

# 高精度な道路標識検出器構築のための 重み付き投票型 Co-training 手法の提案

児島 勇司<sup>†</sup> 出口 大輔<sup>††,†</sup> 井手 一郎<sup>†</sup> 村瀬 洋<sup>†</sup>

<sup>†</sup> 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

<sup>††</sup> 名古屋大学 情報連携統括本部 〒464-8601 愛知県名古屋市千種区不老町

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

**あらまし** 近年、運転支援を目的として、車載カメラ映像から道路標識を検出・認識する研究が広く行われている。しかし、安定して高い検出性能が得られる道路標識検出器の構築には、設置位置や経年劣化、照明の変動などの多様な見えの変化をバランス良く含んだ大量の道路標識画像を学習サンプルとして用意し、これらを用いて道路標識検出器を構築する必要がある。提案手法では、Co-training 手法に重み付き投票によるラベル付与方法を導入することにより、学習サンプルの効率的な収集を実現する。これにより、有効な識別器を適切に選択しながら、車載カメラ映像から学習サンプルを自動的に収集する。そして、収集した多様な学習サンプルを用いて道路標識検出器を構築することにより、道路標識の検出精度向上を目指す。評価実験では、提案手法により F 値が 0.628 の初期検出器から最大で F 値が 0.841 の道路標識検出器が構築可能であることを確認した。

**キーワード** ITS, 道路標識検出, Co-training

## Proposal of the weighted voting type co-training method for the construction of an accurate traffic sign detector

Yuji KOJIMA<sup>†</sup>, Daisuke DEGUCHI<sup>††,†</sup>, Ichiro IDE<sup>†</sup>, and Hiroshi MURASE<sup>†</sup>

<sup>†</sup> Graduate School of Information Science, Nagoya University

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

<sup>††</sup> Information and Communications Headquarters, Nagoya University

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

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

**Abstract** Recently, traffic sign detection and recognition from in-vehicle camera images have been widely studied. However, a traffic sign detector requires a large number of training samples of traffic signs with various appearances to obtain higher performance. The main contributions of this paper are the extension of the Co-training method by introducing a weighted voting scheme, and the introduction of this framework for improving the accuracy of traffic sign detection. By using this weighted voting type Co-training, the proposed method gathers traffic sign samples automatically and accurately, which improves the performance of the traffic sign detector. Experimental results showed that the proposed method improved the accuracy of the detector with a maximum F-measure of 0.841 from 0.628.

**Key words** ITS, traffic sign detector, Co-training

### 1. はじめに

近年、車載カメラを用いた周囲環境認識技術が注目を集めており、歩行者 [1] や道路標識 [2], [3] など様々なものを対象とした物体検出・認識の研究が盛んに行われている。自動車の周囲

環境の中でも、道路標識は速度制限や追い越し禁止など重要な情報を含んでいる。そのため、これらの見落としは重大な交通事故につながる可能性がある。ここで道路標識検出は、図 1 の矩形の赤枠のように道路標識を車載カメラ画像中から見つけ出す技術である。このような道路標識検出器は、自動車に搭載し





図 1 道路標識の検出例

て利用されることから、リアルタイムで動作する必要がある。また、確実な情報をドライバに提供するため、その精度も高くなくてはならない。これらのことから、道路標識検出器は高速かつ高精度であることが要求される。

これまでに、標識の色特徴を用いた手法 [4] や、形状特徴を用いた手法 [5] など、様々な道路標識検出手法が提案されている。一方、高速な物体検出手法として、Viola らはカスケード型 AdaBoost 識別器を提案しており、顔検出に広く用いられている [6]。Bahlmann らはこの手法が道路標識検出器においても有効であることを実験で示している [2]。しかし、安定して高い性能を得るためには、様々な見えの変化をバランス良く含んだ大量の道路標識画像を学習サンプルとして用意し、道路標識検出器の学習に用いる必要がある。Bahlmann らは学習サンプルを手で収集し、道路標識検出器を構築している。しかし、実環境では、標識周辺の背景には樹木や家屋など様々な物体が映り込む。また標識自体も、道路標識の設置位置や経年劣化、照明の変動などにより多様に見えが変化する。そのため、現実に起こり得る見えのパターンを手で網羅的に収集することは困難である。以降、このような人手による労力をコストと表現する。

本研究ではこのような多様な見えの学習サンプルを収集する手法として、半教師付き学習手法の一つである Co-training 手法に注目する。ここで、道路標識と非道路標識を含んだ車載カメラ映像はラベルなしデータとみなすことができ、これは実環境中を走行することで比較的容易に収集することが可能である。ゆえに、少数のラベルありデータと多数のラベルなしデータを用いた半教師付き学習により道路標識検出器を構築することができれば、学習サンプルの収集コストを大幅に削減するこ



図 2 検出対象の道路標識

とができる。このように、半教師付き学習の枠組みを用いることで、道路標識検出器の高精度化とその構築の低コスト化が期待できる。しかし、道路標識の見えの変化は多様であり、単純に Co-training 手法を適用しただけでは十分な性能は得られない。Co-training 手法で道路標識検出器をより高精度に構築するためには、性質が異なる多様な識別器を利用することが好ましい。しかし、Co-training 手法では全ての識別器が独立に学習サンプルの収集を行うため、性能が低い識別器による誤収集が大きな問題となる。

そこで本論文では、Co-training 手法に重みつき投票の枠組みを加えることで、従来問題となっていた性能の低い識別器による誤収集の問題を解決する。具体的には、Co-training 手法に対し、識別器の重み付き投票によるラベル付与方法を導入する。これにより、車載カメラ映像から抽出されたラベルなしの学習サンプル候補に対して、ラベルの付与を行う。そして、ラベルなしデータへのラベル付与精度を改善しつつ、ラベル付けのための人手による労力を最小限にする。

なお、本研究では、道路標識として図 2 に示す規制標識を検出対象とする。

以降、まず 2. で学習サンプル収集の関連研究について述べる。次に 3. で提案手法の詳細について述べる。そして、提案手法の有効性を確認するため、4. で実際に標識検出器の構築実験を行い、5. で実験結果に対する考察を述べる。最後に 6. で本研究のまとめと今後の課題について述べる。

## 2. 関連研究

道路標識検出器の学習サンプルを低コストに収集する手法として、道満らは生成型学習を用いた道路標識検出器の構築手法を提案している [3]。この手法では、カメラの撮影時に起こり得る道路標識の見えの変化をモデル化し、それを計算機上でシミュレートすることで、少数の原画像から多様な変化を加えた画像を生成し、学習サンプルに加えている。しかし、現実に起こり得る変化のパターンを完全にモデル化することは困難であるとともに、生成時のパラメータ調整が難しいという問題があった。一方、実際の走行によって得られる車載カメラ映像から、道路標識画像を自動的に収集する手法が提案されている。出口らは、車両の近くで大きく映っている標識を検出し、その位置を基準として車載カメラ映像を時系列に遡って、より遠くの低解像度な標識画像を自動収集する遡及型の手法を提案している [7]。しかし、標識の追跡に失敗した場合は不適切な学習用データを収集してしまうという問題があった。

一方、学習サンプルを低コストに収集する手法として、半教師付き学習を用いたものがある。半教師付き学習の代表的な手




図3 重み付き投票型 Co-training 手法における学習の流れ

法の1つに Self-training 手法がある [8]. この手法では、ラベルありデータにより学習した識別器により、ラベルなしデータへのラベル付与を行う。そして、ラベルを付与したデータをラベルありデータへ追加し、再び識別器の学習を行う。これを繰り返すことで、ラベルありデータを逐次的に増やし、識別器の性能向上を図る。この手法は単純な枠組みであり、様々な識別器に適用できる。しかし、早い段階でのラベル付与の失敗に弱く、また、すでに識別器が持っている情報を利用するため、本質的な性能向上が見込めない場合がある。

そこで、Self-training 手法を改良した半教師付き学習手法として、Co-training 手法 [9] が提案されている。Co-training 手法では、ラベルありデータを複数の特徴に分割し、特徴ごとに識別器を構築する。これにより、同一のデータから複数の性質が異なる識別器を構築する。そして Self-training 手法と同様に、ラベルありデータにより学習した識別器により、ラベルなしデータの識別を行い、確実なものにラベル付与を行う。そして、ラベルを付与したデータをラベルありデータへ追加し、再び各識別器の学習を行う。これを繰り返すことで、ラベルありデータを逐次的に増やし、識別器の性能向上を図る。Blum らはこれを Web ページ分類に適用し、その効果を示している [9]. Roth らは Co-training 手法の概念を歩行者検出器の学習に取り入れ、固定カメラから自動で学習サンプルの収集を行い、歩行者検出器の精度を向上させた [10]. しかし、Co-training 手法は複数の識別器が独立にラベルなしデータへのラベル付与を行うため、ラベル付与に十分な性能でない識別器があると、誤ったラベル付与がされやすいという問題があった。

### 3. 提案手法

#### 3.1 重み付き投票型 Co-training 手法

本節では、重み付き投票型 Co-training 手法について説明する。Co-training 手法では、複数の性質が異なる識別器を用いてラベルなしデータへのラベル付与と各識別器の再学習を繰り返すことにより、逐次的に識別器の性能を向上させる。しかし、学習サンプルの数と得られる性能の関係は識別器によって大きく異なる。たとえば、少ない学習サンプルでもある程度の性能が得られる反面、学習サンプルを増やしても性能向上が少ない識別器もあれば、少ない学習サンプルでは低い性能しか得られなくとも、学習サンプルの増加により高い精度が得られる識別器もある。そのため、Co-training 手法における学習の反復によって有効な識別器を適切に選択することが望ましい。そこで本研究では、各識別器をその識別の信頼度で重み付けする方法を提案する。ここで信頼度とは、その識別器の識別結果が信頼できる度合いである。そして、その重みを付けた投票によってラベルを決定する。重み付き投票型 Co-training 手法における学習の流れを図3に示す。これにより、性能が低い識別器の影響を抑えつつ、複数の識別器の情報をういてラベルなしデータへラベル付与を行う。

返すことにより、逐次的に識別器の性能を向上させる。しかし、学習サンプルの数と得られる性能の関係は識別器によって大きく異なる。たとえば、少ない学習サンプルでもある程度の性能が得られる反面、学習サンプルを増やしても性能向上が少ない識別器もあれば、少ない学習サンプルでは低い性能しか得られなくとも、学習サンプルの増加により高い精度が得られる識別器もある。そのため、Co-training 手法における学習の反復によって有効な識別器を適切に選択することが望ましい。そこで本研究では、各識別器をその識別の信頼度で重み付けする方法を提案する。ここで信頼度とは、その識別器の識別結果が信頼できる度合いである。そして、その重みを付けた投票によってラベルを決定する。重み付き投票型 Co-training 手法における学習の流れを図3に示す。これにより、性能が低い識別器の影響を抑えつつ、複数の識別器の情報をういてラベルなしデータへラベル付与を行う。

#### 3.2 識別器の構成

提案手法に用いる 29 種類の識別器  $H_i$  について説明する。これらの識別器は主識別器  $H_1$  および副識別器  $H_2 \sim H_{29}$  からなる。ここで主識別器は、道路標識検出に用いる識別器であり、ここでは高速に識別が可能 Multi-exit cascade 型 Gentle AdaBoost 識別器 [11] [12] を利用する。また、副識別器は主識別器の性能向上のためのラベル付与に用いる識別器である。副識別器は主識別器と性質を変えるために、主識別器と構築手法が異なるものを利用する。ここでは副識別器として、少ないサンプルからでも高精度な識別が期待できる SVM、部分空間法を利用する。これらの識別器は画像  $\mathbf{x}$  から抽出した特徴ベクトル  $\mathbf{y}$  を用いて学習を行う。ここで、特徴ベクトル  $\mathbf{y}$  は、

$$\mathbf{y} = f_i(\mathbf{x}) \quad (1)$$

と表すことができ、 $f_i$  は識別器  $H_i$  で利用する特徴抽出関数である。また、識別器  $H_i$  は、画像  $\mathbf{x}$  を入力とし、道路標識と判断すれば 1 を、背景と判断すれば 0 を返す。主識別器の特徴量には Multi-Block LBP 特徴量 [13] を利用し、この識別器を  $H_1$  とする。また、副識別器の特徴量は RGB 各色成分画像 (3 種類)、正規化 RGB 画像 (4 種類)、NTSC グレースケール画像、Opponent 色画像 (3 種類)、HSV ヒストグラム、HOG 特徴量 [14]、LBP 特徴量の 14 種類の特徴量を利用する。SVM と部分空間法の 2 種類の識別器構築手法と 14 種類の特徴量を組み合わせた 28 種類の識別器を副識別器  $H_2 \sim H_{29}$  とする。

#### 3.3 重み付き投票型 Co-training 手法による道路標識検出器の構築

道路標識サンプルの集合を  $\mathcal{V}_{\text{pos}}$ 、非道路標識サンプルの集合を  $\mathcal{V}_{\text{neg}}$  とする。提案手法では  $\mathcal{V}_{\text{pos}}$  を逐次的に更新していくことにより、構築される道路標識検出器の精度を向上させる。以下、手法の詳細について述べる。なお、ここでは識別器の数が  $N$  個の場合の一般的な形で説明を行う。

##### STEP 1. 初期サンプル収集

人手により、少数の道路標識画像を車載カメラ映像中から切り出し、ラベルあり道路標識サンプル集合  $\mathcal{V}_{\text{pos}}$  へ追加する。ま

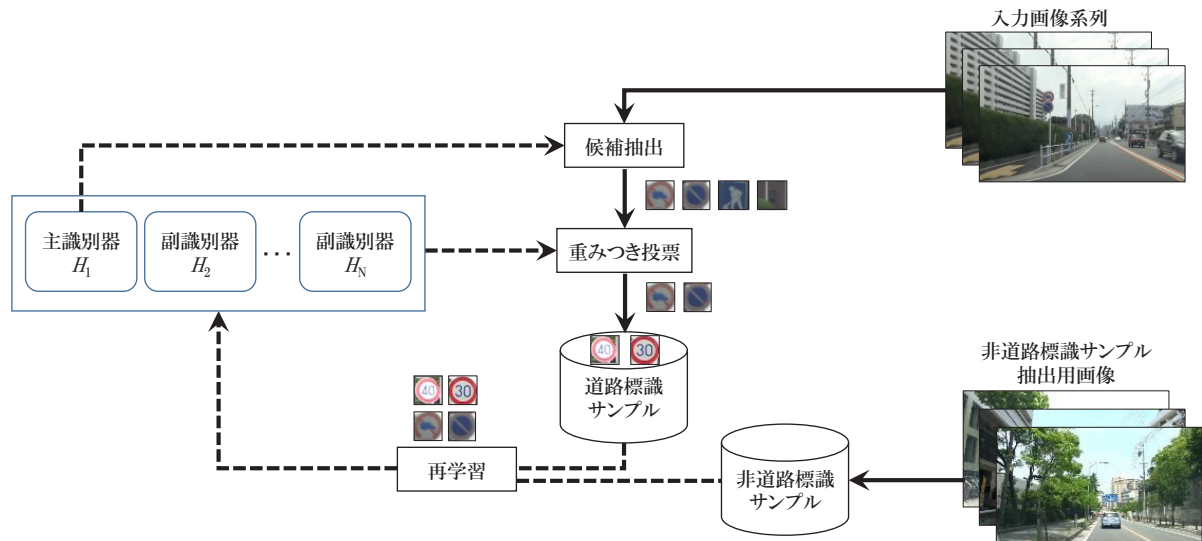


図 4 道路標識サンプル収集処理の流れ

た、道路標識が映っていない車載カメラ画像を収集し、非道路標識サンプル抽出用データとする。

### STEP 2. 初期識別器の学習

初期ラベルあり道路標識サンプル集合  $\mathcal{V}_{\text{pos}}$  内のデータを学習サンプルとし、識別器  $H_1 \sim H_N$  を学習する。なお非道路標識サンプルは、非道路標識画像抽出用データの車載カメラ画像から大きさや位置をランダムに変えて切り出すことで収集し、 $\mathcal{V}_{\text{neg}}$  へと加えて用いる。 $\mathcal{V}_{\text{neg}}$  は、各識別器の学習を行うごとにランダム抽出により入れ替えて利用する。各識別器  $H_i$  は、それぞれの特徴抽出関数  $f_i$  により取得した特徴ベクトルから学習を行う。

### STEP 3. 各識別器の重み計算

識別器  $H_1 \sim H_N$  の重み  $a_1 \sim a_N$  の計算を行う。各識別器により、 $\mathcal{V}_{\text{pos}}$ 、 $\mathcal{V}_{\text{neg}}$  内のデータの識別を行い、性能を評価する。そして、その識別器が道路標識と識別した結果がどの程度信頼できるかを信頼度として計算し、重みとする。この重み  $a_i$  は、次式により計算する。

$$a_i = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

ここで、TP は道路標識と正しく識別された (True Positive) 道路標識サンプル数、FP は誤って道路標識と識別された (False Positive) 非道路標識サンプル数である。

### STEP 4. 候補抽出

車載カメラ映像から標識の候補となる領域の抽出を行う。ここでは、主識別器  $H_1$  によって標識領域を映像中から検出する。ただし、 $H_1$  における検出は、再現率が高くなるようにしきい値を低く設定しておく。これによって、確実なものから識別が難しいものまで、多様な見えの道路標識サンプルを収集する。ただし、同時に大量の非道路標識も収集されてしまう。そこで、検出されたサンプルを道路標識サンプルの候補データとして集

合  $\mathcal{U}$  に加え、ラベルなしデータとして扱う。

### STEP 5. 重み付き投票

複数の識別器の多数決により、候補データへラベル付与を行う。まず、候補抽出で得られた  $\mathcal{U}$  内のデータをそれぞれの識別器  $H_i (i = 1, \dots, N)$  により識別する。このとき、各識別器  $H_i$  はそのデータが道路標識であれば 1 を、背景であれば 0 を返す。そして、次式のように、重み付き和がしきい値  $\theta$  より大きくなるデータを収集し、道路標識サンプルの集合  $\mathcal{W}$  を作成する。

$$\mathcal{W} = \left\{ \mathbf{x} \mid \mathbf{x} \in \mathcal{U}, \frac{\sum_{i=1}^N a_i H_i(f_i(\mathbf{x}))}{\sum_{i=1}^N a_i} \geq \theta \right\} \quad (3)$$

そして、次式により、集合  $\mathcal{V}_{\text{pos}}$  を更新する。

$$\mathcal{V}_{\text{pos}} \leftarrow \mathcal{V}_{\text{pos}} \cup \mathcal{W}, \quad (4)$$

ここで  $\cup$  は集合和を表す。

### STEP 6. 識別器の更新

STEP 5 で更新された道路標識サンプル集合  $\mathcal{V}$  を用い、識別器  $H_1 \sim H_N$  を再学習する。

STEP 3 ~ STEP 6 を繰り返し実行することで、ラベルありデータ数を逐次的に増やし、識別器の性能向上を図る。

### 3.4 道路標識検出の流れ

道路標識検出処理の流れを図 5 に示す。入力画像に対して、位置と大きさを変化させながら検出窓を走査する。各検出窓内の画像を入力とし、重み付き投票型 Co-training 手法により構築された  $H_1$  により道路標識であるか否かを判定し、その結果を出力する。そして、出力された検出結果枠に対して、Mean Shift Clustering [15] により重なった窓を統合することで最終的な道路標識の検出を行う。

## 4. 実験

実環境で撮影した車載カメラ映像を用いて、提案手法により

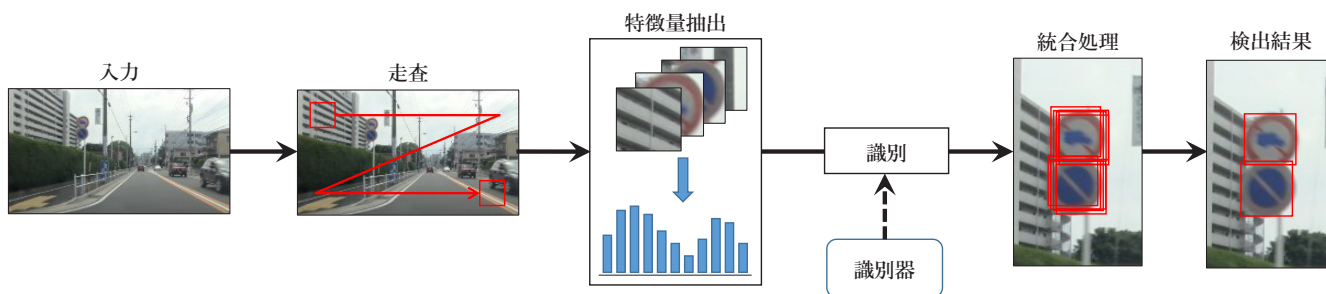


図 5 道路標識検出処理の流れ

表 1 提案手法による検出精度

	$\mathcal{V}_{\text{pos}}$ 内サンプル数	適合率	再現率	F 値
$H_1^0$	20	0.883	0.488	0.628
$H_2^1$	230	0.906	0.538	0.675
$H_3^2$	495	0.890	0.618	0.730
$H_4^3$	1,052	0.900	0.734	0.808
$H_4^4$	1,677	0.852	0.769	0.808
$H_4^5$	1,943	0.855	0.827	0.841

構築した検出器の評価を行った。車載カメラ映像は、民生用のデジタルビデオカメラ CANON G10 及び CANON G20 を用い、車両に対して前方向きに設置して撮影を行った。映像の各フレームの大きさは  $1,920 \times 1,080$  pixels、フレームレートは 23.976 fps であった。この映像から、 $20 \times 20$  pixels 以上の大きさで道路標識が映っているフレーム 4,177 枚を手で取り出し、このうち 2,051 枚をサンプル収集用、2,136 枚を性能評価用データとした。サンプル収集用データには 3,313 個、性能評価用データには 3,385 個の道路標識が含まれる。サンプル収集用データは 5 つの系列へ分割し、これらを  $S_1 \sim S_5$  とした。性能評価用データの道路標識は、人手により外接矩形を囲むことで正解データを作成しておいた。また、車載カメラ映像から標識が映っていないフレームを 70 枚用意し、Gentle AdaBoost 識別器等の構築時に非道路標識画像抽出用データとして用いた。以下、これを  $N_{\text{all}}$  と表す。

まず、初期の学習サンプルとして、20 枚の道路標識画像を手で収集した。また、各識別器の学習および、重みの計算に用いる非道路標識画像は、 $N_{\text{all}}$  からその都度ランダムに 5,000 枚を切り出して用いた。また、提案手法における重み付き投票のしきい値  $\theta$  は 0.7 とした。実験にあたり、まず初期の学習サンプルによって各識別器の構築を行った。これらを用いて、提案手法により系列  $S_1$  から順にサンプル収集を行った。そして、各系列からサンプルを収集しながら逐次的に学習サンプル集合  $\mathcal{V}_{\text{pos}}$  に加え、各識別器の再学習を行った。初期の主識別器による検出器を  $H_1^0$  とし、 $S_i$  からサンプル収集後に構築した検出器を  $H_1^i$  とした。

表 1 に提案手法の実験結果を載せる。提案手法により道路標識サンプル数を 20 枚から 1,943 枚まで増やすことができ、F 値を 0.628 から最大で 0.841 まで向上させることができた。また、主識別器のみを用い、入力系列  $S_i$  からの検出結果を道路標識サンプルへ追加し、再学習を行う Self-training との比較を


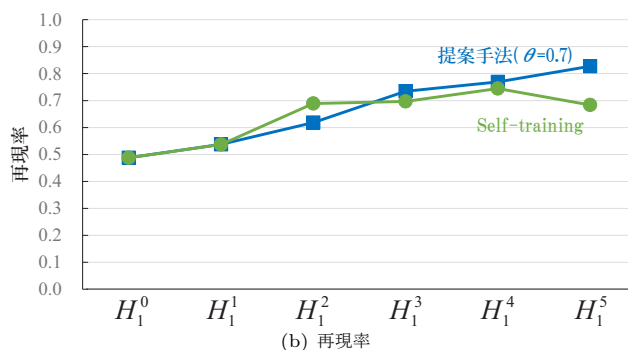
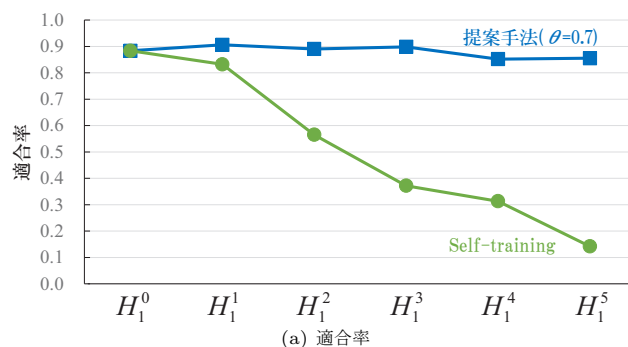


図 6 提案手法と Self-training 手法による検出性能の比較

行った。提案手法と比較手法の実験結果の比較を図 6 に示す。Self-training 手法では 2 反復目以降 F 値が低下し、最終的には 0.235 まで低下している。

## 5. 考 察

提案手法と比較手法 (Self-training) の検出精度について比較する。表 1 より道路標識検出器の F 値は、初期値 0.628 から最大 0.841 まで上昇した。このことから、道路標識の収集によ

り、初期道路標識検出器  $H_1^0$  と比べて多様な見えの道路標識が学習され、性能が向上したと言える。一方、Self-training 手法の F 値は初期値 0.628 から 0.235 まで低下した。これは、1 つの識別器によりラベル付与を行ったため、多くの非道路標識画像を誤って道路標識サンプルへ加えてしまい、適合率が大幅に低下したためである。提案手法では、複数の識別器による投票を行うことで、ある識別器による誤った判断を他の識別器が抑制することができるため、誤ったサンプルの収集を防げたと考えられる。

再現率を比較すると、Self-training 手法では 1, 2 反復目は提案手法よりも上昇した。これは、誤った道路標識サンプルとともに正しい道路標識サンプルも多く収集できたためと考えられる。しかし、3 反復目からは提案手法と比べて再現率が上昇しなかった。これは、新しい見えの道路標識サンプルを収集できなくなったためと考えられる。この原因は、主識別器のみを収集に用いたため、収集できる道路標識の見えが限定的であったためだと考えられる。しかし、ある識別器で道路標識と判断できない場合でも、性質が異なる他識別器では識別可能である場合がある。提案手法では、このような識別器の性質の違いによる効果により、主識別器のみでは収集できない道路標識サンプルを収集できたと考えられる。

以上から、提案手法において、複数の識別器を用いること、および、重み付き投票を取り入れることの有効性を確認した。しかし、提案手法においてもわずかに誤った学習サンプルを収集してしまった。今後はより高精度な学習サンプル収集を行うように、重み付け方法や用いる識別器の組み合わせ等の検討が必要である。

## 6. むすび

本論文では、重み付き投票型 Co-training 手法を用いた低コストな道路標識検出器の構築手法を提案した。高精度な道路標識検出器を構築するためには、多様な見えの変化を含んだ道路標識画像の学習サンプルが必要である。しかし、その収集を人手で行うためには多大な労力を必要とし、そのコストは非常に高い。そこで、重み付き投票型 Co-training 手法により、車載カメラ映像中から自動的に道路標識サンプルを収集し、検出器の構築に用いることで収集コストの削減を目指した。

提案手法の有効性を確認するため、実際の車載カメラ画像を用いて評価実験を行った。評価実験では車載カメラ画像中から道路標識サンプルの収集を行い、検出器を構築した。そして、異なる車載カメラ画像に対して道路標識検出器の性能を評価した。実験の結果、初期の道路標識サンプルのみで構築された道路標識検出器の F 値は 0.628 であったのに対し、提案手法により最高で 0.841 まで性能を向上させることができた。これにより、提案手法の有効性を確認した。

今後の課題としては、より大規模なデータセットでの評価、道路標識サンプル収集精度の改善、非道路標識サンプルの質の向上、などが挙げられる

謝辞 日頃より熱心な御指導と御鞭撻を頂く名古屋大

学村瀬研究室諸氏に深く感謝する。本研究の一部は、JST 戦略的創造研究推進事業 CREST および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] H. Yoshida, D. Deguchi, I. Ide, H. Murase, K. Goto, Y. Kimura, and T. Naito, "Integration of generative learning and multiple pose classifiers for pedestrian detection," Proc. Int. Con. on Computer Vision Theory and Applications (VISAPP) 2012, vol.1, pp.567-572, Feb. 2012.
- [2] 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. 2005 IEEE Intelligent Vehicles Symposium, pp.255-260, June 2005.
- [3] K. Doman, D. Deguchi, T. Takahashi, Y. Mekada, I. Ide, and H. Murase, "Construction of cascaded traffic sign detector using generative learning," Proc. 4th Int. Con. on Innovative Computing, Information and Control (ICICIC), pp.889-892, Dec. 2009.
- [4] 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," 信学論 (D-II), vol.J83-D-II, no.2, pp.855-858, Feb. 2000.
- [5] 竜岡琢磨, 長坂保典, 鈴木宣夫, "円形状の道路標識の認識," 信学技報, EID99-143, Feb. 2000.
- [6] P. Viola, and M.J. Jones, "Robust real-time face detection," Int. J. of Computer Vision, vol.57, no.2, pp.137-154, May 2004.
- [7] D. Deguchi, M. Shirasuna, K. Doman, I. Ide, and H. Murase, "Intelligent traffic sign detector: Adaptive learning based on online gathering of training samples," Proc. 2011 IEEE Intelligent Vehicles Symposium, pp.72-77, June 2011.
- [8] D. Yarowsky, "Unsupervised word sense disambiguation rivaling supervised method," Proc. 33rd Annual Meeting of the Association for Computational Linguistics, pp.189-196, June 1995.
- [9] A. Blum, and T. Mitchell, "Combining labeled and unlabeled data with co-training," Proc. 11th ACM Annual Conf. on Computational Learning Theory, pp.92-100, July 1998.
- [10] P.M. Roth, H. Grabner, D. Skocaj, H. Bischof, and A. Leonardis, "On-line conservative learning for person detection," Proc. 2nd Joint IEEE Int. Workshop on Visual Surveillance and Performance Evaluation of Tracking and Surveillance, pp.223-230, Oct. 2005.
- [11] P. Wang, C. Shen, H. Zheng, and Z. Ren, "Training a multi-exit cascade with linear asymmetric classification for efficient object detection," Proc. 2010 IEEE International Conference on Image Processing, pp.61-64, Sep. 2010.
- [12] J. Friedman, T. Hastie, and R. Tibshirani, "Additive logistic regression: A statistical view of boosting (with discussion and a rejoinder by the authors)," The Annals of Statistics, vol.28, no.2, pp.337-407, Dec. 2000.
- [13] L. Zhang, R. Chu, S. Xiang, S. Liao, and S. Li, "Face detection based on multi-block LBP representation," Advances in Biometrics, Int. Con., ICB2007, Proceedings, Lecture Note in Computer Science, vol.4642, pp.11-18, Aug. 2007.
- [14] N. Dalal, and B. Triggs, "Histograms of oriented gradients for human detection," Proc. 2005 IEEE Computer Society Con. on Computer Vision and Pattern Recognition, pp.886-893, June 2005.
- [15] D. Comaniciu, and P. Meer, "Mean shift: A robust approach toward feature space analysis," IEEE Tran. on Pattern Analysis and Machine Intelligence, vol.24, no.5, pp.603-619, May 2002.