

王世芳, 李玉龙. 基于卷积神经网络的车牌号码识别方法[J]. 长安大学学报(自然科学版), 2023, 43(4): 106-117.

WANG Shi-fang, LI Yu-long. License plate number recognition method based on convolution neural network[J]. Journal of Chang'an University (Natural Science Edition), 2023, 43(4): 106-117.

DOI: 10.19721/j.cnki.1671-8879.2023.04.011

基于卷积神经网络的车牌号码识别方法

王世芳¹, 李玉龙^{1,2}

(1. 安徽工程大学 电气工程学院, 安徽 芜湖 241000; 2. 宁波大学 信息科学与工程学院, 浙江 宁波 315000)

摘要: 在自然道路交通环境中, 车牌定位检测与识别是实现智慧交通系统的关键技术之一。为了解决传统方法受到分割字符失败以及暗光、大角度倾斜等不利因素影响导致车牌号码误判率较高而识别率较低的问题, 提出一种使用单阶段目标检测算法(you only look once v5, YOLOv5)结合基于深度神经网络(license plate recognition neural networks, LPRNet)的车牌识别方法, 使用中国停车数据集(Chinese city parking dataset, CCPD)以及自建的数据集进行训练及试验。首先 YOLOv5 网络利用跨阶段局部网络(cross stage partial network, CSPNet)结构进行图片特征提取, 通过多尺度特征信息融合, 采用完备交并比(complete intersection over union, CIoU_Loss)损失函数与非极大值抑制(non-maximum suppression, NMS)联合得到预测框, 定位车牌位置。轻量级的 LPRNet 网络无需字符分割, 使用连接时序分类(connectionist temporal classification, CTC)解决车牌字符识别问题。在 YOLOv5+LPRNet 网络的基础上增加改进算法, 通过非线性图像增强来恢复低照度下丢失的车牌信息, 利用双边滤波算法滤除背景噪声的同时保留车牌边缘信息, 输入车牌矫正网络, 通过透射变换得到最终车牌照。为验证该算法的有效性, 在夜间环境、角度倾斜、雨雪雾天等多种场景下开展试验。研究表明: 车牌识别模型的平均识别准确率均超过 95%, 识别速度平均达到 32 帧/s; 与 Easy PR、Hyper LPR、Faster-RCNN+LPRNet 和 YOLOv3+LPRNet 模型相比, 提出方法的识别准确率和召回率均得到提高, 分别达到 97.65% 和 96.74%; 提出方法在道路交通复杂的场景中表现出较强的鲁棒性, 识别速度上也有明显优势。

关键词: 交通工程; 车牌识别; LPRNet; YOLOv5; 车牌定位

中图分类号: U491.116

文献标志码: A

文章编号: 1671-8879(2023)04-0106-12

License plate number recognition method based on convolution neural network

WANG Shi-fang¹, LI Yu-long^{1,2}

(1. School of Electrical Engineering, Anhui Polytechnic University, Wuhu 241000, Anhui, China; 2. School of Information Science and Engineering, Ningbo University, Ningbo 315000, Zhejiang, China)

Abstract: License plate localization, detection, and recognition in natural road traffic environments are key technologies for implementing intelligent transportation systems. To address the problem of high misrecognition rates and low recognition rates resulting from

收稿日期: 2022-12-06

基金项目: 高节能电机及控制技术国家地方联合工程实验室基金项目(KFKT201510); 安徽工程大学校青年基金项目(2015YQ15)

作者简介: 王世芳(1981-), 女, 安徽芜湖人, 副教授, E-mail: wangshifang@ahpu.edu.cn.

traditional methods that affected by factors such as failed character segmentation and adverse lighting and large angle inclination, a license plate recognition method was proposed, which combines the YOLOv5 (you only look once v5) network with the LPRNet (license plate recognition neural networks) network, CCPD (Chinese city parking dataset) and a self-built dataset were used for training and experiments. First, the YOLOv5 network utilized the CSPNet (cross stage partial network) structure for image feature extraction, and through the fusion of multi-scale feature information, the prediction box was obtained through the CIOU_Loss (complete intersection over union) loss function and the NMS (non-maximum suppression) to locate the position of the license plate. The lightweight LPRNet network did not require character segmentation, but instead used CTC (connectionist temporal classification) to solve the problem of license plate character recognition. To validate the effectiveness of our algorithm, experiments in various scenarios, such as nighttime environments, angle inclination, and rainy, snowy, and foggy weather were conducted. The results show that the average recognition accuracy of the license plate recognition model exceeded 95%, with an average recognition speed of 32 frames/s. Compared with the Easy PR, Hyper LPR, Faster-RCNN + LPRNet, and YOLOv3 + LPRNet models, the proposed method improves the recognition accuracy and recall rate, reaching 97.65% and 96.74%, respectively. The improved license plate recognition method exhibits strong robustness even in complex road traffic scenarios and has a significant advantage in recognition speed. This text concludes that the proposed method achieves high accuracy and robustness in license plate recognition, and has a faster recognition speed compared to other models. 4 tabs, 15 figs, 24 refs.

Key words: traffic engineering; license plate recognition; LPRNet; YOLOv5; license plate location

0 引言

车牌号码识别已经广泛应用于高速超速车辆抓拍、疫情期间流调车辆排查、普通交通违法车辆抓拍等智慧交通领域中,目前对车牌识别的方法研究主要集中在车牌定位和字符识别2个方面。传统车牌定位方法主要有基于颜色定位方法、基于边缘特征检测定位方法和基于纹理特征定位方法。杨鼎鼎等将车牌定位分为粗定位和细定位两部分,根据车牌背景和字符固定颜色搭配,用新的颜色模型对车牌进行粗定位,使用改进的Canny边缘检测算法进行细定位^[1],这样将红绿蓝(RGB)空间图像向HSV(hue, saturation, value)转换,更容易区分颜色,而且还具有线性伸展性。同时在HSV下可以计算颜色空间距离以及确定两色彩的相似度。郭延祥等提出了将边缘检测和颜色纹理直方图相结合的车牌定位识别方法,该方法使用了Sobel算子提取车牌边缘特征,并结合滤波、投影等方法进行车牌粗定位,结合候选区域的颜色纹理直方图最终精确定位车牌^[2]。

为了改进传统方法复杂场景识别率低的问题,

近年来国内外学者开展了基于深度学习车牌定位识别方法研究。Selmi等将Tensorflow框架搭建的卷积神经网络(CNN)应用到车牌定位模块^[3],但是车牌定位的准确率还有待提高。王燕等提出了Faster_RCNN与Inception_ResNet_v2级联的车牌定位模块,并将mLeNet5网络成功应用到单个字符的识别当中,在有效检测车牌的同时,实现字符的精确识别,但字符识别依然依赖分割算法的准确性,且对车牌照照片质量要求较高,在光照不均匀的情况下分割结果错误率较高^[4]。目前车牌定位算法更多的是使用单阶段目标检测算法(YOLO)^[5],其发展基于Faster_RCNN的两阶段算法,但YOLO在检测速度性能上优于RCNN等两步法网络,它与单次多边框检测算法(single shot multi box detector, SSD)大同小异^[6],都属于端到端的目标检测算法。该算法以生成一定宽高比的anchor作为候选区,类似于滑动窗口,然后对每个候选区进行分类和回归。这样端到端的网络在训练中更容易收敛,速度也有所提升。车牌定位后需要通过字符分割与字符识别来获取车牌信息。为防止光线不均匀、照片模糊等外界因素的干扰,字符分割通常需要采用图像灰度

化、二值化、边缘检测等处理方法来提高分割精度。字符识别中的经典算法是模板匹配法,该算法首先建立模板库分析字符特征,通过将单个字符特征与模板库内的字符特征进行匹配,输出与模板库匹配相似度最高的结果。禹润华等提出通过BP神经网络与模板匹配方法联合应用,先通过BP神经网络筛选出字符范围,再根据模板匹配精确确定字符^[7]。其中BP神经网络训练收敛后,后续的模板匹配法即使不采用特殊处理,也可避免在相似度高的字符识别中出现错误识别问题。胡成伟等在传统的车牌识别基础上使用角点响应算子(Harris算子)方法提取车牌的字符特征,再与数据库中的训练样本进行匹配,利用欧式距离判断字符的相似程度,最终实现车牌的识别^[8]。Harris算子方法的应用在字符分割后的识别率优化方面起到促进作用,弥补了字符分割错误的后续影响。这些基于机器学习的字符识别方法已经比较成熟,但是基于机器学习方法的鲁棒性不强,需要人为设计特征。近年来,相关研究利用深度学习来实现识别字符的任务,可以通过大量训练数据迭代,使得网络自动学习参数,直接输入图像就能进行识别,识别效果显著提升。Zou等提出在充分提取车牌字符特征的基础上,结合车牌的上下文位置信息,使用双向长短期记忆网络(long short term memory, LSTM)机制进行字符识别,即使在车牌照片获取环境恶劣、识别难度大的情况下仍有较好鲁棒性^[9]。实际车牌的号码上下文联系不大, LSTM的使用具有较好的识别率,但在识别速度上会有欠缺。欧先锋等提出利用Caffe深度学习框架的字符识别算法,利用Caffe网络特点来对车牌的二维图像数据进行特征提取,在各种噪声污染下平均识别率仍然高出约5%。但网络训练采用粗切割产生的单个字符,未能实现识别整张车牌照片,且研究范围仅限于数字而未涉及到中文字符的识别^[10]。Liu等提出使用端到端的字符识别方法,该方法由校正网络、残差模块和序列识别模块三部分组成,其中序列识别模块中的时序连接网络(CTC)可识别不定长的字符序列,不需要预先划分训练数据,它同时也是实现端到端车牌字符识别的关键方法^[11]。饶文军等提出使用YOLOv3网络进行车牌定位,后续嵌入空间变换网络模块对倾斜车牌进行矫正,使用双向循环神经网络(BRNN)与CTC进行连接,成功实现端对端车牌识别,而且大幅简化传统车牌的识别流程^[12]。但是现有算法往往模型复杂度较高、运行速度慢、难以部署到实际应用场景中,

且存在恶劣环境下的识别准确率不理想等缺点。

本文提出一种基于YOLOv5一阶段目标检测网络与轻量化卷积网络LPRNet的车牌识别网络。YOLOv5网络的体积相对于YOLOv4减小了90%,在车牌定位模块推理速度更快,更容易实现实时目标检测。针对大角度旋转的车牌照片提出利用双边滤波与透射变换方法相结合的矫正模块,使得识别方法可以应用更多的实际生活场景。针对暗光条件下车牌照片识别的难点,本文提出一种利用非线性彩色图片增强来恢复低照度下车牌号码的方法,进一步提高YOLOv5+LPRNet车牌识别方法在复杂环境下的鲁棒性。LPRNet网络采用轻量卷积方法,相较于基于上下文信息的LSTM的方法,能够大幅提高识别精度和识别速度,通过在夜间环境、中长距离、雨雪雾天、倾斜畸变等几种具有挑战性的验证集上进行测试,验证本文方法的准确性。

1 YOLOv5 和 LPRNet 的车牌识别流程及改进

针对复杂的实际道路情况,本文开展基于卷积神经网络的车牌号码识别方法,将具有快速定位能力的YOLOv5和轻量级网络结构的LPRNet进行融合,并且在图像预处理模块添加暗光增强与车牌矫正模块,具体流程如图1所示。道路摄像设备获取图像后,低照度的车辆图片会先被暗光增强算法恢复丢失信息。YOLOv5检测网络会对处理后的图片提取车牌区域,输出候选框作为车牌矫正模块的输入。大角度旋转图片需要首先根据矩形车牌4个角点的位置计算变换矩阵来完成矫正。最终,经过矫正后的车牌照片被输入到LPRNet网络,字符识别网络对检测到的候选框利用主干网络提取字符信息,利用CTC和集束搜索输出最终车牌号。

2 基于 YOLOv5 的车牌定位方法

2.1 YOLOv5 网络设计

(1)主干提取网络。YOLOv5主干提取部分用于实现图像特征的提取,主要包括Focus模块、CBS模块、CSPNet模块和SPP模块。Focus模块对输入图像进行下采样,获得参数数量更少、维数更低的特征图,提高后续卷积的运算速度。CBS模块由卷积层、批量归一化层和激活函数组成,对图像卷积、数据进一步优化处理。CSPNet模块,即跨阶段局部网络,其首先对提取到的特征图在通道维度分割为两部分,主干部分进入残差特征提取模块再向

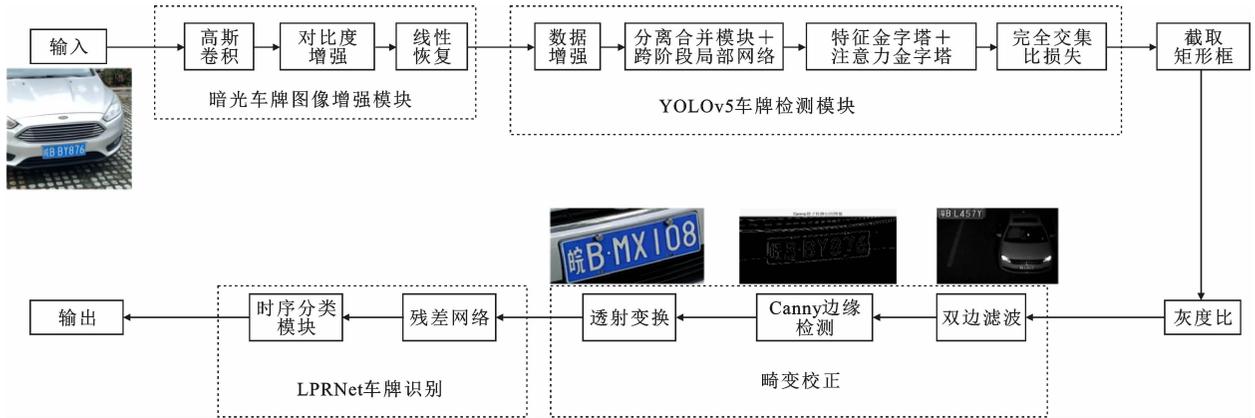


图 1 车牌识别整体流程

Fig. 1 Overall flow of license plate recognition

后传递,另一部分跨阶段直接送入到运算末端,与特征提取模块进行融合。这种跨阶段层次结构合并特征信息的方法能够在一定程度上解决梯度信息重复的问题。空间金字塔池化(spatial pyramid pooling, SPP)由 CBS 模块和最大池化层组成,它使用不同大小的卷积核进行卷积并最大池化,可以提高网络的感受野范围。

(2)特征提取加强网络。特征金字塔网络(feature pyramid network,FPN)+金字塔注意力网络(pyramid attention network,PAN)可以实现多尺度特征信息的融合。车牌照照片特征层经过 FPN 结构由顶部到底部进行上采样,并且与前面骨干网提取的特征进行融合。PAN 结构由底部到顶部特征层对图片信息下采样,然后与 FPN 结构提取的特征信息再进行融合,强化底层特征的传播。

(3)预测端。预测端由 CIOU_Loss 损失函数与 NMS 组成,用于输出置信度最高的车牌定位框。CIOU_Loss 在 DIOU_Loss 的基础上添加边界框宽高比的尺度信息,有效解决预测框中心点位置相同无法分辨的问题。CIOU_Loss 损失函数 C 真正包含了目标框回归函数应该考虑的重要几何因素,其计算公式为

$$C=1-\left(I_{OU}-\frac{b^2}{c^2}-\frac{v^2}{(1-I_{OU})+v}\right) \quad (1)$$

式中: v 为衡量长宽比一致性的参数; b 为预测框与标准框间中心点的欧氏距离; c 为预测框与标准框的最小外接矩形的对角线距离; I_{OU} 为预测框和真实框之间的交并比值。

NMS 非极大值抑制用于筛选最优目标检测框。CSP 结构见图 2。 x 为根据 YOLOV5 确定模块数。

2.2 YOLOv5 的改进算法

YOLOv5 网络损失函数的计算主要有:目标位

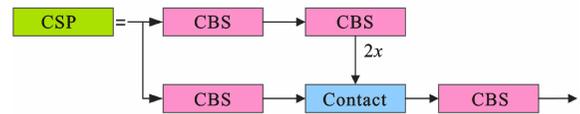


图 2 CSP 结构

Fig. 2 CSP structure

置损失、目标分类损失及区域内目标损失。目标位置损失利用真实框和预测框计算 CIOU 函数,但只计算正样本的定位损失。目标分类损失采用二元交叉熵损失(binary cross entropy loss,BCE loss),通过计算正样本的真实框种类和先验框种类预测结果的交叉熵损失,来获取最终损失值。区域内目标损失的计算原理是由正负样本预测结果计算交叉熵损失得出,但其中有大小不同的 3 种预测特征层,80 像素×80 像素×256 通道预测特征层用于针对小目标检测;40 像素×40 像素×512 通道预测特征层用于针对中等目标检测,20 像素×20 像素×1 024 通道预测特征层用于针对大目标检测。区域内目标损失中给不同目标预测函数分配不同权重,来提高网络对不同目标的检测能力,权重分配 L_{obj} 如式 2 所示

$$L_{obj}=4.0L_{obj}^s+1.0L_{obj}^m+0.4L_{obj}^l \quad (2)$$

式中: L_{obj}^s 、 L_{obj}^m 、 L_{obj}^l 分别代表小目标、中目标、大目标权重分配。

在真实交通道路场景中,车牌检测更考验网络小目标的检测能力。因此,区域内目标损失函数的权重需要重新分配,即增加小目标损失函数权重,同时减少大目标损失函数的权重。本文通过大量对比试验最后确定不同损失函数的超参数值,改进后的损失函数权重如式 3 所示

$$L_{obj}=7.0L_{obj}^s+2.0L_{obj}^m+0.01L_{obj}^l \quad (3)$$

YOLOv5 网络整体结构见图 3。

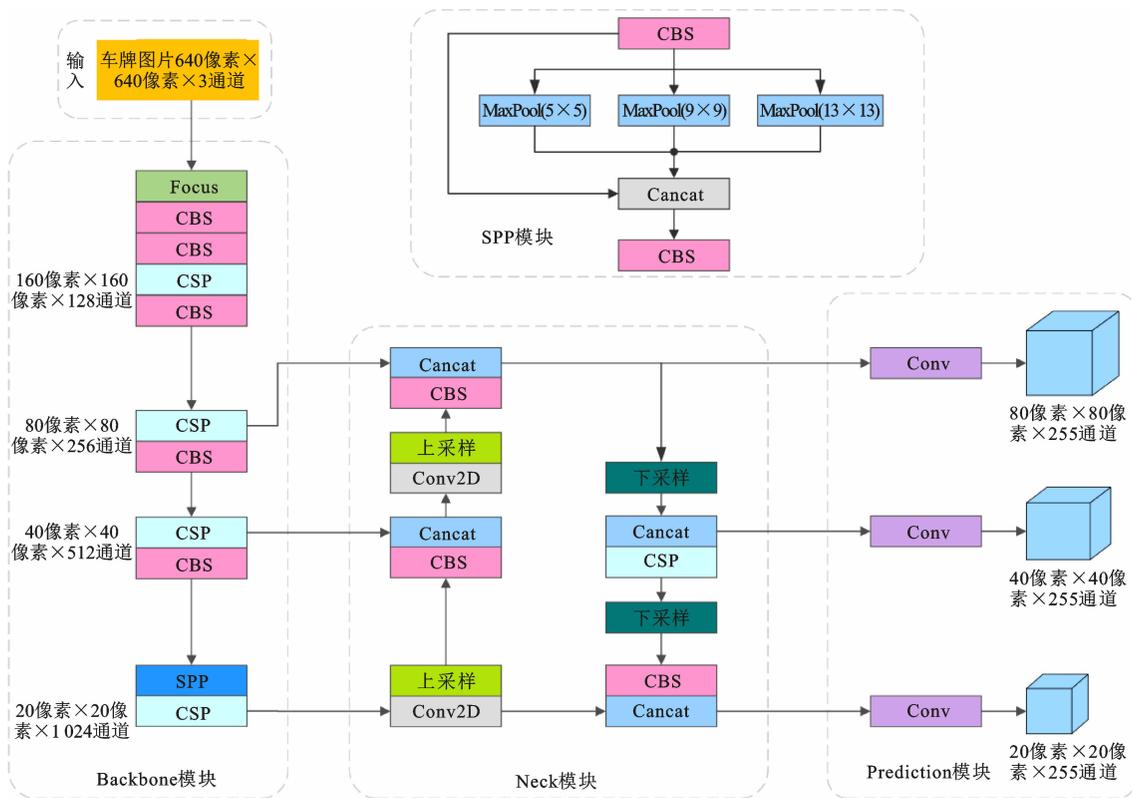


图3 YOLOv5网络整体结构

Fig. 3 Overall structure of YOLOv5 network

3 基于LPRNet的车牌识别方法

3.1 车牌畸变校正

通过YOLOv5网络对车牌定位可以获得处于不同位置的车牌,其中会出现大角度倾斜的车牌照片。无论是垂直方向还是水平方向倾斜,如果直接将这些车牌照片送入下一阶段的车牌识别网络,容易得到较低识别准确率^[13]。因此本文在对车牌照片字符识别之前先对大角度旋转的车牌照片进行矫正处理。

矫正处理前的预处理环节需要首先对车牌照片进行灰度处理获取有价值的车牌信息^[14]。其次灰度化车牌照片以便于提高车牌矫正的效率。本文将已灰度化的照片再经双边滤波处理,可以很好地保留边缘细节信息,避免照片高斯模糊后边缘信息丢失而不利于后续定位处理的问题。

双边滤波同时考虑邻域内像素空间邻近性及灰度相似性进行局部加权平均,在消除噪声的同时保留边缘^[15]。设输入车牌图像为 $f(x, y)$,滤波输出图像为 $g(x, y)$,双边滤波过程如式4所示

$$g(x, y) = \frac{\sum_{i, j} f(i, j) w(x, y, i, j)}{\sum_{i, j} w(x, y, i, j)} \quad (4)$$

式中: (x, y) 为当前处理点; (i, j) 为 (x, y) 邻域内的点; $w(x, y, i, j)$ 为加权系数,其综合考虑了相邻2点的距离和像素值差,如式5所示

$$w(x, y, i, j) = e^{-\left[\frac{(i-x)^2 + (j-y)^2}{2\sigma_d^2}\right]} - \left[\frac{f(i, j) - f(x, y)}{2\sigma_r}\right]^2 \quad (5)$$

式中: σ_d 为空间邻近度,用来控制滤波窗口中包含的像素个数; σ_r 为灰度邻近度,用来控制图像高频边缘的灰度信息。

为了验证所提算法是否可以用于复杂多变的道路条件,针对夜间、雾天、雪天3种恶劣环境下的车牌照片,添加高斯噪声模拟真实环境外部干扰,分别使用不同参数进行试验,最终得到适应不同环境的最佳参数。不同环境下双边滤波结果如图4~图6所示。

从图4~图6可以明显看出:高斯滤波后的图像虽然通过平滑滤除部分噪声,但同时也让车牌照片质量下降严重,边缘纹理十分模糊;而双边滤波由于融合空间邻近性与灰度相似性,图像质量有一定程度的下降,但车牌区域边缘纹理仍然得以保留。这表明所提出的双边滤波算法可以达到滤除噪声且保留边缘的目的。

车牌矫正利用透视旋转定律进行透射变换^[16-17],其变换过程遵从透视中心、像点、目标点3

图 4 夜间环境 ($\sigma_d=3, \sigma_r=1$)Fig. 4 Nocturnal environment ($\sigma_d=3, \sigma_r=1$)图 5 雾天环境 ($\sigma_d=3, \sigma_r=0.2$)Fig. 5 Foggy environment ($\sigma_d=3, \sigma_r=0.2$)图 6 雪天环境 ($\sigma_d=5, \sigma_r=0.2$)Fig. 6 Snow environment ($\sigma_d=5, \sigma_r=0.2$)

点共线的原则,使 1 张扭曲图像映射到新的成像平面上,得到符合正常视角观看的图片。

在许多交通场景下,假如直接对拍摄的照片进行透射变换,车牌之外许多区域的冗余像素值会降低算法运行效率,同时透射变换后的车牌位置也不准确^[18-19]。因此要对拍摄车牌照片进行透射变换,首先要找出矩形车牌照片边界的 4 个角点,然后送入透射变换模块进行车牌矫正得到正常视角的车牌照片。透视前照片和透视后照片之间的变换关系可以用以下变换矩阵表示

$$\begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = \begin{bmatrix} a_1 & a_2 & b_1 \\ a_3 & a_4 & b_2 \\ c_1 & c_2 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \quad (6)$$

式中: x, y 为车牌矩形区域的角点坐标; x', y' 为经过透射变换后新成像平面上的坐标; $\begin{bmatrix} a_1 & a_2 \\ a_3 & a_4 \end{bmatrix}$ 为对像素点进行旋转的矩阵; $\begin{bmatrix} b_1 \\ b_2 \end{bmatrix}$ 为对像素点进行平移

的向量; $\begin{bmatrix} c_1 & c_2 \end{bmatrix}$ 为对像素点进行投影的向量。

车牌照片数据常为二维,矩阵中三维坐标做置 1 处理。使用透射变换需要首先根据 4 个角点的坐标计算出 3×3 的变换矩阵,其次再根据此矩阵把车牌照片剩余像素点投影到新的成像平面。原车牌照片见图 7。



图 7 原车牌照片

Fig. 7 Original license plate pictures

3.2 基于图像增强的暗光车牌识别改进

车牌识别在夜间环境交通路段,容易遇到光线不足、车牌数字被物体阴影遮挡、曝光不足等问题,这些造成车牌识别系统应用场景受限^[20-21]。即使如今大多数目标检测网络精度、准确率不断提高,但对于欠曝光区域车牌信息大块丢失的车牌定位识别仍然是一大难题^[22-24]。本文提出一种彩色图像非线性增强的集成邻域相关的方法(INDANE),首先利用图像增强的方法恢复低照度下车牌照片信息,然后再将预处理后的车牌照片送入车牌识别系统。其主要实现步骤如下:

(1)将彩色车牌照片灰度化与量纲一化后,通过亮度变换对低光照区域进行亮度增强;

(2)对原始车牌照片 $I(x, y)$ 进行二维离散卷积,卷积核为高斯卷积核;

(3)将卷积结果 $I'(x, y)$ 中有相邻像素的亮度信息部分与中心像素进行对比度增强,其中对比度增强融合多尺度的卷积结果,以期得到最佳的图像效果;

(4)使用线性方法恢复彩色的车牌照片,具体如下

$$R_j(x, y) = R(x, y) \frac{I_j(x, y)}{I(x, y)} \lambda \quad (7)$$

式中: $I_j(x, y)$ 为原图像的 R、G、B 三通道增强后的像素值; $R(x, y)$ 为增强算子; $R_j(x, y)$ 为恢复后的彩色车牌图像; λ 用来调整 3 个光谱带的色调,本文中 λ 取值为 1。

本文选取 CCPD 数据集中夜间车牌照片进行图像增强测试,记录原图和经过图像增强后的车牌识别率,其暗光下车牌图像增强的效果如图 8 所示。

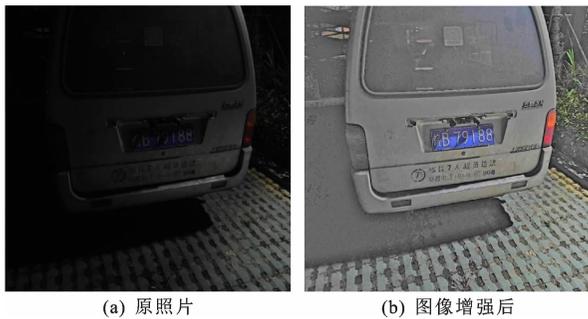


图8 暗光环境下车牌图像增强前后对比

Fig. 8 Contrast of license plate image before and after enhancement in dark environment

从图8可以明显看出:原照片由于物体阴影遮挡以及光线不足等原因,车牌数字、边框等信息几乎完全丢失,难以辨认;但经过INDANE图像增强后车牌照可以较好恢复低照度导致的信息丢失,还原的车牌照整体清晰、细节丰富、边缘信息丰富。表1给出图像增强后模型识别率,可见其针对暗光车牌的识别率提升10.97%。

表1 图像增强对模型识别率的影响

Tab. 1 Effects of image enhancement on model recognition rate

模型	原照片识别率	图像增强后识别率
YOLOv5+LPRNet	85.60	96.57

3.3 基于LPRNet的车牌字符识别

LPRNet网络结构中使用空间卷积替代空间序列LSTM,且替代后精度没有大幅降低。原因在于循环神经网络虽然具有记忆功能,可以连结上下文语义信息进行预测,但车牌序列的字符往往是若干个无语境的单个字符组合而成。因此,当RNN学习字符信息后去预测下一字符时,RNN的记忆功能对未知字符的识别作用有限,但产生的参数量与计算量是小型设备难以承受的。

LPRNet的主干提取网络采用全卷积结构来提取图像特征信息与车牌字符序列,见表2。它的主干提取网络共包含3个卷积层和3个小基本构建块,其后连接最大池化层和随机失活层。其中小基本构建块由4个卷积层和1个特征输出层组成,每次卷积操作后进行批量归一化后数据送入ReLU激活函数。

LPRNet子网络的输出是一个带有概率的字符序列,不同字符对应着自身不同的概率值,但由于解码器的RNN负责将向量映射输出时,目标序列长度会出现长短不同的问题,而使用具有可变长度编码的CTC可以避免这一问题。LPRNet解码过程

表2 LPRNet骨干网络结构

Tab. 2 LPRNet backbone network structure

网络层类型	参数
输入层	94 像素×24 像素,RGB 图像
卷积层	通道维度为 64,3 像素×3 像素,步长为 1
最大池化层	通道维度为 64,3 像素×3 像素,步长为 1
小基本构建块	通道维度为 128,3 像素×3 像素,步长为 1
最大池化层	通道维度为 64,3 像素×3 像素,步长为 2 或 1
小基本构建块	通道维度为 256,3 像素×3 像素,步长为 1
小基本构建块	通道维度为 256,3 像素×3 像素,步长为 1
最大池化层	通道维度为 64,3 像素×3 像素,步长为 2 或 1
随机失活层	0.5
卷积层	通道维度为 256,4 像素×1 像素,步长为 1
随机失活层	0.5
卷积层	分类类别为 1×13,步长为 1

中采用集束搜索,使得输出序列总概率最大化。

4 试验与验证分析

4.1 应用试验

CCPD是由中科大研发并公开发表的大型车牌开源数据集,其经过仔细标注的特性成为车牌定位网络研究的常用数据集。本文从CCPD数据集以及自建数据集中共挑选出15 755张车牌照,包括在停车场、路边以及夜间、倾斜、遮挡等复杂场景下的车牌照。本文训练过程中照片分配比例为训练集占80%,测试集占20%,网络训练选取的照片种类为距离较远的车牌、拍摄光线较暗的车牌、发生旋转的车牌、恶劣天气下的车牌。5种车牌种类照片数量均为3 151张。

在训练阶段,Epoch设置为200,优化器使用Adam,初始学习率设置为0.01,学习率递增递减步长设置为0.01,batch_size设置为32,权重衰减系数设置为0.000 5。试验软硬件版本参数如表3所示。

表3 软硬件版本及其参数

Tab. 3 Software and hardware version and its parameters

配置名称	版本
GPU	NVIDIA GTX1650
CPU	Intel(R) i5-9300H CPU @ 2.40 GHz
CUDA	Cuda10.1
PyTorch	1.10.0
Python	3.9

4.2 训练结果分析

图9为YOLOv5训练结果。可见:在模型训练过程中,随着迭代次数的不断增加,召回率提升迅

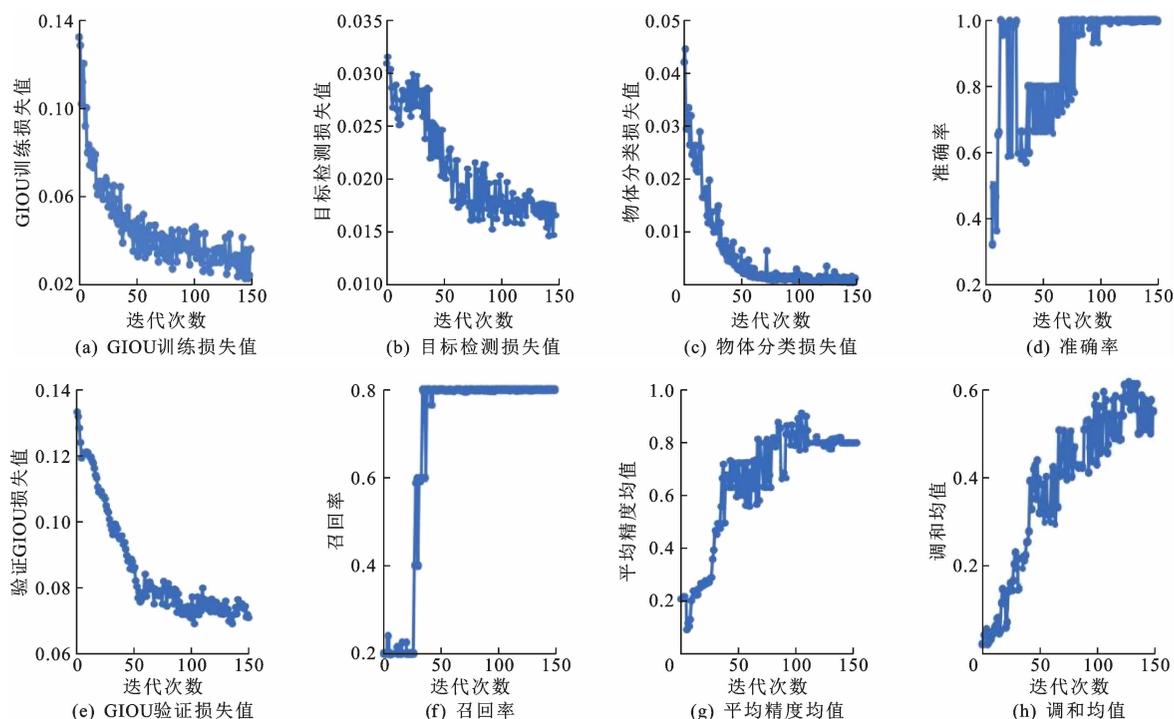


图 9 YOLOv5 训练结果

Fig. 9 YOLOv5 training result graph

速稳定,准确率虽有一定程度的波动,但等到模型收敛后其值可以稳定保持在 99% 以上;召回率可以稳定保持在 80% 附近。平均精度均值以及调和均值也最终稳定在一个较高的水平附近。GIOU 损失函数均值随着迭代次数的增加逐步下降,一直到 0.02 附近,代表预测框的准确性在一直提高。目标检测损失函数均值虽有波动反复,但也逐步下降到 0.015 附近,代表目标检测的精度逐步提高。物体分类损失函数均值下降迅速,迭代 100 次以后几乎不产生错误分类结果。此 3 类指标对应的 val 坐标图

像代表其模型在验证集上的结果,可以看到损失函数稳定下降,具有良好的训练效果。

4.3 验证集车牌识别效果及分析

本文验证集照片共选取 2 730 张不同场景车牌图像,车牌照照片共分为标准组、中长距离组、夜间环境组、雨雪雾天组、角度倾斜组分别进行识别。验证集每组包含 546 张,识别结果标注在原照片上。标准组车牌图像均为室外正面拍摄,拍摄距离较近,照片质量高,且拍摄角度无倾斜畸变,如图 10 所示。



图 10 标准组仿真结果

Fig. 10 Standard group simulation results

中长距离组中车牌图像均为在室外正面中距离或较远距离拍摄,照片质量高,且拍摄角度无倾斜畸变,如图 11 所示。

夜间环境组车牌图像均拍摄于夜晚灯光环境下,照片质量高,距离适中,且拍摄角度无倾斜畸变,如图 12 所示。

雨雪雾天组车牌图像均在雨、雪、雾等恶劣天气时拍摄,但照片质量高,光线良好,拍摄距离适中,如图 13 所示。

角度倾斜组车牌图像均在合适距离拍摄,照片质量高,光线良好,但角度倾斜导致车牌图像畸变,如图 14 所示。

5 组车牌图像仿真识别结果如表 4 所示。

通过上述验证集车牌识别结果分析可知,本文使用 YOLOv5+LPRNet 模型(模型 1)组合将车牌

识别率提升在 95% 以上,其中标准组车牌图像准确率达 97.56%,夜间环境组、角度倾斜组、雨雪雾天组的精确度分别为 96.57%、97.63%、95.52%。

从上述数据可以看出,本文对车牌的图像预处理、畸变矫正以及暗光条件下的图像增强方法,使得在车牌产生畸变以及暗光条件等复杂条件下仍得到不错的准确识别率。相较于传统车牌定位与车牌识别方法大多使用车辆颜色、大小和形状等方法,本文方法在复杂场景中的泛化能力更强,对于传统方法难以识别的车牌都有较好识别率,而且总体模型车牌识别精度、识别速度都达到了预期目标,可以满足实际生活场景的需要。

4.4 模型性能比较

将 YOLOv5+LPRNet 车牌识别模型与开源项目 Easy PR(模型 2)、HyperLPR(模型 3)、YOLOv3



图 11 中长距离组仿真结果

Fig. 11 Medium and long distance group simulation results



图 12 夜间环境组仿真结果

Fig. 12 Night environment group simulation results



图 13 雨雪雾天组仿真结果

Fig. 13 Rain, snow and fog group simulation results



图 14 角度倾斜组仿真结果

Fig. 14 Angle tilt group simulation results

表 4 车牌检测结果

Tab. 4 License plate detection results

类别	准确率/%	召回率/%	mAP 值/%	传输帧数/(帧·s ⁻¹)
标准	97.56	97.86	97.34	30
中长距离	97.44	96.23	95.86	31
夜间环境	96.57	95.13	95.48	33
雨雪雾天	95.52	95.16	96.35	32
角度倾斜	97.63	96.09	96.26	32
综合平均值	96.94	96.09	96.26	32

注:mAP 为平均精度均值。

(模型 4)以及 Faster-RCNN(模型 5)目标检测算法在本文构建的数据集中进行训练测试,对比检测结果如图 15 所示。

从图 15 可以看出:在 CCPD 数据集上本文提出方法(模型 1)的识别率、召回率分别可以达到 97.65%、96.74%。而且相较于传统的使用字符分

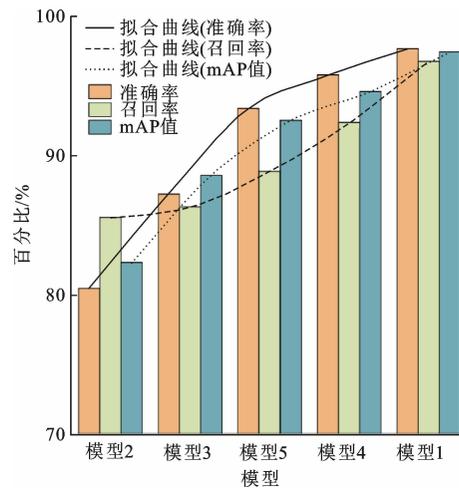


图 15 不同模型性能对比

Fig. 15 Performance comparisons of different models
割方法的 Easy PR、Hyper LPR、YOLOv5 与 LPR-

Net 融合的方法(模型 2~模型 4)将识别率分别提高 17.19%、10.42%，召回率分别提高 11.18%、10.43%；相比于两阶段的目标检测法 Faster-RCNN+LPRNet(模型 5)识别率提高 4.29%；与(模型 1)相比,识别率提高 1.88%。

5 结 语

(1)本文提出了一种在 YOLOv5+LPRNet 车牌识别模型上添加车牌矫正模块和暗光车牌识别改进模块;该方法采用一阶段的目标检测网络 YOLOv5 定位车牌位置,使用添加了 CTC 作为损失函数的 LPRNet 网络识别车牌字符,可以避免传统的字符分割错误带来的影响,最终综合车牌识别率可以提升到 95%以上;目前夜间环境下的车牌识别仍是大多数车牌识别算法的短板,本文通过提出一种低照度下图像增强的方法,将低光照、被阴影遮挡等条件下的车牌识别率提高 10.97%。经过选取组合数据集中暗光车牌照片进行试验,验证了此方法的效果。在车牌倾斜问题上采用双边滤波与透射变换的方式实现旋转车牌的矫正,角度倾斜组的车牌识别率达到 97.63%。

(2)后续研究中,可以在车牌定位与识别网络训练中使用 GAN 网络生成不同省份的车牌,扩充车牌数据集以应对车牌省份单一的问题,并针对污损车牌构建特定的识别网络,或添加污损车牌检测提示模块,进一步提高实际交通场景中的实用性。

参考文献:

References:

- [1] 杨鼎鼎,陈世强,刘静漪.基于车牌背景和字符颜色特征的车牌定位算法[J].计算机应用与软件,2018,35(12):216-221.
YANG Ding-ding, CHEN Shi-qiang, LIU Jing-yi. License plate location algorithm based on background and character color feature[J]. Computer Applications and Software, 2018, 35(12): 216-221.
- [2] 郭延祥,陈耀武.基于边缘检测和颜色纹理直方图的车牌定位方法[J].计算机科学与探索,2014,8(6):719-726.
GUO Yan-xiang, CHEN Yao-wu. Vehicle license plate location method based on edge detection and color-texture histogram[J]. Journal of Frontiers of Computer Science and Technology, 2014, 8(6): 719-726.
- [3] SELMI Z, BEN H M, ALIMI A M. Deep learning system for automatic license plate detection and recognition[C]//IEEE. Proceedings of 2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR). New York: IEEE, 2018: 1132-1138.
- [4] 王 燕,张继凯,尹 乾.基于 Faster R-CNN 的车牌识别算法[J].北京师范大学学报(自然科学版),2020,56(5):647-653.
WANG Yan, ZHANG Ji-kai, YIN Qian. License plate recognition algorithm based on Faster R-CNN[J]. Journal of Beijing Normal University (Natural Science), 2020, 56(5): 647-653.
- [5] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]//IEEE. Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). New York: IEEE, 2016: 779-788.
- [6] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]//Springer. Proceedings of Computer Vision-ECCV 2016 14th European Conference. Amsterdam: Springer International Publishing, 2016: 21-37.
- [7] 冯润华,苏婷婷,马晓伟. BP 神经网络联合模板匹配的车牌识别系统[J].清华大学学报(自然科学版),2013,53(9):1221-1226.
GUO Run-hua, SU Ting-ting, MA Xiao-wei. License plate recognition system using a BP neural network and template matching[J]. Journal of Tsinghua University (Science and Technology), 2013, 53(9): 1221-1226.
- [8] 胡成伟,袁明辉.基于 Harris 算子的车牌定位识别改进算法研究[J].电子测量技术,2019,42(24):138-142.
HU Cheng-wei, YUAN Ming-hui. Research on improved algorithm of license plate location and recognition based on Harris operator[J]. Electronic Measurement Technology, 2019, 42(24): 138-142.
- [9] ZOU Y J, ZHANG Y J, YAN J, et al. A robust license plate recognition model based on Bi-LSTM[J]. IEEE Access, 2020, 8: 211630-211641.
- [10] 欧先锋,向灿群,郭龙源,等.基于 Caffe 深度学习框架的车牌数字字符识别算法研究[J].四川大学学报(自然科学版),2017,54(5):971-977.
OU Xian-feng, XIANG Can-qun, GUO Long-yuan, et al. Research of recognition of digital characters on vehicle license based on Caffe deep learning framework[J]. Journal of Sichuan University (Natural Science Edition), 2017, 54(5): 971-977.
- [11] LIU Z, ZHU Y P. Vehicle license plate recognition in

- complex scenes [C]//IEEE. Proceedings of 2020 IEEE 5th International Conference on Intelligent Transportation Engineering (ICITE). New York, IEEE, 2020; 235-239.
- [12] 饶文军,谷玉海,朱腾腾,等. 基于深度学习的车牌智能识别方法[J]. 重庆理工大学学报(自然科学), 2021, 35(3): 119-127.
- RAO Wen-jun, GU Yu-hai, ZHU Teng-teng, et al. Intelligent license plate recognition method in complex environment[J]. Journal of Chongqing University of Technology (Natural Science), 2021, 35(3): 119-127.
- [13] 辛莉,赵钦炎,许茜,等. 基于计算机视觉的复杂场景车牌识别算法[J]. 制造业自动化, 2021, 43(12): 135-139.
- XIN Li, ZHAO Qin-yan, XU Qian, et al. License plate recognition algorithm in complex scenes based on computer vision [J]. Manufacturing Automation, 2021, 43(12): 135-139.
- [14] VALDEOS M, VADILLO V A S, REZ P M G, et al. Methodology for an automatic license plate recognition system using convolutional neural networks for a Peruvian case study[J]. IEEE Latin America Transactions, 2022, 20(6): 1032-1039.
- [15] HUANG Q Y, CAI Z C, LAN T. A new approach for character recognition of multi-style vehicle license plates[J]. IEEE Transactions on Multimedia, 2021, 23: 3768-3777.
- [16] CHRIS H, YOON A S, WOONG L S. Multinational license plate recognition using generalized character sequence detection[J]. IEEE Access, 2020, 8: 35185-35199.
- [17] WANG W H, TU J Y. Research on license plate recognition algorithms based on deep learning in complex environment[J]. IEEE Access, 2020, 8: 91661-91675.
- [18] RAGHUNANDAN K S, SHIVAKUMARA P, JALAB H A, et al. Riesz fractional based model for enhancing license plate detection and recognition[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2018, 28(9): 2276-2288.
- [19] 周晓君,高媛,李超杰,等. 基于多目标优化多任务学习的端到端车牌识别方法[J]. 控制理论与应用, 2021, 38(5): 676-688.
- ZHOU Xiao-jun, GAO Yuan, LI Chao-jie, et al. Multi-objective optimization based multi-task learning for end-to-end license plates recognition[J]. Control Theory & Applications, 2021, 38(5): 676-688.
- [20] 赵汉理,刘俊如,姜磊,等. 基于卷积神经网络的双车牌分割算法[J]. 计算机辅助设计与图形学学报, 2019, 31(8): 1320-1329.
- ZHAO Han-li, LIU Jun-ru, JIANG Lei, et al. Double-row license plate segmentation with convolutional neural networks[J]. Journal of Computer-Aided Design & Computer Graphics, 2019, 31(8): 1320-1329.
- [21] 张彩珍,李颖,康斌龙,等. 基于深度学习的模糊车牌字符识别算法[J]. 激光与光电子学进展, 2021, 58(16): 259-266.
- ZHANG Cai-zhen, LI Ying, KANG Bin-long, et al. Blurred license plate character recognition algorithm based on deep learning[J]. Laser & Optoelectronics Progress, 2021, 58(16): 259-266.
- [22] 王艳,谢广苏,沈晓宇. 一种基于MSER和SWT的新型车牌检测识别方法研究[J]. 计量学报, 2019, 40(1): 82-90.
- WANG Yan, XIE Guang-su, SHEN Xiao-yu. A new vehicle licence plate recognition method based on MSER and SWT[J]. Acta Metrologica Sinica, 2019, 40(1): 82-90.
- [23] 凌翔,赖锟,王昔鹏. 基于模板匹配方法的不均匀照度车牌图像识别[J]. 重庆交通大学学报(自然科学版), 2018, 37(8): 102-106.
- LING Xiang, LAI Kun, WANG Xi-peng. Uneven illumination license plate image recognition base on template matching method[J]. Journal of Chongqing Jiaotong University (Natural Science), 2018, 37(8): 102-106.
- [24] LI Rui-min, SHI Wang, JIAO Peng-peng, et al. Traffic control optimization strategy based on license plate recognition data[J]. Journal of Traffic and Transportation Engineering (English Edition), 2023, 10(1): 45-57.