

ETC 車両検知器データを利用した車種判別 学習区分細分化による精度向上

Vehicle Classification using Vehicle Detector Data from ETC Accuracy Improvement by Subdivision of Learning Data

○増島 悠人¹, 泉 隆², 香取 照臣²

*Yuto Masujima¹, Takashi Izumi¹, Teruomi Katori¹

ETC is the Electronic Toll Collection System which has been introduced on expressway in Japan. We focused on vehicle detector data in ETC. We are studying the vehicle classification using vehicle detector data with aiming at advance of vehicle detector in ETC. We have proposed the method for vehicle classification by combining features extracted from vehicle detector data, using Boosting algorithm. In this report, we examined the subdivision of learning data on AdaBoost.

1. はじめに

ETC(Electronic Toll Collection System/ノンストップ自動料金支払いシステム)は料金収受を無線通信により行うシステムであり, 高速道路料金所に設置・運用されている^[1]. ETC レーンの構成例を Figure 1 に示す.

本研究では, ETC レーンに設置されている ETC 車両検知器に着目し, ETC 車両検知器データを利用して通行車両を高速道路の料金支払い車種区分に対する車種判別について検討している^[2].




Figure 1. Configuration of ETC lane

本稿では, 車種判別精度向上のため学習区分の細分化について検討を行う. また, 学習区分の細分化に用いる k-means++法のクラスター数を自動で推定する手法の検討を行い, 提案手法の有効性を車種判別実験により確認する.

2. 車種判別手法

2.1 ETC 車両検知器データの変換

ETC 車両検知器は ETC レーンの側方に設置され, 発光器群から発光される赤外線を受光器群で受光するか否かで車両を検知する. ETC 車両検知器から, 車両の有無である高さ方向の 1 次元 2 値データを収集して, 横軸を時刻とする 2 次元 2 値データを得る. この 2 次元 2 値データから, 物体有を黒, 物体無を白で表す 2 値画像を作成することで, 車両側面の概形画像を得る. この画像を本研究では「車影」と呼ぶ.

2.2 特徴量抽出

車種判別を行うため, 車両特徴量である車長^[2], 車軸数^[2], 黒画素数^[2]と画像特徴量である HOG 特徴量^[3], Haar-like 特徴量^[4]の抽出をそれぞれ行う.

2.3 特徴量を組み合わせた車種判別

本研究では, 車影から車種と関連のある多数の特徴量を用いることから, 学習手法には多くの特徴量を効率的に学習することができる AdaBoost^[5]を 1vs 他方式により多クラスに拡張して用いる.

3. 提案手法

3.1 概要

Figure 2 に示す車影のように, 従来の学習区分では同一区分であっても概形や特徴が全く異なる車両が含まれている. このことから, 従来の学習区分では学習に用いる特徴量のばらつきが多く, 効率的な学習が行えていない可能性がある. そこで, 学習区分の細分化を行うことで, 効率的な学習が行えると考えた.



(a) Regular passenger vehicle (b) Small freight vehicle

Figure 2. Vehicle shadow of regular vehicles

3.2 k-means++法を用いた学習区分の細分化

本稿では, 学習区分の細分化を k-means++法^[5]を用いて行う. k-means++法は, 非階層クラスター分析手法のひとつである k-means 法のクラスター中心の初期値決めを変更して初期値依存による精度低下を改善した手法である.

3.3 クラスタ数自動推定

k-means++法ではクラスタ数 k を設定する必要があり、設定した値によってクラスタリングの精度が大きく異なる。また、本稿では学習区分（車種区分）ごとにクラスタリングを行うため、学習区分ごとに最適なクラスタ数を指定する必要がある。そこで、最適なクラスタ数を自動推定する手法を提案する。

提案手法では、k-means++法をクラスタ数 $k=2$ として再帰的に実行する。その際、逐次的に学習回数を抑えた AdaBoost を用いて学習を行い、学習データに対する誤り率を分割停止基準として用い、 k を決定する。これにより、最適なクラスタ数を自動で推定することができ、本研究で用いる AdaBoost の学習に特化した細分化を行うことができると考えた。

4. 車種判別実験

提案手法の有効性確認のため、車種判別実験を行う。

4.1 実験方法

車種判別実験は、k-means++法を用いた学習区分の細分化を $k=1$ (細分化なし)、 $k=2$ の k の値を指定した 2 通りと、提案手法の分割停止基準は AdaBoost の弱識別器 10 個算出時の誤り率 0.5% の場合と 1.0% の場合の 2 通りの計 4 通りで検証を行い、車種判別結果の比較を行う。それぞれ AdaBoost の学習回数 1~500 回すべてにおいて 5 分割交差検証を用いることで汎化性能の算出を行う。

4.2 使用データ

本研究で使用するデータを以下に示す。

首都高速道路 用賀本線料金所

第 6 レーン ETC 車両検知器 S1, S2

2014/02/18-19 18,669 台

正解データは ETC 車載器情報とカメラ映像の目視確認により作成した。使用するデータの内訳を Table 1 に示す。なお、本来は大型車と特大車に分類されているバスとトレーラは、本実験で使用するデータ数に偏りがあることや、正解データ作成時に正確な車種区分に分類することが困難であるといった問題があることから、本稿では料金支払い 5 車種区分 {軽・二輪, 普通車, 中型車, 大型車, 特大車} から 6 車種区分 {軽・二輪, 普通車, 中型車, 大型車, バス, トレーラ} に変更して車種判別を行う。

Table 1. Detail of targets for vehicle classification [vehicles]

	軽・二	普通	中型	大型	バス	トレ	全体
台数	943	11,268	2,490	3,533	190	245	18,669

4.3 車種判別結果

学習回数 1~500 回までで最も正解率が高かった車種判別結果の平均を Table 2 に示す。

Table 2. The result of vehicle classification [%]

	軽・二	普通	中型	大型	バス	トレ	車種平均	全体
$k=1$	99.26	99.51	95.66	98.36	98.42	99.18	98.40	98.75
$k=2$	99.47	99.59	95.86	98.39	98.95	98.78	98.51	98.84
提案 0.5%	99.36	99.56	95.86	98.42	97.89	99.18	98.38	98.82
提案 1.0%	99.47	99.54	96.10	98.44	98.95	99.18	98.61	98.86

4.4 考察

Table 2 から、 k の値を設定している場合より提案手法（分割停止基準を 1.0% とした場合）の車種平均と全体の正解率が高く、 k の値を自動推定した場合の正解率が向上していることがわかる。特に、他の車種より正解率の低い中型車の正解率は $k=1$ (細分化なし) から 0.44% 向上した。これらのことから、提案手法は車種判別精度の向上に有効であると考えられる。

5. まとめ

本稿では、車種判別精度向上のため学習区分の細分化について検討を行った。学習区分の細分化を用いているクラスタ数自動推定手法の検討を行い、車種判別実験により確認した。その結果、提案手法の正解率が 98.86% (提案 1.0%, 全体) となり、クラスタ数 k の設定をして学習区分の細分化を行った結果より高い正解率を得ることができた。

今後は、特徴量の次元削減、クラスタリング手法の改善等を行うことで車種判別精度の向上を図る。

最後に、本研究に協力を頂いた首都高速道路並びに、首都高 ETC メンテナンスに感謝する。

6. 参考文献

- [1]道路システム高度化推進機構：「ETC 便覧」(2012)
- [2]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)
- [3]N.Dalal and B.Triggs: "Histograms of oriented gradients for human detection", IEEE CVPR, pp.886-893 (2005)
- [4]P.Viola and M.Jones: "Rapid object detection using a boosted cascade of simple features", IEEE CVPR, vol.1, pp.511-518 (2001)
- [5]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)
- [6]D.Arthur and S.Vassilvitskii: "k-means++: the advantages of careful seeding", Proceedings of the eighteenth annual ACM-SIAM symposium on Discrete algorithms, pp.1027-1035 (2007)