

## 高次局所自己相関特徴の拡張

豊田 崇弘<sup>†</sup> 長谷川 修<sup>†,††,†††</sup>(正会員)<sup>†</sup> 東京工業大学大学院総合理工学研究科<sup>††</sup> 東京工業大学情報工学研究施設<sup>†††</sup> 科学技術振興機構, さきがけ研究 21

あらまし 高次局所自己相関特徴は画像解析において広く利用されている基本的な特徴である。これらは従来、次数 2 次までに限定され、25 個のマスクパターンによって表現されていた。一方、本研究では次数を最高 8 次まで拡張し、最大 223 個のマスクパターンを用いて特徴を表現する。さらにマスクパターンのサイズを拡大することで広い変位領域に関する特徴も抽出できるようにし、これらを用いて多重解像度化特徴を構成する。提案手法は種々のテクスチャ識別においてガウシアンマルコフ確率場, Gabor 特徴, Local Binary Pattern 特徴より良好な結果を得た。例えば  $32 \times 32$  画素の小さい画像の識別では Gabor 特徴で 93.4% の識別率だったのに対し提案手法では 97.5% を得た。他にもスケール変化や 90 度回転を含む画像の識別, 300 クラス以上の多クラスの識別において良好な識別性能を示した。また顔識別では Gabor 特徴で識別率が 96.0% だったのに対し提案手法では 98.4% が得られ、特定の構造を持つ対象に対しても有効であることを確認した。

キーワード: 高次局所自己相関特徴, マスクパターン, テクスチャ識別, 顔識別

**Summary** Higher order local autocorrelation (HLAC) features are basic features which are used in various applications. They have been restricted up to the second order and are represented by 25 mask patterns. We increase their orders up to eight and extract the extended HLAC features using 223 mask patterns. Furthermore, we create large mask patterns to support large displacement regions. We use masks of different sizes together and construct multi-resolution features. In texture classification, the proposed method outperformed other methods such as Gaussian Markov random fields, Gabor features, and local binary pattern operator. For example, in the classification of small  $32 \times 32$  texture images, the proposed method achieved a 97.5% recognition rate compared to 93.4% using Gabor features. Good performance was also shown for classification of scaled images and 90-degree rotated images, and for classification of numerous classes, over 300, using only a few training samples. The proposed method performed well in face recognition as well. It achieved a 98.4% recognition rate, as opposed to 96.0% using Gabor features. This result indicates its applicability to objects with shape.

**Key words:** Higher order local autocorrelation features, Mask pattern, Texture classification, Face recognition

## 1. はじめに

現在、画像解析は文字認識や顔認証をはじめ様々な分野で実用化されている。これらの応用の多くは特定の対象に対し決まった処理を行っている。一方、近年の急速な計算機の性能向上や記憶容量の増大にともなって、処理の高精度化・高速化とともに対象や課題に依存しない

“Extension of Higher Order Local Autocorrelation Features” by Takahiro TOYODA, (Interdisciplinary Graduate School of Science and Engineering, Tokyo Institute of Technology), and Osamu HASEGAWA, (Member) (Imaging Science and Engineering Laboratory, Tokyo Institute of Technology), (PRESTO, Japan Science and Technology Agency (JST)).

汎用性も重要となっている。例えば現在盛んに研究されている自動走行車や人間共存型ロボットなどの応用では、実環境中で遭遇する様々な物体や人間の識別、道路や障害物の認識、文字やジェスチャーの理解などが要求される。このように様々な対象や課題をひとつのシステムで扱う応用では汎用的な特徴を利用した画像解析が必要となる。

実利用を考慮した場合、特徴は汎用的で高い識別精度を持つだけでなく、計算が容易であることやハードウェア化に適していることも重要となる。そこで本稿では基本的な画像特徴であり、種々の好ましい特性を有する高次局所自己相関特徴<sup>11)</sup>に着目をする。高次局所自己相関特徴はこれまでに顔<sup>3),6)</sup>や文字<sup>11)</sup>、ジェスチャー<sup>5)</sup>の認識等に利用されているように汎用性がある。また特徴を計算するビジョンチップの実装もされており高速かつ高解像度での処理が可能となっている<sup>14)</sup>。さらに最近、3次元空間における高次局所自己相関特徴の抽出法も提案され<sup>13)</sup>、3次元物体の認識や時間軸方向を含む画像の解析など応用範囲の一層の拡大が考えられる。

一般に用いられる高次局所自己相関特徴では次数は2次までに限定され、25個のマスクパターンによって特徴は計算されている。一方、本研究では次数を最高8次まで拡張し、223個のマスクパターンを用いて特徴の計算を行う。このとき算出される特徴量は各マスクパターンのパワースペクトルを表現するもので、拡張により多様なマスクパターンを利用することでより詳細な画像の特徴付けが可能となる。さらに本研究ではマスクパターンのサイズを拡大し、広い変位領域に関する特徴も抽出できるようにする。これらの異なるサイズのマスクパターンから抽出される特徴はそれぞれ画像の異なる周波数成分を表しており、それらを併用することで多重解像度化特徴が構成される。

本稿ではまず種々のテクスチャ識別実験により提案手法の性能を評価する。課題としては様々なサイズの画像の識別、拡大や回転を含む画像の識別、300クラス以上の多クラスの識別などを行う。使用する画像データには木目や紙表面、穀物なども含んでおり、品質検査等への応用が考えられる。またテクスチャは画像の基本的な構成要素として様々な画像解析に利用されているため、実験を通して手法の応用可能性についても検証される。その具体的な応用例としては医用画像やリモートセンシング画像の解析、物体表面のテクスチャに基づく対象物の抽出や認識、シーン画像における領域分割などが挙げられる。本稿ではさらに提案手法を顔識別にも適用し、特定の構造を持つ対象に対する有効性も確認する。これらの実験ではテクスチャ解析で広く利用されているガウシ

アンマルコフ確率場 (GMRF)<sup>2)</sup>、Gabor 特徴<sup>8)</sup>、Local Binary Pattern (LBP) 特徴<sup>10)</sup>との性能比較を行う。

## 2. 高次局所自己相関特徴

### 2.1 従来手法

自己相関関数を高次に拡張した  $N$  次自己相関関数は、着目点  $r$  での対象画像の輝度値を  $f(r)$  とするとその周りの  $N$  個の変位  $a_1, a_2, \dots, a_N$  に対して、

$$x(a_1, a_2, \dots, a_N) = \int f(r)f(r+a_1)\dots f(r+a_N)dr \quad (1)$$

で定義される。高次局所自己相関 (higher order local autocorrelation: HLAC) 特徴はこの関数に基づいた基本的な画像特徴で、次数は2次までに(3点の相関)、変位方向は  $3 \times 3$  領域に限定されて利用された<sup>11)</sup>。このとき平行移動に関して等価なものを除くと特徴は  $3 \times 3$  サイズの25個のマスクパターンを用いて計算される(図1のパターンのうち最初の25個)。特徴量は画像の各位置においてパターンに対応する画素の輝度値の積を計算し、それらを画像全体で足し合わせることで求められる。ここで算出される特徴量は画像に含まれる各マスクパターンのパワースペクトルを表しており、これは周波数解析手法における変換基底をマスクパターンで表現したことに相当する。これらは周波数成分とマスクパターンのサイズ、方向成分とパターンの形状とがそれぞれ対応し、高次局所自己相関特徴では方向のみでなく2次元の分布も解析に利用するためより詳細に画像が特徴付けられる。

$3 \times 3$  サイズのマスクパターンから抽出される特徴は画像の高周波数成分を表している。ここでさらに低周波数成分からなる特徴も利用することで解析能力の向上が見込まれる。これは単純に変位領域を広げることによって実現されるが<sup>4)</sup>、その場合、領域サイズに応じて特徴次元数が指数関数的に増大するため実際に拡大できるサイズには限界がある。そこで画像ピラミッドを利用する手法<sup>6)</sup>や、マスクパターンのサイズを拡大する手法<sup>3)</sup>などが提案されている。これらの改良手法では自己相関の次数はすべて2次までに限定されていた。

自己相関の次数と変位領域に関する拡張としては、自己相関の内積だけを計算し、特徴量自体は明示的に算出しない手法が提案されている<sup>12)</sup>。この手法により変位領域を最大  $9 \times 9$  領域、次数を最高6次までとした特徴による識別が行われた。しかし文献<sup>12)</sup>の実験では変位領域を広くすると識別率は低下し、 $3 \times 3$  領域の特徴を利用したときが最高の識別率となっていた。これは拡大した領域内のすべての変位方向に関する特徴を識別に利用したため変位の組み合わせにより特徴次元数が膨大となり、サンプル数に対して過多となったことが影響している考




図 1 0 次から 8 次までの高次局所自己相関特徴を表現する 223 個のマスクパターン (3 × 3 領域)

Fig. 1 223 mask patterns of the 0th-order to 8th-order HLA features (3 × 3 pixels)




図 2 マスクパターンのサイズ拡大

Fig. 2 Larger mask patterns obtained through dilation

えられる．結果的に，特徴の信頼度が下がったり，冗長な特徴や互いに相関の高い特徴が多くなるなどして識別能力が低下したと考えられる．またこの手法ではサポート・ベクター・マシンを識別に用いるため同時に 2 クラスまでしか識別が行えない．

## 2.2 提案手法

従来から利用されている次数 2 次までの高次局所自己相関特徴は 25 個のマスクパターンを用いて計算される．ここで算出される各特徴量は対応するマスクパターンのパワースペクトルを表しており，多様なパターンを利用することでより詳細な画像の特徴付けが行えると考えられる．そこで本研究では自己相関の次数を最高 8 次まで拡張し，図 1 に示す 223 個のマスクパターンを用いて特徴抽出を行う．さらに図 2 に示すように 3 × 3 サイズのマスクパターンを拡大し，広い変位領域に関する特徴も抽出できるようにする．

拡大したマスクパターンでは着目点からの距離が 2, 3 画素に位置する点との相関を計算するため，3 × 3 サイ

ズのマスクパターンと比較して画像の低周波数成分を表す特徴が抽出される．これは画像から一定間隔でサブサンプリングして得られる低解像度の画像に対し，3 × 3 サイズのマスクパターンを適用していることに相当する．ただし画像ピラミッドを利用する手法のように実際に低解像度画像を作成する手法では画像サイズが小さくなり情報量が減少してしまう．また特徴抽出の行える領域も狭くなるため算出される特徴が不安定となることもある．一方，マスクパターンのサイズを拡大する本手法では元の画像から特徴を計算するため安定した特徴抽出が可能である．提案手法ではこれらの小さいマスクパターンから抽出される高周波数成分特徴と大きいマスクパターンから抽出される低周波数成分特徴を同時に利用する．これにより特徴は複数の異なる解像度の画像から抽出される特徴を表現する多重解像度化特徴となる．本稿の実験ではマスクパターンのサイズの小さい順に特徴を抽出し，それらを順に追加していくことで多重解像度化を行った．また自己相関の次数は併用するマスクサイズ間で一致させた．

高次自己相関関数は定義から式 (1) の変位  $a_1, a_2, \dots, a_N$  の中に同じものを含んでいても構わない (例えば  $a_1 = 0, a_1 = a_2$ )．この場合，図 3 に示すようにマスクパターンの同一画素を重複して参照することで特徴は計算される．本稿ではこれらの特徴を「重複参照特徴」と呼んで，標準の特徴とともに識別に利用す




図 3 標準の特徴 (standard) と「重複参照特徴」(repetition reference) の計算

Fig. 3 Standard feature and “repetition reference features” calculated using multiplication of the same pixels

る。ここで重複参照特徴を高次数まで利用しようとすると変位の組み合わせにより特徴数が膨大となってしまう。そこで従来は次数を 2 次までに限定した 10 個の重複参照特徴が利用されていた。これに対し、提案手法では次数を 3 次までに拡張し、図 3 に示すように 0 次のマスクパターンから 3 つ、1 次のマスクパターンから 5 つずつ (5 × 4 パターン = 20)、2 次のマスクパターンからは 3 つずつ (3 × 20 パターン = 60)、全体で 83 個の重複参照特徴を利用する。特徴の多重解像度化を行った場合は、用いるマスクパターンの各サイズで 83 個の重複参照特徴を計算する。

重複参照特徴は標準の特徴と同じマスクパターンによって算出されるものであるがふたつは異なる特徴を表し、これらを同時に用いることでより詳細な特徴付けが行える。例えば右方向の変位に重複を持つ重複参照特徴では、右上がりの輝度値の勾配を持つ画像に対して強く反応し、大きな特徴量を示すようになる。これにより標準の特徴のみを利用したときよりも容易に識別が行えるようになる。

### 3. テクスチャ識別実験

提案特徴の識別性能を評価するため種々のテクスチャ識別実験を行った。実験データにはテクスチャ解析手法を詳細に比較・評価する枠組みとして Web 上に様々なテクスチャ画像と識別課題セットを公開している “Outex” データベース<sup>9)</sup>を利用した。本実験に用いたデータの詳細は表 1 に示すとおりで、各 Test では学習サンプルとして使用していない画像を使って識別テストを行い、手法の性能を評価した。

提案特徴との比較には、テクスチャ解析において広く利用されているガウシアンマルコフ確率場 (GMRF)<sup>2)</sup>、Gabor 特徴<sup>8)</sup>、Local Binary Pattern(LBP) 特徴<sup>10)</sup>を用いた。これらの特徴計算の実装には一般に公開されてい

表 1 実験データ (Outex データベース)  
Table 1 Experimental data (Outex database)

Test	Outex ID	Classes	Image sizes	Training samples
00	Outex_TC_00000	24	128 × 128	10
01	Outex_TC_00001	24	64 × 64	44
02	Outex_TC_00002	24	32 × 32	184
03	Outex_TC_00016	319	128 × 128	10, 15, 19
04	Contrib_TC_00004	32	64 × 64	32 (8 × 4)

るソースコードを利用し<sup>8),15),16)</sup>、各パラメータについては課題ごとに最適になるように調整をした。

GMRF モデルは “MeasTex”<sup>15)</sup> から公開されているソースコードに基づいて実装したもので、特徴抽出にはシメトリックマスクを用い、近傍画素数は order = 1 の 2 点から order = 20 の 60 点までを計算した。このとき識別には各モデルから算出される特徴を単独で用いることも可能であるが、複数の特徴を組み合わせる方が高い識別精度が得られたので、本実験では order = 1 から順に特徴を追加していき識別率が最高となる組み合わせを用いた。Gabor 特徴の抽出には Manjunath 等の Gabor フィルタバンクを利用し<sup>8)</sup>、フィルタ出力の平均値と標準偏差を識別に用いた。フィルタバンクの中心周波数の上限と下限は文献<sup>8)</sup>と同様にそれぞれ 0.4, 0.05 とし、方向数を 3 ~ 15、スケール数を 3 ~ 9 と変化させて最適となるものを識別に利用した。LBP<sup>16)</sup>では “uniform” パターン<sup>10)</sup>を導入し、半径 1, 2, 3 の 3 つのオペレータからそれぞれサイズが 59, 243, 555 のヒストグラムを作成し識別を行った。これらのヒストグラムをそれぞれ単独に用いた場合のほか、連結し多重解像度化を行った LBP(半径の組み合わせが (1, 2), (1, 3), (2, 3), (1, 2, 3) の 4 通り) による識別も行った。この計 7 つの LBP 特徴のうち最適となるものを選択した。

本実験では単純でありながら高い識別性能が期待できる線形判別分析により識別を行った。線形判別分析は変換行列と各クラス平均のみを用いて高速に識別ができ、記憶容量も多く必要としないため従来から広く利用されている。また各特徴については学習サンプルから計算される特徴の標準偏差で正規化し、その後に線形判別分析を適用した。

#### 3.1 Test 00, 01, 02: Outex テクスチャ (24 クラス)

表 1 の Test00 ~ 02 では 24 種類のモノクロテクスチャ画像を使用した。各画像は予め平均輝度値 128、標準偏差 20 に正規化されているもので画像全体の輝度値の大小のみからでは識別できないようになっている。各 Test ではその 24 枚の画像をそれぞれ重なりなく分割し、異

表 2 Test 00, 01, 02 (24 クラス Outex テクスチャ識別)

Table 2 Test 00, 01 and 02 (24 Outex texture classification)

	Test 00	Test 01	Test 02
<b>Extended HLAC (Resolutions, Orders)</b>	<b>99.8%</b> (3, 5)	<b>99.3%</b> (3, 3)	<b>97.5%</b> (4, 6)
2nd-order HLAC (Resolutions, Orders)	99.6% (3, 2)	97.6% (3, 2)	91.9% (4, 2)
GMRF (Orders)	99.7% (1-7)	98.6% (1-14)	89.8% (1-18)
Gabor (Scales, Orientations)	99.6% (3, 7)	98.0% (3, 10)	93.4% (7, 12)
LBP (Radii)	<b>99.8%</b> (1, 2, 3)	<b>98.4%</b> (1)	<b>93.1%</b> (1, 2)




図 4 テクスチャ画像の例 (Test 00)

Fig. 4 Examples of texture images (Test 00)

なるサイズ・枚数のサンプル画像を作成して識別に利用する．画像サイズと学習サンプル数は表 1 に示すとおりで，テストでは学習に用いていないサンプル画像を学習サンプルと同数だけ識別する．識別性能を正確に評価するため各 Test では学習サンプル・テストサンプルの組み合わせを変えて 100 回ずつ識別課題を繰り返し，その平均識別率で評価を行った．図 4 に Test00 で用いたサンプル画像の例を示す．

図 5 は高次局所自己相関特徴の次数の上限を 2~8 次，多重解像度 (異なるマスクサイズの数) を 1~4 と変化させたときの Test02 の識別結果である．次数を高くするにつれて識別精度が向上し，多重解像度化によってさらに識別率が上昇しているのが確認される．ここで図 5 の左端に示される次数 2 次における 4 つの結果は従来の高次局所自己相関特徴によるもので，2 次までの 10 個の「重複参照特徴」を含み，多重解像度化したものである．この従来手法では多重度を 4 としたとき識別率が 91.9% となった．一方，提案手法により次数を高くし，さらに 3 次までの 83 個の重複参照特徴を利用することで次数 6 次において最高 97.5% の識別率を得た．

表 2 に示すように他手法による最高識別率は Gabor 特徴の 93.4% で，これは 12 方向・7 スケールのフィルタバンクを利用したときである．この Test02 ではサンプル画像のサイズが  $32 \times 32$  画素と小さいため局所領域に関する詳細な特徴付けが必要となる．Gabor 特徴では用いるフィルタバンクの方向数とスケール数を多くすることで識別精度が上がったが，2 次元の多様な分布の特徴付けが行えるマスクパターンを利用した高次局所自己相関特徴の方が優れた識別性能を示した．LBP ではサン

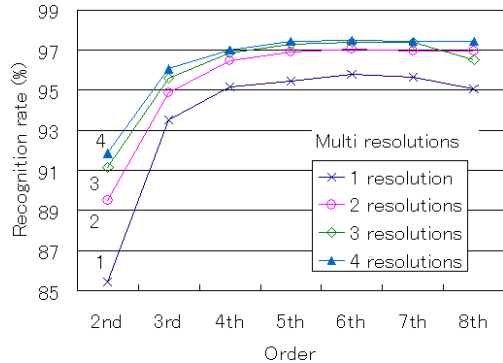


図 5 2 次から 8 次までの高次局所自己相関特徴による識別 (Test 02)

Fig. 5 Recognition rates using the 2nd-order to 8th-order HLAC features (Test 02)

プル画像のサイズが小さかったため作成されるヒストグラムが 0 値を多く含む不安定で信頼性の低いものとなった．結果的に最も良かった LBP の識別率は半径 1, 2 のオペレータを用いたときの 93.1% であった．

提案手法は表 2 に示す 3 つの Test すべてにおいて最高の識別率を得た．サイズの大きい画像の識別では GMRF や LBP も良好な識別結果を示したが，画像サイズが小さく難易度の高い識別課題では局所領域の詳細な解析が行える提案手法が優れた性能を発揮した．

### 3.2 Test 03: Outex テクスチャ (319 クラス)

表 1 の Test03 は 319 種類の多様なテクスチャ画像を利用した多クラスの識別課題である．用いたテクスチャ画像は図 6 に示すように植物の種や石の表面など多岐に渡っている．データベースには平均輝度値 128，標準偏差 20 に正規化されたモノクロのサンプル画像が各種類 20 枚ずつ含まれている．Test03 ではこれらのサンプル画像を学習用・テスト用とに分けて 319 クラスの識別課題を構成した．課題は各クラスの学習サンプル数を 10, 15, 19 と設定した 3 通りを行い，テストには残りのサンプルを使用した．用いるサンプルの組はランダムで決定

表 3 Test 03 (319 クラス Outex テクスチャ識別) Test 04 (32 クラス Brodatz テクスチャ識別)

Table 3 Test 03 (319 Outex texture classification) and Test 04 (32 Brodatz texture classification)

	Test 03			Test 04
	10 samples	15 samples	19 samples	
Extended HLAC (Resolutions, Orders)	79.1% (3, 2)	82.0% (3, 2)	83.0% (3, 2)	95.7% (2, 3)
2nd-order HLAC (Resolutions, Orders)	75.0% (3, 2)	76.6% (3, 2)	76.8% (3, 2)	89.7% (3, 2)
GMRF (Orders)	77.4% (1-11)	77.0% (1-11)	77.1% (1-14)	85.3% (1-11)
Gabor (Scales, Orientations)	73.9% (6, 3)	75.9% (6, 4)	76.4% (6, 6)	87.9% (5, 8)
LBP (Radii)	77.9% (1, 2)	80.8% (1, 2)	82.2% (1, 2)	91.1% (1, 2)




図 6 テクスチャ画像の例 (Test 03)  
Fig. 6 Examples of texture images (Test 03)

し、3 つの課題をそれぞれ 100 回ずつ行って平均識別率を求めた。

Test03 の結果は表 3 のようになり、多クラスの識別課題においても提案手法は他手法よりも良好な結果が得られた。この課題では次数 2 次までの自己相関特徴で十分な識別性能が得られている。これは Test03 では学習サンプル数が少なかったため多くの特徴を必要としなかったことによると考えられる。提案手法と従来手法との違いは利用した「重複参照特徴」にある。従来手法では次数 2 次までに限定しているため利用した重複参照特徴は 10 個となっている。一方、提案手法では 3 次まで拡張することで 83 個の重複参照特徴を利用している。これにより識別率を 5% 以上も上昇させることができた。重複参照特徴は元来、低次数の比較的単純なマスクパターンから算出されるものであるが、同一画素を重複して参照することで小さな差を強調させることができる。その結果、詳細な特徴付けを要するテクスチャ識別では標準の特徴とともに利用することで識別精度を上げることができた。

### 3.3 Test 04: Brodatz テクスチャ (32 クラス)

表 1 の Test04 は画像のスケール変化と回転を含む難易度の高い識別課題である。用いた 32 種類のモノクロテクスチャ画像は Brodatz アルバム<sup>1)</sup>に収められている(図 7)。これらの画像をヒストグラム平坦化した後、64




図 7 32 クラス Brodatz テクスチャ (Test 04)  
Fig. 7 32 Brodatz textures (Test 04)



図 8 拡大, 90 度回転, 拡大と回転 (Test 04)  
Fig. 8 Scaling, 90-degree rotation, and both scaling and rotation (Test 04)

× 64 サイズに重なりなく分割し、得られた 16 枚ずつのサンプル画像をランダムで等分して学習用・テスト用のサンプルとする。さらに図 8 に示すように各サンプル画像から、中央 45 × 45 領域を 64 × 64 サイズに拡大した画像、90 度回転した画像、拡大と回転の両方を行った画像の 3 つを新たに作成し、学習サンプル・テストサンプルに含めて使用する。

10 回繰り返した平均識別率は表 3 のようになった。提案手法の 95.7% は次に良かった LBP の 91.1% などと比較して良好で、提案手法は画像の変形に対しても頑健であることが示される。

## 4. 顔識別実験: AT&T データベース

前節の実験では領域の一樣性に基づいて解析を行うテクスチャ識別により提案手法の性能を評価した。一方、本節では対象の持つ画像構造が特徴付けに重要な役割を果

表 4 40 人顔識別 (AT&amp;T データベース)

Table 4 40 Face recognition rates (AT&amp;T database)

Extended HLAC (Resolutions, Orders)	98.4% (7, 7)
2nd-order HLAC (Resolutions, Orders)	96.7% (4, 2)
GMRF (Orders)	76.6% (1-7)
Gabor (Scales, Orientations)	96.0% (3, 9)
LBP (Radii)	90.3% (1, 2, 3)

たす例として顔識別を行う．平行移動に対して不変な高次局所自己相関特徴は顔の向きや位置の変動に対して頑健性があり，また特徴計算や識別が高速で行えることから従来より顔識別に利用されている．

本実験では AT&T データベース<sup>17)</sup>に含まれる 40 人のモノクロ画像 (92 × 112 サイズ) を 10 枚ずつ計 400 枚を使用した (図 9 (a))．各人の 10 枚の画像には眼の開いているもの，閉じているもの，笑っているもの，笑っていないもの，眼鏡をかけているもの，かけていないもの，異なるスケール，異なる顔の向きの画像などが含まれている (図 9 (b))．実験では各クラスにつきランダムで選択した 5 枚を学習サンプル，残り 5 枚をテストサンプルとして用い，識別課題を 100 回繰り返して平均識別率を求めた．

表 4 に示すように従来から顔識別への適用が行われている高次局所自己相関特徴は本実験においても良好な識別が行え，従来の次数 2 次までの手法で 96.7%，提案手法では 98.4% の識別率が得られた．これは顔認識に広く利用されている Gabor 特徴の 96.0% よりも高い識別率となっている．この顔識別実験の結果から提案手法はテクスチャのように一様な画像構造を持つもののみでなく，特定の構造を持った対象に対しても有効であると考えられる．

顔識別に広く利用されている手法には画像から特徴を抽出する手法のほか，各画素の輝度値を直接使い，部分空間を構成して識別を行う手法もある．その代表的なものは主成分分析を利用した固有顔 (Eigenface) 法である．文献<sup>7)</sup>ではこのような部分空間を利用した手法の識別性能を比較した実験結果を報告している．実験データには AT&T データベースを利用しており，本実験と同じ課題設定で顔識別を行っている．参考のためその報告結果を表 5 にまとめた．表に示した手法は，主成分分析 (PCA)，独立成分分析 (ICA)，フィッシャー判別分析 (FDA)，そしてこれらをガウシアンカーネルにより非線形に拡張した KPCA, KICA, KFDA である．ここで示した識別率は課題を 5 回繰り返したときの平均値である．このときの最高は KFDA の 95.3% で，表 5 においても提案手法の 98.4% が良好な結果であることが確認される．



(a) Examples of 10 persons



(b) 10 images of one person

図 9 顔画像の例 (AT&amp;T データベース)

Fig. 9 Face image examples of AT&amp;T database

表 5 提案手法と文献<sup>7)</sup>で報告されている他手法による顔識別Table 5 40 Face recognition rates by the proposed method and other reported methods<sup>7)</sup>

Extended HLAC	Reported results <sup>7)</sup> (%)					
	PCA	KPCA	ICA	KICA	FDA	KFDA
98.4	92.2	90.1	88.2	89.0	89.1	95.3

## 5. む す び

本研究では画像解析において広く利用されている高次局所自己相関特徴の次数を従来の 2 次までから最高 8 次までに拡張し，より詳細な画像の特徴付けを行えるようにした．さらに高次数に拡張した特徴を用いて多重解像度化特徴を構成し，広い変位領域に関する特徴も抽出できるようにした．提案手法は種々のテクスチャ識別実験を通して局所領域における優れた解析性能を有することを示した．また顔識別において特定の画像構造を持つ対象に対する有効性も確認されたことから，提案手法は適用範囲が広いと考えられる．高次局所自己相関特徴は計算が容易でハードウェア化による高速な演算が可能である．このことから提案手法は実用可能性の高い有用な手法であると考えられる．

## 参考文献

- 1) P. Brodatz, "Textures: A photographic album for artists and designers," New York, Dover, 1966.
- 2) R. Chellappa and S. Chatterjee, "Classification of textures using Gaussian Markov random fields," IEEE Trans. Acoustics Speech and Signal Processing, Vol.33, pp.959-963, 1985.

- 3) F. Goudail, E. Lange, T. Iwamoto, K. Kyuma, and N. Otsu, "Face recognition system using local autocorrelations and multiscale integration," *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol.18, No.10, pp.1024-1028, 1996.
- 4) M. Kreutz, B. Völpel, and H. Janssen, "Scale-invariant image recognition based on higher order autocorrelation features," *Pattern Recognition*, Vol.29, No.1, pp.19-26, 1996.
- 5) T. Kurita and S. Hayamizu, "Gesture recognition using HLAC features of PARCOR images and HMM based Recognizer," *Proc. International Conference on Automatic Face and Gesture Recognition*, pp.422-427, 1998.
- 6) T. Kurita, N. Otsu, and T. Sato, "A face recognition method using higher order local autocorrelation and multivariate analysis," *Proc. International Conference on Pattern Recognition*, Vol.2, pp.213-216, 1992.
- 7) J. Li, S. Zhou, and C. Shekhar, "A comparison of subspace analysis for face recognition," *Proc. IEEE International Conference on Acoustics, Speech, and Signal Processing*, pp.121-124, 2003.
- 8) B. S. Manjunath and W. Y. Ma, "Texture features for browsing and retrieval of image data," *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol.18, No.8, pp.837-842, 1996, <http://vision.ece.ucsb.edu/texture/software/>.
- 9) T. Ojala, T. Mänpää, M. Pietikäinen, J. Viertola, J. Kyllönen, and S. Huovinen, "Outex - New framework for empirical evaluation of texture analysis algorithms," *Proc. International Conference on Pattern Recognition*, Vol.1, pp.701-706, 2002, <http://www.outex oulu.fi/outex.php>.
- 10) T. Ojala, M. Pietikäinen, and T. Mänpää, "Multiresolution gray-scale and rotation-invariant texture classification with Local Binary Patterns," *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol.24, No.7, pp.971-987, 2002.
- 11) 大津展之, "パターン認識における特徴抽出に関する数理的研究," *電子技術総合研究所研究報告*, Vol.818, 1981.
- 12) V. Popovici and J. P. Thiran, "Higher order autocorrelations for pattern classification," *Proc. International Conference on Image Processing*, pp.724-727, 2001.
- 13) M. Suzuki, Y. Yaginuma, N. Osawa, and Y. Sugimoto, "Classification of 3D solid textures using 3D mask patterns," *Proc. International Conference on Systems, Man & Cybernetics*, pp.6342-6347, 2004.
- 14) 山本健吉, 石井抱, "高次自己相関ビジョンチップの設計," *信学論 (D-II)*, Vol.J86-D-II, No.8, pp.1205-1211, 2003.
- 15) Meastex image texture database and test suite, <http://www.cssip.uq.edu.au/meastex/meastex.html>.
- 16) University of Oulu, Department of Electrical and Information Engineering, Machine Vision Group, <http://www.ee.oulu.fi/mvg/mvg.php>.
- 17) AT & T database of faces, <http://www.uk.research.att.com/facedatabase.html>.

(2005年5月25日受付)

豊田 崇 弘



2004 東京工業大学工学部情報工学科卒。現在、同大学院総合理工学研究科知能システム科学専攻修士課程に在学中。画像処理、パターン認識に関する研究に従事。

長谷川 修 (正会員)



1993 東京大学大学院電子工学専攻博士課程修了, 博士(工学), 同年電子技術総合研究所, 1999 から1年間米国カーネギーメロン大学客員研究員, 2001 産業技術総合研究所主任研究員, 2002 東京工業大学像情報工学研究施設助教授, JST さきがけ研究 21 研究者(兼任), 情報処理学会, 電子情報通信学会, 日本認知科学会, 人工知能学会, 日本顔学会, IEEE-CS 等会員。