

単純な図形の組合せによる分類アルゴリズム

大平良司^{†1,†2} 矢田紀子^{†1} 長尾智晴^{†1}

人間の図形認識メカニズムは、単純な図形の組合せで複雑な図形を認識する機構であると考えられている。これが“図形アルファベット仮説”である。我々はこの考え方を“比較的単純な図形群の中から選択された図形の組合せによって複雑な図形を認識する機構”ととらえ、コンピュータによるパターン分類への応用を提案する。提案手法では、単純な図形と仮定した $N \times N$ 画素のドットパターン (Alphabet Dot Pattern; ADP) と認識対象図形のハミング距離を特徴量として分類する。本論文では、まず提案手法のシステムについて述べる。また、実験の一例として提案手法をマルチフォント図形の認識に適用した結果について示す。この結果、提案手法では比較的手法よりも高い分類正答率が得られた。

Classification Algorithm by the Combination of a Simple Figure

RYOJI OHIRA,^{†1,†2} NORIKO YATA^{†1}
and TOMOHARU NAGAO^{†1}

It is thought that human being recognizes a complicated figure by combining simple figure. This is “figure alphabet hypothesis” and these simple figures are called a figure alphabet. We considered “the mechanism in which a complicated figure is recognized with the combination of the figure chosen from comparatively simple figure groups”, and applies it to a pattern classification. The proposed method assumes the figure alphabet to be the dot pattern (Alphabet Dot Pattern; ADP) of an $N \times N$ pixel. Because there are many kinds of ADP, ADP group is optimized by the genetic algorithm (GA). And, the hamming distance of an input figure and an ADP group is calculated, and classifies a figure. In this research, the proposed method was applied to recognition of a multifont figure as an example of an experiment, and the validity of the proposed method was verified. Consequently, the result of the proposed method was able to obtain the correct answer rate higher than the result of a comparative experiment. This paper describes the way of thinking and experiment result of the proposed method.

1. はじめに

近年、画像認識や画像分類の要求が高まり多くの手法が提案されている。その代表的なものとしてニューラルネットワーク、テンプレートマッチング、サポートベクターマシン (Support Vector Machine; SVM) などを用いた手法があげられる。ニューラルネットワークは結合荷重を最適化することで様々な環境に適応でき、特に画像中の対象物体の認識^{1),2)} や顔画像の認識³⁾ などに適用されている。しかし、ニューラルネットワークは構造が簡単で扱いやすく適応範囲が広い反面、適応環境に応じて入力層や中間層を試行錯誤して構築することで回路規模が膨大になるという課題がある。テンプレートマッチングは、認識対象の画像と基準図形 (テンプレート) を画素単位で比較する手法で、ナンバープレートの文字認識⁴⁾ や遺伝的アルゴリズム (Genetic Algorithm; GA)^{5),6)} と組み合わせた認識⁷⁾、自然画像中からの顔検索⁸⁾ など画像検索や画像認識に適用されている。しかし、テンプレートマッチングは画素単位で照合するため、画像のサイズや分解能によって処理時間が増加するという課題がある。SVM は、近年注目されている手法で、2クラスの非線形分離問題に適した分類器であることが知られており、類似した2種類の文字の識別⁹⁾ や顔画像の認識¹⁰⁾ に適用されている。しかし、SVM は2種類の対象図形 (カテゴリ) の分類器であり、多カテゴリへの適用は工夫する必要があり回路構成が複雑化するという問題がある。このように従来の代表的な手法は様々な環境に適応が可能であるが、回路規模の増大、回路構成の複雑化が課題となる。そこで、コンパクトな回路規模とシンプルな回路構成で汎用性の高い分類アルゴリズムの開発を目指して着目したのが人間の図形認識メカニズムである。

人間の図形認識メカニズムは、単純な図形の組合せで複雑な図形を認識する機構であると考えられている。これが“図形アルファベット仮説”であり、これらの単純な図形は図形アルファベットと呼ばれている¹¹⁾。我々は、この図形アルファベット仮説の考え方を“比較的単純な図形群の中から選択された図形の組合せによって複雑な図形を認識する機構”ととらえ、コンピュータによるパターン分類への応用を提案する¹²⁾。提案手法では、図形アルファベットの形状を白と黒のドットの配列パターンで表した $N \times N$ 画素のドットパターン

^{†1} 横浜国立大学大学院環境情報学府

Graduate School of Environment and Information Sciences, Yokohama National University

^{†2} 沖電気工業株式会社

Okai Electric Industry Co., Ltd

(Alphabet Dot Pattern ; ADP) とする。また、分類に使用する ADP を M 個とし、その ADP の集合を ADP 群とする。そして、単純な図形の組合せで複雑な図形を認識する機構を、カテゴリの図形と ADP 群のハミング距離を用いて対象図形(カテゴリ)を分類する機構とする。ここで、考えられる ADP 群の種類は $2^{N \times N}$ 個の要素から M 個をとる組合せの数である ${}_{2^{N \times N}}C_M$ 個と膨大であり、分類対象に適した ADP を手動で選択することは非常に困難である。そこで、ADP 群を自動的に構築するために、GA を用いる。

本論文では、単純な図形の組合せで対象図形を分類するアルゴリズムと GA を用いて ADP 群を自動的に構築できるシステムについて述べる。また、基本的な検討実験の一例として、提案手法をマルチフォント図形の認識問題に適用する。

2. 分類アルゴリズム

2.1 本システムの概要

図 1 に提案手法のシステム構成を示す。本システムは、GA の処理部と特徴抽出部と分類部で構成される。まず、カテゴリごとに複数枚の画像を用意し、学習画像と未知画像に分ける。これらの画像の画素数は $K \times K$ 画素である。ADP は、白と黒のドットの配列パターンで表した $N \times N$ 画素のドットパターンである。ここで、 K は N の整数倍とする。

2.2 システムの動作

2.2.1 学習フェーズ

学習フェーズでは、学習画像を用いて GA で ADP を最適化し、学習画像と ADP のハミング距離から代表特徴量を求める。この GA で最適化する方法は 2.3 節で述べる。

図 2 に代表特徴量の求め方を示す。代表特徴量は、ADP の 1 つの画素を $(K \div N) \times (K \div N)$ 画素に拡大した ADPL を作り、学習画像の画素数と ADPL の画素数を合わせた後、学習画像と ADPL のハミング距離を式 (1) で求め、このハミング距離を学習画像の枚数で平均したものである。計算方法を式 (2) に示す。以後、本論文ではハミング距離を総画素数で除算して正規化したものをハミング距離と呼ぶ。

$$H_j = \frac{1}{K \times K} \sum_{x=1}^K \sum_{y=1}^K d(P(x, y), AL(j, x, y)) \quad (1)$$

$$d(n_1, n_2) = \begin{cases} 0 & \text{if}(n_1 = n_2) \\ 1 & \text{otherwise} \end{cases}$$

ここで、 $P(x, y)$ は学習画像、 $AL(j, x, y)$ は ADP の 1 つの画素を $(K \div N) \times (K \div N)$ 画

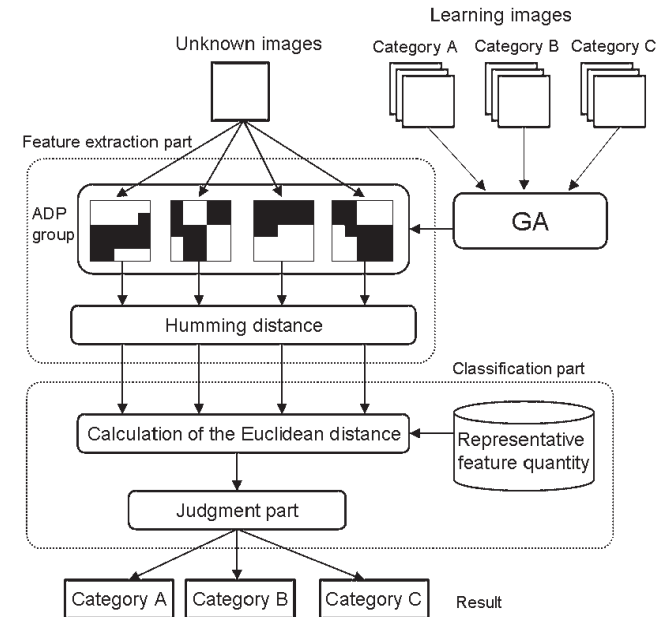


図 1 システム構成
Fig. 1 System configuration.

素に拡大した j 番目の ADP, H_j は学習画像 $P(x, y)$ と j 番目の ADPL のハミング距離である。

$$R(i, j) = \frac{1}{C_i} \sum_{k=1}^{C_i} H_j(S_{i,k}) \quad (2)$$

ここで、 $R(i, j)$ は i 番目のカテゴリの j 番目の ADP の代表特徴量、 C_i は i 番目のカテゴリの学習画像の枚数、 $S_{i,k}$ はカテゴリ i の学習画像で、 $S_{i,1}, S_{i,2}, \dots, S_{i,C_i}$ 、 H_j は学習画像の j 番目のハミング距離を計算する関数である。

2.2.2 分類フェーズ

分類フェーズでは、未知画像がそれぞれどのカテゴリに属するかを判定する。分類の処理は、ADP の 1 つの画素を $(K \div N) \times (K \div N)$ 画素に拡大した ADPL と未知画像とのハミング距離を計算し、そのハミング距離とカテゴリごとの代表特徴量のユークリッド距離を式

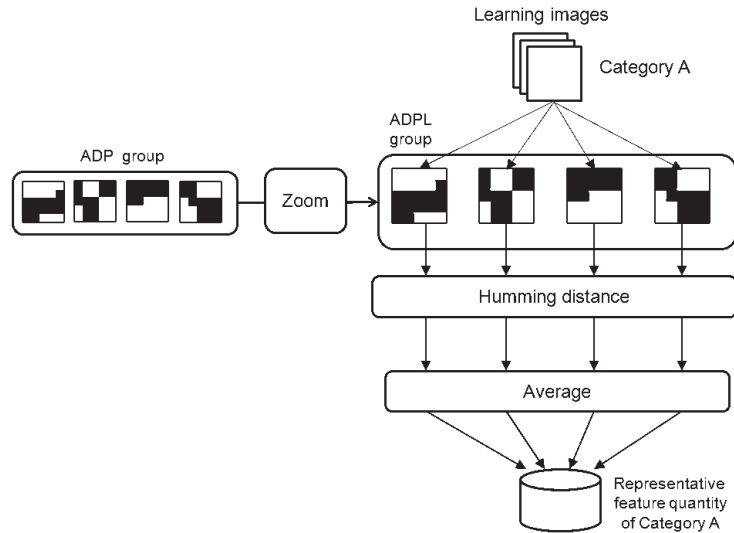


図 2 代表特徴量の計算処理
Fig. 2 Calculation of representative feature quantity.

(3) で計算する．このとき，ユークリッド距離が最小となったカテゴリを未知画像の分類結果とする．


提案手法は，単純な図形と仮定した M 個の ADPL から得られたハミング距離を， M 次元特徴空間に写像して分類する手法を，単純な図形の組合せととらえている．

$$E_i = \sqrt{\sum_{j=1}^M (R(i, j) - H_j)^2} \quad (3)$$

ここで， $R(i, j)$ は i 番目のカテゴリの j 番目の ADP の代表特徴量， H_j は未知画像と j 番目の ADPL とのハミング距離， E_i は i 番目のカテゴリにおける代表特徴量とハミング距離のユークリッド距離 ($E_i \geq 0$) である．

2.3 GA を用いた ADP 群の自動構築

ADP は $N \times N$ 画素の白と黒のドットの配列パターンで表され，その総数 M_{max} は $2^{N \times N}$ 個である．たとえば， $N=5$ ， $M=10$ のとき， M_{max} は約 3.4×10^7 個となり，そこから 10 個をとる組合せは膨大である．この膨大な組合せの中から，分類対象の図形に最適な ADP



(a) Genotype (b) Phenotype

図 3 遺伝子型と表現型
Fig. 3 Genotype and phenotype.

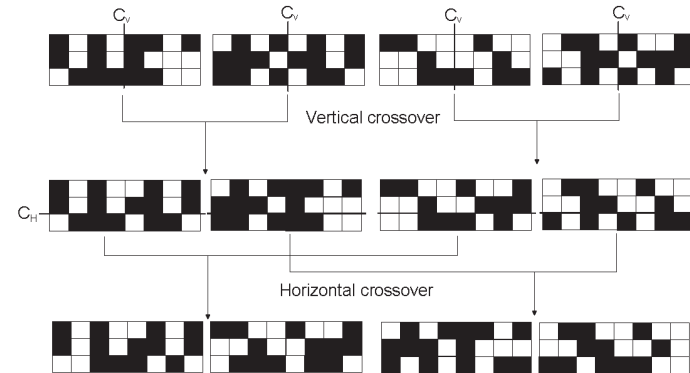


図 4 交叉の例
Fig. 4 Example of the crossover.

を手動で選択し ADP 群を構築することは非常に困難である．そこで，この M_{max} の中から分類対象の図形に適した M 個をとりだし ADP 群を構築するために GA を用いる．

2.3.1 遺伝子型と表現型

図 3 に $N=3$ ， $M=4$ のときの遺伝子型と表現型の例を示す．本研究で用いる遺伝子型は， $N \times N \times M$ の 2 次元ビット列で表し，遺伝子が '1' であるときに対応する表現型のドットは黒となり，'0' のときは白となる．本論文では，この N と M は予備実験によって決定し， $N=5$ ， $M=10$ とする．

2.3.2 交叉と突然変異

2 次元の遺伝子型の交叉には，2 次元ブロック交叉などが考えられるが，本論文では垂直交差点 C_v と水平交差点 C_H をランダムに決め，垂直交叉と水平交叉を 1 世代ごとに交互に行う，変形 1 点交叉を用いる．図 4 に，この 2 世代分の交叉によって生じる子孫の表現型の生成例を示す．




図 5 突然変異の例
Fig. 5 Example of the mutation.

突然変異は、突然変異率の割合で 1 画素の遺伝子が反転する。図 5 は本研究で用いる表現型の突然変異の様子を示したもので、遺伝子 a は突然変異前と突然変異後で白から黒に反転している。

2.3.3 適応度関数

本研究では、最適な ADP 群を構築するために、GA の適応度として次の条件を考慮する。

- (a) カテゴリの代表特徴量間の距離
- (b) カテゴリ内のハミング距離の分散
- (c) ADP の多様性
- (d) 学習画像の分類性能
- (e) ADP の単純性

式 (4) に示す適応度関数は式 (5) から式 (9) に示す 5 つの関数, F_1, F_2, F_3, F_4, F_5 の線形和として表される。

$$fitness = \alpha_1 F_1 + \alpha_2 F_2 + \alpha_3 F_3 + \alpha_4 F_4 + \alpha_5 F_5 \quad (4)$$

ここで, $\alpha_1, \alpha_2, \dots, \alpha_5$ は定数である。本論文では予備実験の結果から、学習画像の分類性能と ADP の単純性に重きを置いて, $\alpha_1 = 1, \alpha_2 = 1, \alpha_3 = 1, \alpha_4 = 1.5, \alpha_5 = 2$ とする。

(a) カテゴリの代表特徴量間の距離

カテゴリごとの代表特徴量が離れているほど独立性が高く、未知画像へのロバスト性を期待することができる。そこで、カテゴリごとの代表特徴量が離れていることを評価するために、式 (5) で示される F_1 を適応度に加える。

$$F_1 = \sum_{i_1=1}^{V-1} \sum_{i_2=i_1+1}^V \sqrt{\sum_{j=1}^M (R(i_1, j) - R(i_2, j))^2} \quad (5)$$

ここで, V はカテゴリ数である。

(b) カテゴリ内のハミング距離の分散

カテゴリに属する学習画像のハミング距離の分散が小さいと特徴空間上でそのカテゴ

リが集まっているといえ、そのカテゴリの特徴をよりよく表していることになる。そこで、式 (6) で示される F_2 を適応度に加える。

$$F_2 = -\frac{1}{V} \sum_{i=1}^V \sum_{j=1}^M \frac{1}{C_i} \sum_{k=1}^{C_i} (H_j(S_{i,k}) - R(i, j))^2 \quad (6)$$

ここで, H_j は学習画像 P の j 番目のハミング距離を計算する関数, $S_{i,k}$ はカテゴリ i の k 番目学習画像である。

(c) ADP の多様性

ADP 群に類似した ADP があると、算出されるハミング距離も近い値となり、特徴量の次元数が減少してしまうため、多様性を評価したい。そこで、式 (7) で示される F_3 を適応度に加える。

$$F_3 = -\sum_{j_1=1}^{M-1} \sum_{j_2=j_1+1}^M \frac{1}{N \times N} \sum_{x=1}^N \sum_{y=1}^N \bar{d}(A(j_1, x, y), A(j_2, x, y)) \quad (7)$$

$$\bar{d}(n_1, n_2) = \begin{cases} 1 & \text{if } (n_1 = n_2) \\ 0 & \text{otherwise} \end{cases}$$

(d) 学習画像の分類性能

学習画像の分類性能が高い ADP を評価するために、式 (8) で示される F_4 を適応度に加える。

$$F_4 = \frac{1}{V} \sum_{i=1}^V \frac{1}{C_i} \sum_{k=1}^{C_i} \bar{d}(i, g_2(S_{i,k})) \quad (8)$$

ここで, g_2 はカテゴリ i の k 番目の学習画像 $S_{i,k}$ が分類された結果のカテゴリ番号である。

(e) ADP の単純性

黒画素の集まりは図形の特徴をよりよく表す。そこで、黒画素が集まった ADP を評価するために、式 (9) で示される F_5 を適応度に加える。

$$F_5 = \frac{2}{M \times N \times N} \sum_{j=1}^M \sum_{x=1}^{N-1} \sum_{y=1}^{N-1} (\bar{d}(A(j, x, y), A(j, x+1, y)) + \bar{d}(A(j, x, y), A(j, x, y+1))) \quad (9)$$

表 1 実験に用いた画像の設定
Table 1 Setting of experiment images.

Gradation of the images	Binary images
Font	Multifont
Type of characters	Alphabet, Number
Pixel of images	75 × 75
Categories of alphabet	5
Categories of number	10



図 6 マルチフォント英字のサンプル画像: 'A', 'B', 'C', 'D', 'E'
Fig. 6 Sample of multifont alphabet images-'A','B','C','D' and 'E'.



図 7 マルチフォント数字のサンプル画像
Fig. 7 Sample of multifont number images.

3. マルチフォント図形を用いた実験

3.1 実験環境の設定

3.1.1 実験に用いた画像

本論文では、実験の一例として、提案手法をマルチフォント図形の分類に適用し、提案手法の有効性を検証する。表 1 に実験で用いた画像の設定を示す。マルチフォント英字画像のカテゴリは次に示す (1)、マルチフォント数字画像のカテゴリは次に示す (2) である。

- (1) A, B, C, D, E
- (2) 0, 1, 2, 3, 4, 5, 6, 7, 8, 9

実験に用いた画像は、Microsoft office を用いて各カテゴリに対して 88 種類のフォントから 88 枚の画像を作成した。図 6, 図 7 にマルチフォント図形のサンプル画像を示す。作成した画像 88 枚からランダムに選んだ 25 枚を学習画像とし、その他の画像を未知画像とする。表 2 に学習画像と未知画像の枚数を示す。

3.1.2 実験に用いたパラメータ

ADP 群を自動的に構築するために用いる GA のパラメータを表 3 に示す。また、本論文では予備実験の結果から ADP の画素数を 5 × 5 画素、個数を 10 個と決めた。

表 2 学習画像と未知画像の枚数

Table 2 The total number of learning images and unknown images.

	Learning images	Unknown images
Multifont alphabet	125	315
Multifont number	250	650

表 3 GA のパラメータ

Table 3 Parameter for GA.

	SGA (Simple Genetic Algorithm)
Change of generation	100
Population size	15000
Generation number	roulette + elite preservation
Selection type	0.8
Crossover rate	0.03
Mutation rate	Deformation one point crossover
Crossover type	



図 8 文字画像をモデル化したドットパターン: 'A', 'B', 'C', 'D', 'E'
Fig. 8 Modeled dot patterns-'A','B','C','D' and 'E'.



図 9 文字画像をモデル化したドットパターン: 数字
Fig. 9 Modeled dot patterns of number.

3.2 比較手法の設定

提案手法の有効性を検証するために、次に示す比較手法を行う。

(1) 比較手法 1

比較手法 1 は、人が画像ツールを用いて文字画像をモデリングしたドットパターン (Modeled dot pattern; MDP) を用いた実験である。図 8, 図 9 に実験で用いた MDP 群を示す。この実験では、提案手法の ADP 群を MDP 群に置き換えて未知画像に適用させて行う。

41 単純な図形の組合せによる分類アルゴリズム



図 10 テンプレートマッチングのテンプレート
Fig. 10 Standard images of the template matching.



図 11 GA で最適化されたマルチフォント英字画像 'A', 'B', 'C', 'D', 'E' の ADP 群
Fig. 11 ADP group of the multifont alphabets 'A', 'B', 'C', 'D' and 'E'.



図 12 GA で最適化されたマルチフォント数字画像の ADP 群
Fig. 12 ADP group of the multifont number.

(2) 比較手法 2

比較手法 2 は、テンプレートマッチングを用いた実験である。このテンプレートマッチングの学習画像と未知画像の画素数は、 75×75 画素とする。またテンプレートは、学習画像の各カテゴリ内の平均値に最も近い画像を選ぶ。本論文で選んだテンプレートを図 10 に示す。そして、テンプレートと未知画像の差分を式 (10) で求める。

$$B = \frac{1}{75 \times 75} \sum_{i=1}^{75} \sum_{j=1}^{75} |T(i, j) - P(i, j)| \quad (10)$$

ここで、 i, j は画素の座標、 $T(i, j)$ はテンプレート、 $P(i, j)$ は未知画像、 B はテンプレートと未知画像の差分であり、 B が小さいほどテンプレートと未知画像の類似度が高いことを示す。

3.3 マルチフォント図形の実験結果

図 11、図 12 は分類対象のマルチフォント図形の学習画像を用いて GA で最適化された ADP 群である。この図 11、図 12 の ADP 群を用いた提案手法を、分類対象のマルチフォント図形に適用した結果が、表 4、表 5 である。この結果、提案手法は比較手法より高い正答率を示した。このことから、提案手法が英字や数字のマルチフォント図形の認識問題に

表 4 マルチフォント英字画像 'A', 'B', 'C', 'D', 'E' の正答率
Table 4 Correct answer rate -'A','B','C','D' and 'E'.

	Learning images	Unknown images
Proposed method	97.6%	96.2%
Comparative method1	76.0%	84.8%
Comparative method2	90.4%	90.1%

表 5 マルチフォント数字画像の正答率
Table 5 Correct answer rate of multifont number images.

	Learning images	Unknown images
Proposed method	98.4%	95.9%
Comparative method1	85.6%	84.4%
Comparative method2	80.8%	80.9%

表 6 最適化された ADP 群の検証 (マルチフォント数字画像)
Table 6 Verification of the optimized ADP group (Multifont number images).

	Learning images	Unknown images
図 12 ADP group	98.4%	95.9%
図 11 ADP group	91.2%	93.7%

対して有効であるといえる。

次に、GA によって最適化された ADP 群の妥当性を検証するための実験として、マルチフォント英字画像用に最適化された図 11 の ADP 群をマルチフォント数字画像に適応した。この結果を表 6 に示す。上段は図 12 をマルチフォント数字画像に適用した正答率、下段は図 11 をマルチフォント数字画像に適用した正答率である。この結果、図 12 のマルチフォント数字画像用に GA で最適化された ADP 群は図 11 のマルチフォント英字画像用に GA で最適化された ADP 群より高い正答率が得られている。このことから、分類対象に適した ADP 群が GA によって自動的に構築できたといえる。

また、GA の適応度関数の必要性を検証するための実験として、学習画像の分類性能 F_4 を適応度関数から除いて構築した ADP 群と ADP の単純性 F_5 を適応度関数から除いて構築した ADP 群をマルチフォント英字画像に適応した。この結果を表 7 に示す。この結果から、提案手法で考慮した 5 つの適応度関数を用いて構築した ADP 群は、適応度関数を減らして構築した ADP 群より高い正答率が得られている。これは、文字図形のように黒のドットが連続する図形には ADP の黒画素の配列パターンが連結していることが望ましく ADP

表 7 GA の適応度関数の必要性の検証 (マルチフォント英字画像に適用)

Table 7 Verification of fitness function.

	Learning images	Unknown images
学習画像の分類性能を除いた適応度	71.5%	70.6%
ADP の単純性を除いた適応度	78.4%	76.1%

の単純性が必要である。さらに、学習画像の分類性能の適応度が未知画像の分類にも影響することから学習画像の分類性能の適応度が必要である。このことから、5つの適応度関数を用いることで高い分類性能が実現できたといえる。

3.4 考 察

提案手法をマルチフォント図形に適用した結果、比較手法よりも高い正答率が得られた。この結果によって、GA で最適化された ADP 群を持ち、ADPL とのハミング距離を特徴量として図形を分類するという新しい画像分類システムが有効であることが分かった。また、表 6 に示す結果から、分類対象の図形に最適化された ADP 群は高い正答率が得られ、GA で ADP 群を最適化することの重要性と、GA によって最適化された ADP 群が自動的に構築できたことが分かった。

以上、提案手法と比較手法の結果から、単純な図形の組合せで対象図形を分類できる新しい考え方の画像分類システムを実現できた。さらに、ADP 群の妥当性を検証する実験結果から、本システムは GA によって ADP 群を自動的に構築できるシステムであることを示した。

4. おわりに

本論文では、人間が図形を認識するメカニズムと考えられている図形アルファベット仮説に着目し、図形アルファベット仮説の考え方を“比較的単純な図形群の中から選択された図形の組合せによって複雑な図形を認識する機構”にとらえ、コンピュータによるパターン分類への応用を提案した。また、実験の一例として、提案手法をマルチフォント図形の認識問題に適用し、比較手法との性能比較を行った。この結果、提案手法では比較手法より高い正答率が得られ、提案手法の有効性を確認できた。また、GA によってマルチフォント英字画像用に自動的に構築した ADP 群をマルチフォント数字画像に適用する実験を行い、その正答率の結果から GA によって分類対象の図形に適した ADP 群が自動的に獲得できたことを確認した。これらの結果から、GA で ADP 群を最適化することの重要性を示し、単純な図形の組合せで対象図形を分類できる新しい考え方の画像分類システムを実現できたとい

える。

今後は、本論文で構築した画像分類システムを階調画像の分類実験として顔画像などの分類に適用する。さらに、色情報を考慮した画像分類システムの検討を行い、カラー画像の分類に適用する。また、分類対象図形の部分構成要素を考慮した ADP 群の構築、高精度化を目指した GA の適応度関数について検討する予定である。

参 考 文 献

- 1) 下平隆史ほか：ニューラルネットワークを用いた車両画像認識，電子情報通信学会技術研究報告，NLP，非線形問題，Vol.97, No.53, pp.69-76 (1997).
- 2) 朝倉俊行，青柳裕治：ニューラルネットワークを用いた速度標識の画像認識，日本機械学会論文集（C 編），Vol.61, No.589, pp.206-212 (1995).
- 3) 森田 学，永野 俊：顔画像の前処理とニューラルネットワークによる認識，電子情報通信学会技術研究報告，NC，ニューロコンピューティング，Vol.93, No.537, pp.79-84 (1994).
- 4) 高橋裕子ほか：多値テンプレートマッチングを用いたナンバープレート認識法—雑音抑制フィルタと文字配置規則の効果的利用，電子情報通信学会論文誌 D-II，Vol.J87-D-II, No.7, pp.1451-1461 (2004).
- 5) Holland, J.H.: *Adaptation in Natural and Artificial Systems*, The Univ. Michigan Press (1975).
- 6) 安居院猛，長尾智晴：ジェネティックアルゴリズム，昭晃堂 (1993).
- 7) 上田道夫ほか：遺伝的アルゴリズムを用いたテンプレートマッチングによる新聞フォントの自動識別，日本法科学技術学会誌，Vol.11, No.1, pp.77-93 (2006).
- 8) 加来俊彦，栗田多喜夫：一般画像からの顔抽出のための局所的な顔らしさの選択的な統合，電子情報通信学会技術研究報告，PRMU，パターン認識・メディア理解，Vol.101, No.421, pp.33-38 (2001).
- 9) 篠原早苗ほか：SVM を用いた手書き文字認識における学習データ選択と認識精度に関する一考察，電子情報通信学会技術研究報告，PRMU，パターン認識・メディア理解，Vol.102, No.708, pp.81-86 (2003).
- 10) 瀧川えりな，細井 聖，川出雅人：顔画像による人種推定技術，電子情報通信学会技術研究報告，PRMU，パターン認識・メディア理解，Vol.103, No.452, pp.19-24 (2003).
- 11) Fujita, I., Tanaka, K., Ito, M. and Cheng, K.: Columns for visual features of objects in monkey inferotemporal cortex, *Nature*, Vol.360, pp.343-346 (1992).
- 12) Saiki, K., Ohira, R. and Nagao, T.: Finding optimized object alphabet using GA, *IWAIT2008* (2008).

(平成 22 年 2 月 4 日受付)
(平成 22 年 3 月 24 日再受付)
(平成 22 年 4 月 23 日再受付 (2))
(平成 22 年 4 月 26 日採録)



大平 良司

1968 年生。1993 年日本大学大学院理工学研究科博士前期課程修了。同年沖電気工業株式会社入社。図形認識の研究開発に従事。2007 年横浜国立大学大学院環境情報学府博士課程後期入学，現在に至る。画像分類，画像認識等に関する研究に従事。



矢田 紀子 (正会員)

1981 年生。2008 年横浜国立大学大学院環境情報学府博士課程後期修了。同年同大学院環境情報研究院特任教員 (研究教員)，現在に至る。視覚情報処理，コンピュータビジョン等に関する研究に従事。博士 (工学)。



長尾 智晴 (正会員)

1959 年生。1985 年東京工業大学大学院博士後期課程中退。同年同大学工学部附属画像情報工学研究院施設助手。1995 年同大学工学部附属画像情報工学研究院施設助教授。2001 年横浜国立大学大学院環境情報研究院教授，現在に至る。画像処理，進化計算法，神経回路網，マルチエージェント，進化経済学等に関する研究に従事。工学博士。