

3次元CT像からの複数臓器抽出における Affinity Propagation を用いた 臓器存在尤度アトラス構築に関する検討

チヨ 成文[†] 小田 昌宏[†] 北坂 孝幸^{††} 三澤 一成^{†††}
 藤原 道隆^{††††} 森 健策^{†††††,†}

[†] 名古屋大学大学院情報科学研究科 〒464-8603 愛知県名古屋市千種区不老町

^{††} 愛知工業大学情報科学部情報科学科 〒470-0392 愛知県豊田市八草町八千草 1247

^{†††} 愛知県がんセンター 〒464-8681 愛知県名古屋市千種区鹿子殿 1-1

^{††††} 名古屋大学情報連携統括本部情報戦略室 〒464-8601 愛知県名古屋市千種区不老町

^{†††††} 名古屋大学大学院医学系研究科 〒466-8550 愛知県名古屋市昭和区鶴舞町 65 番地

あらまし 本稿では、複数臓器存在尤度アトラスを用いた腹部3次元CT像からの多臓器抽出手法について提案する。本手法では、全ての学習画像をクラスタリングし、各クラスごとにアトラスを構築するため、クラスタリング手法は構築するアトラスの有効性に大きく影響する。また、クラスタリングの結果は学習画像の画像間類似度にも大きく依存する。そのため、最適な類似度計算手法とクラスタリング手法の組み合わせを求める必要がある。従来研究では、類似度には NCC、クラスタリング手法は Normalized Cut を用いていた。本研究では、Normalized Cut と Affinity Propagation をクラスタリング手法として採用し、NCC と IMED の二つの類似度計算方法を用い、クラスタリング手法と類似度計算手法の全ての組み合わせについて、実験データ数が 100 の場合の抽出結果を比較した。結果として、IMED + Affinity Propagation の組が最も高い性能が得られた。

キーワード セグメンテーション、類似度、クラスタリング、複数アトラス

A Study on Multi Organ Segmentation from 3D CT Images Using Likelihood Atlases of Organ Existence Constructed by using Affinity Propagation Technique

Chengwen CHU[†], Masahiro ODA[†], Takayuki KITASAKA^{††}, Kazunari MISAWA^{†††},

Michitaka FUJIWARA^{††††}, and Kensaku MORI^{†††††,†}

[†] Graduate School of Information Science, Nagoya University

^{††} School of Information Science, Aichi Institute Of Technology

^{†††} Aichi Cancer Center

^{††††} Information Strategy Office, Information and Communications Headquarters, Nagoya University

^{†††††} Graduate School of Medicine, Nagoya University

Abstract In this paper, we propose a method for organ segmentation based on multiple likelihood atlases from 3D abdominal CT images. In our method, performance of clustering methods affects performance of segmentation methods utilizing the clustering results. Also, similarities between the training data affect the performance of the clustering methods. Hence, we need to find an optimal combination of the similarity criteria and the clustering method. In this research, we utilize two similarity criterion including the Normalized Cross Correlation and the Image Euclidean Distance, combined them with two clustering methods of the Normalized Cut and the Affinity Propagation. For all of the combinations, we evaluated the segmentation performance using 100 cases of CT images. From the experimented results, we found that the combination of the IMED and the Affinity Propagation showed the best performance.

Key words segmentation, similarity, clustering, multi-atlas

1. はじめに

3次元腹部CT像からの臓器抽出処理は、計算機支援診断、手術支援手法の前処理として、または腹腔鏡手術ナビゲーションシステムなどにおける臓器の色分け表示などに利用され、重要な処理である。

臓器領域抽出手法として、複数の学習画像をいくつかの類似画像集合に分類し、各クラスタにおける臓器存在尤度アトラス[1,2,3]を構築し、このアトラスを利用して臓器抽出を行う手法が提案されている[4]。この手法では、クラスタリングの結果がアトラスの構築、および臓器抽出結果に大きく影響を与える。また、クラスタリングは学習画像同士の画像間類似度を用いて行うため、クラスタリングの結果は類似度の計算手法に大きく依存する。

従来研究[4]では、正規化相互相関(Normalized Cross Correlation: NCC)を類似度として、Normalized Cut[5]をクラスタリング手法として利用したが、NCCは領域内の画素全体の平均に基づいて類似度を計算するため、濃淡構造が大きく異なるものの同じ平均値を持つ領域間の相関が高くなりやすく、NCCを用いて計算した類似度が多くの画像において特定の値付近に偏ってしまうという問題点がある。また、Normalized Cutは再帰的にクラスタリングを行うため、多数のクラスタを生成する際、クラスタリング結果が再帰的クラスタリングの初期の結果に依存するという問題点と、クラスタ数を事前に決定する必要があるという問題点がある。そこで本研究では、類似度の計算にNCCに加えて画像間ユークリッド距離(Image Euclidean Distance:IMED)[6]を用い、クラスタリングにNormalized Cutに加えてAffinity Propagation手法[7,8]を用い、類似度の計算方法とクラスタリング手法の四つの組み合わせについて、実験用のデータ数が100の場合に臓器抽出を行い、抽出性能の評価を行った。以下、2.で抽出手法、3.で実験および結果、4.で結果に対する考察を述べる。

2. 手 法

2.1 概 要

本研究では、文献[4]と同様に臓器の統計的な位置情報を表す臓器存在尤度アトラスを用いて肝臓、脾臓、膵臓、腎臓の4つの臓器領域の抽出を行う。

本手法では、まず画像間類似度に基づき学習用画像のクラスタリングを行い、各クラスタの平均画像[9]および、その平均画像上における臓器存在尤度アトラスを構築する。臓器抽出においては、入力画像と各クラスタの平均画像の画像間類似度を比較し、最も類似度が高い平均画像に対する臓器存在尤度アトラスを選択する。選択した臓器存在尤度アトラスと入力画像をMAP推定[10]により粗抽出し、グラフカット[11-14]による精密抽出を行う。

2.2 類似度の計算

本研究では正規化相互相関(Normalized Cross Correlation: NCC)と画像間ユークリッド距離(Image Euclidean Distance: IMED)の二つの類似度計算手法を利用した。

NCC[1]は

$$R_{NCC}(S, T) = \frac{\sum_{k=0}^{N-1} \sum_{j=0}^{M-1} \sum_{i=0}^{L-1} (S(i, j, k) - \bar{S})(T(i, j, k) - \bar{T})}{\sqrt{\sum_{k=0}^{N-1} \sum_{j=0}^{M-1} \sum_{i=0}^{L-1} (S(i, j, k) - \bar{S})^2 \times \sum_{k=0}^{N-1} \sum_{j=0}^{M-1} \sum_{i=0}^{L-1} (T(i, j, k) - \bar{T})^2}}$$

により計算される。ここで、 N, M, L はそれぞれ、 x, y, z 軸方向の画像のサイズである。ここで、人体の右側から左側方向を x 軸、腹側から背側方向を y 軸、頭側から尾側方向を z 軸とする。また、 S, T は画像を表し、 \bar{S}, \bar{T} は濃度値の平均を表す。 $S(i, j, k)$ は点 (i, j, k) における画像 S の濃度値とする。

IMED[2]は伝統的なユークリッド距離の変形である。IMEDは

$$d(\mathbf{x}, \mathbf{y}) = [(\mathbf{x} - \mathbf{y})^T \mathbf{G} (\mathbf{x} - \mathbf{y})]^{1/2} \quad (1)$$

により計算される。 $\mathbf{x} = (x^1, x^2, \dots, x^{NML})$, $\mathbf{y} = (y^1, y^2, \dots, y^{NML})$ は大きさが $N \times M \times L$ の二つのCT像のすべての画素値からなるベクトルである。ここで、 N, M, L はそれぞれ、 x, y, z 軸方向の画像のサイズである。 \mathbf{G} は距離係数行列で、式

$$g_{ij} = f(|\mathbf{P}_i - \mathbf{P}_j|) \quad (2)$$

により計算される。ここで、 $|\mathbf{P}_i - \mathbf{P}_j|$ は画素 i と画素 j の座標間の距離である。例えば、 \mathbf{P}_i と \mathbf{P}_j がそれぞれ座標 $(k, l), (k', l')$ に位置する時、 $|\mathbf{P}_i - \mathbf{P}_j|$ は $\sqrt{(k - k')^2 + (l - l')^2}$ になる。 f は $|\mathbf{P}_i - \mathbf{P}_j|$ の増加により減少する連続的な関数であり

$$g_{ij} = f(|\mathbf{P}_i - \mathbf{P}_j|) = \frac{1}{2\pi\sigma^2} \exp\{-|\mathbf{P}_i - \mathbf{P}_j|^2 / 2\sigma^2\} \quad (3)$$

により計算される。伝統的なユークリッド距離尺度は画像間の微小な変化にとっても敏感であり、小さな変化(2, 3画素の変化)でも大きなユークリッド距離をもたらすこともある。IMEDは微小な変化に影響されないという利点がある。その一方、大きな画像に対して、距離係数行列 \mathbf{G} は非常に大きくなり、IMEDの計算量が膨大なる。計算量を減少するには、画像サイズを小さくする必要がある。

2.3 類似画像の分類

本研究ではNormalized CutとAffinity Propagationの二つのクラスタリング手法を用いた。

Normalized Cutはグラフに基づいたクラスタリングアルゴリズムの一種である。グラフに基づいたクラスタリングでは、グラフ $\mathbf{G} = (\mathbf{V}, \mathbf{E})$ を2つの独立した頂点の集合 \mathbf{X}, \mathbf{Y} に分割する問題を考える。ここで、 $\mathbf{X} \cup \mathbf{Y} = \mathbf{V}$, $\mathbf{X} \cap \mathbf{Y} = \emptyset$ である。また、グラフの枝は重みを持っており、頂点 i と頂点 j を結ぶ枝の重みを $w(i, j)$ とする。このとき、Normalized cutでは、

$$N_{\text{cut}}(\mathbf{X}, \mathbf{Y}) = \frac{\sum_{u \in \mathbf{X}, v \in \mathbf{Y}} w(u, v)}{\sum_{u \in \mathbf{X}, t \in \mathbf{V}} w(u, t)} + \frac{\sum_{u \in \mathbf{X}, v \in \mathbf{Y}} w(u, v)}{\sum_{v \in \mathbf{Y}, t \in \mathbf{V}} w(v, t)} \quad (4)$$

のコストを最小化することにより、集合 \mathbf{V} を集合 \mathbf{X} と集合 \mathbf{Y} に分割を行う。今回は画像 I^i, I^j 間の類似度 $R(I^i, I^j)$ を用いて、頂点 i と頂点 j を結ぶ枝の重みが正となるように、

$$w(i, j) = 1 + R(I^i, I^j) \quad (5)$$

表 1 CT 画像の仕様

スライス内画素数 [pixels]	512 × 512
スライス枚数 [枚]	263 ~ 538
画素サイズ [mm]	0.546 ~ 0.820
スライス厚 [mm]	0.400 ~ 0.800

として用いた。この手法では 2 分割を再帰的に行うことで、クラス多数は 1, 2, 4, 8, 16 のいずれかになる。また、クラスタの再分割の結果は分割前の結果に依存する。

Affinity Propagation 手法 [2,3] はメッセージ交換によりいくつかのクラスタの代表を決定し、学習用画像をクラスタリングする手法の一つである。具体的には、まず全ての n 個の画像間の類似度を計算し、 $n \times n$ の行列 S で表す。得られた類似度を利用し、式 (7),(8) より、responsibility と availability

$$r(i, k) \leftarrow S(i, k) - \max_{k', k' \neq k} \{a(i, k') + S(i, k')\} \quad (6)$$

$$a(i, k) \leftarrow \min\{0, r(k, k) + \sum_{i', i' \notin i, k} \max\{0, r'(i', k)\}\} \quad (7)$$

を反復的に調整する。ここで、 r, a はそれぞれ responsibility, availability を表し、 i, k はデータ番号である。 r と a は $n \times n$ の行列で、すべての成分の初期値は 0 とする。ある収束条件を満たしたら、式 (8) のように、この二つの行列を加え、新しい類似度行列 E

$$E(i, k) = r(i, k) + a(i, k) \quad (8)$$

を得る。行列 E から、0 より大きい対角成分を選択し、この成分に対応する画像をいくつかのクラスタの代表画像として選択する。上記のようにクラスタの代表画像を決めることで、クラスタ数も自動的に決定される。クラスタリングにおいて、クラスタリングする画像と全てのクラスタの代表画像の間の類似度を算出し、一番大きい類似度を持つクラスタに画像を分類することにより、学習画像のクラスタリングを行う。Normalized Cut と比べると、Affinity Propagation は事前にクラスタ数を決める必要はない。また、この手法は全ての学習データ間の情報交換によって適切なクラスタ数を決めることができる。

3. 実験および結果

実験に用いた CT 像の仕様を表 1 に示す。実験環境として、Intel(R) Xeon(R) W5590 3.33GHz × 2 プロセッサ、メモリ 24.0GB の計算機を使用した。本研究では、造影晚期相にて撮影された腹部 CT 像 100 例を用い、二つの類似度計算手法と二つのクラスタリング手法の四つの組み合わせについて実験を行った。100 例を 50 例ずつの二つの組 a, b に分け、2-fold cross validation により肝臓、腎臓、膵臓、脾臓の抽出結果について評価を行った。評価尺度には一致度

$$\text{一致度} = TP / (TP + FP + FN) \times 100\% \quad (9)$$

を用いた。TP, FP, FN はそれぞれ、抽出画素数、過抽出画素数、未抽出画素数である。ここで、IMED を類似度尺度とし




図 1 a 組 (50 個) の画像間における画像間類似度 (2450 個) の頻度。ここで、類似度の範囲は 0 ~ 1 である。x 軸と y 軸がそれぞれ類似度の範囲と各範囲内における画像間類似度の頻度を表す。

て用いた場合、計算時間を短縮するため、実験用の画像サイズを $32 \times 32 \times 32$ に縮小した。クラスタ数が 4 の場合の各手法の組み合わせを用いて得られた抽出結果を表 2 に示す。a 組を学習用にする場合、クラスタリングした後各クラスタ内の学習データ数が表 3 である。これに対応するテスト組 b を抽出する時選択されたクラスタの結果を表 4 に示す。

図 1 は二つの類似度計算方法により得られた a 組の 50 個の画像間の類似度のヒストグラムを示す。図 2 に NCC+Normalized Cut を使う場合、各クラスタ内の全ての学習画像のラベル画像を重ね合わせた結果を示す。図 3 は IMED+Affinity Propagation を使った場合である。図 4 は IMED+Affinity Propagation と NCC+Normalized Cut の二つの手法を用いて得られた膵臓抽出結果と対応するアトラスの一例を示す。

4. 考 察

表 2 から、NCC を画像間類似度の計算手法として用いた場合、得られた脾臓、膵臓、腎臓の一致度が、IMED を用いた場合より低いことが分かる。これは、NCC を用いて計算した類似度が多くの画像において特定の値付近に偏ってしまうため、NCC を用いた場合はクラスタリング結果が最適ではないと考えられる。すなわち、全ての画像間の類似度が近い場合、類似していない画像同士を同じクラスに分類する可能性が高い。図 1 の (a) に見られるように、NCC により計算した類似度がほぼ 0.96 ~ 1 の小さい範囲に集中していることが分かる。

表 2 から、IMED+Affinity Propagation の組が四つの臓器全体に対して一番良い抽出結果が得られることが分かる。原因としては、IMED が画像間の微小な違いに影響されないため、微小な差異しかない画像同士がすべて同じクラスに分類され、大きく異なる画像は他のクラスに分類されることになる。ここから得られたクラスタリング結果は、クラスタ内の画像同士は類似しており、異なるクラスタの間で差が大きいということであり、より良いクラスタリング結果が得られる。図 2 の NCC+Normalized Cut により得られた四つのクラスタ内の全ての学習画像のラベル画像を重ね合わせて得られた領域、特に (d) に丸で囲んだ部分に見られるように、肝臓の右上部分と膵臓の右下部分に小さい凸状領域が出ている。これはクラスタ内にほかの画像同士と類似していない画像が存在しているため、重ね合わせて得られた画像の臓器領域の表面がこのように

表 2 クラスタリング手法と類似度計算手法の組み合わせにおける臓器領域抽出結果の一致度.

クラスタリング手法	類似度計算手法	肝臓	脾臓	膀胱	腎臓
Normalized Cut	NCC	89.0%	74.5%	42.1%	80.8%
	IMED	90.9%	80.4%	43.5%	83.9%
Affinity Propagation	NCC	89.2%	76.0%	39.6%	80.6%
	IMED	91.0%	79.8%	45.8%	84.8%

表 3 a 組 (50 個) を学習データとして利用しクラスタリングを行った時に各クラスターへ分類された学習データ数.

クラスタリング手法	類似度計算手法	cluster1	cluster2	cluster3	cluster4
Normalized Cut	NCC	14	14	11	11
	IMED	16	9	9	16
Affinity Propagation	NCC	10	19	11	10
	IMED	6	2	34	8

表 4 a 組を学習データ, b 組 (50 個) をテストデータとして, テストデータの臓器抽出を行う際に各クラスターのアトラスが使用された回数.

クラスタリング手法	類似度計算手法	cluster1	cluster2	cluster3	cluster4
Normalized Cut	NCC	38	3	4	5
	IMED	33	0	1	16
Affinity Propagation	NCC	3	4	17	26
	IMED	0	1	49	0

なった. これと比較すると, 図 3 に示すように IMED+Affinity Propagation により得られた四つのクラスターのラベル画像を重ね合わせて得られた領域には, 図 2 の (d) のような小さなみ出し領域がなく, また肝臓と膀胱の辺縁と表面がより滑らかになり, 膀胱の形が解剖学的な構造に近いことが分かる. これは, IMED+Affinity Propagation により得られた四つのクラスター内の画像間類似度が NCC+Normalized Cut により得られた四つのクラスター内の画像間類似度より高く, 類似した画像がクラスター内集めたためである. そのため, IMED+Affinity Propagation は今回用いた組み合わせの中で最も有効と考えられる.

図 4 は IMED+Affinity Propagation と NCC+Normalized Cut の二つの手法を用いた膀胱抽出結果と抽出に用いたアトラスの一例である. 図から IMED+Affinity Propagation を用いて構築されたアトラスの領域は膀胱の正解領域に類似していることが分かる. その一方, 表 3 を見ると, IMED+Affinity Propagation を用いて得られた cluster3 が 34 個と多くの学習画像数を含んでいることが分かる. そのため, cluster1, cluster2 と cluster4 に含まれる学習データ数が cluster3 より非常に少なく, この三つのクラスターにおいてアトラスが持つ情報が特定の症例に依存しているため, 臓器抽出において, 平均的な臓器構造を持つ cluster3 のアトラスを選択する傾向がある. 表 4 に見られるように, 50 個の画像の内 49 個が cluster3 を選択して抽出を行う. そのため, 大量の学習データを追加し, 再検討する必要がある. また, 表 4 に見られるように, IMED+Affinity Propagation を用いた場合に, 1 例の CT 像 (以降 CT 像 X) だけが cluster2 を用いて臓器抽出を行っていた. 図 5 に CT 像 X と cluster2,3 の平均画像の Sagittal 断面を示す. 図から, CT 像 X と cluster2 の平均画像の頭尾方向の撮影範囲が類似し

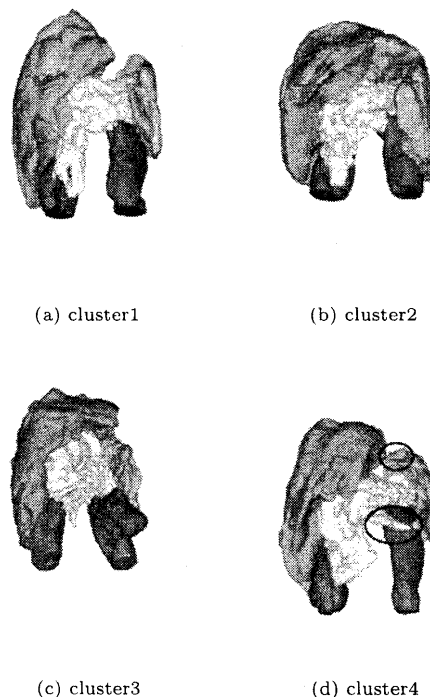


図 2 a 組を学習データとし, NCC+Normalized Cut により得られた四つのクラスターにおいて, クラスター内の全てのラベル画像を重ね合わせて得た領域.

ていることがわかる. しかし, CT 像 X と cluster3 の平均画像の頭尾方向の範囲はずれている. そのため, 類似度を計算する時, CT 像 X と cluster3 の類似度が低くなった. そこで, 撮影範囲の影響を減少するため, 体格正規化手法と類似度計算手法について検討を行う必要がある.

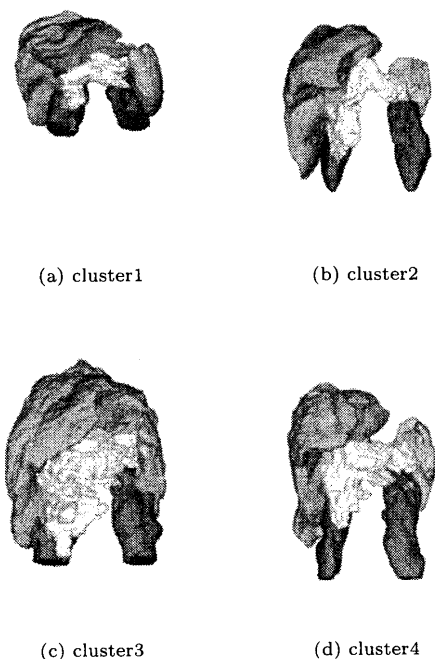


図3 a組を学習データとし、IMED+Affinity Propagationにより得られた四つのクラスタにおいて、クラスタ内の全ての学習画像のラベル画像を重ね合わせて得た領域。

また、IMEDは画像間の類似度を計算する際、計算量が膨大になるという欠点がある。式(1)から、大きさが $N \times M \times L$ の画像において、距離尺度 G の大きさは $(N \times M \times L) \times (N \times M \times L)$ になる。例えば、CT像のサイズが $512 \times 512 \times 512$ の場合、 G は $(512 \times 512 \times 512) \times (512 \times 512 \times 512)$ 、すなわち $2^{27} \times 2^{27}$ の巨大な行列となる。本研究では計算時間を短縮するため、CT像の画像サイズを $32 \times 32 \times 32$ に縮小し扱っているが、縮小によって画像上の有用な情報が失われている。そのため、画像の縮小サイズの検討が必要である。

膵臓の抽出については、IMED+Affinity Propagation手法により得られた膵臓の抽出精度は、NCC+Normalized Cutにより得られた結果と比べると約3%向上したが、他の臓器抽出一致度と比べると依然として低い。原因としては、膵臓の形状が他の臓器と比較すると個人間の差が大きく、膵臓の体積は他の臓器と比較して小さいため、アトラスに膵臓の位置と形状が反映されにくいことが挙げられる。実験に用いた症例は発泡剤によって胃を拡張した状態で撮影したものであるが、胃の中の気体の量に個人間の差があった。そのため、胃の拡張により膵臓の位置が大きく変化し、アトラスに膵臓の位置が反映されにくかったと考えられる。様々な膵臓の位置を複数アトラスで表現することができれば、膵臓の抽出一致度を向上させることが可能である。そのため、さらに多くの症例を学習に用いることとクラスタ数を増加させることが必要である。

膵臓の境界部分、特に他の臓器と接触している部分が粗抽出の際に他の臓器領域として誤って抽出されてしまう場合が多い。また、精密抽出を行う時、グラフカットにより粗抽出において

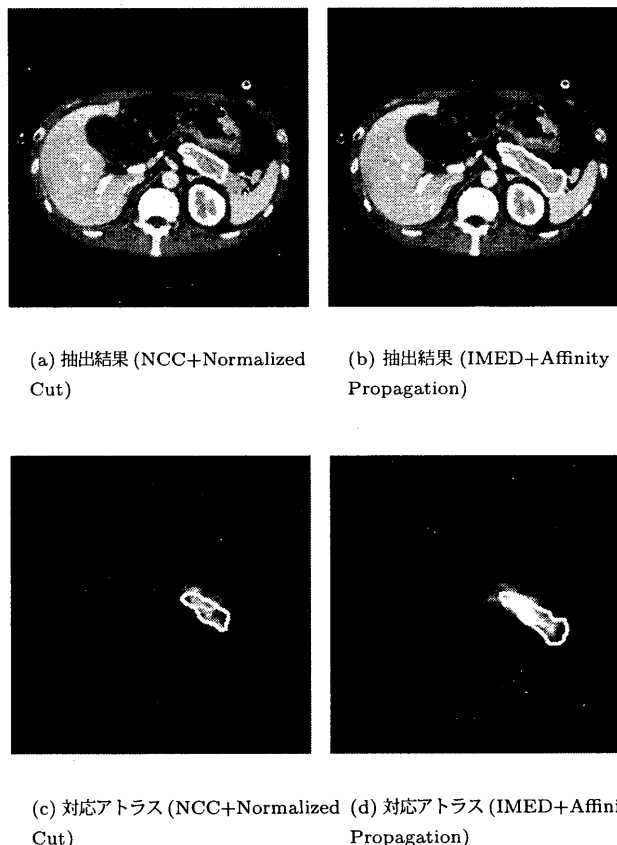


図4 IMED+Affinity Propagation手法により膵臓抽出精度が向上した例。NCC+Normalized Cutにより得られた膵臓領域の一致度が53%であり、IMED+Affinity Propagation手法により得られた膵臓領域の一致度が73%である。(c)(d)は抽出に用いられた臓器存在尤度アトラスであり、輝度値が高いほど存在尤度が高い。

得られていた膵臓領域の一部を削除する場合があった。図5に示すように、肝臓と隣接した膵臓の一部を粗抽出において肝臓として誤抽出している。さらにグラフカットを用いた精密抽出において、膵臓の一部を削除し、膵臓の一致度が低くなった(14%)。そのため、臓器の粗抽出および精密抽出について改善する必要がある。

5. むすび

本研究は複数アトラスを用いた臓器抽出手法を用い、IMEDとNCCの二つの類似度計算手法、またAffinity PropagationとNormalized Cutの二つのクラスタリング手法の全ての四つの組み合わせを用いて、アトラスを作成し、肝臓、腎臓、脾臓、膵臓の抽出実験を行った。実験結果では、Affinity Propagation+IMED手法で最も良い結果が得られた。この結果はアトラスに基づく臓器セグメンテーション処理においてアトラスを作成する際の画像選択の重要性も示唆している。今後の課題として、学習データ数を大幅な追加とクラスタ数を増加させた実験、膵臓の抽出率を改善するため膵臓領域の抽出手法の再検討などが挙げられる。





図 5 CT 像 X(左), cluster2 の平均画像(中), cluster3 の平均画像(右) の Sagittal 断面図。
図の中の線は画像中に写っている人体の範囲を示す。



(a) 正解領域 (b) 粗抽出結果 (c) 精密抽出結果

図 6 粗抽出で得られていた膵臓領域が精密抽出において失われた例。細い線で囲んである部分は肝臓領域, 太い線で囲んである部分が膵臓領域である。この症例の膵臓領域の一致度は 14% である。

謝辞 謝辞日頃から熱心に御討論頂く名古屋大学森研究室の諸氏に感謝する。本研究の一部は、日本学術振興会科学研究費補助金、国立がん研究センターがん研究開発費、愛知県「知の拠点」、栢森情報科学振興財団研究助成金によった。

文 献

- [1] H. Park, P.H. Bl, and C.R. Meyer, "Construction of an abdominal probabilistic atlas and its application," IEEE Trans. on MI, vol.22, no.4, pp.483-492, 2003.
- [2] 横田圭太, 岡田俊之, 中本将彦, 堀雅敏, 中村仁信, 佐藤嘉伸, "臓器間の隣接関係を考慮した統計的形状モデルを用いた 3 次元 CT 画像からの階層的複数臓器抽出," MI2007-70, pp.43-46, 2008.
- [3] P. Aljabar, R.A. Heckemann, A. Hammers, J.V. Hajnal, and D. Rueckert, "Multi-atlas based segmentation of brain images: Atlas selection and its effect on accuracy," NeuroImage, vol.46, pp.726-738, 2009.
- [4] 中岡輝久, 他: 臓器存在尤度アトラスとグラフカットを用いた腹部 3 次元 CT 像からの臓器領域抽出, 電子情報通信学会技術研究報告, MI2010-123(2011-1), pp.223-228.
- [5] J. Shi, and J. Malik, "Normalized cuts and image segmentation," IEEE Trans. on PAMI, vol.22, pp.888-905, 1997.
- [6] Liwei Wang e.t. : On the Euclidean Distance of Images, IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE, vol.27, No.8, pp.1334-1339, 2005.
- [7] Feng shi e.t. : Construction of multi-region-multi-reference atlas for neonatal brain MRI segmentation, NeruoImage, vol.51, pp.684-693, 2010.
- [8] Frey,B.J., Dueck,D.: Clustering by passing messages between data points, Science, vol.315, pp.972-976, 2007.
- [9] A. Guimond, J. Meunier, and J.P. Thirion, "Average brain models: A convergence study," Computer Vision and Image Understanding, vol.77, no.77, pp.192-210, 1999.
- [10] A.P. Dempster, N.M. Laird, and D.B. Rubin, "Maximum likelihood from incomplete data via the em algorithm," Journal of the Royal Statistical Society, B, vol.39, no.1, pp.1-38, 1977.
- [11] Y. Boykov, and M.P. Jolly, "Interactive graph cuts for optimal boundary and region segmentation of objects in n-d images," ICCV, pp.105-112, 2001.
- [12] N. Komodakis, and G. Tziritas, "Approximate labeling via graph-cuts based on linear programming," IEEE Trans. on PAMI, vol.29, pp.1436-1453, 2007.
- [13] Y. Boykov, O. Veksler, and R. Zabih, "Efficient approximate energy minimization via graph cuts," IEEE Trans. on PAMI, vol.20, no.12, pp.1222-1239, 2001.
- [14] V. Kolmogorov, and R. Zabih, "What energy functions can be minimized via graph cuts?," IEEE Trans. on PAMI, vol.26, pp.147-159, 2002.