

# グラフィカルモデルの構造推定と確率推論法の違いによる Point Distribution Model と医用画像の非剛体位置合せの精度比較

澤田 好秀<sup>†a)</sup>      本谷 秀堅<sup>†b)</sup>

A Performance Comparison Study of Non-rigid Registration between Point Distribution Model and Medical Images with Respect to Graphical Model Structure and to Probabilistic Inference Method

Yoshihide SAWADA<sup>†a)</sup> and Hidekata HONTANI<sup>†b)</sup>

あらまし 本論文では、臓器表面の point distribution model (PDM) と医用画像との非剛体位置合せを高精度化するための、グラフィカルモデルの構築法と確率推論法について報告する。PDM は臓器表面など曲面を多数の点の集合で表現し、各点の座標を確率変数とするグラフィカルモデルが曲面の統計を表現する。グラフィカルモデルによる表現を構築する際、従来法の多くは曲面上の測地距離に近い 2 点を辺で結んでいた。しかし、測地距離のみで 2 点の条件付き従属性を正しく判定できるか否かは自明ではない。本論文では、統計的に根拠をもつ方法によりグラフィカルモデルの構造推定を行うことで位置合せの精度が統計的に有意に向上することを確認したので報告する。同時に、本論文ではグラフィカルモデル上での確率推論の方法に関しても報告する。確率推論に主として利用される方法である、確率伝搬法と MCMC を用いて精度の比較を行った。同一のモデル・同一のテストデータを用いて実験を行ったところ、MCMC の方が有為に推定精度が高いことを確認したので、併せて報告する。

キーワード 非剛体位置合せ, point distribution model, グラフィカルモデル, 構造推定, 確率推論

## 1. ま え が き

三次元医用画像中の臓器表面と臓器モデルとの高精度な位置合せは、大量の画像から臓器領域を自動抽出して、対象臓器に関する統計を計算することを可能にする。そのため、臓器の体積や体内における位置、形状などの解剖学的知見の取得に役立つ [1]。高精度な位置合せは診断支援や治療計画にとって必須の機能であり、多くの研究が行われている [2]～[12]。

本論文では、臓器表面の表現に PDM (Point Distribution Model) [12], [13] を採用し、PDM と医用画像との非剛体位置合せを高精度化するための比較実験について報告する。位置合せの方法としては、文

献 [14], [15] の方法を採用する。この方法は、各点において位置や局所アピランスの確率分布をもつグラフィカルモデルを構築し、構築したモデルに従って新規画像との位置合せを行う。位置合せは各点における周辺事後分布を推論することで行い、推論した周辺事後分布の平均位置によって画像中の臓器の位置を推定する。周辺事後分布は推論の確度が高くなるほど局在化する。そのため、周辺事後分布の分散の逆数によって、位置合せの際に重要となる、各点における確度を自己推定することができる [14]。本論文では、グラフィカルモデルの構造と周辺事後分布の推論方法に着目し、これらを変化させたときの精度の比較を行う。

一般にグラフィカルモデルは、各確率変数をそれぞれのノードにより表現する、多変量確率分布のグラフによる表現である。それら多数の確率変数のうち二つが条件付き独立の場合には、対応する二つのノード間は辺で結ばず、それ以外の場合にはノード間を辺で連結することによりグラフの構造を決定する [16]～

<sup>†</sup> 名古屋工業大学, 名古屋市

Nagoya Insutitute of Technology, Gokiso-cho, Showa-ku, Nagoya-shi, 466-8555 Japan

a) E-mail: sawada@cv.nitech.ac.jp

b) E-mail: hontani@nitech.ac.jp

[18]. しかし、文献[14],[15]を含むグラフィカルモデルにより PDM を表現する多くの手法においては、画像中で距離の近い 2 点に対応するノードを辺で連結することによりグラフィカルモデルの構造を決定している[19],[20]. 例えば、臓器表面上の 2 点が近くにあれば条件付き独立でない可能性は高く、それら 2 点を辺で結ぶことに違和感はない. しかし、距離のみに基づき条件付き独立性の有無を判定できるかどうかは自明ではない. モデルの構築の前に体型などを正規化するのであれば、その正規化も独立性の有無に影響を与える[21].

本論文では、臓器 PDM の統計を表現するグラフィカルモデルの構造を学習データの精度行列を推定することにより決定する. 多変量のグラフィカルモデルの構造は、それら多変量が正規分布に従うとき、共分散行列の逆行列である、精度行列によって推定することができる[18]. 精度行列の非対角成分のゼロ要素が条件付き独立な点間に対応する. ただし、医用画像において十分な学習データを収集することは容易ではない[12]. 学習データ数が少ないとき、推定される精度行列は過学習を起こし、不正確になり得る. 過学習を抑制する一般的な手法は、推定対象に何らかの拘束を設け、正則化するものである.

ところで、臓器表面のような生体膜の形状は、部分的な形状の変形の組合せによって表現されることが多い[12],[22]. 例えば、臓器の一部が他の臓器と接触すると、接触箇所近傍のみが変形する. このように、ある点の変位が臓器全体へと波及せず、限られた点にのみ影響を及ぼすことは、グラフィカルモデルにおいて各ノードが全ノードと結合されるのではなく、限られた一部のノードとのみ結合されることを意味する. このとき、精度行列は非対角成分の一部のみが非ゼロとなる、スパースな構造をもつようになる. 精度行列をスパースな構造に拘束して推定する手法としては、graphical lasso [18] が広く知られている. そこで本論文では、graphical lasso を用いてスパースな精度行列を推定し、得られた精度行列に基づいて PDM を表現するグラフィカルモデルの構造を決定する. 本論文では、graphical lasso によって 2 変数間の条件付き独立性を考慮して構築したグラフと、次の各手法により構築したグラフを比較する. まず、点間の（条件付きではない）相関に基づきグラフの構造を決定するために、正準相関解析 (canonical correlation analysis: CCA) [11],[23]~[27] を適用した. 正準相関の強弱は、

本来の条件付き独立性の有無とは異なるが、比較として正準相関の強い点同士を連結してグラフを構築する. 次に、2 点間の測地距離に基づき構造を決定したグラフィカルモデル [15] と、完全グラフ [28],[29] を構築とするモデルとも比較を行った. その結果、graphical lasso によって構築したグラフを用いることで、位置合せの精度が有為に向上したので報告する.

本論文で扱う位置合せ法は、グラフィカルモデル上で各点座標の周辺事後分布を推論する. 各点の座標の事前分布は正規分布で近似できるが、アピアランスに基づくゆう度分布は与えられた画像上において非線形な分布になる [15]. グラフィカルモデル上の非線形な分布の確率推論に用いられる代表的なアルゴリズムにはノンパラメトリック確率伝搬法 (non-parametric belief propagation: NBP) [15],[24]~[26],[30]~[32] とマルコフ連鎖モンテカルロ法 (markov chain monte carlo: MCMC) [16],[24]~[26],[33]~[35] の二つがある. このうち、文献[14],[15] が採用している確率伝搬法はグラフィカルモデルが木構造の場合は正確に分布を推論することができるが、グラフィカルモデルに閉路がある場合は不偏推論になることが保証されていない[28],[36]. 一方、MCMC は分布からサンプリングを行う方法である. 得られるサンプルは閉路の有無にかかわらず、サンプリングを十分な回数行えば、求めたい分布からのサンプルへと収束する [16],[35]. そのため、グラフに多数の閉路が存在する場合には、MCMC の方が確率伝搬法よりも高精度な推論を行う可能性が高い. そこで本論文では、同一のモデル・同一のテストデータに対して NBP と MCMC のそれぞれを適用し、推論精度の比較を行う. この結果、MCMC の方が NBP よりも有為に正確な位置合せを実現したので、併せて報告する.

## 2. PDM を用いた非剛体位置合せについての関連研究

曲面を PDM で表現したときの、非剛体位置合せの従来法について述べる. 非剛体位置合せを行う際、曲面の変形を制限しなければ工学的に有意義な結果を得られない. 制限がなければ、例えば曲面を一点に収めさせることにより、誤差ゼロでどのようなデータに対しても任意の曲面を位置合せすることができる. 従来法のうち、ACM (Active Contour Model) [2],[3],[37],[38] と Non-rigid ICP (Iterative Closest Point) [39],[40] に代表される手法は、曲面に剛性や滑らかさを要求す

る．いずれも PDM において隣接する点間の変位差にペナルティを課し，これにモデルとデータ間の偏差と合わせたコスト関数を最小化することによりモデルをデータへと位置合せする．これらの方法は対象の形状に関する知識のないときに，画像中の境界領域を抽出する際に有用である．しかし，これらの方法を医用画像中の臓器モデルの位置合せに応用することは容易ではない．ACM も Non-rigid ICP も臓器表面の形状に関する統計をモデル化できない．医用画像においては複数の臓器が隣接して存在しており，曲面の剛性や滑らかさのみに基づいて複数の臓器を区別し，特定の臓器のみにモデルを位置合せすることは難しい．医用画像中の臓器領域を抽出するには，臓器モデルが対象臓器の形状の統計も表現できる必要がある．

対象臓器の形状を PDM により表現する従来法のうち代表的なものに ASM (Active Shape Model) [12], [13] がある．ASM は対象形状のバリエーションを形状の部分空間により表現し，PDM の変形をこの部分空間上に制約する．学習データに基づき部分空間表現を構築する際には，データに主成分分析を適用する．モデルの位置合せは，基本的にデータをこの部分空間へと射影することにより行われ，データに対象以外から抽出された点が含まれるような場合でも比較的頑健な位置合せができる．このため，臓器位置合せだけでなく [8]～[10]，顔の位置合せなど幅広く応用されている [41]～[43]．形状だけではなく，画像のアピランスも含めて表現するモデルには AAM (Active Appearance Model) [12], [44], [45] がある．AAM を用いると，対象表面候補点を画像より陽に抽出することなく，モデルの位置合せを実行できる．ただし，医用画像のように対象内部のテクスチャが患者ごとに大きく変化しうる場合には，一般に位置合せの精度は ASM より低くなる [45]．

ASM や AAM においてデータの部分空間へと射影する操作は，モデルとデータの残差の二乗和を最小化する手続きにはかならない．これは，残差にガウス分布を仮定した上での最ゆう推定でもある．最ゆう推定は点推定であり [16]，このままでは本論文が焦点を当てる手法 [14], [15] のように周辺事後分布を推論することはできない．また，学習データに主成分分析を適用して構築する部分空間の特性には注意を要する．部分空間表現の基底ベクトルは，多くの場合，全成分がゼロではない．このことは，ASM における部分空間表現が，臓器表面全点が同期して変位する大局的変形の

線形和により対象形状のバリエーションを表現していることを意味する．ASM における部分空間表現をグラフィカルモデルで表現し直せば，そのモデルは，全ノードが互いに連結する完全グラフ構造をもつことになる．先に述べたとおり生体膜で覆われた臓器表面の変形において，一部の変位が臓器全体へと常に波及するとは考えにくい．

曲面の統計の形状の表現にグラフィカルモデルを採用する手法もこれまでに多数提案されている [14], [15], [19], [20], [31], [46]．ASM における部分空間表現と異なり，グラフィカルモデルを用いれば，局所的な変形を陽に表現できる．例えば文献 [20] では，各指の関節などのランドマークの位置を確率変数とし，レントゲン写真への位置合せのために，それらランドマーク間の位置関係をグラフィカルモデルで表現している．また，文献 [14], [15] では，臓器表面に配置した点の座標に関するグラフィカルモデルを構築し，三次元の医用画像に対して位置合せを行っている．これら手法におけるグラフィカルモデルは，無向グラフで表現されたマルコフモデルでもあり，閉路を多数含む構造をもっている．従来法においては，グラフィカルモデルの構造が学習データの統計解析に基づき決定されることはまれであり，多くの場合画像上で近接する 2 点間にのみ条件付従属性を仮定し，対応する二つのノード間を辺で結びグラフィカルモデルを構築している．本来は，確率変数間の条件付独立性に基づき構造を決定することにより，初めて対象形状の統計を正確に表現できるようになる．

モデルの位置合せを行うために，グラフィカルモデル上で最ゆう推定や MAP 推定を行い，PDM の各点の座標を点推定することも可能ではある．しかし，点推定を行うと，位置合せ結果の確度情報を獲得できない．位置合せにおいて，その確度情報を推定することは重要であり [14], [15], [47]，本論文では文献 [14], [15] と同様に，周辺事後分布を推論するアプローチを採用する．前節で述べたように，グラフィカルモデル上における周辺事後分布の推論法には確率伝搬法 [15], [24]～[26], [30]～[32] と MCMC [16], [24]～[26], [33]～[35] が広く利用されている．これら推論法が周辺事後確率分布の推定精度にどのような影響を及ぼすのか調査することも本論文の目的である．

### 3. 統計情報による臓器表面の表現

本論文で採用する位置合せ法は，PDM をグラフィ

カルモデルで表現し、その上で確率推論により各点の座標を推論するものである [15]。各点の周辺事後分布を推論することにより、各点の位置合せの確度も自己評価できることが、この方法の特徴である。本論文の目標は、このグラフィカルモデルの構造と確率推論が位置合せの精度に与える影響を解析することである。以下、本節において、文献 [15] の方法で構築される臓器表面の確率統計モデルについて述べる。

臓器表面の統計モデルは、学習用の複数の臓器表面のそれぞれに対応点を配置し、その対応点の分布に基づき構築する。\$M\$ 個の学習用臓器表面の集合を \$\{S^i\} (i = 1, 2, \dots, M)\$ で表し、臓器表面 \$S^i\$ の上に配置された \$N\$ 個の対応点を \$\{P\_j^i\} (j = 1, 2, \dots, N)\$ で表す。また、対応点 \$P\_j\$ の画像上における三次元座標を \$\mathbf{x}\_j\$ で表す。学習用データは三次元 CT 画像により手作業で抽出したものであり、体型の違いは肋骨と気管支の分岐点を用いた thin-plate-spline により正規化し、全ての画像が共通の座標系で表現されている。対応点の生成には点の分布のエントロピーに基づく方法 [48] を採用する。生成した対応点 \$P\_j\$ に基づき、下記三つの確率分布を推定する [14], [15]。

- \$p(\mathbf{x}\_j)\$: \$P\_j\$ の事前分布
  - \$p(I\_j|\mathbf{x}\_j)\$: \$P\_j\$ 周辺のアピアランス \$I\_j\$ の確率分布
  - \$p(\mathbf{x}\_j, \mathbf{x}\_k)\$: \$P\_j\$ と \$P\_k\$ の相対位置に関する分布
- 本論文では、上記三つの確率分布をそれぞれ以下のように与えた。

$$p(\mathbf{x}_j) = \mathcal{U}(\mathbf{x}_j | \bar{\mathbf{x}}_j, d_j), \quad (1)$$

$$p(I_j | \mathbf{x}_j) = \frac{1}{Z} \exp \left( - \sum_{a=1}^{r_j} \frac{\{\Delta_j^a\}^2}{\lambda_j^a} \right), \quad (2)$$

$$p(\mathbf{x}_j, \mathbf{x}_k) = \mathcal{N}(\mathbf{x}_{j,k} | \bar{\mathbf{x}}_{j,k}, \Sigma_{j,k}). \quad (3)$$

ただし、\$\mathcal{U}(\mathbf{x}\_j | \bar{\mathbf{x}}\_j, d\_j)\$ は \$\bar{\mathbf{x}}\_j = \sum\_i^M \mathbf{x}\_j^i / M\$ を中心とする一様分布を表す。本論文では、各点のマハラノビス距離 \$d\_j = (\mathbf{x}\_j - \bar{\mathbf{x}}\_j)^\top \Sigma\_j (\mathbf{x}\_j - \bar{\mathbf{x}}\_j)\$ が 2 以下の領域で一様の値をもつように設定した。また、式 (3) 中の \$\bar{\mathbf{x}}\_{j,k}\$ と \$\Sigma\_{j,k}\$ は \$\mathbf{x}\_{j,k} = [\mathbf{x}\_j^\top, \mathbf{x}\_k^\top]^\top\$ の平均と共分散を表す。

\$I\_j\$ は \$\mathbf{x}\_j\$ を中心とした一辺 \$L\$ の立方体内部の画像であり、\$L^3\$ 次元のベクトルである。\$\lambda\_j^a\$ (\$\lambda\_j^1 \geq \lambda\_j^2 \geq \dots\$) はアピアランスの集合 \$\{I\_j^i\} (i = 1, 2, \dots, M)\$ の共分散行列から得られる固有値である。\$\Delta\_j^a\$ は \$\Delta\_j^a = (I\_j - \bar{I}\_j)^\top \mathbf{v}\_j^a\$ であり、\$\mathbf{v}\_j^a\$ は \$\lambda\_j^a\$ に対応する固有ベクトル、\$\bar{I}\_j = \sum\_i I\_j^i / M\$ である。また、\$r\_j\$ は寄与率を参照

して決定される固有ベクトルの数を表す。

上記の確率分布を使用して、同時分布 \$p(\{\mathbf{x}\_j\}, \{I\_j\})\$ を以下のように表現する。なお、この分布にはアピアランスのゆう度分布が含まれているため、画像上で非線形な分布になる。

$$p(\{\mathbf{x}_j\}, \{I_j\}) = \frac{1}{Z} \prod_j \psi_j(\mathbf{x}_j, I_j) \prod_{e_{j,k} \in \mathcal{E}} \psi_{j,k}(\mathbf{x}_j, \mathbf{x}_k). \quad (4)$$

ただし、\$\psi\_j(\mathbf{x}\_j, I\_j) = p(\mathbf{x}\_j)p(I\_j|\mathbf{x}\_j)\$、\$\psi\_{j,k}(\mathbf{x}\_j, \mathbf{x}\_k) = p(\mathbf{x}\_j, \mathbf{x}\_k)\$ である。また、\$\mathcal{E}\$ はグラフィカルモデルの辺の集合を表す。文献 [14], [15] の方法では、点 \$P\_j\$ と \$P\_k\$ の平均測地距離がしきい値より低いときに、\$P\_j\$ と \$P\_k\$ をグラフィカルモデル中で辺で連結する。それ以外の点間については、相対位置関係は表現しない。

本論文で考えるグラフィカルモデルの構造を決定することは、\$N\$ 点のうちどの 2 点について相対位置関係を表現するか決定することである。次章において、本論文で扱うグラフィカルモデルの決定法について述べる。

#### 4. 統計的グラフィカルモデルの構築

グラフィカルモデルの構造決定法として、本論文では 4 種類を検討する。一つは文献 [14], [15] と同様に測地距離が近い点同士のみを連結する方法である。これは測地距離が十分遠い点は条件付き独立であるとみなす方法である。すなわち、注目している 2 点以外の点を固定したとき、それら 2 点が互いに離れているときにはそれぞれの座標が独立に変化すると考える。図 1 (A) に、測地距離に基づき構築した、大動脈の上弓部のグラフィカルモデルの例を示す。グラフ構造が曲面に沿っていることが見て取れる。二つ目の方法は任意の 2 点間で座標の正準相関解析 (Canonical Correlation Analysis: CCA) [23] を行い、相関の強い点同士を連結する手法である [11], [24], [25], [27]。条件付き独立性の判定をせず、単に相関の強弱のみでグラフィカルモデルの構造を近似的に決定する。三番目の方法は、全ての点と連結する完全グラフ [28], [29] である。この方法では、ASM の部分空間表現と同様に、臓器上の全ての点が互いに条件付き独立ではないとみなすモデルが構築される。そして最後に、全点の座標分布に正規分布を仮定した上で、その精度行列に基づき構造決定するものである。精度行列は共分散行列の逆行列であり、条件付き独立な 2 点があれば、それら

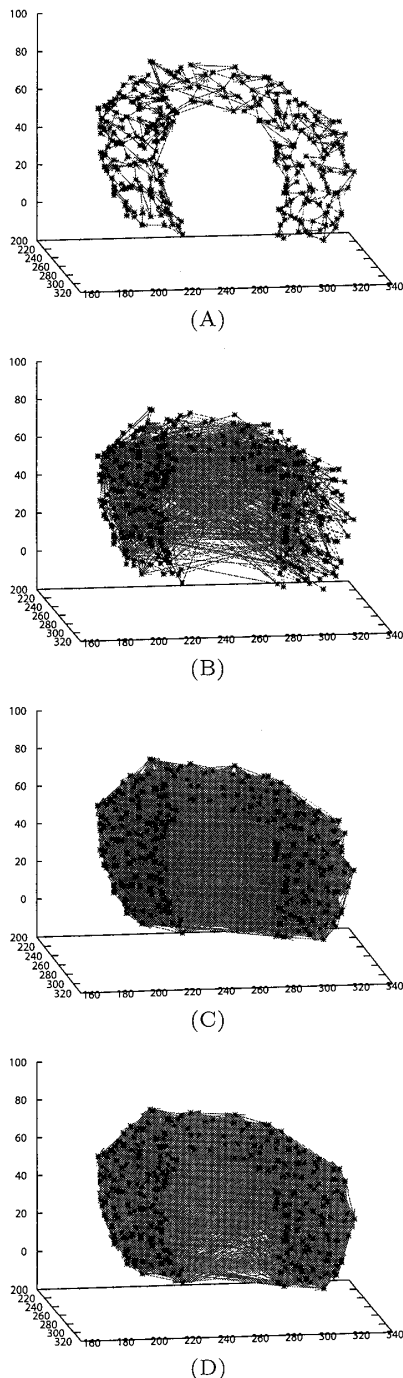


図 1 グラフィカルモデルの構造推定の結果. それぞれ (A) 点間の測地距離, (B) CCA ( $c_{th} = 0.985$ ), (C) CCA ( $c_{th} = 0.935$ ), (D) graphical lasso に基づき推定した.

Fig.1 Estimated structures of the graphical model. Each graph was estimated based on (A) the geodesic distance between two points, (B) CCA ( $c_{th} = 0.985$ ), (C) CCA ( $c_{th} = 0.935$ ), and (D) graphical lasso.

2 点に対応する精度行列の非対角成分はゼロになる. ここでは学習データに対する過学習を回避するために, graphical lasso [18] を用いてスパースな精度行列を推

定し, 条件付き独立性を考慮したグラフィカルモデルの構造を決定する. 以下, CCA と graphical lasso について説明する.

#### 4.1 正準相関解析に基づくグラフィカルモデル構造の推定

CCA は以下の式に従って二つの多次元変数  $x_j$  と  $x_k$  の相関係数  $c_{j,k}$  を計算する方法である [23].

$$c_{j,k} = \max_{\alpha_j, \alpha_k} \frac{\alpha_j^\top C_{j,k} \alpha_k}{\sqrt{\alpha_j^\top C_{j,j} \alpha_j} \sqrt{\alpha_k^\top C_{k,k} \alpha_k}}. \quad (5)$$

ここで,  $x_j$  と  $x_k$  が三次元ベクトルであるなら,  $\alpha_j$  と  $\alpha_k$  は三次元ベクトル,  $C_{j,j}$  と  $C_{k,k}$  はそれぞれ  $x_j$  と  $x_k$  のクラス内分散行列,  $C_{j,k}$  は  $x_j$  と  $x_k$  のクラス間分散行列を表し, いずれも  $3 \times 3$  の行列となる. 相関係数  $c_{j,k}$  は値が大きいほど 2 点間の相関が強いことを示す. なお,  $c_{j,k}$  は 0 以上 1 以下の実数である.

$c_{j,k}$  を任意の 2 点間で計算し,  $c_{j,k} > c_{th}$  を満たす点間を辺で結び, グラフィカルモデルの構造を決定する.

#### 4.2 Graphical lasso に基づく条件付き独立性を考慮したグラフィカルモデルの構造推定

全点の確率変数を並べたベクトルを  $X = [x_1, x_2, \dots, x_N]^\top$  とする. このとき,  $X$  の共分散行列を  $\Sigma = E[(X - E[X])(X - E[X])^\top]$  で表す.  $\Sigma$  の逆行列  $\Theta = \Sigma^{-1}$  は精度行列と呼ばれる.  $\Theta$  の非対角要素が 0 のとき, その要素に対応する 2 点間は条件付き独立となる [18]. ただし, データ数が十分に取得できない場合に, 推定される精度行列が過学習により不正確になり得る. そこで, graphical lasso においては, 多くの確率変数間が条件付き独立であることを仮定し, 精度行列をできるだけスパースとする正則化項を加えた次式を最大化することにより精度行列を推定する.

$$\hat{\Theta} = \arg \max_{\Theta} \{\log \det \Theta - \text{tr}(S\Theta) - \rho \|\Theta\|_1\}. \quad (6)$$

ただし,  $\text{tr}(\cdot)$  は行列のトレースを表し,  $S$  は  $M$  個の学習用データから得られる共分散行列を表す. 右辺の最初の 2 項が学習データに対するゆう度を表し, 最後の 3 項目が正則化項を表す. 正則化項の係数  $\rho$  は調整パラメータを表し,  $\rho$  を大きく設定するほど  $\hat{\Theta}$  はスパースになる.

## 5. 周辺事後分布の確率推論

新規画像  $I$  が与えられたとき、構築したモデルに従って各点の位置の周辺事後分布  $p(\mathbf{x}_j|I)$  を推論することでモデルと画像との位置合せを行う。以下に、本論文で行う非剛体位置合せ法の簡単な処理の流れを示す [15].

- (1) 新規画像  $I$  の体型を正規化する.
- (2) 各点の事前分布  $p(\mathbf{x}_j)$  とゆう度分布  $p(I_j|\mathbf{x}_j)$  の積  $\psi_j(\mathbf{x}_j, I_j)$  (式 (4) の第一項) を計算する.
- (3)  $\psi_{j,k}(\mathbf{x}_j, \mathbf{x}_k)$  も考慮して、グラフィカルモデル上で周辺事後分布  $p(\mathbf{x}_j|I)$  を推論する.

周辺事後分布の推論方法には、文献 [14], [15] で使用しているノンパラメトリック確率伝搬法 (non-parametric belief propagation: NBP) [31], [32] のほかに、周辺事後分布の推論方法として広く利用されているギブスサンプリング (gibbs sampling: GS) [16], [24] ~ [26], [34], [35] を採用する。本論文では、これら二つの確率推論法を用いたときの位置合せの精度の違いを同一の確率モデル・同一のテストデータを用いて比較する。以降では、これら二つの方法について説明を行う。

### 5.1 ノンパラメトリック確率伝搬法

NBP はグラフィカルモデル上で連結されている点間でメッセージを交換しながら、確率変数の分布を繰り返し更新していく方法である [31], [32].

$t$  ( $t = 1, 2, \dots, T$ ) 回目の更新時における  $\mathbf{x}_j$  の周辺事後分布を  $\hat{p}^{(t)}(\mathbf{x}_j|I)$  と表し、 $P_k$  から  $P_j$  へ送信されるメッセージを  $m_{k,j}^{(t)}(\mathbf{x}_j)$  と表す。ただし、 $T$  は繰り返し回数の上限を表し、手作業で設定する [31], [32]. このとき、 $\hat{p}^{(t)}(\mathbf{x}_j|I)$  はポテンシャル  $\psi_j(\mathbf{x}_j, I_j)$  とメッセージ  $m_{k,j}^{(t)}(\mathbf{x}_j)$  を用いて次式のように計算する。

$$\hat{p}^{(t)}(\mathbf{x}_j|I) \propto \psi_j(\mathbf{x}_j, I_j) \prod_{e_{j,k} \in \mathcal{E}} m_{k,j}^{(t)}(\mathbf{x}_j). \quad (7)$$

このとき、メッセージ  $m_{k,j}^{(t)}(\mathbf{x}_j)$  は以下のように表現される。

$$m_{k,j}^{(t)}(\mathbf{x}_j) \propto \int_{\mathbf{x}_k} \psi_{j,k}(\mathbf{x}_j, \mathbf{x}_k) \frac{\hat{p}^{(t-1)}(\mathbf{x}_k|I)}{m_{j,k}^{(t-1)}(\mathbf{x}_k)} d\mathbf{x}_k. \quad (8)$$

ただし、本論文では以下のように  $W_{bp}$  個の混合ガウス分布を用いて表現する [32].

$$m_{k,j}^{(t)}(\mathbf{x}_j) = \sum_{w=1}^{W_{bp}} \omega_{k,j}^w \mathcal{N}(\mathbf{x}_j | \boldsymbol{\mu}_{k,j}^w, \boldsymbol{\Sigma}_{k,j}). \quad (9)$$

ここで、 $\omega_{k,j}^w$  は各ガウス分布の重みを表し、 $\boldsymbol{\mu}_{k,j}^w$  は各ガウス分布の平均を表す。また、 $\boldsymbol{\Sigma}_{k,j}$  は共分散行列を表し、各ガウス分布で同一の値に設定する [32]. このような表現を使用することによって、メッセージは  $\{\omega_{k,j}^w, \boldsymbol{\mu}_{k,j}^w, \boldsymbol{\Sigma}_{k,j} | w = 1, 2, \dots, W_{bp}\}$  で定義されるパーティクルの集合として表現することができる。

上記のように  $W_{bp}$  個のパーティクルで表現したメッセージ  $m_{k,j}^{(t)}(\mathbf{x}_j)$  を、 $P_j$  は辺で結ばれた  $P_k$  から受信する ( $e_{j,k} \in \mathcal{E}$ ). その後、式 (7) に従って  $\hat{p}^{(t)}(\mathbf{x}_j|I)$  を更新する。この際、メッセージと同様に、 $\hat{p}^{(t)}(\mathbf{x}_j|I)$  は  $W_{bp}$  個のパーティクルを使用して以下のように表現する。

$$\hat{p}^{(t)}(\mathbf{x}_j|I) = \sum_{w=1}^{W_{bp}} \omega_j^w \mathcal{N}(\mathbf{x}_j | \boldsymbol{\mu}_j^w, \boldsymbol{\Sigma}_j). \quad (10)$$

### 5.2 ギブスサンプリング

GS は、 $P_j$  の周辺事後分布  $p(\mathbf{x}_j|I)$  をサンプルの集合  $\{\mathbf{z}_j^{(w)} | w = 1, 2, \dots, W_m\}$  で近似する方法であり、MCMC の一種として広く利用されている。まず、ポテンシャル  $\psi_j(\mathbf{x}_j, I_j)$  に従ってサンプル  $\mathbf{z}_j^{(1)}$  を取得する。次に、以下の条件付き分布を計算する。そして、式 (11) の値に従って新たなサンプル  $\mathbf{z}_j^{(w+1)}$  を取得する。

$$p(\mathbf{z}_j | \mathbf{Z}_{\setminus j}) = \psi_j(\mathbf{z}_j, I_j) \prod_{e_{j,k} \in \mathcal{E}} \psi_{j,k}(\mathbf{z}_j, \mathbf{z}_k). \quad (11)$$

ただし、 $\mathbf{Z}_{\setminus j} = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_{j-1}, \mathbf{z}_{j+1}, \dots, \mathbf{z}_N\}$  である。この計算を全点に対して行い、サンプル数が  $W_1$  個になるまで繰り返す。

ここで、GS に代表される MCMC の手法の多くは、繰返しの初期段階のサンプルが周辺事後分布  $p(\mathbf{x}_j|I)$  に従わない可能性がある。そこで本論文では、 $W_0 (< W_1)$  回までの繰返しで得られたサンプルを棄却して、残りの  $W_m = W_1 - W_0$  個のサンプル  $\{\mathbf{z}_j^{(w)} | w = W_0 + 1, W_0 + 2, \dots, W_0 + W_m\}$  を使用する [35]. また、GS は  $p(\mathbf{x}_j|I)$  が多峰性の場合には、それら多数の峰のうち一つの峰のみからサンプルされる場合がある。このとき、サンプル集合  $\{\mathbf{z}_j\}$  は分布を正確に表現しない。このような状態を防ぐために、本論文では初期状態の各々異なる  $D$  個の GS を複数同時に実行する。そして、全ての点  $P_j$  において以下の  $R$  を計算して、各 GS で得られたサンプリング結果が  $p(\mathbf{x}_j|I)$  を十分に近似しているかどうか判定を行う [35].

$$R = \left(1 + \frac{\sigma_B^2/\sigma_W^2 - 1}{W_m}\right)^{1/2}. \quad (12)$$

ただし,

$$\sigma_B^2 = \frac{W_m \sum_{d=1}^D (m(d) - \bar{m})^2}{D-1}, \quad (13)$$

$$\sigma_W^2 = \frac{\sum_{d=1}^D \sum_{w=1}^{W_m} (z_j^{(W_0+w)}(d) - m(d))^2}{DW_m}, \quad (14)$$

であり,  $\{z_j^{(W_0+w)}(d)|w = 1, 2, \dots, W_1, d = 1, 2, \dots, D\}$ ,  $m(d) = (\sum_w z_j^{(w)}(d))/W_m$ ,  $\bar{m} = (\sum_d m(d))/D$  である. 本論文では,  $R \simeq 1$  のときにサンプリングを終了する [35]. そして, 最終的に得られた  $DW_m$  個のサンプルを用いて周辺事後分布  $p(x_j|I_j)$  を推論する.

## 6. 実画像を用いた評価実験

グラフィカルモデルの構造決定法の違いと確率推論法の違いによる, 位置合せの精度の違いを三次元 CT 画像中の大動脈を対象として行った. 使用した画像は空間分解能が  $0.98 [\text{mm}] \times 0.98 [\text{mm}] \times 4.25 [\text{mm}]$  の非造影画像であり, 前述したように, 事前に体型の正規化を行っている.

まず,  $M = 12$  症例の CT 画像中の大動脈に  $N = 300$  点の対応点をエントロピーに基づき配置した [48]. 配置結果の例を図 2 に示す. 臓器全体に対応点が配置されているのが確認できる.

位置合せの精度は, 学習データ 12 症例に対して leave-one-out を行うことで評価した. 評価には, 推論結果と真の大動脈表面との誤差を用いた.

$$E_j^i = |\hat{\mu}_j^i - \bar{\mu}_j^i|. \quad (15)$$

ただし,  $\hat{\mu}_j^i$  は  $i$  番目の症例の  $j$  番目の点の周辺事後分布を推論したときの期待値を表し,  $\bar{\mu}_j^i$  は結果から最も近い大動脈表面の位置を表す.




図 2 対応点の配置の例. 同じ色同士の点に対応している.

Fig. 2 Examples of the corresponding points. The colors represent the index.

なお, 本論文で使用するパラメータは  $L = 5$ ,  $W_0 = 1000$ ,  $T = 5$ ,  $W_{bp} = 1000$  と設定した. これらパラメータの値は実験により精度が最良となるように設定した.

### 6.1 推論法の違いによる位置合せの精度の変化

グラフィカルモデルの構造を固定し, 確率推論に GS を用いる場合と NBP を用いる場合で位置合せの精度がどのように変化するかを確認した. グラフィカルモデルの構造には CCA に基づく手法により決定したものを採用した. 使用したグラフィカルモデルを図 1 (B) に示す. ただし,  $c_{th} = 0.985$  と設定した.

本論文では, 複数同時に実行する GS の数を変化させつつ NBP と精度の比較を行った. 具体的には,  $D = 1, 2, 3, 4$  と設定した. ただし,  $D = 1$  は 5.2 で述べた収束判定を行うことができないため,  $W_m = 1000$  と固定して実験を行った. これは, NBP のパーティクル数と同じであることに注意する. 位置合せの精度評価結果を図 3 に示す. 図 3 の縦軸は各症例における誤差の平均  $E^i = \sum_j E_j^i / N$  を表す. また, 表 1 は  $E^i$  の最小値, 平均値, 最大値を示している. GS における並列数  $D$  を増やすと, 推定誤差は基本的に減少していくことを確認した. また, GS と NBP を比較するとき, 同一のモデルを同一の画像に対して位置合せをしているにもかかわらず, 確率推論に NBP を用いる場合よりも GS を用いる場合の方が位置合せの精度が高いことが確認できた. NBP はグラフィカルモデルに閉路を含んでいる場合, 不偏推論になることが保証されていない [28], [36]. 実際に, 実験で使ったグラフィカルモデルには図 1 (B) に示すように, 大きさの異なる多数の閉路が存在する. 一方の MCMC はグラフの構造にかかわらず, 十分なサンプリングを行えば, 目的とする分布からの正確なサンプリングを実現できる. 推論法以外の条件を揃えた比較実験であるため, NBP では十分な精度が得られなかったのは, NBP による推定バイアスが原因であると考えられる. 本論文では, これらの結果の統計的有意差を Wilcoxon 符号付き順位検定により検定した. その結果, 本論文で設定した全ての  $D$  の値において, NBP よりも位置合せの精度が有意に高いことが確認できた ( $p < 0.05$ ). 以降では, 平均誤差が最も小さかった  $D = 4$  に固定して実験を行う.

図 4 の (A) と (B) に各点での  $E_j^i$  の分布を示す. 図 4 (A) が NBP により得られた誤差分布であり, (B) が GS により得られた分布である. いずれも色が濃い




図3 確率推論ごとの各症例に対する位置合せの誤差. グラフィカルモデルの構造は固定. 横軸: 症例番号, 縦軸: 平均誤差  $E^i$  [mm].

Fig. 3 Averaged registration error for each case obtained by each of the probabilistic inference methods. For all cases, the structure of the graphical model was fixed. The horizontal axis: the case index. The vertical axis: the averaged error [mm].

表1 確率推論の違いによる位置合せ精度の違い  
Table 1 The difference of the registration accuracy with respect to the method of the probabilistic inference.

	最小値 [mm]	平均値 [mm]	最大値 [mm]
GS (D=1)	2.17	3.87	6.35
GS (D=2)	2.14	3.85	6.26
GS (D=3)	2.03	3.78	6.26
GS (D=4)	1.87	3.72	6.30
NBP	2.23	4.11	6.99



(A) CCA+NBP



(B) CCA+GS

図4 大動脈の位置合せの誤差  $E_j^i$  の分布

Fig. 4 Difference of the error for the registered aorta.

部位ほど誤差が大きいことを示している. GSの方が誤差  $E_j^i$  が小さいため, 全体に色が薄く表示されている. NBPを用いてもGSを用いても, 似た部位で推定誤差が大きいことが分かる. これら誤差の大きい部位は, 図5に示すように, 大動脈が他の臓器と接触




図5 エッジが欠落している部位の周辺事後分布の推論結果の例. (A) 矢印が点の位置を示している. (B) GSによる周辺事後分布の推論結果.

Fig. 5 Examples of marginal posterior distributions of lacking edges. (A) The arrow indicates the position of point. (B) The result of the inference of GS.

し, 患者によっては臓器表面のエッジが欠落している部位である. そのため, 図5(B)に示すように, 正確に臓器表面を推定することができず, 推定誤差が大きくなった.

最後にGSとNBPの実行時間を示す. なお, 使用した計算機はIntel社製CPU Xeon(R) E5620を搭載したものであり, OSはCentOS 5.6 (64 bit)である. 上記計算機を使用した結果, GSは平均約20分で終了したのに対し, NBPはGSの10倍以上を必要とした. これは, 精度を向上させるために多くのパーティクル ( $W_{bp} = 1000$ ) を使用してメッセージを伝搬していることが主な原因である [32].

以上の結果から, グラフィカルモデル上での確率推論に基づき高精度な位置合せを行うためには, NBPよりもGSの方が適していると考ええる.

## 6.2 グラフィカルモデルの構造の違いによる位置合せの精度の変化

次に, 確率推論法をGSに固定して, グラフィカルモデルの構造を変化させたときの位置合せ精度の変化を確認した. グラフィカルモデルの構造は, graphical lassoに基づき推定した場合とCCAに基づき推定した場合, 2点間の測地距離に基づき推定した場合 [14] と完全グラフの4種類を用意し, 比較した. 構築したグラフィカルモデルを図1に示す. 図1(C)は先に述べたとおり, CCAに基づき推定したグラフィカルモデルの構造である. このとき, しきい値を表すパラメータ  $c_{th}$  は, 位置合せの精度が最良となるように設定した. 具体的には  $c_{th} = 0.935$  と設定した. 点間の相関に従って構造を推定したことにより, 図1(A)に示す2点間の測地距離に基づいて構造を推定したモデルとは異なる



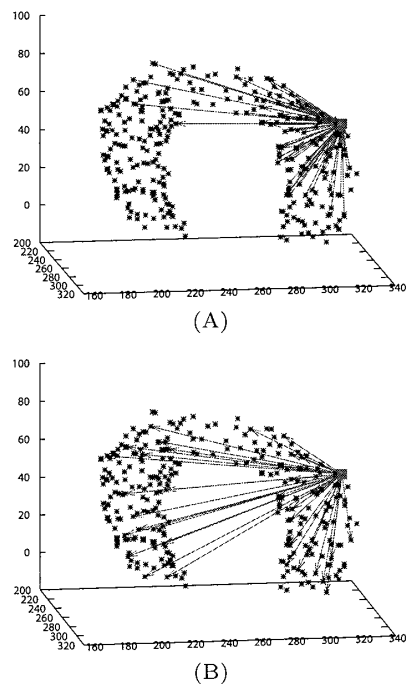
表 2 構築したグラフィカルモデルの辺の総数と次数の比較

Table 2 Comparison of the informations of edges.

	Glasso	Distance	CCA	Full
総数	7834	545	10029	44850
最大次数	94	7	298	299
平均次数	52	3	66	299
最小次数	11	3	25	299

り、近隣の点のみではなく、遠方の点とも辺で結ばれていることが確認できる。また、表 2 にグラフの辺の総数と次数に関する情報を示す。左列の distance は測地距離に基づき構築したグラフ構造であり、図 1 (A) に対応する。辺の総数は 545 本と少なく、次数すなわち各点に接続している辺の本数も一定して少ない。一方、CCA で構築したグラフは辺の数が distance より多く、最大次数 (298) と平均次数 (25) の差が大きい。これは、大動脈上の特定の部位が近傍以外の多くの部位とも強い相関をもっていることを示している。

Graphical lasso に基づき推定したグラフィカルモデルを図 1 (D) に示す。ただし、graphical lasso のパラメータは、CCA と同様に位置合せの精度が最良となるように設定した。具体的には、 $\rho = 30$  とした。CCA で構築した場合と同様に、測地距離の意味で離れている点同士が辺で結ばれていることが分かる。先に述べたとおり、モデル構築を行う前に、気管支の分岐点と肋骨を用いて体型の正規化を行っている。大動脈上弓部は気管支分岐点をまたぐように通過するため、正規化により上弓のアーチ部分を中心として、左右対称な変形が行われる。この変形は局所的ではなく、大局的な変形である。対称軸左側と右側は同期して変位する。このため、対称軸を挟んだ離れた 2 点の位置座標分布は、それら以外の点を全て固定したとしても、独立ではなくなる。すなわち、離れた 2 点が条件付き従属性をもつようになり、グラフ内で辺で結ばれるようになる。ただし、近傍の点以外とも連結されてはいるが、辺の本数 (7834 本) は完全グラフの場合 (44850 本) の約 17% であり、精度行列がスパースであることに注意する。体型正規化はモデルの位置合せの前処理に不可欠であり、この前処理の影響を CCA や graphical lasso を利用することにより、モデルに組み込んでいることが分かる。表 2 の glasso を見ると、CCA の場合と比べて辺の総数が少なく、最大次数と最小次数の差も小さいことが分かる。条件付き独立性を考慮して構造推定することにより、各点がまんべんなく連結さ

図 6 四角形で示した点に接続する辺集合。(A) graphical lasso, (B) CCA ( $c_{th} = 0.935$ )Fig. 6 A set of edges connected to the point indicated by the green square. (A) graphical lasso, (B) CCA ( $c_{th} = 0.985$ ).

れるようになったことが分かる。

図 6 に図 1 (C) と (D) に示したグラフから適当に選択した 1 点に接続している辺のみを、構造の特徴の違いを示すために、例示する。図 6 (A) は graphical lasso により構築されたものであり、近傍の点と遠くの点の双方が連結されていることが分かる。一方、図 6 (B) は、CCA に基づき構築された構造であり、近傍の点とは辺で接続されておらず、遠くの点とのみ接続されている。離れた点ほど正規化などの影響で患者の違いによる対応点の座標の変化も大きく、その結果相関の値も大きくなる傾向にあるため、遠い点が好んで連結される。

位置合せの結果を図 7 に示す。図 7 を見ると、いずれの症例についても、graphical lasso を用いて構築したモデルによる結果が誤差を小さくする傾向にあることが分かる。全点を連結した完全グラフは、これら四つの中で最も辺の数が多いが、推定誤差は最小ではない。表 3 に誤差の大きさを示す。これら四つの構造推定法のうち、graphical lasso を用いたものが最良の結果となった。この結果は Wilcoxon 符号付き順位検定により統計的に有為であることが確認された ( $p < 0.05$ )。




図 7 グラフィカルモデルごとの各症例に対する位置合せの誤差。横軸と縦軸は図 3 と同じ

Fig. 7 Averaged registration error for each case obtained by each of the graphical structures. The axes indicate same ones with those in Fig. 3.

表 3 グラフィカルモデルの構造の違いによる位置合せの精度の違い

Table 3 The difference of the registration accuracy with respect to the structure of the graphical model.

	最小値 [mm]	平均値 [mm]	最大値 [mm]
Glasso	1.67	3.26	5.40
Distance	2.05	3.77	6.37
CCA	1.76	3.46	5.43
Full	1.88	3.48	5.27

本論文で採用した位置合せ手法は、PDM の各点の座標をグラフィカルモデル上で推論する。推論により得られる推定値の精度は、そのグラフィカルモデルが対象の統計を正確に表現するほど、高くなる。グラフィカルモデルの構造はその定義上、条件付き独立性の有無に基づき決定しなければならない。CCA は相関の強弱を求める手法であり、相関の強弱のみに基づいて条件付き独立性の有無は判定できない。本論文で示した例においては、CCA により構造推定すると、臓器表面上で隣接する 2 点は連結されず、遠方の 2 点間のみが辺で連結された。この構造は、生体膜の弾力や臓器表面の滑らかさと明らかに整合しない。一方の graphical lasso は精度行列を介して条件付き独立性の有無を評価できる手法であり、実際本例では、近傍の点と遠方の点の結合に成功している。そして、そのグラフィカルモデルの構造推定結果は、位置合せの精度が高かったことによっても支持されている。これらのことが、graphical lasso が CCA よりも優位であったことの背景である。

図 8 には、確率推論の前後における、各点の推定位置の分布の変化を示す。確率推論前は  $\psi_j(\mathbf{x}_j, I_j)$  によ




図 8 確率推論前後の各点の位置の分布。(A) 確率推論前の分布。  $\psi_j(\mathbf{x}_j, I_j)$  により得られる、(B) GS を適用した後の周辺事後分布  $p(\mathbf{x}_j|I)$ 。

Fig. 8 The inferred distributions of the positions of the points. (A) The distributions before the probabilistic inference was applied. These distributions were obtained by computing  $\psi_j(\mathbf{x}_j, I_j)$ . (B) The marginal posterior distributions  $p(\mathbf{x}_j|I)$  obtained after GS was applied.

り各点の画像中の座標が推定される。この推定には他の点との相対的な位置関係が考慮されておらず、臓器の形状に関する情報が使われていない。一方、確率推論を行うときには、 $\psi_{j,k}(\mathbf{x}_j, \mathbf{x}_k)$  の確率モデルが考慮されるため、臓器形状に関するモデルも考慮されることがとなり、結果として確率推論後の分布が局在化する。これは、位置推定の確度が確率推論により向上したことを意味する。

### 6.3 グラフィカルモデルのパラメータを変化させたときの精度の変化

前節では、graphical lasso のパラメータ  $\rho$  の値を固定して実験を行っていた。本節では、graphical lasso のパラメータの値を変更したときの位置合せの精度の変化を示す。図 9 に  $\rho$  の値を 10 ～ 100 まで 10 ずつ変化させたときの  $E^i$  の平均値  $E = \sum_i E^i / M$  を示す。また、比較として CCA のパラメータ  $c_{th}$  を変化させたときの結果も併せて示す。ただし、 $c_{th}$  は 0.93 ～ 0.99 まで  $5.0 \times 10^{-3}$  ずつ変化させた。なお、図中の  $\diamond$  は前節で使用した位置合せの精度が最良のパラメータでの結果を示している。

実験結果より、graphical lasso は CCA に比べて位置合せの精度が高くなる傾向にあることが見て取れる。ただし、graphical lasso は辺の本数が少ない場合は位置合せの精度が CCA よりも低いことも確認できる。これは、辺の本数が少なくなるように  $\rho$  の値を設定し




図 9 グラフィカルモデルの辺の総数を変化させたときの位置合せ精度の変化. 横軸は辺の総数を表し, 縦軸は誤差  $E^i$  の平均値を表す.  $\diamond$  は 6.2 で使用したパラメータでの誤差を示す.

Fig. 9 The change of the registration error with respect to the number of edges in the graphical model. The horizontal axis shows the number of edges and the vertical one shows the average of  $E^i$ . The marks,  $\diamond$ , indicate the best graphs corresponding to the parameters reported in Sect. 6.2.

たことで, グラフィカルモデルに多くの独立な点が含まれたためと考える. 実際に CCA の精度が graphical lasso よりも上回っている, 辺の総数が 1000 程度の場合には, CCA により構築したモデルには独立な点は含まれていなかった ( $c_{th} = 0.985$ ). 一方, graphical lasso は全 300 個の点のうち, 独立な点は約 40% の 127 個となった ( $\rho = 90$ ). 位置合せの精度を最良とするパラメータ ( $\rho = 30$ ) では独立な点は存在しなかった.

以上の結果から, 位置合せ精度の向上のためには, graphical lasso のパラメータは全点が連結するように決定することが有効であると考ええる. ただし, 本論文では大動脈を対象とした実験のみを行っている. 他の臓器においても同様の基準が適用できるかどうかは, 更なる検証が必要と考える.

## 7. む す び

本論文では, 臓器表面上の PDM と三次元医用画像との非剛体位置合せを高精度化するための, グラフィカルモデルの構築法と確率推論法について報告した. PDM を各点の座標を確率変数とするグラフィカルモデルにより表現し, その上で各点の座標を推論した. 従来法の多くでは, 距離に基づきグラフィカルモデルの構造を推定していた. しかし, 一般にグラフィカルモデルは条件付き独立性に従って構造を決定すべきで

あり, 距離のみで条件付き独立性を評価できるか否かは自明ではない. 本論文では, 学習データに基づき点間の統計を解析してグラフィカルモデルの構造を推定し, この推定が位置合せの精度向上に寄与するか否かを調査した. その結果, スパースな精度行列を用いて条件付き独立性を考慮したグラフィカルモデルを構築することによって, 位置合せの精度が統計的に有為に向上することを確認した. また, 確率推論の方法としては, GS を採用すべきであることも実験的に確認した.

本論文では, 上記の内容は全て大動脈を対象として実験を行った. 今後は大動脈以外の臓器に対する実験や学習データを増加させたときのモデル構造や位置合せ精度の変化の調査など, 本論文の内容をより詳細に検証していく予定である. また, 周辺事後分布の推論や条件付き独立性を考慮したグラフィカルモデルの構造推定に関しては, 本論文で採用した以外にも多くの方法が存在する. より高精度な位置合せの実現のためにも, 今後はそれらとの比較・検証も行う必要がある.

## 文 献

- [1] "Computational anatomy," <http://www.comp-anatomy.org/wiki>
- [2] D.E. Maroulis, M.A. Savelonas, D.K. Iakovidis, S.A. Karkanis, and N. Dimitropoulos, "Variable background active contour model for computer-aided delineation of nodules in thyroid ultrasound images," *IEEE Trans. Information Technology in Biomedicine*, vol.11, no.5, pp.537–543, 2007.
- [3] B. Al-Diri, A. Hunter, and D. Steel, "An active contour model for segmenting and measuring retinal vessels," *IEEE Trans. Med. Imaging*, vol.28, no.9, pp.1488–1497, 2009.
- [4] A. Andreopoulos and J.K. Tsotsos, "Efficient and generalizable statistical models of shape and appearance for analysis of cardiac MRI," *Medical Image Analysis*, vol.12, no.3, pp.335–357, 2008.
- [5] A. Klein, S.S. Ghosh, B. Avants, B.T.T. Yeo, B. Fischl, B. Ardekani, J.C. Gee, J.J. Mann, and R.V. Parsey, "Evaluation of volume-based and surface-based brain image registration methods," *NeuroImage*, vol.51, no.1, pp.214–220, 2010.
- [6] X. Zhang, J. Tian, K. Deng, Y. Wu, and X. Li, "Automatic liver segmentation using a statistical shape model with optimal surface detection," *IEEE Trans. Biomed. Eng.*, vol.57, no.10, pp.2622–2626, 2010.
- [7] K.T. Rajamani, M.A. Styner, H. Talib, G. Zheng, L.P. Nolte, and M.A.G. Ballester, "Statistical deformable bone models for robust 3D surface extrapolation from sparse data," *Medical Image Analysis*, vol.11, no.2, pp.99–109, 2007.

- [8] H.C. van Assen, M.G. Danilouchkine, M.S. Dirksen, J.H.C. Reiber, and B.P.F. Lelieveldt, "A 3-D active shape model driven by fuzzy inference: application to cardiac CT and MR," *IEEE Trans. Information Technology in Biomedicine*, vol.12, no.5, pp.595-605, 2008.
- [9] M. Spiegel, D.A. Hahn, V. Daum, J. Wasza, and J. Hornegger, "Segmentation of kidneys using a new active shape model generation technique based on non-rigid image registration," *Computerized Medical Imaging and Graphics*, vol.33, no.1, pp.29-39, 2009.
- [10] T. Heimann, I. Wolf, T. Williams, and H.P. Meinzer, "3D active shape models using gradient descent optimization of description length," *Information Processing in Medical Imaging*, pp.566-577, 2005.
- [11] T. Okada, M.G. Linguraru, Y. Yoshida, M. Hori, R.M. Summers, Y.W. Chen, N. Tomiyama, and Y. Sato, "Development of a framework of automated generation of multi-structure statistical atlas," *2nd International Symposium on Computational Anatomy*, pp.60-64, 2011.
- [12] T. Heimann and H.P. Meinzer, "Statistical shape models for 3D medical image segmentation: A review," *Medical Image Analysis*, vol.13, no.4, pp.543-563, 2009.
- [13] T.F. Cootes, C.J. Taylor, and J. Graham, "Active shape models-their training and application," *Comput. Vis. Image Understand.*, vol.61, no.1, pp.38-59, 1995.
- [14] 渡辺 航, 本谷秀堅, "部位ごとに推定値の確度を自己評価する臓器モデルの画像へのレジストレーション," *Medical Imaging Technology*, vol.29, no.8, pp.149-155, May 2011.
- [15] H. Hontani and W. Watanabe, "Point-based non-rigid surface registration with accuracy estimation," *2010 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.446-452, 2010.
- [16] C.M. Bishop, *Pattern Recognition and Machine Learning*, Springer, 2006.
- [17] S. Allasoniere, P. Jolivet, and C. Giraud, "Detecting long distance conditional correlations between anatomical regions using Gaussian graphical models," *3rd MICCAI workshop on Mathematical Foundations of Computational Anatomy*, pp.111-122, 2011.
- [18] J. Friedman, T. Hastie, and R. Tibshirani, "Sparse inverse covariance estimation with the graphical lasso," *Biostatistics*, vol.9, no.3, pp.432-441, 2008.
- [19] P. Zhang, S.A. Adeshina, and T.F. Cootes, "Automatic learning sparse correspondences for initialising groupwise registration," *Proc. Medical Image Computing and Computer Assisted Intervention 2010*, pp.635-642, 2010.
- [20] R. Donner, G. Langs, B. Micusik, and H. Bischof, "Generalized sparse MRF appearance models," *Image Vis. Comput.*, vol.28, no.6, pp.1031-1038, 2010.
- [21] 山岡尚登, 吉村 涼, 澤田好秀, 本谷秀堅, "Graphical LASSOに基づく臓器点群モデルの構造推定," *信学技報, MI2011-57*, 2011.
- [22] S. Zhang, Y. Zhan, M. Dewan, J. Huang, D.N. Metaxas, and X.S. Zhou, "Deformable segmentation via sparse shape representation," *Proc. Medical Image Computing and Computer Assisted Intervention 2011*, pp.451-458, 2011.
- [23] R. Donner, M. Reiter, G. Langs, P. Peloschek, and H. Bischof, "Fast active appearance model search using canonical correlation analysis," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol.28, no.10, pp.1690-1694, 2006.
- [24] Y. Sawada and H. Hontani, "Performance comparison between markov chain monte carlo and non-parametric belief propagation in registration of point distribution model," *Proc. 2nd International Symposium on Computational Anatomy*, pp.48-53, 2011.
- [25] Y. Sawada and H. Hontani, "A comparison of inferences on graphical model for registering surface model to 3D image," *Second International Workshop on Machine Learning in Medical Imaging*, pp.257-264, 2011.
- [26] 澤田好秀, 渡辺 航, 本谷秀堅, "MCMCと確率伝搬法による臓器レジストレーションの性能比較," *信学技報, MI2010-90*, 2011.
- [27] 山岡尚登, 澤田好秀, 本谷秀堅, "点群統計モデルによる複数臓器レジストレーション," *第30回日本医用画像工学会大会*, pp.1-9, 2011.
- [28] 田中和之, *確率モデルによる画像処理技術入門*, 森北出版, 2006.
- [29] M. Nemoto, Y. Masutani, S. Hanaoka, Y. Nomura, T. Yoshikawa, N. Hayashi, N. Yoshioka, and K. Ohtomo, "Construction of a unified framework for automated detection of anatomical landmarks from medical images and its experimental evaluation," *2nd International Symposium on Computational Anatomy*, pp.37-42, 2011.
- [30] T.X. Han, H. Ning, and T.S. Huang, "Efficient non-parametric belief propagation with application to articulated body tracking," *2006 IEEE Computer Society Conference Computer Vision and Pattern Recognition*, pp.214-221, 2006.
- [31] E.B. Sudderth, A.T. Ihler, M. Isard, W.T. Freeman, and A.S. Willsky, "Nonparametric belief propagation," *Commun. ACM*, vol.53, no.10, pp.95-103, 2010.
- [32] A.T. Ihler, J.W. III, R.L. Moses, and A.S. Whisky, "Nonparametric belief propagation for self-localization of sensor networks," *IEEE J. Sel. Areas Commun.*, vol.23, no.4, pp.809-819, April 2005.
- [33] M.I. Jordan, "Graphical models," *Statistical Science*, vol.19, no.1, pp.140-155, 2004.
- [34] S. Geman and D. Geman, "Stochastic relaxation,

- gibbs distributions, and the bayesian restoration of images," IEEE Trans. Pattern Anal. Mach. Intell., vol.6, no.2, pp.721-741, Nov. 1984.
- [35] 伊庭幸人, 種村正美, 大森裕浩, 和合 肇, 佐藤整尚, 高橋明彦, 計算統計 II マルコフ連鎖モンテカルロ法とその周辺, 岩波書店, 2005.
- [36] K. Murphy, Y. Weiss, and M.I. Jordan, "Loopy belief propagation for approximate inference: An empirical study," Proc. Uncertainty in AI, pp.467-475, 1999.
- [37] M. Kass, A. Witkin, and D. Terzopoulos, "Snakes: Active contour models," Int. J. Comput. Vis., vol.1, no.4, pp.321-331, 1988.
- [38] 石田隆行, 桂川茂彦, 藤田広志, 医用画像ハンドブック, オーム社, 東京, 2010.
- [39] B.J. Brown and S. Rusinkiewicz, "Global non-rigid alignment of 3-D scans," ACM Trans. Graphics, vol.26, no.3, pp.21-30, 2007.
- [40] B. Amberg, S. Romdhani, and T. Vetter, "Optimal step nonrigid icp algorithms for surface registration," 2007 IEEE Conference on Computer Vision and Pattern Recognition, pp.1-8, 2007.
- [41] K. Seshadri and M. Savvides, "Robust modified active shape model for automatic facial landmark annotation of frontal faces," IEEE 3rd International Conference on Biometrics: Theory, Applications and Systems, 2009, pp.1-8, 2009.
- [42] Z. Zheng, J. Jiong, D. Chunjiang, X.H. Liu, and J. Yang, "Facial feature localization based on an improved active shape model," Information Sciences, vol.178, no.9, pp.2215-2223, 2008.
- [43] D. Zhou, D. Petrovska-Delacrétaz, and B. Dorizzi, "Automatic landmark location with a combined active model," IEEE 3rd International Conference on Biometrics: Theory, Applications, and Systems, pp.1-7, 2009.
- [44] T. Cootes, G. Edwards, and G. Taylor, "Active appearance models," Computer Vision-ECCV'98, pp.484-498, 1998.
- [45] R. Beichel, H. Bischof, F. Leberl, and M. Sonka, "Robust active appearance models and their application to medical image analysis," IEEE Trans. Med. Imaging, vol.24, no.9, pp.1151-1169, 2005.
- [46] P.A. Tresadern, H. Bhaskar, S.A. Adeshina, C.J. Taylor, and T.F. Cootes, "Combining local and global shape models for deformable object matching," Proc. British Machine Vision Conference 2009, pp.1-12, 2009.
- [47] K.M. Simonson, S.M. Drescher, and F.R. Tanner, "A statistics-based approach to binary image registration with uncertainty analysis," IEEE Trans. Pattern Anal. Mach. Intell., vol.29, no.1, pp.112-125, 2007.
- [48] J.E. Cates, P.T. Fletcher, M.A. Styner, M.E. Shenton, and R.T. Whitaker, "Shape modeling and analysis with entropy-based particle systems," Information Processing in Medical Imaging, pp.333-345,

2007.


(平成 23 年 10 月 10 日受付, 24 年 2 月 18 日再受付)



澤田 好秀 (学生員)

2009 名古屋工業大学大学院工学研究科情報工学専攻博士前期課程了。同年オムロン(株)入社。2010 より名古屋工業大学大学院工学研究科情報工学専攻博士後期課程に入学。2011 より日本学術振興会特別研究員(DC2), 現在に至る。医用画像処理

に関する研究に従事。日本医用画像工学会会員。



本谷 秀堅 (正員)

1991 東大・工・計数卒。1993 同大大学院工学系研究科計数工学専攻修士課程了。同年(株)東芝入社。1996 より東京大学助手, 2000 より山形大学工学部助教授, 2004 より名古屋工業大学助教授, 2011 より同大学教授, 現在に至る。この間 2010 より 1 年間 UCLA の客員研究員。形状記述, 医用画像処理, センサネットワークなどの研究と教育に従事。博士(工学)。日本医用画像工学会, IEEE 等各会員。