論文

進化的条件判断ネットワーク EDEN による画像分類

Image Classification using Evolutionary Decision Network

中山 史朗[†], 穂積 知佐[†], 矢田 紀子^{††}, 正会員 長尾 智晴[†]Shiro Nakayama[†], Chisa Hozumi[†], Noriko Yata^{††} and Tomoharu Nagao[†]

Abstract Many methods that construct image classification algorithms automatically using evolutionary computation have been studied. Although these classifiers are very effective, several problems have been pointed out. For example, it is difficult to analyze or modify classifiers, and they are too complicated for humans to understand. In this paper, we propose a new method for classification using an evolutionary decision network (EDEN) that emphasizes good human-readability. EDEN automatically constructs an adequate network for classification by combining simple nodes using evolutionary computation. This network is composed of a set of nodes that changes the branches of the decision flow in accordance with the feature values of the input data. We build an effective classifier by optimizing a set of nodes and their threshold values for branching. In experiments, we evaluate EDEN by applying it to image classification problems. The experimental results show EDEN is able to build an effective classifier with a human-readable structure and achieve satisfactory performance.

キーワード：画像認識, 決定木, 進化計算法

1. ま え が き

近年、画像を扱う機会が増えたことで、計算機による画像認識・分類に対するニーズがより一層高まっている。一般に、デジタル画像には多種多様な物体が存在する。さらに、角度や照明などの変化によって見え方が変わるため、計算機によってすべての画像を自動的に認識・分類することは大変困難である。そこでそれらに対応するため、精度の高い画像特徴量および識別器を生成するための研究が盛んに行われており、さまざまなアプローチがなされている。しかし、これらの手法の多くで得られる識別器や特徴量が複雑になり、認識・分類の根拠を人間が理解することは大変困難である。本論文では、分類の処理過程のわかりやすさという観点から、可読性の高い構造での分類器の自動生成に重点を置いた手法である進化的条件判断ネットワーク (Evolutionary Decision Network; EDEN^{*1)2)}) を提案す

る。EDEN は、単純な条件判断を行うノードを進化計算法によってネットワーク状に構築し、入力したデータの分類を行う手法である。EDEN の各ノードでは、単一の特徴の大きさによる分岐だけを行うが、分岐に用いる特徴量とその分岐の基準、およびそれらの組合せを最適化することで、目的の分類を行う構造を自動獲得することを目指す。ネットワーク構造を用いる利点としては、決定木がもつ木構造と比較して、よりシンプルな構造を獲得することができるが挙げられる。さらに、分類を行う対象データに加えて、関連するデータを別の入力ノードからそれぞれ入力することで、より複雑なネットワークの処理を表現することができる。

本論文では、一般的な画像から車が存在する領域を判定する実験を行い、提案手法の性能を検証する。

2. 従 来 研 究

2.1 画像認識およびパターン分類に関する手法

近年、進化計算法を用いた事例ベース学習によって、認識器や用いる特徴量などを問題ごとに最適化することで、対象とする問題に適応した認識アルゴリズムを生成する研究がさかんに行われており、様々な手法が提案されている。そのような手法のひとつとして、Support Vector Machine (SVM) による分類に用いる特徴量の組合せを、あらかじめ用意した多数の特徴量の中から遺伝的アルゴリズム (Genetic Algorithm; GA) によって最適化する手法³⁾が挙げられる。この手法では、GA を用いることで対象の問題に適

2013年1月7日受付, 2013年4月27日再受付, 2013年5月23日採録

[†] 横浜国立大学 大学院環境情報学府

(〒 240-8501 神奈川県横浜市保土ヶ谷区常盤台 79-7, TEL 045-339-4131)

^{††} 千葉大学 大学院融合科学研究科

(〒 263-8522 千葉県千葉市稲毛区弥生町 1-33, TEL 043-290-3293)

[†] Graduate School of Environment and Information Sciences, Yokohama National University

(79-7, Tokiwadai, Hodogaya-ku, Yokohama-shi, Kanagawa 240-8501)

^{††} Graduate School of Advanced Integration Science, Chiba University

(1-33, Yayoicho, Inage-ku, Chiba-shi, Chiba 263-8522)

* 特願 2010-2217177

した特徴量を選択して用いることができる。

進化計算法を用いた別の画像分類手法として、画像分類アルゴリズムを自動的に構築する手法である Genetic Image Network for Image Classification (GIN-IC)⁴⁾⁵⁾が提案されている。GIN-IC では、特徴量だけを最適化対象とするのではなく、前処理としての画像変換と、特徴量の算出、演算などの分類手法も含めて最適化を行う。GIN-IC では、処理の内容と手順はノードの処理内容と接続関係で決定され、用いるノードの処理内容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。特徴量抽出の前処理として画像変換を行うことで特徴量を強調・生成することができ、用意した特徴量だけでは、分類が困難な問題にも適用することができるという利点がある。

以上に述べた手法では、それぞれ有効性が示されている一方で、分類のための構造が複雑になり、認識・分類の根拠を示すことは難しく、人間には理解しづらいものになるという欠点がある。特に、医用画像認識や自動製品検査など、対象となる問題によっては利用者が納得することができるような分類の根拠の提示や、専門家の判定基準を取り入れることが求められる場合があり、実際に使用する際にはそれらを考慮した可読性のある手法が必要である。

2.2 決定木

可読性に重点を置いている分類手法のひとつとして、木構造で分類を行う決定木が挙げられる。決定木の中間ノードでは、対象の属性値を参照して分岐先を決定する。また、葉ノードは対象が属するクラスに対応しており、入力データは分岐によって到達したノードが表すクラスに分類される。決定木を学習するためのアルゴリズムとしては、C4.5⁶⁾が代表的である。C4.5 は空の決定木から始めて、データ集合のエントロピーを減少させるように、ノードを付け加えていくことで徐々に精密化していく。その後、データの信頼度による枝刈りを行うことで、より汎用的な決定木の構築を目指す。決定木は属性値による判定を繰り返すことで分類先を決定するため、可読性の高い構造であるといわれている。しかし、学習データを正確に分類することはできるが、一般的に未知データに対しては精度が下がってしまうという性質がある。近年では、Bagging⁷⁾や Adaboost⁸⁾などのアンサンブル学習法における弱識別器として、分類精度を向上させるために用いられる⁹⁾¹⁰⁾ことが一般的である。しかし、このようなアンサンブル学習法では、弱識別器が複雑に組合さるために、決定木のもつ可読性を活かしているとはいえない。また、近年では進化計算法を用いて木構造を最適化することで、分類器を構築する手法も多く提案されており、進化計算法を用いた手法では、C4.5 のような帰納的に木構造を構築する手法と比べて、ロバスト性のある分類器を構築することができるという利点がある¹¹⁾。しかし、決定木のような表現方法では、同じ部分構造の再利用をすることができないため、冗長な部分構造が表れることで木構造が大きくなり、可読性が低下する場合がある。

図1 EDEN の表現型
Example of a phenotype in EDEN.

以上のように、従来手法によって構築される識別器は精度が高い反面、認識・分類の根拠の示しやすさに重点を置いた手法は少ない。特に、決定木のように単純な条件分岐を行う分類器は処理過程を示すことができるが、精度を高めるためにはノード数が多くなり、可読性は低くなってしまいうため、精度と可読性は一般的にトレードオフの関係である。

以降では、この問題に対して可読性が高い構造での分類器の自動生成に重点を置いた分類手法である進化的条件判断ネットワーク（Evolutionary Decision Network; EDEN）について述べる。従来手法では、判定対象のデータだけを分類器に適用することで、分類を行うが、EDENでは対象データに関連するデータを別の入力ノードから入力する多入力のネットワーク構造を用いることで、可読性が高い構造での分類器を獲得することを目指す。

3. 進化的条件判断ネットワーク（EDEN）

EDEN は、決定木のような単純な条件判断を行うノードを進化計算法によってネットワーク状に構築し、入力したデータの分類を行う手法である。各ノードでは、単一の特徴の値による分岐だけを行うが、分岐に用いる特徴量とその分岐の基準、およびそれらの組合せを最適化することで目的の分類を行う構造を自動獲得する。本手法で用いるネットワーク構造は決定木の木構造を包含しており、処理フローを再利用することで、木構造と比べてノード数が少なく、判定の過程を示すことができるという点で可読性のある構造を獲得することができるという利点がある。さらに3.3で述べるように、判定対象データに加えて参照データを入力することによって、ネットワークの処理を変更することができる。

3.1 EDEN の構造

EDEN の表現型の構造を図1に、それに対応する遺伝子型の例と図1中のNo.3, No.4, No.5のノードに注目した場合の染色体の例を図2に示す。EDENでは表現型であるフィードフォワード型のネットワーク構造を、遺伝子型と

図 2 EDEN の遺伝子型と染色体
Example of a genotype in EDEN.

して 1 次元の文字列に変換し、その文字列に対して遺伝操作を施す。染色体では、ノードの判定内容と出力先、およびそのノードのパラメータ値を保持している。ここで、図 2 の各ノードの判定内容は、ノードの種類と用いる特徴量で構成されており、図中図 1 の表現型におけるノードの種類、特徴量 ID にそれぞれ対応している。ノードの出力数はその種類によって一意に決まっており、ノードが n 出力である場合は、 $n+1$ 番目以降の出力先と n 番目以降のパラメータ値は無視される。なお、図 1 は $n=2$ の場合である。また、パラメータ値は、各ノードの判定内容によって用いられ方が異なる。EDEN で用いるノードは、大きく分けて入力ノード、中間ノード、出力ノードの 3 種類である。入力ノードは、入力するデータである特徴量ベクトルに対応する。入力ノードには、分類対象データの入力ノードと、分類対象データに関連する参照データの入力ノードが含まれる。各中間ノードではひとつの特徴量について、閾値による分岐など、ノードごとに決められた判定内容によって分岐を行う。ここで、図 1 において、EDEN を画像分類に適用した例として中間ノードの種類について説明する。入力するデータは、画像をブロック分割し、各ブロックから算出した特徴量ベクトルとする。特徴値比較ノードでは、入力された特徴量ベクトルのうち注目する特徴量について、ノードに設定されたパラメータ値との比較を行い、分岐先のノードを決定する。局所特徴比較ノードでは、入力された特徴量ベクトルのうち注目する特徴量について、局所特徴量との比較を行い、分岐先のノードを決定する。ここで、4 章の実験では、局所特徴量として参照データである隣接するブロックの特徴量値を用いている。大局特徴比較ノードでは、入力された特徴量ベクトルのうち注目する特徴量について、画像全体の特徴量値との比較を行い、分岐先のノードを決定する。出力ノードは分類先のクラスにそれぞれ対応している。出力ノードを分類問題のクラスの数だけ用意することで、多値分類問題へ適用することができる。

入力ノードから入力されたデータは、各中間ノードの分岐条件によって出力先のノードを決定され、最終的に到達した出力ノードが表すクラスに分類される。EDEN では、これらの処理過程を進化計算法を用いて自動的に構築する。入力ノード数、中間ノードの最大数、出力ノード数は固定であり、各個体の遺伝子は固定長の文字列で表現される。接続の状態次第では、使用されるノードとして表現型に現れるノードと、遺伝子として値は保持しているが使用されずに表現型に現れないノードがあるため、表現上はノード数は可変となる。また、中間ノードの最大数をあらかじめ指定することで、ネットワークの最大の大きさを制限し、可読性の高い構造を得ることができる。

3.2 EDEN の遺伝操作と世代交代モデル

まず、EDEN の世代交代モデルについて述べる。EDEN の世代交代モデルには進化戦略の $(1+4)ES^{12)}$ を用いている。 $(1+4)ES$ は提案手法と似たネットワーク構造をもつ Cartesian Genetic Programming (CGP)¹³⁾ や GIN-IC⁴⁾⁵⁾ にも用いられ、実験的にその有効性が示されている。

EDEN の世代交代は次のように行われる。

- Step 1:** 初期個体をランダムに 1 つ生成し、親個体 M として評価値を計算する。
- Step 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_i ($i = 1, 2, 3, 4$) としてそれぞれ評価値を計算する。
- Step 3:** 全個体の集合 $M + C_i$ から評価値が最も高い個体を選び、 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。また、最大評価値となる子個体が複数あった場合は、先に評価した個体を優先して選択する。
- Step 4:** 終了条件を満たす場合は終了する。そうでなければ Step 2 に戻る。

また、遺伝操作には突然変異だけを用いている。この遺伝操作は関連研究のグラフ構造における進化計算法⁴⁾⁵⁾ で用いられており、予備実験によって有効性が確認できたため決定した。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や出力先、パラメータ値を一様乱数で変更する。具体的には、入力ノードでは出力先ノードに対して突然変異が行われる。中間ノードでは判定内容の種類、特徴量 ID、出力数、出力先ノード、パラメータ値、発火した場合のパラメータ値、および比較元となる参照データに対して突然変異が行われる。ここで、各ノードにはあらかじめ番号が割り当てられており、入力ノード、中間ノード、出力ノードの順に番号が割り当てられる。EDEN では、フィードフォワード構造の制約を満たすために、出力先として選択できるノードを自分の番号より大きい番号に制限している。この制約によって、各個体が表現するネットワークは、入力ノードの出力先は、最終的に必ず出力ノードに到達する。

EDEN 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。Step3 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ことで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。

3.3 参照データと発火状態

EDEN では、分類を行う対象データに加え、参照データとして対象データに関連するデータを別の入力ノードからそれぞれ入力することで、ひとつのノードで複数の分岐条件を表現することができる。

画像分類問題について、分類を行う対象データがある領域であった場合、その周辺の領域を参照データとして用いることや、動画であった場合、別のフレームの特徴量を参照データとして用いることが考えられる。4 章の画像分類実験では、判定を行う対象である画像ブロックの上下左右に隣接する 4 つの画像ブロックを用いている。なお、参照データとしては、適用問題に応じて適した参照データを入力することができ、今後有効な参照データの用い方について検討の余地がある。参照データが通ったノードは発火状態となり、発火しない場合とは異なる処理が行われる。なお本論文では、発火状態の処理の変更を、判定に用いるパラメータ値の変更とする。この処理は図 2 に示すように、染色体に通常のパラメータ値とは別に発火後のパラメータ値を保持しておくことで実現する。処理の流れとしては、はじめに参照データの入力ノードから、参照データをネットワークに入力し、その経路上に存在するノードを発火状態にする。そして、すべての参照データを入力し終わった後に、対象データを対象データの入力ノードから入力して分類を行う。発火による処理の変更がない場合と発火による処理の変更がある場合の例を図 3 に示す。ここでは、画像中の革製品に付いたキズの有無を判定するネットワークを例に用いる。画像はブロックに分割し、判定対象には画像を 3×3 のブロックに分割したもの、参照データは判定対象ブロックのひとつ上のブロックとし、各ブロックから算出した特徴量ベクトルを入力する。特徴量は階調値についての統計量である。図中の発火による処理の変更がある場合では、中央値について分岐する中間ノードで発火による処理の変更が行われている。具体的には分岐の際の閾値が 140 から 130 に変更されている。このようにひとつのノードが表す分岐条件が、発火状態によって変更されることで、少ないノード数でも、参照データの影響によって異なる分岐条件の表現ができるようになる。また、参照データを用いることで、対象データだけでは判定が困難なデータに対しても、判定することができるようになることを期待する。

4. 画像分類実験

本章では、画像の分類実験によって提案手法の有効性を検証する。判定の処理過程を示すための可読性の高い構造での分類器は、医用画像認識や製品検査などの特定の分野

図 3 発火による処理の変更の例
Example of changing parameters by firing nodes.

において求められる場合がある。しかし医用画像の入手は困難であるため、本実験では実画像から車両が存在する部分の検出問題に提案手法を適用する。

4.1 実画像を用いた分類実験

実画像を用いた分類実験では、ベンチマーク問題のひとつである Graz-02 データセット*を使用した。画像をブロックに分割し、提案手法を適用して各ブロックが車クラスか背景クラスかに分類する。この画像セットは、写り込んでいる車の大きさ、種類、向きなどが統一されていないため、分類問題としての難易度は非常に高い。実験には、画像サイズが横 640×縦 480[pixel] のものを学習、および未知画像としてそれぞれ 150 枚を用いた。ブロック分割数は、1 枚の画像に対して 8×8 としたので、1 ブロックあたり横 80×縦 60[pixel] であり、分類対象となるブロック数は学習、および未知でそれぞれ 9600 ブロックである。また、Graz-02 データセットには正解画像が用意されており、正解画像における車領域がブロック内に 1 画素でも存在すれば車クラス、そうでない場合は背景クラスとした。クラスの内訳は学習用データの車クラスが 1872 ブロック、背景クラスが 7728 ブロックであり、未知データの車クラスが 2187 ブロック、背景クラスが 7413 ブロックとなった。画像分類実験で用いた提案手法の設定を表 1 に示す。ここで、突然変異率の値については、試行実験を行い最も結果の良好な値を採用した。また、入力ノード数は判定対象である注目ブロックと参照入力数の合計である。本実験では、判定を行う対象

* http://www.emt.tugraz.at/~pinz/data/GRAZ_02/

表 1 車両の分類実験で用いた提案手法の設定
Parameters of EDEN.

世代交代モデル	(1+4)ES
遺伝操作	突然変異
世代数	1,000,000
突然変異率	0.02
入力ノード数	5
最大中間ノード数	100
出力ノード数	2
分割数	8 × 8

である注目ブロックの上下左右に隣接する 4 ブロックを参照データとして用いた。なお、注目ブロックが画像の端などであり、上下左右の 4 ブロックが画像外に当たる場合は、そのブロックは参照データとして用いない。

中間ノードとしては、出力先のノードを決定する際の比較対象として用いる参照値を 3 種類、判定方法を 2 種類用意したため、これらの組合せで、中間ノードとして 6 種類の分岐を行うことができる。参照値として使用した値は次の 3 種類である。

- 遺伝子のパラメータ値 (パラメータ値)
- 4 近傍ブロック (上下左右) から抽出した特徴量 (局所特徴量)

● 画像全体から抽出した特徴量 (大局特徴量)
ここで特徴量としては、6 種類の色成分 (RGB, $L^*a^*b^*$) に対して 11 種類の統計量を計算した色特徴 66 種類と、輝度値の勾配の方向や強さに関する勾配特徴 8 種類の合計 74 種類を用いた。

色特徴に用いた統計量は、平均値、最大値、最小値、標準偏差、最大値と最小値の差、 1σ 内確率、 3σ 外確率、第 1 四分位数、中央値、第 3 四分位数、最頻値の 11 種類である。勾配特徴としては、画像の輝度値に対して Sobel フィルタを適用し、次のような勾配の方向と強度それぞれに関する特徴量を用いた。方向に関する特徴量としては、次の 3 種類を用いた。

- 画像中に存在する勾配方向の数
- 勾配強度が最大の勾配方向から $\pm 90^\circ$ の勾配方向をもつ画素の割合
- 全画素の 50% の画素を含む、勾配強度が最大の勾配方向からの角度

強度に関する特徴量としては、勾配強度の平均値、最大値、最小値、標準偏差、最大値と最小値の差の 5 種類である。

また、判定方法には次の 2 種類を用いた。

- 参照値を閾値として特徴量の大小で分岐
- 参照値 $\pm d$ に収まっているかどうかで分岐

ここで d は参照値からの幅を表しており、遺伝子の染色体であるパラメータ値である。出力数としては、遺伝子のパラメータ値を用いて閾値による分岐を行う場合だけ 2, 3, 4 のいずれかを選択することができるものとし、他の組合せについてはすべて 2 出力とした。出力ノードは分類先のクラスにそれぞれ対応しており、車クラスと背景クラスを

表 2 車両分類の各クラスの正答率 [%]
Discrimination rate in the experiment.

	C4.5		EDEN		EDEN (偏りあり)	
	学習	未知	学習	未知	学習	未知
車	96.9	59.7	50.4	51.8	83.4	82.1
背景	99.4	87.0	97.0	91.2	78.8	74.2
全体	98.8	80.7	87.9	82.2	79.7	76.0

表す。

提案手法におけるネットワークを構築する際の評価関数について、車クラスと背景クラスのブロック数の偏りを考慮しない場合の F_1 を式 1 に、偏りを考慮し重みづけを行った場合の F_2 を式 2 に示す。これは、車ブロック数の方が背景ブロック数より少ないため、学習に偏りが生じないように、同等に扱われるような重みづけをすることを目的としている。

$$F_1 = \Sigma N_c + \Sigma N_b + \frac{1}{N_e} \quad (1)$$

$$F_2 = \left[\frac{N_B}{N_C} \right] \Sigma N_c + \Sigma N_b + \frac{1}{N_e} \quad (2)$$

ここで、 N_c は正しく分類された車クラスのブロック数であり、 N_b は正しく分類された背景クラスのブロック数である。 N_C は教師画像での車クラスの総ブロック数、 N_B は教師画像での背景クラスの総ブロック数である。 N_e はネットワークで実際に使用されているノード間の接続エッジの本数である。これらの評価関数では正答数が多いほど良い評価となり、正答数が同じ場合には N_e が少ない単純なネットワークであるほど良い評価となる。このように、提案手法では、評価関数にネットワークの大きさに関する指標を用いることで、ノードが少なく可読性の高い分類器を構築する。

比較手法としては、決定木を構築するアルゴリズムである C4.5 を用いて同様の実験を行う。本論文では、オープンソースソフトウェアである Weka (ver. 3.6.4)* を使用した。パラメータは信頼度 0.25、葉ノードにおける最小データ数 2 を採用した。比較手法である C4.5 に用いた特徴量として、EDEN の分岐条件と同等の特徴量を利用するために 1480 種類の特徴量を用意した。具体的には、EDEN で用いた 74 種類の特徴量に加え、それらの特徴量と特徴量の値域を 10 等分した定数との絶対値差分 $74 \times 9 = 666$ 種類と、画像全体および注目ブロックの上下左右に隣接する 4 ブロックとの差分、絶対値差分の $5 \times 2 \times 74 = 740$ 種類の計 1480 種類である。

4.2 実験結果と考察

学習画像および未知画像に対する分類結果を、比較手法である C4.5 による結果と比較して表 2 と表 3 に示す。ここで、EDEN の結果は 5 回試行の平均であり、評価関数においてデータの偏りを考慮していない場合と考慮した場合

* <http://www.cs.waikato.ac.nz/ml/weka/>

表 3 車両分類の適合率と再現率
Precision and recall in the experiment.

	C4.5		EDEN		EDEN (偏りあり)	
	学習	未知	学習	未知	学習	未知
Precision	0.976	0.574	0.803	0.635	0.488	0.484
Recall	0.969	0.597	0.504	0.518	0.834	0.821
F-measure	0.968	0.585	0.619	0.570	0.616	0.609

表 4 各ノードについて通ったデータに対して発火処理が行われた割合
Frequency of changing the node parameters by firing nodes.

ノード番号	学習	未知
No.1	0.040	0.043
No.2	0.213	0.215
No.3	0.481	0.478
No.4	0.080	0.091
No.5	0.221	0.328
No.6	0.701	0.735
No.7	0.455	0.537

表 5 発火処理の有無についての比較
Comparison of with and without changing the node parameters by firing nodes.

	発火処理あり		発火処理なし	
	学習	未知	学習	未知
Precision	0.524	0.517	0.671	0.755
Recall	0.799	0.808	0.331	0.522
F-measure	0.633	0.630	0.443	0.617

(偏りあり)の両方の結果を示している。
学習の結果としては、評価関数でデータの偏りを考慮することで、データが少ない車クラスの分類精度が背景クラスと同程度になることを確認した。しかし、学習データ全

体に対する分類精度としては C4.5 の方が良い結果を示している。これは、C4.5 が各ノードでエントロピーが減少するように、決定論的に木を構築する一方、EDEN では、最終的な分類の正誤とエッジの本数を考慮して、発見的にネットワークを構築することに起因している。そのため、分類が困難なデータセットに対しては、学習時には C4.5 の方が良い精度を示すことになる。一方で得られた構造を見ると、C4.5 では 863 個のノードが使用されているのに対し、EDEN では、参照入力と接続されたノードと判定対象と接続されたノードだけを合わせると 56 個のノード、判定対象と接続されたノードだけに注目すると 10 ノードと非常にコンパクトな構造が得られた。このことは、分類の処理過程を示す上で大きな利点があるといえる。
EDEN (偏りあり)によって構築されたネットワークを図 4 に示す。なお、ここでは参照入力だけに接続しているノードは省略し、対象ブロックの判定に直接用いられるネットワークを示している。また、表 4 に、図 4 の構造の各ノードに対して、発火によって分岐の処理が変更されたデータの割合を示す。すべてのノードが参照データによって発火しており、発火した割合が高いノードも見られ、EDEN の発火処理が有効に働いていることがわかる。このことから、より複雑な問題に対しても、同様に発火による分岐処理の変更を行うノードが多く表れることで、ノード数を抑えた可読性の高い分類構造を獲得することが期待できる。
また、EDEN における参照データの有効性を確認するために、獲得したネットワークについて、発火処理によるパ

図 5 学習画像に対する結果の例
Examples of results for train images.

図 6 未知画像に対する結果の例
Examples of results for unknown images.

表 6 ノードのパラメータ d を変更したときの分類結果
Precision and recall for test images by change of the node parameter d .

	変更前	変更後
Precision	0.467	0.616
Recall	0.808	0.626
F-measure	0.592	0.621

ラメータの変更を行わない場合との比較を表 5 に示す。参照データを用いて分岐処理の変更を行った場合の方が、参照データによる発火を考慮しない場合よりも良い精度を示した。これは、参照データを用いた発火による分岐処理の変更が分類の際に有効であったためと考えられる。

これらのことから、EDEN では、決定木と比べてノード数を抑えつつ精度の高い分類器を獲得することができたといえる。

また、EDEN では C4.5 と比較して学習と未知の正答率に大きな差がないことを確認することができた。これは、C4.5 では学習データを過分割するために、未知データのわずかな違いに対応することができなかったと考えられる。これに対して EDEN では、参照入力によるノードの分岐基準の変更によって、少ないノード数でも決定木と比べてより複雑な分岐を表現することができ、過分割を回避することで、未知データに対しても学習時と同程度の精度を保った分類を行うことができたと考えられる。

図 7 ノードのパラメータ d を変更したときの結果の例
Results of test images by change of the node parameter d .

ここで、得られた結果について解析を行う。EDEN（偏りあり）について、学習用画像に対する分類結果を示した例を図 5 に、検証用画像に対する分類結果を示した例を図 6 に示す。ここで、矩形の枠で囲まれた部分が車クラスと判定されたブロックである。また、誤分類したブロックは×印で示し、正しく分類したブロックは○印で示した。上段の結果のように、EDEN による分類では大まかに道路と車との切り分けを行うことができているといえる。しかし下段の結果のように、木や手すりなど特徴的な色またはエッジをもつ物体を過検出する場合が多く見受けられ、それによって背景クラスの分類精度が低くなってしまっていた。

そこで、これらの考察から、進化計算法によって得られたネットワークの一部を人手で変更し、過検出を抑えることができるかどうかを確認する。図 4 に示したネットワークにおいて、A のノードのパラメータを変更する。このノードは最も過検出が多いパスが最後に通るノードであり、背景と判定される特徴量の範囲 d が比較的広く設定されていた。そのため、参照データによる発火が起きない場合のパラメータ d を約 4 分の 1 にすることで過検出の抑制を図る。ノードのパラメータを変更する前後の正答率を表 6 に示し、パラメータを変更した後の分類結果を示した例を図 7 に示す。車クラスに分類されていた木などの特徴的なエッジが存在する領域の多くが、正しく背景クラスと判定されるようになった。一方で、図 7 における右上の画像のように、大きく写りこんでいる車の内側のブロックが背景クラスに誤分類される傾向も見受けられた。

以上のことから、EDEN では、処理フローを追いやすく、可読性の高い構造を獲得することができるとともに、ノードに対するパラメータを変更し微調整することで、目的とする処理に合わせて分類器を人手での調整を行うことができたことを確認することができた。

5. ま と め

本論文では、分類の処理過程のわかりやすさという観点から、可読性に重点を置いた手法である進化的条件判断ネッ

トワーク (EDEN) を提案した。EDEN では、単一の特徴量の大きさに着目した分岐だけを行うノードを組合せて分類処理を進化計算法によって最適化することで、目的の分類を行う構造を獲得することができた。ネットワーク構造を用いることで、決定木と比較してよりシンプルな構造を獲得することができることを確認した。また、分類対象のデータの他に、参照データを入力することで、少ないノード数でも複雑な分岐処理を表現することができた。今後の課題としては、遺伝操作における有効な交叉の方法についての検討や、精度を保ちつつ可読性を高める方法の検討、画像特徴量などの検討を行うことが挙げられる。また、本論文ではノードのパラメータによって調整を行ったが、ノードの追加を行ったり、データが通ったパスによって分岐を変更したりするなど、さらに詳細な解析を行うことが必要である。さらに、EDEN はあらゆる多次元ベクトルの分類に有効であるため、画像分類以外にも応用して性能を評価する予定である。

〔文 献〕

- 1) 中山史朗, 穂積知佐, 矢田紀子, 長尾智晴: “進化的条件判断ネットワーク EDEN による画像分類”, 計測自動制御学会 第 38 回知能システムシンポジウム (2011)
- 2) 穂積知佐, 長尾智晴: “進化的条件判断ネットワーク EDEN の提案”, 第 7 回進化計算フロンティア研究会 第 1 回進化計算学会研究会合同研究会 (2011)
- 3) 余部治昭, 長尾智晴: “特徴量選択型 SVM を用いた欠陥画像分類”, FIT2006 第 5 回情報科学技術フォーラム (2006)
- 4) 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, **25**, 2, pp. 262–271 (2010)
- 5) S. Shirakawa, S. Nakayama, and T. 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), **5484 of LNCS**, pp. 395–404 (2009)
- 6) J. R. Quinlan: “Improved Use of Continuous Attributes in C4.5”, Journal of Artificial Intelligence Research, **4**, pp. 77–90 (1996)
- 7) L. Breiman: “Bagging Predictors”, Machine Learning, **24**, pp. 123–140 (1996)
- 8) Y. フロインド, R. シャピリ, 安倍直樹: “ブースティング入門”, 人工知能学会誌, **14**, 5, pp. 771–780 (1999)
- 9) Y. Freund and R. E. Schapire: “Experiments with a New Boosting Algorithm”, In Machine Learning: Proceedings of 13th International Conference (ICML-96), pp. 148–156 (1996)
- 10) J. R. Quinlan: “Bagging, Boosting and C4.5”, Proceedings of the 13th national conference on artificial intelligence, (1996)
- 11) R. C. Barros, M. P. Basgalupp, A. C. P. L. F. De Carvalho, and A. A. Freitas: “A Survey of Evolutionary Algorithms for Decision-Tree Induction”, IEEE Transactions on Systems, Man and Cybernetics, Part C: Applications and Reviews, **42**, 3, pp. 291–312 (2012)
- 12) I. Rechenberg: “Evolutionstrategie: Optimierung technischer Systeme nach Prinzipien der biologischen Evolution”, Frommann-Holzboog Verlag, Stuttgart (1973)
- 13) J. F. Miller, and P. Thomson: “Cartesian Genetic Programming”, Proceedings of the Third European Conference on Genetic Programming (EuroGP2000), **1802 of LNCS**, pp. 121–132 (2000)

なかやま しろう
中山 史朗 2009 年, 横浜国立大学工学部電子情報工学科卒業。2011 年, 同大学大学院環境情報学府情報メディア環境学専攻博士課程前期修了。在学中, 画像処理, パターン認識, 進化計算法等の研究に従事。

ほづみ ちさ
穂積 知佐 2011 年, 横浜国立大学工学部電子情報工学科を飛び級のために中退。現在, 同大学大学院環境情報学府情報メディア環境学専攻博士課程前期在学中。画像処理, パターン認識, 進化計算法等の研究に従事。

や た のりこ
矢田 紀子 2008 年, 横浜国立大学大学院環境情報学府情報メディア環境学専攻博士課程後期修了。同年, 同大学大学院環境情報研究院特任教員 (研究教員)。2011 年, 千葉大学大学院融合科学研究科助教, 現在に至る。博士 (工学)。画像認識, 進化計算法, 視覚情報処理, 神経回路網等の研究に従事。

ながお ともはる
長尾 智晴 1985 年, 東京工業大学大学院博士課程後期課程中退。同年, 同大学工学部付属画像情報工学研究施設助手。同大学工学部助教授を経て, 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。工学博士。画像処理, 進化計算法, 神経回路網, 分散人工知能等の研究に従事。正会員。