

弱識別器に Genetic Image Network を用いた アンサンブル画像分類法

中山 史朗^{†1} 白川 真一^{†1}
矢田 紀子^{†1} 長尾 智晴^{†1}

近年、画像を身近に扱う機会が増えたことで、計算機による画像分類のニーズがより一層高まっている。Genetic Image Network for Image Classification (GIN-IC) は進化計算によって自動的に画像変換部を含む画像分類アルゴリズムを構築する手法であり、その有効性が示されている。本報告の目的は、AdaBoost のアルゴリズムに基づいて GIN-IC の性能を向上させることである。具体的には GIN-IC を弱識別器として利用し、相互補完させることで性能の向上を図る。実験では、提案手法を 3 種類の画像分類問題に適用した結果を示す。これらの実験から、提案手法の学習および検証用画像に対する分類精度が、従来の GIN-IC と比較して改善されることが確認できた。

Ensemble Image Classification Using Genetic Image Network as Weak Classifiers

SHIRO NAKAYAMA,^{†1} SHINICHI SHIRAKAWA,^{†1}
NORIKO YATA^{†1} and TOMOHARU NAGAO^{†1}

Automatic construction method for image classification algorithms have been required. Genetic Image Network for Image Classification (GIN-IC) is the automatic construction method for image classification algorithms which include image transformation component using evolutionary computation, and its effectiveness has already been proven. In our study, we try to improve the performance of GIN-IC with AdaBoost algorithm using GIN-IC as weak classifiers to complement with each other. We apply our proposed method to three types of image classification problems, and show the results in this paper. In our method, discrimination rates for training images and test images improved in the experiments compared with the previous method GIN-IC.

1. はじめに

近年、画像を身近に扱う機会が増えたことで、計算機による画像分類のニーズがより一層高まっている。一般的に画像分類アルゴリズムは、画像の前処理（画像変換）、特徴抽出処理、分類処理から構成されるが、あらゆる画像分類問題に対して有効な画像分類アルゴリズムを作り出すことは大変困難である。そのため、対象とする問題に合わせて画像分類アルゴリズムを自動的に構築する手法が求められている。そのような手法として、進化計算を利用して画像分類アルゴリズムを自動構築する Genetic Image Network for Image Classification (GIN-IC)^{1),2)} が提案されており、その有効性が示されている。GIN-IC は、学習画像と対応するクラスラベルを与えるだけで、対象の問題に合わせた画像分類アルゴリズム（画像変換部、特徴抽出部、演算部）を進化計算によって自動構築する手法である。GIN-IC によって構築される画像分類アルゴリズムは、入力画像に対して画像変換処理を行った後に特徴量を抽出し、それらの値に対して演算処理を施した出力値を用いて分類を行う。GIN-IC の最大の特長は画像変換部にあり、特徴抽出の前に画像変換を行うことによって様々な分類問題に適用することができる。しかし、分類先を決定する出力部が単純であるため、学習不足や演算部で無理に調整することで過学習が生じる場合がある。

本報告では AdaBoost³⁾ のアルゴリズムに基づいて GIN-IC の拡張を行う。AdaBoost は、識別性能の低い識別器（弱識別器）を多数組み合わせると一つの強い識別器を作り出すというアンサンブル学習の中で、最も一般的かつ強力な手法の一つである。Viola らが提案した顔検出法⁴⁾ に代表されるように、AdaBoost のアルゴリズムは画像分類の分野にも広く適用され、その有効性が示されている。また、遺伝的プログラミング (Genetic Programming; GP) や粒子群最適化 (Particle Swarm Optimization; PSO)、ニューラルネットワーク (Neural Network; NN) などを用いて構築された分類器を AdaBoost によって統合し、分類の性能を向上させる研究もなされている⁵⁾⁻⁹⁾。本報告の提案手法では GIN-IC の出力 1 セットを弱識別器として扱い、相互に補完しあう多数の出力セットを統合して一つの画像分類アルゴリズムを構築することで分類精度の向上を図る。本報告では、提案手法を 3 種類の画像分類問題に適用することでその有効性を検証する。

^{†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. Genetic Image Network for Image Classification (GIN-IC)

2.1 GIN-IC の構造と分類の流れ

GIN-IC^{(1),(2)} は、目的の画像変換を自動的に構築する手法である Genetic Image Network (GIN)^{(10),(11)} を基にした画像分類手法である。GIN-IC は学習画像と対応するクラスラベルを与えるだけで、目的の画像分類アルゴリズムを進化計算によって自動構築する。

GIN-IC は表現型 (Phenotype) にフィードフォワード型のネットワーク構造を採用している。この構造の利点としては、ノードの再利用や多出力の表現が可能であることが挙げられる。GIN-IC の各ノードは入力ノード、画像変換ノード、特徴量抽出ノード、演算ノード、出力ノードの 5 種類に分類される。入力ノードは入力画像に対応し、画像変換ノードでは対応する画像処理フィルタによる画像変換が行われる。特徴量抽出ノードでは入力される画像から対応する特徴量を抽出し、演算ノードでは入力値に対して対応する演算を施して出力する。出力ノードは出力値を保持しており、各クラスラベルに対応する。入力画像は全出力ノードのうち最大の値を出力した出力ノードに対応するクラスに分類される。GIN-IC では処理の内容と手順はノードの接続関係で決定され、使うノードの種類と接続関係を同時に最適化することで画像分類アルゴリズムを構築する。得られる処理の流れとしては、入力画像に対して画像変換処理を行った後に特徴量を抽出し、それらの値に演算処理を施した出力値を用いて分類を行う、というものになる。図 1 に GIN-IC の構造例を示す。ここで、図中の英小文字は画像変換ノード、Fn は特徴量抽出ノード、An は演算ノードに対応している。

2.2 遺伝操作と世代交代モデル

GIN-IC の遺伝子型 (Genotype) は一次元の数字列で表される。染色体は各ノードごとに、ノードの種類と入力元のノード番号を保持している。あるノードが n 入力である場合は、 $n+1$ 番目以降の入力元のノード番号は表現型では無視される。遺伝子長は固定であるが、出力ノードにつながっていないノードは表現型には現れないため、実際に使用されるノード数は可変となる。図 1 の例では、No.8 と No.11 のノードが出力ノードにつながっていないノードである。GIN-IC の世代交代モデルには進化戦略の (1+4) ES が採用されており、遺伝操作には突然変異だけを用いている。突然変異の操作は各遺伝子に対して行われ、突然変異率 P_m の確率でノードの種類または入力元を一樣乱数で変更する。GIN-IC の世代交代は次のように行われる。

- (1) 世代数を $j=0$ とする。初期個体をランダムに生成し、親 M とする。
- (2) M に突然変異の操作を適用して子個体を 4 つ生成し、その子個体集団を C とする。

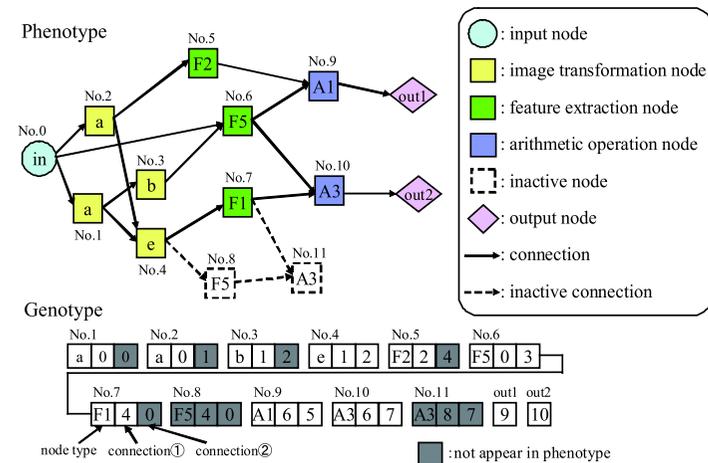


図 1 GIN-IC の構造例 (2 クラス分類の場合)

Fig. 1 Example of a structure in Genetic Image Network for Image Classification for binary classification.

- (3) 全個体の集合 $M+C$ から最良個体を選び、 M に置き換える。ここで、親個体と子個体の評価値が等しい場合は子個体を優先して選択する。
- (4) 終了条件を満たす場合は終了する。そうでなければ $j=j+1$ とし、Step 2 に戻る。

GIN-IC は表現型に現れないノードが存在するため、遺伝操作によって評価値が変わらない変化が生じる可能性が高い。Step 3 で最良個体を選択する際、個体の評価値が同じである場合は子個体を優先して選択する。そうすることで、評価値が変わらない場合も探索点を移動させることができ、個体数の少ない単純な世代交代モデルでも効率的な探索が行うことができる。ここで用いている (1+4) ES は GIN-IC に似たネットワーク構造をもつ CGP⁽¹²⁾ にも適用され、その有効性が示されている。

2.3 GIN-IC の利点と問題点

GIN-IC の最大の利点としては、特徴抽出部の前に画像変換部を擁しており、ノードの組み合わせによって分類に適した画像特徴を生成、選択することができる点が挙げられる。特徴抽出の前に画像変換を行うことで、画像を分類し易いかたちに変換することが可能であり、これによって様々な画像分類問題に適応することができる。しかし一方で、GIN-IC の分類方法は出力値が最も大きい出力ノードに分類を行うという単純なものであるため、学習

不足や演算部で無理に調整することで過学習が生じる場合がある．また，学習画像のサイズや枚数が増加すると，学習時間が膨大になってしまうという問題もある．

3. 提案手法

3.1 概要

提案手法では 2.3 で挙げた GIN-IC の問題点を解消するため，GIN-IC に AdaBoost³⁾ のアルゴリズムを応用する．1 つの構造では困難な分類問題も，弱識別器同士が相互に補完し合うことで精度を向上させるという AdaBoost の性質を利用することで解決を図る．提案手法では GIN-IC の出力 1 セットを弱識別器とし，その出力セットを複数用意する．つまり，分類クラス数を N ，弱識別器数を T とすると，出力ノード数は $N \times T$ になる．各弱識別器は，指定したエラー率に到達するまでひとつずつ順に進化させる．この処理では，一度構築した弱識別器の構造は固定し，その構造はそれ以降に構築する弱識別器で再利用することを許可している．構造の再利用を行うことで他の弱識別器内の有効な処理の一部またはすべてを利用することができるため，新たな弱識別器を作る際に有効に働くことが期待される．また，固定したノードでの出力を保持しておくことで画像変換ノードなどでの再計算を省略できるため，学習時間の短縮にもつながると考えられる．構築した弱識別器はそれぞれが出力の信頼度を保持しており，最終的な分類はすべての弱識別器の重み付き投票によって決定する．2 クラス分類の場合の提案手法の構造例を図 2 に示す．

3.2 提案手法の流れ

提案手法の処理の主な流れを次に示す．

Step 1: 初期の重み $D_1(i) = \frac{1}{m}$, ($i = 1, 2, \dots, m$) とし，注目する弱識別器を $t = 1$ とする．ただし， m は学習画像数である．

Step 2: GIN-IC の t 番目の出力ノードの組を注目出力とする．また，弱識別器を構築する際に十分な数のノードを確保するため，弱識別器を作る前に新たに使用できるノードを追加する．ここで追加する画像変換ノード，特徴量抽出ノード，演算ノードの数はそれぞれパラメータ n_i, n_f, n_a として設定する．

Step 3: エラー率 ϵ_t が任意のしきい値 τ 以下になるまで弱識別器を GIN-IC のアルゴリズムに基づいて進化させる．ここで ϵ_t は，注目出力において誤分類した画像の重み $D_t(i)$ を足し合わせたものであり，式 (1) で表される．

$$\epsilon_t = \sum_{i: h_t(x_i) \neq y_i} D_t(i) \quad (1)$$

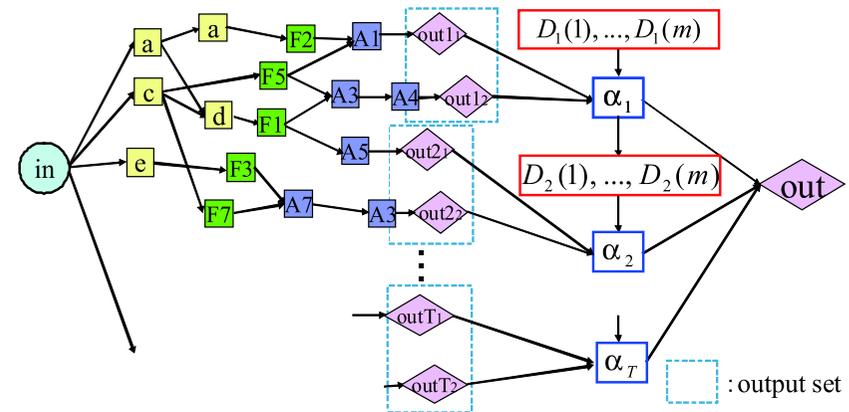


図 2 提案手法の構造例 (2 クラス分類の場合)

Fig. 2 Example of a structure in proposed method for binary classification.

ただし， $h_t(x_i)$ は画像 x_i を入力としたときの弱識別器 t の出力であり， y_i は画像 x_i の正解のクラスラベルである．ここでの世代交代モデルは 2.2 節と同様の (1+4) ES を用いる．Step 6 で固定されたノードに対応する遺伝子への遺伝操作は行わないが，他のノードの入力元として選択することは許可する．こうすることで， t 番目の弱識別器を作る際に， $t - 1$ 番目までの弱識別器の構造を保存したまま再利用することができる．

Step 4: 注目出力の信頼度を式 (2) によって求める．

$$\alpha_t = \frac{1}{2} \log \left(\frac{1 - \epsilon_t}{\epsilon_t} \right) \quad (2)$$

Step 5: 式 (3) を用いて重みを更新する．ただし， Z_t は正規化のための定数である．

$$D_{t+1}(i) = \frac{D_t(i)}{Z_t} \times \begin{cases} e^{-\alpha_t} & \text{if } h_t(x_i) = y_i \\ e^{\alpha_t} & \text{otherwise} \end{cases} \quad (3)$$

ここでは式 (3) によって，正しく分類した画像の重みは小さく，誤分類した画像の重みは大きくなる．これは AdaBoost のアルゴリズムに従い学習画像に対応した重みを適応的に変化させていく操作である．この操作によって以前の弱識別器で分類に失敗した画像ほどその重みが大きくなるため，優先的に正しく分類ようになる．

Step 6: $t = t + 1$ とし， $t \leq T$ ならば現在の注目出力に接続している構造を固定し，Step

2に戻る。

Step 7: 式(4)によって最終的な識別 $h_{\text{fin}}(x_i)$ を行う。

$$h_{\text{fin}}(x_i) = \arg \max_{y_i \in Y} \sum_{t: h_t(x_i)=y_i} \alpha_t \quad (4)$$

提案手法で得られる構造では、すべての弱識別器の投票によって最終的な分類を行う。各弱識別器 t が出力したクラスに対してその信頼度 α_t を足し合わせる。その結果、入力画像 x_i は最も大きい値をもつクラスに分類される。

3.3 提案手法の特徴

本節では、提案手法の特徴について述べる。提案手法で構築される画像分類アルゴリズムは、複数の GIN-IC から構成されている。それらが弱識別器として相互補完することによって、GIN-IC を単体で用いた場合と比較してより良い性能が得られると考えられる。また、構築済みの弱識別器内のノードを他のノードの入力元として選択できるため、以前に構築した有効な処理の一部を必要に応じて再利用することができる。さらに、GIN-IC を弱識別器として使用するため、少ない世代数で進化を終えることができる。こうすることで学習に必要な計算量を削減でき、過学習の抑制にもつながることを期待している。

4. 画像分類実験

4.1 実験設定

本章では、画像分類実験によって提案手法の性能を評価する。実験では従来手法との比較のために、次の3種類の分類問題で実験を行った。

- (1) テクスチャ画像の分類
- (2) 歩行者・非歩行者の分類
- (3) 一般的な物体の分類

本実験では全ての画像をグレースケールに変換し、同じデータセットに対して提案手法および従来手法である GIN-IC を適用した。表 1 に 3 つの実験で使用した提案手法と比較手法のパラメータを示す。ここで表に示した提案手法の画像変換ノード、特徴量抽出ノードおよび演算ノードの値は、3.2 節の Step 2 で追加するノード数である。また、出力ノード数はそれぞれの問題におけるクラス数に対応している。

画像変換ノードには、1 入力 1 出力のフィルタ 26 種類と 2 入力 1 出力のフィルタ 9 種類の計 35 種類を使用した。画像変換ノードの例としては、平均値フィルタや Sobel フィルタ、論理和などが挙げられる。特徴量抽出ノードには、階調値の平均や分散など 17 種類を使用

表 1 実験に用いたパラメータ

Table 1 Parameters used in the experiments.

Parameters	GIN-IC	Proposal
Generation alternation model	(1+4)ES	(1+4)ES
Mutation rate (P_m)	0.02	0.02
Image transformation nodes (n_i)	100	Add 50
Feature extraction nodes (n_f)	100	Add 50
Arithmetic operation nodes (n_a)	100	Add 50
Output nodes	6, 2, 5	6, 2, 5
The number of generations	112500	-
The number of weak classifiers (T)	-	100
Error rate threshold (τ)	-	0.4

した。演算ノードには四則演算や大小比較など 20 種類を使用した。いずれのノードについても基礎的かつ重要なノードとして筆者らが選択しており、比較手法、提案手法ともに同じ種類のノードを用いた。また、弱識別器として使用する GIN-IC の世代交代の際に各個体を評価する関数には式(5)を用いた。

$$fitness = N_c \times m + \frac{1}{N_a} \quad (5)$$

ここで、 N_c は正しく分類した画像の重みを足し合わせたもの（重み付き正答率）であり、 N_a は実際に使用されているノードの数（active node 数）である。 m は学習画像数であり、評価の際に重み付き正答率、active node 数の順に考慮するため N_c に掛け合わせている。

次に各実験に用いた画像とその特徴について述べる。

4.1.1 実験 1: テクスチャ画像の分類

分類対象は Vision Texture^{*1} で公開されているテクスチャ画像から 6 種類を選択し、6 クラス分類とした。画像は 512×512 [pixel] のもの 2 枚をそれぞれ 64×64 [pixel] に分割することで各クラス 128 枚ずつ用意し、各クラス 10 枚を学習用、残りの 118 枚を検証用とした。問題の傾向としては、1 枚の画像を分割して用いているため、学習画像と検証用画像が類似していることが挙げられる。図 3 に学習時に用いた画像を示す。

4.1.2 実験 2: 歩行者・非歩行者の分類

分類対象は MIT Pedestrian Database^{*2} で公開されている歩行者画像 924 枚と、手動で切り出した歩行者が写っていない画像（非歩行者画像）200 枚を用意し、2 クラス分類とした。画像は 64×128 [pixel] であり、各クラス 100 枚を学習用、残りを検証用とした。これ

*1 <http://vismod.media.mit.edu/vismod/imagery/VisionTexture/vistex.html>

*2 <http://cbcl.mit.edu/software-datasets/PedestrianData.html/>

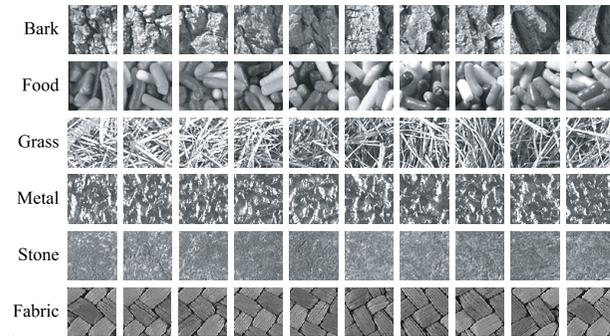


図 3 実験 1 で学習に用いたテクスチャ画像
Fig. 3 Training images used in experiment 1 (texture).



図 4 実験 2 で学習に用いた歩行者・非歩行者の画像例
Fig. 4 Example images used in experiment 2 (pedestrian).



図 5 実験 3 で学習に用いた一般的な物体の画像
Fig. 5 Training images used in experiment 3 (generic object).

らの画像の特徴としては、歩行者画像については解像度がまちまちであるが、人物の頭から足先までの大きさがおおよそ統一されており、人物の向きは正面または後ろ向きとなっている。また、非歩行者画像については屋外の画像から切り出したものだけを用いた。図 4 に学習時に用いた画像の例を示す。

4.1.3 実験 3：一般的な物体の分類

分類対象は WANG image database^{*1}で公開されている画像セットから 5 種類を選択し、5 クラス分類とした。画像は 96×64 [pixel] または 64×96 [pixel] のものを各クラス 100 枚ずつ用意し、各クラス 10 枚を学習用、残りの 90 枚を検証用とした。問題の傾向としては、対象物体の大きさ、位置、種類などが統一されていないため、前に挙げた 2 つの問題よりも難易度が高くなっている。図 5 に学習時に用いた画像を示す。

4.2 結果のまとめと考察

学習および検証用画像に対する分類精度を従来の GIN-IC と比較する。画像分類アルゴリズムの構築は同一パラメータで 10 回試行し、結果には学習画像および検証用画像に対する正答率の 10 回試行における平均と標準偏差 (SD) を用いている。テクスチャ画像の分類実験と歩行者・非歩行者の分類実験、および一般的な物体の分類実験で得られた結果を表 2、表 3 および表 4 にそれぞれ示す。

提案手法は、3 種類の実験の全試行において学習画像をすべて正しく分類することができ

表 2 学習画像と検証用画像に対する分類精度 (テクスチャ画像の分類)
Table 2 Discrimination rate for the training and test images (texture).

Class	Training set		Test set	
	GIN-IC	Proposal	GIN-IC	Proposal
	Average	Average	Average \pm SD	Average \pm SD
Bark	99.0%	100.0%	70.7 \pm 9.2%	91.7 \pm 4.0%
Food	100.0%	100.0%	86.1 \pm 5.8%	98.4 \pm 1.8%
Grass	100.0%	100.0%	88.1 \pm 3.2%	85.6 \pm 6.5%
Metal	90.0%	100.0%	76.7 \pm 16.2%	98.3 \pm 1.9%
Stone	99.0%	100.0%	80.4 \pm 10.5%	94.9 \pm 5.7%
Fabric	100.0%	100.0%	94.7 \pm 6.1%	99.4 \pm 0.8%
Total	98.0%	100.0%	82.8 \pm 8.2%	94.7 \pm 1.5%

た。また、検証用画像に対する精度も大幅に向上していることから、GIN-IC を単体で用いるよりも過学習を防ぐ傾向があることが確認でき、提案手法の有効性を示すことができた。GIN-IC は画像特徴を生成、選択することができるという特長があるため、提案手法では画像変換部をもつ GIN-IC を弱識別器として用いることが複数の問題に対して有効に働いたといえる。本実験ではノードとして単純な画像変換ノードおよび特徴量抽出ノードだけを用いているが、より複雑で効果的な処理を加えることでさらに性能が向上すると考えられる。加えて、提案手法では GIN-IC を単体で用いる場合よりも学習にかかる時間が 2 ~ 50 倍程度高速化された。特に歩行者・非歩行者の分類では学習画像の枚数が多く、2 クラス分類の問題であるため、10 ~ 50 倍の高速化が確認できた。これは、以前に構築した弱識別器を

*1 <http://wang.ist.psu.edu/docs/related/>

表 3 学習画像と検証用画像に対する分類精度 (歩行者・非歩行者の分類)
Table 3 Discrimination rate for the training and test images (pedestrian).

Class	Training set		Test set	
	GIN-IC	Proposal	GIN-IC	Proposal
	Average	Average	Average ± SD	Average ± SD
Pedestrian	89.5%	100.0%	81.4 ± 7.0%	88.6 ± 4.2%
Non-pedestrian	90.5%	100.0%	73.0 ± 10.5%	75.7 ± 4.0%
Total	90.1%	100.0%	80.5 ± 6.1%	87.2 ± 3.7%

表 4 学習画像と検証用画像に対する分類精度 (一般的な物体の分類)
Table 4 Discrimination rate for the training and test images (generic object).

Class	Training set		Test set	
	GIN-IC	Proposal	GIN-IC	Proposal
	Average	Average	Average ± SD	Average ± SD
Building	76.0%	100.0%	34.3 ± 19.5%	62.7 ± 6.9%
Bus	95.0%	100.0%	67.6 ± 12.4%	74.8 ± 7.8%
Elephant	95.0%	100.0%	66.3 ± 10.7%	84.0 ± 5.9%
Flower	100.0%	100.0%	70.9 ± 9.1%	86.4 ± 7.3%
Horse	96.0%	100.0%	56.6 ± 19.5%	73.4 ± 7.9%
Total	92.4%	100.0%	59.1 ± 6.3%	76.3 ± 3.5%

参 考 文 献

- 1) 白川真一, 中山史朗, 矢田紀子, 長尾智晴. Genetic Image Network に基づく画像分類アルゴリズムの自動構築. 人工知能学会論文誌, Vol.25, No.2, pp. 262–271, 2010.
- 2) Shinichi Shirakawa, Shiro Nakayama, and Tomoharu Nagao. Genetic Image Network for Image Classification. *Proceedings of European Workshops on the Applications of Evolutionary Computation on Image Analysis and Signal Processing (EvoIASP 2009)*, Vol. 5484 of LNCS, pp. 395–404, 2009.
- 3) Yoav Freund and Robert E. Schapire. Experiments with a New Boosting Algorithm. *Machine Learning: Proceedings of 13th Int'l. Conference (ICML-96)*, pp. 148–156, 1996.
- 4) Paul Viola and Michael Jones. Rapid Object Detection using a Boosted Cascade of Simple Features. *Proceedings of IEEE International Conference on Computer Vision and Pattern Recognition (CVPR2001)*, Vol.1, pp. 511–518, 2001.
- 5) Hitoshi Iba. Bagging, Boosting, and Bloating in Genetic Programming. *Proceedings of the Genetic and Evolutionary Computation Conference 1999 (GECCO '99)*, Vol.2, pp. 1053–1060, 1999.
- 6) G.Folino, C.Pizzuti, and G.Spezzano. Boosting Technique for Combining Cellular GP Classifiers. *Proceedings of the 7th European Conference on Genetic Programming (EuroGP 2004)*, Vol. 3003 of LNCS, pp. 47–56, 2004.
- 7) G.Folino, C.Pizzuti, and G.Spezzano. GP Ensembles for Large-scale Data Classification. *IEEE Transaction on Evolutionary Computation*, Vol.10, No.5, pp. 604–616, 2004.
- 8) A.W. Mohemmed, M.Zhang, and M.Johnston. Particle Swarm Optimization Based Adaboost for Face Detection. *Proceedings of the 2009 IEEE Congress on Evolutionary Computation*, pp. 2494–2501, 2009.
- 9) Holger Schwenk and Yoshua Bengio. Boosting neural networks. *Neural Computation*, Vol.12, No.8, pp. 1869–1887, 2000.
- 10) 白川真一, 荻野慎太郎, 長尾智晴. Genetic Image Network による画像変換の自動構築. 情報処理学会論文誌: 数理モデル化と応用 (TOM 19), Vol.48, No. SIG 19, pp. 117–126, 2007.
- 11) Shinichi Shirakawa and Tomoharu nagao. Feed Forward Genetic Image Network: Toward Efficient Automatic Construction of Image Processing Algorithm. *Proceedings of the 3rd International Symposium on Visual Computing (ISVC '07) Part II*, Vol. 4842 of LNCS, pp. 287–297, 2007.
- 12) Julian F. Miller and Peter Thomson. Cartesian Genetic Programming. *Proceedings of the Third European Conference on Genetic Programming (EuroGP2000)*, Vol. 1802 of LNCS, pp. 121–132, 2000.

再利用する際に処理計算を省略できることと、構築に必要な最適化の評価回数を削減できることに起因すると考えられる。

5. ま と め

本報告では GIN-IC を弱識別器として利用し、それらを AdaBoost に基づき統合することで画像分類アルゴリズムを得る手法を提案した。また、提案手法を 3 種類の画像分類問題に適用し、従来の GIN-IC との比較を行った。結果としては、AdaBoost を利用することで、従来の GIN-IC よりも全体的に検証用画像に対する正答率の向上が見られた。加えて学習時の精度と学習時間においても改善が見られ、提案手法の有効性が確認できた。しかし、提案手法では使用されるノード数が増えるため、解析が困難になってしまうという問題がある。従来の GIN-IC ではおよそ 30 個程度のノードでネットワークが構成されているのに対し、提案手法では 100 個の弱識別器を作成した場合で 2500 個前後のノードでネットワークが構成されている。この複雑なネットワークでどのような処理が行われているかを解析することが今後の課題である。さらに、より客観的に手法の有効性を示すため、ベンチマークなど様々な分類問題への適用や他の分類器との比較なども今後の課題として挙げられる。