

doi: 10.3969/j.issn.0490-6756.2018.02.013

基于 HSV 和 MB_LBP 特征的级联 Adaboost 车牌检测算法

马永杰, 李欢, 刘姣姣

(西北师范大学物理与电子工程学院, 兰州 730070)

摘要: 车牌检测作为车牌识别系统中的重要环节, 直接影响着车牌识别的准确度。为提高车牌的检测率和检测速度, 提出了一种基于 HSV 颜色模型和多分块局部二值模式(MB_LBP)特征的级联 Adaboost 车牌检测方法。首先将车牌图像由 RGB 颜色空间转换到 HSV 颜色空间, 统计蓝色像素占车牌总像素的比例, 来构建第一层强分类器; 其次对车牌字符样本提取 MB_LBP 特征, 利用 Adaboost 分类器训练方法进行特征选择及分类器训练, 最后利用 Cascade 结构检测法形成一种新的车牌检测算法。实验表明, 本文算法有效的提高了车牌检测率和检测速度。

关键词: Adaboost 算法; 车牌检测; HSV 颜色模型; MB_LBP 特征; 级联分类器

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 0490-6756(2018)02-0290-05

Detection algorithm of cascaded adaboost license plate based on HSV color model and MB_LBP features

MA Yong-Jie, LI Huan, LIU Jiao-Jiao

(School of Physics and Electronic Engineering, Northwest Normal University, Lanzhou 730070, China)

Abstract: License plate detection is an important part of the license plate recognition system, which deeply affects the accuracy of license plate recognition. A method for cascade adaboost license plate detection based on HSV color model and multi-block local binary patterns (MB_LBP) is presented to realize fast and accurate license plate detection and recognition. Firstly, the license plate image is transformed from RGB color space to HSV color space, and the ratio of the blue pixels to the total pixels of the license plate is counted to construct the first class strong classifier. Then, the MB_LBP feature is extracted from the license plate character samples, and the feature selection and the classifier training are carried out by using the Adaboost classifier training method. Finally, a new license plate detection algorithm is formed by using the Cascade structure detection method. Experiments results show that the license plate detector improves the detection rate and the detection speed.

Keywords: Adaboost algorithm; Plate detection; HSV color model; MB_LBP features; Cascade classifier

1 引言

车牌识别技术^[1,2]是智能交通系统中的核心

部分, 已经成为图像处理和模式识别领域的研究热点。车牌识别系统主要包括车牌定位、字符分割、字符识别^[3,4]3部分, 在不停车收费系统、实时短时道

路交通流量检测^[5]、各类违章车辆抓拍、车辆出入管理及高速公路超速自动化监管系统、车辆安全防盗、停车管理等^[6]方面有着重要应用。车牌检测是车牌识别系统中的重要环节,直接影响着后续车牌识别的准确度。

用于车牌检测的算法有多种,主要可以分为以下两种:一种是基于车牌显著性特征的检测算法^[7-9],一种是基于统计学习的检测算法^[10-12]。前者计算复杂度小,得到广泛使用,但是对于复杂背景的检测率较低;后者适用于复杂背景的检测,且有较高的鲁棒性,但它需要大量的训练样本,特征提取要求高,计算量大。

传统的 Adaboost 算法选取的 Haar 特征比较单一,而且 Haar 特征的分类能力比较差,较高的检测率和较低的误检率需要大量的 Haar 特征来完成,因此训练比较耗时。为了解决 Haar 特征分类能力差和训练耗时的问题,本文提出了一种基于 HSV 颜色模型和多分块局部二值模式(MB_LBP)特征的级联 Adaboost 车牌检测方法。充分利用车牌区域的特点,首先根据蓝色像素占车牌总像素的比例,来构建第一层强分类器,实现车牌的粗定位;其次提取车牌字符的 MB_LBP 特征,通过 Adaboost 算法选取最优特征训练得到强分类器;最后利用 Cascade 结构检测法形成一种新的车牌检测算法。实验表明本文算法能有效的提高车牌检测的精度和速度。

2 HSV 颜色特征的提取

车牌区域的显著特征是具有固定的背景颜色,且颜色特征的稳定性良好,较其他区域更为饱满^[13],因此可以作为车牌检测的有效依据。本文中用于检测的车牌主要是蓝底白字的标准车牌。需要将从视频图像中采集到的车牌图像由 RGB 颜色空间转换为 HSV 颜色空间。

将 RGB 转换为 HSV 颜色空间的转换公式为:

$$V = \max(R, G, B) \quad (1)$$

$$S =$$

$$\begin{cases} [\max(R, G, B) - \min(R, G, B)] / \max(R, G, B), & \max(R, G, B) \neq 0 \\ 0, & \max(R, G, B) = 0 \end{cases} \quad (2)$$

$$H = \begin{cases} \frac{(G - B) \times \pi}{3 \times [\max(R, G, B) - \min(R, G, B)]}, & R = \max(R, G, B); \\ \frac{(B - R) \times \pi}{3 \times [\max(R, G, B) - \min(R, G, B)]}, & G = \max(R, G, B); \\ \frac{(R - G) \times \pi}{3 \times [\max(R, G, B) - \min(R, G, B)]}, & B = \max(R, G, B); \\ \text{undefined}, & G = R = B \end{cases} \quad (3)$$

经过实验可以统计出此种底色的车牌在 HSV 颜色空间中, H 参数的取值范围为 $[200^\circ, 270^\circ]$, 根据采集到的车牌样本的颜色特征, 从而可以将车牌蓝色的 H 值设定在 $[200^\circ, 270^\circ]$ 。遍历每个子区域的所有像素, 若 $H \in [200^\circ, 270^\circ]$, 则该像素即为蓝色颜色。从而统计得到该区域蓝色颜色数 N_{blue} 与颜色像素总数 S 。定义蓝色颜色数占车牌颜色像素总数的比率 λ 如下。

$$\lambda = \frac{N_{\text{blue}}}{S} \quad (4)$$

其中, λ 的阈值范围为 $[0.2, 0.72]$ 。将车牌图像统一处理成分辨率为 640×480 、子区域大小为 48×16 。统计出每张车牌图像的颜色像素总数 S 与蓝色颜色数 N_{blue} , 获得每张车牌图像蓝色颜色数的比例 λ 。

本文采用文献[14]中的方法来构建第一层强分类器。定义分类算法:若 $\lambda(x) \in [0.2, 0.72]$, 则认为图像 x 为车牌图像;若 $\lambda(x) \notin [0.2, 0.72]$, 则认为图像 x 为非车牌图像。故本文级联分类器中的第一层强分类器为 $H_1(x) = -\text{sign}[\lambda(x) - 0.2][\lambda(x) - 0.72]$ 。

3 基于 MB_LBP 特征的 Adaboost 算法

3.1 MB_LBP 特征

车牌区域的图像特征是具有固定的字符,所以采用 MB_LBP 算子来提取车牌字符特征,主要检测车牌中的数字。MB_LBP 算子采用 3×3 的子窗口进行特征计算,子窗口中的每个点对应块状区域像素的均值。通过比较中心子块灰度的平均值 g_c 与其周围子块的灰度平均值 $\{g_1, \dots, g_8\}$, 当周围子块的灰度平均值小于中心子块的灰度平均值时记为 0, 反之记为 1, 可以得到一个 8 位的二进制序

列,图 1 给出了基本的 MB_LBP 算子的示意图。定义 MB_LBP 的特征值为

$$MB_LBP = \sum_{i=1}^8 s(g_i - g_c) 2^i \quad (5)$$

$$s(x) = \begin{cases} 1, & \text{if } x \geq 0 \\ 0, & \text{if } x < 0 \end{cases} \quad (6)$$




图 1 MB_LBP 算子示意图

Fig. 1 MB_LBP operator diagram

每种 MB_LBP 特征具有 256 种模式,而 MB_LBP 的特征值只能作为一种标识,不具有度量意义。MB_LBP 特征对于一些涉及阈值的分类器不适用,故本文采用多分支树型结构^[15]的弱分类器来解决这个问题,每个弱分类器对应 MB_LBP 特征的一个特征值,共有 256 种,弱分类器的定义如下。

$$f(x_i) = \begin{cases} a_0, & x_i = 0 \\ a_j, & x_i = j \\ a_{255}, & x_i = 255 \end{cases} \quad (7)$$

式中, x_i 表示第 i 个样本的 MB_LBP 特征值,可由式(4)得到; a_j 表示相应的判决系数,如下。

$$a_j = \frac{\sum_i w_i y_i \delta(x_i = j)}{\sum_i w_i \delta(x_i = j)} \quad (8)$$

由式(8)知, $a_j \in [-1, +1]$,当 $a_j > 0$ 时,表明 MB_LBP 特征值为 j 的样本是正样本的可能性比是负样本的可能性大。

3.2 Adaboost 分类器的构造

Adaboost 算法是一种自适应的机器学习算法,其核心思想是对同一个训练集训练不同的弱分类器^[16],将弱分类器通过一定的权重叠加,组合成一个分类能力更强的分类器。

该算法具体描述如下。

步骤 1 $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ 为训练样本,其中包含了 m 个正样本, l 个负样本, $y_i \in \{+1, -1\}$, $+1$ 表示正样本, -1 表示负样本。 x_i 代表第 i 个样本。

步骤 2 初始化权重, $y_i = +1$ 时, $w_{1i} = \frac{1}{2m}$; $y_i =$

-1 时, $w_{1i} = \frac{1}{2l}$.

步骤 3 计算所有样本的特征值,并将所有样本的特征值按升序进行排列。

步骤 4 对于 $t=1, 2, \dots, T$ (其中 T 为迭代次数);

步骤 4.1 归一化权值 $w_{ti} = \frac{w_{ti}}{\sum_{j=1}^N w_{tj}}$;

步骤 4.2 提取一个最优的弱分类器 f_t ,使得权值误差平方和 $J_{use} = \sum_{i=1}^N w_i (y_i - f_m(x_i))^2$ 最小;

步骤 4.3 更新强分类器: $F(x) \rightarrow F(x) + f_t(x)$;

步骤 4.4 更新权值.

1) 设定该轮训练的权值更新阈值为

$$WT_i = \frac{1}{N} \sum_{i=1}^{i=N} w_i$$

2) 更新样本权重:

$$w_{t+1,i} = \begin{cases} w_{t,i} e^{-y_i f_t(x_i)}, & f_t(x) = y_i \\ w_{t,i} e^{-y_i f_t(x_i)}, & f_t(x) \neq y_i, \text{ 且 } w_{ti} > WT_i \\ w_{t,i}, & f_t(x) \neq y_i, \text{ 且 } w_{ti} \leq WT_i \end{cases} \quad (9)$$

步骤 5 T 轮训练完毕,得到的强分类器为 $F(x) = \text{sign}[\sum_{t=1}^T f_t(x)]$.

4 基于 HSV 和 MB_LBP 特征的级联 Adaboost 的车牌检测器

Viola 的人脸检测方法使用一种级联结构来提高人脸检测的速度,这种设计思想是逐步提高检测精度^[17]。级联分类器的每一层都是由若干个弱分类器组成的强分类器,第一层的弱分类器的个数虽少,但是能通过所有检测的车牌而拒绝大多数的非车牌。后面的每一层强分类器由更多的弱分类器组成,来检测通过上一层子窗口的车牌。随着级联层数的增加,弱分类器的数量也在不断增加,然而子窗口的检测数却大幅度减少,从而能够达到提高检测速度的目的。

设级联分类器共有 N 层, $H(x)$ 表示各层强分类器,级联分类器的结构如图 2 所示。

图 2 中的第一层强分类器 $H_1(x)$ 是利用 HSV 颜色模型构建的分类器,即 $H_1(x) = -\text{sign}[\lambda(x) - 0.2][\lambda(x) - 0.72]$,其余各层分类器是 MB_LBP

特征经过 Adaboost 算法训练得到的强分类器。第一层强分类器对待检测子窗口的图像进行分类后, 如果分类结果为 $T(\text{车牌})$, 则可能包含车牌图像的子窗口就传递到下一个强分类器, 强分类器对上一个子窗口传递下来的可能包含车牌图像的车牌进行判断, 如此循环下去直到最后一个强分类器, 这样先排除了大量不包含车牌的子窗口, 缩小了检测范围, 从而提高了检测精度和速度。




图 2 级联分类器检测过程

Fig. 2 Cascade classifier detection process

5 实验结果与分析

选取了从车牌上分割出来的 1217 张数字作为训练正样本, 从车牌背景区域中选取不含数字的 1324 张图像作为训练负样本。训练样本被归一化成 18×48 大小。

测试环境为 Intel(R) Pentium(R) 1.8 GHz CPU, 2 G 内存, 程序运行平台是 Matlab 2012a。实验中使用 8 层级联强分类器, 第一层是基于 HSV 颜色模型的分类器, 后面 7 层是用 MBLBP_Adaboost 算法训练的强分类器, 一共 150 个 MB_LBP 特征的车牌检测器。将测试图像归一化成 352×288 大小, 采用的是步进为 1 像素的滑动窗口检测。实验数据来自于用相机拍摄的白天不同时段的车牌, 共收集了 400 张车牌图像, 其中部分车牌图像的周围存在类似车牌的干扰区域和模糊的情况, 几种方法的实验结果如表 1 所示。

表 1 几种方法检测性能比较

Tab. 1 Performance comparison of several methods

检测方法	检测率(%)	检测时间(s)
基于 HSV 颜色空间的检测方法	91.5	32
普通 adaboost 检测方法	93.5	71
本文方法	97.4	35

为了比较 Haar-adaboost 算法和 MBLBP-adaboost 算法的性能, 实验过程中两种算法分别对包含 30 个特征进行分类器训练, 从图 3 中可以看出, 同样数目的特征数 MB_LBP 分类器的效果要好一些, 这是因为 MB_LBP 特征包含了更多的分类信

息, 具有更强的分类能力, 从而能够达到较低的误检率。




图 3 特征数与误检率的关系

Fig. 3 The relationship between feature number and false rate

为了说明本文 MBLBP-adaboost 算法训练时间短的优点, 通过实验将本文的算法和 Haar-adaboost 算法的训练时间进行比较, 两种算法分别对 150 个特征进行训练, 分别比较它们训练一个特征的平均时间, 结果如表 2 所示。由表 2 可知, 采用 MBLBP-adaboost 算法能有效的缩短训练时间, 这是因为 Adaboost 算法在查找最优特征时, 由于每一个强分类器训练开始时进行了特征值计算和排序, 并且 MB_LBP 特征总数较少, 所以搜索的范围要比 Haar 小, 缩短了训练时间。

表 2 MBLBP-adaboost 算法和 Haar-adaboost 算法训练时间的比较

Tab. 2 Training time comparison between MBLBP-adaboost algorithm and Haar-adaboost algorithm

算法	平均训练一个特征的时间(s)
MBLBP-adaboost	32.5
Haar-adaboost	68.8

为了说明本文算法的优越性, 将本文算法与文献[12]中的算法做比较, 实验从数据库中随机挑选了 154 张车牌, 采用文献[12]中的算法检测出了 146 个车牌, 同时误检出 2 个非车牌区域。而采用本文算法检测出了 150 个车牌, 同时误检出 2 个非车牌区域。实验结果如表 3 所示, 虽然两种算法的误检率相同, 但是从表 3 中可以看出本文算法的检测率比文献[12]中算法的检测率高出约 3 个百分点, 检测时间缩短了近一半。由此可以得出, 本文算法在车牌检测中具有较好的性能。

表 3 本文算法和文献[12]算法检测性能比较

Tab. 3 Detection performance comparison

检测方法	检测率(%)	误检率(%)	检测时间(s)
文献[12]	94.8	1.2	62
本文	97.4	1.2	35

6 结 论

车牌的有效定位是车牌识别系统的关键环节,从实验结果分析,本文提出的基于 HSV 和 MB_LBP 特征的级联 Adaboost 算法用于车牌检测,首先利用车牌颜色特征构建第一层强分类器,然后在级联 Adaboost 算法中采用 MB_LBP 特征很好地反应了车牌的字符特征,提高了定位的准确性,缩短了整个算法的时间。从实验结果可以看出本文构建的车牌检测器具有较快的检测速度、较高的检测率、较低的误检率。

本文设计的车牌检测器适用于检测常见的蓝底白字的小型汽车牌照,因此还需要通过构建全面的级联分类器,实现对各种颜色车牌的有效检测。

参考文献:

- [1] 耿庆田,赵宏伟. 基于分形维数和隐马尔科夫特征的车牌识别[J]. 光学精密工程, 2013, 21: 3198.
- [2] 贾润华,苏婷婷,马晓伟. BP 神经网络联合模板匹配的车牌识别系统[J]. 清华大学学报: 自然科学版, 2013, 53: 1221.
- [3] 裴明涛,王永杰,贾云得. 基于多尺度模板匹配和部件模型的车牌字符分割方法[J]. 北京理工大学学报, 2014, 34: 961.
- [4] 柯海峰,应晶. 基于 R-ELM 的实时车牌字符识别技术[J]. 浙江大学学报: 工学版, 2014, 48: 1209.
- [5] 代雨婷,王俊峰. 基于网络层析成像技术的道路交通流预测算法[J]. 四川大学学报: 自然科学版, 2015, 52: 985.
- [6] 张浩鹏,王宗义. 基于灰度方差和边缘密度的车牌定位算法[J]. 仪器仪表学报, 2011, 32: 1095.
- [7] 沈勇武,章专. 基于特征颜色边缘检测的车牌定位方法[J]. 仪器仪表学报, 2008, 29: 2673.
- [8] 郭延祥,陈耀武. 基于边缘检测和颜色纹理直方图的车牌定位方法[J]. 计算机科学与探索, 2014, 8: 1095.
- [9] 陈振学,常发亮,刘成云. 基于特征显著性的多特征融合车牌定位算法[J]. 控制与决策, 2010, 25: 1910.
- [10] 张晓娜,何仁,陈士安,等. 基于主动学习 Adaboost 算法与颜色特征的车牌定位[J]. 交通运输工程学报, 2013, 13: 122.
- [11] 刘彬,严京旗,施鹏飞. 高斯差分的 Adaboost 车牌定位方法[J]. 智能系统学报, 2010, 5: 471.
- [12] 潘秋萍,杨万扣,孙长银. 基于 Haar 与 MB_LBP 特征的车牌检测算法[J]. 东南大学学报: 自然科学版, 2012, 42: 74.
- [13] 王洪亚. 基于 HSV 的夜间车牌识别算法[J]. 智能计算机与应用, 2013, 3: 86.
- [14] 王毅,王创新,卢进,等. 基于 HSV 和改进的 Ada-boost 算法的车牌检测[J]. 电子科技, 2015, 28: 107.
- [15] 蔡灿辉,崔晓琳,朱建清,等. 具有自适应 MB_LBP 前置滤波的 CAMShift 人脸跟踪算法[J]. 信号处理, 2013, 29: 1540.
- [16] 董超,周刚,刘玉娇,等. 基于改进的 Adaboost 算法在网络入侵检测中的应用[J]. 四川大学学报: 自然科学版, 2015, 52: 1225.
- [17] 李文娜. 基于 Haar 特征级联强分类和肤色模型的人脸检测 [J]. 辽宁石油化工大学学报, 2010, 30: 61.