

1. はじめに

本研究では、車載カメラ画像から後方車両を検出することを目的とする。車両は人工物特有の直線的なエッジを多く含み、その形状には左右や上下の対称性や連続性といった特徴がある。本稿では、対称性や連続性の特徴を自動的に選択する Joint HOG 特徴と、2 段階 AdaBoost による後方車両検出法を提案し、その有効性を示す。

2. Joint HOG 特徴と識別器の構築

提案する Joint HOG 特徴は、2 段階に AdaBoost を構築することで、位置の異なる 2 つの low-level な特徴を組み合わせた Joint HOG 特徴の POOL を作り、最終識別器により Joint HOG 特徴を自動的に選択するものである。提案手法の概要を図 1 に示す。

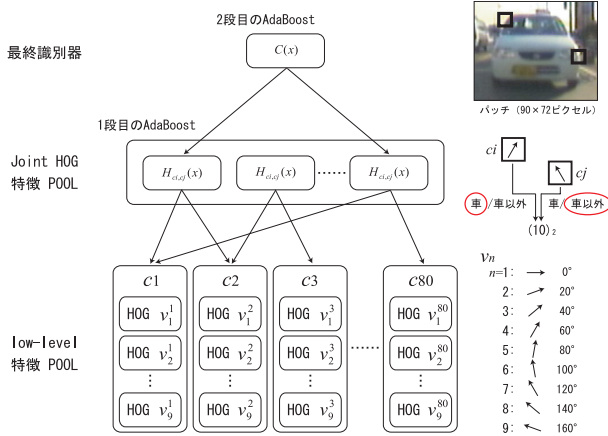


図 1：提案手法の概要

2.1. low-level 特徴

本手法では、low-level 特徴として Histograms of Oriented Gradients(HOG)[1]を用いる。HOG 特徴は図 2 に示すように、セル(9 × 9 ピクセル)における勾配方向をヒストグラム化した特徴(V = [v_1, v_2, v_3, ..., v_9])であり、物体の形状を表すことが可能である。隣接画素の勾配を局所領域毎にヒストグラム化するため、照明の変化を受けにくく、局所的な幾何学変化に頑健な特徴となる。




図 2：HOG 特徴

2.2. Joint HOG 特徴

位置の異なる 2 つのセル c_i, c_j の HOG 特徴の関係を 1 段階目の AdaBoost により捉える。そのために、各セルから 1 つずつ HOG 特徴 v_k^{c_i}, v_l^{c_j} を選択し、車と車以外の識別を行う。ここで、k と l は HOG の特徴の勾配方向を表す。この結果を組み合わせる共起を表現した Joint HOG 特徴量を算出する。次に、この計算を k と l の全組み合わせの回数行い、共起を表現した特徴量を用いて、車の学習サンプルの出現確率と車以外の出現確率を算出する。識別時には、学習により得られる各クラスの出現確率の大小関係から車と車以外の識別を行う。これにより、次式に示す強識別器 H_{c_i, c_j}(x) が構築される。

$$H_{c_i, c_j}(x) = \begin{cases} 1 & \sum_{t=1}^T \alpha_t^{c_i, c_j} \cdot h_t^{c_i, c_j}(x) > 0 \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

ここで、T は学習回数、\alpha_t^{c_i, c_j} は 1 段階目の弱識別器 h_t^{c_i, c_j}(x) の重み、c_i と c_j はセルの組み合わせを表す。1 段階目の AdaBoost により、2 つのセル間における Joint HOG 特徴が選択される。その組み合わせはセルの位置関係からエッジの対称性や連続性を自動的に捉えたものとなる。

2.3. 最終識別器

2 段階目の AdaBoost では、Joint HOG 特徴で構築した強識別器 H_{c_i, c_j}(x) の中から、最も識別に有効な Joint HOG 特徴を選択して学習を行う。これは、車の識別に有効なセルの位置関係を選択することになる。2 段階目の AdaBoost により得られる最終的な強識別器 G(c) を次式に示す。

$$G(c) = \begin{cases} 1 & \sum_{t=1}^T \alpha_t \cdot g_t(c) > \lambda \\ 0 & \text{otherwise} \end{cases} \quad (2)$$

ここで g_t(c) は 1 段階目の AdaBoost より得られる強識別器、c = {c_i, c_j : 1 < i < 80, 1 < j < 80}, \lambda は検出器の閾値を表す。

3. 評価実験

提案手法の有効性を示すため、従来法である HOG 特徴のみを用いた検出法 [1] と Joint HOG 特徴のみを用いた検出法との識別精度の比較を行う。評価には、車載カメラの映像から車両部分を切り出したデータベースを用い、Detection Error Tradeoff(DET) カーブを用いて比較を行う。図 3(a) に各手法の DET カーブを示す。また、図 3(b) に提案手法による車載カメラの映像から後方車両を検出した例を示す。HOG 特徴のみを用いて識別した場合と比べ、Joint HOG 特徴と 2 段階の AdaBoost を組み合わせることで、誤検出率が 2.0 % の場合、未検出率が約 1.0 % となり、約 7.0 % 検出性能を向上させることができた。




図 3：DET カーブと後方車両検出例

図 4(a),(b),(c),(d) に最終識別器 G(c) の t 番目の弱識別器 g_t(c) として選択された 2 つのセルの組み合わせを示す。また、図 4(e),(f),(g),(h) に最終識別器のそれぞれのセルの組み合わせで、Joint HOG 特徴により選択された勾配方向を示す。図 4 より、車両の識別には、図 4(a), (b) のようなセルの位置関係が有効であることがわかる。また図 4(c) は左右対称となるセルの位置関係が、図 4(d) は連続性を捉えたセルの位置関係が自動的に選択されている。さらに図 4(g)(h) に注目すると、Joint HOG 特徴においても、それぞれのセルから左右対称な勾配方向や連続的な勾配方向が自動的に選択されていることがわかる。提案する Joint HOG 特徴では、車両形状の対称性や連続性を捉える特徴量を予め用意することなく、学習により自動的に対称性や連続性を表現したセルの位置関係を選択し、車の識別に有効な特徴セットを得ることができる。




図 4：識別器により選択された特徴

4. おわりに

本稿では、Joint HOG 特徴と 2 段階の AdaBoost による学習法を用いた車両検出法を提案し、有効性を確認した。参考文献

[1] N. Dalal and B. Triggs: "Histograms of Oriented Gradients for Human Detection", CVPR, pp. 886-893, 2005.