

矩形特徴による弱識別器のブースティングによる対象検出手法の汎化性能向上のための工夫と車載カメラの映像中の車の検出への応用

A Tip for improving vehicle detector using rectangle features combined by AdaBoost

谷川昌司† 日高章理‡ 佐野夏樹† 西田健次† 栗田多喜夫†

TANIGAWA Masashi†, HIDAKA Akinori‡, SANO Natsuki, NISHIDA Kenji, KURITA Takio†

†産業技術総合研究所 脳神経情報部門 ‡筑波大学大学院情報システム研究科

† AIST, Neuroscience Research Institute, ‡Graduate school of Information technology,
University of Tsukuba

E-mail: m_tanigawa@aist.go.jp

Abstract

Viola と Jones[1] は、矩形特徴を元にした弱識別器を AdaBoost[2] の方法で統合する手法を提案し、ヒトの顔や車両の検出をリアルタイム処理として十分な処理性能があることを示した。矩形特徴は非常に簡単な構造のため、演算回数が少なく高速処理に適している。本報告では、Viola と Jones の手法の改良点について検討し、矩形特徴に基づく識別器の出力結果を多数決で用いる際に、その出力結果に飽和的な関数を利用することで検出性能が向上することを確認した。

1 はじめに

物体検出に関して、最近、画像中の局所領域の矩形特徴を利用した簡単な識別器（弱識別器）を複数個用意し、各識別器の重みつき多数決で最終的な識別器を実現する手法が提案され、画像中の顔の検出に応用された。Viola と Jones[1] は、矩形特徴を元にした弱識別器を AdaBoost[2] の方法で統合する手法を提案し、ヒトの顔や車両の検出をリアルタイム処理として十分な処理性能があることを示した。矩形特徴は非常に簡単な構造のため、演算回数が少なく高速処理に適している。Wu ら[3]は、Viola と Jones の方法に改良を加え、回転不変の認識システムを構築した。また、矩形特徴に改良を加えて、ひとつの矩形特徴から得られる識別器の性能を高め、少ない個数の矩形特徴を用いても有効な認識性能を得ることを示した。本研究課題では、Wu ら

の方法を基本にして、矩形特徴による識別器に飽和特性を付加することで、より高性能な識別性能を持つ検出器を作る手法を開発し、各弱識別器の出力に飽和的な関数を適用することで検出性能が向上することを確認した。

2 矩形特徴

まず、矩形特徴を用いた高速な識別器について簡単に紹介する。より詳しい解説は、例えば Lienhart の技術レポート[4]がある。矩形特徴は図1に示すような局所領域に含まれる画素の輝度の総和の組み合わせで表される。矩形特徴の強度は白い部分に含まれる画素の輝度値の平均と黒い部分に含まれる画素の輝度の平均の差として表される。つまり、白い部分の平均輝度から黒い部分の平均輝度を引いた値を計算する。矩形特徴のパターンは、多くのものが考えられるが、ここで報告する評価実験では、




図1: 矩形特徴: 本報告で用いた矩形特徴のパターンは4種類。それぞれの特徴について位置、サイズの異なった矩形特徴が抽出可能である

図1に示す4種類の矩形特徴のパターンを用いた。このような矩形特徴を抽出するのに必要な計算は、局所領域に含まれる画素の輝度の総和演算である。この演算は、あらかじめ以下に示す積分イメージを求めておくことで、比較的簡単な演算の組み合わせで計算できる。図2に、矩形特徴を用いた簡単な識別器をAdaBoost[5][6]を用いて統合するためのアルゴリズムの概略を示す。ここでは、ブースティングの手法としては、Real-AdaBoostと呼ばれる手法を利用した。

Wuら[3]は、矩形特徴に改良を加えて、ひとつの矩形特徴から得られる識別器の性能を高め、少ない

個数の矩形特徴を用いても有効な認識性能を得ることを示した。具体的には、LUT(Look Up Table)を組み入れた矩形特徴検出器を用いることで計算コストが少なくしかも高い識別性能の弱識別器をつくることを考えた。基本的なアイデアは、ViolaとJonesが用いていたように、矩形特徴の出力値を閾値で二値化するのではなく、矩形特徴値がとる確率密度をヒストグラムで表現することで、単純な矩形特徴量から、分類カテゴリーの尤もらしさの程度を出力する変換を行うことにある。矩形特徴量が x の値をとるときのカテゴリー'+とカテゴリー'-に対応

-
1. Let N be the number of samples, M be the number of boosting steps,
 2. Initialize with weights $w_i = 1/N, i = 1, 2, \dots, N$.
 3. For $m = 1$, to M :
 - (a) Find optimal classifier $h_{opt}^m(x)$ from rectangle feature family, so that the reference function $Z = \sum_k (\sqrt{W_+^k W_-^k})$ is minimized, where k is the index of histogram bin. $W_+^k = \sum_i w_{y_i=+1}$.
 - (b) set $w_i \leftarrow w_i \cdot \exp[-y_i h_{opt}^m(x_i)], i = 1, 2, \dots, N$, and normalize the weights so that $\sum_i w_i = 1$.
 4. Output the classifier's confidence value: $G(x) = \sum_{m=1}^M h_{opt}^m(x)$. and Classified results are obtained by $sgn(G(x))$.
-

図2: 特徴選択を用いた Real-AdaBoost のアルゴリズム [5, 6]

する確率密度をそれぞれ、 $P_+(x)$ と $P_-(x)$ で表すとすると、弱識別器の出力 (対数尤度比) は、

$$h_{opt}(x) = \frac{1}{2} \log \frac{P_+(x)}{P_-(x)} \quad (1)$$

で計算される。一般に、これらの確率密度は不明であり、データからこれらの確率密度を推定しなければならない。Wuら[3]は、これらの確率密度を、適当なサイズのビンを持つヒストグラムから推定した。矩形特徴量の差で表されるような軸へ射影した確率密度のヒストグラムをカテゴリー'+と'-に別けて W_+, W_- で表すことにすると、弱識別器の出力は、

$$h_{opt}(x) = \frac{1}{2} \log \frac{W_+}{W_-} \quad (2)$$

となる。ここで、 W_+ は

$$W_+^m = \sum_i^N w_i \quad (3)$$

で定義される。ここで、 P_i はカテゴリー+に属するデータの番号 i だけを集めたものであり、 N はそのデータの数である。また、 w_i^m は m 番目のブースティング時に割り当てられているデータの重み係数を表す。それぞれのヒストグラムに割り当てられた値を

LUT として保存しておけば、特徴量 x から、そのときの識別器の出力（カテゴリの尤もらしさ）を呼び出すことができる。図 4 に、LUT を持つ矩形特徴の弱識別器を使った場合の学習プロセスを示す。

3 飽和関数の導入による汎化性能の改善

上述の手法により、高速演算が可能で、しかも高性能の弱識別器を構成することができる。しかしながら、上記の弱識別器の出力（対象の尤もらしさ）の計算では、汎化性能（未学習データに対する識別性能）が損なわれるケースがしばしば見受けられた。つまり、式(2)において W_+ が W_- に対して非常に小さい場合、とくに、 $W_+ = 0$ の場合には、弱識別器の出力（対象の尤もらしさ）が無限大になってしまう ($W_- = 0$ の場合には負の無限大になる)。その結果、学習データの重みが 0 になってしまっていて、以降の AdaBoost の過程において、このデータは $W=0$ 分の価値として参照されてしまう。言い替えると、このデータは既に学習したデータとして扱われてしまっていて、以降の学習過程で無視されてしまう。そこで、本報告の手法では、識別器の出力を飽和関数を導入して、ある程度以上大きくならないように制限することで、汎化性能の改善を行う。飽和関数として、ここでは、

$$S[x] = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4)$$

を用いた。この時、弱識別器の出力は、

$$h_{opt} = S\left[\frac{1}{2} \log \frac{W_+}{W_-}\right] \quad (5)$$

となる。式変形の結果弱識別器の出力は

$$h_{opt} = \frac{W_+ - W_-}{W_+ + W_-} \quad (6)$$

で計算すれば良いことがわかる。このような飽和関数の導入によって、ひとつの識別器が誤った答えを出力した場合にも、他の識別器の出力による補正効

果が働くので、統合された識別器の認識性能は向上する。ここでは飽和特性を弱識別器の出力制限の方法で適用したが、より本質的にブースティングの損失関数を改善することにより性能の改善を図ろうとする試みもある [7]。



図 3: 学習に用いた顔データの例

	Hit	False Alarm
従来法 ($\frac{1}{2} \log \frac{W_+}{W_-}$)	94.6%	10.4%
改善法 ($\frac{W_+ - W_-}{W_+ + W_-}$)	98.8%	0.3%

表 1: 従来法と改善法の認識性能（顔検出）

4 識別器の性能評価と物体検出実験

提案する飽和特性を持つ弱識別器の採用によって、認識性能がどれほど改善するかを調べるために顔、車両についての検出課題についての実験を行った。学習に用いた実験データの一部を図 4 に示す。学習データは顔画像 100、非顔画像 200 個として、認識率を測定するためのテストデータは顔画像 425 個、非顔画像 1000 個とした。また AdaBoost で用いた弱識別器の個数は 200 個とした。表 1 は、顔検出における認識性能を示す。この結果から、飽和特性の導入した弱識別器の採用によって認識率の大幅な改善が図られたことがわかる。次に、上述の識別器を用いて画像の中から対象を検出する探索課題についても実験を行った。対象物の探索には、次のようなアルゴリズムを用いた。

1. 与えられた画像の積分イメージを作成する。
2. 対象位置を 1 ピクセルずつずらしながら、識別器で検出対象の有無を判定する。縮尺は 24x24 ピクセルを最小単位にして 1.25 倍ずつ変化させた。

3. 適当に定めた閾値以上のものについて、識別器が出力する信頼度に応じて色づけをして表示した。

図4には車両検出に応用した結果を示す。これらの実験結果から、個々の弱識別器の出力（対象の尤もらしさ）の計算に飽和特性を導入することによって、汎化性能が大幅に向上することが確認された。

参考文献

- [1] P. Viola and M. Jones, "Rapid object detection using a boosted cascade of simple features," Proc. of CVPR, 2001.
- [2] R.E. Schapire and Y. Singer, "Improved Boosting Using Confidence-rated Predictions," Machine Learning, Vol.37,

No.3, pp.297-336, 1999.

- [3] B. Wu et al. , "Fast rotation invariant multi-view face detection based on real adaboost, Proc. of Sixth IEEE International Conference on Automatic Face and Gesture Recognition (FG2004), 2004.
- [4] R. Lienhart and J. Maydt, "An Extended Set of Haar-like Features for Rapid Object Detection," Proc. of ICIP, Vol.1, pp900-903, 2002.
- [5] N. Sano, H. Suzuki and M. Koda, A robust boosting method for mislabeled data, Journal of the Operations Research Society of Japan, 47 (3) (2004)182-196.



図4 車両検出に応用した例。車両後部画像を学習し追跡する課題。複数の四角形は車両の存在を表し、四角の濃淡は車両の尤もらしさを表す。