

# 基于卷积神经网络的车牌定位算法

姜策<sup>1,2,3</sup>, 胡岸明<sup>1,3</sup>, 何为<sup>1\*</sup>

<sup>1</sup>中国科学院上海微系统与信息技术研究所无线传感网络重点实验室, 上海 201800;

<sup>2</sup>上海科技大学信息科学与技术学院, 上海 200120;

<sup>3</sup>中国科学院大学, 北京 100864

**摘要** 针对当前车牌识别系统在存在复杂环境以及车牌倾斜的情况下无法精确定位的问题, 提出一种基于卷积神经网络的端到端车牌精确定位算法, 从而精确计算车牌的坐标。通过 Faster R-CNN 对输入车辆图片中的信息进行处理, 提取候选区域的特征映射, 利用特征映射计算车牌的精确坐标。实验结果表明本文算法在 OpenITS 数据库的功能评测数据库中的平均识别准确率为 99%, 在性能评测数据库中的平均识别准确率为 85%。

**关键词** 图像处理; 卷积神经网络; Faster R-CNN; 车牌检测; 精确定位

中图分类号 TP391.4

文献标识码 A

doi: 10.3788/LOP57.021010

## Convolutional-Neural-Network Based License Plate Location Algorithm

Jiang Ce<sup>1,2,3</sup>, Hu Anming<sup>1,3</sup>, He Wei<sup>1\*</sup>

<sup>1</sup>Key Laboratory of Wireless Sensor Network and Communication, Shanghai Institute of Microsystem and Information Technology, Chinese Academy of Sciences, Shanghai 201800, China;

<sup>2</sup>School of Information Science and Technology, ShanghaiTech University, Shanghai 200120, China;

<sup>3</sup>University of Chinese Academy of Sciences, Beijing 100864, China

**Abstract** The existing license plate recognition system is unable to locate accurately in the cases of complex background and license plate tilting. To solve this issue, this study proposes an end-to-end license plate location algorithm based on a convolutional neural network to accurately calculate the license plate coordinates. The information is extracted based on the input vehicle picture using Faster R-CNN to obtain the feature mapping of the candidate area. Further, the license plate coordinates are precisely obtained using feature mapping. The experimental results denote that the recognition accuracy of the proposed algorithm is 99% with respect to the functional assessment database of the OpenITS database and 85% with respect to the performance evaluation database.

**Key words** image processing; convolutional neural network; Faster R-CNN; license plate detection; accurate location

**OCIS codes** 100.2000; 100.5010; 110.2970; 110.300

## 1 引言

近年来,私家车的占有量增多,人工交通管理负担增大,对交通自动管理提出了极大的需求。自动车牌识别系统(ALPR)作为智能交通系统的重要组成部分,通过对车辆车牌进行识别,自动监控车辆,极大减轻了交通管理的负担。除在交通管理上,

ALPR 在控制私人停车场车辆进出、高速公路收费、违规停车等场景下都有广泛应用。

常见的车牌识别系统包括车牌定位、字符分割和字符识别<sup>[1]</sup>,其中车牌定位准确度的高低对于字符分割和字符识别的准确度有着极大的影响。图像中车牌定位的传统方法是通过手动设计特征检测器,依据不同部分的特征,对图像中的车牌进行检

收稿日期: 2019-05-20; 修回日期: 2019-06-18; 录用日期: 2019-07-09

基金项目: 国家科技部重点研发计划(2018YFC1505204-2)

\* E-mail: wei.he@mail.sim.ac.cn

测,如:文献[2]中利用车牌的边缘信息对车牌进行定位;文献[3]中利用车牌独特的颜色对车牌进行定位;文献[4]利用车牌独有的纹理特征对车牌进行定位;文献[5]则是采用多种特征混合的方法进行识别。近年来由于深度学习的发展,基于深度学习的车牌检测开始应用在 ALPR 中并取得了较好的结果。文献[6]基于 YOLO 设计了车牌检测器并取得较好的识别准确率;文献[7]通过对图片的预处理,降低图片识别难度,再通过卷积神经网络(CNN)对车牌进行定位。这些方法将车牌近似为一个矩形,尽管对于复杂环境下的车牌识别有较高的精度,但对于倾斜车牌的识别结果会存在大量背景信息的冗余,这会对后续的字符切割和识别造成很大的干扰。对车牌坐标的精确定位可以在提高判断准确度的同时避免背景冗余信息的出现。文献[6]虽然实现了一定程度上的精确定位,但只考虑了简单的旋转,对更复杂形变的情况没有很好的识别结果;文献[8]提出精确定位车牌四个点坐标的网络,但是坐标预测网络为独立的网络,没有利用目标检测网络计算出特征值,且无法利用现有的数据集进行迁移学习,因而具有较高的训练难度。

本文提出一种基于 CNN 的车牌定位算法。该算法利用 Faster R-CNN<sup>[9]</sup>提取图片的特征映射,再基于计算出的特征值进行车牌坐标的精确计算。本文算法主要有两方面的优势:在复杂环境下,如车牌倾斜、车牌旋转、阴影遮挡、车牌模糊等,可以对车牌的坐标进行精确定位;可以通过提高目标检测算法精度提高定位的准确度。

## 2 Faster R-CNN

Faster R-CNN 是 R-CNN<sup>[10]</sup>的改进网络。R-CNN 通过 selective search 将输入图片生成若干个 region proposal,将每一个 region proposal 输入到 CNN 中对其进行目标类别和尺寸的预测。R-CNN 方法不仅在生成候选框时需要耗费大量的时间,且神经网络之间相互独立,这增大了待计算参数的数量,浪费了计算资源。针对 R-CNN 出现的问题,Faster R-CNN 对候选框的选取和目标预测方式进行了改进。

对于一张输入图片,Faster R-CNN 先使用 ResNet<sup>[11]</sup>计算图片的特征映射,根据预先设定的 anchor box,从特征映射中每个位置提取对应 anchor box 大小的特征图;在得到特征图之后,通过卷积网络对每一个特征图进行前景和背景的判断,

并输出对 anchor box 尺寸的修正,对尺寸修正后且认为是前景的 region proposal 进行下一阶段的处理;通过 ROI pooling,将处理后的 region proposal 映射为相同大小,随后将这些 region proposal 输入至卷积网络进行目标类别和坐标值的计算。由于直接预测坐标会存在极大的误差,Faster R-CNN 使用偏移量和尺度因子作为预测值,通过与 anchor 中心点的坐标和长宽进行比较,得到目标的坐标和尺寸。相较于 R-CNN,Faster R-CNN 不再使用 selective search 等传统方法生成 region proposal,而使用卷积神经网络生成 region proposal,这极大减少了生成 region proposal 需要的时间,并且该算法将所有的运算整合到了一个神经网络中,实现了网络参数的共享,减少了训练难度,从而提高了识别准确率和识别效率。

Faster R-CNN 由于是一种 two-stage 的目标检测方法,在目标检测的准确率尤其是小目标的检测准确率上会优于 one-stage 的目标检测方法,如 YOLO 等,对交通标志的识别准确率较高<sup>[12]</sup>。基于摄像机中的车牌往往会出现车牌在图像中占比很小的情况,因此选择 Faster R-CNN 作为改进网络的参考。Faster R-CNN 在 COCO<sup>[13]</sup>数据集上实现了 42.7% 的准确率,测试时识别一张图片需要 200 ms。

## 3 车牌定位算法

### 3.1 网络结构

车牌定位算法的网络结构如图 1 所示。在使用 Faster R-CNN 得到判断为前景且尺寸修正的 region proposal 之后,除了将 region proposal 输入到矩形框预测网络中进行矩形框与类别的预测,同时将 region proposal 输入到顶点预测网络(VertexNet)中,对车牌的坐标进行预测。因为车牌在目标检测问题中可以作为目标检测的一个类别,因此在超参数和权重的选择上可以参考 Faster R-CNN 的设定。本文选择 ResNet-50<sup>[11]</sup>作为 Faster R-CNN 骨架网络(backbone),并使用其通过 ImageNet<sup>[14]</sup>数据集训练的结果作为预训练权重。使用 COCO 数据集对 Faster R-CNN 进行训练,并将训练后的权重作为车牌定位算法的预训练。对于 anchor box,使用与 Faster R-CNN 相同的尺寸设定以保证对各种尺寸车牌的检测准确率。

### 3.2 顶点预测网络

顶点预测网络分为特征提取和预测两部分,网




图 1 神经网络结构

Fig. 1 Architecture of neural network

络结构如图 2 所示。将通过候选区域生成网络 (RPN) 得到的 region proposal 经过 ROI align 转换为大小相同的特征映射; 对特征映射进行线性变化得到图片中相应部分的特征提取; 为防止参数出现过拟合, 将特征图经过线性变换之后输入到 group




图 2 顶点预测网络结构

Fig. 2 Architecture of vertex prediction network

训练网络时, 对每一个 anchor 定义一个二分类的类别, 用于指定该 anchor 是否为正。认为以下两种情况下 anchor 的类别为正: 一个 anchor 和某一个标记的 box 有最大的 Intersection-over-Union (IOU, 用  $I_{IOU}$  表示); 一个 anchor 和任意一个标记的矩形框的 IOU 值大于 0.7 [9]。因此每一个归类为正的 anchor 都有一个与之匹配的标定 box。RPN 的损失函数定义为

$$L_{RPN}(\{p_{Ri}\}, \{t_{Ri}\}) = \sum_i L_{regcls}(p_{Ri}, p_{Ri}^*) + \sum_i p_{Ri}^* \cdot L_{reg}(t_{Ri}, t_{Ri}^*), \quad (1)$$

式中:  $p_{Ri}$  为 RPN 对于 anchor 类别的预测值;  $p_{Ri}^*$  为每个 anchor 是否为正的标定值;  $t_{Ri}$  为预测矩形框四个参数坐标;  $t_{Ri}^*$  为与 anchor IOU 最大的标定矩形框的四个参数坐标 [8];  $i$  代表 RPN 网络预测的每一个候选框。

在得到 RPN 生成的 region proposal 之后, 将预测值分别输入到 box 预测网络和 vertex 预测网络。添加 box 的预测网络是为了使训练出的模型能更好地对包含车牌的区域进行预测, 提高对顶点预测的准确度。根据 Faster R-CNN 的网络结构对包含车牌的矩形框进行预测, 损失函数定义为

$$L_{box}(\{P_{Bi}\}, \{t_{Bi}\}) = \sum_i L_{boxcls}(p_{Bi}, p_{Bi}^*) + \sum_i p_{Bi}^* \cdot L_{box}(t_{Bi}, t_{Bi}^*), \quad (2)$$

norm 层 [15] 并进行归一化处理; 最后将提取出的特征经线性变化, 得到对输出的预测。

### 3.3 损失函数

车牌定位算法的损失函数由 RPN, box 网络, vertex 网络的损失函数构成。

式中:  $p_{Bi}$  为矩形框是否为车牌区域的类别预测;  $p_{Bi}^*$  为矩形框是否为车牌区域的标定值;  $t_{Bi}$  为预测矩形框的中心的坐标和长宽;  $t_{Bi}^*$  为标定矩形框的左上点的坐标和长宽 [8]。

在构建车牌损失函数时, 引入部分先验知识。将车牌视为一个不规则的四边形, 车牌的四个点之间存在以下关系: 左上角点的横坐标小于右上角点的横坐标; 左上角点的纵坐标小于左下角点的纵坐标; 右上角点的纵坐标小于右下角点的纵坐标; 左下角点的横坐标小于右下角点的横坐标。由于坐标值在图片中的取值范围过大, 直接对坐标预测会增大网络的计算负担并且有极大的误差, 因此在 vertex 网络中对车牌的坐标预测采取相对偏移量形式。如果只对点进行预测, 那么预测点之间的相对距离缺乏量化的标准, 从而使预测四边形与标定四边形之间的 IOU 过小, 而对长宽的直接预测会增大误差和训练难度, 因此在 vertex 网络中通过添加长宽相对比例进行衡量。标定值与预测值满足:

$$\begin{cases} t_{xi} = \frac{x_i - x_{ai}}{w_a}, & t_{yi} = \frac{y_i - y_{ai}}{h_a} \\ t_{wi} = \log(w_i/w_a), & t_{hi} = \log(h_i/h_a) \end{cases}, \quad (3)$$

$$\begin{cases} t_{xi}^* = \frac{x_i^* - x_{ai}}{w_a}, & t_{yi}^* = \frac{y_i^* - y_{ai}}{h_a} \\ t_{wi}^* = \log(w_i^*/w_a), & t_{hi}^* = \log(h_i^*/h_a) \end{cases}, \quad (4)$$

式中:  $x_i$  为预测顶点的横坐标,  $y_i$  为预测顶点的纵坐标;  $x_i^*$  为标定顶点的横坐标,  $y_i^*$  为标定顶点的纵坐标;  $x_{ai}$  为 anchor 的顶点横坐标,  $y_{ai}$  为 anchor 顶点的纵坐标;  $w_i$  为预测四边形顶点横坐标的差值,  $w_i^*$  为标定四边形顶点横坐标的差值;  $w_a$  为 anchor 的宽;  $h_i$  为预测四边形顶点纵坐标的差值,  $h_i^*$  为标定四边形顶点纵坐标的差值,  $h_a$  为 anchor 的长。计算出的值可认为是顶点预测的回归参数。网络中选择四边形左上角点的横纵坐标, 右下角点的横纵坐标, 左上角点与右上角点横坐标之间的差值, 右上角点与右下角点纵坐标之间的差值, 左上角点与左下角点纵坐标之间的差值, 左下角点与右下角点横坐标之间的差值来计算回归参数。

为提高预测相对位移的准确度, 采取对相应的点求偏移值的方法, 即比较四边形的左上角点与 anchor 的左上角点, 右下角点与 anchor 的右下角

点。顶点预测网络的损失函数定义为

$$L_{\text{vex}}(\{P_{Vi}\}, \{t_{Vi}\}) = \sum_i p_{Vi}^* (|t_{xi} - t_{xi}^*| + |t_{yi} - t_{yi}^*| + |t_{wi} - t_{wi}^*| + |t_{hi} - t_{hi}^*|), \quad (5)$$

式中:  $P_{Vi}$  为顶点预测网络的预测值;  $t_{Vi}$  为顶点预测网络的标定值。

因此整个网络的损失函数定义为

$$L = L_{\text{RPN}} + L_{\text{box}} + L_{\text{vex}}. \quad (6)$$

## 4 实验结果与分析

### 4.1 数据准备

本文数据集使用中山大学 OpenITS 公共服务平台提供的 Open Data——功能性能车牌数据库作为车牌检测数据集。对图片中车牌的四个角点进行数据标记, 并对包含四个点的最小矩形框进行标记, 生成标记文件, 如图 3 所示。



图 3 数据标记示例

Fig. 3 Examples of data annotation

为了使训练集图片包括更多的复杂环境和车牌位置, 引入数据增强算法对训练集进行处理, 如图 4 所示。为了使训练集中车牌的旋转角度尽量符合现实中的车牌旋转角度, 对训练集中的车牌进行角度变换, 使车牌数据旋转随机角度; 在图像拍摄的过程中, 车牌有极大的可能位于图片的中心区域, 为了提高对位于图像边缘车牌的检验准确率, 对图像中的车进行随机长度的位移; 为了使训练集更好地拟合现实环境中的光照条件, 对训练集图像的对比度进行调整<sup>[16-17]</sup>; 为了降低模型对图片中背景的依赖, 对图片中车牌附近的区域进行随机切割。通过数据增强算法, 将训练集中的照片扩大 200 倍。

### 4.2 实验结果

Open Data——功能性能车牌数据库分为功能

评测图像库和性能评测图像库。功能评测图像库中图片为车辆的正面图片, 车牌在图片中为一近似矩形; 性能评测图像库中图片则是对车牌图片进行不同处理后的图片, 如改变分辨率、改变亮度、进行旋转等。将性能评测图像库中的图片按 6:4 的比例划分, 分别作为训练集和测试集 1。为了检测模型对不同情况下车牌的识别准确率, 将性能评测图像库中图片作为测试集 2。预测结果如图 5 所示。

训练结束后, 首先在测试集 1 和 2 中检验算法的性能。表 1 分别为检验不同 IOU 条件下模型在测试集 1 和 2 中的准确率。

由表 1 可知, 直接使用坐标点预测的 IOU 表现较差。该方法虽然可以较为准确地确定车牌的位置, 但由于没有长宽的限制, 因此预测的结果往往与




图 4 数据增强示例

Fig. 4 Examples of data augmentation



图 5 预测结果示例

Fig. 5 Examples of prediction results

IOU 大于 0.6 时,算法定位的结果不会丢失车牌中的字符数据,因此对后续字符的识别不会产生影响。在测试集 2 上,本算法的准确率表现出明显的下降。通过对误识图片的分析,发现水平倾斜大于  $60^\circ$ 、竖直错切角大于  $44^\circ$ 、照片尺寸  $\leq 75$  dpi、亮度差大于 130 nit( $1 \text{ nit} = 1 \text{ cd/m}^2$ )的情况下均无法准确定位,其中在存在亮度差的图片中,模型只能框出高亮度的部分而对亮度低的部分无法圈出。

考虑到车牌坐标的错误预测可能与矩形框的错误预测有关,因此对矩形框正确预测(矩形框将车牌完全包含)下的车牌坐标预测的准确度进行统计,结果如表 2 所示。

表 2 模型在正确矩形标注下的准确度

Table 2 Accuracy of proposed model under correct rectangular labeling

Model	$I_{IOU}=0.6$		$I_{IOU}=0.7$		$I_{IOU}=0.8$	
	Test 1	Test 2	Test 1	Test 2	Test 1	Test 2
Ours	0.997	0.995	0.994	0.993	0.993	0.992

表 2 说明在矩形框正确预测情况下,模型对车牌的顶点坐标有很高的预测准确性。因此提升基础网络目标检测的准确性可以在一定条件下提升对车牌预测的准确性。同时,采用 YOLOv3 与 Faster R-CNN 对训练集中车牌定位的准确度进行对比,实验结果表明 Faster R-CNN 对测试集中的数据,特别是小尺寸的车牌有更好的定位效果。

为验证添加 vertex 网络对目标检测准确度的影响,使用训练集对 Faster R-CNN 进行训练,并对两个网络在测试集 1 和 2 中的表现性能进行比较,结果如表 3 所示。

表 1 模型在测试集 1 和 2 中的准确率表现

Table 1 Accuracy of models in test 1 and test 2

Model	$I_{IOU}=0.6$		$I_{IOU}=0.7$		$I_{IOU}=0.8$	
	Test 1	Test 2	Test 1	Test 2	Test 1	Test 2
Ours	0.995	0.852	0.993	0.812	0.988	0.752
Ours-only use point	0.985	0.652	0.983	0.611	0.979	0.598
WPOD <sup>[8]</sup>	0.992	0.834	0.981	0.785	0.963	0.719
ALMD-YOLO <sup>[6]</sup>	0.914	0.757	0.878	0.732	0.866	0.623
Model in Ref. [18]	0.941	0.792	0.913	0.744	0.885	0.662
Model in Ref. [19]	0.958	0.764	0.927	0.733	0.914	0.631

标定值在长宽上的差距较大,如图 6 所示。



图 6 使用坐标点预测结果示例

Fig. 6 Examples of prediction results using coordinate points

根据表 1,本算法在测试集 1 上实现了高准确率。通过对实验结果的观察和统计,可以得到:当

表3 两模型在测试集1和2中的准确度表现

Table 3 Accuracy of two models in test 1 and test 2

Model	$I_{IOU}=0.6$		$I_{IOU}=0.7$		$I_{IOU}=0.8$	
	Test 1	Test 2	Test 1	Test 2	Test 1	Test 2
Faster R-CNN	0.998	0.854	0.991	0.818	0.918	0.755
Ours	0.993	0.852	0.988	0.818	0.905	0.753

对比表3的数据,可以发现添加 vertex 预测网络对目标的检测影响很小,结合表2的结论可以得出在提高目标检测准确性的前提下,对网络添加 vertex 预测网络可以极大提高车牌坐标的精确定位。

## 5 结 论

提出中文车牌检测算法,可以准确计算车牌的精确坐标。针对训练集难以标注及训练集难以很好地覆盖现实环境中的复杂环境,引入数据增强算法,该算法通过 vertex 网络在测试集上取得较好的表现性能。通过实验验证 vertex 网络可以依托提高目标检测网络的准确度实现更高的车牌检测准确率。实验结果表明该方法对现实情况中的车牌信息具有较高的识别精度,可以满足实际应用的需要。

## 参 考 文 献

- [1] Du S, Ibrahim M, Shehata M, et al. 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.
- [2] Zheng D N, Zhao Y N, Wang J X. An efficient method of license plate location [J]. *Pattern Recognition Letters*, 2005, 26(15): 2431-2438.
- [3] Shi X F, Zhao W Z, Shen Y H. Automatic license plate recognition system based on color image processing[M]//Gervasi O, Gavrilova M L, Kumar V, et al. *Computational science and its applications-ICCSA 2005. Lecture notes in computer science*. Berlin, Heidelberg: Springer, 2005, 3483: 1159-1168.
- [4] Nathan V S L, Ramkumar J, Kamakshi Priya S. New approaches for license plate recognition system [C]//*International Conference on Intelligent Sensing and Information Processing*, 2004. *Proceedings of*, January 4-7, 2004, Chennai, India. New York: IEEE, 2004: 149-152.
- [5] Zhang B L, Tang H J. An approach to locate multi-license plates in complex vehicle images [J]. *Acta*

*Photonica Sinica*, 2007, 36(1): 184-187.

张变莲,唐慧君.一种复杂车辆图像中的多车牌定位方法[J].*光子学报*, 2007, 36(1): 184-187.

- [6] Xie L L, Ahmad T, Jin L W, et al. A new CNN-based method for multi-directional car license plate detection [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, 19(2): 507-517.
- [7] Selmi Z, Halima M B, Alimi A M. Deep learning system for automatic license plate detection and recognition [C] // *2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR)*, November 9-15, 2017, Kyoto, Japan. New York: IEEE, 2017: 1132-1138.
- [8] Silva S M, Jung C R. License plate detection and recognition in unconstrained scenarios[M] // Ferrari V, Hebert M, Sminchisescu C, et al. *Computer vision-ECCV 2018. Lecture notes in computer science*. Cham: Springer, 2018, 11216: 593-609.
- [9] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [C] // *Advances in Neural Information Processing Systems 28 (NIPS 2015)*, December 7-12, 2015, Montreal, Quebec, Canada. Canada: NIPS, 2015: 91-99.
- [10] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C] // *2014 IEEE Conference on Computer Vision and Pattern Recognition*, June 23-28, 2014, Columbus, OH, USA. New York: IEEE, 2014: 580-587.
- [11] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C] // *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 770-778.
- [12] Tong Y, Yang H C. Real-time traffic sign detection method based on improved convolution neural network [J]. *Laser & Optoelectronics Progress*, 2019, 56(7): 071003.  
童英,杨会成.基于改进卷积神经网络的实时交通标志检测方法[J].*激光与光电子学进展*, 2019, 56(7): 071003.
- [13] Lin T Y, Maire M, Belongie S, et al. Microsoft COCO: common objects in context[M] // Fleet D, Pajdla T, Schiele B, et al. *Computer vision-ECCV 2014. Lecture notes in computer science*. Cham: Springer, 2014, 8693: 740-755.
- [14] Russakovsky O, Deng J, Su H, et al. ImageNet

- large scale visual recognition challenge [J]. International Journal of Computer Vision, 2015, 115(3): 211-252.
- [15] Wu Y X, He K M. Group normalization [C] // Proceedings of the European Conference on Computer Vision (ECCV), September 8-14, 2018, Munich, Germany. New York: IEEE, 2018: 3-19.
- [16] Fei Y J, Shao F. Contrast adjustment based on image retrieval [J]. Laser & Optoelectronics Progress, 2018, 55(5): 051002.  
费延佳, 邵枫. 基于图像检索的对比度调整[J]. 激光与光电子学进展, 2018, 55(5): 051002.
- [17] Wang Y X, Diao M, Han C. Underwater image enhancement algorithm based on iterative histogram equalization with conventional light source[J]. Acta Photonica Sinica, 2018, 47(11): 1101002.  
王永鑫, 刁鸣, 韩闯. 基于迭代直方图均衡化的常规光源下水下成像增强算法[J]. 光子学报, 2018, 47(11): 1101002.
- [18] Li H, Shen C H. Reading car license plates using deep convolutional neural networks and LSTMs [J/OL]. (2016-01-21) [2019-05-19]. <https://arxiv.org/abs/1601.05610>.
- [19] 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.