

道路標識認識のための学習データ生成手法の検討

石田 皓之[†] 高橋 友和[†] 井手 一郎[†] 村瀬 洋[†] 榎本 光宏^{††}

[†] 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

^{††} 株式会社デンソー

〒 470-0111 愛知県日進市米野木町南山 500-1

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

あらまし 車載カメラにより外界を認識し、運転を支援する技術の実用化が期待されている。道路標識の認識技術もその一つである。技術の実用化のためには、画像品質にロバストな標識の認識が要求される。しかし実際の撮影画像はぶれの影響や解像度の低下によって、認識が困難な場合が多い。本稿では、そのような低品質画像の認識に適した学習法の検討を行った。本手法は、原画像から学習画像を自動生成するもので、学習画像の生成過程において、現実の劣化・変形特性を反映した生成を行う。それにより認識率の向上を図るとともに、学習画像の収集を行う手間が省け、学習過程が効率化される。本学習法では、劣化および変形を種々の要因に分離しモデル化して、各要因毎のパラメータの設定により生成を行う。撮影画像からその劣化特性を得るため遺伝的アルゴリズムによってパラメータ分布の推定を行い、生成過程に利用した。認識は部分空間法を用い、学習過程においてこの生成型学習法を用いる。実際の道路標識の認識実験により、本学習法の有効性を示した。

キーワード 生成型学習, 標識認識, 車載カメラ, 低解像度, 部分空間法

A Study on the Generation Process of Training Data for Traffic Sign Recognition

Hiroyuki ISHIDA[†], Tomokazu TAKAHASHI[†], Ichiro IDE[†], Hiroshi MURASE[†], and Mitsuhiro ENOMOTO^{††}

[†] Graduate School of Information Science, Nagoya University

Furo-cho, Chikusa-ku, Nagoya, Aichi, 464-8601 Japan

^{††} DENSO Corporation

500-1, Minamiyama, Komenoki-cho, Nisshin-shi, Aichi, 470-0111 Japan

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

Abstract Traffic sign recognition is one of the ITS(Intelligent Transport system) technologies for supporting car drivers. We are developing a robust recognition system for traffic signs using the Subspace method. For that purpose, we propose a new training method for the recognition of low quality traffic sign images. This method is based on Generative Learning, which generates various training samples from an original image. This method is efficient, because it saves the process of collecting various traffic sign images. We propose six independent generation models, which reflect the actual degradations. Each generation model has its own parameters that represents the degree of degradations, so this system generates various degraded images artificially. We estimated the distribution of parameters using Genetic Algorithm by evaluating the similarity between the generated image and the actually captured sign image. We generate parameters that follow the estimated distributions for artificially generated sign images for the learning. We confirmed the usefulness of our method through the application to actual sign.

Key words Generative Learning, Sign Recognition, Car-mounted Camera, Low Resolution, Subspace Method

1. はじめに

近年、車載カメラで外界を認識し、運転を支援する技術が注目を集めている。撮影画像中の道路標識の認識もその一つである。道路標識の認識に関しては、現在まで多くの研究がなされてきた。画像の色情報と標識の形状特徴を利用した高速な円形標識の抽出法 [1]、円形判別と領域面積比率判別を利用した円形標識の抽出法 [2]、また、輝度、彩度の分布特徴を利用した標識の種類別・認識手法 [3] などである。これらの手法 [1] ~ [3] はいずれも色情報や形状情報を用いた抽出および分類を行っているが、低品質画像から標識中の文字など細かな差異を識別する研究は少ない。

我々は、低品質画像中の標識を認識するための学習法を研究している。撮影した標識画像は、ぶれやぼけ、解像度低下などの影響を受けるため、学習法の検討が必要となる。文字認識の分野では、ぼけ関数を用いて学習画像を自動生成する生成型学習法 [4], [5] が提案されている。生成型学習法は、実際に撮影されるであろう劣化画像を原画像から多数生成し、それらを学習画像として学習する方法であり、全学習画像を収集する方法と比較すると、学習過程が効率化される。[5] では、デジタルカメラを用いた動画からの文字認識手法 [9] の学習過程において、学習画像を自動生成することで、学習画像の収集作業をせずとも、低品質文字画像の学習ができることが示されている。学習画像の生成においては、コンパウンド法 [10] を用いて複数画像から推定した劣化の点広がり関数 (PSF: Point Spread Function) [8] により、劣化のシミュレーションを行っている。しかし [5] で提案された生成型学習法には、劣化要因が分離されていないため、撮影環境の変動に柔軟に対応できないという問題点があった。

本研究では、様々な撮影条件を想定し、多数の劣化・変形要因について個別にモデル化を試みた。要因別に、生成モデルを構築し、各モデルに対し適切なパラメータを与えることで、多様な学習画像を生成できるようになる。また生成型学習法では、生成過程において現実に即した生成を行う必要があるため、生成モデルのパラメータの分布推定を行う。この際撮影した標識画像を目標画像とし、それに類似する画像を標識の原画像からシミュレートする。本研究では目標画像とシミュレートした画像の類似度を最大にするパラメータを遺伝的アルゴリズム [11] によって推定する。さらに、多数の撮影画像からそれを推定することでパラメータの分布を推定する。本手法においてパラメータ分布の推定とは、各パラメータの平均と分散を推定することである。生成過程においては、推定された分布に従うパラメータを発生させ、これを用いて各標識の学習画像群を生成する。

なお本研究では、部分空間法 [6] [7] による認識を行う。一般に部分空間法は学習と認識の 2 段階からなり、学習段階では学習画像の画像特徴を近似する固有ベクトルを計算し、各クラス毎の部分空間を作成する。認識では学習段階で作成した部分空間に認識対象となる画像を射影し、各クラスごとの部分空間との類似度を求め、その類似度を基準に対象物をクラスに分類



図 1 撮影標識画像

する。

本稿では、標識の中でも判別の難しい速度標識を対象とした認識実験を行うことにより、提案する生成型学習法の有効性を示す。2 章では、標識画像の劣化・変形要因と、それをシミュレートするために提案した生成モデルについて述べる。3 章では、本稿の核となる生成型学習法について述べ、生成モデルに基づくパラメータの推定から学習までの手順を示す。4 章では、部分空間法を用いた標識の認識手法について述べる。5 章では、認識実験による学習法の比較を行い、結果の考察を行う。

2. 劣化・変形要因

学習画像を生成するためには、現実に起こる劣化・変形の特徴を知る必要がある。本章では撮影標識画像の劣化・変形要因について述べる。認識対象となる標識画像の例を図 1 に示す。

図 1 はデジタルカメラにより撮影した標識の画像であるが、撮影条件が悪かったため、計算機による識別が難しくなっている。このような撮影画像のシミュレーションを行うために、要因別に以下に示す生成モデル (図 2) を構築した。

(a) 位置ずれモデル

標識切り取り位置のずれを表すモデルである。原画像上における標識の標準となる切り取り位置を定義し、その位置からの水平方向のずれ、及び垂直方向のずれをそれぞれパラメータ Δx , Δy で定義する (図 2(a))。

(b) 縦横伸縮モデル

切り出し範囲の伸縮を表すモデルである。この切り出し範囲の変動は、カメラの特性に起因するものである。切り出し範囲の横幅、縦幅をそれぞれパラメータ w , h で定義する (図 2(b))。

(c) 回転モデル

標識およびカメラの傾きに起因する撮影画像中の標識の回転を表すモデルである。標識は空間中の平面 $z = 0$ 上に存在し、点 $(0, 0, 0)$ を中心とするものとする。 x , y , z 軸回りのそれぞれの回転角 θ_x , θ_y , θ_z をパラメータとし、回転を行う (図 2(c))。

回転前の画像を P_0 、回転後の画像を P_1 、軸回転行列を $R_z R_y R_x$ とし、回転を次式で表す。

$$P_1(x, y) = P_0(x', y') \quad (1)$$




図 2 生成モデル

$$\begin{bmatrix} x' \\ y' \\ z' \end{bmatrix} = (\mathbf{R}_z \mathbf{R}_y \mathbf{R}_x)^{-1} \begin{bmatrix} x \\ y \\ 0 \end{bmatrix}$$

(d) 光学ぼけモデル

対象物がカメラのレンズを通してセンサ上に写像されるとき、焦点ずれに起因するぼけのモデルである。次式のガウス関数を画像にたたみこみ、ぼけをシミュレートする。 σ はぼけの強度に対応するものであり、これをパラメータとする (図 2(d))。

ぼかし前の画像を P_1 、ぼかし後の画像を P_2 、ガウス関数を G とし、ぼけを次の式で表す。

$$P_2 = P_1 * G \quad (2)$$

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

(e) ぶれモデル

カメラが撮影中に高速で移動することに起因する、ぶれのモデルである。ぶれ画像をぶれ方向 ϕ ($-\pi/2 < \phi < \pi/2$)、ぶれ距離 b の 2 つのパラメータを用いる (図 2(e))。

ぶれ前の画像を P_2 、ぶれ後の画像を P_3 、水平方向のぶれを b_x 、垂直方向のぶれを b_y とし、ぶれを次の式で表す。

$$P_3(x, y) = \sum_{i=0}^I P_2\left(x + \frac{i}{I}b_x, y + \frac{i}{I}b_y\right) \quad (3)$$

$$b_x = b \cos \phi$$

$$b_y = b \sin \phi$$

なお、本手法では $I = 4$ とした。

(f) 解像度低下 (画素数変換) モデル

切り出した (もしくは生成時に設定する) 標識のサイズをパラメータ d として表す。このパラメータは他のパラメータと異なり、目標画像から一意に求められるため、推定する必要はない。解像度低下前の画像を P_3 、解像度低下後の画像を P_4 とし、低下後の画像を次式で表す (図 2(f))。

$$P_4(i, j) = \sum_{x, y \in D(i, j)} P_3(x, y) \quad (4)$$

$$D(i, j) = \left\{ (x, y) \mid \frac{i}{d+1}w \leq x + \frac{w}{2} - \Delta x < \frac{i+1}{d+1}w, \right. \\ \left. \frac{j}{d+1}h \leq y + \frac{h}{2} - \Delta y < \frac{j+1}{d+1}h \right\}$$

以上のモデル (a) ~ (f) を用い撮影画像をシミュレートする際には、回転、ぼけ、ぶれの順に処理を行い、その後位置ずれ、伸縮、解像度低下モデルに従う切り取り処理を行う。

3. 生成型学習法

3.1 概要

生成型学習法は、提案した生成モデルに従い、原画像から実際に撮影されるであろう画像を多数生成して、これを学習画像として学習する方法である。従来は、撮影によって学習画像を収集する方法が用いられているが、収集には多くの手間を要する。一方、原画像をそのまま照合させる方法もあるが、この場合、現実の劣化・変形特性を考慮した学習がされないため、低品質画像の認識に不適であるということが明らかになっている [5]。

生成型学習法は、原画像からシミュレーションにより学習画像を生成するため、その両者の特徴を併せ持つ手法といえる。利点としては、学習に用いる全ての学習画像を撮影によって収集する必要がないため、学習過程が効率化されていること、クラス数を増加させる場合でも、クラスに対する原画像の追加のみで対応できることが挙げられる。

図 3 に従来の学習法 (a) と生成型学習法 (b) の手順をそれぞれ示す。以下の節において、生成型学習法における各々の手順について述べる。

3.2 各訓練データにおけるパラメータ推定過程

はじめに、生成モデルのパラメータを、撮影画像から推定する。パラメータを与えて原画像から劣化させた生成画像を P 、撮影した推定用の目的画像を Q とする。 p, q は、 P, Q の各画素値を要素とするベクトルを、平均 0、ノルム 1 となるように変換したものとす。生成画像と目的画像の類似度を内積 $p \cdot q$ で定義する。この類似度を最大にするパラメータが最適パラメータである。実際は最適パラメータを求めるのは困難であ

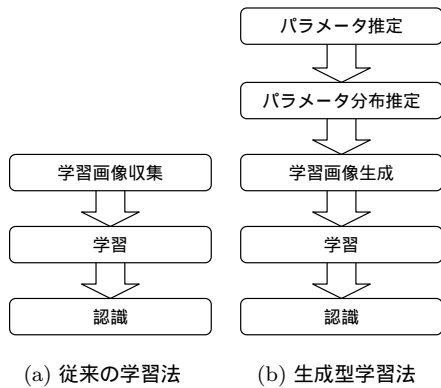


図 3 認識までの手順

るため、本手法では遺伝的アルゴリズムを用いて最適パラメータを推定する。

ここで推定すべきパラメータは 2 章で示したパラメータ $\Delta x, \Delta y, w, h, \theta_x, \theta_y, \theta_z, \sigma, \phi, b$ である。目的画像に対し、それらのパラメータを用いて、そのクラスの標識の原画像を劣化させる。パラメータ d は目的画像の大きさから求まる。以下に、パラメータの推定過程を示す。

1. 個体数 M の集団を生成し、各個体につきそれぞれを構成する 10 個のパラメータ $\Delta x, \Delta y, w, h, \theta_x, \theta_y, \theta_z, \sigma, \phi, b$ を一様乱数によって設定する。
2. 各個体につき、そのパラメータをもとに劣化・変形させた画像を生成し、目的画像との類似度を求める。
3. 次世代に残す個体を 2 つ選択する。個体の選択は、類似度で重み付けされたルーレット選択を用いる。
4. 選択した 2 個体に対し、交叉率 P_c で交叉を行う。交叉を行う場合は、各パラメータにつき確率 0.5 で 2 個体間のパラメータを交換する。生成した個体は次世代集団に加える。
5. 次世代集団の個体数が M に等しくなるまで、手順 3, 4 を繰り返す。
6. 次世代集合中の各個体に対し、突然変異率 P_m で、パラメータの一つを一様乱数で再設定する。
7. 世代数が G になるまで世代交代を行い、手順 2.~6. を繰り返す。
8. 類似度が最大となる個体のパラメータを採用する。

パラメータ推定過程の概略を図 4 に、遺伝的アルゴリズムによる類似画像の生成例を図 5 に示す。

3.3 パラメータ分布の推定

パラメータの分布を求めることは、標識画像の劣化・変形の傾向を把握し、生成過程においてそれを再現する上で重要となる。前節では単一の撮影画像のパラメータを推定する手順について述べた。それらのパラメータを多数の撮影画像から推定することで、各パラメータの分布が求まり、それを生成過程に利用することができる。各パラメータにつき、その平均および分散を求め、これをパラメータ分布とする。

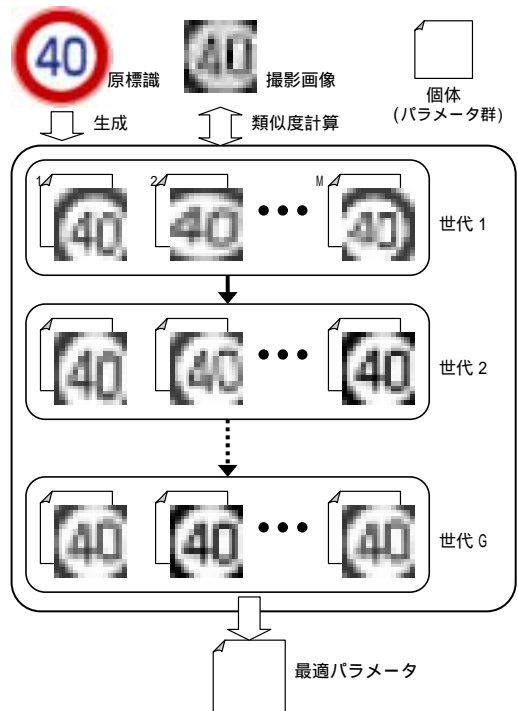


図 4 パラメータ推定過程




図 5 パラメータ推定により生成された画像例

3.4 学習画像の生成過程

学習画像を生成する過程について述べる。生成過程においては、生成パラメータを発生 [12] させ、学習画像を生成する。パラメータの分布は、撮影時の解像度パラメータ d および標識の種類によらないものと仮定する。各標識、各解像度ごとに分布に従う学習画像群の生成を行う。生成までの概略図を図 6 に示す。

3.5 部分空間の作成

本手法で用いる部分空間法の学習過程について述べる。部分空間法は、学習画像の画像特徴を近似する低次元の固有ベクトルを作成し、分類に用いる手法である。標識のクラス数を M 、クラス毎に用意する学習画像の数を N 、認識に用いる固有ベクトルの数を L 、認識対象の解像度の段階数を R とする。クラス m 、解像度 r における n 番目の学習画像画像を、ラスタスキャン方式でベクトル化し、 $x_{m,n,r}$ と表す。これらのベクトルを 1 列に並べ、その行列の自己相関行列 $X_{m,r}$ を次式 (5) で求める。

$$X_{m,r} = [x_{m,0,r} \cdots x_{m,N-1,r}] [x_{m,0,r} \cdots x_{m,N-1,r}]^t \quad (5)$$

この自己相関行列の固有ベクトル展開を行う。 $X_{m,r}$ の固有値を求め、その値の大きい順に L ($\leq N$) 個の固有ベクトル $u_{m,r,l}$ を認識に用いる。

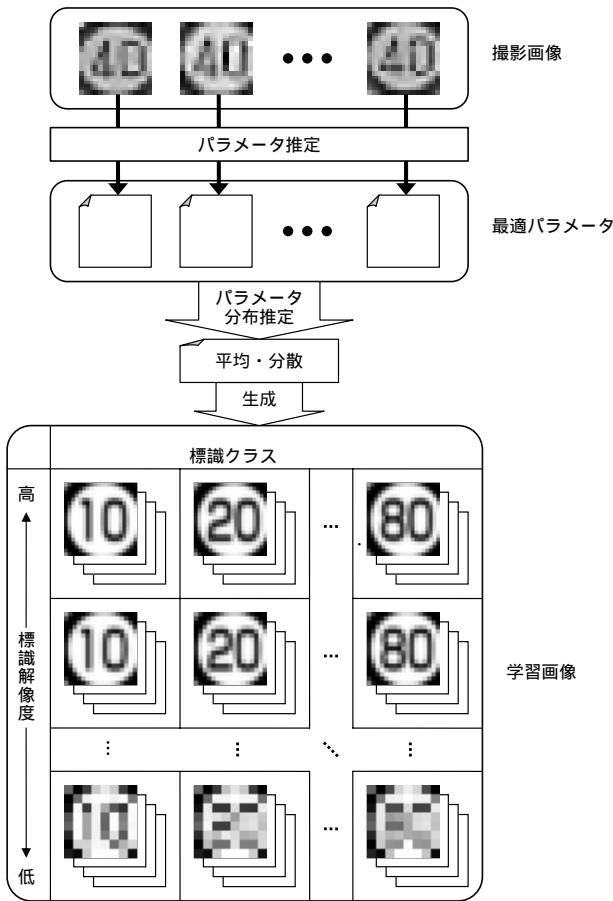


図 6 パラメータ推定から生成までの過程



図 7 固有ベクトルの例 (標識「20」の上位 3 個)

4. 部分空間法による認識

本章では、部分空間法による標識の認識過程について述べる。部分空間法では、標識画像を、各クラスに対し対応する解像度の部分空間に射影することによって類似度を計算する。

単一フレームから認識を行う場合の具体的な計算式を以下に示す。認識対象の標識を切り出し、それを学習画像と同じクラスタスキャンによってベクトル化し、平均値 0、ノルム 1 となるように変換したものを y とする。ここで r は切り出した標識のサイズである。

$$s_m(0) = \sum_{i=0}^{L-1} (\mathbf{u}_{m,r,i} \cdot \mathbf{y})^2 \quad (6)$$

なお、複数のフレームの情報を累積的に利用することで、全体の認識率が向上することが示されている [9]。 F フレーム分の撮影画像 y_j を使用する場合、類似度は次式で表される。

$$s_m(F) = \sum_{j=0}^{F-1} \sum_{i=0}^{L-1} (\mathbf{u}_{m,r,i} \cdot \mathbf{y}_j)^2 \quad (7)$$

全クラスに対して、入力標識との類似度を計算し、最大の類似度を与えるクラスを認識結果とする。

5. 手法比較実験

5.1 比較手法

提案手法の有効性を示すために速度標識を対象とした比較実験を行った。本実験では、提案する生成型学習法における 2 つの柱—生成モデルの構築および、パラメータの分布推定について有効性をそれぞれ示すため、以下に示す 3 つの学習法を用いて学習を行い、認識結果の比較を行った。

- ・提案手法：生成型学習（パラメータ推定あり）

本稿で提案する生成型学習法であり、パラメータの推定に基づく手法である。推定されたパラメータ分布に従い、解像度以外のパラメータを正規乱数で与えることにより、学習画像の生成を行う。部分空間法により次元を圧縮し、上位 10 個の固有ベクトルを用いて認識する。

- ・比較手法 (A)：原画像照合

原画像をそのまま学習データとして用いる学習法である。照合のため、解像度低下モデルに基づいた辞書データのサイズ正規化は行うが、その他の劣化要因を考慮に入れない学習法である。

- ・比較手法 (B)：生成型学習（パラメータ推定なし）

提案する生成モデルに基づき、パラメータを与えて生成を行う生成型学習法である。パラメータの分布推定は行わず、解像度以外のパラメータを一様乱数で与えることにより、学習画像の生成を行う。部分空間法により、次元を圧縮し、上位 10 個の固有ベクトルを用いて認識する。

5.2 標識切り出し

パラメータ推定用の標識画像と認識対象の標識画像の切り出しには、色情報を用いたアルゴリズムを適用する。本実験では速度標識を対象とするため、標識の赤い外周領域の色情報を利用する。日射条件や標識自体の色あせに対してもマスクに切り出しが行えるように HSV 空間への変換 [13] を行う。画素 (x, y) における色相、彩度、明度をそれぞれ $H(x, y)$, $S(x, y)$, $V(x, y)$ とし、注目画素が赤い外周領域かどうかを以下の判別式 red で定義する。

$$\text{red}(x, y) = \begin{cases} 1 & \left(\begin{array}{l} 2n\pi - \frac{\pi}{9} < H(x, y) < 2n\pi + \frac{\pi}{9} \\ \text{and } 0.2 < S(x, y) \leq 1 \\ \text{and } 30 \leq V(x, y) \leq 255 \end{array} \right) \\ 0 & (\text{otherwise}) \end{cases} \quad (8)$$

(x_0, y_0) を標識の中心、 R_1 を内周領域、 r_1 を内周円の半径、 R_2 を外周円領域、 r_2 を外周円の半径とする。(図 8)

各領域は次の式で表現される。

$$R_1 = \left\{ (x, y) \mid \sqrt{(x-x_0)^2 + (y-y_0)^2} < r_1 \right\} \quad (9)$$

$$R_2 = \left\{ (x, y) \mid r_1 < \sqrt{(x-x_0)^2 + (y-y_0)^2} < r_2 \right\} \quad (10)$$

以下の評価値 $c_{(x_0, y_0, d)}$ を最大にする標識の中心位置 (x_0, y_0)




図 8 標識切り出しパラメータ

およびサイズ d を求めることによって切り出しを行う。

$$C_{(x_0, y_0, d)} = \frac{\sum_{(x, y) \in R_2} \text{red}(x, y)}{\sum_{(x, y) \in R_2} 1} - \frac{\sum_{(x, y) \in R_1} \text{red}(x, y)}{\sum_{(x, y) \in R_1} 1} \quad (11)$$

本実験では動画像を用い、連続するフレームに対し順々に標識を切り出して利用した。前フレームの標識位置情報 x_0, y_0 を用い、その近傍のみを探索することで、効率良く標識の追跡を行うことができる。

5.3 パラメータ分布推定

本稿の提案手法による、パラメータの分布推定実験について述べる。本実験では標識「40」を撮影した動画から 200 フレーム (サイズ 10~19 につき各 20 枚) の標識画像を抽出し、それら各標識画像に対し、パラメータの推定を行った。遺伝的アルゴリズムのパラメータは、個体数 $M = 50$, 世代数 $G = 100$, 交叉率 $P_c = 0.7$, 突然変異率 $P_m = 0.001$ とした。求まったパラメータの分布を以下の表 1 に示す。

表 1 パラメータ分布

	平均	偏差		平均	偏差
$\Delta x [cm]$	0.23	1.10	$\theta_y [^\circ]$	-0.11	4.53
$\Delta y [cm]$	1.19	1.24	$\theta_z [^\circ]$	-3.27	3.17
$w [cm]$	37.7	1.86	σ	12.1	5.30
$h [cm]$	40.9	1.79	$\phi [^\circ]$	3.03	54.9
$\theta_x [^\circ]$	0.17	4.39	$b [cm]$	0.08	1.56

5.4 実験方法

各学習法の認識精度の比較実験を行う。本実験では速度標識「10」~「80」の 8 クラスを想定し、学習を行った。デジタルビデオカメラを用いて様々な距離で撮影した速度標識「20」, 「30」, 「40」, 「50」, 「80」につき、提案手法および比較手法 (A), (B) による認識率を比較した。認識対象の画像は、各標識につき、切り出し時の標識画像の大きさが $7 \times 7 \sim 20 \times 20$ の 14 段階の解像度を、それぞれ 20 フレーム分を用いた。本実験では類似度を単一フレームのみから求め、認識率を比較した (4 章式 (6))。




図 9 認識結果 (解像度別)




図 10 認識結果 (標識種類別)

5.5 実験結果

解像度を、7~10, 11~15, 16~20 の 3 段階に大分し、各段階につき認識率を求め、対象とする全標識に対しその平均を求めたグラフを図 9 に示す。また、全解像度の認識率を平均し、標識の種類別に認識率の比較を行ったグラフを図 10 に示す。

5.6 考察

提案手法および手法 (B) において、全体の認識率が向上しているという実験結果より、本稿で提案した生成モデルが、現実の撮影画像のシミュレーションに有効であることが示された。また、提案手法と手法 (B) を比較すると、サイズ 11 以上の標識に対しては、提案手法が高い認識率を示す一方で、サイズ 10 以下の標識に対しては顕著な改善が見られなかった。切り出し時のサイズが 10 以下の低解像度画像は、位置ずれの影響が特に大きく、推定したパラメータが有効ではなかった可能性がある (図 11(a))。これは、解像度低下パラメータが他のパラメータと独立であるという仮定に反する結果であり、今後の検討が必要であると考えられる。しかし、全体として提案手法がより良好な認識率を挙げたことにより、パラメータ設定値の有効性が明らかになった。

標識種類別の認識結果によると、標識「20」, 「30」, 「40」, 「50」ではいずれも提案手法が高い認識率を得た。その一方で、標識「80」では大きく認識率を下げている (図 10)。誤りの中では、標識「60」と誤認識する例が特に多くみられた (図 11(b))。低解像度においては、標識「60」と「80」の生成画像の差異が僅かであり、結果として標識クラス「60」とクラス「80」の間の決定境界が曖昧になったためだと考えられる。



(a) 標識「30」8 × 8
標識「80」と誤認識



(b) 標識「80」12 × 12
標識「60」と誤認識

図 11 提案手法で認識に失敗した例

6. 車載カメラによる認識実験

6.1 実験方法

実際に車載カメラで撮影した動画を対象とした認識実験を行った。まず、提案手法(パラメータ推定に基づく生成型学習)により学習画像を生成した。全 11 箇所の異なる地点において移動中の車から動画を撮影し(平均約 75 フレーム=2.5 秒)、その中の 1 本を学習データとして用い、パラメータ推定を行った。残りの 10 本を認識実験に用い、認識率を求めた。なお、学習データとして用いた動画の標識は標識「40」であり、認識実験に用いた動画は、標識「20」2 本、標識「40」5 本、標識「50」3 本である。標識の切り出しには 5.2 節と同じアルゴリズムを使用した。学習時に用いる遺伝的アルゴリズムでは 5.3 節と同じパラメータを使用した。本実験では、単一フレームを用い類似度計算を行った場合(式(6))の認識結果の他、複数フレーム(連続する 10 フレーム)を用い類似度計算を行った場合(式(7))の認識結果も求めた。

6.2 実験結果

単一フレーム使用時のサイズ別認識率を表 2 に示す。また、複数フレーム(連続する 10 フレーム)使用時の認識率を表 3 に示す。

図 12 に認識に用いた動画の例を示す。図 13 のそれぞれの画像は図 12 より切り出された標識画像の拡大図である。この動画は全 71 フレームからなり、画面の解像度は 320 × 240 ピクセルであった。提案手法を用いて学習することにより、サイズ 7 × 7 の低解像度画像(図 13(a))に対して 8 フレーム中 6 フレームで正しい認識結果が得られた。それでも、単一フレームを用いて認識した場合では、比較的解像度の高い標識画像に対しても突発的な認識誤りが見られた。例えば、25 フレーム目(図 13(b))では、前後のフレームで正しい認識結果が得られているのにも関わらず、標識「10」と誤認識されていた。しかし、46 フレーム目(図 13(c))以降は認識誤りは見られなかった。なお、複数フレームを用いた場合では常に正しい認識結果が得られた。

6.3 考察

実験により、本稿で提案した学習法は、実際の車載カメラで撮影された動画にも有効であることが明らかになった。実験結果は、撮影時のサイズが 13 × 13 程度の離れた標識でも高精度の認識結果が得られた。なお、近距離にある標識は解像度は高いものの、ぶれの影響が大きいため認識誤りを起こす例も見られた。そのため、比較的ぶれの影響の少ない遠方の標識に

表 2 標識サイズ別認識率(単一フレーム)

サイズ	認識率	
6 以下	33.3%	(11/33)
7	64.2%	(42/65)
8	72.0%	(72/100)
9	80.0%	(76/95)
10	73.3%	(55/75)
11	92.2%	(59/64)
12	84.0%	(42/50)
13	92.3%	(48/52)
14	97.2%	(35/36)
15	92.1%	(35/38)
16	97.2%	(35/36)
17	95.0%	(19/20)
18	100.0%	(17/17)
19	100.0%	(14/14)
20	100.0%	(9/9)
21 以上	95.0%	(38/40)
全体	81.6%	(607/744)

表 3 標識サイズ別認識率(複数フレーム)

平均サイズ	認識率	
6 - 7	87.9%	(29/33)
7 - 8	98.7%	(76/77)
8 - 9	97.7%	(85/87)
9 - 10	100.0%	(85/85)
10 - 11	97.2%	(69/71)
11 - 12	93.0%	(53/57)
12 - 13	94.0%	(47/50)
13 - 14	97.7%	(43/44)
14 - 15	100.0%	(37/37)
15 - 16	100.0%	(32/32)
16 - 17	100.0%	(21/21)
17 - 18	100.0%	(15/15)
18 - 19	100.0%	(13/13)
19 - 20	100.0%	(10/10)
20 - 21	100.0%	(5/5)
21 以上	100.0%	(17/17)
全体	97.4%	(637/654)

対しロバストに認識を行うことは重要であるといえる。

なお、複数フレームの累積利用によって、より安定した認識結果が得られることも確認できた。

7. まとめ

本稿では、生成型学習を用いた道路標識認識のための生成手法を提案した。生成型学習法における生成過程を見直し、標識認識に適した生成モデルを提案した。新たな生成モデルでは、劣化・変形要因を位置ずれ、伸縮、回転、ぼけ、ぶれ、解像度低下の 6 つに分離した。独立なパラメータを用いてモデル化することで、撮影画像をシミュレートした。従来の生成型学習では、生成時のパラメータ設定に関する検討がなされていなかった。



(a) 6 フレーム目



(b) 25 フレーム目



(c) 46 フレーム目

図 12 車載カメラによる撮影画像の例



(b) 6 フレーム目
サイズ 7 × 7
標識「40」と認識



(b) 25 フレーム目
サイズ 9 × 9
標識「10」と認識



(c) 46 フレーム目
サイズ 12 × 12
標識「40」と認識

図 13 図 12 中の標識の拡大画像

どの影響を受けた低品質標識画像の認識に有効であることが明らかになった。また、車載カメラによる認識実験も行い、提案手法の有効性を確めた。

提案手法は速度標識に限らず他の種類の標識にも応用が可能である。その場合、色情報を用いた標識の判別も検討の必要がある。

謝辞

本研究の一部は日本学術振興会科研費、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。

文 献

- [1] 内村圭一, 木村英雄, 脇山慎也, “道路情景カラー画像における円形道路標識の抽出および認識”, 信学論 (A), vol.J81-A, no.4, pp.546-553, April, 1998.
- [2] 松浦大祐, 山内仁, 高橋浩光, “特定色判別と領域限定を用いた円形道路標識の抽出”, 信学論 (D-II), vol.J85-D-II, no.6, pp.1075-1083, June, 2002.
- [3] 莫舸舸, 青木由直, “カラー画像における道路標識の認識”, 信学論 (D-II), vol.J87-D-II, no.12, pp.2124-2135, December, 2004.
- [4] 村瀬洋, “画像認識における生成型学習法”, 信学技報, PRMU-81, pp.41-48, September, 2004.
- [5] 石田皓之, 柳詰進介, 目加田慶人, 井手一郎, 村瀬洋, “部分空間法を用いた文字認識のための生成型学習法”, 信学技報, PRMU-7, pp.37-42, May, 2004.
- [6] 村瀬洋, 木村文隆, 吉村ミツ, 三宅康二, “パターン整合法における特性核の改良とその手書き平仮名文字認識への応用”, 信学論 (D), vol.J64-D, no.3, pp.276-283, March, 1981.
- [7] 田村秀行, 村瀬洋, 松山隆司, 山本裕之, “コンピュータ画像処理”, オーム社出版局, 2002.
- [8] 橋本正一, 斎藤秀雄, “PSF パラメータ分布を推定するシフトバリエーションぼけ画像の復元法”, 信学論 (D-II), vol.J77-D-II, no.4, pp.719-728, April, 1994.
- [9] 柳詰進介, 目加田慶人, 村瀬洋, “携帯デジタルカメラによる動画を用いた低解像度文字の認識”, 2004 年度電子通信学会総合大会講演論文集, vol.3, p.197, March, 2004.
- [10] 網島宣浩, 中島真人, “コンバウンド法を用いた PSF の推定とぼけ画像の復元”, 信学論 (D-II), vol.J81-D-II, no.11, pp.2688-2692, November, 1998.
- [11] Daris, L., “Handbook of genetic algorithms”, Van Nostrand Reinhold, 1991.
- [12] von Neumann, J., “Various techniques used in connection with random digits”, National Bureau of Standards Series, no.12, pp.36-38, 1951.
- [13] Smith, A. R., “Color gamut transform pairs”, Computer Graphics, vol.12, no.3, pp.12-19, August, 1978.

た。本稿の提案手法では、実際に撮影される画像の劣化・変形特性を反映することが認識率の向上につながるという考えのもとで、撮影画像から生成パラメータを推定し、生成時にそれらを再現し学習画像として用いた。実験により、提案する生成モデルによるシミュレーションは、ぼけやぶれ、解像度の低下な