

テクスチャ識別のためのマスクパターンによる特徴抽出法

豊田 崇弘[†], 長谷川 修^{††,†††}

マスクパターンによるテクスチャ識別のための特徴抽出法を提案する。提案手法では 3×3 サイズの 223 個のマスクパターンを基本として複数のサイズのパターンを作成し、各サイズのマスクから 10 個の付加特徴を含め最高 233 個の特徴を抽出する。これらの異なるサイズのマスクから抽出される特徴を複合的に利用して多重解像度化特徴を構成する。提案手法は画像の周波数解析手法における変換基底をマスクパターンによって表現したことに相当し、算出される特徴量は画像に含まれる各パターンのパワースペクトルに対応している。テクスチャ識別実験では Gabor などの他特徴よりも高い識別率を得た。さらに提案特徴に対して特徴選択を適用することで、少ない特徴数で高精度の識別が行えることを確認した。また異なる光源下で撮影された画像の識別実験においても良好な結果が得られ、提案手法は高い識別能力を持つとともに実環境における利用可能性の点においても優れていることが示された。

Feature Extraction for Texture Classification Using Mask Patterns

Takahiro TOYODA[†], Osamu HASEGAWA^{††,†††}

We propose a texture feature extraction method using mask patterns of several sizes. A mask of each size has 223 patterns. A maximum of 233 features, including the 10 additional features, are extracted from each mask. We construct multi-resolution features by combining the features extracted from masks of different sizes. The calculated feature value corresponds to the power spectrum of a mask pattern within the image. This method is equivalent to expressing the basis functions in frequency analysis by the mask patterns. Texture classification experiments demonstrate that our proposed features outperformed other features such as Gabor. They also worked well in a test where the images to be classified were captured under different illuminants from training images. These results indicate a high practicality of the proposed method. This paper also shows that applying a feature selection method to the proposed features provides high recognition rates with a small number of features.

[†] 東京工業大学大学院総合理工学研究科
Interdisciplinary Graduate School of Science
and Engineering, Tokyo Institute of Technology
^{††} 東京工業大学像情報工学研究施設
Imaging Science and Engineering Laboratory,

Tokyo Institute of Technology
^{†††} 科学技術振興機構, さきがけ 21,
PRESTO, JST

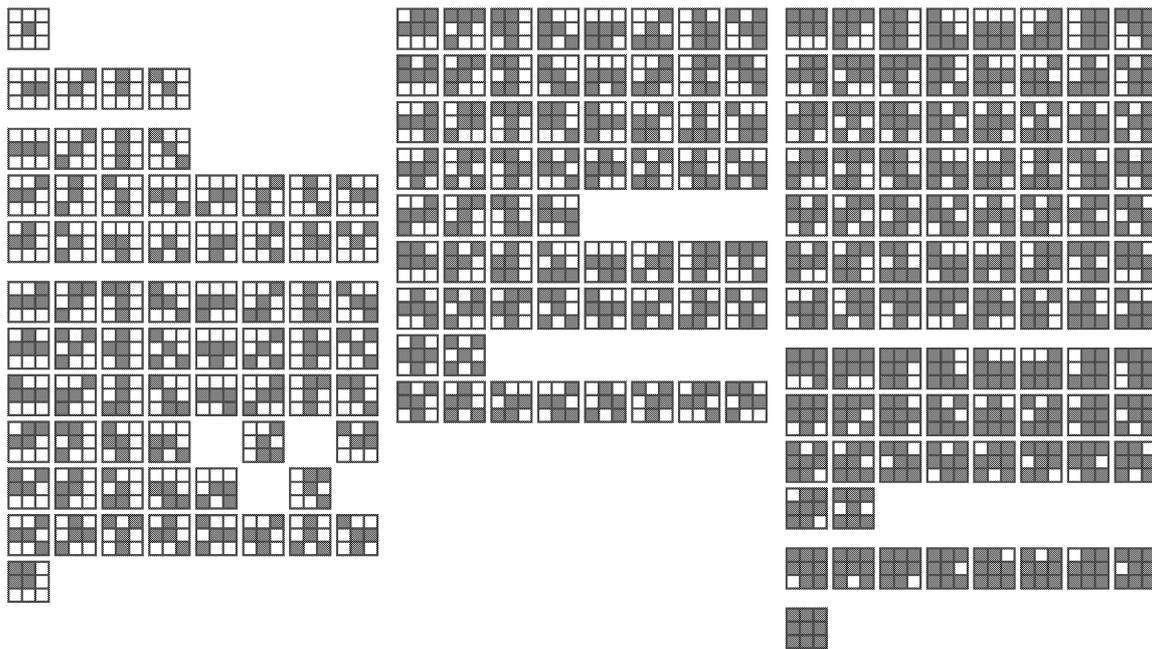


図 1: 3 × 3 サイズにおける 223 個のマスクパターン

1 まえがき

画像の基本的な構成要素であるテクスチャの解析は医用画像処理やリモートセンシング画像解析をはじめ様々な画像処理に応用されている。また対象物体を画像から抽出する際に行われる領域分割処理においてもテクスチャ情報は重要な役割を果たしている。

領域分割処理には微分操作によるエッジ検出手法も利用されているが、この場合、複雑な画像に対しては対象領域の境界が閉じた線として得られなかったり、領域内のエッジと境界上のエッジとの区別が困難であったりなどの問題がある。一方、テクスチャ情報を利用した領域分割では必ず閉じた境界線が得られ、分割された各領域については数量的な特徴付けが行える。

近年盛んに研究が行われている自律型ロボットの視覚システムや車載型画像認識装置など多くの画像解析では、第 1 段階の画像処理として画像中の対象物の抽出が行われる。この領域分割処理の結果はその後の解析に大きな影響を与えるため精度良く行われる必要がある。このような観点からもテクスチャ解析の重要性は今後も高いと考えられる。

テクスチャ解析では特徴の表現方法によって性能が大きく変わる。解析手法としては統計的手法と構造的な手法とに大別されることが多く、構造的な手法は規則的なテクスチャ画像に対して適用され、テク

スチャを構成する要素とその配列規則によって特徴を表現する。一方、統計的手法はきめが細かく不規則な構造をもつ画像の解析に対して用いられ、画像の濃度分布に関する統計的性質によって特徴付けを行う。統計的手法には、高次局所自己相関特徴 (HLAC)、ガウシアンマルコフ確率場 (GMRF)、Local Binary Pattern (LBP) 特徴のような局所領域に着目した手法や、フーリエ特徴、Gabor 特徴のように周波数の概念を用いた手法などがある。

本論文では多様な形状・サイズのマスクパターンを作成し、それらを用いて各局所領域における輝度値の分布に着目した統計的画像特徴の抽出を行う。提案手法は画像の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し、画像の平行移動に対しては不変性を有している。

本研究では提案特徴に対して従来から利用されている基本的な特徴選択手法の適用も行う。識別実験の結果、識別率を上昇させつつ、同時に特徴数の大幅な削減が可能なが示される。

マスクパターンを用いた提案手法は特徴の算出アルゴリズムが簡素でハードウェア化も容易である。また実環境中での利用を想定した識別課題においても良好な結果が得られ、提案手法は実応用化に適した有用な手法であると考えられる。

2 マスクパターンによる画像特徴の抽出

2.1 提案特徴の構成

マスクパターンによる特徴表現において抽出特徴の表現力・識別能力が高めるには多様なパターンを用いる方向性が考えられる。しかしこのとき適切な指針の下でマスクサイズを決定し、パターンの作成を行わないと得られるパターン数が膨大となってしまう。そこで本研究ではまずマスクサイズを 3×3 画素領域とし、参照点を着目点の周囲近傍 8 点に限定してパターンの作成を行う。このとき 2^8 通りの異なるパターンが考えられ、このうち平行移動に対して等価なものを削除すると図 1 に示す 223 個のパターンが得られる。

これらのパターンから計算される特徴量のうち、算出アルゴリズムが容易かつ識別性能の見込める特徴量として、各マスクパターンに対応する画素の輝度値の「積」を計算する。これにより 3×3 領域から 223 個の特徴量 (223 次元特徴ベクトル) が得られる。この演算を画像の各位置に対して行い、各位置で得られる特徴ベクトルをすべて足し合わせて 1 枚の画像から 1 つの 223 次元特徴ベクトルを抽出する。このようにして得られる特徴は画像の平行移動に対して不変性を有している。このとき特徴量の演算方法として、輝度値の積以外に和や差なども考えられるが、予備実験において積が最も良好な結果を示したので積を用いることとした。

3×3 サイズのマスクによって抽出される特徴は画像中の高周波数成分からなっている。用いるマスクのサイズを大きくすることで低周波数成分からなる特徴の抽出も可能となるが、単純に大きな領域において参照点の組み合わせを考えると作成されるマスクパターンの数は膨大となってしまう。例えば 5×5 領域では取り得る参照点の組み合わせ (マスクパターン) は 2^{24} 通りとなる。そこで図 2 に示すように、参照点の位置をマスクの外枠上に等間隔で並んだ 8 点に制限し、各マスクではこの 8 点の組み合わせによってパターンを作成する。これによりパターン数の爆発を抑えつつ、様々なサイズのマスクから方向性に偏りのない低周波数成分の特徴が抽出可能となる。

本研究では 3×3 および図 2 に示す 5×5 ①、 7×7 ①の 3 つのマスクを小さい順に作成し、各サイズのマスクから抽出される特徴ベクトルを連結して抽出特徴の多重解像度化を行う。このとき併用するマスクの数やその組み合わせ方は任意で、例えば同

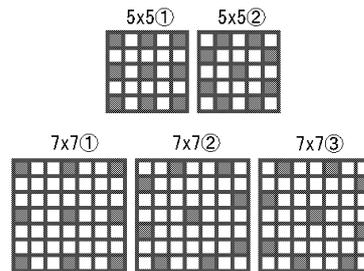


図 2: 様々なサイズのマスクにおける参照点の位置

じサイズのマスク 5×5 ①と 5×5 ②を組み合わせることも可能である。しかし併用するマスク間のサイズを変えた方が、異なる周波数成分からなる特徴が抽出されるため互いに相関が低く、識別にはより有効と考えられる。そこでここでは異なるサイズのマスクを用いて特徴抽出を行う。

同サイズのマスク①, ②, …については、予備実験においてこれらのマスクの識別力に有意な差は確認されなかったが、本研究では特徴抽出にマスク①を利用した。これはマスクの中心着目点から周囲参照点までの距離を 2 倍, 3 倍とするだけで 3×3 サイズの参照点との対応付けが可能で、図 1 を基に容易にパターンの作成ができるからである。

提案手法で算出される特徴量は画像に含まれる各パターンのパワースペクトルを表しており、これは画像の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ていることに相当する。提案手法をフーリエ変換基底と比較すると、周波数成分がマスクサイズに、方向成分がパターンの形状に対応する。提案手法では方向のみでなく様々な 2 次元分布を持ったパターンを用いるため、局所領域の詳細な解析が行える。本論文ではこれらの特徴と、2.3 で述べる「付加特徴」も利用して識別を行う。

2.2 高次局所自己相関特徴

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 $f(r)$ とすると着目点の周り N 個の変位 (a_1, a_2, \dots, a_N) に対して、

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

で定義される。この関数に基づいた画像特徴として高次局所自己相関特徴 (higher order local autocorrelation features) が提案されている。文献 [8]

では自己相関の次数は2次までに、変位方向は 3×3 領域に限定されている。この2次までの自己相関特徴は、本論文で提案する図1の223個のマスクパターンのうち参照点数が0~2である最初の25個のマスクパターンで表現されるものである。自己相関特徴の観点からは、図1のマスクパターンは参照点の位置が変位に、参照点数が次数に対応し、全体で8次までの自己相関特徴を表している。

この自己相関特徴の改良としてこれまでに、ピラミッド画像の利用[4]や、図2の異なるサイズのマスク①を利用した抽出特徴の多重解像度化[2]が行われている。また式(1)の変位 (a_1, a_2, \dots, a_N) の中に重複を許し、マスクパターンの同一箇所からデータを採取する手法も提案されている。なお以上の自己相関特徴では主に計算量が増大するのを避けるため、次数はすべて2次までに制限されている。

他にも自己相関特徴の内積演算の工夫により、煩雑な特徴量の計算を明示的には行わない手法も提案されている[9]。この手法では局所領域を最大 9×9 領域、次数を最高6次までとした特徴による識別と実質的に等価となっている。しかし識別にはサポート・ベクター・マシンが用いられており、この手法で同時に識別できるのは2クラスまでとなっている。また文献[9]の識別実験では、マスクパターンを構成する領域を広げると識別率が低下している。これは[9]の手法では、実質的に拡大した領域内のすべての参照点の位置の組み合わせを考慮して特徴を構成しているため特徴次元数がサンプル数に対して膨大となり、特徴の中に冗長なものが多くなったことが原因と考えられる。

一方、本論文で提案する手法ではマスクサイズを大きくする際、パターンを構成する参照点の数と位置に制約を設けている。これにより特徴数が膨大となるのを防いでいる。

2.3 「付加特徴」の導入

文献[2]では式(1)の変位 (a_1, a_2, \dots, a_N) の中に重複を許して特徴を構成している(例えば $a_1 = a_2$)。すなわち表1の特徴算出式に示すように、参照演算(輝度値の積演算)を、中心着目点も含めマスクパターンの同一箇所に対して行っている。ここで表1の $f(r)$ は中心着目点の輝度値、 $f(r+a_1)$ は周囲参照点の輝度値を表している。

これらの重複して参照を行う特徴の有用性が本研究においても示されたので、以下では「付加特徴」として2.1の提案特徴とともに識別に利用する。た

表 1: 周囲参照点数 0, 1 個のマスクパターンの特徴算出式

	マスクパターンの周囲参照点数	
	0 個	1 個
	$f(r)$	$f(r) \times f(r+a_1)$
付加特徴 (変位)	$f(r) \times f(r)$ ($a_1=0$)	$f(r) \times f(r+a_1) \times f(r)$ ($a_2=0$)
付加特徴 (変位)	$f(r) \times f(r) \times f(r)$ ($a_1=a_2=0$)	$f(r) \times f(r+a_1) \times f(r+a_1)$ ($a_1=a_2$)

$f(r)$: 中心着目点の輝度値, $f(r+a_1)$: 周囲参照点の輝度値

だし参照演算回数が増えると算出される付加特徴の数も指数関数的に増大するため、ここでは演算回数を2回までとする。これにより図1のマスクパターンのうち周囲参照点数が0, 1個である5つのマスクパターンからそれぞれ2つずつ、計10個の付加特徴が得られる。この付加特徴と先の223個の特徴をあわせて各マスクから最大233個の特徴が抽出される。

2.4 特徴選択手法

特徴抽出に用いるマスクパターンのサイズや形状の組み合わせ方を変えることで様々な特徴が構成可能である。しかし適当な特徴構成法は課題ごとに異なるため最適なものを事前に推定するのは困難である。また手動での探索は煩雑であり効率的でない。そこで提案特徴に対して従来から利用されている基本的な特徴選択手法を適用し、有効な特徴集合の推定を行う。

本論文では 3×3 , 5×5 ①, 7×7 ①の3つのマスクから、2.3の「付加特徴」も含めて233個ずつ特徴を抽出し、全体で699個の特徴を選択候補(「原特徴集合」とする。学習サンプルのみを用いて、この「原特徴集合」から特徴を選択する具体的なアルゴリズムを以下に示す。

Step 1). 各学習サンプル画像から上で述べた「原特徴集合」を抽出し、「選択済み特徴集合」の要素数を0に初期化する

Step 2). 「原特徴集合」のうち未選択の特徴のすべてについて、各未選択特徴を既存の「選択済み特徴集合」に加えて特徴を構成したときの、学習サンプルに対するクラス間分離度 J を計

算する

$$J = \text{tr}(\Sigma_W^{-1} \Sigma_B) \quad (2)$$

Σ_W : クラス内共分散行列

Σ_B : クラス間共分散行列

Step 3). Step 2 で算出されるクラス間分離度を最大とする未選択特徴を新たに「選択済み特徴集合」に追加する

Step 4). 下記の [停止時点] まで Step 2, 3 を繰り返し、停止したら「選択済み特徴集合」を出力しアルゴリズムを終了する

[停止時点] 要素数が $i \sim i+M-1$ ($i = 1, 2, \dots$) である M 個の「選択済み特徴集合」のそれぞれについて学習サンプルに対する識別率を求める。算出された識別率 M 点からなる系列を直線で最小二乗誤差近似し、この近似直線の傾きが 0 以下となる直前を停止時点とする。本研究では予備実験に基づき、 $M=40$ とした。

3 テクスチャ識別実験

提案特徴の識別性能と、提案特徴に対し特徴選択を適用することの有効性をテクスチャ識別実験により検証した。また提案手法の実環境中における利用可能性を評価するため、学習サンプルとテストサンプルとで異なる光源を使用した画像の識別も行った。本実験では線形判別分析により識別を行った。このとき学習サンプルの平均特徴量が各次元で 1 となるように正規化した。

3.1 実験データ

画像解析手法を詳細に比較・評価する目的で構成され、Web 上で公開されているテクスチャ識別課題のセット“Outex” [6] から、Test suite ID : Outex_TC_00000, 00001, 00014 (以下 Test00, 01, 14) を実験データとして利用した (<http://www.outex.oulu.fi/outex.php>)。これらの課題セットの詳細は表 2 に示す通りで、各課題のテストでは学習サンプルでは用いていない画像の識別を行う。図 3 に実際に用いたテクスチャ画像の例を示す。

Test00, 01 では学習サンプルとテストサンプルに用いられる画像の組み合わせを変えてそれぞれ 100 回ずつ識別を行い、その平均識別率で評価を行う。また Test14 では実環境中における照明条件の

表 2: 実験データの詳細

Test	クラス数	画像 サイズ	サンプル数	
			学習	テスト
00	24	128×128	240(24×10)	240(24×10)
01	24	64×64	1056(24×44)	1056(24×44)
14	68	128×128	680(68×10)	1360(68×10×2)

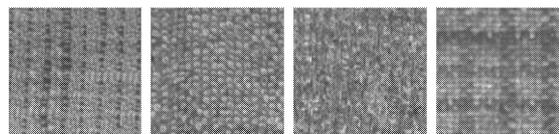


図 3: 実験に用いたテクスチャ画像の例

変化に対する頑健性を評価するため、学習サンプル (2856K の白熱灯) とは異なる 2 種類の光源下 (2856K の日没光, 4000K の蛍光灯) で撮影された画像の識別を行う。

Test00, 01 で用いたテクスチャ画像はいずれも平均輝度値 128, 標準偏差 20 に正規化されたモノクロ画像である。Test14 では元のカラー画像をモノクロ変換し、平均輝度値 128, 標準偏差 20 に正規化して利用した。

3.2 提案特徴による識別結果

特徴抽出に用いるマスクパターンの参照点数の上限を 2 ~ 8, 多重解像度を 1 ~ 3 と変化させて構成した特徴による Test01 の識別結果を図 4 と表 3 に示す。このとき各マスクから 10 個ずつ抽出される「付加特徴」も利用した。また本実験では多重化のために併用する各マスクの参照点数の上限を一致させた。

図 4 に示すようにマスクパターンの参照点数を増加し、特徴の多重度を高くすると識別精度が向上する傾向が得られた。ここで参照点数 2 個までの特徴はこれまでに報告された次数 2 次までの自己相関特徴に相当する。付加特徴を含めずに多重度 1 で参照点数を 2 個までとした特徴は [8] の 25 次元の自己相関特徴 (“Original-HLAC”) に相当し、識別率は 93.4%であった。[8] の特徴に付加特徴を加え多重解像度化した改良法 (“Improved-HLAC”) [2, 4] では 97.5%となった。提案手法によりパターンの参照点数を増やすと識別率は上昇し、多重度 1 で参照点数 5 個までとしたときは 99.0%, 多重度 3

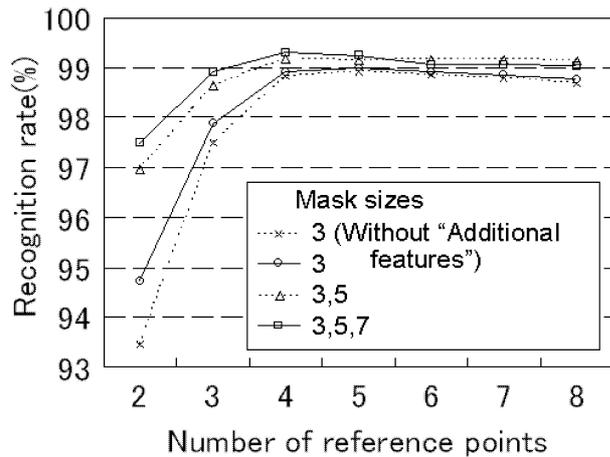


図 4: 参照点数・多重度を変化させた識別 (Test01)

で参照点数 4 個までとしたときは最高 99.3% が得られた。

表 4 と図 5 に、提案特徴 (Proposed)、自己相関特徴 (Original-HLAC, Improved-HLAC)、報告されている他特徴 (GMRF, LBP, Gabor) [5, 6, 7] を Test00, 01, 14 に適用した識別結果を示す。このとき提案特徴と自己相関特徴では線形判別分析により識別を行った。また LBP と Gabor については 3-NN 法による識別が行われており、それぞれの距離尺度には対数尤度とマハラノビス距離が用いられていた。

図 5 に示すように、提案手法は 3 つすべての課題においていずれの手法よりも良好な結果が得られ、識別能力が高いことが示される。また異なる光源を使用した Test14 でも提案手法の結果は良好で、実環境中での利用可能性も高いことが示される。

提案手法ではより詳細な解析を行うため、参照点数 2 個までのパターンで表現される従来の自己相関特徴よりも参照点数を増やし、多様なマスクパターンを作成した。また広い領域についての解析も行えるようサイズの大きいマスクを利用し、特徴の多重解像度化を行った。これにより識別能力が向上し、他特徴と比較しても精度の高い識別が可能となった。

3.3 特徴選択の適用結果

提案特徴に対して 2.4 で述べた特徴選択手法を適用し、得られた特徴集合を用いて 3.2 と同じ 3 つの識別課題を行った。このとき選択候補の特徴 (「原特徴集合」として、多重度 3、参照点数 8 個までの特徴に 2.3 で述べた「付加特徴」を加えた全部で

表 3: 参照点数・多重度を変化させた識別 (Test01)

マスク サイズ	参照点数 (%)						
	2	3	4	5	6	7	8
3 ⁽⁻⁾	93.4	97.5	98.8	98.9	98.9	98.8	98.7
3	94.7	97.9	98.9	99.0	98.9	98.8	98.8
3,5	97.0	98.6	99.2	99.1	99.2	99.2	99.1
3,5,7	97.5	98.9	99.3	99.2	99.0	99.1	99.0

3⁽⁻⁾: 「付加特徴」を含めずに特徴構成

表 4: 提案特徴と他特徴との比較

	Test00	Test01	Test14
Proposed (多重度, 参照点数)	99.7% (2, 3)	99.3% (3, 4)	74.8% (2, 8)
Original-HLAC	97.2%	93.4%	64.1%
Improved-HLAC	99.6%	97.5%	71.4%
GMRF	96.1%	95.1%	N/A
LBP	99.5%	95.5%	69.0%
Gabor	99.5%	98.6%	66.0%

HLAC: Higher order local autocorrelations

GMRF: Gaussian Markov Random Field

LBP: Local Binary Pattern

699 個の特徴を用いている。Test00, 01 についてはそれぞれ 100 回特徴選択と識別を行い、その平均識別率で評価をしている。

図 6 は Test01 の最初の 1 題の識別課題について、選択された特徴を 1 つずつ追加したときの学習サンプルとテストサンプルに対する識別率の変化を示している。2.4 のアルゴリズムでは□印で示される時点で特徴選択は停止するが、図 6 では参考のため 699 個すべての特徴を追加するまでの変化を示している。ここでグラフの横軸は識別に用いた特徴数、縦軸は識別率を表している。

特徴を追加していくと学習サンプルに対する識別率は上昇を続ける。一方、テストサンプルに対する識別率は特徴追加の初期では上昇するが、ある時点から低下傾向となる。このテストサンプルに対する識別率が低下する直前で特徴選択を停止するのが最適である。しかし適当な停止時点を学習サンプルのみから推定するのは困難であり、図 6 の例では□印の時点で特徴選択が停止となった。このとき特徴数は 699 個から 157 個に大幅に削減された一方、識

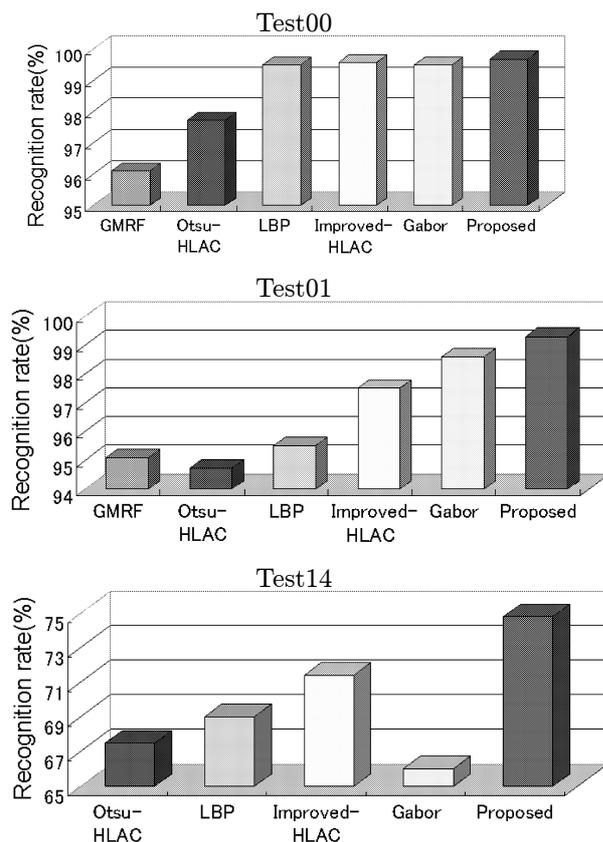


図 5: 提案特徴と他特徴との比較

表 5: 多重度 3 における参照点数と特徴数 (付加特徴含む) との対応

参照点数	2	3	4	5	6	7	8
特徴数	105	240	426	588	672	696	699

別率は 98.3% から 99.1% に上昇した。この識別率が上昇した要因として、「原特徴集合」に含まれていた冗長な特徴や、識別には有効でない特徴が削除されたことが考えられる。

図 6 で●印で表される系列は特徴選択をしなかった場合で、●印における識別率は多重度 3 において参照点数を 2 ~ 8 に設定したときの特徴による識別結果である。このときの参照点数と特徴数との対応は表 5 のようになっており、特徴数には「付加特徴」も含んでいる。この図 6 の例では特徴選択を適用したときの□印の識別率は、特徴選択をしなかったときの●印の識別率のいずれよりも高くなった。これにより特徴選択の有効性が確認される。

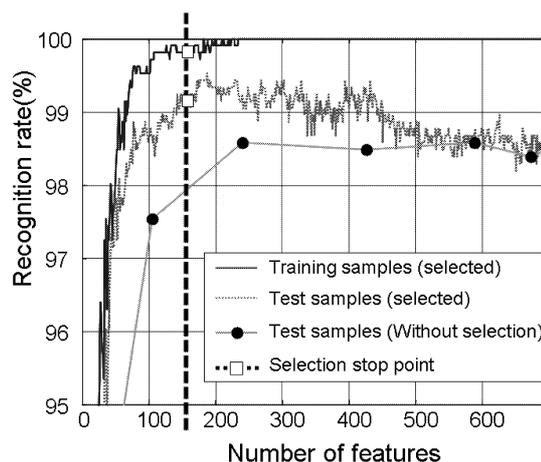


図 6: 選択された特徴を追加したときの識別率の変化 (Test01)

3.4 考察

一般には識別に用いる特徴数を多くすることで識別精度の向上が期待される。提案手法においてもマスクパターンの参照点数を増やし、多重解像度化を行って特徴数を多くすることで識別率が大きく上昇した。しかし一方で有限のサンプル数に対し特徴数が過多となると識別性能が低下することも知られている [3]。これは特徴数が多くなると冗長な特徴や相関の高い特徴の組が含まれやすくなることや、各特徴に対する統計的な信頼度が低下することが原因として考えられる。本論文で行った実験でも特徴を構成するパターン数がある程度以上になると識別率の改善は見られなくなった。

一方、サンプル数が十分ある課題に対しては、図 2 のマスク①を作成したと同様の方法で、参照点の間隔を 3 画素ずつに設定した 9×9 マスクの利用や、 5×5 ①と 5×5 ②、 7×7 ①と 7×7 ②のように同サイズのマスクを併用する手法の有効性も著者らの他の研究で得られている [10]。しかし現実の課題では多数のサンプルを用意するのは困難なことが多いため識別に用いる特徴数はなるべく抑えることが望ましい。そこで本研究では特徴数を削減するため、比較的簡単な特徴選択手法の適用を検討した。

表 6 と図 7 に示すように 3 つすべての課題において特徴選択の適用による識別率の上昇が確認された。このとき特徴数は特徴選択前の 699 個から大きく削減され、Test00 では 70、Test01 では 154、Test14 では 200 となった。特徴数を減らすことによって、特徴計算に要する演算量やメモリ量の削減も可能となっている。

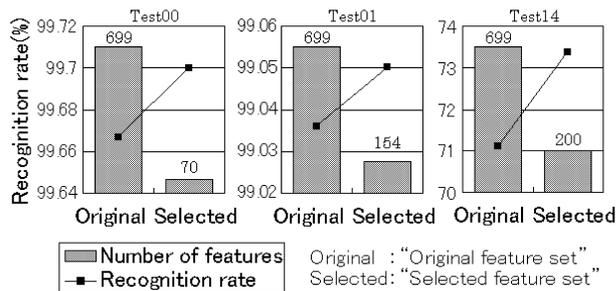


図 7: 特徴選択の適用による識別率と特徴数の変化

表 6: 「原特徴集合」に特徴選択を適用した結果

	Test00	Test01	Test14
	識別率 (特徴数)	識別率 (特徴数)	識別率 (特徴数)
原特徴	99.7% (699)	99.0% (699)	71.1% (699)
選択特徴	99.7% (70)	99.1% (154)	73.4% (200)

特徴選択手法の適用によって得られた特徴数や選択された特徴は各課題で異なっていた。これは課題ごとに適当な選択が行われたことを示すものと考えられる。また特徴選択時とは異なる光源下で撮影された画像の識別を行う Test14 でも識別率は 71.1% から 73.4% に上昇し、実環境中においても特徴選択が有効であることが示唆される。

特徴選択手法には本論文で利用した基本的な手法以外にも多数存在する。特に近年のコンピュータの性能向上を背景に様々な手法が研究されており、これらを利用することでより効果的な特徴選択が行えると期待される。

4 むすび

特徴計算が簡便でハードウェア化も容易なマスクパターンによる画像特徴の抽出手法を提案した。マスクパターンは 3×3 サイズを基本として大きなサイズも構成可能で、各サイズにつき 223 個のパターンが作成される。これらの異なるサイズのパターンを併用することで抽出特徴の多重解像度化表現も行える。マスクパターンから算出される特徴は、従来の 2 次までの自己相関特徴を高次に拡張した 8 次までの自己相関特徴に相当する。

テクスチャ識別実験の結果、提案手法は 2 次までの自己相関特徴や Gabor などの他特徴を用いた識別よりも良好な結果が得られた。また実環境への応用を想定した課題においても識別精度は高く、提案

手法は実用化の期待も高いと考える。さらに提案特徴に対し特徴選択を適用することによって各課題に適した特徴集合が自動的に構成され、識別率の向上とともに特徴数の大幅な削減が可能なが示された。

これまでに自己相関特徴は文字認識 [8] や顔識別 [1, 4] など広く応用されており、今後は提案手法をテクスチャ以外の様々な対象に対しても適用することを検討する。

参考文献

- [1] F. Goudail, E. Lange, T. Iwamoto, K. Kyuma, and N. Otsu, "Face recognition system using local autocorrelations and multiscale integration," IEEE Trans. PAMI, vol.18, No.10, pp.1024–1028, 1996.
- [2] 長谷川修, 栗田多喜夫, 坂上勝彦, 大津展之, "高次相関特徴によるテクスチャ解析の試み," 第 55 回情報処理学会 全国大会講演論文集, vol.2, pp.258–259, 1997.
- [3] 石井健一郎, 上田修功, 前田英作, 村瀬洋, わかりやすいパターン認識, オーム社, 1998.
- [4] T. Kurita, N. Otsu and T. Sato, "A face recognition method using higher order local autocorrelation and multivariate analysis," Proc. ICPR, vol.2, pp.213–216, 1992.
- [5] T. Mänpää, M. Pietikäinen and J. Viertola, "Separating color and pattern information for color texture discrimination," Proc. ICPR, vol.1, pp.668–671, 2002.
- [6] T. Ojala, T. Mänpää, M. Pietikäinen, J. Viertola, J. Kyllönen and S. Huovinen, "Outex-New framework for empirical evaluation of texture analysis algorithms," Proc. ICPR, vol.1, pp.701–706, 2002.
- [7] T. Ojala, M. Pietikäinen and T. Mänpää, "Multiresolution gray-scale and rotation-invariant texture classification with Local Binary Patterns," IEEE Trans. PAMI, vol.24, No.7, pp.971–987, 2002.
- [8] 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.
- [9] V. Popovici and J.P. Thiran, "Higher order autocorrelations for pattern classification," Proc. ICIP, pp.724–727, 2001.
- [10] 豊田崇弘, 長谷川修, "局所自己相関マスクの拡張とその応用に関する一考察," 第 10 回画像センシングシンポジウム (SSII04) 講演論文集, pp.307–310, 2004.