

# Research on Front Vehicle Detection Algorithm Based on Multi-feature Fusion and AdaBoost

Fangying Liang Qian Yan

Zhejiang Vocational and Technical University of Mechanical and Electrical Engineering, Hangzhou, Zhejiang, 310051, China

## Abstract

Vehicle detection in front is a key link in unmanned driving technology, which directly affects driving safety and decision-making accuracy. Aiming at the problem that traditional detection methods are greatly disturbed by factors such as illumination and occlusion in complex urban road environments, a multi-feature fusion detection algorithm based on monocular vision is proposed. This algorithm first extracts the Histogram of Oriented Gradients (HOG) features and Haar features of vehicles, and fuses the two features to overcome the limitations of a single feature; then, the AdaBoost algorithm is used to train a cascade classifier to achieve rapid and accurate detection of vehicles in front. Experimental results show that the algorithm has good adaptability in complex campus environments (including occlusion, illumination changes, etc.), with high detection accuracy and real-time performance that meets the requirements of practical applications, providing an effective solution for environmental perception of unmanned driving vehicles.

## Keywords

Vehicle detection; Monocular vision; Histogram of Oriented Gradients (HOG); Haar features; AdaBoost algorithm

# 基于多特征融合与 AdaBoost 的前方车辆检测算法研究

梁方英 闫茜

浙江机电职业技术大学, 中国 · 浙江 杭州 310051

## 摘 要

前方车辆检测是无人驾驶技术中的关键环节, 直接影响行驶安全性与决策准确性。针对复杂城市道路环境下传统检测方法受光照、遮挡等因素干扰大的问题, 提出一种基于单目视觉的多特征融合检测算法。该算法首先提取车辆的方向梯度直方图 (HOG) 特征与 Haar 特征, 通过融合两种特征克服单一特征的局限性; 随后采用 AdaBoost 算法训练级联分类器, 实现对前方车辆的快速准确检测。实验结果表明, 该算法在校园复杂环境 (含遮挡、光照变化等场景) 中表现出良好的适应性, 检测准确率高且实时性满足实际应用需求, 为无人驾驶车辆的环境感知提供了有效解决方案。

## 关键词

车辆检测; 单目视觉; 方向梯度直方图 (HOG); Haar 特征; AdaBoost 算法

## 1 引言

随着无人驾驶技术的快速发展, 环境感知作为其核心模块, 需实时准确识别周围车辆、行人等障碍物, 其中前方车辆检测是保障行驶安全的首要任务<sup>[1]</sup>。为此, 本文提出一种多特征融合的机器学习方法: 融合 HOG 特征 (抗光照变化能力强) 与 Haar 特征 (计算高效), 结合 AdaBoost 算法构建强分类器, 实现复杂环境下前方车辆的稳定检测。实验验证了该算法在遮挡、光照变化等场景中的有效性。

## 2 相关工作进展

车辆检测技术的发展经历了从传统方法到机器学习驱

动的演进<sup>[2]</sup>。近年来, 基于机器学习的方法通过样本训练分类器, 有效提升了检测鲁棒性。

## 3 检测算法设计

### 3.1 总体框架

算法流程如图 1 所示, 分为样本预处理、特征提取、分类器训练与车辆检测四个阶段。样本预处理: 对采集的车辆图像 (正样本) 与非车辆图像 (负样本) 进行灰度化、标准化, 统一尺寸; 特征提取: 分别提取 HOG 特征与 Haar 特征, 并进行特征融合; 分类器训练: 采用 AdaBoost 算法筛选弱分类器, 构建级联强分类器; 车辆检测: 通过级联分类器对输入图像进行多尺度滑动窗口检测, 输出车辆位置。

【作者简介】梁方英 (1984-), 女, 中国浙江诸暨人, 本科, 实验师, 从事电气自动化, 智能网联研究。

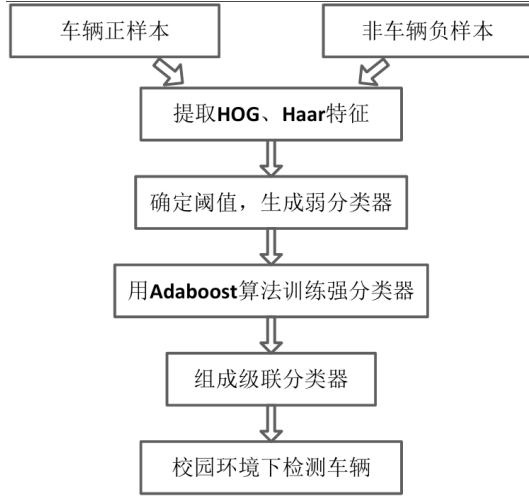


图 1 算法总体框架

### 3.2 特征提取

#### 3.2.1 HOG 特征提取

HOG 特征通过统计图像局部区域的梯度方向直方图描述目标形状, 提取步骤如下: 图像标准化: 采用 Gamma 压缩 ( $\gamma=1/2$ ) 减少光照与阴影影响, 公式为:

$$I(x, y) = I(x, y)^\gamma \quad (1)$$

梯度计算: 使用一维中心对称模板  $[-1, 0, 1]$  计算像素梯度, 梯度大小与方向公式为:

$$m(x, y) = \sqrt{f_x(x, y)^2 + f_y(x, y)^2} \quad (2)$$

$$\theta(x, y) = \arctan\left(\frac{f_y(x, y)}{f_x(x, y)}\right) \quad (3)$$

其中,  $f_x$ 、 $f_y$  分别为 x、y 方向梯度分量。单元格梯度投影: 将图像划分为  $30 \times 30$  像素的单元格 (cell), 每个 cell 的梯度方向均匀划分为 8 个通道 ( $0^\circ \sim 360^\circ$ ), 统计各通道梯度幅值之和, 形成梯度直方图。块归一化: 将 4 个 cell 组成  $2 \times 2$  的块 (block), 采用  $l_2$ -norm 归一化减少局部对比度差异, 公式为

$$v = \frac{v}{\sqrt{\|v\|_2^2 + \epsilon^2}} \quad (4)$$

其中  $\epsilon$  为极小值, 避免分母为 0。特征拼接: 整合所有块的归一化特征, 形成最终 HOG 特征向量。为提升实时性, 引入积分直方图优化计算: 通过预计算梯度图像的行列积分, 在滑动窗口检测时仅需通过加减运算快速获取区域特征, 减少重复计算。

在实际应用中, HOG 特征的参数设置对检测性能影响显著。本文通过对比实验确定最佳参数: 单元格大小设为  $30 \times 30$  像素, 既能捕捉车辆轮廓的整体特征, 又不过度牺牲局部细节; 梯度方向划分为 8 个通道, 在保证方向分辨率的同时控制计算复杂度; 块大小采用  $2 \times 2$  单元格, 兼顾特征的局部性与冗余度。Gamma 压缩参数  $\gamma=1/2$  能够有效抑

制光照变化带来的灰度波动, 提升特征鲁棒性。此外, 在滑动窗口检测中, 通过积分直方图技术将特征计算复杂度从  $O(N^2)$  降至  $O(N)$ , 显著提高实时性。针对车辆多尺度问题, 采用图像金字塔方法生成不同尺度的候选窗口, 确保远处小目标与近处大目标均能被有效检测。实验表明, 该参数组合在保证检测精度的同时, 实现了较高的处理速度, 满足无人驾驶系统对实时性的要求。

#### 3.2.2 Haar 特征提取

Haar 特征通过黑白矩形区域的灰度差描述局部边缘与纹理, 适用于车辆的水平/垂直特征 (如车窗、车身轮廓)。特征值计算公式为

$$\text{feature}_k = \sum_{i=1}^N \omega_i \cdot \text{RectSum}(r_i) \quad (5)$$

其中,  $\omega_i$  为矩形权值 (黑框为 -1, 白框为 +1),  $\text{RectSum}(r_i)$  为矩形区域的灰度积分。通过积分图技术加速计算, 避免重复遍历像素。

Haar 特征的显著优点是计算速度快, 但它在光照变化方面较为敏感, 为应对这一难题, 本文于提取 Haar 特征前实施局部对比度归一化处理, 通过对每个像素邻域开展标准差归一化, 减轻光照不均的作用, 为提升特征的辨别性, 利用 AdaBoost 算法自动筛选出对车辆识别贡献最为突出的 Haar 特征, 去除冗余和噪声特征, 特征计算时, 运用积分图技术让特征提取时间和图像尺寸呈线性关联, 极大提高了检测效率。

#### 3.2.3 特征融合

将 HOG 特征与 Haar 特征按维度拼接, 形成融合特征向量。融合后的特征既保留 HOG 对形状的鲁棒描述, 又包含 Haar 的局部细节信息, 有效提升分类器对复杂环境的适应能力。

### 3.3 基于 AdaBoost 的分类器设计

#### 3.3.1 弱分类器构建

以单一特征作为弱分类器, 表达式为

$$h(f(x), p, \theta) = \begin{cases} 1 & \text{if } p \cdot f(x) \leq p \cdot \theta \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

其中,  $f(x)$  为融合特征,  $p$  为方向参数 ( $\pm 1$ ),  $\theta$  为分类阈值。

弱分类器性能的优劣对强分类器的整体效果有着直接作用, 本文选用单一特征阈值分类充当弱分类器, 通过对特征值逐一遍历的方式来确定使分类错误率最小的最佳分类阈值, 以降低分类错误率, 为提升弱分类器的多样性, 每次迭代时随机挑选部分特征开展评估, 防止陷入局部最优。

#### 3.3.2 强分类器训练

初始化权重: 正样本权重为  $1/(2l)$ , 负样本权重为  $1/(2m)$  ( $l$ 、 $m$  分别为正、负样本数量); 迭代训练: 归一化样本权重; 计算每个弱分类器的加权错误率, 选择错误率最低的弱分类器; 更新权重: 错误分类样本权重增大, 正确分类样本权重减小, 公式为:

$$w_{t+1,d} = w_{t,d} \cdot \beta_t^{1-\alpha_t} \quad (7)$$

其中  $\beta_t = \varepsilon_t / (1 - \varepsilon_t)$ ,  $\varepsilon_t$  为第  $t$  轮错误率,  $e_t$  为分类结果标识 (错误为 1, 正确为 0); 强分类器组合: 将  $T$  个弱分类器加权融合, 公式为

$$H_{\text{final}}(x) = \begin{cases} 1 & \text{if } \sum_{t=1}^T \alpha_t h_t(x) \geq \frac{1}{2} \sum_{t=1}^T \alpha_t \\ 0 & \text{otherwise} \end{cases} \quad (8)$$

其中  $\alpha_t = \log(1/\beta_t)$  为弱分类器权重。

强分类器训练过程构成了 AdaBoost 算法的核心, 每一轮迭代时, 利用加权错误率选取最优弱分类器, 并且按照错误率动态改变其权重, 让错误率低的弱分类器在最终决策里起到更大作用, 为防止出现过拟合现象, 实施早停策略。

### 3.3.3 级联分类器优化

为提升检测速度, 将多个强分类器按级联结构串联: 前级分类器快速过滤非车辆区域, 后级分类器精细检测, 减少无效计算。级联阈值随层级递增, 平衡检测速度与精度。



(a) 遮挡



(c) 上午

## 4 实验结果与分析

### 4.1 实验设置

数据集: 采集校园道路图像构建数据集, 含正样本 2000 张 (各类车辆)、负样本 600 张 (行人、建筑物等), 图像分辨率为  $640 \times 480$ ; 硬件平台: JJUV-5 智能车, 搭载 Intel Core i5 处理器, 8GB 内存; 软件平台: OpenCV4.5, Python3.8; 评价指标: 准确率 (Precision)、召回率 (Recall)、帧率 (FPS)。

### 4.2 结果分析

#### 4.2.1 不同场景下的检测结果

实验测试了遮挡、傍晚、上午、中午四种典型场景 (图 2), 结果表明: 遮挡场景 (图 2a): 行人部分遮挡车辆仍能准确检测, 体现算法对遮挡的鲁棒性; 光照变化场景 (图 2b-d): 从低光照 (傍晚) 到强光照 (中午), 检测结果稳定, 验证 HOG 特征抗光照干扰的优势; 多尺度检测: 远处车辆 (小尺寸) 与近处车辆 (大尺寸) 均被有效识别, 表明算法支持变尺度检测。



(b) 傍晚



(d) 中午

图 2 不同场景下的检测结果

#### 4.2.2 性能对比

与单一特征算法对比 (表 1), 本文算法在准确率与召回率上均有提升, 且帧率满足实时性要求 ( $> 25\text{FPS}$ )。

表 1 算法对比结果

算法	准确率 (%)	召回率 (%)	帧率 (FPS)
HOG+AdaBoost	89.2	87.5	22
Haar+AdaBoost	86.8	85.3	30
本文算法 (HOG+Haar+AdaBoost)	92.5	91.3	26

#### 4.2.3 讨论

本文算法通过多特征融合与级联分类器设计, 在校园环境中表现出良好性能, 但仍存在局限性: 数据集场景单一 (主要为校园), 需在城市主干道、高速路等场景进一步验证; 极端天气 (暴雨、大雾) 下的检测精度可能下降, 需结合红外图像或雷达数据融合优化; 实时性可通过 GPU 加速

或轻量化网络结构进一步提升<sup>[3]</sup>。

## 5 结语

本文提出一种基于 HOG 与 Haar 特征融合的 AdaBoost 前方车辆检测算法, 通过多特征互补提升复杂环境适应性, 级联分类器设计平衡检测精度与速度。实验表明, 该算法在遮挡、光照变化场景中准确率达 92.5%, 召回率达 91.3%, 可满足无人驾驶车辆的实时检测需求。未来将扩展数据集场景, 并探索与深度学习方法的结合, 进一步提升算法鲁棒性。

### 参考文献

- [1] 吴文玲. 汽车行驶环境中的实时图像处理与目标检测技术[J]. 汽车电器, 2025, (07): 117-119.
- [2] 王一飞, 李勇杭, 张雅丽, 等. 基于自适应分割网络的隧道车道线检测[J]. 汽车安全与节能学报, 2025, 16(03): 478-486.
- [3] 金宝根, 吕庆梅. 基于卷积神经网络的红外弱小车辆目标检测方法[J]. 激光杂志, 2024, 45(05): 241-245.