

機械学習を用いた交通信号機の検出と認識

仲野 彰 洋^{†1} 子安 大 士^{†1} 前川 仁^{†1}

カメラ画像を利用した安全運転支援のひとつに、交通信号機の認識が挙げられる。我々は信号機の認識手法としてカルマンフィルタとテンプレートマッチングを使用する手法を提案しており、ある範囲での信号機灯火の検出と追跡ができることを確認した。しかし、テンプレートマッチングではカメラの撮影位置による信号機の見え方の変化や、太陽光などの影響による明度の変化に対応できない場合がある。そこで、本研究では機械学習を利用した交通信号機の認識手法を検討した。信号機画像と信号機以外の画像から信号機の識別に有効な特徴量を抽出し、その特徴量を分類することで信号機の検出を行う。様々な環境で撮影した信号機画像を用いて学習させることにより、テンプレートマッチングでは検出できなかった信号機を本手法によって検出できることを確認した。信号機の検出精度を検証する実験を行い、本手法の有効性と課題を示す。

Detection and Recognition of Traffic Signal Using Machine Learning

AKIHIRO NAKANO,^{†1} HIROSHI KOYASU^{†1}
and HITOSHI MAEKAWA^{†1}

To improve road safety by assisting the driver, traffic signal recognition by on-board camera is one of required technologies. We have proposed to detect traffic signals and to keep tracking them by template matching and Kalman filtering. However, its stability of detection is not robust enough to illumination variation or changes in appearance of the signals to detect. To adapt these kind of changes in circumstances, we present recognition method of traffic signal using machine learning approach in which we employ AdaBoost and support vector machine(SVM) technique. We conduct experiments to evaluate its performance for several hundreds sample images.

1. はじめに

今や自動車は日常生活になくてはならないものになってきている。その一方で、自動車の交通事故による人身被害や渋滞による時間の損失、排気ガスによる環境汚染などといった問題を抱えている。この様な道路交通の問題解決のため、近年では、「走る、曲がる、止まる」などの基本性能だけではなく、「安全性」、「環境性」、「エネルギー性」などの分野の研究が行われている。国内外では、ITS(Intelligent Transport System: 高度道路交通システム)を利用した安全性の向上、渋滞の緩和、環境の保全を図る取り組みが進められている。特に安全運転の支援は、交通事故の減少や渋滞の緩和に深く関係することから注目されている。

安全運転の支援において、特に交差点における支援は重要であるといえる。交通安全白書¹⁾によると、道路形状別で交通死亡事故発生件数をみた場合、交差点とその付近で約半数を占めている。しかし、交差点で重要な交通情報デバイスである交通信号機から得られる情報を活用しようという試みはほとんどなされていない。

一部の主要道路では、赤外線などを通して、道路側から信号機情報を車両側に配信するシステムが実用化されているが、全ての道路に実装するとすると、莫大な費用と時間が必要となる。従って、現状では車両側が既存の交通環境から情報を取得しなくてはならない。

また、ドライバーは自動車を運転する際、交通信号機、走行レーン、車間距離、道路標識などの多くの視覚的情報を用いて安全運転を心がける。しかし、情報が多い交通状況では、ドライバーの視野の範囲が狭くなることが報告されている³⁾。視野の範囲が狭くなると、交通状況に関する重要な情報が発見できなかったり、発見が遅れてしまい、交通事故へ繋がる恐れがある。

そこで本研究では、車載カメラ画像を用いて交通信号機の認識を行う。自動車の運転は、視覚に強く依存している。従って、カメラによる画像認識でドライバーの視覚情報を補う運転支援は有効な手段であると考えられる。カメラを用いた運転支援は、多くの研究が進められており、道路上の障害物の検出⁶⁾、道路交通標識の認識⁷⁾、後方の車両の検出⁸⁾などがある。

木村らの研究では、信号機の灯火のように輝度の高い物体をカメラで撮影したときに生じる、色情報の損失(色飽和)にロバストな交通信号認識手法を提案している⁵⁾。

また、我々はカルマンフィルタとテンプレートマッチングを使用する信号機認識手法を提

^{†1} 埼玉大学大学院理工学研究科
Graduate School of Science and Engineering, Saitama University

案しており、ある範囲での信号機灯火の検出と追跡ができることを確認した¹⁾。しかし信号機のテンプレートは、赤・黄・青信号機それぞれに対して2枚ずつしか使用していない。そのため、信号機の明度の変化や、角度の変化に対応できず誤検出や非認識が生じる場合がある。そこで、本研究では機械学習に着目し、この問題点を改善を試みる。赤・黄・青信号機のそれぞれに対して機械学習を行うことで、多様なパターンの信号機検出に対応できると考える。

2. 信号機認識手法

2.1 概要

交通信号機の検出は図1の手順に示すように、学習フェーズと認識フェーズに分けて行う。学習フェーズでは、複数枚の信号機画像から、学習の際に用いる特徴量を抽出し、検出対象であるポジティブデータと、検出対象以外のネガティブデータの2つに分ける。認識フェーズでは、まず入力画像から信号機灯火の候補となる領域を求め、信号機の位置と灯火の色を決定する。その後、入力画像から学習フェーズで用いた特徴抽出手法で特徴量を抽出する。学習結果を用いて、信号機領域を探索する。その領域が灯火候補の領域を含んでいたら、信号機の領域として検出する。

2.2 Haar-like 特徴を用いた信号機の特徴量抽出

まず、学習フェーズでの処理を説明する。学習フェーズでは、複数枚の学習画像内から特徴量抽出とその特徴量の分類の処理を行う必要がある。本研究では、2パターンの機械学習を行うため、それぞれ違う特徴量と分類方法を用いて学習を行う。まず、Haar-like 特徴を用いて画像内から特徴量を抽出する手法を以下に説明する。

Haar-like 特徴は、黒と白の二種類の矩形領域を組み合わせることで作成する特徴であり、図2は、Haar-like 特徴で用いる矩形領域のパターンである。矩形領域のパターンにより、2つの白黒領域から、縦方向、横方向、斜め方向のエッジと円形の特徴を抽出することが可能である。また、3つの白黒領域からは、線分の特徴を抽出することが可能である。

この矩形領域間における特徴量 $T(W, B)$ は、次式のように算出する。この式における $S(W)$ は、白い矩形領域内における画素の輝度値の総和を表し、 $S(B)$ は、黒い矩形領域内における画素の輝度値の総和を表す。

$$T(W, B) = S(W) - S(B) \quad (1)$$

図3は、Haar-like 特徴の一部を、グレースケール化した信号機画像上に置いた場合である。

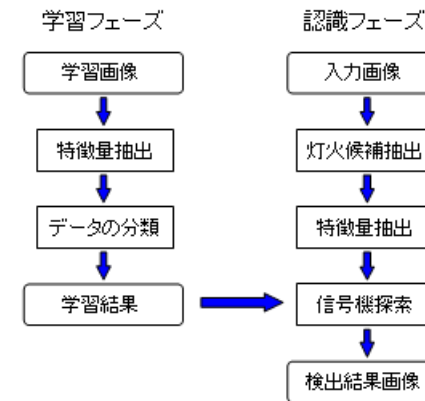


図1 提案手法の流れ。学習フェーズと認識フェーズの2つの段階に分けて交通信号機の検出を行う。
Fig.1 Flow of proposed method which consists of learning phase and recognition phase.

信号機画像では、点灯している灯火の領域は明るく、点灯していない灯火の領域は暗いため、図3のような Haar-like 特徴を置くことができる。さらに、2つの点灯していない灯火の間は、周辺よりも明るいいため、暗明暗の Haar-like 特徴を置くことができる。このような Haar-like 特徴が、信号機を判定する上で重要となる。また、この Haar-like 特徴パターン一つ一つが、次に述べる AdaBoost を構成する弱識別器となる。

2.3 AdaBoost を用いた特徴量の識別

学習フェーズでは、学習の処理で学習画像から抽出した特徴量を、ポジティブデータとネガティブデータに識別しなければならない。本研究では Haar-like 特徴量データを、AdaBoost を用いて識別する。AdaBoost は、一つひとつはあまり判別能力の高くない弱識別器に対して、信号機を判定する上での重要度にあわせて重みをつける。それらの弱識別器を多数組み合わせることで、判別能力の高い強識別器を作ることができる。以下に AdaBoost における識別器の生成の手順を示す。

- (1) まず、 N 個の学習用データセット $(x_1, y_1), \dots, (x_i, y_i), \dots, (x_N, y_N)$ を与える。ここで、 x_i は Haar-like 特徴の特徴量ベクトル、 y_i は x_i に対する出力ラベルであり、 x_i がポジティブデータなら $y_i = 1$ を、 x_i がネガティブデータなら $y_i = 0$ を与える。




図 2 使用する Haar-like 演算子. 特徴量は黒領域と白領域の差分
Fig. 2 Haar-like differential operators in use.




図 3 Haar-like 特徴を信号機画像への適用.
Fig. 3 Haar-like operators to detect features of signal light.

- (2) 重み w_i を初期化する. $w_i = \frac{1}{N}$, ($i = 1, \dots, N$)
- (3) 弱識別器の総数を M とした時, $m = 1, \dots, M$ について以下を繰り返す.
 - step1 弱識別器を $f_m(x)$ とし, 重み w_i を用いて学習させる.
 - step2 各弱識別器の重み付けされたデータに対する誤差率 $\varepsilon_m = \frac{\sum_{i=1}^M w_i f_m(x)}{\sum_{i=1}^N w_i}$ から, 各弱識別機の信頼度 $\alpha_m = \log\{\frac{1-\varepsilon_m}{\varepsilon_m}\}$ を計算する.
 - step3 重み w_i を更新する. $w_i = w_i \exp\{\alpha_m f_m(x)\}$

(4) 最終的な強識別器 $F(x)$ は, 各弱識別器の和で表す. $F(x) = \text{sign}(\sum_{m=1}^M \alpha_m y_m(x))$
各弱識別器の重み付けされたデータに対する誤差率 ε_m の値が小さいと, 各弱識別機に対する信頼度 α_m が大きくなり, その信頼度が高くなる.

2.4 HOG 特徴を用いた信号機の特徴量抽出

本研究で用いる 2 つ目の機械学習として, Histogram of Oriented Gradients(HOG) 特徴を用いる学習を行う. HOG 特徴は近接画素の勾配を局所領域ごとにヒストグラム化する. そのため, 照明の影響を受けにくく, 局所的な幾何学変化に頑健である. 画像内から HOG 特徴量を抽出する手法を以下に説明する.

まず, 画像をセルと呼ばれる 5×5 画素の小領域に分割する. 分割したセル上の座標 (x, y) の輝度値 $I(x, y)$ から勾配強度 m と, 勾配方向 θ を次式より算出する.

$$m(x, y) = \sqrt{f_x(x, y)^2 + f_y(x, y)^2} \quad (2)$$

$$\theta(x, y) = \tan^{-1} \frac{f_y(x, y)}{f_x(x, y)} \quad (3)$$

$$\begin{cases} f_x(x, y) = I(x+1, y) - I(x-1, y) \\ f_y(x, y) = I(x, y+1) - I(x, y-1) \end{cases} \quad (4)$$

算出された勾配強度 m と, 勾配方向 θ を用いてセル領域における輝度勾配の方向ヒストグラムを作成する. 勾配方向 θ は本来, $0^\circ \sim 360^\circ$ の範囲であるが, ここでは勾配の向きを考慮する必要がないため, 輝度勾配の方向ヒストグラムは, $0^\circ \sim 180^\circ$ の範囲を 20° ずつ分割した, 9 方向の方向ヒストグラムから作成する.

3×3 セルを 1 ブロックとし, 各セルで作成した輝度勾配の方向ヒストグラムを正規化する. 正規化はブロックを画像の左上から右下に 1 セルずつ移動させながら行う. 1 つのセルが 9 方向の方向ベクトルを持つため, 1 セル 9 次元の特徴量となり, 1 ブロックあたり 9 次元 \times 9 セル = 81 次元の特徴量を持つことになる.

i 行 j 列のセルの方向ヒストグラムを $H_{ij} = [h_1, \dots, h_9]$ とすると, k 番目のブロックの特徴ベクトル V_k は, 次式のように表すことができる.

$$V_k = [H_{ij}, H_{i+1j}, H_{i+2j}, H_{ij+1}, \dots, H_{i+2j+2}] \quad (5)$$

正規化した特徴ベクトルの特徴量を v_{ijl} とすると, 次式のように正規化を行う.




図 4 信号機画像を 5×5 ピクセルのセルに分割し、9 方向の方向ヒストグラムを作成する。
Fig. 4 Cell division of signal image.

$$v_{ijl} = \frac{h_{ijl}}{\sqrt{\|V_k\|^2 + \epsilon^2}} \quad (6)$$

このとき h_{ijl} は i 行 j 列目の方向ヒストグラムを表し、 l は輝度勾配を分割した数を表す。また $\epsilon = 1$ とする。この正規化されたブロックを信号機の特徴量として、学習データを作成する。

2.5 SVM を用いた特徴量の識別

学習画像から抽出した HOG 特徴の特徴量データは、ポジティブデータとネガティブデータに識別しなければならない。本研究では、HOG 特徴量データを Support Vector Machine(SVM) を用いて識別する。SVM は未学習データに対して高い識別性能を持つ。SVM は以下のような手順で行い、学習データを識別する。

ポジティブデータとネガティブデータの 2 クラスの分離にマージンを用いた線形分離を行う。マージンとは分離境界と最も近い学習データとの最短距離であり、このマージンが最大となるような線形分離を求める。

しかし、実際には線形分離できる特徴空間はほとんどない。そこで、より高次元な空間に学習データを写像し、その高次元空間内で線形分離を行うという手法が考えられる。しかし、高次元空間内での線形分離には莫大な計算量が必要となるため現実まででない。

そこで、カーネルトリックを用いる。カーネルトリックとは、学習データを高次元空間に写像するが、実際には写像された空間内での学習データの計算を避け、学習データの特徴ベ

クトルを $\mathbf{x}_1, \mathbf{x}_2$ とすると、カーネル $K(\mathbf{x}_1, \mathbf{x}_2)$ の計算のみで最適な識別関数を構成する。カーネルは計算が容易なものが望ましく、本研究では以下のカーネル関数を用いる。

$$K(\mathbf{x}_1, \mathbf{x}_2) = \exp\left(-\frac{\|\mathbf{x}_1 - \mathbf{x}_2\|^2}{2\sigma^2}\right) \quad (7)$$

2.6 Hough 変換による信号機灯火の検出

図 1 の認識フェーズでは、まず信号機灯火候補の検出を行う。この手法は中田らの手法の中で使われているものと同じものであり、信号機灯火が円形であることを利用して一般 Hough 変換を用いて検出を行う¹⁾。詳細な手順は、まず、信号機の灯火の色ごとに 2 値化画像を作成する。2 値化画像を入力として、Hough 変換による円検出を行う。図 5 は、円検出を行い、作成した 2 値化画像の例と検出した円を表示した例である。(a) を入力画像とした時、(d) が赤色を閾値として作成した 2 値化画像であり、(g) が検出した円を表示した画像である。同様に、(e) は (b) から黄色を閾値として作成し、(h) を検出した円とする。同様に、(f) は (c) から青色を閾値として作成し、(i) を検出した円とする。この処理で検出した円を信号機灯火の候補とする。

また、認識フェーズにおける特徴量の抽出とその分類方法は学習フェーズで用いた手法と同じものを用いる。認識フェーズでの特徴量の分類は、信号機の探索において、抽出した特徴量が学習した信号機の特徴量と一致しているのかの判定の際に用いる。

3. 実験と考察

3.1 実験方法

提案手法を用いて、様々なパターンで撮影した画像から、赤・青・黄色信号機をそれぞれ検出できるか実験を行う。画像の撮影は、天候は晴れの日、異なる日時、場所で行った。その他の撮影環境とカメラの設定を表 1 に記す。

また、信号機を正しく認識しているかを目視で確認し、信号機の認識精度の評価を行う。それぞれの結果から、認識の成功例・失敗例や、正答数・失敗数から正答率を示す。

3.2 カメラ画像からの信号機認識実験

信号機認識結果の一部を図 6 に示す。信号機を検出した位置を画像中に円または矩形で示し、認識した灯火の色と円または矩形の色を対応させている。

図 6 (a) (b) は Haar-like 特徴と AdaBoost による学習結果を用いた信号機検出の例である。(a) では画像中から信号機の認識に成功した。正しい位置に、正しい色の円が表示されているのが確認できる。しかし、(b) では画像中から信号機の認識に失敗した。信号機を




図 5 信号機灯火の抽出結果. 上段は入力画像, 中段は信号機灯火の色閾値とした 2 値化画像, 下段は灯火候補である円の抽出結果をそれぞれ表す.
Fig. 5 Some results of signal-light extraction. Top row: input images, middle row: binarized images, and bottom row: recognition results.

表 1 カメラの撮影環境

Table 1 Specifications of camera used.

使用カメラ	Canon ivis HF11
焦点	自動調整
画素数	640 × 480[pixel]
フレーム・レート	30[fps]
撮影時刻	8:00 ~ 16:00
天候	晴れ

認識しなかったり, 灯火の色を誤認識している.

同図 (c) (d) は HOG 特徴と SVM による学習結果を用いた信号機検出の例である. (c) では画像中から信号機の認識に成功した. 正しい位置に, 正しい色の矩形が表示されているのが確認できる. しかし, (d) では画像中から信号機の認識に失敗した. 信号機を認識しなかったり, 信号機のない場所に矩形が表示されている.

本研究で使用した 2 つの手法と, 中田らの手法¹⁾ との信号機検出精度の比較を行う. 赤・黄・青信号機をそれぞれ別々に評価し, 各色についての正答数, 失敗数, 正答率を示す. 入力画像内の信号機の位置と色を正しく検出できていれば正答とし, 誤検出や非検出がある場合は失敗とする.

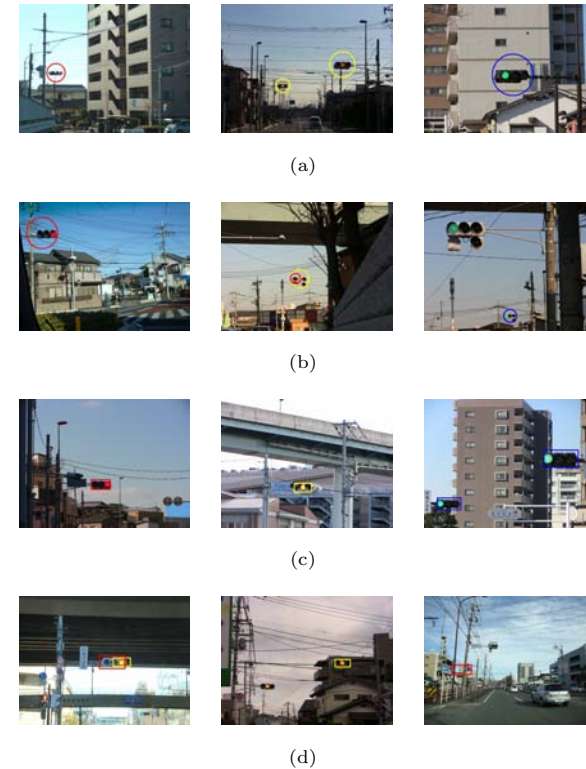


図 6 信号機検出の結果例. (a) と (b) は Haar-like 特徴と AdaBoost による学習結果を用いた信号機の検出例であり, (a) は成功例, (b) は失敗例をそれぞれ表す. (c) と (d) は HOG 特徴と SVM による学習結果を用いた信号機の検出例であり, (c) は成功例, (d) は失敗例をそれぞれ表す.
Fig. 6 (a)-(b): Detection example of signal in machine learning for Haar-like operators and AdaBoost. (a) is success example. (b) is failure example. (c)-(d): Detection example of signal in machine learning for HOG operators and SVM. (c) is success example. (d) is failure example.

表 2 ~ 表 4 を見てみると, 本研究と先行研究の結果を比べてみると, 正答率が全体的に向上している. これは, 先行研究ではあまり検出できなかった傾いて見える信号機に対して, 本研究で検出率が大幅に上昇したためだと考えられる.

しかし, 全体的に検出精度は多少向上が, 実用化するにはまだ精度が低い結果である. 特に,

表 2 各手法で赤信号機検出の精度比較
Table 2 Performance of red signal detection.

	総画像数	正答数	失敗数	正答率
先行研究	210	109	101	52%
Haar-like+AdaBoost	210	151	59	72%
HOG+SVM	210	133	77	63%

表 3 各手法で黄信号機検出の精度比較
Table 3 Performance of yellow signal detection.

	総画像数	正答数	失敗数	正答率
先行研究	116	45	71	39%
Haar-like+AdaBoost	116	70	46	60%
HOG+SVM	116	54	62	46%

表 4 各手法で青信号機検出の精度比較
Table 4 Performance of blue signal detection.

	総画像数	正答数	失敗数	正答率
先行研究	204	86	118	42%
Haar-like+AdaBoost	204	155	49	75%
HOG+SVM	204	131	73	64%

表 3 を見てみると, Haar-like+AdaBoost の学習を用いた検出結果では 60%, HOG+SVM の学習を用いた検出結果では 46%と, 他の色の信号機と比べてかなり低い結果となった。

また, Haar-like+AdaBoost の機械学習手法よりも HOG+SVM の機械学習手法の方が全体的に検出精度が低かった。これは, HOG+SVM の学習手法を用いた信号機検出では, 誤検出の数が多いことが原因であると考えられる。Haar-like+AdaBoost の学習手法では特徴量を信号機全体の領域としている。しかし, HOG+SVM の学習手法では HOG における 1 ブロックあたりの領域を特徴量としているため, Haar-like+AdaBoost の学習手法に比べて, 信号機領域の探索処理における領域の大きさが小さい。よって, 信号機の一部と類似した領域に誤検出が起きることが多くなってしまった。

3.3 考 察

本研究で提案した, Haar-like+AdaBoost の機械学習を用いた信号機認識手法と HOG+SVM の機械学習を用いた信号機認識手法の両方も, 全体的に中田らの手法¹⁾と比べて交通信号機の検出精度の向上した。これは中田らの手法¹⁾では, 信号機が傾いて見

える画像の認識精度が低いのに対して, 本研究の手法では, 傾いて見える信号機の特徴量データを数パターン学習させたため, 検出精度が大幅に上昇したためであると考えられる。

しかし, 検出精度は多少向上したが, 実用化するにはまだ全体的に精度が低い結果である。信号機の検出精度が低い原因として, 信号機の灯火候補の検出精度が低いことが考えられる。学習結果のみを用いた信号機検出では信号機の領域を検出できているが, Hough 変換による円検出で灯火を正しく検出できていないため, 結果的に信号機を正確に検出できない場合が多い。図 7 は, その例を示したものである。(a) は Hough 変換による円検出信号機の灯火候補を表示した図である。図中の信号機灯火の領域が正しく検出されていない。また, 明らかに円でない領域を円として誤検出している。(b) は Haar-like+AdaBoost の学習結果から検出した信号機領域を表示した図である。図中の信号機領域を正しく検出していることがわかる。(c) は (a) と (b) から検出した信号機領域を表示した図である。学習結果のみを用いた信号機検出では正しく信号機領域を検出していたが, Hough 変換による円検出で信号機灯火の領域を検出できていないため, 結果的に信号機は非検出となってしまった。



図 7 灯火の検出失敗による信号機非認識。(a) は信号機灯火の候補を検出し, 表示した図。(b) は Haar-like 特徴+AdaBoost の学習結果により信号機を検出した図。(c) は (a) と (b) より検出された信号機領域。

Fig. 7 (a): Detection of signal light. (b): Detection of signal only machine learning result. (c): Result of detection by (a) and (b).

さらに, 太陽光等の外部からの影響で灯火の色情報が変化し, 灯火候補の円の誤検出に繋がってしまう場合がある。特に, 黄信号機の灯火を赤信号機の灯火と誤検出してしまうことが多く, 黄信号機の正答率が他の信号機と比べて低い原因の一つであると考えられる。この問題に対しては, 灯火の色情報の変化にロバストな手法の検討が必要である。

4. ま と め

本論文では、まず、運転支援における交通信号機認識の重要性について述べ、道路側の情報提供デバイスが道路情報を提供するのではなく、車両側が道路情報を取得する必要性について述べた。提案手法では、一般道路より撮影した様々なパターンの信号機画像を用いて実験を行い、先行研究との検出精度の比較を行った。

以下に本研究の成果を示す。

- 信号機画像から Haar-like 特徴を特徴量データとして抽出した。
- AdaBoost を利用し、信号機の Haar-like 特徴量データとそれ以外の Haar-like 特徴量データに分類し、画像内から信号機領域の検出をした。
- 信号機画像から HOG 特徴を特徴量データとして抽出した。
- SVM を利用し、信号機の HOG 特徴量データとそれ以外の HOG 特徴量データに分類し、画像内から信号機領域の検出をした。
- 本研究で得られた信号機の検出結果に対して、中田らの手法¹⁾で得られた信号機の検出結果との比較を目視で行った。
- 中田らの手法¹⁾よりカメラの視点によって傾いて見える交通信号機の検出精度が向上した。

提案した手法を実装し、画像内から信号機の検出を行い、信号機の位置と灯火の色情報を取得できることを示した。特に、カメラの視点により傾いて見える信号機に対して、先行研究より大幅に正答率が上がった。しかし、太陽光の影響等で灯火の色が変わってしまうと灯火の非検出や誤検出が多くなってしまい、信号機領域を正しく検出できない場合が多い結果となった。

参 考 文 献

- 1) 中田裕士, 子安大士, 前川仁, “車載カメラを用いた動画からの交通信号認識”, 信学技報, Vol.107, No486, pp.121-125(2008-2).
- 2)
- 3) 高木修, 蓮花一己, “交通行動の社会心理学”, 北大路書房, pp.27-35(2000).
- 4) N.Dalal and B.Triggs “Histograms of Oriented Gradients for Human Detection”, IEEE Conference on Computer Vision and Pattern Recognition 2005, Vol.1, pp.886-893.
- 5) 木村文香, 高橋友和, 目加田慶人, 井手一郎, 村瀬洋, “安全運転支援のための多様な撮

影環境における信号認識”, MIRU2006, pp.618-623(2006-7).

- 6) 関晃仁, 奥富正敏, “ステレオ動画像を利用した平面領域抽出による障害物検出”, 情報処理学会論文誌, Vol.45, No.SIG 13(CVIM 10), pp.1-10(2004-12).
- 7) 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”, MIRU2008, pp.376-381(2008-7).
- 8) 尾崎貴洋, 山内悠嗣, 藤吉弘巨, “Joint HOG 特徴を用いた 2 段階 AdaBoost による車両検出”, 動的画像処理実用化ワークショップ (DIA2008), pp.101-106(2008).
- 9) C.M. ビショップ, “パターン認識と機械学習 下 第 14 章 モデルの結合”, シュプリンガー・ジャパン, pp.374-379.
- 10) 国土交通省:
<http://www.mlit.go.jp/>
- 11) 内閣府 政策統括官 交通安全白書:
<http://www8.cao.go.jp/koutu/taisaku/index-t.html/>