

陈鑫,唐东峰,江拼,等. 基于改进轻量化 YOLOv8n 的输电线路绝缘子故障检测模型[J]. 湖南科技大学学报(自然科学版), 2025, 40(1):60-68. doi:10.13582/j.cnki.1672-9102.2025.01.009

CHEN X, TANG D F, JIANG P, et al. A Fault Detection Model for Transmission Line Insulators Based on Improved Lightweight YOLOv8n [J]. Journal of Hunan University of Science and Technology (Natural Science Edition), 2025, 40(1):60-68. doi:10.13582/j.cnki.1672-9102.2025.01.009

基于改进轻量化 YOLOv8n 的输电线路 绝缘子故障检测模型

陈鑫,唐东峰*,江拼,唐钊,黄新凯

(湖南科技大学 信息与电气工程学院,湖南 湘潭 411201)

摘要:针对航拍巡检高压输电线路绝缘子目标易受复杂背景和部分遮挡影响,造成传统算法难以准确检测的问题,提出了一种基于改进 YOLOv8n 的轻量化检测模型.模型整体由主干特征提取网络、颈部特征融合网络、头部检测网络等3个部分构成.利用 C2f_Star 替换主干网络和颈部网络中 C2f 模块,很大程度上缩减了模型大小;在头部网络部分引入细节增强卷积(DEConv)捕捉更细微的故障特征,增强了对局部特征的表达;通过组归一化(GN)技术提高了模型在数据上的泛化能力;在定位分支采用可变形卷积(DCNV2),以适应目标的几何变形,实现更精确的定位.模型还通过任务分解与特征融合策略,加强分类与定位任务间的交互,进一步提升检测性能.利用无人机巡检图像制作数据集,将改进算法与4种经典目标检测算法进行比较实验,结果表明:该模型的平均检测精度可以达到98.5%,每张图片的检测时间为0.01s,兼具了检测的准确率和轻量化.

关键词:输电线路;绝缘子故障检测;YOLOv8n;轻量化模型;深度学习

中图分类号:TP391.41

文献标志码:A

文章编号:1672-9102(2025)01-0060-09

A Fault Detection Model for Transmission Line Insulators Based on Improved Lightweight YOLOv8n

CHEN Xin, TANG Dongfeng, JIANG Pin, TANG Zhao, HUANG Xinkai

(School of Information and Electrical Engineering, Hunan University of Science and Technology, Xiangtan 411201, China)

Abstract: Aiming at the problem that insulator targets on high-voltage transmission lines are difficult to be accurately detected by traditional algorithms due to complex backgrounds and partial occlusions in aerial inspection, this study proposes a lightweight detection model based on the improved YOLOv8n. The model is composed of three parts, i.e. the backbone feature extraction network, the neck feature fusion network, and the head detection network. By replacing the C2f module in the backbone network and the neck network with C2f_Star, the model size is significantly reduced. In the head network, detail enhancement convolution (DEConv) is introduced to capture more subtle fault features and enhance the expression ability of local features. Group normalization (GN) technology is used to improve the model's generalization ability on data. Deformable convolution (DCNV2) is adopted in the localization branch to adapt to the geometric deformation of the target and achieve more accurate localization. The model also enhances the interaction between classification and

localization tasks through task decomposition and feature fusion strategies, further improving the detection performance. A dataset is created using aerial inspection images of unmanned aerial vehicles, and the improved algorithm is compared with four classic object detection algorithms. The results show that the average detection accuracy of the model can reach 98.5%, and the detection time for each image is 0.01 s, achieving a balance between detection accuracy and lightweight.

Keywords: transmission lines; insulator fault detection; YOLOv8n; lightweight model; deep learning

在人人用电的大背景下,电能作为我们的生活中不可或缺的存在,这使得电力系统的安全运行显得至关重要.绝缘子作为输电线路中的关键元件,不仅起到支撑导线的作用,还提供了必要的电气隔离,以确保电力系统的正常工作.然而,绝缘子长期暴露在户外,接受着各种自然因素的侵蚀,导致绝缘子的性能下降,甚至发生故障,这不仅会导致电力传输的中断,还可能引发大规模的停电事件,进而影响整个输电线路的安全运行^[1-2],对社会经济造成重大影响.因此,绝缘子的故障检测研究对于保障电力系统的稳定运行具有重要意义.

在实际工作中,传统的绝缘子检测方法主要依赖人工巡检,这种方法不仅效率低下、成本高昂,而且存在一定的安全隐患.伴随着无人机技术的兴起以及深度学习目标检测算法的不断突破,智能化的绝缘子故障检测方法得以快速发展,并展现出了巨大潜力^[3].深度学习通过对图像中的特征进行自动学习,从而去识别可能存在的相似特征,这种方法相较于传统的人工巡检为绝缘子故障检测提供了一种高效、准确的解决方案^[4-5].然而,将现有的深度学习模型运用在工程实际应用中仍然存在一些挑战.属于 Two-stage 算法的 Faster R-CNN 虽然在目标检测精度上表现出色,但其计算复杂度高、检测速度慢,难以满足实时检测的需求^[6-7];属于 One-stage 算法的 YOLO 系列虽然检测速度快,但在小目标检测和复杂背景识别上存在不足,特别是在针对无人机巡检图像的情况下,尤为明显^[8-9].为了克服这些挑战,研究者们进行了大量的创新工作.例如,KUMAR 等^[10]提出的 Mask R-CNN 通过引入区域分割的概念,显著提高了目标检测的精度,尤其在需要精细定位目标的场景中表现出色;ARUN 等^[11]提出的 EfficientNet 通过系统地缩放网络尺寸,实现了更高的效率和准确性,为轻量化模型设计提供了新思路.此外,轻量化模型设计也成为当前研究的热点.轻量化模型通过减少模型参数和计算量,能够在保持检测精度的同时,满足在工程项目中实际应用需求^[12-13].

基于现有研究,本文提出了一种基于改进 YOLOv8n 的轻量化输电线路绝缘子故障检测模型.该模型融合了轻量化 C2f_Star 模块、细节增强卷积(DeConv)、组归一化(Group Normalization, GN)和可变形卷积(Deformable Convolution V2, DConv2)等先进技术,既能提高模型的检测精度和鲁棒性,又能实现模型的轻量化,满足无人机图像处理设备的实时检测需求.并且在模型的头部网络部分设计了一种特征提取器学习联合特征,加强分类与定位任务间的交互,提升模型的整体性能.使得模型在检测精度和速度上均展现出显著的优势,这些成果为输电线路绝缘子故障的自动化检测提供了一种有效的技术手段,对于提高电力系统的运维效率和安全性具有重要意义.

1 改进的 YOLOv8n 算法

1.1 C2f_Star 模块

在原始 YOLOv8n^[14-15]主干网络中,C2f 模块由标准卷积和多个瓶颈(Bottleneck)模块组成,结构如图1所示,进而造成原模型复杂度高,推理速度慢,不适用于输电线路绝缘子故障检测任务,因此,为了最大程度地减少计算冗余并优化主干部分的参数量,本文使用 Star Blocks^[16]模块替换 C2f 模块中的 Bottleneck 模块,降低模型的参数量和计算复杂度.其结构如图2所示,由一个卷积层组成,该层将输入分辨率降低了16倍,然后是一系列同质演示块,用于特征提取.在每个演示块中,应用星形操作或求和操作合并来自2个不同分支的特征.




图 1 C2f 结构图及 Bottleneck 结构




图 2 Star Blocks 结构

在神经网络的单层中,星形操作通常被写为 $(W_1^T X + B_1)(W_2^T X + B_2)$, 这表示通过逐元素乘法融合 2 个线性变换的特征.为了方便起见,将权重矩阵和偏置合并为一个实体,记作 $W = \begin{bmatrix} W \\ B \end{bmatrix}$, 同样地, $X = \begin{bmatrix} X \\ 1 \end{bmatrix}$, 从而简化星形操作为 $(W_1^T X)(W_2^T X)$. 为了简化分析,关注涉及一个输出通道变换和单元元素输入的情况.具体来说,定义 $w_1, w_2, x \in \mathbf{R}^{(d+1) \times 1}$, 其中 d 是输入通道数.它可以很容易地扩展到多个输出通道 $W_1, W_2 \in \mathbf{R}^{(d+1) \times (d+1)}$ 和处理多个特征元素,其中 $X \in \mathbf{R}^{(d+1) \times n}$.

一般来说,可以将星形操作重写为

$$w_1^T w_2^T x = \left(\sum_{i=1}^{d+1} w_1^i x^i \right) \left(\sum_{j=1}^{d+1} w_2^j x^j \right) = \sum_{i=1}^{d+1} \sum_{j=1}^{d+1} w_1^i w_2^j x^i x^j = \underbrace{\alpha_1^1 x^1 + \dots + \alpha_{(4,5)} x^4 x^5 + \dots + \alpha_{(d+1,d+1)} x^{d+1} x^{d+1}}_{(1,1)}. \quad (1)$$

式中: i, j 为使用索引通道; α 为每个项的系数.

$$\alpha_{(i,j)} = \begin{cases} w_1^i w_2^j, & \text{if } i = j; \\ w_1^i w_2^j + w_1^j w_2^i, & \text{if } i \neq j. \end{cases} \quad (2)$$

将式(1)的星形操作重写后,可以将其扩展为一个由 $\frac{(d+2)(d+1)}{2}$ 个不同项组成的组合.值得注意的是,除了 $\alpha_{(d+1,d+1)} x^{d+1} x^{d+1}$ 项外,每个项(与 x)都表现出非线性关联,表明它们是独立且隐式的维度.因此,使用计算效率高的星形操作在 d 维空间中执行计算,却能在 $\frac{(d+2)(d+1)}{2} \approx \left(\frac{d}{2}\right)^2$ (考虑 $d \gg 2$) 隐式维特征空间中实现表示,显著放大了特征维度,而无需在单个层中增加任何额外的计算开销.

因此,通过堆叠多层,即使只有几层,星形操作也可以指数方式显著放大隐式维度.综上所述使用 Star Blocks 模块替换 C2f 模块中的 Bottleneck 模块,可以实现模型的轻量化,且不会降低模型的精度,改进后的 C2f 模块如图 3 所示.

1.2 DEConv_GN 模块

本研究在 YOLOv8n 检测模型的输出部分集成了一种创新的卷积单元——细节增强卷积(DEConv),这一组件在 DEA-Net^[17] 架构中已被证实可有效地提升性能.DEConv 的核心优势在于其能够将先验知识整合入卷积过程中,从而增强网络对特征的表达和泛化.

值得一提的是,DEConv 通过一种重参数化技术,能够无损地转换为标准卷积形式,这种转换利用了卷积操作的线性属性,同时避免了增加额外的参数负担和计算开销.这一特性使得 DEConv 在保持计算效率的同




图 3 C2f_Star 结构

时,能够提供更为强大的特征提取能力.

DEConv 卷积由 5 个并行工作的卷积层构成,结构图如图 4 所示.具体来说,DEConv 分别采用了中心差分卷积(CDC)、角差分卷积(ADC)、水平差分卷积(HDC)以及垂直差分卷积(VDC),通过这些卷积计算图像中像素间的差异,并将这些差异与卷积核相结合,进而生成能够提供更深层次的视觉信息特征图,这不仅可以提高识别能力,还可以提高模型对于各种图像特征的泛化能力.

中心差分卷积(CDC)和角差分卷积(ADC):中心差分卷积和角差分卷积是差分卷积的 2 种具体形式,分别关注图像的中心区域和角区域.

水平差分卷积(HDC)和垂直差分卷积(VDC):水平差分卷积和垂直差分卷积分别关注图像的水平 and 垂直方向上的特征,各差分卷积可以表示为

$$y(p_0) = \sum_{p_n \in \mathfrak{N}} w(p_n) [x(p_0 + p_n) - x(p_0)]. \quad (3)$$

式中: $\mathfrak{N}$ 为不同方向的领域,根据不同的差分卷积选取,如水平差分卷积的 $\mathfrak{N}$ 表示水平方向的领域.

对于重新参数化技术,可以表示为

$$F_{out} = \text{DEConv}(F_{in}) = \sum_{i=1}^5 F_{in} * K_i = F_{in} * (\sum_{i=1}^5 K_i) = F_{in} * K_{cut}. \quad (4)$$

式中: $\text{DEConv}(\cdot)$ 为 DEConv 的运算; K_i 为 VC, DC, ADC, HDC 和 CDC 的核; $*$ 为卷积操作; K_{cut} 为将并行卷积组合在一起的转换核.

Group Normalization(GN)作为深度学习中的一种归一化技术,其作用在于解决小批量大小下性能下降的问题.其通过在特征通道的组内进行归一化,从而去提高模型的泛化能力以及模型的稳定性.

GN 通过假设特征图的形状为 $[N, C, H, W]$,其中 N 是批量大小, C 是通道数, H 和 W 是特征图的高度和宽度,将 C 个通道分成 G 个组,每组有 C/G 个通道,对于每个组,计算该组内的均值 μ_{ng} 和方差 σ_{ng}^2 , 计算公式为

$$\mu_{ng} = \frac{1}{(C/G)HW} \sum_{c=g(C/G)}^{(g+1)(C/G)-1} \sum_{h=1}^H \sum_{w=1}^W x_{nchw}; \quad (5)$$

$$\sigma_{ng}^2 = \frac{1}{(C/G)HW} \sum_{c=g(C/G)}^{(g+1)(C/G)-1} \sum_{h=1}^H \sum_{w=1}^W (x_{nchw} - \mu_{ng})^2. \quad (6)$$

式中: x_{nchw} 为第 n 个样本在第 c 个通道、第 h 行、第 w 列的特征值.

之后对每个组内的特征进行归一化,计算公式为

$$\hat{x}_{nchw} = \frac{x_{nchw} - \mu_{ng}}{\sqrt{\sigma_{ng}^2 + \varepsilon}}. \quad (7)$$

式中: ε 为一个很小的常数,用于防止分母为零,通常取 10^{-5} .

通过将 GN 与 DEConv 卷积相结合,使得 DEConv_GN 模块能够更加准确地去处理不同分辨率下的图像,无论是在近距离还是远距离的无人机图像分析中,都能够实现有效的学习以及泛化,使其能够成为提高输电线路绝缘子故障检测精度的理想方案.

1.3 DCNv2 模块

通过引入可变形卷积 DCNv2(Deformable Convolution, DCN)^[18],得益于模块的灵活性,使其能够很好地适应图像中的相对细微的特征,特别是在闪络等相对不明显的故障情况,能够实现对缺陷的精准定位,从而提高模型检测的精确性.

DCNv2 模块巧妙地结合了多个元素.它以可变卷积层为基础,引入批量归一化过程、Hardswish 激活函数,优化了模型的训练,从而确保了模型在学习过程中的稳定性和效率,进一步提升了模型的整体性能,图




图 4 DEConv 结构

5 表示的是普通的 3×3 卷积采样方式,而图 6 表示的是可变卷积的采样方式.




图 5 普通卷积的采样方式




图 6 可变卷积的采样方式

设 x 为输入特征图, y 为输出特征图, P_0 代表输出特征图的当前位置, 对于一个普通的 3×3 卷积要输出 $y(P_0)$, 要在 x 上采样 9 个位置, 这 9 个位置是由中心点 $x(P)$ 向四周均匀扩散得到的, 其中扩散位置表示为 $R = \{(-1, 1), (-1, 0), \dots, (0, 1), (1, 1)\}$, $y(P_0)$ 的表达方式为

$$y(P_0) = \sum_{k=1}^K W_k x(P + P_k). \quad (8)$$

式中: W 为卷积核; P_k 为卷积核位置; k 为采样点位置; K 为采样点总量. 可变卷积并没有改变原卷积的计算操作, 而是在原卷积操作的基础上引入一种新的可学习参数 ΔP_k . 对于输出 $y(P_0)$, 依然要从中心位 $x(P)$ 上采样, 但是由于引入的 ΔP_k 采样点扩散呈非均匀分布, 新的 $y(P_0)$ 的表达方式为

$$y(P_0) = \sum_{k=1}^K W_k x(P + P_k + \Delta P_k). \quad (9)$$

在提升模型对细微的特征的识别方面 DCNv2 模块采用了一种创新的调节策略^[19]. 该策略通过在训练过程中动态地去调整各区域的特征强度, 从而去增强模型对输入数据的理解 and 处理. 这种策略甚至能够将某些区域的特征响应降至最低, 实现特征的零响应, 从而让模型有选择性地忽略那些对于当前任务不重要的特征信号, 其数学表达式如式(10)所示.

$$y(P_0) = \sum_{k=1}^K W_k x(P + P_k + \Delta P_k) \Delta m_k. \quad (10)$$

式中: ΔP_k 和 Δm_k 为第 k 个位置的学习偏移和调制标量. ΔP_k 和 Δm_k 都是通过应用于相同输入特征 x 的单独卷积获得. DCNv2 的结构如图 7 所示.




图 7 DCNv2 结构

通过引入可变卷积的采样方式和调节机制, 网络能更好的关联各种有效特征分布. 因此本文在模型中的探头部分引入 DCNv2 模块, 提高对于输电线路绝缘子复杂故障的定位.

2 改进后的网络模型

为了确保所设计的模型能够轻量化并提高检测精度, 对原始的 YOLOv8n 模型进行了优化以及改造. 用 C2f_Star 模块替代了原有的 C2f 模块. 通过简化网络结构, 去除了模型当中冗余的参数, 在头部网络部

分,本研究提出了一种创新的 Head 模型,命名为 TADEDH,其设计灵感来源于 TOOD^[20] 论文中所提出的概念,所设计的模型在标签分配策略上采用了任务对齐的方法.具体而言,TADEDH 模型首先利用 p3、p4、p5 特征图通过 2 个 DEConv_GN 模块进行特征处理,然后将这些特征图进行拼接,以生成交互特征.交互特征随后被用于生成可变形卷积 DCNV2 中的 mask 和 offset,进一步地,模型利用 ReLU 和 Sigmoid 激活函数对交互特征进行处理,生成一个旨在强调动态特征选择的模块.同时,任务拆解模块对生成的交互特征进行拆分,这一模块的设计参考了 TOOD 论文中的 TAP 模块,如图 8 所示.拆分后的交互特征被分别送入可变形卷积 DCNV2 和动态特征选择模块,最终传递至定位中,以实现精确的目标检测.




图 8 TaskDecomposition 结构

图 9 展示了 TADEDH 模型的结构,清晰地描绘了特征的交互过程,以及如何通过任务对齐结构来增强模型的检测能力,改进后的整体模型结构如图 10 所示.




图 9 Head 部分结构




图 10 改进后的 YOLOv8n 网络模型

3 实验分析

3.1 数据集介绍

在本研究中,针对实验构建了一个包含 2 288 张高清绝缘子图像的数据集.其中,数据集由 600 张无人机拍摄的正常绝缘子图像以及 1 688 张带有真实缺陷的绝缘子图像构成.使用了 Labeling 工具对所有图像进行了细致的标注工作.绝缘子被标记为"insulator",防震锤为"hammer",绝缘子的损坏部分标记为"damaged",而闪络现象则被标注为"Flashover".在模型的训练过程中,为了确保模型的泛化能力并且避免过拟合,针对由于所采集的绝缘子图像大多为正常样本,可能导致训练过程中的不平衡问题.通过多种数据增强技术,包括添加噪声、随机裁剪、图像翻转、旋转以及调整亮度等,以模拟不同拍摄条件下的图像以及绝缘子可能遇到的遮挡情况.使数据集扩充到了 11 440 张图像,并按照 9:1:1 的比例划分为训练集、验证集和测试集,用于模型的训练.图 11 展示了数据集中的部分图像示例.



图 11 部分实验数据集

3.2 评价指标

本实验采用召回率(Recall, R)、精确率(Precision, P)、平均精度(mean Average Precision, mAP)、参数量(Params)、计算量(GFLOPs)、帧率(Frames Per Second, FPS)作为评价指标.其中召回率、精准率、平均精度和平均精度均值的计算公式如下:

$$R = \frac{T_p}{T_p + F_N}; \quad (11)$$

$$P = \frac{T_p}{T_p + F_p}; \quad (12)$$

$$f_{AP} = \int_0^1 P(R) dR; \quad (13)$$

$$f_{mAP} = \frac{\sum_{i=1}^N AP_i}{N}. \quad (14)$$

式中: T_p, F_p, F_N 为真正例、假正例、假反例; N 为样本数量; mAP 为不同类别的平均精确度; mAP@0.5 为当 IOU 阈值为 0.5 不同类别的平均精确度.

3.3 模型性能对比试验

本文分别使用 YOLOv8n 算法和 C2fStar-TADEDH 算法在制作的数据集上进行训练,同时训练 300 个 epoch 之后,得到 mAP 变化曲线对比如图 12 所示.

在图 10 所呈现的分析数据中,可以直观的看模型界定的区域较 YOLOv8n 模型更加广阔,同时




图 12 YOLOv8n 与 C2fStar-TADEDH mAP@0.5 对比情况

模型的 mAP 曲线也展现出更优的平滑性证明本文模型在检测精度上以及连续性能表现上都具有更高的水平.在前 15 个训练周期中,YOLOv8n 的 mAP 达到了 66.8%,本文模型的 mAP 为 64.2%,在随后的 285 个周期中持续保持领先.至 300 个周期训练结束时,mAP 达到了 98.5%,凸显了本文模型在性能上的优势.

3.4 消融实验

为了验证本文提出的各个改进的有效性,消融实验进行比较分析,训练过程中保证参数相同,在制作的数据集上进行实验.消融实验结果如表 2 所示.

表 2 消融实验

YOLOv8n	LSCD	DCNv2+任务交互	DEConv_GN	C2f_Star	mAP@ 0.5/%	Params/M	Model size/M
√	×	×	×	×	97.6	3.1	6.0
√	√	×	×	×	98.3	2.3	4.7
√	√	√	×	×	98.4	2.2	4.5
√	√	√	√	×	98.5	2.7	7.0
√	√	√	√	√	98.5	2.2	6.0

在分析表 2 的数据后,可以发现,一系列模块的引入显著提升了模型在 mAP 指标上的表现,超越了传统基准模型.这些技术包括新检测头、DCNv2 模块和增强的任务交互功能,它们分别带来了 0.7%、0.8%和 0.9%的性能提升,有效地减少了漏检和误检,提高了检测的准确性.新检测头的采用,不仅增强了模型识别缺陷的能力,还显著降低了模型的参数量和存储需求,与原始模型相比,分别减少了 26%和 21.7%.这种优化不仅提升了效率,也验证了改进措施的有效性.而 DCNv2 和任务交互模块的集成,进一步推动了模型轻量化,参数量和模型大小分别减少了 29.1%和 25%,同时通过加强任务间的交互,提升了模型对图像特征的捕捉能力,mAP 值的提升 0.8%进一步证实了这一点.尽管 DEConv_GN 模块的加入导致模型参数量略有增加,但与原始模型相比,依然实现了模型大小的减少,并且 mAP 值提升了 0.9%.此外,将 BackBone 和 Neck 部分的 C2f 模块替换为 C2f_Star 模块,压缩了因加入细节增强卷积导致的模型体积增大,同时保持了 mAP 值的提升,与原始模型相比提高了 0.9%.

3.5 不同算法对比

为了进一步验证 C2fStar-TADEDH 在输电线路绝缘子故障检测任务上的优越性,选择了一些常见的深度学习检测模型进行了比较,对比模型包括 Faster R-CNN、YOLOv3-tiny、YOLOv5 和 YOLOv6.所有的模型都通过所制作的数据集进行训练,各个模型的训练结果如表 3 所示.

表 3 CfStar-TADEDH 与其他模型的对比实验

Model	mAP@ 0.5/%	Params/M	Model size/M
Faster R-CNN	74.5	25.5	107.8
YOLOv3-tiny	94.6	12.1	23.3
YOLOv5	97.3	2.5	5.0
YOLOv6	96.5	4.2	8.3
YOLOv8n	97.6	3.1	6.0
C2fStar-TADEDH	98.5	2.2	6.0

表 3 的实验结果清晰地展示了本文所提出的模型与其他几种算法相比在检测性能上的卓越表现,C2fStar-TADEDH 在 mAP 上分别实现了 24.0%、3.9%、1.2%和 2.0%的增长,这些数字不仅凸显了其在精确度上的优势,也反映了算法在实际应用中的潜力.在模型复杂度方面,C2fStar-TADEDH 同样展现出了其优势,与其他算法相比,参数规模分别下降了 91.4%、81.8%、12.0%和 47.6%.这不仅减轻了模型的整体负担,也提高了算法的实用性和灵活性.尽管与 YOLOv5 相比,模型大小有所增加,但在关键的 mAP 指标上,它依然实现了 1.2%的提升,这在复杂环境中的绝缘子缺陷检测中显得尤为重要.与原始的 YOLOv8n 网络相比,优化后的模型在 mAP 上增长了 0.9%,同时也实现了模型参数量大幅度降低,减少了 29%.使其更适用于资源受限的应用场景.综上所述,C2fStar-TADEDH 模型在保持高精度的同时,兼顾了模型的整体轻量化,为输电线路绝缘子缺陷检测提供了一种高效且实用的解决方案.

4 结论

1) 本文提出了一种强调特征交互信息的目标检测模型用于输电线路绝缘子的故障检测当中,通过实验证明:该模型在将计算参数量减少至 2.2 M 的同时,仍能使模型保持着 98.5% 的精度,相较于 YOLOv8n 及其他经典算法具有明显的优势。

2) 本文模型为复杂环境下的小目标检测提供了一种高效、轻量化的优化思路。然而,对于处在极端光照和遮挡条件下的绝缘子图像本文模型在性能上仍有提升空间,且考虑模型在工程实际应用当中可能出现的资源受限问题,在未来的研究中,将进一步探索模型的轻量化结构以及与边缘计算设备的适配性,同时构建更为复杂的绝缘子数据集以提升模型的泛化能力及检测精度,继续推动关于智能化输电线路绝缘子故障检测研究的深入发展。

参考文献:

- [1] 杨潇. 输电线路运检中绝缘子故障与检测技术研究[J]. 电力设备管理, 2023(24): 28-30.
- [2] WU X Y, ZHU J, ZHAI X P. Intelligent fault detection of transmission line insulator based on deep learning[C]//2023 7th International Symposium on Computer Science and Intelligent Control (ISCSIC). IEEE, 2023: 27-30.
- [3] 左川. 基于图像识别的输电线路绝缘子检测方法研究[D]. 保定: 华北电力大学, 2019.
- [4] DU Q W, DONG W Z, SU W, et al. UAV inspection technology and application of transmission line[C]//2022 IEEE 5th International Conference on Information Systems and Computer Aided Education (ICISCAE). IEEE, 2022: 594-597.
- [5] 陈凤翔, 杨磊, 谢春, 等. 无人机输电线路巡线技术及其应用[J]. 科技创新与应用, 2021, 11(25): 174-176.
- [6] 霍红刚, 周鑫, 蔡杰, 等. 基于先验知识 Faster R-CNN 的输电线路无人机图像识别方法[J]. 智慧电力, 2024, 52(6): 108-115.
- [7] 韩帅. 基于卷积神经网络的学术论文图像检测与对比研究及应用[D]. 济南: 山东师范大学, 2024: 63.
- [8] WANG Y, WANG L, JIANG Y, et al. Detection of self-build data set based on YOLOv4 network[C]//2020 IEEE 3rd International Conference on Information Systems and Computer Aided Education (ICISCAE). IEEE, 2020: 9236808.
- [9] 余潜江. 基于改进 YOLO 的航拍图像小目标检测算法研究[D]. 重庆: 重庆理工大学, 2024.
- [10] KUMAR D, ZHANG X L. Improving more instance segmentation and better object detection in remote sensing imagery based on cascade mask R-CNN[C]//2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS. IEEE, 2021: 9554512.
- [11] ARUN Y, VIKNESH G S. Leaf classification for plant recognition using EfficientNet architecture[C]//2022 IEEE Fourth International Conference on Advances in Electronics, Computers and Communications (ICAEECC). IEEE, 2022: 1-5.
- [12] LIU Y, XIAO P, FANG J, et al. A survey on image classification of lightweight convolutional neural network[C]//2023 19th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD). IEEE, 2023: 1-10.
- [13] 高杨, 曹仰杰, 段鹏松. 神经网络模型轻量化方法综述[J]. 计算机科学, 2024, 51(z1): 11-21.
- [14] 周晋伟, 王建平. YOLO 物体检测算法研究综述[J]. 常州工学院学报, 2023, 36(1): 18-23.
- [15] 沈学利与王灵超. 基于 YOLOv8n 的无人机航拍目标检测[J]. 计算机系统应用, 2024, 33(7): 139-148.
- [16] MA X, DAI X Y, BAI Y, et al. Rewrite the stars[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2024: 5694-5703.
- [17] CHEN Z X, HE Z W, LU Z M. DEA-net: single image dehazing based on detail-enhanced convolution and content-guided attention[J]. IEEE Transactions on Image Processing, 2024, 33: 1002-1015.
- [18] ZHU X Z, HU H, LIN S, et al. Deformable ConvNets V2: more deformable, better results[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2019: 00953.
- [19] 刘卫光, 刘东, 王璐. 可变形卷积网络研究综述[J]. 计算机科学与探索, 2023, 17(7): 1549-1564.
- [20] FENG C J, ZHONG Y J, GAO Y, et al. TOOD: task-aligned one-stage object detection[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), 2021: 3490-3499.