

医用画像中の臓器レジストレーションのための 特徴抽出と最適化手法の統合の試み

本谷 秀 堅^{†1} 渡 辺 航^{†1}

本稿では X-CT 画像中の臓器表面とモデルの非剛体レジストレーション法を提案する。提案法は、画像中の臓器表面の位置を推定できるだけでなく、推定精度もあわせて推定することができる。提案法は臓器表面上に配置した複数の特徴点により臓器表面を表現し、各特徴点の画像からの抽出演算子と各点の位置に関する確率モデルを学習モデルに基づいて学習し、画像中の特徴点の位置推定にはノンパラメトリック確率伝搬法を用いる。人工画像と実画像を利用した評価実験をおこなったので、その結果を報告する。

An Approach to Unification of Feature Extraction and Optimization for Registration of Organs in Medical Images

HIDEKATA HONTANI^{†1} and WATARU WATANABE^{†1}

This article presents a new method for non-rigid surface registration between a surface model and a surface of an internal organ in a given 3D medical image. The proposed method can estimate not only the location of the surface but also the confidence of the estimated location. In the method, the model represents the surface with a set of feature points distributed on it. An operator for detecting each feature point in a given image and probabilistic models of the locations of the feature points are both obtained from an identical set of training samples. For the estimation, we employ the non-parametric belief propagation. We report some experimental results: our method was applied to some synthetic images and to some clinical ones.

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

1. はじめに

診断や治療計画立案に医用画像を参照することは不可欠である。医用画像の空間分解能は向上しつつあり、また超音波画像やレントゲン写真、拡散 MRI や PET, SPECT など、撮影される医用画像のモダリティの数も年々増えつつある。このことは各患者の体内に関する多様な情報を高精度に取得できるようになりつつあることを示す反面、医師ひとりが日々精査すべき画像の枚数が年々増加しつつあることも意味している。例えば、癌診断に際して撮影されることの多い FDG-PET/CT 画像は、ひとりの患者の全身像が、近年では、1,000 枚を超える断層像より構成される。医師は医用画像の洪水と呼びうる状況に直面しており、それら大量の画像より診断に有用な情報を自動抽出し医師に提示する診断支援システムの高度化が待たれている¹⁾。

診断支援システムにおいて体内の各臓器のレジストレーションは必須の処理であり、臓器モデルを画像に位置合わせする手法が盛んに研究されている。医用画像においては複数の臓器が入り組んで隣接しており、患者ごとに臓器形状は大きく異なり、また病変により画像特徴も大きく変化しうる。このため、テクスチャにより領域分割したり、輪郭の滑らかさを仮定して閉曲面を探索したりするだけでは臓器を高精度かつ頑健に抽出することはできない。モデルにより画像特徴や形状に関する多様性を表現しておき、与えられた画像の特徴を記述し、モデルの表現と画像特徴の記述の適合度を最大化することにより初めて臓器のレジストレーションは可能となる。

本稿では 3 次元の全身 X 線 CT 画像中の対象臓器とそのモデルのレジストレーションをおこなう新しい手法を提案する。提案法は、与えられた画像中の対象臓器表面をレジストレーションするだけでなく、ベイズ推定の枠組みに基づき、対象臓器表面の各位置におけるレジストレーションの精度を見通し良く推定する。本提案法の新規性は、臓器の位置と形状の多様性の表現、画像特徴の抽出、モデルと画像特徴との適合度の最適化の全体を統計的に統一する枠組みにある。提案手法を用いれば、例えば画像コントラストの低い位置においてはレジストレーションの精度が低いことが自動的に判定される。以下、次節において従来法と比較しつつ提案法の位置づけを説明したあと、具体的に手法を説明し、実験結果を報告する。

2. 従 来 法

モデルと濃淡画像のレジストレーションをおこなう手法は極めて数多く提案されている²⁾³⁾。

これら手法は、モデルとの適合度を計算する際の画像の記述に基づいて、大雑把に三種類に大別することができる²⁾。第一は画素値そのものをモデルと比較する手法である。これら手法においては、対象臓器を内に含むべき領域をROI(Region of Interest)として定め、ROI内部の画素値の分布をモデルとして表現する。そして与えられた画像よりROIを抽出したのちに、ROI全体に対する画素値の二乗誤差を最小化⁴⁾したり、相互情報量を最大化⁵⁾したりすることにより、画像と最も適合するモデルの変形を定める。画像特徴の抽出を必要としない反面、ROI全体で定まる評価関数に基づいてレジストレーションをおこなうため、(ROI内部で)対象臓器とは無関係な領域における画素値の変化によりレジストレーションの結果が変化する。また、これら手法においてはROI全体をthin plate splineなどに基づいて変形する場合が多く、臓器の形状や変形の多様性をモデルにより直接表現することには適さない。レジストレーションの精度評価もROI全体に対しておこなうことになり⁴⁾、対象臓器のレジストレーションの精度を直接正確に評価するには不向きである。

第二は画像より境界面やランドマークなど構成要素を抽出し、それら構成要素とモデルとの適合度を最適化する手法であり、active contours⁶⁾に類する手法や特徴点に基づいた手法⁷⁾⁸⁾⁹⁾を含む。これら手法においては、臓器表面や臓器上に配置したランドマークなど、構成要素の形状や配置などをモデルとして表現する。そして、それら構成要素を画像より抽出し、モデルと画像中の要素間の距離を最小化することによりモデルの変形を定める。このとき、対象臓器を直接の対象としてレジストレーションをおこなうため、第一の手法と比べると対象臓器自身に対するレジストレーションの精度評価を直接的におこなうことができる⁶⁾。

ここで、構成要素の表現をパラメトリックにおこなうと、精度評価も当該パラメータに関しておこなわれることになる。例えば臓器表面をspline曲面の制御点の座標で表現すると、画像からエッジを抽出し、spline曲面とエッジとの距離が最小になるよう制御点の座標を推定し、その推定精度は制御点の座標の推定共分散などで表現することになる。このような手法を採用するとき、エッジ抽出演算子は既存の手法から選択して採用する場合が多く、そのエッジ抽出精度はレジストレーションの精度に影響を与えるはずであるが、その精度を正確に位置ごとに評価することは容易ではない。また、仮にレジストレーションの精度を推定できたとしても、その精度はspline曲面の制御点の座標の分布で表現されることになり、レジストレーションされた曲面の各位置における精度の直接的な表現は得られない。

本稿では対象臓器表面に配置した点群をランドマークとし、その配置により対象臓器の位置と形状をノンパラメトリックに表現する。このとき、それら点群の位置推定精度により臓

器の各位置におけるレジストレーションの精度を直接的に表現できる。ただし、臓器表面への点群の配置法に課題が残る。提案法では、この点群の配置にエントロピーに基づくパーティクルシステムを採用する。

第三の手法は上記二種類の発想を併用する手法である¹⁰⁾。これら手法に対するレジストレーションとその精度評価のための統計的な統一的枠組みについては、本稿では扱わない。今後考察したいと考えている。

3. 特徴抽出・形状の表現・最適化法の統合

本節では提案法を説明する。まず学習サンプルに基づいたモデルの構築法を説明し、次にモデルと画像の位置合わせ法を説明する。

3.1 臓器モデルの構築

本提案法では、臓器表面上に配置された N 個の特徴点 $\{P_j | j = 1, 2, \dots, N\}$ により表面の位置と形状を表現する。特徴点 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 G により曲面の統計を表現する。

モデル構築に際して、まず学習用に収集した M 枚の3次元X線CT画像のそれぞれから対象臓器表面を手作業でトレースし、次に骨格や肺などに基づき体の位置・形・大きさを自動的に正規化することにより、正規化後の3次元画像座標系で記述された多数の臓器表面のデータを用意する。正規化後の3次元画像の集合を $\mathcal{I} = \{I^i | i = 1, 2, \dots, M\}$ 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。

曲面モデルの生成は次の手順によりおこなう。まず、各曲面 $\{S^i\}$ 上に N 個の対応点 $\{P_j^i | j = 1, 2, \dots, N\}$ を配置する。配置法はのちに説明する。 M 個の曲面 S^i に配置された対応点 $\{P_j^i | i = 1, 2, \dots, M\}$ を、特徴点 P_j の位置に関する確率密度分布 $p(x_j)$ にしたがってサンプルされた M 個の点とみなす。

グラフィカルモデルは確率変数間の条件付き独立性をグラフで表現したものである。各ノードが各確率変数をあらわし、統計的に依存しあう確率変数間が辺で結ばれている。本稿の臓器モデルでは、各ノードにより各特徴点の座標 x_j をあらわし、近接するノード間を辺で結ぶ。具体的には、次の手順により辺で結ぶノードを決定する。 P_j^i の3次元座標を x_j^i で表し、 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 $\bar{d}_{jk} = \sum_i d_{jk}^i / M$ が閾値より小さいとき、 G の節 x_j と x_k を辺 e_{jk} で結ぶ。辺 e_{jk} でノード j と k が結ばれているとき、モデル G は P_j と P_k の相対位置に関する確率分布 $p(x_j - x_k)$ を表現する。また、このほかに、全ての点 P_j の事前分布 $p(x_j)$ も表現する。

$p(x_j)$ や $p(x_j - x_k)$ は, $\{x_j^i\}$ に基づき推定する. 以下, まず対応点 P_j^i の配置法を説明する.

3.2 対応点配置法

対応点 P_j^i の配置にはエントロピーに基づいた手法¹¹⁾を採用する. この手法は, 次に示す二つの性質をエントロピーにより定量化し, これら双方の性質を満たす点の配置を求めるものである.

第一の性質は, 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 $\{P_j^i | j = 1, 2, \dots, N\}$ の分布の均一性をエントロピー $H^i[X]$ によりあらわし, $J_1 \equiv -\sum_i H^i[X]$ により全曲面における均一性に関するコストを定義する. 第二の性質は, 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 $\{S^i | i = 1, 2, \dots, M\}$ 間における点の分布の相違度をエントロピー $H'[Z]$ であらわし, $J_2 \equiv H'[Z]$ 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形状モデルを構築する. 第一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. 第二の性質は, 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表すエントロピー $H^i[X]$ について説明する. $\{P_j^i | j = 1, 2, \dots, N\}$ 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 $H^i[X]$ を用いて第一の性質を評価する. $H^i[X]$ は式 (1) で近似できる.

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

確率密度関数 $p^i(x)$ の推定には Parzen 推定を用いる. 具体的には $p^i(x)$ を式 (2) に基づき推定する.

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

式 (1) と式 (2) より, S_i 上における点 $\{P_j^i\}$ の分布の均一さ $H^i[X]$ は次のとおり定義される.

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

ここで, $\mathcal{N}(x; \mu, \sigma)$ は平均が μ , 分散が σ^2 の等方な 3 次元ガウス分布をあらわす.

次に異なる面の間における配置の相違性を表すエントロピー $H'[Z]$ 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, $z^i = (x_1^{i\top}, x_2^{i\top}, \dots, x_N^{i\top})^\top$ 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 z^i 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 $\{z^i | i = 1, 2, \dots, M\}$ の分布の局在度により定量化することができる. $\{z^i | i = 1, 2, \dots, M\}$ の分布が正規分布に従うと仮定すると, $\{z^i | i = 1, 2, \dots, M\}$ の局在性は, 正規分布の共分散 Σ を用いて, 次式のように, エントロピー $H'[Z]$ の小ささであらわすことができる.

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

ここで, λ は Σ の固有値である.

$\{z^i\}$ の平均を \bar{z} で表し, 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 Σ は式 (5) で計算できる.

$$\Sigma = \frac{1}{M-1} Y Y^\top. \quad (5)$$

式 (4) と式 (5) から, エントロピー $H[Z]$ は次式であらわすことができる.

$$J_2 \equiv H'[Z] = \frac{1}{2} \log \left| \frac{1}{M-1} Y^\top Y \right|. \quad (6)$$

前記 2 つの性質を満たす点配置を求めるために, 次に示す配置の性質に対するコスト J を最小化する.

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

J の最小化是最急降下法によりおこなう. 点の初期配置はランダムにおこなう. 勾配 $\partial J / \partial x$ は次の通りである.

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

ここで, 各エントロピーの勾配は次式の通りである.

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

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

ただし $\sum_{k=1}^N w_{jk} = 1$ であり, 式 (10) の α 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している.

ところで, $x \leftarrow x - \gamma(\partial J/\partial x)$ により各点の位置を更新すると, 各点は面から外れてしまう (γ は正の定数). そこで, 最急降下法による更新後に各点を面上で最も近い位置へと射影する. この射影を容易にするためには, 面 S^i を距離画像の 0 レベルにより記述しておけばよい. 距離画像の計算には, Fast Marching Method が利用できる. 式 (9) の正則化係数 α の値が大きいくとき, 異なる面と面の間における点の配置を類似させる動きが小さくなる. そこで, α の初期値を大きな値に設定し, 更新回数と共に減少する枠組を導入する. 点の初期配置はランダムな配置でよい.

3.3 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 S^i 上に N 点ずつ点を配置する. 次に, 面内における平均距離 \bar{d}_{jk} に基づいて隣接する点どうしを辺 e_{jk} で結び, 特徴点の位置 x_j のグラフィカルモデル G を作成する. グラフィカルモデル G と, 画像 $\{I^i | i = 1, 2, \dots, M\}$ に基づき, 下記三つの統計量を計算する.

- P_j の位置 x_j の事前分布: $p(x_j)$
- P_j と P_k の相対位置に関する確率分布 $p(x_k - x_j)$
- P_j 近傍のパターンが I_j である確率: $p(I_j | x_j)$

$p(x_j)$ は正規分布で表現する.

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

ただし, \bar{x}_j, Σ_j は, それぞれ M 個の対応点の平均と分散であり, M 個の対応点 $\{P_j^i | i = 1, 2, \dots, M\}$ より求める. 前節の点配置法の局在化の性質により, $p(x_j)$ の分散が著しく大きな値となることは避けられる.

$p(x_k - x_j)$ は臓器の局所的な変形に関する確率分布である. 本稿では $p(x_k - x_j)$ 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 Σ_{kj} は M 個のベクトル $\{(x_k^i - x_j^i) | i = 1, 2, \dots, M\}$ の平均と共分散により推定する.

$p(I_j | x_j)$ は画像より点 P_j を抽出するときに利用される. 本稿では $p(I_j | x_j)$ を点 $\{P_j^i | i = 1, 2, \dots, M\}$ の局所画像の集合 $\{I_j^i\}$ の PCA に基づいて表現する. ここで P_j^i の局所画像とは, x_j^i を中心とし, 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定める. まず, 局所集合 $\{I_j^i | i = 1, 2, \dots, M\}$ の共分散行列 Σ_j を求める. Σ_j の固有値を $\lambda_1 \geq \lambda_2 \geq \dots$ であらわす. また, 対応する固有ベクトルを $v_j^1, v_j^2, \dots, v_j^{L^3}$ であらわす. 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 の確率を次式にしたがい評価する. ただし, 表現に用いる固有ベクトルの数 L_j は寄与率を参照して決定する.

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

ただし, $\Delta_d = (I_j - \bar{I}_j)^\top v_j^d$ 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.

3.4 医用画像へのモデルのレジストレーション

新規医用画像が与えられた時, 体型に基づき正規化をおこない画像 I を得る. 提案法は I と上記モデル (グラフィカルモデル G と $p(x_i | I)$ の組) の位置あわせをおこない, 事後確率 $p(x_i | I)$ を推定する. 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, それぞれ各特徴点ごとの配置のポテンシャル, 及び, 隣接する特徴点どうしの相対位置のポテンシャルを表している. また, \mathcal{E} はグラフィカルモデル G を構成する辺 e_{jk} の集合である. 式 (15) 及び, 式 (16) の右辺はそれぞれ, 式 (11), (12) 及び, 式 (13) により既にあらわされている.

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

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

ここで, 本稿で提案するレジストレーション法の概略を述べる. 提案法は最初に, 式 (15) に従い, 与えられた画像 I における各特徴点の位置分布のポテンシャル $\psi(x_i, I_i)$ を推定する. すなわち, 各特徴点の位置の事前分布 $p(x_i)$ がモデルにより与えられ, 画像 I に対する各特徴点の位置に関する尤度分布を式 (13) に基づき計算し, これらの積により $\psi(x_i, I_i)$

を推定する．このときのポテンシャル $\psi(x_i, I_i)$ の推定には， $p(x_i - x_j)$ により表現されている臓器の形状に関する情報を一切利用していないことに注意する．そこで，次に式 (14) を利用することにより臓器形状を考慮し，各特徴点の位置 x_i の周辺分布を推定する．この推定には Non-parametric Belief Propagation¹²⁾ (NBP) を用いる．

以下，NBP による周辺分布の推定法を説明する．NBP では，グラフィカルモデルにおける節と節の間でメッセージを交換しながら，確率変数の推定分布を更新していく．以下， G において x_i に対応する節を v_i であらわす．また， n 回目の更新時における特徴点の確率分布を $\hat{p}^n(x_i|I)$ 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．

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

ここでメッセージ m_{ki}^n は次式のとおりである．

$$\begin{aligned} m_{ki}^n(x_i) &\propto \int_{x_k} \psi_k(x_k, I_k) \psi_{i,k}(x_i, x_k) \prod_{e_{tk} \in \mathcal{E}, t \neq i} m_{tk}^{n-1}(x_k) dx_k \\ &\propto \int_{x_k} \psi_k(x_k, I_k) \frac{\hat{p}^{n-1}(x_k|I)}{m_{ik}^{n-1}(x_k)} dx_k. \end{aligned} \quad (18)$$

本稿が扱う問題においては，上記メッセージがあらわすべき分布をガウス分布など単一の分布で表現することは難しい．このことが NBP を採用した理由である．NBP においては，複数のパーティクルを用いて混合ガウス分布を表現する．

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

ここで， W はガウス分布の混合数， 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．各メッセージは， $\{w_{ki}^{(\alpha)}, \mu_{ki}^{(\alpha)}, \Sigma_i | \alpha = 1, 2, \dots, \alpha\}$ で定義される，パーティクルの集合であらわされる．

各ノード v_i は，隣接するノード $v_k (e_{ki} \in \mathcal{E})$ 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 $\hat{p}^n(x_i|I)$ の更新を行う．メッセージと同様，推定位置 $\hat{p}^n(x_i|I)$ も，混合ガウスモデルを用いて，次式のようにノンパラメトリックな表現を採用する．

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

各メッセージ m_{ij} は，パーティクル $\{w_{ij}^{(\alpha)}, \mu_{ij}^{(\alpha)}, \Sigma_{ij}\}$ と式 (12) を用いて計算する．まず，パーティクルの平均 $\mu_{ij}^{(\alpha)}$ は次式のように計算する．

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

ここで， ν_{ij} は式 (12) にしたがうランダムノイズをあらわす．また，重み $w_{ij}^{(\alpha)}$ は式 (18) にしたがって，次式で計算する．

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

以上の手続きにより，メッセージと推定位置を収束するまで更新することで，各特徴点の位置を推定する．

4. 実験結果

本提案手法をテスト画像と実臨床画像に適用した結果を報告する．

4.1 人工画像による評価

学習・評価用に，楕円体の領域ひとつを内に含む 3 次元濃淡画像を 20 枚用意した．図 1 に断面の例を示す．図に示すように用意した画像は濃淡値の異なる 2 領域の中央に，それぞれの領域と異なる濃淡値を持つ楕円体が描かれている．20 枚の画像それぞれに描かれている楕円体はいずれも長軸が 36 ピクセル，短軸が 30 ピクセル程度の大きさであり，それぞれ中央の位置が 5 ピクセル程度ランダムにずれており，長軸の向きは標準偏差 10 度，短軸と長軸の長さは標準偏差が平均長の 10% の正規分布でランダムに生成されたものである．

先に述べたエントロピーに基づき手法により，各楕円体表面に 250 点の対応点を生成した．その結果の一例を図 2 に示す．図 2(A) が対応点の初期配置であり，同図 (B) が収束後の配置である．面内における分布の均一さが増していることがわかる．図 3 には，収束させる過程におけるコスト関数の推移のグラフを示す．同図 (A) は各面内における均一さの推移を示し，(B) は配置の類似性の推移を示す．図 (B) のグラフの初期値が小さいのは，すべての楕円体表面に似通った配置で初期対応点を与えたからである．グラフに示されているとおり，まず各面内の均一さを増加させるように対応点は移動し，そのあとで対応関係が修

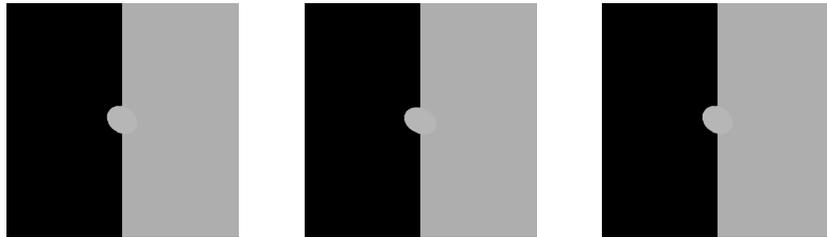


図 1 評価用画像の例

Fig. 1 Examples of synthetic images for validation

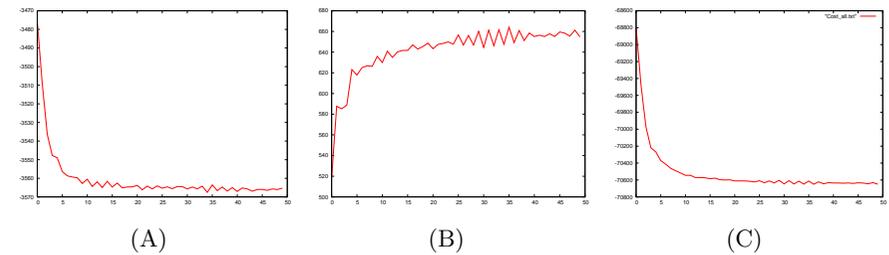


図 3 対応点の生成におけるコスト (7) の推移

Fig. 3 The change of the cost (7) for distributing corresponding points

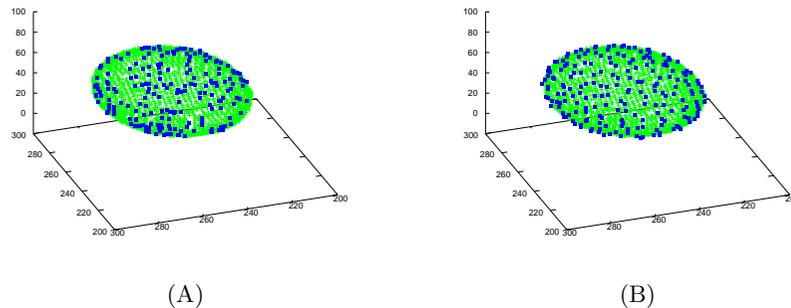


図 2 対応点の生成 . (A) 初期配置 . (B) 収束後

Fig. 2 Generation of corresponding points. (A)Initial distribution. (B)The resultant one.

復されるように移動している . 図 (C) が式 (7) に示すコスト関数の推移である . 最急降下法による最適化をおこなっているため , 得られた対応点の配置が最適配置である保証はなく , 初期配置に依存して得られる対応点の配置は異なる . ただし , 各面内における均一さや面間における配置の類似性が極端に損なわれていない限り , 提案法の性能には大きな影響を与えない . 各対応点のための特徴抽出演算子は , これら対応点の配置に基づいて対応点ごとに学習される .

様々な形状の楕円体表面に対応点を生成する . 配置の類似性をエントロピーで評価しており , 各対応点は (体型で) 正規化された画像座標系において局在化する . 図 4 に対応点ごとの分布を示す . ここに示した分布は , 各点の事前分布 $p(x_j)$ を推定に利用される .

構築した楕円体表面のモデルを用いてレジストレーションをおこなう . レジストレーション

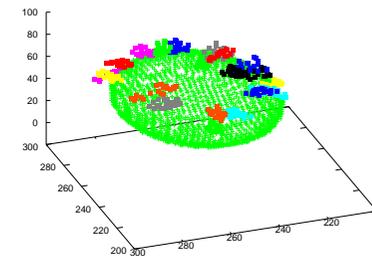


図 4 対応点ごとの分布 (一部)

Fig. 4 Some examples of the distributions of corresponding points

のために , まず各特徴点を画像より抽出する . 図 5 に , 特徴抽出の様子を図示する . 図 5(A) は 250 点の特徴点のうち的一点の位置をスライス画像内で示したものである . 同図 (B) は同対応点の事前分布を示したものである . 上で述べたとおり , この事前分布 $p(x_j)$ は , 図 4 に示した分布に基づいて推定されたものである . 図 4(C) は式 (13) にしたがって推定した , 図 (A) に示した点の位置の尤度分布である . 局所的に右上が明るく左下が暗い領域の尤度が高くなっている . (B) と (C) に示した分布の積により , 事後分布 (D) が得られる . 尤度分布は楕円体表面に沿っており位置を特定できるほど十分な情報を含んでいないが , 事前分布がエントロピーをコストとすることにより局在化しており , 事後分布の分散は小さい . ここで , 特徴点の位置の推定が , 点推定ではなく分布の推定になっていることに注意する .

NBP を適用して得られた最終結果を図 6 に示す . 同図 (A) は図 5(D) に対応しており ,

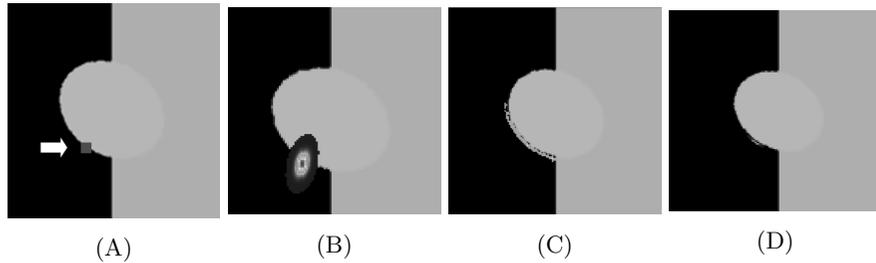


図 5 特徴点の抽出

Fig. 5 Extraction of feature points

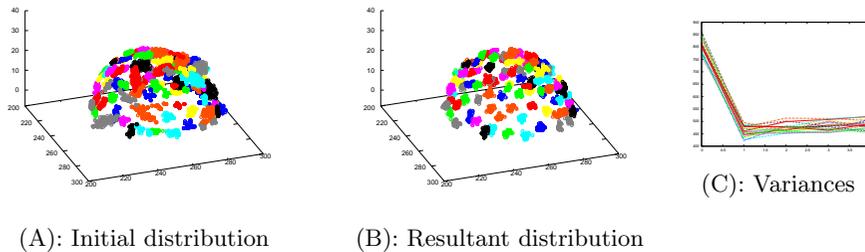


図 6 NBP による特徴点の位置推定結果

Fig. 6 Estimation of feature points locations by means of NBP

事前分布 $p(x_i)$ と尤度分布 $p(I|x_i)$ に基づいて得られた各点の位置の推定分布を示しており、NBP を適用する直前の分布である。同図 (B) は NBP により得られた、形状モデルも考慮して計算された周辺分布である。両図を比較すると、各点の分布の推定分散値が小さくなっていることがわかる。図 6(C) は NBP の計算過程における、各点の推定分布の分散の変化を示す。メッセージを交換するたびに推定分散が減少していたことがわかる。各点の推定位置分布の平均と真の位置との平均誤差は約 0.7 ピクセルであった。推定位置は面表面に沿って分布しており、面の法線に沿った位置ずれは図 6(C) に示した分散値と比べると小さい。

4.2 実画像による評価

全身の X-CT 画像中の大動脈を対象として評価実験をおこなった。使用した画像の空間分解能は $[0.98mm \times 0.98mm \times 4.25mm]$ で、非造影画像である。大動脈は心臓を起点とし

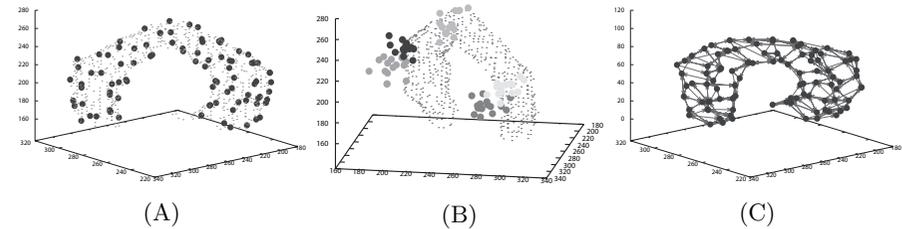


図 7 (A) 大動脈表面への対応点の自動生成結果。(B) 各点の分布。(C) 位置の依存関係に関する仮定を示すメッシュ構造

Fig. 7 (A): Automatic generation of the corresponding points. (B): The distribution of each point. (C): A mesh representation of the graphical model G .

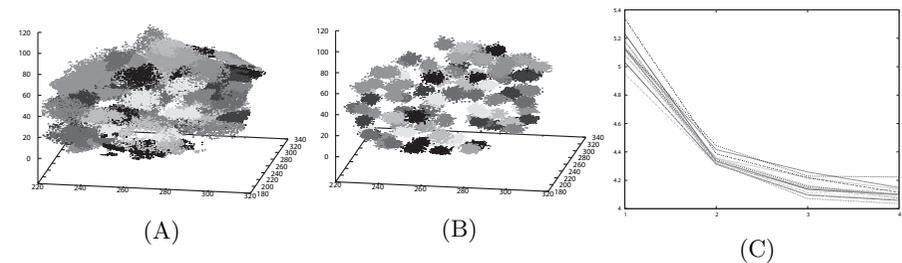


図 8 大動脈のレジストレーションの結果

Fig. 8 An example of the results of the aorta registration

て一度体軸に沿って頭部のほうに上昇し、円弧を描いて気管支の分岐部において脚部のほうへと下降する。この円弧部のモデルを構築し、レジストレーションをおこなった。大動脈のレジストレーションはリンパ節の位置同定や大動脈石灰化の検出などに必要な、重要な処理である。実験には 15 人の X-CT 画像より手作業で大動脈部を抽出したものを利用した。

図 7(A) と (B) に対応点とその分布の例をそれぞれ示す。大動脈表面に均一かつ類似した分布で点を配置することに成功している。得られた対応点群を用いてグラフィカルモデル G を構築した。点間の平均距離に基づいて G に辺を挿入した。辺の挿入された点どうしを線分で結んで得られたメッシュを図 7(C) に示す。

図 8 に NBP を適用する前のパーティクルの分布 (A) と適用後の分布 (B) を示す。また、分布の分散の NBP の繰り返し計算による変化を同図 (C) に示す。確率伝搬法により $p(x_i - x_j)$ により表現されている局所形状の情報も考慮され、分布の分散が小さくなってい

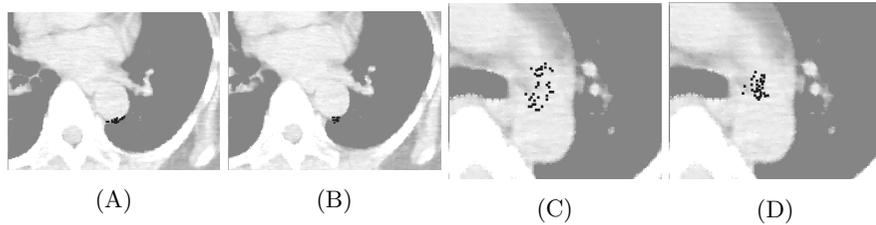


図9 大動脈のレジストレーションの結果。(A)と(C)はNBPの適用前。(B)と(D)が適用後。
Fig.9 Some results of the registration of the aorta. (A) and (C) shows the distributions before NBP was applied. (B) and (D) shows the resultant distributions.

ることがわかる。

より詳細な結果を図9に示す。大動脈壁は、図9に示すように、コントラストの強弱が部位によって異なる。図9(A)と(C)はNBPを計算する前の $p(x_j)p(I_j|x_j)$ の分布を示す。コントラストの強い部位では特徴点の推定位置分布の分散が小さいが、弱い部位では大きい。次にNBPによる推定結果を図9(B)と(D)に示す。それぞれ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。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できることは、応用上有用なことだと考える。

5. おわりに

本稿では臓器表面の位置を点推定ではなく、その分布も推定する手法を提案した。提案法はエントロピーに基づいて対応点を生成することにより特徴点の位置分布のモデルを構築し、グラフィカルモデルによりそのモデルを表現し、確率伝搬法によりモデルに基づいた画像中の臓器表面のレジストレーションをおこなう。本提案法は、特徴点に基づく多くの手法と大きく異なり、局所画像特徴に基づいて画像から特徴点を抽出する際の精度を一切考慮することなく特徴点の配置を決定する。このような決定法が可能なのは、医用画像においては体型正規化に基づいて対象臓器のおおよその位置を決定できるからである。このように対象のおおよその位置をあらかじめ決定できることを仮定することは、例えば文字認識手法の多くが文字切り出しを大前提としていることと似ており、汎用性を大きく減ずるものではない。レジストレーションに重要なことは与えられた画像中で各特徴点の位置を局在化させることであり、本来は事前分布と画像特徴の特異性の双方を特徴点の配置決定の際には考慮す

べきであると考え、今後の課題のひとつとしたい。

参考文献

- 1) 小畑秀文：医用画像の計算機支援診断技術の現状と動向，医用画像情報学会雑誌，Vol.21, No.1, pp.11-18 (2004).
- 2) Audette, M.A., Ferrie, F.P. and Peters, T.M.: An algorithmic overview of surface registration techniques for medical imaging, *Medical Image Analysis*, Vol.4, No.3, pp.201-217 (2000).
- 3) Duncan, J.S. and Ayache, N.: Medical Image Analysis: Progress over Two Decades and the Challenges Ahead, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.22, No.1, pp.85-106 (2000).
- 4) Taron, M., Paragios, N. and Jolly, M.-P.: Registration with Uncertainties and Statistical Modeling of Shapes with Variable Metric Kernels, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.31, No.1, pp.99-113 (2009).
- 5) Pluim, J. P.W., Maintz, J. B.A. and Viergever, M.A.: Mutual-information-based registration of medical images: a survey, *IEEE Transactions on Medical Imaging*, Vol.22, No.8, pp.986-1004 (2003).
- 6) Blake, A. and Isard, M.: *Chapter 2 of Active Contours*, Springer-Verlag (1999).
- 7) Edwards, G., Lanitis, A., Taylor, C. and Cootes, T.: Statistical models of face images - Improving specificity, *Image and Vision Computing*, Vol.16, No.3, pp.203-211 (1998).
- 8) Johnson, A.E. and Hebert, M.: Using spin images for efficient object recognition in cluttered 3D scenes, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, Vol.21, No.5, pp.433-449 (1999).
- 9) Rangarajan, A., Coughlan, J. and Yuille, A.L.: A Bayesian Network Framework for Relational Shape Matching, *Computer Vision, IEEE International Conference on*, Vol.1, pp.671-678 (2003).
- 10) Droske, M. and Ring, W.: A Mumford-Shah level-set approach for geometric image registration, *SIAM journal on Applied Mathematics*, Vol.66, pp.2127-2148 (2006).
- 11) Cates, J.E., Fletcher, P.T., Styner, M.A., Shenton, M.E. and Whitaker, R.T.: Shape Modeling and Analysis with Entropy-Based Particle Systems, *In Proceedings of the 20th International Conference on Information Processing in Medical Imaging*, pp.333-345 (2007).
- 12) Sudderth, E.B., Ihler, E.T., Freeman, W.T. and Willsky, A.S.: Nonparametric belief propagation, *In Proceedings of the IEEE Conference of Computer Vision and Pattern Recognition*, pp.605-612 (2003).