

基于卷积神经网络多特征联合的车辆识别模型

刘泽康 孙华志 马春梅 姜丽芬

(天津师范大学计算机与信息工程学院 天津 300387)

摘要 车辆识别在智能交通领域中发挥着重要的作用,其可被用于违章抓拍、交通拥堵报警和自动驾驶等众多领域。文中提出结合车辆边缘联合建模的方法进行车辆识别。边缘联合卷积神经网络(E-CNN)通过简单有效的多特征联合方法提高了识别精度和模型收敛速度。为了验证 E-CNN 的性能,将多特征联合模型与 VGG16 和 GoogLeNet 模型进行对比。实验结果表明,所提模型的收敛速度相比 VGG16 和 GoogLeNet 有明显的优势,并且在有效时间内识别率达到了 99.90%,高于 VGG16 的 99.82% 和 GoogLeNet 的 99.35%。

关键词 边缘联合卷积神经网络,车辆识别,边缘特征,特征融合

中图分类号 TP391 **文献标识码** A

Vehicle Recognition Model Based on Multi-feature Combination in Convolutional Neural Network

LIU Ze-kang SUN Hua-zhi MA Chun-mei JIANG Li-fen

(College of Computer and Information Engineering, Tianjin Normal University, Tianjin 300387, China)

Abstract Vehicle recognition plays an important role in intelligent transportation, which can be used in many fields such as illegal snapping, traffic jam warning, and automatic driving, etc. This paper proposed a joint model that combines vehicle edge(E-CNN) to identify vehicles. The simple and effective feature combining not only improves the recognition accuracy, but also accelerates the convergence speed of the model. In order to verify the performance of E-CNN, the multi-features combination model was compared with the model of VGG16 and GoogLeNet. The experimental results show that the convergence speed of the proposed model has obvious advantages compared with VGG16 and GoogLeNet. Further more, the recognition accuracy of the proposed model is up to 99.90%, which is higher than 99.82% of VGG16 and 99.35% of GoogLeNet.

Keywords E-CNN, Vehicle identification, Edge features, Feature fusion

1 引言

随着人们生活水平的不断提高,汽车已经普遍进入到了人们的日常生活中。道路上汽车数量的增多,使得单纯依靠人工监管交通系统已经无法满足如今的需求,所以近几年智能交通得到快速发展。车辆识别作为智能交通系统中尤为重要的环节,其目的是识别出图像中包含的车辆。它被广泛应用于道路违章抓拍^[1]、交通拥堵报警^[2]、无人驾驶^[3]以及辅助驾驶众多方向。

深度学习是一种基于对数据进行表征学习的方法,其通过对大量数据集的训练调整自身参数,以得到最优模型。由于深度学习模型的识别精度明显高于其他方法,因此深度学习被广泛用于车辆识别领域。现阶段人们对深度学习的研究都是通过构建复杂的模型结构或者加深网络层数实现的,比如 GoogLeNet^[4]和 VGG16^[5]等模型都是通过以上方法来提

高识别精度的。但是使用以上方法改进的模型需要更多的数据和时间去训练以达到收敛,并且模型的训练对硬件有很高的要求。针对以上问题,本文提出结合车辆边缘特征联合建模的卷积神经网络模型 E-CNN,其优势在于:1)通过特征融合的方式将从原图像和边缘图像提取到的特征联合到一起,模型简易,便于训练;2)联合边缘图像特征,在提取边缘图像的过程中减少了噪声,使得模型降低了对训练所用图片的要求;3)利用原图像联合建模,在训练过程中结合原图像有效地弥补了边缘图像提取时损失的车辆特征。

为了客观评价所提模型的性能,本文利用 VGG16 模型和 GoogLeNet 模型进行对比实验。实验结果表明,E-CNN 模型在收敛速度上明显快于 VGG16 模型和 GoogLeNet 模型,并且 E-CNN 模型的识别正确率可以达到 99.90%,高于 VGG16 模型的 99.82% 和 GoogLeNet 模型的 99.35%。

本文第 2 节介绍相关工作;第 3 节描述 E-CNN 模型的搭

本文受国家自然科学基金(61702370),天津市国际科技合作项目(14RCGFGX00847),天津市自然科学基金(17JCYBJC16400),天津市科技计划项目(17ZLZXZF00530),天津师范大学 131 三层次人选(043/135305QS20),天津师范大学博士基金(043/135202XB1615,043/135202XB1705)资助。

刘泽康 男,硕士生,主要研究方向为图像处理、模式识别,E-mail:lzk100953@163.com;**孙华志** 男,博士,教授,主要研究方向为人工智能、模式识别、机器学习等,E-mail:sunhuazhi@tjnu.edu.cn(通信作者);**马春梅** 博士,讲师,主要研究方向为人工智能、群智感知、智能交通等;**姜丽芬** 女,博士,教授,主要研究方向为人工智能、普适计算、机器学习等。

建过程;第4节通过实验验证 E-CNN 模型的性能;最后总结 E-CNN 模型的优势以及未来发展方向。

2 相关工作

车辆识别是智能交通系统中最为关键的技术,其任务是确定图像中车辆的位置。一般车辆识别分为两大类:基于浅层学习的车辆识别和基于深度学习的车辆识别。其中,基于浅层学习的车辆识别主要通过人工设计的特征提取(如边缘检测、颜色直方图等)方法进行特征提取。传统基于浅层学习的车辆识别方法有帧间差分法^[6]、背景差分法^[7]以及光流法^[8]。但是传统的车辆识别均存在实时检测性差和过于依赖外部环境等局限性,现阶段的研究在传统方法上进行了改进。Hu等^[9]利用二色反射模分析图像,通过提取颜色特征对车辆进行识别,此方法不但可以去除噪声的干扰,而且对光照变化也有较强的鲁棒性。Behley等^[10]通过构建混合词袋模型,并且引入不同尺度的图像信息,实现了对多尺度车辆局部信息的表达,从而提高了车辆识别精度。徐骏骅^[11]基于 Lab 颜色空间转换和 Canny 边缘检测,建立了强识别器,以准确识别车辆。

虽然基于浅层学习的车辆识别方法可以满足一定的需求,但是其精确度仍然比不上基于深度学习的车辆识别。常见的基于深度学习的车辆识别模型包括深度置信网络、深度玻尔兹曼机、自编码器和卷积神经网络等。其中,Hu等^[12]结合手工特征和深度玻尔兹曼机方法,将方向梯度直方图等3种手工设计的特征作为输入,并通过学习融合各特征的优点,以提高识别精度。Shi等^[13]在深度置信网络结构的基础上,交替使用有监督和无监督过程训练,有效解决了梯度消失问题。康妙等^[14]将提取的25种基线特征和局部纹理特征融合,进入栈式自编码器训练,简化了网络结构,提高了识别精度。另外,基于卷积神经网络的改进模型^[15-18]也斩获了多个视觉识别挑战赛的冠军,其作为时下最重要的深度网络模型,同样发挥着重要的作用。Feyzabadi^[19]通过遮挡物处理,再利用卷积神经网络,提高了有物体遮挡汽车的识别精度。Song等^[20]在基于卷积神经网络的基础上使用 Adaboost 分类器进行车辆识别,检测正确率达到 98.08%。为了达到较高的识别精度,这些模型通常向着更深层结构、更复杂的方向发展。

本文提出结合车辆边缘联合建模,将边缘信息考虑到模型搭建中在进行边缘提取的过程中,不仅可以得到包含车辆特征信息最多的边缘图像,而且在一定程度上减少了边缘模糊背景产生的噪声。另外,本文将车辆原图像特征和车辆边缘图像特征进行融合,从而弥补了车辆特征在边缘提取时的缺失。

3 模型搭建

3.1 边缘特征联合建模

边缘检测是模仿人类视觉的一个过程,人类在识别车辆的过程中也是通过车辆边缘去提取车辆大小、车辆外形等车辆属性特征的。因此,本文提出联合车辆边缘特征进行建模。

E-CNN 结合原图像和边缘图像联合建模,模型构建过程如图1所示。模型总共由7部分构成:输入层、卷积层、池化层、特征融合层、全连接层、分类层以及输出层。首先,输入层分别输入原图像和边缘图像。输入的图像与卷积层中的神经

元局部连接,一方面减少了网络参数的数量,降低了时间复杂度;另一方面,提取了车辆的初级特征。卷积层的计算公式如下:

$$a_l = f(w_l * a_{l-1} + b_l) \quad (1)$$

其中, a_l 为第 l 卷积层的输出, $f(\cdot)$ 为卷积层的激活函数, w_l 为卷积核, $*$ 代表卷积操作, b_l 为偏置参数。通过卷积操作后得到特征提取图,特征提取图通过最大池化来降低特征提取图的数据维度,有效避免过拟合。最大池化使用局部最大池化,即选择图像区域的最大值作为该区域池化后的值。在充分提取特征后,将原图像提取到的特征图和边缘图像提取到的特征图进行融合,各特征图在融合层所占权重通过训练得到最优参数。特征融合方法如下:

$$G(x) = F(o_i)w_i \oplus F(e_j)w_j \quad (2)$$

其中, $G(x)$ 为融合层的输出,表示融合操作,将特征图按照给定轴进行连接; $F(o_i)$ 表示第 i 个原图像的特征图, $F(e_j)$ 表示第 j 个边缘图像的特征图; w 表示特征图所占权重。融合后的特征图与全连接层的每个神经元全连接,之后通过分类层进行分类。分类层使用 Softmax 分类器进行分类。Softmax 分类器 $P(y_i)$ 及其对应的多分类的对数损失函数 $J(\theta)$ 如下所示:

$$J(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{j=1}^k I\{y^{(i)} = j\} \cdot \log(P(y^{(i)} = j | x^{(i)}; \theta)) \right] \quad (3)$$

$$P(y^{(i)} = j | x^{(i)}) = \frac{\exp(\omega_j^T x)}{\sum_{k=1}^k \exp(\omega_k^T x)} \quad (4)$$

其中, m 表示训练集数量, ω 表示特征值权重, x 代表特征向量, k 表示分类的个数, $I\{\cdot\}$ 为指示性函数。




图1 E-CNN 模型结构

E-CNN 在训练过程中自动调整各层参数,经过调整后的参数可以有效地提取特征并进行融合;原图像特征和边缘图像特征各自所占权重也通过训练达到最优,互相弥补对方的不足,以达到更好的分类效果。

3.2 图像预处理

由于 E-CNN 要求输入层输入图像的大小要保持一致,但通过摄像头等方式采集到的样本没有办法做到大小一致,因此本文利用多相位图像插值(Lanczos)算法进行图像预处理。通过缩放尺寸计算新的像素点,在将图像缩放到目标大小的基础上,尽量保留原图像的特征。

假设 $f(i, j)$ 为缩放前的像素点, $g(u, v)$ 为缩放后的像素点,两像素点相差 (x, y) 坐标。其中, $x = (u \times W_{in}) \% W_{out}$, $y = (v \times H_{in}) \% H_{out}$ 。 W_{in} 和 W_{out} 分别为缩放前后的图像宽度, H_{in} 和 H_{out} 分别为缩放前后的图像高度。输出点 $g(u, v)$ 可由下式得出:

$$H_{out}(i, j) = \sum_{k=-1}^2 f(i, j+k) Lanczos2P_{V(k+1)} \quad (5)$$

$$g(u, v) = \sum_{l=-1}^2 H_{out}(i+l, j) Lanczos2P_{H(l+1)} \quad (6)$$

$$LanczosN(x) = \begin{cases} 1, & x=0 \\ \frac{\sin(\pi x)}{\pi x} \frac{\sin(\pi x/N)}{\pi x/N}, & x \neq 0, |x| < N \\ 0, & |x| \geq N \end{cases} \quad (7)$$

从上式中可以看出:实际上 Lanczos 图像缩放分为两步实现,分别进行垂直滤波和水平滤波。其中有关系式: $i = (u \times W_{in}) / W_{out}$, $j = (v \times H_{in}) / H_{out}$ 。图 2 为在 4×4 范围内进行的 Lanczos 算法缩放示意图。




图 2 预处理示意图

图 2 中,水平相位值为 $P_{H0}, P_{H1}, P_{H2}, P_{H3}$;垂直相位值为 $P_{V0}, P_{V1}, P_{V2}, P_{V3}$ 。根据上述关系式就能获得 8 个相位值,从而实现多相位滤波。原图像与经过缩放后的图像如图 3 所示,图 3(a)为像素值为 300×240 的原图像,图 3(b)为缩放后的像素值为 64×64 的图像。



图 3 图像缩放对比

3.3 图像边缘获取

车辆拥有外形、大小、颜色等属性特征,这些属性特征都是进行车辆识别时的重要考量依据。其中,车辆的外形和大小等重要信息都包含在车辆的边缘信息中。因此,本文提出提取车辆的边缘图像联合原图像进行建模,以加快模型收敛,并提高识别正确率。

首先,为了去除图像中单独像素噪声对边缘检测的影响,本文选取 $k \times k$ 大小的滑动窗口对原图像 I 进行平滑滤波,获得平滑图像 I_0 :

$$I_0 = I * G \quad (8)$$

$$G_i = \alpha \exp\left(\frac{-(i - \frac{k-1}{2})^2}{2\sigma^2}\right) \quad (9)$$

其中, $i=0,1,\dots,k-1$; $*$ 表示卷积操作; α 为标度因数,用来控制 $\sum G_i = 1$; 标准差 $\sigma = 0.3 \times ((k-1) \times 0.5 - 1) + 0.8$ 。

得到平滑图像后,计算图像中每个像素点的梯度幅值和方向,保留每个像素点和同方向的其他像素点中梯度幅值最大的点来细化边缘线条。梯度幅值 G 和方向 θ 的计算方法如下所示:

$$G = \sqrt{G_x^2 + G_y^2} \quad (10)$$

$$\theta = \arctan\left(\frac{G_y}{G_x}\right) \quad (11)$$

$$\text{其中, } G_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix} * I_0, G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ +1 & +2 & +1 \end{bmatrix} * I_0。$$

为细化目标边缘,还需使用非极大值抑制方法进行边缘稀疏操作,如果待计算像素点大于同方向邻近的两个像素点,则保留该像素点,否则抑制该像素点。然后设置滞后阈值,只保留高于阈值的像素点和阈值内与其相邻的像素点。进一步消除图像中的噪声点,最后抑制孤立点,去除与强边缘点相隔距离较远的弱边缘点,以得到如图 4 所示的车辆边缘图像。



(a)原图像

(b)边缘图像

图 4 车辆边缘提取效果图

4 实验与性能分析

4.1 样本库的建立

本文使用了斯坦福大学的 ImageNet 数据集和文献[19]中的数据,从中选取了 8588 张车辆图像以及 11375 张背景图像,并按照记录仪记录的真实场景中车辆的尺寸将所有样本图像统一裁剪为 64×64 像素大小的图像,从而组成了一套原图像数据集。另外,E-CNN 模型需要结合边缘图像联合建模,所以本文按照 3.3 节提出的方法对原图像数据集进行边缘提取,将提取到的车辆边缘图像以及背景边缘图像组成了一套边缘图像数据集。其中,每套数据集中训练集样本占样本总数的 80%,测试集样本占样本总数的 20%。部分车辆和背景的原图像以及边缘图像如图 5 所示。



图 5 部分样本图像

将样本库中的图像分为车辆图像和背景图像两类。其中,样本库图像标签标记时不区分原图像和边缘图像,仅根据车辆和背景标签进行标注。表 1 所列为原图像数据集标注结果,边缘图像数据集标注与原图像数据集标注结果相同。


表 1 样本标签统计

	图像类别	标签	样本数量
训练集	背景	0	9100
	汽车	1	6870
测试集	背景	0	2275
	汽车	1	1718


4.2 参数设置

深度学习中模型参数的调整对实验结果的影响很大,因此本节通过实验结合往常经验进行参数设置,使模型结构达到最优。E-CNN 采取原图像和边缘图像联合建模的方法,模


型输入层分别输入大小为 64×64 的原图像以及边缘图像。卷积核尺寸首先按照现有默认的参数(分别为第一层: 5×5 , 第二层: 3×3 , 第三层: 3×3)输入的图像分别经过卷积层和最大池化层提取特征,之后通过改变不同卷积层的卷积核尺寸选取最优的卷积核尺寸进行模型搭建。各卷积层参数对特征提取效果的影响如图 6 所示。



(a) 第一层卷积核对实验结果的影响



(b) 第二层卷积核对实验结果的影响



(c) 第三层卷积核对实验结果的影响

图 6 卷积核参数的对比

通过图 6 可以看出随着网络深度的加深,图像信息更为抽象,因此选用不同卷积核尺寸会产生不同的实验结果。从中选取效果最好的卷积核尺寸设置,如表 2 所列。特征融合层将提取到的特征图融合到一起,融合层中的各特征图所占权重通过训练自动调整,以得到边缘特征和车辆其他特征优势互补的最佳权重。全连接层设置 500 个神经元与特征融合层的每个特征图全连接,使得每个提取到的特征图都参与最后的分类。

表 2 卷积层参数的设置

	第一层	第二层	第三层
边缘图像	5×5	4×4	3×3
原图像	5×5	4×4	3×3

4.3 实验结果的对比

本文首先搭建并对比了单独的车辆图像模型、车辆边缘图像模型以及 E-CNN 模型,实验结果如图 7 所示。由于车辆边缘图像模型仅仅关注图像的边缘信息,从而导致了颜色特征等一些特征信息的丢失,所以单独考虑边缘信息不能充分提取车辆特征,很难使模型达到理想的正确率。另外,在单独的车辆图像模型中,颜色特征等边缘信息中不包含的特征可能会在识别中占主导地位,造成识别错误,如背景颜色单一的车辆图像可能会被误判为背景图像。E-CNN 有效地融合了

车辆原图像和车辆边缘图像,使得 E-CNN 的鲁棒性更好。由图 7 也可以看出 E-CNN 在训练过程中的整体识别正确率高于其他两种模型,并且其识别正确率的稳定性要优于其他两种模型定。






图 7 模型融合前后的对比

为了测试验证本文提出的结合车辆边缘联合建模方法的性能,本文搭建了 VGG16 以及 GoogLeNet 模型进行实验并与本文模型进行比较。由图 8(a)可以看出,由于 VGG16 和 GoogLeNet 通过搭建复杂的模型结构来提高识别精度,随着模型深度的增加,计算量成倍增加。而 E-CNN 以较少的层数通过多特征联合来提高识别精度,所以 E-CNN 模型在较短的时间内训练就可以达到 VGG16 以及 GoogLeNet 等模型的识别精度。由图 8(b)可以看出,E-CNN 模型有效地联合了多特征,提高了使得模型精度,当模型正确率稳定后,E-CNN 模型的正确率整体上高于 VGG16 和 GoogLeNet 模型。



(a) 收敛速度的对比



(b) 正确率对比

图 8 不同模型收敛速度对比

表 3 分别从正确率、F-measure 和响应时间上对比了 E-CNN, Adaboost+CNN, Vgg16 以及 GoogLeNet 4 种模型。从表 3 可以看出,由于 Adaboost 是一种迭代分类器,需要大量的时间去训练不同的弱分类器,因此在相同的时间内,Adaboost+CNN 模型只能达到 97.02% 的正确率,远低于 E-CNN 的 99.90%。E-CNN 的正确率 99.90% 高于 VGG16 的 99.82% 和 GoogLeNet 的 99.35%,并且 E-CNN 的 F-measure 99.84%,也明显高于 VGG16 的 99.78% 和 GoogLeNet 的 99.36%。另外,E-CNN 的响应速度比 Adaboost 快 2 倍,比 VGG16 快 5 倍,比 GoogLeNet 快 8 倍,这就使得 E-CNN 更适用于监测车辆拥堵或者图像中有大量车辆的场景。

表3 不同模型的对比

方法	正确率/%	F-measure/%	响应时间/ms
E-CNN	99.90	99.84	16
Adaboost+CNN	97.02	99.51	40
VGG16	99.82	99.78	91
GoogLeNet	99.35	99.36	133

结束语 本文提出的 E-CNN 结合车辆原图像和车辆边缘图像联合建模,利用边缘检测算法提取边缘图像,一方面人为给定有效特征以加速模型收敛,另一方面在提取边缘图像时可以减少噪音。为了弥补因边缘提取时其他特征的缺失,E-CNN 将边缘图像和原图像提取到的特征进行融合,并将融合后的特征联合进行分类。通过对比 VGG16 和 GoogLeNet 模型,E-CNN 可以在有效时间内收敛,并且达到了 99.90% 的精度,高于 VGG16 的 99.82% 和 GoogLeNet 的 99.35%,已经可以满足正常需求。另外,E-CNN 具有模型简单、搭建成本低和对硬件要求低等优势,更适合广泛应用在智能交通系统中。

参考文献

[1] 刘肃亮. 交通车辆违章智能视频监控系统的设计与实现[D]. 西安:西北大学,2004.

[2] 艾永春. 拥挤场景下低分辨率快速车辆检测与跟踪方法研究[D]. 成都:电子科技大学,2014.

[3] 赵起超. 无人车视觉导航中的前方车辆检测方法研究[D]. 南京:南京理工大学,2017.

[4] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]// IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2015:1-9.

[5] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional Networks for Large-Scale Image Recognition[J]. arXiv:1409.1556.

[6] COLLINS R T, LIPTON A J, KANADE T. Introduction to the special section on video surveillance[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2000, 22(22): 745-746.

[7] LONG W, YANG Y H. Stationary background generation: An alternative to the difference of two images [J]. Pattern Recognition, 1990, 23(12): 1351-1359.

[8] 向川平. 基于光流场的视频运动检测研究[D]. 成都:西华大学, 2011.

[9] HU W, BAI L. A new approach for vehicle color recognition based on specular-free image[C]// Proceedings of SPIE-The International Society for Optical Engineering. 2013; 90671Q-90671Q-5.

[10] BEHLEY J, STEINHAGE V, CREMERS A B. Laser-based segment classification using a mixture of bag-of-words[C]// Ieee/rsj International Conference on Intelligent Robots and Systems. IEEE, 2013: 4195-4200.

[11] 徐骏骅. 基于边缘检测与模式识别的车脸识别算法[J]. 控制工程, 2018(2): 357-361.

[12] AIQIN H U, HONG L I, ZHANG F, et al. Deep Boltzmann Machines based Vehicle Recognition[C]// Control and Decision Conference. IEEE, 2014: 3033-3038.

[13] SHI T, ZHANG C, LI F, et al. Application of alternating deep belief network in image classification[C]// Control and Decision Conference. IEEE, 2016: 1853-1856.

[14] 康妙, 计科峰, 冷祥光, 等. 基于栈式自编码器特征融合的 SAR 图像车辆目标识别[J]. 雷达学报, 2017, 6(2): 167-176.

[15] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]// International Conference on Neural Information Processing Systems. Curran Associates Inc., 2012: 1097-1105.

[16] ZEILER M D, FERGUS R. Visualizing and Understanding Convolutional Networks[J]. European Conference on Computer Vision, 2013, 8689: 818-833.

[17] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]// IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2015: 1-9.

[18] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition[C]// Computer Vision and Pattern Recognition. IEEE, 2016: 770-778.

[19] FEYZABADI S. Joint Deep Learning for Car Detection[J]. arXiv:1412.7854.

[20] SONG X, RUI T, ZHA Z, et al. The AdaBoost algorithm for vehicle detection based on CNN features[C]// International Conference on Internet Multimedia Computing and Service. ACM, 2015: 5.

(上接第 241 页)

[2] DU S, IBRAHIM M, SHEHATA M. Automatic License Plate Recognition (ALPR): A State-of-the-Art Review [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2013, 23(2): 311-325.

[3] 钟菲, 杨斌. 基于主成分分析网络的车牌检测方法[J]. 计算机科学, 2018, 45(3): 270-275.

[4] 李彦, 张洪博, 石莲英. 基于 SIFT 特征匹配的车牌识别方法[J]. 计算机工程与应用, 2016, 52(12): 194-200.

[5] 瞿中, 常庆丽, 王永昆, 等. 改进的车牌相似字符分级分类识别算法研究[J]. 计算机工程与设计, 2013, 34(4): 1336-1340.

[6] 罗辉武, 唐远炎, 王翊等. 基于结构特征和灰度特征的车牌字符

识别方法[J]. 计算机科学, 2011, 38(11): 267-302.

[7] 焦娜. 基于软 K 段主曲线的 LPR 字符特征的提取方法[J]. 计算机科学, 2017, 44(9): 49-52.

[8] 贾文其, 李明, 朱美强等. 基于栈式降噪自编码神经网络的车牌字符识别[J]. 计算机工程与设计, 2016, 37(3): 750-756.

[9] 施隆照, 强书连. 基于组合支持向量机的车牌字符识别[J]. 计算机工程与设计, 2017, 38(6): 1619-1623.

[10] 平源, 李慧娜. 快速精确识别车牌字符的方法[J]. 计算机工程与设计, 2008, 29(9): 2410-2412.

[11] 何兆成, 余锡伟, 余文进, 等. 字符多特征提取方法及其在车牌识别中的应用[J]. 计算机工程与应用, 2011, 47(23): 228-231.