

## 基于 YOLOv5 的动态车牌识别及残差网络优化方法

杨子奕<sup>a</sup>, 崔善柠<sup>a</sup>, 曲大义<sup>b,\*</sup>, 杨宇翔<sup>a</sup>, 刘朝晖<sup>a</sup>

(青岛理工大学 a. 土木工程学院; b. 机械与汽车工程学院, 青岛 266525)

**摘要:** 为精确识别复杂交通场景中实时运行的动态车辆牌照, 提出了一种基于 YOLOv5 的动态车牌识别及残差网络优化方法。基于深度残差网络优化方法, 采用飞桨 Paddle-Paddle 平台数据集进行网络模型训练, 对车牌数据样本进行图像特征提取; 运用 YOLOv5 模型架构提升动态车牌的识别效果。基于残差网络优化的 YOLOv5 动态车牌识别模型输出结果显示, 对于小角度、远距离的动态车牌识别, 相较于传统模型, 识别效果提升 15%~20%, 优化效果在识别范围内随角度减小及距离增加而提升。基于 YOLOv5 的动态车牌识别及残差网络优化模型可以有效提升动态车牌的识别精度和识别效率, 为复杂交通场景的车车交互提供技术支持。

**关键词:** 智能交通; 动态车牌识别; YOLOv5; 残差网络优化

**中图分类号:** U491.2 **文献标志码:** A **文章编号:** 1673-4602(2025)02-0115-09

## Dynamic license plate recognition and residual network optimization based on YOLOv5

YANG Ziyi<sup>a</sup>, CUI Shanning<sup>a</sup>, QU Dayi<sup>b,\*</sup>, YANG Yuxiang<sup>a</sup>, LIU Zhaohui<sup>a</sup>

(a. School of Civil Engineering; b. School of Mechanical and Automotive Engineering, Qingdao University of Technology, Qingdao 266525, China)

**Abstract:** To accurately identify dynamic vehicle license plates in complex traffic scenes in real-time, a method of recognizing dynamic license plates and optimizing residual network is proposed based on YOLOv5. Using the deep residual network optimization method and training the network model with a large sample dataset from Paddle-Paddle platform, image features are extracted from license plate data samples. YOLOv5 model architecture is employed to enhance the performance in recognizing dynamic license plates. The results of YOLOv5 dynamic license plate recognition model optimized with residual networks show a 15% to 20% improvement in recognizing dynamic license plates at small angles and long distances, compared with traditional models. The optimization performance improves as the angle decreases and the distance increases within the recognition range. YOLOv5-based dynamic license plate recognition and residual network optimization model can effectively enhance the accuracy and efficiency of dynamic license plate recognition, providing technical support for vehicle-to-vehicle interactions in complex traffic scenarios.

**Key words:** intelligent transportation; dynamic license plate recognition; YOLOv5; residual network optimization

收稿日期: 2023-12-06

基金项目: 国家自然科学基金(52272311)

作者简介: 杨子奕(2000—), 男, 山东青岛人。硕士, 研究方向为人机交互与人机共融理论。E-mail: 1171563497@qq.com。

\* 通信作者: 曲大义(1973—), 男, 山东青岛人。博士, 教授, 主要从事智能网联汽车技术方面的研究。  
E-mail: dayiqu@qut.edu.cn。

图像识别是通过计算机对人类理解图片的过程进行模拟,根据图片不同的特征要素,自动将图片归结到不同的语义类别,目前,图像识别技术在众多领域中均有一定应用,如人脸识别<sup>[1]</sup>、情绪识别<sup>[2]</sup>、农林虫害识别<sup>[3]</sup>等。近年来,关于图片处理的模型也被纷纷提出,如 HE 等<sup>[4]</sup>提出一种新的残差网络框架,对深度较深的网络进行简化训练;HU 等<sup>[5]</sup>提出了一种局部关系层图像特征提取器,自适应地提取局部像素的聚合权值;GU 等<sup>[6]</sup>提出了一种基于图嵌入和成对约束的判别式半监督字典学习方法(DSDL-GEPC);REZA<sup>[7]</sup>等在高分辨率图片压缩基础上,提出了一种基于可变比特预算分配的元启发式算法,使图像精度进一步提高;CHEN、TEJA、ZHAO 等<sup>[8-10]</sup>基于现有算法,探讨了深度学习的体系结构与模型优势。多方学者根据现有理论提出了自身的见解,均在图像识别领域取得了很大进展,但在图片的识别度、特征的提取、图像的分类等方面仍面临巨大挑战。用计算机模型提取特征进行识别与人类大脑皮层感知信息的准确度之间仍存在较大差距,建立一类模型使得计算机进行图像识别时更为准确、更加适用,是当前图像识别领域的一个巨大难题。近年来,随着深度学习(Deep Learn)的延伸以及卷积神经网络技术的提出,图像识别技术有了突破性的进展。深度学习以神经网络为主要模型,其主要目的是通过数据,主动地去学习数据中有效的特征表示,深度学习可以将原始特征进行多次的特征转化得到一类特征表示,并进一步运算得到预测函数和最终结果。

车辆行为轨迹预测一直以来都是无人驾驶技术中的关键一环。近年来,无人驾驶技术各方学者做了许多研究,ZHU 等<sup>[11]</sup>提出了一种基于模拟退火的走廊搜索(SACS)算法,对自动驾驶列车进行最优部署;LI 等<sup>[12]</sup>提出了一种基于深度强化学习(DRL)的信号交叉口混合交通控制系统;LIN 等<sup>[13]</sup>提出了一种增强自适应信号控制的安全环境;CHEN、LI 等<sup>[14-15]</sup>根据不同使用场景设计了混合交通流的协调控制;ZHOU 等<sup>[16]</sup>设计了一种优化周期稳定情况下的网联自主车辆(CAV)跟随稳定的自主编队策略;孟奕名等<sup>[17]</sup>针对网联混合车流呈现的复杂特性,分析跟驰特性,修正优化速度,提出了网联车辆跟驰特性及稳态响应策略;宋慧等<sup>[18]</sup>考虑了前后车头最优间距以及最优速度记忆项,建立了适用智能网联汽车的混行车流跟驰模型;曲大义等<sup>[19-20]</sup>结合交通流频变区域,建立了车流动态分配模型,结合分子力场,剖析网联自主车辆的自驱动粒子特性和车车交互行为安全特性,提出网联异质车群协同关系和安全态势演化规律的新思路。这些方法可以通过对大量数据的处理,做出较为精准的预测。但在预测之后如何将结果精准、快速地匹配到对应车辆上,仍是一个关键的技术难题。车辆牌照是对车辆的编号和信息登记,可以通过车辆牌照获知车辆的基本信息,如所属地区、车辆主人信息、车辆数据等。鉴于车辆牌照的特殊性与唯一性,其特性符合驾驶信息传递的要求,因此可以作为信息传递的途径。如何精确识别车辆牌照并准确匹配,是进行车辆行为意图预测的关键一环。

YOLOv5 被广泛应用于视频场景中的物体识别工作,可解决在远距离、小目标、环境复杂等特定场景下无法识别或识别错误的问题。YOLO 系列的算法以计算速度快、模型体积小、网络结构简洁著称。YOLOv5 是在 YOLOv3 和 YOLOv4 的基础上,综合了优势特性,运行速度更上一层楼。虽然 YOLOv5 因在检测速度以及大目标检测方面的优点而备受瞩目,但是 YOLOv5 在小目标的对象识别上表现得却并不是很好,主要是因为小目标的分辨率较低,在噪声跟外界复杂环境的影响下,导致小目标的检测难度较大。针对小目标分辨率较低、信息量较少、干扰性较大等问题,本文使用更大深度的残差网络对原本的模型进行优化,使模型直接对输入与输出之间的残差进行学习,采用有监督的机器算法,改进模型神经网络结构,提取不同层次的图像特征,建立一个高效的网络模型,提高不同拍摄角度、不同外部环境、不同图片清晰度的车辆牌照的识别率。

## 1 残差网络优化方法

### 1.1 残差网络结构

卷积神经网络是一种多层的神经网络模型,残差网络(Residual Network, ResNet)是一种特殊的卷积神经网络,内部由众多的残差块组成,通过残差链接(Residual Connection)的方式提高信息传递效率,同时较大程度缓解深度网络环境中由于学习深度的增加带来的梯度消失和梯度爆炸等问题。残差网络一般分为两种,浅层残差网络(ResNet18、ResNet34)以及深层残差网络(ResNet50、ResNet52、ResNet101),不

同深度残差网络的残差单元如图 1、图 2 所示。

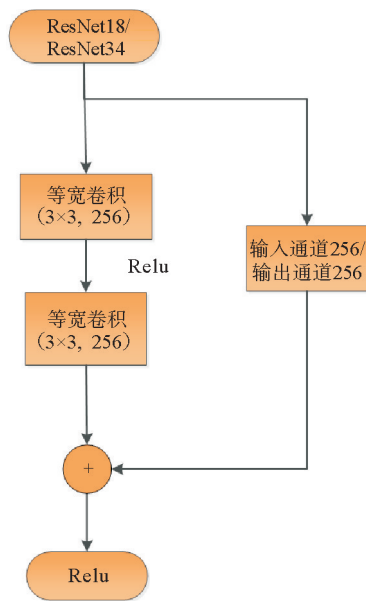


图 1 浅层残差网络残差单元结构示意图

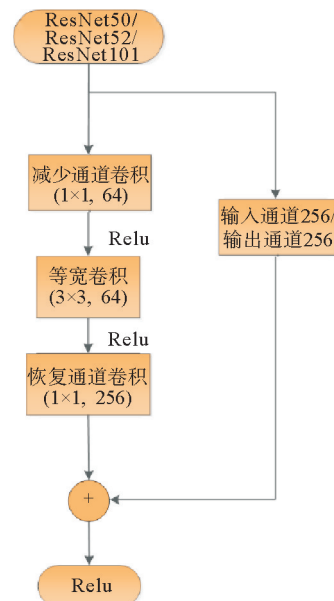


图 2 深层残差网络残差单元结构示意图

设  $f(X; \theta)$  为一个或多个神经层,残差单元  $f(\cdot)$  的输入和输出之间加入一个直连边。

$$B_f(X) = f(X; \theta) + X \tag{1}$$

式中:  $X$  为残差单元;  $\theta$  为可学习的参数。

残差网络即为许多残差单元串联在一起构成的一个深度网络,网络结构如图 3 所示。本文残差网络可以划分为 6 个模块,模块 1 为卷积模块,包含一个卷积层,通过输出通道输出卷积层的输出,卷积层的输出经过激活函数、批量规范化的处理后,接入最大汇聚层;模块 2—模块 5 包含各类残差单元,可以调整特征训练图像以及网络卷积的计算;模块 6 包含一个全局平均汇聚层,可提高网络泛化能力,避免出现过拟合状况,对模型进行降维和参数精简,最终通过全连接层计算,得出最后的输出结果。

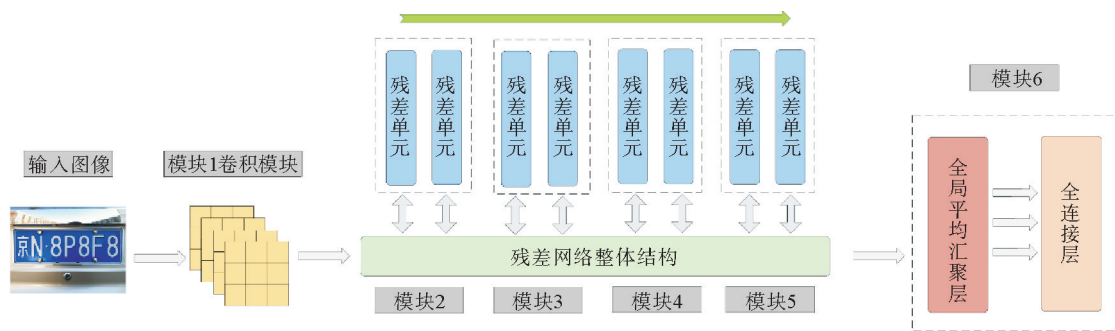


图 3 残差网络整体结构

### 1.2 随机梯度下降法迭代求解

梯度下降法是近年来流行的算法之一,梯度下降法采用迭代的方式进行求解,迭代公式如式(2)所示:

$$w_{t+1} = w_t - \eta \nabla F(w_t) \tag{2}$$

式中:  $w_t$  为模型参数的第  $t$  次迭代;  $\eta$  为学习率,即在梯度下降过程中,损失函数向负方向移动的距离;  $\nabla F(w_t)$  为损失函数在  $w_t$  处的梯度。

在梯度下降算法中,如果学习率选取过小,会导致梯度下降算法的收敛速度过低,训练时间过长;学习率选取过大则会导致最优解丢失,甚至发散无法收敛。因此在梯度下降算法中需对学习率进行细致入微

地把控。而当数据样本过多时,每次迭代都会耗费大量的时间,每一次通过梯度下降算法对全部样本进行梯度更新都需要花费大量的计算资源,会导致运行效率低下。随机梯度下降算法在梯度下降算法的基础上每次仅使用一个样本进行梯度的迭代更新,如式(3)所示:

$$\boldsymbol{w}_{t+1} = \boldsymbol{w}_t - \eta \nabla F(\boldsymbol{w}; m) \quad (3)$$

因为随机梯度下降法每次仅使用一个样本进行迭代,因此迭代所需消耗的时间和计算资源大大减少,但也存在2个问题,①随机样本的梯度迭代并不能代表整个样本空间上的梯度,因此,进行随机梯度迭代时,并不能每次迭代都朝向梯度负方向进行迭代;②由于单样本的随机梯度迭代与全样本的梯度迭代相距较大,因此采用小批量的随机梯度下降算法,即每次迭代对小批量的样本进行随机梯度迭代算法,更新公式如式(4)所示:

$$\boldsymbol{w}_{t+1} = \boldsymbol{w}_t - \eta \nabla F(\boldsymbol{w}; \xi_{(t,n)}) \quad (4)$$

式中:  $\xi_{(t,n)}$  为第  $t$  次迭代的随机批次样本,样本批量大小为  $n$ 。

即可知:

$$f(\boldsymbol{w}_{t+1}, \xi_{(t,n)}) = \frac{1}{n} \sum_{m \in \xi_{(t,n)}} f(\boldsymbol{w}; m) \quad (5)$$

使用梯度下降来更新参数:

$$\boldsymbol{w}_t \leftarrow \boldsymbol{w}_{t-1} - \eta f(\boldsymbol{w}_{t+1}, \xi_{(t,n)}) \quad (6)$$

采用小批量的随机梯度下降法既可以节省时间与计算资源,又与全梯度的偏差较小。

### 1.3 网络学习率调整与梯度估计修正

采用自适应梯度算法(Adaptive Gradient Algorithm)对学习率进行自适应调整。采用  $l_2$  正则化的思想,如式(7)所示,自适应地调整学习率,计算每个参数梯度平方的累加值。

$$\delta_t = \sum_{\tau=1}^t \lambda_{\tau} \odot \lambda_{\tau} \quad (7)$$

式中:  $\delta_t$  为梯度平方累加值;  $\odot$  为元素乘积;  $\lambda_{\tau}$  为第  $\tau$  次迭代的梯度。

$$\nabla \theta_t = - \frac{\eta'}{\sqrt{\lambda_t} + \epsilon} \odot \lambda_{\tau} \quad (8)$$

式中:  $\nabla \theta_t$  为自适应调整学习率;  $\lambda_t$  为第  $t$  次迭代梯度;  $\eta'$  为初始制定的学习率;  $\epsilon$  为保持数值稳定而设定的常数,取值为  $e^{-7} \sim e^{-10}$ 。

参数更新轨迹如图4所示。

在小批量梯度下降法中,因为迭代样本具有一定的随机性和不确定性,因此每次迭代得到的小批量梯度估计与整个样本空间上的最优梯度存在一定的差异,本次实验采用动量法(Momentum Method),选择累计动量替代梯度完成梯度的估计修正,在  $t$  次迭代时,采用负梯度的加权移动平均作为梯度参数的修正方向,如式(9)所示:

$$\nabla \theta_t = \rho \nabla \theta_{t-1} - \eta f(\boldsymbol{w}_{t+1}, \xi_{(t,n)}) = - \eta \sum_{\tau=1}^t \rho^{t-\tau} f(\boldsymbol{w}_{t+1}, \xi_{(t,n)}) \quad (9)$$

式中:  $\rho$  为动量因子,取值通常为 0.9。

采用动量法,每个参数的更新差值依赖于在最近时段内梯度弥散的加权平均数,如果参数值在最近时段内梯度方向不同,则参数的更新幅度减小;反之,当梯度方向相同时,参数更新幅度变大,具有相应的加速效果。在迭代初期,梯度方向大致相同,会有加速作用,更优更快地到达梯度最优点;当处于迭代后期,梯度存在收敛处来回震荡的现象,动量法会起到一定的减速作用,增加迭代过程的稳定性。动量法参数更新轨迹如图5所示。




图4 学习率参数更新轨迹



### 1.4 基于残差网络的图像识别算法

基于残差网络的图像识别模型依托于 Python 语言以及飞桨 (Paddle-Paddle) 框架平台, 采用平台车牌识别数据集进行创建和训练, 数据集中包含 30 000 张车辆拍照图片, 拥有各种角度及天气可视度情况下的数据图像。采用小批量随机梯度下降法对参数进行更新, 并对网络学习率更迭以及梯度估计进行适当修正, 具体步骤如下:

Step1 根据输入通道数和输出通道数计算所需卷积核数量, 建立卷积核算子, 根据卷积核大小、空洞大小、填充、步长以及输入的大小确定输出特征层的大小。

Step2 实现卷积层, 为使残差单元更加灵活, 对第 1 个卷积层设置不同的步长和输出通道, 当输入通道和输出通道不一致时, 采用带  $1 \times 1$  卷积的直连边, 卷积层实现后构建直连边, 如形状不一致则引入  $1 \times 1$  卷积, 将残差单元输入特征图的形状转换为与输出特征图相同。

Step3 构建支持基于小批量随机梯度下降法的计算方法, 设定参数 metric 用于计算评价指标。①构建当前网络模型的训练迭代数, 记录训练过程中损失函数的变化情况, 传入训练回合数、总的训练步数, 统计损失并对每个阶段的损失进行保存; ②采用梯度反向传播方法对每个相关参数的梯度值进行计算, 并采用小批量随机梯度下降法对参数进行更新; ③模型评价阶段, 控制储存梯度, 统计训练集损失, 遍历之前每个批次, 计算模型输出、损失函数、累计评价和累计损失, 运行模型使模型前向运算, 得到预测结果。

Step4 构建残差网络整体结构, 加入残差连接, 将本次网络分为 6 个模块, 模块 1 为卷积块, 对卷积层的输出批量化、规范化, 采用 Relu 作为激活函数进行处理, 连接一个最大汇聚层; 模块 2—模块 5 包含残差单元, 对特征图的大小, 形状进行转换; 模块 6 采用全局平均汇聚层, 经过全连接层计算最后输出。

Step5 使用训练样本集对模型进行模型训练, 用验证集对训练好的模型进行检验, 保存准确率最高的模型作为最终的最优模型。

Step6 使用测试样本集对在上述训练过程中所保存的最优模型进行评价, 检验模型在测试样本集上的识别准确率以及损失变化情况。

本文实验是在 Python 环境下, 采用 Paddle-Paddle 框架, 基于残差网络实现车牌识别, 网络设计 4 个残差单元模块、全局平均汇聚层以及全连接层。采用小批量随机梯度下降法、AdaGrad 算法以及动量法对网络进行优化处理。数据样本集采用 Paddle-Paddle 平台中车牌识别项目数据集, 数据集包含测试集与训练集, 其中测试集包含 10 000 张车牌照片, 训练集包含 20 000 张车牌照片, 如图 6 所示。




图 5 动量法参数更新轨迹



图 6 数据集部分样本

为确定最优学习率与小批次批量, 采用数据集对学习率及批量进行损失输出, 设定批次大小分别为 16、32、64、158、256, 学习率设定为 0.02、0.04、0.06、0.08, 输出结果如图 7 所示。

依照数据结果可知, 当数据样本批次较小时, 下降明显, 因此, 选择采用 32 批次, 在保证合理性的同时尽快进行收敛。

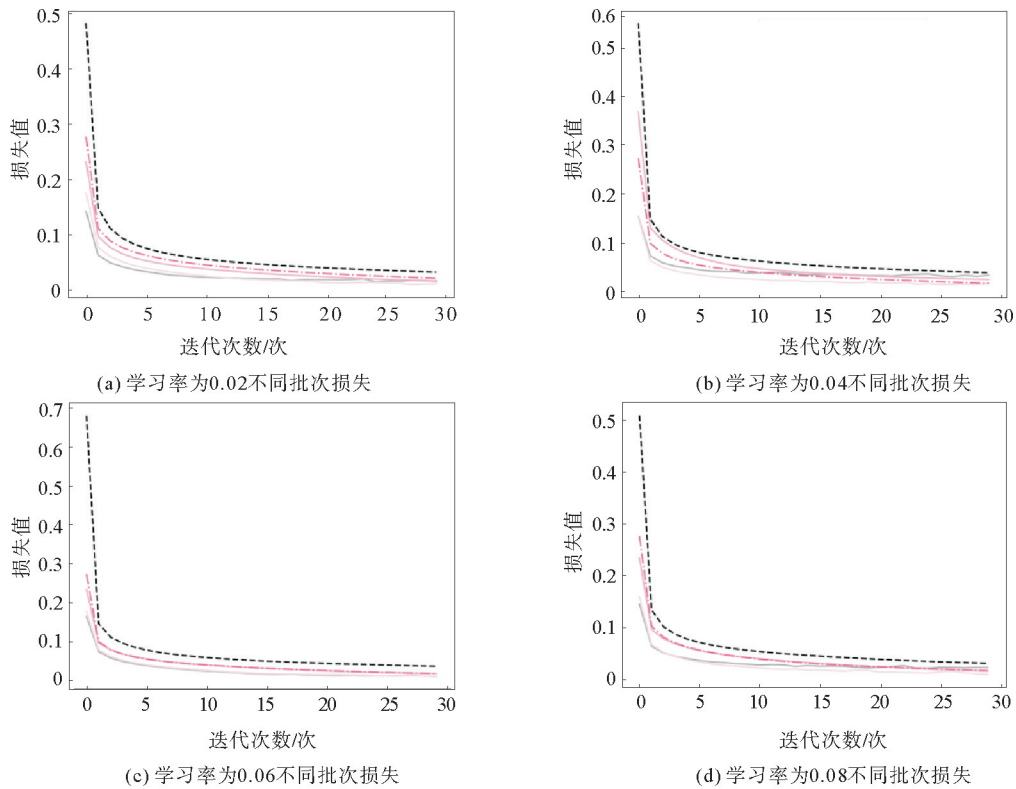


图7 学习率及批次损失输出

— 批次:16; — 批次:32; - - 批次:64; - - 批次:128; - - 批次:256

为增强车牌图像识别的准确率与效率,对数据集内样本集合数据进行增强处理,采用边缘识别,对图像轮廓点进行检测,检测图像关于形状和反射的信息,提取图像重要特征。本次图像处理任务中,采取Laplacian算子对图像进行边缘提取,创建 $3 \times 3$ 的卷积核,采用零填充(Zero Padding)方式进行处理,测试输出可视化结果如图8所示。




图8 Laplacian 图像边缘识别

## 2 基于YOLOv5的车牌识别实验与结果分析

本次实验分析基于YOLOv5目标检测模型进行,采用上述残差网络为主干网络,对视频抓拍中的动态车牌进行识别,识别效果如图9、图10所示。对不同距离及不同倾斜角度的车牌识别率如图11所示。优化后效果如图12所示。



图 9 路段识别效果



图 10 交叉口识别效果




图 11 不同距离及不同倾斜角度识别效果

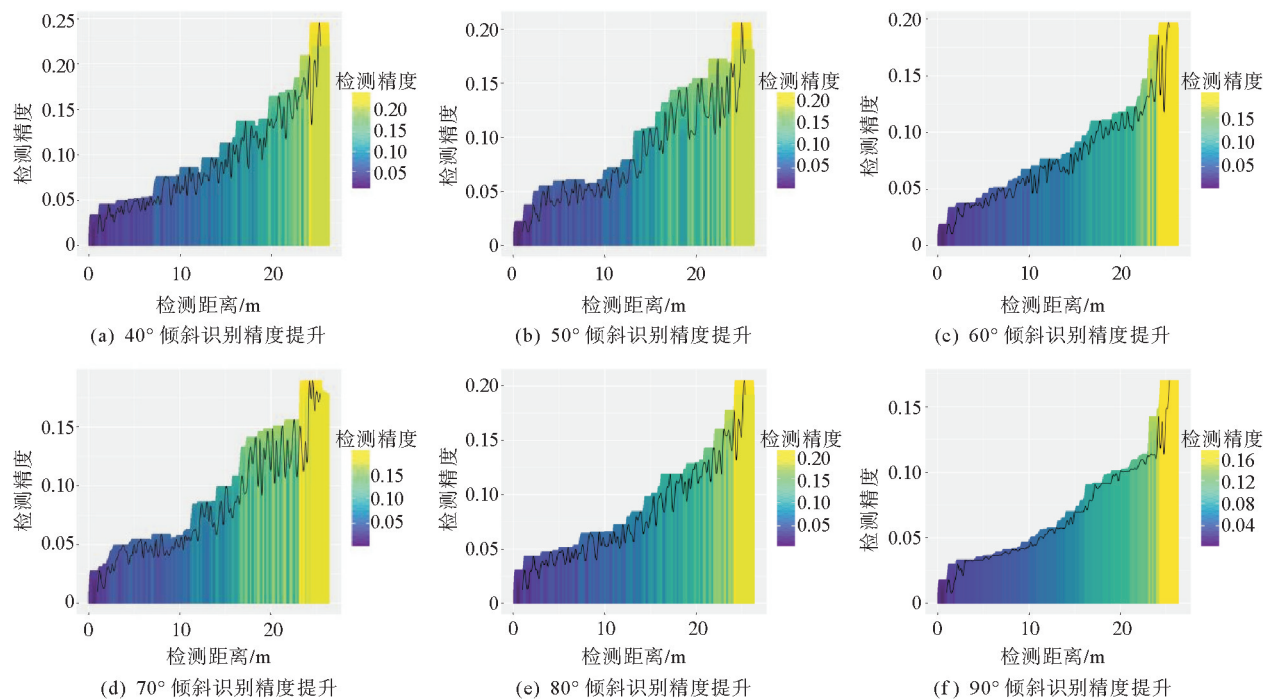


图 12 不同倾斜角度识别精度提升



### 3 结论

车牌检测工作这一研究存在诸多难点,对算法要求高,首先,因为距离远、目标小、角度刁钻,目标分辨率普遍较小,神经网络能提取到的特征较少;其次,由于图像或者视频样本中存在大量的相似特征,加上交通环境的复杂背景以及噪声干扰,容易出现较多误检现象。本模型采用更深层次的残差网络对 YOLOv5 框架进行模型优化,相比于传统卷积神经网络模型具有以下特色优势:

- 1) 相较于传统卷积神经网络模型,优化后模型的识别距离更远,准确率更高。
- 2) 优化后模型对于短距离识别工作成功率可达 85% 以上。
- 3) 相较于传统卷积神经网络模型,优化后模型对于不同倾斜角度的识别工作成功率提升约 15%~20%。

结果显示,优化后残差网络模型可以有效提升车牌识别精度。

#### 参考文献(References):

- [1] 胡宇晨,李秋生. 基于结构化深度聚类网络的人脸表情识别研究[J]. 赣南师范大学学报,2023,44(6):56-63.  
HU Yuchen,LI Qiusheng. Research on facial expression recognition based on structured depth clustering network[J]. Journal of Gannan Normal University,2023,44(6):56-63.
- [2] HU Y,WANG F. Multi-Modal emotion recognition combining face image and EEG signal[J]. Journal of Circuits, Systems and Computers,2023,32(7):48-55.
- [3] 王瑞鹏,陈锋军,朱学岩,等. 采用改进的 EfficientNet 识别苹果叶片病害[J]. 农业工程学报,2023,39(18):201-210.  
WANG RuiPeng,CHEN Fengjun,ZHU Xueyan,et al. Identifying apple leaf diseases using improved EfficientNet[J]. Transactions of the Chinese Society of Agricultural Engineering,2023,39(18):201-210.
- [4] HE K,ZHANG X,REN S,et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Las Vegas,2016:770-778. DOI:10.1109/CVPR.2016.90.
- [5] HU H,ZHANG Z,XIE Z,et al. Local relation networks for image recognition[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul,2019:3463-3472.
- [6] GU X P,WANG M X,WANG Y T,et al. Discriminative semisupervised dictionary learning method with graph embedding and pairwise constraints for crop disease image recognition[J]. Crop Protection,2024,176:106489.
- [7] REZA K,GHOLAMREZA A,HADI G. A new method of facial image compression based on meta-heuristic algorithms with variable bit budget allocation[J]. Signal, Image and Video Processing,2023,17(8):3923-3931.
- [8] CHEN Y X,LI Y Y,ZHANG S. Research on image recognition of three *Fritillaria cirrhosa* species based on deep learning[J]. Scientific Reports,2023,13(1):19486-19486.
- [9] TEJA R B,MYTHILI D,LAXMIPRASANNA D,et al. Deep learning feature extraction architectures for real-time face detection[J]. SN Computer Science,2023,4(5):645.
- [10] ZHAO H,JIA J,KOLTUN V. Exploring self-attention for image recognition[C]//Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. 2020:10073-10082.
- [11] ZHU D,XIE T,LIU Y,et al. Optimal deployment of an equitable CAV platoonable corridor on road networks with mixed traffic flow[J]. Transportation Research Part C,2023,157:104399.
- [12] LI D W,ZHU F,WU J P,et al. Managing mixed traffic at signalized intersections: An adaptive signal control and CAV coordination system based on deep reinforcement learning[J]. Expert Systems with Applications,2024,238:121959.
- [13] LIN W,WEI H. CAV-enabled data analytics for enhancing adaptive signal control safety environment[J]. Accident Analysis and Prevention,2023,192:107290.
- [14] CHEN X D,LIN X,MENG Q,et al. Coordinated traffic control of urban networks with dynamic entrance holding for mixed CAV traffic[J]. Transportation Research Part E,2023,178:103264.
- [15] LI T F,CAO Y N,XU M,et al. Optimal intersection design and signal setting in a transportation network with mixed HVs and CAVs[J]. Transportation Research Part E,2023,175:103173.



- [16] ZHOU Z, LI L H, QU X, et al. An autonomous platoon formation strategy to optimize CAV car-following stability under periodic disturbance[J]. *Physica A: Statistical Mechanics and Its Applications*, 2023, 626: 129096.
- [17] 孟奕名, 曲大义, 杨子奕, 等. 网联混合车流跟驰特性及稳态响应策略[J]. *青岛理工大学学报*, 2023, 44(3): 104-112.  
MENG Yiming, QU Dayi, YANG Ziyi, et al. Car-following characteristics and steady-state response strategy of networked hybrid traffic flow[J]. *Journal of Qingdao University of Technology*, 2023, 44(3): 104-112.
- [18] 宋慧, 曲大义, 王少杰, 等. 考虑多车响应的网联混行车流跟驰模型及稳态分析[J]. *吉林大学学报(工学版)*, 2024, 54(11): 3220-3230.  
SONG Hui, QU Dayi, WANG Shaojie, et al. Connected mixed traffic flow car-following model and stability analysis considering multiple vehicles response[J]. *Journal of Jilin University(Engineering and Technology Edition)*, 2024, 54(11): 3220-3230.
- [19] 曲大义, 刘浩敏, 杨子奕, 等. 基于车路协同的交通瓶颈路段车流动态分配机制及模型[J]. *吉林大学学报(工学版)*, 2024, 54(8): 2187-2196.  
QU Dayi, LIU Haomin, YANG Ziyi, et al. Dynamic allocation mechanism and model of traffic flow in bottleneck section based on vehicle infrastructure cooperation[J]. *Journal of Jilin University(Engineering and Technology Edition)*, 2024, 54(8): 2187-2196.
- [20] 曲大义, 孟奕名, 王韬, 等. 基于分子力场的网联自主车辆跟驰安全特性及模型[J]. *交通运输系统工程与信息*, 2023, 23(6): 33-41.  
QU Dayi, MENG Yiming, WANG Tao, et al. Car-following model and safety characteristics of connected autonomous vehicle based on molecular force field[J]. *Journal of Transportation Systems Engineering and Information Technology*, 2023, 23(6): 33-41.

(责任编辑 张晓靖; 英文校审 程文华)

---

### (上接第 98 页)

- [15] GAO F, ZHANG H, YANG F L, et al. Study of an innovative anaerobic (A)/oxic (O)/anaerobic (A) bioreactor based on denitrification-anammox technology treating low C/N municipal sewage[J]. *Chemical Engineering Journal*, 2013, 232: 65-73.
- [16] HU B L, ZHENG P, TANG C J, et al. Biochemistry and molecular biology of anammox bacteria[J]. *Critical Reviews in Biochemistry and Molecular Biology*, 2009, 44(2/3): 65-84.
- [17] WU P, CHEN J, GARLAPATI V K, et al. Novel insights into anammox-based processes: A critical review[J]. *Chemical Engineering Journal*, 2022, 444: 136534.
- [18] LIU Y J, GU J, LIU Y. Energy self-sufficient biological municipal wastewater reclamation: Present status, challenges and solutions forward[J]. *Bioresource Technology*, 2018, 269: 513-519.
- [19] ZHANG J H, MIAO Y Y, SUN Y, et al. An effective strategy for in situ start-up of mainstream anammox process treating domestic sewage[J]. *Bioresource Technology*, 2021, 339: 125525.
- [20] MA B, WANG S Y, CAO S B, et al. Biological nitrogen removal from sewage via anammox: Recent advances[J]. *Bioresource Technology*, 2016, 200: 981-990.
- [21] CAO Y S, LOOSDRECHT M C M V, DAIGGER G T. Mainstream partial nitritation-anammox in municipal wastewater treatment: Status, bottlenecks, and further studies[J]. *Applied Microbiology and Biotechnology*, 2017, 101(4): 1365-1383.
- [22] OSHIKI M, SHIMOKAWA M, FUJII N, et al. Physiological characteristics of the anaerobic ammonium-oxidizing bacterium 'Candidatus Brocadia sinica'[J]. *Microbiology*, 2011, 157(6): 1706-1713.

(责任编辑 张晓靖; 英文校审 程文华)