

基于改进 YOLOv8 的受电弓燃弧检测算法^{*}

张书朝 彭立强 郭阿康 王立新

(河北科技大学机械工程学院 石家庄 050018)

摘要: 针对现有受电弓燃弧检测算法对高精度和轻量化的需求,提出一种基于 YOLOv8 的轻量级受电弓燃弧检测算法 RIL-YOLO。首先,结合 RepConv 模块和 GhostNet 思想,设计了一种轻量级特征提取模块 RELAN,降低参数量和计算量的同时,保持模型对燃弧特征提取的性能;其次,针对小燃弧漏检问题,增加一个小目标检测模块,并使用加权双向特征金字塔网络结构实现更高层次的特征融合,提高模型对小目标的检测能力;为解决小目标检测模块带来的计算量大幅增加的问题,对颈部网络进行重构,降低计算量的增加;最后,设计轻量化细节增强检测头来替换 YOLOv8 检测头,在减少模型参数的同时提高模型对细节特征的捕获能力。研究结果表明,与相较于 YOLOv8, RIL-YOLO 在参数量降低 66% 与计算量降低 13.6% 的情况下,平均精度 AP@0.5、AP@0.5:0.95 分别提升了 5.2%、3.7%,检测速度达到 112.4 fps,能够有效实现燃弧快速、准确检测。该方法为受电弓燃弧实时检测提供理论方法参考。

关键词: 受电弓燃弧; YOLOv8; RELAN 模块; IBiFPN 结构; 轻量化细节增强检测头

中图分类号: TP183; TN40 **文献标识码:** A **国家标准学科分类代码:** 460.5040

Pantograph arc detection algorithm based on improved YOLOv8

Zhang Shuzhao Peng Liqiang Guo Akang Wang Lixin

(School of Mechanical Engineering, Hebei University of Science and Technology, Shijiazhuang 050018, China)

Abstract: Aiming at the problems of low detection accuracy and false detection and missed detection of small arcing in the existing pantograph arcing detection model, a lightweight pantograph arcing detection algorithm RIL-YOLO based on improved YOLOv8 is proposed. Firstly, combined with RepConv module and GhostNet idea, a lightweight feature extraction module RELAN is designed to reduce the amount of parameters and calculations while maintaining the performance of the model for arc feature extraction. Secondly, aiming at the problem of small arc missed detection, a small target detection module is added, and a weighted bidirectional feature pyramid network structure is used to achieve a higher level of feature fusion, so as to improve the detection ability of the model for small targets. In order to solve the problem that the computational cost of the small target detection module is greatly increased, the neck network is reconstructed, the reconstructed IBiFPN structure only increases the computational complexity by 0.3G while ensuring the accuracy of the model. Finally, a lightweight detail enhancement detection head is designed to replace the YOLOv8 detection head, which improves the model's ability to capture detailed features while reducing model parameters. The research results show that compared with the YOLOv8n model, the RIL-YOLO model has an average accuracy of AP@0.5 and AP@0.5:0.95 increased by 5.2% and 3.7%, respectively, when the number of model parameters is reduced by 66% and the calculation amount is reduced by 13.6%. The detection speed reaches 112.4 fps, which can effectively realize rapid and accurate detection of ignition arc. The method provides theoretical method reference for real-time detection of pantograph arc.

Keywords: pantograph arc; YOLOv8; RELAN module; IBiFPN structure; lightweight detail-enhanced detection head

0 引言

随着我国铁路事业的高速发展和列车行驶速度的提

高,列车行驶安全越来越受重视^[1]。受电弓作为列车供电系统的核心组件,与接触网在振动和摩擦的双重作用下容易发生离线现象,这种不良接触会引发燃弧,进而影响到受

流的质量,甚至威胁到列车运行安全。因此,研究受电弓燃弧实时智能检测与识别技术,具有重要研究意义与应用价值。

随着机器视觉的快速发展,基于深度学习的图像检测技术在铁路行业中得到了广泛应用,许多研究者认为这些方法能够应对工业管理中的各种挑战。Luo 等^[2]利用 Fast R-CNN 模型对燃弧进行检测与识别,并利用 SIFT 方法对视频相邻帧数图片进行特征点匹配计算像素差值,来定位燃弧发生时的真实地理位置。冯庆胜等^[3]将 MobileNet 网络的特征提取部分与 SSD 网络连接到一起,来提高算法对燃弧的检测精度,但在检测精度方面仍有待提升。Liu 等^[4]提出一种基于图像的燃弧多尺度融合语义分割模型,将 Transformer 与卷积网络聚合在一起,来实现燃弧像素分割,但检测速度较低不适用于实时检测。虽然上述燃弧检测方法在精度上有良好的表现,但由于其复杂的模型结构、庞大的参数量以较高的运算需求导致处理速度下降,进而影响整体检测性能。因此,对深度学习模型轻量化设计具有重要意义。

当前,深度学习模型轻量化的设计主要为两类:基于轻量化模块的结构设计和基于参数剪枝的模型压缩。高嘉等^[5]设计了轻量级 LW-C3 模块,有效降低了 YOLOv5 模型的参数量和计算量。刘航等^[6]通过对 YOLOv8 模型进行通道剪枝,去除模型中存在的冗余计算,大幅降低了模型大小和浮点运算量。姚景丽等^[7]通过在 C2f 模块中引入轻量级卷积 SCConv,来降低 YOLOv8 在空间和通道维度的冗余计算。Fan 等^[8]通过引入轻量级非对称检测头 LADH,有效提升了 YOLOv8 的推理速度。Ma 等^[9]通过将 YOLOv8 的主干网络替换为 GhostNet 网络,实现了轻量级部署。张小艳等^[10]在 YOLOv8 颈部网络中引入 GSConv 和 VOVGSCSP 模块替换卷积和部分 C2f 模块,从而降低模型参数。Zhou 等^[11]利用 GhostConv 和 C3Ghost 模块替换 YOLOv8 主干和颈部网络中的卷积和 C2f 模块,部署到 NVIDIA Jetson TX2 开发板上检测速度达到 69.8 fps。

虽然上述方法能显著减少模型的参数量和运算量,但对模型检测精度会造成一定影响,因此如何在计算效率和识别精度之间取得最优平衡仍需深入研究。本文为提高燃弧检测精确度与轻量化的需求,提出基于 RIL-YOLO 的轻量化受电弓燃弧检测算法,通过对 YOLOv8 模型的主干网络、颈部网络和头部网络的改进,在轻量化的同时提升模型的检测能力,具体工作如下:

1)针对 C2f 模块中 Bottleneck 结构进行特征融合操作时,导致的通道特征信息过度冗余问题,利用 RepConv 模块和 GhostNet 思想设计重参数化高效层聚合网络 (reparameterized efficient layer aggregation networks, RELAN),在降低模型大小和计算成本的同时,保持特征提取和梯度流通的性能。2)针对小燃弧漏检问题,通过增加小目标检测模块和引入加权双向特征金字塔网络

(weighted Bi-directional feature pyramid network, BiFPN),并重构颈部网络,降低模型计算量的增加,提高模型对小燃弧的检测能力。3)利用参数共享技术和细节增强卷积 (detail enhanced convolution, DEConv),设计轻量化细节增强检测头 (lightweight detail enhanced detection head, LDEDH),对头部网络进行轻量化处理,在降低参数量和计算量的同时,提升对细节特征的捕获能力。

1 RIL-YOLO 网络

1.1 YOLOv8 算法存在的问题

在受电弓燃弧检测任务中,由于实时性要求较高,直接使用 YOLOv8x 算法虽然能提供最佳检测效果,但由于其对硬件要求较高,因此不适合应用于资源设备有限的设备。为此,本文选取了 YOLOv8 算法中最小权值模型 YOLOv8n,但在实际的检测过程中,YOLOv8n 算法也暴露出一些问题。首先,YOLOv8n 算法使用了大量的标准卷积和 C2f 模块,在提高了算法准确性的同时,增加了模型的大小和计算成本。其次,受电弓燃弧检测中存在较小的燃弧目标,需要足够的检测精度,但 YOLOv8n 算法在这类小目标检测上的表现并不理想,常出现误检或漏检的情况。

1.2 改进的 YOLOv8 算法

基于 YOLOv8 改进后的 RIL-YOLO 结构如图 1 所示。将 YOLOv8 主干网络中 C2f 模块替换为 RELAN 模型,在保持模型特征提取性能的同时,降低模型大小和计算成本。针对小燃弧漏检的问题,在模型中增添一个 160×160 的小目标检测模块,同时使用加权双向特征金字塔网络结构实现更高层次的特征融合,并重构颈部网络降低小目标检测模块带来的计算成本。将检测头替换为轻量化细节增强检测头,来捕获更多细节特征信息。

为进一步体现出本文对 YOLOv8 模型改进的优势,与已有改进的 YOLOv8 模型进行对比,说明本文 YOLOv8 模型改进与改进的 YOLOv8 模型之间的联系和区别^[12-17],如表 1 所示。表 1 中简要说明了 RIL-YOLO 与其他 YOLOv8 改进模型的相似与不同之处,能够充分体现出 RIL-YOLO 模型的优势与创新之处。

1.3 RELAN 模块

C2f 模块中含有多个 Bottleneck 结构并且需要特征融合操作,导致通道特征信息过度冗余,增加模型的计算复杂度,对此,舍弃 YOLOv5 与 YOLOv8 中常用的 Bottleneck 结构,降低模型的计算复杂度。为弥补 Bottleneck 结构中残差块所带来的性能损失,在梯度流通分支上使用多分支结构,增强特征提取能力和梯度流通能力,但复杂的多分支结构会导致模型推理速度和内存利用率降低。所以本文引入重参数化 RepConv (Re-param Conv) 模块^[18],在模型训练阶段使用多分支并行结构,在推理阶段将分支参数重参数化到主分支上转换为单分支结构,减少模型计算量和内存消耗^[19]。

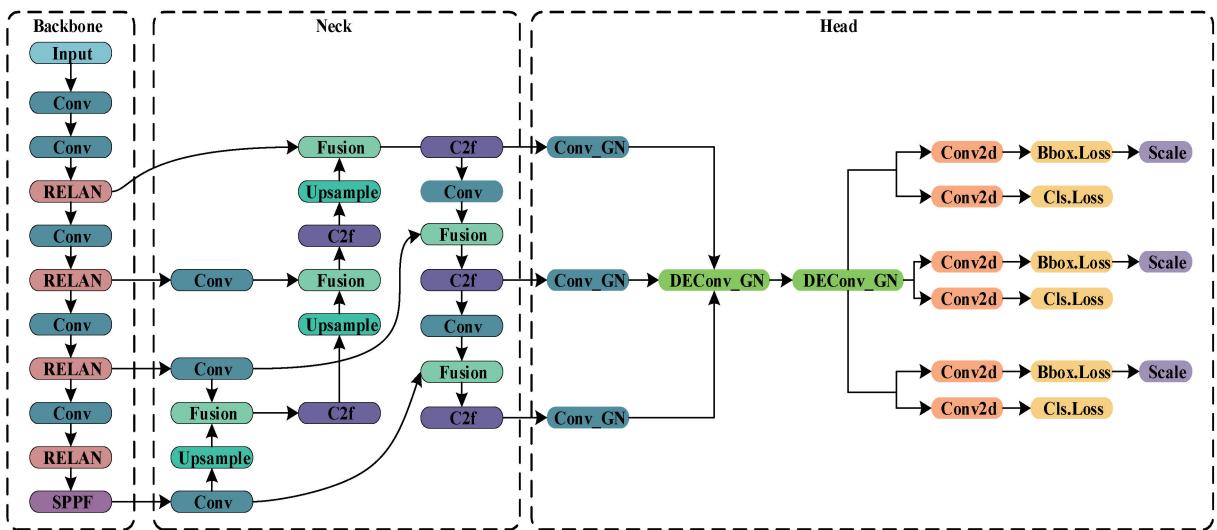


图 1 RIL-YOLO 网络结构

Fig. 1 RIL-YOLO network structure

表 1 与已有改进模型间的联系和区别

Table 1 The relation and difference with existing improved models

YOLOv8 改进方法	联系	区别
文献[12-13]	均应用到共享卷积检测头	在其基础上引入细节增强卷积, 提升模型对小目标的检测能力
文献[14-15]	使用到 BiFPN 与改进 C2f 模块	本文在降低模型大小与计算量的同时, 提升了检测精度
文献[16]	均添加小目标检测头和采用 BiFPN 结构	该文献未对添加改进后的模型计算量进行降低
CR-YOLOv8 ^[17]	均对模型小目标检测性能优化	本文在提升模型小目标检测能力的同时, 对模型进行轻量化

RepConv 结构如图 2 所示, 使用卷积重参数化技术, 训练阶段采用 3×3 Conv、 1×1 Conv 和 BatchNorm 的并行结构获取多尺度特征信息, 在推理阶段使用卷积重参数化技术将分支参数融合到主分支成为单分支结构, 通过 3×3 Conv 实现高效检测。

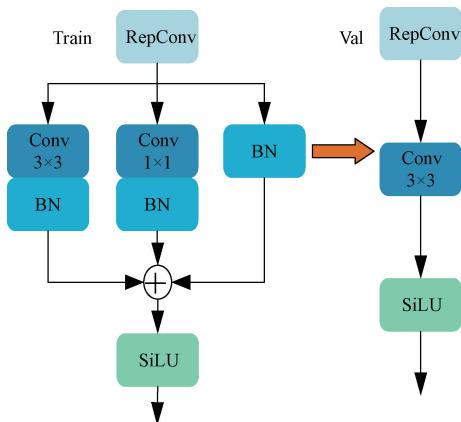


图 2 RepConv 网络结构

Fig. 2 RepConv network structure

GhostNet^[20]指出主流 CNN 计算中间特征映射存在广泛的冗余情况, 因此, 借鉴 GhostNet 思想采用廉价的 1×1 Conv 操作生成一部分冗余特征图, 来降低参数量和计

算量。结合 RepConv 模块和 GhostNet 思想提出重参数化高效层聚合网络 (RELAN), 在降低参数量和计算量的同时, 保持特征提取和梯度流通的性能。RELAN 网络结构如图 3 所示, 在梯度流通分支最初的位置使用 RepConv 模块, 在结尾使用廉价的 1×1 Conv 操作, 并通过缩放因子控制 RELAN 的大小, 使其可以兼顾不同大小的模型。

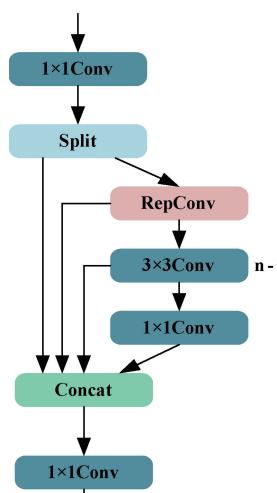


图 3 RELAN 网络结构

Fig. 3 RELAN network structure

1.4 IBiFPN 结构

受电弓燃弧在图像中像素占比较小,并且检测的图像燃弧像素占比较小的情况居多,会导致燃弧检测效果相对较差,而原 YOLOv8 的 3 个检测头对应颈部输出特征图大小为 80×80 、 40×40 、 20×20 ,但模型经过多次下采样,小燃弧特征已不明显,甚至融入到背景中。因此,利用主干网络的浅层特征图中丰富的小目标特征信息,在颈部端进行上采样和特征拼接获得大小为 160×160 的特征图,对应小目标检测模块,以此降低小燃弧的漏检。

YOLOv8 颈部采用路径聚合网络(PAN)对特征进行

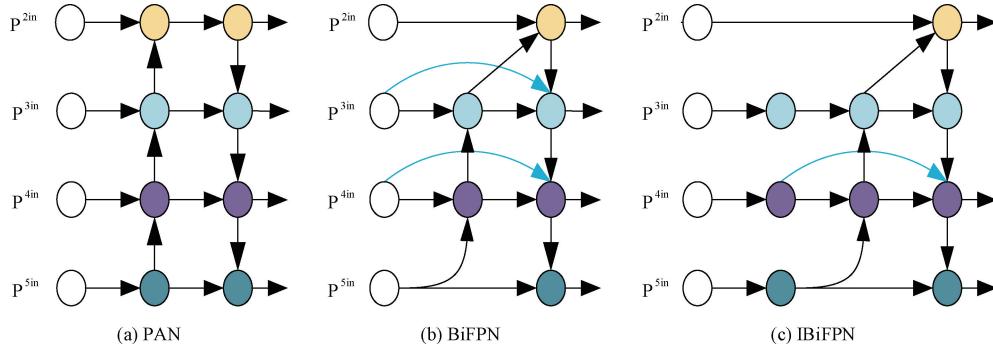


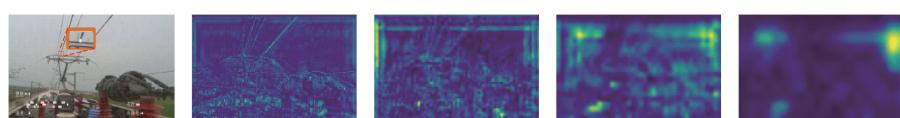
图 4 重构的 IBiFPN 结构

Fig. 4 Reconfigured IBiFPN structure

上述对 YOLOv8 颈部的改进能够有效降低小燃弧的漏检率,但由于添加小目标检测模块,导致模型计算量大幅度增加,对此,本文对颈部网络进行优化,来降低计算成本。将添加小目标检测模块后的 YOLOv8-P2 模型可视化颈部网络输出模块的特征图(从左到右分别为原图、18 层特征图、21 层特征图、24 层特征图、27 层特征图),如图 5 所示,可以看出小燃弧特征只出现在 18 层,常规燃弧特征

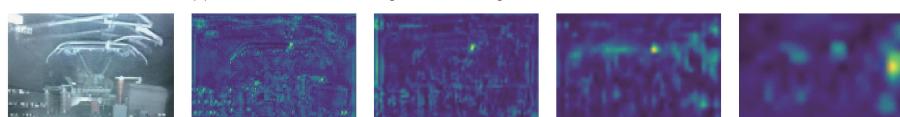
融合,通过自上而下的结构将浅层信息传导到深层,如图 4(a)所示,增强多尺度特征的定位能力,但特征融合中的冗余节点作用甚微,不能分辨输入特征的重要程度,反而产生额外的参数量和计算成本。本文在颈部使用加权双向特征金字塔网络(BiFPN)^[21],BiFPN 结构如图 4(b)所示,去除在特征融合贡献较小的一些输入节点,并在尺度相同的输入与输出节点添加跳跃链接,保证计算成本不变的前提下融合多尺度特征,对不同尺度的特征图进行动态加权的融合方式,使模型学习到各尺度特征中的重要信息。

在 18、21、24 层均能显著体现,大燃弧特征均能显著体现出来,且 27 层特征图中燃弧的显著性高于另外 3 张,因此,小检测头和大检测是必须存在的,考虑到 21 层输出特征图大于 24 层计算量更多,所以关闭颈部网络 21 层对头部网络的输出,并删除对应的检测头。在主干网络与 BiFPN 之间 3×3 大小、通道数为 256 的卷积,使得 YOLOv8 网络与 BiFPN 更好衔接,由 p2 层输出特征图尺寸较大,因此, p2



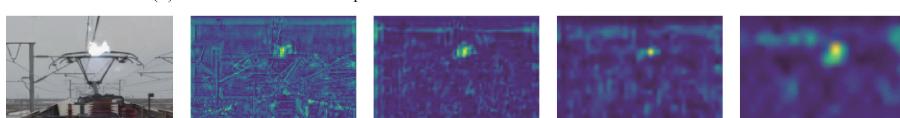
(a) 小燃弧颈部网络输出特征图可视化

(a) Visualization of the output feature map of a small arc neck network



(b) 常规燃弧颈部网络输出特征可视化

(b) Visualization of the output characteristics of a conventional arc neck network



(c) 大燃弧颈部网络输出特征可视化

(c) Visualization of network output features for large arc necks

图 5 特征图可视化

Fig. 5 Feature map visualisation

层输出到 BiFPN 之间没有添加卷积操作。重构后的 IBiFPN 如图 4(c)所示,在降低模型参数量和增加少量计算成本的情况下,降低了小燃弧的漏检率。

1.5 检测头改进

YOLOv8 检测头采用解耦头结构,颈部网络输出的每个尺度特征都有独立的检测头进行处理预测,头部网络中缺少特征信息之间的交互,可能会使部分特征信息丢失,从而导致检测能力下降。为了解决上述问题,并利用参数共享技术和 DEConv^[22],提出轻量化细节增强检测头,其结构如图 6 所示。输入 LDEDH 检测头的特征信息,首先,特征

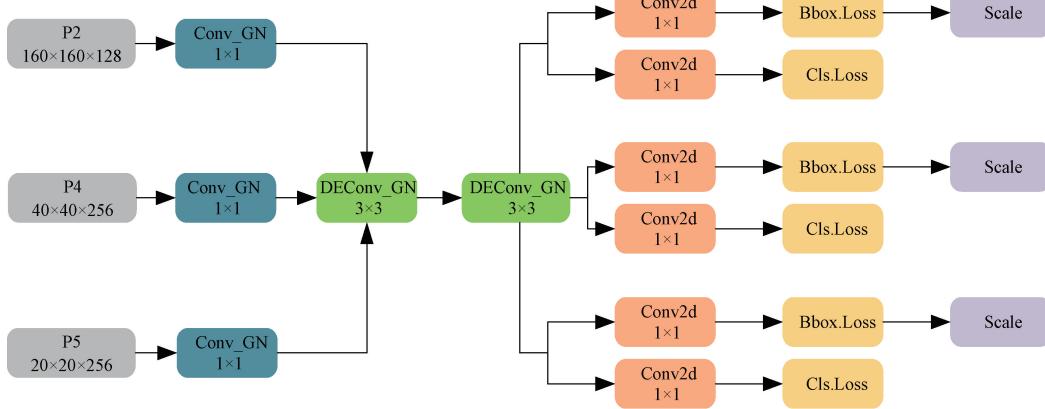


图 6 LDEDH 网络结构

Fig. 6 LDEDH network structure

DEConv 模块是细节增强注意力网络(details-enhance attention network, DEA-Net)提出的一种新的细节增强卷积,其结构如图 7 所示。DEConv 是由一个香草卷积(vanilla convolution, VD)和四个差分卷积(difference convolution, DC)组成,它们并行部署进行特征提取,利用 VD 获得强度级特征信息,而差分卷积用于增强梯度级特征信息。在差分卷积中,利用中心差分卷积(central difference convolution, CDC)、角差分卷积(angular difference convolution, ADC)、水平差分卷积(horizontal difference convolution, HDC)和垂直差分卷积(Vertical Difference Convolution, VDC)将梯度先验信息编码到卷积中,通过学习梯度信息来提高表达和泛化能力。此外,利用重参数化技术将 DEConv 的参数量和计算成本等效为普通卷积水平。计算公式如下:

$$F_{out} = F_{in} * \left(\sum_{i=1}^5 K_i \right) = F_{in} * K_{cut} \quad (1)$$

式中: K_i = 1:5 分别表示 VC、CDC、ADC、HDC 和 VDC 的核,* 表示卷积运算, K_{cut} 表示并行卷积组合在一起的转换核。

2 实验结果与分析

2.1 实验准备

本实验在 Win10 操作系统下进行,使用 Intel Xeon

信息分别通过 1×1 卷积将通道数量压缩一致,再连续通过两个 3×3 共享参数的细节增强卷积,来捕获更多细节特征信息,最后将共享特征信息的结果进行标准化卷积操作,获得固定尺寸的输出特征,并利用 Scale 层对输出特征进行缩放,对应每个检测头的目标尺度。并受到分组归一化(group normalization, GN)^[23]的启发,替换卷积组合中的批量归一化(batch normalization, BN),GN 将通道按组分开,在计算每组平均值和方差进行归一化。GN 计算与批量大小无关,其精度在广泛的批量大小范围内都是稳定的,避免了 BN 在批量过大或过小时模型训练不稳定的问题。

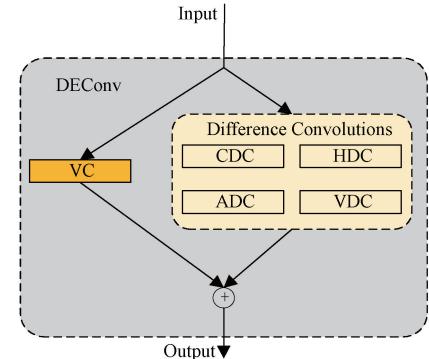


图 7 DEConv 网络结构

Fig. 7 DEConv network structure

Gold 6300 处理器, GPU 为 NVIDIA RTX 3090(24 GB),采用编程语言为 Python3.8,深度学习框架为 PyTorch1.9.0, 使用 CUDA11.1 对 GPU 进行加速。模型训练周期 300, 每批次训练 16 张图片, 输入图像尺寸为 640×640 , 采用 SGD 优化器, 学习率为 0.01, 其余为模型默认参数。

本文以高速铁路运行中的列车运行监测系统拍摄的视频和公开燃弧视频为研究对象, 视频分辨率为 1920×1080 。利用 OpenCV 对采集到的视频进行逐帧提取, 通过人工筛选获得 1 608 张燃弧图像, 以及 2 100 张无燃弧图像, 其中包

含晴天、阴天、夜晚、隧道等 4 种不同场景下的燃弧图片。同时,本文使用 OpenCV 库将随机挑选数据集中 50% 的图片模拟雨天、雪天、雾天等天气状态,以及噪声和不同亮度处理,用于模拟受电弓运行下的不同背景环境。对增强后的数据集使用 LabelImg 进行标注,将标注框命名为“arcing”,获得燃弧标签 2 806 个,其中小燃弧标签 888 个、常规燃弧标签 1 351 个、大燃弧标签 576 个,燃弧数据集按 7:2:1 划分为训练集、测试集、验证集。

2.2 评价指标

本文采用召回率 (recall, R)、平均精度 (average precision, AP)、模型参数量 (Params)、每秒浮点运算次数 (GFLOPs) 和模型每秒检测图片速度 (frames per second, FPS) 等作为模型评价指标。R 和 AP 计算公式如下:

$$R = \frac{TP}{TP + FN} \quad (2)$$

$$AP = \int_0^1 \max(P(r')) d(r) \quad (3)$$

式中: TP 表示待测燃弧被预测正确的数量, FN 表示待测燃弧被预测错误的数量, P 为精确率。

2.3 RELAN 缩放因子选择实验

为了选取合适的 RELAN 缩放因子,本文分别选择大小为 0.25、0.5、0.75、1 这 4 种缩放因子进行对比实验,实验结果如表 2 所示。从表 2 中可以看出,缩放因子的大小与模型平均精度之间没有相应关系,模型平均精度 AP@0.5 和 AP@0.5:0.95 在缩放因子为 0.25 和 1 时最大,并且缩放因子为 0.25 时,模型的参数量和计算量最少,因此,缩放因子大

小选择 0.25,在轻量化的同时,保持模型检测性能。

表 2 不同缩放因子对模型性能的影响

Table 2 Model performance comparison after improved loss function

缩放因子	AP@0.5/%	AP@0.5:0.95/%	Params/M	FLOPs/G
0.25	89.9	57.9	2.5	6.6
0.5	88.0	56.8	2.6	6.8
0.75	87.9	55.8	2.7	7.1
1	89.3	58.3	2.8	7.4

2.4 颈部网络重构实验

为了验证本文重构颈部网络的有效性,将重构后的 IBiFPN 与 BiFPN、YOLOv8-P2、YOLOv8n 模型和已有改进 BiFPN 结构进行比较,对比试验如表 3 所示。本文重构后的 IBiFPN 在性能指标、模型参数量和计算成本方面表现出显著的优势,与 BiFPN 和 YOLOv8-p2 模型相比,在平均精度 AP@0.5 与 AP@0.5:0.95 轻微波动的情况下,参数量分别降低 0.4 M、1.1 M,计算量分别降低 8.3 G、3.8 G,IBiFPN 模型的平均精度 AP@0.5 与 AP@0.5:0.95 相较于 YOLOv8n 模型,分别提升了 5.2%、1.6%,与已有改进 BiFPN 结构相比,平均精度 AP@0.5 至少高出 1.4%。因此,在保证检测精度的同时,选择 IBiFPN 模型能够使模型参数更低、计算成本少量增加,并且检测速率仅次于 YOLOv8n 模型达到 105.3 fps。

表 3 颈部网络重构对比实验

Table 3 Comparative experiments on neck network reconfiguration

模型	AP@0.5/%	AP@0.5:0.95/%	Params/M	FLOPs/G	FPS/fps
YOLOv8n	90	58.8	3.0	8.1	138.9
YOLOv8-p2	95.2	60.9	2.9	12.2	100
YOLOv8n+BiFPN	95.3	60.8	2.2	16.7	99
SC-BiFPN ^[24]	91.9	61.3	1.5	6.8	123.5
BiFPN-D ^[25]	93.8	61.5	2.5	11.7	102.2
文献[26]	92.7	61.2	2	7.4	116.7
YOLOv8n+IBiFPN	95.2	60.4	1.8	8.4	105.3

2.5 消融实验

消融实验如表 4 所示,从表中可知,实验 2 在 YOLOv8n 模型中将部分 C2f 模块替换为 RELAN 后,在平均精度基本不变的情况下,模型参数量和计算量分别降低了 0.5 M 和 1.5 G;实验 3 在重构颈部网络后,参数量降低了 1.2 M,计算量仅提高了 0.3 G,AP@0.5、AP@0.5:0.95 分别提高 5.2%、1.6%,有效提高了模型对小目标的检测能力;实验 4 将检测头替换为 LDEDH 模块,模型参数量和计算量分别降低了 0.6 M 和 1.6 G,明显降低了模型计算成本,与实验 1 相比

AP@0.5 提高了 0.9%,提升了对细节特征的捕捉能力;实验 5、实验 6 和实验 7 是将 RELAN、IBiFPN 和 LDEDH 两两组合添加到 YOLOv8 模型中,平均精度相较于实验 1 均有大幅提升,实验 5 和实验 6 参数量和计算量相较于实验 1 均有大幅降低,实验 7 计算量相较于实验 1 仅提升 0.3 G;实验 8 是将所有模块添加到 YOLOv8 模型,经过 300 轮迭代,最终训练得到 RIL-YOLO 模型,相较于 YOLOv8n 模型 AP@0.5、AP@0.5:0.95 分别提高 5.2%、3.7%,模型参数量降低了 2.0 M,计算量降低了 1.1 G,检测速率高达 112.4 fps。

表 4 消融实验

Table 4 Ablation experiment

编号	RELAN	IBiFPN	LDEDH	AP@0.5/%	AP@0.5:0.95/%	Params/M	FLOPs/G	FPS/fps
1	—	—	—	90	58.8	3.0	8.1	138.9
2	✓	—	—	89.9	57.9	2.5	6.6	119.
3	—	✓	—	95.2	60.4	1.8	8.4	105.3
4	—	—	✓	90.9	58.3	2.4	6.5	126.6
5	✓	✓	—	95.9	60.6	1.2	7.0	111.1
6	✓	—	✓	91.8	59.8	1.9	5.0	138.9
7	—	✓	✓	94.6	59.5	1.6	8.4	102
8	✓	✓	✓	95.2	62.5	1.0	7.0	112.4

实验结果表明, RELAN、IBiFPN 和 LDEDH 相结合对模型改进检测效果要优于表 4 中的其他组合。

图 8 为消融实验每组模型训练结果, 图 8(a)、(b) 表示平均精度 AP@0.5 和 AP@0.5:0.95 曲线图。由图 8 可

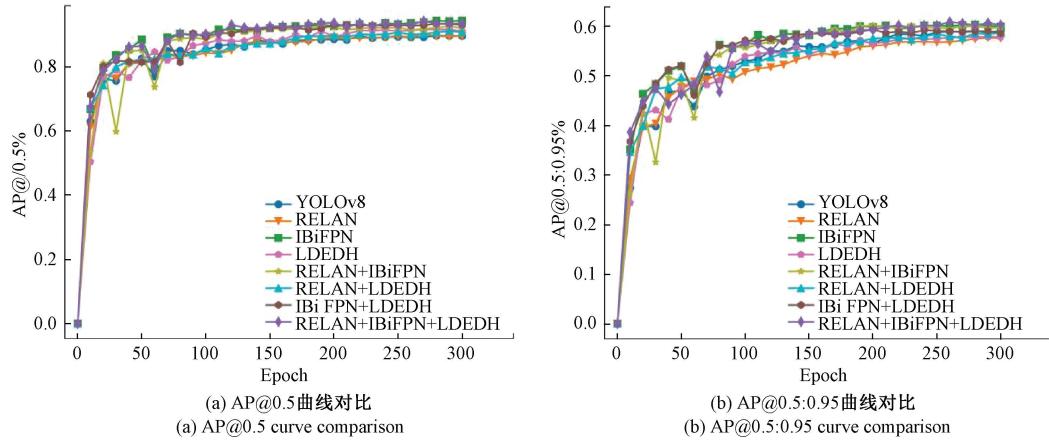


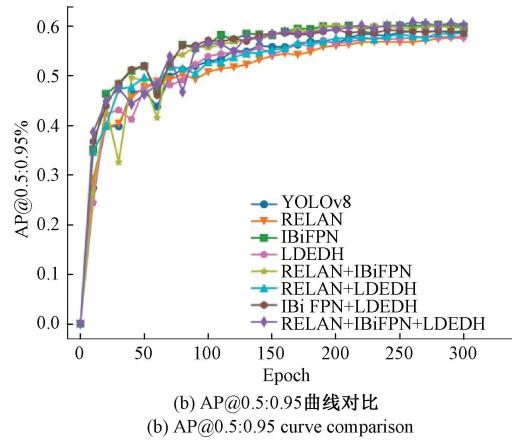
图 8 模型改进前后平均精度曲线对比

Fig. 8 Comparison of mean accuracy curve and recall curve before and after model improvement

2.6 不同模型性能对比实验

为了验证改进模型在受电弓燃弧检测中的优势, 将改进后的 RIL-YOLO 模型与 Fast-RCNN^[27]、YOLOv5n、YOLOv7^[28]、YOLOv7-tiny、YOLOv9-tiny^[29]、YOLOv10n^[30]、YOLOv11n^[31] 等主流检测模型在相同实验条件下进行对比。实验结果如表 5 所示, 改进后的 RIL-YOLO 模型参数量和计算量均低于目前主流的模型, 而检测速度 FPS 高于 Fast-RCNN、YOLOv7 和 YOLOv7-tiny、YOLOv9-tiny 模型, 仅次于 YOLOv5 模型达到 112.4 fps, 满足受电弓燃弧实时性检测要求。RIL-YOLO 模型的平均精度 AP@0.5 相较于 Fast-RCNN、YOLOv5n、YOLOv7、YOLOv7-tiny、YOLOv8n、YOLOv9-tiny、YOLOv10n、YOLOv11n 模型分别提高了 1.1%、5.5%、6.4%、7.5%、5.2%、3.7%、6.1%、5.3%, AP@0.5:0.95 分别提高了 3.3%、4.3%、5.3%、5.9%、3.7%、1.8%、2.9%、0.6%。综上所述, 改进后的 RIL-YOLO 模型在提高目标检测精度的同时, 保持了较高的检测速度和较低的模型参数量与计算量, 优于目前主流的检测模型。

知, 本文提出的 RIL-YOLO 模型在 AP@0.5 曲线上仅次于重构后的 IBiFPN 模型, 而在 AP@0.5:0.95 曲线上收敛后优于其他组合。因此, RIL-YOLO 模型整体优于其它改进模型, 对燃弧检测具有更好的性能。



2.7 可视化分析

为了更加直观地体现 RIL-YOLO 对不同尺寸燃弧的识别能力, 本文通过使用 GradCAMPlusPlus^[32] 方法对颈部网络的输出层进行可视化。算法改进前后的热力图效果对比如图 9 所示。根据图 9 可知, RIL-YOLO 相较于 YOLOv8 模型, 能更好的关注不同尺寸燃弧区域的特征, 且高亮区域与图像中燃弧区域重合度更高、聚焦效果更好, 能有效检测出燃弧位置。改进后的算法能有效降低燃弧的漏检与误检的识别率, 提升了模型在燃弧检测中的整体性能。

为进一步验证 RIL-YOLO 模型在不同燃弧尺寸下检测的有效性, 从测试集中选取小燃弧、常规燃弧和大燃弧进行测试比较, 检测结果如图 10 所示。图 10(a) 为小燃弧图片, 可以看出 YOLOv8n 模型没有检测到小燃弧的存在, 而改进后 RIL-YOLO 模型能够精准的检测到小燃弧。YOLOv8n 模型和 RIL-YOLO 模型对于常规燃弧检测都有很好的效果, 对于大燃弧检测, 从图 10(c) 可以看出 RIL-YOLO 模型在夜晚比 YOLOv8n 模型能够更好检测到燃弧的整体形状。这些对比结果表明, 改进后的模型没有明

表 5 不同模型性能对比

Table 5 Performance comparison of different models

模型	AP@0.5/%	AP@0.5:0.95/%	Params/M	FLOPs/G	FPS/fps
Fast-RCNN	94.1	59.2	41.8	135.0	26.3
YOLOv5n	89.7	58.2	2.5	7.1	114.9
YOLOv7	88.8	57.2	36.5	103.2	74.6
YOLOv7-tiny	87.7	56.6	6.0	13.0	88.5
YOLOv8n	90.0	58.8	3.0	8.1	138.9
YOLOv9-tiny	91.5	60.7	2.6	10.7	107.5
YOLOv10n	89.1	59.6	2.3	6.5	127.8
YOLOv11n	89.8	61.9	2.6	6.3	133.3
RIL-YOLO	95.2	62.5	1.0	7.0	112.4

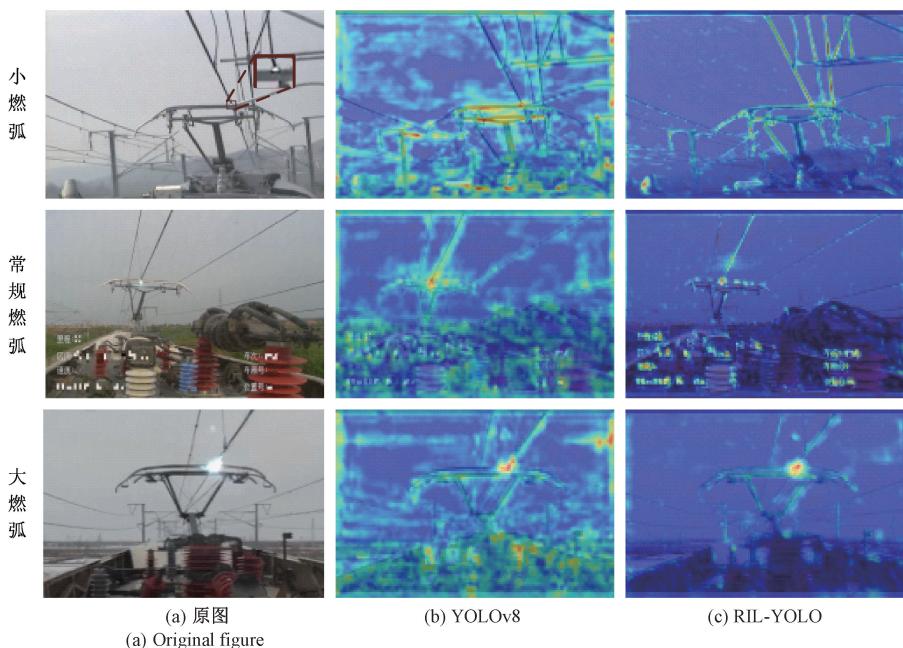
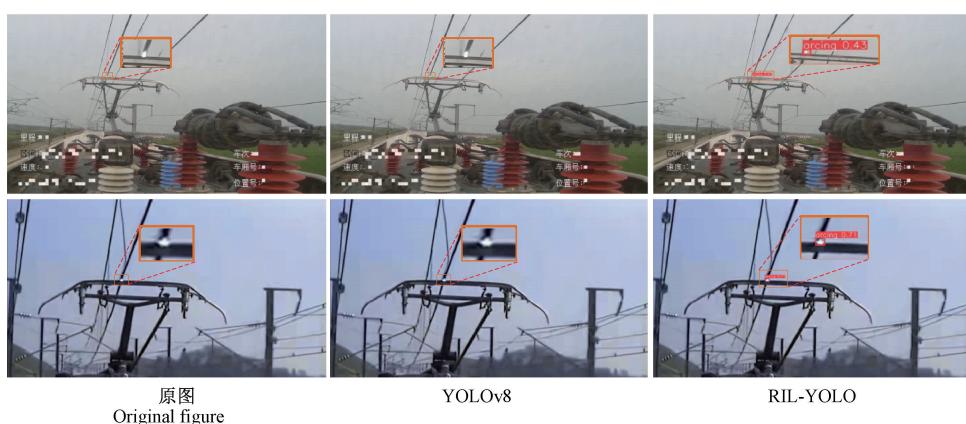


图 9 热力图可视化效果

Fig. 9 Heat map visualisation effect

(a) 小燃弧检测结果对比
(a) Comparison of small arc detection results

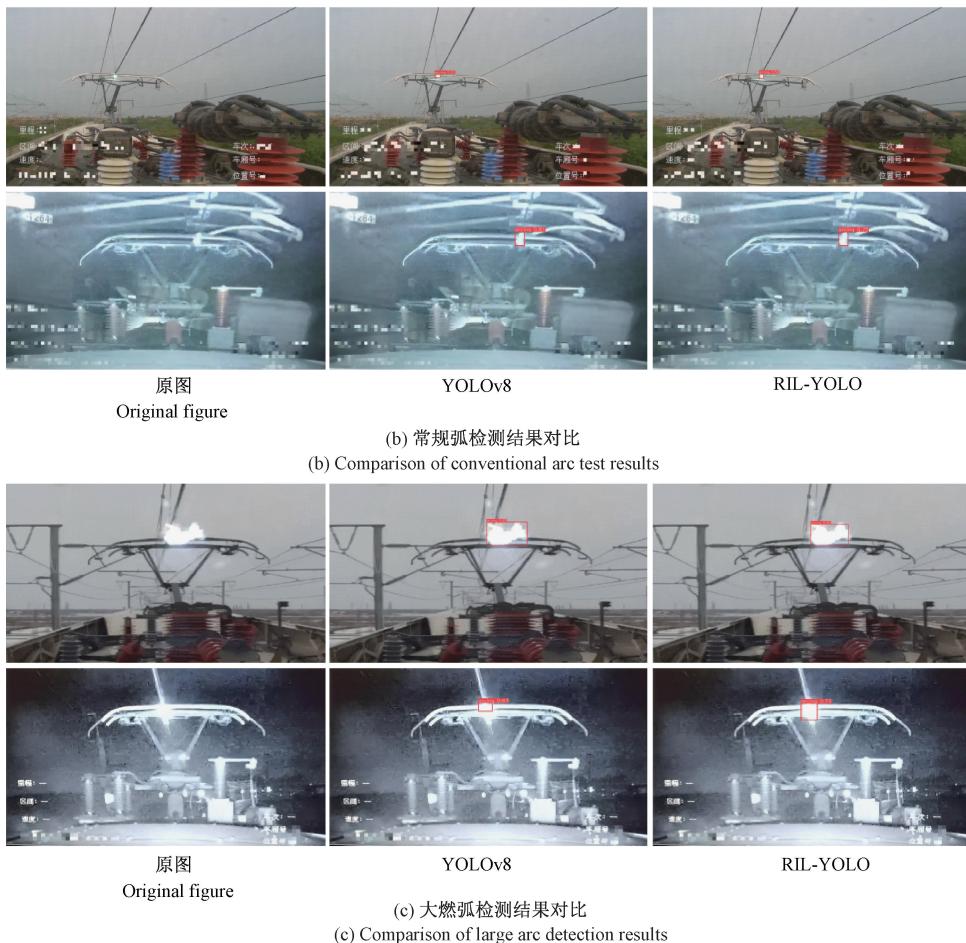


图 10 不同燃弧尺寸下检测结果对比

Fig. 10 Comparison of detection results under different arc sizes

显漏检现象,在不同背景下表现出良好的泛化性和鲁棒性,能够有效的满足燃弧检测需求。

2.8 系统测试

为了验证 RIL-YOLO 模型的实时检测能力,本文基于 PyQt5 搭建受电弓燃弧检测系统界面,将算法模型与权重

转换为 ONNX 格式文件,便于检测系统调用。使用一段 1 min 29 s 的视频去检测系统的准确性和实时性,该视频中有燃弧 65 帧,其检测过程如图 11 所示。两种算法对比结果如表 6 所示,系统调用 RIL-YOLO 算法相较于 YOLOv8 算法,燃弧检测准确率提升了 6.1%,平均每张图



图 11 系统检测示意图

Fig. 11 Schematic diagram of system detection

表 6 对比结果
Table 6 Comparative results

算法	准确率/%	每帧处理时间/ms
YOLOv8	90.8	13.67
RIL-YOLO	96.9	10.32

片处理时间为 10.32 ms, 满足实时检测需求。

3 结论

针对受电弓燃弧检测任务中对复杂背景下燃弧检测精度较低和小燃弧漏检、误检问题, 本文基于 YOLOv8 模型提出高效、准确的检测算法 RIL-YOLO。改进算法通过去除 C2f 模块中 Bottleneck 结构, 融合 RepConv 模块和 GhostNet 思想设计 RELAN 模块替换 C2f 模块, 降低主干网络中的冗余计算; 颈部网络通过增加小目标检测模块和引入 BiFPN 结构, 提升模型对小目标的检测性能, 并通过重构颈部网络, 在保证精度情况下, 降低添加小目标检测模块所带来的计算成本; 最后, 设计 LDEDH 模块对头部网络进行轻量化处理, 并提高对细节特征的捕获能力。实验结果表明, RIL-YOLO 模型与 YOLOv8n 模型相比, 参数量降低 2.0 M, 计算量降低 1.1 G, 平均精度 AP@0.5、AP@0.5:0.95 分别提升了 5.2%、3.7%, 在保证轻量化的情况下, 有效解决了复杂背景下燃弧检测精度较低和漏检问题。经过消融试验与对比试验的验证, 在相同试验条件下, 改进后的 RIL-YOLO 模型综合检测性能是优于各项试验结果, 并且检测速度达到 112.4 fps, 可以实现在复杂和开阔的场景下燃弧快速、准确的检测, 同时, 燃弧检测系统准确率达到 96.9%, 每张图片处理时间为 16.32 ms, 满足实际应用需求。

参考文献

- [1] 刘力, 荀军年. 基于 YOLOv4 的铁道侵限障碍物检测方法研究[J]. 铁道科学与工程学报, 2022, 19(2): 528-536.
- [2] LIU L, GOU J N. Research on detection method of railway encroachment obstacles based on YOLOv4[J]. Journal of Railway Science and Engineering, 2022, 19(2): 528-536.
- [3] LUO Y P, YANG Q R, LIU S. Novel vision-based abnormal behavior localization of pantograph-catenary for high-speed trains[J]. IEEE Access, 2019, 7: 180935-180946.
- [4] 冯庆胜, 董琦, 刘雨奇, 等. 基于改进 MobileNet-SSD 的受电弓燃弧检测方法[J]. 自动化与仪表, 2023, 38(11): 54-59.
- [5] FENG Q SH, DONG Q, LIU Y Q, et al. Arc detection model of pantograph based on improved MobileNet-SSD[J]. Automation and Instrumentation, 2023, 38(11): 54-59.
- [6] LIU Y, QUAN W, LU X M, et al. A novel arcing

detection model of pantograph-catenary for high-speed train in complex scenes[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-13.

- [5] 高嘉, 刘涛, 王显峰, 等. TWRD-Net: 一种用于曳引钢丝绳缺陷的实时检测网络算法[J]. 仪器仪表学报, 2023, 44(6): 223-235.

GAO J, LIU T, WANG X F, et al. TWRD-Net: A real-time detection network algorithm for traction wire rope defects [J]. Chinese Journal of Scientific Instrument, 2023, 44(6): 223-235.

- [6] 刘航, 李明, 刘志坚, 等. 基于轻量化改进 YOLOv8n 绝缘子自爆缺陷检测方法[J]. 电子测量与仪器学报, 2025, 39(1): 57-69.

LIU H, LI M, LIU ZH J, et al. Self-explosion defect detection method of insulator based on lightweight and improved YOLOv8n [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39 (1): 57-69.

- [7] 姚景丽, 程光, 万飞, 等. 改进 YOLOv8 的轻量化轴承缺陷检测算法[J]. 计算机工程与应用, 2024, 60(21): 205-214.

YAO J L, CHENG G, WAN F, et al. Improved lightweight bearing defect detection algorithm of YOLOv8[J]. Computer Engineering and Applications, 2024, 60(21): 205-214.

- [8] FAN ZH P, WU Y, LIU W, et al. LG-YOLOv8: A lightweight safety helmet detection algorithm combined with feature enhancement [J]. Applied Sciences-Basel, 2024, 14(22): 1-16.

MA S ZH, LU H M, LIU J, et al. LAYN: Lightweight multi-scale attention YOLOv8 network for small object detection[J]. IEEE Access, 2024, 12: 29294-29307.

- [9] [10] 张小艳, 王苗. 改进的 YOLOv8n 轻量化景区行人检测方法研究[J]. 计算机工程与应用, 2025, 61(2): 84-96.

ZHANG X Y, WANG M. Research on improved YOLOv8n light-weight pedestrian detection method in scenic spots [J]. Computer Engineering and Applications, 2025, 61(2): 84-96.

- [11] ZHOU L, YANG SH, WANG CH, et al. QCF-YOLO: A lightweight model of surface defect detection for quick-connect fittings[J]. IEEE Sensors Journal, 2025, 25(1): 1716-1731.

- [12] 古佳欣, 陈高华, 张春美. YOLOv8-DEL: 基于改进 YOLOv8n 的实时车辆检测算法研究[J]. 计算机工程与应用, 2025, 61(1): 142-152.

GU J X, CHEN G H, ZHANG CH M. YOLOv8-DEL: Research on real-time vehicle detection algorithm based on improved YOLOv8n [J]. Computer Engineering and Applications, 2025, 61(1): 142-152.

- [13] XU Y F, XUE X R, LI CH L, et al. RLE-YOLO: A

- lightweight and multiscale SAR ship detection based on improved YOLOv8[J]. IEEE Access, 2025, 13: 46584-46600.
- [14] 刚帅, 刘培胜, 郭希旺. 改进基于 YOLOv8n 的轻量化钢材表面缺陷检测算法[J]. 电子测量技术, 2025, 48(3): 74-82.
- GANG SH, LIU P SH, GUO X W. Lightweight improved YOLOv8n model for steel defect detection features [J]. Electronic Measurement Technology, 2025, 48(3): 74-82.
- [15] LI Y T, FAN Q S, HUANG H S, et al. A modified YOLOv8 detection network for UAV aerial image recognition[J]. Drones, 2023, 7(5), DOI: 10.3390/drones7050304.
- [16] 李云文, 冯宇平, 安文志, 等. 基于改进 YOLOv8 的无人机图像小目标检测算法[J]. 高技术通讯, 2024, 34(7): 765-775.
- LI Y W, FENG Y P, AN W ZH, et al. Small object detection algorithm for unmanned aerial vehicle image based on improved YOLOv8 [J]. Chinese High Technology Letters, 2024, 34(7): 765-775.
- [17] ZHANG L J, FANG J J, LIU Y X, et al. CR-YOLOv8: Multiscale object detection in traffic sign images[J]. IEEE Access, 2024, 12: 219-228.
- [18] DING X, ZHANG X, MA N, et al. RepVGG: Making VGG style convnets great again [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13733-13742.
- [19] 王海群, 王炳楠, 葛超. 重参数化 YOLOv8 路面病害检测算法[J]. 计算机工程与应用, 2024, 60(5): 191-199.
- WANG H Q, WANG B N, GE CH. Re-parameterized YOLOv8 pavement disease detection algorithm[J]. Computer Engineering and Applications, 2024, 60(5): 191-199.
- [20] HAN K, WANG Y, TIAN Q, et al. GhostNet: More features from cheap operations[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, 2020: 1580-1589.
- [21] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10781-10790.
- [22] CHEN Z X, HE Z W, LU ZH M. DEA-Net: Single image dehazing based on detail-enhanced convolution and content-guided attention[J]. IEEE Transactions on Image Processing, 2024, 33: 1002-1015.
- [23] WU Y X, HE K M. Group normalization[J]. Arxiv Preprint. arXiv: 1803.08494, 2018.
- [24] 艾峰, 邓耀华. 用于缺陷检测的 YOLOv8 轻量化设计方法[J]. 电子测量技术, 2025, 48(4): 181-190.
- AI F, DENG Y H. YOLOv8 lightweight design approach for defect detection [J]. Electronic Measurement Technology, 2025, 48(4): 181-190.
- [25] 郝友胜, 文贞慧, 冯小溪, 等. 基于改进 YOLOv8 的车辆漆面缺陷检测[J/OL]. 计算机工程, 1-10 [2025-04-10]. <https://doi.org/10.19678/j.issn.1000-3428.0070032>.
- HAO Y SH, WEN ZH H, FENG X X, et al. Vehicle paint defect detection based on improved YOLOv8[J/OL]. Computer Engineering, 1-10 [2025-04-10]. <https://doi.org/10.19678/j.issn.1000-3428.0070032>.
- [26] GUO J B, WANG SH H, CHEN X H, et al. QL-YOLOv8s: Precisely optimized lightweight YOLOv8 pavement disease detection model[J]. IEEE Access, 2024, 12: 128392-128403.
- [27] GIRSHICK R. Fast R-CNN[C]. IEEE international conference on computer vision, Santiago, Chile: 2015 IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [28] WANG CH Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for realtime object detectors[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.
- [29] WANG CH Y, YEH I H, MARK LIAO H Y. YOLOv9: Learning what you want to learn using programmable gradient information [C]. European Conference on Computer Vision. Springer, Cham, 2025: 1-21.
- [30] WANG AO, CHEN H, LIU L, et al. YOLOv10: Real-time end-to-end object detection [J]. Arxiv preprint arXiv:2405.14458, 2024.
- [31] KHANAM R, HUSSAIN M. YOLOv11: An overview of the key architectural enhancements[J]. Arxiv preprint arXiv: 2410.17725, 2024.
- [32] ADITYA C, ANIRBAN S, PRANTIK H, et al. Grad-CAM + +: Generalized gradient-based visual explanations for deep convolutional networks [C]. 2018 IEEE Winter Conference on Applications of Computer Vision(WACV), 2018: 839-847.

作者简介

张书朝, 硕士研究生, 主要研究方向为故障检测及计算机视觉。

E-mail: zsz@stu.hebust.edu.cn

彭立强(通信作者), 博士, 讲师, 研究方向轨道车辆智能运维与控制研究。

E-mail: lq201600@163.com

郭阿康, 硕士研究生, 主要研究方向为计算机视觉及目标检测。

E-mail: 1225873138@qq.com

王立新, 教授, 主要研究方向为机器视觉。

E-mail: wanglx@hebust.edu.cn