

# 特徴点確率モデルに基づく曲面のレジストレーション

渡辺 航<sup>\*1</sup> 本谷秀堅<sup>\*1</sup> 武田 徹<sup>\*2</sup> 渡邊 順久<sup>\*3</sup>

## 要旨

本稿では、X-CT 画像から臓器を自動的に抽出するために、特徴点確率モデルを用いた、臓器レジストレーション法を提案する。特徴点確率モデルは、臓器表面の位置と形状に関する確率分布を、臓器表面に配置した特徴点群に基づき表現したものである。特徴点は臓器表面に均一に配置され、各点は自身の位置に関する事前分布と画像からそれぞれの点を抽出するための抽出演算子を保持している。また、これらに加えてモデルは隣接する特徴点間の相対位置に関する確率分布を持っている。提案手法では、まず、学習データの臓器表面上に特徴点を配置する。配置にはエントロピーを用いた評価法を用いる。次に、配置した特徴点に基づき、特徴点確率モデルを構築する。さらに、構築したモデルに基づき、特徴点の位置を推定することで、レジストレーションを行う。特徴点の位置推定には確率伝搬法を用いる。本稿では大動脈に対して、提案手法を適用した結果を報告する。

キーワード：CT CAD 臓器抽出 レジストレーション 確率伝搬法

## 1. はじめに

医用画像中の臓器に対してモデルをあてはめるレジストレーションは、医療診断支援システムに必須の機能である。レジストレーションには画像の輝度値を直接用いる手法[1]と、画像より抽出した特徴を用いる手法[2][3][4]と、それら双方を併用する手法[5]がある。提案手法は、臓器表面上に配置する点群を特徴としてレジストレーションをおこなう。

本稿で構築する臓器表面の点群モデルは識別モデルではなく生成モデルであり[6]、各点近傍の画像パターンと点間の関係を確率的に記述したものである[7][8][9]。生成モデルで

あるため画像に関するはずれ値の検出が原理的には可能であり、確率的なモデルであるためレジストレーションの結果の精度を定量的に評価できる。これらの事柄が提案法の利点である。

対象表面の点群に基づきレジストレーションするには、画像から各対応点を抽出する必要がある。それぞれの点が画像から抽出できる程度に十分な「特徴」を有しているならば、画像からの対応点の抽出は容易である。例えば曲面の曲率の高い点や個性的な画像局所パターンを有する点などの対応付けは比較的容易である。しかし、そのように特徴的な点をレジストレーションに十分な数だけ臓器表面に配置することは容易ではない。このような場合には、表面に多数の点を配置し、各点の抽出に画像特徴だけではなく、隣接する点間の相対位置も併用すると良い[1]。点間の相対的な位置関係の表現には、各点を格子点とするメッシュの表現が適している。本稿で提案する手法においては、エントロピーに基づいた点の配置法[10]に基づき多数の対応点を臓器表面に配置し、配置さ

---

\*1 名古屋工業大学

[〒466-8555 名古屋市昭和区御器所町]

e-mail: [watanabe@hilbert.elcom.nitech.ac.jp](mailto:watanabe@hilbert.elcom.nitech.ac.jp)

e-mail: [hontani@nitech.ac.jp](mailto:hontani@nitech.ac.jp)

\*2 筑波大学臨床医学系

[〒305-8575 茨城県つくば市天王台 1-1-1]

\*3 山形済生病院

[〒990-8545 山形県山形市沖町 79-1]

れた各点を画像より抽出するための特徴と各点間の相対位置関係の双方を確率的に記述する。この記述は各点の特徴に関するグラフィカルモデルとなり、各点を格子点とするメッシュ状の構造を持つことになる。

画像特徴に基づいた臓器表面のレジストレーション法を実現するには、画像からの特徴抽出法、臓器表面の位置・形状のモデル化、画像中の臓器表面とモデルとの距離の定義、ならびにその距離の最小化法を検討する必要がある。従来法の多くでは、これら個々の要素が別々に開発されている。例えば画像からの表面抽出には、sobelフィルタを用い、距離の定義には法距離と正則化項の和を用い、最適化にはカルマンフィルタを利用する、といった手法が散見される。一方、本稿で提案する手法は、画像からの対応点抽出、モデルの位置・形状表現、画像との距離の定義、ならびにその最小化の全体を、前記グラフィカルモデルの下で統一的に扱うことができる。具体的には、グラフィカルモデルを学習サンプルより生成したあと、画像へのレジストレーションには確率伝播法を利用する[11]。このことにより、レジストレーションの精度評価を臓器表面上の各点ごとにおこなうことができる。以下、モデルの生成法を中心に提案法を説明する。

## 2. モデル生成

### 2-1. モデル生成の概略

本節では、 $N$ 点 $\{P_j | j=1,2,\dots,N\}$ による臓器表面の確率モデルの生成法を説明する。まず、学習用のCT画像の体型の位置・形・大きさを正規化する。正規化した後の $M$ 人分の画像を $\{I^i | i=1,2,\dots,M\}$ とあらわす。体型の正規化法は、後にモデルと新規画像をレジストレーションする際に用いる手法と同じ手法を採用する。正規化後の画像における点 $P_j$ の座標を $x_j$ であらわす。

次に、正規化した各画像 $\{I^i\}$ から、モデル生成のために、対象とする臓器表面を手作業で抽出する。画像 $I^i$ から抽出した臓器表面を

$S^i$ とあらわす。

モデル生成のために、臓器表面に $N$ 点を配置する。配置法は第2-2節で説明する。 $S^i$ 上に配置された $j$ 番目の点を $\{P_j^i | j=1,2,\dots,N\}$ であらわす。 $P_j^i$ の3次元座標は $x_j^i$ であらわす。この $x_j^i$ を、モデル生成のために、確率変数 $x_j$ の実現値と解釈する。また $S^i$ における対応点間のユークリッド距離を $d_{jk}^i = \|x_j^i - x_k^i\|$ であらわす。 $d_{jk}^i$ の平均値 $\bar{d}_{jk} = \sum_i d_{jk}^i / M$ が閾値より小さい時、 $G$ の節 $x_j$ と $x_k$ を辺 $e_{jk}$ で結び、確率変数 $x_j$ に関するグラフィカルモデル $G$ を生成する。 $e_{jk}$ で結ばれている確率変数どうしは、それらの相対位置関係に関する確率分布が、 $N$ 点全点の位置に関する同時確率を表現する際に利用されることになる。具体的には、グラフ $G$ に $e_{ij}$ が存在するときには $p(x_i - x_j)$ がモデルに含まれることになる。

次節では、まず対応点 $P_j^i$ の配置法について説明する。

### 2-2. 対応点配置法

全曲面 $\{S^i\}$ に対応点を配置するために、エントロピーに基づいた手法[10]を採用する。この手法は、次に示す2つの性質をエントロピーにより定量化し、その双方の性質を満たす点の配置を求めるものである。第1の性質は、同一曲面上における点配置の均一性である。各曲面 $S^i$ 上における $N$ 個の点 $\{P_j^i | i=1,2,\dots,N\}$ の分布の均一性を、エントロピー $H^i[X]$ によりあらわす。さらに、 $J_1 \equiv -\sum_{i=1}^N H^i[X]$ により、全曲面での均一性を定量化する。第2の性質は、異なる曲面間における対応点の配置の類似性である。 $M$ 個の曲面 $\{S^i | i=1,2,\dots,M\}$ の間における、点の分布の相違度をエントロピー $H'[Z]$ によりあらわし、 $J_2 \equiv H'[Z]$ により、配置の類似性を定量化する。先に述べたとおり、提案法は点の配置に基づき曲面の形状モデルを構築する。第1の性質はモデルの形状表現能力が表面の部位ごとに大きく異なってしまうことを回避する。第2の性質は、正規化した画

像中における各特徴点の位置に関する事前分布  $p(x_j)$  をできるだけ局在化させる。これらはいずれもモデルを画像中の臓器にレジストレーションする際の精度を向上させる上で有用な性質である。

まず同一面内における均一性をあらわすエントロピー  $H^i[X]$  について説明する。点群  $\{P_j^i\}$  が、確率密度関数  $p^i(x)$  に従って発生したとする。このとき  $p^i(x)$  のエントロピー  $H^i[X]$  を用いて第1の性質を定量化する。 $\{P_j^i\}$  が、 $S^i$  を十分サンプリングできているとき、 $H^i[X]$  は次式で近似できる。

$$H^i[X] \cong -\frac{1}{N} \sum_{j=1}^N \log p^i(x_j^i) \quad (1)$$

$p^i(x)$  の推定にはParzen推定を用いる。具体的には次式に基づいて推定をおこなう。

$$p^i(x_j^i) \cong \frac{1}{N(N-1)} \sum_{k=1, k \neq j}^N \mathcal{N}(x_j^i; x_k^i, \sigma) \quad (2),$$

$\mathcal{N}(x; \mu, \sigma)$  は平均が  $\mu$ 、分散が  $\sigma^2$  の等方なガウス分布をあらわす。

式(1)と式(2)より、 $S^i$  上における点の分布の均一さは次式のとおり定義される。

$$H^i[X] \cong -\frac{1}{N} \sum_{j=1}^N \log \left\{ \frac{1}{N(N-1)} \sum_{k=1, k \neq j}^N \mathcal{N}(x_j^i; x_k^i, \sigma) \right\} \quad (3)$$

次に異なる面の間での配置の相違性をあらわすエントロピー  $H^i[Z]$  について説明する。 $S^i$  上の対応点の座標  $\{x_j^i | j=1, 2, \dots, N\}$  を並べたベクトルを  $z^i = (x_1^{iT}, x_2^{iT}, \dots, x_N^{iT})^T$  とあらわす。これは  $3N$  次元のベクトルであり、面  $S^i$  上における対応点の配置は  $3N$  次元ベクトルであらわされることになる。このとき、 $M$  個の曲面それぞれにおける対応点の配置の類似性は、 $3N$  次元空間における  $M$  個の点の分布の局在度により定量化することができる。

$z^i = (x_1^{iT}, x_2^{iT}, \dots, x_N^{iT})^T$  の分布が正規分布に従うと仮定すると、 $z^i = (x_1^{iT}, x_2^{iT}, \dots, x_N^{iT})^T$  の局

在性は、正規分布の共分散  $\Sigma$  を用いて、次式のように、エントロピーの小ささであらわすことができる。

$$H[Z] \cong \frac{1}{2} \log |\Sigma| = \frac{1}{2} \sum_{j=1}^{3N} \log \lambda_j \quad (4)$$

ここで  $\lambda$  は  $\Sigma$  の固有値である。

$\{z^i\}$  の平均を  $\bar{z}$  とあらわし、平均まわりの偏差を  $y^i = z^i - \bar{z}$  とあらわす。 $y^i$  を並べた  $3N \times M$  の行列  $Y = [y^1, y^2, \dots, y^M]$  を定義する。このとき  $\Sigma$  は次式で計算できる。

$$\Sigma = \frac{1}{M} Y Y^T \quad (5)$$

式(4)と式(5)からエントロピーは次式であらわすことができる。

$$H^i[Z] = \frac{1}{2} \log \left| \frac{1}{M-1} Y^T Y \right| \quad (6)$$

上記の性質の双方を満たす点配置を求めるために、次に示す配置に対するコスト  $J$  を最小化する。

$$J(\{x_j^i\}) = J_1 + J_2 = -\sum_{i=1}^M H^i[X] + H^i[Z] \quad (7)$$

$J$  の最小化は再急降下法により行う。勾配  $\partial J / \partial x$  は次式のようになる。

$$\frac{\partial J}{\partial x} = -\frac{\partial H^i[X]}{\partial x_j^i} + \frac{\partial H^i[Z]}{\partial x_j^i} \quad (8)$$

$$\frac{\partial H^i[X]}{\partial x_j^i} = -\sigma^2 \sum_{j=1, j \neq k}^N (x_j - x_k) w_{jk} \quad (9)$$

$$\frac{\partial H^i[Z]}{\partial x_j^i} = -Y(Y^T Y + \alpha I)^{-1} \quad (10)$$

ここで、 $\sum_k w_{jk} = 1$  であり、式(10)の  $\alpha$  は正則化のための正の定数である。式(8)の右辺第1項は式(9)に示すように同一曲面内における点の間の斥力をあらわす。一方式(8)の第2項は式(10)を解析するとわかるように、面と面の間における対応点間の引力をあらわす。

### 2-3. 統計モデルの生成

前節で述べた手法により、学習用に用意した  $M$  個の曲面上に  $N$  点ずつ点を配置する。次に、面内における、点どうしの平均距離  $\bar{d}_{jk}$  に基づいて、隣接する点どうしを結び、グラフィカルモデル  $G$  を作成する。ここで、グラフ  $G$  における節  $x_j$  と  $x_k$  を結ぶ辺を  $e_{jk}$  であらわす。まず、各曲面における点どうしのユークリッド距離  $\{d_{jk}^i\}$  を求める。次に距離の平均  $\bar{d}_{jk} = \sum_i d_{jk}^i / M$  が  $\bar{d}_{jk} < d_0$  を満たす場合  $x_j$  と  $x_k$  を結ぶ。ここで閾値  $d_0$  は実験により適当な値を求める。得られた辺の集合を  $\mathcal{E} = \{e_{jk}\}$  とあらわす。グラフ  $G$  に基づき、臓器表面の位置と形状の統計的性質を表現できる。

上記の方法で得たグラフ  $G$  及び画像  $\{I^i | i=1,2,\dots,M\}$  に基づき、次に示す3つの統計量を計算する。

- $P_j$  の位置の事前分布  $p(x_j)$
- $P_j$  と  $P_k$  の相対位置の確率分布  $p(x_i - x_j)$
- $P_j$  近傍のパターンが  $I_j$  である確率  $p(I_j | x_j)$

$p(x_j)$  は次式のように正規分布で表現する。

$$p(x_k - x_j) = \mathcal{N}(\cdot; \bar{x}_j, \Sigma_j) \quad (11)$$

平均と分散は対応点の集合  $\{P^i | i=1,2,\dots,M\}$  より求める。前節の点配置の局在性により、 $p(x_j)$  の分散が極端に大きくなることは避けられる。

$p(x_i - x_j)$  は特徴点間の相対位置関係の確率分布をあらわす。 $p(x_i - x_j)$  はグラフ  $G$  における局所的な変形をあらわす確率分布であり、曲面形状の平均と多様性のあり方を表現する。本稿では、 $p(x_i - x_j)$  も正規分布に従うことを仮定し、次式で表現する。

$$p(x_k - x_j) = \mathcal{N}(\cdot; \bar{x}_{kj}, \Sigma_{kj}) \quad (12)$$

ただし、 $\bar{x}_{kj}$  と  $\Sigma_{kj}$  は  $M$  個のベクトル  $\{(x_k^i - x_j^i) | i=1,2,\dots,M\}$  の平均と共分散から求める。

$p(I_j | x_j)$  は画像より、 $P_j$  を抽出する際に利用する。 $p(I_j | x_j)$  は点  $\{P^i | i=1,2,\dots,M\}$  の局所画像の集合  $\{I_j\}$  の PCA に基づいて表現する。

ここで  $P_j$  の局所画像とは、 $x_j$  を中心とした、一辺  $L$  の立方体内部の画像とする。局所画像のサイズ  $L$  は実験により適当に決める。まず局所画像  $\{I_j^i | j=1,2,\dots,M\}$  の共分散行列  $\Sigma_j$  を求める。 $\Sigma_j$  の固有値を  $\lambda_1 \geq \lambda_2 \dots$  であらわし、対応する固有ベクトルを  $v_j^1, v_j^2, \dots, v_j^{L_j}$  とあらわす。このとき、新規画像中に配置された点  $P_j$  の近傍の画像  $I_j$  の出現確率を次式で表現する。

$$p(x_k | I) = \frac{1}{Z} \exp \left\{ \sum_{d=1}^{L_j} \frac{\Delta_d}{\lambda_d} \right\} \quad (13)$$

ここで、 $\Delta_d = (I_j - \bar{I}_j)^T v_j^d$  であり、 $\bar{I}_j = \sum_i I_j^i / M$  である。また、 $Z$  は正規化定数をあらわす。表現に使用する固有ベクトルの数  $L_j$  は、寄与率を参照して求める。

隣接する点どうしを結んだグラフ  $G$  と、上記3つの確率分布の組が、本稿で提案する臓器表面の表現  $R$  である。

### 3. 医用画像とモデルのレジストレーション

与えられた新規医用画像とモデルとのレジストレーションを行い、臓器表面の抽出を行う。まず、新規医療画像を体型に基づき正規化し、画像  $I$  を得る。提案法は  $I$  と  $R$  に基づき事後確率を推定し臓器表面のレジストレーションを行う。特徴点の位置  $x_i$  とその周辺の局所画像  $I_i$  の同時分布について、次式が成り立つ。

$$p(\{x_i\}, \{I_i\}) = \prod_i \psi_i(x_i, I_i) \prod_{e_{ij} \in \mathcal{E}} \psi_{i,j}(x_i, x_j) \quad (14)$$

ただし  $\psi_i(\cdot, \cdot)$ 、 $\psi_{i,j}(\cdot, \cdot)$  は、それぞれ、各特徴点の配置のポテンシャル、及び隣接する特徴点間の相対位置に関するポテンシャルをあらわしている。これら各ポテンシャルは、臓器表面の表現  $R$  を用いて以下のように表現できる。

$$\psi_i(x_i, I_i) = p(x_i) p(I_i | x_i) \quad (15)$$

$$\psi_{i,j}(x_i, x_j) = p(x_i - x_j) \quad (16)$$

上記ポテンシャルを用いて、各特徴点の周辺分布 NBP を用いて推定する. 以下に推定法を説明する. NBP では、グラフィカルモデル  $G$  における節と節の間で、メッセージを交換しながら、推定分布を更新していく. 以下、 $G$  における特徴点の位置  $x_i$  に対応する節を  $v_i$  とあらわす. また  $n$  回目の更新時に得られる特徴点の推定分布を  $\hat{p}^n(x_i | I)$  とあらわす.  $\hat{p}^n(x_i | I)$  はポテンシャル  $\psi_i(x_i, I_i)$  と隣接するノード  $v_k$  から送信されてくるメッセージ  $m_{ki}^n$  を用いて次式のように計算する.

$$\hat{p}^n(x_i | I) \propto \psi_i(x_i, I_i) \prod_{e_{ki} \in E} m_{ki}^n(x_i) \quad (17)$$

ここでメッセージ  $m_{ki}^n$  は次式で計算できる.

$$\begin{aligned} m_{ki}^j &\propto \int_{x_k} \psi(x_k, I_k) \psi(x_i, x_k) \\ &\times \prod_{e_{ik} \in E, l \neq k} m_{ik}^{n-1}(x_k) dx_k \\ &\propto \int_{x_k} \psi(x_k, I_k) \frac{\hat{p}^{n-1}(x_k | I)}{m_{ik}^{n-1}(x_k)} dx_k \end{aligned} \quad (18)$$

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[nbp]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. したがってメッセージは次式のようにあらわすことができる.

$$m_{ki} = \sum_{\alpha=1}^W w_{ki}^{(\alpha)} \mathcal{N}(x_i; \mu_{ki}^{(\alpha)}; \Sigma_i) \quad (19)$$

ここで  $W$  はガウス分布の混合数、 $\alpha$  は各ガウス分布のラベルをあらわしている. 各ガウス分布は  $w^{(\alpha)}$  によって重み付けされる. したがって各メッセージはパーティクルの集合  $\{w_{ki}^{(\alpha)}, \mu_{ki}^{(\alpha)}, \Sigma_i | \alpha = 1, 2, \dots, W\}$  であらわすことができる.

各ノード  $v_i$  は、隣接するノード  $v_i (e_{ki} \in E)$  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(17)を計算し、推定位置  $\hat{p}^n(x_i | I)$  を更新する. 推定位置  $\hat{p}^n(x_i | I)$

もメッセージと同様に、ノンパラメトリックに表現する.  $\hat{p}^n(x_i | I)$  も混合ガウスモデルを用いて次式のようにあらわす.

$$\hat{p}^n(x_i | I) = \sum_{\alpha=1}^W w_{ki}^{(\alpha)} \mathcal{N}(x_i; \mu_i^{(\alpha)}; \Sigma_i) \quad (20)$$

各メッセージ  $m_{ki}^n$  は、 $\{w_{ki}^{(\alpha)}, \mu_{ki}^{(\alpha)}, \Sigma_i\}$  と式を用いて計算する. まずパーティクルの平均  $\mu_{ki}^{(\alpha)}$  は次式のように計算する.

$$\mu_{ij}^{(\alpha)} = \mu_i^{(\alpha)} + v_{ij} \quad (21)$$

ここで  $v_{ij}$  は式にしたがうランダムノイズである. 重み  $w^{(\alpha)}$  は次式にしたがい計算する.

$$w_{ij}^{(\alpha)} = \frac{w_i^{(\alpha)}}{m_{ji}(\mu_i^{(\alpha)})} \quad (22)$$

以上に基づき、メッセージと推定位置が収束するまで更新し、特徴点の位置を推定する.

#### 4. 実験結果

本稿では、大動脈を対象臓器として、実験を行った. 学習用のデータとして、15 患者分の X-CT 画像を用意した. 画像の空間分解能は [0.98mm, 0.98mm, 4.25mm] で、非造影画像である. まず、用意した画像の位置及び体型を、正規化する必要がある. 本稿では、肋骨の凸法と気管支の分岐点を抽出し、それぞれが定めた形状になるよう Thin-plate-spline で変換することにより体型を正規化した. 気管支の分岐点は、大動脈が近くを走行するためランドマークとして有用であることが知られている. 体型正規化の結果の例を Fig.1 に示す. 上記のランドマークにしたがって、胸部の形状が正規化されていることが分かる.




Fig.1: Body shape normalization. (a) Examples of given image. (b) Normalized ones

#### 4-1. モデルの生成

まず第2-2節で述べた，エントロピーに基づく点の配置結果を示す．各面に配置した数は  $N = 500$  点である．点の初期配置は次のようにした．まず，曲面  $S^1$  上の点から，点  $x_j^i$  をランダムに  $N$  点選択する．次に， $x_j^i$  を  $S^i (i \neq 1)$  に対し射影する．ここで，曲面  $S^i$  を距離0とする距離画像  $\Psi^i$  を，あらかじめ作成しておく．点  $x_j^i$  の近傍の距離画像  $\Psi_j^1$  と点  $x_j^i$  の近傍の距離画像  $\Psi_j^i$  のテンプレートマッチングを行い，もっともマッチング率の高い場所に  $x_j^i$  を移動させ，再び  $S^i (i \neq 1)$  に対し射影する．この方法で初期化することで，対応する点どうしが，ある程度，曲面上の似通った位置に分布する．Fig. 2(a) に初期配置を示し，Fig. 2(b) に収束後の点配置を示す．図に示すとおり，大動脈上に均一に分布していることがわかる．Fig. 3 には，15人分の大動脈に分布した  $P_j^i$  の例を5点選んで示す．結果は，対応点の番号  $j$  ごとに色分けして表示している．各点が局在していることがわかる．Fig. 4 には繰り返し計算中の各評価関数の減少の様子を示すグラフを掲載する．上記の方法で初期化したため，異なる面における点の配置の類似性は高いが，同一面内における均一性は低くなる．したがって，最急降下法により点の配置を更新すると，Fig. 4(a) に示すように，均一性に関するコスト関数  $J_1$  は単調減少し，Fig. 4(b) に示すように，各対応点の局在性に対応するコスト関数  $J_2$  は最初は減少し，その後均一さを優先して増加した．得られた点群を用いて，臓器表面の確率モデルを構築した．まず，配置した対応点群に基づいてグラフィカルモデルを作成した．得られた  $G$  に対応するメッシュをFig. 5 に示す．

次に，各特徴点に基づき，各特徴点の座標  $x_j^i$  の平均と分散を求め，特徴点  $P_j$  の位置の事前分布  $p(x_j)$  を求めた．また， $G$  において辺で結ばれた節と節について， $p(x_i - x_j)$  を求めた．さらに，それぞれの点の周囲に出現す

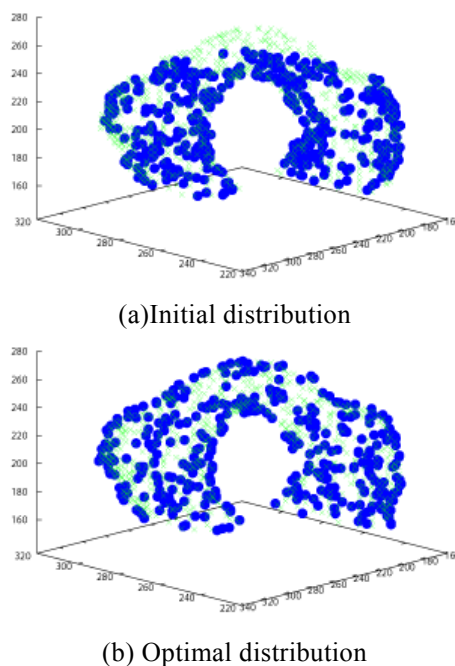


Fig.2: Generation of a set of corresponding points




Fig.3: The distribution of the corresponding points




Fig.4: The change of cost functions




Fig.5: Mesh of corresponding points


る画像の確率  $p(I_j | x_j)$  を求めた。局所画像は各点を中心に  $5 \times 5 \times 5$  ボクセルの画像を切り出したものとした。また固有空間を表現する固有ベクトルの数  $L_d$  は、累積寄与率が 98% となる固有値に対応した本数を特徴点ごとに選択した。

#### 4-2. 医用画像へのモデルのレジストレーション


上記のモデルを用いて、臓器のレジストレーションを行った。今回、レジストレーションの結果を比較するために、モデル構築に使ったデータ (closed data) を用いて実験を行った。まず、構築したモデルにしたがい事後確率  $p(x_j)p(I_j | x_j)$  を求めた。結果を以下に示す。**Fig.6** がモデル作成に使用した点の位置を示す。各特徴点の事前分布を **Fig.7** に示す。対応する特徴点が局在しているため、事前分布も局在化していることがわかる。

また、 $p(I_j | x_j)$  を **Fig.8** に示す。**Fig.6** に示した点の周辺画像と、似通った部分が高い値を持っていることがわかる。本提案手法は、各特徴点  $P_j$  の配置を定めるときに曲面  $S_j$  の幾何情報 (位置と大きさと形) のみを参照し、画像パターンは参照していない。このため、各特徴点近傍の局所画像のパターンは、位置を画像中で特定できるほど限定されておらず、図に示すとおり、画像中の広い範囲において高い値を示している。事後確率  $p(x_j)p(I_j | x_j)$  を **Fig.9** に示す。事前確率が局在化しているため、 $p(x_j | I_j)$  と比べると、局在化した分布を推定できている。特に輪郭におけるコントラストの強い画像 **Fig.9**(a) では強く局在化した分布が推定されている。いずれの事後分布も単一のガウス分布では表現しにくいことに注意する。


上記統計を用いて、ノンパラメトリック確率伝搬法の枠組みで、特徴点の位置を推定した。まず、初期推定位置として、 $N = 1000$  点を  $\psi_i(x_i, I_i)$  にしたがって配置した。結果を **Fig.10** (a) に示す。 $\psi_i(x_i, I_i)$  にしたがって、パ




**Fig.6:** Two of the feature points



**Fig.7:** Prior probabilities  $p(x_j)$



**Fig.8:** Likelihood distribution  $p(I_j | x_j)$




**Fig.9:** Posterior probabilities  $p(x_j)p(I_j | x_j)$

ーティクルが分布している．次に，NBPにより得られたパーティクルの分布 **Fig.10**(b)に示す．各パーティクルが収束し，特徴点の位置推定の分散が減少したことがわかる．ここで，各特徴点の推定位置の分散の推移を評価するために，各パーティクルの共分散行列を求め，その **trace** を計算した．面  $S_j$  ごとに **trace** の平均を求め，その値が NBP における繰り返しの過程でどのように変化したかを **Fig.11** に示す．NBP における更新にしたがって，確率分布の分散が減少していることがわかる．これは，各特徴点の位置の推定誤差分散が小さくなっていることをあらわしている．


特徴点の推定結果の詳細な結果を以下に示す．大動脈画像の境界部には，**Fig.12** に示すように境界に沿って強いコントラストが存在する部位と，**Fig.12** に示すように境界の位置を画像から判別しにくい部位とが混在する．**Fig.12(a)**は，NBP を用いた推定をする前の  $p(I_j | x_j)p(x_j)$  の分布を示す．強いコントラストの存在する部位では，高い確信度で推定できているが，コントラストの低い部位では確信度が低い．次に NBP による推定結果を示す．特徴点を含むスライス画像内における，パーティクルの分布を示している．いずれの場合においても，正しい特徴点の位置の周りで，分布の分散を小さくすることに成功していることが分かる．また，画像中のコントラストの有無などを反映して，特徴点の位置ごとに推定の確度を評価できていることが分かる．このように，レジストレーションの確度を部位ごとに評価することは，応用上も有用なことである．

## 5. おわりに

本稿では，医用画像中の臓器抽出を想定し，曲面の統計モデルとそのレジストレーション法を提案した．提案したモデルは，点群により臓器表面を表現するものであり，各点の画像中における事前分布，画像からの抽出演算




(a) Initial distributions of the particles representing



(b) Final distributing of the particles.


**Fig.10:** Example of experimental results obtain by the NBP



**Fig.11:** The change of the variances of the feature point distributions

子、臓器表面の形状、画像とモデルとの距離、ならびに画像とモデルの位置合わせのそれぞれの確率モデルを統一的に表現する．上記確率モデルを構築するために，学習用の臓器表面にエントロピーに基づいて対応点を配置した．この手法は，面の内部での点の均一性と，面と面の間における対応点の配置の類似性の双方を満たす点の配置を求める手法であった．





**Fig.12:** Examples of the estimated distributions.  
 (a) and (c) show the initial distributions,  
 and (b) and (d) show the resultant ones.

配置された各点の位置に基づき、画像中の事前分布と相対位置関係の確率分布を推定し、また各点近傍の画像の集合に基づき、各点を画像より抽出する演算子を構築した。新規画像が与えられ、その画像中の臓器とモデルとをレジストレーションする場合は、上記確率モデルに基づき、周辺分布を計算する。この確率の計算にはNBPを採用した。

第4節で結果を示したとおり、本手法では、レジストレーションした曲面上での各位置における確度の推定も行うことができる。このことは、応用上重要なことである。今回、特徴点間のユークリッド距離に基づく、単純な閾値処理に基づいて、グラフィカルモデルを生成した。適切なグラフの構築法の検討は今後の課題に含まれる。

## 文 献

- [1] J.P.W.Pluim, J.B.A.Maintz, et al. Mutual information based registration of medical images: a survey. *IEEE Transactions on Medical Imaging*, 22(8):986--1004, 2003,1.
- [2] Y. amit and A. Kong. Graphical templates for model registration. *IEEE. Transa*

tion on Pattern Analysis and Machine Intelligence, 18(3):225--236,1996.1,2

- [3] A. E. Johnson and M. Hebert. Using spin images for efficient object recognition in cluttered 3d scenes. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 21(5):433--449, 1999.
- [4] A. Rangarajan, J. Coughlan, et al. A bayesian network framework for relational shape matching. *Computer Vision, IEEE International Conference on*, 1:671-678, 2003.
- [5] M. Droske and W. Ring. A Mumford-Schah level-set approach for geometric image registration. *SIAM journal on Applied Mathematics*, 66:2127--2148, 2006.
- [6] Christopher M. Bishop. *PATTERN RECOGNITION and MACHINE LEARNING*. Chapter 1.
- [7] Splinger, 2006A. Blake and M. Isard. Chapter 2 of *Active Contours Springer-Verlag*, 1999. d d
- [8] M. Taron, N. Paragios, et al Registration with uncertainties and statistical modeling of shapes with variable metric kernels. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(1):99--113, 2009.22
- [9] A. Peter and A. Rangarajan. Information geometry for landmark shape analysis: Unifying shape representation and deformation. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 31(2):337--350, February 2009.Ff
- [10] J. Cates and M. Meyer. et al Entropy-Based Particle Systems for Shape Correspondence, *Proceedings of the Workshop on Mathematical Foundations of Computational Anatomy, MICCAI*, 90--99, 2006.
- [11] Alexander T. Ihler, Student Member, IEEE, et al. Nonparametric Belief Propagation for Self-Localization of Sensor Networks. *IEEE Journal*, April 2005, Volume: 23, Issue: 40, pp.809--819

# Free-Form Surface Registration

## Using Probability Model Based on Feature Points

Wataru WATANABE<sup>\*1</sup>, Hidekata HONTANI<sup>\*1</sup>, Tohoru TAKEDAI<sup>\*2</sup>, Yori-hisa WATANABE<sup>\*2</sup>

<sup>\*1</sup> Nagoya Insutitute of Technology

<sup>\*2</sup> Tsukuba University

<sup>\*3</sup> Yamagata Saisei Hospital

This article proposes a new method for registering a surface of an organ in a 3D medical image with a surface mesh model of the surface. Each grid point of the surface mesh has probabilistic models of its position, the local deformation, and its local image pattern. For learning those probabilistic models, we compute a set of correspondences on each surface of sample data by using an entropy-based particle system. For the registration, we use a non-parametric belief propagation. The proposed method can estimate the probability density distribution of the position of each grid of the surface mesh. The proposed method was applied to some actual 3D medical images, and the results are presented in this article.

**Key words:** CT, CAD, Organ Segmentation Registration, Belief Propagation