

DOI:10.19651/j.cnki.emt.2106833

基于极性检测和改进 CNN 框架的车牌识别方法*

李 娅 王兴路 雷 蕾 上官望义
(西安航空学院 车辆工程学院 西安 710077)

摘要: 为了提高车牌自动识别的性能和适用性,提出一种基于前景极性检测和改进卷积神经网络(CNN)的车牌识别方法。所提方法包含两个主要模块:字符分割模块和字符识别模块。在字符分割模块中,基于 RGB 颜色的前景极性检测进行二值化处理 and 感兴趣区域(ROI)的分割,然后进行字符高度估计和倾斜校正等处理。在字符识别模块中,通过包含聚合模块的多通道深度 CNN 框架提取深度特征,提高输出特征的表征能力。实验结果表明,所提方法具有较好的识别精度,在较难的 SSIG 测试集和 AOLP 数据集上分别获得 92.2% 和 94.1% 的识别率,且在一些极端情况下优于商业的车辆门禁系统。

关键词: 车牌自动识别;卷积神经网络;字符分割;字符识别;感兴趣区域

中图分类号: TP391.41 **文献标识码:** A **国家标准学科分类代码:** 520.6020

Research of license plate recognition method based on polarity detection and improved CNN framework

Li Ya Wang Xinglu Lei Lei Shangguan Wangyi

(School of Vehicle Engineering, Xi'an Aeronautical University, Xi'an 710077, China)

Abstract: To improve the performance and applicability of license plate recognition, a license plate recognition method based on foreground polarity detection and improved convolutional neural network (CNN) is proposed. The proposed method consists of two main modules: character segmentation module and character recognition module. In the character segmentation module, foreground polarity detection based on RGB color is used for binarization and ROI segmentation, and then character height estimation and skew correction are performed. In the character recognition module, the depth features are extracted by the multi-channel deep CNN framework including the aggregation module to improve the representation ability of the output features. The experimental results show that the proposed method has good recognition accuracy, and the recognition rate is 92.2% and 94.1% respectively on the more difficult SSIG test set and aolp data set, and it is superior to the commercial vehicle access control system in some extreme cases.

Keywords: automatic license plate recognition; convolutional neural network; character segmentation; character recognition; ROI

0 引 言

车牌自动识别^[1](atuomated license plate recognition, ALPR)是智能交通领域的重要研究课题。执法机关可利用 ALPR 进行交通检测,拥堵控制,边境安全,可疑车辆检测等。此外,ALPR 还可以被用于智能停车场和智能收费站,以支持车辆灵活出入,确保交通顺畅,提高安全性^[2]。ALPR 一般首先进行车辆检测,然后进行车牌检测,接着对车牌的字符进行识别。如何有效进行车牌检测和字符识别是研究的关键所在,且需要具有较好的实际应用性能。

一般来说,影响到车牌字符分割和识别的因素包括照明变化、旋转、阴影、边缘字符等。不同国家有着不同的车牌标准,例如不同的背景和前景颜色,包含不同形状和字体的复杂背景,且车牌和字符的形状和大小也有差别,有些国家还支持定制化车牌,进一步增加了识别难度^[3]。目前已有一些研究成果。如文献[4]利用模板匹配进行光学字符识别(optical character recognition, OCR),但该方法不能很好处理不同字体、噪声、旋转和粗细变化。林国聪等^[5]采用统计像素法对车牌图像进行定位,对已定位好的车牌图像进行二值化,对处理过的车牌图像字符进行分割,并采用

收稿日期:2021-06-01

* 基金项目:陕西省教育厅专项科研项目(20JK0695)资助

模板匹配法对分割好的车牌字符进行识别,但这种方法对于倾斜字符的匹配难以有效。Khan 等^[6]利用 CIE-LAB 颜色空间以及支持向量机对车牌进行字符提取,但该方法对阴影非常敏感。丁进超等^[7]提出一种基于双向长短期记忆网络的车牌字符识别方法,利用双阈值法对图片中车牌的候选区域进行自适应阈值分割,搭建 Bi-LSTM 模型,将车牌内整个字符串作为系统的识别目标。Laroca 等^[8]利用改进的 YOLO 探测器,针对中国和巴西车牌完成车牌识别任务。Bjorklund 等^[9]利用合成图像对 2 个卷积神经网络(convolutional neural network, CNN)进行训练,实现稳健的车牌识别,虽然该方法有能力执行该任务,但需要大量训练数据。

为了适应更多类型和一些极端情况下的车牌检测与识别任务,本文提出了一个自适应阈值的车牌识别框架。框架中包括两个重要组成部分:字符分割模块和基于改进 CNN 的字符识别模块。第 1 个模块中,提出基于 RGB 颜色的前景极性检测模型,以有效完成车牌字符分割任务。在第 2 个模块,提出了多通道改进的 CNN 框架及层聚合模块,以提取深度特征,提高识别性能。实验结果表明,所提的车牌识别方法能够在多种情况下,很好地识别不同形状和布局,具有不同的背景/前景颜色的车牌字符。

1 自适应车牌识别的整体框架

所提方法的基本框架如图 1 所示。对于输入的车辆图像(正前面或正后面),首先利用 Yolo v3(Yolo 系列的第 3 版)快速目标检测器^[10]进行车牌检测,定位车牌的位置,从而获得车牌图像;然后,将分割后的图像分解为红、绿、蓝通道;接着,将其通过极性匹配模块,均匀处理数据,以消除车牌的前景极性变化的影响。为了分层次地学习特征,将这些分离后的通道图像馈入本文 CNN,并得到输出向量,将输出向量级联起来,以获得增强后的图像特征信息。在将输出特征向量发送到分类器之前,本文引入了一个数据标准化模块,以优化输出得分。最后,将标准化的特征向量馈入分类器,得到目标标签。

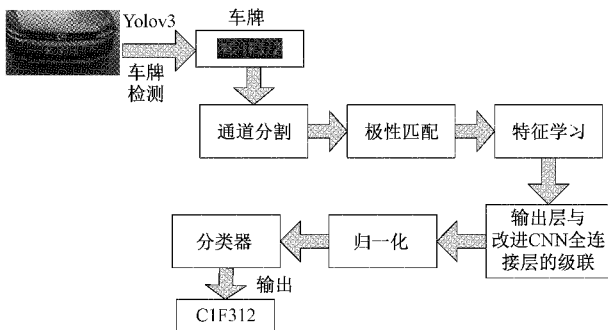


图 1 所提方法的基本框架

本文所提方法主要包括车牌字符分割和车牌字符识别模块。其中,字符分割采用一种具有一定倾斜校正的前景

性检测方法,字符识别采用改进的 CNN 网络学习方法。下面就这两个核心模块进行介绍说明。

2 核心模块介绍

2.1 车牌字符分割

本文车牌字符分割的完整过程如图 2 所示,该过程分为两个模块。模块 A,分割出感兴趣区域(region of interest, ROI),以缩小图片处理面积,丢弃大量冗余信息。模块 B,应用所提出的字符高度估计过滤器与连通组件分析,以提取所需目标。

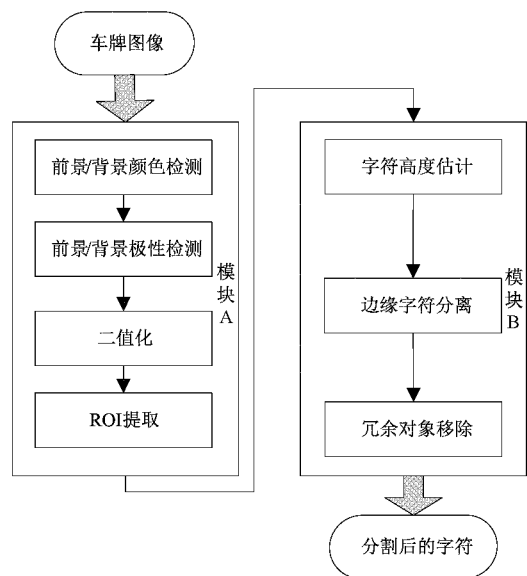


图 2 本文车牌字符分割流程图

首先,将检测到的车牌图像馈入图 1 的模块 A,进行前景和背景分类。前景和背景区分是目标分割中难度最大的步骤。需要识别背景/前景颜色和极性,并由此进行进一步分割处理。“极性”指的是基于前景/背景颜色强度的亮色或暗色。大部分车牌会使用单一的前景和背景颜色。理论上,最大的颜色候选区域属于背景区域,第二大的颜色候选区域属于前景区域,本文将此作为前景背景分类的关键点,使用 RGB 颜色空间,在各种照明条件下识别颜色。

我国目前常用的车牌(部分)示意图如图 3 所示。由图 3 可知,不管什么类型的车牌,其背景和前景颜色为已知,因为最大的候选像素组属于背景,第二大的候选颜色组属于前景,如“蓝牌”,最大像素组是蓝色像素,前景是白色像素组成的字符图像。利用该信息确定前景极性以进行后处理,该信息对于自适应阈值化和大部分形态运算来说非常重要。

自适应阈值化技术要求前景极性的先验知识,以精确区分背景和前景,形态运算也需要该信息以得到所需结果。前景极性检测伪代码如算法 1 所示。其中, \max_1 和 \max_2 分别表示车牌背景和前景。




图 3 我国目前常用的车牌示例图

算法 1 前景极性检测伪代码

```

Input 1: max1 //表示属于车牌背景的颜色像素数
Input 2: max2 //表示属于车牌前景的颜色像素数
if (max1 & max2) CG1
    if max1 (Ind) > max2 (Ind)
        FP ← bright //FP 表示前景极性
    else
        FP ← dark
    end
else if (max1 CG1 & max2 CG2) || (max1 CG2 & max2 CG1) Output:
    FP ← find {CG2(Ind)}
end
    
```

$$CG1_{mean} = \frac{1}{N} \sum_{i=1}^N V_{CG1(i)} \quad (1)$$

$$CG2_{mean} = \frac{1}{N} \sum_{i=1}^N V_{BW(i)} \quad (2)$$

$$CG2(Ind) = \begin{cases} 1, & CG1_{mean} < CG2_{mean} \\ 2, & CG1_{mean} > CG2_{mean} \end{cases} \quad (3)$$

其中,上述公式中的下标 mean 表示均值;Ind 表示颜色序列;CG1_{mean} 表示前景像素亮度均值;CG2_{mean} 表示背景像素亮度均值。

上述操作之后,将 RGB 图像转换为二值图像 $BI(x, y)$ 。为此,首先利用标准转换,将图像转换为灰度图像(GI),然后利用局部平均强度(一阶统计),使用实时自适应阈值化进行二值转换。与 OTSU^[11]或其他基于两个类内方差来分离背景和前景的方法相比,该阈值化技术更适用于阴影和照明变化的环境。

$$BI(x, y) = \begin{cases} 1, & GI(x, y) < \frac{\sum_{i=x-m/2}^{x+m/2} \sum_{j=y-n/2}^{y+n/2} GI(i, j)}{nm} \\ 0, & GI(x, y) \geq \frac{\sum_{i=x-m/2}^{x+m/2} \sum_{j=y-n/2}^{y+n/2} GI(i, j)}{nm} \end{cases} \quad (4)$$

$$Ns = 2 \times \text{floor}(\text{size}(I)/16) + 1 \quad (5)$$

式中:Ns 表示域的大小;size()表示求集合大小的函数。在得到二值图像后,通过式(6)将车牌背景极性变为亮色:

$$B_I(x, y) = \begin{cases} B_I(x, y), & FP = Dark \\ \bar{B}_I(x, y), & FP = Bright \end{cases} \quad (6)$$

其后,通过丢弃车牌的冗余区域,提取出仅包含所需字符的 ROI。设 I 为给定的两个类型(type1 和 type2,分别对应白色和黑色对象)的对象集合,则所需区域(R_R)可提取如下:

$$R_R = \{R\} \quad (7)$$

式中: R 为 I 中 type1 的最大连通集。

在不同车牌的字符分割中,字符高度估计非常重要,该步骤之前,本文已通过提取所需的背景区域,丢弃了大量的车牌冗余区域。为完成该任务,提出了一种自适应方法以估计车牌高度:

$$H_{O_{h_i}} = \{O_{h_i} \mid h_i = \pm 20\% \text{ of } h_{max}; i = 1, 2, \dots, n\} \quad (8)$$

式中: $H_{O_{h_i}}$ 是用于保持特定高度对象的集合; h_{max} 为车牌的提取区域(R_R)中所有检测到的包围框的最大高度; O_{h_i} 是根据高度标准 h_i 选择出的目标对象。将下一个包围框对象与 h_{max} 相比较,若其高度为 h_{max} 的 $\pm 20\%$,则将其考虑为所需对象。若该包围框对象不满足标准,则上一个有着最大高度的包围框将被丢弃,并将最新的包围框考虑为后续处理中的最大高度对象。继续该过程,直至所有所需对象均被提取。通过该方法,自动移除所有过大和过小的对象,仅保留所需对象(即车牌字符)。

在得到所需对象的高度后,利用该信息,通过式(9)进行倾斜纠正。从而提升系统在分割阶段和识别阶段的性能。

$$CA_{i,p} = \arctan\left(\frac{y_{RM(O_{h_i})} - y_{LM(O_{h_i})}}{x_{RM(O_{h_i})} - x_{LM(O_{h_i})}}\right) \quad (9)$$

式中: $y_{RM(O_{h_i})}$ 和 $y_{LM(O_{h_i})}$ 分别为检测对象的最右侧和最左侧的 y 轴数值, $x_{RM(O_{h_i})}$ 和 $x_{LM(O_{h_i})}$ 分别为检测对象的最右侧和最左侧的 x 轴数值。

通过利用集合 $H_{O_{h_i}}$ 中对象的上界和下界的信息,分离边缘字符。最后一步,移除剩余的冗余信息,得到所需车牌字符上的包围框。

2.2 基于改进 CNN 的字符识别

本文利用深度学习框架来完成车牌字符识别任务。CNN 已被证明能够有效完成图像识别分类的神经网络类别,甚至可以进行故障分类和预测的困难任务^[12]。每个神经元接收一些输入,执行点积运算。整个网络仍然表达着一个单一的可微分函数:从一端的原始图像像素到另一端的类分数,且最后一层(全连接层)包含一个损失函数。

使用预训练网络作为起始点以学习新任务。通常来说,利用迁移学习对网络进行微调,并从头开始利用随机初始化权重训练网络的速度要快得多。可以使用较少数量的训练图像,将习得的特征快速迁移到新的任务中。一些知名的预训练网络有 AlexNet^[13], GoogleNet^[14], ResNet^[15]等。本文研究针对实时应用,因此速度是一个重要参数,选择 AlexNet-CNN 作为迁移学习的基础网络。

深度神经网络中,高级卷积层的特征表示更加全面,但空间信息不足,而浅层保留了空间信息,但表达性特征较差。一般来说,全连接(full connection, FC)层使用来自最后一个卷积层的特征,并用于进一步的分类。在卷积神经网络中,最大池化为下采样策略。由此,得到的空间信息在下采样过程中可能会丢失。梯度消失是深层网络中可能会出现的一个问题。在识别和检测任务中,可利用不同卷积层的集体特征信息,提高网络性能,并减少信息丢失情况。此外,可通过深度层聚合的概念来改善收敛时间。由此,本文提出了基于 AlexNet 的改进 CNN,该网络是一个轻量级网络,比原 CNN 网络更小。本文改进的轻量级 CNN 网络结构如图 4 所示,具体参数配置如表 1 所示。在改进的 CNN 中,对第 4 和第 5 卷积层的特征进行合并,引入一个额外的最大池化层,以匹配两个卷积层的特征尺寸。




图 4 本文改进的轻量级 CNN 网络结构

表 1 本文改进的 CNN 的参数配置

层	配置			
输入	FM:1	OS:227×227×3	KS:—	S:—
Conv1	FM:96	OS:55×55×96	KS:11×11	S:4
最大池化层 1	FM:96	OS:27×27×96	KS:3×3	S:2
Conv2	FM:256	OS:27×27×256	KS:5×5	S:1
最大池化层 2	FM:256	OS:13×13×256	KS:3×3	S:2
Conv3	FM:384	OS:13×13×384	KS:3×3	S:1
Conv4	FM:384	OS:13×13×384	KS:3×3	S:1
最大池化层 3	FM:384	OS:6×6×384	KS:3×3	S:2
Conv5	FM:256	OS:13×13×256	KS:3×3	S:1
最大池化层 4	FM:256	OS:6×6×256	KS:3×3	S:2
级联	OS:6×6×640		Layer4	Layer5
FC6	OS:1×1×4 096			
FC7	OS:1×1×4 096			
FC8	OS:1×1×3			

3 实验结果与分析

本文使用 MATLAB 2011b,在 Intel® Core™ i5 CPU, GTX 1080Ti GPU 的平台上进行特征提取和评估。实验比较了几种优秀的车牌识别方法,同时对一些商用系统进行比较分析。

3.1 数据集与评价指标

本文选择了 2 个公开的数据集,即 SSIG^[16] 和 AOLP^[17](路面巡逻),这两个数据集包含了很多不同场景的车牌识别,有国内车牌也有国外车牌,其具体信息如表 2 所示。

在上述两个数据集中,AOLP 数据集的采集较难,信息十分丰富,拥有不同角度拍摄的车牌,很多图像是在巡逻车辆上(或手持)拍摄获得,除了高清图像外,还包含了

表 2 数据集信息列表

数据集	车牌情况	车辆 距离	图像 数量	采集 地区
SSIG 测试集	大多为正面	中、远	804	巴西,欧洲
AOLP 数据集	正面+倾斜	近	611	中国

低分辨率图像,以及受到不同天气和照明条件影响的图像,部分车牌图像中还包含阴影、部分阴影和模糊区域。SSIG 数据集是中远距离拍摄获得,但图像分辨率依然较高,具备较好的可视性。一些示例图像如图 5 所示。

车牌识别的准确度定义如下:

$$Acc = \frac{MC}{T} \quad (10)$$

其中,MC 表示检测到车牌上所有字符,且这些字符识



图 5 不同车牌的示例图像

别准确; T 表示车牌的总数量。从上述公式可以看出一次准确的检测必须包含: 1) 字符被准确分割, 没有漏分割; 2) 没有检测到额外的字符; 3) 这些字符在字符识别模块中被准确识别。

3.2 不同层聚合模块分析

CNN 模块是本文方法的核心, 从车牌图像中提取特征时发挥着关键作用, 决定了识别性能。为此, 本文通过使用层聚合模块, 融合低级和高级特征, 评估四个不同的改进型 CNN 结构。这四个模型分别为 CNN_{C15} , CNN_{C25} , CNN_{C35} 和 CNN_{C45} , 其中, CNN_{C15} 表示将卷积层 1 的特征图与卷积层 5 相级联。 CNN_{C25} 表示将卷积层 2 的特征图与卷积层 5 相级联。 CNN_{C35} 表示将卷积层 3 的特征图与卷积层 5 相级联。 CNN_{C45} 表示将卷积层 4 的特征图与卷积层 5 相级联。 CNN 表示基础结构, 其仅输出卷积层 5 的特征图。其具体结构如图 6 所示, 其中, C 表卷积, P 表示池化层。




图 6 不同的层聚合结构

在 SSIG 测试集和 AOLP-RP 路面巡逻数据集中, 采用不同层聚合模块和传统模型的结果比较如表 3 所示。从中可知, 与 CNN, CNN_{C15} , CNN_{C25} 和 CNN_{C35} 相比, 采用 CNN_{C45} 模型的神经网络具有更好的字符识别性能。与 CNN_{C45} 相比, CNN_{C15} , CNN_{C25} 和 CNN_{C35} 可能依然包含大量的背景噪声, 由此导致系统性能下降, 因此, 后续实验使用 CNN_{C45} 作为优选模块, 其能够处理更全面、更合适的特征, 从而增强原始图像的特征信息, 提高识别准确度。

表 3 不同层聚合模块的识别准确度 %

模块	SSIG 测试集	AOLP 数据集
CNN	89.5	88.9
CNN_{C15}	86.7	86.3
CNN_{C25}	88.2	87.8
CNN_{C35}	91.5	91.1
CNN_{C45}	92.9	92.3

3.3 车牌识别结果比较

在车牌识别阶段中, 需要对从车牌提取出的每个字符进行单独识别。本文使用改进 CNN 模块中的分类函数进行分类, 在训练过程中使用包含 37 个类别 (0-9, A-Z, EC) 的 84 058 个字符的数据库, 每个类别约包含 2 250 个字符。其中, EC 表示额外分类, 设置 EC 类别的目的是消除错误分割的字符。为支持不同类型的车牌识别, 并证明提出的框架的有效性, 在训练过程中采集同一类型的车牌字符, 并使其适用于测试数据。所有训练数据均由灰度图像组成, 以消除颜色的影响, 且所有图像均为暗色前景极性, 从而实现均匀性, 使得系统更具有通用性。使用所提方法识别出的一些典型车牌示例如图 7 所示, 包含了国内和国外车牌。由图 7 可知, 对于一定角度倾斜, 甚至部分遮挡、光线较暗的情况下, 所提方法依然能够准确检测并识别出车牌的信息。这说明本文方法有效地分割字符, 并没有错误分割和额外分割, 且 CNN 学习框架可以较好地学习字符特征, 提高了 OCR 准确度。




图 7 一些典型的车牌识别示例

为了展开进一步分析, 本文另外构建一个数据集, 该数据集是自采集的车牌图像, 拥有 225 个不同类型的车牌图像。这些图像有正面拍摄, 也有侧面拍摄; 有正常光线情况下, 也有灰暗情况下的图像采集。

此外, 为了说明对于具有一定倾斜车牌包围框的识别

性能,实验比较了校正和未校正两种情况的结果,其目的是验证本文方法对倾斜拍摄的字符识别性能。不同方法在不同数据集上的识别准确率如表 4 所示。可以看出,本文方法在包围框校正(均值 93.4%)和未校正情况(均值 92.1%)下,均取得了不错的识别准确率,这说明所提方法具有一定的抗包围框倾斜能力,这反映了改进 CNN 网络对于数字和字母倾斜的特征学习能力优秀。文献[5]采用统计像素法对车牌图像进行定位,采用模板匹配法进行 OCR,这种方法的字符识别较为传统,对于扭曲倾斜、光线较为敏感。文献[8]利用改进的 YOLO 探测器进行车牌识别,总体识别较为稳健。文献[9]通过 2 个卷积神经网络(CNN)进行车牌识别,虽然该方法可以较好地执行检测识别任务,但训练量很大。本文方法拥有最高的识别准确率主要得益于两方面。一是较好的字符分割模块,该模块通过前景极性处理和 ROI 提取,准确分割字符目标,避免了错分割和多分割;二是较好的字符识别模块,改进 CNN 框架可以准确地表征字符特征,学习不同字符特性,提高 OCR 准确度。

表 4 不同方法的车牌识别准确率 %

对比的方法	SSIG 测试集	AOLP 路面巡逻	自采集 数据集	均值
所提方法(有校正)	93.3	95.7	91.1	93.4
所提方法(未校正)	92.2	94.1	90.2	92.1
文献[5]	85.5	—	—	—
文献[8]	91.3	92.1	—	—
文献[9]	90.3	90.8	—	—

3.4 与一些商用门禁系统的比较

车牌识别经常使用在停车场或居民区的门禁系统中,这些商用的车牌识别系统大多采用较为简单快速的识别方法,OCR 方法较为传统,本文比较了道尔智控、森诺智能两种商用车辆门禁系统进行比较,选在上午光线柔和的时候,采用高清 CCD 相机在相同角度上采集车牌图像。本文遴选 100 幅较大倾斜情况下的车牌图像,字符检测的可接受阈值与识别准确率的关系如图 8 所示。可以看出,当字




图 8 较大倾斜情况下的识别性能比较

符检测可接受阈值在 4.0~4.5 之间,3 种方法基本达到了最佳准确率。在相对较差的情况下,所提方法的优势更大,森诺智能和道尔智控系统需要严格的拍摄角度,值得一提,对于新能源牌照的识别准确度明显较低,这是因为该类型的牌照背景色较难分离。而本文方法在字符分割方面能够很好地适应阴影和不同背景色,同时,利用改进 CNN 框架可以更好地表征字符特征,防止信息丢失,提高 OCR 准确度。

4 结 论

本文提出了一种自适应车牌识别方法,包含了一个前景极性检测模型,根据前景和背景的颜色进行分类,该模型在字符分割阶段和字符识别阶段均发挥着重要作用,且能够很好地适应阴影和照明条件的变化。同时,本文提出了多通道处理和改进 CNN 架构用以提取深度特征,通过神经网络分类器得到输出标签。所提方法增强了神经网络的识别性能,显著提升多种车牌的识别准确率。未来,本文将考虑一些极端情况下的车牌识别,如扭曲程度较大的拍摄图像,如何解扭曲是解决该问题的关键。

参考文献

- [1] 牛进才,余建立,李孟君. 车辆牌照识别算法的研究与实现[J]. 电子测量技术, 2018, 41(6):45-49.
- [2] 陈炫烽. 复杂环境下车牌自动识别系统的研究及实现[D]. 北京:北京邮电大学, 2019.
- [3] MA L, ZHANG Y. Research on vehicle license plate recognition technology based on deep convolutional neural networks [J]. Microprocessors and Microsystems, 2021, 82(8): 32-43.
- [4] 景亮,康青杨,唐潞轩,等. 基于模板匹配的 OCR 识别方法: CN106682698A[P]. 2017-05-17.
- [5] 林国聪,王冬青,薛斌强,等. 基于彩色图像信息的车牌自动识别系统仿真研究[J]. 青岛大学学报(工程技术版), 2019, 34(4): 24-28.
- [6] KHAN M A, SHARIF M, JAVED M Y, et al. License number plate recognition system using entropy based features selection approach with SVM[J]. Iet Image Processing, 2018, 12(2): 200-209.
- [7] 丁进超,张伟伟,吴训成. 基于双向长短期记忆网络的车牌识别算法[J]. 电子测量与仪器学报, 2018, 32(6): 173-179.
- [8] LAROCA R, SEVERO E, ZANLORENSI L A, et al. A robust real-time automatic license plate recognition based on the YOLO detector [C]. International Joint Conference on Neural Networks, Rio de Janeiro, Brazil: IEEE, 2018: 8-13.
- [9] BJORKLUND T, FIANDROTTI A, ANNARUMMA M, et al. Robust license plate recognition using neural

- networks trained on synthetic images [J]. *Pattern Recognition*, 2019, 93(7): 134-146.
- [10] 张培培,王昭,王菲. 基于深度学习的图像目标检测算法研究[J]. *国外电子测量技术*, 2020, 39(8): 42-47.
- [11] 周迪 夏哲雷. 一种改进的 Otsu 阈值分割算法[J]. *中国计量大学学报*, 2016(27): 319-323.
- [12] 王震,黄如意,李霖浦,等. 一种用于故障分类与预测的多任务特征共享神经网络[J]. *仪器仪表学报*, 2019, 40(7): 172-180.
- [13] HAN X, ZHONG Y, CAO L, et al. Pre-trained AlexNet architecture with pyramid pooling and supervision for high spatial resolution remote sensing image scene classification[J]. *Remote Sensing*, 2017, 9(8): 848-857.
- [14] XIE S, ZHENG X, CHEN Y, et al. Artifact removal using improved GoogLeNet for sparse-view CT reconstruction[J]. *Scientific Reports*, 2018, 8(1): 67-78.
- [15] 汤凯,何庆,赵群,等. 基于改进的深度残差网络的图像识别[J]. *南京师大学报(自然科学版)*, 2019, 42(3): 115-121.
- [16] DAVIX X A, CHRISTOPHER C S. Edge based marker controlled watershed algorithm for automatic car licence plate localization [J]. *Journal of Computational & Theoretical Nanoscience*, 2017, 14(11): 5539-5551.
- [17] HSU G S, CHEN J C, CHUNG Y Z. Application oriented license plate recognition [J]. *IEEE Transactions on Vehicular Technology*, 2013, 62(2): 552-561.

作者简介

李娅,硕士,主要研究方向为无人驾驶的环境感知与测量,图像识别等。

E-mail:lcc0919k@163.com

王兴路,博士,主要研究方向为车辆工程感知测量。

E-mail:494649992@qq.com

雷蕾,硕士,主要研究方向为无人机与无人驾驶,图像识别。

E-mail:leilei19860111@126.com

上官望义,博士,主要研究方向为图像识别分析;汽车底盘应用技术。

E-mail:52802535@qq.com