

モデルからの逸脱に頑健な非剛体曲面レジストレーション

浅井 健史^{†1} 山岡 尚登^{†1} 本谷 秀 聖^{†1}

本稿では点群統計モデルにより表現した曲面をデータへとレジストレーションする際に、モデルから逸脱している部分を自動的に検出し無視する手法を提案する。Active Shape Model のような、点群統計モデルを利用した従来の変形方法では、画像から得られた画像に最も近くなるように、モデルの形状パラメータを求める。しかし、対象表面が欠損するなどして統計モデルから逸脱した領域を有するとき、従来法は統計モデルから逸脱している領域とそうではない領域とを区別できないため、形状パラメータを正しく推定できない。そこで提案法は、統計モデルから逸脱する領域が全体の一部分であることを仮定し、逸脱領域を自動的に検出しパラメータ推定をおこなう。そのために L_1 ノルムに基づく正則化項をコスト関数に導入する。シミュレーション画像および 3 次元医用画像中の肝臓を対象に提案法を適用し、その性能を評価したので報告する。

Non-rigid robust surface registration with automatic elimination of outlier regions

TAKESHI ASAI,^{†1} NAOTO YAMAOKA^{†1}
and HIDEKATA HONTANI^{†1}

In this article, we propose a new method for non-rigid surface registration between a surface model and measured data. Proposed method ignore the irregular parts which do not obey the surface model when fit the model shape to a given data. The conventional methods that used Point Distribution Model such as Active Shape Model estimate the model parameters to be near measured data. However, when target surface has parts deviated from statistical model, conventional methods can not estimate model parameters because they can not distinguish irregular region and regular region. Therefore proposed method assumes sparseness of irregular region deviated from statistical model, estimates model parameters while detecting irregular regions automatically. And we introduce a L_1 -norm regularization term to an inference criterion. We apply and evaluate proposed method for artificial range data and clinical X-CT images to show its performance.

1. はじめに

3 次元医用画像中の臓器のセグメンテーションやレンジデータ中の対象認識、顔画像認識などの応用において、対象の曲面モデルをデータへとレジストレーションすることは極めて重要である。このため、曲面モデルとデータをレジストレーションする手法が多数提案されてきた。これらレジストレーション法の多くは、対象表面を表すモデルを有し、モデルと対象データの残差に基づくコスト関数を最小化することによりレジストレーションを行う。例えば ICP (Iterative Closest Point)^{1),2)} や ASM (Active Shape Model)³⁾ では対象表面は点群により表現されており、コスト関数はモデルの各点とデータ上の対応点の間の距離の二乗和により定義される。そしてこのコスト関数を最小化することによりレジストレーションを行なう。

以下本稿では、観測データ中の対象をターゲットと呼ぶ。また、対象表面のモデルをテンプレートと呼ぶことにする。レジストレーション法は、テンプレートをターゲットへと位置合わせする。テンプレートが何をモデルとして表現すべきかは、データとして与えられるテンプレートの性質に依存して変化する。例えば、対象が剛体でターゲットとモデルの形状が同一ならば、テンプレートは変形を表現する必要はない。一方、対象が変形しうる場合には、どのように変形しうるかを適切に表現することによりレジストレーションの精度を向上させることができる。例えば、ASM における Shape Space はテンプレートの変形の表現である。Shape Space を含む対象の変形のモデルは、学習サンプルに基づき統計的に表現されることが多い。

ところで、テンプレートが対象の変形を表現している場合でも、ターゲットが被っている変形をそのモデルで常に記述できるとは限らない。モデルが想定していない変形に対処することは、応用上極めて重要である。例えば、3 次元医用画像中の臓器レジストレーションでは隣接臓器同士の接触により対象臓器の表面を画像中に観測できなくなる。また、病変により臓器の一部が損なわれ形状がモデルから逸脱することもある。モデルから逸脱している領域の形状については、定義の上から明らかなように、レジストレーションに有用なモデルが存在しない。レジストレーション法は、これらモデルから逸脱している領域を自動的に検知

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

し、レジストレーションの対象から除外する仕組みを必要とする。モデルからの逸脱に対処する能力は robustness (頑健性) と呼ばれている。

例えば、Dorai らの手法⁴⁾ は、頑健なレジストレーションを達成するために、テンプレートの注目点とターゲット上の対応点間の距離が注目点の近傍点での距離と比較し、大きく異なる場合には該当点を除外する。Fractional RMSD に基づく ICP 法⁵⁾ はデータセットを、テンプレートと最近傍点との距離が小さいものだけに限定し、外れ値が存在する場合にもコスト関数が局所解に収束することを示した。また、Pulli の手法⁶⁾ では点間の距離の悪い方から数%を除去する。

ロバストレジストレーション法の多くは、テンプレートとターゲットの残差の大きさに基づきモデルから逸脱している領域を検知している。このとき、どの程度の残差を逸脱部としてみなすかを適切に決定する必要がある。一方、上に挙げた例では、Fractional RMSD に基づく ICP 法は残差の大きさではなくモデルから逸脱している領域が全体に占める割合の小ささを陰に仮定した手法となっており、モデルから逸脱しているか否かを判断するための閾値を必要としない。

本稿で提案する手法は、モデルから逸脱している領域の小ささを陽に仮定する。その小さな領域がもし存在すれば、その領域を自動的に検知するとともにレジストレーションの対象から除外し、残りの領域に対してモデルの位置合わせを行なう手法を提案する。

同様の発想に基づく手法に、オプティカルフローの算出に際してオクルージョンの領域を自動検知する手法⁷⁾ が存在する。この手法でも、対象の運動によりオクルージョンの状態が変化した領域を、その領域の狭さに基づき検出する。本提案法の枠組みは、このオクルージョン検知法と同様である。以下、提案法を説明する。

2. 提案手法

2.1 モデル表面の表現

提案法は対象表面を、表面上に配置した N 点の点群により表現する。点群の i 番めの 3 次元座標を u_i , ($i = 1, 2, \dots, N$) と表し、 N 点の座標を並べた $3N$ 次元のベクトルを $u = [u_1^T, u_2^T, \dots, u_N^T]^T$ で表す。この $3N$ 次元のベクトル u が表面の表現である。

この表面の変形は式(1)に示す線形なモデルにより表現する。 U は $3N \times L$ の列直交行列であり、 θ は形状を表す L 次元ベクトルである。 \bar{u} は平均形状を表す。

$$u(\theta) = \bar{u} + U\theta \quad (1)$$

曲面が点群により表現されるとき、各点はその位置における接平面内で摂動しても表現さ

れる形状は変化しないことに注意する。点群統計モデル (PDM: Point Distribution Model) においては、面内の点の配置の変化ではなく、面の法線に沿った点の移動が形状の変化に対応する。

式(1)のモデルは学習サンプルの曲面の PCA により構築する。サンプルとなる曲面上に対応点を生成する必要がある。同一の学習サンプルを利用しても、対応点生成法に依存して得られるモデルが変化する。対応点生成法は本提案法含む全ての PDM を利用する手法にとって極めて重要であるが、本稿では対応点生成法の違いによるモデルの変化には触れない。

2.2 ターゲット

先に述べたとおり、モデルのレジストレーションをおこなうデータをターゲット \mathcal{T} と呼ぶ。ターゲットは必ずしも点群で表現されている必要はない。レンジデータで計測した対象や X 線 CT 画像から抽出した対象臓器の表面がターゲットである。

ターゲットは計測雑音により微小に摂動している。さらに、計測の欠落により穴が空いたり、式(1)のモデルでは表現しきれないような大きな変形をううる。例えば X 線 CT 画像中の臓器表面は、隣接する臓器との接触によりエッジが消失したり、腫瘍などの病変により大きく変形したりする。これらの穴や大きな変形は式(1)のモデルでは表現されない。また、正規分布に従う計測雑音などと異なり、穴や大きな変形を統計モデルで表現することは容易ではない。本提案法の目的は、対象表面の正常なモデルである式(1)のみに基づき、上記の穴や大きな変形の部位を検出し無視しつつ、式(1)のパラメータを推定しモデルをターゲットに位置合わせすることである。

2.3 レジストレーションのためのコスト関数

テンプレート上の点 u_i を通り、テンプレートに直交する法線を l_i と表す。 l_i とターゲットとの交点を v_i とし、ターゲット上の点を u_i に対応付ける。 u_i と v_i の間の符号つき距離を $d_i \in (-\infty, +\infty]$ とし、以下のようにターゲット上の点 v_i を表す。

$$v_i = u_i + d_i n_i \quad (2)$$

ここで、 n_i は点 u_i におけるテンプレート表面の外向き単位法線ベクトルである。直線 l_i とターゲット面 \mathcal{T} 間の交点が存在しない場合は $d_i = +\infty$ とする。

ターゲットの穴などの大きな変形は、先に述べたとおり統計モデルで表現することが困難である。ターゲット上の、統計で変形を表現することが困難な領域を Ω で表すことにする。領域 Ω においては、式(2)の d_i は任意の値をとりうる。一方、領域 Ω 以外の場所では微小な計測雑音により d_i を表現できると仮定する。ゆえに領域 Ω 以外では、平均が 0、分散

が σ^2 であるような正規分布 $\mathcal{N}(0, \sigma^2)$ に従うと仮定する．統計モデルで表現できない残差 d_i の成分を e_i^1 で表し，正規分布に従う計測雑音で表現できる残差成分を e_i^2 で表すことにする． $u_i \in \Omega$ のとき残差 d_i を e_i^1 で表し， $u_i \in T \setminus \Omega$ のとき残差を e_i^2 で表す．すなわち，

$$v_i = u_i + (e_i^1 + e_i^2)n_i \quad (3)$$

である．ただし，

$$e_i^1 = \begin{cases} v_i & (u_i \in \Omega) \\ 0 & (u_i \in T \setminus \Omega) \end{cases}, e_i^2 = \begin{cases} 0 & (u_i \in \Omega) \\ \epsilon & (u_i \in T \setminus \Omega) \end{cases} \quad (4)$$

であり， $\epsilon \sim \mathcal{N}(0, \sigma^2)$ である．

ここで， $e^1 = [e_1^1, e_2^1, \dots, e_N^1]^T$ ， $e^2 = [e_1^2, e_2^2, \dots, e_N^2]^T$ とする．穴や大きな変形がモデルとなる表面の一部にのみ生じることが仮定する．このとき， e^1 は多くの要素が 0 で領域 Ω に属する一部の要素のみが大きな値を持つことになる．一方， e^2 は多くの要素が領域 $u_i \in T \setminus \Omega$ に属し，小さな値を持つことになる．上記のように残差をモデル化することにより，レジストレーションのためのコスト関数を次式のように設定することができる．

$$\psi'(\theta, e^1) = \lambda \|e^1\|_{l_0} + \|e^2\|_{l_2}^2 \quad (5)$$

$$= \lambda \|e^1\|_{l_0} + \sum_{i=1}^N \|v_i - u_i - e_i^1 n_i\|_{l_2}^2 \quad (6)$$

$$= \|v - \bar{u} - U\theta - Ve^1\|_{l_2}^2 + \lambda \|e^1\|_{l_0} \quad (7)$$

ただし，ここで V は以下に示す $3N \times N$ 行列である．

$$V = \begin{bmatrix} n_1 & & & \\ & n_2 & & \\ & & \ddots & \\ & & & n_N \end{bmatrix} \quad (8)$$

式 (7) の右辺第一項は領域 $T \setminus \Omega$ における計測雑音による残差の二乗和を表し，第二項は L_0 ノルムにより領域 Ω に属する点の数を表す． λ は L_0 ノルム正則化項と二乗誤差の項との相対的な重要度を調節するパラメータである．

2.4 最適化

式 (7) の ψ' は L_0 項を含んでおり，その最小化問題は NP 困難である．Donoho らの研究^{8),9)} により， L_1 ノルムの正則化項を導入することで L_0 ノルムによる正則化を行った場

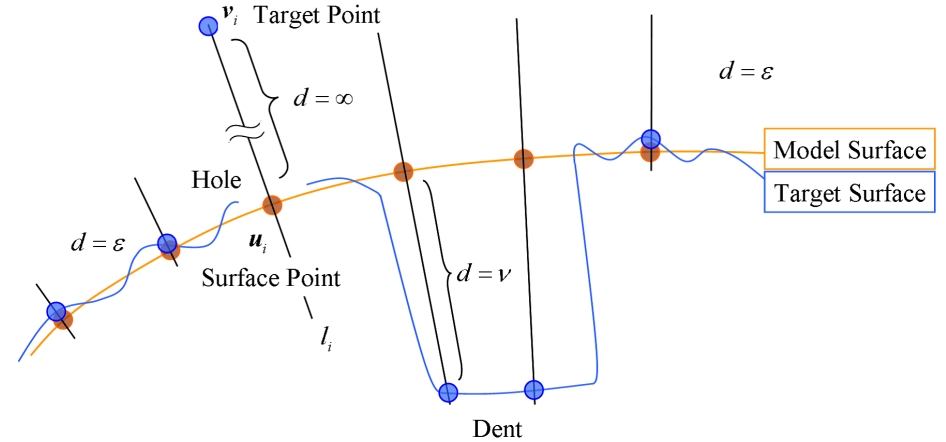


図 1 モデル表面とターゲット T ．ターゲットは雑音による摂動のほか穴やへこみなどによって変形する．
Fig. 1 A model surface and target. The shape of a target can be perturbed by measurement noises. In addition, it can be deformed by holes and large irregularities.

合の解を高い確率で得られることが知られている．そこで，コスト関数を次式のものに書き換える．

$$\psi(\theta, e^1) = \|v - \bar{u} - U\theta - Ve^1\|_{l_2}^2 + \lambda \|e^1\|_{l_1} \quad (9)$$

ICP や ASM などその他の動的輪郭モデルの最適化と同様に，以下に示すように (θ, e^1) の最小化とターゲット点 v_i の選択を交互に繰り返す．式 (9) のコスト関数 ψ を最小化する手続きは以下の通りである．

最小化の手続き

- (0) 形状パラメータの初期値は $\hat{\theta}^0 = 0$ とする．更新後のパラメータとの誤差，および試行回数の閾値をそれぞれ T_θ, T_N とする．試行回数のインデックス k を 1 にセットする．
- (1) $\theta^k = \hat{\theta}^{k-1}$ とし，各 u_i についてターゲット表面 T より v_i をサンプルする．
- (2) v_i を更新したのち，コスト関数を最小化し， $\hat{\theta}^k$ および e^1 を計算する．
- (3) $\|\hat{\theta}^k - \hat{\theta}^{k-1}\| < T_\theta$ ，もしくは $k > T_N$ ならば試行を停止する．そうでなければ， $k \leftarrow k + 1$ とし 1 へ戻る．

重要なことは，点 v_i を固定するときコスト関数 ψ が凸関数であり， v_i が固定されている




図 2 元データ
Fig.2 Original range data.

条件のもとでは最適解を得ることができることである⁷⁾。すなわち、上記手続きの (2) では最適な θ が推定できる。しかし、モデル上の各点 u_i に対応するターゲット上の点 v_i をあらかじめ求める手法が存在しない。このため、上記最小化の手続きにより常に最適解を得られる保証はない。また、この繰り返し更新の収束判定も困難になりうる。しかし実験的に確認できた範囲では、上記繰り返しにより、比較的単調にコスト関数は減少し、適切な解を十分高い確率で得ることができる。

3. 実験

シミュレーション画像、および三次元医用画像に提案法を適用した。本節ではその性能について報告する。

3.1 人工データでのレジストレーション

図 2 に示すレンジデータを Thin-Plate-Spline 法¹⁰⁾ で変形することにより学習サンプルを生成する。それらを式 (1) のモデルを構築するためのサンプルと性能評価用のものに分けた。表面上の点の総数は $N = 1887$ である。

3.2 モデルの構築

学習用サンプルの総数は $K = 1000$ である。変形したデータの一例を図 3 に示す。各データを $u^k (k = 1, 2, \dots, K)$ と表し、 k 番目のデータの i 番目の点を u_i^k と表す。

これら u^k に PCA を適用し、平均形状ベクトル \bar{u} 、データから得られた共分散行列の固有ベクトルを並べた $3N \times L$ 行列 U を計算した。 L の大きさは寄与率により決定した。今回の実験では累積寄与率が 0.99 となる第 34 固有値までに対応する固有ベクトルを採用した。




図 3 データの変形例
Fig.3 Examples of deformed surfaces




図 4 ターゲットデータの例
Fig.4 Examples of targets

3.3 ターゲット曲面の構築

式 (1) のモデルを構築したあと、モデルのパラメータ θ を与えることにより、変形した曲面を生成し、ガウス雑音を各頂点の法線方向に加え、手動により穴をあけることでターゲットのサンプルを生成した。穴を開ける前のターゲットの各頂点 w は次式により表現できる。

$$w = \bar{u} + U\theta + V\epsilon \quad (10)$$

ここで、 ϵ は N 次元ベクトルであり、その要素 ϵ_i は互いに独立な正規分布 $\mathcal{N}(0, \sigma^2)$ に従う。穴は頂点 w のうちいくつかを削除することで形成した。図 4 に形成したターゲットデータの一例を示す。ターゲットは頂点を w とする 3 角ポリゴンであり、レジストレーションの際には u_i に対応する点の位置は未知であることに注意する。

3.4 比較対象：ICP

ICP に基づく手法との比較実験を行った。ICP を利用して穴が空いたターゲットに頑健にレジストレーションする際には、モデル u_i に最も近い点をターゲットより求め、それら

の距離が閾値よりも近いもののみを利用して変位・変形を算出する。すなわち、次式のコストを最小化する。

$$\psi_{ICP} = \frac{\mu}{2} \sum_{\|v_i - u_i(\theta)\|_{l2} < R} \|v_i - u_i(\theta)\|_{l2} \quad (11)$$

ここで R は事前に決定した閾値である。コスト関数 ψ_{ICP} の最小化には最急降下法が用いられる。

3.4.1 実験結果

提案法と上記 ICP に基づく手法とを比較した。式(1)の形状パラメータの初期値は $\theta = 0$ とし式(11)の閾値 R は穴の大きさに基づいて手作業で決定した。このような閾値 R の設定は、実際には事前に穴やへこみのサイズを知ることができないため、次節で述べる肝臓データのような実画像実験では設定できない値である。

標準偏差 $\sigma = 0.3$ のガウス雑音を付加した 30 パターンのターゲットを用意した。それぞれの手法により二つの形状パラメータ θ_{prop} , θ_{ICP} を各ターゲットについて推定する。図 5 にパラメータ θ の推定誤差の分布を示す。推定誤差は以下で測定した。

$$e_{\theta} = (\Delta\theta)^T \Sigma_s^{-1} (\Delta\theta) \quad (12)$$

ここで、 $\Delta\theta = \hat{\theta} - \theta$ である。 θ はターゲット v のパラメータの真値であり、 $\hat{\theta}$ は推定したパラメータである。また、 $\Sigma_s = \text{diag}(\lambda_n)$ である。 λ_n は学習用データから得られた共分散行列の固有値を降順に並べた場合の n 番目の固有値に対応している。図 5 で示すように、提案法の推定精度は今回試行した内の多くのケースで ICP を上回った。

図 6 に提案法によるレジストレーションの結果の一例を示す。図における赤色領域は検出したイレギュラー領域を示しており、これらの部分では $e_i^1 \neq 0$ である。また、各頂点の復元誤差の大きさを白色から黄色のグラデーションで示した。誤差が大きい領域ほど黄色が濃くなっている。図から観察できるように、提案法はイレギュラー領域として穴領域を検出した。一方、穴領域のために ICP ベースな手法では形状復元の精度が低く、ターゲット形状と異なる形状に変形されたことが観察できた。

領域 Ω の検出性能を以下で評価した。推定した領域 $\hat{\Omega}$ は $e_i^1 \neq 0$ となった頂点の集合とする。

$$r_{TP} \equiv \frac{|\Omega \cap \hat{\Omega}|}{|\hat{\Omega}|}, r_{FP} \equiv \frac{|\hat{\Omega} \cap (\mathcal{T} \setminus \Omega)|}{N - |\hat{\Omega}|} \quad (13)$$

r_{TP} は true positive 率を、 r_{FP} は false positive 率を示し、それぞれ、ターゲット上の穴を




図 5 形状パラメータの推定誤差のヒストグラム。青色が提案法、赤色が ICP に基づく手法による結果。
Fig. 5 Distributions of errors of estimated parameters. The red bars show the errors obtained by the ICP-based method, and the blue ones were obtained by the proposed method.

検知できたかどうか、ターゲット上の穴ではない領域を領域 Ω として検知したかどうかを示している。これらの精度尺度は平均して $r_{TP} = 0.93$, $r_{FP} = 0.05$ であった。

3.5 肝臓表面データでのレジストレーション

提案法を X 線 CT 画像中の肝臓表面のレジストレーションに適用した。本節ではその結果について報告する。

3.5.1 実験準備

今回用意した腹部 X 線 CT 画像は、 $M = 36$ 枚であり画像サイズは $512 \times 512 \times 200$ [voxels] である。画像の解像度は $0.625 \times 0.625 \times 1$ [mm³] である。肝臓表面点の統計モデルを生成するため、およびモデル点とターゲット点を同一の座標系で扱えるようにするため、画像の正規化を行う必要がある。本稿では肋骨を囲う直方体を生成し、その直方体が各症例で一致するように正規化を行った。

学習データを構築するため、各画像の肝臓表面を手作業でラベル付けした。図 7 で示すように、肝臓は胃や腎臓など隣接する臓器と接触することが多く、そのような部位では画像中にエッジが明確に観測できない。手作業でラベル付けを行なう際には、エッジを観測できない部位は表面を滑らかに補間するようにした。このラベル付けで得られた表面を

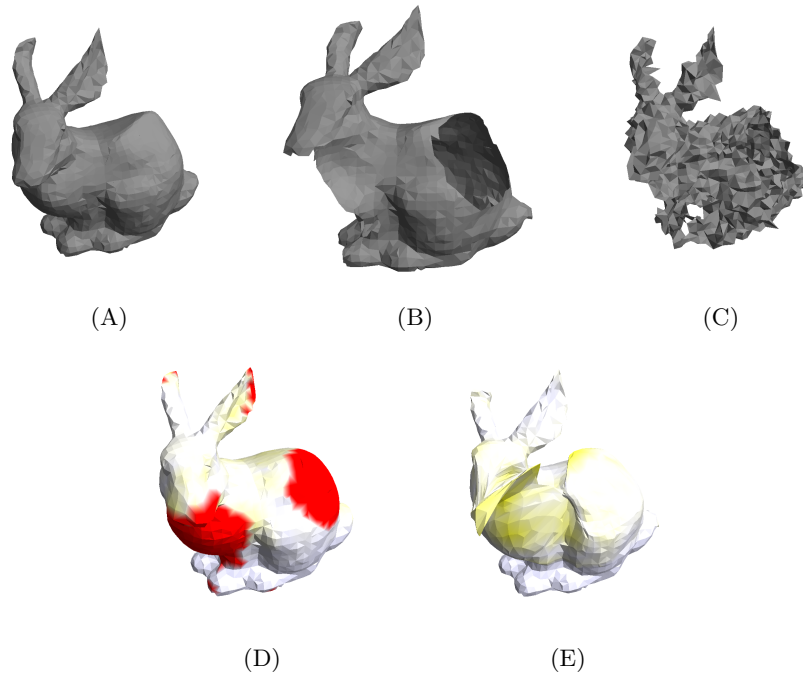


図 6 レジストレーション結果：(A) ターゲットの元形状．(B) 整形後のターゲット形状．(C) ノイズを付加した後のターゲット形状．(D) 提案法による結果．赤色部が領域 Ω の推定領域である．(E)ICP に基づいた手法による結果

Fig. 6 Example of registration results. An example deformed surface (A), a corresponding surface that has some holes (B), and the target on which small noises are added. The registration result is shown in (D), where red regions indicate the detected irregular regions. The result obtained by the ICP-based method is shown in (E). In (D) and (E), the registraion error at each point is indicated by the tickness of yellow color.

$\mathcal{M}^j (j = 1, 2, \dots, 36)$ で表す．

3.5.2 モデル曲面の構成

式(1)のモデルを構築するためには、各学習用データの表面 $\mathcal{M}^j (j = 1, 2, \dots, M)$ に対応点 $u_i^j (i = 1, 2, \dots, N)$ を生成する必要がある．今回の実験では、対応点集合 u_i^j を生成するため、Generalized Multidimensional Scaling(GMDS)法^{11),12)}を用いた．生成した点の数は $N = 200$ である．図 8 に学習用表面の対応点の例を示した．



(A) (B)

図 7 X 線 CT 画像の例：他臓器との接合部ではエッジが観測できない．(A) 肝臓先端と胃との接合部．(B) 肝臓底部と腎臓との接合部

Fig. 7 Example of X-CT images. No edge is observed where the liver touches with the stomach (A) and with the kidney (B).




図 8 GMDS 法により生成した対応点の例

Fig. 8 Corresponding points generated by GMDS

実験ではデータ集合のうちひとつをテスト用、残りを学習用とし、PCAにより式(1)における平均形状 \bar{u} および固有ベクトル U を計算する．シミュレーション実験の場合と同様に、採用する固有ベクトルの本数は奇与率により決定した．累積奇与率が 0.99 となった 34 番目の固有値に対応する固有ベクトルまでを採用した．図 9 に平均形状と第 1 固有ベクトルによる形状の変化を示す．

3.5.3 ターゲットの取得

テスト用の X 線 CT 画像から肝臓表面の候補点を自動的に取得する．肝臓領域の各ボクセル値は正規分布に従うことが知られている¹³⁾．各画像の各ボクセルにおいて肝臓領域が否かを表す尤度を計算し、二値化することにより肝臓表面を抽出する．尤度画像には図 10




図 9 肝臓表面の平均形状と第一固有ベクトルに従う変化
Fig. 9 Deformation of the liver corresponding to the first eigen vector.




図 10 肝臓尤度画像の例
Fig. 10 Examples of the liver-enhanced images.

に示すように肝臓以外の臓器や肋骨、血管などの領域も高い尤度を示す。これら肝臓以外の領域をできるだけ削除するために、モルフォロジのオープニングなどの後処理を適用し、肝臓表面候補のターゲットを得る。図 11 に例を示す。

このようにして得られたターゲットには、肝臓領域以外に上述処理では除去しきれなかった胃や心臓、腎臓などの他臓器や肋骨・血管などが含まれる。胃と肝臓が接触している場合には、接触部が肝臓表面上の穴となる。また、癌などの腫瘍が肝臓表面に存在する場合、これらの領域は尤度が低いためにターゲット曲面上のへこみとなって表れる。図 11 では上で述べたような他部位との接合や、へこみが観察できる。

3.5.4 実験結果

前節で述べた方法で取得したターゲットに対し、提案法を適用した。また、比較のために、手作業で他臓器との接触部と腫瘍部を抽出し、gold standard を生成した。図 12 にレジストレーション結果を示す。図中の上段に示した青色領域は前処理により得られたターゲット




図 11 ターゲットの例
Fig. 11 Example of a target

曲面、図中の下段にレジストレーション後のテンプレート表面を示す。赤色の領域は領域 Ω に属すると判断された点である。図に示すように、腫瘍に対応するへこみ領域の自動的な検出に成功した。一方、心臓との接合部は検出できなかった。肝臓表面を表現する点数が 200 点と少なく、点と点の間の距離と比べて心臓との接合部の大きさが小さかったことが原因であった。各テンプレート点のレジストレーション誤差は平均して 4.65 ボクセルであった。

4. おわりに

本論文では与えられたターゲット曲面に対し、可変形状のテンプレートモデルの表面を位置合わせすると同時に、モデルから逸脱している領域を検出する手法を提案した。穴やへこみなどの領域を検出し無視しつつレジストレーションをおこなった。対象の統計モデルに従っている領域とそれ以外とを区別するために、モデルとターゲットの残差の分布の違いに着目した。対象がモデルに従うときには残差は分散の小さな正規分布に従い、モデルから逸脱している領域では残差の大きさは不明であり、そのような領域の面積は狭い。この面積の狭さを積極的に活用するためにコスト関数の正則化項に残差の L1 ノルムの項を導入した。シミュレーション画像と X 線 CT 画像の双方を用いた実験によりモデルに従わない部分の自動検出と形状推定の双方について良好な結果を得た。

提案法における繰り返し更新法は、コスト関数の単調減少と局所解への収束を保証していない。この点の解決が今後の課題である。




図 12 提案法により得られたレジストレーションの結果

Fig. 12 An example of the liver registration obtained by the proposed method.

参 考 文 献

- 1) Y, C. and G, M.: Object modeling by registration of multiple range images, *IEEE International Conference on Robotics and Automation*, pp.2724–2729 (1991).
- 2) Besl, P.j. and McKay, N.D.: A Method for Registration of 3-D Shapes, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.14, No.2, pp.239–256 (1992).
- 3) 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).

- 4) Dorai, C., Weng, J. and Jain, A.: Registration and Integration of Multiple Object Views for 3D Model Construction, *IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE*, Vol.20, No.1, pp.83–89 (1998).
- 5) Phillips.J.M, Liu, R. and Tomasi.C: Outlier Robust ICP for Minimizing Fractional RMSD, *3-D Digital Imaging and Modeling, 2007. 3DIM '07. Sixth International Conference*, pp.427–434 (2007).
- 6) Pulli, K.: Multiview Registration for Large Data Sets, *3-D Digital Imaging and Modeling* (1999).
- 7) A.Ayvaci, M.Raptis and S.Soatto: Occlusion detection and motion estimation with convex optimization, *In Advances in Neural Information Processing Systems* (2010).
- 8) D.Donoho: For most large underdetermined system of linear equations the minimal l1-norm solution is also the sparsest solution.
- 9) Candès, E., Romberg, J. and Tao., T.: Stable Signal Recovery from Incomplete and Inaccurate Measurements.
- 10) BOOKSTEIN, F.L.: Principal Wrap, Thin-Plate Spline and the Decomposition of Deformations.
- 11) Bronstein, A., Bronstein, M. and Kimmel: *NUMERICAL GEOMETRY OF NON-RIGID SHAPES*, Springer Verlag (2008).
- 12) 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, 日本医用画像工学会 (2010).
- 13) 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).