

基于 STDD-YOLO 的输电线路小目标缺陷检测<sup>\*</sup>

罗 毅 韩义涛 黄 徽

(华北电力大学控制与计算机工程学院 北京 102206)

**摘 要:** 针对输电线路小目标缺陷检测中存在的边缘定位精度低、多尺度特征提取能力不足以及复杂背景干扰等问题,提出了一种基于 STDD-YOLO 的目标检测算法。该算法通过设计边缘空间特征增强模块,强化高频特征提取能力,提高缺陷边界的定位精度,增强了边缘和轮廓等高频信息感知能力;以高效多核卷积替代原有 Bottleneck 中的标准卷积,增强网络对多尺度小目标的检测性能,解决 C3k2 结构在细节信息利用上的局限性;设计了共享卷积 GN 检测头,抑制背景噪声干扰,增强小目标特征表达能力,有效提高复杂环境下模型检测的鲁棒性,避免复杂背景下缺陷目标显著性低而导致误检和漏检。实验表明,所提算法可显著提高检测精度。

**关键词:** 小目标缺陷检测;边缘定位精度;多尺度特征提取;复杂背景干扰;YOLOv11

**中图分类号:** TP391.4;TN60 **文献标识码:** A **国家标准学科分类代码:** 510.4050

## Transmission line small target defect detection based on STDD-YOLO

Luo Yi Han Yitao Huang Hui

(School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China)

**Abstract:** To address the issues of low edge location accuracy, insufficient multi-scale feature extraction capability, and complex background interference in the detection of small target defects in transmission lines, a target detection algorithm based on STDD-YOLO is proposed. This algorithm enhances the high-frequency feature extraction capability by designing an edge-spatial feature enhancement module, improving the positioning accuracy of defect boundaries and enhancing the perception of high-frequency information such as edges and contours. It replaces the standard convolution in the original Bottleneck with efficient multi-kernel convolution to enhance the network's detection performance for multi-scale small targets and solve the limitations of the C3k2 structure in utilizing detail information. A shared conv group norm head is designed to suppress background noise interference, enhance the feature expression ability of small targets, effectively improve the robustness of model detection in complex environments, and avoid false detection and missed detection caused by the low saliency of defect targets in complex backgrounds. Experiments show that this algorithm can significantly improve detection accuracy.

**Keywords:** small target defect detection; edge localization accuracy; multi-scale feature extraction; complex background interference; YOLOv11

## 0 引 言

输电线路作为电能传输的核心通道,其健康状况直接影响着电力系统的可靠性<sup>[1]</sup>。然而,由于输电线路长期处于自然环境中,受气候条件、周围动物活动以及人类活动等因素的影响,有较大概率出现各类隐患、缺陷甚至事故<sup>[2-3]</sup>。特别是在复杂环境条件下,输电线路中的绝缘子、销钉等关键部件容易受到多种因素的损害,其中绝缘子破损、绝缘子闪络、绝缘子自爆和销钉缺失等小目标缺陷尤为常见。这

些缺陷虽然目标尺寸较小,但危害性极大;绝缘子破损可能引发局部放电,绝缘子闪络会造成绝缘性能丧失,绝缘子自爆会直接导致机械强度下降,而销钉缺失则可能导致金具脱落等连锁故障。因此,如何准确、快速地对输电线路中绝缘子、销钉等小目标缺陷进行检测对于提升电网运维效率、保障电力系统安全稳定运行具有重要的理论意义和工程实用价值。

近年来,电网规模持续扩大,导致输电线路运维工作的难度日益提升<sup>[4]</sup>,基于此,越来越多的企业机构开始推行无

人机与人工智能技术相结合的“智能巡检”<sup>[5]</sup>。在此技术框架下,无人机采集电力线路图像后,由计算机视觉技术替代人工分析,显著提升了输电线路关键部件缺陷检测的效率与准确率。目前,应用于输电线路缺陷检测的主流深度学习算法主要包括以 Faster R-CNN<sup>[6]</sup>、Mask R-CNN<sup>[7]</sup> 为代表的两阶段检测算法,以 YOLO 系列<sup>[8-10]</sup>、SSD<sup>[11]</sup>、RetinaNet<sup>[12]</sup> 为代表的一阶段检测算法,以及以 DETR<sup>[13]</sup> 为代表的基于 Transformer 的检测算法。在深度学习应用于输电线路缺陷检测的研究中,赵霖等<sup>[14]</sup> 提出基于改进 YOLOv5 模型的输电线路鸟巢检测算法,通过在主干网络加入 CBAM 注意力模块提升特征提取能力,在颈部网络引入自适应特征融合模块加强多尺度特征融合,并采用 Mish 激活函数提升分类精度与泛化能力,实验表明,该方法对遮挡目标及远近距离目标检测效果良好,但该方法的实时性仍需优化。周景等<sup>[15]</sup> 提出一种基于 SDH-DETR 的绝缘子缺陷检测算法,采用轻量级 StarNet 为主干网络降低复杂度并提升特征提取能力,引入 DySample 动态上采样模块减少细节丢失与图像失真,实验表明,该方法在保证精度的同时,实现了轻量化设计,然而,该算法在边缘定位精度方面仍存在不足,特别是对于形状不规则或边缘模糊的小目标,其边界框定位存在偏差。Fu 等<sup>[16]</sup> 提出了一种 I2D-Net 检测网络,通过设计三路径特征融合模块、增强感受野注意力机制和上下文感知模块,有效提升了架空输电线路绝缘子缺陷的检测精度,但其多尺度检测能力有待提高。刘宏志等<sup>[17]</sup> 提出改进 YOLOv11n 算法,设计 C3K2-SG 与弥散金字塔网络结构,分别增强了特征提取能力与多尺度特征融合能力,提升了输电线路检测性能,但当该算法并未考虑到小目标缺陷检测的情况。赵福生等<sup>[18]</sup> 提出一种基于 YOLOv8 的输电线路巡检算法,该算法设计全局通道-空间注意力模块以增强输入特征图表达能力,用降采样模块 (adaptive downsampling, ADown) 替换传统卷积以提升不明显特征检测准确率,实验结果表明,该方法能较好检测电力部件缺陷及输电线路异物,但该方法并未考虑到在实时检测中计算开销大的问题。季星宇等<sup>[19]</sup> 提出结合多样化分支特征和排斥损失的 YOLOv11 绝缘子缺陷检测算法,更新 C2PSA 模块的部分自注意力 (pyramid squeeze attention, PSA) 机制,补偿被遮挡区域的响应损失,加入动态上采样器,提升上采样的质量和效率,但该算法的泛化能力有待提高。刘航等<sup>[20]</sup> 提出了一种轻量化改进的 YOLOv8n 检测方法,通过添加小目标检测模块、引入 SIOU 损失函数并结合通道剪枝技术,有效提升了绝缘子自爆缺陷的检测精度和模型效率,但该算法只针对绝缘子自爆这一单一缺陷,尚未涵盖绝缘子闪络、破损等其他常见缺陷类型。值得注意的是,小目标缺陷检测的技术难点在跨领域场景中具有共性,张莹等<sup>[21]</sup> 针对印制电路板小目标缺陷提出的 YOLOPCB 网络为输电线路小目标缺陷检测提供了参考,但输电线路更复杂的户外环境对算法抗干扰能力提

出了更高要求。

综上所述,当前目标检测算法在输电线路小目标缺陷检测中还存在边缘定位精度低、多尺度小目标特征提取能力不足以及易受复杂背景干扰等问题。

因此,本文针对上述问题提出一种改进 YOLOv11 的输电线路小目标缺陷检测算法 (small target defect detection-YOLO, STDD-YOLO)。首先,该算法针对现有目标检测算法对边缘和轮廓等高频信息的感知能力不足,导致对缺陷边界的定位精度受限的问题,提出边缘空间特征增强模块 (edge-spatial feature enhancement module, ESFEM),提升缺陷边界定位精度;其次,针对网络中的 C3k2 结构无法充分利用图像中的细节信息,导致网络在处理多尺度小目标时出现精度下降的问题,设计高效多核卷积 (efficient multi-kernel convolution, EMKC),替代 Bottleneck 中的传统卷积,优化特征提取流程并增强网络对多尺度小目标的检测能力;最后,针对复杂背景下由于故障目标图像显著度弱造成检测网络精度低的问题,提出共享卷积 GN 检测头 (shared conv group norm head, SCGNH),抑制复杂背景噪声,增强小目标特征信息的提取能力,由此改善模型在复杂背景下小目标检测任务中的表现。

## 1 STDD-YOLO 小目标缺陷检测算法

### 1.1 YOLOv11 算法原理

YOLOv11 在继承单阶段检测器高效特性的基础上,通过引入 C3k2、C2PSA 特征提取模块、设计解耦检测头,实现检测性能全面提升,这使其成为改进输电线路缺陷检测模型的优选基础。其主干网络引入基于 CSP 架构改进的 C3k2 模块,具备串联双 C3k 模块增加特征提取深度或退化为 C2f 模块提高计算效率的可配置模式,特别有利于捕捉输电线路缺陷的细微特征;同时结合 C2PSA 模块,将 CSP 结构与部分自注意力机制结合,经卷积分流、多尺度卷积特征提取、通道加权及 Softmax 特征重校准,提升复杂场景下多尺度目标检测能力。颈部网络采用改进的路径聚合特征金字塔结构 (feature pyramid network, FPN),在 FPN 自顶向下路径基础上新增自底向上特征聚合路径,通过双向路径实现跨层级特征互补,增强对不同尺度目标的特征表达能力。检测头采用解耦设计,分离分类与回归任务,以深度可分离卷积替代标准卷积,降低参数量和计算复杂度,通过并行处理不同尺度特征图实现目标定位与分类协同优化,进一步提升整体检测性能。

相比于前代版本,尽管 YOLOv11 性能卓越,但在输电线路缺陷检测的应用中仍存在一些局限性。特别是在复杂场景下,算法无法有效抑制背景干扰,对小目标的细节特征提取能力有待提升,对亚像素级边缘的定位精度也需要进一步优化。这些局限性为后续算法的改进提供了明确的研究方向。

1.2 STDD-YOLO 小目标缺陷检测算法网络结构

本文提出的 STDD-YOLO 小目标检测算法的网络结构如图 1 所示。在主干网络部分, 首先将输入图像输入 ESFEM。ESFEM 通过 Sobel 卷积分支提取边缘梯度信息, 池化分支捕获空间上下文信息, 二者融合后增强缺陷的边缘和空间特征。随后, 特征图经过多个 C3k2 与卷积层的组合, 进一步提取和细化特征。之后, 在主干网络的深层

引入 C3k2\_EMKC 模块, 该模块利用 EMKC 替代传统 Bottleneck 中的卷积操作, 通过  $1 \times 1$ 、 $3 \times 3$ 、 $5 \times 5$ 、 $7 \times 7$  的混合卷积核并行提取不同尺度缺陷特征, 经分组卷积和  $1 \times 1$  跨通道融合, 有效解决缺陷尺度多变的问题。随后, 特征图依次经过快速空间金字塔池化 (spatial pyramid pooling-fast, SPPF) 模块和 C2PSA 模块, 进一步增强特征的尺度适应性和上下文感知能力。




图 1 STDD-YOLO 网络结构

Fig. 1 STDD-YOLO network structure

颈部网络部分采用 YOLOv11 的颈部架构。不同层级的特征图先进行拼接操作, 然后经上采样操作增大高层特征图尺寸, 以便与低层特征图融合。融合后的特征图经卷积层处理后, 与来自主干网络的另一部分特征图再次拼接。在此基础上, 在颈部网络的深层引入 C3k2\_EMKC 模块, 进一步强化多尺度特征的融合效果。检测头部分采用 SCGNH。首先利用组归一化卷积替代批归一化, 将特征图通道分组归一化, 保留通道差异的同时适应图像尺寸变化, 增强对微弱缺陷的辨识度; 随后, 特征图通过基于深度可分离卷积的共享卷积结构, 抑制复杂背景噪声干扰, 稳定提取目标特征; 最后, 输出层沿用差异化设计处理分类与回归任务, 并在回归分支引入可学习缩放因子, 自适应调整不同尺度缺陷的检测输出, 精准预测缺陷位置与类别, 有效克服传统检测头在复杂环境下的性能瓶颈。

2 STDD-YOLO 小目标缺陷检测算法实现步骤

2.1 边缘空间特征增强模块

现有目标检测算法的前端模块主要负责从输入图像

中提取特征。然而, 前端模块中的标准卷积操作对边缘等高频特征的响应较弱, 而输电线路缺大多表现为明显的边缘异常, 传统的卷积操作往往不能有效地捕捉到这些缺陷的精细信息。为了弥补这一不足, 本文提出了一种名为 ESFEM 的新型前端模块, 旨在提升缺陷目标的特征表达能力, 其结构如图 2 所示。

ESFEM 结合了边缘特征增强和空间特征池化, 能够有效地提取具有空间和边缘信息的多层次特征, 增强故障目标的特征表达能力。其结构可以分为 3 个主要部分: 边缘特征增强分支、空间特征池化分支和特征融合与变换。

ESFEM 首先通过 Sobel 滤波器来提取图像的边缘信息。Sobel 滤波器有两个方向的核, 分别用于检测水平方向和垂直方向的边缘, 其水平与垂直梯度核定义为:

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad (1)$$




图 2 ESFEM 结构

Fig. 2 ESFEM structure

$$\mathbf{G}_y = \mathbf{G}_x^T = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad (2)$$

通过以下变换将理论核  $\mathbf{G}_{x,y}$  转换为可操作的卷积核

$\mathbf{W}_{x,y}$ , 即:

$$\mathbf{W}_{x,y} = \underbrace{\mathbf{G}_{x,y} \oplus \mathbf{G}_{x,y} \oplus \cdots \oplus \mathbf{G}_{x,y}}_{d \uparrow} \quad (3)$$

其中,  $\oplus$  表示通道维度拼接。最终, 对输入特征图进行 Sobel 卷积运算:

$$\mathbf{S}(\mathbf{X}) = \sqrt{(\mathbf{W}_x * \mathbf{X})^2 + (\mathbf{W}_y * \mathbf{X})^2} \quad (4)$$

其中,  $\mathbf{W}_x, \mathbf{W}_y \in \mathbb{R}^{d \times 1 \times 3 \times 3}$  为冻结参数的 Sobel 核,  $*$  表示卷积操作,  $\mathbf{X}$  为输入特征图,  $\mathbf{S}(\mathbf{X})$  为最终的边缘强度图。在提取边缘信息的同时, 对输入图像进行最大池化操作来增强空间特征。具体来说, 进行零填充后, 使用一个大小为  $2 \times 2$ 、步长为 1 的最大池化层来增强模型对空间上下文信息的理解。然后, 双分支输出先进行通道拼接融合

特征, 形成增强的混合特征表示, 再通过  $3 \times 3$  卷积进一步压缩特征图尺寸, 扩大有效感受野, 最后通过  $1 \times 1$  卷积实现通道降维与特征整合。

## 2.2 高效多核卷积

在 YOLOv11 网络中, C3k2 模块是常用的 CSPBottleneck 设计, 用于特征提取和多尺度信息融合。然而, 尽管 C3k2 模块在许多大目标检测任务中表现优异, 对于小目标缺陷检测任务来说, 其表现并不理想。小目标通常在图像中占据较少的像素区域, 且可能与背景、其他大目标有较强的相似性, 导致 C3k2 模块难以有效提取细粒度特征并进行精确的目标检测。因此, 针对这些问题, 本文提出了一种高效多核卷积, 替代 Bottleneck 中的传统卷积, 将其集成到 C3k2 架构中形成 C3k2\_EMKC 模块, 并替代网络中深层的 C3k2 模块, 该架构优化了特征提取流程并增强了网络对小目标的检测能力, 其结构如图 3 所示。




图 3 EMKC 结构

Fig. 3 EMKC structure

EMKC 的核心思想是通过多尺度卷积操作增强特征提取能力, 从而提升多尺度小目标检测的准确性。EMKC 首先将输入特征图  $\mathbf{X} \in \mathbb{R}^{B \times C \times H \times W}$  按照通道维度均分为 4 组, 以便为每组应用不同大小的卷积核。具体实现中, 设置了  $\{1, 3, 5, 7\}$  4 种不同尺度的卷积核, 每组特征图通过对应的卷积核进行处理。这种分组多尺度卷积策略使模块

能够同时捕获不同粒度的特征信息, 既保留了细粒度的局部特征, 又获取了大范围的上下文信息。

在所有卷积操作完成后, EMKC 模块将每个组的输出特征图进行堆叠, 然后通过  $1 \times 1$  卷积进一步融合这些多尺度特征, 最终输出统一的特征图, 通过这一操作将不同尺度的信息融合到一个通道维度上, 从而增强网络对多尺



度特征的表达能力。

2.3 共享卷积 GN 检测头

为解决复杂背景下由于故障目标显著度弱造成检测

精度低的问题,本文提出共享卷积 GN 检测头,其结构如图 4 所示。

该检测头采用组归一化卷积替代批归一化卷积处理




图 4 共享卷积 GN 检测头  
Fig. 4 Shared conv-GN head

输入特征图,利用 GroupNorm 操作解决小批量训练时的性能波动问题,在保留通道间差异性的同时适应图像尺寸变化,增强对微弱目标的辨识能力。具体地,在组归一化层上将特征图的通道  $C$  分为  $G$  个组,每个组中包含  $C/G$  个通道,每组通道中的特征图会分别进行归一化处理。输出特征的标准化公式为:

$$\hat{x}_i = \frac{x_i - \mu_i}{\sigma_i} \tag{5}$$

$$\mu_i = \frac{1}{m} \sum_{k \in S_i} x_k \tag{6}$$

$$\sigma_i = \sqrt{\frac{1}{m} \sum_{k \in S_i} (x_k - \mu_i)^2 + \epsilon} \tag{7}$$

$$S_i = \left\{ k \mid k_N = i_N, \left[ \frac{k_C}{C/G} = \frac{i_C}{C/G} \right] \right\} \tag{8}$$

其中,  $\hat{x}_i$  为标准化输出的特征向量;  $x_i$  为卷积层输出的特征向量;  $\mu_i$  为均值;  $\sigma_i$  为标准差;  $x_k$  为卷积层输出的特征向量,其中  $k$  表示在集合  $S_i$  中的索引;  $m$  为每组的元素总和;  $S_i$  为计算均值和方差的点集合;  $\epsilon$  为常量;  $i$  为样本索引;  $i_N$  为在数据维度  $N$  上的索引;  $G$  为组数;  $C$  为通道数。

为克服复杂背景下噪声导致的特征提取不一致性,通过设计基于深度可分离卷积的共享卷积结构,借助跨尺度共享的深度卷积核和点卷积核实现空间特征一致性学习,有效抑制复杂背景噪声并保持目标特征稳定捕获,深度可分离卷积结构如图 5 所示。最终输出层沿用 YOLOv11 网络中的检测头的差异化设计处理分类与回归任务。在回归分支中引入一个可学习的缩放因子对每个检测头的输出进行缩放,提高定位精度,优化检测头的多尺度适应性。




图 5 深度可分离卷积结构  
Fig. 5 Depthwise separable convolution structure

3 实验验证与分析

3.1 实验环境

本次实验操作系统为 Windows11,采用 PyTorch2.1.0 深度学习框架, GPU 为 NVIDIA GeForce RTX4070 Laptop GPU 12 GB,CPU 为 AMD Ryzen7 7745HX with Radeon Graphics 3.60 GHz,显卡内存为 16 GB,深度学习加速环境为 CUDA12.1,OpenCV 库版本为 4.10.0.84,开发环境为 Pycharm。

3.2 数据集

本次实验数据集来源部分为某电网公司拍摄的绝缘子缺陷数据集和销钉缺失数据集,另一部分为网络的公开数据,总共 1 302 张缺陷图像,各类缺陷名称、数量、标签数量如表 1 所示。

表 1 缺陷名称和数量  
Table 1 Defect names and quantities

| 缺陷类型  | 自定义名称 | 图像张数 | 标签个数 |
|-------|-------|------|------|
| 绝缘子破损 | ID    | 238  | 334  |
| 绝缘子闪络 | IF    | 213  | 543  |
| 绝缘子自爆 | IE    | 351  | 372  |
| 销钉缺失  | PM    | 500  | 740  |

3.3 模型训练

将数据集中各类别样本按照 7:1:2 随机划分成训练集、验证集和测试集,各类缺陷实例如图 6 所示。训练模型时将图像大小统一调整 640×640。模型使用 SGD 优化器更新优化参数,初始学习率 0.01,动量参数 0.937,权重衰减率 0.000 5,批大小为 8,模型最大迭代次数为 400。



图 6 各类缺陷实例

Fig. 6 Instances of various defects

3.4 评价指标

本文采用精确率(precision, P)、召回率(recall, R)、平均精度(average precision, AP)和平均精确均值(mean average precision, mAP)作为模型的评价指标。

精确率衡量模型预测为正类的样本中真实正类的比例,反映检测结果的可靠性:

$$P = \frac{TP}{TP + FP}$$
 (9)

其中, TP(true positive)为正确检测的目标数量, FP(false positive)为误检数量。召回率则表征模型对真实正类样本的覆盖能力,即:

$$R = \frac{TP}{TP + FN}$$
 (10)

其中, FN(false negative)表示漏检目标数。二者存在权衡关系,通常通过调节置信度阈值来平衡。

AP 是通过计算不同召回率下的精确率曲线下面积,综合评估单一类别的检测性能,其计算公式为:

$$AP = \int_0^1 P(R) dR$$
 (11)

mAP 作为多类别检测任务的全局评价指标,是所有类别 AP 值的算术平均值:

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i$$
 (12)

其中, n 为类别总数, AP<sub>i</sub> 表示第 i 个类别的 AP 值。

3.5 对比实验

1)改进策略对比

为明确本文算法与现有输电线路目标检测领域改进 YOLO 算法的技术差异,凸显本文创新点的独特性,选取 3 个同领域高相关文献的网络模型,分别从网络的 backbone、neck、head 这 3 个部分展开对比,剖析本文改进策略的差异化价值。

由表 2 可知,文献[22-24]的改进策略多依赖注意力机制或模块替换等通用策略,未从卷积核结构优化、边缘高频信息感知等对小缺陷适配性至关重要的细分方向寻求突破,导致对小目标缺陷的针对性不足。相比之下,本文算法在创新设计上展现出显著优势,不依赖注意力机制进行改进,且算法所设计的 ESFEM、EMKC 以及 SCGNH,均分别对应小目标缺陷检测中边缘定位差、多尺度小目标特征提取弱、复杂背景干扰的核心难题,确保改进方向与实际检测需求高度契合。

2)ESFEM 框架下不同边缘增强策略对比实验

为验证本文所提 ESFEM 中边缘增强分支的有效性 及最优实现方式,选用当前主流的边缘增强方法进行对比,包括:基于二阶导数的拉普拉斯(Laplacian)边缘检测算子,其对高频边缘变化敏感;一阶导数算子 Prewitt,通过均等权重卷积核计算梯度提取边缘;一阶导数算子 Sobel,通过加权梯度计算提取边缘信息。实验结果如表 3 所示。

表 2 改进策略

Table 2 Improvement strategy comparison

| 模型        | Backbone          | Neck                | Head            |
|-----------|-------------------|---------------------|-----------------|
| 文献[22]    | 利用 ODConv 强化局部特征  | 设计 FMNet 动态聚焦关键区域   |                 |
| 文献[23]    | 引入 CAFM 增强特征融合    | 设计 C2f_Star 降低模型复杂度 | 引入 DyHead 提升注意力 |
| 文献[24]    | 设计 DC-SE 增强浅层特征提取 | 设计 NewC3 轻量化提取特征    |                 |
| STDD-YOLO | 设计 ESFEM 提升边界定位精度 | 设计 EMKC 优化多尺度特征提取   | 设计 SCGNH 抑制背景干扰 |

表 3 ESFEM 框架下不同边缘增强策略对比实验

Table 3 Comparative experiments of different edge enhancement strategies in ESFEM framework

| 模型                       | mAP50/%     | mAP50-95/%  | Params/M    | GFLOPs/G    |
|--------------------------|-------------|-------------|-------------|-------------|
| YOLOv11s                 | 82.4        | 52.1        | <b>9.41</b> | <b>21.3</b> |
| YOLOv11s-ESFEM-Laplacian | 82.5        | 50.4        | 9.47        | 24.2        |
| YOLOv11s-ESFEM-Prewitt   | 83.7        | 51.6        | 9.47        | 24.4        |
| YOLOv11s-ESFEM-Sobel     | <b>84.6</b> | <b>55.3</b> | 9.42        | 21.8        |

由表 3 数据可知,在引入 ESFEM 框架,采用不同边缘增强方法均能使模型的 mAP50 较原始模型得到提升,验证了 ESFEM 中边缘增强分支的有效性,更验证了 ESFEM 的有效性。其中,当 ESFEM 搭配 Sobel 边缘增强方法时,模型性能最优;mAP50 达到 84.6%,较原始模型提升 2.2%;mAP50:95 达到 55.3%,较原始模型提升 3.2%。这一结果表明,Sobel 算子与 ESFEM 框架的适配性最佳,相比于其他算子,能最大化发挥边缘增强对检测性能的增益作用。

3)C3k2\_EMKC 不同位置替换效果对比实验

为验证本文所提 C3k2\_EMKC 模块在增强多尺度小目标检测精度中的最优部署位置,通过在网络不同层级选

择性替换原始 C3k2 模块进行对比,探究模块部署策略与多尺度小目标检测性能的关联性,确定能最大化性能增益的替换方案。实验结果如表 4 所示。实验 1:仅在网络浅层特征区域(对应高分辨率特征图生成阶段)的 C3k2 模块替换为 C3k2\_EMKC,聚焦于早期多尺度特征捕捉。实验 2:仅在网络中层特征区域(对应中分辨率特征图处理阶段)的 C3k2 模块替换为 C3k2\_EMKC,聚焦于中期多尺度特征融合。实验 3:仅在网络深层特征区域(对应低分辨率特征图处理阶段)的 C3k2 模块替换为 C3k2\_EMKC,聚焦于后期多尺度语义信息增强。实验 4:在网络浅、中、深层所有特征区域的 C3k2 模块均替换为 C3k2\_EMKC,验证全局部署的综合效果。

表 4 C3k2\_EMKC 不同位置替换效果对比实验

Table 4 Comparison experiment of C3k2\_EMKC substitution effect at different positions

| 模型                      | mAP50/%     | mAP50-95/%  | Params/M    | GFLOPs/G    |
|-------------------------|-------------|-------------|-------------|-------------|
| YOLOv11s                | 82.4        | 52.1        | 9.41        | 21.3        |
| YOLOv11s-C3k2_EMKC-浅层替换 | 82.6        | 51.2        | 9.81        | 26.4        |
| YOLOv11s-C3k2_EMKC-中层替换 | 83.1        | 52.5        | 9.40        | 21.3        |
| YOLOv11s-C3k2_EMKC-深层替换 | 83.2        | 52.8        | <b>9.23</b> | <b>21.2</b> |
| YOLOv11s-C3k2_EMKC-全局替换 | <b>84.1</b> | <b>54.6</b> | 9.83        | 36.4        |

由表 4 实验结果可知,在引入 C3k2\_EMKC 后,所有替换方案均能模型的性能较原始模型得到提升,验证了 C3k2\_EMKC 的有效性。浅层替换组虽在高分辨率特征处理中引入多尺度卷积,但因缺乏深层语义信息支撑,对复杂场景下多尺度小目标的区分能力提升有限;中层替换组在特征融合阶段增强了多尺度交互,但受限于中层特征的语义表达能力,性能增益不及深层替换组;全局替换组覆盖所有特征层级,虽然其性能增益最大,但因过度引入 C3k2\_EMKC 导致了模型计算量的激增,较原始模型增加了 15.1 G 的计算量;深层替换组通

过强化深层语义特征的多尺度建模能力,在提升检测性能的同时实现了模型的轻量化;其 mAP50 达到 83.2%,mAP50-95 达到 52.8%,较原始模型显著提升,更重要的是,该方案的参数量与计算量均低于原始模型,在性能增益与资源消耗间取得了最佳平衡。综合来看,深层替换组既充分发挥了 C3k2\_EMKC 的性能,又避免了过度引入模块导致的参数量、计算量的增加,因此成为最优部署策略。

3.6 消融实验

为验证本文算法的有效性,本文以 YOLOv11s 网络作



为基线模型,依次引入对应的模块进行消融实验,实验结果如表 5 所示,其中“√”表示采用对应的模块,A 代表 ESFEM,B 代表 EMKC,C 代表 SCGNH。由表中的实验结果可知,无论是单独引入模块,还是组合引入模块,较基线模型 P、R、mAP50、mAP50-95 均有着不同程度的提升,有效证明了 3 个模块对输电线路小目标缺陷检测的能力的增强

与各个模块之间的兼容性。本文算法通过融合边缘空间特征增强模块、高效多核卷积和共享卷积 GN 检测头 3 个方面进行优化,与基线模型相比有明显的提升,P、R、mAP50、mAP50-95 分别提升了 5.7%、0.8%、3.9%、3.1%,增强了模型对边缘和轮廓等高频信息感知能力,提升了多尺度小目标的检测性能,改善了模型在复杂环境下的检测鲁棒性。

表 5 消融实验结果  
Table 5 Results of ablation experiments

| 模型       | A | B | C | AP/%        |             |             |             | P/%         | R/%         | mAP50/<br>% | mAP50-95/<br>% | Params/<br>M | GFLOPs/<br>G |
|----------|---|---|---|-------------|-------------|-------------|-------------|-------------|-------------|-------------|----------------|--------------|--------------|
|          |   |   |   | ID          | IF          | IE          | PM          |             |             |             |                |              |              |
| YOLOv11s |   |   |   | 79.6        | 81.3        | 82.1        | 86.8        | 86.2        | 76.6        | 82.4        | 52.1           | 9.41         | 21.3         |
| M1       | √ |   |   | 82.4        | 84.7        | 81.5        | 89.7        | 86.9        | <b>78.2</b> | 84.6        | <b>55.3</b>    | 9.42         | 21.8         |
| M2       |   | √ |   | 82.1        | 82.5        | 80.1        | 87.9        | 83.3        | 77.8        | 83.2        | 52.8           | 9.23         | 21.2         |
| M3       |   |   | √ | 85.4        | 82.3        | 79.3        | 86.6        | 87.9        | 77.4        | 83.4        | 53.9           | 9.66         | 22.0         |
| M4       | √ | √ |   | <b>87.4</b> | 84.6        | 83.0        | 89.0        | 91.7        | 75.6        | 86.0        | 54.4           | 9.24         | 21.6         |
| M5       | √ |   | √ | 82.2        | 85.5        | 80.3        | <b>89.9</b> | 88.0        | 78.0        | 84.5        | 54.6           | <b>9.23</b>  | <b>21.2</b>  |
| M6       |   | √ | √ | 83.7        | <b>86.2</b> | 77.5        | 86.1        | 87.0        | 76.3        | 83.4        | 52.6           | 9.48         | 21.9         |
| M7       | √ | √ | √ | 87.0        | 85.7        | <b>83.5</b> | 89.0        | <b>91.9</b> | 77.4        | <b>86.3</b> | 55.2           | 9.48         | 22.3         |

为验证本文算法所具有的优势,对本文网络 and 原网络进行了热力图可视化对比,如图 7 所示,亮度高的区域代表网络所关注的重点部分,可以看出本文算法提高了对缺陷部位的关注度,减少了复杂背景的干扰,降低了漏检率

和错检率,提升了模型对输电线路小目标缺陷的检测能力。




图 7 热力图可视化对比结果  
Fig. 7 Heat map visual comparison results

3.7 不同算法对比分析

为验证本文算法对输电线路小目标缺陷检测的优越性,选取多尺度密集分布、低照度、部分遮挡和复杂背景这 4 组场景进行测试,在相同实验环境下,将本文算法与 YOLOv11s、MHAF-YOLO<sup>[25]</sup>、MAF-YOLO<sup>[26]</sup>、Mamba-YOLO<sup>[27]</sup>、Hyper-YOLO<sup>[28]</sup>、RTDETR-18<sup>[29]</sup>、RTDETR-34 这些主流算法进行对比,前 5 种算法均为近年来基于

YOLO 系列优化的目标检测算法,具备直接可比性,后 2 种算法则是主流的 Transformer-based 目标检测算法,代表了不同检测范式下的性能基准,可进一步验证本文算法在“模型复杂度-精度”平衡上的优势。实验结果如表 6 所示。由实验结果可知,Mamba-YOLO 的参数数量最小、计算量最小,但其检测精度相对偏低。Hyper-YOLO 的 mAP50 和 mAP50-95 表现较好,但参数量、计算量相对较



高,在参数量与精度的平衡上不如本文算法。虽然 MHAF-YOLO 的参数量低于本文算法的参数量,但其检测精度远低于本文算法的检测精度,mAP50 低了 5.8%,mAP50-95 低了 5%。RTDETR-18 的综合指标是最接近本文算法的,但其参数量、计算量却是本文算法的两倍多,而且存在误检的情况。除此之外,本文研究的算法无论是在 mAP50 值或是 mAP50-95 值上都表现出了优异的成绩,其中,最受关注的 mAP50 和 mAP50-95 值分别达到了 86.3%、55.2%。


图 8 为本文算法与其他算法的在 4 组典型场景下的检测结果可视化对比图,4 组检测实验结果和分析如下:

第 1 组:存在多尺度密集分布的缺陷目标,且缺陷形状各异,均表现为边缘异常,目前的主流一阶段检测算法

表 6 不同算法对比实验结果

Table 6 Comparison of experimental results with different algorithms

| 模型         | mAP50/      | mAP50-95/   | Params/     | GFLOPs/     |
|------------|-------------|-------------|-------------|-------------|
|            | %           | %           | M           | G           |
| YOLOv11s   | 82.4        | 52.1        | 9.41        | 21.3        |
| MHAF-YOLO  | 80.5        | 50.2        | 7.42        | 26.7        |
| MAF-YOLO   | 82.8        | 49.6        | 8.51        | 25.2        |
| Mamba-YOLO | 82.2        | 50.6        | <b>5.66</b> | <b>12.3</b> |
| Hyper-YOLO | 83.6        | 53.7        | 13.52       | 33.8        |
| RTDETR-18  | 84.2        | 55.0        | 19.88       | 57.0        |
| RTDETR-34  | 82.1        | 53.7        | 31.11       | 88.8        |
| STDD-YOLO  | <b>86.3</b> | <b>55.2</b> | 9.48        | 22.3        |






图 8 不同算法可视化结果对比

Fig. 8 Comparison of visualization results of different algorithms

对缺陷边缘和轮廓等高频信息感知能力不足,导致缺陷边缘定位精度低,无法准确定位整个缺陷。从第 1 组的检测结果可以看出,YOLOv11s、MHAF-YOLO、MAF-YOLO 以及 Hyper-YOLO 存在漏检的情况,而 Mamba-YOLO 与 Hyper-YOLO 在缺陷处存在多个检测框,对缺陷的边缘定位不够准确。本文算法能较好的检测此场景下的缺陷,预测框更接近真实框的位置,有效解决了缺陷边缘定位精度低、多尺度小目标检测难度大的问题。

第 2 组:巡检图像采集于低照度环境,整体画面偏暗,缺陷与背景的对比度较小,并且,光线不足导致了缺陷边缘模糊、纹理细节丢失,难以准确检测。从第 2 组的实验结果可知,MHAF-YOLO、Mamba-YOLO、Hyper-YOLO 均存在漏检的情况,RTDETR-34 存在误检的情况。YOLOv11s、MAF-YOLO、RTDETR-18 与本文算法能够在光照不足的环境下较好的完成检测任务。

第 3 组:图中高压输电线遮挡了一部分的缺陷,增加了检测难度。从第 3 组的检测结果可以看出,Hyper-YOLO、RTDETR-18、RTDETR-34 均存在误检的情况,YOLOv11s、MHAF-YOLO、Mamba-YOLO 存在漏检的情况,只有 MAF-YOLO 与本文算法检测出了部分遮挡的缺陷目标。

第 4 组:缺陷处于复杂背景中。由于背景过于复杂,且缺陷极小,导致了检测难度的增加。从第 4 组的检测结果可以看出,YOLOv11s、MHAF-YOLO、Mamba-YOLO、Hyper-YOLO、RTDETR-34 均存在不同程度的误检、漏检情况,而 MAF-YOLO、RTDETR-18 和本文算法准确的检测出了复杂背景下的微小缺陷,有效解决了复杂背景下缺陷目标显著性低导致的误检和漏检问题。

3.8 泛化实验

为验证模型的泛化性能,本文在公开遥感目标检测数据集(remote sensing object detection, RSOD)上与其他主流目标检测模型开展对比实验,以进一步评估算法的检测能力。实验结果如表 7 所示。RSOD 数据集聚焦遥感场景下的目标检测任务,具有鲜明的小目标与多尺度特性:其中 4 993 架飞机分布于 446 张图像中,单张图像平均含 11 架飞机,且密集分布,多数飞机在图像中仅由十几个像素构成,属于典型小目标;同时,1 586 个油桶、180 座立交桥及 191 个操场在各自图像中呈现从极小到较大的显著

尺度差异,同一类目标的尺度跨度覆盖多个数量级,对模型的多尺度特征捕捉与小目标识别能力构成严峻考验。

表 7 不同算法在 RSOD 数据集上的对比实验结果

Table 7 Comparative experimental results of different algorithms on RSOD dataset

| 模型         | mAP50/      | mAP50-95/   | Params/     | GFLOPs/     |
|------------|-------------|-------------|-------------|-------------|
|            | %           | %           | M           | G           |
| YOLOv11s   | 88.0        | 56.5        | 9.41        | 21.3        |
| MHAF-YOLO  | 87.2        | 52.8        | 7.42        | 26.7        |
| MAF-YOLO   | 88.7        | 54.5        | 8.51        | 25.2        |
| Mamba-YOLO | 86.7        | 55.8        | <b>5.66</b> | <b>12.3</b> |
| Hyper-YOLO | 79.8        | 55.8        | 13.52       | 33.8        |
| RTDETR-18  | 88.9        | 60.3        | 19.88       | 57.0        |
| RTDETR-34  | 87.6        | <b>61.1</b> | 31.11       | 88.8        |
| STDD-YOLO  | <b>93.2</b> | 59.2        | 9.48        | 22.3        |

由表 7 的实验结果可知,本文算法在 RSOD 数据集上对比其他主流算法有着明显的优势,其 mAP50、mAP50-95 能达到 93.2%、59.2%,取得了一个优异的成绩。综上所述,在 RSOD 公共数据集上,本文的算法较其他算法表现优异,验证了其良好的鲁棒性和泛化能力。

4 结 论

本研究针对输电线路小目标缺陷检测中存在的边缘定位精度低、多尺度特征提取能力不足以及复杂背景干扰等问题,提出了一种基于 STDD-YOLO 的目标检测算法。通过设计边缘空间特征增强模块,有效提升了缺陷边界的定位精度;提出高效多核卷积,替代传统 Bottleneck 中的标准卷积,增强了网络对多尺度小目标的特征提取能力;此外,设计的共享卷积 GN 检测头显著抑制了复杂背景干扰,降低了误检和漏检率。实验结果表明,STDD-YOLO 在平均检测精度 mAP50 和 mAP50-95 上分别较基准模型 YOLOv11s 提升了 3.9%和 3.1%,显著提高了检测精度。本文算法为复杂场景下的输电线路缺陷检测提供了有效的解决方案,能够为无人机输电线路巡检工作提供有力支持,进而有效保障电力系统的安全稳定运行。

## 参考文献

- [1] 李坤祥, 刘大明. 改进 YOLOv10 的架空输电线路多缺陷检测方法[J]. 电子测量技术, 2025, 48(9): 156-167.  
LI K X, LIU D M. Detection method of overhead transmission line defects based on improved YOLOv10[J]. Electronic Measurement Technology, 2025, 48(9): 156-167.
- [2] HAO Y P, LIANG W, WANG X Y, et al. Automatic calculation of graphic area change rate for icing overhead power line insulators based on bounding box automatic matching and grabcut contour automatic segmentation[J]. IEEE Transactions on Power Delivery, 2023, 38(4): 2821-2830.
- [3] HAO Y P, LIANG W, YANG L, et al. Methods of image recognition of overhead power line insulators and ice types based on deep weakly-supervised and transfer learning[J]. IET Generation, Transmission & Distribution, 2022, 16(11): 2140-2153.
- [4] 刘传洋, 吴一全, 刘景景. 基于视觉的输电线路金具锈蚀缺陷检测方法研究进展[J]. 仪器仪表学报, 2024, 45(3): 286-305.  
LIU CH Y, WU Y Q, LIU J J. Research progress of vision-based rust defect detection[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 286-305.
- [5] 邵瑰玮, 刘壮, 付晶, 等. 架空输电线路无人机巡检技术研究进展[J]. 高电压技术, 2020, 46(1): 14-22.  
SHAO G W, LIU ZH, FU J, et al. Research progress in unmanned aerial vehicle inspection technology on overhead transmission lines[J]. High Voltage Engineering, 2020, 46(1): 14-22.
- [6] REN SH Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6): 1137-1149.
- [7] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN [C]. IEEE International Conference on Computer Vision, 2017: 2961-2969.
- [8] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [9] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2017: 7263-7271.
- [10] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.
- [11] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. European Conference on Computer Vision. Cham: Springer International Publishing, 2016: 21-37.
- [12] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]. IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [13] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers [C]. European Conference on Computer Vision. Cham: Springer International Publishing, 2020: 213-229.
- [14] 赵霖, 王素珍, 邵明伟, 等. 基于改进 YOLOv5 的输电线路鸟巢缺陷检测方法[J]. 电子测量技术, 2023, 46(3): 157-165.  
ZHAO L, WANG S ZH, SHAO M W, et al. Improved YOLOv5-based bird's nest defect detection method for transmission lines [J]. Electronic Measurement Technology, 2023, 46(3): 157-165.
- [15] 周景, 刘心, 唐振洋, 等. SDH-DETR 轻量化绝缘子缺陷检测算法[J]. 电子测量技术, 2025, 48(11): 88-104.  
ZHOU J, LIU X, TANG ZH Y, et al. SDH-DETR lightweight insulator defect detection algorithm [J]. Electronic Measurement Technology, 2025, 48(11): 88-104.
- [16] FU Q, LIU J F, ZHANG X T, et al. A small-sized defect detection method for overhead transmission lines based on convolutional neural networks[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-12.
- [17] 刘宏志, 黄振龙, 邱彬, 等. 基于改进 YOLOv11n 的输电线路主要缺陷检测方法[J/OL]. 高电压技术, 1-12 [2025-11-06]. <https://doi.org/10.13336/j.1003-6520.hve.20241908>.  
LIU H ZH, HUANG ZH L, QIU B, et al. Major defect detection method for transmission lines based on improved YOLOv11n [J/OL]. High Voltage Engineering, 1-12 [2025-11-06]. <https://doi.org/10.13336/j.1003-6520.hve.20241908>.
- [18] 赵福生, 尼鹿帕尔·艾克木, 伊力哈木·亚尔买买提, 等. 基于 YOLOv8 的输电线路巡检算法研究[J]. 电子测量技术, 2025, 48(10): 117-126.  
ZHAO F SH, NILUPAER A, YILIHAMU Y, et al. Research on transmission line inspection algorithm based on YOLOv8 [J]. Electronic Measurement



- Technology, 2025, 48(10): 117-126.
- [19] 季星宇, 黄陈蓉, 姚军财, 等. 结合分支特征和排斥损失的绝缘子检测研究[J]. 计算机工程与应用, 2025, 61(7): 141-152.
- JI X Y, HUANG CH R, YAO J C, et al. Research on insulator detection based on branch characteristics and repulsion loss [J]. Computer Engineering and Applications, 2025, 61(7): 141-152.
- [20] 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.
- [21] 张莹, 邓华宣, 王耀南, 等. 基于多通道特征融合学习的印制电路板小目标缺陷检测[J]. 仪器仪表学报, 2024, 45(5): 10-19.
- ZHANG Y, DENG H X, WANG Y N, et al. Small defects detection of PCB based on multi-channel feature fusion learning [J]. Chinese Journal of Scientific Instrument, 2024, 45(5): 10-19.
- [22] 蔡智雯, 邱志斌, 陈瑞婷. 融合全维动态卷积与聚焦调制网络的输电线路防振锤缺陷检测模型[J/OL]. 南方电网技术, 1-9[2025-11-06]. <https://link.cnki.net/urlid/44.1643.TK.20241216.1317.013>.
- CAI ZH W, QIU ZH B, CHNE R T. Anti-vibration hammer defect detection model of transmission line based on full-dimensional dynamic convolution and focused modulation networks[J/OL]. Southern Power System Technology, 1-9[2025-11-06]. <https://link.cnki.net/urlid/44.1643.TK.20241216.1317.013>.
- [23] 易磊, 黄哲玮, 易雅雯. 改进 YOLOv8 的输电线路异物检测方法[J]. 电子测量技术, 2024, 47(15): 125-134.
- YI L, HUANG ZH W, YI Y W. Improved YOLOv8 foreign object detection method for transmission lines[J]. Electronic Measurement Technology, 2024, 47(15): 125-134.
- [24] 贾晓芬, 吴雪茹, 赵佰亭. 绝缘子自爆缺陷的轻量化检测网络 DE-YOLO[J]. 电子测量与仪器学报, 2023, 37(5): 28-35.
- JIA X F, WU X R, ZHAO B T. Lightweight detection network for insulator self-detonation defect DE-YOLO[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(5): 28-35.
- [25] YANG ZH Q, GUAN Q, YU ZH W, et al. MHAF-YOLO: Multi-branch heterogeneous auxiliary fusion YOLO for accurate object detection [J]. ArXiv preprint arXiv: 2502.04656, 2025.
- [26] YANG ZH Q, GUAN Q, ZHAO K E, et al. Multi-branch auxiliary fusion yolo with re-parameterization heterogeneous convolutional for accurate object detection [C]. Chinese Conference on Pattern Recognition and Computer Vision (PRCV). Singapore: Springer Nature Singapore, 2024: 492-505.
- [27] WANG Z Y, LI CH, XU H Y, et al. Mamba YOLO: A simple baseline for object detection with state space model[C]. AAAI Conference on Artificial Intelligence, 2025, 39(8): 8205-8213.
- [28] FENG Y F, HUANG J G, DU SH Y, et al. Hyper-YOLO: When visual object detection meets hypergraph computation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 47(4): 2388-2401.
- [29] ZHAO Y AN, LYU W Y, XU SH L, et al. DETRs beat YOLOs on real-time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2024: 16965-16974.

## 作者简介

罗毅, 博士, 教授, 主要研究方向为计算机视觉、机器人系统智能控制检测技术。

E-mail: lyphzh@ncepu.edu.cn

韩义涛(通信作者), 硕士研究生, 主要研究方向为计算机视觉。

E-mail: 3047813039@qq.com