

引文格式:

卜庆志, 裘君, 胡超. 基于 HOG 特征提取与 SVM 驾驶员注意力分散行为检测方法研究 [J]. 集成技术, 2019, 8(4): 69-75.

Bu QZ, Qiu J, Hu C. Research on driver's distracted behavior detection method based on histogram of oriented gradient feature extraction and support vector machine [J]. Journal of Integration Technology, 2019, 8(4): 69-75.

基于 HOG 特征提取与 SVM 驾驶员 注意力分散行为检测方法研究

卜庆志^{1,2} 裘君² 胡超²

¹(江西理工大学 赣州 341000)

²(浙江大学宁波理工学院 宁波 315100)

摘 要 驾驶员注意力分散是导致交通事故的主要原因。该文以驾驶员注意力分散行为图像为分类目标, 提出了一种基于方向梯度直方图(Histogram of Oriented Gradient, HOG)与支持向量机(Support Vector Machine, SVM)的行为检测方法。首先, 获取图像中的感兴趣区域, 并对图像进行增强、去噪及归一化处理; 然后, 提取图像 HOG 特征, 进而采用交叉验证法对 SVM 分类器中的参数进行优化; 最后, 对视频图像中驾驶员的不同行为进行分类识别。实验中, 通过与传统 SVM 算法以及基于局部二值模式的 SVM 算法进行对比, 验证了所提方法具有更好的识别准确率。

关键词 驾驶员注意力分散; 方向梯度直方图; 交叉验证; 支持向量机

中图分类号 TP 391.41 **文献标志码** A **doi**: 10.12146/j.issn.2095-3135.20190527001

Research on Driver's Distracted Behavior Detection Method Based on Histogram of Oriented Gradient Feature Extraction and Support Vector Machine

BU Qingzhi^{1,2} QIU Jun² HU Chao²

¹(Jiangxi University of Science and Technology, Ganzhou 341000, China)

²(Ningbo Institute of Technology, Zhejiang University, Ningbo 315100, China)

Abstract To reduce the occurrence of traffic accidents caused by driver distraction, a behavior detection method based on histogram of oriented gradient (HOG) and support vector machine (SVM) was proposed in this

收稿日期: 2019-05-27 修回日期: 2019-06-18

基金项目: 宁波市科技计划项目(创新团队 2014B82015); 浙江省教育厅一般项目(Y201738805)

作者简介: 卜庆志, 硕士研究生, 研究方向为机器视觉; 裘君(通讯作者), 博士, 副教授, 硕士研究生导师, 研究方向为机器视觉、运动控制、嵌入式系统、机器人路径规划等, E-mail: qiujuunb@zju.edu.cn; 胡超, 博士, 教授, 博士研究生导师, 研究方向为机器视觉、机器人控制、医疗电子等。

paper. In the algorithm, interesting region of driver was detected first from the video images. Then the image was enhanced, smoothed and normalized. The histogram of oriented gradient was used to extract the feature of the target image. The cross-validation method was used to optimize the SVM parameters, and then used for the classification of driver behaviors. In the experiments, the proposed method was compared with classical SVM and the local binary patterns feature based SVM algorithms. The results show that, the proposed method can obtain better classification accuracy.

Keywords driver distraction; histogram of oriented gradient; cross validation; support vector machine

1 引 言

我国公安部最新统计显示：2018 年全国新注册登记机动车 3 172 万辆，机动车保有量已达 3.27 亿辆，其中汽车 2.4 亿辆，而汽车驾驶员 3.69 亿人^[1]。疲劳驾驶、分心驾驶、酒后驾驶和超速等危险行为引发的交通事故已成为“世界第一害”^[2]。据美国宾夕法尼亚州的保险公司统计，25% 的机动车交通事故是由于注意力分散驾驶导致^[3]，其中因分心或注意力不集中死亡人数占总死亡人数的 62%，其次因驾驶过程中使用手机导致死亡人数占总死亡人数的 12%。因此，迫切需要对驾驶员的注意力分散行为进行检测并进行有效的提醒。

驾驶员注意力分散行为一直是人们备受关注的问题，同时也吸引了越来越多的国内外研究机构和学者的关注与研究。王尽如^[4]针对在驾驶过程中打电话行为的检测，提出了一种半监督聚类算法——基于密度的有噪声聚类算法，得到了较好的识别率。Liang 等^[5]计算出眼球所及视线的距离和方向盘角度、车道位置、方向盘的转向误差，结合这些参数，运用支持向量机 (Support Vector Machine, SVM) 对驾驶员分心驾驶与集中驾驶进行分类识别。Liu 等^[6]提出一种拉普拉斯支持向量机算法在半监督模式下对驾驶员的眼睛与头部进行检测，来评估驾驶员的驾驶行为。程文东等^[7]提出了驾驶员注意力分散的图像检测，将头部的横摆角、俯仰角、鼻孔中心的偏移量作

为特征向量，建立支持向量机分类模型。Omid 和 Mojtaba^[8]设计了一种可穿戴数据采集系统，通过收集驾驶员在自然状态下打电话、发短信时皮肤电流反应信号，并使用卷积神经网络 (CNN) 在 2D 频谱与梅尔 (MEL) 倒谱空间进行学习与时识别。Wathiq 和 Ambudkar^[9]采用前馈神经网络检测眼睛位置、头部位置、嘴巴位置来确认驾驶员是否有分心。Baheti 等^[10]采用深度卷积神经网络对驾驶员分散行为进行检测，并对 VGG-16 模型进行改进，取得了较好的效果。虽然采用深度学习算法对驾驶员的分散注意力进行检测具有很好的效果，但都是在图片数量较大的情况进行。而对于小样本图像集识别时，在保证识别率的前提下，传统的机器学习算法在训练与识别速度方面有着一定的优势。

本文采用方向梯度直方图 (Histogram of Oriented Gradient, HOG) 对驾驶员注意力分散行为特征进行提取，并使用交叉验证方法对支持向量机参数寻优，构造出多类分类器进行分类识别。另外，分别与支持向量机算法和局部二值模式 (LBP) + 支持向量机算法进行对比实验，验证了本文算法的有效性。

2 驾驶员分散行为识别过程

驾驶员注意力分散行为图片集由美国 State Farm 保险公司采集，提供的照片像素大小为 640×480。其中包含很多场景，首先需要对图片

集进行预处理, 然后使用 HOG 算法提取特征, 将得到的特征向量输入到 SVM 中进行训练, 再使用优化后训练模型对测试集进行分类, 最终得到测试结果。系统总体结构如图 1 所示。

2.1 图像预处理

首先需要提取感兴趣的场景, 并对图像进行灰度化处理、图像增强及滤波, 目的是削弱噪声、光线、拍摄角度等外界因素的影响, 增强有效信息。同时, 也需要对图片集进行归一化处理, 减少一些几何变化的影响, 加快提取速度。归一化后的图片如图 2 所示, 从左到右分别为正常驾驶、发短信、打电话和喝饮料。

2.2 特征提取

HOG 算法首次被提出是在 2005 年的 CVPR 大会上, Dalal 和 Triggs^[11]使用该算法对行人特征进行提取, 取得了很好的效果。其核心思想是: 计算图像中某块区域的梯度大小和方向, 累加得到该块区域的方向梯度直方图, 之后将图像中的每一块区域叠加起来, 生成整幅图像的方向梯度直方图, 这样就可以表示出整张图像的特征。HOG 提取过程如图 3 所示。

(1) Gamma 标准化

为了减少在窗口滑动时的光照影响, 先进行图像灰度化处理, 再进行 Gamma 空间上的处

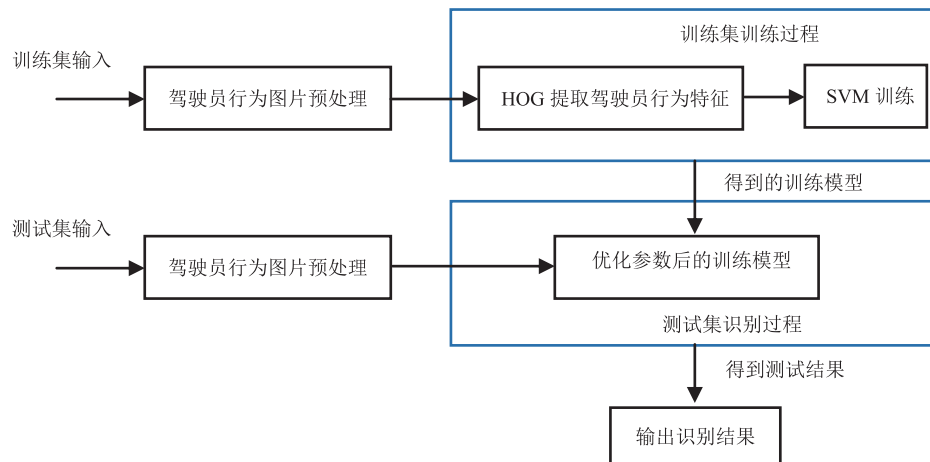


图 1 系统总体框架结构图

Fig. 1 General frame structure diagram of the system



图 2 归一化后图片

Fig. 2 Normalized images




图 3 HOG 特征提取过程

Fig. 3 HOG feature extraction process

理,降低对光照的敏感度,提高算法对光照的鲁棒性。

(2) 图像梯度计算

图像梯度的计算可获得轮廓等一些纹理信息,同时也可削弱光照的干扰。

(3) 细胞单元构建方向直方图

将图像均分为多个大小相同的细胞单元(cell),将梯度方向划分为9个方向(bin),每个方向的区间为 $[0^\circ, 20^\circ]$ 。其中,像素点的梯度大小表示该点的权值。当某个像素点的梯度方向在9个方向中的一个方向时,则该方向的区间直方图计数上就会加上该点的权值。

(4) 块区域(block)归一化

相邻的4个细胞单元组成一块连通区域,一块块区域中包含了梯度信息。因图像部分区域曝光度的差异性,会使得对比度不同,导致块区域中梯度变化范围很大。这时候需要对块区域进行归一化处理,压缩其中的光照、阴影信息。块区域与细胞单元之间的关系如图4所示。



图4 块区域与细胞单元的关系图

Fig. 4 Diagram of block and cell

(5) 生成 HOG 特征描述器

首先,将所有块区域中的梯度直方图连接起来,形成 HOG 特征描述符。归一化后的图片大小为 128×128 像素点,即滑动窗口大小。每个细胞单元的像素大小为 16×16 ,有 2×2 个细胞单元组成一个块区域。滑动步长的像素大小为 8×8 ,即块的总数为 $[(128-16) \div 8 +$

$1] \times [(128-16) \div 8 + 1] = 225$ 个。每个细胞单元有9个方向,那么图像总共有 $225 \times 4 \times 9 = 8100$ 个特征向量。然后,将该特征向量输入到支持向量机中进行训练与识别。

2.3 SVM 分类器

支持向量机是由 Cortes 和 Vapnik^[12]在1995年首次提出的,在解决小样本、非线性、高维空间中的数据分类问题有着突出的表现,其核心思想是寻找一个超平面把数据正确区分开来。支持向量机可分为线性和非线性两种分类器。

2.3.1 线性支持向量机

线性分类器的基本思想是对线性可分的数据在目标区域中找到一个超平面,使类间距最大。假设有 m 个样本集 $(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)$, y_m 为1或-1, x 为 q 维特征向量。目的就是把1和-1分开,使超平面距 x_m 最近的点间隔最大。

超平面可定义为:

$$w^T x + b = 0 \quad (1)$$

其中, x 为特征向量; w 为权重向量; w^T 为权重向量的转置向量; b 为常数。

支持向量函数定义为:

$$w^T x + b = \pm 1 \quad (2)$$

则支持向量到超平面的距离为:

$$\frac{y(w^T x + b)}{\|w\|} = \frac{1}{\|w\|} = \frac{1}{\sqrt{w^T w}} \quad (3)$$

其中, $\|w\|$ 为权重向量的范数。

最终得到的分类器为:

$$f(x) = \text{sgn}(w^* x + b^*) \quad (4)$$

其中, w^* 、 b^* 分别为计算所得的最优解。

一个支持向量到超平面的距离是 $1/\|w\|$,两个支持向量之间的距离为 $2/\|w\|$ 。在线性 SVM 下的最优分类如图5所示。

2.3.2 非线性支持向量机

在实际情况下,非线性问题是比较多的,使用公式(1)无法完全区分数据集,这会产生很大的错分问题,因此需引入非线性支持向量机。非

线性分类器如图 6 所示。




图 5 最优超平面与支持向量

Fig. 5 Optimal hyperplane and support vector




图 6 非线性分类器

Fig. 6 Nonlinear classifier

非线性分类的思想就是通过某种映射关系将输入量从低维空间转化到高维空间, 在高维空间上实现线性可分^[13]。公式如下:

$$\begin{cases} \min_{w, \xi} \left(\frac{1}{2} \|w\|^2 + C \sum_{i=1}^m \xi_i \right) \\ s.t.: y^{(i)} [w^T x + b] \geq 1 - \xi_i, i=1, 2, \dots, m, \xi_i \geq 0 \end{cases} \quad (5)$$

其中, C 为惩罚因子; ξ 为松弛变量。

通过一系列计算, 得到最终的分类决策函数为:

$$f(x) = \text{sgn} \left[\sum_{i=1}^m \beta_i y^{(i)} K(x, x^{(i)}) + b \right] \quad (6)$$

其中, β 为拉格朗日乘子; $K(x, x^{(i)})$ 为核函数。

核函数的参数 Γ 值与惩罚因子 C 是决定分类是否精确的关键性因子。通常参数值的选取是凭个人经验, 达不到针对性分类的效果, 因此需要采用 K -fold 交叉验证方法^[14]对参数 C 与

Γ 寻优。其算法原理是: 将原始数据分为 K 组, 每组分别做一次测试集, 其余 $K-1$ 组作为训练集。交叉验证 K 次, 并将 K 次的平均识别率作为分类器的性能指标。

3 实验结果及分析

3.1 实验环境

实验中使用的图像集来自 Kaggle 官网上的美国州立农场驾驶员注意力分散检测的数据集^[15]。随机选取 4 类共 1 320 张图片, 其中 1 200 张作为训练集, 120 张作为测试集。这 4 类样本包括正常驾驶、驾驶时发短信、驾驶时打电话和驾驶时喝饮料。原图片的像素大小为 640×480 , 经过对归一化处理之后变成像素大小为 128×128 。使用 QT5.6 软件与 OpenCV3.1 图像视觉库作为开发环境。运行的计算机配置为 win7 系统, 处理器为 Inter(R) Core(TM) i5-4200U, CPU 主频为 1.6 GHz、内存为 4 G。

3.2 算法对比及分析

SVM 解决的是二分类问题, 由于 OpenCV 中的 SVM 算法是基于 Libsvm 库, 使用的是一一对一法 (one-versus-one) 对多类别进行分类。因此, 4 类样本需要 $K(K-1)/2=6$ 个分类器。

使用 HOG 算子提取图像特征, 将提取到的 8 100 维特征向量输入到 SVM 中进行训练与识别, 寻找最优参数。首先, 建立 C_SVC 分类模型, 选取径向基核函数 (RBF), 采用 K -fold 交叉验证方法, 此处 K 为 10。 C 的搜索范围设置为 $[0.000 1, 500]$, 每次以 5 个步长搜索。同时, Γ 的范围设定为 $[0.000 1, 10]$, 每次以 10 个步长进行搜索。然后, 得到最优值 C 为 39.062 500, Γ 值为 0.001 500。最后, 选取线性核函数进行训练并分类。

为了验证算法的优良性能, 将本文提出的算法与已有文献中的算法进行对比。具体地, 在相

同的数据集中,使用王振华等^[16]提出的 SVM 算法和赵李坤等^[17]提出的 LBP+SVM 算法,分别对 120 张测试图片进行分类识别。五种算法的识别结果如图 7 所示,并且通过对图 7 数据进行统计,求得平均识别率如表 1 所示。

表 1 HOG+SVM、SVM 和 LBP+SVM 测试样本的平均识别率

Table 1 Average recognition rate of HOG+SVM, SVM and LBP+SVM test samples

使用方法	平均识别率 (%)
SVM_Linear ^[16]	70.00
SVM_RBF ^[16]	75.84
LBP+SVM ^[17]	88.33
HOG+SVM_Linear ^[18]	90.84
HOG+SVM_RBF (本文)	93.33

通过图 7 和表 1 的数据可以得出:在对 4 类测试样本中, SVM 算法对正常驾驶行为的识别率最高,而线性 SVM 算法对喝饮料行为的识别率最低; LBP+SVM 算法对正常驾驶行为的识别率最高,对喝饮料行为的识别率最低;线性 HOG+SVM 算法对正常驾驶行为的识别率最高,而对打电话行为的识别率最低;采用 HOG+SVM 进行交叉验证参数寻优后的模型(即本文

方法)的平均识别率比 LBP+SVM 算法和 SVM 算法都要高。上述实验表明,在一定误差允许的条件下,采用 HOG+SVM 并对参数进行优化后的算法,对驾驶员分散行为进行识别是可行的。

4 结论

本文提出了一种基于 HOG+SVM 的识别算法,采用 HOG 对驾驶员分散行为提取不同特征,利用 SVM 分类器对分散行为进行分类,并分别与 SVM 算法和 LBP+SVM 算法在驾驶员分散行为的识别率上进行了对比。实验结果表明,使用 HOG+SVM 并对 SVM 参数寻优的算法对本次数据集的识别具有良好的效果,平均识别率达 93.33%。另外,实验过程中发现,虽然采用参数寻优算法识别率有较好的表现,但是在训练与识别速度方面还有待提高,还需使用更多的样本进行训练与识别。接下来将会进一步寻求更好优化参数的算法,提高训练与识别的速度,并将算法嵌入树莓派开发板中,对分散行为进行语音提醒,实现对驾驶员分散行为检测更深入的研究。

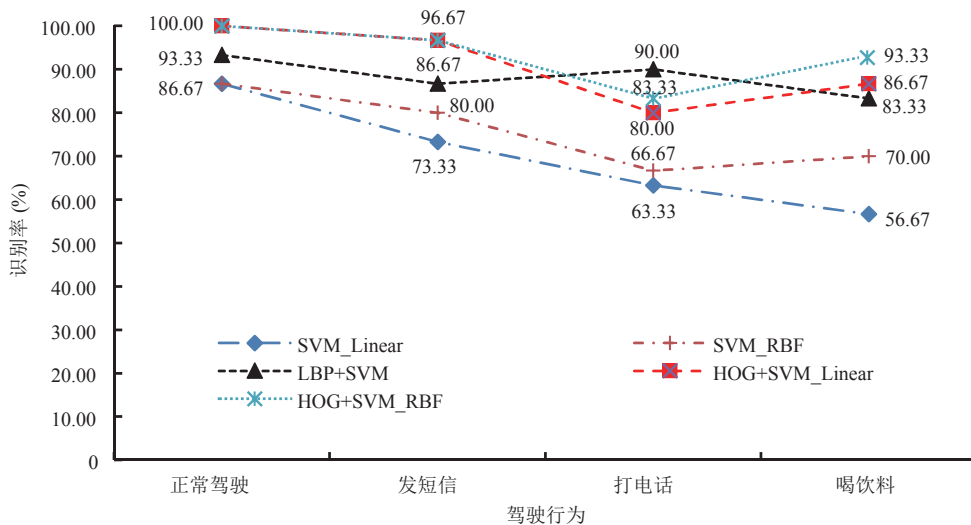


图 7 HOG+SVM 与 SVM、LBP+SVM 测试样本结果图

Fig. 7 HOG+SVM, SVM and LBP+SVM test sample result diagram

参 考 文 献

- [1] 蒋菱枫. 2018 年全国小汽车保有量首次突破 2 亿辆 [EB/OL]. [2019-5-15]. <http://www.mps.gov.cn/n2254098/n4904352/c6354939/content.html>.
- [2] 赵磊. 基于深度学习和面部多源动态行为融合的驾驶员疲劳检测方法研究 [D]. 济南: 山东大学, 2018.
- [3] SafeStart. Top 10 causes distracted driving and what they all have common [EB/OL]. [2019-5-15]. <https://safestart.com/news/top-10-causes-distracted-driving-and-what-they-all-have-common/>.
- [4] 王尽如. 基于半监督支持向量机的驾驶员打电话行为检测 [D]. 长沙: 湖南大学, 2018.
- [5] Liang YL, Reyes ML, Lee JD. Real-time detection of driver cognitive distraction using support vector machines [J]. *IEEE Transactions On Intelligent Transportation Systems*, 2007, 8(2): 340-350.
- [6] Liu TC, Yang Y, Huang GB, et al. Driver distraction detection using semi-supervised machine learning [J]. *IEEE Intelligent Transportation Systems Magazine*, 2016, 17(4): 1108-1120.
- [7] 程文东, 付锐, 袁伟. 驾驶人注意力分散的图像检测与分级预警 [J]. *计算机辅助设计与图形学学报*, 2016, 18(8): 1287-1296.
- [8] Omid D, Mojtaba T. Driver distraction detection using MEL cepstrum representation of galvanic skin responses and convolutional neural networks [C] // 2018 24th International Conference on Pattern Recognition (ICPR), 2018: 1481-1486.
- [9] Wathiq O, Ambudkar BD. Driver safety approach using efficient image processing algorithms for driver distraction detection and alerting [M] // *Intelligent Engineering Informatics*. Springer, 2018: 461-469.
- [10] Baheti B, Gajre S, Talbar S. Detection of distracted driver using convolutional neural network [C] // *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2018: 1145-1151.
- [11] Dalal N, Triggs B. Histograms of oriented gradients for human detection [C] // 2005 IEEE Conference on Computer Vision & Pattern Recognition (CVPR), 2005: 886-893.
- [12] Cortes C, Vapnik V. Support-vector networks [J]. *Machine Learning*, 1995, 20(3): 273-297.
- [13] Guo HS, Wang WJ. Granular support vector machine: a review [J]. *Artificial Intelligence Review*, 2019, 51(1): 19-32.
- [14] Jayanthi S, Ayswaria SV, Vaishali M, et al. A high quality embedded system for assessing food quality using histogram of oriented gradients [J]. *ICTACT Journal on Soft Computing*, 2018, 9(1): 1781-1787.
- [15] StateFarm. State farm distracted driver detection [EB/OL]. [2019-5-15]. <https://www.kaggle.com/c/state-farm-distracted-driver-detection>.
- [16] 王振华, 贾银山, 陈兴. 基于 SVM 的驾驶员疲劳检测研究 [J]. *科学技术与工程*, 2011, 11(8): 1828-1832.
- [17] 赵李坤, 蒋新华, 杨海燕. 基于 MLBPFF 和 SVM 的驾驶员疲劳检测 [J]. *计算机与现代化*, 2013(9): 82-85, 90.
- [18] 王正友, 郭旭锋, 张泽文, 等. 基于局部特征的铁路驾驶员目标检测 [J]. *中国科技论文*, 2018, 13(20): 2357-2364.