

色変動を考慮した生成型学習による道路標識検出器の構築

道満 恵介[†] 出口 大輔[†] 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

^{††} 岐阜聖徳学園大学 経済情報学部 〒 500-8288 岐阜県岐阜市中鶉 1-38

^{†††} 中京大学 情報理工学部 〒 470-0393 愛知県豊田市海津町床立 101

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

あらまし 環境変化に対してロバストかつ高速な物体検出を可能とする識別器として、Violaらが提案したカスケード型識別器がある。これを用いて様々な環境下に存在する道路標識を高精度に検出するためには、多様な見えの変動を含んだ大量の標識画像を用いて識別器の学習を行う必要がある。しかしながら、多様な見えの変動をバランスよく含んだ大量の標識画像を手作業で収集するには多大なコストがかかる。そのため、本研究では生成型学習を用いてカスケード型識別器を構築することを考える。これまでも生成型学習を用いて識別器を構築する手法は提案されているが、形状やテクスチャの変動のみが考慮されており、色の変動は考慮されていない。そこで本稿では、形状やテクスチャの変動に加えて色の変動も考慮し、より高い検出性能を持ったカスケード型識別器を構築する手法を提案する。車載カメラ映像を用いた道路標識の検出実験の結果、本稿で提案する色の変動を考慮する生成型学習により、従来よりも高い検出性能を持つカスケード型識別器が構築できることを確認した。

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

Construction of a Traffic Sign Detector Using Generative Learning Considering Color Variation

Keisuke DOMAN[†], Daisuke DEGUCHI[†], 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

^{††} Faculty of Economics and Information, Gifu Shotoku Gakuen University
1-38 Nakauzura, Gifu, Gifu, 500-8288 Japan

^{†††} School of Information Science & Technology, Chukyo University
101 Tokodachi, Kaizu-cho, Toyota, Aichi, 470-0393 Japan

E-mail: †{kdoman,ddeguchi,ttakahashi,mekada,ide,murase}@murase.m.is.nagoya-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 obtain a high detection accuracy in real environment, it is necessary to train the classifier with a set of traffic sign images which contains various appearances of traffic signs. However, collecting the sign images manually for training takes much cost. Therefore, we use a generative learning method for constructing the traffic sign detector. Furthermore, in this paper, color degradation is also considered in addition to shape and texture. By this method, the performance of the traffic sign detection is improved and the cost of collecting the training images is also reduced. Experimental results using car-mounted camera images showed the effectiveness of our method.

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

1. はじめに

近年、自動車の安全運転支援技術に対する需要が高まっている。本研究ではその一環として、車載カメラ映

像からの道路標識認識に注目する。高精度なリアルタイム道路標識認識システムが実現できれば、速度超過や進路制限の警告といった安全運転支援のための様々な応用が考えられる。



図 1 多様な変動を含んで撮影された道路標識画像

道路標識認識システムは大きく分けて、検出処理、認識処理の2つから構成される。このうち、検出処理における検出精度は後の認識精度に大きく影響するため、高い精度が求められる。標識検出手法はこれまでも数多く研究されており、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]がある。また、Violaらが提案したカスケード型識別器[5]（以降、単に「カスケード型識別器」と呼ぶ）を用いたもの[8][9][10]もある。カスケード型識別器には、多様な変動に強く、高速に物体検出が行えるという利点がある。そのため、本研究では、このカスケード型識別器に注目する。しかしながら、カスケード型識別器には、その構築において大量の学習用サンプルが必要という実用上の問題がある。図1は、実際に道路標識を撮影した際に得られた撮影画像の例である。撮影された標識の見えは、カメラと標識の位置関係や時間帯、天候等の違いから様々に変動する。安定して高い検出性能を持つ識別器の構築には、このような見えの変動を網羅的に含む大量の学習用サンプルが必要のため、学習用サンプルの収集コストが大きな問題となる。

この問題を解決するためのアプローチの1つとして、生成型学習を用いる手法が提案されている[6][7]。生成型学習とは、対象をカメラで撮影する際に起こりうる種々の見えの変動をモデル化し、それら生成モデルにより原画像から生成された生成画像を用いて学習を行う手法である。これにより、数枚の原画像から様々な変動を含んだ大量の標識画像を生成することができ、学習用サンプルの収集コストが大幅に削減できる。しかしながら、こ

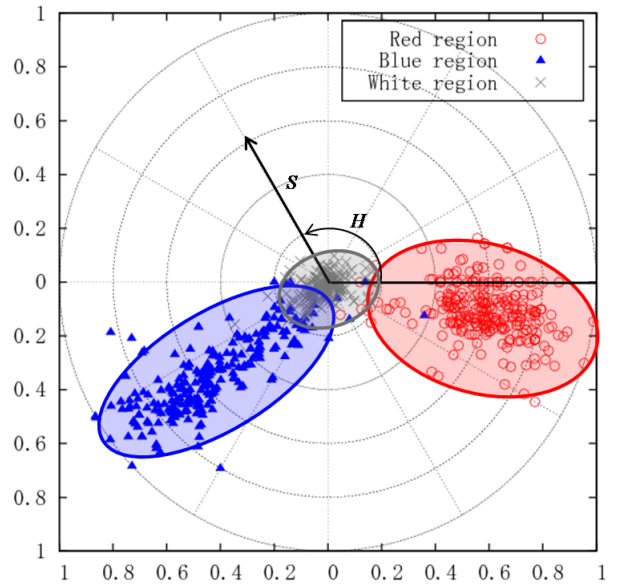


図 2 実際の標識画像における色相 H と彩度 S の分布

れまでの研究では、幾何学的変動や光学ぼけ等の形状やテクスチャの変動は考慮されているが、道路標識における色の変動は考慮されていない。図2は、実際に同一のカメラで同じ日の同じ時間帯に撮影した複数の異なる円形規制標識画像の赤色、青色、白色の3領域からランダムに抽出した画素の色相 H と彩度 S の分布である。これを見ると、同様の条件で撮影された標識画像であっても、大きな色の変動が含まれることが確認できる。このことから、実際に生じうる色の変動についても検出器の構築時に学習しておくことで、より多様な変動に対してもロバストな検出が可能になると考えられる。

そこで本稿では、形状やテクスチャの変動だけでなく色変動も考慮した生成型学習法による道路標識検出器の構築手法を提案する。これにより、色の変化に対してもロバストな検出が期待できる。以降、2節ではカスケード型識別器を用いた道路標識検出手法について述べる。続く3節では提案手法の詳細を述べ、4節では有効性を確認するための評価実験の結果と考察を述べる。最後に5節でまとめる。

2. カスケード型識別器による標識検出

本研究で標識検出器として用いるカスケード型識別器[5]は、図3に示すように、複数の識別器 H_1, H_2, \dots, H_n が直列に並んだ構造を持つ。カスケード型識別器は、顔検出[5]をはじめ、標識検出[8][9][10]、歩行者検出[11]、車両検出[12]等、様々な問題への適用例もあり、その有効性が確認されている。

カスケード型識別器により標識を検出する際には、次のように処理を行う。まず入力画像に対して、1段目の識別器 H_1 によって標識か非標識かを判定する。このとき、標識であると判定された場合のみ次段の識別器 H_2 による判定が行われ、同様の判定処理を繰り返し、最終的に




図 3 カスケード型識別器





図 4 Haar-like 特徴

全ての段の識別器を通過した場合のみ標識と判定する。いずれかの段の識別器で非標識であると判定された場合には、その時点で棄却されて処理が終了する。大抵の非標識画像は初期の段で棄却されるため、単一の識別器を利用するよりも効率的な検出処理が可能である。なお、カスケード型識別器を構成する各識別器は、AdaBoost アルゴリズムによって逐次選択された複数の Haar-like 特徴 (図 4) の組み合わせで構成される。Haar-like 特徴は、白矩形領域における平均輝度値と黒矩形領域における平均輝度値の差で表され、Integral Image を利用することで高速に計算することができる [5]。また、Haar-like 特徴は、グレースケール成分のエッジ特徴の評価に利用されることが一般的であるが、これを複数の色成分上で評価する手法が提案されている [8]。これにより、カスケード型識別器を構成する各識別器において、標識のエッジ特徴と色特徴を同時に評価することができ、検出精度の向上を図ることができる。


以上のように、カスケード型識別器により高速かつ高精度な物体検出が可能であるが、実用上の問題点も存在する。それは、十分な検出精度を得るためには、実際に起こりうる様々な変動を含む学習用サンプルを大量に用意する必要があるという点である。カスケード型識別器を標識検出器として利用する手法を提案している Bahlmann らは、識別器の学習のために標識画像を 4,000 枚収集したと報告している [8] が、多様な変動をバランス良く含んだ標識画像を数千枚も収集するコストは膨大である。次節では、高性能なカスケード型識別器を低コストで構築するための手法を提案する。

3. 提案手法：生成型学習を用いたカスケード型識別器の構築

本節では、本稿で提案する生成型学習を用いたカスケード型識別器の構築手法について述べる。生成型学習とは、検出対象の状態や撮影環境の変化によって実際に起こりうる種々の見えの変動をモデル化し、各種モデルに従って大量に生成した画像を用いて識別器の学習を行う手法である。これにより、少ない枚数の原画像を元に様々な変動を含んだ大量の学習用サンプルを得ることができる。その結果、識別器の作成時に必要な学習用サン



(a) 回転 (b) ずれ (c) 伸縮



(d) 光学ぼけ (e) 背景



(f) 退色 (g) 反射・影

図 5 提案手法で考慮する形状やテクスチャ、色の变化要因

プルの収集コストが大幅に低減される。本手法の最大の特長はこの点にある。以降、生成モデルの定義、標識画像の生成、カスケード型識別器の構築のための処理について順に述べる。

3.1 生成モデルの定義

本研究における生成型学習では、次の 7 つの見えの変動を考慮する (図 5)。

- 形状の変化：回転，ずれ，伸縮
- テクスチャの変化：光学ぼけ，背景
- 色の变化：退色，反射・影

以降、各変化要因とモデル化方法について述べる。

3.1.1 形状の変化に関する生成モデル

- 回転モデル：撮影対象の標識とカメラとの位置関係により、撮影画像の標識に回転が生じる (図 5(a))。回転をシミュレートするために、標識画像の中心を原点とした 3 次元空間の各軸周りに $\theta_x, \theta_y, \theta_z$ 度の回転を加える。

- ずれモデル：撮影画像上を走査する検出窓の位置により標識の切り出し位置のずれが生じる (図 5(b))。また、撮影時のカメラ内部における標準化の過程によりサブピクセル単位のずれが生じる。ずれをシミュレートするために、入力画像の x 軸, y 軸方向にそれぞれ Δx pixels, Δy pixels の平行移動を加える。



(a) 分割前 (b) 赤色 (c) 青色 (d) 白色

図 6 退色モデルにおける領域分割例

• 伸縮モデル：カメラの高速な移動やカメラ特性によって、撮影時に得られる標識画像の縦横比が変化する（図 5(c)）。これをシミュレートするために、入力画像の水平方向、垂直方向にそれぞれ w 倍、 h 倍の伸縮を加える。

3.1.2 テクスチャの変化に関する生成モデル

• 光学ぼけモデル：撮影に使用したカメラの焦点が標識に合っていない場合、撮影画像に光学ぼけが生じる（図 5(d)）。光学ぼけをシミュレートするために、入力画像と式 (1) に示すガウス関数との畳み込みを計算する。

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

ここで、 σ はぼけの度合いを制御するパラメータである。

• 背景モデル：撮影画像に含まれる標識の背景部分には、木や建築物、空といった風景が写り込む（図 5(e)）。背景の変化をシミュレートするために、複数の異なる環境で撮影された情景画像から N_b 枚の背景パターンを抽出し、 n_b 番目の背景パターンを入力画像の背景として合成する。

3.1.3 色の変化に関する生成モデル

• 退色モデル：標識が設置されてから年月が経ち劣化が進むにつれて、標識表面で退色が進行する（図 5(f)）。退色は、標識表面の塗料中の色素が空気や光のエネルギーにより分解されることで発生する。特に、光の成分に含まれる紫外線のエネルギーは高く、退色の最大の原因となる。そのため、紫外線を比較的吸収しやすい赤色の物質は退色しやすく、逆に紫外線を吸収しにくい青色の物質は退色しにくいという傾向がある。

本研究では、色によって退色のしやすさが異なることを考慮し、あらかじめ原画像に対して色による領域分割を行ってから、領域毎に独立に HSV 色空間上で色変化を加える。また、各領域内の色は一樣であると仮定し、各領域における退色後の画素値 (h_i, s_i, v_i) を決定する。例えば、赤色、青色、白色の 3 色で構成される「最高速度制限 50km/h」の標識の場合、赤色領域における画素値 (h_r, s_r, v_r) 、青色領域における画素値 (h_b, s_b, v_b) 、白色領域における画素値 (h_w, s_w, v_w) をそれぞれ独立に決定する（図 6）。

• 反射・影モデル：標識と光源、または標識と周囲に存在する建築物との位置関係により、標識表面での光の反射量が変化する（図 5(g)）。反射・影をシミュレ-



図 7 生成された標識画像の例

トするために、入力画像全体に一様な明度変化 v を与える。なお、反射・影に関して、標識表面における反射材の反射特性 [13]、夕焼け等の白色光源ではない光の照射、鏡面反射等によって、明度以外の色相や彩度に変化が生じる。しかしながら、本稿では各要因の発生頻度を考慮して、標識全体に定常的に発生する一様な明度変化のみを対象とする。

3.2 標識画像の生成

前節で述べた計 7 つの生成モデルによって原画像に加えられる各種変動は、生成パラメータベクトル $P = \{\theta_x, \theta_y, \theta_z, \Delta x, \Delta y, w, h, \sigma, n_b, h_i, s_i, v_i, v\}$ によって制御される。この P を適切な範囲で変化させることで、様々な変動を含んだ標識画像を生成する。実際に、形状やテクスチャ、色に関する 7 つの生成モデルにより生成された標識画像の例を図 7 に示す。

3.3 カスケード型識別器の構築

これら様々な変動が含まれた標識画像を学習用サンプルとしてカスケード型識別器を作成することで、各種変動に対してロバストな検出器の構築を目指す。カスケード型識別器を構成する各識別器の学習を行う際には、次に示す 7 つの色成分上で Haar-like 特徴を評価し、AdaBoost アルゴリズムによって最適な特徴を選択する。これにより、標識のエッジ特徴だけでなく色特徴も利用した検出処理が可能となる [8]。

- R, G, B
- $r = R/S, g = G/S, b = B/S$
- $Grayscale = 0.2989R + 0.5866G + 0.1145B$

ここで $S = R + G + B$ である。

4. 評価実験

本節では、提案手法の有効性を確認するための評価実験について述べる。

4.1 実験条件

4.1.1 検出対象

運転時に見落とすことによる危険性が高い円形の規制標識を検出対象とした。また、評価用映像を用意するため、表 1 に示す仕様のカメラを車両に搭載し、昼間に市街地や郊外を走行しながら道路標識を撮影した。その車載カメラ映像から、直径が 15 ~ 45 pixels までの対象標識が 1 つ以上含まれる計 6,874 フレームを抽出し、評価用映像を作成した。なお、評価用映像には、対象標識が合計 12,235 個含まれていた。

4.1.2 評価基準

検出精度の評価基準としては、検出結果の正確性を表す適合率（式 (2)）、検出結果の網羅性を表す再現率（式 (3)）、及びそれらの調和平均である F 値（式 (4)）を用いた。

$$\text{適合率} = \frac{\text{正検出の数}}{\text{検出領域の総数}} \quad (2)$$

$$\text{再現率} = \frac{\text{正検出した対象標識の数}}{\text{対象標識の総数}} \quad (3)$$

$$F \text{ 値} = \frac{2 \times \text{適合率} \times \text{再現率}}{\text{適合率} + \text{再現率}} \quad (4)$$

なお、本実験では、検出領域が人手で指定した対象標識の中心を含んでいれば正検出（検出成功）、そうでなければ誤検出として数えた。

4.1.3 学習条件

生成型学習における対象標識の原画像としては、図 8 に示す 20 種類の標識画像を用いた。標識画像の生成に用いた各パラメータは互いに独立で正規分布に従うと仮定し、表 2 に示す平均と標準偏差から正規乱数により発生させた。なお、これら平均と標準偏差は経験的に決定した。退色モデルについては、各原画像を赤色領域と青色領域、白色領域に分割し、赤色領域と青色領域のみに退色を適用した。背景モデルについては、合成用背景パターンとして 216 種類の部分画像を用意し、これらからランダムに選択した。

また、カスケードを構成する各識別器の学習時には、AdaBoost アルゴリズムに基づき、標識画像の 99.9%、非標識画像の 50% を正しく識別できるようになるまで Haar-like 特徴の追加を行った。なお、各識別器の学習における非標識画像としては、対象標識を含まない 160 枚の情景画像（640 × 480 pixels）からランダムに抽出した部分領域を用いた。カスケードを構成する各識別器の学習に用いる非標識画像は最大 5,000 枚とし、160 枚の情景画像における部分領域を全て棄却できるようになるまでカスケードの段数を増やした。

表 1 車載カメラの仕様

撮影機器	SANYO Xacti DMX-HD2
解像度	640 × 480 pixels
フレームレート	30 fps



図 8 生成に用いた原画像（340 × 340 pixels）

4.2 実験方法

生成型学習において色変動を考慮することの効果を確認するため、以下の方法によりカスケード型識別器の検出性能を評価した。まず、形状、テクスチャ、色に関する 7 つの生成モデルを用いて標識画像を計 5,000 枚（原画像毎に 250 枚）生成し、それらを学習用サンプルとしてカスケード型識別器の学習を行った（色変動あり）。次に、それら 7 つの生成モデルのうち、形状、テクスチャに関する 5 つの生成モデルのみを用いて標識画像を計 5,000 枚（原画像毎に 250 枚）生成し、同様にカスケード型識別器の学習を行った（色変動なし）。また、それぞれの場合において、Grayscale 成分のみを学習と検出に利用した場合（色特徴なし）と、 R, G, B, r, g, b , Grayscale の 7 つの成分を学習と検出に利用した場合（色特徴あり）の 2 種類の学習を行い、次の 4 つの方法で構築されたカスケード型識別器を評価用映像に適用して検出精度を比較した。

- 生成：色変動なし，学習・検出：色特徴なし
- 生成：色変動なし，学習・検出：色特徴あり
- 生成：色変動あり，学習・検出：色特徴なし
- 生成：色変動あり，学習・検出：色特徴あり（提案手法）

4.3 実験結果

4 種類の場合それぞれにおける検出精度を表 3 に示す。この値は、それぞれの学習・検出処理を 10 回ずつ試行して得られた検出精度の平均値である。色変動なしと色変動ありの間の F 値の変化に注目すると、色特徴の有無を問わず、色変動ありの場合の方が高い検出精度が得られた。ただし色変動考慮の効果は、色特徴なしの場合より

表 2 生成パラメータの平均と標準偏差

	回転 [°]			ずれ [pixels]		伸縮		光学ぼけ σ	退色						反射・影 v
	θ_x	θ_y	θ_z	Δx	Δy	w	h		赤色領域			青色領域			
									h_r	s_r	v_r	h_b	s_b	v_b	
平均	0.0	0.0	0.0	0.0	0.0	1.0	1.0	0.0	355.0	0.65	0.8	214.0	0.7	0.7	-0.25
標準偏差	2.45	2.45	2.45	10.0	10.0	0.078	0.078	2.0	9.49	0.14	0.045	7.75	0.16	0.045	0.17

色相，彩度，明度はそれぞれ， $[0, 360)$ ， $[0, 1]$ ， $[0, 1]$ の範囲で正規化した値。

表 3 検出性能の比較：色変動なし vs. 色変動あり

	色変動なし		色変動あり	
	色特徴なし	色特徴あり	色特徴なし	色特徴あり (提案手法)
適合率	0.85	0.96	0.86	0.97
再現率	0.74	0.56	0.85	0.93
F 値	0.79	0.71	0.85	0.95

も色特徴ありの場合の方が大きかった。また，色変動なしの場合においては，色特徴を利用することにより再現率が逆に低下した。4 種類の方法の中で最も高い検出精度となったのは，色変動ありの場合に色特徴を利用した場合（提案手法）であり，F 値で 0.95 と高い検出精度が得られた。色変動なしの場合に色特徴を利用した場合と，色変動ありの場合に色特徴を利用した場合（提案手法）における検出結果の例を図 9，図 10 にそれぞれ示す。これらの図で，緑の矩形が対象標識であると判定された検出領域である。なお，一つの標識の周辺に複数の検出領域が重複して出力されているが，本実験ではこれらの検出領域を統合する処理は行っていない。

4.4 考察

4.4.1 色変動考慮の効果

生成型学習において，形状やテクスチャの変動に加えて色の変動も考慮した生成画像により識別器の学習を行うことで，検出精度が向上した。これに関して，評価用映像に含まれる標識画像と各生成画像との比較を図 11 に示す。これを見ると，色変動を考慮した場合の方が，生成画像に含まれる各種変動の分布が実際の撮影画像に含まれる変動の分布に近い。このことが，色変動を考慮した生成型学習により検出精度が向上した要因であると考えられる。なお，色変動を考慮した生成型学習の効果は，色特徴なしの場合よりも色特徴ありの場合の方が大きかった。これは，色特徴なしの場合においては *Grayscale* のみを用いて学習，検出を行ったため，グレースケール変換の際に色の差異が吸収され，様々な色変動を含んだ標識画像を生成することの効果が現れにくかったからであると考えられる。

4.4.2 色特徴利用の効果

色変動考慮の有無によって色特徴利用の効果が異なり，色変動を考慮しない場合には色特徴の利用により検出精度が低下した。これは，識別器構築時に用いた学習用サンプルにおける色分布と，実際に撮影画像に含まれる標

識の色分布が関係していると考えられる。色変動を考慮せずに生成された標識画像には，円周部分やシンボル部分における色の多様性がなく，全てのサンプル間で同じ色となる（図 11(b)）。そのため，これらのサンプルで学習した色特徴が多様な変動を含む実際の標識画像に対して有効に作用せず，結果として色特徴の利用が逆効果となったと考えられる。

4.4.3 収集コストの削減

本実験では，5,000 枚の標識画像を用いてカスケード型識別器の学習を行ったが，このうち手作業での収集が必要な標識画像は，生成における原画像 20 枚のみである。これに関して，評価用映像の 2,967 frames から手作業でランダムに収集した 5,000 枚の標識画像を用いてカスケード型識別器を構築する操作を 10 回繰り返し，評価用映像に含まれる残りの 3,907 frames に対する検出精度の平均を求めた結果，F 値は 0.94 であった。このときの学習用サンプルの収集枚数は 5,000 枚であるが，提案手法とほぼ同じ検出精度である。20 枚の収集で 5,000 枚の収集と同程度の性能を得ることができたことから，提案手法によって収集コストが削減できていることが確認できた。

4.4.4 色変動のシミュレート性能

生成型学習における色変動のシミュレート性能を更に向上させるためには，次の 3 つの要素について更に検討する必要がある。

- 考慮する色変動要因：本実験では色変動要因として退色と反射・影に注目したが，それら以外にも，例えばカメラの露光量やホワイトバランス等のカメラ特性の違いにより撮影画像の全体的な色分布は大きく変化する。そのため，新たな色の変動要因を追加考慮することで，より撮影画像に近い標識画像を生成することができると考えられる。

- モデル化の方法：本実験では，HSV 空間上での色変化モデルにて退色をシミュレートした。しかし，HSV 表色系による表現方法は人の色感覚とよく一致することが知られているものの，退色による色の変化表現に適しているとは限らない。そのため，より適した退色表現が可能な色空間を定義することで，実際の退色を更にうまくシミュレートできると考えられる。

- 生成パラメータの決定方法：適切に変動要因が考慮され，かつ適切にモデル化できたとしても，モデルに適切な生成パラメータを与えなければ実際の変動を精度



(a) 色変動なし，色特徴なし



(b) 色変動あり，色特徴あり（提案手法）

図 9 検出結果の比較 1



(a) 色変動なし，色特徴なし



(b) 色変動あり，色特徴あり（提案手法）

図 10 検出結果の比較 2



(a) 実際の撮影画像



(b) 生成画像（色変動なし）



(c) 生成画像（色変動あり）

図 11 評価用映像に含まれる実画像と生成画像の比較

良くシミュレートすることはできない。本実験では実際の撮影画像を目視で確認しながら経験的に生成パラメータを決定したが、回転やぼけに関する生成パラメータの分布を遺伝的アルゴリズムを用いて実験的に推定する手法 [7] も提案されている。色変動に関するパラメータ分

布も同様な方法で実験的に推定できれば、実際に撮影された標識画像により近い画像生成が可能になると考えられる。

5. ま と め

本稿では、道路標識を検出するためのカスケード型識別器を、形状やテクスチャ、色の変動を考慮した生成型学習により構築する手法を提案した。生成型学習により識別器を作成することで、様々な見えの変動を含んだ学習用サンプルを少ない収集コストで生成することができる。また、生成型学習における画像生成時に、形状やテクスチャの変化だけでなく色の変化も考慮することで、実際の撮影画像により近い標識画像が生成できる。さらに、色変動を適切に考慮することで、生成型学習を用いて作成されたカスケード型識別器においてエッジ特徴だけでなく色特徴も有効に利用することができる。車載カメラ映像を用いた実験により、色変動考慮の有無による検出精度の比較を行った結果、提案手法によってF値で0.95という高い検出精度が得られたことから、本手法の有効性が確認できた。

今後は、生成型学習において、退色や反射、影に加えてカメラ特性の考慮、最適な色変動のモデル化方法、生成パラメータの決定方法等を検討していく。また、検出器から出力された検出領域に対する統合処理、時系列情報報の利用による検出精度向上に関しても検討していく。

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深く感謝する。本研究の一部は文部科学省科学研究費補助金による。また、本研究では画像処理にMISTライブラリ (<http://mist.murase.m.is.nagoya-u.ac.jp/>)を使用した。

文 献

- [1] A. de la Escalera, L. E. Moreno, M. A. Salichs and J. M. Armingol: "Road traffic sign detection and classification," *IEEE Trans. on Industrial Electronics*, Vol.44, No.6, pp.848–859, December 1997.
- [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, PRMU2004-262, March 2005.
- [3] N. Barnes and A. Zelinsky: "Real-time radial symmetry for speed sign detection," *Proc. of 2004 IEEE Intelligent Vehicles Symposium*, pp.566–571, June 2004.
- [4] G. Loy and N. Barnes: "Fast shape-based road sign detection for a driver assistance system," *Proc. of 2004 IEEE/RSJ International Conference on Intelligent Robots and Systems*, Vol.1, pp.70–75, September–October 2004.
- [5] P. Viola and M. Jones: "Rapid object detection using a boosted cascade of simple features," *Proc. of 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Vol.1, pp.511–518, December 2001.
- [6] 道満恵介, 高橋友和, 目加田慶人, 井手一郎, 村瀬洋: "生成型学習とカスケード型識別器による道路標識検出・認識," 画像の認識・理解シンポジウム (MIRU2008) 講演予稿集, pp.376–381, July 2008.
- [7] 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.

- [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 2005 IEEE Intelligent Vehicles Symposium*, pp.255–260, June 2005.
- [9] C. G. Keller, C. Sprunk, C. Bahlmann, J. Giebel and G. Baratoff: "Real-time recognition of U.S. speed signs," *Proc. of 2008 IEEE Intelligent Vehicles Symposium*, pp.518–523, June 2008.
- [10] R. Ach, N. Luth and A. Techmer: "Real-time detection of traffic signs on a multi-core processor," *Proc. of 2008 IEEE Intelligent Vehicles Symposium*, pp.307–312, June 2008.
- [11] C. R. Wang and J. J. Lien: "AdaBoost learning for human detection based on histograms of oriented gradients," *Proc. of Asian Conference on Computer Vision, Lecture Notes in Computer Science*, Vol.4843, pp.885–895, Springer-Verlag, June 2007.
- [12] P. Negri, X. Clady, S. M. Hanif and L. Prevost: "A cascade of boosted generative and discriminative classifiers for vehicle detection," *EURASIP J. on Advances in Signal Processing*, Vol.8, No.2, Article No.65, January 2008.
- [13] 山中俊夫, 石川真澄, 古川匡亮, 栗岡豊, 池田潤平: "交通標識用再帰性反射材料の照明・観測条件による色の変化," 日本色彩学会誌, Vol.4, No.3, pp.82–83, May 1980.