

# ETC 車両検知器データを利用した車種判別

—AdaBoost の学習における閾値設定範囲の検討—

有吉 達見<sup>†</sup> 泉 隆<sup>†</sup> 藤 琳<sup>†</sup>

日本大学<sup>†</sup>

## 1. はじめに

ETC<sup>[1]</sup>は、ITS 開発分野における自動料金収受システムに位置付けられ、ノンストップで料金収受を無線通信により行うシステムである。ETC には、料金収受の効率化、料金所周辺での渋滞緩和などのメリットがある。ETC レーンの構成例を図 1 に示す。




図 1 ETC レーンの構成例

図 1 に示すように ETC レーンには車両検知器が設置されており、無線通信装置等 ETC 設備のトリガとして使われている。本研究では、車両検知器データの有効活用として、車両検知器から得られるデータを利用した車種判別について研究している。ここでは、高速道路料金支払い 5 車種区分に対応する車種判別を行う。

本稿では、AdaBoost の学習時に必要なパラメータである閾値の設定範囲を変更し、車種判別精度の向上について検討した。

## 2. ETC 車両検知器データを利用した車種判別

ETC 車両検知器データを利用した車種判別の全体の流れを図 2 に示す。

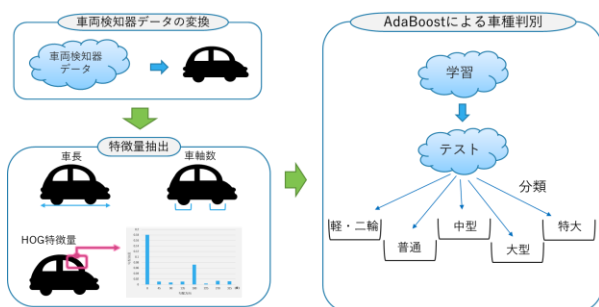


図 2 本研究の流れ

車種判別の流れとして、まず車両検知器データを特徴量が抽出しやすいデータに変換を行う。変換後のデータから特徴量を抽出し、AdaBoostにより特徴量を組み合わせて車種判別を行う。車両検知器データの変換、特徴量抽出、特徴量を組み合わせた車種判別の順に、次に説明する。

## 3. 車両検知器データの変換

ETC 車両検知器は、赤外線透過式センサであり、発光器群から投光される赤外線を受光器群が受光するか否かで車両の有無を検知する。

この車両検知から得られるデータは 1 次元 2 値データであり、これを時系列順に並べることで 2 次元 2 値データとなる。この 2 次元 2 値データを画像化すると図 3 のような車両側面の擬似データが得られる。本研究では、このバイナリ画像を「車影」と呼ぶ。



図 3 車影の例

## 4. 特徴量抽出

車両検知器データおよび車影から車種と関連のある特徴量を抽出する。

本研究で利用する特徴量は、車長、車軸数、黒画素数、HOG 特徴量<sup>[2]</sup>、Haar-like 特徴量<sup>[3]</sup>である。車長は、車両側面から見た前端から後端までの長さであり、車種区分定義に使用されている重要な特徴量である。車軸数は、車両側面から見たタイヤの数に相当し、車長と同様に車種区分定義に使用されている。黒画素数は、車両の側面積に相当する特徴量である。HOG 特徴量は、画像内のエッジ部分に着目した特徴量である。Haar-like 特徴量は、局所領域間の平均輝度差に着目した特徴量である。総次元数は 12711 次元となる。

## 5. 特徴量を組み合わせた車種判別

### 5.1 概要

抽出した特徴量を標準化した後に、AdaBoostにより学習を行い、車種判別を行う。

### 5.2 AdaBoost<sup>[4]</sup>

機械学習アルゴリズムの一種であり、弱識別器を組み合わせて強識別器を構成し、高精度な分類が可能である。各特徴量に閾値を設け、分類器を生成する。学習時には、その分類器に対して評価を行い、弱識別器を選定する。

### 5.3 閾値の設定範囲

AdaBoostにおいて、1次元の特徴量から複数の分類器を生成する。生成される分類器の数は、学習時に利用する閾値の設定範囲に依るものである。従来研究<sup>[5]</sup>において閾値の下限値-2.0, 上限値 2.0, 設定刻みを 0.1 としたため、1次元の特徴量から 40 個の分類器が生成される。

本研究では、この上限値および下限値を変更し、各車種の上下限値の最適値を探索する。

### 5.4 車種判別実験

首都高速道路用賀本線料金所 L6 を 2014 年 2 月 18 日 16 時 41 分から 2014 年 2 月 19 日 14 時 24 分までの間に通過した 18669 台分の車両検知器データを使用した。データ内訳を表 1 に示す。

表 1 データ内訳[台]

軽	普通	中型	大型	特大
942	11269	2492	3553	413

閾値の設定範囲を①[-2.0,2.0], ②[-2.3,2.3], ③[-2.5,2.5], ④[-2.9,2.9]の 4 パターンに設定した。また評価手法としては、5 分割交差検証を用いて車種判別実験を実施した。結果を表 2 に示す。

表 2 実験結果[%]

	軽	普通	中型	大型	特大	全体
①	99.04	99.52	95.30	97.92	98.06	98.60
②	99.15	99.46	95.38	97.92	97.54	98.58
③	99.36	99.46	95.35	97.75	97.50	98.54
④	99.25	99.51	95.34	97.66	97.53	98.55

表 2 より、全体の車種判別精度は①[-2.0,2.0] が最も高くなる結果となった。車種別で見ると、普通車、大型車、特大車に関しては、①[-2.0,2.0] が高くなる結果となった。軽自動車に関しては、変更後のいずれのパターンにおいても判別精度が向上する結果となり、③[-2.5,2.5]に設定時には、従来研究より 0.32% 向上した。中型車に関しても

②[-2.3,2.3]に設定時には、従来研究より 0.08% 向上した。

表 2 において色付けされたセルの閾値を最適値として、再度車種判別実験を行ったところ、全体の車種判別精度は 0.02% 向上する結果が得られた。

### 5.5 誤判別車両

本実験での誤判別車両については、従来研究で問題視されている誤判別車両と同じものが多くを占めていた。図 4 に誤判別車両の例を示す。



図 4 誤判別車両の例(左：普通車, 右：中型車)

本実験においては、210 台の誤判別車両のうちおよそ 65 台が図 4 のような車両に該当した。これらは、積載重量によって普通車または中型車に分類されており、特徴量の分布が似ているため、判別が困難であると考えられる。

## 6. まとめ

本稿では、AdaBoost 学習時における閾値の設定範囲を変更し、車種判別実験を実施した。軽自動車と中型車は、車種判別精度の向上が確認され、各車種の最適値での車種判別実験により全体の車種判別精度の向上も確認できた。

今後、更に様々な閾値の設定範囲による車種判別実験を実施し、車種判別精度の向上を目指す。

最後に、本研究にご協力いただいた首都高速道路、並びに首都高 ETC メンテナンスに感謝いたします。

## 文 献

- [1] 道路システム高度化推進機構：「ETC 便覧」(2012)
- [2] N.Dalal and B.Triggs : “Histograms of oriented gradients for human detection”, IEEE CVPR, pp.886-893 (2005)
- [3] P.Viola and M.Jones : “Rapid object detection using a boosted cascade of simple features”, IEEE CVPR, Vol.1, pp.511-518 (2001)
- [4] Y.Freund and R.E.Schapire : “A decision-theoretic generalization of on-line learning and an application to boosting”, Journal of Computer and System Sciences 55, pp.119-139 (1995)
- [5] 増島悠人, 泉隆, 高橋友彰, 山内伸一郎, 及川宗敏：「ETC 車両検知器データによる車種判別」, 平成 29 年電気学会全国大会, 4-215(2017-3)