

カスケード型識別器による標識検出のための生成型学習法

道満 恵介[†] 高橋 友和[†] 目加田慶人^{††} 井手 一郎[†] 村瀬 洋[†]

[†] 名古屋大学大学院情報科学研究科
〒 464-8601 愛知県名古屋市千種区不老町
^{††} 中京大学生命システム工学部
〒 470-0393 愛知県豊田市海津町床立 101

E-mail: †{kdoman,ttakahashi,ide,murase}@murase.m.is.nagoya-u.ac.jp, ††y-mekada@life.chukyo-u.ac.jp

あらまし 高速かつ環境変化に対してロバストな物体検出手法として、Viola らが提案したカスケード型識別器を用いる手法がある。この手法では、十分な検出性能を得るためには対象物体の種々の見え方に対する大量の学習用画像が必要となり、それらを手作業で収集することは一般に容易ではない。本稿では、この問題に対して識別器の学習に生成型学習を採用することで解決を試みる。生成型学習とは、物体をカメラで撮影した際に実際に起こりうる劣化現象をモデル化し、それを基にシミュレートされた劣化画像を学習に使用するものである。これをカスケード型識別器へ適用することで、学習用画像の収集コストを大幅に削減し、識別器の学習過程の効率化が図れる。実際に、生成型学習を用いてカスケード型識別器を作成して標識検出を行った結果、その有効性が確認された。

キーワード 生成型学習, カスケード型識別器, 標識検出, 車載カメラ

Generative Learning for Traffic Sign Detection Using Cascaded Classifiers

Keisuke DOMAN[†], Tomokazu TAKAHASHI[†], Yoshito MEKADA^{††}, Ichiro IDE[†], and Hiroshi MURASE[†]

[†] Graduate School of Information Science, Nagoya University
Furo-cho, Chikusa-ku, Nagoya, Aichi, 464-8601 Japan
^{††} School of Life System Science & Technology, Chukyo University
101, Tokodachi, Kaizu-cho, Toyota, Aichi, 470-0393 Japan

E-mail: †{kdoman,ttakahashi,ide,murase}@murase.m.is.nagoya-u.ac.jp, ††y-mekada@life.chukyo-u.ac.jp

Abstract Viola et al. have proposed a robust and extremely rapid object detection method based on a boosted cascade of simple feature classifiers. To make full use of this, we need to collect a huge number of effectual training data which contain various appearances of target object. In general, it is not easy to do that manually. In this paper, we introduce an efficient method of designing cascaded classifier by using Generative Learning. The Generative Learning has been developed to generate synthetic learning patterns by simulating actual imaging process. The proposed method enables us to obtain a number of training data without exhaustively collecting them. Experimental results of detecting traffic signs showed the effectiveness of our method.

Key words Generative Learning, Cascaded Classifiers, Sign Detection, Car-mounted Camera

1. はじめに

近年、自動車の運転支援技術が様々な角度から研究されている。本研究ではその一つとして、車載カメラ映像から道路標識を検出するための識別器を効率良く設計する手法に注目する。

道路標識検出のための手法としては、標識の色特徴を利用するもの [1] [2] と形状特徴を利用するもの [3] [4] に大別される。

前者では、天候や照明変動等に比較的大きく影響され、検出が不安定となりやすい問題がある。後者では、テンプレートマッチングや Hough 変換等をベースにした手法が多くみられるが、これらを単純に用いた手法では計算量が膨大になってしまう。

多様な変動に比較的に強く、高速に物体検出が行えるものとしては AdaBoost ベースの識別器 [5] があり、それをカスケード状に並べて効率よく検出を行う手法が Viola らによって提案さ

れている [6] [7] . このカスケード型識別器は主に顔検出に広く用いられているが, 道路標識を対象とした例も存在する [8] . ただし, この手法を採用する場合には, 識別器の作成に大量の学習用画像が必要となるという問題点が存在する . 通常, 学習用画像の収集は手作業により行われ, 学習に適した何千枚もの画像を収集するには膨大な手間と時間が必要となる . この点に関して, 学習用画像の収集方法に関する研究は数少なく, Viola らの研究をはじめ, 学習を基本とする識別器を採用した手法を提案する研究の多くは, あらかじめ作成された大規模な画像データベースを利用して実験を行っている .

これに対して本稿では, Viola らのカスケード型識別器の学習に生成型学習 [9] を適用し, 高性能な識別器を低コストで作成する手法を検討する . 生成型学習では, ある物体をカメラで撮影した際に実際に起こりうる劣化現象をモデル化する . そして, そのモデルを用いて自動生成された劣化画像を学習に使用する . これにより, 学習用画像の収集に伴う煩雑な作業が不要となる .

以降, 2 節では本研究で使用する検出器のベースとするカスケード型識別器について述べ, 3 節で生成型学習について述べる . 続く 4 節, 5 節では, それぞれ提案手法とそれを用いた標識検出の実験結果を記し, 6 節で考察を行う . 最後に 7 節で本稿のまとめを行う .

2. AdaBoost ベースのカスケード型識別器

これまで物体検出のための様々な手法が提案されている . なかでも, 単純な特徴の利用による高速性と環境変化に対するロバスト性を比較的好く兼ね備えた検出手法として, 図 1 に示す AdaBoost アルゴリズムを用いて作成された識別器を用いる手法が挙げられる [5] . このアルゴリズムは, いくつかの低性能な特徴 (弱識別器) h を組み合わせて全体として高性能な識別器 (強識別器) H を作成することを基本理念としている . 実際の識別の際には, 次式によって検出対象かどうかを判定する .

$$H(x) = \begin{cases} 1 & \sum_{t=1}^T \alpha_t h_t(x) \geq \frac{1}{2} \sum_{t=1}^T \alpha_t \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

ここで, $\alpha_t = -\ln \beta_t$ である .

ここで用いられる弱識別器としては, 図 2 に示す Haar-like 特徴がよく採用される . 図 2 に示す各特徴はいずれも, 検出対象か非検出対象かを判定するために, 白矩形領域のピクセル値の総和と黒矩形領域のピクセル値の総和との差分を用いた関数として作用する . AdaBoost ベースの識別器においては, これら各弱識別器の判定結果を基に全体として検出対象であるか非検出対象であるかを決定する .

また, AdaBoost ベースの識別器の応用として Viola らが提案したカスケード型識別器による物体検出手法が広く知られている [6] [7] . これは, AdaBoost ベースの識別器を複数段カスケード状に並べて全体として一つの識別器を構成する手法である . ここで用いるカスケード状の識別器では, 通常, 非検出対象と判定されるべきものはカスケードの比較的初期の段で棄却されるため, 単一の識別器よりも効率の良い検出が可能となる .

- 学習用画像の用意
($x_1, y_1, \dots, (x_n, y_n)$ ($y_i = 0, 1 \mid i = 0, 1, \dots, n$))
 - 学習重みの初期化
 $w_{1,i} = \begin{cases} \frac{1}{2l} & y_i = 1 \text{ (} l \text{: 検出対象クラスの総数)} \\ \frac{1}{2m} & y_i = 0 \text{ (} m \text{: 非検出対象クラスの総数)} \end{cases}$
 - 特徴の選択
 $t = 1, \dots, T$
 - (1) 学習重みの正規化
 $w_{t,i} \leftarrow \frac{w_{t,i}}{\sum_{j=1}^n w_{t,j}}$
 - (2) 各特徴 h_j について識別エラー ϵ_j の計算
 $\epsilon_j = \sum_i w_{t,i} |h_j(x_i) - y_i|$
 - (3) 識別エラー ϵ を最小とする特徴 h_t の選択
 - (4) 学習重みの更新
 $w_{t+1,i} = \begin{cases} w_{t,i} \beta_t & h_t(x_i) = y_i \\ w_{t,i} & h_t(x_i) \neq y_i \end{cases} \quad (\beta_t = \frac{\epsilon_t}{1-\epsilon_t})$
- 終了条件 (適宜指定) を満たすまで繰り返し

図 1 AdaBoost アルゴリズム




図 2 Haar-like 特徴を基本とする弱識別器

しかしながら, これを用いて十分な検出性能を得るためには, 識別器の学習に用いる画像を大量に用意しなければならない . 顔検出を対象とした分野では MIT や CMU によって大規模な学習に適した顔画像のデータベースが既に構築されており, 多くの研究ではそれを利用して研究を進めている . すなわち, 既に大量の学習用画像が収集できていると仮定して研究を行っている . しかし, データベースが利用できない場合は, 通常, 手作業により学習用画像を収集しなければならない . その作業には膨大な手間や時間がかかる . 一般に, 識別器の学習に適した標識画像を数千枚も収集するのは容易ではない . そのため, Viola らの提案したカスケード型識別器は検出性能の面で優れているものの, その利用範囲が限られているのが難点といえる .

3. 生成型学習

識別器の作成にあたり, いかに優れた作成手法を採用しようとも, 識別器の学習にとりかかるまでの作業コストが高ければ, その実用性は大幅に減少する . これまで識別器の作成手法に関しては盛んに研究が行われてきたのに対して, 学習用画像の収集方法に関する研究は少ない . 石田らは, 生成型学習を利用して文字や標識の認識を行う手法を提案している [9] . 生成型学習とは, 検出対象をカメラで撮影した場合に実際に起こりうる種々の劣化現象をモデル化し, それらのモデルに従って生成される劣化画像を用いて大量枚数による学習を行うものである . 入力としてカメラ等で撮影した画像を想定すると, 撮影画像における検出対象物体の回転, 伸縮, 位置ずれ, 光学ばけ等とい

た品質劣化が考えられる．これら各種劣化に対するモデルを定義し，各々に必要となる生成パラメータを適切に与えることができれば，現実に入力される劣化画像を近似的に自動生成することが可能となる．その結果，大量の学習用画像を少ない収集コストで用意することができ，効率良く学習が行える．

4. 提案手法

4.1 手法概要

本稿で提案する手法は，Viola らが提案したカスケード型識別器を用いて標識の検出を行い，各識別器の作成において生成型学習を適用するというものである．これによって学習用画像の自動生成が可能となり，その収集コストが大幅に削減される．この点が本手法の最大の特長である．

提案手法は大別して，生成，学習，検出の3つの段階からなる．まず生成段階では，劣化画像を生成する際に基準とする標識画像を用意し，そこから劣化画像をシミュレートする．次の学習段階で，生成された学習用画像を用いて識別器の学習を行う．これら2つの段階は事前処理として行う．最後に検出段階において，作成された識別器を用いて入力画像上を走査する．

4.2 生成段階

本稿で想定する劣化とそのシミュレート方法を次に述べる．

• 位置ずれ

本手法では，入力画像上を走査しながら検出処理を行うため，切り出し位置によるずれを考慮する必要はない．しかし後述するように，実際には入力画像を各倍率毎に縮小したピラミッド画像上を走査するため，1ピクセル未満（サブピクセル単位）の位置ずれが発生することがある．そこで，厳密化をはかるためには，縮小前の位置ずれを Δx ，縮小率を r として，

$$|\Delta x| < r \quad (2)$$

の範囲にある位置ずれを考慮する．

これをシミュレートするためには，原画像となる標識のサイズを n ，識別器への入力サイズを n' として，

$$|\Delta x| < \frac{n}{n'} \quad (3)$$

の範囲で画像を水平方向，垂直方向それぞれについて独立に平行移動させる．

• 伸縮

撮影時のカメラと標識の位置関係やカメラ移動によって，撮影された標識画像の縦横比が変化する．伸縮のパラメータとして，水平方向の伸縮率 r_w と垂直方向の伸縮率 r_h を与え，原画像における水平方向，垂直方向それぞれを r_w 倍， r_h 倍に拡大することで伸縮をシミュレートする．

• ぼけ

撮影に使用したカメラのピント（焦点）が合っていない場合，画像がぼけて撮影される．これは一般に光学ぼけと呼ばれ，原画像では点であったものが拡がりをもつようになる劣化である．この拡がりは方向によらず一定であり，原点からの距離 $r = \sqrt{x^2 + y^2}$ のみに依存した焦点ぼけを近似する関数として，次式に示すガウス関数が一般的によく使用される．

$$h(x, y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (4)$$

光学ぼけをシミュレートするためには，入力画像と(4)式との畳み込み積分を計算する．

• 解像度低下

遠方にある標識を撮影した場合や入力画像を縮小する際に解像度の低下が起こる．後者においては，作成するピラミッド画像は離散的であるため，縮小率の間隔が重要となる．いま，サイズ $n \times n$ の標識が映っている入力画像を $1/r$ 倍ずつ縮小したピラミッド画像を考え，識別器への入力サイズが $d \times d$ であったとすると， $n = r^m \times d$ (m は任意の正の整数) であれば，ピラミッド画像上のいずれかの段で標識のサイズと識別器への入力サイズが一致する．しかし，現実にはそれ以外のサイズの標識も入力される．あらゆるサイズパターンを入力を学習時に考慮するには，

$$[d, r \times d) \text{ または } \left[d - \frac{d(r-1)}{2}, d + \frac{d(r-1)}{2} \right) \quad (5)$$

の範囲において，有効な全ての解像度への画像縮小をシミュレートする．

以上5つの劣化をシミュレートした結果と実際の画像との比較を図3に示す．本手法における生成型学習では，上記の劣化ごとに必要となるパラメータをそれぞれ適切な範囲で一様に変化させ，現実の入力をシミュレートする．なお，シミュレートによって生成された画像は，濃度値による正規化を経て次の識別器の作成のための学習に使用される．



図3 生成画像と実画像との比較

4.3 学習段階

本手法で採用する標識検出システムを図4に示す．この図で， H_i ($i = 0, 1, \dots, n$) は，表1のAdaBoost アルゴリズムにより学習完了した識別器を意味しており，本手法では図5に示すアルゴリズムに従ってそれぞれの識別器が作成される．

このシステムにおける識別の流れは次のようになる．識別対象となる画像が一段目の識別器 H_1 に入力されると，そこで標識か非標識かの判定が行われる．標識と判断された場合は次の識別器 H_2 での判定に進むが，非標識と判断された場合にはそれを最終出力とする．同様の操作が以降の識別器においても行われ，全ての識別器で標識であると判定された場合に限り，入力された画像が標識であったと出力する．




図4 AdaBoost ベースのカスケード型識別器

- 各学習用画像（標識画像： I_p 、非標識画像： I_n ）の用意
 $I_p \leftarrow$ 原画像を基にシミュレートした m 枚の劣化画像
 $I_n \leftarrow$ 標識を含まない画像 I_N から抽出した m 枚の部分領域
- カスケード型識別器 H_{cas} の作成
 $t = 1, \dots, T$
 - 各学習用画像を用いて H_t を作成
 - H_t を H_{cas} の最後段に追加
 - 各学習用画像の更新
 $I_p \leftarrow I_p$ の中で H_{cas} を通過する画像
 $I_n \leftarrow I_n$ 内で H_{cas} を通過する部分領域（最大 m 枚）

I_N 内の全部分領域が H_{cas} を通過しなくなるまで繰り返し

図 5 カスケード構築アルゴリズム

4.4 検出段階

作成した識別器を用いて実際に標識の検出を行うにあたって、まず入力された画像を $1/r$ 倍ずつ縮小したピラミッド画像を作成する。そしてピラミッドの各段を走査しながら部分領域を作成した識別器へ入力し、それが「標識」か「非標識」が逐次判定を行う。なお、以下の実験では $r = 1.25$ とし、識別器へ入力する際には、対象となる部分領域の濃度正規化を行う。これにより、照明変動に対してよりロバストな検出が可能となる。

5. 実験

以降では、本手法の有効性を確認するために行った実験とその結果を示す。

5.1 実験条件

各実験では識別器の性能評価のため、表 1 に示す車載カメラを用いて晴天時に撮影された連続する 112 フレームからなる映像を使用した。なお、これらの画像には全て「制限速度 50」の標識が含まれており、本実験では生成型学習の有効性を確認するために「制限速度 50」の標識のみを検出対象とした。また、入力画像に対する識別器からの出力結果に対し、目視により検出領域内に標識内の「50」の文字が完全に含まれていれば正しく識別できたとし、含まれていなければ誤識別したと判定した。

表 1 車に装着したカメラの仕様

撮影機器	Sony DCR-PC 105
解像度	720 × 480 pixel
フレームレート	30 fps
焦点距離	3.7 mm

5.2 生成型学習適用の有無による性能比較

5.2.1 実験手法

識別器の学習において生成型学習を適用した場合と適用しなかった場合の検出精度がどのように変化するかを確認するための比較実験を行う。すなわち、学習用画像の収集コストを同じにした場合の生成型学習の効果を確認する。

実験手順は以下の通りである。

(1) 実際に撮影された標識画像 (24 × 24 pixel) を 10 枚 (図 6)、非標識画像の抽出用となる標識の映っていない画像 (720 × 480 pixel) を 29 枚用意。

(2) 4.3 節に示す方法で識別器を作成。このとき、10 枚の標識画像を次の 2 つの方法に分けて学習に使用。

(a) 10 枚の標識画像をそのまま学習に使用。

(b) 10 枚の標識画像から 4.2 節に述べた方法 (各種劣化モデルに与える生成パラメータの範囲は表 2 の通り) で各 100 枚ずつ生成して学習に使用。

ここで、特徴選択の終了条件としては次の条件を与えた。

- 学習用標識画像の 99.9% 以上を正しく識別
- 学習用非標識画像の 50.0% 以上を正しく識別

カスケード構造をなす各識別器の学習の際には、この条件を満たすまで図 1 に従って特徴を追加し続ける。




図 6 用意した 10 枚の原画像となる標識

表 2 実験で使用した各種生成パラメータ

生成パラメータ	伸縮率		位置ずれ		光学ぼけ	解像度低下
	r_w	r_h	Δx	Δy	σ	d
最小値	0.95	0.95	†	†	0.00	‡
最大値	1.05	1.05	†	†	2.00	‡

†: 学習時画像サイズにより決定 ((3) 式)

‡: 学習時画像サイズにより決定 ((5) 式)

5.2.2 実験結果

実験結果を表 3 に示す。図 7 は、作成した識別器を評価用画像に適用した結果の例である。表 3 の結果をみると、生成型学習を適用した場合の方が適合率、再現率から計算される F 値はともに高い値を示している。特に再現率においては生成型学習適用の有無によって大きな差が生じており、生成型学習の効果が確認できた。

なお、表 3 は評価用画像に映っている標識のサイズに関係なく計算した値である。実際に 112 フレームの評価用画像を確認すると、16 × 15 pixel から 53 × 45 pixel までのサイズの標識が含まれていた。このうち標識のサイズが 24 × 24 pixel よりも小さいフレームについては、本実験で作成した識別器では正しく検出することはできない。

表 3 学習枚数の違いと検出精度の関係

	10 枚 (生成なし)	10 枚 × 100 (生成あり)
適合率	0.87	0.95
再現率	0.39	0.74
F 値	0.53	0.83



(a) 10 枚 (生成なし)



(b) 10 枚 × 100 (生成あり)

図 7 学習枚数の違いによる検出結果の比較

5.3 原画像による性能比較

5.3.1 実験手法

収集コストの面からみただけの場合、出来るだけ少数の画像から十分な性能が得られる学習用画像が生成できることが望ましい。そこで、生成のための原画像を 1 枚のみとした場合に、選択する画像の違いが識別器の性能に与える影響を実験的に確認する。実験手順は以下の通りである。

(1) 実際に撮影された標識画像 3 枚とコンピュータ上で作成された CG の標識画像を用意

(2) それぞれを原画像から生成型学習により識別器を作成
 なお、学習画像のサイズは 24×24 pixel とし、識別器の学習における特徴選択の終了条件や学習用標識画像の生成時に与える各種生成パラメータの範囲は 5.2 節の実験と同じとした。本実験で用意した実際の標識画像、および CG 標識画像を図 8 に示す。




図 8 生成の原画像とした標識画像

5.3.2 実験結果

異なる原画像を基にして作成された識別器による検出実験の結果を表 4 に示す。図 9 は、評価用画像に適用した結果の例である。

実画像を基に生成して学習した場合の方が F 値が高かったが、基にした画像によっては検出性能が大きく異なった。また

ほとんどの場合、学習枚数を増やすと検出性能は向上しており、5.2 節と同様に生成型学習適用の効果が確認できた。

表 4 原画像の違いと検出精度の関係

生成枚数		実画像			CG 画像
		画像 A	画像 B	画像 C	
1 枚 × 1,000	適合率	0.63	0.80	0.96	0.79
	再現率	0.37	0.63	0.71	0.35
	F 値	0.46	0.70	0.81	0.48
1 枚 × 5,000	適合率	0.86	0.92	0.98	0.92
	再現率	0.56	0.90	0.68	0.42
	F 値	0.68	0.91	0.80	0.57



(a) 画像 C



(b) CG 画像

図 9 原画像の違いによる検出結果の比較

6. 考 察

6.1 生成型学習適用の効果

生成型学習を適用したことで、作成される識別器の検出性能は向上する傾向にあった。これは、特徴量空間内の少数の事例の近傍に大量の学習用画像を生成したことにより、分類曲面が安定して求められるようになったと考えられる。

原画像として 10 枚の実画像を使用した 5.2 節の実験では、生成型学習を適用して作成した識別器において選択された特徴の数は比較的多くなっていた。このことは、多くの特徴を選択しなければ与えられた終了条件を満たせなかったことを示しており、学習がそれだけ困難であったことを意味している。実際に、1 枚の原画像からそれぞれ 500 枚の劣化画像を生成した計 5,000 枚での学習実験も行ったが、終了条件を最後まで満たせずに実験は失敗した。図 6 は、コントラストや回転、ぼけの程度が異なる標識画像が存在する。こうした大きく特徴が異なる

画像を基に生成した場合、生成枚数が多くなればなるほど、学習が困難となることは直感的に理解できる。

一方、原画像として1枚のみを使用した5.3節の実験では、学習が失敗したケースは一つもなかった。これは、1枚の原画像から生成される劣化画像の分布範囲は比較的よくまとまっていることが関係していると考えられる。1枚のみから生成する方が収集コストの面において良いが、生成された劣化画像の分布範囲が十分でなければ、次に述べるように汎化性が失われるおそれがある。

6.2 劣化画像の生成モデル

5.3節の実験において生成の原画像として実画像を使用した場合、作成された識別器の性能が基の画像により大きく異なる。また、生成した画像枚数を増加させたときの効果も大きく異なっている。ある種の劣化を受けた画像を種として様々な学習画像を生成しているため、この選び方が識別器の性能に大きく影響していることが予想される。6.1節にも述べたように、複数の実画像を利用する場合は識別器の設計自体も難しくなるため、なんらかの画像選択基準や選択された画像に合わせた生成手法の開発が必要と考えられる。

一方、CG画像を原画像とした場合の結果では、再現率が最高でも0.66と決して安定して検出が行えているとはいえない。この主な要因としては、本稿で採用した画像生成モデルでは実際の劣化を正確にモデル化できていないということが考えられる。つまり、考慮した劣化モデル自体に不完全さが存在することや、各種劣化モデルにおける生成パラメータの与え方が不適切であることが考えられる。前者に対しては、光反射や老朽化による色あせといった本稿では考慮しなかった劣化モデルの導入の検討、または各種劣化に対するモデル化方法自体の改良が必要であると考えられる。後者に対しては、より現実の劣化傾向に基づいた生成パラメータ決定法への変更などが必要であると考えられる。後者に関して石田らは、実際に撮影された複数の標識画像から各種モデルにおける生成パラメータ分布の推定を行った[9]。こうすることで、生成パラメータを指定した範囲内から一様乱数にて決定するよりも現実に即した劣化画像が統計的にシミュレートでき、検出精度の向上が期待される。

7. む す び

本稿では、AdaBoostをベースとしたカスケード型識別器に生成型学習法を適用し、特に道路標識検出に着目してその効果を確認した。生成型学習の適用により、生成の原画像となる標識画像を数枚（または1枚）用意すれば、それらから十分な数の学習用画像を生成でき、その収集コストが大幅に削減された。実際に、学習枚数による性能比較実験からは、生成型学習を適用せずに数枚で学習を行った場合よりも、生成型学習を適用して大量の枚数で学習を行った場合の方が高い検出性能が得られることが確認できた。一方で原画像による性能比較実験からは、本稿で採用した生成型学習における劣化のモデル化、または生成パラメータの決定方法に次のような検討の余地があることが示された。

- 考慮する劣化モデルの再検討（新たなモデル導入の検討）

- 各種モデルに対する生成パラメータ決定方法の改善
今後は、これらについて更なる研究が必要である。

謝辞 日頃より熱心に御討論頂く名古屋大学村瀬研究室諸氏に感謝する。本研究の一部は日本学術振興会科学研究費補助金、21世紀COEプログラム「社会情報基盤のための音声・映像の知的統合」による。本研究では、画像処理にMISTライブラリ (<http://mist.suenaga.m.is.nagoya-u.ac.jp>) を使用した。

文 献

- [1] 内村 圭一, 脇山 慎也, 藤野 麻衣子, “限定色表示を用いた円形道路標識の抽出,” 電子情報通信学会論文誌, Vol.J83-D-2, No.2, pp.855–858, February 2000.
- [2] 明珍 甲太, 景山 陽一, 西田 眞, “カラー情景画像における円形道路標識の認識に関する検討,” 電子情報通信学会技術研究報告, Vol.104, No.740, pp.181–185, March 2005.
- [3] 竜円 琢磨, 長坂 保典, 鈴村 宣夫, “円形状の道路標識の認識,” 電子情報通信学会技術研究報告, Vol.99, No.609, pp.17–22, February 2000.
- [4] 藪木 登, 三木 成彦, “道路情景中の最高速度標識の検出および認識,” 電子情報通信学会論文誌, Vol.J77-D-2, No.7, pp.1393–1394, July 1994.
- [5] Y. Freund and R.E. Schapire, “A decision-theoretic generalization of on-line learning and an application to boosting,” Journal of Computer and System Sciences, Vol.55, No.1, pp.119–139, August 1997.
- [6] P. Viola and M. Jones, “Rapid object detection using a boosted cascade of simple features,” Proc. of IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Vol.1, pp.511–518, December 2001.
- [7] P. Viola and M. Jones, “Robust real-time object detection,” Proc. of IEEE Workshop on Statistical and Computational Theories in Computer Vision, pp.1–25, July 2001.
- [8] C. Bahlmann, Y. Zhu, V. Ramesh, M. Pellkofer and T. Koehler, “A system for traffic sign detection, tracking, and recognition using color, shape, and motion information,” Proc. of IEEE Intelligent Vehicles Symposium 2005, pp.255–260, June 2005.
- [9] H. Ishida, T. Takahashi, I. Ide, Y. Mekada and H. Murase, “Identification of degraded traffic sign symbols by a generative learning method,” Proc. of 18th International Conference on Pattern Recognition, Vol.1, pp.531–534, August 2006.