

## 医用画像中の臓器レジストレーションのための画像辞書生成

松野 高道<sup>†1</sup> 浅井 健史<sup>†1</sup>  
岩田 卓哉<sup>†1</sup> 本谷 秀堅<sup>†1</sup>

本稿では、医用画像中の臓器表面の抽出に有用な画像特徴を、臓器表面に特化した辞書に基づいて構築する試みについて報告する。画像の辞書とは、画像パターンを線形に表現するために利用する基底系のことであり、正規直交系ではなく対象の画像群に特化した過完備な基底系であることに特徴を有する。画像復元に仕様された基底の組み合わせに基づいて臓器の部位を定めつつレジストレーションに利用する枠組みを提案する。

### Construction of Image Dictionary for Registering Inner Organs in Medical Image

TAKAMICHI MATSUNO,<sup>†1</sup> TAKESHI ASAI,<sup>†1</sup>  
TAKUYA IWATA<sup>†1</sup> and HIDEKATA HONTANI<sup>†1</sup>

In this article, we report on selecting image features that are useful for registering organ surface in medical image based on image dictionary constructed for the organ. Here, the image dictionary denotes a basis set, which is non-orthogonal and over-complete one and is designed to represent images of the target organ. We propose a method that refers to a combination of the basis obtained for reconstructing a given image in order to estimate the location of the target organ.

#### 1. はじめに

三次元医用画像中の臓器表面を抽出することは、診断支援システムの実現の観点などが

基本的かつ重要な処理である。このため臓器抽出法がこれまでも多数提案されてきた。それら手法の多くは、臓器表面のモデルと画像とのレジストレーションにより実現されている。

モデルと画像のレジストレーション法は多数存在する。本稿ではそれら手法のうち特徴点に基づくレジストレーションについて考える。その手法として文献<sup>1)11)</sup>に示されている方法がある。特徴点に基づくレジストレーション法は、一般に、特徴点の空間的な配置により対象のモデルを表現しておき、与えられた画像より抽出した特徴点とモデルとの位置合わせをおこなう。このような手法を採用するとき、特徴点の選定が問題となる。

例えば Active Contour に代表される一連の手法<sup>3)</sup>は、与えられた画像よりエッジ抽出をおこない、曲面のモデルをエッジに対して位置合わせする。これら手法においてはエッジを特徴点として選定したことになる。エッジ抽出には既存の手法が利用でき、患者によらず臓器表面の候補点を抽出できる利点がある。しかし、抽出演算子としては一般的であるため、臓器の内部と外部から多数の候補点が抽出される。これら多数の候補点から真の臓器表面のみを選別することは容易ではない。その理由のひとつは、抽出される各エッジの点が、臓器表面の部位に関連する情報を一切提供しないことにある。いずれのエッジも臓器表面の候補として抽出され、臓器の上部・下部といった位置に関する情報を取得することができない。このことは、曲面モデルの位置合わせをする際の大きなデメリットである。

一方、曲率の極大点など、局所画像に内在する画像特徴に基づき特徴点を定義する一連の手法がある<sup>1)</sup>。これら手法は画像より抽出する特徴点が臓器の部位に関する情報を提供し、その情報に基づいてモデルの位置合わせをおこなうことができる。このため、特徴を頑健に抽出できれば、上記エッジのみに基づく手法よりも曲面モデルの位置合わせ処理は容易になる。しかし、曲面モデルの位置合わせに十分な数の特徴を臓器ごとに選定する手続きが不明瞭であり、また患者に依らず頑健に抽出できる特徴であるかどうかの検証も不十分になりかねない。

すべての患者から抽出できる、臓器抽出と部位同定に有用な特徴点のことをランドマークと区別して呼ぶことにする。また、ランドマークとランドマークの間の補間に有用な特徴をセミ・ランドマークと呼ぶことにする<sup>2)</sup>。仮にランドマークとセミ・ランドマークを定義しモデルとして用意することができれば、与えられた画像よりまずランドマークを抽出し、続いてランドマーク間から適切なセミ・ランドマークを抽出することにより臓器抽出ができる。このような臓器抽出法の実現を目標とし、本稿では肝臓表面を対象とし、ランドマークとセミ・ランドマークを定める試みについて報告する。具体的には、臓器表面に対応する画

<sup>†1</sup> 名古屋工業大学  
Nagoya Insutitute of University

像辞書を構築し、ランドマークとセミ・ランドマークを定める。

画像辞書とは、画像を数ピクセル四方のパッチに分割したときの、それらパッチを表現するための基底系のことである。例えば MPEG における DCT 基底は画像辞書の一例である。与えられたパッチが含むボクセルの総数を  $n$  であらわすとき、 $N$  個の直交基底を用意すれば任意のパッチを表現することができる。一方本稿で採用する画像辞書は、直交基底系ではなく、対象に特化した非直交の基底系である。

対象を臓器表面などに限定するとき、 $N$  次元パッチの画像は  $N$  次元パターン空間において、 $N$  よりも十分低い次元の多様体で表現できることが多い。この多様体上の画像をできるだけ少ない個数の基底の線形和で表現するために、当該する多様体に特化した過完備な基底系を学習用のサンプル画像に基づき構築して辞書を作成する手法が提案されている。対象に特化した辞書を用意したあと、新しいパッチ画像が与えられれば、非直交基底系である辞書の中からパッチ画像を高精度に復元する基底を選択する。ここで辞書による画像の復元とは、辞書を構成する基底ベクトルの線形和により元画像を表現しなおすことを意味する。そのために L1 ノルムを正則化に利用する枠組みが有用であることが知られている<sup>4), 5)</sup>。

本稿では、対象臓器の表面より多数の学習用のパッチの集合を用意し、その集合に基づいて対象臓器表面に特化した画像の辞書を構築する。構築される辞書は対象臓器表面の記述に適した基底の集合である。この辞書を用いて与えられた画像を復元するとき、部位に依存して復元に利用される基底が変化する。例えば、Julien Mairal らは文献<sup>6)</sup>で自転車などの対象を自然画像より抽出する際に、自転車など対象に特化した辞書を利用する手法を提案している。本稿では同様の考え方にに基づき、画像復元に利用される基底に基づいて臓器の部位に関するおおまかな情報を取得する。なおかつ、テスト用に複数の患者の画像を用意し、辞書に基づき全員の臓器表面を復元する。このとき、全患者に対して共通にあわられる基底の組み合わせを患者に依存せずに現れる特徴とみなし、ランドマークの候補とする。また、ランドマークを基準として隣接する臓器表面上の点の位置を表現し、それら隣接点の復元に利用された基底の組み合わせをセミ・ランドマークとみなす。上記の考え方にに基づく基礎実験をおこなったので報告する。

## 2. 辞書構築法

本節では、文献に示されている辞書構築法の概略を説明する。

### 2.1 辞書構築法概略

第1章で述べた辞書の構築について説明する。これは対象臓器表面を含むパッチ画像群をも

とにして学習を行なうことで生成する。パッチ画像の次元を  $n$  で表し、各パッチ画像を  $\mathbf{x}_i \in R^n$  で表す。また、学習用の  $N$  個のパッチを並べ、データ行列  $\mathbf{X} = [\mathbf{x}_1 | \mathbf{x}_2 | \dots | \mathbf{x}_N] \in R^{n \times N}$  を作成する。 $n$  次元の基底ベクトルを  $\mathbf{d}_j \in R^n$  で表し、 $K$  個の基底を並べて辞書を表す行列  $\mathbf{D} \in R^{n \times K}$  を作成する。 $\mathbf{x}_i$  を各基底  $\mathbf{d}_j$  の線形和で表すときの係数ベクトルを  $\alpha_i \in R^K$  と表すとき、 $\mathbf{x}_i = \mathbf{D}\alpha_i$  である。係数ベクトル  $\alpha_i$  を並べて行列  $\alpha = [\alpha_1 | \alpha_2 | \dots | \alpha_N] \in R^{K \times N}$  を作成すると、 $\mathbf{X} = \mathbf{D}\alpha$  と表すことができる。辞書生成アルゴリズムは与えられた  $\mathbf{X}$  に対して次元を満たす辞書  $\mathbf{D}$  と係数  $\alpha$  を近似的に求める。

$$\min_{\mathbf{D}, \alpha} \|\mathbf{X} - \mathbf{D}\alpha\|_F^2 \quad \text{subject to} \quad \forall i, \|\alpha_i\|_0 \leq T_0. \quad (1)$$

ただし、 $T_0$  は復元に用いる基底の本数を表す。L0 ノルムを用いた正則化項は各パッチの復元に用いる基底数を制限する条件を表している。辞書構築法について説明する前に、パッチ画像を構築済みの辞書に基づいて復元する手法を説明する。

### 2.2 L1 ノルム最小化による基底の選択

ここでは画像の復元を行なう際の基底の選択法を説明する。与えられたパッチ  $\mathbf{x}_i$  を復元する際には、式 (2) を満たす  $\alpha_i$  を求める。L1 ノルムの最小化により、 $\alpha$  についてできるだけ疎な解を求める。

$$\min \|\alpha_i\|_1 \quad \text{subject to} \quad \mathbf{D}\alpha_i = \mathbf{x}_i. \quad (2)$$

係数のうちゼロの成分に対応する基底はその元のパッチを表現するのに使われない。式 (2) の解法として Basis Pursuit 法<sup>4)</sup> や Orthogonal Matching Pursuit 法<sup>5)</sup> がある。今回の実験では Orthogonal Matching Pursuit 法を用いたので、これについて詳しく説明する。

#### 2.2.1 Orthogonal Matching Pursuit 法

Orthogonal Matching Pursuit 法 (以下 OMP 法) は L1 ノルムを最小にする係数を貪欲法で求める。あらかじめ定めた数  $T_0$  個の基底ベクトルを用いてパッチ  $\mathbf{x}_i$  を復元することを考える。OMP 法では復元に使われる基底の組み合わせとその係数を  $T_0$  個求める。基底選択に際しては  $K$  個の基底のうち最適なものを毎回一つだけ選択し、学習サンプルとの誤差が小さくなるように係数を求める。この操作を  $T_0$  回繰り返す。

更新する際には残差を手掛かりとする。 $t-1$  回基底を更新したあとのパッチ  $\mathbf{x}_i$  を復元した画像をベクトル  $\mathbf{a}_{i,t-1}$  とし、式 (3) で表す。

$$\mathbf{a}_{i,t-1} = \mathbf{D}_{i,t-1}\alpha_{i,t-1}. \quad (3)$$

ただし、 $\mathbf{D}_{i,t-1}$  は  $t-1$  回の更新で選択された基底を並べた  $n \times (t-1)$  の行列であり、その各基底に対応する係数を格納した  $(t-1)$  次元のベクトルを  $\alpha_{i,t-1}$  で表す。ここで、 $\mathbf{x}_i$  と

$t-1$  回の復元画像  $\mathbf{a}_{i,t-1}$  との残差ベクトルを  $\mathbf{r}_{i,t-1}$  で表す.

$$\mathbf{r}_{i,t-1} = \mathbf{x}_i - \mathbf{a}_{i,t-1}. \quad (4)$$

$t-1$  回の更新のあと,  $K$  個のうち  $K-(t-1)$  個の基底が残っている. この残りの各基底に対して, 残差  $\mathbf{r}_{i,t-1}$  との内積を計算すれば, どの基底が残差を小さくできるかを調べることができる. 具体的には式 (5) を解く.

$$\lambda_{i,t} = \arg \max_j |\mathbf{r}_{i,t-1}^T \mathbf{d}_j|. \quad (5)$$

式 (5) によって得られる  $\lambda_{i,t}$  は残差ベクトルとの内積を最大にする基底のインデックスである.

$$\Lambda_{i,t} = \Lambda_{i,t-1} \cup \lambda_{i,t}. \quad (6)$$

$$\mathbf{D}_{i,t} = [\mathbf{D}_{i,t-1} \mid \mathbf{d}_{\lambda_{i,t}}]. \quad (7)$$

この  $\Lambda_{i,t-1}$  は今までの復元に使われた基底のインデックスの集合である. また,  $\mathbf{D}_{i,t}$  は  $t$  回目の更新で選択された基底を並べた  $n \times t$  の行列である.

次に, この  $\mathbf{D}_{i,t}$  に掛ける係数  $\alpha_{i,t}$  の値を求める. この係数は次式の解として求める.

$$\alpha_{i,t} = \arg \min_{\alpha} \|\mathbf{D}_{i,t} \alpha - \mathbf{x}_i\|_2. \quad (8)$$

式 (8) を解くには  $\mathbf{D}_{i,t}$  の擬似逆行列  $\mathbf{D}_{i,t}^+$  を求めて, それを式 (9) の両辺に左から掛ければよい.

$$\mathbf{D}_{i,t} \alpha_{i,t} = \mathbf{x}_i. \quad (9)$$

$$\alpha_{i,t} = \mathbf{D}_{i,t}^+ \mathbf{x}_i. \quad (10)$$

式 (10) の  $\alpha_{i,t}$  が求めるべき係数の値となる. さらにそのときの残差  $\mathbf{r}_{i,t}$  も求めることができる.

$$\mathbf{a}_{i,t} = \mathbf{D}_{i,t} \alpha_{i,t}. \quad (11)$$

$$\mathbf{r}_{i,t} = \mathbf{x}_i - \mathbf{a}_{i,t}. \quad (12)$$

以上の操作を  $T_0$  回繰り返すことにより, 復元に利用される基底の組み合わせとそのときの係数を求めることができる. 初期状態は  $\mathbf{r}_{i,0} = \mathbf{x}_i$ , さらに  $\Lambda_{i,0} = \emptyset$ ,  $\mathbf{D}_0 = \{\}$  である. この操作が終わると係数の値を格納した列ベクトル  $\alpha_{i,T_0}$  が得られ, これが求めるべき係数の値であるが, これではまだ不十分である. これは影響が大きい順に係数を格納しているだけであるため, 本当の係数ベクトル  $\alpha_i \in R^K$  にする必要がある. これは各係数に対応する基底のインデックスを記憶してあるので, 簡単になおすことができる.  $\alpha_i$  のうち記憶していたインデックスの行にそれに対応する係数を格納するだけである.

### 2.3 辞書構築法

前節までに述べた基底選択法に基づいた辞書構築法を説明する. 辞書構築法は多数の局所画像パッチを入力とし, これら局所画像の記述に適した基底系を出力する. 本研究ではそのような基底系の構築に K-SVD 法<sup>7),9)</sup> を採用する.

第 2.2.1 節で説明したように式 (1) を最小化することにより辞書  $\mathbf{D}$  を求める. K-SVD では, 辞書行列  $\mathbf{D}$  と係数  $\alpha$  とを交互に更新する. 係数の更新手続きは sparse coding と呼ばれ, 辞書行列の更新手続きは dictionary update と呼ばれている. 以下, それぞれの手続きを説明する.

#### 2.3.1 Sparse Coding

Sparse Coding では, 学習用のパッチ  $\mathbf{x}_i$  の復元に利用する基底ベクトルの選択と選択された基底に対する係数の値を求める. 具体的には式 (13) を解く.

$$\min_{\alpha_i} \|\mathbf{x}_i - \mathbf{D}\alpha_i\|_2^2 \quad \text{subject to} \quad i = 1, 2, \dots, N, \quad \|\alpha_i\|_0 \leq T_0. \quad (13)$$

第 2.2.1 節で説明した OMP 法を用いれば近似解が得られる. よって, ここでは各パッチ  $\mathbf{x}_i$  の復元に用いる基底を OMP 法により算出する. OMP 法の終了判定には, 復元に利用する基底の上限  $T_0$  を用いる. また, 係数を求めた上で元画像データと復元画像データとの二乗誤差に基づき K-SVD の収束判定を行なう.

#### 2.3.2 Dictionary Update

係数  $\alpha$  の更新の次に, 辞書を構成する基底ベクトル  $\mathbf{d}_i$  を更新する. 係数行列  $\alpha$  のうち  $i$  行目のベクトル  $\alpha_i^j$  は基底  $\mathbf{d}_i$  に対応する.  $\alpha_i^j$  は  $N$  個の要素を持ち, それぞれ  $\mathbf{x}_1$  から  $\mathbf{x}_N$  のパッチを復元するときの基底  $\mathbf{d}_j$  の係数を表す. 仮に  $\mathbf{x}_k$  の復元に基底  $\mathbf{d}_j$  が使われなければ  $\alpha_i^j$  の第  $k$  要素は 0 になる. つまり, 復元画像は式 (14) のように表すことができる.

$$\mathbf{D}\alpha = \sum_{j=1}^K \mathbf{d}_j \alpha_i^j. \quad (14)$$

ここで,  $K$  個の基底のうち  $k$  番目の基底ベクトル  $\mathbf{d}_k$  を更新することを考える.  $\mathbf{d}_k$  を更新すると,  $\mathbf{d}_k$  を使用して復元しているパッチは, その復元結果が変化する. この結果, 復元画像と元画像との二乗誤差も変化する.  $\mathbf{d}_k$  の更新は, この二乗誤差が小さくなるように行われる. 基底  $\mathbf{d}_k$  を更新するときには, 学習用のパッチの集合とそれらの復元画像との二乗誤差を,  $\mathbf{d}_k$  とそれ以外に分けて式 (15) のように表現する.

$$\begin{aligned}
 \|\mathbf{X} - \mathbf{D}\alpha\|_F^2 &= \|\mathbf{X} - \sum_{j=1}^K \mathbf{d}_j \alpha_j^j\|_F^2 . \\
 &= \|\left(\mathbf{X} - \sum_{j \neq k} \mathbf{d}_j \alpha_j^j\right) - \mathbf{d}_k \alpha_k^k\|_F^2 . \\
 &= \|\mathbf{E}_k - \mathbf{d}_k \alpha_k^k\|_F^2 . \tag{15}
 \end{aligned}$$

ここで、 $\mathbf{E}_k$  は  $\mathbf{d}_k$  以外の基底で復元したパッチと学習用の元のパッチとの残差画像を表している。基底  $\mathbf{d}_k$  によりこの残差を表現できるならば、基底の線形和により元パッチを誤差なく復元できることを意味する。

$\alpha_T^k$  のうち非ゼロの値を持つ成分のインデックスの集合を  $\omega_k$  で表す。  $\omega_k$  が含むインデックスは、復元に基底  $\mathbf{d}_k$  が使用されるパッチのインデックスでもある。

$$\omega_k = \{i \mid 1 \leq i \leq N, \alpha_T^k(i) \neq 0\} . \tag{16}$$

基底  $\mathbf{d}_k$  を更新するために、  $n \times |\omega_k|$  の行列  $\Omega_k \in R^{n \times |\omega_k|}$  を定義する。この行列の要素は  $(\omega_k(i), i)$  だけが 1 でそれ以外が 0 の行列である。ただし、  $\omega_k(i)$  は  $\omega_k$  の第  $i$  要素を表しているとする。

この行列を  $\alpha_T^k$  に掛け合わせることで、そのパッチにおいて復元に使用した基底の係数だけを取り出すことができる。

$$\alpha_R^k = \alpha_T^k \Omega_k . \tag{17}$$

また、式 (15) の行列  $\mathbf{E}_k$  にも掛けることでその係数に対応している部分が抜き出せる。

$$\mathbf{E}_k^R = \mathbf{E}_k \Omega_k . \tag{18}$$

$\mathbf{E}_k^R$  は基底  $\mathbf{d}_k$  以外を用いてパッチを復元したときの残差である。基底  $\mathbf{d}_k$  を修正することによりこの残差をできるだけゼロに近づけたい。すなわち、次式で定義される二乗誤差をゼロに近づけるように  $\mathbf{d}_k$  と  $\alpha_R^k$  を更新したい。

$$\|\mathbf{E}_k^R - \mathbf{d}_k \alpha_R^k\|_F^2 . \tag{19}$$

そのために、 $\mathbf{E}_k^R$  を特異値分解する。ただし、特異値は降順に並べているとする。

$$\mathbf{E}_k^R = \mathbf{U} \Delta \mathbf{V}^T . \tag{20}$$

このとき分解された  $\mathbf{U}$  の一列目を新たな  $\mathbf{d}_k$  とし  $\mathbf{V}$  の一列目を  $\alpha_R^k$  にするとき、式 (19) の二乗誤差が最小になる。この手続きを収束するまで各基底で実行する。



図 1 元画像  
Fig.1 Original Image

上記手続きを実際の画像に適用すると、二十回前後の繰り返し計算を行えば収束する。ただし、十分な回数繰り返しても誤差が収束しなければ計算を打ち切る。

辞書構築の実例を示す。図 1 の画像を  $8 \times 8$  のパッチへと分割することで局所画像を作成し、辞書の構築を行なった。初期辞書として DCT 基底群 (図 2(a)) を用いた。構築された基底群を図 2(b) に示す。さらに、DCT 基底群と学習して作成した辞書の二つを用いて基底選択を行ない、画像の復元を行なった。復元結果を図 3 に示す。今回の復元は縦横の各方向とも 8 ピクセルおきに辞書の線形和で局所画像を復元し、それをタイルのように並べて画像全体を復元した。いずれも基底の最大数  $T_0 = 5$  である。  $T_0$  が小さいためいずれも復元精度は低いが、復元精度には大きな違いがある。DCT 基底を辞書とした場合、例えば机の縁のような斜めのエッジを表現できていない。一方、対象画像に特化して構築した辞書には、図 2(b) に示すように斜め方向のパターンも基底に現れており、その結果机の縁などの復元精度が向上している。

### 3. 辞書に基づく画像の復元とランドマークの同定

先に述べた通り、本稿で提案する手法は辞書に基づく画像の復元結果に基づいて臓器表面の抽出に有用なランドマークとセミ・ランドマークを抽出する。本節では辞書に基づいてランドマークなどを選定するための手続きを説明する。

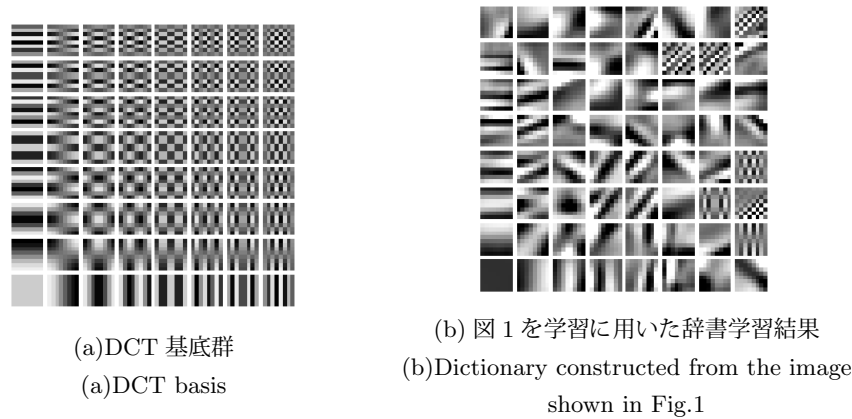


図 2 辞書構築結果  
Fig. 2 Example of constructed dictionary

### 3.1 画像の復元結果の統計解析

最初に各画像を体型に基づいて正規化したあと、学習用の臓器表面画像を複数用意し、それら表面よりサンプルされたパッチ画像に基づき臓器表面画像に特化した辞書を構築する。辞書構築の際には第 2.3 節でも述べた通り、基底の数に関するしきい値  $T_0$  を定める。この  $T_0$  の値を維持したまま、次にテスト用のパッチを辞書に基づき復元する。復元には第 2.2 節で説明した OMP 法を利用する。

復元後には、各パッチが  $T_0$  個の基底の組み合わせで表現される。この組み合わせには、OMP 法が基底を選択する順序の情報も附されているため、基底の総数を  $K$  であらわすとき、全部で  $K^{T_0}$  通り存在する。これら基底の組み合わせのうち、全患者に共通してあらわれる基底の組み合わせを求めるために、基底の組み合わせの利用頻度をあらわすヒストグラムを求める。このヒストグラムは  $K^{T_0}$  次元であり、頻度は患者数をあらわしている。

全患者の復元に利用された基底の組み合わせが存在すれば、それをランドマークの抽出演算子に採用する。次に、それぞれの組み合わせについて復元したパッチの位置の分布を求める。各患者の画像は体型により正規化されている。このため、復元したパッチの位置を重ねてプロットすることができ、プロットされた点の分布に基づきランドマークの位置に関する事前分布を求めることができる。この事前分布が局在化することを期待し、その度合を実験により確認する。




図 3 復元結果  
Fig. 3 Reconstructed Image

ランドマークが臓器の特定の部位より抽出される場合には、その近傍における曲面の形状も患者に依らず共通していることが期待できる。そこで、ランドマーク近傍における臓器表面の分布を統計的に求めるとともに、近傍の復元に利用された基底の組み合わせの統計も算出する。これら統計はランドマークに基づき臓器抽出をおこなう際のモデルとして利用できる。例えば、tensor voting の枠組み<sup>10)</sup>が有用であろうと考えている。

## 4. 実験結果

### 4.1 前処理

本研究では対象に肝臓表面を選択した。モデル構築と実験には 20 症例の X-CT 画像を利用した。その空間分解能は  $0.625\text{mm} \times 0.625\text{mm} \times 1\text{mm}$  で、画像サイズは  $512 \times 512$  である(図 4(a))。肝臓内部の CT 値は正規分布でモデル化できることが知られており、このことを利用して各ボクセルに対する肝臓内部か否かをあらわす尤度画像を作成する<sup>8)</sup>。例として、図 4(a) に対応する尤度画像を図 4(b) に示す。肝臓表面の多くに比較的コントラストの強いエッジが観測できるが、近くに胃や心臓といった臓器があるため単純に二値化したりエッジを追跡したりしても肝臓表面を抽出することはできない。これら 20 症例中の肝臓表面の正しい位置については、エキスパートが手作業で抽出した結果があり、モデル構築に利



(a)X-CT 画像  
(a)X-ray CT image

(b) 尤度画像  
(b)Likelihood Image

図 4 医療画像

Fig.4 Example of Medical Image

用した。

また、統計モデルを構築するためには患者の体型の正規化が事前になされねばならない。本研究では肋骨と肺を手がかりに正規化を行った。本来なら肋骨と肺を自動抽出を行った上でそれをもとにして正規化をするのだが、今回の実験は便宜上手作業で肋骨と肺を抽出し、それをもとにして肝臓全体が入るような立方体を作成し、そのスケールをそろえることで正規化を行った。

#### 4.2 辞書構築結果と復元結果

先ほどの方法で正規化した 20 症例のうち 19 症例の肝臓表面に対してパッチを作成し、学習を行い辞書を作成する。構築された辞書を用いて残り 1 症例の肝臓表面を復元する。

始めに、辞書構築にあたって学習サンプル用のパッチの集合を作成する。そのために肝臓表面を均一にサンプリングし、各サンプル点を中心に  $8 \times 8 \times 8$  の立方体の領域を切り出しパッチとした。学習用のパッチの総数は 19 症例に対して約 7 万 9 千であった。

パッチの記述に用いる基底の総数  $T_0$  は本研究で目指すランドマークの生成結果に大きな影響を与える。本稿では  $T_0 = 2$  としたときの結果を報告する。適切な  $T_0$  の決定法については今後考察する。これらのパッチに基づき、肝臓表面の画像表現に特化した 512 の基底ベクトルを学習する。学習は DCT 基底を初期状態とし、第 2.1 節で述べた通り、式 (1) を




図 5 辞書構築過程における誤差の推移

Fig.5 Decrease of squared error in the dictionary construction

最小にするように基底を繰り返し修正することによりおこなう。繰り返しの回数は第 2.3 節で述べた通り二十回とした。

K-SVD 法における繰り返しの修正により、学習用サンプルと復元結果との二乗誤差である式 (1) がどのように変化してきたかを図 5 に示す。横軸が繰り返し回数であり二十回で打ち切られており、縦軸が式 (1) に示す二乗誤差の値である。図 5 に示す通り、DCT と比べて対象を二乗誤差の意味でより良く表現する基底系を獲得できていることが分かる。

先に述べた通り 20 症例のうち 19 症例よりサンプルしたパッチに基づき辞書を構築し、その辞書に基づき残り 1 症例の臓器表面を構築した。復元に用いた 1 症例に関しても同様に肝臓表面点を均一にサンプリングし、テスト用のパッチの集合を作成した。これらテスト用パッチのそれぞれを OMP 法を用いて辞書により復元した。すなわち、辞書を構成する基底ベクトルのうちの  $T_0$  個の線形和で各パッチを表現した。その復元画像と元画像との差を求めた。その結果を図 6 に示す。図中で高輝度な点ほど差の大きさが大きいことを示している。輝度差を解析したところ、肝臓の表面点が密集している部位の復元精度が低いことが判明した。部位に依存して復元精度が変わってしまう理由は今後の解析課題である。

#### 4.3 復元結果の統計

本節ではパッチの復元に利用された基底ベクトルの組み合わせに関する統計解析の結果を報告する。辞書構築と復元の双方で  $T_0 = 2$  とした。

20 症例全てで復元に利用された基底の組のヒストグラムを図 7 に示す。ヒストグラムは便宜上  $512^T = 262,144$  通りの基底の組み合わせに通し番号を付し、一次元で表現する。横軸が通し番号、縦軸が利用された症例数を表している。図 7 の 20 症例全てで利用された基底の組み合わせを調べた結果全部で 125 個あった。これらの各組が肝臓表面のどの位置の復元に使われたのかを調べた。その一例を図 8 と図 9 に示す。図 8 と図 9 に示すよう



図 6 誤差画像  
Fig. 6 Image of error




図 7 基底の組のヒストグラム  
Fig. 7 Histogram of basis

に、特定の基底の組み合わせは臓器表面の特定の部位の復元に利用されることを確認できた。これら全症例に共通して出現した基底の組み合わせをランドマークとして利用することを考えるとき、図 8 と図 9 に示している分布はランドマークの出現位置に関する事前分布を表現している。辞書による画像復元とランドマークの事前分布を併用することにより、肝臓の位置の同定に有用な情報を取得できると考えている。

また、この 125 個の基底の組に関して隣接している基底の組に関して調べた。まず、ある 125 個のうち一組に注目する。この組に隣接している基底の組がどのくらいの頻度で何組あ




図 8 ランドマークの事前分布 (その一)  
Fig. 8 Prior distribution of a landmark (1)




図 9 ランドマークの事前分布 (その二)  
Fig. 9 Prior Distribution of a landmark (2)

るのかを調べた。その結果を図 10 に示す。横軸が基底の通し番号、縦軸が隣に現れた回数を表している。図 10 に示すように隣接している基底の組が限定されていることがわかる。

また、図 10 において一番目に値が大きい組と二番目の組についてどの方向に出やすいかを調べた。その結果を図 11 に示す。黒丸の大きさがその位置で現れた回数を表していて、大きいほど回数が多かったことを意味している。図 11 を見ると、ある方向でしか隣接していないことがわかる。つまり、レジストレーションするにあたって隣接関係は有効なデータになることがわかる。





図 10 基底の組のヒストグラム

Fig.10 Histogram of bases near the landmark shown in Fig.9



(a) 頻度が一番目に多かった組に関する位置

(a) location to be the most in Fig:9(a)

(b) 頻度が二番目に多かった組に関する位置

(b) location to be the second most in

Fig:9(a)

図 11 隣接関係

Fig.11 Image of neighbor

## 5. おわりに

画像辞書を利用する医療画像からの臓器表面抽出法を提案した。画像辞書は対象画像の記述に適した基底群であり、学習用の画像より L1 ノルム最小化の手法により構築される。構築された辞書を用いて復元した結果少ない基底の線形和でも十分に肝臓が表現できることを確認した。さらに、復元した結果、復元した基底の組が肝臓表面の位置によって違うことを確認した。さらに、ある特定の種類の組は復元に使われる位置がある程度限定されていることも確認できた。今後、本稿のはじめに述べた考え方に則って、新たなレジストレー

ション法を構築する。

## 参考文献

- 1) Xavier Pennec, Nicholas Ayache, and Jean-Pjilippe Thirion, "Landmark-based registration using features identified through differential geometry", *INRIA - Projet Epidaure*, February 14, 2000
- 2) Yoshitaka Masutani, Hidekata Hontani, and Atsushi Imiya, "Mathematical Foundations of Computational Anatomy" 「計算解剖学」第1回国際シンポジウム 2010
- 3) A. Blake and M. Isard. "Chapter 2 of Active Contours" Springer-Verlag, 1999
- 4) S. S. Chen, D. L. Donoho, and M. A. Saunders, "Atomic decomposition by basis pursuit," *SIAM Rev.*, vol. 43, no. 1, pp.33-61, 2001
- 5) JOEL A. TROPP and ANNA C. GILBERT "SIGNAL RECOVERY FROM RANDOM MEASUREMENTS VIA ORTHOGONAL MATCHING PURSUIT"
- 6) Julien Mairal, Francis Bash, Jean Ponce, Guillermo Sapiro, Andrew Zisserman, "Discriminative Learned Dictionaries for Local Image Analysis", *IEEE Conference on Computer Vision and Pattern Recognition*, June.2008
- 7) M. Aharon, M. Elad, and A. M. Bruckstein, "K-SVD: An Algorithm for Designing Overcomplete Dictionaries for Sparse Representation," *IEEE Trans. Image Process.*, vol. 54, no. 11, pp.4311-4322, Nov.2006
- 8) Y. Taieb, O. Eliassaf, M. Freiman, L. Joskowicz, and J. Sosna, "An iterative Bayesian approach for liver analysis: tumors validation study"
- 9) J. Mairal, M. Elad, and G. Sapiro, "Sparse Representation for Color Image Restoration," *IEEE Trans. Image Process.*, vol. 17, no. 1, Jan.2008
- 10) Jiaya Jia and Chi-Keung Tang, "Tensor Voting for Image Correction by Global and Local Intensity Alignment", *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol 27, no. 1, Jan 2005
- 11) C. Goodall, "Procrustes method in the statistical analysis of shape," *Journal of the Royal Statistical Society. Series B(Methodological)*, 53(2):285-339, 1991.