

PDPモデルによるテクスチャ画像の識別

Textural Image Discrimination Using a PDP Model

梅田三千雄

Michio UMEDA

大阪電気通信大学 工学部

Faculty of Engineering, Osaka Electro-Communication University

Abstract Two different features, an auto-correlation function and a gray level co-occurrence matrix, are typical second-order statistics concerned in gray levels of images. This paper discusses the discrimination of natural textural images using these two features independently. Both features are extracted from an arbitrary 64*64 pixels area in textural images and consist of 80 elements. An artificial neural network based on a parallel distributed processing model is applied to the discrimination of textural images. In the training procedure of this network, error backpropagation algorithm is utilized. The experimental result shows that 5 different textural images are almost perfectly distinguishable each other.

1. ま え が き

局所的にはランダムに見える画像のなかに、幾つかの基本的な構成要素が存在し、それらがある種の規則のもとに配列されてできる繰り返しパターンをテクスチャと呼ぶ。テクスチャの解析は、画像理解の基礎をなすものとして、これまでに多くの研究が行われている[1][2]。

テクスチャ解析は、テクスチャを構成する基本的な要素を抽出し、それらの配列規則を求めることにより行うことができる。この方法によるテクスチャ解析は、一般に、構造レベルのテクスチャ解析と呼ばれる[2]。しかし、構成要素の明確な人工のテクスチャは別として、岩石や芝生、布地、木目などの自然に存在するテクスチャにおいて、その構成要素を求め、配列規則を知ることが簡単ではない。それゆえ、このようなテクスチャの解析では、画素濃度に着目して、画像の性質を表す統計量を求める方法が広く用いられる。この方法によるテクスチャ解析は、上述の構造レベルの解析に対して、統計レベルのテクスチャ解析と呼ばれる[2]。

統計レベルでのテクスチャ解析の研究の代表的なものに、R.M.Haralickらによる研究[3]がある。ここでは、テクスチャ画像に対して、2次統計量の一つである濃度共起行列 (co-occurrence matrix) と

呼ばれる行列を求め、これをもとに、テクスチャの性質を表すと考えられる、14種類の特徴量の提案と抽出方法が示されている。その特徴量とは、例えば、行列の2次モーメントから求めたテクスチャの一様性とか、濃度差の2乗平均から求めたテクスチャのコントラストとか、あるいは行列の相関から計算したテクスチャの方向性などである。

しかし、これらの特徴量は、単に上述のようなテクスチャの性質だけを表しているのではなく、一つの特徴量がいくつかのテクスチャの性質を表していたり、あるいは他の特徴量もテクスチャの同じ性質を表していたり、物理的に何を測定しているのかわからないところがある。さらに、これらの特徴量を用いて、顕微鏡写真や航空写真のテクスチャ識別実験を行い、80~90%の正解率を得ているが、必ずしも十分に高いものではない。

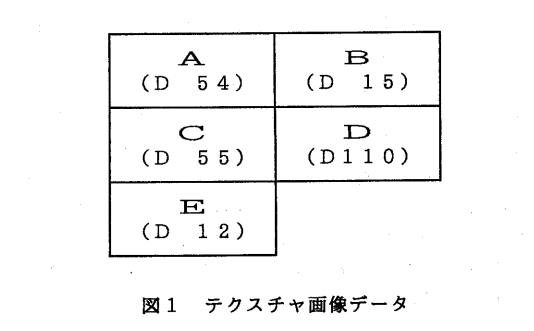




これに対して、ここではテクスチャの性質を表す特徴量については議論せず、代表的な2次統計量である自己相関関数および濃度共起行列そのものを用いたテクスチャ画像の識別について検討する。識別には、逆伝搬学習法によって学習させた多層型の並列分散処理モデル (PDPモデル) を利用し、その識別能力を明らかにするとともに、類似度を尺度とした識別との比較検討を行う。

2. テクスチャ画像の特徴抽出

2.1 テクスチャ画像

テクスチャには、自然に存在するものと、人工的なものがある。ここでは、自然に存在するものとしてよく引用される P. Brodatz の写真集 [4] のなかから、5種類のテクスチャ画像を選択し、識別実験の対象とした。

テクスチャ画像は、上述の本のなかの該当のものをカメラで撮影し、原寸大に作成した写真を用いてイメージスキャナにより入力した。スキャナの分解能は100DPIとし、一つのテクスチャ画像は、512×400画素の領域を濃淡16レベルに量子化して取り込み、画像データとした。こうして作成



したテクスチャ画像データを図1に示す。図には、各々のテクスチャ画像データの濃度ヒストグラムをあわせて示す。

2.2 自己相関関数による特徴抽出

テクスチャ画像の性質を表す2次統計量として、最初に考えられるものに、空間的な、つまり2次元の自己相関関数がある。

ここでは、次のようにして、自己相関関数によるテクスチャ画像の特徴抽出を行う。いま、あるテクスチャ画像 $f(i, j)$ において、図2(a)に示すように、ある点 (x, y) を基準点とする近傍の 64×64 画素の領域と、これから (m, n) 画素だけずれた領域、つまり点 $(x+m, y+n)$ を基準点とする 64×64 画素の領域とを対象として、

A (D 54)	B (D 15)
C (D 55)	D (D110)
E (D 12)	

図1 テクスチャ画像データ

自己相関関数を

$$R(x, y; m, n) = \frac{\sum \sum f(x+i, y+j)f(x+m+i, y+n+j)}{\sqrt{\sum \sum f(x+i, y+j)^2 \sum \sum f(x+m+i, y+n+j)^2}}$$


により与える。ここで、基準点 (x, y) を固定し、相関を取るもう一方の対象領域を

$$m, n = 0, \pm 1, \pm 2, \pm 3, \pm 4$$

の範囲内でずらすことにより、図 2 (b) に示すように、各々の自己相関関数値を要素とする、 9×9 の相関関数行列を求めることができる。

こうして求めた自己相関関数から、例えば、その広がりやテクスチャの粗さや細かさや深く関係し、その周期的な変化などからはテクスチャの周期性や方向性などの性質を知ることができよう。しかし、この自己相関関数から、テクスチャの性質を明確に表現する特徴量を抽出することは、必ずしも容易なことではない。

ここでは、自己相関関数からテクスチャの性質を表現する特徴量を改めて求めることは行わず、抽出した相関関数行列そのものを特徴量として、テクスチャ画像の識別を行うことにする。それゆえ、この特徴量は 9×9 の行列で表されるが、このうち相関関数の値が 1 となる $m = n = 0$ の要素を除外した、80次元の特徴量をテクスチャ画像の性質を表現す



(a) 相関を取る領域 (b) 相関関数行列



(c) 抽出した相関関数行列の例

図 2 自己相関関数による特徴抽出

る特徴として用いる。三つの異なった点を基準点とした 64×64 画素の領域と、その領域で抽出した相関関数行列の例を図 2 (c) に示す。

さらに、作成したテクスチャ画像データの分解能と抽出される自己相関関数との関係を調べるため、上述の自己相関関数において、相関を取るもう一方の基準点をずらすときの画素間隔を表すパラメータ d を導入し、

$$R(d) = \frac{\sum \sum f(x+i, y+j)f(x+dm+i, y+dn+j)}{\sqrt{\sum \sum f(x+i, y+j)^2 \sum \sum f(x+dm+i, y+dn+j)^2}}$$

として、種々の画素間隔 d に対する自己相関関数の抽出を行うこととした。つまり、画素間隔 d が 1 のときは、領域を 1 画素単位でずらし、 $d = 2$ のときは、領域を 2 画素単位でずらして、それぞれ相関を取るものとする。

2. 3 濃度共起行列による特徴抽出

テクスチャ画像 $f(x, y)$ において、特定の相対的な位置関係にある二つの画素の濃度対に関する統計量は、2次統計量と呼ばれる。この2次統計量を求める具体的かつ代表的な方法として、濃度共起行列が提案されている[3]。

この濃度共起行列 $M(m, n; \delta, \theta)$ とは、図 3 (a) に示すように、ある特定の相対的位置関係 (δ, θ) にある画素対 (i, j) と (k, l) において、その濃度対が (m, n) になる、すなわち $f(i, j) = m, f(k, l) = n$ になる頻度を表したものである。各画素が 0 から $h-1$ の h レベルの濃度値を取るものとするれば、この濃度共起行列 $M(m, n; \delta, \theta)$ は $h \times h$ の行列となる。

ここでは、次のようにして、濃度共起行列によるテクスチャ画像の特徴抽出を行う。まず、16レベルに量子化された画像データを 0 から 3 の 4 レベルの濃度値に再量子化する。一方、着目する画素対の方向 (θ) は、 0° (\rightarrow)、 45° (\nearrow)、 90° (\uparrow)、 135° (\nwarrow) の 4 方向とし、ある画素とその画素から見て θ 方向に距離 δ だけ離れた画素とを着目する画素対とする。次に、着目する画素対の濃度値を求め、その濃度が m, n であったとすると、濃度共起行列 $M(m, n; \delta, \theta)$ の対応する要素の項に累積していく。このとき、濃度対 m と n は、二つの画素のどちらがその濃度でもかまわないものとする。例えば、図 3 (b) に示した画像に対して、破線で囲んだ領域の画素に着目すると、距離 1 の 4 方向別の濃度共起行列 $M(m, n; 1, *)$ は図 3 (c) のようになる。

こうして求めた濃度共起行列は、テクスチャ画像の 2 次統計量を表しており、それをもとに、テクスチャの一様性や方向性、コントラストなどの性質を

知ることができよう。

しかしここでも、濃度共起行列からテクスチャの性質を表現する特徴量の議論はせず、濃度共起行列そのものを特徴量として、テクスチャ画像の識別を行う。このとき、ある距離 δ に対する濃度共起行列は、図3(c)の例のように、40次元の特徴量となる。そこで、ある点 (x, y) を基準点とした、 64×64 画素の領域にある各画素について、その画素と θ 方向に距離 δ および 2δ だけはなれた画素とを対とする濃度共起行列を別々に求め、あわせてテクスチャ識別のための濃度共起行列とする。そうすると、自己相関関数の場合と同じように、濃度共起行列も80次元の特徴量となる。

さらに、テクスチャ画像データの分解能と画素対の距離との関係を調べるため、濃度共起行列においても画素間隔 d を導入する。つまり、画素間隔 d のときの濃度共起行列は

$$M(d) = [M(m, n; d, \theta), M(m, n; 2d, \theta)]$$

$$\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$$

と表すことができる。

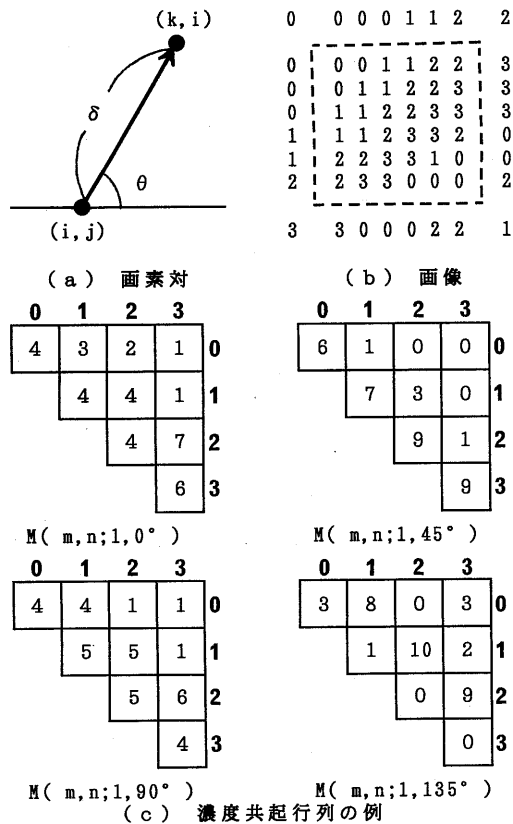


図3 濃度共起行列による特徴抽出

3. 識別系の構成

テクスチャ画像の識別には、図4に示すような、並列分散処理モデル(PDPモデル)を使用した。このPDPモデルは、入力層、中間層および出力層の3層からなる階層型ネットワークである。入力層には、抽出した自己相関関数あるいは濃度共起行列特徴が入力される。したがって、入力層のユニット数は、抽出した特徴の次元数に一致させ、80個のユニットで構成する。中間層のユニット数は8個とし、固定した。出力層のユニット数は、識別すべきテクスチャの種類に等しく、対判定実験では2個、識別実験では5個とする。

各ユニット間の接続は、層を飛び越えた接続はないものとし、かつ各層間(出力層と中間層、中間層と入力層)ではすべてのユニットは接続されているものとした。つまり、信号が下層から上層に向かって一方的に伝達されるフィードフォワード型ネットワークである。中間層と出力層の各ユニットでは、その入力の総和に対して、シグモイド関数を入力特性とする処理が行われる。

このネットワークの学習には、誤差逆伝搬法と呼ばれる、教師ありの学習則を用いた。学習による重みの変更は

$$\Delta \omega_{n+1} = -\eta \frac{\partial E}{\partial \omega} + \alpha \Delta \omega_n$$

E は出力誤差

において、学習定数 $\eta = 0.2$ 、安定化定数 $\alpha = 1$ とし、学習のたびごとに重みを変更する逐次修正により学習を進めた。

PDPモデルによるテクスチャ画像の識別能力を比較し、評価するため、抽出した同一の特徴量に対して、類似度を尺度とする対判定あるいは識別実験をあわせて行った。類似度を尺度とした識別とは、学習データの平均から算出した標準パターンベクト




図4 識別に使用したPDPモデル

ル X_k と、ある入力テキストチャの特徴ベクトル Y との類似度を

$$\rho_k = \frac{(X_k, Y)}{\|X_k\| \cdot \|Y\|}$$

k はカテゴリ、つまりテキストチャの種類により求め、その大きさによって入力テキストチャの種類 k を決定するものである。

4. テキスチャ画像の対判定実験

テキストチャ画像から抽出した2種類の特徴量、つまり自己相関関数と濃度共起行列を用いて、PDPモデルによる識別の可能性について検討するため、まず5種類のテキストチャ画像のうち、任意の二つが区別できるかどうかの対判定実験を行った。

4.1 自己相関関数による対判定実験

自己相関関数を利用したテキストチャ画像の対判定実験は、次のようにして行った。

まず、 512×400 画素の領域で表される一つのテキストチャ画像データに対して、乱数系列をもとに200個の点をランダムに定め、それらを基準点とする 64×64 画素の領域について自己相関関数を求める。したがって、一つのテキストチャ画像に対して、80次元の特徴量からなる自己相関関数が、ランダムに設定した画素の領域から、200個づつ得られる。

つぎに、これらの特徴量を入力して、図4に示したPDPモデルに学習させ、ネットワークの重みを決定する。対判定においては、出力層のユニット数は2個である。学習は、対判定の対象とする二つのテキストチャを設定し、各200個の特徴量を対にして交互に入力し、誤差逆伝搬法によって、その都度重みを変更していくことにより行う。これを1回の学習として繰り返し、50回の学習によって最終的

表1 自己相関関数による対判定結果

画素 間隔 (d)	PDPモデル		類似度	
	学習 データ	未知 データ	学習 データ	未知 データ
1	99.50	98.93	98.65	98.63
2	99.40	100	97.98	98.43
4	99.48	99.23	98.05	98.00
6	97.90	98.95	97.50	97.43

なネットワークの重みを決定する。

自己相関関数によるテキストチャ画像の対判定実験結果を表1に示す。この表は、5種類のテキストチャ画像に対する任意の二つの組み合わせ、つまり10種類の対判定における平均の正解率(%)を示したものである。なお、比較のため、類似度を尺度とした対判定結果をあわせて示す。

表において、PDPモデルの学習データに対する結果とは、学習の最終回、つまり50回目の学習において得られた正解率である。一方、未知データに対する結果とは、学習データの作成に用いたのとは異なる乱数系列によって基準点を設定し、各テキストチャ画像について200個の相関関数行列を求め、それらを学習によって作成したPDPモデルに入力したときの対判定正解率である。

この結果、自己相関関数の特徴量として、PDPモデルに学習させることにより、未知データに対しても99~100%の対判定正解率が得られる。特に、画素間隔2では、すべてのテキストチャ対を正確に判定できることがわかる。これより、テキストチャ画像から抽出した自己相関関数は、テキストチャ対の区別に有効な特徴を備えているといえよう。ちなみに、画素間隔1での判定誤りは、テキストチャBとEの組み合わせに多く、その個数は41個であった。また、画素間隔dが大きくなりすぎると、対判定の正解率は低下する。

一方、類似度を尺度とした対判定でも、例えば、画素間隔1のとき、98.6%の正解率が得られるものの、PDPモデルに比べて1%前後低くなる。なお、学習データに対する結果と未知データに対する結果にはほとんど差がない。

4.2 濃度共起行列による対判定実験

濃度共起行列によるテキストチャ画像の対判定実験も、自己相関関数の場合と同様にして行った。

つまり、乱数系列によってランダムに指定した点を基準点とする 64×64 画素の領域について、濃度共起行列を求める。一つのテキストチャ画像に対して、200個の濃度共起行列を作成した。つぎに、

表2 濃度共起行列による対判定結果

画素 間隔 (d)	PDPモデル		類似度	
	学習 データ	未知 データ	学習 データ	未知 データ
1	99.95	99.90	96.05	96.65
2	100	99.90	96.48	96.55

対象とする二つのテキスト画像から作成した特徴を対にして、合計400個の濃度共起行列を交互にPDPモデルに入力し、学習を行う。これを1回の学習とし、50回繰り返して学習させた。

濃度共起行列によるテキスト画像の対判定実験結果を表2に示す。この結果より、濃度共起行列を特徴量として学習させたPDPモデルにより、未知データに対しても99.9%の対判定正解率が得られる。つまり、濃度共起行列そのものを特徴量としてもテキストの区別が可能であることがわかる。ちなみに、画素間隔1における判定誤りは、テキストDとEの組み合わせに集中し、4個であった。また、画素間隔1と2の違いは、ほとんど差がないといえよう。

一方、類似度を尺度とした対判定では、学習および未知データに対しても、96%台の正解率しか得られず、PDPモデルに比べて3%以上も低下している。また、この値は、自己相関関数を特徴としたときのそれと比較しても、2%前後も悪くなっていることがわかる。

4.3 特徴抽出領域の変更

ここでは、濃度共起行列を用いて、類似度を尺度としたときの、対判定における正解率の低下を改善するため、濃度共起行列を算出する特徴抽出領域の

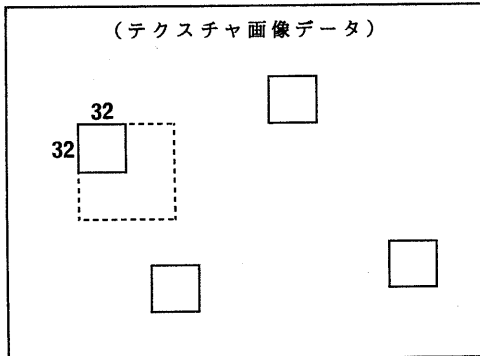


図5 特徴抽出領域の変更

表3 独立な4個の領域から抽出した濃度共起行列による対判定結果

画素間隔 (d)	PDPモデル		類似度	
	学習データ	未知データ	学習データ	未知データ
1	100	99.95	98.60	98.80
2	100	99.95	98.80	98.73

変更を試みることにする。

すなわち、これまでの濃度共起行列では、ある点を基準点とした64×64画素の領域にある画素について濃度対を算出していたのに対して、図5に示すように、32×32画素の独立した4個の領域をランダムに設定して、それらの領域に含まれる画素について濃度対を算出し、一つの濃度共起行列とする。このようにすると、算出の対象となる画素数および特徴抽出に要する演算量とも、これまでと全く同じになる。

独立な4個の領域から求めた濃度共起行列によるテキスト画像の対判定実験結果を表3に示す。

この結果より、類似度を尺度とした対判定の正解率は98%台となり、4個の独立した領域から特徴抽出することによって2%以上も改善されることがわかる。また、PDPモデルによる対判定においても、わずかではあるが、これまでの正解率より高くなっている。つまり、この方法で算出した濃度共起行列の方が、より高いテキスト識別能力を備えているといえよう。

5. テキスチャ画像の識別実験

これまでの検討により、テキスト画像から抽出した自己相関関数と濃度共起行列は、どちらもテキスト対の区別に有効な特徴を備え、かつかなり高い対判定能力を備えていることが明らかになった。ここでは、これらの特徴量による、5種類のテキスト画像の識別について検討する。

5.1 自己相関関数による識別実験

自己相関関数によるテキスト画像の識別実験は次のようにして行った。

5種類のテキスト画像に対して、乱数系列に基づいてランダムに基準点を設定し、各々200個の相関関数行列を抽出する。次に、これらの特徴量をPDPモデルのネットワークに入力し、重みの学習を行う。よって、このときの出力層は5ユニットである。学習は合計1000個の特徴量の入力を1回として、200回繰り返して行い、最終的なネットワークの重みを決定した。

自己相関関数による、5種類のテキスト画像の識別実験結果を表4に示す。表で、PDPモデルの学習データに対する結果とは、学習の最終回、つまり200回目の学習において得られた識別率(%)である。未知データに対する結果とは、学習データとは異なる乱数系列に基づいて、ランダムに領域を指定して算出した、各テキスト画像当り200個の相関関数行列を、前述のPDPモデルに入力したときの識別率である。一方、類似度による結果は、

学習データの平均によって各テキストの標準パターンを作成し、これをもとに学習および未知データを識別させたものである。

この結果、PDPモデルによるテキスト画像の識別では、画素間隔2において最も識別率が高く、学習および未知データに対してとも100%の識別率が得られる。すなわち、画像領域のどこから特徴を抽出しても、自己相関関数によって、すべてのテキストが識別できることになる。また、画素間隔

表4 自己相関関数による識別結果

画素間隔 (d)	PDPモデル		類似度	
	学習データ	未知データ	学習データ	未知データ
1	98.2	98.3	96.8	96.6
2	100	100	93.7	95.0
4	97.6	99.9	94.9	94.2
6	94.7	97.2	93.5	93.1

表5 混同行列 (画素間隔1, 未知データ) (PDPモデル)

出力 入力	A	B	C	D	E
A	200				
B		199		1	
C			200		
D	1			199	
E	4	9		2	185

(類似度)

出力 入力	A	B	C	D	E
A	200				
B		189			11
C			200		
D	13			187	
E				8	192

がこれより大きくなっても、小さくても、識別率は低下する。一方、類似度による識別は、PDPモデルによる識別よりも常に悪く、最も識別率が高い画素間隔1においても、96.6~8%にとどまる。さらに、画素間隔dが大きくなるとともに、識別率は低下していく。

また、テキスト画像の識別結果を、対判定結果と比較すると、PDPモデルでは、画素間隔が大きすぎなければ、両者はほぼ同じになるのに対して、類似度を尺度とすると、識別結果の方が2~4%も悪くなるのがわかる。

画素間隔1における未知データに対して、PDPモデルおよび類似度を尺度とした、テキスト画像の識別で得られた混同行列を表5に示す。PDPモデルによる識別(98.3%)では、テキストEの入力に対する識別に誤りが集中し、テキストBに9個、Aに4個、Dに2個誤っていることがわかる。一方、類似度を尺度とした識別(96.6%)では、テキストDに対する識別が最も悪く、テキストAに13個も誤っている。ついで、テキストBがEに誤るのが11個、テキストEがDに誤るのが8個の順になる。しかし、PDPモデルによる識別において生じる誤りと、類似度を尺度としたときのそれとは、かなり異なった傾向を示すことができる。

5.2 濃度共起行列による識別実験

濃度共起行列を用いたテキスト画像の識別実験も、自己相関関数の場合と同様に、ランダムな領域から抽出した、各テキスト画像当たり200個の特徴行列をPDPモデルに入力して、200回の学習を実行させるとともに、これとは異なる同数の未知データに対して行った。なお、濃度共起行列の特徴

表6 濃度共起行列による識別結果

画素間隔 (d)	PDPモデル		類似度	
	学習データ	未知データ	学習データ	未知データ
(64×64領域)				
1	99.9	100	89.3	91.6
2	100	99.5	91.3	91.3
(32×32×4領域)				
1	100	99.9	97.0	96.9
2	100	100	96.5	96.2

抽出領域は、 64×64 画素から抽出する場合と、4個の 32×32 画素の領域から抽出する場合とについて検討した。

濃度共起行列によるテクスチャ画像の識別結果を表6に示す。この結果、 64×64 画素の領域から特徴抽出した場合は、PDPモデルでは、学習および未知データに対してとも、99.5~100%の識別率が得られるのに対して、類似度を尺度とすると90%前後にまで低下する。

これに対して、特徴抽出領域を 64×64 画素の領域から、4個の独立した 32×32 画素の領域に変更すると、類似度による識別率は96~97%になり、5%以上も向上する。それとともに、PDPモデルによるテクスチャ画像の識別率もさらに高くなり、99.9~100%と、ほぼ完全に5種類のテクスチャ画像を識別できることがわかる。識別においても、1個の領域から濃度共起行列を抽出するよりも、4個の独立した領域から抽出する方が、より有効であるといえる。

また、識別にPDPモデルを利用すれば、5種類のテクスチャ画像を識別する場合も、二つのテクスチャ画像を対判定するときと同様に、極めて高精度の識別が可能になる。

6. むすび

テクスチャ画像の性質を表す代表的な2次統計量である、自己相関関数と濃度共起行列を用いた識別の可能性について検討した。ここでは、抽出した統計量をもとに、方向性や周期性などのテクスチャの性質を表す特徴量を定義して、識別を行うのではなく、自己相関関数あるいは濃度共起行列そのものを特徴量として、テクスチャ画像の識別を行うこととした。

自己相関関数は、ランダムに指定した基準点をもとに、画素間隔 d で決まる 64×64 画素の領域において、 ± 4 までの範囲で領域をずらすことにより80次元の特徴量として抽出される。一方、濃度共起行列も、4レベルに再量子化したテクスチャ画像から、ランダムに指定した 64×64 画素の領域に存在する画素に対して、画素間隔の距離およびその2倍の距離にある4方向の画素との濃度対を求め、累積することにより、やはり80次元の特徴量として抽出される。

自己相関関数あるいは濃度共起行列によるテクスチャ画像の識別には、並列分散処理モデル(PDPモデル)を使用した。このPDPモデルは、3層のフィードフォワード型階層ネットワークであり、その学習には誤差逆伝搬法を用いた。また、PDPモデルによる識別能力を評価するため、類似度を尺度とした実験をあわせて行った。

その結果、次のようなことが明らかになった。

1) 5種類のテクスチャ画像のうちの任意の二つを区別する対判定では、PDPモデルにより、画素間隔をうまく設定すると、どちらの特徴を用いても99.9~100%の正解率が得られる。

2) 一方、類似度を尺度とすると、自己相関関数では1%前後、濃度共起行列では3%以上も正解率が低下する。しかし、濃度共起行列の抽出領域を変更して、4個の独立した領域から算出すると、正解率は98%台になり、かつPDPモデルによる正解率も向上する。

3) 5種類のテクスチャ画像に対する識別でも、画素間隔をうまく設定すれば、PDPモデルにより100%の正解率が得られる。つまり、どの領域から特徴抽出しても、すべてのテクスチャ画像の識別が可能となる。

4) これに対して、類似度を尺度とすると、自己相関関数では3%以上、濃度共起行列では、たとえ抽出領域を変更しても、やはり3%あまり識別率が低下する。

これより、テクスチャ画像の代表的な2次統計量である自己相関関数と濃度共起行列のどちらを用いても、学習によって構成したPDPモデルにより、高精度のテクスチャ識別が可能であることが明らかになった。

今後は、1)さらに多くのテクスチャ画像に対する識別の可能性、2)回転などの変形吸収の可能性3)特徴の併用による識別能力の向上の可能性などについて検討していく。

謝辞

本研究に際して、実験資料を提供して戴き、かつ議論して戴いた、NTTヒューマンインタフェース研究所の金子博主幹研究員に深謝する。多くの実験に協力して戴いた、本学卒研生の永村保君に深く感謝する。また、実験ツールを提供して戴いた、日本電気技術情報システム開発株式会社に感謝する。

参考文献

- [1] J.S.Weszka, C.R.Dyer & A.Rosenfeld: "A Comparative Study of Texture Measures for Terrain Classification", IEEE Trans. on SMC, Vol.SMC-6 No.4, pp269-285 (1976.4).
- [2] 富田, 白井, 辻: "テクスチャの解析", 情報処理, Vol.19, No.2, pp173-182 (1978.2).
- [3] R.M.Haralick, K.Shanmugam & I.Dinstein: "Textural Features for Image Classification", IEEE Trans. on SMC, Vol.SMC-3, No.6, pp610-621 (1973.11).
- [4] P.Brodatz: "Textures", Dover, New York (1966).