

Received January 7, 2000; Accepted February 22, 2000

可変サイズのサブ画像を用いた階層的な画像のセグメンテーション

大倉 恵子・Yucel Ugurlu・小尾 高史・山口 雅浩・大山 永昭

東京工業大学像情報工学施設 〒226-8503 横浜市緑区長津田町 4259

The Hierarchical Image Segmentation Method Using Adaptive Sizes of Sub-Image

Keiko OHKURA, Yucel UGURLU, Takashi OBI, Masahiro YAMAGUCHI and Nagaaki OHYAMA

Imaging Science and Engineering Laboratory, Tokyo Institution of Technology, 4259, Nagatsuta, Midori-ku, Yokohama 226-8503

In the analysis of medical image database aiming to formulate useful knowledge for image diagnosis, unsupervised image processing technique without using preconceived knowledge is required. In this paper, we propose a method for unsupervised image segmentation, suitable for finding the features contained in the image. The proposed method takes an approach of top-down hierarchical division procedure. In each division procedure, many small regions (sub-images) are acquired from whole input area of the division procedure, and the set of sub-images is classified by clustering in the multi-dimensional vector space. The size of sub-image is automatically decided depending on the input area. The performance of the proposed method is tested using the image generated by the Markov Random Field (MRF) model and the real medical images, photomicrographs of colon tumor.

1. はじめに

近年の保健医療分野における情報化の進展により、大量の医用画像データベースの蓄積が可能になりつつある。これに伴い、蓄積された医用画像データベースから画像診断に有用な知識を抽出することが期待されている。

画像診断の中でも、画像の特徴と病状の関係がある程度明確になっており、医師による診断精度の相違が比較的少ない分野もあれば、画像の特徴と病状の関係が明確になっていないために、その診断精度は医師の経験によるところが大きい分野もある。後者の画像診断の例としては、がんの病理診断が挙げられる。がんの病理診断では、核、細胞、細胞の集合体である組織、組織の配列など、さまざまな構造の特徴に基づいた診断が必要とされている。また、悪性・良性の診断のみではなく、悪性の度合いも診断する必要があり、その診断基準は複雑多岐にわたり¹⁾、医師は診断の大半を経験に頼らざるを得ない。このような分野においては、より信頼性の高い診断を行うために、コンピューター支援診断(CAD)技術の開発が強く求められるが、

CADのアルゴリズム構築にあたっては、画像の特徴と病状の関係を明確にし、客観的な診断基準を構築することが必要である。

本論文は、病理診断で得られる画像データベースを解析し、画像中に含まれる細胞、組織、組織の配列などのさまざまな構造の特徴とがんの悪性度の関係を明確にすることを目的として、画像からさまざまな構造を抽出するための手法の開発を行う。この目的を実現するために、本論文では、画像に含まれるさまざまな大きさの構造をセグメントとして抜き出すことが可能となる画像のセグメンテーション手法を提案する。当然のことながら、この手法では構造の大きさやその構造の輝度、テクスチャー、形などの画像の特徴に関する先駆知識を用いないことが求められる。

先駆知識を用いずに画像のセグメンテーションを行う場合、画像中の小さな領域の類似性に基づいて画像の分割を行う手法が一般的である。通常、この小さな領域をサブ画像と呼ぶ。一般に、サブ画像の類似性の評価には、サブ画像からなんらかの特徴パラメータを抽出する方法が用いられている。伝統的な特徴パラメーターとしては、共起行列^{2,3)}や二次統計量^{4,5)}、または、自己回帰モデルやマルコ

E-mail: keiko@isl.titech.ac.jp

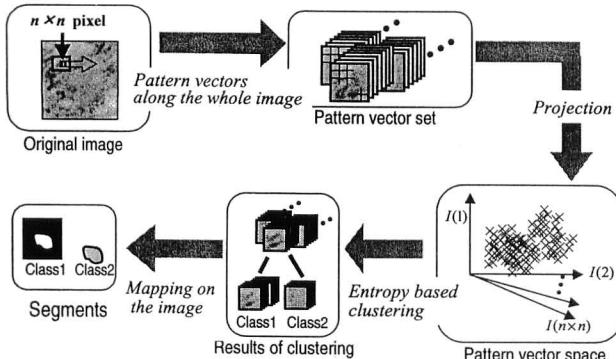


Fig. 1 The flow of the segmentation using the entropy-based clustering.

フモデル⁶⁻⁸⁾などのモデルへのあてはめによって得られるモデル係数などが挙げられる。これらの特徴パラメーターを用いた手法は、サブ画像を大きくするとパラメーターの個数が大幅に増大し、その結果莫大な処理時間を必要とするため、通常はサブ画像のサイズを小さめに設定している。このことから、組織標本へ適用する場合には、組織や組織の配列などの大きな構造の抽出は難しくなるといえる。

一方、最近は、ガボール変換^{9,10)}やウェーブレット変換¹¹⁻¹³⁾を用い、さまざまな解像度で得られる特微量パラメーターに基づいて画像の分割を行う手法が開発されている。低い解像度から得られる特微量には、比較的広範囲のサブ画像の情報が含まれているため、さまざまな構造の抽出が行える可能性がある。しかし、これらの手法は、すべての解像度から得られる特微量を一度に用いて解析しているため、個々の解像度に特有な構造の抽出を行うものではない。このため、異なる解像度間で得られた構造の関係を解析し、ある構造を抽出するために有用な解像度などの情報を抽出することは難しい。

われわれは先に、サブ画像内のすべての画素値から成るベクトル（パターンベクトル）の空間で、サブ画像のクラスタリングを行う手法を提案した¹⁴⁾。この手法では、サブ画像から共起行列や二次統計量などの特徴パラメーターを抽出したり、自己回帰モデルやマルコフモデルなどのモデルを用いていないため、テクスチャーや輝度などのさまざまな画像の特徴を一度に考慮することが可能である。また、パラメーター抽出の必要がないため、比較的大きなサブ画像を用いた場合でも、実用的な計算時間で処理できるという利点を有する。しかし、サブ画像サイズをあらかじめ与える必要があるため、対象とする画像や処理できる画像内の領域に応じて、適切なサブ画像のサイズを選択することはできなかった。

本論文で提案する手法は、階層的に分割を繰り返す方式

を用い、各分割で対象とする領域に応じて最適なサブ画像サイズを自動的に選択することを可能にするものである。具体的には、各分割において、先の論文で提案した手法を拡張し、サブ画像サイズもパラメーターとして、パターンベクトルの類似性が強く、かつ、画像上で連続した大きな領域を占めるセグメントに分割する。このような分割を繰り返すことで、大きなセグメントから小さなセグメントまでを階層的に効率よく抽出することが可能となる。

以下、次章で先の論文で提案したセグメンテーション手法の概観を、3章で本論文で提案する手法について記述する。そして、4章ではテスト画像を用いたシミュレーションとその結果を、5章では病理診断に用いる組織標本の顕微鏡画像へ提案手法を適用した実験結果を示す。

2. エントロピークラスタリングを用いた画像の領域分割手法¹⁴⁾

本章では、エントロピークラスタリングを用いた画像の領域分割手法について、その考え方と原理を概説する。本手法では、Fig. 1 の概念図が示すように、はじめに与えられた画像上のすべての画素に対応するサブ画像 ($n \times n$ 画素) をきりだし、サブ画像の集合を得る。そして、すべてのサブ画像を $n \times n$ 次元のパターンベクトル空間に投影し、この空間上でサブ画像をクラスタリングする。ここでサブ画像は、各画素の周囲 $n \times n$ 画素の領域をもつ小画像であり、各サブ画像をベクトル $t = \{I(1), I(2), \dots, I(n^2)\}$ (パターンベクトル) で表す ($I(m)$ は m 画素目の画素値) ことにする。得られたサブ画像のクラスタリングは、上記のパターンベクトル空間に投影されたサブ画像集合から出現確率分布 ρ を推定し、この分布を統計的に評価することで行われる。用いる評価関数は、熱統計力学のエントロピーのモデルに基づくものである。具体的には 1 つのサブ画像を 1 つの粒子と考え、サブ画像の集合を 1 つの多粒子系で表すことにより、系のエントロピー H を次式で定義する。

$$H = - \sum_{t \in \Omega} p(t) \cdot \log\{p(t)\} \quad (1)$$

ここで、 $p(t)$ はパターンベクトル t が出現する確率であり、多粒子系において、粒子がある状態をとる確率に相当する。また、 Ω はパターンベクトル空間全体を示している。この系を k 個の系に分割したときのエントロピーは式 (2) で表せる。

$$E = \sum_{j=1}^k \frac{N_j}{\sum_{i=1, \dots, k} N_i} H_j \quad (2)$$

ここで、 N_i 、 H_j は、それぞれ、系 i における粒子数、お

よび、エントロピーである。 E が最小値をとるとき、系全体が最も秩序のある状態であると考えることができる。このようにして得られたクラスタリング結果を画像空間に逆投影することで、1枚の画像を k 個のセグメントに分割した結果を得る。

ここでレビューした手法では、固定サイズ ($n \times n$ 画素) のサブ画像をあらかじめ設定していたが、次章で提案する手法は、上記の手法を可変サイズのサブ画像を用いた手法へ拡張するものである。

3. 可変サイズのサブ画像を用いた階層的な画像のセグメンテーション

3.1 概 観

本手法では、大きなセグメントから小さなセグメントまでさまざまな大きさのセグメントを効率よく抽出するために、階層的に2分割を繰り返す方式を用いる。そして、各分割で対象とする領域に応じて、最適なサブ画像サイズを自動的に選択し、画像上で連続した大きな領域を占めるセグメントから探していく。

各2分割における処理の流れを Fig. 2 に示す。Fig. 2 に示すように、まず、さまざまなサイズのサブ画像でエントロピーを用いた画像の領域分割手法（2章参照）を行い、それぞれのサイズごとに、2つのセグメントに分割された結果を得る。次に、これらの結果の中から、次節で提案する手法を用いて最適なサブ画像サイズにおける結果を選択する。選択された結果が、この2分割の出力となる。以後、ある2分割に着目したとき、入力として与えられるセグメントを母セグメント、2分割処理後に得られるセグメントを子セグメントと呼ぶことにする。

3.2 最適なサブ画像サイズの決定手法

本節では、評価関数を用いて最適なサブ画像サイズを決定するために、さまざまなサブ画像サイズで得られた子セグメント対から、1つの子セグメント対を選択する手法について述べる。

本手法では、大きなセグメントから小さなセグメントまでを1本の2分木で表現するために、各2分割ではできるだけ大きな子セグメントに分割する。いいかえると、各子セグメントができるだけ画像上でまとまりをもつように分割することが望ましい。このため、各2分割では、さまざまなサブ画像サイズで得られた子セグメント対の中から、各子セグメントの画像上の連続性が高い、子セグメント対が求められる。一般的に、サブ画像サイズを大きくすると、画像の局所的な変化に影響を受けにくくなり、画像上の連続性が強い子セグメントが得られやすくなる。しか

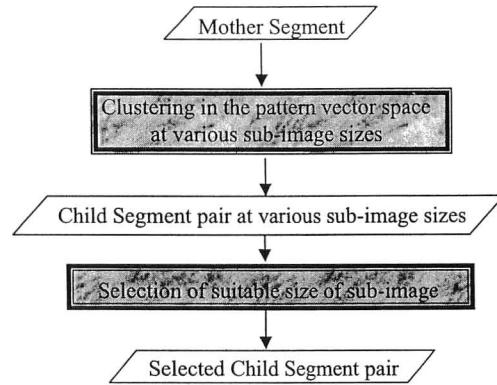


Fig. 2 The diagram of the division method.

し、画像の局所的な変化に影響を受けにくいということは、一方で、子セグメントの輪郭線が曖昧になる、下位の階層で母セグメントが小さくなったりときの分割が困難になる、などの好ましくない影響を与えててしまう。そこでここでは、パターンベクトルのサイズは小さく、かつ子セグメントの画像上の連続性は強いという2つの要件を考慮した評価方法の考案が必要である。

上記のことを念頭において、前章で解説した熱統計力学のエントロピーモデルに基づいた評価関数を用いたクラスタリング手法について考察する。この手法は、パターンベクトル空間上でサブ画像集合の確率密度分布を推定し、推定された分布を用いて各クラスターのエントロピーを計算し、評価関数であるエントロピーの合計が最も低くなるようにサブ画像集合をクラスターに分類するものであるため、ここで用いられた評価関数は、パターンベクトル空間上で各クラスターの確率密度分布のまとまり具合を評価しているといえる。そこで、このエントロピーに基づく評価関数を、最適なサブ画像サイズを決定するための評価方法に適用することを試みる。すなわち、パターンベクトル空間を画像空間に、パターンベクトル空間におけるクラスターの分布を画像空間における子セグメントの分布に対応させることで、子セグメントの画像上のまとまり具合を評価することが可能になると考えられる。そして、パターンベクトル空間におけるクラスタリングと同様に、評価関数の値が小さくなる子セグメント対を選ぶことで、画像上でまとまった分布を形成している子セグメント対を選択する。さらに、最適なサブ画像サイズを決定するためには、パターンベクトルのサイズはできるだけ小さいほうが良いという要件を考慮することが必要であるため、ここでは、確率密度分布の推定に用いるパルゼンの窓関数の分散を、サブ画像のサイズに比例させて変化させることにする。このような推定手法を用いることで、子セグメント対が同じような分布をとっていても、大きいサブ画像で得られた子

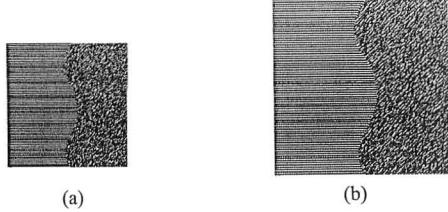


Fig. 3 Test images used in the simulation of the division method.

セグメント対の確率密度分布のほうが、より広がりをもつた分布となり、評価関数の値を大きくすることができます。

以上から、窓関数の分散をサブ画像のサイズに比例させた確率密度分布の推定手法とともに、画像空間のエントロピーに基づく評価関数を用いることで、パターンベクトルのサイズは小さく、かつ、子セグメントの画像上での連続性は高いという2つの要件を満たして、サブ画像サイズの最適性の評価が可能になると予想される。以下では、これらについて具体的に説明する。

3.2.1 子セグメント対の出現確率分布の推定

サブ画像サイズ $n_q \times n_q$ 画素におけるクラスタリングで得られた子セグメント対を $\{s_1^q, s_2^q\}$ とする。ここで、 q はサイズを表すパラメーターである。2つの子セグメントの画像空間におけるエントロピーを求めるために、まず、各セグメントの画像上での分布 $s_k^q(\mathbf{r}_{i,j})$ から、出現確率分布 $f_k^q(\mathbf{r})$ の推定を行う。 $s_k^q(\mathbf{r}_{i,j})$ は、次式で与えられる。

$$\begin{aligned} s_k^q(\mathbf{r}_{i,j}) &= 1 && \text{画素 } (i, j) \in \text{クラスター } k \\ s_k^q(\mathbf{r}_{i,j}) &= 0 && \text{画素 } (i, j) \notin \text{クラスター } k \end{aligned} \quad (3)$$

ここで、 $(\mathbf{r}_{i,j})$ は、画素 (i, j) の位置ベクトルである。出現確率分布 $f_k^q(\mathbf{r})$ は、パルゼンの窓関数法¹⁵⁾を適用し、次式を用いて推定する。

$$\hat{f}_k^q(\mathbf{r}) = \frac{1}{M_i \cdot M_j} \sum_{i=1}^{M_i} \sum_{j=1}^{M_j} W(\mathbf{r} - \mathbf{r}_{i,j}) \cdot s_k^q(\mathbf{r}_{i,j}) \quad (4)$$

ここでは、窓関数 W には次式で与えられるガウス関数を用いる。

$$W(\mathbf{r} - \mathbf{r}_{i,j}) = \frac{1}{\sqrt{2\pi}\sigma^q} \exp\left\{-\frac{D_{\mathbf{r}, \mathbf{r}_{i,j}}}{2 \cdot (\sigma^q)^2}\right\} \quad (5)$$

ここで、 $D_{\mathbf{r}, \mathbf{r}_{i,j}}$ は \mathbf{r} と $\mathbf{r}_{i,j}$ の画像空間内でのユークリッド距離を、 M_i, M_j はそれぞれ画像の縦および横方向の画素数を表している。また、 σ^q は窓関数の分散であるが、サブ画像のサイズが大きくなると位置の不確定さが増えるため、サブ画像のサイズに比例して変化させる。ここでは、サブ画像のサイズ n_q とガウス関数の半幅を一致させることにする。このような σ^q を用いることで、子セグメント対の分布 $s_k^q(\mathbf{r}_{i,j})$ が同じでも、サブ画像のサイズが大きくなればなるほど、出現確率分布 $\hat{f}_k^q(\mathbf{r})$ はまとまりのな

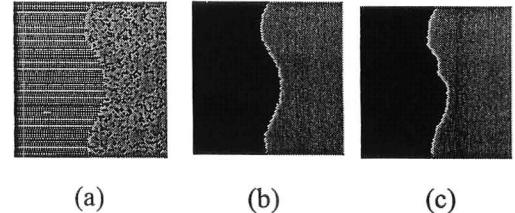


Fig. 4 Divided results of the Fig. 3 (a) with various sizes of sub-image. (a)-(c) results with the sub-image size of 3×3 , 5×5 and 7×7 , respectively.

い広がった分布となる。

3.2.2 評価関数

得られた確率分布 $f_k^q(\mathbf{r})$ から、次式に示すような評価値 $E(q)$ を計算し、 $E(q)$ の値が最小となる q を選択する。

$$E(q) = \sum_{k=1,2} H_k^q \quad (6)$$

ここで、 H_k^q はパターンサイズ q におけるセグメント s_k のエントロピーであり、次式によって与えられる。

$$H_k^q = \int \hat{f}_k^q(\mathbf{r}) \cdot \log\{\hat{f}_k^q(\mathbf{r})\} d\mathbf{r} \quad (7)$$

$E(q)$ が最小値となる q を選択することで、サブ画像のサイズが小さく、子セグメント対の分布の連続性が高い結果を選択することが可能になる。

このような2分割を繰り返すことで、1枚の画像からセグメントの2分木構造を得るが、抽出するセグメントの数をあらかじめ決定することはできないため、階層的な2分割の終了条件を設ける必要が生じる。そこで本手法では、2分割の結果得られた子セグメント対が、画像上でまったくランダムな分布をとったときに、それ以上の分割は意味がないものとし、分割処理を終了している。

4. シミュレーション

4.1 テクスチャー画像を用いた2分割のシミュレーション

本節では、式(6)で定義した評価関数の妥当性を確認するために行った計算機シミュレーションについて説明する。用いた画像は、Fig. 3に示される2つの異なるテクスチャーから成るテスト画像で、各テクスチャーは、それぞれMRF (Markov random field) モデルに基づいて生成されたものである¹⁶⁾。Fig. 3(a)は、 180×180 画素で256階調であり、Fig. 3(b)は、(a)を 256×256 画素に拡大したものである。

サブ画像サイズを 3×3 画素、 5×5 画素、 7×7 画素として2分割を行った結果を、Fig. 4とFig. 5に示す。Fig. 3(a), (b) のどちらの例においても、サブ画像サイズが小さい場合には、2つのテクスチャー領域の抽出が行われ

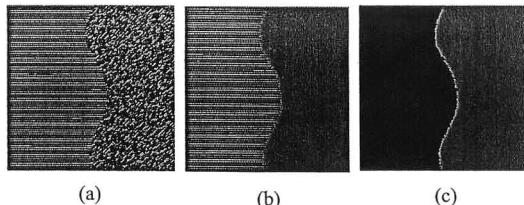


Fig. 5 Divided results of the Fig. 3 (b) with various sizes of sub-image. (a)-(c) results with the sub-image size of 3×3 , 5×5 and 7×7 , respectively.

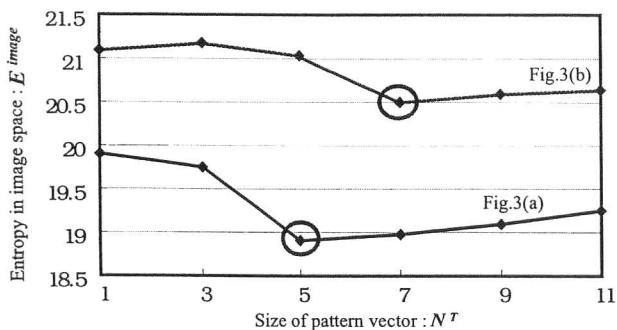


Fig. 6 The entropy in image space with the varying pattern vector size in the simulation of Fig. 3.

ていない。その原因としては、サブ画像サイズが小さすぎると、テクスチャーとしての特徴を反映することができないためであることが考えられる。Fig. 6に、サブ画像サイズに対する評価値の変化のグラフを示す。Fig. 3(a), (b) のどちらの例においても、テクスチャーの領域抽出が良好に行われているサブ画像サイズの中で、最小のサイズが評価関数の最小値をとっている。両者の結果を比較することで、画像の特徴に応じて適切なサイズが選べることが確認できる。

4.2 階層的分割のシミュレーション

次に行った計算機シミュレーションでは、階層的な分割により複数の構造を抽出することが可能であるかを確認する。ここでは Fig. 7(a) に示すような、4 つの異なる領域、マルコフモデルに基づいて作成されたテクスチャーの領域; S_1 , S_2 , ガウシアンノイズが加えられた均一な輝度の領域; S_3 , S_4 (ノイズレベルはそれぞれ、26 dB, 20 dB), を有するテスト画像を用いている。画像サイズは 256×256 画素で、階調は 256 階調である。

分割の結果を Fig. 7(b) に、対応する 2 分木構造を Fig. 7(c) に示す。また、各階層における評価関数の変化のグラフを Fig. 8 に示す。得られた結果からわかるように、第 1 階層では S_1 領域の抽出が行われているが、ここで選択されたサブ画像サイズは、 7×7 画素である。次の第 2 階層では S_2 の領域の抽出が行われ、このときのサブ

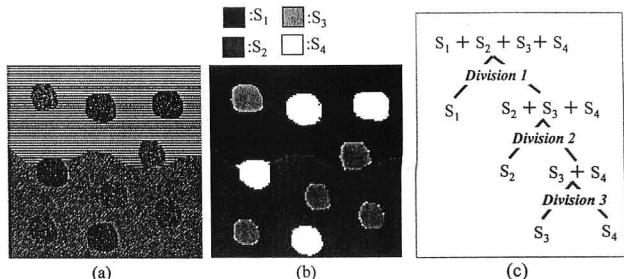


Fig. 7 Hierarchical image segmentation of the multi-regions test image. (a) original images, (b) segmented image, (c) binary tree.

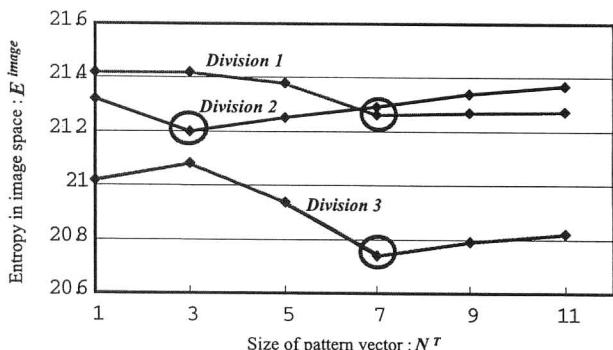


Fig. 8 The entropy in image space with the varying pattern vector size in the simulation of Fig. 4.

画像サイズは 3×3 画素になっている。さらに第 3 階層では、 7×7 画素のサブ画像サイズが選択され、領域 S_3 と領域 S_4 の識別が行われている。この結果から本手法は、階層構造を利用し、各階層で適切なサイズのサブ画像を用いることで、さまざまな大きさや異なる性質を有するセグメントの抽出が行えることが確認された。

5. 組織標本の顕微鏡画像を用いた実験

病理診断に用いられる大腸の顕微鏡画像に本手法を適用した結果を示す。原画像 (Fig. 9(a) 参照) のサイズは 256×460 pixel, 階調は 256 レベルであり、がんの悪性度の異なる 2 つの領域が写されている。

可変サイズのパターンを用いたときのセグメンテーション結果を Fig. 9(b), (c), (d) に、そのときのセグメントの階層構造を Fig. 10 に示す。また、各階層におけるサブ画像サイズの変化と評価関数の変化のグラフを Fig. 11 に示す。Fig. 9(b) に示すように、第 2 階層までのセグメンテーションにおいて、画像全体が背景・良性・悪性の 3 種の領域に分割されている。このときのパターンサイズは 11×11 画素であった。さらに、第 3 階層では、 3×3 画素のパターンサイズが選択され、Fig. 9(c) に示すように、

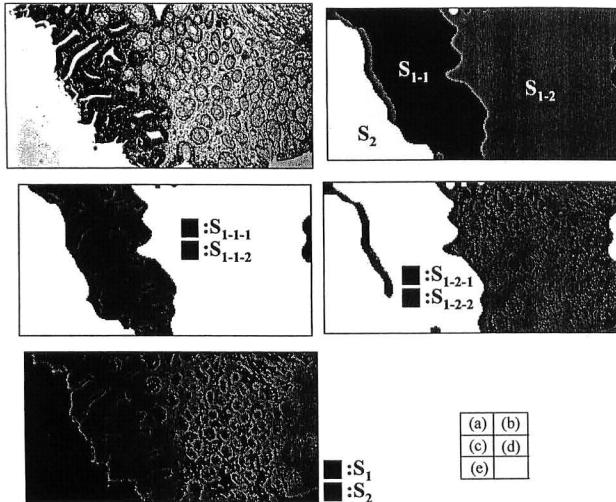


Fig. 9 Experimental results. (a) original image, (b)-(d) results of division 1-4 with adaptive pattern sizes, (e) result of division 1 with fixed pattern size.

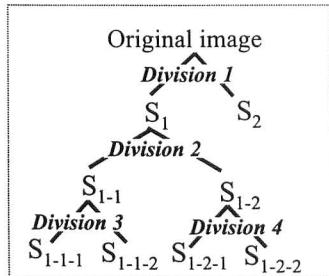


Fig. 10 Segments' labels and their binary tree.

悪性領域内の腺口等の領域が抜き出されている。一方、固定サイズ (3×3 画素) のパターンを用いた手法では、第1階層 (Fig. 9(e) 参照) において、画像の細かい構造に影響を受けたために、がんの悪性度の違いと組織の違いを段階的に分類することはできない。

これらの結果から、提案した最適なサブ画像サイズの決定手法を用いることで、各階層ごとに悪性度の違いや組織の違いなどの、異なる医学的性質に基づいたセグメンテーションを行える可能性があることがわかる。また、これらの結果は、医用画像をさまざまな角度から解析するための基礎的な技術として、本手法が有効であることを示唆している。

6. まとめ

本論文では、大量の医用画像データから画像診断に有用な情報を抽出するための基礎的な技術の確立を目的とし、先駆知識を用いずに画像に含まれるさまざまなセグメントをクラス分けする手法を提案した。提案した手法は、階層的に2分割を繰り返し、大きなセグメントから小さなセグ

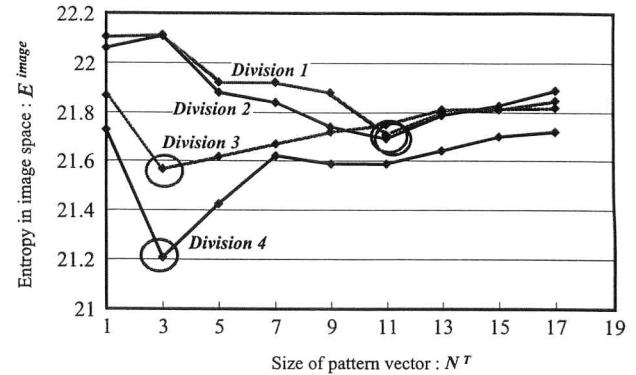


Fig. 11 The entropy in image space with the varying pattern vector size in the experiment of Fig. 9.

メントまでを効率よく2分木構造で表現するものである。具体的には、各2分割で母セグメントを2つの子セグメントに分割する際に、熱統計力学のエントロピーの考え方に基づいて、サブ画像の類似性と子セグメントの画像上の分布を評価し、最適なサブ画像サイズの決定と、母セグメントの2分割を同時に実行。テスト画像を用いたシミュレーションにより、エントロピーに基づいた評価関数の有効性と階層的な分割が可能であることを確認を行った。さらに、本手法を実際の病理診断に用いる組織標本の顕微鏡画像に適用し、悪性・良性の領域、および各領域内の組織の抽出が行えることを確認した。これらの結果は、本手法によりさまざまな医学的性質に基づいた医用画像の解析が行えることの可能性を示しており、医用画像から診断に有用な情報を抽出するための解析にあたり、本手法が非常に有用な技術となり得ることを示唆していると結論できる。

文 献

- 1) 向井 清：“がんの病理診断”，からだの科学増刊，(1989) 45-49.
- 2) R. M. Haralick, K. Shanmugan and I. Dinstein: “Textural features for image classification,” IEEE Trans. Syst., Man, Cybern., **SMC-8** (1973) 610-621.
- 3) A. Baraldi and F. Parmiggiani: “An investigation of the textural characteristic associated with gray level cooccurrence matrix statistical parameters,” IEEE Transaction on Geoscience and Remote Sensing, **33** (1995) 293-304.
- 4) R. Bajcsy: “Computer identification of visual surface,” Computer Graphics and Image Processing, **2** (1973) 118-130.
- 5) P. C. Chen and T. Pavlidis: “Segmentation by texture using correlation,” IEEE Trans. Patt. Anal. Machine Intell., **5** (1983) 64-69.
- 6) S. Geman and D. Geman: “Stochastic relaxation, gibbs distributions, and the bayesian restoration of images,” IEEE Trans. Patt. Anal. Machine Intell., **6** (1984) 721-741.
- 7) H. Derin and H. Elliott: “Modeling and segmentation of noisy and textured images using gibbs random fields,” IEEE Trans. Patt. Anal. Machine Intell., **9** (1987) 39-53.

- 8) P. Andrey and P. Tarroux: "Unsupervised segmentation of Markov Random Field modeled textured image using selectionist relaxation," *IEEE Trans. Patt. Anal. Machine Intell.*, **20** (1998) 252-262.
- 9) D. Dunn, W. E. Higgins and J. Wakeley: "Texture segmentation using 2-D Gabor elementary functions," *IEEE Trans. Patt. Anal. Machine Intell.*, **16** (1994) 130-149.
- 10) T. Hofmann, J. Puzicha and J. M. Buhmann: "Unsupervised texture segmentation in a deterministic annealing framework," *IEEE Trans. Patt. Anal. Machine Intell.*, **20** (1998) 803-817.
- 11) T. Chang and C.-C. Jay Kuo: "Texture analysis and classification with tree-structured wavelet transform," *IEEE Trans. Image Process*, **2** (1993) 429-441.
- 12) J.-L. Chen and A. Kundu: "Rotation and gray scale transform invariant texture identification using wavelet decom- position and hidden Markov model," *IEEE Trans. Patt. Anal. Machine Intell.*, **16** (1994) 208-214.
- 13) M. Unser: "Texture classification and segmentation using wavelet frames," *IEEE Trans. Image Process*, **4** (1995) 1549-1559.
- 14) K. Ohkura, H. Nishizawa, T. Obi, M. Yamaguchi and N. Ohyama: "Hierarchical clustering method for the segmentation of medical images," *Medical Imaging 1998*, Proc. SPIE, **3338** (1998) 1306-1313.
- 15) K. Fukunaga: *Introduction to Statistical Pattern Recognition* (Academic Press, Inc., New York, 1972).
- 16) R. Chellappa, S. Chatterjee and R. Bagdazian: "Texture synthesis and compression using Gaussian-Markov random field models," *IEEE Trans. Sys. Man. Cybern.*, **15** (1985) 298-308.