

図 13: 提案手法による ID=2 の体毛除去実験 (視認性のためコントラスト調整済み)



(a) 検証用画像

(b) 体毛除去後

図 14: 提案手法による ID=3 の体毛除去実験 (視認性のためコントラスト調整済み)

写りこんでしまうことがあり、画像内の局所領域から候補領域を検出する際、多数のノイズも一緒に検出すると付近の候補領域の方向ベクトル分布のばらつきを大きくしてしまう上、その付近の体毛領域の生起確率が小さくなるため、式 2 より実際の体毛領域の尤度を著しく低減させてしまう可能性があると考え、今後の課題として、ノイズに強い体毛の識別モデルを検討する必要がある。

謝辞 本研究は、総合科学技術・イノベーション会議が主導する革新的研究開発推進プログラム (ImPACT) の一環として実施した。

参考文献

- [1] Kitai, T. Torii, and M. Sugie et al., "Photoacoustic Mammography: Initial Clinical Results," *Breast Cancer*, Vol.21, No.2, pp.146–153, Apr. 2014
- [2] C. Li, and L. V. Wang, "Photoacoustic Tomography and Sensing in Biomedicine," *Phys. Med. Biol.*, Vol.54, No.19, pp.59–97, Sep. 2009
- [3] A. F. Frangi, W. J. Niessen, K. L. Vincken, and M. A. Viergever, "Multiscale Vessel Enhancement Filtering," *MICCAI*, Vol.1496, pp.130–137, 1998
- [4] R. Bise, and Y. Sato, "Cell Detection From Redundant Candidate Regions Under Nonoverlapping Constraints," *IEEE Transactions on Medical Imaging*, Vol.34, No.7 pp.1417–1427, Jul. 2015
- [5] F. E. Harrell, "Ordinal Logistic Regression," *Regression modeling strategies*. Springer, New York, NY, pp.331–343, 2001
- [6] C.M. ビショップ著, 元田浩, 栗田多喜夫, 樋口知之, 松本裕治, 村田昇監訳, *パターン認識と機械学習 (上): ベイズ理論による統計的予測*, シュプリンガー・ジャパン, 2007
- [7] Zhou, Xueyuan, and M. Belkin, "Semi-Supervised Learning," *Academic Press Library in Signal Processing*, Elsevier, Vol.1, pp.1239–1269, 2014
- [8] X. Chang, D. Tao, and X. Chao, "A Survey on Multi-View Learning," *arXiv preprint arXiv, 1304.5624*, Apr. 2013
- [9] 内田誠一, *バイオイメージングフォーマティクスと画像情報学*, 電子情報通信学会誌, Vol.98, No.7, pp597–603, 2015