

## 車両前方画像における影に着目した先行車両抽出

## - Haar-Like 特徴量による車両抽出の検討 -

## Detection of preceding vehicles based on shadow in the vehicle front view

## - Examination of vehicles detection by Haar-Like feature -

○関 弘翔<sup>1</sup>, 堀江 忠裕<sup>2</sup>, 松原 一樹<sup>2</sup>, 泉 隆<sup>3</sup>\*Hiroto Seki<sup>1</sup>, Tadahiro Horie<sup>2</sup>, Kazuki Matsubara<sup>2</sup>, Takashi Izumi<sup>3</sup>

Abstract: This research aims at prevention of a rear-end collision by performing dangerous prediction from the distance between two cars, and aiming at reduction in a human error by precedence vehicles detection by image processing. Precedence vehicles detection which paid its attention to the bottom shadow of vehicles has so far been performed. This report considered the vehicles detection using Haar-Like features and the AdaBoost learning algorithm.

## 1. まえがき

近年、交通事故発生件数は減少傾向にあるものの、平成 23 年には約 69 万件と依然として多くの交通事故が発生している。交通事故は車両相互による事故が 86[%]を占め、その中でも、追突事故が 39[%]と最も多くを占めている。また、これらの追突事故の多くは、脇見運転等のヒューマンエラーが原因とされている。そこで本研究は、単眼視により取得した車両前方画像に対し、計算機により画像処理を行うことで先行車両の存在を検知し、その情報をドライバに提供することで、追突事故の低減を目的とする。本研究は ITS(Intelligent Transport Systems: 高度道路交通システム)の開発分野の一つである、安全運転の支援に位置づけられる。

これまで、本研究では車両下影の利点から先行車両下影抽出を検討してきた<sup>[1]</sup>。本研究の車両下影抽出は、建物の影等の雑音成分を車両下影として誤抽出する問題がある。この車両下影抽出の欠点を補うために、車両自体を抽出する車両抽出と車両下影抽出との併用を検討する。車両抽出を行うに当たり、濃淡関係や位置関係といった研究者があらかじめ決めた特徴に従って行う手法では、汎用的な特徴の作成が困難である。そこで、学習を用いた車両抽出を行う。今回は、車両下影抽出と車両抽出の併用のための前段階として、Haar-Like 特徴量と AdaBoost 学習アルゴリズムを用いた車両抽出手法について検討したので報告する。

## 2. 処理概要

本研究の処理は、単眼視により取得した車両前方画像に対して行い、白線抽出による処理領域限定および車両下影抽出からなる。それぞれの処理について記す。

## 2. 1. 処理領域の限定

先行車両下影は、自車両が走行するレーン上に存在

するため、自車両走行レーンの白線を抽出することで、以後に行う車両下影抽出の処理領域を限定している。車両下影抽出の処理領域を自車両走行レーン内に限定することで、対向車両の影や歩道に存在する影等による誤抽出を抑制する。本研究での処理領域の限定はマルチバッファを用いたエッジ重畳および連結画素走査を用いて行う。

## 2. 2. 車両下影抽出

車両下影は輝度が低く、バラつきも少ないという特徴があることから、閾値未満の画素を影とみなし 2 値化を行うことで車両下影抽出を行う。本研究で使用する BMP 画像は R, G, B で構成されるため、以下に記す(1)式を用いて RGB 値から輝度値  $L$  への変換を行う。

$$L = 0.299 \times R + 0.587 \times G + 0.114 \times B \quad (1)$$

輝度変換画像に対し、輝度値の低い画素からカウントし、カウントが規定値に達した時の輝度値を 2 値化の閾値とする。2 値化後に、車両下影以外の雑音が存在、あるいは車両下影が分離することがあるため、影補完を行い、車両下影抽出とする。

## 3. Haar-Like 特徴量による車両抽出

## 3. 1. Haar-Like 特徴量

Haar-Like 特徴量<sup>[2]</sup>とは、局所特徴量のうち、輝度に着目したものの一つである。局所特徴量は、抽出対象物体の局所的な領域に着目した特徴量の事であり、環境変化や物体の形状変化にロバストな特徴である。どのような車両においてもほぼ同じような領域に輝度勾配を持つことから、Haar-Like 特徴量が車両抽出に有効な特徴量であると考えられるため今回採用した。

Haar-Like 特徴量は、Figure 1 に示すような白( $r1$ )と黒( $r2$ )の矩形領域の輝度平均の差を(2)式により算出し、特徴量とするものである。

$$H(r1, r2) = S(r1) - S(r2) \quad (2)$$

ここで  $S(r)$  は矩形領域  $r$  の輝度平均値を算出する関数

である。




Figure 1. Example of Haar-Like features

### 3. 2. AdaBoost による学習

前述した局所特徴量は、研究者の事前知識無しで、物体抽出に有効な特徴を多数の候補の中から学習できる Boosting と相性が良い。Boosting の中でも適応的なサンプル重みの更新が行え、2 クラス識別が可能である AdaBoost<sup>[3]</sup>を学習アルゴリズムとして採用した。以降、AdaBoost のアルゴリズムを記す。

学習サンプル  $S = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ ,  $x_n$ : サンプル,  $y_n$ : 属性(正誤)を用意する。

#### Step 1. 初期化

$$D_1(n) = 1/N \quad \text{For } n=1, \dots, N$$

ただし、学習サンプル重み  $D_t(n)$  ( $n=1, 2, \dots, N$   $t=1, 2, \dots, T$ ) とする。

#### Step 2. 弱識別器 $h_t(x)$ の学習

For  $t=1, \dots, T$

(a)  $M$  個の弱識別器候補の誤り率  $e_t$  算出

$$e_t^{(m)} = \sum_{i: y_i \neq h_t^{(m)}(x_i)} D_t(n) \quad \text{For } m=1, \dots, M$$

ただし、弱識別器候補  $h_t^{(m)} = \{h_t^{(1)}(x), h_t^{(2)}(x), \dots, h_t^{(M)}(x)\}$  とする。

(b) 誤り率  $e_t$  が最小となる弱識別器の選択

$$h_t(x) = \operatorname{argmin} e_t^{(m)}$$

ただし、弱識別器  $h_t = \{h_1(x), h_2(x), \dots, h_T(x)\}$ ,  $h_t(x) = \{+1, -1\}$  とする。

(c) 選択した弱識別器に対する信頼度  $\alpha_t$  の算出

$$\alpha_t = \frac{1}{2} \ln \frac{1 - e_t}{e_t}$$

(d) 学習サンプル重みの更新

$$D_{t+1}(n) = \frac{D_t(n) \exp\{-\alpha_t y_n h_t(x_n)\}}{\sum_{n=1}^N D_t(n) \exp\{-\alpha_t y_n h_t(x_n)\}}$$

$$D_{t+1}(n) = \frac{D_{t+1}(n)}{\sum_{n=1}^N D_{t+1}(n)}$$

#### Step 3. 強識別器 $H(x)$ の構築

$$H(x) = \operatorname{sign}[\sum_{t=1}^T \alpha_t h_t(x)]$$

以上の Step により構築した強識別器  $H(x)$  は、[] 内为正であれば車両であることを示す +1 を、負であれば非車両であることを示す -1 を出力する関数である。

### 4. 車両抽出実験

3. の手法の評価を行うために車両抽出実験を行った。実験に使用した動画は、天候が晴れと曇りで、一般道昼と高速道昼のものを使用し、画像サイズ 320×240

[pixel], AVI 形式, 30[fps] のものである。また、学習には画像サイズ 20×20[pixel], 正解画像には車両前方画像から切り出した車両画像 69[枚], 不正解画像には MIT データベース<sup>[4]</sup>の画像 2000[枚]を用いて行った。実験に使用した PC の仕様を以下に記す。

CPU : Intel(R)Core(TM)i5-4370K CPU @3.40GHz

メモリ : 8.00GB OS : Windows 7 Professional

抽出窓の中心が先行車両上にあり、かつ窓スケールが車幅程度のものを正抽出とした。抽出窓が残らなかったものを未抽出とし、それ以外のものを誤抽出とした。車両抽出実験結果を Table 1 に記す。

Table 1. Result of vehicles detection

	Expressway daytime	Ordinary road daytime
detection count[frame]	391	76
error count[frame]	114	262
undiscovered count[frame]	253	5
detection rate[%]	51.58	22.16
processing time[ms]	58.39	64.65

Table 1 より、抽出率はいずれも約 52[%]以下と低く、処理時間も 58[ms]以上という結果を得た。以降、実験結果についての考察を行う。

正抽出では、車両下影抽出において区別の難しい建物の影等の誤抽出を避け、かつ正抽出という結果を得ることができた。誤抽出では、特に一般道において路面や歩道などを捉える事が多かった。誤抽出の原因には、学習に用いた不正解画像として実際に車両前方画像から得られるものを使用しなかったことが挙げられる。これは、使用する学習サンプルを変更することで、抽出精度の向上が図れるものと考えられる。未抽出の原因は、主に高速道路において、先行車両が遠方に位置していたことが挙げられる。

### 5. まとめ

Haar-Like 特徴量と AdaBoost 学習を用いた車両抽出の検討を行った。抽出率や処理時間の改善が必要であるが、車両下影抽出において区別の難しい建物の影等の誤抽出を避けることができた。今後は、車両抽出精度の向上を図ると共に、車両下影抽出と車両抽出の併用手法について検討していく。

### 6. 参考文献

- [1] 堀江忠裕, 小野裕記, 泉隆: 「画像処理によるパーティクルフィルタを応用した先行車両追跡」, 平成 23 年電気学会交通・電気鉄道 ITS 合同研究会, TER-11-058, ITS-11-033, pp.1-6(2011)
- [2] P. Viola, M. Jones: "Rapid object detection using a boosted cascade of simple features," Proc. IEEE Conf. CVPR, pp.511-518 (2001)
- [3] Yoav Freund and Robert E. Schapire: "A decision-theoretic generalization of on-line learning and an application to boosting", Journal of Computer and System Sciences, 55(1), pp.119-139 (1997)
- [4] MIT ホームページ: 「CBCL code / datasets」  
<http://cbcl.mit.edu/cbcl/software-datasets/>(2012 年 9 月現在)