

# 基于并行 CNN 和识别策略优化的车牌识别方法研究

邬忠萍<sup>1</sup>, 刘新厂<sup>1</sup>, 郝宗波<sup>2</sup>

(1. 成都工业学院汽车与交通学院, 四川 成都 611730)

(2. 电子科技大学信息与软件工程学院, 四川 成都 611731)

**[摘要]** 为改善车牌自动识别系统的通用性, 在一般卷积神经网络(CNN)的基础上, 提出一种具有两个浅层独立子网络的 CNN, 且具有并行卷积层计算的功能. 一个用于推理车牌的概率; 另一个利用线性激活对仿射参数进行回归. 支持对汽车(包括公交车和卡车等)、摩托车等不同类型的交通工具牌照的检测识别. 此外, 使用基于 YOLO v3 的车牌字符识别模块, 并施加了一系列的优化策略, 实现对车牌中汉字的准确读取. 实验结果表明所提方法的识别精度优于一些同类优秀方法, 在 AOLP 数据集上的车牌检测准确率达到 98.9%, 在 CLPD 数据集上的字符识别准确率达到 96.2%. 所提方法有助于促进智能交通系统的进一步发展.

**[关键词]** 车牌检测, 优化策略, 字符识别, 卷积神经网络, 智能交通系统

**[中图分类号]** TP391 **[文献标志码]** A **[文章编号]** 1001-4616(2023)03-0098-07

## Research of License Plate Recognition Method Based on Parallel CNN and Optimization Strategies

Wu Zhongping<sup>1</sup>, Liu Xinchang<sup>1</sup>, Hao Zongbo<sup>2</sup>

(1. School of Automobile and Transportation, Chengdu Institute of Technology, Chengdu 611730, China)

(2. School of Information and Software Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China)

**Abstract:** To improve the generalization of the automatic license plate recognition system, based on the general convolutional neural network (CNN), a CNN with two shallow independent sub-networks is proposed, which has the function of parallel convolutional calculation, one is used to infer the probability of license plate, and the other uses linear activation to regress affine parameters. The proposed method supports the detection and recognition of different types of vehicle license plates such as cars (including buses and trucks) and motorcycles. In addition, the license plate character recognition module based on YOLO v3 is used and a series of optimization strategies are applied to accurately read the Chinese characters in the license plate. The experimental results show that the recognition accuracy of the proposed method is better than other advanced methods, and the license plate detection on AOLP data set achieved a test accuracy of 98.9%, and the character recognition accuracy on CLPD data set is 96.2%. The proposed method is helpful to promote the further development of intelligent transportation system.

**Key words:** license plate detection, optimization strategies, character recognition, convolutional neural network, intelligent transportation system

自动车牌识别旨在利用图像处理和模式识别技术, 提取并识别车牌图像或视频中的车牌字符<sup>[1]</sup>. 当前, 深度卷积神经网络(CNN)已成为车牌检测中最热门的机器学习技术<sup>[2]</sup>. 但如何处理光学变化(不同颜色、照度、阴影、图像噪声)和几何变化(各种视角拍摄到的不同形状车牌)依然是一个具有挑战性的问题<sup>[3]</sup>.

统一框架的车牌识别一般使用区域候选网络(RPN). 如文献[4]提出了车牌检测和识别的统一框架(TE2E), 使用 RPN 进行车牌检测, 并使用递归神经网络(RNN)进行字符识别. 但使用 RNN 造成该方法效率较差. 文献[5]提出了大型数据集 CCPD, 作为中国车牌基准数据集, 并提出了结合车牌检测与车牌识别

收稿日期: 2023-02-15.

基金项目: 国家自然科学基金资助项目(61003032)、轨道交通运维技术与装备四川省重点实验室开放课题基金项目(2020YW003)、成都工业学院引进人才科研启动项目(2021RC003)、四川省大学生创新创业项目(S202111116048).

通讯作者: 邬忠萍, 讲师, 研究方向: 人工智能应用, 汽车智能化检测技术. E-mail: vitamin9991@163.com

模块的端到端网络. 统一框架的问题是无法使用任务特定的技术,例如输入图像的车牌纠正,造成检测和识别性能下降.

深度卷积神经网络(DCNN)已成为应用在车辆和车牌检测上的最热门机器学习技术<sup>[6]</sup>. 如文献[7]使用了基于 YOLO 架构的 3 个网络,用于车辆检测、车牌检测和字符分割,并使用一个额外网络进行字符分类. 文献[8]对该方法进行了扩展,在车牌检测模块中纳入布局分类,并使用单个网络进行字符识别和分类. 但这些方法不适用于车牌形状严重畸变和恶劣照明条件场景. 文献[9]提出一种变型的卷积神经网络(DU-CNN),学习对发生各种不同形变的车牌进行检测,并通过对仿射变化的系数进行回归,将发生形变的车牌重新恢复为接近正前方视角的矩形,从而处理严重畸变车牌的检测识别任务. 文献[10]提出了基于 YOLO v3 的光学字符识别(OCR)系统,实现各种场景下车牌字符的准确读取. 文献[11]针对无约束捕捉场景,提出了一种扭曲平面目标检测网络(WPOD-NET),可对多个畸变车牌进行检测和纠正.

为了能处理各种不同扭曲情况以及不同类型的车辆车牌,在一般卷积神经网络的基础上,作如下改进:(1)利用两个子网络分别进行车牌分类和检测,增强分类和检测的性能;(2)在网络训练时加入摩托车图像以及公交、卡车等不同类型的汽车图像,基于单独的推理和回归模块,支持不同类型的交通工具牌照检测;(3)提出了本文方法与 OCR 相结合的车牌识别策略,在提高识别精度的同时加快处理速度,极大扩展了所提方法的适用性,有助于促进智能交通系统(ITS)的进一步发展.

## 1 多国多类型车牌检测识别系统

本文系统流程图如图 1 所示. 首先,基于 YOLO v3 的车辆检测预处理模块,以限制搜索区域. 然后,使用所提改进网络,检测各种场景下的汽车和摩托车牌,并使用畸变纠正技术,将车牌图像修正为正前方视图. 最后,将修正后的车牌图像输入车牌识别模块,基于所提策略进行识别并提供车牌字符串.

### 1.1 网络架构

本文核心网络架构如图 2 所示. 所提网络包括一系列带批归一化的卷积层,并利用残差块(本文的残差块结构如图 3 所示)缓解消失梯度问题,加快训练速度. 卷积过滤器大小固定为(3×3),过滤器数量从 16 到 128. 在网络的所有中间层使用修正线性单元(ReLU)作为激活函数,最后一层则专用于分类和定位任务. 网络包含 4 个最大池化层,大小为 2×2,步长为 2,将输入维数降低为 1/16.

在图 2 的改进网络中,最后一个网络子块包括两个并行卷积层,其中一个卷积层用于推理目标车牌的概率,通过 softmax 函数激活;另一个卷积利用线性激活对仿射参数进行回归,在除最后一层之外的所有网络层共享分类和检测权重. 但随着输入图像外观和形状的变化增加,每个任务可能会向上层反向传播冲突信息,从而可能降低分类和检测任务的性能.

为了解决该问题,并提高对不同类型车牌的检测性能,本文提出添加两个浅层的独立子网络,每个网络模块分别针对分类和检测任务. 通过两个带批归一化的卷积层组成分类子网络,两个卷积层分别使用 Relu 和线性激活函数. 最后一层使用 Sigmoid,提供输出层的每个 cell 中包含车牌的概率. 检测子网络在最后一层利用线性激活对 6 个参数进行回归,其他配置与分类子网络相同.




图 1 系统流程图

Fig. 1 System flowchart

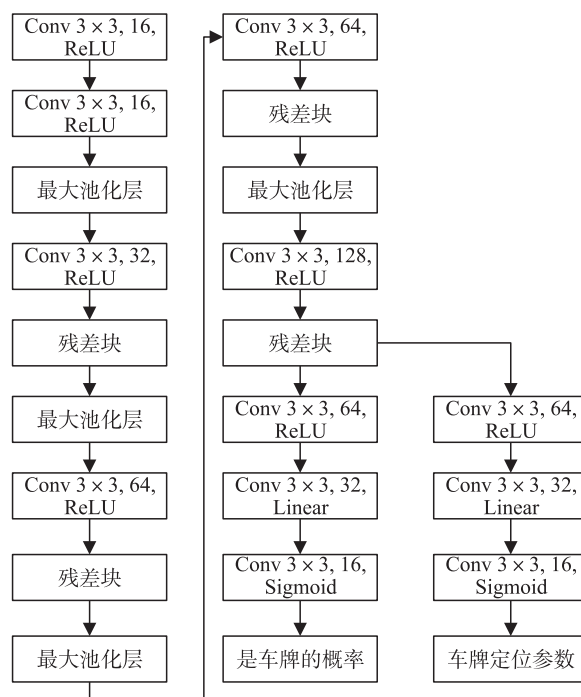


图 2 网络架构图

Fig. 2 Network architecture diagram

## 1.2 车辆图像检测和缩放

在应用所提网络前,首先采用 YOLO v3 进行车辆检测. 由于所提网络被训练为检测特定范围内的车牌,可利用车辆检测降低搜索空间,调整输入到所提网络中的图像大小,使得预期车牌大小在合理范围内.

在大部分正面或背面视图中,车牌宽度与车辆宽度的比例变化不大. 在倾斜视角中,车牌在车辆中的占比会变小,因为车辆图像中会包含侧面车身. 此外,车辆包围框的高宽比提供了正面和倾斜视图的粗略区分:正面视角更接近 1,侧面视角则会变大.

基于经验,将尺度因子确定为:

$$scale = \min \left\{ 1, \frac{W_d \max \{ 1, w_d/h_d \}}{w_d} \right\}, \quad (1)$$

式中,  $w_d \times h_d$  为检测车辆的包围框尺寸,  $\max \{ 1, w_d/h_d \}$  为裁剪后的高宽比,  $W_d$  为比例常数. 对于汽车,设  $W_d = 256$ ; 对于摩托车,设  $W_d = 208$ .

## 1.3 车牌检测与去畸变方法

车牌图像去畸变原理图如图 4 所示. 将重新调整大小后的车辆检测模块的输出馈送到网络. 生成一个 8 信道特征图,对车牌或非车牌概率和仿射变化参数编码.

在提取畸变车牌时,考虑围绕  $cell(m, n)$  中心的虚构正则正方形. 如果该  $cell$  包含车牌概率超过给定检测阈值,则使用回归参数构建仿射矩阵,将正则正方形转换为车牌区域. 其中,损失函数定义为:

$$loss = \sum_{n=1}^N \sum_{m=1}^M [\prod_{obj} f_{aff}(m, n) + f_{pr}(m, n)]. \quad (2)$$

通过损失函数的最小化,将畸变车牌转换为水平对齐和垂直对齐的目标,得到接近正前方视角的车牌图像.

## 1.4 网络的扩展性训练

不同于一些传统车牌识别方法<sup>[12]</sup>,使用全卷积网络的好处是可在固定分辨率输入上训练,由此生成训练批,加快处理速度,并在任意尺寸的测试图像上执行推理<sup>[13]</sup>. 考虑到网络必须处理各种不同类型车牌的几何变化(尺寸和角度畸变),以及颜色和照度条件,必须进行数据增广以训练网络. 给定注释训练图像,随机应用几何畸变(模拟不同大小和视图)和光度扭曲(模拟颜色和照度变化,以及模糊和噪声).

首先定义目标宽度  $w \in [w_{min}, w_{max}]$ ,  $0 < w_{min} < w_{max} < N$ . 使用  $w_{min} = 0.2N$ ,  $w_{max} = N$ , 最大宽度是最小宽度的 5 倍. 由于车牌实际尺寸未知(训练数据集包含多国车牌,每个国家车牌规格不同),随机选择目标车牌高宽比  $a_r$ , 并计算高度  $h = w/a_r$ . 基于不同区域的车辆和摩托车高宽比,选择  $a_r \in [2.5, 4.5]$  用于车辆,  $a_r \in [1.25, 2.5]$  用于摩托车. 其后,通过随机选择水平偏移  $h_o \in [0, N-w]$  和垂直偏移  $v_o \in [0, N-h]$ , 对目标车牌四角进行平移,使其完全拟合到期望尺寸  $N \times N$ . 其后,找到将训练图像的注释车牌四角映射到平移后的目标车牌四角的单应性矩阵  $H_0$ .

得到规范车牌后,在包含车牌的平面上应用 3D 旋转,模拟相同相机的不同视角<sup>[14]</sup>. 具体来说,分别选择、和的倾斜角、俯仰角和偏航角. 由此提供了各种不同的视角,用于生成另一个平面单应性矩阵  $H_1$ ,以执行平面上的 3D 旋转. 假定标准针孔相机的焦距  $f = 1\,000\text{ mm}$ , 并考虑包含车牌的平面位于相同距离  $z = 1\,000\text{ mm}$ , 以得到单应性矩阵  $H_1$ . 最后,计算最终单应性矩阵有:

$$H = H_1 H_0. \quad (3)$$

同时,基于  $H$  对输入训练图像进行变形. 由于单应变形通常不会填满目标图像的整个矩形区域,使用一组随机选择的背景图像进行填充. 由此,增加负样本数量,减少网络的漏检数量.

在几何形变后,随机应用以下畸变:

(1) 负畸变:得到负畸变图像,概率  $p = 5\%$ ;

(2) 模糊:应用高斯模糊,概率  $p = 15\%$ . 在  $[0, 0.1N]$  范围内随机选择模糊尺度  $\sigma$ ;




图 3 残差块结构图

Fig. 3 Diagram of residual block struture




图 4 去畸变示例

Fig. 4 Example of dewarping operation



(3)颜色变化:随机修改 HSV 颜色空间,概率  $p=100\%$ 。

利用上述变换,从手工标注的单个样本中得到包含高区分性视觉特征的增强测试图像。

为了训练模型,使用 200 张普通汽车注释图像,150 张包含摩托车牌的注释图像,以及 200 张包含其他车辆(公交和卡车等)的图像,共计 550 张增强图像。选择  $N=208$ ,定义  $208 \times 208$  的输入分辨率以训练网络,由此增强过程中的所有车牌的宽度范围为  $w_{\min}=42$  至  $w_{\max}=208$  像素。

### 1.5 车牌字符的优化识别策略

车牌识别模块可分为两类:基于目标的车牌识别,以及基于顺序信息的车牌字符串读取<sup>[15]</sup>。

所提系统生成修正后的车牌,极大简化了车牌识别问题,不需要处理字符的旋转或大小变化。使用基于目标检测的更合适。原因如下:(1)相同车牌中所有字符高度是相似的,字符包围框可用于识别和拒绝离群点;(2)顺序/递归方法不适用于双排布局的摩托车牌;(3)若已得到车牌中字符数量(或范围)的先验知识,则可以使用置信度得分,对检测结果做相应调整。基于上述特征,介绍所提车牌识别策略。

本文基于 YOLO v3 的车牌识别模块,并应用以下策略:

(1)强制大小一致性:所提网络提供的去畸变图像接近车牌正面视角,车牌中所有字符为相似高度。利用这一点,通过包围框测量每个字符高度与中值的差异。设  $h_i$  为给定车牌中第  $i$  个检测到的字符的高度,计算其与中值的相对差:

$$e(h_i) = \left| \frac{h_i - \text{median}\{h_i\}}{\text{median}\{h_i\}} \right|, \quad (4)$$

由此,  $e(h_i)$  高于阈值  $T_h$  的字符将被视为离群点。

(2)寻找双行字符串:本文考虑两行字符的摩托牌照。当检测到的车牌被分入摩托车标签时,首先检索每个字符的中心垂直坐标  $v_i$ ,并将检测分为两行。为此,计算  $v_i$  的均值(移除最低和最高值,取区域字符的均值)。其后,将  $v_i$  低于均值的字符分入第一行,将其他字符分入第二行。

(3)强制地域约束:在不知道车牌地域的情况下,检索所有得分大于阈值  $T_{pr}$  的检测结果。若已知车牌的字符数  $n \in [n_{\min}, n_{\max}]$ ,则可以放宽阈值约束,在  $n < n_{\min}$  的情况下得到  $n_{\min}$  检测结果,或在  $n > n_{\max}$  的情况下得到有着最高  $n > n_{\max}$  得分的字符。在每个字符的置信度阈值之外,本文还对整个车牌施加全局最小置信度,包括所有字符的平均检测得分。若数值低于阈值  $T_{\text{mean}}$ ,则车牌将被丢弃,这有助于减少车牌检测中的假阳性检测。若车牌中的字符分布是已知的,则可以将出现在错误位置的数字与相似字母相互替换。

## 2 实验

实验利用 Python wrapper 集成所有模块,硬件平台为 Intel Core i7-4770 处理器,8GB RAM, NVIDIA RTX 1080 GPU,运行 Windows 10 操作系统。实际运行时间取决于车辆数和输入图像大小。在所有数据集上的完整自动车牌识别系统的平均运行帧率为 8.6 FPS。

### 2.1 参数设置

所提方法在流水线中使用了 3 个网络,根据经验设置以下阈值:车辆检测为 0.35,车牌检测为 0.35,车牌字符识别为 0.4。要指出,车牌检测仅应用到车辆探测器生成的区域,因此在第一个模块中选择较低阈值,以减少漏检数量。此外,少于 4 个字符,或者平均字符置信度低于  $T_{\text{mean}}=0.6$  的车牌视为假阳性检测,并被丢弃。实验中的 ADAM 优化器通过大小为 64 的 mini-batch 对网络进行 5 万次迭代训练,学习率 0.001。使用相同学习率对网络进行 5.5 万次迭代训练。最后,将学习率降至 0.000 1,再进行额外 10 万次迭代。

### 2.2 数据集和评估度量

本文实验中使用了 3 个数据集,其中的图像包含了各种不同视角、照明条件、拍摄距离和车牌区域,具体介绍如下:

(1)CLPD<sup>[16]</sup> 包含从中国所有省份采集到的 1 200 张图像。该现实数据集包含各种不同环境、车辆类型。

(2)CCPD<sup>[5]</sup>,中国城市停车数据集。该数据集是评估无约束环境下自动车牌识别方法的车牌基准数据集。其中包含不同天气、照明、旋转和模糊情况下捕捉到的超过 28 万张车辆图像,图像分辨率为  $720 \times 1\ 160$ 。数据集中提供的注释包括车牌字符、包围框及 4 个顶点、水平和垂直倾斜角度以及亮度和模糊度。

(3) AOLP<sup>[17]</sup>, 基于应用的车牌数据集. 该数据集中包含 3 个子集, 分别为用于区域出入控制的 AC 子集, 违反交规被抓拍的 LE 子集, 以及任何视角和距离拍摄到的 RP 子集. AOLP 中共包含 2 049 张图像.

评估指标: 对于 CCPD 数据集, 探测器对每个图像预测一个包围框. 若预测包围框与地面真实的交并比(IoU)大于 0.7, 则视为正确预测.

2.3 车牌检测结果

首先比较所提方法与其他先进方法的车牌检测. CCPD 数据集中包含各种不同环境, 因此在 CCPD 上得到的结果可以验证所提方法在无约束环境下的车牌检测性能. 基于 0.7 的 IoU 阈值计算出精度指标, 要求探测器能够提供高质量包围框.

表 1 给出了在 CCPD 数据集上进行车牌检测的整体精度和不同子集检测精度. 所提方法取得了整体最优精度, 并且在绝大部分子集中的车牌检测精度都优于原 WPOD-NET 方法. 这是因为所提方法通过单独的子网络进行分类和检测, 并且在训练中使用了更完善的数据增强技术, 提高了探测器对不同场景的检测能力, 由此提高了在困难场景中的车牌检测精度.

表 1 CCPD 测试集上的车牌检测结果  
Table 1 License plate detection precision results on CCPD test set

方法	整体精度	CCPD 子集					
		Base	DB	FN	Rotate	Title	Weather
TE2E	85.17	89.7	88.1	82.6	85.4	80.1	85.1
DU-CNN	87.85	91.5	90.1	88.4	84.7	85.0	87.4
WPOD-NET	92.22	94.3	90.5	85.6	94.2	92.8	95.9
本文方法	93.82	95.5	90.2	91.4	95.5	94.2	96.1

图 5 给出了在 CCPD 数据集上使用所提方法进行车辆检测时的一些定性结果. 图中红色包围框为地面真实注释, 绿色包围框为所提方法的检测结果. CCPD 数据集中的图像分辨率相对较低, 这进一步增加了检测难度. 但从结果中可发现, 所提方法能够很好地处理无约束环境, 例如不均匀照明或倾斜视角. 此外, 所提方法在训练中仅使用了 550 张图像, 证明了所提数据增强技术的有效性.




图 5 CCPD 数据集上的定性结果  
Fig. 5 Qualitative results on CCPD dataset

表 2 给出了在 ALOP 数据集上的车牌检测结果. 使用 AOLP 中的包围框注释, 并评估精度和召回率结果. 根据该数据集定义, 若检测结果与真实注释的 IoU 大于 0.5, 则视为正确检测. 从中可发现, 原 WPOD-NET 和所提方法均表现良好. 所提方法在大部分子集中取得最优性能. 与 CCPD 数据集的结果相比, AOLP 数据集上的检测精度要高得多, 这是因为该数据及定义的 IoU 阈值比 CCPD 要低, 且图像清晰度更高.

表 2 AOLP 数据集的车牌检测精度和召回率  
Table 2 License plate detection precision and recall results on AOLP dataset %

方法	子集					
	AC		LE		RP	
	精度	召回率	精度	召回率	精度	召回率
TE2E	90.5	95.6	90.1	92.2	88.8	91.9
DU-CNN	97.7	96.0	94.8	94.1	93.7	92.4
WPOD-NET	98.8	97.4	99.2	98.5	98.7	96.7
本文方法	98.9	98.5	97.6	98.4	99.9	100

2.4 车牌字符识别结果

首先比较所提方法与其他方法在 CLPD 数据集上的车牌识别精度. 表 3 给出了实验结果,由于所提方法能够将车牌纠正为正前方视角,极大地简化了车牌识别的难度. 并通过施加一系列车牌识别约束策略,进一步增加了识别准确度,最终取得了 96.2%的整体识别精度. 值得一提的是,所提方法在训练时并没有使用 CLPD 数据集中的图像,但依然取得了最终综合识别精度,这证明了所提方法具有很好的泛化性能,能够在未知场景中准确完成车牌检测和识别任务.

图 6 给出了所提方法在各种不同场景下,对不同类型的车辆牌照进行检测和识别的示例,其中,图片来源于网络搜集或街道拍摄. 得益于性能强大的车牌检测网络和完善的车牌识别模块,所提方法能够在各种复杂场景中准确识别出不同类型车辆的牌照信息,而且能正确读取双排摩托车牌照信息,证明所提识别策略是有效的.




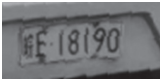




采集图像	检测结果	车牌标识
		08151F3
		皖 E18190
		粤 Q S1878
		闽 F238FC

图 6 车牌识别结果示例

Fig. 6 Example of license plate recognition results

3 结论

本文在一般卷积神经网络的基础上提出了一系列的改进,通过单独的分类和检测子网络进一步改善困难场景下的车牌检测性能,并结合所提车牌识别策略,准确检测不同类型和不同国家车牌. 实验结果表明,所提方法在大部分情况下的性能优于一些同类方法,且通过性能更好的 OCR 模块,实现了对中文字符的读取.

[参考文献]

[1] ARAFAT M Y, KHAIRUDDIN A S M, KHAIRUDDIN U, et al. Systematic review on vehicular licence plate recognition framework in intelligent transport systems[J]. IET intelligent transport systems, 2019, 13(5): 745-755.

- [2] 牛迪. 基于自注意力机制的多特征融合槽抽取模型[J]. 南京理工大学学报(自然科学版), 2022, 46(1): 69–75.
- [3] 吴仁彪, 冯晓赛, 屈景怡, 等. 雾霾环境下基于 PLATE-YOLO 的车牌检测方法[J]. 信号处理, 2020, 36(5): 666–676.
- [4] LI H, WANG P, SHEN C. Toward end-to-end car license plate detection and recognition with deep neural networks[J]. IEEE transactions on intelligent transportation systems, 2018, 20(3): 1126–1136.
- [5] XU Z, YANG W, MENG A, et al. Towards end-to-end license plate detection and recognition: A large dataset and baseline[C]// Proceedings of the European Conference on Computer Vision(ECCV). Munich, Germany, 2018: 255–271.
- [6] KIM S G, JEON H G, KOO H I. Deep-learning-based license plate detection method using vehicle region extraction[J]. Electronics letters, 2017, 53(15): 1034–1036.
- [7] HSU G S, AMBIKAPATHI A M, CHUNG S L, et al. Robust license plate detection in the wild[C]//2017 14th IEEE International Conference on Advanced Video and Signal Based Surveillance(AVSS). Lecce, Italy: IEEE, 2017: 1–6.
- [8] LAROCA R, ZANLORENSI L A, GONÇALVES G R, et al. An efficient and layout-independent automatic license plate recognition system based on the YOLO detector[J]. IET intelligent transport systems, 2021, 15(4): 483–503.
- [9] 王昆, 王晓峰, 刘轩, 郝潇. 基于卷积神经网络的解扭曲车牌检测识别方法[J]. 计算机工程与设计, 2021, 42(11): 3225–3231.
- [10] 李林, 赵凯月, 赵晓永, 等. 基于卷积神经网络的污损遮挡号牌分类[J]. 计算机科学, 2020, 47(S1): 213–219.
- [11] SERGIO M S, CLAUDIO R J. License plate detection and recognition in unconstrained scenarios[C]//European Conference on Computer Vision. Munich, Germany: IEEE Press, 2018: 1–11.
- [12] 刘智. 基于改进自适应图像分割算法的车牌识别技术研究[J]. 西南师范大学学报(自然科学版), 2017, 42(5): 28–33.
- [13] XIANG H, ZHAO Y, YUAN Y, et al. Lightweight fully convolutional network for license plate detection[J]. Optik, 2019, 17(8): 1185–1194.
- [14] OMAR N, SENGUR A, AL-ALI S. Cascaded deep learning-based efficient approach for license plate detection and recognition[J]. Expert systems with applications, 2020, 149(12): 113280–113291.
- [15] 段宾, 符祥, 江毅, 等. 结合 GAN 的轻量级模糊车牌识别算法[J]. 中国图象图形学报, 2020, 25(9): 1813–1824.
- [16] XU H, GUO Z H, WANG D H, et al. 2D license plate recognition based on automatic perspective rectification[C]//2020 25th international conference on pattern recognition(ICPR). Milano, Italy: IEEE, 2021: 202–208.
- [17] YAO Z J, YI W D. Bionic vision system and its application in license plate recognition[J]. Natural computing, 2019, 19(3): 1–11.

[责任编辑: 陆炳新]