

DOI:10.19651/j.cnki.emt.2417584

SDH-DETR 轻量化绝缘子缺陷检测算法^{*}

周景 刘心 唐振洋 董晖

(华北电力大学控制与计算机工程学院 北京 102206)

摘要:为解决无人机在输电线路绝缘子巡检中目标检测算法面临的模型复杂度高、小目标缺陷检测精度不足和上下采样过程中容易造成特征丢失等挑战,本文提出了一种基于轻量化改进的RT-DETR绝缘子缺陷检测算法(SDH-DETR)。首先,以RT-DETR作为基线算法,降低优化难度并提高鲁棒性;其次,采用轻量级StarNet作为主干网络,在显著降低模型复杂度的同时提升特征提取能力;接着,引入DySample动态上采样模块,通过基于采样点的自适应上采样方法,有效减少细节丢失与图像失真;最后,利用Harr小波变换下采样模块(HWD),实现低频与高频信息的高效融合,抑制复杂背景干扰并增强对小目标的检测能力。在复杂背景数据集上的验证实验表明,SDH-DETR的平均精度达98.5%,较基线算法提升0.9%,参数量和计算量分别减少43%和46.1%,检测速度达78.6 fps。这表明该算法在保证高准确性的同时,实现了轻量化设计,满足了输电线路巡检对效率和性能的实际需求。

关键词:输电线路;目标检测;绝缘子缺陷检测;复杂背景;轻量化;RT-DETR算法

中图分类号:TP391.41;TM75;TN919.8 **文献标识码:**A **国家标准学科分类代码:**520.6040

SDH-DETR lightweight insulator defect detection algorithm

Zhou Jing Liu Xin Tang Zhenyang Dong Hui

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

Abstract: In order to solve the challenges faced by target detection algorithms of UAVs in transmission line insulator inspection, such as high model complexity, insufficient accuracy in detecting defects of small targets, and easy feature loss during up and down sampling, this paper proposes a lightweight improved RT-DETR insulator defect detection algorithm based on lightweight improvement (SDH-DETR). Firstly, RT-DETR is used as the baseline algorithm to reduce the optimisation difficulty and improve the robustness; secondly, lightweight StarNet is used as the backbone network to improve the feature extraction capability while significantly reducing the model complexity; next, the DySample dynamic upsampling module is introduced to efficiently reduce the detail loss and image distortion by the adaptive upsampling method based on the sampling points. Finally, the Harr wavelet transform downsampling module (HWD) is used to achieve efficient fusion of low-frequency and high-frequency information, suppressing complex background interference and enhancing the detection of small targets. The validation experiments on the complex background dataset show that the average accuracy of SDH-DETR reaches 98.5%, which is 0.9% higher than the baseline algorithm, the number of parameters and computation are reduced by 43% and 46.1%, respectively, and the detection speed reaches 78.6 fps. This indicates that the algorithm achieves a lightweight design while ensuring high accuracy, and meets the practical demands for efficiency and performance in transmission line inspection.

Keywords: transmission lines; target detection; insulator defect detection; complex background; lightweight; RT-DETR algorithm

0 引言

绝缘子是输电线路中的重要核心组件,其主要作用是提供绝缘功能并悬挂和固定导线,对于电力系统的安全稳

定运行具有关键意义^[1]。为确保输电线路的正常运行,绝缘子的状态监测与缺陷检测已成为电力巡检工作的重点^[2]。然而,许多高压输电线路位于人烟稀少的山地、河流等偏远区域,传统人工巡检模式不仅耗时较长、效率较低,

收稿日期:2024-12-19

*基金项目:国家自然科学基金(52179014)项目资助

还需要耗费大量的人力物力^[3]。近年来,无人机技术的蓬勃发展,使基于无人机的绝缘子缺陷检测逐步成为电力巡检的主流解决方案^[4]。与传统巡检方式相比,无人机巡检不仅大幅降低了成本,同时也显著提高了巡检效率^[5]。

目标检测作为计算机视觉领域的核心研究方向之一,近年来受到了广泛关注^[6]。随着深度学习技术的快速进步,目标检测算法逐渐由依赖人工特征设计的方法,转型为通过深度卷积神经网络(CNN)自动提取高级图像特征,从而实现更精准的目标识别。伴随检测精度要求的提高和任务复杂性的增长,出现了如 YOLOX^[7]、YOLOv7^[8]以及 Faster R-CNN^[9]等性能卓越的复杂网络模型。这些算法通常包含接近 100 MB 的参数量,推理速度相对较慢^[10]。在目标检测中,特征损失因上下采样操作而产生,是影响检测性能的主要难点之一。尽管下采样技术(如步幅卷积和池化)能减少计算开销,但会削弱缺陷小目标的细节特征,降低检测精度。RT-DETR 采用步长为 2 的卷积下采样易导致细节丢失、感受野受限及高频特征混叠,而传统池化方法在保留高频信息方面亦存在不足。上采样用于恢复分辨率以增强细节捕捉,但传统方法(如双线性插值、最近邻插值)难以保留细节信息。RT-DETR 的最近邻插值未充分利用语义信息,导致感受野有限、特征模糊和定位误差,影响小目标缺陷检测效果。

文献[11]提出了一种融合全卷积网络(FCN)与 YOLOv3 的双阶段协同深度学习方法用于绝缘子故障检测。具体来说,第一阶段利用 FCN 对目标绝缘子进行初步分割,从而有效削弱背景干扰;第二阶段则通过 YOLOv3 算法进一步检测故障,提高了检测精度。而文献[12]则在 Cascade R-CNN 中融入了 RoI-Align 方法,有效缓解小目标漏检的难题,并显著提升了检测性能,在与 Faster R-CNN 的对比中,某些优化方案显示出更优的性能。针对航拍图像中背景复杂且小目标比例较低的挑战,文献[13]对 Mask R-CNN 进行了优化,进而增强了其检测能力。此外,文献[14]则提出了一种级联框架,先通过 Faster R-CNN 检测到绝缘子区域,再通过人工裁剪方式得到绝缘子串图像,最终使用 U-Net 进行缺陷的识别。尽管文献[11-14]中的双阶段方法在检测精度和泛化能力方面明显优于传统方法,但其复杂的模型设计导致参数量较大,计算成本较高,从而对训练速度和检测效率产生了负面影响,仍需进一步改进。

为了满足无人机实时检测的需求,研究者开发了多种轻量化模型。文献[15]基于 GhostNet 并结合 RFB 模块对 CenterNet 进行了改进,提出了一种轻量化的特征融合网络。通过这一优化,模型的参数量从 124.61 M 减少到 64.2 M,达到了无人机边缘部署的需求。文献[16]构建了多尺度特征融合网络,针对绝缘子缺陷像素占比低、形状多变的问题,提出了有效的解决方案。文献[17]通过对 EfficientDet 算法进行改良,实现了检测精度与检测速度的

平衡。针对绝缘子缺陷检测中的目标尺度变化和种类多样问题,文献[18]设计了融合多尺度特征与注意力机制的 YOLOX-s 改进算法。文献[19]则通过引入多尺度卷积注意力机制对 YOLOv8 进行优化,在目标尺度多样、背景复杂以及样本不足的场景中显著提升了检测性能。文献[20]提出了一种基于轻量级改进 RT-DETR 的绝缘子缺陷检测算法,旨在解决传统算法难以在边缘设备上部署的问题。该方法采用轻量级 EMO 模型作为特征提取主干网络,并设计了轻量级高效混合编码器,同时引入定位信息补充分支和 DIoU 损失函数,显著降低了模型的参数量和计算复杂度,使其满足边缘部署的要求。然而,尽管该方法在轻量化设计上取得了进展,但其精度仍有所损失,未能在轻量化与检测精度之间实现理想的平衡。

尽管上述方法取得了较高的检测精度,但仍存在一定的局限性。例如,文献[15-16]的轻量化设计仍有参数量较大的问题,而文献[18-19]依赖于非极大值抑制(NMS)^[21]进行后处理,这在一定程度上增加了模型的复杂性,同时在鲁棒性方面仍需进一步研究和改进^[22]。无论是二阶段检测还是单阶段检测,大多需要经过阈值筛选和非极大值抑制两种后处理,前者为滤除低得分的检测框,后者则是滤除对同一物体的冗余响应,但都没有统一的阈值参数设定,增大网络优化的难度。为优化参数,出现了多种 DETR 变体,如 2021 年 Zhu 等^[23]提出的 Deformable DETR,将注意力机制与可变形卷积相结合,通过关注关键采样点提升对小目标的检测性能。2024 年,百度团队提出 MS-DETR^[24],采用混合监督提升训练效率,无需额外解码器分支,提高预测质量并优化计算和内存效率。然而,Deformable DETR 和 MS-DETR 忽略了颈部网络的多尺度设计。为克服这些局限性,百度团队于 2023 年提出了实时端到端检测器 RT-DETR^[22],通过去除置信度筛选和 NMS 等后处理步骤,有效提升了检测性能。相比 YOLO 系列等主流模型,RT-DETR 在检测精度和速度上均表现出显著优势。然而,其较高的计算量和参数量限制了在移动端及资源受限设备上的部署能力。此外,在复杂背景的航拍输电线路场景中,RT-DETR 对小目标检测仍存在漏检和误检现象,影响了绝缘子缺陷检测的稳定性和准确性。

针对上述问题,本文提出一种融合动态采样与小波变换的轻量级绝缘子缺陷检测算法。首先,选择无需 NMS 后处理的 RT-DETR 作为基准模型,相较于常见的使用 NMS 后处理的 YOLO^[25]系列算法,其优化难度减小、鲁棒性得到增强;其次,采用轻量级 StarNet^[26]模型作为主干网络,在增强模型特征提取能力的同时降低模型复杂度;然后,引入 DySample^[27]动态上采样模块,从采样点的角度构建上采样,改善最近邻插值法可能出现的细节丢失、锯齿状边缘和图像失真等问题;最后,引入 Haar 小波变换下采样模块(HWD)^[28],使模型能够充分利用图像的低频和高频信息并抑制复杂背景信息的干扰,增强模型对绝缘子缺陷

小目标的感知能力。实验结果表明,改进后的绝缘子缺陷检测模型在显著降低网络计算量和复杂度的同时,进一步提升了对绝缘子缺陷的检测性能。该模型不仅有效满足了输电线路绝缘子状态巡检过程中对检测准确率的高要求,同时也充分适应了边缘设备部署对轻量化的技术需求。

1 方法

1.1 RT-DETR 算法

RT-DETR 是一种基于 Transformer 架构的模型,包含 R18、R34、R50、R101、L 和 X 等版本。为了满足无人机在小目标检测任务中对复杂背景处理和模型尺寸限制的需求,本文选用 RT-DETR-R18 作为基线算法,该版本在计算开销和检测精度之间取得了良好平衡。模型的主要组成部分包括主干网络 (Backbone)、颈部混合编码器 (Neck Hybrid Encoder) 和 Transformer 解码器 (Transformer Decoder),具体结构如图 1 所示。

主干网络采用 ResNet18^[29]作为特征提取的卷积神经网络(CNN),提取最后 3 个阶段的特征并送入编码器。编码器部分包含 AIFI(基于注意力的尺度内特征交互)和 CCFM(基于 CNN 的跨尺度特征融合模块)。AIFI 主要用于高层多尺度特征的编码,强化细粒度信息;CCFM 通过卷积层构成的融合块(Fusion Block)实现多尺度特征的整合。这些融合块使用 1×1 卷积调整通道数量,并通过 RepConv 的 RepBlock 模块完成特征融合。融合后的特征经过加法合并和平坦化(Flatten)操作,最终转化为图像特征序列,具体设计如图 1。解码器阶段首先利用 IoU 感知查询选择模块(IoU-aware query selection)从编码器输出中选择部分图像特征作为初始查询。随后通过多次迭代推理与优化,生成预测的边界框和对应置信度分数,从而实现高效准确的目标检测过程。

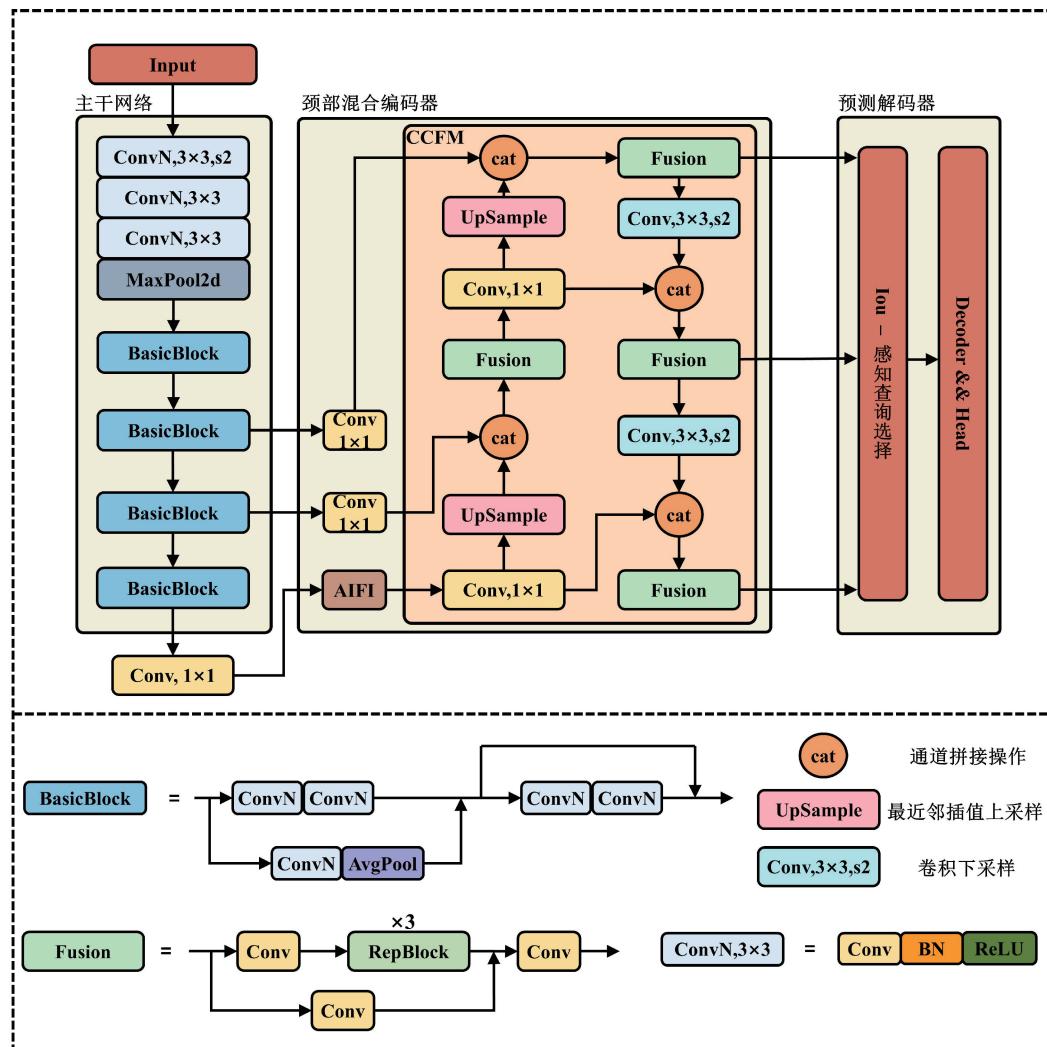


图 1 RT-DETR 模型结构

Fig. 1 RT-DETR model structure

1.2 SDH-DETR 算法

本文改进模型由主干网络(Starnet Backbone)、颈部混合编码器(Encoder)、预测解码器(Decoder)3部分构成。为解决 RT-DETR 模型的高复杂性问题,本文引入 StarNet 作为特征提取的骨干网络,保留更多判别信息,提升特征表示效率,实现了模型轻量化,使其适合无人机平

台边缘部署。此外,采用 DySample 替换原有的上采样模块,使采样点集中于目标区域,忽略背景部分,减少模型参数量。该模型还集成了 HWD 模块,能够充分利用图像的低频和高频信息,抑制复杂背景噪声,增强模型对缺陷小目标的检测能力,取代了原有的卷积下采样方法。最终,优化后的绝缘子缺陷检测模型整体结构如图 2 所示。

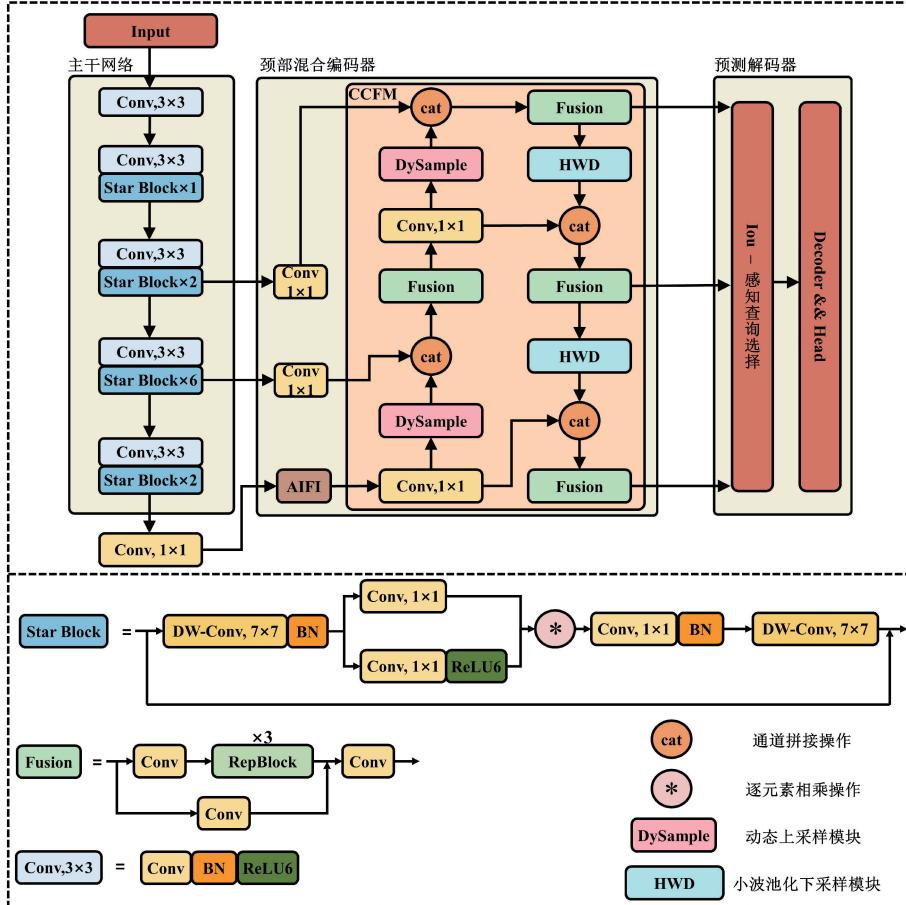


图 2 轻量化改进 RT-DETR 模型结构

Fig. 2 Structure of lightweight improved RT-DETR model

1.3 轻量化主干网络 StarNet

RT-DETR 模型的特征提取主干网络采用了 ResNet-18^[29],然而,该网络在特征提取过程中存在一定的冗余计算,导致较高的浮点运算量,从而增加了模型在硬件资源有限的无人机平台上部署的难度。为适应移动端部署需求并进一步优化模型性能,本文将原主干网络替换为 StarNet 主干网络。

针对上述问题,本文提出了一种基于 StarNet^[23]模型的优化方案。StarNet 作为一种简洁高效的网络架构,通过其独特的星形操作(即元素级乘法)显著增强了全局特征提取能力,同时避免了网络宽度的增加。具体而言,元素级乘法操作将输入映射至高维非线性特征空间,具有类似于核方法的效果,不仅提升了模型对小尺度绝缘子缺陷目标的特征表征能力,还通过简化计算流程,有效降低了

模型的参数量与计算复杂度。该改进方案显著增强了模型在资源受限环境下的部署适应性。

StarNet 采用四阶段分层架构(如图 3 左侧所示),每个阶段通过卷积层实现下采样,并使用 Star Block 模块进行特征提取。图 3 右侧详细展示了 Star Block 的架构,其流程如下:首先,特征图输入 Star Block,经过 7×7 深度卷积层(DW-Conv),高效捕捉局部特征并减少参数量。接着,通过批量归一化层^[30]稳定训练过程,加速收敛,并增强对输入扰动的鲁棒性。归一化后的数据分为两路,一路通过 1×1 点卷积层进行通道混合,实现特征的非线性变换;另一路通过 ReLU6 激活函数^[31]引入非线性,增强模型的表达能力并优化梯度流。

Star Block 的核心创新在于元素级乘法操作,通过对不同特征图的对应元素进行乘法运算,增强特征交互和融

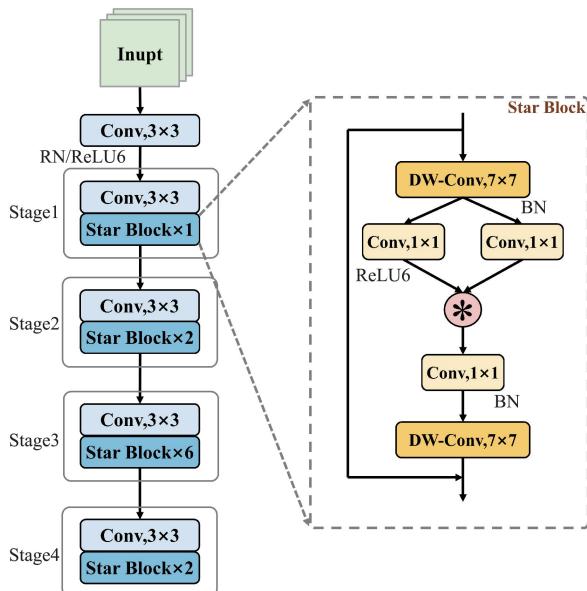


图 3 StarNet 结构

Fig. 3 StarNet structure

合能力,从而提高模型对复杂特征的捕捉能力。最终,经过第二次深度卷积和批量归一化处理,输出的特征图为后续网络层或任务提供了丰富的特征表示。实验结果表明,使用 StarNet 替换 RT-DETR 原有的特征提取主干后,不仅保持了对小尺度缺陷的高分辨率感知能力,还显著降低了模型的计算负担。

1.4 DySample 动态上采样模块

RT-DETR 在图像上采样过程中默认采用最近邻插值方法,该方法以计算简便和操作高效而著称,其基本原理是将变换后像素的灰度值直接赋值为距离其最近的输入像素的灰度值,从而实现图像的放大。然而,最近邻插值仅依赖像素点的空间位置关系,对图像内容的语义信息缺乏深入分析。因此,在处理具有复杂纹理或细节丰富的图像时,该方法往往导致细节模糊或失真,难以真实还原原始图像中的精细特征。此外,由于忽略了像素间的相关性以及图像全局信息的利用,最近邻插值容易产生伪影和锯齿效应,从而降低了重建图像的视觉质量和语义一致性,影响模型的整体性能。

为应对上述问题,本文引入了一种超轻量化且高效的动态上采样模块 DySample^[27]。DySample 通过引入偏移量机制,根据输入特征图的内容动态调整采样点的位置,从而实现位置感知的上采样操作,能够更精确地保留和重建特征图中的细节信息,显著提升模型的表现。与传统上采样方法不同,DySample 采用基于点采样的策略,无需额外的高分辨率特征输入,以简洁而高效的方式生成内容感知的上采样结果。此设计不仅在质量和精度上实现突破,还有效降低了模型的复杂性和计算成本,从而在保证性能的同时更具轻量化特性。DySample 的上采样过程如图 4

所示。

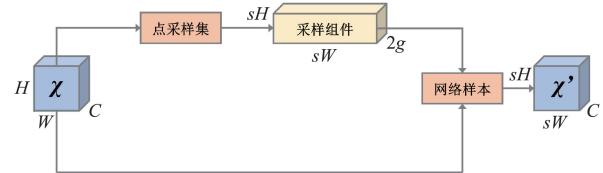


图 4 DySample 上采样流程图

Fig. 4 Sampling flowchart on DySample

给定一个 $C \times H \times W$ 的特征图 X 和一个 $2g \times sH \times sW$ 的点采样集 S ,其中 $2g$ 表示 x 和 y 坐标, $grid_sample$ 函数使用点采样集 S 中的位置对 X 重新采样,生成大小为 $C \times sH \times sW$ 的特征图 X' ,这一上采样过程如式(1)所示。

$$X' = grid_sample(X, S) \quad (1)$$

其中, X 为输入特征, X' 为上采样特征, S 为采样集。采样点生成器生成采样集 S ,给定上采样比例因子 s 和形状大小为 $C \times H \times W$ 的特征图 X ,使用输入和输出通道数为 C 和 $2gs^2$ 的线性层来生成大小为 $2gs^2 \times H \times W$ 的偏移量 O ,然后通过像素重组将其重塑为 $2g \times sH \times sW$ 。采样集 S 就是偏移量 O 与原始网格采样 G 之和,运算过程如式(2)所示。

$$S = G + O \quad (2)$$

动态范围操作过程如式(3)所示。

$$O = 0.5 \text{sigmoid}(\text{linear}_1(X)) \times \text{linear}_2(X) \quad (3)$$

首先,接收输入特征图 X ,并通过卷积操作将其映射为输出特征图 X' 。生成的输出经过 sigmoid 函数激活后,再乘以 0.5 以缩放范围参数的值。该范围参数用于调整目标的尺度,通过与偏移量相乘,并经过归一化处理,以确保尺度的精确控制。接着,利用像素重组函数对坐标进行重新排序,并将其与初始位置相加,最终获得精确的目标位置坐标。为了增强偏移的灵活性,进一步通过线性投影操作从输入特征生成逐点动态范围因子。该动态范围因子用于根据输入数据的特性动态调整偏移量,以适应不同特征分布和数据场景,从而提高模型的适应性与鲁棒性。与传统的上采样方法相比,DySample 动态上采样能够更好地保留图像中的细节信息,避免由于简单的像素复制而导致的模糊或锯齿效应。DySample 中的点采样集生成过程如图 5 所示。

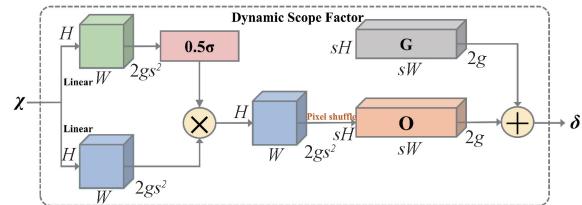


图 5 基于动态范围因子的点采样集生成过程

Fig. 5 Dynamic range factor based point sampling set generation process

1.5 Haar 小波变换下采样模块

RT-DETR 的下采样过程最初采用步长为 2 的卷积操作,尽管该方法能够有效减小特征图的尺寸,但由于特征图尺寸缩减较快,会导致大量细节信息的丢失,进而限制感受野的范围,影响模型对缺陷小目标的识别精度。小目标的显著特征通常集中于高空间频率区域,而传统降采样方法在处理这些高频信息时容易产生混叠现象^[32],导致信息失真,这一问题在缺陷小目标检测任务中尤为突出。此外,传统池化方法(如平均池化和最大池化^[33])由于未能充分保留高频信息,在应用中也存在一定的局限性。

为了解决上述问题,本文提出了一种基于小波变换的 Haar 小波变换下采样方法(HWD)^[28]。该方法通过 Haar 小波变换实现下采样,能够在保持图像细节的基础上扩大特征图的感受野,从而增强模型对全局特征的提取能力,并显著提升小目标检测的性能。相比于传统的步长卷积方法,HWD 具有更高的设计简洁性和计算效率,能够有效降低计算成本,加快训练速度,同时显著提升检测效果。由于其多尺度分析能力和可逆特性,HWD 在特征选择和信息保留方面优势突出,使模型在检测过程中保留更多关键细节信息,从而实现更高的检测准确性和鲁棒性。

HWD 模块主要由无损特征编码模块和特征表示学习模块组成(如图 6 所示)。无损特征编码模块基于 Haar 小波变换,将输入特征进行转换,降低分辨率的同时保留完整信息,确保信息无损处理。特征表示学习模块由标准卷积层、批量归一化层和 ReLU 激活函数组成,其主要作用是去除冗余特征,提取关键特征,以增强特征表示质量,为后续检测任务提供更优支持。

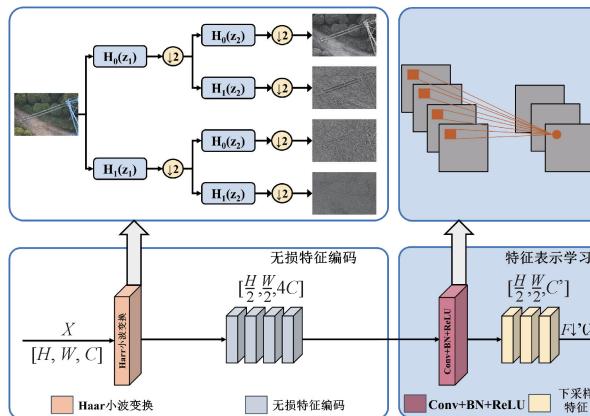


图 6 Harr 小波下采样模块结构

Fig. 6 Structure of the Harr wavelet downsampling module

HWD 模块主要包括无损特征编码块和特征学习块,其中无损特征编码块利用 Haar 小波变换对特征图进行转换和降低空间分辨率,该过程将分辨率为 $H \times W$ 的图像进行分解,利用高通滤波器 H_0 和低通滤波器 H_1 提取图像的近似信息和高频细节信息。随后,通过对近似和细节分量进行下采样操作($\downarrow 2$),生成图像在水平(H)、垂直(V)

和对角线(D)方向上的低频近似分量(A)以及细节高频分量,从而有效保留细节特征信息。Haar 小波变换的基函数和尺度函数如式(4)所示。

$$\begin{cases} \phi_1(x) = \frac{1}{\sqrt{2}}\phi_{1,0}(x) + \frac{1}{\sqrt{2}}\phi_{1,1}(x) \\ \psi_1(x) = \frac{1}{\sqrt{2}}\phi_{1,0}(x) - \frac{1}{\sqrt{2}}\phi_{1,1}(x) \end{cases} \quad (4)$$

$$\phi_{1,k}(x) = \sqrt{2^k}\phi(2^jx - k), k = 0, 1, \dots, 2^j - 1 \quad (5)$$

其中,j 和 k 表示基函数的阶。

特征学习块由卷积层、批归一化层和 ReLU 激活层组成。用于调整特征映射的通道数并尽可能过滤掉冗余信息,使后续层更高效地学习代表性特征。

计算分析:假设特征图和下采样特征图的输入大小分别为 $H \times W \times C$ 和 $H/2 \times W/2 \times C$ 。则 HWD 模块与传统跨步卷积的参数量和计算复杂度在数学上可分别表示为:

$$P_H = 4C^2, F_H = 2HWC^2 + 3.75HWC \quad (6)$$

$$P_C = 9C^2, F_C = 4.5HWC^2 - 0.25HWC \quad (7)$$

P 和 F 分别代表模型的参数量和计算复杂度。根据公式可知,跨步卷积的参数量大约是 HWD 模块的两倍,而当通道数 $C > 1$ 时,其计算开销也远高于 HWD 模块。由此可见,HWD 模块在输出更丰富细节特征的同时,实现了参数量与计算复杂度之间的良好平衡。

将 Haar 小波变换下采样引入 RT-DETR 模型,不仅降低了特征图的空间分辨率,还能更有效地保留目标的高空间频率特征,从而提升小尺度缺陷目标的检测和定位精度。这一改进降低了模型的复杂度,同时增强了模型对不同尺度缺陷的适应性和泛化能力。

2 数据集与实验设置

2.1 数据集

本实验所用数据集整合自多种公开资源,包括国家电网发布的 CPLID 数据集(248 张)^[34]、IEEE 提供的 IDID 绝缘子多缺陷数据集(1 600 张)^[35],以及第八届“泰迪杯”数据挖掘挑战赛的绝缘子数据集(33 张)。该数据集共包含 1 881 张图片,涵盖了输电线路中玻璃绝缘子、陶瓷绝缘子和复合绝缘子的不同尺寸,同时背景涉及森林、河流、建筑工地、麦田、草地和雪地等复杂环境。为了实现对数据的标注,借助了 LabelImg 工具进行标注工作,并对标注结果进行了统计分析(如图 7 所示)。数据标签包括正常绝缘子(insulator)和缺陷绝缘子(defect),其中各种缺陷类型(例如破损、闪络、自爆等)均被统一归为缺陷绝缘子(defect)。最终,按照 7:2:1 的比例随机划分为训练集、测试集和验证集。

2.2 实验环境及参数设置

实验使用改进的 RT-DETR 模型在自制数据集上从头进行训练。RT-DETR 原训练配置文件的检测类别为 Microsoft COCO 2017 数据集 80 种类别,需要修改预训练

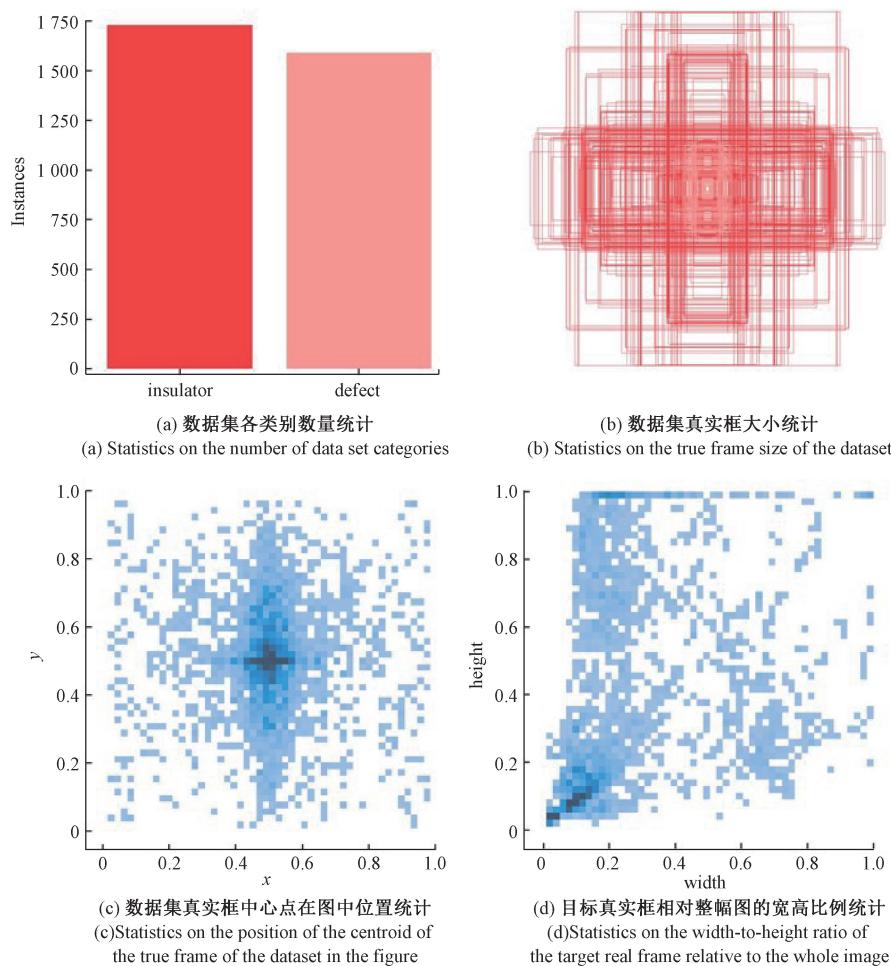


图 7 数据集标签详情统计

Fig. 7 Statistics of data set labelling details

模型类别为正常绝缘子和缺陷绝缘子。按照表 1 设置实验超参数。实验平台使用 Windows10 操作系统, GPU 为 NVIDIA GeForce RTX 2080Ti, 详细配置如表 2 所示。

表 1 实验超参数设置

Table 1 Experimental hyperparameter settings

参数名称	参数值
迭代次数	200
批处理大小	4
图片尺寸	640×640
损失函数	GIou
IoU	0.7
优化方法	AdamW
学习率	0.001
权重衰减	0.000 1

2.3 评价指标

目标检测模型的性能评价需要特定的指标支持。本

文通过参数量(Parameters)和浮点运算量(GFLOPs)来衡量模型的复杂度, 以评估其空间和时间开销。参数量和 GFLOPs 值越小, 表示模型的轻量化程度越高, 同时对硬件资源的需求也更低。

表 2 实验平台配置

Table 2 Experimental platform configuration

名称	配置
CPU	Intel Xeon Gold 5120
GPU	NVIDIA GeForce RTX 2080Ti
显存	12 G
运行内存	16 G
系统	Win10
CUDA	CUDA-11. 3

为更全面地评估算法的性能, 本文采用平均精度(AP)、平均类别精度(mAP)和每秒传输帧数(FPS)作为主要指标。其中, AP 是基于召回率(Recall)与精确率

(Precision)的综合衡量,用于评估模型在不同类别上的检测表现,是目标检测领域的重要评价标准。

召回率为:

$$R_{rc} = T_p / (T_p + F_N) \times 100\% \quad (8)$$

查准率为:

$$P_{re} = T_p / (T_p + F_p) \times 100\% \quad (9)$$

其中, T_p 为正样本检测结果为正样本; F_N 为样本检测结果为负样本; F_p 为负样本检测结果为正样本。通过将召回率作为横坐标,取对应的最大精确率值作为纵坐标,可以绘制 Precision-Recall 曲线。通过对曲线下方面积进行积分,即得到 AP 值。累加所有类别的 AP 值并取平均,即可得出 mAP 值,其计算公式如下:

$$AP = \int_0^1 P(r) dr \quad (10)$$

$$mAP = \sum_{k=0}^c AP_k / C \quad (11)$$

其中, $P(r)$ 为 Precision-Recall 曲线; $\sum_{k=0}^c AP$ 为每一个类别的精度; C 为总类别数。

3 实验结果与分析

3.1 对比实验

为了验证本文所提出算法的有效性,选择了一系列参数量相近的轻量级模型进行对比实验,包括 YOLOv5s、YOLOv8s、YOLOv10s^[36]、Mamba-YOLO^[37]、YOLO-DETR^[38],以及同类型算法 Deformable-DETR^[23]和 MS-DETR^[24],此外还选取了基准模型 RT-DETR-R18。实验中,基于 IoU 值为 0.5 的标准测试了各模型的平均精度(mAP),结果详如表 3 所示,结果的可视化展示如图 8 所示。

表 3 目标检测算法实验结果对比

Table 3 Comparison of experimental results of target detection algorithms

模型	AP%		mAP@0.5%	参数量/ 10^6	计算量/GFLOPs	FPS/fps
	绝缘子	缺陷				
YOLOv5s	99.5	94.9	97.2	9.1	24.0	57.4
YOLOv8s	99.5	95.4	97.4	11.1	28.6	68.0
YOLOv10s	99.3	94.5	96.9	8.0	24.8	65.6
Mamba-YOLO-T	99.5	91.7	95.6	9.0	17.2	60.7
Mamba-YOLO-B	99.5	95.9	97.7	23.6	48.4	58.9
YOLO-DETR	99.5	96.5	98.0	26.1	70.8	52.9
Deformable-DETR	99.3	94.7	97.0	40.0	173.2	48.5
MS-DETR	99.2	93.8	96.5	39.8	160.4	53.4
RT-DETR-R18	99.4	95.8	97.6	20.0	58.3	76.7
SDH-DETR	99.5	97.6	98.5	11.4	31.4	78.6

实验结果表明,本文提出的算法在平均精度均值(mAP)上至少优于其他算法 0.5%。这一优势主要源于本研究的方法在检测绝缘子缺陷小目标时展现出更高的平均精度(AP),从而显著提升了整体性能。此外,本研究的方法在参数量和计算量上分别为 11.4 M 和 31.4 GFLOPs,进一步验证了在显著降低模型参数和计算需求的同时,未牺牲精度,反而实现了精度的提升。相关对比实验结果的模型参数与精度关系散点图如图 9 所示。这种在轻量化与高精度之间的平衡能力,构成了本研究方法的显著优势。

3.2 不同轻量化主干网络实验对比

表 4 提供了基于 RT-DETR 目标检测架构,采用七种不同主干网络构建的模型的性能评估数据。通过细致分析表 4 中的实验结果,可以观察到,当 StarNet 作为主干网络时,模型在平均精度均值(mAP)上达到了 98.1% 的显著成绩。这一结果相较于其他 6 种主干网络,包括

ResNet18、EfficientVit、EfficientFormerv2、GhostNetv2、MobileNetv4 以及 FasterNet,分别展现出了 0.5%、2.5%、1.1%、1.3%、2.6% 和 2.0% 的相对优势。

特别值得注意的是,以当 StarNet 作为主干网络时,针对缺陷绝缘子这一特定类别的平均精度(AP)显著高于其他六种模型。这表明 StarNet 以逐元素相乘的类残差方式连接不同的卷积核相较于其他 6 种主干网络对缺陷绝缘子小目标在保持轻量化的同时具有更强的特征提取能力。因此,本研究选择 StarNet 作为特征提取主干网络。

3.3 消融实验

以 RT-DETR-R18 为基准模型,依次使用 RT-DETR、RT-DETR+StarNet、RT-DETR+DySample、RT-DETR+HWD、RT-DETR+StarNet+DySample、RT-DETR+StarNet+HWD、RT-DETR+StarNet+DySample+HWD 的组合进行实验。消融实验的数据如表 5 所示。“√”表示使用了该模块,“×”表示未使用该模块。

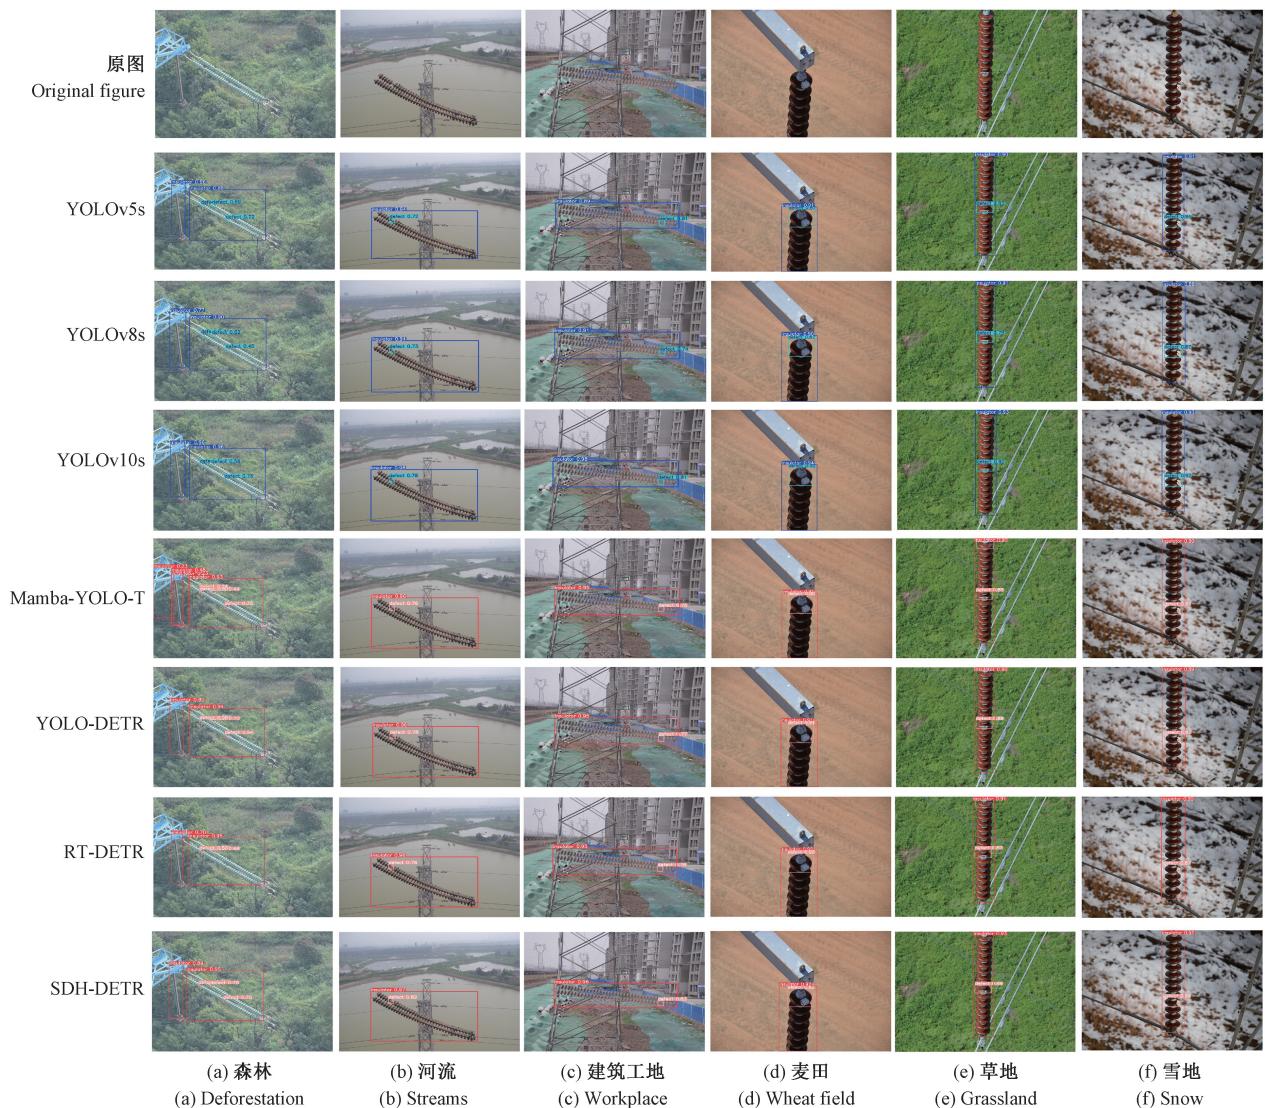


图 8 对比实验结果图

Fig. 8 Comparison of experimental results graph

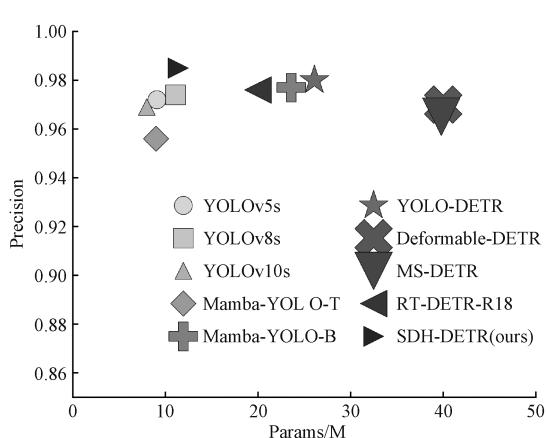


图 9 模型参数与精度关系的散点图

Fig. 9 Scatterplot of model parameters versus accuracy

从表 5 可以看出, 实验 2~7 的 mAP@0.5 值均高于基准模型(实验 1), 表明改进后的模型在绝缘子缺陷检测中表现出色。实验 2 中, 采用 StarNet 主干网络的改进模型不仅提升了检测精度, 还显著减少了参数量和计算量, 分别较基准模型降低了 39.5% 和 43.6%, 验证了改进策略的有效性。实验 3 和 4 中, 替换为 DySample 上采样模块和 HWD 下采样模块后, 在参数量和计算量接近基准模型的情况下, 检测精度略有提升。实验 5 中, 结合 StarNet 和 DySample 后, 参数量和计算量分别减少了 40% 和 45.5%, 进一步提升了模型的轻量化效果。实验 6 中, 通过引入 StarNet 和 HWD, 有效增强了模型对小尺度缺陷目标的感知能力, 绝缘子缺陷目标的 AP 值较基准模型提升了 1.6%, 同时参数量和计算量分别减少了 43% 和 46.3%, 验证了 HWD 在提升性能和降低复杂性方面的可行性。实

验 7 中,集成上述模块后,算法的检测精度达到 98.5%,较基线算法提升 0.9%,参数量和计算量分别下降了 43% 和

46.1%,同时检测速度达到 78.6 fps,满足输电线路绝缘子巡检的准确性和边缘部署的轻量化要求。

表 4 不同轻量化主干网络实验对比

Table 4 Experimental comparison of different lightweight backbone networks

模型	主干网络	AP%		mAP@0.5%	参数量/ 10^6	计算量/GFLOPs
		绝缘子	缺陷			
RT-DETR	ResNet18	99.4	95.8	97.6	20.0	58.3
	EfficientVit	99.4	91.9	95.6	11.0	28.7
	EfficientFormerv2	99.4	94.5	97.0	12.0	30.6
	GhostNetv2	99.4	94.2	96.8	9.9	26.0
	MobileNetv4	99.4	91.5	95.5	11.5	40.6
	FasterNet	99.4	92.8	96.1	11.1	29.9
	StarNet	99.5	96.7	98.1	12.1	32.9

表 5 消融实验结果对比

Table 5 Comparison of results of ablation experiments

实验	StarNet	DySample	HWD	AP%		mAP@ 0.5%	参数量/ 10^6	计算量/ GFLOPs	FPS/ fps
				绝缘子	缺陷				
1	×	×	×	99.4	95.8	97.6	20.0	58.3	76.7
2	√	×	×	99.5	96.7	98.1	12.1	32.9	77.7
3	×	√	×	99.5	95.9	97.7	20.1	58.3	73.6
4	×	×	√	99.5	95.9	97.7	19.5	63.3	72.9
5	√	√	×	99.5	97.4	98.4	12.0	31.8	78.7
6	√	×	√	99.5	97.4	98.4	11.4	31.3	78.9
7	√	√	√	99.5	97.6	98.5	11.4	31.4	78.6

本文引入的上下采样模块的特征映射可视化结果如图 10 所示,算法对亮度较高区域更加敏感。图 10 第 1 行展示了 RT-DETR 基准模型(实验 1)中,采用传统最近邻插值上采样与卷积下采样技术生成的特征图。尽管这些特征图能够捕捉部分图像信息,但在边缘和纹理细节的表达上存在局限性。相比之下,图 10 第 2 行展示了实验 3 和 4 生成的特征图,在边缘、纹理特征和细节信息保留方面表现更佳。

对比分析显示,实验 3 中采用的 DySample 下采样模块比实验 1 更好地保留了绝缘子目标的全局信息。传统最近邻插值上采样方法虽擅长保留背景信息,但容易导致目标边缘模糊,而 DySample 下采样方法更有效地保存纹理特征,显著增强了边缘和纹理表达。实验 4 中的特征图使用了 Haar 小波变换下采样模块,采用 3 个高频滤波器和 1 个低频滤波器实现下采样。小波变换下采样更好地保留了目标的高空间频率特征,使模型能够更准确地识别和定位小尺度缺陷目标。这一改进不仅丰富了特征映射的语义信息,还为后续深度学习层提供了更具代表性的学习特征。

3.4 结果可视化分析

为了直观展示复杂背景下绝缘子缺陷检测研究的必

要性,从测试集中选取部分检测结果进行可视化对比,模型检测效果如图 11 所示。在森林、工地、河流、雪地、麦田、草地复杂背景下本文改进模型检测效果均优于 RT-DETR 基准模型。

图 12 所呈现的分析结果揭示了在高分辨率且具有复杂背景的图像中,对于小尺度目标的检测任务对现有模型而言是一项极具挑战性的任务。在所考察的基准模型 RT-DETR 中,观察到在检测绝缘子以及缺陷等小尺度目标时,模型表现出了明显的漏检和误检现象。这表明基准模型在处理小尺度目标的检测问题上存在一定的局限性。本文所提出的改进模型在检测绝缘子和缺陷等小尺度目标方面表现出了显著的性能提升。改进后的模型成功地检测到了这些小尺度目标,突显了本文改进措施的有效性。

目标检测热力图是图像中信息对于预测结果的贡献排名,分数越高(颜色越红)的地方表示在输入图像中该区域对网络的响应越高、贡献越大。本研究采用 GradCAMPlusPlus^[39]方法对基准模型 RT-DETR 和本文改进模型进行热力图可视化,热力图中像素值表示该像素区域对于检测结果的重要性。图 13 为部分复杂背景下绝

缘子缺陷图像检测热力图,其中第 1 列为原图,第 2 列为基准模型 RT-DETR 热力图,第 3 列为本文改进模型热力图。从图 13 中可看出,本文改进模型的检测热力图更加贴近

真实绝缘子和绝缘子缺陷区域,能够注意到不同复杂背景下的绝缘子目标,可从弱语义的目标中提取更强的目标特征,有着较好的鲁棒性和泛化能力。

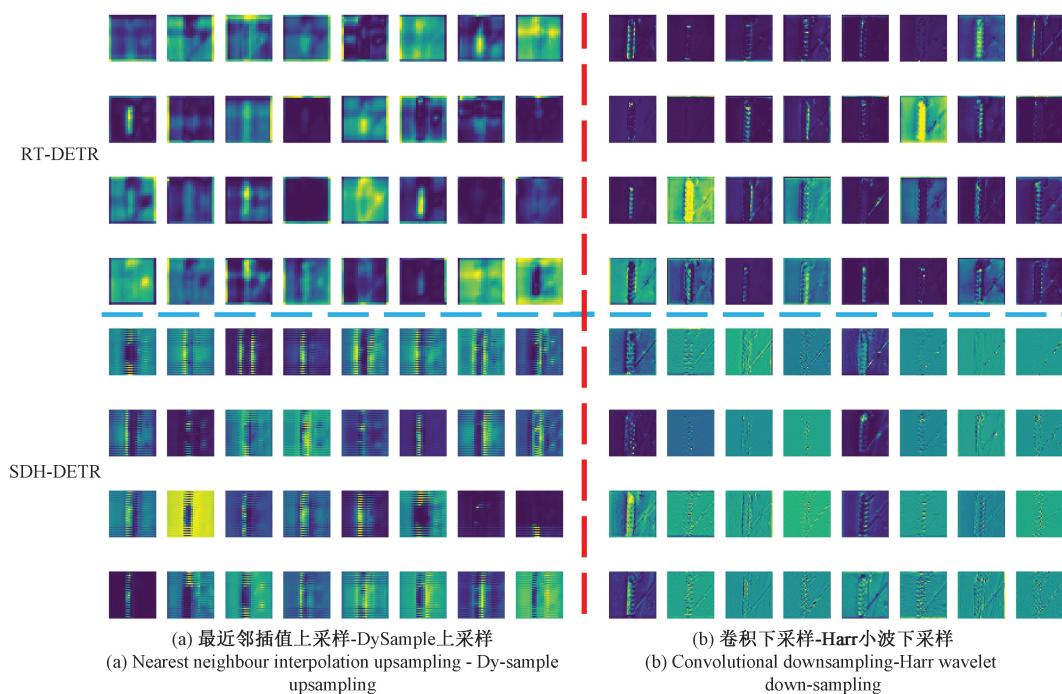
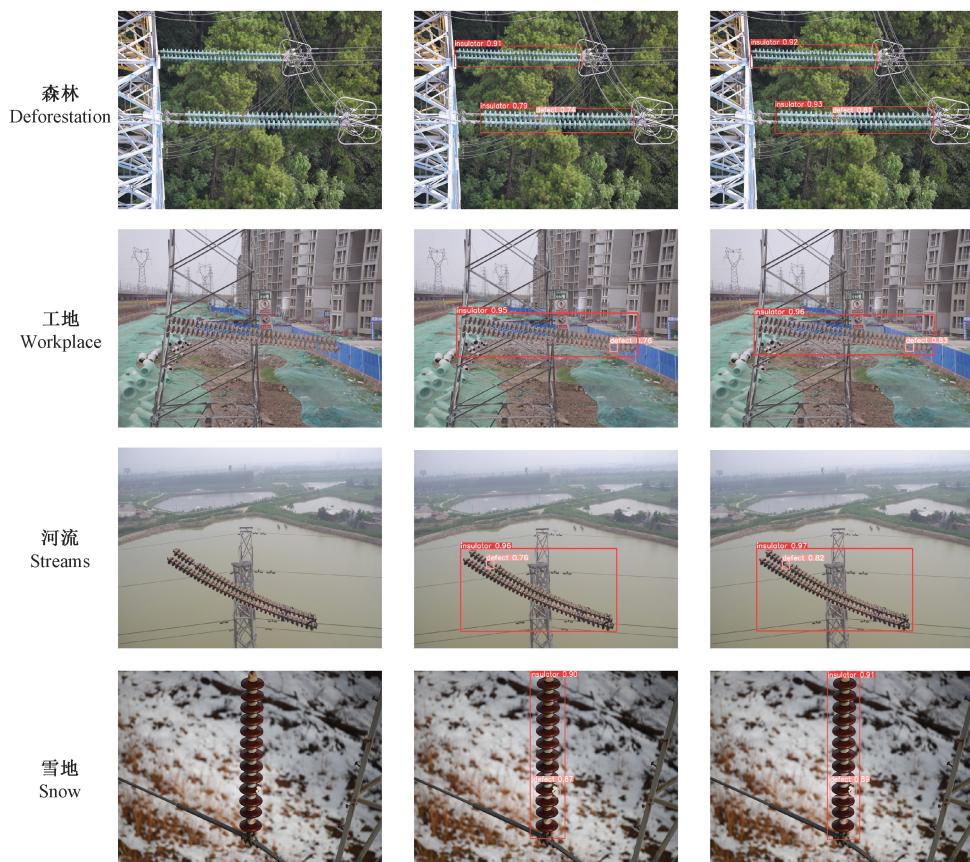


图 10 上下采样特征映射可视化

Fig. 10 Visualisation of up and down sampling feature mapping



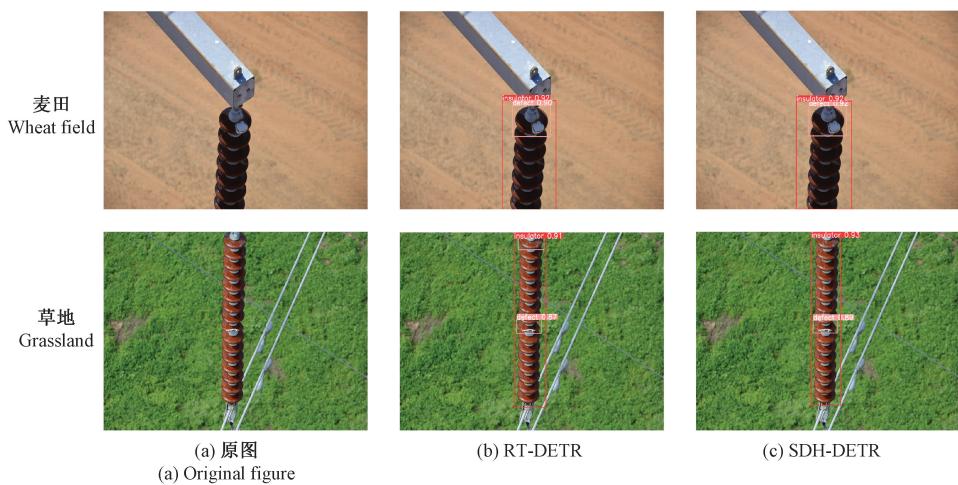


图 11 复杂背景下绝缘子缺陷检测效果对比

Fig. 11 Comparison of insulator defect detection effect in complex backgrounds

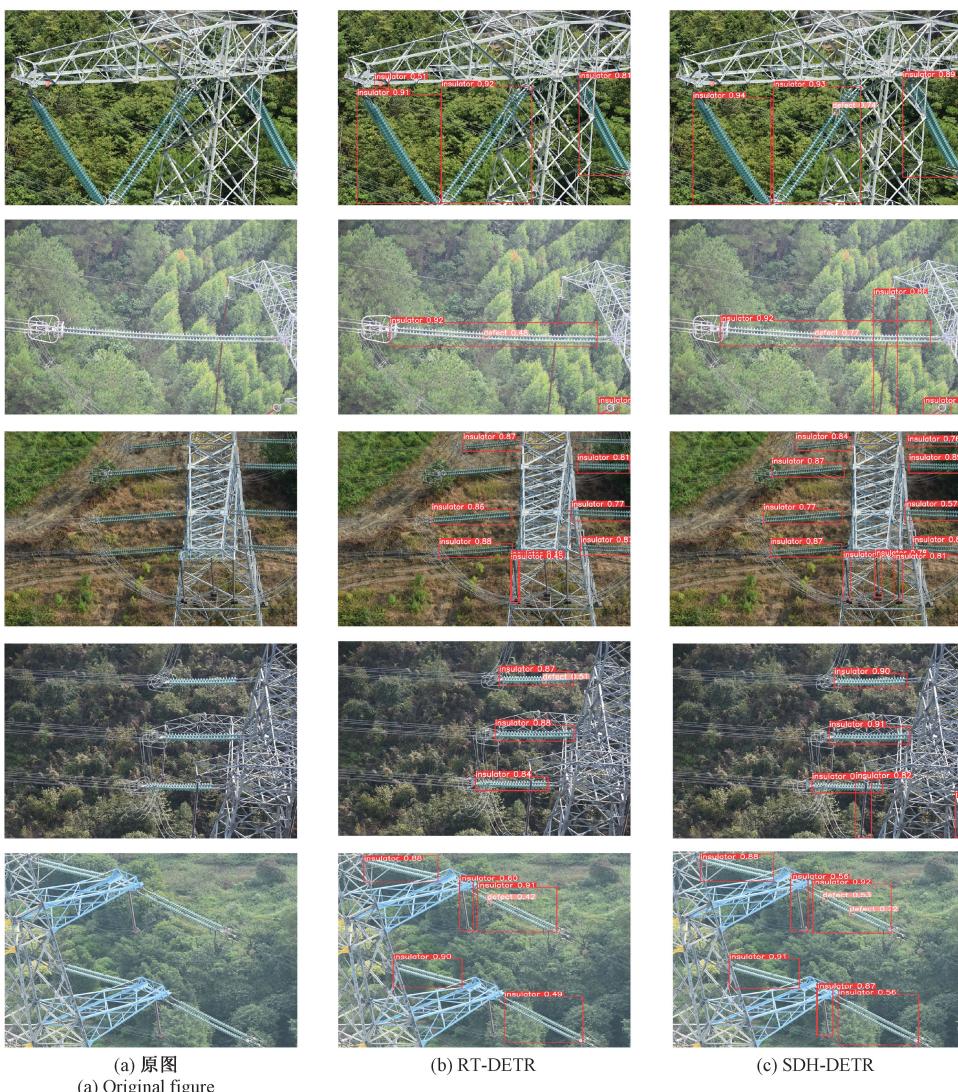


图 12 高分辨率下小尺度绝缘子缺陷检测效果对比图

Fig. 12 Comparison of the effect of small-scale insulator defect detection at high resolution

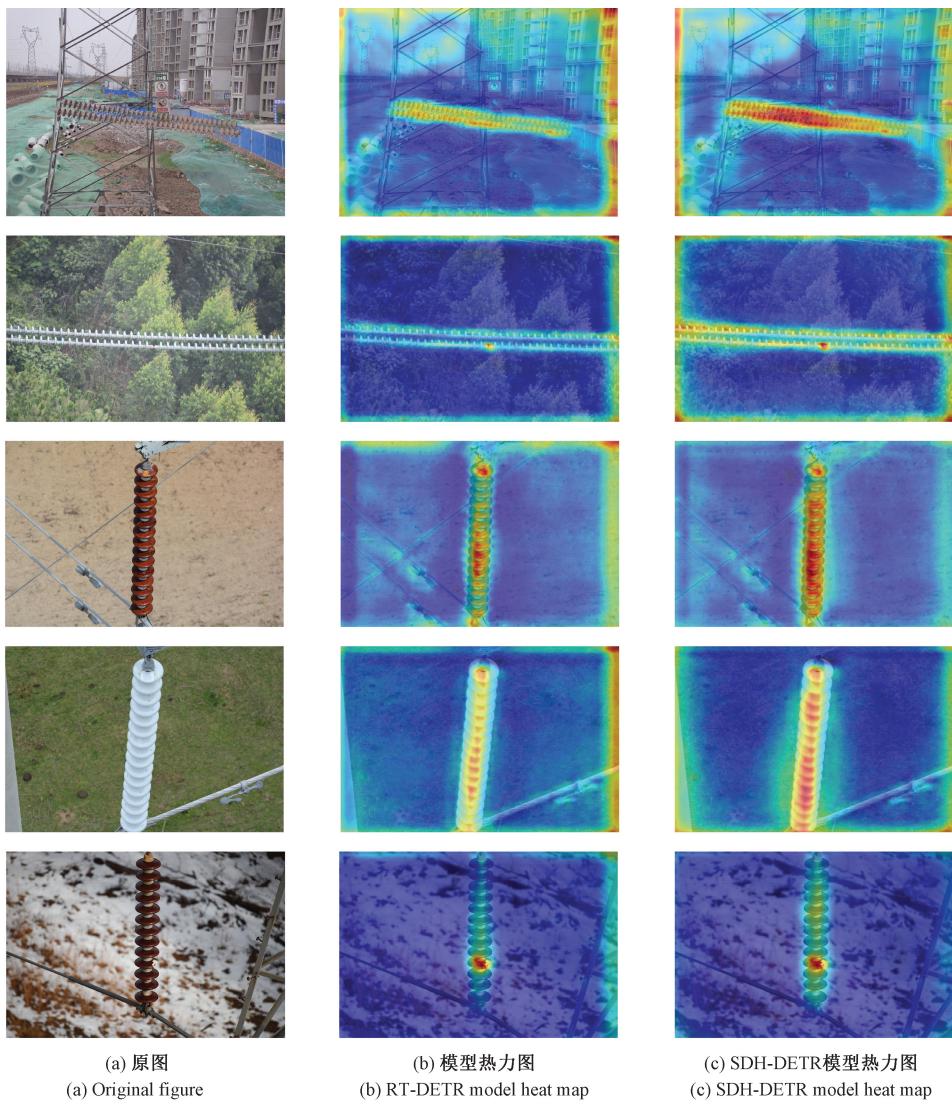


图 13 消融实验热力图

Fig. 13 Heat map of ablation experiment

如图 14 所示,改进模型与基准模型在训练过程中精确率、召回率、mAP@0.5、mAP@0.5-0.95 四个指标以及训练集和验证集的损失进行了对比。通过观察图中的数据,可以明显看到,改进模型在所有指标上均超越基准模型。具体而言,精确率提高了 0.8%,表明改进模型在目标检测中的预测准确性得到了提升;召回率提升了 3.0%,显示其在捕捉缺陷目标方面的表现更为出色;在验证集上,mAP@0.5 增加了 2.0%,而 mAP@0.5-0.95 则提高了 2.1%,这充分说明改进策略在不同 IoU 阈值下有效提高了检测精度。此外,如图 15 所示,改进模型在第 75 轮训练时,收敛曲线趋于平稳,明显优于基准模型。

3.5 在绝缘子多缺陷小目标检测数据集上的泛化实验

为了充分展示本文算法的适应性,在自制的绝缘子多缺陷小目标检测数据集上进行模型的验证实验,将改进模型与基线模型 RT-DETR 进行对比,以进一步评估改进模

型的检测能力。该数据集本文所使用的数据集包括由以下三部分组成:一是国家电网通过 GitHub 公开的 CPLID 数据集^[34],包含 1 240 张图像;二是 IEEE 提供的绝缘子多缺陷数据集(insulator defect image dataset, IDID)^[35],共计 1 702 张图像;三是某电网公司采集的输电线路绝缘子缺陷检测数据集,包含 119 张图像。这 3 个数据集共计 3 061 张图像,涵盖了输电线路中玻璃、陶瓷和复合绝缘子多种规格,并包含了森林、河流、建筑工地、麦田、草地以及雪地等复杂场景下的绝缘子图像。所有数据均通过 LabelImg 软件进行精准标注,绝缘子缺陷分为自爆(drope)、破损(break)和闪络污损(flashover_damage) 3 类,与本文的研究背景和问题契合。表 6 展示了改进前后各个类别 AP 的对比,由表可知各类别精度均有提升,其中闪络污损类小目标 AP 值提升最大,表明改进算法对小目标检测效果显著。

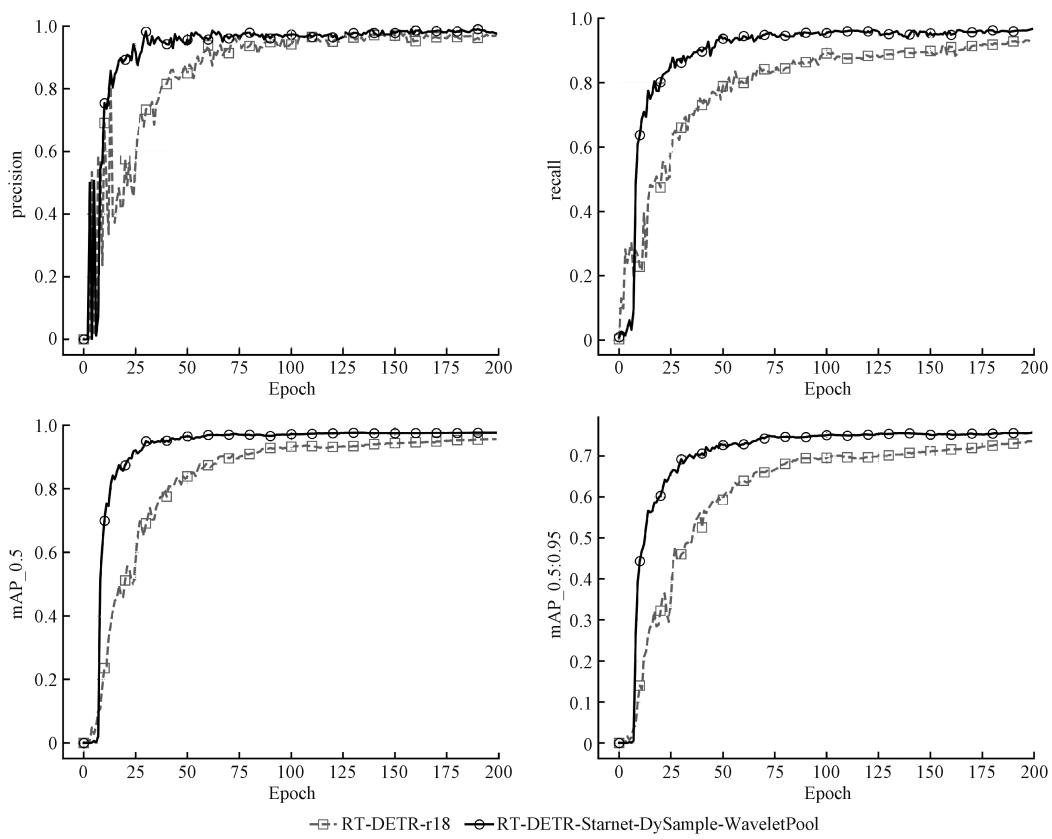


图 14 模型训练性能指标对比

Fig. 14 Comparison of model training performance metrics

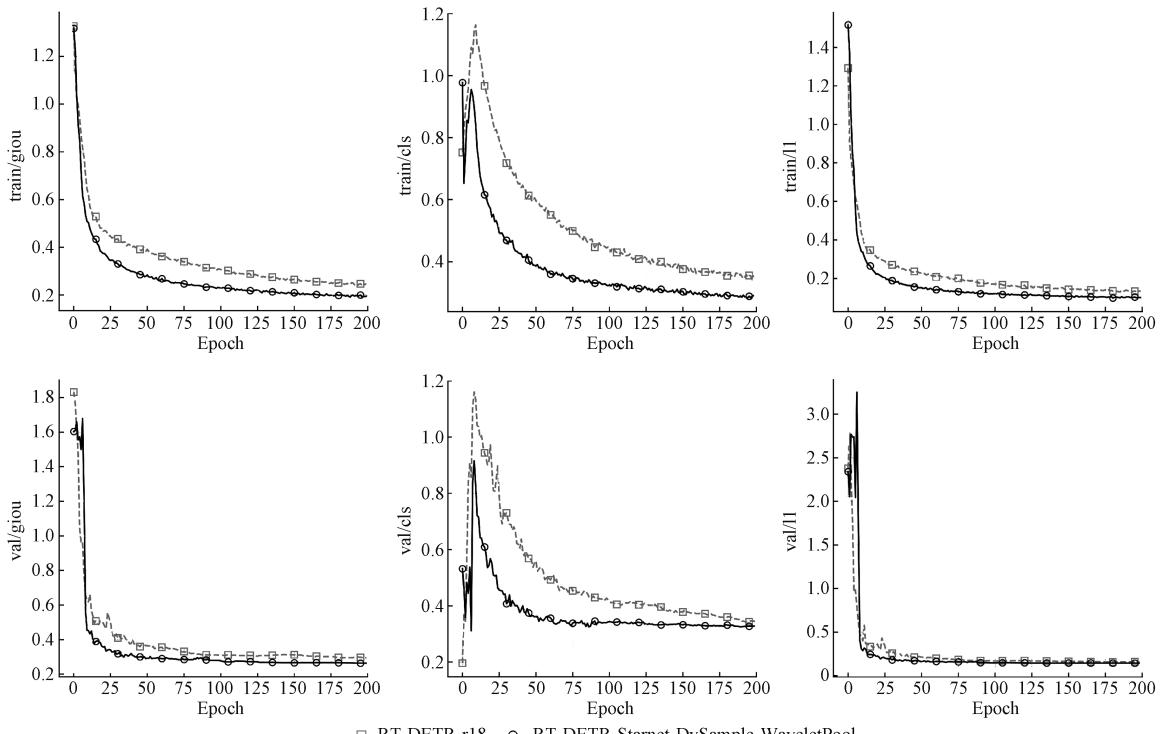


图 15 模型训练损失曲线分析

Fig. 15 Model training loss curve plot

表 6 SOEP 结构与小目标检测模型对比实验

Table 6 Comparison experiment between SOEP structure and small target detection model

模型	AP%			mAP@0.5%	参数量/ 10^6	计算量/GFLOPs	FPS/fps
	自爆	破损	闪络污损				
RT-DETR	95.5	96.2	90.1	93.9	19.8	56.9	74.0
SDH-DETR	95.9	96.1	91.9	94.6	11.3	30.5	78.8

4 结论

针对复杂背景下模型复杂度高且绝缘子缺陷小目标难以准确检测,以及上下采样过程中容易导致特征丢失的问题,本文提出一种融合动态采样与小波变换的轻量级绝缘子缺陷检测算法 SDH-DETR。本文选择无需非极大值抑制后处理的 RT-DETR 作为基准模型,降低了优化难度,并增强了模型的鲁棒性。设计了 StarNet 主干网络,显著降低了模型的参数量与计算量,有效实现模型的轻量化的同时保证了模型检测精度。针对上下采样过程中容易导致特征丢失的问题,引入了 DySample 轻量动态上采样模块和 Harr 小波变换下采样模块(HWD),抑制复杂背景干扰,进一步减少了模型参数量,尽可能保留了边缘、纹路等细节信息,增强模型对缺陷小目标的感知能力。实验表明,本文提出的算法在绝缘子缺陷检测中的平均精度均值达到 98.5%,相较基准模型提升 0.9%,并且参数量和计算量分别下降 43% 和 46.1%,FPS 达到 78.6 fps,满足输电线路巡检的轻量化和实时性要求。未来的工作将探索模型剪枝和知识蒸馏,以进一步简化算法,降低复杂性,同时提高检测速度。

参考文献

- [1] 熊炜,黄玉谦,孟圣哲. 基于改进 YOLOv8 算法的绝缘子缺陷检测模型[J]. 电子测量技术,2024,47(12):132-139.
- XIONG W, HUANG Y Q, MENG SH ZH. Insulator defect detection model based on improved YOLOv8 algorithm[J]. Electronic Measurement Technology, 2024, 47(12):132-139.
- [2] 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. Progress of UAV inspection technology for overhead transmission lines[J]. High Voltage Technology, 2020, 46 (1): 14-22.
- [3] 贾晓芬,于业齐,郭永存,等. 航拍绝缘子自爆缺陷的轻量化检测方法[J]. 高电压技术,2023,49(1):294-300.
- JIA X F, YU Y Q, GUO Y C, et al. Lightweight detection method of self-explosion defects in aerial insulators[J]. High Voltage Technology, 2023, 49(1): 294-300.
- [4] 廖丽瑛,刘洪. 基于改进 YOLOv8 的绝缘子自爆缺陷检测[J]. 电子测量技术,2024,47(18):138-144.
- LIAO L Y, LIU H. Self-explosion defect detection of insulators based on improved YOLOv8[J]. Electronic Measurement Technology, 2024, 47(18):138-144.
- [5] 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 detection method for defects in glass insulator glass parts[J]. High Voltage Technology, 2022, 48 (12): 4933-4940.
- [6] 邬开俊,丁元. 宽型自注意力融合密集型残差网络的图像去雾[J]. 湖南大学学报(自然科学版),2023,50(8):13-22.
- WU K J, DING Y. Wide self-attention fusion of dense residual networks for image defogging[J]. Journal of Hunan University(Natural Science Edition), 2023,50(8): 13-22.
- [7] GE Z. YOLOx: Exceeding YOLO series in 2021[J]. ArXiv preprint arXiv:2107.08430, 2021.
- [8] 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.
- [9] GIRSHICK R. Fast R-CNN[C]. IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [10] 霍超,谷晓钢,黄玲琴,等. 基于 YOLOv4 优化的航拍绝缘子缺陷图像检测模型[J]. 电子测量技术,2023,46(9):175-181.
- HUO CH, GU X G, HUANG L Q, et al. Aerial insulator defect image detection model based on YOLOv4 optimisation [J]. Electronic Measurement Technology, 2023, 46(9):175-181.
- [11] 王卓,王玉静,王庆岩,等. 基于协同深度学习的二阶段绝缘子故障检测方法[J]. 电工技术学报, 2021, 36(17): 3594-3604.
- WANG ZH, WANG Y J, WANG Q Y, et al. A two-stage insulator fault detection method based on cooperative deep learning[J]. Journal of Electrotechnology, 2021, 36(17): 3594-3604.

- (17): 3594-3604.
- [12] 张欣,王红星,陈玉权,等. 基于改进 Cascade R-CNN 算法的多类型绝缘子缺陷图像联合检测[J]. 电瓷避雷器, 2022, 1: 189-196.
ZHANG X, WANG H X, CHEN Y Q, et al. Joint detection of defective images of multiple types of insulators based on improved Cascade R-CNN algorithm [J]. Electric Porcelain Surge Arrester, 2022, 1: 189-196.
- [13] 苟军年,杜愫愫,刘力. 基于改进掩膜区域卷积神经网络的输电线路绝缘子自爆检测[J]. 电工技术学报, 2023, 38(1):47-59.
GOU J N, DU S S, LIU L. Self-explosion detection of transmission line insulators based on improved mask region convolutional neural network[J]. Journal of Electrotechnology, 2023, 38(1):47-59.
- [14] LING Z, ZHANG D, QIU R C, et al. An accurate and real-time method of self-blast glass insulator location based on faster R-CNN and U-net with aerial images [J]. CSEE Journal of Power and Energy Systems, 2019, 5(4): 474-482.
- [15] 苟军年,杜愫愫,王世铎,等. 轻量化特征融合的 CenterNet 输电线路绝缘子自爆缺陷检测[J]. 北京航空航天大学学报, 2022, 50(7): 2161-2171.
GOU J N, DU S S, WANG SH D, et al. Lightweight feature fusion for self-destructive defect detection of insulators on CenterNet transmission lines[J]. Journal of Beijing University of Aeronautics and Astronautics, 2022, 50(7): 2161-2171.
- [16] 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 SH, et al. Insulator defect detection based on multi-scale feature fusion [J]. Journal of Electrotechnology, 2023, 38(1): 60-70.
- [17] 宋立业,刘帅,王凯,等. 基于改进 EfficientDet 的电网元件及缺陷识别方法[J]. 电工技术学报, 2022, 37(9): 2241-2251.
SONG L Y, LIU SH, WANG K, et al. Grid component and defect identification method based on improved EfficientDet [J]. Journal of Electrotechnology, 2022, 37(9): 2241-2251.
- [18] 王韵琳,冯天波,孙宁,等. 融合注意力与多尺度特征的电力绝缘子缺陷检测方法[J]. 高电压技术, 2024, 50(5):1933-1942.
WANG Y L, FENG T B, SUN N, et al. A defect detection method for power insulators by fusing attention and multiscale features [J]. High Voltage Technology, 2024, 50(5):1933-1942.
- [19] 张烨,李博涛,尚景浩,等. 基于多尺度卷积注意力机制的输电线路防振锤缺陷检测[J]. 电工技术学报, 2024, 39(11): 3522-3537.
ZHANG Y, LI B T, SHANG J H, et al. Detection of anti-vibration hammer defects in transmission lines based on multi-scale convolutional attention mechanism[J]. Journal of Electrotechnology, 2024, 39(11): 3522-3537.
- [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]. Journal of Electrotechnology, 2025, 40(3):842-854.
- [21] GILG J, TEEPE T, HERZOG F, et al. Do we still need non-maximum suppression? Accurate confidence estimates and implicit duplication modeling with IoU-Aware calibration [C]. IEEE/CVF Winter Conference on Applications of Computer Vision, 2024: 4850-4859.
- [22] ZHAO Y AN, LYU W Y, XU SH L, et al. DETRs beat YOLOs on real-time object detection[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 16965-16974.
- [23] ZHU X ZH, SU W J, LU L W, et al. Deformable DETR: Deformable transformers for end-to-end object detection[J]. ArXiv preprint arXiv:2010.04159, 2020.
- [24] ZHAO CH Y, SUN Y F, WANG W H, et al. MS-DETR: Efficient DETR training with mixed supervision[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 17027-17036.
- [25] 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.
- [26] MA X, DAI X Y, BAI Y, et al. Rewrite the stars[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 5694-5703.
- [27] 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.
- [28] XU G P, LIAO W T, ZHANG X, et al. Haar wavelet downsampling: A simple but effective downsampling module for semantic segmentation[J]. Pattern Recognition, 2023, 143: 109819.
- [29] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition [C]. IEEE

- Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [30] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift [C]. International Conference on Machine Learning. PMLR, 2015: 448-456.
- [31] LIN G F, SHEN W. Research on convolutional neural network based on improved Relu piecewise activation function[J]. Procedia Computer Science, 2018, 131: 977-984.
- [32] GONZALEZ R C. Digital image processing[M]. New York: Pearson Education India, 2009.
- [33] BIEDER F, SANDKÜHLER R, CATTIN P C. Comparison of methods generalizing max-and average-pooling[J]. ArXiv preprint arXiv:2103.01746, 2021.
- [34] 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, 2018, 50(4): 1486-1498.
- [35] LEWIS D, KULKARNI P. Insulator defect detection[J]. IEEE Dataport, 2021, DOI: 10.21227/vkdw-x769.
- [36] WANG AO, CHEN H, LIU L H, et al. YOLOv10: Real-time end-to-end object detection [J]. ArXiv preprint arXiv:2405.14458, 2024.
- [37] WANG Z Y, LI CH, XU H Y, et al. Mamba YOLO: SSMs-based YOLO for object detection[J]. ArXiv preprint arXiv:2406.05835, 2024.
- [38] NUGRAHA S J A, ERFIANTO B. White blood cell detection using YOLOV8 integration with DETR to improve accuracy[J]. Sinkron: Jurnal dan Penelitian Teknik Informatika, 2023, 8(3): 1908-1916.
- [39] CHATTOPADHYAY A, SARKAR A, HOWLADER P, et al. Grad-CAM++: Generalized gradient-based visual explanations for deep convolutional networks [C]. 2018 IEEE Winter Conference on Applications of Computer Vision (WACV). IEEE, 2018: 839-847.

作者简介

周景(通信作者),博士,副教授,硕士生导师,主要研究方向为人工智能、机器学习和电力大数据分析。

E-mail:zhoujing108@ncepu.edu.cn

刘心,硕士研究生,主要研究方向为计算机视觉与电力故障检测。

E-mail:liuxin0710@ncepu.edu.cn

唐振洋,硕士研究生,主要研究方向为计算机视觉。

E-mail:tangzhenyang@ncepu.edu.cn

董晖,硕士研究生,主要研究方向为电力大数据分析、机器学习。

E-mail:donghui99@ncepu.edu.cn