

基于深度学习的模糊车牌字符识别算法

张彩珍, 李颖*, 康斌龙, 常元

兰州交通大学电子与信息工程学院, 甘肃 兰州 730070

摘要 随着城市智慧停车场的建设和高速路口自动收费系统的普及, 基于深度学习的车牌识别技术得到越来越广泛的应用。为了解决现实中模糊车牌的字符识别, 提出一种基于改进 CRNN + CTC (Convolutional Neural Network + Recurrent Neural Network + Connectionist Temporal Classification) 的免字符分割车牌字符识别算法。首先将 CRNN 中的标准 CNN 改为深度可分离卷积网络的微改模型, RNN 采用双向长短期记忆网络, 并引入 CTC 损失函数对其进行训练; 其次为了避免训练过程中的过拟合现象, 损失函数中加入 L2 正则项, 并增加训练数据集; 最后引入批量归一化算法来加快训练过程中的学习速度。实验结果表明, 与其他几种基于复杂环境中的方法相比, 本文算法在三个实验测试集上的平均车牌识别准确率、识别精度和速度方面均有一定提升, 网络的鲁棒性和泛化能力也更强。

关键词 图像处理; 深度学习; CNN; RNN; 车牌识别

中图分类号 TP391.1

文献标志码 A

doi: 10.3788/LOP202158.1610012

Blurred License Plate Character Recognition Algorithm Based on Deep Learning

Zhang Caizhen, Li Ying*, Kang binlong, Chang yuan

School of Electronics and Information Engineering, Lanzhou Jiaotong University, Lanzhou, Gansu 730073, China

Abstract With the construction of urban smart parking lots and the popularization of automatic toll collection systems at high-speed intersections, license plate recognition technology based on deep learning has been widely used. In order to solve a large number of blurred license plate character recognition in reality, a character free segmentation license plate character recognition algorithm based on improved CRNN + CTC (Recurrent Neural Network/Convolutional Neural Network + Connectionist Temporal Classification) is proposed. Firstly, the standard CNN in CRNN is changed into a micro-modified model of deeply separable convolutional network. Bi-directional long-term and short-term memory network is adopted in RNN, and CTC loss is introduced to train it. Secondly, in order to avoid the overfitting phenomenon in the training process, L2 regular term is added into the loss function and the training dataset is added. Finally, a batch normalization algorithm is introduced to accelerate the learning speed in the training process. Experimental results show that the proposed algorithm is applied to three experimental test sets. Experimental results show that compared with other methods based on complex environment, the proposed algorithm improves the average license plate recognition accuracy, recognition accuracy and speed on the three experimental test sets, and the robustness and generalization ability of the network are also stronger.

Key words image processing; deep learning; convolutional neural network; recurrent neural network; license plate recognition

OCIS codes 100.2000; 100.5010; 110.2970; 110.3000

收稿日期: 2020-11-13; 修回日期: 2020-12-03; 录用日期: 2020-12-22

基金项目: 国家自然科学基金青年科学基金(61905102)、甘肃省高等学校创新能力提升项目(2019A-035)

通信作者: *873238393@qq.com

1 引言

车牌识别(LPR)是智能交通管理系统中的关键环节,随着国内智慧停车场的建设以及高速公路自动收费系统的普及,智能交通管理系统对车牌识别的速度与准确度方面提出了更高的要求。LPR 技术主要分为车牌定位技术和车牌字符识别技术,定位技术在国内外的发展较为成熟,尤其 Slimani 等^[1]基于小波分解和卷积神经网络(CNN)对车牌区域进行定位,定位的准确率高达 99.43%,在普通自然环境下达到了近乎 100%的准确率。目前国内较常用的车牌识别技术却只有 86.4%的准确率^[2-6],远低于定位过程中定位的准确率。这些主流的识别方法中大多数还是传统的基于字符分割的方法,而这些方法在车牌识别环境复杂、车牌模糊等情况下,面临着算法局限性大、性能低等问题。因此,对车牌字符识别技术进行革新仍具有较高的研究意义。

现有的 LPR 方法大致可分为基于字符分割的方法和字符无分割的方法两类,其中基于字符分割的方法执行分割步骤来分离字符,再进行单个字符的逐一识别,常见的有基于支持向量机(Support Vector Machine, SVM)^[7]、基于投影^[8]、基于灰度量化^[9]和基于模板匹配^[10]的方法。然而上述基于字符分割的方法易受到识别环境的影响,存在分割和识别阶段误差累积的现象,且这些方法需手动设置适当的参数,因此这些方法在实际应用过程中不够稳健。基于字符无分割的方法是识别所有字符,而不使用特定的结构分离字符。目前基于字符无分割的车牌识别方法均属于深度学习领域,该方法能保留车牌图像内部的整体信息,同时不受分割结果的影响,对模糊车牌的识别有一定优势。主流的无分割识别算法主要分为基于 CNN、基于循环神经网络(RNN)和基于两者的组合网络 CNN + RNN (CRNN)三种类型。文献[11-12]使用 CNN 作为车牌字符的分类器,将车牌当成一个整体,由 CNN 定位每个字符所属的位置和类别,最终输出不同位置处字符的整体识别结果。文献[13-14]充分利用 RNN 具有很强的捕获序列上下文信息的能力,将车牌作为序列问题来解决,这种方法比 CNN 独立处理每个低分辨率车牌字符更加稳定和有效。文献[15]中的 LPR-Net、文献[16]中的 Mask R-CNN,以及文献[17]中的 CRNN + CTC (Connectionist Temporal Classification)网络均是将 CNN 和 RNN

进行结合,使得对车牌字符的识别性能达到了新的高度。文献[18]提出了改进的 CRNN + CTC 车牌识别网络,其字符识别率在理想条件下能达到 98.7%,但存在的问题是网络在训练时易产生过拟合的现象,且网络的结构复杂度和计算量仍有降低空间。

为了提高算法在车牌扭曲变形、字符模糊不清情况下的字符识别率,较少网络训练时的过拟合现象,提高识别速度。本文在如下方面开展研究:1)在已有 CRNN + CTC 网络模型的基础上实现免字符分割方式的端到端车牌字符识别,避免基于字符分割的传统方法所导致的误差累积问题;2)对原始 CRNN + CTC 模型的内部组成网络进行调整,降低网络模型的大小以及运算量;3)对 CNN 和 RNN 进行重塑,并在 CTC 模块中加入 L2 范数正则化以降低训练过程中过拟合现象发生的概率,其次增加辅助损失函数以加速模型收敛的速度,进而提升模型整体的泛化能力和识别性能;4)针对性地增加网络训练数据集,尤其是增加由车牌自身以及环境原因造成字符模糊的车牌图像;5)引入 BN (Batch Normalization)算法以加速神经网络的训练。

2 本文算法

为了避免基于字符分割方法中的误差累积现象,改善单个 CNN 或 RNN 在复杂环境中的识别性能,降低网络复杂度并解决过拟合现象。本文提出了一种基于改进 CRNN + CTC 的车牌字符识别算法。以文献[18]中提出的网络模型架构为基础,利用 CNN + RNN 来提取图像的时序特征,再使用 CTC 的损失函数来确定字符数量以及最终的字符识别结果。由于文献[18]的方法在训练过程中容易产生过拟合现象且网络计算量较大,因此本文首先对 CRNN 模块中的基础网络进行改进,引入带残差连接的深度可分离卷积替代原文 VGG-16 (Visual Geometry Group-16)网络,以减少网络的参数量,继而减少最终的模型大小和运算量。其次将 RNN 模块中的标准网络改为双向长短期记忆网络 (Bi-LSTM)。最后引入 CTC 模块对网络进行训练,并在损失函数中加入 L2 范数正则化,使网络在训练过程中参数冗余所带来的数值变化降到最小,进而减少过拟合现象的发生。

2.1 基于改进 CRNN + CTC 的车牌识别算法

CRNN + CTC 的免分割车牌识别算法主要由一个多层次网络模型构成,网络模型主要包含 CNN、RNN、CTC 三部分。首先将车牌图像输入

CNN 中以提取特征图,并将其中的标准卷积替换为带残差连接的深度可分离卷积。得到车牌图像的特征图后,将其转换为特征序列,使用双向循环神经网络对 CNN 所提取的特征序列进行学习和预测。最后由 CTC 将循环层获取的标签分布通过去重整合等操作转换成最终的识别结果。

2.1.1 CNN 模块

原始 CNN 采用 VGG-16 网络模型,通过多个卷积层提取车牌的多维特征,但深层的网络结构会导致网络参数量和模型大小较为庞大。在实际应用中,车牌字符识别算法常需要嵌入到固定或者移动

设备中,模型过大无疑会增加算法的部署成本和难度。本文使用深度可分离卷积神经网络替换 CRNN 中的 8 层卷积网络,减少了卷积层的计算量,在压缩模型大小的同时提升了模型的计算速度。深度可分离卷积将标准卷积操作分为深度卷积和 1×1 的逐点卷积,深度卷积起滤波作用,逐点卷积用来进行通道的转换,最终得到使用深度可分离卷积计算出的特征。深度可分离卷积块以及改进后的 CNN 如图 1 所示,其中 K 、 S 和 P 分别为卷积核大小、步长和填充大小,RGB 为红绿蓝通道,ReLU 为线性整流函数。

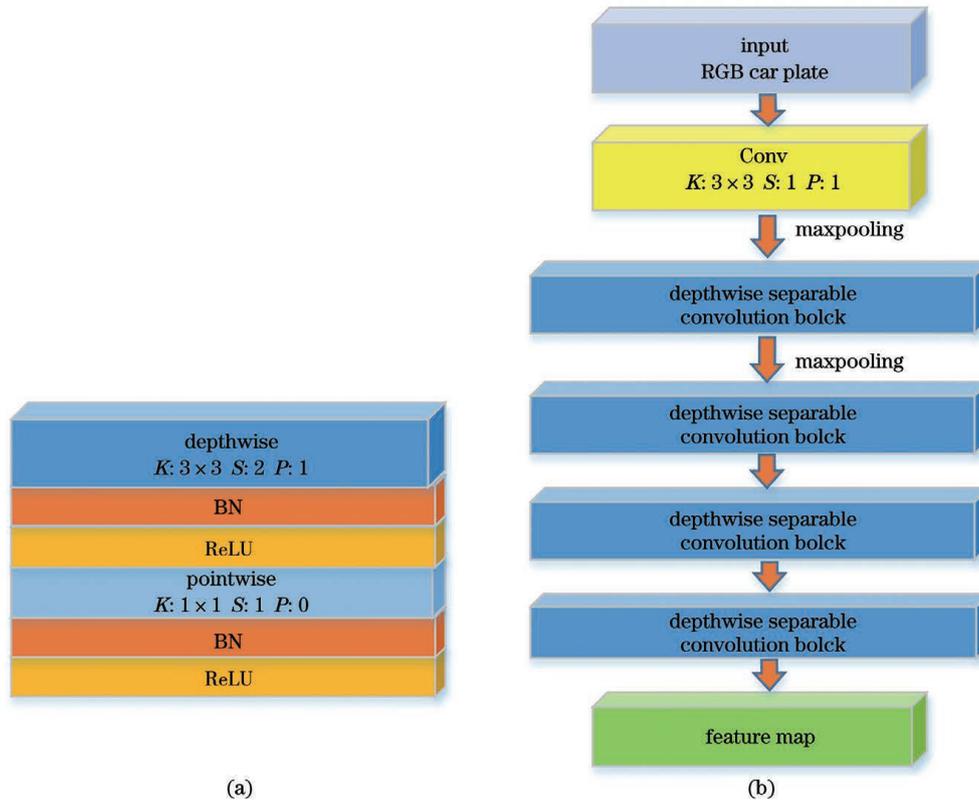


图 1 CNN 结构配置。(a)深度可分离卷积块;(b)CNN 结构

Fig. 1 CNN configuration diagram. (a) Depthwise separable convolution bolck; (b) CNN structure

CNN 输入的是尺寸为 $160 \text{ pixel} \times 48 \text{ pixel}$ 的 RGB 车牌图像,经过一个 3×3 卷积核的卷积层和一次极大值池化操作后送入到深度可分离卷积层,得到第一层图像特征后经过一次极大值池化送入到下一个深度可分离卷积层中以获取更深层的特征。经过 4 层的深度可分离卷积的特征提取后输出图像的特征图。

2.1.2 RNN 模块

传统的 RNN 单元存在梯度消失的问题,因此限制了其可以存储的上下文范围,增加了训练过程中的负担。本文在 RNN 模块设计时改用长短期记

忆模型(LSTM),LSTM 属于递归神经网络的一种,用于解决前后有关联的序列,适合处理和预测时间序列中间隔及延迟较长的事件。但 LSTM 和 RNN 都存在只能以一个固定方向进行预测的问题,导致前后时刻的重要度不同。本文在 RNN 阶段使用 Bi-LSTM,其中正向 LSTM 捕获车牌上文的特征信息,反向 LSTM 捕获了下文的特征信息。相对于单向 LSTM 而言,本文的 Bi-LSTM 能捕获更多的信息,同时,Bi-LSTM 结构比 LSTM 更加容易提取更高层次的抽象特征,更有助于分类。Bi-LSTM 的结构如图 2 所示,其中 x 表示输入特征, x_i 表示第

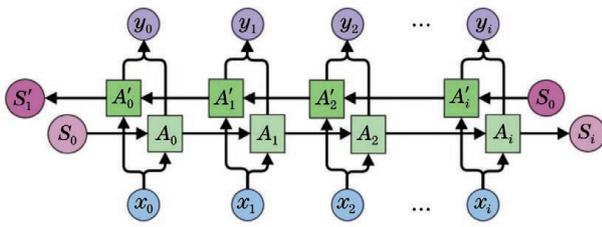


图 2 Bi-LSTM 网络模型的结构

Fig. 2 Structure of Bi-LSTM network model

$i+1$ 个特征, y 表示输出的分类概率, A 表示网络中的记忆单元, S 表示输入门(决定将哪些输入信息提取到下一个记忆单元), 因为双向长短期记忆网络是将输入正向和反向各处理一次, 因此网络中的 A 和 A' 分别表示正向记忆单元和反向记忆单元。

将 CNN 的输出结果 $[b, c, \omega]$ 经过转化变为 $[\omega, b, c]$ 并作为 RNN 的输入, 即 $[\omega, b, c] = [\text{seq_len}, \text{batch}, \text{input_size}]$, 其中 seq_len 为序列长度, batch 为批尺寸, input_size 为输入特征数目。再由 Bi-LSTM 对输入的特征序列进行学习和预测。

整个 CRNN 的处理流程如图 3 所示。通过 CNN 提取车牌图像的特征图, 将三个通道大小为 $160 \text{ pixel} \times 48 \text{ pixel}$ 的车牌图像转换为 $1 \times 25 \times 512$ 大小的卷积特征矩阵。然后将每一个通道作为特征长度 $D=512$ 和时间步长为 25 的时间序列并输入到 Bi-LSTM 中, 经过归一化指数函数 Softmax 计算后输出后验概率矩阵。

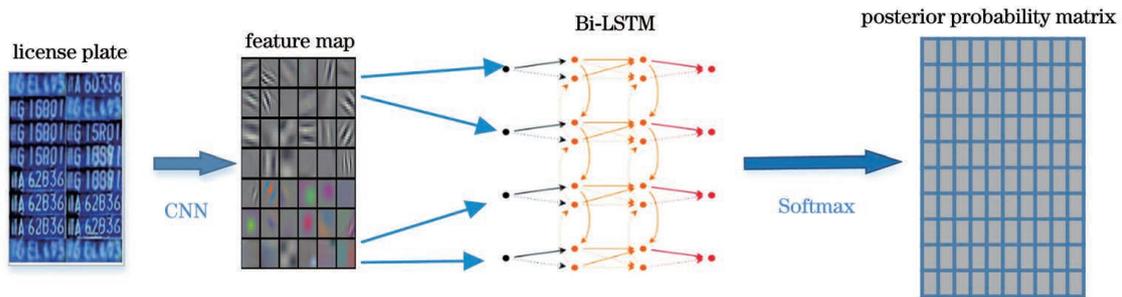


图 3 CRNN 算法的流程

Fig. 3 Process of CRNN algorithm

2.1.3 CTC 损失函数

当对 RNN 进行训练时, 如果使用常见的交叉熵损失函数, 则每一列输出都需要对应一个字符元素, 且每张样本图片需要标记出每个字符在图片中的位置, 再通过 CNN 的感受野将标记出的字符位置对齐到特征图的每一列, 最终获取该列输出对应的标签后才能进行训练。在识别中国车牌字符的实际应用中, 由于这些字符的长度、数量存在差异, 且识别过程中无法预知应该输出多长的文字, 因此使用常见的交叉熵函数训练出的网络, 识别效果不够理想。改进算法有两种: 采用 Seq2seq+ Attention 机制, 不限制输出长度, 在最后加一个结束符号, 让模型自动和标签对齐; 另一种是引入 CTC 损失函数, 即给定一个模型输出的最大长度, 且输出并未与标签对齐。其中 Seq2seq+ Attention 机制更适合应用于语音识别领域, 但计算量更大。因此, 本文采用 CTC 损失函数来训练 RNN。CTC 损失函数本质上是使所有路径的概率和最大, 其特点是引入空字符, 且能通过递推运算实现梯度的快速计算。

本文在传统 CTC^[19] 的基础上, 借鉴了隐马尔科

夫模型(HMM)的前向和后向算法思路, 利用动态规划算法计算出了 CTC 损失函数及其导数, 从而解决 RNN 训练过程中存在的问题。结合 CTC 解码算法使 RNN 能准确对序列数据进行端到端的预测。最后, 为了减少训练过程中过拟合现象的发生, 使训练结果更加具有鲁棒性, 在损失函数中引入权重衰减, 即在原来损失函数的基础上添加 L2 范数正则项。

假设给定输入序列以及模型参数, 且 RNN 每个时刻的输出条件是独立的, 则确定损失函数有以下对应关系, 表达式为

$$\begin{cases} p(\pi_t | x) = \prod_{t=1}^T y_{\pi_t}^T, \forall \pi_t \in L'^T \\ p(Z | x) = \sum_{\pi_t \in B^{-1}(Z)} p(\pi_t | x) \end{cases}, \quad (1)$$

式中: π_t 为输入 x 对应输出序列中的一个元素; y 为模型在所有时刻输出各个字符的概率; L 为序列标签; L' 为序列标签加空字符; $y_{\pi_t}^t$ 为模型在 t 时刻输出为 π_t 的概率; B^{-1} 为 Z 全路径集合的映射函数。

根据(1)式, 便可进一步得到 CTC 损失函数, 即

$$L(S) = -\ln \left[\prod_{(x,Z) \in S} p(Z|x) \right] = -\sum_{(x,Z) \in S} \ln [p(Z|x)] = -\sum_{(x,Z) \in S} \ln \left[\sum_{\pi_t \in B^{-1}(Z)} p(\pi_t|x) \right] =$$

$$-\sum_{(x,Z) \in S} \ln \left[\sum_{\pi_t \in B^{-1}(Z)} \prod_{t=1}^T y_{\pi_t}^T p(\pi_t|x) \right]. \quad (2)$$

为了在一定程度上防止过拟合现象的发生并且提高模型的泛化能力,本文在损失函数上引入 L2 范数正则项后的目标函数,表达式为

$$J(S) = \alpha \sum_S S^2 - \sum_{(x,Z) \in S} \ln \left(\sum_{\pi_t \in B^{-1}(Z)} \prod_{t=1}^T y_{\pi_t}^T \right), \quad (3)$$

式中: α 为 L2 范数正则项系数,通过实验设置不同的 α 系数,观察权值衰减的速率, α 系数越大,权值系数衰减的速率也越快。最终,本文的 α 系数设为 0.8,使本文权值更新过程能有效避免过拟合和欠拟合现象的发生。

2.2 数据集

为了进一步加强本文算法的识别性能和鲁棒性,本文使用了三个数据集,数据集样本实例如图 4 所示。第一个数据集是对抗生成的仿真数据集^[20],随机选取其中 20000 张,并命名为 GAN_LP;第二个数据集是面向应用程序 LP(AOLP)基准^[21]的数据集 Reld,此数据集主要针对车牌自身的复杂多变以适应现实中的各种特殊情形,包含 76412 张不同图像长度、图像模糊、车牌扭曲变形、轻微遮挡等彩色车牌图片,选取其中 3000 张模糊车牌图像,截取出车牌区域的图像后作为 Reldv1;第三个数据集是中国科学技术大学团队建立的 CCPD 数据集^[22],该数据集主要针对因为拍摄环境的复杂多变而导致车牌图像模糊的情形,本文主要选取其中光线较暗或较亮、距离摄像头较远或较近、没上牌的新车以及新能源汽车 4 类数据子集,总共 4000 张,截取出车牌区域后命名为 CCPDv1。数据集统计如表 1 所示。

表 1 数据集的统计

Table 1 Statistics of datasets

Dateset	Training set	Validation set	Test set
GAN-LP	12200	980	7406
Reldv1	2500	0	500
CCPDv1	3000	0	1000

2.3 训练细节

本文使用 TensorFlow 进行网络训练,并进行 20000 次 64 批的迭代训练,初始学习率设置为 0.001。深度神经网络在训练过程中,超参数的选择

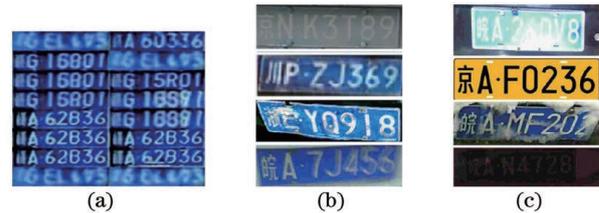


图 4 数据集样本实例。(a)GAN_LP 样本;(b)Reldv1 样本;(c)CCPDv1 样本

Fig. 4 Sample dataset example. (a) Samples of GAN_LP; (b) samples of Reldv1; (c) samples of CCPDv1

也会对网络性能有很大的影响。超参数是神经网络的外部配置,其值不能从数据中学习得到。因此,根据其他文献中的参数设定和典型调整规则来试验性地找到较理想的值。本文的超参数设定值如表 2 所示,其中 Base_lr 为基本学习率, γ 为学习率的更新因子,Lr_policy 为学习率的更新策略,Active_fun 为激活函数,本文采用多步更新策略进行学习率更新;type 为损失函数的优化策略;weight_decay 为防止过拟合的权重衰减因子;momentum 为一种动量因子,当损失曲面平坦时允许网络学习更快的因素;BN 表示 BN 层的使用与否;batch_size 表示一批包含的样本数目。

表 2 超参数设定

Table 2 Hyper parameters setting

Parameter	Setting
Base_lr	0.001
γ	0.1
Lr_policy	Multistep
Active_fun	ReLU
Iterations	2×10^4
Type	SGD
Weight_decay	0.0005
Momentum	0.8
BN	Yes
Batch_size	64

3 实验结果与分析对比

在本节中,对提出的算法进行实验以验证网络

的鲁棒性、有效性及其他综合性能。实验的硬件环境是 Intel 酷睿 i7-6700K CPU 主频为 4 GHz, 16 GB 物理内存, GPU 选用 NVIDIA GTX1080, 操作系统为 ubuntu 14.01, 在 Python 2.7 的环境下进行编译。

3.1 评估指标

本文采用文献[12]中的评估指标对算法进行性能评估, 包括字母数字字符识别率(ACRR)、汉字识别率(CCR)、车牌识别准确度(RA)和字符识别准确度(CRA)。计算 ACRR 和 CCR 的意义在于分析造成模糊车牌识别准确度低的主要因素, 是汉字的识别还是字母和数字的识别。通过分析 ACRR 和 CCR 这两个数据也能为算法后续的改进提供方向和理论依据; RA 和 CRA 指标是对算法整体的识别性能、鲁棒性等进行量化分析, 且两个指标更适用于算法之间的对比分析。其中部分评估指标计算公式

$$f_{RA} = \frac{X}{Y}, \quad (4)$$

$$f_{CRA} = \frac{G}{B}, \quad (5)$$

式中: X 为被正确识别的车牌数; Y 为车牌的总数; G 为正确识别的字符数; B 为所有字符数。

3.2 结果与分析

在本文开展研究的初期, 对大量传统方法、主流算法以及文献[15]和文献[18]中的关键方法逐一进行复现。在本文数据集确定后, 将上述复现的算法在本文的三个数据集上进行训练和测试, 并准确记录每一次的指标数据, 为算法的进一步改进提供基础和方向。通过算法复现、实验结果分析、算法改进、实验对比的重复进行, 最终得到本文的 CRNN+CTC 改进算法。在本节中, 首先列出本文算法在三个数据集测试集下的字母数字字符识别率(ACRR)、

汉字识别率(CCR)、车牌识别准确度(RA)以及字符识别准确度(CRA), 结果如表 3 所示。

表 3 改进 CRNN+CTC 网络的综合实验结果

Dataset	CRNN+CTC network		
	GAN-LP	CCPDv1	Reldv1
ACRR	97.6	97.8	98.2
CCR	95.1	93.3	95.7
f_{RA}	96.8	96.9	97.8
f_{CRA}	97.1	97.2	98.4

从表 3 可以看到, ACRR 在 GAN-LP 测试集和 CCPDv1 测试集得到的结果一致, 分别为 97.6% 和 97.8%, 而在 Reld 测试集上能达到 98.2%; CCR 在三个测试集上的结果分别为 95.1%、93.3% 和 95.7%, 均低于该数据集下的字母数字字符识别率。这也说明造成模糊车牌识别难度大的主要原因在于对车牌中汉字字符的准确识别, 且对进一步提高算法的识别准确率的方向也应该是提高对汉字的识别准确率。此外, 由于 CCPDv1 测试集中包含大量扭曲变形、字符模糊的车牌, 因此汉字的识别率低于其余其他两个数据集下的结果。在综合性能指标 RA 和 CRA 中, 通过在三个测试集上的测试, 本文提出算法的车牌识别准确度在 96.8%~98.4%, 整体性能较好, 识别准确率较高。

为了对比分析本文算法的识别性能, 分别基于字符分割的传统车牌识别方法^[10]、LPR-Net^[15]、原 CRNN+CTC^[18]以及本文改进的 CRNN+CTC, 4 种方法在本文三个数据集上的实验结果进行对比分析, 主要分析其中 RA、CRA 和 T 三个指标, 其中 T 表示单张车牌平均识别时间, 结果如表 4 所示。

表 4 实验对比结果

Table 4 Experimental comparison results

Method	GAN_LP			CCPDv1			Reldv1		
	RA%	CRA%	T /ms	RA%	CRA%	T /ms	RA%	CRA%	T /ms
Traditional ^[10]	84.2	77.3	25	83.4	74.2	31	85.5	75.7	32
LPR-Net ^[15]	94.3	92.7	62	87.4	86.6	72	88.5	86.3	46
CRNN+CTC ^[18]	96.9	96.2	46	97.1	96.3	48	96.4	97.0	44
Ours	96.8	97.1	29	96.9	97.2	33	97.8	98.4	37

从表 4 可以看到, 基于字符分割的传统车牌识别方法^[10]和 LPR-Net^[15]算法对含模糊字符的车牌

均不具有较好的识别结果, 在三个数据集下的车牌识别准确度和车牌字符识别准确度均在 90% 以下。

原 CRNN+CTC 网络^[18]和本文算法则对含模糊字符的车牌,识别精度达到 96% 以上。该对比实验证明,对于含模糊字符的复杂车牌,基于 CRNN+CTC 网络的算法具有较好的识别准确率,能极大提高车牌识别的鲁棒性和通用性;在三个测试集下,无论是 RA 还是 CRA,本文算法较传统识别方法和 LPR-Net 算法均有明显提升,尤其在 CCPDv1 测试集下的车牌识别率对比结果中,本文算法相比于其余两个方法分别提升了 13.5 个百分点和 9.5 个百分点。相较于原始 CRNN+CTC^[18],本文对原始网络的 CNN 和 RNN 层进行替换,并在 CTC 中引入了正则项等的改进后,在一定程度上解决了对模糊车牌特征提取及字符识别困难的问题,进一步提高了对模糊字符的识别精度,尤其在 Reldv1 测试集下,本文算法相较于改进之前的原始算法,其 RA 和 CRA 均提升了 1.4 个百分点。此外,从表中单张车牌平均识别时间的对比结果可以看出,本文所提出的算法在 GAN_LP 和 CCPDv1 测试集的单张图像平均识别时间为 31 ms,比原始的 CRNN+CTC 网络用时减少了 1/3,而 4 种方法相比,检测识别速率最高的是基于字符分割的传统方法,其在两个测试集下单张平均识别时间为 28 ms。综上分析可以看出本文算法对模糊字符的特殊车牌具有较好的识别效果,能在减少车牌识别用时的同时提高车牌字符的识别准确率。

4 结 论

本文提出一种基于改进的 CRNN+CTC 模糊车牌字符识别算法。核心是利用深度可分离卷积和双向长短期记忆网络改进原始算法的 CRNN 内部结构,再结合本文的 CTC 损失函数来实现含模糊字符特殊车牌的更快速、精确的识别。在算法设计上,保证识别精度的要求,进一步缩减了网络模型大小,减少了网络的参数和计算量。此外,在损失函数中引入了 L2 正则项,通过设置合适参数,最终实现有效降低训练过程中过拟合现象的发生概率。最后,采用基于批归一化的有效方案来加快训练过程中的学习速度。在大量的仿真和现实中国车牌数据集上的实验表明,所提出的改进 CRNN+CTC 算法在车牌识别率和识别速度方面都优于原始方法以及其他主流方法。但本文仍未完全解决过拟合的现象发生,在训练过程中还是出现了少次数的过拟合现象,这也是接下来的主要改进点。

参 考 文 献

- [1] Slimani I, Zaarane A, Al Okaishi W, et al. An automated license plate detection and recognition system based on wavelet decomposition and CNN[J]. Array, 2020, 8: 100040.
- [2] Jiang C, Hu A M, He W. Convolutional-neural-network based license plate location algorithm [J]. Laser & Optoelectronics Progress, 2020, 57(2): 021010.
姜策, 胡岸明, 何为. 基于卷积神经网络的车牌定位算法 [J]. 激光与光电子学进展, 2020, 57(2): 021010.
- [3] Zang D, Chai Z L, Zhang J Q, et al. Vehicle license plate recognition using visual attention model and deep learning [J]. Journal of Electronic Imaging, 2015, 24(3): 033001.
- [4] Yao W F, Zhen T, Lü Z W, et al. Research on technology of segmentation and recognition of license plate character [J]. Modern Electronics Technique, 2020, 43(19): 65-69.
姚文凤, 甄彤, 吕宗旺, 等. 车牌字符分割与识别技术研究 [J]. 现代电子技术, 2020, 43(19): 65-69.
- [5] Feng Y, Li W J, Sun J H, et al. Chinese character recognition of license plate based on wavelet transform and fractal dimension [J]. Computer Engineering, 2011, 37(22): 137-138.
冯宇, 李文举, 孙娟红, 等. 基于小波变换和分形维度的车牌汉字识别 [J]. 计算机工程, 2011, 37(22): 137-138.
- [6] Lin Z C. Design and algorithm implementation of license plate recognition system based on convolutional neural network [D]. Hangzhou: Zhejiang University of Technology, 2018.
林哲聪. 基于卷积神经网络的车牌识别系统设计和算法实现 [D]. 杭州: 浙江工业大学, 2018.
- [7] Zhu Q Q, Liu S, Guo W M. Research on license plate detection based on Faster R-CNN [J]. Auto Industry Research, 2019(1): 57-60.
朱倩倩, 刘森, 郭维明. 基于 Faster R-CNN 的车牌检测研究 [J]. 汽车工业研究, 2019(1): 57-60.
- [8] Tong Y, Yang H C. Real-timetraffic 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.
- [9] Kessentini Y, Besbes M D, Ammar S, et al. A two-stage deep neural network for multi-norm license plate detection and recognition [J]. Expert Systems

- with Applications, 2019, 136: 159-170.
- [10] Zhang J F, Shang Z H, Liu H. Design and implementation of license plate recognition system based on color feature and template matching [J]. Software Guide, 2018, 17(1): 212-215, 220.
张俊峰, 尚振宏, 刘辉. 基于颜色特征与模板匹配的车牌识别系统设计与实现 [J]. 软件导刊, 2018, 17(1): 212-215, 220.
- [11] Gao C, Wang F L. Algorithm of license plate recognition based on template matching and local HOG feature [J]. Computer Systems & Applications, 2017, 26(1): 122-128.
高聪, 王福龙. 基于模板匹配和局部 HOG 特征的车牌识别算法 [J]. 计算机系统应用, 2017, 26(1): 122-128.
- [12] Zhang L Z. Research on license plate recognition system based on image processing technology [J]. Electronic Test, 2020(3): 70-71.
张立志. 图像处理技术的车牌识别系统研究 [J]. 电子测试, 2020(3): 70-71.
- [13] Rafique M A, Pedrycz W, Jeon M. Vehicle license plate detection using region-based convolutional neural networks [J]. Soft Computing, 2018, 22(19): 6429-6440.
- [14] Wu C, Yin H, Huang Z Y, et al. Vehicle plate recognition based on artificial neural network [J]. Computer Technology and Development, 2016, 26(12): 160-163, 168.
吴聪, 殷浩, 黄中勇, 等. 基于人工神经网络的车牌识别 [J]. 计算机技术与发展, 2016, 26(12): 160-163, 168.
- [15] Wang D, Tian Y M, Geng W H, et al. LPR-Net: recognizing Chinese license plate in complex environments [J]. Pattern Recognition Letters, 2020, 130: 148-156.
- [16] Selmi Z, Halima M B, Pal U, et al. DELP-DAR system for license plate detection and recognition [J]. Pattern Recognition Letters, 2020, 129: 213-223.
- [17] Kassm G A, Achkar R. LPR CNN cascade and adaptive deskewing [J]. Procedia Computer Science, 2017, 114: 296-303.
- [18] Chen D. Research on low resolution license plate recognition algorithm [D]. Xi'an: Xi'an University of Technology, 2019.
陈丹. 低分辨率车牌识别算法研究 [D]. 西安: 西安理工大学, 2019.
- [19] Graves A. Connectionist temporal classification [M]// Supervised sequence labelling with recurrent neural networks. Studies in computational intelligence. Heidelberg: Springer, 2006, 385: 61-93.
- [20] Li S Y, Fu G Y, Cui Z M, et al. Data augmentation in SAR images based on multi-scale generative adversarial networks [J]. Laser & Optoelectronics Progress, 2020, 57(20): 201018.
李诗怡, 付光远, 崔忠马, 等. 基于多尺度生成对抗网络的 SAR 图像样本增广 [J]. 激光与光电子学进展, 2020, 57(20): 201018.
- [21] Wang P, Jiao B L, Yang L, et al. Vehicle re-identification in aerial imagery: dataset and approach [C]// 2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea. New York: IEEE Press, 2019: 460-469.
- [22] 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.