

深度学习在驾驶员安全带检测中的应用

霍星¹ 费志伟² 赵峰² 邵堃³

(合肥工业大学数学学院 合肥 230009)¹ (合肥工业大学软件学院 合肥 230009)²

(合肥工业大学计算机与信息学院 合肥 230009)³

摘要 安全带是保障驾驶员安全最有效的措施之一,我国法律明文规定驾驶员驾驶车辆时必须佩带安全带。目前,驾驶过程中安全带佩带的识别以人工筛查为主。随着汽车数量的飞速增加,传统的检测方式已无法满足交通管理的需求,实现安全带检测的自动化处理已成为当前交通系统亟需解决的问题之一。文中设计了一种驾驶人是否佩带安全带的识别系统。首先,通过车牌与车窗位置之间的几何关系进行车窗粗定位;其次,利用霍夫变换检测车窗的上下沿,并利用积分投影变换检测车窗的左右边界,将检测到的图片对半划分,得到驾驶员的粗略位置;最后,基于加入空间变换层的深度卷积神经网络方法进行安全带的识别分析。针对 10 000 张不同卡口、不同时段实时采集的图片进行实验,结果表明该方法能有效地识别驾驶人是否按规定佩带安全带,且综合识别率相比现有方法有显著提高。

关键词 深度学习,安全带检测,空间变换神经网络,车窗边缘检测

中图分类号 TP27 文献标识码 A

Application of Deep Learning in Driver's Safety Belt Detection

HUO Xing¹ FEI Zhi-wei² ZHAO Feng² SHAO Kun³

(School of Mathematics, Hefei University of Technology, Hefei 230009, China)¹

(School of Software, Hefei University of Technology, Hefei 230009, China)²

(School of Computer Science & Information Engineering, Hefei University of Technology, Hefei 230009, China)³

Abstract Seat belts are one of the most effective measures to protect safety of drivers which the law stipulates that drivers must wear seat belts when driving the vehicle. At present, the identification of seat belt during driving is mainly based on manual screening. However, the traditional detection methods can not meet the needs of traffic management as the rapid increase of the number of vehicles. And the automatic processing of seat belt detection has become one of the urgent problems in the current traffic system. In this paper, a recognition system for seat belts of drivers is designed. First, the vehicle window is roughly positioned by the geometric relationship between the license plate and the window. Second, Hough transform is used to detect the upper and lower edges of the window and the integral projection transformation is used to detect the left and right borders of the window. The detected pictures will be cut into half to get the driver rough position. Finally, the seat belt identification analysis based on deep convolutional neural network is conducted which adds spatial transform layer. Experiments are carried out on different bayonet and different time periods for 10 000 pictures. The experimental results show that the proposed method can effectively identify whether the driver wears the seat belt according to the regulations, and the comprehensive recognition rate is significantly improved compared with the existing method.

Keywords Deeping learning, Seat belt detection, Spatial transform networks, Car window edge detection

1 引言

基于机器视觉的交通违章识别是近年来国内外智能交通领域研究的一大热点,极大地促进了城市智能交通系统的发展和完善。随着国内汽车的不断增加,事故的案发量与日俱增。当两车相撞时,驾驶员不系安全带的死亡率为 75%,而系安全带的生还率为 95%,因此驾乘过程中是否系安全带的

检测逐渐成为智能交通管理中的热门研究方向^[1]。目前,对驾驶员安全带检测的研究已经有了一些进展。Guo 等^[2]提出的基于图像处理的安全带检测方法采用车牌与车窗之间的几何关系对驾驶员进行精确定位,然后通过检测直线的方式识别安全带。该方法中定位驾驶员模块部分对照片中车辆的拍摄角度有着很高的依赖性,而且安全带检测部分对图片质量要求很高,现有的交通摄像机无法同时满足上述两个要求,在

本文受国家自然科学基金面上项目(61872407,61572167),安徽省科技强警计划项目(1604d0802018),合肥工业大学 2017 年国家级大学生创新训练计划项目(201710359067),科技部国际合作项目(2015DFA11450),广东省省级科技计划项目(2016B010108002)资助。

霍星(1979-),女,博士,副教授,CCF 会员,主要研究领域为机器学习、图形图像处理,E-mail:huoxing@hfut.edu.cn(通信作者);费志伟(1995-),男,硕士生,主要研究领域为深度学习、图像处理;赵峰(1964-),男,硕士,教授,高级工程师,主要研究领域为智能交通系统;邵堃(1967-),男,博士,副教授,CCF 高级会员,主要研究领域为开放网络环境下的信任评估模型、需求工程、软件理论。

现实中可行性不高。李万臣等采用模糊增强技术对驾驶员图像质量进行了提升,然后使用 Hough 变换检测直线^[3]的方式检测安全带^[4]。该方法采用的图像是车内拍摄的,质量较高,但与现实中的卡口照片质量以及驾驶员在图像中所占的比例具有很大差异,并不能在现实中推广。石时需等^[5]提出一种级联车牌定位技术、Haar 特征人脸识别技术、Hough 变换安全带检测技术于一体的系统,系统本身的复杂度高,且上一个模块所带来的检测错误会影响下一步的工作,工程复杂并容易出错。程伟等^[6-8]提出的方法最后均使用 Hough 变换检测直线的方式来识别安全带,但 Hough 变换算法在实际实施过程中并不是很理想,鲁棒性差。随着机器学习的发展,Ada-boost 也被运用到安全带检测系统中,陈雁翔等^[9-10]先训练识别车窗、驾驶员的弱分类器,然后级联每个弱分类器形成强分类器来完成最后对驾驶员是否系安全带的检测。相比于传统的 Hough 直线检测,该方法在效果上有一定的提高,但是精确度仍然偏低,对图像质量要求也很高,很难在实际中推广。

为了提高安全带检测系统的精度以及鲁棒性,本文提出了一种基于自定义深度卷积神经网络的汽车驾驶员安全带识别方法。如图 1 所示,该方法包括两个部分,第一部分先获取驾驶员区域的大致位置,为后续安全带定位奠定基础;第二部分训练一个深度神经网络,该网络通过向深度卷积神经网络中加入空间变换层来对驾驶员部分进行更加精确的定位对齐,并加入一个分类网络对所得结果进行分类。具体分为以下 3 个步骤:

1) 卡口图片预处理服务。采用灰度化、高斯滤波、形态学操作、轮廓算法和验证算法,提取图像中可能包含车牌的区域。对每个图像块使用支持向量机 SVM 进行分类,确定车牌位置。

2) 在此基础上先利用几何关系确定车窗的大致位置,再利用霍夫变换检测车窗的上下沿,采用积分投影变换确定车窗的左右边界,利用几何关系确定驾驶员区域的初步位置。

3) 将主驾驶区域图片送入定位对齐神经网络中进行调整,结果送入分类网络中进行分类,得到精确度较高的检测结果,完成对卡口图片的检测。




图1 安全带检测算法的整体框架

2 驾驶员粗定位

2.1 基于车牌的车窗定位

2.1.1 基于图像梯度特征的车牌定位算法

本文采用基于图像梯度特征的车牌定位方法。在定位之前,需要对待识别图像 I 进行预处理,使用式(1)进行图像灰度化:

$$I_{\text{gray}} = 0.299 \times I_R + 0.587 \times I_G + 0.114 \times I_B \quad (1)$$

接着使用式(2)进行去噪:

$$I_{\text{denoise}} = f_G * I_{\text{gray}} \quad (2)$$

其中, f_G 为高斯滤波。

图像预处理后,根据图像垂直梯度特征消除待检测图像背景,对去噪后的图像使用式(3)进行垂直边缘检测:

$$I_{\text{edge}} = G_{\perp} * I_{\text{denoise}} \quad (3)$$

其中, G_{\perp} 为垂直方向的 sobel 算子。

对获取边缘信息后的图像使用自适应阈值参数进行二值化,获得二值图像 I_{binary} ,进一步去除背景,再使用式(4)进行闭运算,将车牌区域连通化:

$$I_{\text{Morph}} = (I_{\text{binary}} \oplus b) \odot b \quad (4)$$

其中, b 为矩形结构元。

对 I_{Morph} 进行连通性和颜色判定(本文选取蓝色和黄色),获得多个连通块,接着提取这些连通块的外接矩阵,根据车牌长宽比和方向特征,对各个矩阵块进行相似度判定,最终定位车牌。车牌定位算法的流程如图 2 所示,算法的实施过程如图 3 所示。




图2 车牌定位算法的流程

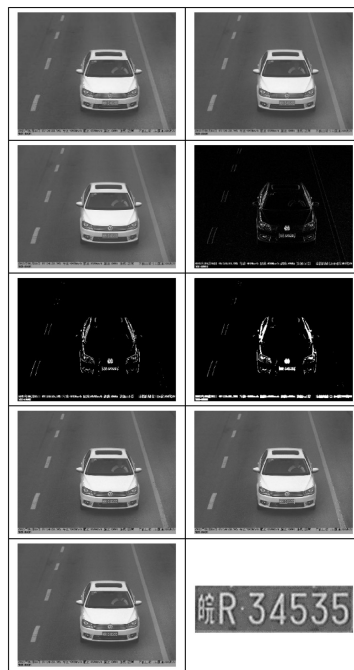


图3 车牌定位方法的实施过程

2.1.2 基于车牌特征的自适应车窗定位算法

本文采用了霍星等人提出的基于车牌特征的自适应车窗定位算法。该算法主要是通过车牌颜色特征来判断车型,根据不同车型的车牌与车窗之间的经验空间几何比例,利用几何仿射变换来达到定位车窗的目的。假设车牌位置标记为 $(x_{Ld}^p, y_{Ld}^p, x_{Ru}^p, y_{Ru}^p)$, 其中 (x_{Ld}^p, y_{Ld}^p) 为车牌左下角点, (x_{Ru}^p, y_{Ru}^p) 为车牌右上角点, 车牌的长宽标志为 w^p 和 h^p ; 假设车窗位置标记为 $(x_{Lw}^w, y_{Lw}^w, x_{Rw}^w, y_{Rw}^w)$, 车窗的长宽标志为 w^w 和 h^w , 车窗位置由几何仿射比例向量 $(\eta_1, \eta_2, \eta_3, \eta_4, \eta_5, \eta_6)$ 确定, 则车窗位置可以由式(5)给出:

$$(x_{Ld}^w, y_{Ld}^w, 1) = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ a_1 w^p & a_2 h^p & 1 \end{pmatrix} (x_{Ld}^l, y_{Ld}^l) \quad (5)$$

$$w^w = a_3 w^p, h^w = a_4 h^p$$

$$x_{Rd}^w = x_{Ld}^w + w^w, y_{Rd}^w = y_{Ld}^w + h^w$$

其中, $a_1 = \eta_4 - \eta_1 \eta_2 \eta_5, a_2 = \eta_6, a_3 = \eta_1 \eta_2, a_4 = \eta_3$, 且 η_i 均为正实数。

通过对大量机动车图片车窗、车牌的手工标定, 并对比例数据进行聚类分析, 本文得出以下比例向量的取值。

在小型车情况下:

$$(\eta_1, \eta_2, \eta_3, \eta_4, \eta_5, \eta_6) = (4.0, 1.0, 1.0, 0.6, 0.5, 0.5, 4.0)$$

在大型车情况下:

$$(\eta_1, \eta_2, \eta_3, \eta_4, \eta_5, \eta_6) = (4.8, 1.5, 0.5, 0.5, 0.5, 7.0)$$

图 4 展示了算法执行过程, 从中可以看到该算法有效地通过车牌位置获取了车窗的粗略位置。



图 4 车窗定位的实施过程

2.2 改进的 Hough 直线变换检测车窗上下沿

在由车牌定位得到的初步车窗图像中, 进一步细化车窗部分。通过对车窗的特征进行分析可以发现机动车车窗的上下边沿近似于水平直线, 因此我们采用改进的 Hough 变换算法检测车窗上下边沿的长直线。Hough 变换的原理是将空间中的直线用极坐标表示时, 极坐标中的参数与空间中的直线是一一对应的。于是我们可以将二值图像转换到 Hough 参数空间, 建立直线与点之间的关系, 以探测参数空间中点阵列的峰值来检测全局边界问题^[11]。在使用 Hough 变换检测直线之后, 可以得到图像中一定长度的直线, 这些直线中包含了车窗的上边沿和下边沿。

实际检测过程中, 会得到较多的短线段, 通过计算线段的斜率可以筛选掉一部分直线。返回的线段端点可能归属于的边缘满足以下条件:

$$y_{\text{mean}} = \frac{1}{n} \sum_{i=1}^n y_i$$

$$y_i = \begin{cases} \text{上边沿点,} & \text{if } y_i > y_{\text{mean}} \\ \text{下边沿点,} & \text{if } y_i < y_{\text{mean}} \end{cases}$$

经过 Hough 变换检测的效果如图 5 所示。



图 5 算法分步执行时的效果

2.3 垂直积分投影定位车窗

积分投影是根据图像在水平和垂直方向上的投影分布特征进行分析检测, 假设 $I(x, y)$ 表示点 (x, y) 处像素值, 则在图像水平范围 $(x_1 \rightarrow x_2)$ 和垂直范围内 $(y_1 \rightarrow y_2)$ 的积分投影函数用式(6)和式(7)表示:

$$\text{水平投影: } f_h(y) = \sum_{x=x_1}^{x_2} I(x, y) \quad (6)$$

$$\text{垂直投影: } f_v(x) = \sum_{y=y_1}^{y_2} I(x, y) \quad (7)$$

其中, $f_h(y)$ 和 $f_v(x)$ 分别表示水平方向和垂直方向的投影值。

将步骤 2 中获取的车窗水平带部分分割出来后, 接下来将要确定的是车窗左右两侧的位置。对图像进行垂直积分投影, 经投影后获得的图像如图 6 所示。




图 6 垂直积分投影图

从垂直投影图像中可以看到车窗的左右两侧对应于垂直积分投影图像中的左右两个峰值, 根据前面所获得的车窗上下沿位置和经过垂直投影后获取的车窗左右两侧的位置, 就可以从原始图像中分割出车窗部分的图像, 如图 7 所示。



图 7 车窗图像

2.4 几何关系确定驾驶员的粗略位置

通过分析所得图像, 可以看到驾驶员的粗略位置在图像的右部, 占整张图片大小的 1/2。在不同的角度下, 通过统计得出图像中最远包含驾驶员信息的点位置约在整幅图像的右起 0.6 处。为了后面所得到的驾驶员部分的完整性, 本文取驾驶员的区域为图片 60% 部分, 如图 8 所示。



图 8 驾驶员部分

3 基于深度学习的驾驶员安全带检测

本文设计了一个深度卷积神经网络^[12]来完成驾驶员部分的对齐以及安全带的检测, 网络结构如图 9 所示。

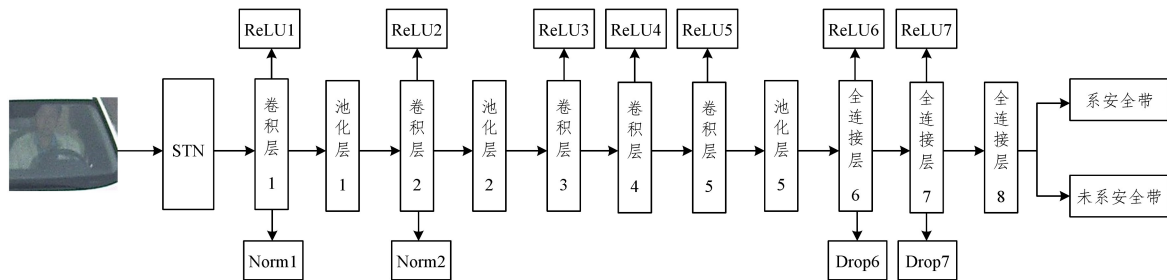


图9 神经网络结构

该网络包含两个部分,分别为空间变换神经网络和一个分类网络。输入一张原图,通过STN部分将驾驶员区域做进一步细化处理,再送入分类网络判断驾驶员是否佩带了安全带。

3.1 空间变换神经网络

在基本的网络模型中加入空间变换神经网络^[13]能够使模型对输入图像做一个显示的几何变换。本文通过STN层能够将驾驶员部分转化到图像中央,精细化驾驶员部分,消除位置和驾驶员周围环境对后期分类的影响。由于采用了标准的反向传播算法,所以转换的参数得到了学习,这意味着不需要额外的数据或监督。

空间变换神经网络主要由定位网络、网格生成器和可微图像采样3部分构成,如图10所示。

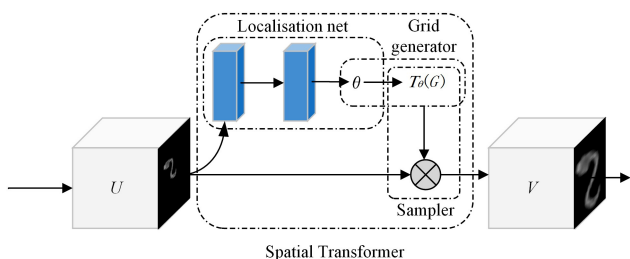


图10 空间变换神经网络的结构

定位网络将输入的图像放入一个子网络(由卷积、全连接等构成的若干层子网络),生成空间变换参数 θ 。 θ 的形式可以多样,如需要实现2D仿射变换,那么 θ 就是一个 2×3 的向量。

网格生成器将通过变换参数 θ 构造出一个参数化的采样网格,以找到输出特征图 V 中的坐标点在输入特征图 U 中所在的坐标位置。

利用可微分图像采样函数对网络生成器中的采样坐标进行双线性插值,以计算出像素值^[14],公式如下:

$$V_i = \sum_n \sum_m U_{nm} \max(0, 1 - |x_i^* - m|) \max(0, 1 - |y_i^* - n|)$$

图11展示了拟训练的神经网络第一层是STN的场景。



图11 STN效果图

其中,左边是输入图片,中间是输入图片的部分被采样,右边是经过空间变换后的输出图像。

3.2 AlexNet

在得到主驾驶区域的图像后,运用一个二元分类器对已经获得的图片进行分类,以判断图中的驾驶员是否佩带了安

全带。本文采用 Alexnet^[15] 深度学习神经网络模型来完成这一个任务。相较于传统的 LeNet 之类的 CNN 网络, Alexnet 具有更好的识别效果,并且一定程度上解决了过拟合问题。

Alexnet 具有 8 层结构,包括 5 个卷积层和 3 个全连接层,其中 layout1—layout5 为卷积层,剩下的部分为全连接层,如图 9 所示的 STN 模块后的网络结构部分。

在卷积层 1 和卷积层 2 之后的是响应归一化层,即利用邻近的数据做归一化。卷积层构成了一个计算模块,即一层卷积,通过插入函数来控制数值以便于后续的计算。全连接层中的神经元被连接到前一层中所有的神经元上。最大池化操作(Maxpooling)在两个响应归一化层和卷积层 5 之后,池化层是通过逐步降低特征的维度来减少网络中的参数和计算量。在每个卷积层和全连接层之后,进行的是 ReLU 操作。相比于 Simoid 之类的函数,ReLU 是一种非饱和的激活函数,它不需要解决其他函数所出现的饱和问题。ReLU 函数如下:

$$\text{ReLU}(x) = \max(x, 0)$$

Alexnet 中使用了 Dropout,它是指在模型训练时随机使模型中的某些节点不工作,但是依旧保留其权重。通过 Dropout 层可以去除一部分没有足够激活的层,它的作用是避免某些特征在其他特征下才出现效果,从而减少了过拟合现象。

4 测试结果与分析

4.1 实验设置

本文实验环境:CPU 为 Intel i7-7700k,8GB 内存,显卡为 GTX1080Ti,采用 Cuda8+CuDNN6.0 加速。

4.2 驾驶员区域检测

实验所用车辆照片来自 10 个卡口相机所拍摄的照片,抽取了 10000 张含有车牌的照片作为测试。测试样本库包括白天、晚上等不同时间段下轿车、面包车和大货车等不同车型的测试结果,统计结果以最后输出图片是否包含驾驶员作为依据。测试结果如表 1 所列。

表1 驾驶员区域截取测试结果

	总数/张	识别结果/张	检出率/%
白天拍摄	5000	4807	96.15
晚上拍摄	5000	4769	95.38

从表 1 中可以看到,整个驾驶员区域粗定位框架的整体效果良好,并且由于不受车辆颜色、拍摄时间等的影响,相比于一些基于色差均值的车窗检查算法^[16]以及使用原生 Hough 变换的方法^[17],在最终的结果和对图像质量的要求上更加具有优势。

4.3 安全带检测效果实验

通过图像预处理得到的包含驾驶员的有效样本数为9576张,从中随机抽取2200张作为训练样本进行训练,其中未系安全带1100张,已系安全带1100张;再用剩余的7376张照片进行测试。

本文使用检测率(CIR)、虚警率(WIR)和漏检率(MIR)作为安全带检测系统的评价指标,计算方式如式(8)和式(9)所示。

$$CIR = \frac{N_r}{N_t}, WIR = \frac{N_w}{N_t}, MIR = \frac{N_m}{N_t} \quad (8)$$

$$N_t = N_r + N_w + N_m \quad (9)$$

其中, N_r 是指被正确检测的图片数, N_w 是指未系安全带而被误检为系安全带的图片数, N_m 是指系安全带而被误检为

未系安全带的图片数, N_t 是指测试图片总数。

本文在自己的图片库上对比了Guo等^[2]提出的基于边缘检测和Hough变换方法的实验结果,并对比了未加入STN层分类网络的实验效果,对比结果如表2所列。图12展示了本文所提算法的部分分类结果图,其中左边为已系安全带的结果,右边为未系安全带的结果。

表2 安全带检测结果的对比

	CIR	WIR	MIR
基于边缘检测和 Hough 变换	67	18	15
CNNs	89	7	4
STN-CNNs	92	6	2

(单位:%)



图12 本文算法的分类结果

从表2的结果可以看出基于传统图像处理的驾驶员安全带检测效果最差。由于传统的图像处理方法极易受光照条件、车身颜色和司机衣服颜色等因素的影响,对卡口相机拍摄的角度也有很高的要求,测试中正面拍摄司机光照条件良好的照片识别效果最佳,此类照片占总卡口照片的比例不大;而且卡口照片中大货车和小汽车的安全带位置差别较大,容易导致此类方法在安全带区域出现锁定错误。这些因素导致了传统图像处理方法的鲁棒性差,在单个卡口照片集上获取的最优参数并不适用于其他的卡口照片数据集。结果显示,传统方法的检出率只有67%,虚警率和漏检率也较高。

在测试中,不同的摄像机角度导致的驾驶员位置并非在图片中央,传统的CNNs由于需要大量数据进行训练,在采用相同的训练样本的基础上,不能很好地解决驾驶员位置差异过大带来的影响。而本文所用的STN-CNNs很好地解决了驾驶员对齐问题,在测试中表现最优。

相较于传统的安全带识别框架,前期一开始就需要确定一个精确的驾驶员区域来消除对后期安全带识别带来的影响,本算法框架将驾驶员区域修正与后期的分类网络联合起来,简化了整体流程,并且训练时无需额外数据,最终识别结果也优于传统方案。

结束语 本文提出了一种基于深度学习的驾驶员安全带检测系统,系统能够精确地识别驾驶员是否佩戴了安全带,系统流程简单。实验表明其安全带检测的正确率可以达到

92%左右,提高了安全带检测的工作效率;并且多个监控路段的图像检测结果表明系统适用性好,能够满足智能交通中安全带识别的需要。

参考文献

- [1] 杨凯杰,章东平,杨力. 深度学习的汽车驾驶员安全带检测[J]. 中国计量大学学报,2017,28(3):326-333.
- [2] GUO H W, LIN H, ZHANG S J. Image-based seat belt detection[C]//Proceedings of IEEE International Conference on Vehicular Electronics and Safety (ICVES). Beijing: IEEE, 2011: 161-164.
- [3] DUDA R O, HART P E. Use of the Hough Transformation to detect lines and curves in pictures[J]. Communications of the ACM(CACM), 1972, 15: 11-15.
- [4] 李万臣,张晋. 基于模糊增强的安全带佩戴识别方法[J]. 应用科技, 2015, 42(1): 22-27.
- [5] 石时需,秦勇,蔡昭权,等. 基于高速公路交通图像的安全带自动识别算法[J]. 计算机与现代化, 2014, 5: 118-121.
- [6] 程伟. 基于图像分析的未系安全带自动检测方法研究[D]. 沈阳: 沈阳理工大学, 2016.
- [7] 唐恬,王秋,李旭. 基于图像的驾驶员安全带自动检测系统[J]. 中国人民公安大学学报(自然科学版), 2016, 22(2): 71-74.
- [8] 傅生辉. 驾驶人未系安全带识别系统研究[D]. 济南: 山东农业大学, 2016.

- [9] 陈雁翔,李庚.基于 Adaboost 的安全带检测系统[J].电子测量技术,2015,38(4):123-127.
- [10] 吴法.图像处理与机器学习在未系安全带驾车检测中的应用[D].杭州:浙江大学,2013.
- [11] 姚东明,韩安华.基于车窗检测的车身颜色识别方法研究[J].信息通信,2017(2):87-88,90.
- [12] 周飞燕,金林鹏,董军.卷积神经网络研究综述[J].计算机学报,2017,40(6):1229-1251.
- [13] JADERBERG M, SIMONYAN K, ZISSERMAN A, et al. Special transformer networks[C]//Proceedings of the 28th International Conference on Neural Information Processing Systems

- (NIPS). Montréal: NIPS, 2015.
- [14] 欧阳钊,陈玮.基于可变形卷积神经网络的图像分类研究[J].软件导刊,2017,16(6):198-201.
- [15] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[C]//Proceedings of the 25th International Conference on Neural Information Processing Systems (NIPS). Nevada: NIPS, 2012: 1097-1105.
- [16] 王运琼,游志胜.基于色差均值的快速车窗定位算法[J].计算机应用与软件,2004,21(1):78-79,117.
- [17] 侯殿福.车窗检测技术研究[D].北京:北京交通大学,2012.

(上接第160页)

以对于各个阈值,标准差越小,证明算法的稳定性越好。

K-means 算法的初始聚簇中心是随机确定的,若初始聚簇中心与目标结果相差太大,很有可能在未达到最佳阈值时就因达到了事先设定的最大迭代次数而停止迭代,或因聚簇中心在错误的阈值处就不再变化就得到错误的结果。若初始聚簇中心与目标结果比较接近,则 K-means 算法也有可能通过比较少的迭代次数就得到理想的结果。这也是 K-means 算法稳定性比较差的原因。而本文提出的算法使用基于信息熵的迭代算法初始化聚簇中心,为改进的 K-means 算法提供了比较可靠的初始聚簇中心,因此本文算法的稳定性要远远高于传统的 K-means 算法。而 OTSU 算法是遍历了所有可能的结果,用类间方差评定分割结果,算法的稳定性与本文算法处于同一级别上,但因质量评价函数不同,OTSU 算法的执行效率较低。

表3 3种算法分割结果的稳定性比较

	OTSU	K-means	本文算法
分割阈值1平均值	63.6	46.7	63.1
分割阈值1标准差	52.0	382.1	46.6
分割阈值2平均值	119.7	75.3	86.4
分割阈值2标准差	44.1	390.4	26.4
分割阈值3平均值	194.6	176.5	193.4
分割阈值3标准差	11.8	1481.8	10.1

结束语 本文使用基于信息熵的迭代改进算法初始化聚簇中心,并使用新的质量评价函数替代传统的 K-means 质量评价函数。实验表明我们在引言部分提出的问题已经基本解决,即本文提出的算法能有效弥补传统 K-means 算法的不足之处,算法稳定性、正确率、分割精细度得到有效提高,目标边界信息更加准确。

参考文献

- [1] KIECHLE M, STORATH M, WEINMANN A, et al. Model-based learning of local image features for unsupervised texture segmentation [J]. IEEE Transactions on Image Processing,

- 2018, PP(99):1-1.
- [2] BAKHSHIPOUR A, JAFARI A, NASSIRI S M, et al. Weed segmentation using texture features extracted from wavelet sub-images[J]. Biosystems Engineering, 2017, 157: 1-12.
- [3] DANIELIS A, GIORGI D, LARSSON M, et al. Lip segmentation based on Lambertian shadings and morphological operators for hyper-spectral images [J]. Pattern Recognition, 2017, 63: 355-370.
- [4] LI X, WANG L, WANG J, et al. A New Method for Multi-focus Image Fusion Based on Multilevel Morphological Component Analysis and Support Vector Machine [J]. Iet Image Processing, 2017, 11(10): 919-926.
- [5] ZHANG X, ZHAO H, LI X, et al. A multi-scale 3D Otsu thresholding algorithm for medical image segmentation [J]. Digital Signal Processing, 2016, 60: 186-199.
- [6] KITTLER J, ILLINGWORTH J. Minimum error thresholding [J]. Pattern Recognition, 1986, 19(1): 41-47.
- [7] KAPUR J N, SAHOO P K, WONG A K C. A new method for gray-level picture thresholding using the entropy of the histogram [J]. Computer Vision Graphics & Image Processing, 1985, 29(3): 273-285.
- [8] OSMAN Z E M, HUSSIN F A, ALI N B Z. Hardware implementation of an optimized processor architecture for SOBEL image edge detection operator [C]// International Conference on Intelligent and Advanced Systems. IEEE, 2010: 1-4.
- [9] DING L, GOSHTASBY A. On the Canny edge detector [J]. Pattern Recognition, 2001, 34(3): 721-725.
- [10] 唐涛,覃晓,易宗剑,等.基于k中心点聚类的图像二值化方法[J].计算机科学与探索,2015,9(2):234-241.
- [11] 孙路,毕笃彦.基于信息熵的图像分割阈值迭代改进算法[J].计算机应用与软件,2008,25(10):225-226.
- [12] 官林.面向杂草识别的特征提取方法研究[D].哈尔滨:东北农业大学,2015.
- [13] 张雪凤,张桂珍,刘鹏.基于聚类准则函数的改进 K-means 算法 [J]. 计算机工程与应用, 2011, 47(11): 123-127.