

N-YOLOv8: 绝缘子缺陷自动检测模型

宋鸿绅¹, 贾晓芬²

1. 安徽理工大学 电气与信息工程学院, 安徽 淮南 232001

2. 安徽理工大学 人工智能学院, 安徽 淮南 232001

摘要:目的 绝缘子正常工作是确保电力系统安全可靠运行的重要环节,为推动绝缘子缺陷的自动检测,设计出一种绝缘子缺陷的轻量化检测模型 N-YOLOv8。方法 在网络轻量化方面,首先融合深度可分离卷积、BN 层、Hardswish 激活函数和残差连接设计轻量化模块 DPHConv,其次融合 Inception-Bottleneck 与 C2f 设计轻量化模块 CFI-X,它们以牺牲少量检测精度为代价,显著降低了网络的参数量。在提升检测精度方面,基于 ECA 注意力机制设计 T-ECA 模块后,将其融合多分支并行结构和 Gather Excite 注意力模块,设计注意力机制 PEG,其次结合 CIoU_Loss 与 EIoU_Loss 的思想设计 CEIoU_Loss,最后引入 Soft-NMS 替换原网络的 NMS,它们有效提升了网络对绝缘子缺陷的检测能力。结果 相比 YOLOv8n 网络,N-YOLOv8 的参数量降低 43%,浮点运算量降低 37%,同时检测精度高达 91.7%,检测精度较原网络提升 0.2%。结论 N-YOLOv8 的检测效果较高,可以有效推动智能检测算法在无人机设备上的部署,实现绝缘子缺陷的实时检测。

关键词:缺陷检测;智能检测;深度可分离卷积;PEG 注意力机制;CEIoU_Loss

中图分类号:TP391 **文献标识码:**A **doi:**10.16055/j.issn.1672-058X.2026.0003.003

N-YOLOv8: An Automatic Detection Model for Insulator Defects

SONG Hongshen¹, JIA Xiaofen²

1. School of Electrical and Information Engineering, Anhui University of Science and Technology, Huainan 232001, Anhui, China

2. School of Artificial Intelligence, Anhui University of Science and Technology, Huainan 232001, Anhui, China

Abstract: Objective The normal operation of insulators is a crucial part of ensuring the safe and reliable operation of power systems. To promote the automatic detection of insulator defects, a lightweight detection model, N-YOLOv8, was designed. **Methods** For network lightweighting, a lightweight module called DPHConv was first designed by integrating depthwise separable convolution, BN layer, Hardswish activation function, and residual connections. Second, a lightweight module, CFI-X, was designed by integrating Inception-Bottleneck and C2f. These two modules significantly reduced the number of network parameters at the cost of only a minor loss in detection accuracy. In terms of improving detection accuracy, a T-ECA module was designed based on the ECA attention mechanism. Then, an attention mechanism PEG was designed by integrating the T-ECA module with a multi-branch parallel structure and a Gather Excite attention module. Furthermore, CEIoU_Loss was designed by combining the ideas of CIoU_Loss and EIoU_Loss. Finally,

收稿日期:2024-03-05 **修回日期:**2024-06-18 **文章编号:**1672-058X(2026)03-0019-11

基金项目:国家自然科学基金面上项目资助(52174141);安徽省自然科学基金面上项目资助(2108085ME158);安徽理工大学引进人才科研启动基金资助(2022YJRC44)。

作者简介:宋鸿绅(1998—),男,硕士研究生,主要研究方向为图像处理、绝缘子故障检测。

通信作者:贾晓芬(1978—),女,博士,教授,主要研究方向为深度学习、图像处理和机器学习等。Email:shs@163.com。

引用格式:宋鸿绅,贾晓芬. N-YOLOv8: 绝缘子缺陷自动检测模型[J]. 重庆工商大学学报(自然科学版), 2026, 43(3): 19-29.

Song Hongshen, Jia Xiaofen. N-YOLOv8: an automatic detection model for insulator defects[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2026, 43(3): 19-29.

Soft-NMS was introduced to replace the NMS in the original network. These improvements effectively boosted the network's performance in detecting insulator defects. **Results** Compared with the YOLOv8n network, N-YOLOv8 reduced the number of parameters by 43% and floating-point operations by 37%, while achieving a detection accuracy of 91.7%, which was 0.2% higher than that of the original network. **Conclusion** N-YOLOv8 delivers high detection performance, which can effectively facilitate the deployment of intelligent detection algorithms on UAV platforms and achieve real-time detection of insulator defects.

Keywords: defect detection; intelligent detection; depth-separable convolution; PEG attention mechanism; CEIoU_Loss

绝缘子按照材质的不同可被划分为瓷绝缘子、玻璃绝缘子与复合绝缘子,在电力输配系统中主要起到隔离、保护与承载的作用。受到气候变化、环境污染等外界因素的影响,电力线路中的绝缘子易于发生脱串缺陷,进而威胁到电力系统的正常运行。登高空作业、爬升电杆等传统的电力设备巡检方式不仅具有安全隐患,还存在效率低、漏检、误检等问题。无人机巡检作为一种新兴技术,更易于满足高效、安全的巡检需求。但无人机智能巡检必须解决复杂背景下缺陷准确识别和识别算法高效等问题。

在经典网络模型中添加经过验证的高效模块是目前常用的提升检测精度的策略。亢洁等^[1]在改进后的网络中添加自注意力与混合卷积注意力机制^[2],有效增强网络提取绝缘子缺陷相关特征中的细节信息。宋智伟等^[3]在所设计的 Flexible YOLOv7 网络中使用 GAM 注意力机制放大全局跨维度交互表示以及减少网络信息提取损失,提升网络检测性能。翟永杰等^[4]设计的输电线路绝缘子多缺陷检测(IDD-YOLOv7)模型,在多尺度特征融合的过程中直接加入坐标注意力(Coordinate Attention)机制,提高了 IDD-YOLOv7 对小目标的全局感知能力。陈奎等^[5]在改进后的网络中采用 CIoU_Loss^[6]替换原网络中的 GIoU_Loss,使得目标框在回归的过程中更加稳定,收敛的精度更高。黄悦华等^[7]在改进的 YOLOv5x 网络结构中添加 EIou_Loss^[8],以优化网络模型的整体性能。欧阳名三等^[9]为了提升预测边框回归精度,在模型 DETR 中引入 DIOU 函数,优化了算法检测精度。此类方法往往会在提升检测精度的同时,增加参数量。

降低模型参数量,提高智能识别算法的检测效率有益于其在无人机上部署。深度可分离卷积、残差连接等都是模型轻量化的有效手段。于业齐等^[10]直接使用深度可分离卷积对 YOLOv3 网络中的普通卷积进行替换,设计 MDD-YOLOv3 网络,改进后模型权重降低至 13.6 M。黄福珍等^[11]引入 GSConv 替换网络普通卷

积,在 C2f 模块中融合 FasterNet Block 模块与 EMA 注意力机制,设计出模型 GCP-YOLOv8s,使得改进后模型权重大小从 11.3 M 降低至 7.2 M。王道累等^[12]结合深度可分离卷积与平均池化等技术设计 D_Resunit 模块,应用于所提出的 L-YOLOv5 网络中,模型整体权重大小从 13.7 M 降低至 3.4 M。

王德文等^[13]在所设计的 Wasserstein 距离优化的生成式对抗网络中引入残差连接,提高生成图片的质量,解决梯度消失的问题。上述方法中深度可分离卷积主要起到模型轻量化的效果,但改进后的模型参数依然相对较大,同时也会不同程度地降低检测精度。

目前,针对密集遮挡的复杂环境缺陷检测的成果较为鲜见。李帷韬等^[14]在所设计基于 Transformer 和强化学习的输电线路缺陷智能识别的方法中,使用 Soft-NMS 算法解决了输电线路较近距离或重叠情况下的缺陷漏检问题。但目前使用 Soft-NMS 算法解决密集遮挡场景下绝缘子缺陷检测的研究尚少。

鉴于此,为了解决绝缘子缺陷检测时目标检测算法因模型结构庞大、运算量复杂,导致算法部署至无人机嵌入式设备困难以及检测精度较低的问题,通过设计轻量化模块与提升缺陷检测精度模块,设计绝缘子缺陷自动检测模型 N-YOLOv8,使模型结构压缩的同时,绝缘子缺陷检测精度也可取得较为满意的效果。

1 N-YOLOv8 网络模型

YOLOv8 是一个模型簇,其按照网络深度和宽度的不同,模型从小到大被分为 n 、 s 、 m 、 l 、 x 五个不同的版本,为了使网络模型更加轻量化,选择 n 版本作为基础模型^[4],设计图 1 所示的 N-YOLOv8 网络。N-YOLOv8 网络由特征提取网络(N-CSPDarknet53)、特征融合网络(N-Neck)与检测头(Head)三部分组成。

(1) 利用深度可分离卷积、残差连接、BN 层、Hardswish 激活函数设计轻量化模块 DPHConv,其中 DPHConv-1 添加至网络第 1、3、5、7 层级,DPHConv-2 添加至网络第 17、20 层级。并将 Inception-Bottleneck

与 C2f 模块融合设计轻量化模块 CFI-X,其中 CFI-3 添加至网络的第 2、8、12、15、19、22 层级,CFI-6 添加至网络的第 4、6 层级,二者致力于显著降低网络参数量。

(2) 结合多分支并行结构、Gather Excite 注意力模块^[15]与基于 ECA 注意力机制^[16]设计的 T-ECA 模块,创新设计出注意力机制 PEG,添加至网络 N-YOLOv8 的小尺度目标检测层(P3)后,用于提升绝缘子缺陷的

感知能力。

(3) 融合 CIoU 损失函数与 EIou 损失函数设计 CEIoU 损失函数,替换原网络中的 CIoU 损失函数,减少训练与验证损失,提升网络检测精度。采用 Soft-NMS^[17]后处理算法,替换原网络中的 NMS 算法,解决原网络中 NMS 在密集遮挡场景中出现的漏检问题,并进一步提升检测精度。

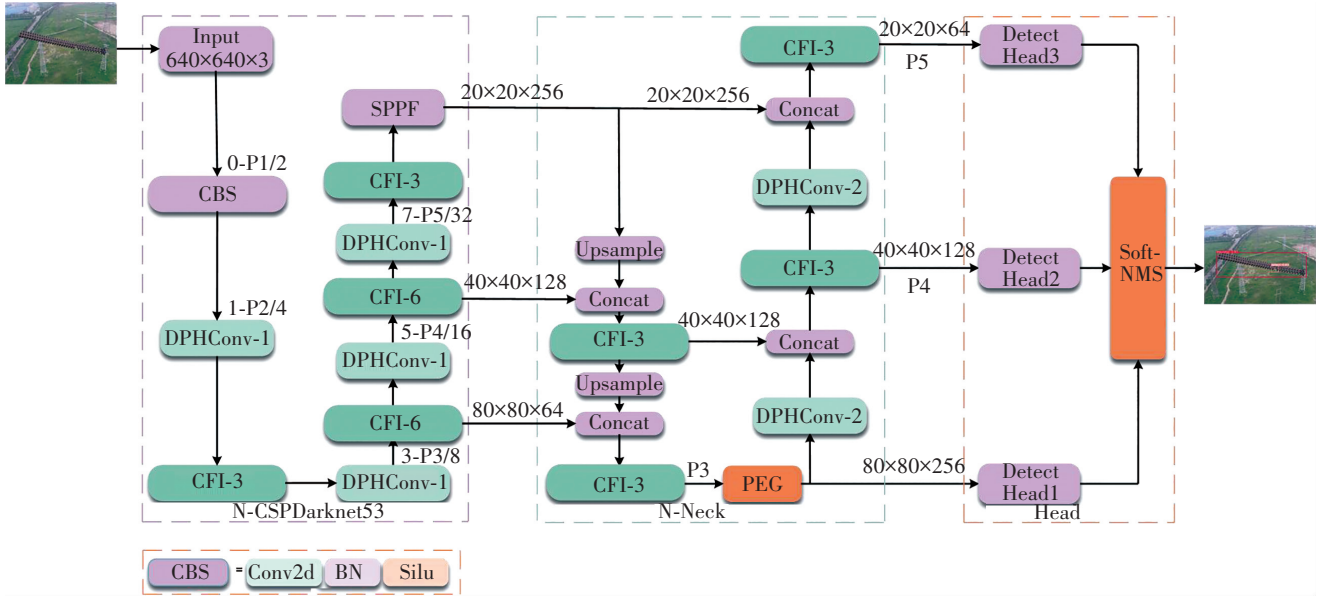


图 1 N-YOLOv8 网络结构图

Fig. 1 N-YOLOv8 structure diagram

1.1 轻量化模块设计

1.1.1 DPHConv 模块

深度可分离卷积利用逐点卷积融合深度卷积捕捉每个通道的特征信息,根据标准卷积的参数量式(1)与深度可分离卷积的参数量式(2)可知,普通卷积的参数量是深度可分离卷积的 8~9 倍。

$$D_K \times D_K \times M \times N \times D_F \times D_F \quad (1)$$

$$D_K \times D_K \times M \times D_F \times D_F + M \times N \times D_F \times D_F \quad (2)$$

其中, D_F 代表输入特征矩阵的高和宽, D_K 代表卷积核的大小, M 代表输入特征矩阵的深度, N 代表卷积输出特征矩阵深度。

残差连接^[18]有助于梯度的顺利传播,它通过对浅层信息的前向传递来确保重要信息的保留。BN 层对输入数据进行批量归一化处理,提高模型泛化能力。Hardswish 激活函数,在正半轴呈线性与非线性增长,负半轴具有非线性特性,零点附近具有连续性,能在一定程度解决梯度消失与信息丢失的问题,增强网络的稳定性能。

鉴于此,本文以深度可分离卷积作为基准模块,与

残差连接、BN 层、Hardswish 激活函数相结合,设计一个更优的轻量化网络模块 DPHConv,如图 2 所示,其中 DPHConv-1 使用了残差连接,DPHConv-2 未使用残差连接。

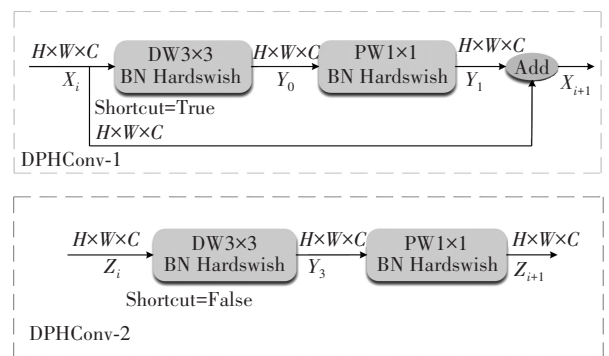


图 2 DPHConv 结构图

Fig. 2 DPHConv structure diagram

绝缘子脱串、自爆等缺陷均属于小目标缺陷,深度提取出绝缘子图像中浅层信息表达的缺陷形状和深层信息表征的细微缺陷特征,并对其进行融合才能保证对小目标缺陷的准确识别。因此,将 DPHConv-1 用于网络架构前端的 N-CSPDarknet53 中,DPHConv-1 中的

残差连接能将浅层信息前向传递至深层,再借助“Add”实现深、浅特征的融合,从而保证网络模型对绝缘子特征的初步稳定提取,且为后续网络层提供更丰富的绝缘子与缺陷特征信息。N-CSPDarknet53 的第 1 层、3 层、5 层、7 层的卷积模块采用 DPHConv-1 进行替换,使网络轻量化的同时,有效提升 N-CSPDarknet53 对绝缘子缺陷特征提取性能。DPHConv-1 模块的计算过程为

$$Y_0 = \text{Hardswish}(\text{BN}(\text{DW}(X_i))) \quad (3)$$

$$Y_1 = \text{Hardswish}(\text{BN}(\text{PW}(Y_0))) \quad (4)$$

$$X_{i+1} = \text{Add}(X_i, Y_1) \quad (5)$$

其中, Y_0 表示对输入的 X_i (i 取 1、2、3... n) 依次经 DW 卷积、BN 层与 Hardswish 激活函数提取的特征图, Y_1 表示对输入 Y_0 的依次经 PW 卷积、BN 层与 Hardswish 激活函数提取的特征图, X_{i+1} 表示对 X_i 与 Y_1 拼接得到最终提取的特征图。

DPHConv-2 模块对 N-Neck 中所有的卷积模块进行替换,旨在采用串行信息传输的方式,提高模型 N-Neck 部分对多尺度绝缘子缺陷的感知与融合能力。DPHConv-2 模块的计算过程为

$$Y_3 = \text{Hardswish}(\text{BN}(\text{DW}(Z_i))) \quad (6)$$

$$Z_{i+1} = \text{Hardswish}(\text{BN}(\text{PW}(Y_3))) \quad (7)$$

其中, Y_3 表示对输入的 Z_i (i 取 1、2、3... n) 依次经 DW 卷积、BN 层与 Hardswish 激活函数提取的特征图, Z_{i+1} 表示对输入的 Y_3 , 依次经 PW 卷积、BN 层与 Hardswish 激活函数提取得到最终的特征图。

1.1.2 CFI-X 模块

YOLOv8 的 C2f 中, Bottleneck 的参数数量较大,其结构如图 3 所示,按照式(1)可知其参数数量为 K^2HWC^2 ,其中 K 取 3。在特征图高(H)与宽(W)一定的情况下,只有通过降低卷积核尺寸大小(K^2)与改变通道数(C)可实现降参。

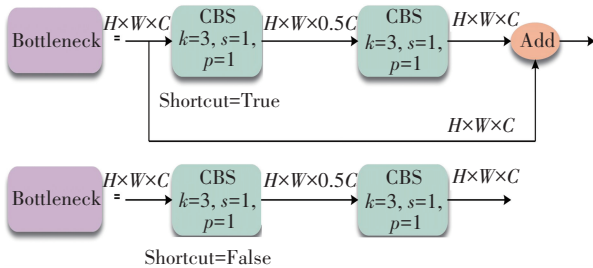


图 3 Bottleneck 结构图

Fig. 3 Bottleneck structure diagram

Inception-Bottleneck 是在 Inception-v1^[19-21]基础上设计的,结构见图 4,其中 CBS_{k₁}、CBS_{k₃} 分别表示卷积核大小为 1x1、3x3 的卷积 CBS。它对 Inception-v1 进行

了两点改进。第一是在卷积层与激活函数之间插入数据批量归一化 BN 层,来解决协方差偏移的问题,让数据更可控,同时加快神经网络训练过程中的收敛速度。第二是用两个 3x3 的卷积核替换其中的 5x5 卷积核,从而在保证感受野的同时降低参数量。

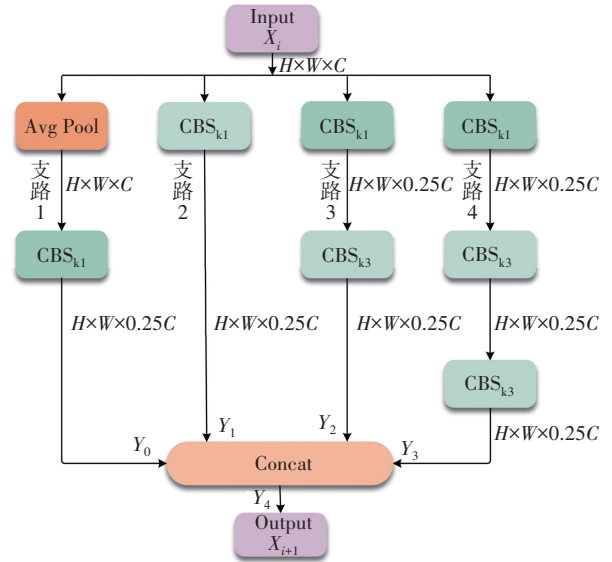


图 4 Inception-Bottleneck 结构图

Fig. 4 Inception-Bottleneck structure diagram

Inception-Bottleneck 模块中采用尺寸大小不同的卷积核,有望提升网络模型对同一层级不同尺度绝缘子图像中的特征信息的提取性能。模块结构由 4 条支路组成,采用网络并行多尺度特征提取的思想,削弱与绝缘子无关的冗余特征,集中强化绝缘子相关特征,提升网络的表征能力。其中模型支路 1、支路 3 与支路 4 中的 1x1 卷积用来改变通道数。支路 1 中的 Avg Pool、支路 3 与支路 4 中的 3x3 卷积用来提取空间信息,支路 2 中 1x1 卷积用来提取通道信息。Concat 融合可有效融合不同尺寸的特征信息,丰富绝缘子及绝缘子缺陷特征的语义信息,增强网络的特征提取能力。

由式(1)可知,Inception-Bottleneck 参数数量为 $K_1^2HWC^2 + 0.1875K^2HWC^2$,其中 K_1 取 1、 K 取 3。显然,其参数量远低于 Bottleneck。因此,为了使模型更加轻量化,采用 Inception-Bottleneck 替换 C2f 中的 Bottleneck,构造出图 5 的轻量化模块 CFI-X。根据 CFI-X 模块中 Inception-Bottleneck 数量 X 的不同划分为不同的 CFI 模块,从而更好地控制网络深度。根据大量实验,确定 N-YOLOv8 主干网络 N-CSPDarknet53 中 4 个 CFI 模块中的 X 依次取值 3、6、6、3,依次对应 CFI-3、CFI-6、CFI-6、CFI-3, N-Neck 网络中的 4 个 CFI 均含有 3 个 Inception-Bottleneck 模块,均对应 CFI-3。将 CFI-X 模块添加至

网络对应层级,使网络在检测精度小幅度下降的情况下,显著达到了轻量化的效果。

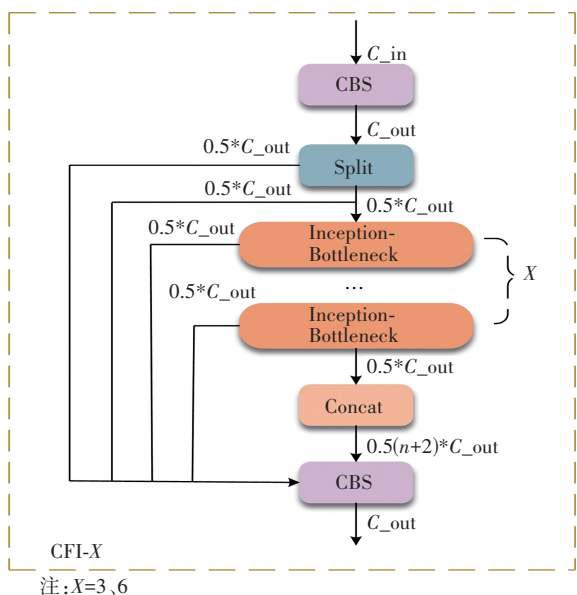


图 5 CFI-X 结构图

Fig. 5 CFI-X structure diagram

1.2 提升缺陷检测精度模块设计

1.2.1 PEG 注意力机制

ECA 注意力模块由平均自适应池化 (Adaptive AvgPool2d)、一维卷积 (Conv1d) 与激活函数 (Sigmoid) 组成。ECA 是一种轻量且有效的注意力机制,它通过学习通道之间的关联性自适应调整通道权重,不引入额外的参数。由于绝缘子图像中的绝缘子缺陷尺寸相较于绝缘子串或背景会很小,而平均自适应池化会对细节信息带来一定的损失,对绝缘子缺陷检测精度的提升方面存在一定的局限性。采用二维卷积 Conv2d 替换 ECA 中的一维卷积,构建出图 6 所示的 T-ECA 模块,它能更好地捕捉绝缘子图像中不同通道的关联信息。

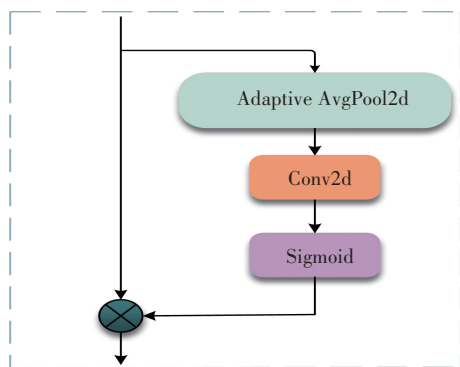


图 6 T-ECA 结构图

Fig. 6 T-ECA structure diagram

为了充分利用并融合表征绝缘子细微缺陷的有效

特征,以 T-ECA 模块作为基础模块,汲取 Gather Excite 注意力模块中框架分支思想,结合 1.1.2 节 Inception-Bottleneck 模块中多分支并行结构,设计一种针对绝缘子缺陷检测的注意力机制 PEG,其结构如图 7 所示。在 T-ECA 网络(支路 2)并行结构方向引入平均自适应池化 (Adaptive AvgPool2d)、最大自适应池化 (Adaptive MaxPool2d) 与激活函数 (Sigmoid) 分别组成的支路 1 与支路 3 网络,用于扩展网络的宽度。采用拼接融合、Hardswish 激活函数等现有技术,用于扩展网络的深度。利用具有宽度与深度的注意力机制 PEG,提取绝缘子特征图信息过程如下:

- (1) 输入的绝缘子图像分别经过支路 1、支路 2 与支路 3 进行绝缘子特征信息提取。
- (2) 将 3 条支路获得的同一绝缘子图像的 3 种不同尺度下的特征信息进行融合。
- (3) 融合后的绝缘子特征图输入至 Hardswish 激活函数进行处理,得到最终的特征图。

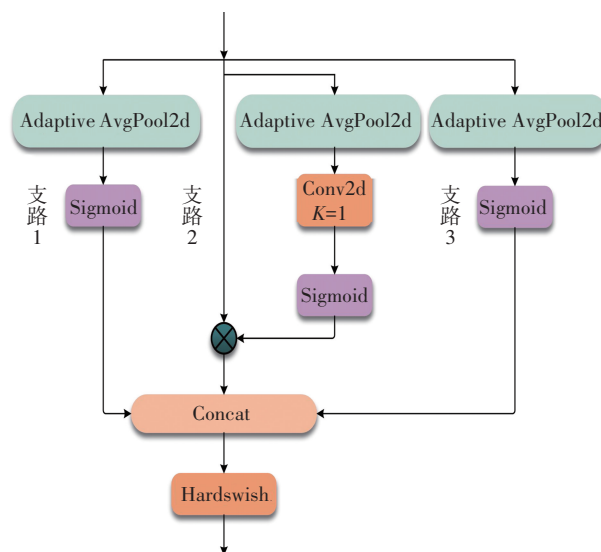


图 7 PEG 注意力机制

Fig. 7 PEG attention mechanism

PEG 注意力机制中使用的自适应池化有助于提高模型的泛化能力与灵活性,有效减少特征图维度,并对全局信息进行凝练。非线性激活函数 Sigmoid 是将经自适应池化输出后的每个元素映射至 0~1 之间的有限输出范围,使网络能够学习和提取复杂的绝缘子特征信息。Hardswish 激活函数是对融合 3 种不同尺度绝缘子特征图之后的图像再进行线性与非线性变换信息提取,进一步提升了网络对绝缘缺陷重要细节特征的学习能力,削减了复杂背景对绝缘缺陷检测带来的检测阻碍。

1.2.2 CEIOU 损失函数

原模型中 Loss 部分是由分类损失(BCE_Loss)和回归损失(DFL_Loss+CIoU_Loss)组成。BCE_Loss 用于衡量模型输出的概率与真实标签之间的差异。DFL_Loss^[22]可使网络聚集至绝缘子串及绝缘子缺陷相邻的分布区域,由预测框向标注框回归,并解决样本之间不平衡的问题。CIoU_Loss 用来精确地测量预测框与真实框之间的重叠程度。CIoU_Loss 衡量重叠程度时考虑了中心点距离、边界框回归的重叠面积与宽高比,但宽高比是预测框与真实框的宽高差异性比较,而非宽高真实值的差异性比较,这在一定程度会影响对模型的优化。

EIoU_Loss 在 CIoU_Loss 的基础之上,将长宽比的影响因子拆开,分别计算预测框与真实框宽高差异值的改进策略。此举措解决了 CIoU_Loss 没有考虑宽高真实值的差异性的缺陷,但它没有考虑反映预测框与真实框的宽高差异性的影响因子 αv 起到的作用。

为此,将 EIoU_Loss 中分别计算预测框与真实框的宽高差异值的策略直接应用于 CIoU_Loss,得到 CEIOU_Loss,使其同时具备两种损失函数的性能,对应数学模型见式(8)一式(13):

$$L_{\text{CIoU}} = 1 - f + \frac{\rho^2(b^p, b^{gt})}{c^2} + \alpha v \quad (8)$$

$$L_{\text{EIoU}} = 1 - f + \frac{\rho^2(b^p, b^{gt})}{c^2} + \frac{\rho^2(w^p, w^{gt})}{Cw^2} + \frac{\rho^2(h^p, h^{gt})}{Ch^2} \quad (9)$$

$$L_{\text{CEIOU}} = 1 - f + \frac{\rho^2(b^p, b^{gt})}{c^2} + \alpha v + \frac{\rho^2(w^p, w^{gt})}{Cw^2} + \frac{\rho^2(h^p, h^{gt})}{Ch^2} \quad (10)$$

$$f = \frac{\text{area}(B_p \cap B_{gt})}{\text{area}(B_p \cup B_{gt})} \quad (11)$$

$$\alpha = \frac{v}{1 - f + v} \quad (12)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w^p}{h^p} \right)^2 \quad (13)$$

其中,变量 f 表示 IoU, v 用来衡量长宽比一致性, α 是平衡参数, B_p 表示预测边框, B_{gt} 表示真实边框, IoU 表示预测边框与真实边框之间交集与并集的比, $\rho^2(b^p, b^{gt})$ 表示真实边框和预测边框的中心点的欧式距离, c 表示覆盖真实边框与预测边框最小边框的对角线长度, w^{gt}/h^{gt} 与 w^p/h^p 分别是真实边框与预测边框的宽长比, Cw 与 Ch 表示覆盖两个边框最小外接框的宽度和高度。

由式(10)可知,回归过程中预测框的高宽比首先

由 CIoU_Loss 进行改变,收敛到合适的范围之后,再通过 EIoU_Loss 对每个边框的边缘进行调整,直至收敛至正确的值。采用 CEIOU_Loss 对回归损失中的 CIoU_Loss 进行替换,以在反向传播过程中更好地使模型调整参数,减少网络训练与验证损失,增加对预测框调整的效率以及加快回归率,提升 N-YOLOv8 模型的检测精度。

1.2.3 Soft-NMS 算法

YOLOv8n 模型使用传统的非极大值抑制算法(NMS),利用得分高的边框抑制得分低且重叠程度高的边框,NMS 的计算公式如下:

$$S_i = \begin{cases} S_i, \text{IoU}(M, B_i) < N_i \\ 0, \text{IoU}(M, B_i) \geq N_i \end{cases} \quad (14)$$

在密集遮挡等复杂的背景下,绝缘子串位置之间存在重叠、交错等现象,在 NMS 算法中,当 $\text{IoU}(M, B_i) \geq N_i$ 时,该候选框的得分被直接置 0,且只保留得分最高且交并比 IoU 较低的预测框,可知此算法会对绝缘子检测带来一定的漏检问题。

针对此问题引入 Soft-NMS 算法替换 NMS 算法,Soft-NMS 的计算公式如下:

$$S_i = \begin{cases} S_i, \text{IoU}(M, B_i) < N_i \\ S_i e^{-\frac{\text{IoU}(M, B_i)^2}{\alpha}}, \text{IoU}(M, B_i) \geq N_i \end{cases} \quad (15)$$

其中, S_i 表示每个候选框的得分, M 表示最高置信度候选框, B_i 表示预测框, N_i 表示所设定的阈值。高斯惩罚函数 $\frac{-\text{IoU}(M, B_i)^2}{\alpha}$ 中超参数 α 经调优设置为 0.5。由

式(15)可知, $\text{IoU}(M, B_i) \geq N_i$ 时,采用 Soft-NMS 算法并没有将其得分直接置 0,而是采用惩罚机制降低与最高置信度候选框重叠的预选框的得分,能较好地缓解传统 NMS 算法暴力剔除带来的检漏问题,促进对密集遮挡下的绝缘子检测,提升网络的检测精度。

2 实验结果与分析

2.1 数据集构建

采用中国输电线路绝缘子数据集(CPLID),它包含绝缘子(Insulator)与绝缘子缺陷(Defect),缺陷类型为绝缘子脱串。其中含正常绝缘子图像的数量 600 张,含缺陷绝缘子图像的数量 248 张。为了避免训练过程中因数据集图片较少所造成的过拟合与泛化能力不足等问题,采用反转、色域变换、Mixup 数据增强等方法对 CPLID 扩充至 4 500 张,扩充样例如图 8 所示。其中, Mixup 数据增强的方法也为绝缘子密集遮挡等复杂背

景创造了条件,命名为 CPLID-DE,并按照训练集与验证集 4:1 的比例进行划分。




图 8 数据集扩充样例

Fig. 8 Examples of dataset augmentation

2.2 实验设备与评价指标

2.2.1 实验设备

实验在 CPU 型号为 Intel Core i7-10700K 3.80 GHz, GPU 为 NVIDIA GeForce RTX 2080 Ti,内存 32 GB,显存 11 GB, Windows11 系统, Pytorch1.13.1 框架, Python3.8 编程语言, Cuda11.6 与 Cudnn8.1.1 加速。实验相关参数 Batch size 设置为 8, Epochs 设置为 200, Optimizer 设置为 SGD, Momentum 设置为 0.937, Learning rate 为 0.01, Decay factor 为 0.0005。

2.2.2 评价指标

利用@mAP0.5、Parameters 以及 GFLOPs 作为网络性能评价指标。精准率(P)是模型预测所有的正类样本中预测正确的比例,其计算如式(16)所示。召回率(R)是在所有真实的正类样本中,模型预测正确的正类样本比例,其计算如式(17)所示。平均精度(F)是 P 与 R 所围成的曲线面积,其计算方法如式(18)所示,@mAP0.5 表示 IoU 阈值为 0.5 时 F 的平均值。

$$P = \frac{T_p}{T_p + F_p} \tag{16}$$

$$R = \frac{T_p}{T_p + F_N} \tag{17}$$

$$F = \int_0^1 P(R) dR \tag{18}$$

其中, T_p 表示预测为真,实际为真; F_p 表示预测为真,实际为假; F_N 表示预测为假,实际为假。

2.3 实验结果分析

2.3.1 消融实验

为了验证绝缘子缺陷检测轻量化网络 N-YOLOv8 设计的合理性,以 CPLID-DE 作为网络模型训练的数据集,以 YOLOv8n 为基础网络,依次引入 DPHConv、CFI-X、PEG 注意力机制、CEIoU_Loss 以及 Soft-NMS 模块进行消融实验,实验结果如表 1 所示。其中“√”表示对该模块的使用。

表 1 消融实验

Table 1 Results of ablation study

Test	DPHConv	CFI-X	PEG 注意力机制	CEIoU_Loss	Soft-NMS	Parameters/MB	GFLOPs	@mAP0.5/%
1						3.0	8.1	91.5
2	√					2.5	7.1	91
3	√	√				1.7	5.1	90.5
4	√	√	√			1.7	5.1	91
5	√	√	√	√		1.7	5.1	91.4
6	√	√	√	√	√	1.7	5.1	91.7

Test1 是对原始模型 YOLOv8n 进行训练实验,可知原模型的参数量为 3.0 M,浮点运算量为 8.1,检测精度高达 91.5%。Test2 是在 Test1 的基础上采用 DPHConv 轻量化模块对原模型中的卷积模块进行替换,参数量下降原模型参数的 16.7%,浮点运算量下降 12.3%,检测精度略降 0.5%。Test3 是在 Test2 的基础上采用 CFI-X 模块对网络中的 C2f 模块进行替换,检测精度相较 Test2 降低 0.5%,参数量与浮点运算量依次显著降低原模型的 43%、37%。Test4 是在 Test3 网络的小尺度目

标检测层后添加 PEG 注意力机制,检测精度提升至 91%,相比较 Test3 提升 0.5%。Test5 是采用 CEIoU_Loss 替换 Test4 网络中的 CIoU_Loss,网络检测精度提升至 91.4%,相比较 Test4 提升 0.4%。Test6 在 Test5 的基础上引入 Soft-NMS 算法,参数量为 1.7 M,浮点运算量为 5.1,检测精度高达 91.7%,相较 Test5 提升 0.2%,相较于原网络检测精度提升 0.2%。由消融实验可知,其中 Test2 与 Test3 验证了所设计模块的轻量化性能,Test4、Test5 与 Test6 验证了所设计模块提升绝缘

子缺陷检测精度的性能。因此,可以有效说明 N-YOLOv8 网络中 5 处模块设计是合理的,在保证网络检测精度的同时,很大程度上减少了网络模型的参数量,实现了网络的轻量化。

2.3.2 验证 PEG 注意力机制的合理性

为了验证 PEG 注意力机制设计的合理性,分别在 N-YOLOv8 模型的小尺度目标检测层(P3)后依次添加 Gather Excite、ECA 与 PEG 注意力机制,以相同的数据集 CPLID-DE 进行 3 次网络模型训练,对比结果如表 2 所示。

表 2 嵌入 3 种注意力模块的对比

Table 2 Comparison of three embedded attention modules

3 种注意力模块的对比	Parameters/MB	GFLOPs	@mAP0.5/%
Gather Excite	1.7	5.1	90.6
ECA	1.7	5.1	91
PEG	1.7	5.1	91.7

由表 2 可知,添加 3 种注意力机制后的 3 种网络模型的参数量与浮点运算量相同,在 N-YOLOv8 网络的 P3 后添加 PEG 注意力机制的检测精度最高,相较于添加 Gather Excite 注意力机制、ECA 注意力机制的检测精度依次提升 1.1%、0.7%。综上,PEG 注意力机制对绝缘子缺陷信息的提取能力以及应用至模型的检测准确率均强于 Gather Excite 与 ECA 注意力机制。

2.3.3 对比试验

为了验证网络 N-YOLOv8 的检测性能,采用经典网络对比、多尺寸对比、同类绝缘子检测方法进行对比,将网络模型 N-YOLOv8 与 3 种传统经典网络(Faster R-CNN、EfficientDet、SSD)和 2 种 YOLOv8 中不同尺寸网络模型以及 MDD-YOLOv3^[10]、GCP-YOLOv8s^[11]与 L-YOLOv5^[12],在绝缘子数据集 CPLID-DE 上展开对比实验,实验采用相同比例划分训练集与验证集。以轻量化评估指标(GFLOPs、Parameters)与检测精度评估指标(@mAP0.5)作为网络性能的评价标准,对比结果如表 3 所示。

由表 3 可知,N-YOLOv8 的参数量与浮点运算量均远远小于 3 种传统经典网络,检测精度均高于单阶段目标检测网络 EfficientDet 与 SSD。主干网络为 ResNet-101 的两阶段目标检测网络 Faster R-CNN 检测精度高于网络 N-YOLOv8 检测精度 1.1%,但模型参数很大,无法满足实际部署的要求。YOLOv8s 模型参数量与浮点运算量远超 N-YOLOv8 模型的数倍,网络检测精度仅高于 N-YOLOv8 网络检测精度的 0.4%。N-YOLOv8 网络模型体积参数为 1.7 M,网络检测精度高达 91.7%,相比较 YOLOv8n 的模型体积缩减 43%,浮

点运算量降低 37%。在同类绝缘子检测方法对比中,N-YOLOv8 比 MDD-YOLOv3 的参数量、浮点运算量依次降低 87.4%、84.9%、检测精度提升 0.3%;N-YOLOv8 比 GCP-YOLOv8s 的参数量、浮点运算量依次降低 76.4%、75.2%,检测精度提升 0.8%。N-YOLOv8 比 L-YOLOv5 的参数量、浮点运算量依次降低 50%、45.2%,在参数量与浮点运算量显著降低的基础上,检测精度仅下降 0.2%。与不同网络模型相比,N-YOLOv8 网络的参数量与浮点运算量更小,检测精度较高,算法相对较优,更适合在无人机上部署。

综上,N-YOLOv8 网络在模型轻量化的同时,检测精度可以达到一定的水准,模型部署对硬件的要求较小,一定程度解决了在硬件条件有限的情况下,部署困难的问题。

表 3 不同目标检测模型对比实验

Table 3 Comparative experiment of different target detection models

网络模型	主干网络	Parameters/MB	GFLOPs/G	@mAP0.5/%
FasterR-CNN	ResNet-101	118.2	79.1	92.8
EfficientDet	EfficientNet-B0	5.7	11.3	82.4
SSD	VGG-SSD	26.2	32.1	81.3
MDD-YOLOv3	D-Darknet53	13.5	33.8	91.4
L-YOLOv5	L-Darknet53	3.4	9.3	91.9
YOLOv8s	CSPdarknet53	11.1	28.6	92.1
GCP-YOLOv8s	G-CSPdarknet53	7.2	20.6	90.9
YOLOv8n	CSPdarknet53	3.0	8.1	91.5
N-YOLOv8	N-CSPdarknet53	1.7	5.1	91.7

2.3.4 测试 N-YOLOv8 的性能

N-YOLOv8 网络的损失函数由分类损失(BCE_Loss)、回归损失(DFL_Loss+CEIoU_Loss)所组成。N-YOLOv8 与 YOLOv8 网络使用相同的 CPLID-DE 数据集,在表 1 的实验参数下进行训练,对比结果分别如图 9 与图 10 所示。图 9 表示两种网络的训练损失与验证损失之间的对比曲线图,其显示 N-YOLOv8 的损失低于 YOLOv8n 网络,收敛效果更好,同时验证了采用 CEIoU_Loss 网络的损失最小,说明改进后的 CEIoU_Loss 优于原始网络中的 CIoU_Loss。图 10 表示 YOLOv8n 与 N-YOLOv8 的准确率曲线,其显示 N-YOLOv8 的准确率在迭代 45 次时趋于稳定,在迭代 200 次后,N-YOLOv8 网络准确率最高。上述结果说明:N-YOLOv8 针对 YOLOv8n 做出的改进策略,可以优化网络性能,提升网络的检测准确率。




图 9 损失对比

Fig. 9 Loss comparison




图 10 准确率对比

Fig. 10 Accuracy comparison

为了更直观地展示改进前后两种模型的对比结果,图 11 展示了网络 YOLOv8n 与网络 N-YOLOv8 分别对 4 处不同背景下的绝缘子及绝缘子缺陷检测的结果。YOLOv8n 网络检测效果图中背景 1 的 1 处与背景 2 的 2 处表示两种模型检测结果的差异,由图可知原模型在背景 1 的 1 处出现误检的问题,在背景 2 的 2 处出现漏检的问题。由背景 1 与背景 2 检测对比结果可知,N-YOLOv8 网络更能准确地检测出绝缘子以及绝缘子缺陷的位置,更能有效避免原网络出现的误检、漏检问题。由第 3 处背景下的绝缘子缺陷检测对比结果可知,YOLOv8n 网络检测绝缘子缺陷的概率仅为 74%,表明原网络模型对绝缘子缺陷信息的提取能力相对较弱,N-YOLOv8 网络以高达 93%的概率定位出绝缘子的位置,再检测出绝缘子缺陷概率为 81%,相较于原网络缺陷检测概率大幅度提升 7%,体现出 PEG 注意力机制可有效提升对网络绝缘子缺陷的检测能力。第 4 处背景是采用 Mixup 数据增强的方法所得到的绝缘子密集遮挡复杂背景,由网络改进前后的检测结果对比可知,在原始网络 YOLOv8n 的检测下,使用 NMS 算法出现了绝缘子串及绝缘子缺陷漏检的问题,而网络 N-YOLOv8 采用 Soft-NMS 算法分别以 66%、70%的概率定位出绝缘子的位置,同时以 62%、71%的概率检测出绝缘子缺陷的位置,说明在绝缘子密集遮挡复杂背景下 Soft-NMS 算法优于 NMS 算法。

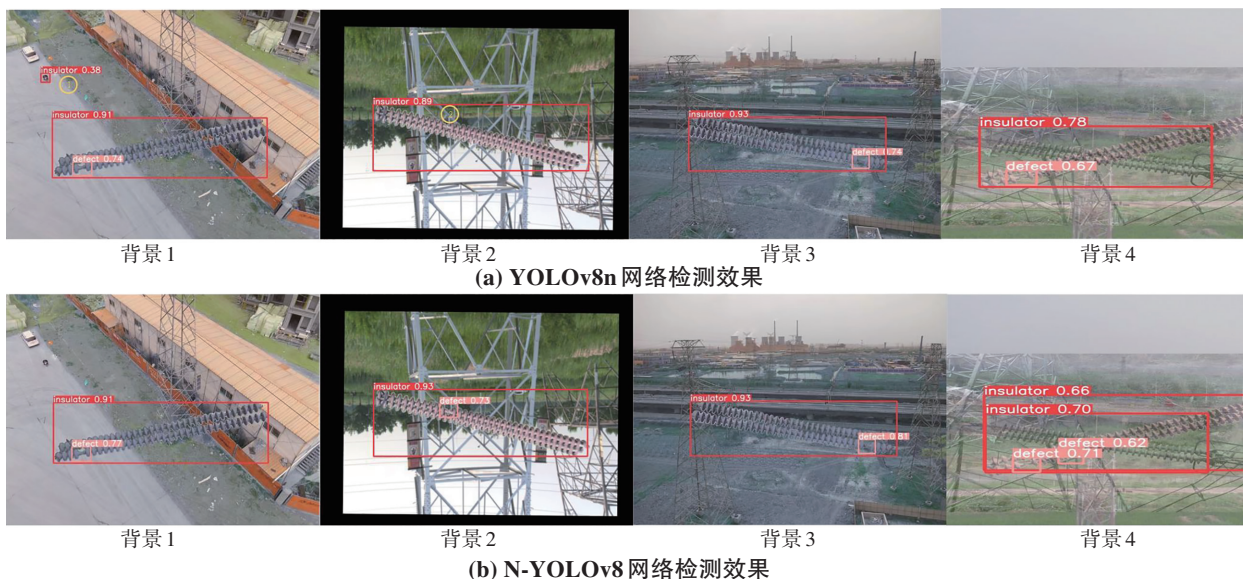


图 11 改进前后网络检测效果对比图

Fig. 11 Comparison of network detection results before and after improvement

综上,N-YOLOv8 网络采用 PEG 注意力机制和 CEIoU_Loss,可以有效提升网络在不同场景下对绝缘子

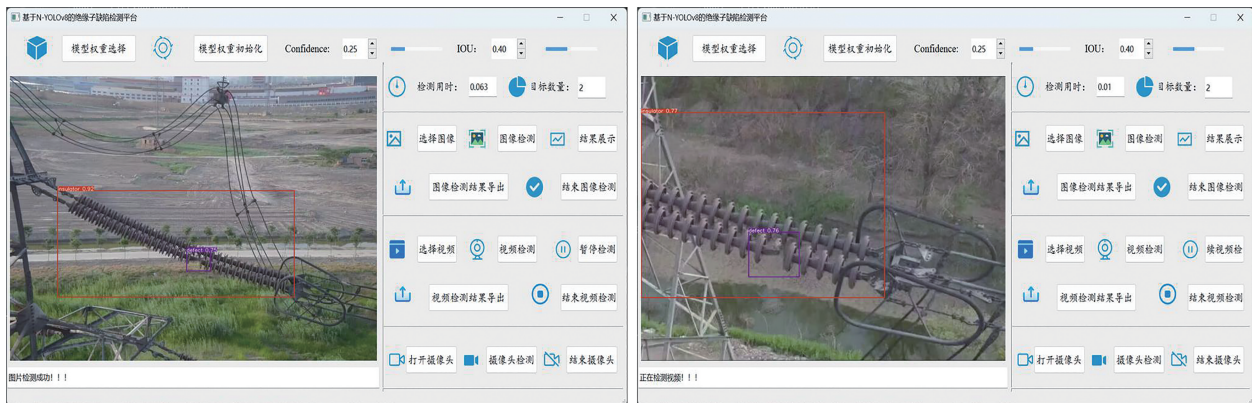
缺陷的检测能力,Soft-NMS 可以有效解决绝缘子串及绝缘缺陷在密集遮挡场景下的漏检难题。

3 检测平台测试与结论

3.1 检测平台测试

根据上述实验,本文开发了基于 N-YOLOv8 的绝缘子缺陷检测平台,其功能主要包括图像检测、视频检测与摄像头实时监控。检测平台对真实无人机巡检场景下所采取的绝缘子缺陷图像检测和视频检测结果如图 12 所示。检测平台运作时,会快速定位检测到绝缘子串的位置,并准确地检测到绝缘子缺陷的

位置,一轮巡检结束之后,可将图像或视频检测结果导出,进行信息整合,有利于电力运维人员的分析。该检测平台可根据用户的实际需求来调节置信度与 IoU 值的大小,以适应不同的应用场景,可结合无人机的灵活特性,实现对绝缘子位置的精准定位以及绝缘子缺陷的实时监控,验证了无人机在真实巡检下的绝缘子缺陷检测性能,提高电力设施巡检的效率,确保电网的稳定性和安全性。



(a) 绝缘子缺陷图片检测

(b) 绝缘子缺陷视频检测

图 12 基于 N-YOLOv8 的绝缘子缺陷检测平台

Fig. 12 Insulator defect detection platform based on N-YOLOv8

3.2 结论

本文针对绝缘子缺陷设计了一种轻量化检测模型 N-YOLOv8,并建立了绝缘子缺陷检测平台。其中,DPHConv 模块能显著减少网络参数数量与浮点运算量,并有效增强网络的表达能力;CFI-X 模块在轻量化的同时,能提高网络的感受野以及网络在多尺度特征提取的能力。N-YOLOv8 中,PEG 注意力机制有助于提高模型对绝缘子缺陷检测的性能;CEIoU_Loss 能更高效地减少网络训练与验证损失,提升网络检测精度;采用 Soft-NMS 算法,能解决密集遮挡场景下漏检问题,进一步提升网络模型的检测性能。N-YOLOv8 在 CPLID-DE 数据集上测试的模型参数数量为 1.7 MB,检测精度高达 91.7%,在模型体积压缩与提升检测精度等方面都达到了预期效果,实现了对绝缘子缺陷的检测。

参考文献(References):

- [1] 亢洁,王勃,刘文波,等.融合 CAT-BiFPN 与注意力机制的航拍绝缘子多缺陷检测网络[J].高电压技术,2023,49(8):3361-3376.
- KANG Jie, WANG Qing, LIU Wen-bo, et al. Detection model of multi-defect of aerial photo insulator by integrating CAT-BiFPN and attention mechanism[J]. High Voltage

Engineering, 2023, 49(8): 3361-3376.

- [2] PAN X, GE C, LU R, et al. On the integration of self-attention and convolution[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2022: 805-815.
- [3] 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 Zhi-wei, HUANG Xin-bo, JI Chao, et al. Insulator defect detection and fault warning method for transmission line based on flexible YOLOv7[J]. High Voltage Engineering, 2023, 49(12): 5084-5094.
- [4] 翟永杰,赵晓瑜,王璐瑶,等.IDD-YOLOv7:一种用于输电线路绝缘子多缺陷的轻量化检测方法[J].图学学报,2024,45(1):90-101.
- ZHAI Yong-jie, ZHAO Xiao-yu, WANG Lu-yao, et al. IDD-YOLOv7: A lightweight method for multiple defect detection of insulators in transmission lines[J]. Journal of Graphics, 2024, 45(1): 90-101.
- [5] 陈奎,刘晓,贾立娇,等.基于轻量化网络与增强多尺度特征融合的绝缘子缺陷检测[J].高电压技术,2024,50(3):1289-1300.
- CHEN Kui, LIU Xiao, JIA Li-jiao, et al. Insulator defect

- detection based on lightweight network and enhanced multi-scale feature fusion[J]. *High Voltage Engineering*, 2024, 50(3): 1289–1300.
- [6] REZATOFI H, TSOI N, GWAK J, et al. Generalized intersection over union: A metric and a loss for bounding box regression[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE Press, 2019: 658–666.
- [7] 黄悦华,刘恒冲,陈庆,等. 基于 USRNet 与改进 YOLOv5x 的输电线路绝缘子故障检测方法[J]. *高电压技术*, 2022, 48(9): 3437–3446.
- HUANG Yue-hua, LIU Heng-chong, CHEN Qing, et al. Transmission line insulator fault detection method based on USRNet and improved YOLOv5x[J]. *High Voltage Engineering*, 2022, 48(9): 3437–3446.
- [8] ZHANG Y F, REN W, ZHANG Z, et al. Focal and efficient IoU loss for accurate bounding box regression [J]. *Neurocomputing*, 2022, 506: 146–157.
- [9] 欧阳名三,李杰. 基于改进 DETR 的绝缘子缺陷检测算法[J]. *重庆工商大学学报(自然科学版)*, 2025, 42(1): 20–27.
- OUYANG Ming-san, Li Jie. The insulator defect detection algorithm based on improved DETR[J]. *Journal of Chongqing Technology and Business University (Natural Science Edition)*, 2025, 42(1): 20–27.
- [10] 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 Xiao-fen, YU Ye-qi, GUO Yong-cun, et al. Lightweight detection method of self-explosion defect of aerial photo insulator[J]. *High Voltage Engineering*, 2023, 49(1): 294–300.
- [11] 黄福珍,王天赐. 基于轻量化 GCP-YOLOv8s 的绝缘子缺陷检测[J]. *激光与光电子学进展*, 2025, 62(2): 0212004.
- HUANG Fu-zhen, WANG Tian-ci. Insulator defect detection based on lightweight GCP-YOLOv8s [J]. *Laser & Optoelectronics Progress*, 2025, 62(2): 0212004.
- [12] 王道累,张世恒,袁斌霞,等. 基于改进 YOLOv5 的轻量化玻璃绝缘子自爆缺陷检测研究[J]. *高电压技术*, 2023, 49(10): 4382–4390.
- WANG Dao-lei, ZHANG Shi-heng, YUAN Bin-xia, et al. Research on self-explosion defect detection of lightweight glass insulators based on improved YOLOv5[J]. *High Voltage Engineering*, 2023, 49(10): 4382–4390.
- [13] 王德文,李业东. 基于 WGAN 图片去模糊的绝缘子目标检测[J]. *电力自动化设备*, 2020, 40(5): 188–198.
- WANG De-wen, LI Ye-dong. Insulator object detection based on image deblurring by WGAN[J]. *Electric Power Automation Equipment*, 2020, 40(5): 188–198.
- [14] 李帷韬,侯建平,张倩,等. 基于强化学习和 Transformer 的输电线路缺陷智能检测方法研究[J]. *高电压技术*, 2023, 49(8): 3373–3384.
- LI Wei-tao, HOU Jian-ping, ZHANG Qian, et al. Research on intelligent detection method of transmission line defects based on reinforcement learning and Transformer[J]. *High Voltage Engineering*, 2023, 49(8): 3373–3384.
- [15] HU J, SHEN L, ALBANIE S, et al. Gather-excite: Exploiting feature context in convolutional neural networks[J]. *Advances in Neural Information Processing Systems*, 2018, 31.
- [16] WANG Q, WU B, ZHU P, et al. ECA-net: efficient channel attention for deep convolutional neural networks[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE Press, 2020: 11531–11539.
- [17] BODLA N, SINGH B, CHELLAPPA R, et al. Soft-NMS—improving object detection with one line of code[C]//*Proceedings of the IEEE International Conference on Computer Vision*. Piscataway: IEEE Press, 2017: 5562–5570.
- [18] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE Press, 2016: 770–778.
- [19] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE Press, 2016: 2818–2826.
- [20] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, inception-resnet and the impact of residual connections on learning[C]//*Proceedings of the AAAI conference on artificial intelligence*. San Francisco, California, USA: AAAI Press, 2017, 31(1): 4278–4284.
- [21] CHOLLET F. Xception: Deep learning with depthwise separable convolution[C]//*Proceedings of the IEEE conference on computer vision and pattern recognition*. Honolulu, HI, USA: IEEE, 2017: 1800–1807.
- [22] LI X, WANG W, WU L, et al. Generalized focal loss: Learning qualified and distributed bounding boxes for dense object detection[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 21002–21012.

责任编辑:陈芳