

構造解析によるテクスチャの記述

富田文明* 白井良明* 辻三部**

* 電子技術総合研究所パターン情報部

** 大阪大学基礎工学部制御工学科

1. まえがき

我々が物を認識するときにはテクスチャの情報を利用している。例えば、ある情景の中に存在する物体を観察する場合、各物体のテクスチャの違いからその輪郭を抽出したり、そのテクスチャの特徴から物体を同定することができる。このような認識能力を機械にも賦与することは、人工知能研究の興味ある問題であるばかりでなく、医用画像や航空写真などの自動解析のように実用的にも重要な課題である。テクスチャは少くとも2つのレベル(統計レベルと構造レベル)で研究されている[1]。統計レベルでは、テクスチャをその局所的性質の分布の統計量により定義している。構造レベルでは、テクスチャを“要素”が一定の“法則”に従って配列されてできる繰り返しパターンと定義している。筆者らは構造解析により、まず画像を異なるテクスチャ領域に分割する方法[2, 3]を、次にテクスチャのサンプルをいくつかのカテゴリーに分類する方法[4]を発表した。本報告では、構造解析によりテクスチャをどのように記述することができるのかを述べると共に、テクスチャの解析アルゴリズムの新しい評価方法を提案する。

従来から行われている性能評価の基準は、テクスチャのサンプルを予め決められたカテゴリーに分類できる能力である[5, 6]。しかし、この方法は使用するサンプルとカテゴリーに大いに依存する。自然のテクスチャのカテゴリーは人工的に作られた文字などのように明らかでない。個々のアルゴリズムの評価はその応用分野によって異ってくる。そこで、各アルゴリズムがテクスチャのどのような情報を抽出しているのかを直接的に調べる方法として *analysis-by-synthesis* (ABS) 法を提案する。即ち、図1のように、我々のシステムではテクスチャのサンプルを解析し、得られた記述を利用してサンプルの分類もできるが、生成プログラムによってテクスチャ画像を再構成することもできる。我々は、この再成画像と原画像を比較することにより、どのような情報が保存されどのような情報が失われているのかを見ることが出来る。従って、このABS法はアルゴリズムの評価および改良に役立つと思われる。

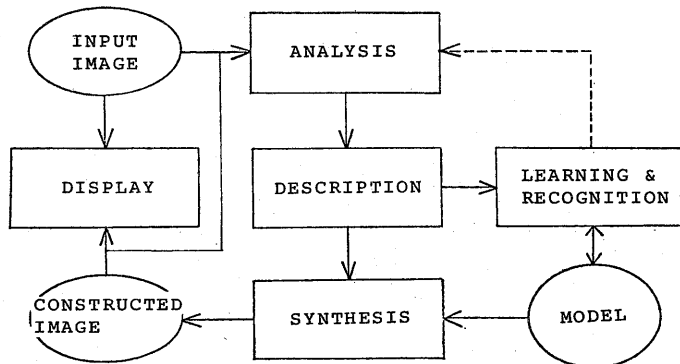


図1 テクスチャ解析システムの概要

2. 構造解析

構造レベルの解析では、テクスチャーの構成要素とその配列法則を調べるが、その結果、我々の解析システムでは図2に示すような階層構造的なテクスチャーの記述を得る。即ち、システムはまずテクスチャー画像内の要素を抽出し、各要素の性質を測定し、その性質の分布に基づいて要素をいくつかの性質の異なるクラスに分類する。そこで、各クラスの要素の特徴として要素の性質の分布の統計量を計算する。さらに、各クラスを画像の“地”に相当するか“図”に相当するか分類し、“図”に相当する各クラスからは要素の形の詳細な記述のために典型的な要素を1つ選ぶ。また、各クラスの要素の配列の特徴として要素の密度や各クラス間の隣接関係を測定する他、各“図”のクラスについては、その要素の配列法則として要素間の相対的位置ベクトルを求める。

この記述を利用して、システムはテクスチャーの学習と認識(分類)および再構成を行うことができる。

2.1 前処理

入力画像は、大きさ 64×64 点、明るさ64レベルのデジタル画像である。例として、図3に3種類の種類テクスチャー画像を示す。入力条件により画像の明るさの第1次統計量に変動するので、入力画像は明るさの平均値が32、標準偏差が8となるように正規化する。また、テクスチャーの要素の抽出を容易にするために、エッジ保存平均化法により(正規化)画像のボケの部分減少させる。

2.2 要素の抽出

テクスチャーの要素を“ほぼ同じ明るさを有する点の連結領域”として抽出する。しかし、どの位の明るさの差をもって“ほぼ同じ”とみなすかは相対的なもので前もって決めることはできない。本報告では、次のように評価基準を定めている。まず、初期領域として明るさの等しい点の連結領域(4連結)を求める。次に、明るさの差の絶対値が $d (=1)$ 以下の隣接領域を合併し、各合併領域内の

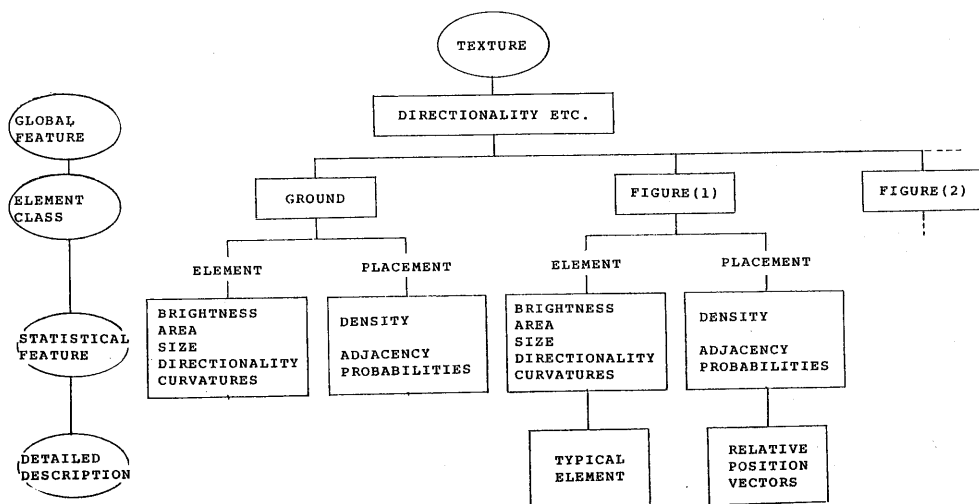


図2 テクスチャーの階層構造的記述

点の明るさをその平均値に変える。この時の合併の影響の大きさを示す指標として、平均化による明るさの変化分 $N(d)$ を計算する。

$$N(d) = \sum_{(x,y)} \sum_{(x,y)} |\delta_d(x,y)|$$

但し、 $\delta_d(x,y)$ は点 (x,y) の明るさの変化分である。そして、 d の値を1つ増して ($d \leftarrow d+1$) この合併処理を繰り返すが、 $d > 4$ のときに次のいずれかの条件を満足すると中止する。


- (1) 明るさの変化分の変化が大きいとき : $N(d) > 5000$
- (2) 明るさの変化分が大きいとき : $N(d) > 1.5 \times \min\{N(d')\} (4 \leq d' < d)$
- (3) 明るさの変化分が小さいとき : $N(d) < 1000$

合併処理が条件(1) または (2) で中止した場合 ($d = d^*$ とする)、 d の値が大きくなり過ぎて異なる要素まで合併しているとみなして、 $d = d^* - 1$ のときに得られた各連結領域をテクスチャーの要素と定義する。また、条件(3) で中止した場合、異なる要素間には明るさのギャップがあるとみなされるので、このときの画像の明るさのヒストグラムを利用して、そのしきい値処理によって得られる各連結領域をテクスチャーの要素と定義する。

例として、図3の画像から以上のようにして抽出した要素を図4に示す。

2.3 要素の性質


抽出した各要素の次の5種類の性質を測定する。これらは要素のおおまかな区別に利用する。



(a)




(b)




(c)


図3 入力画像



(a)



(b)



(c)

図4 抽出要素

- (1) 明るさ
- (2) 面積
- (3) サイズ: $2 \times \text{面積} / \text{周囲長}$ と定義する。
- (4) 方向性 (方向とその強さ): 要素内の点の x, y 座標の共分散行列を

$$\nabla = \begin{bmatrix} V_{11} & V_{12} \\ V_{21} & V_{22} \end{bmatrix}$$

とすると、要素の方向をその長軸の傾きと定義する。

$$D_{\theta} = \frac{1}{2} \tan^{-1} \frac{V_{12}}{V_{11} - V_{22}}$$

また、行列 ∇ の固有値を λ_1, λ_2 ($\lambda_1 \geq \lambda_2$) とすると、要素の方向性の強さを

$$D_0 = \frac{\lambda_1 - \lambda_2}{\lambda_1 + \lambda_2}$$

と定義する。

- (5) 境界線の曲率: 要素の各境界点における k -曲率 ($k=5$) [7] f を測定し、その値により次の6種類に分類する。

- ・凸急曲線 : $-75^\circ \leq f \leq -45^\circ$
- ・凸緩曲線 : $-45^\circ \leq f \leq -15^\circ$
- ・直線 : $-15^\circ \leq f \leq 15^\circ$
- ・凹緩曲線 : $15^\circ \leq f \leq 45^\circ$
- ・凹急曲線 : $45^\circ \leq f \leq 75^\circ$
- ・ジグザグ線: その他

そして、要素の形に関する特徴として、最初の5種類の曲率の生起確率を計算する。

2.4 要素の分類

各要素の以上の性質の分布に基づいて要素を性質の異なるクラスに分類する。本報告では、要素の各性質のヒストグラムのしきい値処理により要素を分類する。但し、ヒストグラムを計算するときはその度数に重み付けをしている。その重み係数を表1に示す。例えば、要素の明るさのヒストグラムを計算するときには、その度数として要素の面

表1 性質の重み付け

PROPERTY	WEIGHTING
BRIGHTNESS	AREA
SIZE	PERIMETER
AREA	AREA
DIRECTIONALITY	
.DIRECTION	AREA x MAGNITUDE
.MAGNITUDE	AREA
CURVATURES	PERIMETER

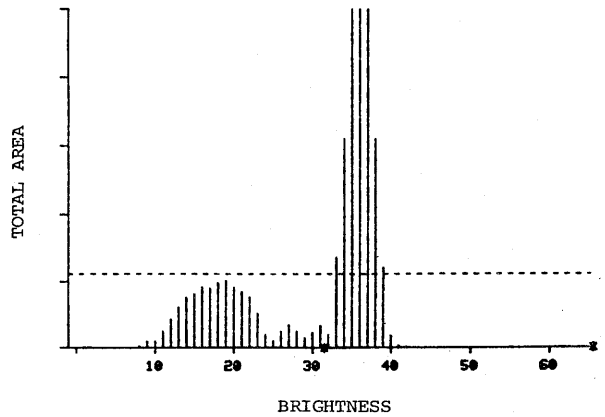


図5 要素の明るさによる分類

積 (個数ではない) を利用している。この重み付けにより要素の個数の少ないテクスチャーも安定に解析することがができる。また、各性質のヒストグラムの定義域と値域が異なるので、総度数を $4K$ (4096)、定義域を 64 レベル以下に正規化する。そこで、システムはヒストグラムの深い谷の部分にしきい値を設定する [4]。

例えば、図5は図4(a)の要素の明るさのヒストグラムであり、1つのしきい値を*の点に設定し、要素を2つのクラスに分類する。

2.5 テクスチャーの記述

統計的特徴

各クラスの要素の性質に関する次の統計的な特徴を計算する。

- (1) N_c : クラスの数
- (2) (μ_{ip}, σ_{ip}) ($i=1\sim N_c, p=1\sim N_p$): 各クラス i の要素の各性質 p の平均と分散。この分布の計算にも表1の重み付けをしている。
この他、各クラスの要素の配列に関する次の特徴も測定する。
- (3) A_i ($i=1\sim N_c$): 各クラス i の要素が画面全体に占める面積の割合(密度)。
- (4) P_{ik} ($i, k=1\sim N_c$): クラス i の要素の境界点がクラス k の要素と隣接する確率。特に、 $i=k$ のとき自己隣接確率と呼ぶことにする。
例として、図3の画像に対するこれらの特徴量を表2に示す。

図と地

要素のクラスが2つ以上ある場合、そのうち1クラスは画像の“地”に相当すると考えられる。この“地”のクラスを次のように定義する。

- (1) 要素の平均面積が非常に大きいクラス(例えば、表2(c)のクラス1)
- (2) 要素の面積の分散値が平均値に比べて大きいクラス(例えば、表2(b)のクラス2)
- (3) 自己隣接確率の大きいクラス(例えば、表2(a)のクラス1)

従って、この他のクラスは画像の“図”と定義する。但し、要素のクラスが1つしかない場合は、そのクラスを“地”であると共に“図”であるものとする。

例として、以上の基準で定めた図3の画像の“地”の部分を図6に示す。

典型的要素

各“図”のクラスの要素の形の詳細な記述のために、そのクラスの典型的な要素を1つ選ぶ。ここで、典型的な要素とは、その形状に関する性質の値がそのクラスの平均値に最も近い要素である。その典型度の計算に利用する性質は、面積、

表2 統計的特徴

TEXTURE	(a)				(b)				(c)			
	1		2		1		2		1		2	
No. of class	mean	s.d.	mean	s.d.	mean	s.d.	mean	s.d.	mean	s.d.	mean	s.d.
properties												
brightness	19.2	5.2	36.1	1.4	18.5	3.8	35.0	2.4	27.0	0.2	45.4	2.9
size	2.9	0.6	8.2	2.1	3.6	0.9	6.9	3.1	8.9	0.8	3.4	0.9
area	12.9	11.7	73.3	70.0	32.6	36.2	67.4	175.2	2664.5	438.3	144.1	105.2
directionality												
.magnitude (%)	56.6	26.5	34.3	24.4	78.8	28.0	71.4	22.7	7.0	6.9	28.7	29.0
.direction	16.4	4.2	17.7	2.0	17.7	2.7	17.3	1.2	17.9	0.8	23.0	3.8
curvatures												
.[-75, -45] (%)	4.4	6.1	5.3	4.5	1.9	3.5	4.4	3.2	9.6	2.1	8.6	5.9
.[-45, -15] (%)	21.0	15.2	17.9	7.7	20.8	9.8	19.8	9.9	24.7	5.1	24.3	12.8
.[-15, 15] (%)	13.9	13.4	16.0	8.3	32.6	17.5	32.1	16.1	28.8	5.6	22.8	13.7
.[15, 45] (%)	24.4	22.1	36.2	13.3	31.4	17.5	24.5	12.8	23.7	8.5	19.6	10.8
.[45, 75] (%)	9.1	10.5	18.9	8.5	6.1	8.6	7.0	8.0	9.2	3.1	8.3	9.9
density (%)	30		70		29		71		73		27	
adacency probabilities (%)												
			1	2			1	2			1	2
	1	22	78		1	10	90		1	0	100	
	2	93	7		2	60	40		2	97	3	

サイズ、方向性、曲率であり、クラス i における要素 j の典型度 E_{ij} を次のように定義する。

$$E_{ij} = \frac{\sum_{p=1}^{N_p} \exp \left[-\frac{(x_{jp} - \mu_{jp})^2}{2\sigma_{jp}^2} \right]}{N_p}$$

但し、 x_{jp} は要素 j の性質 p の値である。そして E_{ij} が最大となる要素を典型的要素に選ぶ。例えば、図3の画像の“国”のクラスの典型的要素を図6に示す。

この典型的要素の記述は、詳細な認識処理の段階で必要である。多くの形の解析アルゴリズムが発表されているが[7]、本報告では簡単のために要素内の点の重心からの相対座標を登録する。

配列法則 (相対的位置ベクトル)

各“国”のクラスの要素の配列法則を求めるために、要素間の相対的位置ベクトルの分布を利用する。但し、2つの要素間の相対的位置をそれらの重心間の相対的位置と定義する。そこで、クラス i とクラス k のすべての要素の対の相対的位置ベクトルを測定し、その2次元ヒストグラム H_{ik} ($i=k$ の場合も含む) を求める。但し、この分布の度数には次のように重み付けをする。例えば、 E_{ij} をクラス i の要素 j の典型度、 E_{kl} をクラス k の要素 l の典型度とすると、この2つの要素による度数の増分を $\min(E_{ij}, E_{kl})$ と定義する。

要素の配列が規則的な場合は、この分布に周期的に密なクラスターが存在することになる。そこで、それらの中で原点 $(0,0)$ に近い独立なクラスターを求め、その平均ベクトルと分散ベクトルを要素の配列法則 R_{ik} と定義する。

$$R_{ik} = \{ \{ \mu_x^n(i,k), \mu_y^n(i,k) \}, \{ \sigma_x^n(i,k), \sigma_y^n(i,k) \} \} \quad (n=1 \sim N_{ik})$$

但し、 N_{ik} は独立なクラスターの数である。一方、密なクラスターが存在しない場合は、要素の配列法則 R_{ik} は不規則であると定義する。

例えば、図6(a)の“国”のクラス2の要素の相対的位置ベクトルの分布 H_{22} を図7に示す。この場合、配列法則 R_{22} は規則的とみなされ、2つの独立なクラスターの平均ベクトルと分散ベクトルを登録する。一方、図6の他の画像の“国”のクラスの場合は不規則とみなされる。




図6 画像の“地” (斜線) と“国” (□) と典型的要素 (□)

規則的な場合

配列法則 R_{ii} が規則的な場合、その相対的位置ベクトルの分布（平均と分散）を利用する。まず平均ベクトル

$$\{M_x^n(i,i), M_y^n(i,i)\} \quad (n=1 \sim N_{ii})$$

を利用して予備的位置を図8の○のように決める（この場合、 $N_{ii}=2$ ）。次に、これらの予備的位置を正規分布

$$N[(0,0), (\bar{\sigma}_x, \bar{\sigma}_y)]$$

に従って⊙のように変動させる。但し、 $\bar{\sigma}_x, \bar{\sigma}_y$ は R_{ii} の分散ベクトルの平均値である。これらの⊙が変形要素を配置する最終的な位置である。




図8 要素の位置の決定
(→ : 平均ベクトル)

不規則な場合

配列法則 R_{ii} が不規則な場合、要素の位置を決めるのに、そのクラスの要素の密度の情報を利用する。即ち、配置する要素の数を

$$N_i = \frac{\text{クラス } i \text{ の要素の総面積}}{\text{クラス } i \text{ の要素の平均面積}}$$

と定めることができるので、その数だけの位置を一様乱数により画面全体に定める。

次に、他のクラス k ($k \neq i$) の要素を配置する場合は配列法則 R_{ik} または R_{kk} を利用する。 R_{ik} と R_{kk} が共に規則的な場合は、分散ベクトルの小さい方を利用する。 R_{ik} と R_{kk} のいずれかが規則的な場合は、規則的な方を利用する。 R_{ik} と R_{kk} が共に不規則な場合は、 R_{kk} を利用する。但し、 R_{kk} を利用する場合は中心クラスの場合と同様にして要素の位置を決めるが、 R_{ik} を利用する場合は既に決められた中心クラスの要素の位置を参照しながら要素の位置を決める。


以上のようにして決められた要素の位置を参照しながら各“図”のクラスの変形要素を配置する。全ての要素の配列を終えると、画像の“地”に相当する部分が残る。この部分を“地”のクラスの要素の明るさと面積の分布に基づいて明るさの値を埋めるとテクスチャーの画像が完成する。

例として、図9に原画像とそれから再構成した画像を示す。


3.3 実験と考察

再構成の実験には、以前に分類実験で利用したテクスチャーのサンプルを利用した[4]。即ち、Brodatzの写真集から比較的要素の小さい16種類のテクスチャーを選んだ。これらの画像の番号はD3, D9, D15, D20, D28, D32, D33, D34, D49, D67, D68, D84, D93, D103, D109, D111である。各画像を、大きさ256×256点、明るさ64レベルにデジタル化し、それを4×4枚の大きさ64×64のサンプルに分割した。

構造解析により人間と似た記述を得ることができ、それ故にわかりやすく便利であるが、テクスチャーを再構成してみるといくつかの問題点が明らかになる。



(a)



(b)



(c)

图9 原画像(左)と再構成画像(右)

テクスチャの要素を抽出するのに明るさの情報だけを利用しているのだから、抽出した要素が必ずしも人間が観察するものや実際の個体とは異なる場合がある。例えば、同じ明るさを有する個体が重なっている場合には、画像上では1つの要素として抽出してしまう。但し、個体の重なり具合を次のように推定することができる。個体の重なりがない場合は、 $D_{OL}=1$ である。

$$D_{OL} = \frac{\mu_{area} + \sigma_{area}}{\mu_{area}} \times \sqrt{\frac{\mu_{size}}{\mu_{size} + \sigma_{size}}}$$

従って、個体についての何らかの知識があれば、このような情報を利用してより正確な要素を抽出することは可能である。

システムの違ふ画像の“地”についても人間の観測するものと異なる場合がある。これは要素の定義や記述に関連してくる問題である。

測定している配列法則（相対的位置ベクトル）は第2次統計量であるか、まだ十分な情報を含んでいるとは言えない。例えば、要素の配置をそのまわりの要素の形状にかかわらず独立に決めているか、各要素の形状（変形）はそのまわりの要素の形状に依存している場合がある。

また、現在のシステムでは階層構造を有するテクスチャをほとんど扱っていない。階層構造を有するテクスチャとは、いくつかの要素が集まって1つの基本単位を形成し、その基本単位が一定の法則に従って配列されてできる繰り返しパターンである。このようなテクスチャは自然の中よりは人工的なものに多く存在する。しかし、Marrのようなaggregationプログラム[10]を加えることにより、階層構造テクスチャも同様に扱うことができる。

参考文献

- (1) Lipkin, B.C. and Rosenfeld A. (Eds.): *Picture Processing and Psychopictorics*, Academic Press (1970).
- (2) Tomita, F., Yachida, M. and Tsuji, S.: "Detection of homogeneous regions by structural analysis," *Proc. 3IJCAI*, p. 564 (1973).
- (3) Tsuji, S. and Tomita, F.: "A structural analyzer for a class of textures," *Computer Graphics and Image Processing*, 2, p. 216 (1973).
- (4) 富田, 白井, 江: "構造解析によるテクスチャの分類" *電子通信学会論文誌* Vol. 61-D No. 7, p. 457 (1978).
- (5) Weszka, J.S., Dyer, C.R. and Rosenfeld, A.: "A comparative study of texture measures for Terrain classification," *IEEE Trans. Syst., Man, Cybern.*, SMC-6, p. 269 (1976).
- (6) Weszka, J.S. and Rosenfeld, A.: "An application of texture analysis to material inspection," *Pattern Recognition*, Vol. 8, p. 195 (1976).
- (7) Rosenfeld, A. and Kak, A.C.: *Digital Picture Processing*, New York: Academic (1976).
- (8) Pavlidis, T.: "A review of algorithms for shape analysis," *Computer Graphics and Image Processing*, 7, p. 243 (1978).
- (9) Brodatz, P.: *Textures*, New York: Dover (1966).
- (10) Marr, D.: "Early processing of visual information," MIT AI Memo, No. 340 (1975).