

基于改进 HOG 特征提取的车型识别算法

耿庆田^{1,2}, 赵浩宇³, 于繁华¹, 王宇婷², 赵宏伟^{2*}

(1. 长春师范大学 计算机科学与技术学院, 吉林 长春 130032;

2. 吉林大学 计算机科学与技术学院, 吉林 长春 130012;

3. 吉林大学 学报编辑部, 吉林 长春 130012)

摘要:本文针对高速环境下的车型识别问题, 提出基于方向可控滤波器的改进 HOG 算法。将方向可控滤波器算法与 HOG 算法相结合, 实现对车辆图像特征提取。采用主成分分析算法(PCA)约减特征向量维数以减少计算复杂度, 利用支持向量机算法对提取特征进行样本训练, 实现对车辆外型特征的识别。仿真实验结果表明:采用该算法原始车辆车型的识别正确率均值达到 92.36%;另外, 本文方法的识别速度比传统的 HOG 特征算法提高了 3.45%, 识别实时性得到提升。本文算法比传统 HOG 算法更优, 能有效提高车型识别的效率。

关键词:车型识别; HOG 特征; 方向可控滤波器

中图分类号: TP391.4 文献标识码: A doi:10.3788/CO.20181102.0174

Vehicle type recognition algorithm based on improved HOG feature

GENG Qing-tian^{1,2}, ZHAO Hao-yu³, YU Fan-hua¹, WANG Yu-ting², ZHAO Hong-weig^{2*}

(1. Department of Computer Science and Technology,

Changchun Normal University, Changchun 130032, China;

2. Department of Computer Science and Technology, Jilin University, Changchun 130012, China;

3. Journal Editorial Board, Jilin University, Changchun 130012, China)

* Corresponding author, E-mail: zhaohw@jlu.edu.cn

Abstract: Aiming at problems of vehicle type recognition in high-speed environment, an improved HOG algorithm based on oriented steerable filter is proposed in this paper. Vehicle image features are extracted by combining the oriented steerable filter algorithm and HOG algorithm. The principle component analysis(PCA) is used to reduce dimensions of the eigenvector for decreasing the computational complexity. The support vector machine(SVM) algorithm is used to train the extracted features to realize the recognition of vehicle's appearance features. The simulation results indicate that average vehicle type recognition accurate of proposed algorithm reaches 92.36%. At the same time, the recognition speed is 3.45% higher than the traditional HOG feature algorithm. In conclusion, the proposed algorithm can effectively improve the efficiency of vehicle type

收稿日期:2017-11-11;修订日期:2017-12-13

基金项目:吉林省省级产业创新专项资金项目(No. 2016C078);吉林省产业技术研究和开发专项项目(No. 2017C031-2);吉林省教育厅“十三五”科学技术研究项目(No. 2018269)

Supported by Jilin Provincial Industrial Innovation Special Fund Project(No. 2016C078); Jilin Provincial Industrial Technology Research and Development Special Project(No. 2017C031-2); Jilin Province Education Department; the 13th Five-year Plan Science and Technology Research Project(No. 2018269)

recognition and is therefore better than the traditional HOG algorithm.

Key words: vehicle type recognition; HOG feature; steerable filter

1 引言

车型识别是对车辆图像预处理后的部分关键区域进行特征提取和特征匹配,从而判断出该车的品牌并结合车牌及车标等识别技术,进一步协助验证该车的身份是否真实,是否存在套牌以及假车牌等违法情况,对于打击上述犯罪活动具有积极的意义。

特征提取作为车型识别重点研究方法,很多学者对此进行了深入的研究,并形成了多种理论算法。目前基于特征提取的汽车车型识别方法有:Sun Z 等提出使用支持向量机作为分类器对 Haar 小波特征与 Gabor 特征相结合后分类学习实现车辆识别^[1-2];吕恒利提出基于 Harris 角点和 SIFT 特征的车型识别方法^[3-5];华莉琴提出采用改进 SIFT 特征提取及多视角的车型识别算法^[6-9];李文勇给出了基于 Bayes 理论的感应曲线自适应特征提取的车型识别方法^[10]。这些方法由于特征提取过程复杂,计算量大,因此识别时间

较长,不利于实际应用。

本文提出基于方向可控滤波器的改进 HOG 特征提取算法,对车辆图像特征进行提取同时采用主成分分析法(PCA)约减特征向量维数,降低计算的复杂程度,利用支持向量机学习方法实现车型的识别,提高了车型图像的识别正确率与速度。仿真实验结果表明:该方法对车辆轮廓外型识别有较好实时性和较高的精确度。

2 基于方向可控的改进 HOG 算法

2.1 梯度方向直方图算法

梯度方向直方图(Histogram of Oriented Gradient, HOG)^[11]算法的思想是通过边缘方向的分布来表示图像目标的外形轮廓。具体做法是将被识别图像分成若干个大小固定的区域,通过获得该区域图像像素梯度并进行特征计算来累加梯度特征,从而获得一定维数的梯度方向直方图,如图 1 所示,具体由以下几步完成^[12]:

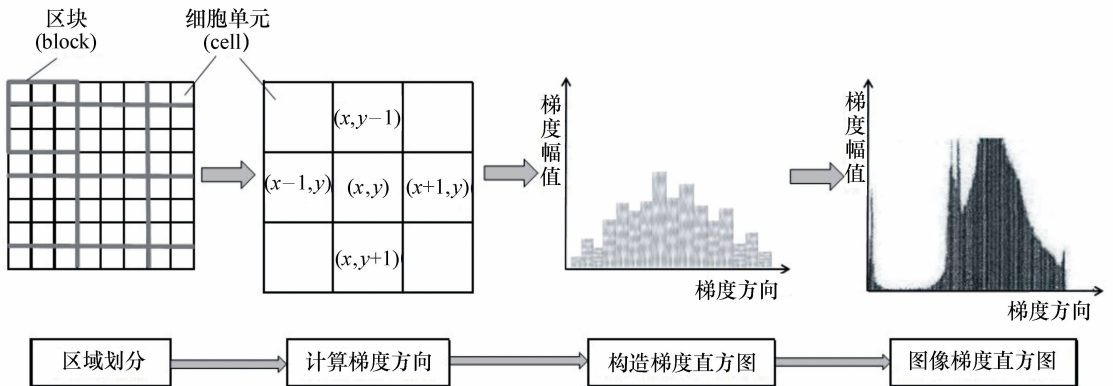


图 1 HOG 特征提取过程

Fig. 1 HOG feature extraction process

(1) 图像区域分层划分

将图像划为两层,第一层互相连通 Cell 单元组成,几个 Cell 构成一个 Block 区块,各 Block 可以重叠。

(2) 梯度值计算

通过计算像素点 (x, y) 的坐标方向的梯度来获取该点的梯度幅值和梯度方向。具体计算公式如式(1)、(2)、(3)所示:

$$\begin{cases} G_x(x, y) = H(x+1, y) - H(x-1, y) \\ G_y(x, y) = H(x, y+1) - H(x, y-1) \end{cases}, (1)$$

式中, $G_x(x, y)$ 、 $G_y(x, y)$ 、 $H(x, y)$ 分别表示像素点在二维平面垂直坐标系中 x 轴和 y 轴方向梯度及像素值。该像素点处的梯度幅值与梯度方向的计算公式为:

$$G(x, y) = \sqrt{G_x(x, y)^2 + G_y(x, y)^2}, \quad (2)$$

$$D(x, y) = \arctan\left[\frac{G_y(x, y)}{G_x(x, y)}\right], \quad (3)$$

(3) 构建梯度直方图

将 Cell 的梯度方向 180 度等分成 n 个被称为 Bin 的方向块, 累加每一个 Cell 的 n 维梯度幅度。

(4) 块内归一化

将多个 Cell 单元组合为 Block 块, 进行对比度归一。

(5) 收集 HOG 特征

收集检测窗口中所有重叠的 Block 块的 HOG 特征。

2.2 方向可控滤波器算法

由上述 HOG 特征提取过程可以看出, 其算法只能计算出像素点不够全面的单一梯度方向信息, 具有一定的缺陷, 不能完全描述车型图像的方向特征。因此, 本文采用能够获取多方向信息的方向可控滤波器算法来弥补 HOG 算法的不足, 使

$$\begin{cases} G_1^0(x, y) = 0.9213(2x^2 - 1)\exp[-(x^2 + y^2)] \\ G_1^{\pi/3}(x, y) = 1.843xy\exp[-(x^2 + y^2)] \\ G_1^{2\pi/3}(x, y) = 0.9213(2y^2 - 1)\exp[-(x^2 + y^2)] \end{cases}, \quad (7)$$

相应系数如式(8):

$$\begin{cases} k_1(\alpha) = \cos^2\alpha \\ k_2(\alpha) = -2\cos\alpha\sin\alpha \\ k_3(\alpha) = \sin^2\alpha \end{cases}, \quad (8)$$

式中, $G_1^0(x, y)$ 、 $G_1^{\pi/3}(x, y)$ 、 $G_1^{2\pi/3}(x, y)$ 分别表示图像像素点在相应方向上的二阶导数, 即表示相应方向的基滤波器, 将三者线性组合即可计算出任意方向的幅值信息。线性组合后的计算公式如式(9)所示,

$$G^\alpha = k_1(\alpha)G_1^0(x, y) + k_2(\alpha)G_1^{\pi/3}(x, y) + k_3(\alpha)G_1^{2\pi/3}(x, y), \quad (9)$$

式中, α 表示方向可控滤波器的方向输入角度。

2.3 改进的 HOG 特征提取方法

在对车型的识别过程中, 最重要的是能有效提取目标图像中车辆轮廓的边界特征。由于传

像素的单一方向信息扩展为 N 多个方向信息。

为了计算出像素点多个方向信息及方向幅值, Bill Freeman 在 1991 年提出方向可控滤波器 (Steerable Filter)^[13]。该算法无论是边缘检测的效果, 还是实现的难易程度都是较好的。其主要思想是通过在不同方向上产生模板去卷积图像, 从而得到图像的边缘。卷积过程通过加权运算, 对于有效像素增加权重, 对于无效像素减少权重。一般定义分布在离散域的函数 f 与 g 二者的卷积如式(4):

$$(f * g)[m] = \sum_n f[n]g[m - n]. \quad (4)$$

方向可控滤波器的一般形式如式(5):

$$G^\alpha = \sum_{i=1}^n k_i(\alpha)G_i, \quad (5)$$

式中, n 表示基滤波器的数量; G_i 表示第 i 个基滤波器; $k_i(\alpha)$ 表示与方向度数 α 相关的滤波器的系数; G^α 表示 α 方向的滤波器。

本文获取多方向滤波器的方法是通过对一组基滤波器的线性组合来实现, 对二维高斯函数求导来完成, 计算公式如式(6):

$$G(x, y) = k(\alpha)\exp[-(x^2 + y^2)]. \quad (6)$$

具体计算过程如式(7):

统的 HOG 方法获得的梯度方向信息对于提取边界特征相对较弱, 本文将方向可控滤波器算法与传统 HOG 算法相结合, 提出基于方向可控滤波器改进 HOG 特征的 HOS (Histograms of Oriented Steerable Filter) 算法。该算法先用方向可控滤波器算法计算出方向值最高的方向数量及幅值信息, 再使用 HOG 算法获得统计方向直方图特征。算法流程如图 2 所示, 具体计算如下:

(1) 设 $P(x, y)$ 为灰度图像的像素点, 构造 P 像素点相互垂直的两个方向的方向可控滤波器 (滤波器的方向分别取值为 α 与 β , 且 $\alpha + \beta = \pi/2$), 分别记做 F^α 与 F^β 。则 P 点在 α 与 β 方向的梯度值 $G_\alpha(x, y)$ 与 $G_\beta(x, y)$:

$$\begin{cases} G_\alpha(x, y) = F^\alpha * I \\ G_\beta(x, y) = F^\beta * I \end{cases}, \quad (10)$$

其中, I 表示灰度图像。

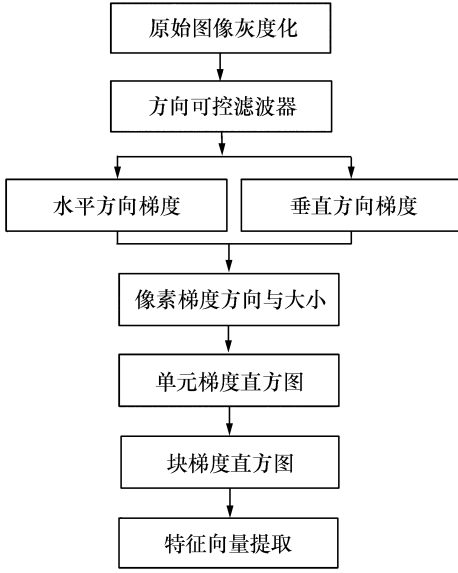


图2 方向可控改进的 HOG 方法流程图

Fig.2 Flow chart of improved HOG method with direction controlled

(2) 计算出 p 像素点的边界方向 $G(x, y)$ 和幅值 $\theta(x, y)$:

$$G(x, y) = \sqrt{G_{\alpha}(x, y)^2 + G_{\beta}(x, y)^2} \approx |G_{\alpha}(x, y)| + |G_{\beta}(x, y)|, \quad (11)$$

$$\theta(x, y) = \arctan\left[\frac{G_{\beta}(x, y)}{G_{\alpha}(x, y)}\right]. \quad (12)$$

(3) 同样将目标图像分为 Cell 单元并将毗邻的 Cell 组成有重叠边缘信息的 Block 块, 再按边缘信息的梯度方向划分区间 Bin, 并将 Cell 像素点的梯度幅值叠加到 Bin 中, 得到 Cell 的梯度方向直方图, 最后对统计出 Block 的直方图特征作归一化处理, 即对于向量 ν 做如下处理:

$$\nu \leftarrow \frac{\nu}{\sqrt{\|\nu\|^2 + \varepsilon^2}}. \quad (13)$$

(4) 最后将全部 Block 的 HOG 特征聚合为目标图像的 HOG 特征向量, 向量的维度用 D 来表示, 计算公式如式(14)所示,

$$D = \left(\frac{l_{\text{width}} - s_{\text{block}}}{l_{\text{step}}} + 1\right) \times \left(\frac{l_{\text{height}} - s_{\text{block}}}{l_{\text{step}}} + 1\right) \times \left(\frac{s_{\text{block}}}{s_{\text{cell}}}\right)^2 \times p, \quad (14)$$

式中, l_{width} 、 l_{height} 分别表示目标图像的宽度与高度; s_{block} 、 s_{cell} 分别表示 Block 块和 Cell 单元的大小;

l_{step} 表示 Block 移动的步长; p 表示 Cell 梯度方向的数量。

3 特征向量降维与 SVM 模型训练

3.1 PCA 算法降维处理

在图像识别过程中, 如果采用原始特征空间的高维度进行模型训练会使计算复杂度大大增加, 致使样本的统计特性无法估计。因此需要降低原始特征的维数。本文采用主成分分析 PCA (Principal Component Analysis) 法^[14-15] 实现特征抽取, 以达到“约减维数”的目的, 从而提高图像识别速度。

理想情况下, 样本 x 的特征空间没有冗余信息, 利用 PCA 算法可表示为(15)、(16)式:

$$y = M^T x, \quad (15)$$

则,

$$x = My = \sum_{i=1}^K y_i m_i, \quad (16)$$

其中, $M = (m_1, m_2, \dots, m_K)$ 是 R^K 特征空间的一组基底, 对前 k 项的 x 进行估算, 可得式(17):

$$\hat{x} = My = \sum_{i=1}^K y_i m_i, \quad (17)$$

由此产生的均方误差为:

$$\varphi = E[(x - \hat{x})^T (x - \hat{x})] =$$

$$\sum_{i=k+1}^K m_i^T E(x \hat{x}) m_i = \sum_{i=k+1}^K m_i^T S m_i. \quad (18)$$

根据拉格朗日乘子, 在满足式(19)的条件下可得到均方误差极大值表达式(20):

$$(S - a_i I) m_i = 0, \quad i = k+1, k+2, \dots, K, \quad (19)$$

$$G = \sum_{i=k+1}^K m_i^T S m_i - \sum_{i=k+1}^K a_i (m_i^T m_i - 1), \quad (20)$$

式中, $y_i = m_i^T x$, $i = 1, 2, \dots, K$, S 是 x 的协方差矩阵, m_i 是特征向量。

若用 k 个特征向量表示 x 时, 其均方误差为式(21):

$$\varphi = \sum_{i=k+1}^K a_i. \quad (21)$$

从式(21)可以得出, 当 a_i 的值越小, 对应的

特征向量信息减损越少。

本文通过改进 HOG 特征提取方法同时采用主成分分析 PCA 法约减维数降低特征向量的维度减少了计算的复杂度,提高识别速度。

3.2 构建 SVM 行为模型

支持向量机 (Support Vector Machine, SVM)^[16-18]通过在样本空间计算出一个最优的平面把不同的样本区分开。如图 5 所示, H 为分类面, H_1 、 H_2 都平行于 H , H_1 、 H_2 是通过各类样本且距 H 最近点的超平面。若 H 满足分类间隔最大, 则 H 为最优分类面。就意味着间隔越远, 也就说明该分类器的推广能力越强。

设训练样本集为 S , 则

$$S = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\},$$

$$y_i \in \{-1, 1\}. \quad (22)$$

最优分割平面方程定义为:

$$\mathbf{w}^T \mathbf{x} + \mathbf{b} = 0. \quad (23)$$

由 SVM 定义, 若样本线性可分, 则须满足下式条件:

$$y_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) \geq 1, \quad (24)$$

分隔间隔表示为式(25):

$$\delta_{\text{jiange}} = y_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}), \quad (25)$$

式中, y_i 表示所属类别, 取值范围为 $[-1, 1]$, \mathbf{x}_i 是针对样本的特征向量。

分类器用于分类的函数简写为式(26):

$$f(x) = \mathbf{w} \cdot \mathbf{x} + \mathbf{b}. \quad (26)$$

设阈值为 0, 由于样本所在类已确定, 则有 $y_i(\mathbf{w} \cdot \mathbf{x}_i + \mathbf{b}) > 0$ 始终成立, 用 $|f(x_i)|$ 来表示。说明几何间隔可用分类间隔表示, 如式(27):

$$\delta_{\text{jijehang}} = |f(x)| / \|\mathbf{w}\|. \quad (27)$$

在对分类间隔进行调整后, 得到最优分类面, 如图 3 所示。图 3 中, H_1 、 H_2 两个分类面之间距离即是公式(27)中所定义的几何间隔。

当样本发生错误分类时, 错误分类的次数 T 为式(28):

$$T \leq \left(\frac{2R}{\delta}\right)^2, \quad (28)$$

其中, $R = \|\mathbf{x}_i\|$, $i = 1, 2, \dots, n$, \mathbf{x}_i 表示第 i 个样本的特征向量。

特征向量的最大值 R 即为 $\|\mathbf{x}_i\|$ 中的最大值。为减少错误分类的次数, 就要求有较大的几




图 3 最优分类面示意图

Fig. 3 Schematic diagram of optimal classification

何间隔, 故而, 将任务调整为:

$$\begin{cases} \min f(\mathbf{w}, \mathbf{b}) = \frac{1}{2} \|\mathbf{w}\|^2 \\ \text{s. t. } y_i(\mathbf{w}^T \mathbf{x} + \mathbf{b}) - 1 \geq 0 \end{cases}. \quad (29)$$

由此, 转化为一个最优二次规划问题。此类问题的求解可通过拉格朗日方法解决。构造拉格朗日函数式(30):

$$L(\mathbf{w}, \mathbf{b}, \mathbf{a}) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n a_i [y_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) - 1], \quad (30)$$

式中, a_i 表示的是拉格朗日因子。分别对 w, b 求解偏导数:

$$\frac{\partial L}{\partial \mathbf{w}} = 0 \Rightarrow \mathbf{w} = \sum_{i=1}^n a_i y_i \mathbf{x}_i. \quad (31)$$

$$\frac{\partial L}{\partial \mathbf{b}} = 0 \Rightarrow \sum_{i=1}^n a_i y_i = 0$$

将式(31)的结果代回式(30), 可得:

$$L(\mathbf{w}, \mathbf{b}, \mathbf{a}) = \frac{1}{2} \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j=1}^n a_i a_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j. \quad (32)$$

对式(32)进行最值求解, 结果就是所需要的目标函数。

3.3 用 SVM 训练车型图像样本集

本文使用 SVM 对分类样本的学习训练, 从而达到完成分类的工作。进行样本训练时采用 LibSVM 库, 由于 LibSVM 使用一对一策略, 即两类样本之间构建一个 SVM, m 种样本需构建 $m(m-1)/2$ 个 SVM。在对车型的样本图像进行训练时, 首先将用 HOS 方法提取的特征向量通过 PCA 降维后存入一个文本文件中, 每一张图片存

储成一个特征向量。将特征向量转化为标准的 SVM 样本格式进行训练,程序的主要参数如表 1 所示。

表 1 样本训练程序参数

Tab.1 Sample training program parameters

参数符号	代表属性
Num	车型图像样本数量
Type	车型图像样本类别
* x	样本遍历指针

为了提高 SVM 训练样本的收敛速度,本文通过增设缓冲区的方法,将样本分成多个样本子集,一部分子集先预存于缓冲区中,每次都训练缓冲区的样本,能被确定属性的样本离开缓冲区。当

所有样本子集都经过训练后,算法结束。

4 实验结果及分析

4.1 数据集

为了验证本文算法对车型识别的性能,在实验中所采用的车辆图像由本实验室所建的车辆图像数据集,收集了 4 000 余张各种车辆图像,图 4 是数据集中的拍摄时间、角度、距离不同类型的车辆图片,包含常见的 SUV 车型、轿车、面包车等车型,用于车辆识别检测实验。在训练阶段选取若干张车辆图片作为正样本,选取不同张不同交通环境背景的图片作为负样本,通过 SVM 分类器进行训练,获得正、负样本模型。



图 4 数据集样例图片

Fig.4 Sample pictures of data set

4.2 同类型车型的识别结果及分析

用 SVM 分类器测试算法时可能出现正样本检测为正样本、正样本检测为负样本、负样本检测为负样本、负样本检测为正样本四种情况。因此对车型检测识别的准确率定义为:

$$\text{准确率} = \frac{\text{正确检测识别的样本数量}}{\text{总测试样本数量}} \times 100\%$$

为客观检验本文提出的方法在车型识别中的有效性,本文在自建的车辆图像数据集进行 5 次独立的实验,每次随机选取 2 058 幅图像进行特征提取,并使用 SVM 进行学习分类训练作为正样本,选取 1 255 幅图像进行特征提取作为负样本。每次随机选取 1 000 幅图片进行识别测试,由于不同次仿真实验挑选不同的训练样本和测试样




图 5 每类车辆图片平均识别准确率

Fig.5 Average image recognition accuracy for each type of vehicle

本,同一类车辆图像在不同次实验中误识数量也会发生变化。每类图片识别正确率如图 5 所示。

图 5 说明了各类车辆图像识别的平均准确率,第 4 类的平均准确率最高,达到 97%,这主要受此类车辆外形轮廓影响。

表 2 车型识别实验结果

Tab. 2 Experimental results of model identification

(%)

识别算法/实验次数	1	2	3	4	5
HOG 算法	83.7	85.2	85.4	85.5	84.6
本文算法	93.2	92.6	92.7	91.5	91.8

在车辆图像分辨率大下不同的情况下,传统 HOG 特征和改进的 HOG 特征的提取时间对比如图所示。检测窗口的大小为 128×64 ,滑动距离 16×16 ,各种分辨率条件下的车型识别时间同样以 1 000 幅随机车辆图片为准。

从识别速度对比图(图 6)来看,在车辆图片不同的分辨率条件下,本文提出的识别方法所用

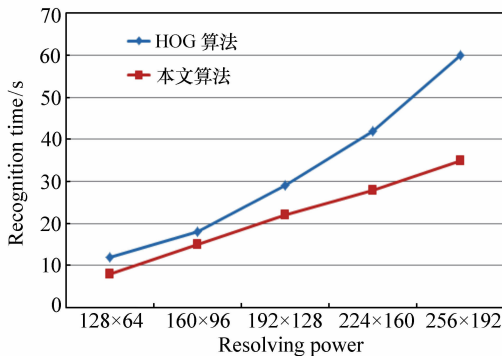


图 6 两种算法不同分辨率的识别时间对比

Fig. 6 Recognition time contrast of two algorithms with different resolutions

4.3 不同类型车型识别实验效率对比及分析

在车辆图像数据集中,训练正样本数量 2 236,负样本数量 1 225,使用 LibSVM 在不同算法下,进行 5 次实验,每次随机选取 1 000 幅图片进行识别测试,实验对比结果如表 2 所示。

的时间较短,图片分辨率的值越高,识别速度的差距就越大。

仿真实验结果表明,在同类型及不同类型的车辆外形识别中,本文方法有较高的识别率,平均识别率达到 92.36%,高于传统 HOG 算法的识别率 84.88%。同时识别效率也高于传统 HOG 算法,提高了 3.45%。

5 结 论

本文将传统的 HOG 算法与方向可控滤波器相结合,提出了 HOS 算法对车辆图像进行特征提取,同时采用主成分分析法(PCA)约减特征向量维数,降低计算特征向量的复杂程度,并使用 SVM 学习方法作为样本分类器进行分类识别车型。仿真实验结果表明,本文所提出的基于改进的 HOG-SVM 车辆识别算法和传统 HOG 算法相比,具有较高识别率和识别速度,并且对不同环境背景、不同角度、不同距离有较强的抗干扰性,能够满足智能交通系统中车辆识别监管的需要。

参考文献:

- [1] PSYLLOS A, ANAGNOSTOPOULOS C N, KAYAFAS E. Vehicle model recognition from frontal view image measurements [J]. *Computer Standards & Interfaces*, 2011, 33(2): 142-151.
- [2] WANG Y, LI H, KIRUI C K, et al. Vehicle discrimination using a combined multiple features based on vehicle face [J]. *Lecture Notes in Electrical Engineering*, 2013, 256: 503-511.
- [3] LLORCA D F, COLÁS D, DAZA I G, et al. Vehicle model recognition using geometry and appearance of car emblems from rear view images [C]. IEEE, International Conference on Intelligent Transportation Systems. IEEE, 2014: 3094-3099.
- [4] ABADI E A J, AMIRI S A, GOHARIMANESH M, et al. Vehicle model recognition based on using image processing and wavelet analysis [J]. *International Journal on Smart Sensing & Intelligent Systems*, 2015, 9(2): 3-8.

- [5] SONG M. Vehicle model recognition based on SURF[J]. *Journal of Information & Computational Science*,2015,12(17):6249-6256.
- [6] ZHANG X D,QIAN W,GAO J,*et al.* Vehicle model recognition system based on sparse bayesian classification[J]. *Mini-micro Systems*,2005:232-238.
- [7] WANG Y Q,HUANG R J,XU T Y,*et al.* Vehicle model recognition based on fuzzy pattern recognition method[J]. *Advanced Materials Research*,2012,383-390:4799-4802.
- [8] ZHANG Z,TAN T,HUANG K,*et al.* Three-dimensional deformable-model-based localization and recognition of road vehicles[J]. *IEEE Transactions on Image Processing*,2012,21(1):1-13.
- [9] HSIEH J W,CHEN L C,CHEN D Y. Symmetrical SURF and its applications to vehicle detection and vehicle make and model recognition[J]. *IEEE Transactions on Intelligent Transportation Systems*,2014,15(1):6-20.
- [10] CHEN Z,PEARS N,FREEMAN M,*et al.* A Gaussian mixture model and support vector machine approach to vehicle type and colour classification[J]. *Iet Intelligent Transport Systems*,2014,8(2):135-144.
- [11] 叶峰,陈灿杰,赖乙宗,等. 基于有序 Hough 变换的快速圆检测算法[J]. 光学精密工程,2014,22(4):1105-1111.
YE F,CHEN C J,LAI Y,*et al.* Fast circle detection algorithm using sequenced Hough transform[J]. *Opt. Precision Eng.*,2014,22(4):1105-1111. (in Chinese)
- [12] 宋悦,林志贤,姚剑敏. 基于 ϵ -支持向量回归机的背光源亮度均匀性评价方法[J]. 液晶与显示,2015,30(5):857-863.
SONG Y,LIN ZH X,YAO J M. Luminance uniformity evaluation for backlight based on ϵ -support vector regression[J]. *Chinese Journal of Liquid Crystals and Displays*,2015,30(5):857-863. (in Chinese)
- [13] 李姜,郭立红. 基于改进支持向量机的目标威胁估计[J]. 光学精密工程,2014,22(5):1354-1362.
LI J,GUO L H. Target threat assessment using improved SVM[J]. *Opt. Precision Eng.*,2014,22(5):1354-1362. (in Chinese)
- [14] 王洪涛,李丹. 基于改进粒子群算法的图像边缘检测研究[J]. 液晶与显示,2014,29(5):800-804.
WANG H T,LI D. Image edge detection based improved PSO algorithm[J]. *Chinese Journal of Liquid Crystals and Displays*,2014,29(5):800-804. (in Chinese)
- [15] 黄璇,郭立红,李姜,等. 磷虾群算法优化支持向量机的威胁估计[J]. 光学精密工程,2016,24(6):1448-1454.
HUANG X,GUO L H,LI J,*et al.* Threat assessment of SVM optimized by Krill Herd algorithm[J]. *Opt. Precision Eng.*,2016,24(6):1448-1454. (in Chinese)
- [16] 贾苏娟,韩广良,陈小林,等. 光度非均匀彩色序列图像超分辨率重建[J]. 液晶与显示,2014,29(1):106-113.
JIA S J,HAN G L,CHEN X L,*et al.* Super-resolution reconstruction with photometric change of color image sequence [J]. *Chinese Journal of Liquid Crystals and Displays*,2014,29(1):106-113. (in Chinese)
- [17] 徐超,高敏,杨锁昌,等. 视觉注意机制下的粒子窗快速目标检测[J]. 光学精密工程,2015,23(11):3227-3237.
XU CH,GAO M,YANG S CH,*et al.* Visual attention mechanism-aided fast target detection by particle window[J]. *Opt. Precision Eng.*,2015,23(11):3227-3237. (in Chinese)
- [18] 柯洪昌,孙宏彬. 图像序列的显著性目标区域检测方法[J]. 中国光学,2015,8(5):768-774.
KE H CH,SUN H B. A saliency target area detection method of image sequence[J]. *Chinese Optics*,2015,8(5):768-774. (in Chinese)

作者简介:



耿庆田(1972—),男,江苏邳州人,副教授,2005年于吉林大学获得硕士学位,现为吉林大学计算机科学与技术学院博士研究生,主要从事计算机网络与智能信息系统方面的研究。E-mail:qtgeng@163.com



赵宏伟(1962—)男,辽宁沈阳人,教授,博士生导师,主要从事智能信息系统与嵌入式技术方面的研究。E-mail:zhaohw@jlu.edu.cn