

多数決型 co-training による 道路標識検出器の構築に関する検討

児島 勇司[†] 出口 大輔^{††} 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^{††} 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 本発表では、低成本で高精度な道路標識検出器を構築する手法を提案する。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いる。その中でも、道路標識は安全運転における重要な情報源であるため、車載カメラ映像から道路標識を検出・認識する技術の研究開発が広く行われている。実環境における道路標識は、背景の多様さに加え、道路標識の設置位置や経年劣化、照明の変動などにより、様々な見えの変化が起こる。そのため、高精度な道路標識検出器の構築には多様な見えを含む大量の学習データが必要である。しかし、学習用データの収集を人手で行う場合、その労力は非常に大きく、検出器の構築において大きな問題となっている。そこで本発表では、半教師付き学習により学習用データの収集コストを抑えた道路標識検出器の構築手法を提案する。提案手法では、異なる性質を持つ複数の識別器を組み合わせて学習を行う co-training に多数決の枠組みを導入する。これにより、低成本で高性能な道路標識検出器を構築する。車載カメラ映像を用いた評価実験の結果、提案手法を適用することにより、F 値が 0.94 の検出器画構築できることを確認した。

キーワード ITS, 車載カメラ, 標識検出, 学習サンプル

1. はじめに

自動車による交通事故の大きな原因の1つは、歩行者や道路標識等の見落としており、ドライバの前方不注意や判断ミスが主な要因となっている。これは、ドライバの思い込みや心理的要因に起因する場合が多く、ドライバへの適切な情報提示による支援が重要だと考えられている。このような支援の実現には、自動車の周囲状況を把握する技術が必要不可欠である。これまでに、車載カメラを用いた物体検出・認識に関する研究が盛んに行われており、歩行者[1] や道路標識[2] など様々なものを対象として研究がなされている。

道路標識は、速度制限や追い越し禁止といった安全運転のための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高い。そこで本稿では、車載カメラ画像からの道路標識検出に注目する。図1に道路標識の検出例を示す。このような道路標識の検出器は、自動車に搭載して利用されることから、リアルタイムでの検出が必要である。また、確実な情報をドライバに提供する必要があるため、その精度は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。

一般に、実環境では道路標識周辺の背景は空や樹木、家屋など多様である。また図2に示すように、道路標識自体にも、角度の変化や退色、環境光の影響などにより様々な見えの変化が起こる。そのため、検出器はこのような多様な見えを考慮して構築する必要がある。しか

し、多様な見えを含む学習用データ（道路標識または背景を切り出した画像）を人手で大量に収集するには、膨大な労力を要する。そのため、検出器を構築する上で学習データの収集コストが大きな問題となっている。

学習用データを低成本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、学習データに加えている。しかし、現実に起こり得る変化パターンを完全にモデル化することは困難であり、また、生成時のパラメータの



図1 道路標識の検出例



図 2 道路標識の多様な見え

調整が難しいといった問題がある。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で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、その位置を基に車載カメラ映像の時系列を遡って、より遠くの低解像度な標識画像を収集する遡及型の手法を提案している[4]。しかし、標識の追跡に失敗した場合は不適切な学習データを収集してしまうという問題がある。

そこで本発表では、半教師付き学習のアプローチを用いた道路標識検出器の構築手法を提案する。通常、検出器の構築には標識もしくは非標識（背景）のラベルが付与されたデータを用いる。このような属性の判明しているデータから学習を行う方法が教師付き学習である。しかし、ラベルの付与には多大な労力が必要である。一方、少量のラベルありデータと大量のラベルなしデータを組み合わせて学習を行う半教師付き学習の手法が近年注目を集めている。半教師付き学習は、ラベルありデータとラベルなしデータが混在しているデータ集合を用い、ラベルなしデータに自動でラベルを付与することで学習を行う。これにより、低コストで用意することが可能なラベルなしデータを効果的に学習に用いることができる。そこで、本研究では、半教師付き学習を利用することで、学習サンプルの収集コストの削減を図る。具体的には、半教師付き学習の1つである co-training に対し、識別器の多数決によるラベル付与方法を導入する。これにより、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、ここでは、道路標識として図3に示す規制標識を対象とする。

以降、まず2.で関連研究について述べる。次に、3.で提案手法の詳細を述べる。そして、4.で提案手法の有効性を確認するため、実際に道路標識検出器の構築を行い、その性能を評価する。さらに、5.で実験結果に対する考



図 3 検出対象の道路標識

察を述べる。最後に6.でまとめと今後の課題について述べる。

2. 関連研究

2.1 道路標識検出器

これまでに、様々な道路標識検出手法が提案されており、道路標識の色特徴を利用した手法[5][6]や、形状特徴を利用した手法[7][8]等が提案されている。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[9]。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には、様々な見えの変化をバランス良く含んだ大量の学習用データを用意する必要がある。Bahlmannら[2]は学習用データを手作業で収集し、道路標識検出器を構築している。しかし、現実に起こりえる見えのパターンを網羅的に手作業で収集することは困難である。

2.2 半教師付き学習

半教師付き学習の代表的な手法の1つに self-training がある[10]。この手法では、ラベルありデータにより学習された識別器により、ラベルなしデータへのラベル付与を行う。そして、更新されたラベルありデータにより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、識別器自身の性能向上を図る。この手法は単純な枠組みであり、多くの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、またすでに自分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 を改良したものとして、co-training[11] が提案されている。co-training では、ラベルありデータを複数の特徴に分割し、各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

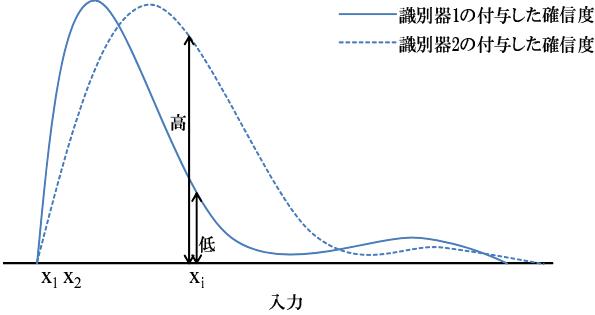


図 4 識別器による確信度算出の違い

質の異なる識別器を構築する。そして self-training と同様に、学習され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の付与を行う。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、更新されたラベルありデータを用いて、再び各識別器の学習を行う。以上の学習、ラベル付与の動作を繰り返すこと、逐次的にラベルありデータ数を増やし、識別器の性能向上を図る。図 4 で、入力 X_i に対して、識別器 2 が高い確信度を付与した場合、このデータはすでに識別器 2 にとって識別が正しく行えるものである。そのため識別器 2 の性能向上には寄与しない。しかし、性質の異なる識別器 1 にとっては確信度が低く、正しく識別できない可能性がある。この場合、このデータへのラベル付与は確実なものであると同時に、識別器 1 にとっては学習に有効な新しい情報を得ることができる可能性がある。このような効果により、self-training よりも効果的に性能向上を行うことが可能である。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 [11]。しかし、ラベル付与を各々の識別器で行うため、識別境界付近のデータには確実なラベルを付与することが難しい。

また、別のアプローチとして類似度グラフを用いたものがある [10]。類似度グラフは、サンプル間の類似度が計算可能であれば、データが上手く重ならない場合にも、類似しているもの同士をつなげていくことにより構築することができる。そして、隣接するノードはラベルも類似したものとなることを利用する。これにより、ラベルありデータから隣接するラベルなしデータにラベルを付与していくことで、伝播的にラベルありデータを増やしていく。グラフ理論等の数学的背景が確立しており、適切なグラフを構築できれば、高い効果が期待できる。しかし、適切なグラフ構造やエッジの重みを得ることが難しく、また計算量が多くなるといった問題がある。

本研究では、複雑な道路標識の見えの変化に対応するために、複数の判断基準を用いることが好ましい。ゆえに、多くの識別器を柔軟に適用させることができある co-training を利用する。

3. 提案手法

3.1 提案手法アプローチ

本研究では、ラベルあり道路標識画像の集合を \mathcal{V} 、ラベルなし画像（標識・非標識混合）の集合を \mathcal{U} と表す。co-training では、複数の識別器それぞれから得られる確信度の高いデータを集めることで、学習に用いるラベルの付与されたデータを逐次的に増やし、性能向上を図る。しかし、識別器の性能が低い場合は得られるデータに多くのラベル付け誤りが含まれるといった問題がある。具体的には、識別境界付近のデータのラベル付与の信頼性が低いという問題点がある。そこで、複数識別器の識別結果の多数決をとることにより、精度良くラベルを付与することを考える。これにより、ラベル付与の信頼性を向上するとともに、一つの識別器では判断できないデータにラベルを付与することで、より効果的なラベル付与を行う。

手法の流れは、まずラベルなしデータを車載カメラ映像から収集し、ラベルなし集合 \mathcal{U} へ追加する。そして、 \mathcal{U} 内の一部のデータに手動でラベルを付与し、ラベルあり集合 \mathcal{V} とする。次に、ラベルあり集合 \mathcal{V} を用いて複数の初期識別器の学習を行う。そして、学習した識別器の多数決によりラベルなし集合 \mathcal{U} へのラベル付与を行い、 \mathcal{V} を更新する。更新後の \mathcal{V} を用いてそれぞれの識別器を再学習する。以上のデータ集合の更新と識別器の学習を繰り返す。そして、学習された識別器を用いて道路標識検出を行う。

以降の説明では、 N 種類の識別器 H_i を利用し、それらを主識別器 H_1 、副識別器 $H_2 \sim H_N$ と表す。ここで、主識別器は道路標識検出器に用いる識別器であり、副識別器は主識別器の性能向上のために用いられる。識別器 H_i は画像 x から抽出した特徴ベクトル y を用いて学習を行う。ここで特徴ベクトル y は

$$y = f_i(x) \quad (1)$$

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 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。

以下、手法の手順を詳細に述べる。

3.2 道路標識検出器の構築

道路標識検出器構築の手順を図 5 に示す。道路標識検出器は、(i) ラベルなしデータの収集、(ii) 初期ラベルありデータの収集、(iii) 初期識別器の学習、(iv) 多数決によるラベル付与、(v) 識別器の再学習、の処理を順次適用することで構築される。手法の各手順の詳細を以降で述べる。

STEP 1. ラベルなしデータ収集

まず、車載カメラ映像中からラベルなしデータを収集

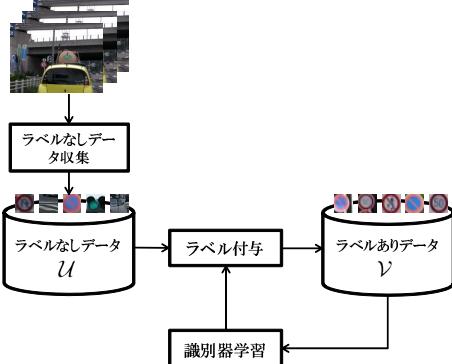


図 5 处理の流れ

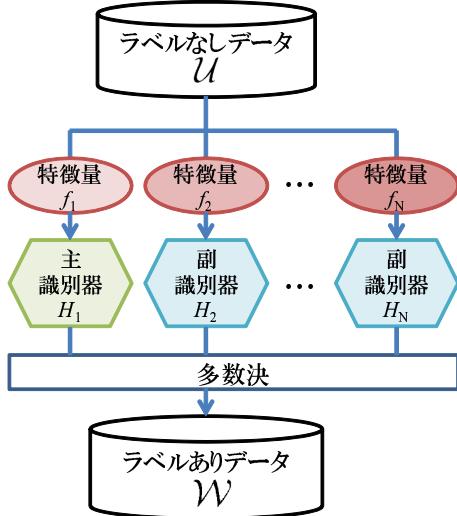


図 6 ラベル付与の流れ

する。ラベルなしデータの収集方法としては車載カメラ映像中からランダムに部分画像を切り出して収集する方法等が考えられる。この場合、道路標識と同時に、大量の背景の領域が抽出される。これらをラベルなし集合 \mathcal{U} へ入れる。

STEP 2. 初期ラベルありデータ収集

STEP 1 で収集されたラベルなし集合 \mathcal{U} の中から、手動で少数の標識画像を選択し、ラベルあり集合 \mathcal{V} へ移す。これを、初期ラベルあり集合とする。

STEP 3. 初期識別器の学習

初期ラベルあり集合 \mathcal{V} 内のデータを学習データとし、識別器 H_1 から H_N を学習する。この時、各識別器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 4. 多数決によるラベル付与

複数識別器の多数決により、ラベルなしデータへのラベル付与を行う。ラベル付与の流れを図 6 に示す。まず、 \mathcal{U} 内のデータをそれぞれの識別器 H_i 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、次の式のように、過半数の識別器が道路標識と判断したデータの集合 \mathcal{W} を作成する。

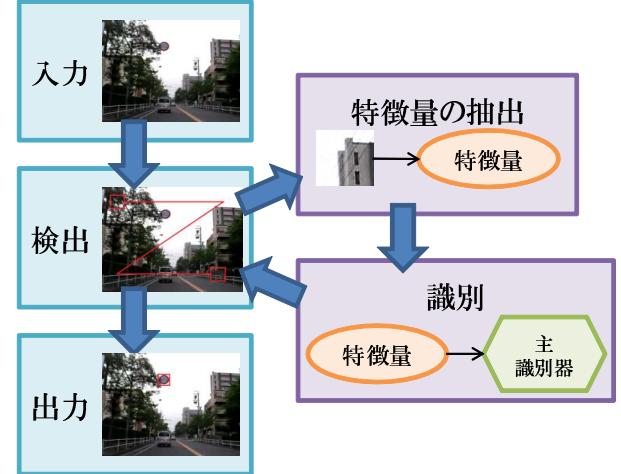


図 7 道路標識検出の流れ

$$\mathcal{W} = \{x | x \in \mathcal{U}, \sum_N H_i(f_i(x)) \geq \frac{N}{2}\} \quad (2)$$

そして、次式により、集合 \mathcal{V} を更新する。

$$\mathcal{V} \leftarrow \mathcal{V} \cup \mathcal{W} \quad (3)$$

ここで \cup は和集合を表す。

STEP 5. 識別器の再学習

STEP 4 で更新されたラベルあり集合 \mathcal{V} を用い、識別器 H_1 から H_N を再学習する。

STEP 4, STEP 5 を繰り返し適用することで、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。

3.3 道路標識検出

3.2 の手順で学習した主識別器を用いて、道路標識の検出を行う。処理の流れを図 7 に示す。道路標識検出では、検出窓の位置、大きさを変化させながら入力画像を走査し、検出窓内の画像から特徴量を算出する。算出した特徴量を用いて、構築した主識別器により画像が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、道路標識として検出された検出窓の集合に対して Mean Shift クラスタリングを適用し、検出結果の統合を行う。以上により、車載カメラ画像中から道路標識を検出する。

4. 実験

提案手法の有効性を確認するために、ラベルなしデータ集合を用いた検出器構築実験を行なった。以降、4.1 で実験条件について述べ、4.2 で実験方法について述べる。最後に、4.3 で実験の結果を述べる。

4.1 実験条件

4.1.1 データセット

提案手法の有効性を調査するため、車載カメラ映像から予め切り出された道路標識画像を 1,020 枚、非道路標

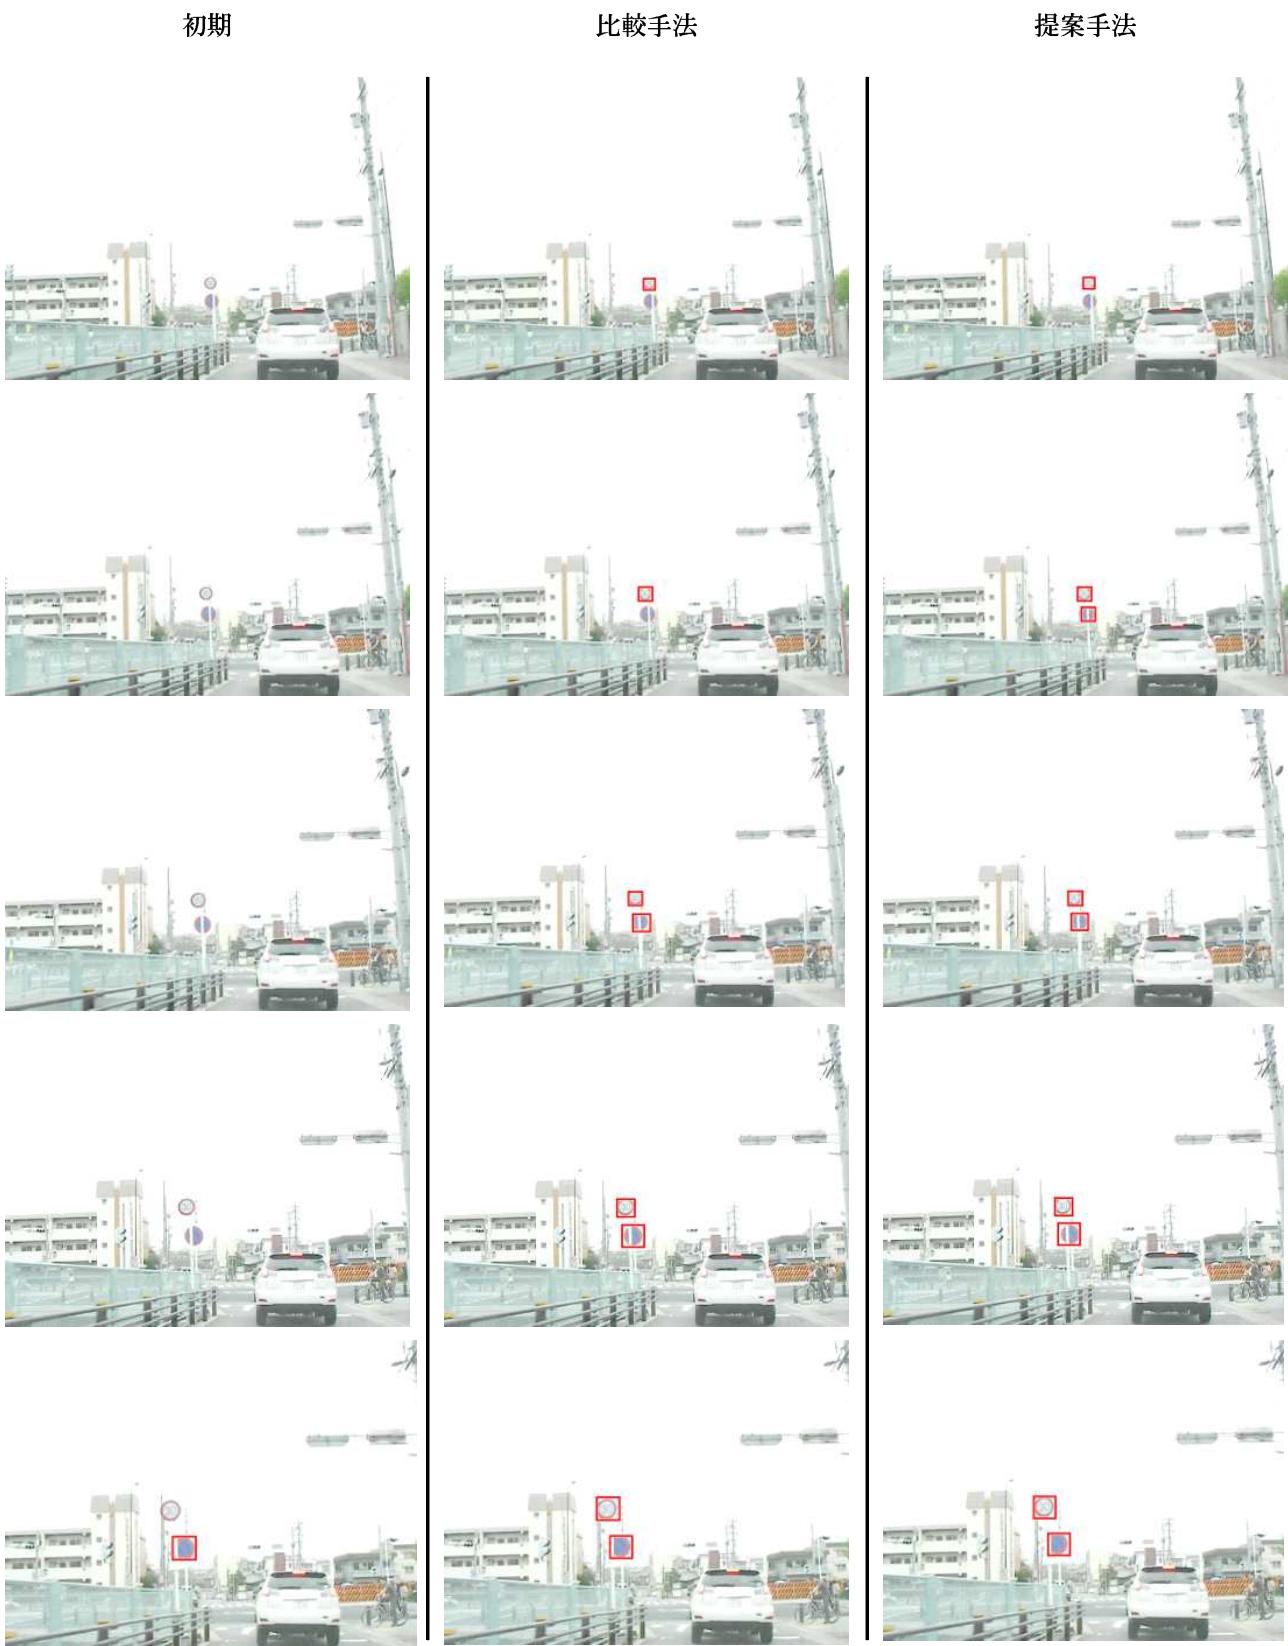


図 10 検出結果例

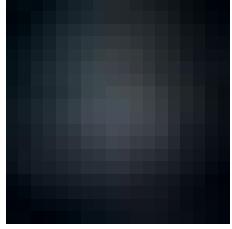


図 12 ラベル付与失敗例

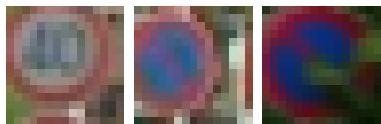


図 13 ラベルを付与できなかった画像例

なかつたためであると考えられる。今回、副識別器に用いた特徴量は、グレースケール画像から特徴を抽出しており、色の情報を用いていない。ゆえに、副識別器を色の特徴を用いたものとする、もしくはより多くの識別器を用意して多数決を行うことで、誤ったラベル付与を防ぐことができると考えられる。今後、識別器の種類、数、についてさらなる検討が必要であろう。

また、今回用意したラベルなしデータの中で、ラベルを付与できなかった道路標識画像が存在した。それは図13に示すような画像であった。図のように、画像中心からずれている道路標識、撮影角度の影響により楕円形となっている道路標識、一部が遮蔽物により隠されている道路標識、といった画像を正しく判定することができなかつた。これは、その時点でのラベルあり集合 \mathcal{V} 中に、このような変化を含んだデータが存在しなかつたため、識別器が道路標識と判定できなかつたためと考えられる。このような特殊な変化を含んだ道路標識をラベル付与の対象と判断するには、事前に \mathcal{V} 中に類似したデータが必要であると考えられる。対策としては、初期ラベルありデータにこのような変化を含む画像を入れておくことが考えられる。今後は初期ラベルありデータを変化させた際の性能の調査が必要である。

6. まとめ

本発表では、ラベルなしデータに自動でラベルを付与することで、低コストに高精度な道路標識検出器を構築する手法を提案した。具体的には異なる特徴量および構築手法で複数の識別器を構築し、ラベルなしデータの識別を行なつた。この識別結果から多数決により道路標識のラベルを付与するデータを選択した。これにより、多様なラベルあり学習用データを自動で増やす手法を実現した。提案手法を用意されたラベルなしデータ集合に適用した結果、F値が 0.73 の検出器の性能を最大で 0.94 まで上げることに成功した。

今後の課題として、多様な識別器の利用によるラベル付与の効率化および信頼性の向上、車載カメラ映像から

のラベルなしデータ自動収集方法の検討、が挙げられる。

謝辞 日ごろ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及び JST 戦略的創造研究推進事業CREST によつた。また本研究では画像処理に MIST ライブリ (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," Proceedings of International Conference 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," Proceedings of IEEE Intelligent Vehicles Symposium (IV) 2005, pp.255–260, June 2005.
- [3] 道満恵介, 出口大輔, 高橋友和, 目加田慶人, 井手一郎, 村瀬洋, "色変動を考慮した生成型学習法による道路標識検出器の構築," 電子情報通信学会論文誌 (D), vol.J93-D, no.8, pp.1375–1385, Aug. 2010.
- [4] D. Deguchi, M. Shirasuna, K. Doman, I. Ide and H. Murase, "Intelligent traffic sign detector: Adaptive learning based on online gathering of training samples," Proceedings of IEEE Intelligent Vehicles Symposium (IV) 2011, pp.72–77, June. 2011.
- [5] 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 (D-II), vol.J83-D-2, no.2, pp.855–858, Feb. 2000.
- [6] 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, Mar. 2005.
- [7] 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, EID99-143, February 2000.
- [8] 萩木登, 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 (D-II), vol.J77-D-2, No.7, pp.1393–1394, July 1994.
- [9] P. Viola and M. Jones, "Robust real-time face detection," International Journal of Computer Vision, vol. 57, no.2, pp.137–154, May 2004.
- [10] Xiaojin Zhu, "Semi-Supervised Learning Tutorial," Proceedings of International Conference on Machine Learning (ICML) 2007, June 2007.
- [11] A. Blum and T. Mitchell, "Combining labeled and unlabeled data with co-training," Proceedings of 11th Annual Conference on Computational Learning Theory, pp.92–100, July 1998.
- [12] A.P. Dempster, N.M. Laird, and D.B. Rubin, "Maximum likelihood from incomplete data via the EM algorithm," Journal of the Royal Statistical Society, Series B, vol.39, no.1, pp.1–38, Jan. 1977.
- [13] L. Zhang, R. Chu, S. Xiang, S. Liao, and S.Z. Li, "Face detection based on multi-block LBP representation," Proceedings of Advances in Biometrics, International Conference (ICB) 2007, pp.11–18, Aug. 2007.
- [14] J. Friedman, T. Hastie, and R. Tibshirani, "Additive logistic regression: A statical view of boosting," The Annals of Statistics 2000, vol.28, no.2, pp.337–407, Dec. 2000.