

一种基于类 Haar 特征和改进 AdaBoost 分类器的车辆识别算法

文学志^{1,2,3}, 方 巍^{1,2}, 郑钰辉^{1,2,3}

(1. 南京信息工程大学计算机与软件学院, 江苏南京 210044; 2. 南京信息工程大学高性能网格计算与并行处理研究中心, 江苏南京 210044; 3. 昆山中创软件工程有限公司, 博士后工作站, 江苏昆山 215311)

摘 要: 提出一种基于类 Haar 特征和改进 AdaBoost 分类器的车辆图像识别算法, 以解决当前基于 SVM 分类器或级联分类器存在的分类识别性能不足以及传统基于 AdaBoost 算法的训练所需时间过长的问题. 首先, 基于积分图提取图像的扩展类 Haar 特征, 然后对所提取的海量类 Haar 特征应用改进的 AdaBoost 分类器训练方法进行特征选择及分类器训练, 最后利用所选择的特征信息及训练得到的分类器进行两类分类识别. 实验结果表明, 文中方法无论是在识别性能还是训练所需时间方面均明显优于传统方法, 具有较好的应用前景.

关键词: 车辆识别; 类 Haar 特征; AdaBoost 算法

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 0372-2112 (2011) 05-1121-06

An Algorithm Based on Haar-Like Features and Improved AdaBoost Classifier for Vehicle Recognition

WEN Xue zhi^{1,2,3}, FANG Wei^{1,2}, ZHENG Yu hui^{1,2,3}

(1. College of Computer and Software, Nanjing University of Information Science and Technology, Nanjing, Jiangsu 210044 China; 2. Research Center for High Performance Grid Computing and Parallel Processing, Nanjing University of Information Science and Technology, Nanjing, Jiangsu 210044 China; 3. Postdoctoral Work Station of Kunshan China Innovation Software Engineering Limited Corporation, Kunshan, Jiangsu 215311, China)

Abstract: An algorithm based on Haar-like features and AdaBoost classifier for vehicle recognition is proposed to solve the problem of poor recognition performance based on SVM (Support Vector Machines) classifier and cascaded AdaBoost classifier as well as the problem of much time consumed for training traditional AdaBoost. At first, the extended Haar-like features are extracted using integral image method, then a small number of critical features from a very large set of Haar-like features are selected while training AdaBoost, finally two classes classification is performed using the AdaBoost classifier and the selected features. Experimental results demonstrate that the proposed approaches has better performance both in recognition and time consuming than traditional methods, and shows promising perspective.

Key words: vehicle recognition; Haar-like features; AdaBoost algorithm

1 引言

在基于视觉的对象识别中, 机器学习方法由于识别性能高、鲁棒性好以及操作便捷而受到越来越多的关注. 机器学习方法主要用于进行两类的分类识别: 目标物或非目标物. 文献[1, 2]介绍了利用 PCA 进行特征提取然后采用 SVM 或神经网络分类器来进行车辆检测的方法. Schneiderman 在文献[3]中使用截断的小波系数特征结合 SVM 进行车辆的检测. Sun 等在文献[4, 5]中分别介绍了采用 Gabor 滤波器提取矩特征或采用 Haar 小波特征与 Gabor 特征相结合然后利用 SVM 分类器来

进行车辆检测的方法. 文献[6]介绍了一种利用级联 AdaBoost 分类器进行车辆检测的方法. 文献[7, 8]则分别介绍了 AdaBoost 分类器在行人检测和文本分类中的应用. 以上方法均在某些方面取得了较好的效果, 但各自均存在着不足之处, 对于基于 SVM 或神经网络的分类器识别方法: (1) 特征提取运算量大、耗时长, 特征描述能力不足, 识别性能仍有待进一步提高; (2) 所采用的基于径向基核函数(Radial Basis Function, RBF)的支持向量机虽然分类能力强, 但选参过程复杂; 而基于神经网络的分类器过分依赖于专家知识, 且容易陷于局部极小; (3) 对于基于级联 AdaBoost 分类器的识别方法, 虽

收稿日期: 2010-08-16; 修回日期: 2011-01-25

基金项目: 国家 863 高技术研究发展计划项目(No. 2006AA1Z221); 国家自然科学基金(No. 60702076); 南京信息工程大学科研基金资助项目(No. 20100394); 江苏高校优势学科建设工程资助项目

然实时性强于前面的两种分类器,但虚警率较高;(4)基于 AdaBoost 的分类方法,虽然实时性较好,识别率高且误识别率低,但训练样本规模非常大时,训练分类器所需时间过长.基于此,借鉴类 Haar 特征结合 AdaBoost 分类在人脸检测中的成功应用^[9-11],本文提出一种基于类 Haar 特征结合改进的 AdaBoost 分类器的识别算法,将其应用于车辆图像识别,实验结果表明本文方法与文献方法相比识别性能更好、误识别率更低,且训练准备时间更短.

2 算法结构

整个算法包括两个过程:训练过程和识别过程.训练过程一方面从海量类 Haar 特征中选取对分类识别起关键作用的特征,另一方面为识别过程准备用于两类分类识别的 AdaBoost 分类器,识别过程首先对测试样本提取关键类 Haar 特征,然后将特征输入到 AdaBoost 进行车辆存在性检测.算法结构图如图 1 所示,以下对训练过程和识别过程分别进行介绍.

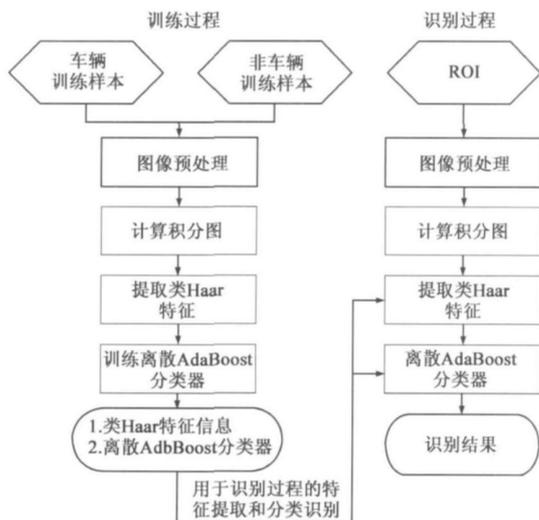


图1 算法结构图

3 训练过程

训练过程共包括图像预处理、计算积分图、提取类 Haar 特征、训练 AdaBoost 分类器 4 个子模块,用于为识别过程提供关键类 Haar 特征信息以及分类器.

3.1 图像预处理以及积分图计算

将所有训练样本图像均归一化为 32×32 的灰度图,然后根据文献^[11]介绍的方法计算每个归一化后图像的正向积分图及斜向积分图,为后续快速计算类 Haar 特征做准备.

3.2 类 Haar (Haar-like) 特征提取

类 Haar 特征是由 Viola 等人^[9,10]在其人脸检测系统中引入的一种简单矩形特征,因类似于 Haar 小波

(Haar wavelet) 而得名,其定义为图像中相邻区域内像素灰度值总和的差,这种矩形特征能反映检测对象局部特征的灰度变化,由于将积分图像的思想应用到类 Haar 小波特征的计算中,极大地提高了用于检测器的特征获取速度. Lienhart 等人^[11]在 Viola 的算法基础上提出了扩展的类 Haar 特征.该算法不仅使用了水平和竖直方向的矩形区域作为特征,而且将矩形进行旋转,得到了与水平方向成 45° 角的矩形特征,并且还提出了 45° 特征的快速计算方法,使得系统的识别性能得到显著改善的同时速度没有受到严重影响.

本文采用扩展的类 Haar 特征来描述车辆的边缘及结构特征,共分 4 大类 15 种特征,如图 2 所示,图 3 为用于描述车辆特征的类 Haar 特征示例.基于 3.1 中计算得到的积分图,计算每个样本图像的 15 种不同尺寸的类 Haar 特征,尺寸的设置参考文献^[9]中的设置方法,每个样本总共可得到 57519 个类 Haar 特征.

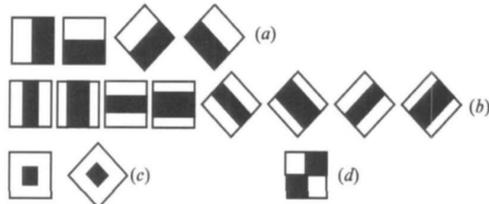


图2 类 Haar 特征 (a) 边缘特征; (b) 线特征; (c) 中心环绕特征; (d) 对角线特征

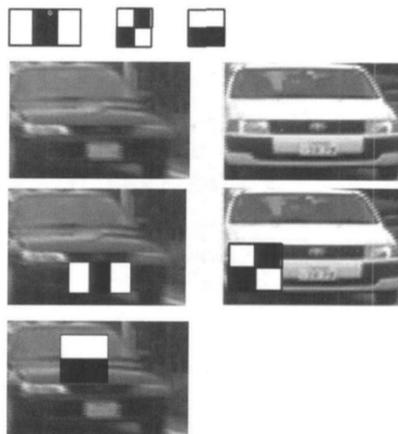


图3 类 Haar 特征示例

3.3 基于 AdaBoost 分类器的特征选择

以上得到的类 Haar 特征,其数量已远远超出 32×32 的灰度图像素点的个数,即使每个特征用于分类时都可以快速的计算,整个计算过程也非常耗时,因此,必须选取那些对分类识别起关键作用的特征,AdaBoost 算法是选取这些关键特征的有效手段.

3.3.1 AdaBoost 分类器

AdaBoost (Adaptive Boosting) 算法是由 Freund & Schapire^[12]提出的一种自适应的 Boost 算法,其主要原理是将所有待分类样本赋予相等的初始权值.在每一轮

选取弱分类器(比随机猜测略好)的训练中,选择对本带权分类错误最小的特征与阈值组合作为当前选取的弱分类器,并根据当前的弱分类器的分类效果对本带的权值进行更新:即分类错误的样本权值升高,而分类正确的样本权值降低.在反复进行多次迭代训练后,可以使分类错误趋近于零.而且,训练 AdaBoost 分类器的同时还伴随有特征的选择过程.

对于每个类 Haar 特征,都可以生成一个分类器,其形式如下:

$$f_i = \begin{cases} 1, & p_i h_i(x) < p_i \theta_i \\ -1, & \text{otherwise} \end{cases} \quad (1)$$

其中 x 代表样本, $h_i(x)$ 为第 i 个类 Haar 特征 h_i 在样本 x 上的取值, $p_i (p_i \in \{-1, +1\})$ 是分类方向符号, f_i 为由特征 h_i 构成的分类器, θ_i 为分类器 f_i 的阈值.按上述形式对每一个类 Haar 特征构造分类器集, AdaBoost 算法的目的,就是在分类器集中寻找分类错误最小的弱分类器,即寻找参数 $\{h_i, p_i, \theta_i\}$,最后将这些弱分类器组合成强分类器.传统的寻找弱分类器方法是仅仅依据每个样本的类 Haar 特征值来寻找弱分类器,即首先对每个类 Haar 特征在训练样本集 S 上得到的特征向量采用穷举的方式得到相应的分类器,然后从所有分类器中寻找分类错误最小的分类器,即弱分类器,因而导致训练过程计算量大、耗时长.基于此,文中提出一种改进的寻找弱分类器的算法,即将样本的类 Haar 特征值与其类别标签结合起来寻找弱分类器,并提出了一种新的弱分类器阈值构造方法.

3.3.2 改进的弱分类器生成方法

共分两步:(1)先求得每一个类 Haar 特征对应的分类器;(2)从(1)得到的所有分类器中寻找分类误差最小的弱分类器.下面分别进行介绍.

为便于叙述,设所有类 Haar 特征在训练样本集 S 上得到的特征值集合为矩阵 A .

$$A = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ a_{i1} & a_{i2} & \cdots & a_{in} \\ \vdots & \vdots & \vdots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{pmatrix}$$

其中 n 表示训练样本集中样本的个数, m 代表一张归一化为 32×32 的灰度图中构造的类 Haar 特征的个数, $a_{ij} (i \in \{1, 2, \dots, m\}, j \in \{1, 2, \dots, n\})$ 表示第 i 个类 Haar 特征在第 j 个样本上的值.

以第 t 次迭代时求第 i 个类 Haar 特征在训练样本集 S 上(对应矩阵 A 的第 i 行)的弱分类器为例,记对应的特征值构成的向量为 Vec , 样本 x_i 的权重为 w_i , 类

型为 $y_i, y_i \in \{-1, +1\}$, $Vec[i/j]$ 的值为样本 x_i 上的特征值,算法构造如下:

算法 改进的弱分类器生成算法

输入

(1) 训练集 S 上的类 Haar 特征值集合构成的矩阵

A .

(2) 第 t 次迭代第 i 个类 Haar 特征值向量 Vec 及对应的类别标签向量 $Label$.

(3) 第 t 次迭代的样本权值向量 W .

(4) 训练样本数量 n .

输出: 弱分类器

处理流程:

Begin

(1) For $i = 1$ To m

(a) 对特征向量排序: 将 Vec 中的元素由小到大排序得到新的向量 $VecSort$, 设排序后对应的类别标签向量变为 Lab ; (b) 候选分类位置集生成: 从左向右对所有标签出现变化的位置对, 察看其对应的特征值是否相同, 若不同, 将位置对的第一个位置放入候选分类位置集中; 若特征值相同, 首先向左查找与其不同的第一个特征值, 判断该特征值对应的位置是否已包含在候选分类位置集中, 若没有, 则加入候选分类位置集中; 再向右查找与相同特征值不同的第一个特征值, 后续操作与向左过程类似, 在此不再赘述, 记得到的候选分类位置集为 $L = \{l_1, l_2, \dots, l_k\}$; (c) 生成第 i 个类 Haar 特征的分类位置: 对第 (b) 步得到的候选分类位置集 $L = \{l_1, l_2, \dots, l_k\}$, 从中选取一个使得分类错误最小的分类位置; (d) 基于最小的分类位置设置分类阈值, 得到第 i 个类 Haar 特征的分类规则.

(2) 从 m 个分类规则中选取使得分类错误最小的分类规则即为本轮迭代得到的弱分类器.

(3) 输出弱分类器.

End

其中弱分类器生成过程如下: 对前面得到的候选分类位置集 $L = \{l_1, l_2, \dots, l_k\}$, 从中选取一个使得分类错误最小的分类位置, 方法如下: 为了描述的方便, $\forall l_s \in L$. 则 l_1, \dots, l_s 对应的样本的预测结果一样, 记其为 $\lambda (\lambda \in \{-1, +1\})$, 而 l_{s+1}, \dots, l_n 对应的样本的预测结果为 $-\lambda$ 将 AdaBoost 算法定义中的误差计算公式改写为:

$$\varepsilon = \frac{1}{4} \sum_{j=1}^n w_j (f_j - y_j)^2 \quad (2)$$

其中, j 为特征向量 $VecSort$ 中元素的下标, n 为样本个数, w_j 为第 j 个样本权值, $f_j \in \{-1, +1\}$ 为第 j 个样本的类别预测结果, $y_j \in \{-1, +1\}$ 为第 j 个样本的真实类别标签. 于是有

$$\begin{aligned}\xi &= \frac{1}{4} \left(\sum_{j=1}^n w_j (f_j - y_j)^2 \right) \\ &= \frac{1}{4} \left(\sum_{j=1}^{l_+} w_j (\lambda - y_j)^2 + \sum_{j=l_++1}^n w_j (-\lambda - y_j)^2 \right) \\ &= \frac{1}{4} \sum_{j=1}^n w_j (\lambda^2 + y_j^2) + \frac{1}{2} \lambda \left(\sum_{j=l_++1}^n w_j y_j - \sum_{j=1}^{l_+} w_j y_j \right) \quad (3)\end{aligned}$$

由于 w_j 和 y_j 已知, 因此 $\sum_{j=1}^n w_j y_j$ 已知. 由 $\sum_{j=1}^n w_j y_j = \sum_{j=1}^{l_+} w_j y_j + \sum_{j=l_++1}^n w_j y_j$ 以及 $\lambda^2 = y_j^2 = 1$, $\sum_{j=1}^n w_j = 1$, 可得

$$\begin{aligned}\xi &= \frac{1}{4} \sum_{j=1}^n w_j (\lambda^2 + y_j^2) + \frac{1}{2} \lambda \left(\sum_{j=1}^n w_j y_j - 2 \sum_{j=1}^{l_+} w_j y_j \right) \\ &= \frac{1}{2} + \frac{1}{2} \lambda \left(\sum_{j=1}^n w_j y_j - 2 \sum_{j=1}^{l_+} w_j y_j \right) \quad (4)\end{aligned}$$

下面讨论 λ 取不同类别标签的情形.

(a) 当 $\lambda = 1$ 时, 式(4)变为

$$\xi = \frac{1}{2} + \frac{1}{2} \left(\sum_{j=1}^n w_j y_j - 2 \sum_{j=1}^{l_+} w_j y_j \right) \quad (5)$$

因此, 要求 $\min(\xi)$, 即是要求 $\max(\sum_{j=1}^n w_j y_j)$. 由于 $w_j > 0$, 因此仅当 $y_{l_s} = 1$ 而 $y_{l_s+1} = -1$ 时, $\sum_{j=1}^n w_j y_j$ 才可能达到最大. 这样便可以从候选分类位置集 $L = \{l_1, l_2, \dots, l_k\}$ 中找到一些符合以上条件的位置, 设共找到 p 个这样的位置, 记为 $\tau = \{s_1, s_2, \dots, s_p\} \subseteq L$. 令

$$e_1 = \sum_{j=1}^{s_1} w_j y_j \quad (6)$$

$$e_r = e_{r-1} + \sum_{j=s_{r-1}+1}^{s_r} w_j y_j, \quad r = 2, 3, \dots, p \quad (7)$$

于是 $\max(\sum_{j=1}^n w_j y_j) = \max\{e_1, e_2, \dots, e_p\}$ (8)

(b) 当 $\lambda = -1$ 时, 式(4)变为

$$\xi = \frac{1}{2} - \frac{1}{2} \left(\sum_{j=1}^n w_j y_j - 2 \sum_{j=1}^{l_+} w_j y_j \right) \quad (9)$$

因此, 要求 $\min(\xi)$, 即是要求 $\min(\sum_{j=1}^n w_j y_j)$. 因此仅当 $y_{l_s} = -1$ 而 $y_{l_s+1} = 1$ 时, $\sum_{j=1}^n w_j y_j$ 才可能达到最小. 从候选分类位置集中找到一些符合以上条件的位置, 设共找到 q 个这样的位置, 记为 $\delta = \{t_1, t_2, \dots, t_q\}$. 类似于式(6)、(7), 可得到

$$\min(\sum_{j=1}^n w_j y_j) = \min\{e_1, e_2, \dots, e_q\} \quad (10)$$

设 $\lambda = 1, \lambda = -1$ 的最小误差分别为 $\varepsilon_1, \varepsilon_{-1}$, 则第 t 次迭代与特征 i 对应的分类方向符号 p_i 及误差 Ω_i 分别为:

$$p_i = \begin{cases} 1, & \lambda = 1 \\ -1, & \lambda = -1 \end{cases}$$

$$\Omega_i = \min(\varepsilon_1, \varepsilon_{-1}) \quad (11)$$

记以上得到的分类误差最小的位置为 $\eta \in L$, 下面计算分类阈值, 传统的计算分类阈值的方法是求平均值的方法, 即:

$$\theta_i = \frac{\text{SortVec}[\eta] + \text{SortVec}[\min(\eta + 1, n)]}{2} \quad (12)$$

然而, 这种计算阈值的方法并没有较好地反映训练样本的分布规律, 为此, 提出一种自适应的分类阈值计算方法: 设当特征值小于等于 $\text{SortVec}[\eta]$ 时, 类别输出为 $\text{Label}(\text{Label} \in \{-1, +1\})$, 则当特征值大于等于 $\text{SortVec}[\eta + 1]$ 时, 输出为 $-\text{Label}$. 于是可得特征值小于等于 $\text{SortVec}[\eta]$ 时类别为 Label 的先验概率为:

$$P_1(\text{Label} | \text{SortVec}[k] \leq \text{SortVec}[\eta]) = \sum_{y_k = \text{Label}} w_k \Big| \sum_{k \leq \eta} w_k \quad (13)$$

特征值大于等于 $\text{SortVec}[\eta + 1]$ 时类别为 $-\text{Label}$ 的先验概率为:

$$P_2(-\text{Label} | \text{SortVec}[k] \geq \text{SortVec}[\eta + 1]) = \sum_{y_k = -\text{Label}} w_k \Big| \sum_{k \geq \eta + 1} w_k \quad (14)$$

其中 w_k 为下标为 k 的训练样本的权值, y_k 为下标为 k 的训练样本的真实标签.

以上得到的两类的概率值反映了两类训练样本的分布规律, 根据样本的分布规律, 设置分类阈值如下:

$$\theta_i = \text{SortVec}[\eta] + \frac{P_1 * |\text{SortVec}[\eta] - \text{SortVec}[\eta + 1]|}{P_1 + P_2} \quad (15)$$

类似地可求得其他所有类 Haar 特征第 t 次迭代的分类方向符号、误差及阈值, 从而可得到所有类 Haar 特征第 t 次迭代的分类方向符号 p 、误差 Ω 及阈值 θ 分别为:

$$\begin{aligned}P &= \{p_1, p_2, \dots, p_j, \dots\} \\ \Omega &= \{\Omega_1, \Omega_2, \dots, \Omega_j, \dots\} \\ \theta &= \{\theta_1, \theta_2, \dots, \theta_j, \dots\}\end{aligned} \quad (16)$$

于是可得第 t 次迭代的最小分类误差、相应的分类方向、分类阈值以及相应的类 Haar 特征信息:

$$\begin{aligned}E_i &= \Omega_i = \min(\Omega) = \min\{\Omega_1, \Omega_2, \dots, \Omega_j, \dots\} \\ P_i &= p_j \mid (\Omega_i = \Omega_j) \\ \theta_i &= \theta_j \mid (\Omega_i = \Omega_j) \\ h_i &= h_j(x, y, h, w, \text{mode}) \mid (\Omega_i = \Omega_j)\end{aligned} \quad (17)$$

其中 $h_j(x, y, h, w)$ 表示所选择的第 j 个类 Haar 特征的位置信息 $\{x, y\}$ 、结构信息(高度为 h 、宽度为 w 以及种类为 mode (表示属于 15 种类 Haar 特征的哪一种)).

最后按照 AdaBoost 分类器的算法定义, 即可将各次迭代得到的弱分类器组合为一个强分类器, 用于后续识别过程的车辆存在性检测.

4 识别过程

识别过程用于对待识别的 ROI 进行车辆的存在性检测, 共包括图像预处理、计算积分图、提取类 Haar 特征以及应用 AdaBoost 分类器进行分类识别 4 个子模块。其中图像预处理和计算积分图与训练过程类似, 提取类 Haar 特征即是利用训练过程所选择的类 Haar 特征信息包括位置、结构及类型信息来计算相应的类 Haar 特征值, 构成特征向量。AdaBoost 分类器利用所得到特征向量对待识别的 ROI 进行车辆存在性检测, 输出最终的分类识别结果。

5 实验结果及分析

为了验证文中方法的有效性和可行性, 将其用于白天基于单目视觉静态图像自车后方车辆检测系统中, 该系统包括两个阶段: 感兴趣区域 (Region of Interest, ROI) 的产生和车辆存在性验证。仿真环境是 MatLab 7.1。首先应用基于阴影以及纵横比的分割算法产生 ROI^[13, 14], 然后对 ROI 进行车辆存在性验证。车辆存在性验证本质上是车和非车的两类模式识别问题。

实验数据来自于从车载 camera 拍摄的白天不同时间、各种场景的 video 片断, 其中包括高速公路、城市普通道路、城市窄道, 道路为柏油路、水泥路, 路面有涂漆、污迹等。文中共收集了 17, 647 张训练样本, 其中包括 8, 774 张车辆样本, 8, 873 张非车辆样本。6, 040 张测试样本, 其中包括 4, 266 张车辆样本, 1, 774 张非车辆样本。车辆样本包括轿车、越野车、中巴、货车以及公交车等, 从颜色来看包括白色、蓝色、黑色和灰色等, 从与自车距离来看不仅有相距较近的车, 也有中远距离的车等; 非车辆样本包括道路路面、交通标示、护栏、建筑



(a) 车辆样本



(b) 非车辆样本

图4 训练样本样例

物、路边树木、绿色植物、广告牌和桥梁等。图 4 为车辆训练样本及非车辆训练样本样例。

实验中采用以下评价指标对不同的算法在车辆检测中的效果进行评价: 真阳性率 (the true positive rate, 即车辆识别率) t_p , 假阳性率 (false positive rate, 即虚警率) f_p , 其定义如式(18)所示:

$$t_p = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad f_p = \frac{N_{FP}}{N_{FP} + N_{TN}} \quad (18)$$

其中 N_{TP} , N_{FP} , N_{TN} 和 N_{FN} 分别表示测试样本中算法正确检测的车辆数目, 将非车辆误识别为车辆的个数, 正确识别的非车辆数目和将车辆误识别为非车辆的个数。共组织了以下 3 组实验:

实验 1 为验证文中方法的有效性, 将文中方法与文献中常见机器学习方法应用于车辆识别中, 评估结果见表 1。

表 1 6 种识别方法的评估结果

识别方法	t_p	f_p	Model 大小(KB)
PCA + SVM ^[1, 2]	96.95%	6.14%	3, 233
Gabor + SVM ^[4]	96.13%	6.54%	3, 458
Wavelet + SVM ^[3]	96.34%	6.43%	11, 954
Wavelet + Gabor + SVM ^[5]	96.81%	5.64%	21, 464
类 Haar 特征 + 级联 AdaBoost ^[6, 15]	97.09%	13.19%	14
文中方法	97.43%	4.33%	244

实验 2 对文中所提出的自适应分类阈值设置方法与传统的阈值设置方法进行比较, 实验评估结果见表 2。

表 2 2 种不同阈值设置方法的评估结果

识别方法	t_p	f_p
传统阈值设置方法	97.40%	4.33%
文中方法	97.43%	4.33%

实验 3 将改进的 AdaBoost 算法与传统 AdaBoost 算法进行性能比较, 实验评估结果见表 3。

表 3 AdaBoost 算法改进前、后的评估结果

AdaBoost 算法	训练时间 (小时)
改进前	116.59
改进后	101.08

由表 1 可以看出, 与文献中的识别方法相比, 文中方法车辆识别率最高且虚警率最低, 分类器所需存储空间仅次于文献[6, 15]的基于级联 AdaBoost 分类器的方法。基于级联 AdaBoost 分类器的识别方法在人脸识别中取得了比较好的识别效果, 但由于其在训练过程中要抛弃大量其认为是非目标的样本, 因而有时也会丢失一些对识别有用的样本信息, 因而会导致虚警率比较高。由表 2 可以看出, 应用文中所提出的自适应阈值设置方法对车辆的识别效果要优于传统的阈值设置方法, 这说明文中的阈值设置方法能更好地反映训练样

本分布规律. 由表 3 可以看出, 文中所提出的改进 AdaBoost 算法训练所需时间比传统 AdaBoost 算法训练所需时间节省了 15 个多小时, 这对训练非常耗时的 AdaBoost 算法来说已经取得了不小的进步. 从算法复杂度来分析, 设训练样本数量为 N , 类 Haar 特征数为 M , 传统 AdaBoost 算法其复杂度为 $O(M * N)$, 改进 AdaBoost 算法其复杂度为 $O(1/2 * M * N)$, 可见所提出的改进算法要优于传统算法.

此外, 将文中方法应用于我们的基于视觉的路面对象检测系统中平均识别率达到了 98.20%, 虚警率为 1.44%, 处理时间平均为约 32ms/frame.

6 结论

文中提出一种基于类 Haar 特征和改进 AdaBoost 算法的识别方法. 首先基于积分图的思想计算图像的扩展类 Haar 特征; 然后应用提取的类 Haar 特征值向量集训练改进的 AdaBoost 算法, 在训练改进 AdaBoost 算法的过程中, 文中提出了两种改进措施: (1) 提出将样本特征值与其类别标签结合起来生成弱分类器的方法; (2) 提出了一种自适应的阈值设置方法. 实验结果表明, 文中所提出的方法在训练所需时间和识别性能方面取得了比传统方法更好的效果, 具有较好的应用前景.

参考文献

- [1] Matthews N D, An P E, Charnley D, Harris C J. Vehicle detection and recognition in greyscale imagery[J]. Control Engineering Practice, Printed in Great Britain, 1996, 4(4): 473-479.
- [2] Sidla O, Paletta L, Lypetsky Y, Janner C. Vehicle recognition for highway lane survey[A]. The 7th International IEEE Conference on Intelligent Transportation Systems[C]. Washington, D. C., USA, 2004: 531-536.
- [3] Schneideman H. A statistical approach to 3D object detection applied to faces and cars[A]. Proceedings IEEE Conference on Computer Vision and Pattern Recognition[C]. Hilton Head, SC, USA, 2000, 1: 746-751.
- [4] Sun Z, Bebis G, Miller R. On-road vehicle detection using Gabor filters and support vector machines[A]. IEEE 14th International Conference on Digital Signal Processing[C]. Santorini, Hellas (Greece). 2002: 1019-1022.
- [5] Sun Z, Bebis G, Miller R. Improving the performance of on-road vehicle detection by combining Gabor and wavelet features[A]. The IEEE 5th International Conference on Intelligent Transportation Systems, [C]. Singapore, 2002: 130-135.
- [6] Werr Chung Chang; Chih Wei Cho. Online boosting for vehicle detection[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics. Published by Institute of Electrical and Electronics Engineers, Inc., 2010, 40(3): 892-902.

- [7] 田广, 戚飞虎. 移动摄像机环境下基于特征变换和 SVM 的分级行人检测算法[J]. 电子学报, 2008, 36(5): 1024-1028.
Tian Guang, Qi Fei hu. Feature transformation and SVM based hierarchical pedestrian detection with a monocular moving camera[J]. Acta Electronica Sinica, 2008, 36(5): 1024-1028. (in Chinese)
- [8] 闫瑞, 曹先彬, 李凯. 面向短文本的动态组合分类算法[J]. 电子学报, 2009, 37(5): 1019-1024.
Yan Rui, Cao Xiarbin, Li Kai. Dynamic assembly classification algorithm for short text[J]. Acta Electronica Sinica, 2009, 37(5): 1019-1024. (in Chinese)
- [9] Viola P, Jones M. Rapid object detection using a boosted cascade of simple features[A]. In Proceeding of International Conference on Computer Vision and Pattern Recognition[C]. Kauai, HI, USA 2001, 1: 511-518.
- [10] Viola P, Jones M. Robust real-time face detection[J]. International Journal of Computer Vision, Published by Springer, 2004, 57(2): 137-154.
- [11] Lienhart R, Maydt J. An extended set of Haar like features for rapid object detection[A]. The IEEE International Conference on Image Processing[C]. New York, USA, 2002, 1: 900-903.
- [12] Freund Y, Schapire R E. Experiments with a New Boosting Algorithm[A]. In Proceedings of the 13th Conference on Machine Learning, Morgan Kaufmann[C]. USA, 1996, 148-156.
- [13] Wen X Z, Zhao H, Wang, et al. A rear vehicle detection system for static images based on monocular vision[A]. 9th International Conference on Control, Automation, Robotics and Vision[C]. Singapore, 2006. 2421-2424.
- [14] Liu W, Wen X Z, Duan B B, et al. Rear vehicle detection and tracking for lane change assist[A]. Proceedings of the IEEE Intelligent Vehicles Symposium[C]. Istanbul, Turkey, 2007: 252-257.
- [15] Lienhart R, Kuranov A, Pisarevsky V. Empirical analysis of detection cascades of boosted classifiers for rapid object detection[A]. Proceedings of the 25th German Pattern Recognition Symposium[C]. Magdeburg, 2003: 297-304.

作者简介



文学志 男, 1970 年 9 月出生于湖南省津市市, 博士/博士后, 副教授. 主要从事模式识别、图像处理、计算机视觉、智能交通、云计算的研究.

E-mail: ww_pub@163.com

方巍 男, 1975 年 7 月出生于安徽省黄山市, 博士/博士后, 讲师. 主要从事信息集成、Web 数据挖掘、知识工程和云计算的研究.