DOI：10.13890/j.issn.1000-128X.2023.04.012　　文章编号：1000-128X(2023)04-0083-07

基于改进yolov4-tiny的地铁受电弓燃弧检测方法

艾生永，丁建明，张青松
（西南交通大学 轨道交通运载系统全国重点实验室，四川 成都 610031）

摘　要：地铁受电弓的燃弧会加剧受电弓滑板和接触网磨损，严重危害轨道交通安全。文章针对地铁车辆受电弓燃弧检测存在强光干扰和背景多变的问题，提出了一种基于yolov4-tiny模型改进的燃弧检测方法。为提升小目标检测能力，该方法在yolov4-tiny原有两个尺度的预测分支的基础上，添加第三尺度的预测分支以实现小燃弧在浅层网络中的定位，在主干网络后增加RFB(Receptive Field Block)模块以扩大网络的感受野，增强模型的特征提取能力。结果表明，改进的模型在测试集上的平均精度值（P_{AP}）比yolov4-tiny提升了7.8个百分点，达到了98.2%，燃弧的定位效果与yolov4相当，但速度得到了极大的提升，单张图片的推理速度仅为6.5 ms，能有效、准确地完成地铁车辆中的受电弓燃弧检测任务。

关键词：地铁车辆；燃弧识别；目标检测；YOLO；深度学习
中图分类号：U231；U225　　**文献标识码：**A

Arcing detection method of metro pantograph based on improved yolov4-tiny

AI Shengyong, DING Jianming, ZHANG Qingsong

(State Key Laboratory of Rail Transit Vehicle System, Southwest Jiaotong University, Chengdu, Sichuan 610031, China)

Abstract: Arcing on metro pantographs contribute to the accelerated wear of pantograph strips and the catenary, imposing a serious safety risk to rail transit. For the problem of strong light interference and variable background in pantograph arcing detection for metro vehicles, an arcing detection method based on an improved yolov4-tiny model is proposed. In order to improve the detection ability of small targets, this method incorporated a third-scale prediction branch to the original two-scale prediction branches of yolov4-tiny, to enable the positioning of small arcs in the shallow network. Moreover, a receptive field block (RFB) module was embedded beneath the backbone network, to expand the network′s receptive field and enhance the model′s feature extraction ability. The test results show the average precision (P_{AP}) of the improved model on the test set is increased to 98.2%, marking an improvement of 7.8 percentage points over yolov4-tiny. Despite yielding similar positioning effect for arcs, the improved model works at significantly higher speeds than yolov4, enabling inference speed of a single image in only 6.5 ms. The proposed method is proven effective and accurate in fulfilling the arcing detection task for pantographs of metro vehicles.

Keywords: metro vehicle; arcing detection; target detection; YOLO; deep learning

0　引言

地铁列车正常运行时，受电弓振动、接触线缺陷等因素会导致受电弓离线并产生弓网燃弧现象。持续的燃弧会使接触线烧蚀形成凹凸点，造成受电弓与接触线的异常磨耗，影响弓网受流，甚至危害运行时的

基金项目：国家自然科学基金项目(51875481)
通信作者：丁建明（1981—），男，博士，副研究员，博士生导师，主要从事信号处理、故障诊断、智能运维方面的研究；
E-mail: fdingjianming@126.com
引用格式：艾生永, 丁建明, 张青松. 基于改进yolov4-tiny的地铁受电弓燃弧检测方法[J]. 机车电传动, 2023(4): 83-89.
Citation: AI Shengyong, DING Jianming, ZHANG Qingsong. Arcing detection method of metro pantograph based on improved yolov4-tiny[J]. Electric drive for locomotives,2023(4): 83-89.

安全[1]。因此，及时准确地识别燃弧对日常受电弓维护和地铁车辆安全运行具有重要意义。

目前，弓网燃弧检测与识别方法主要分为3类：基于列车接触电压及回路电流的燃弧识别[2-4]，基于紫外光传感器的燃弧识别[5-6]和基于图像处理的燃弧识别。其中，前两者对列车回路中的电信号或紫外光传感器转化后的电信号进行滤波处理来检测燃弧，设备安装的复杂性和高成本限制了其广泛应用。在传统的图像处理方面，文献[7]跟踪受电弓和接触线每一帧的接触点并记录为信号，结合跟踪信号和前景识别方法得到燃弧的检测结果；文献[8]提出了一种采用萤火虫优化算法的受电弓自动检测方法，得到包含受电弓的矩形区域，然后使用Otsu方法来检测该区域的燃弧；文献[9]利用紫外相机采集受电弓区域的图像，以200的阈值对图像进行二值化处理来检测燃弧现象；文献[10]采用Otsu算法对灰度图像进行处理反演后滤除二值图像中的干扰，得到图像中受电弓区域，对该区域内R分量值大于254的数量进行统计来判断该帧图像是否反映出现燃弧现象。然而，这些方法仅仅适用于背景简单、光线干扰小的场景，对于强光干扰或多变背景的场景适应性能不稳定。地铁背景环境光线微弱，需要采用补光设备来辅助成像，在强光干扰下，燃弧的亮度特征并不明显，并且线路上方大量的钢结构在强光照射下存在反光，极易与小燃弧混淆，在这种情况下，传统的图像处理手段难以准确识别出燃弧现象。

与传统图像处理方法不同的是，基于深度学习的目标检测算法无须手动确定专门的特征，模型可根据样本自行训练与目标有关的特征，拥有更强的鲁棒性和泛化性，适合背景复杂的情况。目前常见的目标检测算法主要分为两阶段（Two-Stage）算法和单阶段（One-Stage）算法两类，两阶段算法首先生成一系列的目标候选区域，再将这些候选区域送入相应的网络，分别进行检测框的分类和回归，代表算法有R-CNN系列；而单阶段算法没有生成候选区域的过程，直接输出分类信息和位置信息，代表算法有yolo系列和SSD。相比于两阶段算法，单阶段算法虽然精度较低，但有着绝对的速度优势，因此在铁路领域被广泛应用于车轮缺陷检测[11]、接触网紧固件检测[12]、车底部件监测[13]、列车障碍物检测[14]、轨道扣件检测[15]等。

在弓网燃弧识别方面，采用深度学习对燃弧进行定位的研究较少，而yolo算法在铁路领域的大量应用证明了其可靠性。yolo算法参数量较少，尽管具备高速优势，但同时精度较低，需要对网络进行改进，RFB(Receptive Field Block)模块[16]的设计受人眼视觉系统的启发，融合多尺度感受野，适用于小目标检测场景。因此，本文基于目标检测算法yolov4-tiny，针对燃弧区域面积小难以检测的问题，在原模型的基础上添加8倍降采样预测分支，使用RFB模块提升颈部网络的特征融合能力，从而提升算法的小目标检测能力，并使用k-means算法重新选取锚框。试验结果表明，改进后的模型相比于yolov4-tiny的P_{AP}值提升了7.8个百分点，达到了98.2%，与yolov4模型相当，但速度得到了极大提升。

1 改进的yolov4-tiny算法

1.1 yolov4-tiny算法

yolov4-tiny[17]基于yolov4[18]进行了简化，该模型主要由主干网络、颈部网络和预测分支3部分组成。主干网络为CSPDarknet53-tiny，该网络充分利用残差结构提取特征，加强了模型的学习性能，且激活函数为计算开销较小的LeakyRule，在提高计算速度的同时能有效避免神经元“死亡”问题。颈部网络采用类似FPN特征金字塔对主干网络所提取的特征进行多尺度特征融合，向预测分支输出16倍和32倍降采样特征图。预测分支根据输入的特征图将整个图片划分为若干格，该分支为每个单元格中所分配的先验框预测一个向量，包含相应的预测框置信度、预测框位置信息（中心点坐标、宽、高）和概率信息，在yolov4-tiny中，预测分支包含两种尺度，以检测不同大小的目标对象。

相比于yolov4，yolov4-tiny精简了网络结构，推理速度约有6倍的提升，但精度有一定程度的下降，需要对网络进行改进以适应受电弓燃弧检测。

1.2 网络改进

按照COCO数据集中的标准，图像中分辨率小于32×32像素的物体为小目标，标注的燃弧区域中，最大仅为32×12，即燃弧区域全是小目标物体。因此，针对网络中的改进策略以提升模型小目标检测能力为主，改进方法包括在预测分支中构建8倍降采样分支和在颈部网络引入RFB模块。

1.2.1 构建8倍降采样预测分支

一些通用的数据集中包括大量的物体类别（如COCO数据集中含有80种物体），预测分支中输出的信息大小与物体类别息息相关。对于燃弧检测来说，算法输出仅为单个种类，增加额外的预测分支并不会增加太多的计算开销。

一般来说，浅层网络的感受野较小，提取出的特征具有丰富的位置信息，但语义信息较少；随着不断的下采样，网络层数逐渐加深，其感受野不断增大，此时深层网络所提取出的特征包含大量的语义信息，利于目标物体的检测。但对于一些小目标物体来说，过多的卷积操作可能会导致深层特征图受背景的噪声干扰，从而丢失相应特征，出现漏检情况。以416×416的输入图片为例，yolov4-tiny输出13×13和26×26两种检测尺度，前者适用于对大目标进行检测，后者适用于对中等大小的目标进行检测，而该模型由于缺乏小

目标预测分支，因此构建 52×52 尺度的预测分支以增强对小目标检测的能力。

1.2.2　RFB 模块

RFB 模块是一种基于人眼群体感受野而设计的神经网络模块，在模块中使用空洞卷积增大感受野，并在多分支卷积结构中融合多尺度感受野，以提高对特征的提取能力。

1) 空洞卷积

空洞卷积常用于图像语义分割，相比于传统卷积，它额外引入膨胀系数 rate，使得在运算时，卷积核会根据 rate 的大小在相邻值之间补零，填充的数量为 rate−1，如图 1 所示。膨胀系数的引入使卷积核能与特征图中固定间隔点的像素之间进行运算，使得空洞卷积在参数量不变的情况下能获得更大的感受野。

2) 多分支卷积

RFB 模块中使用了与 inception[19]类似的多分支卷积层结构，在各个分支中进行不同大小的卷积操作来获得多重感受野。首先对每个分支使用 1×1 的卷积操作来减少通道数，加快运行速度，接着在各分支中进行不同尺度的空洞卷积，最后将不同分支的特征图进行通道组合。此外，为避免深层网络产生的梯度发散问题，RFB 模块借鉴 ResNet[20]的设计思想，在模块中额外添加直连(shortcut)结构。

RFB 模块包含 RFB 和 RFB-S 两种结构，如图 2 所示，RFB-S 具有更多分支，使用了更深的非线性层，并采用一个 1×n 和 n×1 组合的卷积结构来代替 n×n 的卷积层。

RFB 模块具备空洞卷积和多分支卷积的优点，在扩大感受野的同时，融合多个尺度的特征，增强了模型对小目标的检测能力，且与其他模型结合的方式十分简便，可以直接嵌入网络中。此外，RFB 模块的多分支结构不可避免会引入更多的非检测对象特征，对检测产生一定程度的干扰，本文中的检测对象仅为燃弧，分支较少的 RFB 结构能保证在充分提高模型多尺度特征提取能力的前提下，引入较少的干扰。因此，在添加第三尺度预测分支的基础上，将 RFB 模块中的 RFB 结构引入到 yolov4-tiny 模型中，分别在颈部网络的 8 倍和 16 倍降采样特征图前添加 RFB 结构，最终的模型如图 3 所示。

1.2.3　模型参数调整

1) 修改先验框大小

在 yolov4-tiny 的预测分支中，模型输出位置参数是基于先验框的偏移值，先验框参数的选取在很大程度上影响了模型的准确程度。原 yolov4-tiny 的先验框是对 COCO 数据集中的 80 类物体使用 k-means 聚类算法得出的，对于燃弧检测来说，基本所有的目标物体

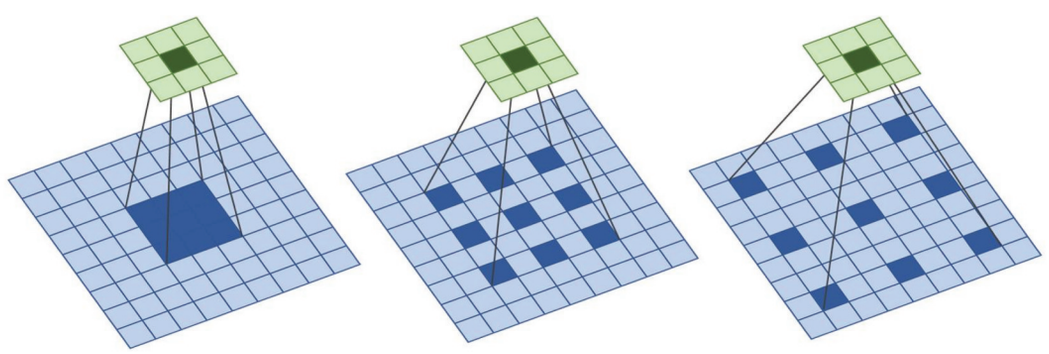

(a) rate=1　　(b) rate=2　　(c) rate=3

图 1　不同 rate 下的空洞卷积示意图

Fig. 1　Schematic diagram of dilated convolution under different rates

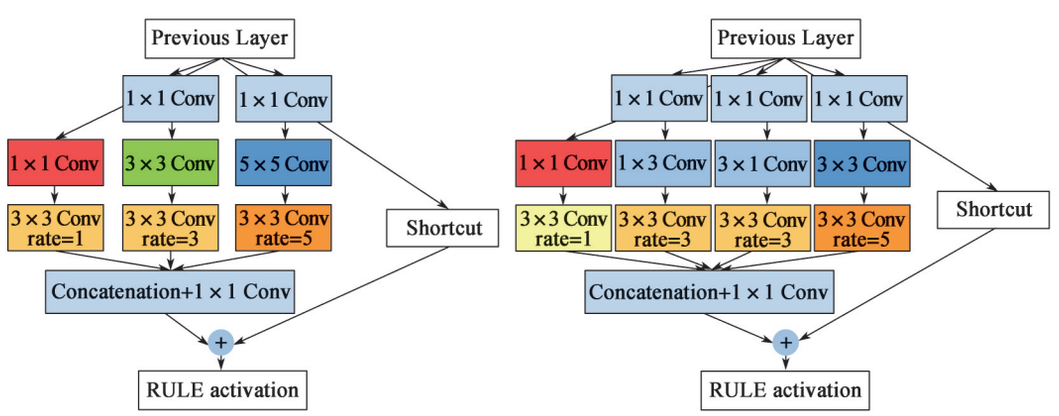

(a) RFB 结构　　(b) RFB-S 结构

图 2　RFB 和 RFB-S 结构

Fig. 2　Structure of RFB and RFB-S

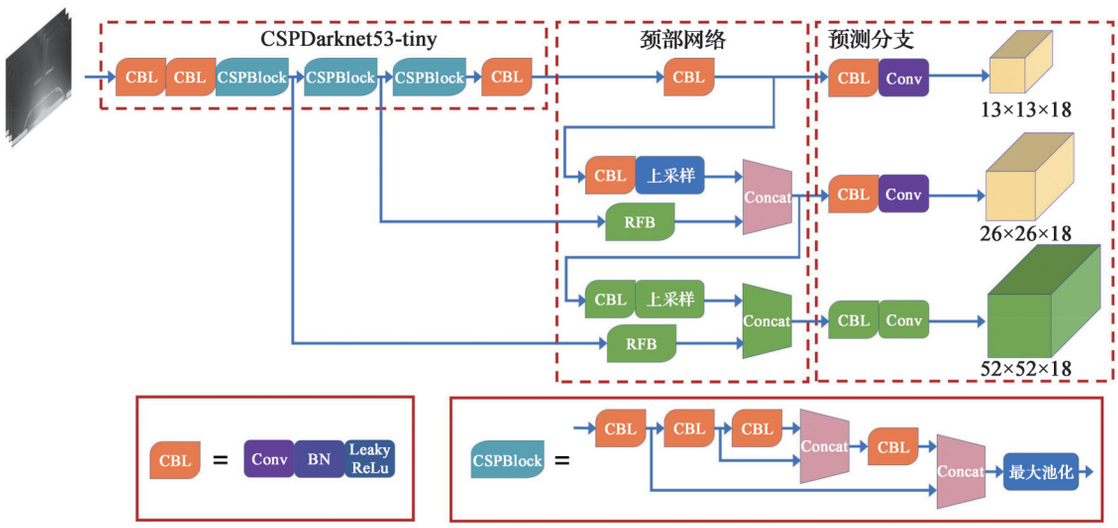

图3 添加预测分支和RFB模块后的模型结构(绿色部分为相比于yolov4-tiny所添加的结构)

Fig. 3 Model structure after adding prediction branch and RFB module (the structure added to original yolov4-tiny is shown in green)

均为小目标，使用原版的多尺度先验框会影响燃弧检出效果，因此对燃弧图片集使用k-means算法重新聚类，得出[7,5]、[10,6]、[13,5]、[17,7]、[25,9]、[30,12]6个先验框，每2个一组分别应用于13×13、26×26和52×52预测分支中。

2) 修改损失函数

在深度学习中，损失函数是模型输出值与实际真实值之间的量化差异。原yolov4-tiny的损失函数L_{loss}主要由3部分组成，分别是边界框损失函数L_{CIoU}、置信度损失函数L_{conf}和类别损失函数L_{class}，如式(1)所示。

$$L_{\text{loss}}=L_{\text{CIoU}}+L_{\text{conf}}+L_{\text{class}} \tag{1}$$

其中，边界框损失函数L_{CIoU}为：

$$L_{\text{CIoU}}=\sum_{i=0}^{S\times S}\sum_{j=0}^{M}I_{ij}^{\text{obj}}\left(2-w_i\times h_i\right)\left(1-A_{\text{CIoU}}\right) \tag{2}$$

$$A_{\text{CIoU}}=1-A_{\text{IoU}}+\frac{\rho^2\left(b,\hat{b}\right)}{c^2}+\alpha v \tag{3}$$

$$\alpha=\frac{v}{1-A_{\text{IoU}}+v} \tag{4}$$

$$v=\frac{4}{\pi^2}\left(\arctan\frac{\hat{w}}{\hat{h}}-\arctan\frac{w}{h}\right)^2 \tag{5}$$

式中：I_{ij}^{obj}用于判断该网格中是否有目标物体，有则为1，无则为0；A_{IoU}为真实框和预测框面积的交集与并集之比；$\rho^2\left(b,\hat{b}\right)$为预测框和真实框中心点的欧氏距离；$c$为真实框和预测框最小闭包区域的对角线距离；$\hat{w}$、$\hat{h}$和$w$、$h$分别为真实框和预测框的宽、高。

置信度损失函数L_{conf}为：

$$L_{\text{conf}}=-\sum_{i=0}^{S\times S}\sum_{j=0}^{M}I_{ij}^{\text{obj}}\left[\hat{C}_i\log\left(C_i\right)+\left(1-\hat{C}_i\right)\log\left(1-C_i\right)\right]-\lambda_{\text{noobj}}\sum_{i=0}^{S\times S}\sum_{j=0}^{M}I_{ij}^{\text{noobj}}\left[\hat{C}_i\log\left(C_i\right)+\left(1-\hat{C}_i\right)\log\left(1-C_i\right)\right] \tag{6}$$

式中：$\hat{C}_i$和C_i分别为真实样本和预测样本的置信度；I_{ij}^{noobj}与I_{ij}^{obj}相反，网格中无物体为1，有则为0。

类别损失函数L_{class}为：

$$L_{\text{class}}=-\sum_{i=0}^{S\times S}\sum_{j=0}^{M}I_{ij}^{\text{obj}}\sum_{c\in\text{classes}}\left[\hat{p}_i(c)\log\left(p_i(c)\right)+\left(1-\hat{p}_i(c)\right)\log\left(1-p_i(c)\right)\right] \tag{7}$$

式中：$\hat{p}_i(c)$和$p_i(c)$分别是网络所预测的物体属于类别c的真实概率和预测概率。

对于燃弧检测来说，模型仅需要输出单个类别，因此可以将类别损失函数L_{class}省略。

为加快模型收敛，防止模型过拟合，在损失函数L_{class}中添加L2范数对模型参数进行权重衰减，正则化系数λ取为0.02，最终的损失函数如下所示：

$$L_{\text{loss}}=L_{\text{CIoU}}+L_{\text{conf}}+\lambda\sum_{i=0}^{n}\omega^2 \tag{8}$$

2 试验分析

2.1 试验指标

为验证受电弓燃弧的检出情况和检测效果，使用准确率P(precision)、召回率R(recall)和平均精度P_{AP}(average precision)对训练好的模型进行评价。准确率P表示检测结果中检测正确的目标个数所占的比例，其分母是预测出的正样本数量，如式(9)所示。

$$P=\frac{P_{\text{TP}}}{P_{\text{TP}}+P_{\text{FP}}} \tag{9}$$

召回率R是指正确的检测结果个数在待检测目标总数中所占的比例，其分母是实际中的正样本数量，如式(10)所示。

$$R=\frac{P_{\text{TP}}}{P_{\text{TP}}+N_{\text{FN}}} \tag{10}$$

式中：P_{TP}为模型正确检出的燃弧数量；P_{FP}为检测错误的数量，即将背景中的其他物体误识别为燃弧的数

量；N_{FN}为未被模型检测出燃弧的数量，即漏检的燃弧数量。

通常，准确率和召回率是一对矛盾的指标，在目标检测中，通过设置不同的置信度阈值可以使这两个指标发生变化，一般来说，随着置信度阈值的升高，准确率越来越大，而召回率越来越小。仅仅依靠准确率和召回率并不能评价模型的综合能力，需要引入P_{AP}值才能评估网络的综合性能。通过计算出不同置信度阈值下的准确率和召回率，得到P-R曲线，其面积即为平均精度P_{AP}，如式(11)所示。

$$P_{AP}=\int_0^1 P(R)\mathrm{d}R \tag{11}$$

引入推理时间作为衡量模型识别速度的指标，推理时间为单张图片送入模型处理到预测分支输出预测信息的时间，该时间仅与模型的性能有关。

2.2　数据集

本文使用的燃弧数据集来自于地铁运营车辆上受电弓监测系统所拍摄的视频，视频分辨率为 1 920×720。使用 openCV 逐帧提取视频中的图片，通过人工筛选并使用 labelimg 标注，收集到 1 356 张燃弧图像。此外，由于补光装置的强光干扰，受电弓上方的受流钢结构长期存在反光现象，为避免该反光与小燃弧产生混淆，还在数据集中添加了 1 500 张不包含燃弧的背景图片，如图 4 所示。因此用于模型验证的数据集共计 2 856 张图片，训练集和测试集的数量按照 7:3 的比例划分，在训练时图像会经过在线 Mosaic 增强，防止出现过拟合现象。



(a) 小燃弧图像

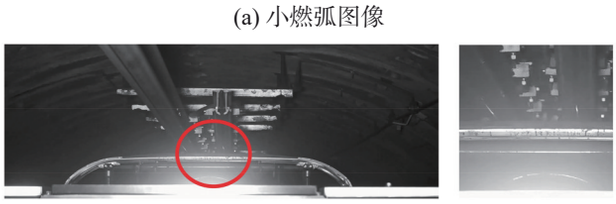

(b) 易混淆背景图像

图 4　燃弧图像与背景图像

Fig. 4　Arc image and background image

2.3　试验设置

试验硬件配置为 ADM 锐龙处理器，16 GiB 内存，显卡为英伟达 GTX 3060，操作系统为 Win10，编程语言为 Python3.9，深度学习框架为 Pytorch1.9。对于各个模型的训练，epoch 为 150，学习率初始值为 0.001，在总 epoch 的 70% 和 90% 分别进行 gamma 为 0.1 的学习率衰减，batch size 设置为 4。

本次试验以 yolov4 和 yolov4-tiny 为基准，分别对网络改进的部分进行测试。为了验证 52×52 尺度预测分支和 RFB 模块对燃弧检测效果的提升具有积极的作用，分别构建 yolov4-tiny-3H、yolov4-tiny-RFB 和 yolov4-tiny-3HRFB 这 3 种网络进行测试。

2.4　训练结果

由图 5 可知，由于初始化权重采用随机值，一开始各个模型的 loss 值较大，随着不断迭代，loss 值逐渐下降。在总 epoch 的 70%(第 105 个 epoch)和 90%（第 135 个 epoch）处，分别进行了 gamma 为 0.1 的学习率衰减，各模型的 loss 值分别有一定程度的下降，最终趋于稳定，从该曲线看，模型收敛较好。

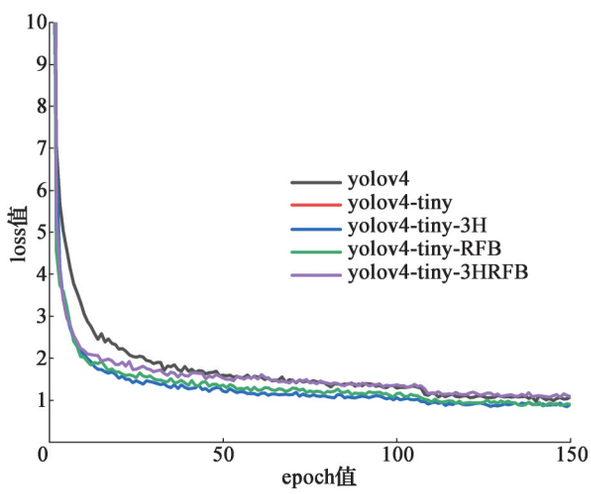

图 5　训练过程中的 loss 曲线

Fig. 5　Loss curve during training

分别使用预先训练好的 yolov4、yolov4-tiny、yolov4-tiny-3H、yolov4-tiny-RFB 和 yolov4-tiny-3HRFB 模型对测试集的图像进行测试，结果如表 1 所示。

表 1　各模型的性能对比

Table 1　Performance comparison of each model

模型	准确率 P/%	召回率 R/%	P_{AP}/%	推理时间/ms
yolov4-tiny	89.2	93.7	90.4	3.8
yolov4-tiny-RFB	91.6	96.5	94.8	4.9
yolov4-tiny-3H	95.1	96.2	95.3	4.0
yolov4-tiny-3HRFB	98.7	98.5	98.2	6.5
yolov4	98.9	97.2	97.5	19.8

由表 1 可知，相比于 yolov4-tiny 算法，单独添加 RFB 模块后的模型，无论是准确率还是召回率都有一定程度的提升，增幅约为 2 个百分点以上；单独添加 52×52 尺度的预测分支后，模型准确率提升较大，大约提升了 5.9 个百分点，召回率的提升幅度与单独添加 RFB 模块的提升幅度大致相同；而同时添加 RFB 模块和 52×52 尺度预测分支后，模型的准确率提升了 9.5 个百分点，达到了 98.7%，召回率提升了 4.8 个百分点，

达到了 98.5%。尽管相比 yolov4 模型来说，yolov4-tiny-3HRFB 的准确率稍低，但后者的 P_{AP} 值却高出了 0.7 个百分点，达到了 98.2%，在检测精度方面的综合性能最好。因此，添加 RFB 模块和第三尺度预测分支对模型精度的提升都有积极的作用，并且二者共同作用的效果最好。

在检测速度方面，yolov4-tiny 的前向推理速度最快，单张图片的耗时仅为 3.9 ms，而添加 RFB 模块和 52×52 尺度预测分支都增加了模型的检测耗时。对整个模型来说，由于在预测分支上仅针对单个目标进行推理，因此相比于添加 RFB 模块来说，构建 52×52 尺度预测分支所增加的参数量要少一些，其检测的耗时会更短一些。最终的 yolov4-tiny-3HRFB 的前向推理时间为 6.5 ms，相较于 yolov4-tiny 模型来说，增加了 2.7 ms，与 yolov4 模型的 19.8 ms 相比，其检测速度大大提升。

图 6 为部分燃弧的识别效果图（为了展示检测效果，图片已经过裁剪处理）。由图 6 可知，yolov4-tiny 模型对于小燃弧的检测能力较弱，在图 6(a)中，模型存在漏检情况，并且单独添加 RFB 模块和单独添加 52×52 尺度预测分支都不能有所改善；在图 6(b)中，相比于实际的燃弧位置，模型给出的定位存在较大的偏离，单独添加 RFB 模块或单独添加 52×52 尺度预测分支后，模型能输出正确的燃弧位置信息，而 yolov4-tiny-3HRFB 和 yolov4 都能正常检出小燃弧，表明 RFB 模块和第三尺度预测分支能提升模型对小燃弧的检测能力，二者的共同作用也能产生更积极的作用。对于较大的燃弧来说，所有模型都能正常检出，定位也较为准确。

为了避免燃弧的背景对检测造成影响，在训练集中还添加了未发生燃弧的背景图像，从测试集结果来看，仅有 yolov4-tiny 和 yolov4-tiny-RFB 两个模型产生了背景的误检现象，背景的区别效果如图 7 所示。由图 7 可知，yolov4-tiny 存在较多的误检现象， RFB 模块的添加能在一定程度上抑制该现象，但仍有少数图像被误识别成了燃弧。

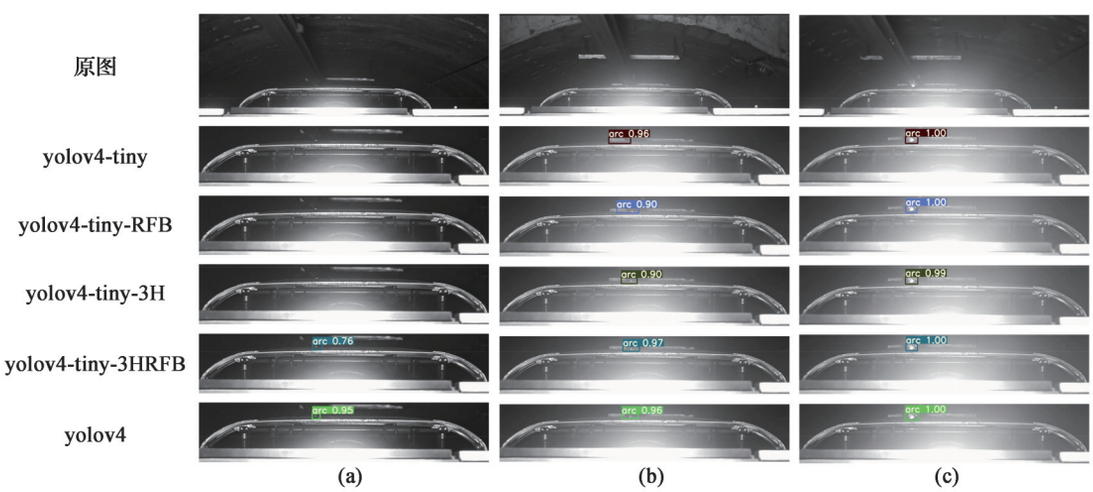

图 6　各模型的识别效果

Fig. 6　Detection effect of models

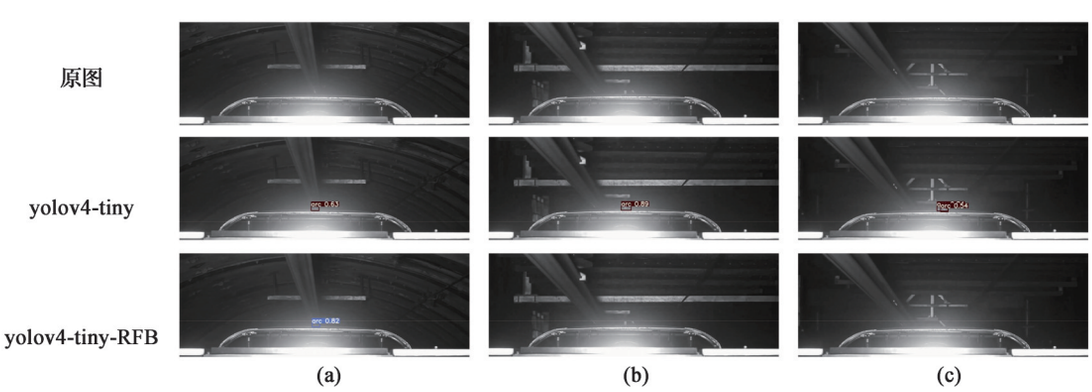

图 7　背景的识别效果

Fig. 7　Detection effect of background

3　结论

针对地铁车辆中的受电弓燃弧检测存在强光干扰和背景复杂的问题，本文对 yolov4-tiny 模型进行了改进。由于燃弧区域的尺寸较小，因此以增强模型的小目标检测能力为目的，在原模型 13×13 和 26×26 两个检测尺度的基础上，额外添加了 52×52 尺度的预测分支，并在特征金字塔 FPN 前引入了 RFB 模块，提出了 yolov4-tiny-3HRFB 模型。为了验证第三尺度预测

分支和RFB模块的效果，分别构建了yolov4-tiny-3H和yolov4-tiny-RFB作为对照组模型。结果表明，改进后的模型在测试集数据上的准确率P和召回率R分别达到了98.7%和98.5%，在平均精度P_{AP}值略高于yolov4模型的情况下，检测速度得到极大程度的提升。从识别效果来看，第三尺度预测分支和RFB模块对燃弧检测效果的提升具有积极作用，能抑制对小燃弧的漏检和定位不准，并有效避免对背景的误检现象，本文所提出的改进模型能很好地完成地铁车辆受电弓燃弧区域的定位。

参考文献：

[1] 高国强, 郝静, 古圳, 等. 高速铁路中受电弓升弓过程弓网电弧电气特性[J]. 高电压技术, 2016, 42(11): 3569-3575.
GAO Guoqiang, HAO Jing, GU Zhen, et al. Electrical characteristics on pantograph-catenary arc during pantograph rising in high speed railway[J]. High voltage engineering, 2016, 42(11): 3569-3575.

[2] KARAKOSE E, GENCOGLU M T, KARAKOSE M, et al. A new arc detection method based on fuzzy logic using S-transform for pantograph-catenary systems[J]. Journal of intelligent manufacturing, 2018, 29(4): 839-856.

[3] LI Bin, LUO Chenyu, WANG Zhiyong. Application of GWO-SVM algorithm in arc detection of pantograph[J]. IEEE access, 2020, 8: 173865-173873.

[4] 王智勇, 郭凤仪, 冯晓丽, 等. 基于电流信号特征的弓网电弧识别方法[J]. 电工技术学报, 2018, 33(1): 82-91.
WANG Zhiyong, GUO Fengyi, FENG Xiaoli, et al. Recognition method of pantograph arc based on current signal characteristics[J]. Transactions of China electrotechnical society, 2018, 33(1): 82-91.

[5] 刘宝轩, 陈唐龙, 于龙, 等. 地铁弓网燃弧能量检测与牵引电流扰动分析[J]. 铁道学报, 2015, 37(3): 8-13.
LIU Baoxuan, CHEN Tanglong, YU Long, et al. Pantograph-catenary arc energy detection and analysis on current disturbance in metro[J]. Journal of the China railway society, 2015, 37(3): 8-13.

[6] 于晓英, 苏宏升. 基于PMT电压一次积分值的城轨弓网电弧检测系统[J]. 铁道学报, 2019, 41(9): 51-58.
YU Xiaoying, SU Hongsheng. Arcing detection system for pantograph-catenary system of urban rail transit based on voltage integral value of PMT[J]. Journal of the China railway society, 2019, 41(9): 51-58.

[7] AYDIN I, KARAKOSE M, AKIN E. Anomaly detection using a modified kernel-based tracking in the pantograph-catenary system[J]. Expert systems with applications, 2015, 42(2): 938-948.

[8] AYDIN I. A new approach based on firefly algorithm for vision-based railway overhead inspection system[J]. Measurement, 2015, 74: 43-55.

[9] 杨恒, 伍川辉, 吴琛. 基于图像处理弓网燃弧检测研究[J]. 铁道科学与工程学报, 2018, 15(4): 1030-1035.
YANG Heng, WU Chuanhui, WU Chen. The pantograph-catenary arc test research based on image processing technology[J]. Journal of railway science and engineering, 2018, 15(4): 1030-1035.

[10] LU Poyan, HUO Changfan, DUAN Wangwang, et al. Information fusion and image processing based arc detection and localization in pantograph-catenary systems[C]//IEEE. 2019 22th International Conference on Information Fusion (FUSION). Ottawa: IEEE, 2019: 1-8.

[11] XING Zongyi, ZHANG Zhenyu, YAO Xiaowen, et al. Rail wheel tread defect detection using improved YOLOv3[J]. Measurement, 2022, 203: 111959.

[12] WU Yunpeng, QIN Yong, QIAN Yu, et al. Automatic detection of arbitrarily oriented fastener defect in high-speed railway[J]. Automation in construction, 2021, 131: 103913.

[13] YAO Zikai, HE Deqiang, CHEN Yanjun, et al. Inspection of exterior substance on high-speed train bottom based on improved deep learning method[J]. Measurement, 2020, 163: 108013.

[14] HE Deqiang, ZOU Zhiheng, CHEN Yanjun, et al. Obstacle detection of rail transit based on deep learning[J]. Measurement, 2021, 176: 109241.

[15] GUO Feng, QIAN Yu, SHI Yuefeng. Real-time railroad track components inspection based on the improved YOLOv4 framework[J]. Automation in construction, 2021, 125: 103596.

[16] LIU Songtao, HUANG Di, WANG Yunhong. Receptive field block net for accurate and fast object detection[C]// Springer. Computer Vision-ECCV 2018. Switzerland: Springer, 2018: 404-419.

[17] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. Scaled-YOLOv4: scaling cross stage partial network[C]//IEEE. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville: IEEE, 2021: 13024-13033.

[18] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection[DB/OL]. (2020-04-23) [2023-01-16]. https://arxiv.org/abs/2004.10934.

[19] SZEGEDY C, LIU Wei, JIA Yangqing, et al. Going deeper with convolutions[C]//IEEE. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston: IEEE, 2015: 1-9.

[20] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//IEEE. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 770-778.

收稿日期：2023-03-07
修回日期：2023-07-01