

グラフィカルモデルにより表現する臓器表面の 3次元画像へのレジストレーションの高精度化

渡辺 航^{†1} 山岡 尚 登^{†1}
本谷 秀 堅^{†1} 渡邊 順 久^{†2}

本稿では、臓器表面の統計点群モデルと3次元画像をレジストレーションする手法の高精度化について報告する。提案法では、グラフィカルモデルにより臓器表面を表現し、ノンパラメトリック確率伝播法により各点の位置の周辺事後分布を推定する。そのため、レジストレーションができるだけでなく、その確度を各点で推定できる。ただし、モデルの構築法に依存して推定精度は変化する。本稿では、特にグラフィカルモデルを構築する際の学習サンプルに含まれる誤りとサンプル数が少ないことがモデルに与える影響を述べる。また、それら影響を克服することにより、推定を高精度化することを示す。X-CT画像中の肝臓を対象とした実験結果により精度向上を定量評価したので報告する。

Improvement of registration of a organ surface represented by a graphical model to 3D images.

WATARU WATANABE,^{†1} NAOTO YAMAOKA,^{†1}
HIDEKATA HONTANI^{†1} and YORIHISA WATANABE^{†2}

In this article, we propose an model-to-image registration method. The method represents organ surface by using a graphical model, and registers model by estimating the marginal posterior distribution of the location of each point by means of non-parametric belief propagation. This enables us to estimate not only the location of the registered surface but also the confidence of the estimated locations. However, performance of estimation changes depending on the accuracy of the constructed model. In this article, we study on the in-accuracy of the registration method under the condition that we can use only small number of samples for model construction. Then, we show some method for improving the performance of the registration. Experimental results showed that the method successfully improved the registration accuracy.

1. はじめに

3次元医用画像中からの臓器領域の自動抽出は、医療診断システムに必須の機能である。また、多数の画像のそれぞれから臓器領域を自動的に抽出できれば、その結果に基づいて臓器の大きさや体積、形状などに関する大規模な統計モデルを構築できる可能性がある¹⁾。このため、臓器抽出の手法は多数提案されており、その中の多くは、臓器表面のモデルと画像のレジストレーションにより実現されている。

レジストレーションの精度は画像のSN比や臓器の境界付近における明暗のコントラスト、臓器の形状の多様性などに依存して変化する。このため、レジストレーションの精度は部位ごとに異なりうる。診断支援を目的とする場合でも、レジストレーションの結果に基づき臓器に関する統計を求める場合においても、抽出された臓器領域の精度を評価することは極めて重要である。本研究の目的は、レジストレーション精度を臓器の各部位で見通しよく推定する手法を開発することである。

画像と臓器表面のモデルのレジストレーションをおこなう場合、表面のモデルとして Point Distribution Model (PDM)²⁾ が広く用いられている。PDMは臓器表面上に配置された点群により対象の位置と形状を表現する。臓器表面モデルを画像にレジストレーションする際には、モデルの各点の画像中の位置を推定する。先に述べたとおり、本研究の目的はモデルをレジストレーションするだけでなく、レジストレーションの確度を自己評価できる手法を構築し、その精度を高めることである。従来より、PDMを利用したレジストレーション法は多数提案されているが、それら手法はレジストレーションの部位ごとの確度を自己推定することができない。例えばPDMを利用したレジストレーション法として広く採用されている手法に Active Appearance Model(AAM)³⁾がある。AAMに基づく手法³⁾⁴⁾⁵⁾は対象全体の形状とアピアランスを部分空間で表現し、与えられたデータとの残差を最小化することにより、対象の位置と形状を推定する。その推定性能の高さから臓器や顔のレジストレーションに広く利用されているが、位置や形状は点推定されるのみであり、部位ごとの推定誤差の自己評価はできない。

提案法はPDMを利用したレジストレーションをおこなう際に、モデルの各点の位置を点

^{†1} 名古屋工業大学
Nagoya Institute of Technology

^{†2} 山形済生病院
Yamagata Saisei Hospital

推定するのではなく、事後分布を推定する。そのために各点に関する統計モデルをグラフィカルモデルで表現し、事後分布の算出には、ノンパラメトリック確率伝播法 (Non-Parametric Belief Propagation: NBP)⁶⁾ を利用する。推定された事後分布の分散の大きさは各点の推定位置の確度を反映する。本稿では、提案法による臓器表面のレジストレーションについて報告する。

提案法では、臓器の統計モデルを学習サンプルから推定する。推定される統計モデルの精度は学習サンプル数に依存する。医用画像処理の分野において十分な数のサンプルを得ることは困難であり、このため、分布を表現する関数型の妥当性を評価したり正確に関数のパラメータの値を推定したりすることが難しい。

本稿では、学習サンプルが少ない場合の統計モデルに基づいたときのレジストレーションの性能の低下について報告するとともに、統計分布の裾野を広げるなどの工夫によりレジストレーションの性能を向上させることができることを報告する。

2. モデルの構築

2.1 概 略

提案法では、臓器表面を N 点 $\{P_j | j = 1, 2, \dots, N\}$ で表現する。点 P_j の位置を x_j であらわす。 x_j は確率変数であり、 x_j を節とするグラフィカルモデルにより臓器モデルを表現する。グラフィカルモデルは、確率変数間の条件付独立性をグラフであらわしたものである⁷⁾ すなわち、二つのノードが辺で結ばれていなければ、対応する二つの確率変数は条件付独立である。

モデルの構築のために、まず、学習用の 3 次元 CT 画像を M 症例用意する。学習用画像から対象とする臓器表面を手作業で抽出し、体型の位置・形・大きさの正規化を行うことで、正規化後の 3 次元座標系における臓器表面のデータを得る。正規化後の画像の集合を $\mathcal{I} = \{I^i | i = 1, 2, \dots, M\}$ であらわし、画像 I^i 中の対象臓器表面を S^i であらわす。次に、各 S^i 上に対応点 $\{P_j^i | j = 1, 2, \dots, N\}$ を配置する。得られた対応点に基づき、グラフィカルモデルの構造を決定・構築し、各点の座標 x_j に関する統計モデルを学習する。次節では、対応点を自動的に配置する方法について説明する。

2.2 Generalized Multi Dimensional Scaling

Generalized Multi Dimensional Scaling (GMDS)⁸⁾⁹⁾ による対応点の自動配置法について説明する。GMDS は、与えられた二つの曲面上に、点間の測地距離ができるだけ保存されるように対応点を配置する。与えられた二つの曲面を X と Y であらわす。また、 X 上の

点 x_i から Y 上の点 y'_i への写像を f とあらわす。すなわち $y'_i = f(x_i)$ である。 X 上の二点 x_i と x_j の測地距離を $d_X(x_i, x_j)$ であらわし、 Y 上の二点 y_i と y_j の測地距離を $d_Y(y_i, y_j)$ であらわす。このとき、GMDS は X 上の点 x_1, \dots, x_N に対し、下記コスト関数 σ を最小とする Y 上の点 y'_1, \dots, y'_N を求める。

$$\sigma_p(y'_1, \dots, y'_N) = \sum_{i>j} \left| d_X(x_i, x_j) - d_Y(y'_i, y'_j) \right|^p \quad (1)$$

提案法は、 X 上の x_i と GMDS が最終的に得た Y 上の点 y'_i を対応点とみなす。

2.3 臓器表面の統計モデルの学習

学習用の臓器表面 S^i 上に配置された対応点に基づき曲面の統計モデルを構築する。先に述べたとおり、統計モデルはグラフィカルモデルで表現する。本稿のモデルでは、各点の位置 x_j は、次の二つの変数に依存すると仮定する。すなわち、(a) x_j 近傍の局所的なアピアランス I_j と (b) 隣接する点 x_k の座標である。(a) に関しては、 I_j は x_j に従う観測変数であるため、後に述べるポテンシャル関数 $\psi(x_j, I_j)$ を用いて表現する。(b) に関しては、ここでは曲面上で離れている二点の位置の独立性を仮定し、二点間の平均距離 d_{jk} が閾値より小さければ、対応する二つの節 x_j と x_k を辺で結ぶことで表現する。

上記の構造を持つグラフィカルモデルは以下の三つの確率分布 $p(x_j)$, $p(I_j | x_j)$, $p(x_j - x_k)$ で記述することができる。

- P_j の位置に関する事前分布 $p(x_j)$ 。
- P_j 周辺の局所画像のアピアランスの分布 $p(I_j | x_j)$ 。
- 隣接する P_j と P_k の相対位置関係に関する確率分布 $p(x_j - x_k)$ 。

これらの確率モデルは、学習サンプルの臓器上に配置した対応点群に基づき推定する。

3. 新規画像とのレジストレーション法

新規に画像が与えられたとき、提案法はまず、体型を正規化した画像 I を得る。次に、 I 上でのモデルの各点の位置を推定することにより、モデルと新規画像中の臓器表面のレジストレーションをおこなう。各点の位置の周辺事後分布 $p(x_i | I)$ が計算されるため、位置推定だけではなく推定の確度も自動的に推定されることになる。まず、各点の位置 x_i とその近傍のアピアランス I_i の同時分布について、次式が成り立つ。

$$p(\{x_i\}, \{I_i\}) = \prod_i \psi_i(x_i, I_i) \prod_{e_{ij} \in \mathcal{E}} \psi_{i,j}(x_i, x_j), \quad (2)$$

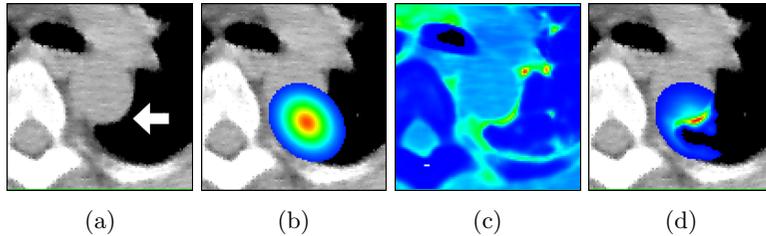


図 1 大動脈を対象とする $\psi(\mathbf{x}_i, I_i)$ の計算例．左から順に元画像 I ，事前分布 $p(\mathbf{x}_i)$ ，尤度分布 $p(I_i|\mathbf{x}_i)$ ，ポテンシャル分布 $\psi(\mathbf{x}_i, I_i)$ ．元画像中の矢印は対応する点の真の位置を示す．

Fig.1 An Examples of computation of $\psi(\mathbf{x}_i, I_i)$

ただし， $\psi_i(\cdot, \cdot)$ ， $\psi_{i,j}(\cdot, \cdot)$ は，次に示すように，各点ごとの配置のポテンシャル，及び，隣接する点どうしの相対位置のポテンシャルを表している．

$$\psi_i(\mathbf{x}_i, I_i) = p(\mathbf{x}_i)p(I_i|\mathbf{x}_i), \quad (3)$$

$$\psi_{i,j}(\mathbf{x}_i, \mathbf{x}_j) = p(\mathbf{x}_i - \mathbf{x}_j). \quad (4)$$

ここで，提案法におけるレジストレーション法の概略を説明する．まず，式 (3) に従い，与えられた画像 I における各対応点の位置の分布のポテンシャル $\psi_i(\mathbf{x}_i, I_i)$ を計算する．式 (3) 右辺の $p(\mathbf{x}_i)$ は点 P_i の位置に関する事前分布でありモデルとして保有している．一方 $p(I_i|\mathbf{x}_i)$ は位置に関する尤度分布であり，局所的なアピアランスに関する分布 $p(I_i|\mathbf{x}_i)$ に基づき画像より算出される．

図 1 に大動脈のレジストレーション結果¹⁰⁾ における $p(\mathbf{x}_i)$ ， $p(I_i|\mathbf{x}_i)$ ，及び $\psi_i(\mathbf{x}_i, I_i) = p(\mathbf{x}_i)p(I_i|\mathbf{x}_i)$ の例を示す．事前分布と尤度分布の表現には，後に第 4 章に示すとおり正規分布を利用している．図に示すとおり，事前分布と尤度分布の積は大動脈壁に沿った分布となっており，点 P_i の位置推定として妥当な結果を得ることができている．ただし，ポテンシャル $\psi_i(\mathbf{x}_i, I_i)$ の計算には，臓器形状を表現する $p(\mathbf{x}_i - \mathbf{x}_j)$ (式 (4)) の情報を利用していない．そこで，次に，式 (4) も利用して各点の分布を推定する．推定にはノンパラメトリック確率伝播法 (NBP)⁶⁾ を用いる．

以下，推定法を説明する．NBP では，グラフィカルモデルにおけるノード間でメッセージを交換しながら，周辺事後分布の推定結果を更新する． n 回目の更新時における特徴点の確率分布を $\hat{p}^n(\mathbf{x}_i|I)$ とあらわす． $\hat{p}^n(\mathbf{x}_i|I)$ は，ポテンシャル $\psi_i(\mathbf{x}_i, I_i)$ と，隣接するノードから送信されるメッセージ m_{ki}^n を用いて，次式のように計算する．

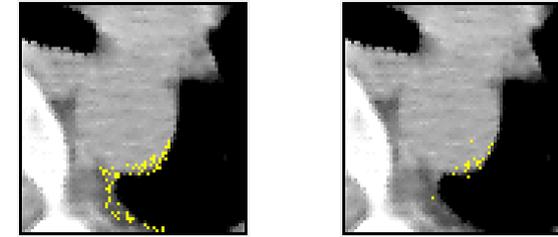


図 2 確率伝播法による分布の変化．(a) ポテンシャル分布 $\psi(\mathbf{x}_i, I_i)$ ，(b) 確率伝播法により得られた周辺事後分布
Fig.2 The change of the probability distributions made by an NBP.

$$\hat{p}^n(\mathbf{x}_i|I) \propto \psi_i(\mathbf{x}_i, I_i) \prod_{e_{ki} \in \mathcal{E}} m_{ki}^n(\mathbf{x}_i), \quad (5)$$

NBP では，上記メッセージをノンパラメトリックに表現する．提案法では，文献⁶⁾ と同様に，メッセージを混合ガウスモデルを用いて表現する．メッセージ m_{ki} は次式のようにあらわすことができる．

$$m_{ki} = \sum_{\alpha=1}^W w_{ki}^{(\alpha)} \mathcal{N}(\mathbf{x}_i; \mu_{ki}^{(\alpha)}, \Sigma_{ij}), \quad (6)$$

ここで， W はガウス分布の混合数， α は各ガウス分布のラベルを表している．それぞれのガウス分布は w_α によって重み付けされる．すなわち，各メッセージは， $\{w_{ki}^{(\alpha)}, \mu_{ki}^{(\alpha)}, \Sigma_{ij} | \alpha = 1, 2, \dots, W\}$ で定義されるパーティクルの集合であらわすことができる．各ノードは，隣接するノードからメッセージを受信する．次に，受信したメッセージを用いて式 (5) を計算し，推定位置 $\hat{p}^n(\mathbf{x}_i|I)$ の更新を行う．メッセージと同様，推定位置 $\hat{p}^n(\mathbf{x}_i|I)$ も，混合ガウスモデルを用いたノンパラメトリックな表現を採用する．

$$\hat{p}^n(\mathbf{x}_i|I) = \sum_{\alpha=1}^W w_{ki}^{(\alpha)} \mathcal{N}(\mathbf{x}_i; \mu_i^{(\alpha)}, \Sigma_i). \quad (7)$$

ここで，各ガウス分布の共分散行列 Σ_i は，各点の分布ごとに推定をおこなう⁶⁾

$$\Sigma_i = \frac{1}{W^{1/n}} \frac{1}{W-1} \sum_{i=1}^W (\mu_i - \bar{\mu})(\mu_i - \bar{\mu})^T \quad (8)$$

ここで n は経験的なパラメータであり、本稿では、文献⁶⁾と同じく $n = 3$ とした。

図 2 に大動脈のレジストレーションにおける、周辺事後分布の計算結果を示す。図 2(a) に推定事後分布の初期値を示す。先に述べたように、推定事後分布の初期値は、ポテンシャル $\psi(x_i, I_i)$ (図 1(d)) よりサンプルされたものである。図 2(b) に、NBP による周辺事後分布の計算結果を示す。NBP により転換の相対位置関係 $p(x_i - x_j)$ も考慮した確率分布を計算できるため、結果として推定位置が真の大動脈表面に局在化したことが分かる。図に示すように、NBP では周辺事後確率をパーティクルの集合で表現する。最終的な推定位置の決定には例えば分布の期待値を利用することができる。また、レジストレーションの精度はパーティクルの分散により推定することができる。

4. 統計モデルとレジストレーションの精度

本節では、統計モデルを正規分布で表現した場合の推定方法について説明する。次に、サンプル数が少ないことが統計モデルの推定に影響を与えた例を示し、その解決方法について説明する。

4.1 正規分布による統計モデルの表現

先に著者らが提案した手法では、モデルの各点の位置 $p(x_j)$ と点近傍のアピアランス $p(I_j|x_j)$ を正規分布で表現していた。事前分布を正規分布で表現するなら次式ようになる。

$$p(x) = \mathcal{N}(\cdot; \bar{x}_j, \Sigma_j). \quad (9)$$

\bar{x}_j, Σ_j が学習サンプルより推定すべきパラメータであり、位置 x_j の対応点の平均と分散をあらわす。

モデルの各点を中心とする局所的な立方体内のアピアランスを I_j であらわす。 $p(I_j|x_j)$ は画像より点 P_j を抽出するときに利用できる。局所アピアランス I_i の分布を正規分布で表現するなら次式ようになる。

$$p(I_j|x_j) = \frac{1}{Z} \exp \left\{ \sum_{d=1}^{L_j} \frac{\Delta_d^2}{\lambda_d} \right\}. \quad (10)$$

ただし、 $\Delta_d = (I_j - \bar{I}_j)^T v_j^d$ であり、 $\bar{I}_j = \sum_i I_j^i / M$ である。また Z は正規化の係数である。分散 λ とベクトル v_d は学習用サンプル $\{I_j^i | i = 1, 2, \dots, M\}$ の共分散行列より求める固有値と固有ベクトルである。 λ は固有値の降順に並んでおり、次元 L_j は奇与率を参照して決定する。

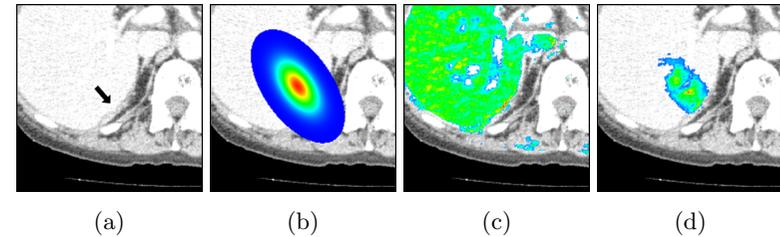


図 3 肝臓におけるポテンシャル $\psi(x_i, I_i)$ の計算
Fig. 3 Computation of the potential distribution ψ in a liver registration.

4.2 正規分布採用時の肝臓のレジストレーション

35 症例の学習サンプルに基づき、式 (9)、式 (10) の平均と分散を推定したときの肝臓表面のレジストレーションの結果を本節で報告する。図 3(a) に示す位置の点の事前分布 $p(x_i)$ 、尤度分布 $p(I_i|x_i)$ 、ポテンシャル $\psi(x_i|I_i)$ をそれぞれ同図 (b)(c)(d) に示す。図 1 に示した大動脈と比較して、肝臓は位置や形状が患者ごとに大きく異なることが知られており、その多様性を 35 症例の学習サンプルでは学習しきれない。また、そもそも正規分布が事前分布などを表現する関数として適しているかどうか未検証である。

図 3 の例では、同図 (c) に示すとおり尤度分布が肝臓表面だけではなく肝臓内部でも高い値を有しており、肝臓表面を適切に選択できていない。このため同図 (d) に示すポテンシャルの分布は同図 (b) に示す事前分布により、ほぼ決定されている。このことは画像から点の位置に関する情報をほとんど取得できていないことを意味しており、本来肝臓表面に位置する点 P_i のポテンシャルが、肝臓表面から大きく内部に離れた位置にピークを持つ分布になっている。手作業で確認すると、図 3(b) に示す事前分布 $p(x_i)$ に対して、真の P_i はおおそ 2σ に位置していた。このことは事前分布の分散が過小評価されている可能性を示唆する。他の点についても事前分布に対する正しい点の位置を確認したところ、図 3 に示した例と同様に、分散 Σ の過小評価を示唆する例が散見された。

また、尤度分布 $p(I_i|x_i)$ は本来臓器表面に沿って局在化している分布になることが望ましく、しかし、実際には図 3(c) に示すように臓器表面を含む広範な領域でほぼ様な分布が得られることが多かった。これは肝臓周囲には他の臓器も密接しており、各点周囲のアピアランスが患者ごとに大きく異なるためである。例として図 3(a) に示した点近傍の学習サンプル中のアピアランスの例を図 4 に示す。対象臓器外部にも様々なテクスチャが存在していることが分かる。このような部位において、臓器表面のみに強く反応する抽出演算子を学

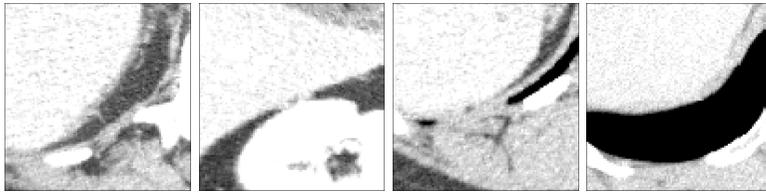


図 4 各症例における対応点周囲の画像
Fig. 4 Examples of local appearance I_j .

習サンプルのみに基づいて構築するためには、十分な学習サンプルが必要であると考えられる。十分な学習サンプルの収集が困難な場合には、アピアランスの多様性を抑える工夫をしなければならない。

4.3 事前分布の修正と画像の前処理

先に述べたとおり事前分布に正規分布を仮定するとき、肝臓では分散の過小評価が散見される。そこで事前分布に有界な一様分布を仮定する。

$$p(x) = \begin{cases} 1/Z & ((x - \mu)^T \Sigma^{-1} (x - \mu) < \text{th}) \\ 0 & \text{otherwise} \end{cases} \quad (11)$$

μ 及び Σ は対応点の平均と共分散をあらわす。また、 Z は正規化定数である。定義域は学習サンプルの分散に対して 2σ とした。この場合、 $\text{th} = 2$ である。

また、肝臓領域のみを強調し、肝臓表面近傍のアピアランスの多様性を抑えることができれば、尤度分布を肝臓表面に沿って局在化させる上で有用である。そこで本稿では文献¹¹⁾の手法を採用し、画素値に基づき肝臓領域内の強調処理をおこなう。このことにより腹膜や筋肉など肝臓外部のテクスチャの成分を削減することができる。肝臓領域の強調により、アピアランスの多様性を削減した画像の例を図 5 に示す。図 4 に示した画像と比較して、アピアランスの多様性を削減できていることが分かる。

提案法では、事前分布の分散の過小評価によるレジストレーション精度の低下を防ぐために、事前分布 $p(x_j)$ を一様分布で表現する。また、肝臓表面近傍のアピアランスの多様性を抑えるために、前処理として図 5 に示す肝臓領域の強調をおこなう。これらの分布に基づいて算出される事前分布 $p(x_i)$ 、尤度分布 $p(I_i|x_i)$ 、ポテンシャル $\psi(x_i|I_i)$ を図 6 に示す。図 3 と比較すると分かる通り、肝臓表面に局在化したポテンシャル $\psi(x_i|I_i)$ を得ることができている。

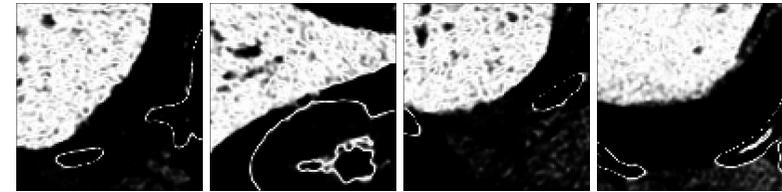


図 5 肝臓強調画像の場合の対応点周囲の画像
Fig. 5 Examples of local appearances in a liver-enhanced image.

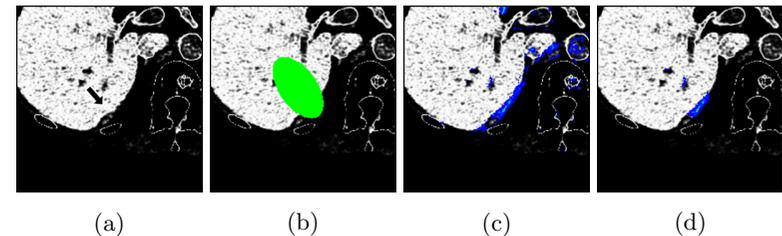


図 6 肝臓強調画像に対するレジストレーション
Fig. 6 An example of liver registration in a liver-enhanced image.

次節では、事前分布を正規分布で表現した場合と、一様分布に変更した場合のレジストレーション結果を比較する。また、肝臓強調画像を用いた場合のレジストレーションに関して調査した結果を報告する。

5. 実験結果

5.1 実験環境

本稿では、肝臓を対象に実験をおこなった。学習用に用意したサンプルの数は $M = 35$ 症例である。対象画像は造影 X-CT 画像（門脈相）であり、空間分解能は $[0.625\text{mm}, 0.625\text{mm}, 1\text{mm}]$ である。画像はあらかじめ体型の大きさ、撮影時の姿勢、位置を正規化しておく必要がある。本稿では、肋骨と背骨に外接する直方体を抽出し、重心と各辺の長さをそろえることで自動的に正規化をおこなった。次に、用意した画像をもとにモデルの学習をおこなった。まず、真の肝臓表面のデータ S^i を手作業で抽出し、次に $\{S^i | i = 1, 2, \dots, M\}$ 間の対応点を自動生成した。対応点の生成には GMDS 法を採用し、対応点の数 $N = 200$ とした。得られた対応点群に基づき統計モデルの構築をおこない、学習した統計モデルと新規画像

とのレジストレーションをおこなった．事前分布の修正と画像の前処理の効果を考察するため，以下の3種類の手法で実験をおこなった．

手法1 事前分布に正規分布を採用，画像に対する前処理なし

手法2 事前分布に一樣分布を採用，画像に対する前処理なし

手法3 事前分布に一樣分布を採用，肝臓強調画像を使用

上記手法におけるレジストレーションの結果を以下に示す．

5.2 レジストレーション結果の比較

まず，事前分布に正規分布を採用した場合のレジストレーション結果を図7に示す．図の上段にNBPにおける推定の初期値を示す．これは， $\psi_i(x_i, I_i)$ からサンプリングしたパーティクルであり，モデルの各点ごとにパーティクルの色を変えて図示したものである．また，図の下段はNBPにより計算した周辺事後分布 $\hat{p}^n(x_i|I)$ をあらわす．また，肝臓の真の表面を赤い曲線で示す．図7(a)に肝臓全体における推定の様子を示す．上段と下段を比較すると，各点の分布が局在化し推定の確度が高くなっていることが分かる．ただし，先に述べたように，肝臓の先端(画像右側)や，背面(画像下部)など，統計モデルの性能が低い部分では肝臓表面の抽出に失敗していることが分かる．図7(b)(c)(d)に，それぞれ異なる点のポテンシャル $\psi(x_i|I_i)$ と事後分布 $p(x_i|I_i)$ の推定結果を示す．図7(b)は肝臓の右側面の部位である．初期値の時点で比較的肝臓表面を抽出出来ている．また，推定事後分布の計算後には，周囲からの情報を受け取ることで肝臓表面のエッジに沿って推定位置の分散を小さくすることに成功した．図7(c)の上段では，肝臓の先端部分，及び隣接する肋骨の二箇所にパーティクルが配置されている．推定事後分布を計算すると，形状の情報により肋骨の部分は推定事後分布の値が低くなり，図7(c)の下段に示すように肝臓の先端部分のみにパーティクルが配置される．ただし，最終的な推定位置は肝臓の内部にあり，肝臓表面の位置推定に失敗している．図7(d)は前節の図3で示した点の推定結果である．この位置においても肝臓表面の位置を推定することに失敗した．

次に，画像に対する前処理をおこなわないまま，事前分布を一樣分布(式(11))に変更した場合(手法2)のレジストレーション結果を図8に示す．事前分布 $p(x_i)$ を一樣分布とすると，ポテンシャル $\psi(x_i|I_i)$ の分布が尤度分布により決定される．このため，事前分布を正規分布で表現していた場合と比較して，ポテンシャルの分布が肝臓表面により局在化されるようになった(図8)．この結果，正規分布の場合に比べ推定精度が向上した．肝臓の右側面(図8(b))では，図7(b)と比較して，ポテンシャルの分布が肝臓表面に局在化されていることが分かる．また，前節の図3で示した点の部位の推定結果を図8(d)に示す．事前

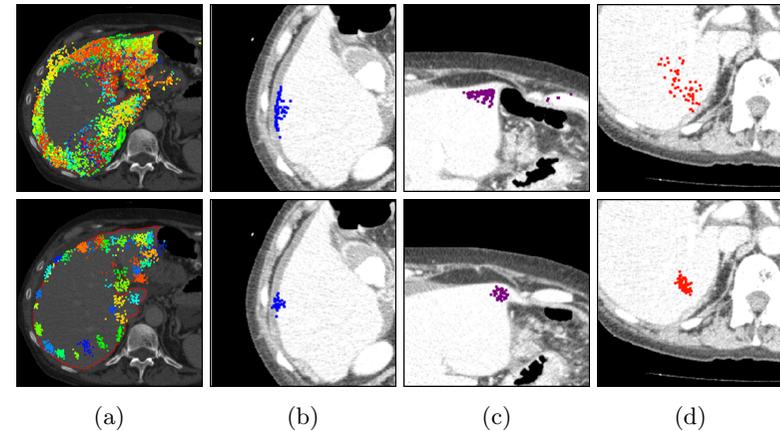


図7 事前分布に正規分布を採用した場合のレジストレーション結果．上段：初期推定位置．下段：NBPによる推定結果．

Fig. 7 Examples of posterior marginal distributions. Prior distribution is estimated as Gaussian distribution.

分布に正規分布を採用した場合(図7(d))と比較してポテンシャルの分布が肝臓表面により局在化されるようになったため，推定精度が改善した．ただし，図8(c)に示す肝臓の先端部位は局所的なアピアランスが患者ごとに大きく異なる部位であるため，尤度分布が肝臓表面を選択することに失敗した．結果として，レジストレーションの精度も他の部位と比べて低くなった．

次に，事前分布に一樣分布を採用し，かつ肝臓領域を強調する前処理をおこなった場合(手法3)の結果を図9に示す．前処理により腹膜などの内部組織の影響を削減した結果，図9(b)(d)に示すように尤度分布が肝臓表面に局在化してきた．そのため，図8(b)(d)に示した結果と比較して，より肝臓表面に沿った分布となっていることが分かる．また，図8(c)において推定に失敗した肝臓の先端部分においても，図9(c)に示すように肝臓表面の推定に成功した．

上記手法による推定精度を定量評価した結果を図10に示す．グラフの縦軸は，レジストレーションの誤差である．棒グラフは35症例での誤差の平均であり，黒線は35症例での誤差の最大最小をあらわす．レジストレーションの誤差は $E^i = \frac{1}{N} \sum_{j=1}^N \left| \hat{\mu}_j^i - \bar{\mu}_j^i \right|$ で測るも

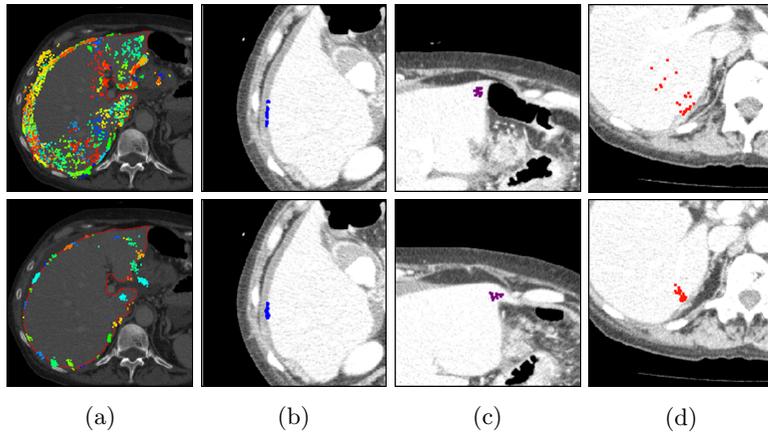


図 8 事前分布に一様分布を採用した場合のレジストレーション結果．上段：初期推定位置．下段：NBP による推定結果．

Fig. 8 Examples of posterior marginal distributions. Prior distribution is estimated as uniform distribution.

のとする．ここで、 $\hat{\mu}_j^i$ は推定事後分布の期待値、 $\bar{\mu}_j^i$ は推定位置から最も近い肝臓表面の位置をあらわす．定量評価の結果、事前分布に正規分布を採用した場合（手法 1）に比べ、一様分布を採用した場合（手法 2）の方が平均的に精度が向上することが分かった．また、肝臓を強調する前処理をおこなった場合（手法 3）に、誤差の平均、最大、最小の全てにおいて最も良好な結果を得ることができた．

5.3 推定誤差と確度の可視化

提案法では、レジストレーションをおこなうだけでなく推定事後分布を計算する．そのため、推定事後分布の分散を用いてレジストレーション結果の確度を場所ごとに計算することが可能である．推定誤差と確度の関係について、強調画像を使った推定結果を用いて説明する．図 9(b) に示すように、肝臓表面の推定精度が高い部位では、周辺事後分布が肝臓表面に沿って分布しており曲面の法線方向の分散は小さい．一方、図 9(d) に示した肝臓の先端部においては、9(b) の部位と比較して推定精度は低く、推定事後分布の分散は大きくなっていることがわかる．このような推定誤差と確度の相関について、肝臓表面全域について調査した結果を以下に示す．

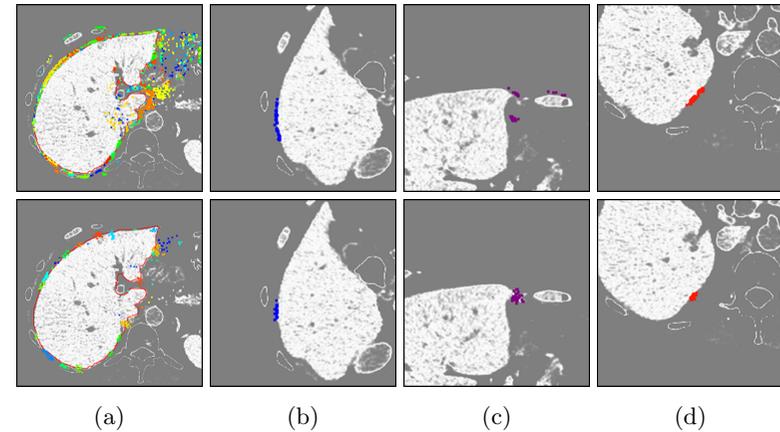


図 9 肝臓強調画像の場合のレジストレーション結果．上段：初期推定位置．下段：NBP による推定結果．

Fig. 9 Examples of posterior marginal distributions. Prior distribution is estimated as uniform distribution. Each image is converted to likelihood image.

まず、推定誤差を場所ごとに可視化した結果を図 11 に示す．それぞれ、同一の症例における結果を異なる視点から見た画像である．図 11(a) は肝臓の上部、図 11(b) は肝臓の底面である．誤差の大きい部分を赤で示した．図 11(a) に示すように、肝臓側面や上部のような形状及びアピランスの個人差が比較的小さい部位に比べ、肝臓の先端部分では誤差が大きくなっていることが分かる．また、図 11(b) に示すように、肝臓の底部のような、門脈や肝静脈の影響により入り組んだ形状になっている部分でも誤差は大きくなっている．

次に、図 12 に、推定事後分布の分散を場所ごとに可視化した結果を示す．肝臓の側面や上部など形状が滑らかな部分では分散が小さくなっている．反対に肝臓の先端や底面など、多様性が多い部位においては、分散が大きくなっている．図 11 において誤差が大きい場所では、図 12 において分散が大きくなっており、推定誤差と確度の間に相関があることが見てとれる．このように、レジストレーションをおこなうだけでなくレジストレーション結果の確度を場所ごとに計算できることは、医用診断支援システム、計算解剖学において重要である．

6. おわりに

本稿では、臓器表面のモデルと 3 次元画像をレジストレーションする手法を提案した．提

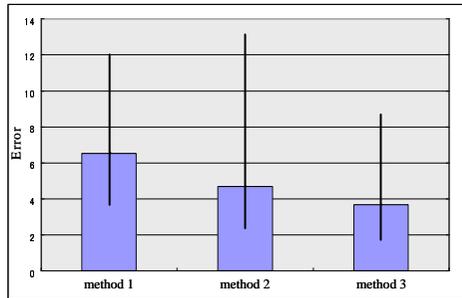


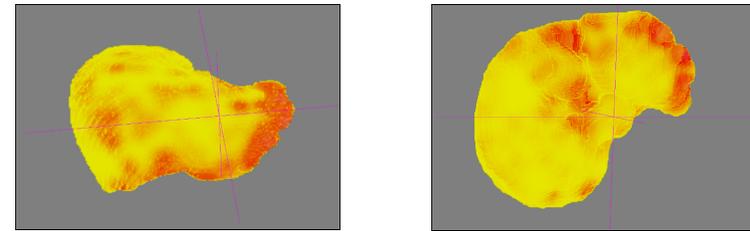
図 10 各手法における推定誤差の比較

Fig. 10 Comparison of estimation errors obtained by the three methods.

案法では、グラフィカルモデルにより臓器表面を表現し、ノンパラメトリック確率伝播法により各点の位置の周辺事後確率を推定する。そのため、対象臓器表面の位置を推定できるだけでなく、その確度を場所ごとに推定することができる。また、本稿ではサンプル数が少ない場合の統計モデルの挙動を調査し、その改善法を提案した。これにより、肝臓のレジストレーションにおいて、サンプル数が少ない場合でも高い精度で推定をおこなうことに成功した。今回は、事前分布とアピアランスの分布について改善をおこなった。形状の情報に関する手法の改善は今後の課題の一つである。

参 考 文 献

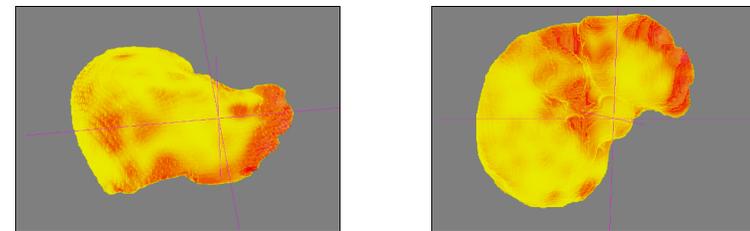
- 1) H.Kobatake et al.: Computational Anatomy, <http://www.comp-anatomy.org/wiki/>.
- 2) T.F.Cootes, C.J.Taylor, D.H.Cooper and J.Graham: Active Shape Models -Their Training and Application, *COMPUTER VISION AND IMAGE UNDERSTANDING*, Vol.61, pp.38-59 (1995).
- 3) Cootes, T.F., Edwards, G.J. and Taylor, C.J.: Active Appearance Models, *ECCV*, Vol.2, pp.484-498 (1998).
- 4) Langs, G., Peloschek, P., Donner, R., Reiter, M. and Bischof, H.: Active Feature Models, *ICPR 2006*, pp.417-420 (2006).
- 5) Donner, R., Langs, G., Micusik, B. and Bischof, H.: Generalized Sparse MRF Appearance Models, *Image Vision Comput*, Vol.28, pp.1031-1038 (2010).
- 6) T.Ihler, A., III, J.W., Moses, R.L. and S.Whisky, A.: Nonparametric Belief Propagation for Self-Localization of Sensor Networks, *IEEE Journal*, Vol.23, No.40, pp. 809-819 (2005).



(a) (b)

図 11 レジストレーション結果の部位ごとの誤差

Fig. 11 An example of the distribution of estimation errors.



(a) (b)

図 12 推定事後分布の分散：部位ごとの確度

Fig. 12 An example of the distribution of the estimated confidences of the estimates.

- 7) Bishop, C.: *Chapter 8 of Pattern Recognition and Machine Learning*, Springer (2006).
- 8) Bronstein, A.M., M.Bronstein, M. and Kimmel, R.: *NUMERICAL GEOMETRY OF NON-RIGID SHAPES*, Springer Verlag, Reading, Massachusetts (2008).
- 9) 山岡尚登, 渡辺 航, 本谷秀堅: 点群統計モデルのレジストレーションの性能と対応点生成法の関係の解析, *JAMIT2010* (2010).
- 10) Watanabe, W. and Hontani, H.: Point-Based Non-Rigid Surface Registration with Accuracy Estimation, *The Twenty-Third IEEE Conference on Computer Vision and Pattern Recognition* (2010).
- 11) Freiman, M., Eliassaf, O., Taieb, Y., Joskowicz, L. and Sosna, J.: An iterative Bayesian approach for Liver Analysis: Algorithm and Validation Study, *Lecture Notes in Computer Science*, Vol.5212, pp.85-92 (2008).