

# 進化的条件判断ネットワークの画像分類過程の可視化

小林 雅幸<sup>1,a)</sup> 菅沼 雅徳<sup>1</sup> 崎津 実穂<sup>1</sup> 長尾 智晴<sup>1</sup>

## 概要：

近年、機械学習を用いた画像分類器の自動構築のニーズが高まっており、様々な研究が行われている。多くの研究で分類精度の向上が試みられてきた一方、その分類過程はブラックボックス化されており、分類がどのように行われているのかを利用者が理解できないといった問題がある。また、計算機で構築した画像分類器を産業応用などで活用する際、分類器の説明責任を果たす必要がある。先に筆者らの研究グループでは、決定木や進化的条件判断ネットワークなどの if-then ルールを用いた分類器の分類過程を文章で説明する手法を提案し、分類過程の説明においてその有効性を示してきた。しかし、この手法ではあらかじめ定義した特徴量やしきい値に関する辞書を参照し、語句に変換することで説明文を生成するが、対応する語句への変換が困難である特徴量を用いた分類器の説明では説明文の可読性が低下してしまう。そこで本論文では、分類に用いられている特徴量分布の可視化を行うことで、これまで対応付けが困難であった特徴量を含む分類過程の説明を行う手法を提案する。提案手法を一般画像の分類問題に適用し、分類過程を可視化をすることの有効性を確認した。

キーワード：分類過程の解析、画像分類、機械学習、進化計算法、進化的条件判断ネットワーク

## Visualizing Evolutionary Decision Network Process for Image Classification

MASAYUKI KOBAYASHI<sup>1,a)</sup> MASANORI SUGANUMA<sup>1</sup> MIHO SAKITSU<sup>1</sup> TOMOHARU NAGAO<sup>1</sup>

### Abstract:

In recent years, machine learning techniques have been developed for image classification. While many techniques have contributed to achieve better performance on various tasks, their models are blackbox and their interpretations are effortful. On the other hand, for some application it is important to make it clear why and how they work. We previously proposed a method for generating simple natural language descriptions from decision trees and decision networks using the if-then rules. However, some features are hard to understand and analysis of classification tends to be difficult. In this paper, we introduce a visualization technique which displays the feature distribution to provide us insight into image classifications. It allows us to gain a better understanding of classifiers and intuitive interpretations. We trained the image classifiers on several benchmarks and generated visualizations. We found the visualizations obtained intuitive and our method is efficient.

**Keywords:** analysis of image classification, image classification, machine learning, evolutionary computing, evolutionary decision network

## 1. はじめに

近年、深層学習をはじめとした機械学習による画像分類器の自動構築のニーズが高まっており、様々な研究が行われている。これらの分類器は工業製品のキズ検出や医用画

<sup>1</sup> 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, Yokohama, Kanagawa, 240-  
8501, Japan

<sup>a)</sup> kobayashi-masayuki-xc@ynu.jp

像分類など、産業応用の現場で活用されることが期待されている。しかし、これまでは分類精度の向上が重要視され、構築された分類器を使用する立場になった研究はあまり行われていなかった。実際の産業応用の現場では分類の根拠や分類過程の提示など、構築した分類器の説明責任を果たす必要がある。このため、機械学習で構築した分類器が今後社会で安心して活用されるためには、分類器の分類精度だけでなく、分類がどのように行われているかということ人間が容易に理解できるようにする必要がある。

分類器の中でも比較的人間が理解しやすい手法として、if-then ルールを用いて分類を行う決定木が挙げられる。決定木を用いた画像分類では、入力画像から算出された特徴量を決定木に入力し、各中間ノードで特徴量の大きさから条件分岐を行い、最終的に到達した終端ノードが表すクラスに分類を行う木構造の分類器である。これに対して、筆者らの研究グループでは決定木を拡張し、高精度かつコンパクトで可読性の高い構造の分類手法として、進化的条件判断ネットワーク (Evolutionary Decision Network; EDEN) \*1[1] を提案している。EDEN は判定領域および判定対象と関連する領域から算出された特徴量の大きさで分岐を行うノードを進化計算法を用いてネットワーク状に配置する。画像分類実験において C4.5[2] で構築された決定木との比較実験から、EDEN は高精度かつ、決定木と比べてノード数の少ない可読性の高い分類が可能であることが示されている。

これらの分類器を用いて、筆者らの研究グループでは、決定木や進化的条件判断ネットワークなどの if-then ルールを用いた分類器の分類過程を文章で説明する手法 [3] を提案している。この手法では、分類に使用する特徴量やしきい値をあらかじめ定義した辞書を参照し、人間が理解しやすい語句に変換することで分類過程の説明文を自動生成する。分類過程を文章で説明することで、これまでブラックボックスであった分類過程を人間がより理解しやすい形で提示することが可能となった。しかし、この手法では対応する語句への変換が困難である特徴量を用いた分類器の説明では、説明文の可読性が低下してしまうといった課題がある。そこで、さらに説明を分かりやすくし利用者の理解を高めるためには、文章での説明のほか、画像を用いた説明が有効であると考えられる。

これまで、Convolutional Neural Network (CNN) を中心に分類器の内部関数の働きを可視化する研究が行われている [4][5][6]。しかし、これらの研究は CNN の各層の内部関数の働きを可視化し、CNN の構造理解を助ける目的の研究であり、構築された分類器の分類過程を説明し、分類器の信頼性の向上を目的としたものではない。

また、Histograms of Oriented Gradients (HOG) [7] や

Bag of Visual Words[8][9][10] などの高次元の特徴量の可視化という研究も行われている [11][12]。しかし、これらの研究は、高次元な特徴量を視覚的に分かりやすく提示する研究や、分類に有効に効いていると思われる Visual Words を提示することを目的とした研究であり、構築した分類器の分類過程の説明に重点をおいた研究ではない。

筆者らの研究グループが提案している、構築された分類器の分類過程を文章や画像を用いて説明することを目的とした研究は筆者らの知る限りまだなされていない。今後、情報量が増え、人間が機械学習を頼る機会がますます増えた際に、分類器の分類過程を分かりやすく提示し、説明責任を果たすことが構築された分類器の信頼性を高めていくうえで重要になると考える。

そこで本論文では、機械学習で構築された分類器の信頼性の向上を目的とし、進化的条件判断ネットワークの分類過程を画像を用いて説明する手法を提案する。


## 2. 進化的条件判断ネットワークと分類過程の文章化

### 2.1 EDEN

筆者らの研究グループでは、決定木を拡張し、高精度かつコンパクトで可読性の高い構造の分類器である進化的条件判断ネットワーク EDEN を提案している。EDEN は入力画像から算出された特徴量の大きさで分岐を行うノードがネットワーク状に配置された分類器であり、進化計算法を用いて分岐に用いる特徴量とそのしきい値、出力先を最適化することで分類器を獲得する。決定木と同様に、入力ノードに分類対象から算出した特徴量を入力し、中間ノードの条件判断で分岐先を決定する。この操作を出力ノードに到達するまで繰り返し行い、最終的に到達した出力ノードに対応するクラスに分類する。EDEN はフィードフォワード型のネットワーク構造であり、このネットワーク構造を遺伝子型として 1 次元の文字列で表現する。この文字列に対して交叉や突然変異などの遺伝操作を施してネットワーク構造を最適化する。染色体はネットワークの各ノードに対応しており、ノードの種類や比較する特徴量の種類、出力先、しきい値などのパラメータを保持する。

また、EDEN は分類を行う判定対象の入力に加え、判定対象データに関連するデータと画像全体からのデータをそれぞれ参照入力と大局入力として別の入力ノードから入力することで処理の変更を行うことができる。これによって、少ないノード数で高精度な分類を行うことができる。具体的には、EDEN で複雑な処理を行うために中間ノードの発火という状態が提案されている。参照入力を通った中間ノードは発火状態となり、発火していないノードとは異なる処理が行われる。これによって、認識対象の入力だけでなく分類対象の周辺の入力も同時に考慮することができ、それらが相互作用することによって、少ないノード数で複

\*1 特許番号：5548990 号



(a) 参照入力による変更がない場合 (b) 参照入力による変更がある場合  
 図 1 参照入力による処理の変更例

Fig. 1 Non-interacting and interacting operations.

雑なネットワークの処理を表現することが可能となる。発火による処理の変更例を図 1 に示す。この例では、発火状態のノードにおける処理の変更として、分岐で用いるしきい値を変更している。

## 2.2 分類過程の言語化

筆者らの研究グループでは、決定木や EDEN などの if-then ルールを用いた分類器の分類過程を文章で説明する手法を提案している。従来手法ではあらかじめ分類に使用する特徴量やしきい値に対応する語句を定義した辞書を用意しておき、分類に用いた特徴量やしきい値をこの辞書と対応付けすることで説明文を生成する。このとき、分類器の利用者によって求める説明の粒度が異なることが考えられる。そこで、従来手法では生成する説明の粒度を 2 つのパラメータで表す。そして、本論文ではこれらのパラメータで指定した分類過程を説明パスと呼び、このパスに対して説明を生成するものとする。

まず 1 つ目は、説明するパスの数  $S$  である。従来手法では、分類器に入力したデータの中で通過頻度の高いパスほど、分類クラスの表現で重要なパスと考える。そのため、構築した分類器に入力したデータの通過頻度を求め、通過頻度の高いパスから順に  $S$  個のパスについて説明文を生成する。

2 つ目は生成する文章の長さ  $s$  である。C4.5[2] で構築した決定木ではルートノードから情報量が減少するように分岐ノードが配置されるため、ルートノードに近いノードは分類に重要なノードであると考えられる。そのため、説明文を生成する際に、語句に置き換えるルートノードからのノード数  $s$  を指定する。この際、 $s$  を説明パス上の最大ノード数  $\max$  とすることで、ルートノードから出力ノードまですべてのノードを説明する説明文を生成することが可能となる。EDEN は必ずしもルートノードに近いノードほど重要であると一概にいえない場合もあるが、従来手法では決定木と同様にルートノードから順に説明文を生成することとしている。

## 3. 提案手法の概要

本論文では、EDEN の分類過程を画像を用いて説明する



図 2 画像の分類方法

Fig. 2 Images used for the experiments.




図 3 特徴量の算出領域

Fig. 3 Region to calculate the features.

手法を提案する。提案手法では、説明パスに対して、(1) 説明パスのデータ集合の性質を表す領域の可視化、(2) 特徴量の可視化の 2 つの分類過程の可視化手法を提案する。

### 3.1 画像分類方法

本論文では図 2 のように 1 枚の画像からオーバーラップありでパッチを  $M$  枚取得・判定し、それらのパッチの多数決により最も多く判定されたクラスに分類を行った。EDEN の入力ノードは判定対象と参照入力、大局入力の 3 種類から構成されるものとした。そして、図 3 で示すように、画像から取得したパッチを判定対象、判定対象を中心とした縦横 2 倍の領域のうち判定対象を除いた領域を参照入力、画像全体から算出した特徴量を大局入力とした。また、EDEN の条件判断ノードには、2 分岐の条件判断ノードのみを使用した。

### 3.2 説明パスのデータ集合の性質を表す領域の可視化

本手法では、説明パスに対して、説明パスを通過したデータ集合のクラスらしさを表すヒートマップを作成する。本論文では、クラスらしさの度数を説明パスを通過するデータの分布を考慮して算出するものとする。

クラスらしさの算出の流れとしては、はじめに説明パス内の各特徴量について通過するデータ集合に対してクラスタリングを適用する。このときのクラスタリング手法として、データに応じて最適なクラスタ数を自動で推定する x-means 法 [13] を用いる。このとき、構築されたクラスタの中心に近く、データ数の多いクラスタに属するデータほどパスを通過するデータの中で代表的なデータ (クラスらしいデータ) であると考えられることができる。これらのことから本論文では、通過パスの各特徴量における特徴量分布

から、構築された分類器のクラスらしさを算出し、クラスらしさのヒートマップを生成する。

そこで本論文では、パスを通過したデータのクラスらしさは、分類に用いたデータをクラスタリングしてできたクラスタの大きさと中間距離をもとに算出されるものとし、データ  $i$  のクラスらしさ  $p_i$  を式 (1) を用いて算出する。

$$p_i = \frac{1}{N_{node}} \sum_{j=1}^{N_{node}} \left\{ e^{-\frac{z_{ij}^2}{2}} \times \frac{n_{ij}}{n_{max_j}} \right\} \quad (1)$$

ここで、 $N_{node}$  は説明パスのノード数であり、 $n_{ij}$  はノード  $j$  についてデータ  $i$  が属するクラスタのデータ数、 $n_{max_j}$  はノード  $j$  について、属するデータ数が最も多いクラスタのデータ数を表す。 $z_{ij}$  はノード  $j$  について、通過するデータ  $i$  と、データの属するクラスタ  $j$  の中心との中心間距離に関する指標であり、式 (2) で表せる。

$$z_{ij} = \frac{\alpha (c_{ij} - a_{ij})}{\sigma_{ij}} \quad (2)$$

ここで、 $c_{ij}$  はノード  $j$  についてデータ  $i$  が属するクラスタの中心の値、 $a_{ij}$  はデータ  $i$  のノード  $j$  に関する特徴量、 $\sigma_{ij}$  はデータ  $i$  が属するクラスタのノード  $j$  に関するデータの標準偏差を示す。また、 $\alpha$  は利用者の説明の要求度に合わせて変更が可能なパラメータであり、ヒートマップの色付けの変化を表す。 $\alpha$  を小さくするほどヒートマップの変化が激しくなり、クラスらしさが高い領域のみを赤く表示することが可能になる。また、パッチのオーバーラップ部は、重なるパッチ同士のクラスらしさの値の平均とする。ヒートマップはクラスらしさが高いほど赤色に、クラスらしさが低くなるほど青色で表される。これによって、構築された分類器が画像内のどの部分に注目して分類を行っているかを直感的に提示することが可能となる。

### 3.3 特徴量の可視化

本手法では、説明パス中の各特徴量の表現が画像内のどの部分と対応しているかを提示することで分類過程の説明を行う。まず、判定に用いたパッチと同サイズのウィンドウを走査し、画像内のすべての画素について、ある画素に注目した時の特徴量を算出する。この際、画像の縁などでウィンドウがはみ出してしまう場合は、はみ出していない領域のみから特徴量を算出する。そして、説明パス中の分岐条件と対応する特徴量の表現との対応関係を出力する。分岐条件と一致している領域を赤色で示し、反対に分岐条件と一致していない領域を青色で示す。この操作を画像内のすべての画素に適用し、生成された各特徴量の表現と画像内の領域の対応関係を示す特徴量マスクの生成を行う。これによって、説明パス中の各特徴量の分岐条件が画像内のどの領域と対応するものであるかを直感的に提示することが可能となる。

## 4. 画像分類過程の可視化実験

### 4.1 実験概要

提案手法の有効性を検証するために、一般画像の分類問題に提案手法を適用し、EDEN の分類過程の可視化を行った。

EDEN については分類精度を高めると同時に、ネットワークのノード数が少なくなるように適応度を設定し、遺伝的アルゴリズムを用いて最適化した。本実験における EDEN の評価関数を式 (3) に示す。

$$\text{Fitness} = \text{AC} + \beta \times \frac{1}{N_{\text{cond}}} \quad (3)$$

ここで、AC は分類精度 (Accuracy) に関する指標であり、 $N_{\text{cond}}$  は構築されたネットワークのノードの総数である。本実験において、パラメータは  $\beta = 0.001$  とした。AC は、データの総数を  $N$ 、正しく分類されたデータ数を  $N_{\text{correct}}$  とすると、式 (4) で表される。

$$\text{AC} = \frac{N_{\text{correct}}}{N} \quad (4)$$

### 4.2 一般画像分類

一般画像分類として Urban and Natural Scene Categories<sup>\*2</sup>[14] から Coast & Beach と Open Country と Mountain, 102 Category Flower Dataset<sup>\*3</sup>[15] から Common Dandelion と California Poppy と Marigold のそれぞれの 3 クラス分類実験を行い、学習データに対して分類過程の可視化を行った。各クラスはそれぞれ 50 枚を学習データとし、一枚の画像から 125 パッチを取得・判定し、それらパッチの多数決により、最も多く判定されたクラスに分類を行った。

本実験で使用した特徴量は、語句と対応付けられた HSL やエッジに関する特徴量 16 種類と語句での表現が困難な特徴量 34 種類を用いた。本実験で使用した特徴量と語句の対応関係を表 1 に示す。語句での表現が困難な特徴量として ULBP 特徴量 [16] ( $P = 10, R = 2$ ) と、6 種類の色成分 (RGB, L\*a\*b\*) にフィルタ処理 (sobel フィルタ, mean フィルタ) を施してから算出した統計特徴量 (平均, 標準偏差) を用いた。また、各ノードのしきい値に対応する語句はあらかじめ用意する辞書の定義の仕方によって説明の粒度を変更することができるが、本実験では多いか少ないかどうかの 2 種類の表現のみに制限をして説明文を生成、その説明文に対する分類過程の可視化を行った。

このときの EDEN の一般画像分類の学習における分類結果と分類器のノード数を表 2 に示す。これらの分類器に対して分類過程を説明する文章と画像の作成を行った。説明文生成の際のパラメータは  $S = 1, s = \max$  とし、最

<sup>\*2</sup> <http://cvcl.mit.edu/database.htm>

<sup>\*3</sup> <http://www.robots.ox.ac.uk/vgg/data/flowers/102/>

も通過頻度の高いパスについて、ルートノードから順にすべてのノードを語句に置き換えるようにした。また、ヒートマップ作成の際のパラメータは  $\alpha = 1.5$  とした。従来手法を Urban and Natural Scene Categories に適用した時に生成された説明文の例を次に示す。そして、同様に提案手法を適用した時の生成画像を図 4, 図 5 に示す。

- EDEN による Coast & Beach と Open Country と Mountain の分類過程の説明文
  - b\*成分画像に対する sobel フィルタの応答の平均値が大きく、緑色っぽい部分が少ない。また、ULBP3 の割合が少なく、B 成分画像に対する mean フィルタの応答の平均値が大きい。そして、b\*成分画像に対する mean フィルタの応答の標準偏差が小さいため、Coast & Beach である。
  - b\*成分画像に対する sobel フィルタの応答の平均値が大きく、緑色っぽい部分が少ない。また、ULBP3 の割合が少なく、B 成分画像に対する mean フィルタの応答の平均値が大きい。そして、b\*成分画像に対する mean フィルタの応答の標準偏差が大きいため、Mountain である。
  - b\*成分画像に対する sobel フィルタの応答の平均値が小さい、赤色っぽい部分が少ない。また、b\*成分画像に対する mean フィルタの応答の平均値が大きいため、Open Country である。

生成された図 4 のヒートマップを見ると Coast & Beach は海面、Mountain は山肌、Open Country は草木の領域がそれぞれ強く反応している。これらの強く反応している領域は、人間が認識で注目する領域と類似しており、構築した分類器が人間と似た分類判断を行っていることが分かる。また、生成された図 5 の特徴量マスクを見ると、b\*成分画像に sobel フィルタを施した後のパッチ全体の平均値が Open Country の草木の領域への反応に有効に効いていることが分かる。

本実験では語句での表現が困難な ULBP 特徴量などを使用しているため、従来手法で生成される説明文は文章が長くなると同時に、説明文自体の可読性が低く、利用者にとって分かりやすい説明であるとはいえない。これに対して、提案手法を用いて分類器の分類過程の可視化をし、画像として提示を行うことで、分類過程を文章で説明する方法よりも直感的で理解しやすい提示ができていているといえる。これは、クラスらしさを直感的に分かりやすいヒートマップで出力することで、構築された分類器が分類の際に注目している領域を理解することができ、また説明パスの特徴量ごとに対応関係を示す特徴量マスクを提示することで、各特徴量が画像内のどの領域と反応するかが分かるため、どの特徴量がどの程度分類に働いているかが明らかになるためであるからと考えられる。

なお、本実験では画像内のどの領域に分類対象が存在し

表 1 特徴量と語句の対応表

Table 1 Linguistic terms for each feature.

特徴量	対応する語句
$0.0 \leq L < 1.0$ または $0.0 \leq S < 1.0$ の時 :	
L が 0.2 以下の画素の割合	黒色っぽい部分
L が 0.8 以上の画素の割合	白色っぽい部分
それ以外の時 :	
H が $30^\circ$ 未満または $330^\circ$ 以上の画素の割合	赤色っぽい部分
H が $30^\circ$ 以上 $90^\circ$ 未満の画素の割合	黄色っぽい部分
H が $90^\circ$ 以上 $150^\circ$ 未満の画素の割合	緑色っぽい部分
H が $150^\circ$ 以上 $210^\circ$ 未満の画素の割合	水色っぽい部分
H が $210^\circ$ 以上 $270^\circ$ 未満の画素の割合	青色っぽい部分
H が $270^\circ$ 以上 $330^\circ$ 未満の画素の割合	紫色っぽい部分
S の平均	鮮やかさ
L の平均	明るさ
H の標準偏差	色数
S の標準偏差	鮮やかさの差
L の標準偏差	明るさの差
ある程度のエッジ強度があり :	
水平方向 $\pm 10^\circ$ のエッジをもつ画素の割合	横線
垂直方向 $\pm 10^\circ$ のエッジをもつ画素の割合	縦線
斜め方向 $\pm 10^\circ$ のエッジをもつ画素の割合	斜め線

表 2 一般画像分類の正解率 (学習) とノード数

Table 2 The classification accuracy and network size.

	EDEN	
	分類精度	ノード数
Coast & Beach vs. Mountain vs. Open Country	91.7%	15
Dandelion vs. Poppy vs. Marigold	95.6%	14

ているかを領域ごとに正解ラベルを与えるのではなく、画像単位で正解ラベルを与えている。そして、画像内から取得されたパッチ判定の多数決をもとに、分類が行えるように EDEN を学習させているため、分類をする上で本来は使用すべきでない領域に注目して分類を行う EDEN が構築されることもある。具体的な例として Caltech-256<sup>\*4</sup>[17] から、Airplane と Motorbike と Helicopter の 3 クラス分類における Motorbike の可視化を行った結果について考察する。今回の実験の学習では Motorbike のクラスの大半 (45/50 枚) は背景が白い画像を用いた。これらの画像を用いて構築した分類器に提案手法を適用した際、画像の背景部分が主に反応する分類器  $C_{white}$  と分類対象である Motorbike が主に反応する分類器  $C_{\neg white}$  の 2 種類が主に構築される。背景に反応する可視化例と分類対象に反応している可視化例を図 6 に示す。この時、画像の背景部分が主に反応する分類器  $C_{white}$  は分類対象である Motorbike に注目して分類を行っているわけではなく、妥当な分類が行われているということは難しい。これらの分類器に対して、Motorbike の背景に草木などの物体が写っている画像集合を未知画像として適用した時の学習画像と未知画像の再現率を表 3 に示す。表 3 が示すように、分類器  $C_{white}$

<sup>\*4</sup> [http://www.vision.caltech.edu/Image\\_Datasets/Caltech256/](http://www.vision.caltech.edu/Image_Datasets/Caltech256/)






図 4 Urban and Nature のヒートマップによる可視化例  
Fig. 4 Heatmap for EDEN Ttrained on Urban and Nature.

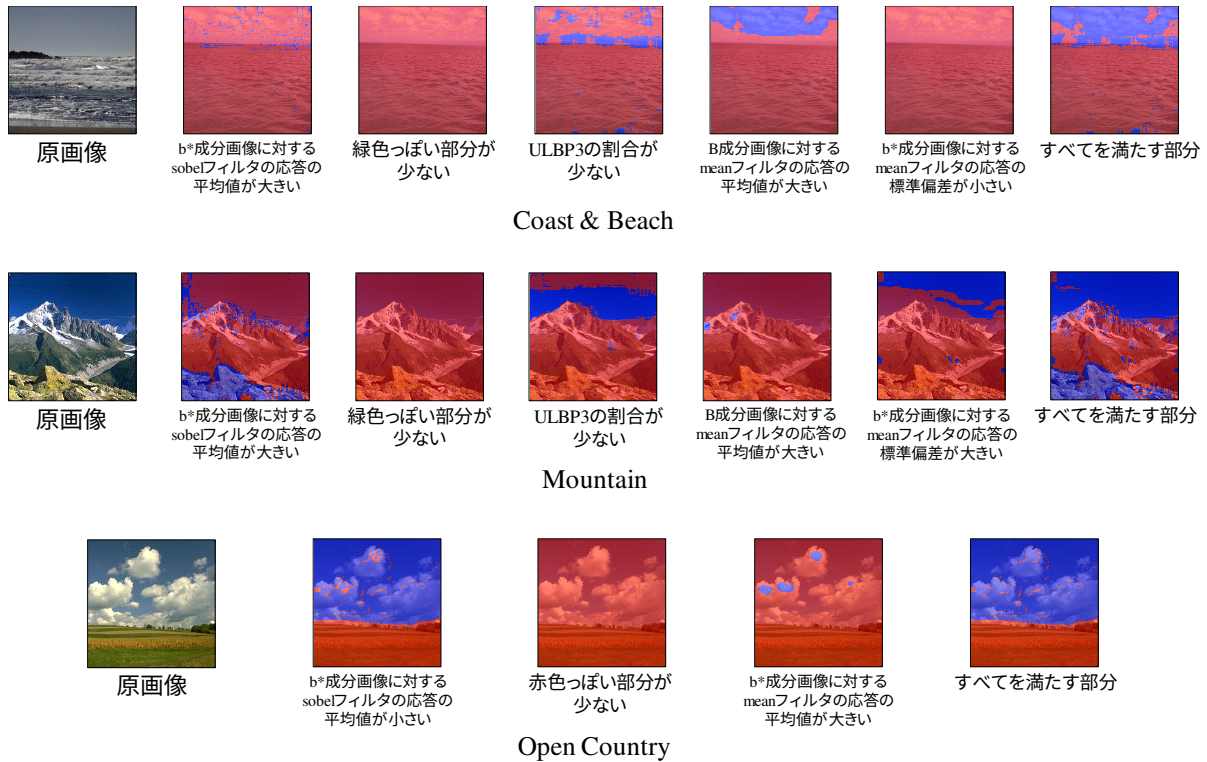


図 5 Urban and Nature の可視化例  
Fig. 5 Visualizations for EDEN trained on Urban and Nature.

は、背景に物体が写っている未知画像に対しては全く分類ができていないことが分かる。一方、分類器  $C_{-white}$  は、背景に反応している分類器よりも精度が優れている。これは、人間の分類判断とは異なる分類過程での分類であるが、分類器が学習データを正しく分類できればよいとして学習させているために起こることであると考えられる。このように機械学習を用いて分類器を構築した際には、用いた学習画像と未知画像の違いや分類器の学習のさせ方の違いによって分類精度が大きく左右される。そのため、提案手法を用いて分類過程を可視化することによって、分類器の分類精度だけでなく、直感的な分類器の分類過程の提示がすることができ、構築した分類器の考察が容易となる。これによって、分類器の信頼性の向上にもつなげることができると考える。

表 3 motorbike の学習・未知の再現率

Table 3 Accuracy of EDEN applied to Motorbike Class.

学習 (5 試行平均)		未知 (5 試行平均)	
再現率 $C_{white}$	再現率 $C_{-white}$	再現率 $C_{white}$	再現率 $C_{-white}$
0.968	0.988	0.057	0.488

## 5. まとめと今後の課題

本論文では、EDEN の分類過程を可視化する手法を提案した。提案手法の有効性を検証するために一般画像の分類問題に適用し、生成される説明の有効性を検証した。結果として、機械学習で構築した分類器の分類過程を直感的に利用者に示すことが可能となり、機械学習で構築した分類器の信頼性の向上につなげることができたといえる。

今後の課題としては、利用者の要求度に合わせて分類クラスの違いを明確に提示することが可能な説明方法の検討



図 6 Motorbike のクラスらしさのヒートマップ  
Fig. 6 Heatmap for EDEN trained on motorbike class.

が挙げられる。これは医用画像分類などの産業応用では、分類クラスのすべての説明を生成する必要はなく、分類クラスの違いが明確になればよいとする場合があるためである。そのため、多クラス分類の分類過程を説明する際にクラス間の違いが明確に分かるような説明方法の検討が必要であると考えられる。

また、本論文では比較的人間が理解しやすい if-then ルールを用いて分類を行う EDEN を対象として分類過程の可視化を行ったが、ニューラルネットワークなど、他の分類器にも適用可能な説明手法を検討する必要がある。分類器の中には情報工学の専門家でも分類過程を解析することが困難なものがあり、それらの分類器に対して直感的で分かりやすい説明を生成する手法を検討する必要がある。また、生成された説明の分かりやすさを数値などで評価し、提案手法の有効性を客観的に示すことも今後の課題である。

#### 参考文献

- [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, 映像情報メディア学会誌, Vol. 67, No. 7, pp. J278–J285 (2013).
- [2] Quinlan, J. R.: *C4.5: Programs for Machine Learning*, Morgan Kaufmann Publishers Inc., San Francisco, CA, USA (1993).
- [3] 崎津実穂, 菅沼雅徳, 土屋大樹, 長尾智晴: 決定木および決定ネットワークによる画像分類過程の説明文の自動生成, 情報処理学会論文誌数理モデル化と応用 (TOM), Vol. 9, No. 1, pp. 43–52 (2016).
- [4] Zeiler, M. D. and Fergus, R.: Visualizing and Understanding Convolutional Networks, *Computer Vision – ECCV 2014*, pp. 818–833 (2014).
- [5] Yosinski, J., Clune, J., Nguyen, A., Fuchs, T. and Lipson, H.: Understanding Neural Networks Through Deep Visualization, *Proc. International Conference on Machine Learning* (2015).
- [6] Simonyan, K., Vedaldi, A. and Zisserman, A.: Deep Inside Convolutional Networks: Visualising Image Classification Models and Saliency Maps, *arXiv:1312.6034* (2013).
- [7] Dalal, N. and Triggs, B.: Histograms of Oriented Gradients for Human Detection, *Proc. IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 886–893 (2005).
- [8] Csurka, G., Dance, C. R., Fan, L., Willamowski, J. and Bray, C.: Visual categorization with bags of keypoints, *Proc. Workshop on Statistical Learning in Computer Vision*, pp. 1–22 (2004).
- [9] Perronnin, F., Sánchez, J. and Mensink, T.: Improving the Fisher Kernel for Large-scale Image Classification, *Proc. the 11th European Conference on Computer Vision*, pp. 143–156 (2010).
- [10] Sivic, J. and Zisserman, A.: Video Google: A Text Retrieval Approach to Object Matching in Videos, *Proc. the International Conference on Computer Vision*, Vol. 2, pp. 1470–1477 (2003).
- [11] Vondrick, C., Khosla, A., Malisiewicz, T. and Torralba, A.: HOGgles: Visualizing Object Detection Features, *International Conference on Computer Vision* (2013).
- [12] Hentschel, C. and Sack, H.: What Image Classifiers Really See - Visualizing Bag-of-Visual Words Models., *MultiMedia Modeling*, Vol. 8935, Springer, pp. 95–104 (2015).
- [13] Pelleg, D. and Moore, A. W.: X-means: Extending K-means with Efficient Estimation of the Number of Clusters, *Proc. Seventeenth International Conference on Machine Learning*, pp. 727–734 (2000).
- [14] Oliva, A. and Torralba, A.: Modeling the Shape of the Scene: A Holistic Representation of the Spatial Envelope, *International Journal of Computer Vision*, Vol. 42, No. 3, pp. 145–175 (2001).
- [15] Nilsback, M.-E. and Zisserman, A.: Automated Flower Classification over a Large Number of Classes, *Proc. the Indian Conference on Computer Vision, Graphics and Image Processing* (2008).
- [16] Guo, Z., Zhang, L. and Zhang, D.: A completed modeling of local binary pattern operator for texture classification, *IEEE Trans. Image Processing*, pp. 1657–1663 (2010).
- [17] Griffin, G., Holub, A. and Perona, P.: Caltech-256 Object Category Dataset, Technical Report 7694, California Institute of Technology (2007).