

## サポートベクターマシンによる車両検出方式の検討

6L-8

宮原 景泰 依田 文夫  
三菱電機(株) 情報技術総合研究所

## 1. はじめに

道路に設置されたカメラの画像を解析し、車両検出・追跡を行う画像センサが普及している。この画像センサは、背景差分やフレーム差分等の動画処理に基づいており、走行車両を効率的に捉えることができるが、長時間停止している車両を検出することは難しい。車両の軌跡情報を用いて駐車車両を検出する試み[1]も為されているが、動画処理に基づく以上、多地点からの映像が随時切り替わるような、時系列の画像が得られないシステムには対応できない。この場合、単独の画像から車両検出できる仕組みが必要となる。

本稿では、時系列の情報を用いずに車両検出するための、パターン認識に基づく検出方式について検討した結果を報告する。パターン認識手法としては、学習時に最適解が一意に定まり、識別性能の高いサポートベクターマシン (SVM: Support Vector Machine) [2] を用いた。

## 2. 検討内容

SVM による検出手法としては、文献[3]で人物検出に適用されているものがある。これは、物体検出を対象物体と非対象物体との 2 クラス識別問題とし、入力画像中に設定したウィンドウ (識別対象領域) をずらしながら特徴抽出・識別を行い、対象物体として識別された領域を検出する手法である。本稿で検討する車両検出手法は、車両前面画像を対象とし、上記手法と同様の動作フローをとる。以下、個別処理を説明する。

## 2.1 特徴抽出

識別対象領域を幅・高さ共に 64 画素となるよう線形正規化し、輝度レベルの正規化も行った後、特徴抽出を行う。使用特徴としては、今回は、モザイク画像と文献[3]で用いられている Haar ウェーブレット変換で検討した。

前者は低周波成分に当たり、 $4 \times 4$  画素の局所平均をとることでモザイク化した画像である。後者は高周波成分であり、 $8 \times 8$  画素と  $16 \times 16$  画素の 2 種類のスケールで Haar ウェーブレット変換 (図 1) を適用し、得られたウェーブレット係数の絶対値を特徴値とする。隣接する Haar ウェーブレットは、水平または垂直方向について 75% オーバーラップするよう配置し、分解能を高めている。




図 1 Haar ウェーブレット

## 2.2 SVM

SVM における非線形識別関数は、式 1 で表される。

$$f(\mathbf{x}) = \sum_{i=1}^l y_i \alpha_i \cdot k(\mathbf{x}, \mathbf{x}_i) + b \quad (\text{式 1})$$

ここで、 $y_i$  はクラスを表す変数 ( $\pm 1$ )、 $\alpha_i$  は乗数、 $k$  はカーネル関数、 $b$  はバイアス項、 $\mathbf{x}$  は識別対象ベクター、 $\mathbf{x}_i$  はサポートベクターで  $l$  はその数である。カーネル関数としては、本稿では 2 次の多項式カーネル (式 2) を用いた。

$$k(\mathbf{x}, \mathbf{y}) = (\mathbf{x} \cdot \mathbf{y} + 1)^2 \quad (\text{式 2})$$

## 2.3 学習

車両の下端中央位置を領域下端中央位置とし、普通乗用車の幅が領域幅・高さとなるよう手動で切り出した画像領域を車両クラスの学習サンプルとする。非車両クラスについては、最初はランダムに選んだ画像領域を用い、学習用画像群の中で誤検出した画像領域を追加して学習サンプルを構成した。この両者から、2.1 節で説明した特徴を抽出し、SVM の学習を行う。

なお、普通乗用車の大きさを基準としているため、大型車両については、上端・左右端の部分は含まれず、中央下部の領域が対象となる。車両クラスの学習画像例を図 2 に示す。



図2 学習画像の例

#### 2.4 車両検出

上記で述べたように、入力画像に対して識別対象領域を設定し、SVMの識別関数値に基づき検出を行うが、設定位置をずらしながら識別するため、車両付近では車両と見なされる領域が複数発生する。このため、識別関数値が一定以上でかつ極大な領域を車両位置と見なし、また領域が一定以上重なるペアがある場合は、識別関数値の小さい方を除外する。

### 3. 実験

実際の道路で約1時間に渡って収集した画像群を用い、基礎実験を行った。対象は一箇所の道路なので非車両のバリエーションには乏しいが、道路上には木やフェンスの影が大きくかかっており、エッジ成分の比較的多い状態である。

学習用画像群は最初の15分で収集したものとし、この中から抽出した、車両クラス332個(166個の車両画像とその鏡像画像)、非車両クラス514個の学習サンプルで学習を行った。テスト用画像群は残り45分における収集画像159個を用いた。テスト用画像群に写っている車両は、極度に遠方にあるものを除き371台あり、これを評価対象とした。


表1に実験結果を、図3に検出結果例を示す。モザイク画像とHaarウェーブレットはそれぞれ独立に学習を行い、検出条件は同じに設定した。検出精度としてはモザイク画像が良いものの、誤検出が非常に多く、全体的にはHaarウェーブレットの方が優れていると考えられる。ただし、モザイク画像の演算量はHaarウェーブレットの1割弱であり、モザイク画像も高速化のための前処理としては有効と思われる。

表1 実験結果

特徴	検出台数	誤検出数
モザイク画像	362 (97.1%)	126
Haar ウェーブレット	341 (91.4%)	26

誤検出の内容としては、車両の一部(特に大型車両)を別車両として検出したものがほとんどであり、

残りは二輪車の検出であった。車両周辺での誤検出対策が課題である。



\* (a)(b)は全車両正しく検出できた例、(c)は検出漏れ、(d)は誤検出の例である

図3 検出結果例

#### 4. まとめ

今回はサンプル数の比較的小さい基礎実験ではあったが、テストサンプルの9割以上を検出でき、一応の有効性は検証できた。今後はデータのバリエーションを増やして検討を進める予定である。

#### 参考文献

- [1]長谷川ほか, “移動物体追跡を利用した屋外駐車場における車両係数”, 信学論 D-II, Vol.J76-D-II, No.7, pp.1390-1398 (1993)
- [2]Scholkopf et al., “Advances in Kernel Methods: Support Vector Learning”, MIT Press (1998)
- [3]Mohan et al., “Example-Based Object Detection in Images by Components”, PAMI, Vol.23, No.4 (2001)