

基于 AMCF-YOLO 算法的腕臂绝缘子表面缺陷检测

董海燕¹, 韩政龙¹, 窦建明^{2†}, 何晓敏³, 苏堃⁴

(1. 兰州交通大学 自动化与电气工程学院, 甘肃 兰州 730070;

2. 兰州交通大学 机电工程学院, 甘肃 兰州 730070;

3. 甘肃省计量研究院, 甘肃 兰州 730050;

4. 中国铁路乌鲁木齐局集团有限公司供电部, 新疆维吾尔自治区 乌鲁木齐 830001)

摘 要:接触网绝缘子表面缺陷检测对于保证牵引供电系统安全运行意义重大, 铁路 4C 巡检车采集的绝缘子图像存在缺陷边缘特征微弱、尺度差异显著、环境噪声大等问题, 智能检测方法的准确性和稳定性仍有待提高. 为此, 提出了一种自适应多尺度校准融合(adaptive multi-scale calibration fusion, AMCF)YOLO 的腕臂绝缘子表面缺陷检测算法. 该算法采取针对性的特征强化、特征融合及回归优化措施, 通过设计层级特征协同金字塔网络改善模型层级之间特征融合不充分的问题; 利用融入可形变注意力机制的 P5 层特征提取模块, 结合具备边缘增强分支的轻量级下采样, 在减少算法参数数量的同时强化缺陷关键信息保留; 引入增强型损失函数强化对中等质量预测框的回归约束, 提升模型定位精度. 对比实验表明, AMCF-YOLO 参数量仅 4.2 M, mAP₅₀ 达到了 93.4%, mAP₅₀₋₉₅ 为 60.1%, 相较于基准模型 YOLOv11n 分别提升了 3.3、5.6 个百分点; 三个公共数据集上的泛化能力实验验证了所提模型的有效性和稳定性; 开发的绝缘子表面多缺陷检测系统部署在边缘设备上, 测试结果显示所提模型检测精度稳定, 且检测帧率达到了 65 frame/s, 满足现场实时检测要求.

关键词:绝缘子; 缺陷检测; AMCF-YOLO; 检测精度; 轻量级; 边缘部署

中图分类号:U225.4+3

文献标志码:A

Cantilever insulator surface defect detection based on AMCF-YOLO algorithm

DONG Haiyan¹, HAN Zhenglong¹, DOU Jianming^{2†}, HE Xiaomin³, SU Kun⁴

(1. School of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China;

2. School of Mechanical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China;

3. Gansu Metrology Institute, Lanzhou 730050, China;

4. Section of Urumqi Power Supply, China Railway Urumqi Group Co., Ltd., Urumqi 830001, China)

Abstract: Catenary insulator surface defect detection is of great significance to ensure the safe operation of the

* 收稿日期:2025-12-17

基金项目:国家自然科学基金资助项目(51567014), National Natural Science Foundation of China(51567014); 甘肃省自然科学基金资助项目(24JRRA1175), Natural Science Foundation of Gansu Province(24JRRA1175); 甘肃省青年科技基金资助项目(20JR5RA382), Scientific Foundation for Young Scholars of Gansu Province(20JR5RA382); 甘肃省计量研究院科技计划资助项目(GJY2024002), Science and Technology Foundation of Measurement Institute of Gansu Province(GJY2024002)

作者简介:董海燕(1987—), 女, 甘肃和政人, 兰州交通大学副教授, 博士

† 通信联系人, E-mail: lgy_116@163.com

traction power supply system. The insulator images collected by the railway 4C inspection vehicle have problems such as weak edge features, significant scale differences, and high environmental noise, and the accuracy and stability of the intelligent detection method still need improvement. Therefore, an adaptive multi-scale calibration fusion (AMCF) YOLO algorithm for surface defect detection of a cantilever insulator is proposed. The algorithm adopts targeted feature enhancement, feature fusion, and regression optimization measures, and the problem of insufficient feature fusion between model levels is improved by designing a hierarchical feature coordination pyramid network. The P5 layer feature integrated with the deformable attention mechanism is used for module extraction, and combined with lightweight down-sampling with edge-enhanced branches, the number of algorithm parameters is reduced, while key defect information is retained. The enhanced loss function is introduced to strengthen the regression constraint on the medium quality prediction box and improve the positioning accuracy of the model. Comparative experiments show that the AMCF-YOLO parameter is only 4.2 M, the mAP_{50} reaches 93.4%, and the mAP_{50-95} is 60.1%, which are 3.3 and 5.6 percentage points higher than the benchmark model YOLOv11n, respectively. The generalization ability experiments on three public datasets verify the effectiveness and stability of the proposed model. The developed insulator surface multi-defect detection system is deployed on edge devices. The test results show that the detection accuracy of the proposed model is stable, and the detection frame rate reaches 65 frame/s, which meets the requirements of real-time detection on-site.

Key words: insulator; defect detection; AMCF-YOLO; detection accuracy; lightweight; edge deployment

接触网腕臂绝缘子具有机械支撑和电气绝缘的双重作用,其绝缘性能直接影响电气化铁路供电的可靠性与安全性.由于腕臂绝缘子长期暴露在复杂环境中,其表面受到持续机械振动、电气应力及环境侵蚀等多因素耦合作用,易产生裂纹、破损等缺陷^[1-2],若未及时发现,缺陷可能扩展进而导致绝缘失效,引发短路故障,造成大面积停电事故,严重威胁供电安全^[3-5].因此,开发实时、精准监测腕臂绝缘子表面状态的智能系统,实现缺陷的早期识别与预警,对保障牵引供电系统的可靠性意义重大.

现场工作中通常使用4C巡检车在夜间列车停运的“天窗”期采集接触网图像,再通过人工观察的方式判别绝缘子状态,但拍摄的灰度图像区分度低、环境噪声大、各类缺陷尺度差距明显,如图1所示,加之工作人员的经验水平、注意力集中程度等主观因素制约,故障筛查漏检风险高、工作强度大,难以满足高效、精准的故障检测需求.

随着计算机与图像处理技术的迅猛发展,绝缘子缺陷检测主要采用两种方法^[6-7],其一是数字图像处理技术与目标检测算法相结合的方法,其二是基于深度学习的目标检测方法.早期研究主要是基于图像处理和机器学习的技术^[8-10],大多通过人工提取特征来区分正常与故障绝缘子,该方法存在检测精




图1 4C巡检车采集的接触网缺陷图像

Fig.1 Defect images of the contact network collected by the 4C inspection vehicle

度低、工作强度大、分类识别准确性不高等问题.基于深度学习的缺陷识别技术具有明显的优势^[11].学者通过优化网络结构或采用特征提取与融合技术捕捉缺陷绝缘子的细节和特征,从而提高检测精度^[12].TAN等^[13]构建了Mask R-CNN模型,运用特征融合聚类方法计算其相邻片之间的特征分布差异以分析模型检测绝缘子缺陷,精确率达到92.5%;WEN等^[14]以航拍绝缘子图像为研究对象,提出了基于Faster R-CNN的深度学习方法,利用编解码器模板提取网络生成绝缘子模板图像,再使用精确R-CNN来检测绝缘子缺陷,使平均准确度提升了4.2%;李鑫等^[15]针对巡检图像中小目标检测和正负样本不平衡等问题,通过优化特征提取网络,设计了一种Cas-

cade R-CNN 的输电线路多目标检测方法, 其 mAP_{50} 达到了 94.1%。上述研究提高了检测精度, 与此同时, 复杂的模型结构、较高的参数量和计算量, 会降低训练速度和检测效率。

为此, 推理速度更快的单阶段检测算法逐渐受到关注。唐炳南等^[16]改进了 YOLOv10 缺陷检测模型, 采用多尺度通道信息提取模块和全局到局部注意力模块来提高缺陷检测精度, 检测速度达到 93.2 frame/s; 宋智伟等^[17]通过引入 Efficient-IoU-Loss 重点关注高质量的锚框, 相较于原始模型 mAP_{50} 领先 1.1%, 但检测帧率仅为 44 frame/s, 不利于部署在算力较低的边端智能检测设备上; 李斌等^[18]基于 SSD 网络提出通过残差注意力网络提取不同分辨率的特征, 从而提升目标分类与位置回归的效果; 杨茜等^[19]通过采用可逆列网络作为骨干网络和上下文引导网络来减少模型参数和降低计算复杂度, 平均精度达到 91%, 参数量为 2.1×10^6 ; 姜香菊等^[20]提出了一种基于轻量级注意力的尺度内特征交互模块的 RT-DETR 绝缘子缺陷检测算法, 结合迁移学习技术, 使得检测速度提升 2.5 倍。以上方法采取了卓有成效的轻量化措施, 可为本文的研究提供借鉴。

考虑到铁路运输对安全性、可靠性的严苛要求, 现有的缺陷识别方法在准确性和时效性上仍不满足

要求, 本文针对 4C 系统采集的绝缘子灰度图像存在缺陷边缘特征微弱、尺度差异显著、环境噪声大等问题, 提出一种自适应多尺度校准融合的腕臂绝缘子表面缺陷检测算法 AMCF-YOLO, 该算法采取针对性的特征强化、特征融合及回归优化措施, 在保证轻量化的同时提高模型检测精度, 并在自建数据集、公共数据集和边缘部署设备上分别验证模型的泛化能力和实用性。

1 AMCF-YOLO 检测方法

AMCF-YOLO 算法框架如图 2 所示。该方法基于 YOLOv11n 模型架构, 在主干网络上加入可形变注意力特征增强模块 (CSP bottleneck with kernel-2 convolutions_ deformable attention, C3K2_DAttention) 和自适应下采样模块 (adaptive downsampling_v2, ADown_v2) 以强化微弱缺陷特征; 颈部网络设计了层级特征协同金字塔网络 (hierarchical feature coordination pyramid network, HFC-PNet) 以增强特征融合能力; 头部网络采用增强型损失函数 (powerful IoU_v2, PIoU_v2) 实施回归优化。各模块围绕特征信息的完整传递与有效利用形成统一协同框架, 其主要功能如下:




图 2 AMCF-YOLO 网络结构

Fig.2 Network structure of AMCF-YOLO

1) 特征强化: 可形变注意力特征增强模块 C3K2_DAttention 与自适应下采样模块 ADown_v2 被引入主干网络。前者通过在 P5 深层语义特征中融合可形变注意力机制, 引导模型聚焦于缺陷相关区域; 后者在下采样阶段引入边缘增强分支, 在降低计算开销的同时保留更多缺陷特征细节信息。

2) 特征融合: 层级特征协同金字塔网络 HFC-PNet, 在水平和垂直方向上捕获全局上下文, 使模

型兼顾底层细节信息和深层语义信息, 以提高模型的多层级特征表示能力, 缓解因对比度不足导致的层级间特征弱关联的问题。

3) 回归优化: 增强型损失函数 PIoU_v2 应用于头部网络, 以尺寸自适应惩罚与锚框梯度优化实现精准定位, 增强对中等质量锚框的聚焦能力。

主干网络通过 ADown_v2 模块在控制模型复杂度的同时为深层保留更多细节, C3K2_DAttention 则

作用于深层特征层 P5, 在高层语义空间中强化缺陷特征, 减少背景信息的冗余干扰, 使特征表达更加聚焦于缺陷区域, 为后续 HFC-PNet 提供更丰富的高层语义信息; 颈部 HFC-PNet 对上述不同层级特征进行统一对齐与融合, 将深层语义与浅层细节有效整合, 形成层级关联性更强的多尺度特征表达, 为检测头提供一致且具有判别性的多尺度特征; 在此基础上, PLoU_v2 在训练优化层面引导网络, 在回归阶段充分利用上述结构层面形成的特征优势, 使整体特征表达能力能够稳定地转化为定位精度的提升。

1.1 层级特征协同金字塔网络 HFC-PNet

在目标检测领域, 特征金字塔网络 (feature pyramid network, FPN) 构建自上而下的传播机制使高层特征图经过多次下采样后, 空间分辨率降至输入图像的 1/32, 导致深层特征的语义表达有限, 小目标检测时易发生误检与漏检, 同时大量无关冗余

会拖慢推理速度。

针对上述局限, 本文提出了一种层级特征协同金字塔网络 HFC-PNet, 整体结构如图 3 所示, 层级上下文聚合模块 (hierarchical context aggregation, HCA) 在统一空间尺度上对 P3、P4、P5 特征完成对齐与全局上下文压缩, 并通过层级卷积实现通道维度的非线性映射与注意力增强, 同时采用矩形自校准模块 (rectangular self-calibration module, RCM) 在水平与垂直感受野内协同校准空间与通道信息, 突出关键特征; 残差校准块 (residual calibration block, RCB) 与多阶段加权校准块 (multi-stage calibration block, MSCB) 分别通过残差连接和分阶段加权策略对特征进行增强与互补融合, 多级门控融合 (multi-level gated fuse, MLG-Fuse) 与插值注意力融合 (interpolated attention fuse, IAF) 通过门控与插值操作自适应地汇聚低级细节与高级语义, 为检测头提供兼具全局语义与局部结构的高质量多尺度特征。




图 3 HFC-PNet 网络结构

Fig.3 Network structure of HFC-PNet

1.1.1 层级上下文聚合 (HCA) 模块

特征金字塔中多层次输入特征列表, HCA 模块实现了从金字塔池化到多级自校准再到动态输出映射的全流程上下文信息提取, 该模块以最高层特征 $X_i \in \mathbf{R}^{B \times C_k \times H_k \times W_k}$ 为基准, 依据预设下采样率 S 计算对齐空间尺寸, 并对每一级特征执行自适应平均池化 $\text{Pool}(X_i; (H', W'))$, 如式 (1)、式 (2) 所示, 将所有尺度在通道维度拼接得到融合张量, 利用矩形自校准和空间注意力深度提取拼接特征中的长条形和局部上下文信息, 输出若干待融合特征, 且引入可学

习权重向量, 并经批量归一化与 SiLU 激活后, 对所有阶段的输出加权求和, 得到融合特征, 输出与原始尺度和通道对齐的多尺度特征图。

$$H' = \left\lceil \frac{H_k - 1}{S} \right\rceil + 1 \quad (1)$$

$$W' = \left\lceil \frac{W_k - 1}{S} \right\rceil + 1 \quad (2)$$

式中: H_k 为高度; W_k 为宽度; H' , W' 分别为自适应平均池化后得到的目标高度和宽度; S 为预设下采样率。

从“统一池化—多级自校准—动态加权—按需投

影”的流程形成一体化闭环,不仅兼顾跨层级的全局上下文,还保证了输出特征与检测任务头部的通道对齐需求。

1.1.2 矩形自校准模块(RCM)

矩形自校准模块由矩形自校准注意力(rectangular self-calibration attention, RCA)、批处理归一化(batch normalization, BN)和多层感知机(multi-layer perceptron, MLP)有机结合的残差式混合块构成。在保留卷积局部感知优势的同时,通过层级缩放与随机路径丢弃实现稳定而高效的深层特征融合。RCA通过长条形方向汇聚与深度可分离卷积,在通道和空间两个维度对特征图进行精细重标定,为了稳定

分布,对输入特征批量归一化,分别采用横向与纵向可学习条形卷积核获得行向和列向全局描述向量,双向一维特征经加权融合后形成具有矩形感受野的全局特征,如图4所示,形状被两个不同权重的条形卷积改变,能有效捕捉目标在不同空间维度的分布,形状自校准函数根据不同权重调整卷积区域以突出目标结构,其函数表达式为:

$$\xi_c(\bar{y}) = \delta(\psi_{k \times 1}(\phi(\psi_{1 \times k}(\bar{y})))) \quad (3)$$

式中: $\xi_c(\cdot)$ 表示由大核条形卷积构成的特征映射函数; $\bar{y}$ 表示输入特征图; $\psi_{n \times m}(\cdot)$ 表示核尺寸为 $n \times m$ 的卷积算子; $\phi(\cdot)$ 表示经批次归一化和SiLU激活后的映射函数; $\delta(\cdot)$ 表示Sigmoid函数。




图4 RCA引起的高亮区域的形状变化

Fig.4 Shape changes of highlighted regions caused by RCA

通道注意力分支对融合特征施加两层逐点卷积、批量归一化及SiLU激活,并经Sigmoid生成通道注意力图以调制各通道响应;空间注意力分支则通过平均池化与最大池化拼接、大核卷积及Sigmoid激活生成空间注意力图,对每个空间位置加权。最后,注意力特征与原始输入通过融合函数进一步提炼局部细节,其具体形式如下:

$$\xi_f(\mathbf{x}, \mathbf{y}) = \psi_{3 \times 3}(\mathbf{x}) \odot \mathbf{y} \quad (4)$$

式中: $\xi_f(\cdot)$ 表示融合映射函数; $\psi_{3 \times 3}(\cdot)$ 表示核为 3×3 的深度可分离卷积算子; $\mathbf{x}$ 为当前层的输入特征图; $\mathbf{y}$ 为上一步得到的注意力特征; $\odot$ 表示Hadamard积。

1.1.3 多级门控融合(MLG-Fuse)模块

绝缘子缺陷检测中,特征融合模块对增强模型的多尺度感知能力和鲁棒性至关重要。在MLG-Fuse模块中,输入的低层特征分支通过标准卷积与归一化保留空间细节,高层语义分支经过卷积与归一化后通过双线性插值对齐空间分辨率,生成自适应门控权重图,该机制依据空间位置响应动态调节信息流,抑制冗余或无效特征并强化关键区域表示。在特征融合阶段,将低级特征与门控权重逐元素相乘,实现对特征内容的动态筛选,融合结果通过增强分支进一步丰富特征表达,该分支在保持计算效率的前提下提升特征的多样性和判别性;可学习缩

放参数加权求和使融合输出与增强特征适应不同场景的特征分布变化。模块输出经归一化后与原始低级特征残差连接,以缓解深层网络梯度消失并促进特征高效流动与信息保留。

1.1.4 插值注意力融合(IAF)模块

IAF模块是一种面向高分辨率与低分辨率特征的轻量级多尺度融合策略,通过插值对齐、卷积映射、自适应加权与信息扩散等一系列操作,实现空间细节与语义信息的高效交互与鲁棒整合。IAF模块在HFC-PNet中以双线性插值对深层网络输出的低分辨率特征图进行空间尺度对齐,使其与浅层高分辨率特征在通道和空间上保持一致。融合张量由对齐后的高低分辨率特征逐元素相加得到,并在细节增强支路中,借助批量归一化与SiLU激活提取局部纹理补偿信息。细节增强分支的输出经由通道注意力机制调制,再结合可学习标量 γ 对增强特征进行加权扩散至融合主干。

HFC-PNet从特征对齐与信息交互的角度重构了多尺度特征融合流程,通过HCA、RCM、MLG-Fuse、IAF建立了不同尺度特征之间的强关联。该结构避免了传统特征金字塔中因简单叠加而引入的语义不一致问题,使浅层空间细节与深层语义信息在融合过程中实现协同增强,从而在复杂尺度变化条

件下保持特征表达的稳定性。

1.2 可形变注意力特征增强(C3K2_DAttention)模块

HFC-PNet 在特征融合层面实现了不同尺度信息的对齐与整合,但其效果仍依赖于输入特征对缺陷区域的响应聚焦程度^[21]。为进一步增强深层特征对缺陷区域的表达能力,本文在主干网络深层引入

C3K2_DAttention 模块,对深层语义信息进行针对性强化。该模块是在 P5 层 C3K2 模块中引入能实现空间自适应的可形变注意力机制^[22],以充分利用全局信息且具有较低计算开销,使模型动态聚焦缺陷区域并抑制背景干扰,从而增强对微小结构的特征表达能力,可形变注意力网络结构如图 5 所示。




图 5 可形变注意力网络结构

Fig.5 Network structure of deformable attention

给定输入特征图 $x \in \mathbb{R}^{H \times W \times C}$, 构建一个统一网格 $p \in \mathbb{R}^{H_c \times W_c \times 2}$ 作为参考, 其空间分辨率由下采样因子 r 决定, 即 $H_c = H/r$, $W_c = W/r$ 。该网格的坐标范围被归一化到 $[-1, +1]$ 区间, 其中左上角对应 $(-1, -1)$, 右下角对应 $(+1, +1)$ 。

为了获取每个参考点的偏移量, 将输入特征图通过线性投影变换生成查询向量 $q = xW_q$, 并送入一个轻量化网络 $\theta_{\text{offset}}(\cdot)$ 以预测偏移量 $\Delta p = \theta_{\text{offset}}(q)$ 。在变形点的空间位置 $p + \Delta p$ 处对特征进行采样, 作为键和值, 其投影表示为:

$$q = xW_q, \tilde{k} = \tilde{x}W_k, \tilde{v} = \tilde{x}W_v \quad (5)$$

$$\Delta p = \theta_{\text{offset}}(q), \tilde{x} = S(x; p + \Delta p) \quad (6)$$

式中: $\tilde{k}$ 和 $\tilde{v}$ 分别表示形变后的键与值嵌入。将采样函数 $S(\cdot)$ 使用可微的双线性插值策略, 具体数学表达式为:

$$S = (z; (p_x, p_y)) = \sum_{(r_x, r_y)} g(p_x, r_x)g(p_y, r_y)z[r_y, r_x, :] \quad (7)$$

式中: $g(a, b) = \max(0, 1 - |a - b|)$; “:” 表示索引 (r_x, r_y) 遍历特征图 $z \in \mathbb{R}^{H \times W \times C}$ 的所有位置。由于 g 仅在 (p_x, p_y) 最近的四个整数坐标处非零, 所以可简化为这四个位置上的加权平均。对查询 q 、键 k 、值 v 实施多头注意力机制 m , 并引入相对位置偏移 R 。每个注意力头的输出表示为:

$$z^{(m)} = \text{Softmax}(q^{(m)}\tilde{k}^{(m)T} / \sqrt{d} + B_R^{(m)})\tilde{v}^{(m)} \quad (8)$$

式中: $\text{Softmax}(\cdot)$ 表示对注意力头进行归一化处理; d 表示单个注意力头的通道维度; B_R 表示可学习的相对位置偏移矩阵, 将所有注意力头的输出拼接后, 通过投影矩阵 W_o 融合, 得到最终输出特征融合图 z 。该设计有效提升了在空间变换下模型的鲁棒性与特征表达能力, 适用于复杂场景下目标检测任务。

可形变注意力特征增强模块 C3K2_DAttention 结构设计如图 6 所示, 模块实现了多尺度特征对齐的优化处理, 以生成偏移向量构建动态注意力映射, 突破传统固定感受野的限制, 使特征响应分布具备自适应调整机制。此方式一方面采用动态聚焦机制实现对细长裂纹等关键特征信息的精准定位, 另一方面借助参数化偏移量控制实现计算资源的智能分配, 从而在保证检测精度的同时有效降低冗余计算成本。

1.3 改进的轻量化下采样(ADown_v2)

传统卷积下采样参数量大且会对特征进行均匀压缩, 多次下采样后容易破坏高、低层有效特征信息。为此, 设计 ADown_v2 轻量化下采样模块, 在实现参数压缩的同时引入边缘增强分支, 以提升多次下采样后的信息保留能力, 其结构如图 7 所示。

ADown_v2 模块对输入特征图进行平均池化以实现初步的空间采样, 在通道维度上将特征分为两组。第一组特征直接通过 3×3 卷积进行空间特征提取和降采样; 第二组先经过最大池化以突出主干




图6 C3K2_DAttention网络结构

Fig.6 Network structure of C3K2_DAttention




图7 轻量化下采样 ADown_v2

Fig.7 Lightweight downsampling ADown_v2

信息,再通过 1×1 卷积实现特征变换;最后将两组特征在通道维度拼接,形成融合后的输出.此外,ADown_v2模块引入边缘增强分支,通过可学习参数 γ 自适应调整增强强度,从而进一步提升对边缘和裂纹等微小目标的感知能力,其输出定义为:

$$Y = X + \gamma \cdot \varepsilon(X) \quad (9)$$

式中: X 为输入特征图; Y 为输出特征图; $\varepsilon(\cdot)$ 表示深度可分离卷积的边缘增强算子; γ 为可学习的标量参数. γ 初始化为0,使模型在训练初期保持原始特征传递,避免额外结构对特征分布造成扰动;后续 γ 通过反向传播损失函数 L 自适应更新.其梯度由式(10)决定,从而实现对边缘增强分支的动态调节.

$$\frac{\partial L}{\partial \gamma} = \sum_i \frac{\partial L}{\partial Y_i} \cdot \varepsilon(X)_i \quad (10)$$

这种分支结构丰富了下采样阶段特征的组合与交互方式,使不同尺度信息在特征压缩过程中得以协同保留.通过对主干信息与边缘增强的联合,

ADown_v2在降低参数数量的同时维持了多尺度上下文信息的连续性,从而降低了多次下采样导致特征丢失的风险.

1.4 增强型损失函数(PIoU_v2)

增强型损失函数PIoU_v2^[23]通过量化锚框与目标框间的质量差异,构建动态梯度调节机制,使特征回归路径具备方向性优化能力,从而更加适应非规则形态缺陷的检测需求.该函数通过引入抗干扰机制,在复杂场景中增强边界匹配的鲁棒性,有效提升检测系统的稳定性,数学表达式见式(11)~式(13):

$$P = \left(\frac{d_{w1}}{w_{gt}} + \frac{d_{w2}}{w_{gt}} + \frac{d_{h1}}{h_{gt}} + \frac{d_{h2}}{h_{gt}} \right) / 4 \quad (11)$$

式中: d_{w1} 、 d_{w2} 、 d_{h1} 、 d_{h2} 为预测框对应边缘与目标框距离的绝对值; w_{gt} 和 h_{gt} 分别为目标框的宽度、高度.将注意力函数和PIoU_v2损失定义为:

$$q = e^{-P}, q \in (0, 1] \quad (12)$$

$$L_{PIoU_v2} = u(\lambda q) \cdot L_{PIoU} = 3 \cdot (\lambda q) \cdot e^{-(\lambda q)^2} \cdot L_{PIoU} \quad (13)$$

式中: e 为欧拉数,约为2.718; $u(\lambda q)$ 代表注意力函数, λ 是控制注意力函数行为的超参数,用衡量锚点框质量的 q 来代替惩罚因子 P .其中 $q=1$ 时实现检测框与真值框的零误差匹配.随着 P 增大, q 逐渐减小,表示锚点质量较低.

2 实验设置

2.1 自建数据集

数据集来源于某铁路部门4C系统中接触网作业车上工业相机获取的接触网悬挂系统的图像,通过截取4C图像集中的1 000张腕臂绝缘子图作为数据集,涵盖陶瓷和复合材料2种材质的绝缘子,以及5种绝缘子缺陷类型,包括鸟啄破损(broken, B)、

伞裙脆断(shed brittle fracture, SBF)、裂纹(crevice, C)、异物附着(foreign plastic debris, FPD)、鸟粪(avian excretion, AE),如图 8 所示,并根据 7:3 的比例将图像随机划分为训练集、测试集.




图 8 典型缺陷样本集
Fig.8 A sample set of typical defects

2.2 公共数据集

选取 CPLID(China power line insulator dataset)^[24]、IDID(insulator defect image dataset)^[25]和 SVRDD(surface vehicular road damage dataset)^[26]作为公共数据集用于评估模型的泛化能力. CPLID 与 IDID 数据集均为公开的输电线路绝缘子缺陷检测数据集, CPLID 数据集共包含 1 942 张图像, IDID 数据集共包含 1 440 张图像, 检测对象均为输电线路绝缘子, 包含掉串(string dropping)、破损(broken)、闪络(pollution-flashover) 3 种绝缘子表面缺陷类型. SVRDD 数据集为公开的道路病害检测数据集, 图像来源于街景采集系统, 共包含 8 000 张图像. 检测对象为路面病害, 主要包括纵向裂缝(longitudinal crack)、横向裂缝(transverse crack)、坑槽(pothole)、井盖(manhole cover)、龟裂(alligator crack)、横向修补(transverse patch)及纵向修补(longitudinal patch)7 种缺陷类型.

2.3 实验环境及参数设计

为了实现模型训练和性能评价, 采用高性能计算机, 其软硬件配置如表 1 所示, 设置训练轮次 epoch=500, 批量 batch=16, 网络初始学习率为 0.01, 采用随机梯度下降法(stochastic gradient descent, SGD)更新网络参数, 训练阶段采用 Mosaic 数据增强策略, 通过随机拼接多幅图像并结合缩放、裁剪与位置扰动, 在不改变缺陷语义的前提下有效扩展了样本的尺度变化与空间分布, 输入图片的尺寸统一缩放为 640×640.

2.4 评价指标

2.4.1 检测精度评价指标

以精确率、召回率、平均精度均值为绝缘子缺陷

表 1 实验运行环境配置
Tab.1 Configuration of experimental operating environment

配置名称	版本参数
操作系统	Windows10, 64 位操作系统
CPU	12th Gen Intel(R) Core(TM) i7-12700KF 3.60 GHz
GPU	NVIDIA GeForce RTX 4090
CUDA	V12.3
cuDNN	V9.4

模型检测精度的评价指标, 上述指标的数值越大表示检测的准确度越高, 检测效果越好.

精确率 P (precision)表示预测为正样本中实际为正样本的比例, 计算式为:

$$P = \frac{T_p}{T_p + F_p}$$
 (14)

召回率 R (recall)表示实际正样本中被正确预测出来的比例, 计算式为:

$$R = \frac{T_p}{T_p + F_n}$$
 (15)

式中: T_p (true positive)为模型正确预测的正样本; F_p (false positive)为模型错误预测为正样本的负样本; F_n (false negative)为实际为正样本但被模型错误预测为负样本的样本.

平均精度 AP(average precision)指某一类别在不同召回率水平下的平均精确率, 平均精度均值 mAP(mean average precision)则是所有类别 AP 的平均值, 分别定义为:

$$AP = \int_0^1 PdR$$
 (16)

$$mAP = \frac{\sum_{i=1}^N AP}{N}$$
 (17)

2.4.2 检测效率评价指标

在模型性能评估中, 除检测精度之外, 还需从检测速度与模型轻量化程度两个维度对模型进行综合考量. 检测速度通常以每秒处理帧数(FPS)作为衡量指标, 该指标反映模型在单位时间内完成前向推理的能力, FPS 值越高表明模型具备更强的实时处理性能.

模型轻量化程度主要通过计算复杂度与参数规模进行度量. 其中 GFLOPs(giga floating point operations)表示模型一次前向传播所需执行的十亿次浮点运算次数, 用以刻画模型的计算复杂度, GFLOPs 值越大意味着模型结构越复杂、计算开销越高;模型

参数量(parameters)反映模型中可学习参数的规模,参数量越大意味着更高的存储需求与推理内存占用.模型大小(model size)从权重文件层面刻画模型的存储开销与部署难度,模型大小越小代表模型整体结构更加紧凑,对硬件资源的消耗越低,更适合在资源受限的边缘计算设备上部署与应用.

3 实验结果分析

3.1 消融实验

消融实验共配置八种不同方案,通过在YOLOv11n上逐次叠加优化模块,考察各模块对最终检测效果的影响,实验结果如表2所示.

相较于基准模型(方案1),方案2在颈部网络引

入HFC-PNet, mAP_{50-95} 提升4.6个百分点,表明多层次校准融合有效增强了特征一致性.方案3、4、5分别引入C3K2_DAttention、ADown_v2以及PIoU_v2,使精确率、召回率、平均精度均值稳定提升.方案6在方案2的基础上进一步叠加C3K2_DAttention,模型召回率提升至90.5%,说明注意力机制引导网络更聚焦于缺陷区域,降低漏检率.方案7将主干下采样替换为ADown_v2,在基本保持检测性能的同时,使参数量(Params)与GFLOPs较方案6分别下降约8.7%和8.2%,验证了轻量化下采样设计的有效性.方案8则为AMCF-YOLO,改进后的模型使 P 、 R 、 mAP_{50} 、 mAP_{50-95} 分别提升了2.8、4.6、3.3、5.6个百分点,模型参数量稍有增加,但整体增加幅度仅为1.6 M,对可部署性的影响微弱.

表2 消融实验

Tab.2 Ablation experiment

方案	HFC-PNet	C3K2_DAttention	ADown_v2	PIoU_v2	$P/\%$	$R/\%$	$mAP_{50}/\%$	$mAP_{50-95}/\%$	Params/M	GFLOPs/G
1	—	—	—	—	90.8	85.4	90.1	54.5	2.6	6.3
2	√	—	—	—	92.2	87.7	90.6	59.1	4.5	9.8
3	—	√	—	—	91.4	88.1	91.8	58.3	2.6	6.3
4	—	—	√	—	92.4	86.6	92.6	59.0	2.2	5.5
5	—	—	—	√	91.8	87.2	91.1	57.4	2.5	6.3
6	√	√	—	—	92.6	90.5	92.1	59.1	4.6	9.8
7	√	√	√	—	92.8	87.5	91.0	58.3	4.2	9.0
8	√	√	√	√	93.6	90.0	93.4	60.1	4.2	9.0

注: mAP_{50} 表示检测框与真实框之间的交并比(IoU)阈值设为0.5时的平均精度均值; mAP_{50-95} 表示在多个IoU阈值(从0.5起始,以0.05为间隔逐步递增至0.95)上的平均精度均值.

3.2 不同模型对比实验

为系统评估轻量级AMCF-YOLO算法中每个模块对模型参数的影响,分别将不同特征金字塔网络、注意力机制、下采样和损失函数逐步代入模型,在自建数据集上开展对比实验.另外,为评估所提模型的整体表现,选择YOLOv8n、v10n、v11n、v11s与v12n开展对比实验.

3.2.1 特征金字塔网络对模型性能的影响

为探究不同特征金字塔网络对模型检测性能的影响,实验选用GoldYOLO^[27]、BiFPN^[28]以及HFC-PNet三种特征金字塔网络替换YOLOv11中使用的金字塔网络进行检测,检测结果如表3所示.HFC-PNet在 mAP_{50} (90.6%)和 mAP_{50-95} (59.1%)上均优于GoldYOLO(90.2%/57.3%)和BiFPN(89.7%/57.6%),表明其多尺度特征自适应校准与融合机制对目标检测精度有显著促进作用.从计算复杂度与模型参数量来看,HFC-PNet的浮点运算量(GFLOPs)为9.8 G,

比GoldYOLO(9.2 G)多出0.6 G,虽较BiFPN(11.4 G)有所下降,却在实时推理中仍带来额外计算负担;其模型参数量为4.5 M,较GoldYOLO、BiFPN分别节省约23.7%、27.4%,降低了模型参数存储规模.

表3 不同特征金字塔网络下的检测结果

Tab.3 Detection results of different feature pyramid

networks					
特征金字塔网络	$mAP_{50}/\%$	$mAP_{50-95}/\%$	Params/M	GFLOPs/G	FPS/(frame·s ⁻¹)
GoldYOLO	90.2	57.3	5.9	9.2	87
BiFPN	89.7	57.6	6.2	11.4	100
HFC-PNet	90.6	59.1	4.5	9.8	105

3.2.2 注意力机制对模型性能的影响

为探究不同注意力机制对模型大小和检测性能的影响,在HFC-PNet的基础上分别将DAttention、EMA^[29]、SFA^[30]和TSSA^[31]注意力机制集成到C3K2模块中作为注意力机制模块进行对比测试.

检测结果如表 4 所示, C3K2_DAttention 的 mAP_{50} 、 mAP_{50-95} 分别为 92.1%、59.1%, 均为最优值, mAP_{50} 相较于 C3K2_EMA、C3K2_SFA、C3K2_TSSA 分别高 0.5、0.6、1.0 个百分点, mAP_{50-95} 比上述注意力机制分别高 1.8、1.0、1.7 个百分点, 但计算量略高于 C3K2_EMA. 在运算速度上 C3K2_DAttention 也具有明显优势, 具有最高的 FPS, 与 C3K2_EMA、C3K2_SFA、C3K2_TSSA 相比, FPS 分别提高 6%、11.8%、2%, 结果证明了 C3K2_DAttention 在提升检测精度的同时, 也保持了检测速度的领先.

通过可视化热力图量化不同注意力机制对缺陷位置的关注度, 颜色越深表示模型对该区域的注意力权重越高, 如图 9 所示. 结果显示 C3K2、C3K2_EMA、C3K2_SFA 和 C3K2_TSSA 对缺陷区域的注意力权重分布较为分散, 模型未能有效聚焦缺陷

表 4 不同注意力机制下的检测结果
Tab.4 Detection results of different attention mechanisms

注意力机制 模块	$mAP_{50}/\%$	$mAP_{50-95}/\%$	Params/ M	GFLOPs/ G	FPS/ (frame·s ⁻¹)
C3K2_EMA	91.6	57.3	4.6	9.7	98
C3K2_SFA	91.5	58.1	4.6	9.8	93
C3K2_TSSA	91.1	57.4	4.6	9.8	102
C3K2_ DAttention	92.1	59.1	4.6	9.8	104

位置, 导致缺陷检测精度较低; 引入 C3K2_DAttention 机制后, 注意力权重集中于缺陷本体, 表明 C3K2_DAttention 不仅有效改善了模型对缺陷区域的关注能力, 还在缺陷边缘及裂纹走向形成了连续且清晰的高权重区域, 表明该机制能够有效捕捉缺陷的几何轮廓与细粒度结构信息.




图 9 不同注意力机制特征可视化热力图

Fig.9 Visualization heatmap of different attention mechanism features

3.2.3 下采样模块对模型性能的影响

为评估 ADown_v2 下采样机制的实际效能, 本研究基于优化后的模型架构, 通过系统替换不同下采样方式进行对比分析. 将 ADown_v2、LDConv^[32]、SPDConv^[33]及 WaveletPool^[34]四种下采样模块分别集成至改进模型主干网络中除初始两层外的所有卷积层对应位置, 对比检测结果详见表 5. ADown_v2 下采样在 mAP_{50} 和 mAP_{50-95} 方面相较于 LDConv、SPDConv、WaveletPool 均具有显著优势, mAP_{50} 分别提高了 11.5、0.5、0.6 个百分点, mAP_{50-95} 分别提高了 14.0、0.4、0.2 个百分点, 同时模型参数量较 LDConv、SPDConv、WaveletPool 分别减少了 2%、30%、2%, 在检测速度方面, 均高于其他下采样模块, 适合在资源受限的环境中部署.

表 5 不同下采样模块的检测结果
Tab.5 Detection results of different downsampling modules

下采样 模块	$mAP_{50}/\%$	$mAP_{50-95}/\%$	Params/ M	GFLOPs/ G	FPS/ (frame·s ⁻¹)
LDConv	79.5	44.3	4.3	8.8	93.4
SPDConv	90.5	57.9	6.0	12.1	101
WaveletPool	90.4	58.1	4.3	8.7	99
ADown_v2	91.0	58.3	4.2	9.0	104

3.2.4 损失函数对模型性能的影响

在原始 YOLOv11 模型中, 边界框回归默认采用 CIoU 损失函数. 尽管其具备较强的拟合能力, 但在处理不规则目标时, 因对长宽比变化响应迟缓, 且中心点距离项对微小位移过于敏感, 易导致损失波动, 影响定位精度. 为提升回归性能, 本实验将 CIoU 替换为 PIoU_v2、PIoU、SIoU、GIoU 和 EIoU 五种

改进型IoU损失函数,通过对比分析各函数在训练过程中的收敛特性与稳定性,评估其对模型检测性能的影响,结果如图10所示.




图 10 不同损失函数收敛性
Fig.10 Convergence of different loss functions

PLoU_v2 曲线在整个训练过程中收敛速度最快,且最终损失值最低,表现出优异的稳定性和收敛性能.

3.2.5 不同目标检测算法对比

为了验证AMCF-YOLO模型在腕臂绝缘子缺陷检测方面的有效性,本文选择了YOLOv8n、YOLOv10n、YOLOv11n、YOLOv11s和YOLOv12n作为对比模型.

结果如表6所示,AMCF-YOLO在同量级模型中具有明显的综合优势.在检测准确率方面,mAP₅₀、mAP₅₀₋₉₅分别达到了93.4%,60.1%,表明AMCF-YOLO在不同的IoU阈值下都保持了出色的检测能力.AMCF-YOLO对伞裙脆断、裂纹缺陷类型的检测准确率分别达到了95.4%、77.2%,相较于基准模型,分别提升了4.6、3.5个百分点,表明该模型对多尺度、多形态绝缘子缺陷的识别能力增强.对比YOLOv11s,AMCF-YOLO的参数量为4.2 M,模型大小仅为8.4 MB,计算复杂度为9.0 G,推理速度达到104 frame/s,能够满足对腕臂绝缘子缺陷实时检测的要求.

综合考虑检测精度、参数规模、计算复杂度和推理速度,AMCF-YOLO在腕臂绝缘子缺陷检测中实现了准确性和效率的平衡.

表 6 主流目标检测算法比较
Tab.6 Comparison of mainstream object detection algorithms

算法	Params/M	Model Size/MB	GFLOPs/G	FPS/(frame·s ⁻¹)	mAP ₅₀ /%	mAP ₅₀₋₉₅ /%	AP/%				
							鸟啄破损	伞裙脆断	裂纹	异物附着	鸟粪
YOLOv8n	2.6	5.9	8.1	158	91.5	59.5	93.9	93.3	74.8	99.4	96.2
YOLOv10n	2.7	5.5	8.2	143	89.3	57.6	91.1	92.4	69.5	98.1	95.3
YOLOv11n	2.6	5.3	6.3	122	90.1	54.5	92.8	90.8	73.7	98.2	96.6
YOLOv11s	9.4	18.3	21.3	127	93.2	61.9	98.0	96.0	76.1	99.4	97.8
YOLOv12n	2.5	5.3	5.8	119	89.6	56.9	90.7	92.0	70.3	97.7	97.2
本文方法 (AMCF-YOLO)	4.2	8.4	9.0	104	93.4	60.1	97.1	95.4	77.2	99.5	97.9

3.2.6 缺陷误分类分析

采用归一化混淆矩阵分析所提模型对不同缺陷的识别情况,如图11所示,与YOLOv11n相比,AMCF-YOLO对鸟啄破损、伞裙脆断、裂纹、异物附着和鸟粪的正确识别能力均有所增强.而弱边缘缺陷裂纹在绝缘子表面分布具有分散性,且在实际采集过程中受拍摄角度影响,小伞裙边缘容易在大伞裙表面形成视觉叠加边界,从而增加裂纹与背景结构之间的混淆,导致YOLOv11n在该类缺陷上的识别稳定性较低.所提模型对裂纹的正确识别率由0.74提升至0.81,背景误判比例显著降低,同时有效抑制了不同缺陷类别间的误分类.

综上所述,AMCF-YOLO在整体架构层面实现了特征融合、特征强化与回归稳定性等关键过程的协同优化,有效增强了缺陷特征的显著性并抑制了背景冗余干扰,在复杂灰度背景下呈现了更加稳定的缺陷检测性能.

3.3 公共数据集对比

为了验证改进模型的泛化性与鲁棒性,在公共数据集CPLID、IDID及SVRDD上进行比较实验,实验过程都使用相同的分区策略进行训练,参数保持一致,结果分别如表7、表8所示.

从表7可知,在CPLID数据集上,AMCF-YOLO相较于基准模型,绝缘子串的平均精度均值提升了




图 11 归一化混淆矩阵

Fig.11 Normalized confusion matrix

表 7 CPLID 及 IDID 原模型和改进模型的 mAP_{50}

Tab.7 mAP_{50} of the original model and the improved model of CPLID and IDID %

标签	CPLID			IDID		
	YOLOv11n	YOLOv11s	AMCF-YOLO	YOLOv11n	YOLOv11s	AMCF-YOLO
绝缘子串	96.1	97.4	97.4	98.5	99.3	98.8
掉串	99.5	99.5	99.5	—	—	—
破损	—	—	—	95.3	96.4	96.7
闪络	—	—	—	94.8	95.7	95.6
平均	97.8	98.4	98.4	96.2	97.1	97.0

表 8 SVRDD 原模型和改进模型的 mAP_{50}

Tab.8 mAP_{50} of the original model and the improved model of SVRDD %

算法	龟裂	纵向裂缝	纵向修补	井盖	坑槽	横向裂缝	横向修补	平均
YOLOv11n	69.2	63.4	69.7	68.1	43.8	60.6	59.8	62.8
YOLOv11s	76.1	64.4	73.8	76.4	50.8	65.5	63.3	67.2
AMCF-YOLO	75.4	66.5	75.3	75.0	51.1	66.7	65.9	67.9

1.3个百分点. 在 IDID 数据集上, 对比 YOLOv11n 绝缘子串、破损和闪络的平均精度均值分别提升了 0.3、1.4 和 0.8 个百分点, 而绝缘子串和闪络的平均精度均值相较于 YOLOv11s 分别略低 0.5、0.1 个百分点, 但破损的平均精度均值高 0.3 个百分点.

此外, 为更直观地展示所提模型的检测性能, 在两个公共数据集上输出推理图像与基准模型进行对比, 可视化结果如图 12 所示. 在 CPLID 数据集中, 基准模型在部分样本中存在漏检与误检现象, 如图 12(a)和图 12(b)所示, 而 AMCF-YOLO 能够更准确地定位缺陷目标, 误检漏检情况明显减少. 在 IDID 数据集中, 基准模型在部分样本中也存在漏检与类别误判问题, 如图 12(c)(d)所示, 在图 12(d)中基准模型将落在绝缘子伞裙上的积雪误识别为破损. 从检测置信度的整体表现来看, AMCF-YOLO 相较两种基准模型具有更高且更稳定的预测置信度, 表明模

型对缺陷区域的判别能力得到了有效增强.

从表 8 可知, 在跨场景道路裂缝数据集 SVRDD 上, AMCF-YOLO 相较于基准模型, 整体检测性能由 62.8% 提升至 67.9%, 同时也优于 YOLOv11s 的 67.2%. 在纵向裂缝、坑槽及横向裂缝等以细小、低对比度裂缝为主的病害类别上, AMCF-YOLO 同样取得更优检测结果.

综合三个公共数据集的实验结果可知, 所提出的 AMCF-YOLO 在同类型绝缘子缺陷检测任务中表现出稳定且一致的性能优势, 同时在检测主体与成像场景发生显著变化的道路裂缝跨场景数据集上仍保持较高检测精度. 结果表明, 该模型并未依赖特定数据分布或应用场景, 其在多尺度特征融合与微弱缺陷表征方面具备良好的适应能力, 体现出 AMCF-YOLO 在不同数据集中具有良好的泛化性与鲁棒性.




图 12 CPLID 及 IDID 数据集模型可视化结果

Fig.12 Visualization results of the original model and improved model of CPLID and IDID public dataset

4 边缘设备部署测试

模型训练完成后，采用 NVIDIA Jetson Orin Nano 开发板作为绝缘子表面缺陷检测系统部署和测试的载体，测试场景如图 13 所示，系统由海康工业级 4K 摄影机[图 13(a)]、复合型腕臂绝缘子[图 13(b)]、开发板、10 英寸显示屏组成，开发板配置如表 9 所示。

为直观展示绝缘子缺陷检测结果，开发了可视化界面，展示原始接触网图像与检测结果，标记表面缺陷位置，显示缺陷类型、置信度等详细信息。此外，系统通过尺度不变特征变换(scale-invariant feature transform, SIFT)算法检测图像中的特征点，并

表 9 NVIDIA Jetson Orin Nano 开发板配置
Tab.9 Configuration of NVIDIA Jetson Orin Nano development board

硬件模块	参数
GPU	NVIDIA Ampere architecture
	1 024 CUDA Cores
	32 Tensor Cores, 635 MHz
AI性能	10 FP16 TFLOPS
CPU	6-core Arm Cortex-A78AE v8.2 64-bit CPU 1.5 GHz
显存	8 GB 128-bit LPDDR5 68 GB/s

利用暴力匹配器(brute force matcher, BFMatcher)进行特征点匹配，再借助单应性矩阵进行坐标变换计算，将缺陷在截取图像中的坐标还原至原始接触网图像坐标，以便回溯追踪和维护保养，提高检测结果的可读性和实用性。




图13 模拟边缘部署场景

Fig.13 Simulation of edge deployment scenarios

在实验室模拟环境下完成边缘设备部署离线模式和在线模式测试,与实验工作站相比,检测准确性保持相同(93.6%),而实时检测帧率降低至65 frame/s.主要原因是边缘设备算力受限,制约了模型推理速度,同时两阶段级联检测架构引入了额外的数据传输与预处理开销,进一步影响了整体帧率表现,但检测响应时间仍满足工业检测帧率35 frame/s的需求,为后续实际铁路场景的应用奠定了良好基础.

5 结论

本文针对4C系统采集的绝缘子图像存在缺陷边缘特征微弱、尺度差异显著、环境噪声大等问题,提出了一种多尺度特征融合的AMCF-YOLO算法,开展了性能评价、泛化能力、边缘设备部署实验,主要结论如下:

1) 所提模型通过特征强化、特征融合与回归优化措施,在轻量化指标浮动较小的情况下,提升了缺陷检测精度,尤其是微弱特征缺陷.相比基准网络,所提模型的 P 、 R 、 mAP_{50} 、 mAP_{50-95} 分别提升了2.8、4.6、3.3、5.6个百分点,而参数量仅为4.2 M.

2) 检测帧率达到了104 frame/s;对于小缺陷鸟啄破损和细长裂纹检测精度提升最高,分别提升了4.6和3.5个百分点;与其他主流模型相比,本文模型优于同量级模型,实现了资源使用 and 性能提升的双重目标.

3) 所提模型的泛化能力表现优异.在公开数据集CPLID和IDID上,AMCF-YOLO的 mAP_{50} 分别达到98.4%和97.0%,明显优于基准模型,且与YOLOv11s

的性能接近,表明模型在绝缘子缺陷检测任务中具有良好的鲁棒性与泛化能力.同时,在跨场景道路裂缝数据集SVRDD上,AMCF-YOLO仍保持较为稳定的检测性能,进一步验证了其对于细小裂缝类缺陷检测的稳定性.

4) 开发了一套绝缘子多缺陷边缘检测设备,在保持检测精度不损失的情况下,实现65 frame/s的检测速度,满足现场应用需求.

本文提出的接触网绝缘子表面缺陷智能巡检方案,可为铁路运维的智能化与安全性提升提供技术支撑.未来工作将结合TensorRT等推理加速框架与量化推理策略,对模型部署流程进行进一步优化,继续提升检测准确性和边缘设备的运行稳定性,推动装置在实际场景中的工程化应用.

参考文献

- [1] 卞建鹏,李凡,郝培旭,等.复杂环境下输电线路绝缘子的破损识别与定位[J].高电压技术,2022,48(2):681-688.
BIAN J P, LI F, HAO P X, et al. Damage identification and location of transmission line insulator in complex environment[J]. High Voltage Engineering, 2022, 48(2):681-688. (in Chinese)
- [2] 张廷荣,段承成,胡延文,等.一种用于接触网腕臂绝缘子破损大小检测的YOLOv7-OpenCV算法[J].铁道科学与工程学报,2025,22(4):1870-1882.
ZHANG T R, DUAN C C, HU Y W, et al. A YOLOv7-OpenCV algorithm for detecting the size of insulator damage in overhead contact system[J]. Journal of Railway Science and Engineering, 2025, 22(4):1870-1882. (in Chinese)
- [3] 居来提·阿不力孜,刘玉龙,曹留,等.基于改进Cascade R-CNN的绝缘子故障检测方法研究[J].电力科学与技术学报,2023,38(3):140-148.

- ABULIZI J, LIU Y L, CAO L, et al. Study of insulator fault detection algorithm based on improved Cascade R-CNN network [J]. Journal of Electric Power Science and Technology, 2023, 38(3): 140–148. (in Chinese)
- [4] 张福增, 宋磊, 李锐海, 等. 复合绝缘子断裂原因分析及缺陷评价方法[J]. 高电压技术, 2012, 38(11): 3093–3100.
- ZHANG F Z, SONG L, LI R H, et al. Evaluation method of defect and fracture reason for composite insulator [J]. High Voltage Engineering, 2012, 38(11): 3093–3100. (in Chinese)
- [5] 胡道婕, 倪翠, 吴春坡, 等. 基于无人机视角的轻量化绝缘子缺陷检测算法[J/OL]. 北京航空航天大学学报, 1–7. (2025–09–10) [2025–09–25]. <https://doi.org/10.13700/j.bh.1001-5965.2025.0495>.
- HU X J, NI C, WU C P, et al. Lightweight insulator defect detection algorithm based on UAV perspective [J/OL]. Journal of Beijing University of Aeronautics and Astronautics, 1–7. (2025–09–10) [2025–09–25]. <https://doi.org/10.13700/j.bh.1001-5965.2025.0495>. (in Chinese)
- [6] 王昱晴, 袁田, 聂霖, 等. 玻璃绝缘子玻璃件缺陷的机器视觉检测方法[J]. 高电压技术, 2022, 48(12): 4933–4940.
- WANG Y Q, YUAN T, NIE L, et al. Machine vision inspection method for defects of glass insulator [J]. High Voltage Engineering, 2022, 48(12): 4933–4940. (in Chinese)
- [7] 朱恩文, 梁翌, 肖进文, 等. 基于MDS-YOLO模型的小目标检测问题研究[J]. 湖南大学学报(自然科学版), 2024, 51(12): 78–86.
- ZHU E W, LIANG Z, XIAO J W, et al. Research of small object detection problem based on MDS-YOLO model [J]. Journal of Hunan University (Natural Sciences), 2024, 51(12): 78–86. (in Chinese)
- [8] 张桂南, 刘志刚, 韩烨, 等. 接触网棒式绝缘子故障检测的快速模糊匹配方法[J]. 铁道学报, 2013, 35(5): 27–33.
- ZHANG G N, LIU Z G, HAN Y, et al. A fast fuzzy matching method of fault detection for rod insulators of high-speed railways [J]. Journal of the China Railway Society, 2013, 35(5): 27–33. (in Chinese)
- [9] 杨红梅, 刘志刚, 韩烨, 等. 基于快速鲁棒性特征匹配的电气化铁路绝缘子不良状态检测[J]. 电网技术, 2013, 37(8): 2297–2302.
- YANG H M, LIU Z G, HAN Y, et al. Defective condition detection of insulators in electrified railway based on feature matching of speeded-up robust features [J]. Power System Technology, 2013, 37(8): 2297–2302. (in Chinese)
- [10] WU X, YUAN P, PENG Q, et al. Detection of bird nests in overhead catenary system images for high-speed rail [J]. Pattern Recognition, 2016, 51: 242–254.
- [11] 刘传洋, 吴一全, 刘景景. 无人机航拍图像中绝缘子缺陷检测的深度学习研究方法研究进展[J]. 电工技术学报, 2025, 40(9): 2897–2916.
- LIU C Y, WU Y Q, LIU J J. Research progress of deep learning methods for insulator defect detection in UAV based aerial images [J]. Transactions of China Electrotechnical Society, 2025, 40(9): 2897–2916. (in Chinese)
- [12] 李鹏, 宿云龙, 宁昊, 等. 基于嵌入式YOLO网络的电力绝缘子自爆缺陷检测[J]. 电工技术学报, 2025, 40(23): 7806–7818.
- LI P, SU Y L, NING H, et al. Self-explosion defect detection of power insulators based on embedded YOLO network [J]. Journal of Electrical Technology, 2025, 40(23): 7806–7818. (in Chinese)
- [13] TAN P, LI X F, DING J, et al. Mask R-CNN and multifeature clustering model for catenary insulator recognition and defect detection [J]. Journal of Zhejiang University-Science A, 2022, 23(9): 745–757.
- [14] WEN Q D, LUO Z Q, CHEN R T, et al. Deep learning approaches on defect detection in high resolution aerial images of insulators [J]. Sensors, 2021, 21(4): 1033.
- [15] 李鑫, 刘帅男, 杨桢, 等. 基于改进Cascade R-CNN的输电线路多目标检测[J]. 电子测量与仪器学报, 2021, 35(10): 24–32.
- LI X, LIU S N, YANG Z, et al. Multi-target detection of transmission lines based on improved Cascade R-CNN [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 24–32. (in Chinese)
- [16] 唐炳南, 柳明贤, 李华, 等. 基于改进YOLOv10的绝缘子缺陷检测算法[J/OL]. 南方电网技术, 1–11. (2025–03–25) [2025–12–17]. <https://link.cnki.net/urlid/44.1643.TK.20250325.1429.002>.
- TANG B N, LIU M X, LI H, et al. Insulator defect detection algorithm based on improved YOLO v10 [J/OL]. China Southern Power Grid Technology, 1–11. (2025–03–25) [2025–12–17]. <https://link.cnki.net/urlid/44.1643.TK.20250325.1429.002>. (in Chinese)
- [17] 宋智伟, 黄新波, 纪超, 等. 基于Flexible YOLOv7的输电线路绝缘子缺陷检测和故障预警方法[J]. 高电压技术, 2023, 49(12): 5084–5094.
- SONG Z W, HUANG X B, JI C, et al. Insulator defect detection and fault warning method for transmission line based on flexible YOLOv7 [J]. High Voltage Technology, 2023, 49(12): 5084–5094. (in Chinese)
- [18] 李斌, 屈璐瑶, 朱新山, 等. 基于多尺度特征融合的绝缘子缺陷检测[J]. 电工技术学报, 2023, 38(1): 60–70.
- LI B, QU L Y, ZHU X S, et al. Insulator defect detection based on multi-scale feature fusion [J]. Transactions of China Electrotechnical Society, 2023, 38(1): 60–70. (in Chinese)
- [19] 杨茜, 熊炜, 孟圣哲, 等. 基于YOLOv8的轻量化绝缘子缺陷检测算法[J/OL]. 激光与光电子学进展, 1–17. (2025–05–08) [2025–12–17]. <https://link.cnki.net/urlid/31.1690.tn.20250506.1426.114>.
- YANG X, XIONG W, MENG S Z, et al. Lightweight insulator defect detection algorithm based on YOLOv8 [J/OL]. Advances in laser and optoelectronics, 1–17. (2025–05–08) [2025–12–17].

- <https://link.cnki.net/urlid/31.1690.tn.20250506.1426.114>. (in Chinese)
- [20] 姜香菊, 王瑞彤, 马彦鸿. 基于轻量级改进RT-DETR边缘部署算法的绝缘子缺陷检测[J]. 电工技术学报, 2025, 40(3): 842-854.
- JIANG X J, WANG R T, MA Y H. Insulator defect detection based on lightweight improved RT-DETR edge deployment algorithm [J]. Transactions of China Electrotechnical Society, 2025, 40(3): 842-854. (in Chinese)
- [21] 罗向龙, 王彦博, 蒲亚亚, 等. 多病害并发复杂场景下的道路病害检测RGT-YOLOv7模型[J]. 湖南大学学报(自然科学版), 2024, 51(12): 107-118.
- LUO X L, WANG Y B, PU Y Y, et al. Road disease detection RGT-YOLOv7 model under multiple diseases complicated scenarios [J]. Journal of Hunan University (Natural Sciences), 2024, 51(12): 107-118. (in Chinese)
- [22] XIA Z F, PAN X R, SONG S J, et al. Vision transformer with deformable attention [EB/OL]. (2022-01-03) [2025-12-17]. <https://arxiv.org/abs/2201.00520>.
- [23] LIU C, WANG K G, LI Q, et al. Powerful-IoU: more straightforward and faster bounding box regression loss with a nonmonotonic focusing mechanism [J]. Neural Networks, 2024, 170: 276-284.
- [24] TAO X, ZHANG D P, WANG Z H, et al. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2020, 50(4): 1486-1498.
- [25] DEXTER L, PRATIK K. Insulator Defect Detection [DB/OL]. IEEE Dataport. (2021-08-11) [2025-12-17]. <https://dx.doi.org/10.21227/vkdw-x769>.
- [26] REN M, ZHANG X F, ZHI X B, et al. An annotated street view image dataset for automated road damage detection [J]. Scientific Data, 2024, 11: 407.
- [27] WANG C C, HE W, NIE Y, et al. Gold-YOLO: efficient object detector via gather-and-distribute mechanism [EB/OL]. (2023-10-23) [2025-12-17]. <https://arxiv.org/abs/2309.11331>.
- [28] TAN M X, PANG R M, LE Q V. EfficientDet: scalable and efficient object detection [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020. Seattle, WA, USA. IEEE, 2020: 10778-10787.
- [29] OUYANG D L, HE S, ZHANG G Z, et al. Efficient multi-scale attention module with cross-spatial learning [EB/OL]. (2023-06-06) [2025-12-17]. <https://arxiv.org/abs/2305.13563>.
- [30] XU W, WAN Y, ZHAO D. SFA: efficient attention mechanism for superior CNN performance [J]. Neural Processing Letters, 2025, 57(2): 38.
- [31] WU Z Y, DING T J, LU Y F, et al. Token statistics transformer: linear-time attention via variational rate reduction [EB/OL]. (2024-12-23) [2025-12-23]. <https://arxiv.org/abs/2412.17810>.
- [32] ZHANG X, SONG Y Z, SONG T T, et al. LDConv: linear deformable convolution for improving convolutional neural networks [J]. Image and Vision Computing, 2024, 149: 105190.
- [33] SUNKARA R, LUO T. No more strided convolutions or pooling: a new CNN building block for low-resolution images and small objects [C]//Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Cham: Springer Nature Switzerland, 2022: 443-459.
- [34] WILLIAMS T, LI R Y. Wavelet pooling for convolutional neural networks [C]//International Conference on Learning Representations, 2018.