

改进 YOLOv10n 的输电线路部件缺陷检测算法^{*}

王海群 王文科 于海峰

(华北理工大学电气工程学院 唐山 063200)

摘要: 针对输电线路巡检图像中部件缺陷检测时易受背景环境干扰、缺陷目标尺度差异大,导致检测精度较低的问题,提出一种改进 YOLOv10n 的输电线路部件缺陷检测算法。首先,利用 RepViTBlock 和 ELA 注意力机制对 C2f 重新设计,构建 ERC2f 模块,抑制背景环境干扰,增强模型特征提取能力,并减少参数冗余;其次,结合动态上采样器 DySample 和注意力尺度序列融合模块 ASF 设计 DASf 颈部结构,提升模型的多尺度特征融合能力;再次,基于多样化分支块 DBB 提出重参化共享卷积检测头 RSCD,通过共享参数减少头部参数冗余,加强特征信息的交互能力;最后,借鉴 Inner-IoU 和 WIoUv3 的思想优化 MPDIoU 损失函数为 Inner-Wise-MPDIoU,加速模型收敛过程,提高对缺陷的定位精度。实验结果表明,改进算法对输电线路部件缺陷的检测精度 mAP₅₀ 达到了 92.1%,较原算法提升了 3.4%,参数量和 GFLOPs 分别减少了 19.4%和 0.4,证明了该改进算法的有效性。

关键词: YOLOv10n;注意力机制;注意力尺度序列融合;重参化共享卷积检测头;损失函数;缺陷检测

中图分类号: TP391.4;TN919.8 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Improving the YOLOv10n algorithm for detecting defects in transmission line components

Wang Haiqun Wang Wenke Yu Haifeng

(School of Electrical Engineering, North China University of Science and Technology, Tangshan 063200, China)

Abstract: In order to solve the problem that the component defect detection in the transmission line inspection image is easily disturbed by the background environment and the defect target scale is different, resulting in low detection accuracy, an improved YOLOv10n transmission line component defect detection algorithm was proposed. Firstly, the RepViTBlock and ELA attention mechanism were used to redesign the C2f, and the ERC2f module was constructed to suppress the background environment interference, enhance the feature extraction ability of the model, and reduce the parameter redundancy. Secondly, the DASf neck structure was designed by combining dynamic upsampling DySample and attention scale sequence fusion module ASF to improve the multi-scale feature fusion ability of the model. Thirdly, based on the DBB of diversified branch blocks, a reparametric shared convolutional detection header RSCD is proposed, which reduces the redundancy of the header parameters and strengthens the interaction ability of feature information by sharing parameters. Finally, the MPDIoU loss function is optimized to Inner-Wise-MPDIoU by drawing on the ideas of Inner-IoU and WIoUv3 to accelerate the model convergence process and improve the defect positioning accuracy. The experimental results show that the accuracy of the improved algorithm for the detection of transmission line component defects reaches 92.1%, which is 3.4% higher than that of the original algorithm, and the number of parameters and GFLOPs are reduced by 19.4% and 0.4, respectively, which proves the effectiveness of the improved algorithm.

Keywords: YOLOv10n; attention mechanisms; attention scale sequence fusion; reparametric shared convolutional detection head; loss function; defect detection

0 引言

在电力系统中,输电线路部件因其关键的承载和导电

性能被广泛应用于电力传输领域,然而在长期运行中,输电线路部件会受自然环境和长时间运行负荷的共同作用下出现诸如绝缘子破损、均压环倾斜等多种缺陷,这些部件缺陷

的存在不仅会增加对输电线路的维护难度,还可能成为电力系统故障的潜在风险。因此,定期对输电线路巡检、及时检测输电线路部件缺陷对保障电力系统的安全具有重要意义。

传统的巡检方法通常依赖人工和其他辅助设备,存在安全隐患且效率较低。随着计算机视觉技术的发展,基于目标检测算法的无人机巡检方法逐渐成为输电线路巡检的重要模式,不仅有效减少了人员安全风险,还大幅提高了巡检效率^[1]。

随着深度学习技术在图像领域的发展,基于深度学习的目标检测算法已逐渐应用到各缺陷检测领域中,主要算法分为两阶段算法(如 Faster R-CNN^[2]、Mask R-CNN^[3]等)和单阶段算法(如 YOLO^[4]系列、TOOD^[5]等)。在两阶段检测算法中,翟永杰等^[6]通过在 Faster-RCNN 算法中引入迁移学习方法,提高了对复杂环境下的样本绝缘子缺陷检测精度不高的问题。蔡彪等^[7]基于 Mask R-CNN 算法,利用 ResNet101 自动提取特征,解决了传统算法不能进行缺陷的分类和分级问题。但此类算法通常参数量较大,计算复杂较高,这对部署在计算资源有限的边缘设备上不利。与之相比,以 YOLO 为代表的单阶段检测算法模型结构简单,所需计算资源较少,能较好地满足实际需求。基于 YOLO 系列算法,在不同的缺陷检测任务中,赵亚凤等^[8]通过引入 CloAttention 注意力机制和 FasterNet 结构对 YOLOv7 主干网络重构,并构建 MS-ASFF 结构,解决了钢轨细粒度缺陷难以检测的问题。王宸等^[9]基于 YOLOv5s 模型,引入 BiFPN 结构,并设计 CBAM-C3 模块,提高了对金属齿轮端面缺陷的多尺度检测能力。与此同时,在输电线路部件缺陷检测任务中,游越等^[10]在 YOLOv6 网络中引入 RepFPN 结构和自底向上的路径聚合网络提升特征表达能力,并引入 RepVGG 结构来降低计算量,提升了对多类电力部件缺陷检测的精度。吴君等^[11]在 YOLOv7 中引入 GSConv 卷积降低模型参数量,并结合全局注意力机制、MPDIoU 损失函数以及设计 NAM-C2f 模块,减少了绝缘子和均压环两种部件缺陷检测误检和漏检的发生,但参数量降低不显著,模型整体结构仍较为复杂。蓝贵文等^[12]对 YOLOv8 进行改进,在主干中引入 GSConv 和坐标注意力机制,并在颈部中嵌入可变形卷积,减少模型参数量的同时提升了绝缘子、防震锤在内的多类部件缺陷检测精度,但其多尺度检测能力仍有待提高。李毅等^[13]通过改进 YOLOv10 模型实现对鸟巢在内的输电线路异物检测,引入 MobileNetv2 作为主干网络,实现高效特征提取,并结合注意力机制和 Shape-IoU 函数提升了对遮挡目标检测能力,但模型的复杂度增大。王国国等^[14]提出一种改进的 YOLOv11 模型,引入 GhostConv、坐标注意力机制以及 SIOU 损失函数提高了绝缘子部件的缺陷检测精度,但缺陷类型较少,泛化能力不足。

上述研究成果采用不同方法虽提高了输电线路部件缺

陷检测性能,但在实际应用中仍存在挑战,不能很好满足现实需求。追求高精度时模型的参数量、计算量增多或降低程度不足,这对资源受限的设备平稳运行不利;此外,受背景环境的影响,检测时易将缺陷特征与背景特征混淆,特别是在对多类部件缺陷检测时,缺陷形状尺度不一,增加了误漏检发生的概率。为更好满足检测需求,算法需不断优化,本文旨在降低模型冗余的同时提升对多类部件缺陷检测精度,基于 YOLOv10n 模型对上述问题进行如下改进:

1) 利用 RepViTBlock 和高效的局部注意力机制(efficient local attention, ELA)对 C2f 进行改进,构建了特征提取模块 ERC2f,抑制背景环境干扰,增强模型特征提取能力,并减少模型参数冗余。

2) 结合动态上采样器 DySample 和注意力尺度序列融合模块(attentional scale sequence fusion, ASF)设计了 DASF 颈部结构,提升模型的多尺度特征融合能力。

3) 基于多样化分支块(diverse branch block, DBB)提出一种重参数化共享卷积检测头(reparameterized shared convolutional detection head, RSCD),通过共享参数减少头部参数冗余,加强特征信息的交互能力。

4) 采用 Inner-IoU 和 Wise-IoUv3 的思想优化 MPDIoU 损失函数为 Inner-Wise-MPDIoU,加速模型收敛过程,提升对输电线路部件缺陷的定位精度。

1 YOLOv10 网络结构

YOLOv10 模型提供了 n、s、m、b、l、x 六种规模的模型,用于适应多样的应用场景和需求。考虑到实际巡检中边缘设备的存储资源有限,故本文以 YOLOv10n 作为基线模型进行改进,旨在减少参数量的同时提高模型对输电线路部件缺陷的检测精度。网络结构如图 1 所示。

YOLOv10 网络结构由输入端(Input)、主干网络(Backbone)、颈部网络(Neck)和检测头(Head)构成,其整体结构与 YOLOv8 类似,在一些细节模块上有所不同,包括引入了空间与通道解耦下采样(spatial channel downsample, SCDown)、部分自注意力(partial self-attention, PSA)、大卷积核和 C2fCIB 模块,旨在以较少的计算成本提高模型的检测效率和学习能力。此外,头部使用 One-to-one Head 和 One-to-many Head 的轻量化分类头进行训练。在训练策略上,YOLOv10 采用双标签分配策略,消除了对 NMS 的需求,在不牺牲检测性能的情况下减少了推理时间。

2 改进 YOLOv10 算法

2.1 构建 ERC2f 模块

为增强模型提取缺陷特征的提取能力,提高复杂背景下对输电线路部件缺陷的检测效果,并减少模型的参数冗余。本文利用 RepViTBlock 和 ELA 注意力机制对主干网络中末尾两个 C2f 模块进行重新设计,构建了 ERC2f 模

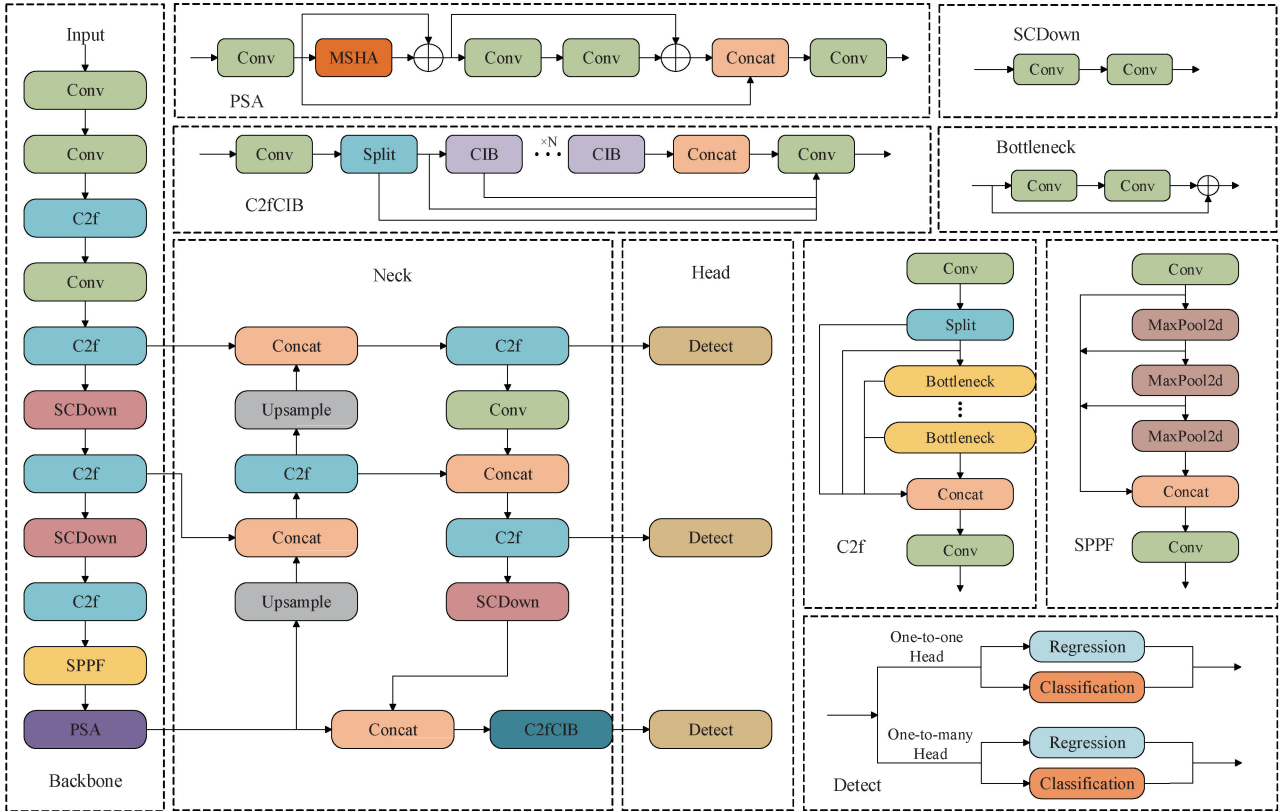


图 1 YOLOv10n 网络结构
Fig. 1 YOLOv10n network structure

块。其中,RepViTBlock^[15]是一种在 MobileNetV3 基础上引入轻量级视觉 ViTs 的高效架构设计,与 MobileNetV3 不同的是,RepViTBlock 将原来的 token mixer 和 channel mixer 进行了分离。在 token mixer 部分,RepViTBlock 利用结构重参化思想,训练时采用 1×1 卷积、 3×3 深度卷积以及残差连接,实现高效的多分支数据处理,并使用可选的通道注意力机制(squeeze-and-excitation, SE)^[16]增强局部特征捕捉能力。推理时将多分支结构合并为一个 3×3 深度卷积,以避免额外的计算开销。channel mixer 部分由两个 1×1 卷积构成,用于通道间的特征融合,该部分设计有助于处理全局特征,并通过残差连接优化梯度流动,使模块在训练和推理阶段都能保持高效的计算性能。

考虑到在 RepViTBlock 的设计中,所用的 SE 注意力机制主要集中于通道维度上的信息处理,未能涵盖空间维度上的复杂背景信息。为此,将 RepViTBlock 中的 SE 注意力机制替换为一种高效的局部注意力机制 ELA^[17],构建如图 2 所示的 ERepViTBlock 结构,以提升模型对空间信息的处理能力。引入的 ELA 注意力机制通过在空间维度上采用条带池化来获取水平和垂直方向的特征向量,使其能够利用窄核形状来捕捉长距离依赖关系,并生成各自方向上丰富的目标位置特征。之后,分别独立处理水平


和垂直方向的特征向量以生成注意力预测,再将不同方向的特征信息进行组合,从而更准确地定位感兴趣区域。

改进后的 ERC2f 模块如图 3 所示,将 C2f 中的 Bottleneck 替换为 ERepViTBlock,使模型在减少计算成本的同时,增强网络对全局和局部特征的捕捉能力,并通过 ELA 注意力机制,使模型有效处理空间维度的复杂背景信息,加强对缺陷区域的关注度,提升对输电线路部件缺陷的特征提取能力。

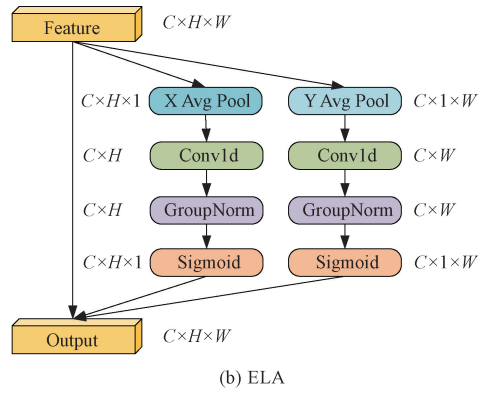
2.2 DASF 颈部结构

YOLOv10 颈部中采用的 PAN+FPN 结构旨在通过融合高层的语义信息和低层的定位信息来实现多尺度特征的融合。然而,该设计在进行多次上采样和下采样操作时,容易导致关键特征信息的丢失,降低了特征的重用率,从而影响输电线路部件缺陷的检测精度。为提高模型的多尺度特征融合能力,本文引入 ASF^[18]框架中的尺度序列特征融合(scale sequence feature fusion, SSFF)和三重特征编码器(triple feature encoder, TFE)改进颈部网络,并利用动态上采样器 DySample^[19]替换 SSFF 中的上采样,构建动态尺度序列特征融合模块 DSSFF,将改进后的颈部结构命名为 DASF。

DSSFF 结构如图 4 所示,该模块首先将来自 P3、P4 和 P5 层的特征图归一化为相同大小,经 DySample 上采样和



(a) ERepViTBlock



(b) ELA

图 2 ERepViTBlock 模块

Fig. 2 ERepViTBlock module


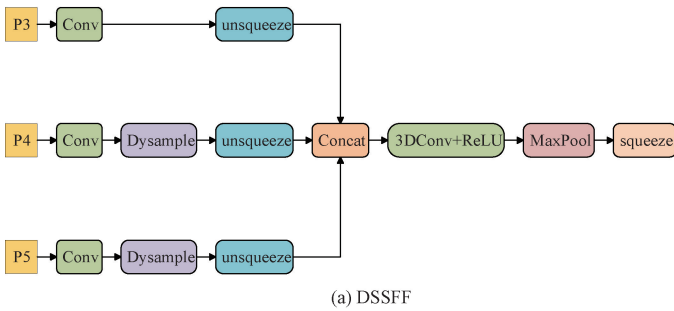


图 3 ERC2f 模块

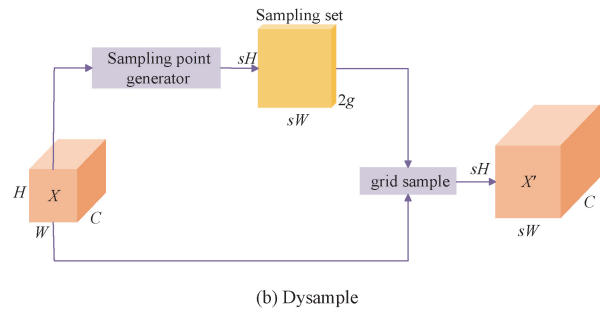
Fig. 3 ERC2f module

unsqueeze 处理后将每个特征层的特征图进行升维并进行深度维度的拼接,形成用于三维卷积的特征图,最后再通过批量归一化和 ReLU 激活函数进行处理以完成尺度序列特征的提取。其中,引入的 DySample 是一种基于动态调整采样点来实现高效的上采样,能够保留更多的空间细节信息。DSSFF 通过利用 DySample 上采样技术和堆叠不同尺度的特征图,更好地将深层特征图的高级信息与浅层特征图的详细信息结合起来,从而增强模型的多尺度信息提取能力。

TFE 结构如图 5 所示,其在编码前会调整特征通道数以确保一致性,具体来说,大尺寸和小尺寸特征图首先通过卷积模块处理来调整为相同的通道数。再采用最大池



(a) DSSFF



(b) DySample

图 4 DSSFF 模块

Fig. 4 DSSFF module

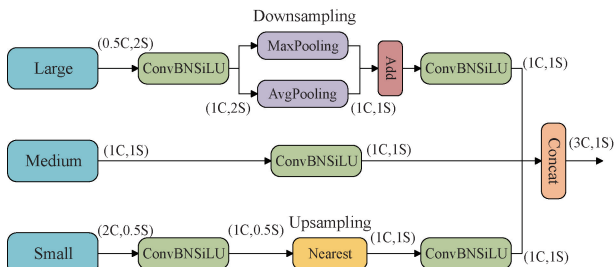


图 5 TFE 模块

Fig. 5 TFE module

化和平均池化的混合结构对大尺寸特征图进行下采样,以及采用最近邻插值方法对小尺寸特征图进行上采样。最后将尺寸相同的大、中、小 3 个特征图进行卷积处理并进行通道维度上的拼接。这不仅增强模型对输入图像空间变化和平移的鲁棒性,并且也保留了局部特征,有助于减少输电线路部件缺陷检测任务中小目标特征信息的丢失。

本文通过引入 TFE 模块和优化后的 DSSFF 模块来构建新的颈部结构 DASF,不仅结合了不同尺度图像的全局语义信息,使其对细小部件缺陷的特征信息更加敏感,还有助于提升通道间的信息交互和融合能力,能够更全面地

理解复杂的缺陷类型,增强了模型对多尺度特征的检测能力。

2.3 重参化共享卷积检测头 RSCD

输电线路部件缺陷检测中通常涉及不同尺度的目标,部件缺陷形状多样且多变。YOLOv10 使用一对一和一对多相结合的检测头进行训练,该设计虽有助于适应检测的多样性,但因每个检测头分支只接收单独的特征图作为输入,导致部件缺陷之间具有的共性特征难以在不同分支之间得到有效共享,造成部分特征信息丢失,影响检测效果。针对此问题,提出一种轻量级的重参化共享卷积检测头 RSCD。

RSCD 结构如图 6 所示,考虑到批量归一化(batch normalization, BN)存在对批量大小依赖性较强的问题,将共享卷积模块中的归一化替换为群组归一化(group normalization, GN)^[20],提升模型的稳定性。参数共享分支

由 3×3 卷积和 DBB^[21] 模块组成,用于对不同尺度的特征图进行特征提取。其中, DBB 是一种重参化模块,如图 7 所示, DBB 在训练时采用含有平均池化层和不同尺寸卷积层的多分支结构来丰富特征空间,以捕捉不同尺度和复杂的缺陷特征,增强对复杂缺陷的识别能力。推理时将多分支结构等效为单个卷积层,确保在推理阶段不会引入额外的计算成本。通过将重参化思想引入到参数共享分支中,以在保证模型轻量级的同时,使模型能够更好地在不同的层级上捕捉到丰富的上下文信息,提升特征信息的交互能力。定位分支(Conv_Reg)和分类分支(Conv_Cls)都采用一对一头和一对多头相结合的方式训练。此外,为应对检测头所检测的目标尺度不一致的问题,在定位分支之后引入 Scale 层对特征进行缩放,进一步提升模型的特征表达能力。

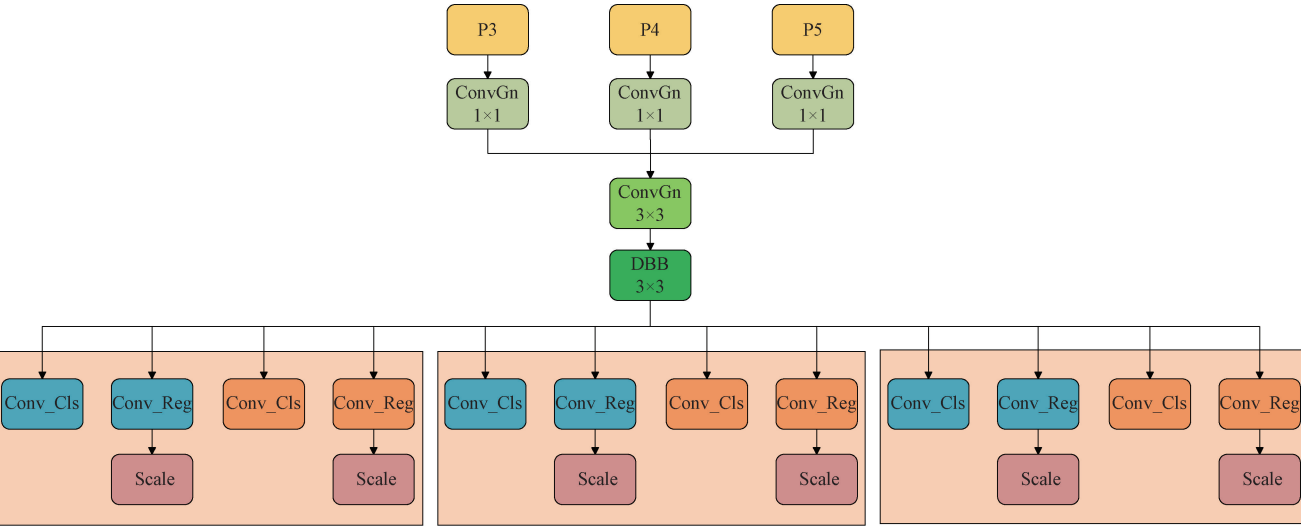


图 6 RSCD 检测头

Fig. 6 RSCD detection head

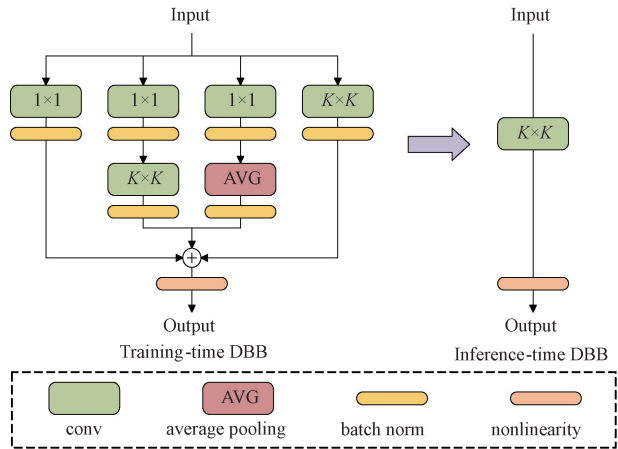


图 7 DBB 模块

Fig. 7 DBB module

2.4 Inner-Wise-MPDIoU 损失函数

YOLOv10 采用 CIoU 损失函数进行边界框回归,综合考虑了预测框与真实框的中心点距离、重叠区域和纵横比 3 个重要因素,然而, CIoU 对长宽比的定义是相对值而不是绝对值,未充分考虑目标在图像中的相对位置关系,该处理方式可能导致预测框与实际部件缺陷的形状不符,从而影响部件缺陷识别的准确性。为此,本文使用基于最小点距离的 MPDIoU^[22]作为新的边界框损失函数,其实现原理如图 8 所示。

在图 8 中,输入图像的宽和高用 w 和 h 表示,实线框为真实框, (x_1^{gt}, y_1^{gt}) 和 (x_2^{gt}, y_2^{gt}) 代表真实框的左上角和右下角坐标,虚线框为预测框, (x_1^{prd}, y_1^{prd}) 和 (x_2^{prd}, y_2^{prd}) 代表预测框的左上角和右下角坐标, d_1 和 d_2 则代表真实框与预测框之间对角线的欧式距离。通过图 8, MPDIoU 的主要计算公式如下:




图 8 MPDIoU 实现原理

Fig. 8 The implementation principle of MPDIoU

$$MPDIoU = IoU - \frac{d_1^2}{w^2 + h^2} - \frac{d_2^2}{w^2 - h^2} \quad (1)$$

$$L_{MPDIoU} = 1 - MPDIoU \quad (2)$$

式中: L_{MPDIoU} 代表 MPDIoU 损失函数, IoU 代表预测框和真实框之间的交并比。

MPDIoU 的设计通过最小化预测框和真实框之间的左上角与右下角的距离,不仅简化了两个边界框之间的相似性比较,还能够有效灵活适应重叠或非重叠的边界框回归,这有助于更准确地描述输电线路部件在图像中的相对位置关系,从而提高部件缺陷的识别效果。

考虑到输电线路部件缺陷检测任务中一些低质量的标注边框会影响检测效果的问题,引入 Inner-IoU^[23] 和 Wise-IoUv3^[24] 的思想对 MPDIoU 作出进一步优化,提升

收敛速度的同时减少低质量锚框带来的负面梯度影响。其中, Inner-IoU 是一种基于辅助边界框的边界框回归损失, 对于不同高低的 IoU 样本, 通过控制缩放因子比率调整不同尺度的辅助边界框来计算损失, 有助于提供更多的调整空间并加速边界框回归。Wise-IoUv3 则利用梯度增益分配策略, 对离群度较大的锚框分配较小的梯度增益, 以减少低质量锚框带来的负面梯度影响。将改进后的损失函数命名为 Inner-Wise-MPDIoU, 其定义如下:

$$inter = ((\min(b_r^{gt}, b_r) - \max(b_l^{gt}, b_l)) \times ((\min(b_b^{gt}, b_b) - \max(b_i^{gt}, b_i))) \quad (3)$$

$$\begin{aligned} union &= (\mathfrak{w}^{gt} \times h^{gt}) \times (ratio)^2 + (\mathfrak{w} \times h) \times (ratio)^2 - \\ inter & \end{aligned} \quad (4)$$

$$IoU_{\text{inner}} = \frac{\text{inter}}{\text{union}} \quad (5)$$

$$r = \frac{\beta}{\delta a^{\beta-\delta}} \quad (6)$$

$$L_{inner-wise-MPDIoU} = r \times (L_{MPDIoU} + IoU - IoU^{inner}) \quad (7)$$

式中: $b_r^{gt}, b_l^{gt}, b_b^{gt}, b_t^{gt}$ 分别代表真实边界框 4 个点的坐标, b_r, b_l, b_b, b_t 分别代表预测边界框 4 个点的坐标, w_{gt}, h_{gt}, w, h 分别代表真实框与预测框的宽度和高度, $ratio$ 为用来调整辅助边界框大小的缩放因子比率, r 为 Wise-IoUv3 中的非单调聚焦系数, 用于动态调节低质量样本对梯度的贡献。

通过上述改进得到最终改进的 YOLOv10n 网络结构如图 9 所示。

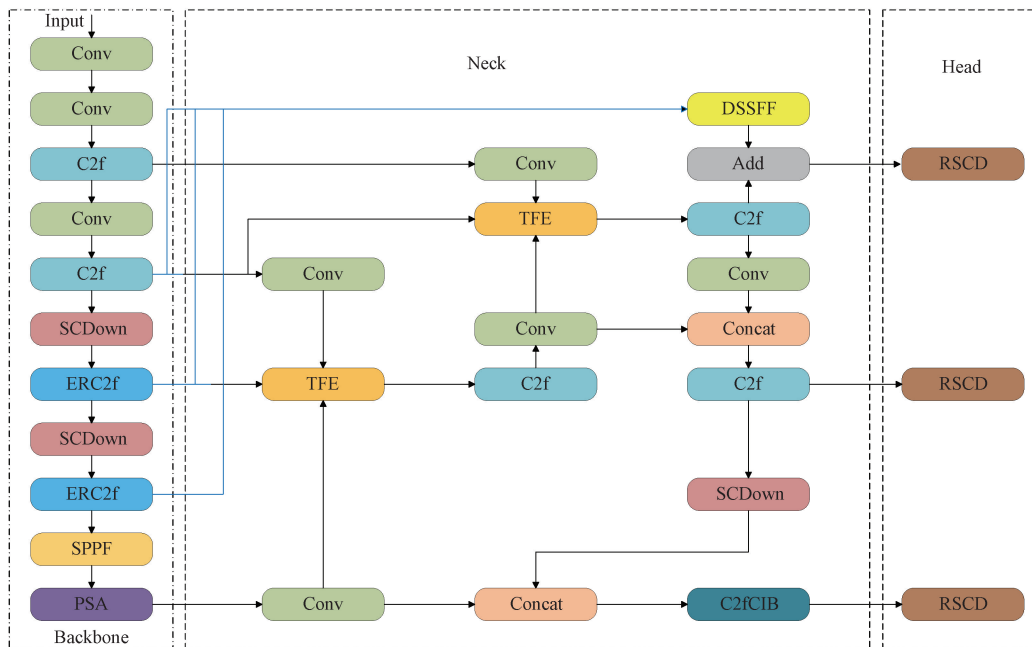


图 9 改进后的 YOLOv10n 网络结构

Fig. 9 Improved YOLOv10n network structure

3 实验结果分析

3.1 数据集介绍

本文实验使用的输电线路部件缺陷数据图像为无人机巡检架空输电线路拍摄得到,共含有 1 606 张图像,包括荒地、树林、楼房等不同背景环境下的输电线路巡检图像,涵盖绝缘子破损、绝缘子自爆、绝缘子闪络、鸟巢、均压环倾斜、防震锤脱落共 6 个缺陷检测类别,缺陷类别如图 10 所示。为防止因图像数量较少导致模型在实验时出现过拟合现象,通过调整亮度、水平旋转、引入掩码、图像雾化等方法对数据集中的图像进行数据增强,最终得到 9 130 张图像。采用 Labellmg 工具对图像进行标注,按照 7 : 2 : 1 的比例划分为训练集、验证集和测试集进行实验。

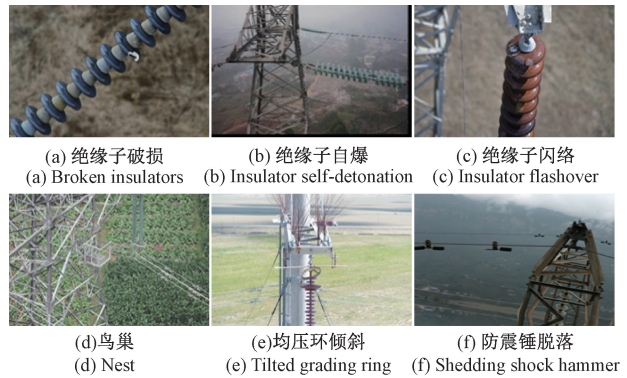


图 10 缺陷类别

Fig. 10 Defect category

3.2 实验环境

本文模型训练过程基于 PyTorch 深度学习框架,将实验训练批次(epoch)设为 250 次,批处理大小(batch)设为 32,初始学习率设为 0.01,图像输入尺寸为 640×640,训练时开启 Mosaic 数据增强,利用 SGD 优化器进行参数优化。实验平台的操作环境如表 1 所示。

表 1 实验环境

Table 1 Experimental environment

名称	参数
操作系统	Ubuntu 20.04
GPU	RTX 4090
CPU	16 vCPU Intel® Xeon® Platinum 8352V CPU @ 2.10 GHz
显存	24 GB
编程语言	Python3.8
深度学习框架	PyTorch 1.11.0+Cuda 11.3

3.3 评价指标

实验以准确率(precision,P)、召回率(recall,R)、平均精度均值(mean average precision,mAP)、浮点计算量(GFLOPs)和模型参数量(Params)作为评价指标,相关计

算公式如式(8)~(11)所示。

$$P = \frac{TP}{TP + FP} \tag{8}$$

$$R = \frac{TP}{TP + FN} \tag{9}$$

$$AP = \int_0^1 P(r)dr \tag{10}$$

$$mAP = \frac{\sum_{i=0}^n AP_{(i)}}{n} \tag{11}$$

式中:TP 表示模型正确检测出的目标;FP 表示模型错误检测出的非目标;FN 表示模型未能检测出的实际目标,AP 表示 P-R 曲线下的面积,用于衡量特定类别目标检测的准确性,mAP 是所有类别 AP 的平均值,mAP50 则为 IoU 阈值为 0.5 时的 mAP。

3.4 ERC2f 模块引入不同注意力机制对比

为验证本文 ERC2f 模块中 ERepViTBlock 的有效性,首先,在 C2f 中引入不含注意力机制的 RepViTBlock 模块,并与原模型进行实验对比,以验证引入 RepViTBlock 模块的有效性。其次,为验证在 C2f 中引入含有 ELA 注意力机制的 RepViTBlock 模块对模型检测性能的优越性,选取 SE、MPCA (multipath coordinate attention)、EMA (exponential moving aver-age)、MLCA(multi-level channel attention)和 CPCA(channel prior convolutional attention)等注意力机制引入到 RepViTBlock 的相同位置进行对比,实验结果如表 2 所示。

表 2 注意力机制对比结果

Table 2 Comparison of attention mechanisms

模块	mAP50/%	Params/10 ⁶	GFLOPs
基线	88.7	2.27	6.5
C2f+RepViTBlock	89.1	1.93	6.0
+SE	89.6	1.94	6.0
+MPCA	89.7	2.05	6.0
+EMA	89.4	1.93	6.0
+MLCA	88.9	1.93	6.0
+CPCA	89.2	1.99	6.2
+ELA	91.0	2.10	6.0

由表 2 可知,在 C2f 中引入不含注意力机制的 RepViTBlock 模块后,较原始模型在参数量和浮点运算次数 GFLOPs 均减少的情况下,mAP50 提升了 0.4%,证明了引入 RepViTBlock 模块的有效性。在此基础上分别引入不同注意力机制后,较原始模型在 mAP50 方面均有不同程度的提升,且参数量和浮点运算次数 GFLOPs 均小于原模型,其中,ELA 注意力机制表现最佳,虽参数量较其他注意力机制有所增多,但 mAP50 值显著优于其他注意力机制,mAP50 达到了 91%,较原始模型提升了 2.3%,证明

了ELA注意力机制的优越性,说明本文改进的ERC2f模块能在保持模型轻量化的同时,还能有效提高模型的检测精度。

3.5 损失函数对比

为验证Inner-Wise-MPDIoU损失函数的优势,在实验环境相同的条件下,将CIoU、EIoU^[25]、SIoU^[26]、WIoUv3、MPDIoU、Wise-MPDIoU与Inner-Wise-MPDIoU损失函数进行实验对比,评估不同损失函数对模型检测效果的影响,实验结果如表3所示。

表3 损失函数对比结果
Table 3 Comparison of loss functions

损失函数	P/%	R/%	mAP50/%
CIoU	92.3	82.8	88.7
EIoU	90.6	82.4	89.4
SIoU	91.1	82.8	89.4
WIoUv3	93.2	83.6	90.1
MPDIoU	92.5	83.8	89.6
Wise-MPDIoU	92.5	84.1	90.4
Inner-Wise-MPDIoU	93.4	84.1	90.5

由表3可知,与原YOLOv10采用的CIoU损失函数相比,在引入上述的各种损失函数后,除EIoU的精确率和召回率分别降低1.7%和0.4%以及SIoU的精确率降低1.2%外,其他损失函数的检测性能均有不同程度的提升,其中,基于MPDIoU损失函数同时引入Wise-IoUv3和Inner-IoU思想的Inner-Wise-MPDIoU提升最为明显,其在精确率、召回率和mAP50方面均表现最佳,较原始模型分别提升了1.1%、1.3%、1.8%。Inner-Wise-MPDIoU损失函数与传统的MPDIoU相比,精确率、召回率和mAP50分别提升了0.9%、0.3%、0.9%,与仅引入Wise-IoUv3思想的Wise-MPDIoU相比,在召回率不变的情况下精确率和mAP50分别提升了0.9%、0.1%。实验结果表明,本文改进的Inner-Wise-MPDIoU损失函数对输电线路部件缺陷的检测效果要优于其他损失函数,验证了Inner-Wise-MPDIoU损失函数的优越性。

3.6 消融实验

为验证改进算法的有效性,本文以原YOLOv10n网络作为基线模型,依次引入对应的改进模块进行消融实验,实验结果如表4所示,其中“√”表示采用对应的改进模块。

表4 消融实验结果
Table 4 Ablation test results

实验	RSCD	Inner-Wise-MPDIoU	ERC2f	DASF	P/%	R/%	mAP50/%	Params/10 ⁶	GFLOPs
基线					92.3	82.8	88.7	2.27	6.5
1	√				92.3	80.9	89.6	1.94	6.2
2		√			93.4	84.1	90.5	2.27	6.5
3			√		92.7	84.0	91.0	2.10	6.0
4				√	92.3	82.9	89.3	2.32	7.0
5	√	√			92	83.4	90.5	1.94	6.2
6	√	√	√		93	83.3	91.5	1.78	5.7
7	√	√	√	√	92.2	85.4	92.1	1.83	6.1

由表中的前4组实验结果可知,单独引入的对应改进模块较基线模型mAP50均有着不同程度的提升,其中,引入改进的ERC2f模块(替换主干网络后两个C2f模块为ERC2f模块)使模型mAP50提升最为显著,较基线模型提升了2.3%。在参数量和GFLOPs方面,引入改进的ERC2f模块和重参化共享卷积检测头RSCD较基线模型均有减少,这说明上述两处改进均能够使模型在提升检测精度的同时还能保持轻量化的性能。在准确率和召回率方面,引入的Inner-Wise-MPDIoU损失函数相比其他单独引入的改进模块提升最优,较基线模型准确率和召回率分别提升了1.1%和1.3%。在验证完单独引入改进模块的作用后,通过后3组实验依次叠加每种改进策略来验证4种改进模块组合后对模型检测性能的影响,其中,实验5是将RSCD检测头和Inner-Wise-MPDIoU损失函数同时引入到模型中,较基线模型mAP50提升了1.8%,与单独

引入Inner-Wise-MPDIoU损失函数相比,在保持mAP50不变的情况下参数量和GFLOPs均得到减少。实验6是在实验5的基础上引入改进的ERC2f模块,较基线模型mAP50提升了2.8%,且参数量和GFLOPs得到了进一步减少。实验7是在实验6基础上引入颈部结构DASF的最终改进模型,虽在参数量和GFLOPs方面不如前者,但mAP50较前者提升了0.6%。与基线模型相比,改进模型虽在准确率方面略微降低了0.1%,但在召回率和mAP50方面分别提升了2.6%和3.4%,且模型参数量和GFLOPs均有明显减少。综上所述,实验7的综合检测性能最佳,证明了本文改进算法的有效性。

3.7 对比实验

为验证本文改进算法对输电线路部件缺陷检测的优越性,将改进算法与主流的两阶段检测算法(Faster-RCNN、Mask-RCNN、Cascade-RCNN)、单阶段检测算法

(TOOD、YOLOv5n、YOLOX-tiny、YOLOv7-tiny、YOLOv8n、YOLOv9-t、YOLOv10n) 以及文献[12]、文献[13]、文献[14]近期研究者提出的改进算法在本文数据集上进行实验对比,实验结果如表 5 所示。由实验结果可知,与两阶段检测算法 Faster-RCNN、Mask-RCNN、Cascade-RCNN 相比,改进算法在 mAP50 方面分别提升了 7.3%、4.3%、6.5%。与单阶段检测算法 TOOD 及 YOLO 系列相比,改进算法在 mAP50 方面分别提升了 25.2%、4.1%、7%、19.8%、3.4%、3.9%、3.4%。与文献[12]、文献[13]、文献[14]近期所提出的改进算法相比,改进算法在 mAP50 方面分别提升了 2.4%、1.4%、1.4%。在模型参数量和 GFLOPs 方面,改进算法小于除 YOLOv5n 以外的其他检测算法。综上所述,本文改进算法较其他经典检测算法和近期提出的改进算法相比,在保持低参数量和 GFLOPs 的同时检测精度达到了最佳,较好地平衡了模型的计算成本和检测精度,验证了本文改进算法的优越性。

3.8 实验结果可视化分析

为更直观地验证本文改进算法对输电线路部件缺陷的检测效果,将其与文献[12]、文献[13]、文献[14]中的算法以及 YOLOv10n 算法进行可视化对比,从测试集中选取

表 5 对比实验结果

算法	mAP50/%	Params/ 10^6	GFLOPs
Faster-RCNN	84.8	41.15	206.69
Mask-RCNN	87.8	44.17	260.14
Cascade-RCNN	85.6	68.94	234.48
TOOD	66.9	31.98	184.4
YOLOv5n	88.0	1.77	4.2
YOLOX-tiny	85.1	5.03	18.94
YOLOv7-tiny	72.3	6.02	13.10
YOLOv8n	88.7	3.01	8.1
YOLOv9-t	88.2	2.62	10.7
YOLOv10n	88.7	2.27	6.5
文献[12]	89.7	7.30	27.99
文献[13]	90.7	4.40	13.2
文献[14]	90.7	2.30	6.6
本文算法	92.1	1.83	6.1

包括丛林、荒地、雪地、雾天和低光照不同背景环境下的输电线路巡检图像进行比较,检测结果对比如图 11 所示,其中第 1 行的红色框是缺陷所处的真实位置,第 2~6 行是不同算法的检测结果。




图 11 不同算法检测效果对比

Fig. 11 Comparison of detection effects of different algorithms

由图可知,在图11(a)丛林场景中,改进算法对被遮挡鸟巢的识别较其他算法具有更高的检测精度,在图11(b)荒地场景中,文献[12]算法对绝缘子闪络的识别出现了漏检,文献[14]算法则多识别出了两个闪络缺陷,出现误检,在图11(c)雪地场景中,YOLOv10n模型、文献[13]算法、文献[14]算法对绝缘子破损的检测均出现漏检情况,在图11(d)、(e)中的雾天和低光照场景中,YOLOv10n模型检测均压环倾斜时出现漏检,检测防震锤脱落时多识别出了一个目标,出现误检。综上,其他检测算法检测时均出现了不同程度的误检或漏检,与之相比,本文改进算法在不同的检测场景中,除具有更高的检测精度外,还有效改善了缺陷检测时的误检和漏检情况,这说明本文改进算法在处理复杂背景信息时具有优势,且对尺度不同的缺陷有较好地识别能力,验证了本文改进算法在复杂环境下的鲁棒性,能够适应不同场景下的缺陷检测任务。

4 结 论

针对输电线路巡检图像中部件缺陷检测易受背景环境干扰、缺陷目标尺度差异大,导致检测精度较低的问题,本文基于YOLOv10n模型进行了改进,首先,利用RepViTBlock和ELA注意力机制构建了ERC2f模块,减少无关背景信息的干扰,增强模型的特征提取能力,并降低模型参数量;其次,结合动态上采样器DySample和注意力尺度序列融合模块ASF设计了DASF颈部结构,使模型的多尺度特征融合能力得到提升;再次,基于多样化分支块DBB提出重参化共享卷积检测头RSCD,通过共享参数减少头部参数冗余,并加强特征信息的交互能力;最后,借鉴Inner-IoU和WIoUv3的思想优化MPDIoU损失函数为Inner-Wise-MPDIoU,加速模型收敛过程,提高对缺陷的定位精度。实验结果表明,改进后的YOLOv10n模型能够有效检测出输电线路部件缺陷,较原始模型mAP50提升了3.4%,参数量和GFLOPs分别减少了19.4%和0.4,在模型计算量和检测精度方面均有优势,为提升输电线路巡检的自动化水平提供了有力支持。

参考文献

- [1] 葛召,李洪文,刘海峰,等.基于YOLO-GSS的输电线路边缘端实时缺陷检测方法[J].高电压技术,2025,51(2):669-677.
- [2] 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.
- [3] HE K M, GKIOXARI G, DOLLAR P, et al. Mask R-CNN [C]. IEEE International Conference on Computer Vision, 2017:2961-2969.
- [4] DIWAN T, ANIRUDH G, TEMBHURNE J V. Object detection using YOLO: Challenges, architectural successors, datasets and applications[J]. Multimedia Tools and Applications, 2023, 82(6): 9243-9275.
- [5] FENG CH J, ZHONG Y J, GAO Y, et al. Toood: Task-aligned one-stage object detection [C]. 2021 IEEE/CVF International Conference on Computer Vision (ICCV), IEEE Computer Society, 2021: 3490-3499.
- [6] 翟永杰,胡哲东,白云山,等.融合迁移学习的绝缘子缺陷分级检测方法[J].电子测量技术,2023,46(6): 23-30.
- [7] ZHAI Y J, HU ZH D, BAI Y SH, et al. Integrating transfer learning for insulator defect grading detection[J]. Electronic Measurement Technology, 2023, 46(6): 23-30.
- [8] 蔡彪,沈宽,付金磊,等.基于Mask R-CNN的铸件X射线DR图像缺陷检测研究[J].仪器仪表学报,2020, 41(3):61-69.
- [9] CAI B, SHEN K, FU J L, et al. Research on defect detection of X-ray DR images of casting based on Mask R-CNN[J]. Chinese Journal of Scientific Instrument, 2020, 41(3): 61-69.
- [10] 赵亚凤,宋文华,刘晓璐,等.基于改进YOLOv7的钢轨缺陷检测方法[J].电子测量技术,2024,47(20): 177-185.
- [11] ZHAO Y F, SONG W H, LIU X L, et al. Improved rail defect detection algorithm of YOLOv7 [J]. Electronic Measurement Technology, 2024, 47(20): 177-185.
- [12] 王宸,杨帅,周林,等.基于自适应多尺度特征融合网络的金属齿轮端面缺陷检测方法研究[J].电子测量与仪器学报,2023,37(10):153-163.
- [13] WANG CH, YANG SH, ZHOU L, et al. Research on metal gear end-face defect detection method based on adaptive multi-scale feature fusion network [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(10): 153-163.
- [14] 游越,伊力哈木·亚尔买买提,吐松江·卡日.基于YOLOv6的输电线路电力部件识别及缺陷检测算法研究[J].高压电器,2024,60(5):194-205,213.
- [15] YOU Y, YILIHAMU Y, TUSONGJIANG K. Research on power component identification of transmission line and defect detection algorithm based

- on YOLOv6 [J]. High Voltage Apparatus, 2024, 60(5):194-205,213.
- [11] 吴君,韩翀,王新良.改进 YOLOv7 的绝缘子与均压环缺陷检测方法[J/OL]. 光子·激光, 1-14[2025-01-27]. <http://kns.cnki.net/kcms/detail/12.1182.O4.20240920.1407.016.html>.
- WU J, HAN CH, WANG X L. Defect detection method of insulator and grading ring based on improved YOLOv7[J/OL]. Journal of Optoelectronics·Laser, 1-14 [2025-01-27]. <http://kns.cnki.net/kcms/detail/12.1182.O4.20240920.1407.016.html>.
- [12] 蓝贵文,徐梓睿,任新月,等.基于 YOLOv8n 改进的航拍输电线路图像多类电力部件检测算法[J]. 测绘通报,2024(9):38-43,49.
- LAN G W, XU Z R, REN X Y, et al. An improved algorithm for detecting components of power transmission lines from aerial inspection images[J]. Bulletin of Surveying and Mapping, 2024 (9): 38-43,49.
- [13] 李毅,徐慧英,朱信忠,等. TFD-YOLO: 基于 YOLOv10 改进的输电线异物检测算法[J/OL]. 浙江师范大学学报(自然科学版), 1-10 [2025-01-27]. <https://doi.org/10.16218/j.issn.1001-5051.2025.034>.
- LI Y, XU H Y, ZHU X ZH, et al. TFD-YOLO: An improved algorithm for foreign object detection on transmission lines based on YOLOv10 [J/OL]. Journal of Zhejiang Normal University (Natural Sciences), 1-10 [2025-01-27]. <https://doi.org/10.16218/j.issn.1001-5051.2025.034>.
- [14] 王国国,龚小玉,袁发庭.基于 YOLO11s 绝缘子缺陷检测的轻量化算法[J/OL]. 重庆工商大学学报(自然科学版), 1-10 [2025-01-27]. <http://kns.cnki.net/kcms/detail/50.1155.N.20241226.1428.003.html>.
- WANG G G, GONG X Y, YUAN F T. Lightweight algorithm based on YOLO11s insulator defect detection[J/OL]. Journal of Chongqing Technology and Business University(Natural Science Edition), 1-10[2025-01-27]. <http://kns.cnki.net/kcms/detail/50.1155.N.20241226.1428.003.html>.
- [15] WANG AO, CHEN H, LIN Z J, et al. Repvit: Revisiting mobile cnn from vit perspective[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024:15909-15920.
- [16] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. IEEE Conference on Computer Vision and Pattern Recognition,2018:7132-7141.
- [17] XU W, WAN Y. ELA: Efficient local attention for deep convolutional neural networks [J]. ArXiv preprint arXiv:2403.01123, 2024.
- [18] KANG M, TING CH M, TING F F, et al. ASF-YOLO: A novel YOLO model with attentional scale sequence fusion for cell instance segmentation [J]. Image and Vision Computing, 2024,147:105057.
- [19] LIU W Z, LU H, FU H T, et al. Learning to upsample by learning to sample [C]. IEEE/CVF International Conference on Computer Vision, 2023: 6027-6037.
- [20] WU Y X, HE K M. Group normalization [C]. European Conference on Computer Vision (ECCV), 2018:3-19.
- [21] DING X H, ZHANG X Y, HAN J G, et al. Diverse branch block: Building a convolution as an inception-like unit [C]. IEEE/CVF Conference on computer vision and Pattern Recognition,2021:10886-10895.
- [22] MA S L, XU Y. MPDIoU: A loss for efficient and accurate bounding box regression[J]. ArXiv preprint arXiv: 2307.07662,2023.
- [23] ZHANG H, XU C, ZHANG SH J. Inner-IoU: More effective intersection over union loss with auxiliary bounding box [J]. ArXiv preprint arXiv: 2311.02877,2023.
- [24] TONG Z J, CHEN Y H, XU Z W, et al. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism [J]. ArXiv preprint arXiv: 2301.10051, 2023.
- [25] ZHANG Y F, REN W Q, ZHANG ZH, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506:146-157.
- [26] GEVORGYAN ZH. SIoU loss: More powerful learning for bounding box regression [J]. ArXiv preprint arXiv:2205.12740,2022.

作者简介

王海群,副教授,硕士,主要研究方向为智能控制与应用、深度学习。

E-mail:wanghq0604@163.com

王文科(通信作者),硕士研究生,主要研究方向为深度学习、目标检测。

E-mail:1920807580@qq.com

于海峰,博士,主要研究方向为深度学习、图像处理。