

IRe-Net: 一种改进 RetinaNet 的绝缘子缺陷检测方法

张紫格¹, 舒征宇¹, 任冠臣¹, 刘颂凯¹, 姚 钦², 童华敏²

(1. 三峡大学 电气与新能源学院, 湖北 宜昌 443002;

2. 国网湖北省电力公司宜昌供电公司, 湖北 宜昌 443000)

摘要: 针对航拍绝缘子图像中背景复杂、目标尺度多样以及检测目标较小导致的检测精度低的问题, 通过改进 RetinaNet, 提出一种绝缘子缺陷检测方法 IRe-Net; 构建自适应卷积模块优化 ResNet 网络, 采用可变形卷积增强小目标缺陷的捕获能力; 设计一种特征增强网络 CeBiFPN, 利用坐标注意机制对 BiFPN 进行改进, 增强对多尺度目标检测能力; 提出 Focal-CIoU 损失函数, 引入 CIoU Loss 优化损失函数, 优化模型收敛过程, 提升复杂场景下缺陷检测的能力; 实验结果表明, 提出的 IRe-Net 在绝缘子缺陷检测中的平均准确率达到 91.46%, 可有效提升复杂场景下航拍绝缘子缺陷检测的准确性和鲁棒性, 满足智能电网安全监测需求。

关键词: 绝缘子缺陷检测; RetinaNet; 自适应卷积; 双向特征金字塔; 损失函数

IRe-Net: A Defect Detection Method for Insulators Based on Improved RetinaNet

ZHANG Zige¹, SHU Zhengyu¹, REN Guanchen¹, LIU Songkai¹, YAO Qin², TONG Huamin²

(1. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China;

2. Yichang Power Supply Company, State Grid Hubei Electric Power Co., Ltd., Yichang 443000, China)

Abstract: To address the challenges of low detection accuracy, diverse scales and small sizes of targets in aerial insulator images due to complex backgrounds, and based on improved RetinaNet, an insulator defect detection method, IRe-Net, is proposed, which optimizes the ResNet network through an adaptive convolution module and enhances the ability to capture small target defects by using a deformable convolution. A feature enhancement network, CeBiFPN, is designed by improving a BiFPN with a coordinate attention mechanism, thus enhancing the ability of multi-scale target detections. Additionally, a Focal-CIoU loss function is presented, and a CIoU Loss is introduced to optimize the loss function and improve the convergence of the model, enhancing the ability of defect detection in complex scenes. Experimental results show that the proposed IRe-Net achieves an average accuracy of 91.46% in the insulator defect detection, effectively improving the detection accuracy and robustness in aerial insulator defect detection in complex scenarios, meeting the safety monitoring needs of smart grids.

Keywords: insulator defect detection; RetinaNet; adaptive convolution; CeBiFPN; loss function

0 引言

在社会生产和生活中, 电能发挥着不可或缺的作用。而在高压输电线路中, 绝缘子更是保障电力系统稳

定运行的关键所在。长期暴露于复杂多变的空气环境以及恶劣的架空线路条件下, 绝缘子极易产生各类缺陷。这些缺陷一旦发生, 极有可能引发大规模停电事故, 而造成巨大的经济损失^[1]。2023 年国网江苏超高压公

收稿日期: 2025-04-07; 修回日期: 2025-05-12。

基金项目: 国家自然科学基金项目(52407118)。

作者简介: 张紫格(2000-), 女, 硕士研究生。

舒征宇(1983-), 男, 博士, 副教授。

引用格式: 张紫格, 舒征宇, 任冠臣, 等. IRe-Net: 一种改进 RetinaNet 的绝缘子缺陷检测方法[J]. 计算机测量与控制, 2025, 33(10): 46-54.

司 2 号线绝缘子发生缺陷, 导致临时停电 9 小时, 期间涉及 ±800 kV 直流功率调整及负荷转移, 严重影响区域供电稳定性, 且缺陷导致的非计划停电单次直接经济损失达千万元级^[2]。因此, 及时且准确地检测输电线路绝缘子的缺陷, 具有重要的理论意义和实际应用价值。传统的缺陷检测主要依靠专业巡线人员的经验进行记录, 但由于架空线路的广泛分布和环境限制, 人工巡检存在效率低、成本高、安全隐患突出等问题^[3]。随着无人机技术愈发成熟, 其在输电线路巡检的应用展现了巨大的潜力。云南电网 35 kV 永德线路采用无人机巡检方式, 实现巡检过程全自动化, 相比人工巡检效率整整提升 5 倍之多, 巡检成本降低 50% 以上^[4]; 大唐烟台金岭风电场 1 名工作人员在 35 kV 集电线路巡检过程中, 发生感应触电造成身亡, 但在采用无人机巡检方式后也未发生类似事故^[5]。综上所述, 与传统的人工巡检相比, 无人机巡检周期短、成本低且安全性高, 解决了人工巡检所存在的问题, 逐渐成为人工巡检的替代方案^[6]。尽管无人机能够拍摄并传回大量输电线路上的绝缘子图像, 但依赖人工来判断其中是否存在缺陷, 工作量过大且极易造成漏检和误检。因此, 需要一个高效、性能优越且智能化的图像处理方式, 用于检测无人机传回的大量图像数据中的输电线路绝缘子缺陷。此前, 绝缘子的实时监测技术主要包括声发射监测、振动信号监测和应变监测^[7-9]等; 离线检测技术主要包括超声扫描和红外线成像等^[10-11]。近年来, 随着深度学习的快速发展, 其广泛的适用性、卓越的检测精度和快速的处理能力, 使其在电力巡检中得到广泛应用^[12-13]。

目前基于深度神经网络的目标检测模型主要分为双阶段与单阶段两大类: 1) 双阶段检测模型以 R-CNN^[14]、Faster R-CNN^[15] 为代表, 其核心为区域建议网络 (RPN)。RPN 通过滑动窗口在卷积特征图上生成锚点 (Anchors), 每个锚点对应原图中不同尺度和宽高比的候选框。通过优化分类与回归损失筛选候选框, 以最终确定目标类别和边界框。尽管两阶段设计使检测精度较高, 但候选框生成导致计算效率低, 难以满足无人机巡检实时性需求。2) 单阶段检测模型以 YOLO^[16]、SSD^[17] 为代表, 相较于双阶段算法省去了生成候选框的步骤, 直接在特征图上进行分类和回归。以 SSD 算法为例, 该算法直接进行多层级特征提取, 深浅层特征图分别负责大小尺度的目标检测。通过在这些特征图上生成不同尺寸和比例的默认框, 使模型能够在单次前向传播中同时预测各种大小和形状的目标, 从而实现高效的多尺度检测。单阶段算法结构简洁, 非常适合在资源受限的环境中快速部署, 尤其适用于无人机图像处理系统, 能够在保持足够检测精度的同时, 满足实时处理的需求。

虽然上述模型在绝缘子缺陷检测任务中取得了一定

的进展, 但实际检测中存在很多不确定的复杂因素, 如强光弱光照射下、杂乱的树木与草地背景下和缺陷类型的不同等问题, 都对目标检测算法有着更高的要求。在绝缘子缺陷检测这种实时性较强, 对推理速度有较高要求的任务中, 单阶段检测模型的使用更加广泛。本文选择的 RetinaNet 算法是一种单阶段检测方法, 具有优良的检测精度与速度。相较于双阶段算法, RetinaNet 结构更为简洁, 并且在中小型目标的检测上表现突出。现有研究主要集中在提升对常规绝缘子缺陷图像的检测精度。在近期的研究成果中, 文献 [18] 对 YOLOv5 改进, 引入 FasterNet-tiny 网络, 针对卷积模块引入长距离注意力机制进行优化, 增大感受野, 解决缺陷目标识别困难的问题。文献 [19] 重构了 YOLOv5s 模型, 并使用了知识蒸馏的技术, 弥补了因对模型进行轻量化而缺失的检测精度。文献 [20] 针对复杂背景以及图片噪声问题, 对 YOLOv8 进行改进, 聚合网络部分使用 LSKNet 进行替代, 使模型性能得到提升。以上方法在绝缘子缺陷识别能力的精度上实现了提升, 但在背景复杂以及多尺度航拍图像差别较大、目标较小等问题上, 适用性还有待提高, 仍会出现漏检误检等问题。

为了解决上述问题, 本文提出了一种基于改进 RetinaNet 的绝缘子缺陷检测方法 IRe-Net。首先, 提出一种自适应卷积模块, 利用可变形卷积对 RetinaNet 主干网络中 ResNet 进行优化, 增加感受野, 使模型能够更加准确地捕捉到小目标缺陷; 其次, 在颈部网络中, 设计一种坐标增强双向特征金字塔网络 (CeBiFPN), 利用坐标注意力机制对 BiFPN 进行改进, 有效整合来自不同尺度的特征信息, 使模型能够增强对多尺度目标检测能力; 最后, 对 RetinaNet 中的边界框回归损失 (Focal Loss) 进行优化, 采用 CIoU Loss 损失函数, 设计 F-CIoU Loss, 并使用 IoU 对损失进行加权, 以提升复杂场景下缺陷检测的能力。

1 RetinaNet 模型原理

RetinaNet^[21] 是由 FAIR 团队提出的一种高效的单阶段目标检测算法, 其结构如图 1 所示。该模型通过骨干网络 (如 ResNet) 提取图像特征, 并结合特征金字塔网络 (FPN) 增强对多尺度物体的检测能力。RetinaNet 包含两个子网: 分类子网用于预测物体类别, 回归子网负责精确定位物体的边界框。在此基础上, 设计了一个损失函数 Focal Loss, 通过降低易分类样本的权重, 聚焦于难分类样本, 从而显著提升了小物体的检测性能。在保证单阶段目标检测算法的检测速度上, 精确度甚至超过了双阶段目标检测算法, 非常适用于输电线路中绝缘子缺陷的检测。

2 改进的 RetinaNet 缺陷检测模型

本文以 RetinaNet 为基线模型, 提出了一种改进的




图 1 RetinaNet 网络结构

RetinaNet 绝缘子缺陷检测模型 IRe-Net。具体改进如下：1) 提出一种自适应卷积模块，利用可变形卷积对 ResNet 进行优化，增加感受野，使模型能够更加准确地捕捉到小目标缺陷；2) 提出一种坐标增强双向特征金字塔网络 (CeBiFPN)，利用坐标注意机制对 BiFPN 进行改进，有效整合来自不同尺度的特征信息，使模型能够增强对多尺度目标检测能力；3) 对 RetinaNet 中的边界框回归损失 (Focal Loss) 进行优化，采用 CIoU Loss 损失函数，设计 F-CIoU Loss，并使用 IoU 对损失进行加权，以提升复杂场景下缺陷检测的能力。改进后的模型整体架构如图 2 所示，C1、C2 用来提取浅层信息，C3、C4、C5 为特征融合网络的输入特征层，P3、P4、P5、P6、P7 为预测特征层，经过特征提取后形成特征提取网络的输出，输入检测头进行回归与分类。




图 2 改进的 RetinaNet 网络结构

2.1 自适应卷积模块

ResNet 作为一种性能卓越的特征提取网络，通过

引入残差结构有效缓解了梯度消失问题，从而提升网络对深层次语义信息的学习与提取能力。原 ResNet 有 5 个阶段，第 1 阶段通过卷积和最大池化进行初步特征提取，第 2~5 阶段为残差结构特征提取，每阶段包含多个残差模块。为了进一步增强网络对不同形状缺陷的特征提取能力，本文设计了一种自适应卷积模块，利用可变形卷积 (DCN, deformable convolution network)^[22] 优化 ResNet 残差模块。将 3~5 阶段残差模块中的 3×3 卷积替换为可变形卷积，其偏移量生成网络由两个 3×3 卷积组成，以实现目标特征的更灵活捕捉与表征，改进后的残差模块结构如图 3 所示。




图 3 自适应卷积模块结构

可变形卷积结构如图 4 所示。与传统卷积操作不同，该结构通过引入可学习的空间偏移量，突破了传统卷积核固定几何形状的限制，实现了感受野的自适应调整。




图 4 可变形卷积结构图

传统的卷积结构由式 (1) 表示，其中每个输出特征图的元素对应卷积核的中心位置。

$$y(p_0) = \sum_{p_n \in R} w(p_n) \cdot x(p_0 + p_n) \quad (1)$$

式中， p_0 为输入特征图的像素点； p_n 为像素点偏移位置； R 为包含卷积核中心周围区域的集合； w 为学习权重； x 为特征映射。

相比于标准卷积, 可变形卷积在式 (1) 中引入了每个位置的偏移量, 这个偏移量由输入特征图和另一个卷积层生成, 通常表现为小的浮动数值, 具体如式 (2) 所示:

$$y(p_0) = \sum_{p_n \in R} w(p_n) \cdot x(p_0 + p_n + \Delta p_n) \quad (2)$$

式中, Δp_n 为每个卷积核位置的偏移量。

在引入偏移量后, 采样位置通常会变成非整数, 这些位置并不直接对应于特征图上实际的像素点。因此, 为了获得偏移后的像素值, 需要通过插值方法进行计算。常见的插值方法是双线性插值, 如式 (3) 所示:

$$\begin{aligned} x(p) &= \sum_q G(q, p) \cdot x(q) = \\ &= \sum_q g(q_x, p_x) \cdot g(q_y, p_y) \cdot x(q) = \\ &= \sum_q \max(0, 1 - |q_x - p_x|) \cdot \\ &\quad \max(0, 1 - |q_y - p_y|) \cdot x(q) \end{aligned} \quad (3)$$

式中, $\max(0, 1 - |q_x - p_x|)$, $\max(0, 1 - |q_y - p_y|)$ 分别为在 x 和 y 方向上, 当差值小于 1 时, 该函数的值为正数, 并且随着距离增大逐渐减小。

在实际计算过程中, 每个插值点的特征值由其 4 个最近邻网格点的特征值加权求和得到。需要特别说明的是, 可变形卷积中的偏移量生成与特征提取是两个独立的计算过程。前者通过辅助卷积层实现, 后者则是在获得偏移量后执行的标准卷积操作。这种分离式设计既保证了特征提取的准确性, 又维持了计算效率。具体采样过程如图 5 所示, 传统卷积在采样时采取固定形状, 而可变形卷积通过偏移对采样点进行动态调整, 使其聚焦于缺陷区域。这种自适应特性显著增强了模型对目标形变的鲁棒性, 使其能够更准确地提取物体的局部特征, 从而更加准确地捕捉到小目标缺陷。




图 5 传统卷积与可变形卷积采样对比

2.2 坐标增强双向特征金字塔网络

2.2.1 坐标注意力

坐标注意力 (CA, coordinate attention) 机制是一种用于提升深度学习模型在计算机视觉任务中的性能的注意力机制^[23]。坐标注意力机制的创新性在于其能够显式建模空间方向信息, 通过坐标感知的方式生成具有

空间敏感性的特征表示。与传统的注意力机制相比, 该机制不仅关注输入特征本身的语义信息, 还通过引入坐标编码策略, 将像素的空间位置信息与特征表示深度融合。这种特征与位置联合建模方式显著增强了模型对图像局部细节特征的提取能力, 同时保留了全局结构信息的完整性, 从而在空间关系建模方面表现出优异的精度与鲁棒性。

坐标注意力结构如图 6 所示, 主要分为坐标信息嵌入和坐标注意力生成两个主要阶段。




图 6 坐标注意力结构图

坐标信息嵌入阶段中, 系统提取输入特征图在 x 方向和 y 方向上敏感的注意力特征。对两个方向分别应用 $(H, 1)$ 和 $(1, W)$ 的池化核进行全局平均池化, 从而为每个通道生成两个一维的方向感知特征图。对于高度 h 与宽度 w 的特征图中第 c 个通道的输出, 计算过程如式 (4) 和 (5) 所示:

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i \leq W} x_c(h, i) \quad (4)$$

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq i \leq H} x_c(j, w) \quad (5)$$

式中, x_c 为上层传入的输入特征; i, j 分别表示水平和垂直方向上第 i 个和第 j 个位置的像素点;

坐标注意力生成阶段中, 将前阶段输出的特征图送入 1×1 的卷积核中对两个不同方向的特征图进行降维与合并处理。计算过程如式 (6) 所示:

$$f = \delta(F(z^h, z^w)) \quad (6)$$

式中, F 为通道特征的合并操作; δ 为非线性激活函数; $f \in R^{C/r \times (W+H)}$ 为水平方向和垂直方向的空间特征, r 是用于映射 f 通道数量的下采样比例。

随后, 对特征图进行分段操作, 将其拆分为 $f^h \in R^{C/r \times H}$ 和 $f^w \in R^{C/r \times W}$ 两个独立的特征张量, 并通过 1×1

卷积和 Sigmoid 函数处理, 使得最终得到的水平方向和垂直方向的注意力向量与输入特征图的维度一致。计算过程如式 (7) 和 (8) 所示:

$$g^h = \sigma[F_h(f^h)] \quad (7)$$

$$g^w = \sigma[F_w(f^w)] \quad (8)$$

最后, 对输出的 g^h 和 g^w 进行加权, 得到坐标注意力块的输出。具体过程如式 (9) 所示:

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j) \quad (9)$$

式中, $g_c^h(i)$ 为水平方向的注意力权重, $g_c^w(j)$ 为垂直方向的注意力权重。

为了提升特征融合效果, 通常将 CA 机制集成到特征提取层中, 本文将 CA 机制应用于 BiFPN 中, 有效整合了来自不同尺度的特征信息。

2.2.2 改进的双向特征金字塔网络

双向特征金字塔网络 (BiFPN) 是在传统的 FPN 和 PANet 基础上提出的改进模型^[24]。其主要特点是通过引入双向特征融合机制, 从而解决了 FPN 和 PANet 在处理不同层次之间语义差异时的不足。BiFPN 不仅可以提高计算效率, 还能在处理不同尺度目标时, 尤其是在检测任务中显著提高精度。

针对绝缘子航拍图像缺陷尺寸较小的问题, 本文对 BiFPN 进行了一定的改进。特别是为了保留更多的小尺寸缺陷信息, 利用坐标注意力机制对其进行改进, 从而使得浅层的信息能够更充分地传递到深层。这种结构可以有效保留更多的细节信息, 特别是在处理小目标时, 具有更大的优势。

FPN、PANet 和 BiFPN 的特征融合结构如图 7 所示, 与 PANet 仅采用单一的自上而下和自下而上的路径进行特征融合不同, BiFPN 能够实现上下双向的特征融合, 并通过多次迭代执行相同层级的融合操作, 从而实现更高层次的特征融合。BiFPN 采用加权融合方法为每个输入分配额外的权重, 其计算过程如式 (10) 所示:

$$O = \sum_i \frac{\omega_i}{\epsilon + \sum_j \omega_j} \cdot I_i \quad (10)$$

式中, O 为输出特征; I_i 为输入特征; ω_i 和 ω_j 为学习权重。

在 BiFPN 网络结构中, P_i 节点具体特征融合过程如式 (11) 和 (12) 所示:

$$P_i^{\text{td}} = \text{Conv} \left[\frac{\omega_1 \cdot P_i^{\text{in}} + \omega_2 \cdot \text{Resize}(P_{i+1}^{\text{in}})}{\omega_1 + \omega_2 + \epsilon} \right] \quad (11)$$

$$P_i^{\text{out}} = \text{Conv} \left[\frac{\omega'_1 \cdot P_i^{\text{in}} + \omega'_2 \cdot P_i^{\text{td}} + \omega'_3 \cdot \text{Resize}(P_{i-1}^{\text{out}})}{\omega'_1 + \omega'_2 + \omega'_3 + \epsilon} \right] \quad (12)$$

式中, P_i 表示第 i 层的特征 (in 为输入, td 为中间, out 为输出); Resize 是上采样或下采样操作; ω 为输入特征的学习权重。




图 7 不同特征融合结构图

BiFPN 使用加权求和来融合不同尺度的特征图, 每个特征图都有一个学习到的加权系数, 这样就能根据特征图的重要性自适应地调整融合比例, 避免了 FPN 和 PANet 中可能存在的特征过度融合的问题。基于此, 本文利用坐标注意力机制将 BiFPN 网络进行优化, 其结构如图 8 所示。




图 8 改进 BiFPN 结构图

首先, 利用 1×1 的卷积升维, 增加特征图的通道数。然后, 对升维后的特征图进行批量归一化后使用深度可分离卷积 (DSC, depthwise separable convolution)。深度可分离卷积包括两部分: 使用 3×3 的深度卷积 (Depthwise Convolution) 对每个通道进行卷积; 使用 1×1 的逐点卷积对深度卷积后的特征图进行通道融合。通过这种结构, 网络能够在减少计算量的同时保持较高的精度。

在此基础上, 本文进一步引入坐标注意力机制对 BiFPN 结构进行改进。通过坐标注意力机制, 对深度可分离卷积处理后的特征图进行更深层次的空间位置相关的信息捕捉, 增强了模型对不同位置特征的敏感度和信息整合能力。坐标注意力机制通过对空间坐标的加权计算, 使得网络能够更加关注关键信息区域, 抑制冗余信息的干扰, 从而提升网络的精度和推理能力。经改进后的网络结构增强了对缺陷特征的关注, 从而提高了

模型对于航拍绝缘子缺陷这种多尺度和小目标的检测精度。

2.3 损失函数优化

损失函数是深度学习中用于衡量模型预测值与实际值之间差距的函数, RetinaNet 中采用的是 Focal Loss 损失函数, 如式 (13) 所示:

$$Focal\ Loss(p_i) = -\alpha_i(1 - p_i)^\gamma \log(p_i) \tag{13}$$

式中, p_i 为正确预测概率; α_i 为正负样本平衡因子; γ 为调节因子。

Focal Loss 在解决类别不平衡问题、提升难分类样本的检测能力方面表现出色, 但它在边界框的回归精度上有所欠缺。

在绝缘子缺陷检测中, 航拍绝缘子图像缺陷容易被噪声和背景所干扰, 导致 Focal Loss 损失函数难以充分优化检测结果。CIoU Loss 损失函数有效解决了这一问题, 因此本文采用了 CIoU Loss 来约束回归分支, Focal Loss 解决类别不平衡问题, 并将把 IoU^[25] 作为加权系数, 构建 F-CIoU Loss 损失函数。具体而言, IoU 计算由式 (14) 所示:

$$L_{IoU} = \frac{A \cap B}{A \cup B} \tag{14}$$

式中, A 为锚框, B 为目标框。

CIoU 损失函数的定义如式 (15) 所示:

$$L_{CIoU} = 1 - L_{IoU} + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha v \tag{15}$$

式中, $\rho(b, b^{gt})$ 为锚框和目标框之间的距离; c 为锚框和目标框最小外接矩形对角线的长度; α 为权衡参数; v 为衡量两框高宽比的一致性。

α 和 v 的计算分别如式 (16) 和 (17) 所示:

$$\alpha = \frac{v}{(1 - L_{IoU}) + v} \tag{16}$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \tag{17}$$

式中, w^{gt} 、 h^{gt} 、 w 、 h 分别为目标框的宽高以及锚框的宽高。

通过引入 IoU 权重系数, 构建了基于 F-CIoU Loss 损失函数, 其定义如式 (18) 所示:

$$L_{F-CIoU} = L_{IoU}^\gamma L_{CIoU} \tag{18}$$

式中, γ 用于控制分类损失和回归损失的权重。

该方法不仅考虑了候选框与标注框之间的 IoU, 还进一步融合了候选框与标注框的中心点距离、高宽比等重要因素, 从而能够增强模型在复杂背景下对于缺陷的检测能力。

3 实验结果与分析

3.1 实验环境及数据集

本实验在 Linux 系统下采用 Pytorch 深度学习框架

进行, 具体配置如表 1 所示。

表 1 实验配置与环境

配置	参数
操作系统	Linux
处理器	Intel(R) Core(TM) i7-12700F
运行内存	64 GB
显卡	NVIDIA GeForce RTX 3080Ti
Pytorch	2.1.0
CUDA	12.0
Python	3.8.18

本文在训练过程中的参数为: 迭代次数 (Epoch) 为 300, 批量大小 (Batch Size) 为 32, 优化器 (Optimizer) 为 Adam, 初始学习率 (Initial Learning Rate) 为 0.001, 权重衰减 (Weight Decay) 为 0.000 5。

本文绝缘子数据集根据开源的中国输电线路绝缘子数据集进行整理制作了一个含有 1 608 张绝缘子图片的数据集。该数据集包括在不同环境条件下的电力绝缘子图像, 其中包括 731 张完好绝缘子和 877 张有缺陷的绝缘子图像, 具体分布如表 2 所示。数据集中图像背景涵盖了森林、草地、高山等复杂场景, 能够全面评估本文所提算法模型在绝缘子自爆缺陷检测方面的性能。数据图像使用 LabelImg 数据标注工具对数据集中的每张图片进行标注, 正常绝缘子标为 (Insulator), 将有缺陷的绝缘子主要分为缺陷绝缘子 (Defect) 和闪络绝缘子 (Flashover) 两大类进行标注, 部分缺陷示例如图 9 所示。将标注好的绝缘子数据集按照 8 : 1 : 1 的比例, 将标注后的数据集随机划分为训练集、验证集和测试集。

表 2 数据集分布

	类别	数量/张
场景类型	森林	537
	草地	482
	高山	231
缺陷类型	缺陷	532
	闪络	345

3.2 评估指标

本文从精度和效率两个方面对模型进行评估。精度评估使用精确率 (P)、召回率 (R) 和平均精度均值 (mAP) 作为指标。各项评估指标表达如式 (19) ~ (22) 所示:

$$P = \frac{TP}{TP + FP} \tag{19}$$

$$R = \frac{TP}{TP + FN} \tag{20}$$

$$AP = \int_0^1 P(R) d(R) \tag{21}$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \tag{22}$$




图 9 数据集绝缘子缺陷示例图

式中, TP 为正样本预测正确的数量, FN 为正样本预测错误的数量, FP 为负样本预测错误的数量, $TP + FN$ 为所有正样本的数量; N 为样本类别数。

3.3 实验结果

3.3.1 对比实验

1) 注意力可视化效果对比:

为了验证引入坐标注意力机制对实际特征融合过程中的作用效果, 在相同实验环境下, 对比 RetinaNet 添加不添加坐标注意力以及加入坐标注意力机制的 BiFPN 的实验结果。采用 CAM 热力图进行可视化呈现, 具体结果如图 10 所示。图中越接近深红色的区域代表模型对该区域的关注度越大, 图 10 (b) 和 (c) 对比可以看出, 引入坐标注意力后的模型能够更明显关注到绝缘子的缺陷区域, 降低背景干扰, 从而提升模型对于缺陷的识别能力。




图 10 CA 热力图可视化对比

2) 损失函数对比:

为了验证损失函数的改进效果, 将基线 RetinaNet 模型分别使用 Focal Loss、CIoU Loss 和 F-Clou Loss 进行对比, 从 mAP 和损失值进行对比, 结果如表 3 和图 11 所示。

在训练过程中 F-Clou Loss 损失曲线波动范围最小, 且在损失值下降至 1.5 所用轮次较 Focal Loss 和 CIoU Loss 分别提前了 20 和 10 个轮次, 有着最快的收敛速度。最终, F-Clou Loss 的损失值达到了 1.31, 相比于 Focal Loss 和 CIoU Loss 的损失值分别减少了 0.28 和 0.22。由图 11 (b) 可以看出, 使用 F-Clou Loss 的模型预测精度表现最佳, mAP 达到了 87.88%, 较对

比方法都有所提升。实验结果表明, 本文提出的 F-Clou Loss 通过动态权重平衡分类与回归任务, 对模型的性能有较大的提升。

表 3 Retina Net 不同损失函数对比

损失函数	$mAP\%$	Loss
Focal Loss	86.12	1.59
CIoU Loss	86.56	1.53
F-Clou Loss	87.88	1.31





图 11 损失函数性能对比

3) 不同算法对比:

为了验证本文提出方法的有效性, 分别使用其他主流模型在同一数据集中进行训练, 其中包括已在绝缘子缺陷检测任务中广泛应用的 SSD、Faster RCNN、YOLOv5^[26]、YOLOv7^[27]、YOLO-X^[28]、EfficientDet、CenterNet^[29] 模型, 以及同为基于 RetinaNet 进行改进的 KE-RetinaNet^[30] 和 U-RetinaNet^[31] 模型。

实验结果如表 4 所示, 从精度 (P) 方面来看, 本文算法表现出色, 达到了 91.64%, 明显高于其他模型, 而其他模型的精度普遍低于 85%。在召回率上, 本文算法同样表现优秀, 达到了 91.41%, 超过了所有对比模型, 表明本文算法在减少漏检的同时, 保持了较高的精度。本算法 mAP 达到了 91.46%, 相较于目前应用较为广泛的 YOLOv5 (77.93%)、YOLOv7 (86.28%)、YOLO-X (86.76%)、EfficientDet (85.23%)、CenterNet (88.15%) 模型分别高出了 13.53%、5.18%、4.70%、6.23%、3.31%, 体现了其在整体检测效果上的优势。虽然 KE-RetinaNet 和 U-RetinaNet 绝缘子缺陷检测算法

与本文算法性能相近,但总体而言本文算法在各项指标上略有优势。综上所述,本文算法在精度、召回率和 mAP 等多个指标上均优于其他对比模型,充分证明了本文的优化方法能够显著增强特征提取、融合和定位能力,提升了模型在多尺度和多目标绝缘子特征上的检测能力,还增强了其在复杂背景中的适应性和鲁棒性。

表 4 与其他算法对比

模型	$P/\%$	$R/\%$	$mAP/\%$
SSD	79.52	50.47	72.34
Faster RCNN	87.36	51.13	74.93
YOLOv5	83.11	60.88	77.93
YOLOv7	83.53	82.14	86.28
YOLO-X	84.64	79.31	86.76
EfficientDet	81.83	85.10	85.23
CenterNet	88.53	81.98	88.15
RetinaNet	84.72	85.46	86.12
U-RetinaNet	90.92	90.01	90.32
KE-RetinaNet	91.42	90.94	91.28
本文算法	91.64	91.41	91.46

3.3.2 消融实验

为了证明改进对于绝缘子缺陷检测模型的提升效果,本文共进行了 8 组消融实验,验证各个改进在算法模型中的作用,结果如表 5 所示。

表 5 消融实验结果对比

实验	自适应卷积模块	CeBiFPN	Focal-CIoU	$P/\%$	$R/\%$	$mAP/\%$
1	—	—	—	84.72	85.46	86.12
2	✓	—	—	85.06	86.03	87.34
3	—	✓	—	86.20	87.11	88.56
4	—	—	✓	86.53	86.74	87.88
5	✓	✓	—	90.52	89.94	90.36
6	✓	—	✓	88.21	87.98	88.73
7	—	✓	✓	89.93	89.34	89.87
8	✓	✓	✓	91.64	91.41	91.46

实验 1 为基线 RetinaNet 模型,实验 2、3、4 分别在 RetinaNet 基础上引入自适应卷积模块、CeBiFPN 和 Focal-CIoU;实验 5、6、7 分别为将自适应卷积模块与 CeBiFPN、自适应卷积模块与 Focal-CIoU、CeBiFPN 与 Focal-CIoU 结合应用于 RetinaNet 后的模型;实验 8 则为本文提出的最终检测方法。实验结果表明,基线 RetinaNet 模型的 mAP 值为 81.12%。在此基础上,单独引入自适应卷积模块、CeBiFPN 和 Focal-CIoU 后, mAP 分别提升了 1.22%、2.34% 和 1.42%。当两种优化方法结合时,相较单独引入改进方法, mAP 进一步提高。最终,结合所有优化方法后,模型的召回率和 mAP 分别提升至 91.41% 和 91.46%,较未优化时分别提高了 5.95% 和 5.34%。这表明,本文提出的优化方

法显著增强了特征提取、融合和定位能力,从而大幅提升了模型的整体检测性能。

3.3.3 可视化结果

图 12 展示了部分图片的检测结果,其中 insulator 表示正常绝缘子, defect 表示缺陷绝缘子, flashover 表示闪络绝缘子,数字为置信度得分。从整体置信度来看,改进后的模型相较于未改进的模型在 3 种标签类型上均表现出显著提升。由图 12 (b) 和 (c) 看出,未改进的 RetinaNet 模型在检测中存在小目标绝缘子漏检的情况,且在背景干扰严重且同一绝缘子串同时有缺陷和闪络的情况下,未能检测到闪络绝缘子,而改进后的模型在这些情况下均能准确检出所有目标。综上所述,本文提出的 Ire-Net 模型在绝缘子缺陷检测任务中具有明显优势,整体改进策略有效,使检测精度得到了提高。



图 12 部分图片检测结果图

4 结束语

为了解决航拍绝缘子缺陷图像中的低检测率和漏检问题,尤其是在复杂背景下多尺度小目标的任务中,本文提出了一种改进 RetinaNet 的绝缘子缺陷检测方法—IRe-Net。该方法提出的自适应卷积模块、坐标增强双向特征金字塔网络以及损失函数,对 RetinaNet 模型进行改进。实验结果表明,相较于改进前的 RetinaNet 模型,本文所提模型在 mAP 上提升了 5.34%,同时在准确率和召回率方面也分别提高超过 5.5%。与其他主流模型与横向改进模型对比,综合指标最优。因此,本文提出的方法能够满足应用需求,对电力巡检中的检测任务具有重要的参考意义。后续研究将扩展数据集,涵盖更多缺陷类型,进一步提高模型在更全面缺陷类型绝缘子分类任务中的表现。

参考文献:

[1] 康忠健,李昌超,于洪国,等. 一种识别电力系统关键输电线路的方法 [J]. 电力自动化设备,2020,40 (4): 63 - 70.

[2] 国际电力网. 国网江苏超高压公司: 紧急消除特高压泰吴 II 线绝缘子发热缺陷 [EB/OL]. (2023 - 08 - 24) [2025 - 03 - 26]. <https://power.in-en.com/html/power-2434599>.

- shtml.
- [3] 刘悦, 黄新波, 刘天娇, 等. 基于深度学习的架空输电线路绝缘子缺陷检测方法研究综述 [J]. 电力电容器与无功补偿, 2024 (6): 167-177.
- [4] 中国政府网. 云南 9 万公里输电线路实现无人机自主巡检 [EB/OL]. (2022-11-22) [2025-03-26]. https://www.gov.cn/xinwen/2022-11/22/content_5728269.htm.
- [5] 国家能源局. 2020 年 8 月事故通报 [EB/OL]. (2020-11-02) [2025-03-27]. https://www.nea.gov.cn/2020-11/02/c_139485392.htm.
- [6] 陈驰, 彭向阳, 宋爽, 等. 大型无人机电力巡检 LiDAR 点云安全距离诊断方法 [J]. 电网技术, 2017, 41 (8): 2723-2730.
- [7] 刘开培, 李博强, 秦亮, 等. 深度学习目标检测算法在架空输电线路绝缘子缺陷检测中的应用研究综述 [J]. 高电压技术, 2023, 49 (9): 3584-3595.
- [8] 郝艳捧, 梁学致, 黄盛龙, 等. GIS/GIL 绝缘子超声检测研究进展与展望 [J]. 高电压技术, 2023, 29 (9): 3597-3606.
- [9] 陈良芳. 输电线路振动监测与预警系统设计 [J]. 集成电路应用, 2024, 41 (5): 234-235.
- [10] 何伟明. GIS 盆式绝缘子界面缺陷与热应力超声检测方法研究 [D]. 广州: 华南理工大学, 2021.
- [11] 章铖. 基于红外热成像的变电站支柱绝缘子缺陷自动检测方法 [J]. 自动化技术与应用, 2024, 43 (8): 16-19.
- [12] 郭晓冰, 刘宁, 白云灿, 等. 基于完整性感知网络的绝缘子串缺陷检测方法 [J]. 电子测量技术, 2023, 46 (20): 191-196.
- [13] 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.
- [14] ROSS G, JEFF D, TREVOR D, et al. Rich feature hierarchies for accurate object detection and semantic segmentation. [C] //IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2014: 580-587.
- [15] 魏业文, 李梅, 解园琳, 等. 基于改进 Faster-RCNN 的输电线路巡检图像检测 [J]. 电力工程技术, 2022, 41 (2): 171-178.
- [16] WANG C Y, BOCHKOVSKIY A, LIAO H M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real time object detectors [C] //IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2023: 7464-7475.
- [17] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector [C] //European Conference on Computer Vision (ECCV), 2016: 21-37.
- [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.
- [19] 李鹏, 宿云龙, 宁昊, 等. 基于嵌入式 YOLO 网络的电力绝缘子自爆缺陷检测 [J/OL]. 电工技术学报, 2025, <https://doi.org/10.19595/j.cnki.1000-6753.tces.242110>.
- [20] 苏怡萱, 李智, 盘书宝. 基于改进 YOLOv8 的输电线路绝缘子缺陷检测方法 [J]. 电子测量与仪器学报, 2025, 39 (1): 14-23.
- [21] LIN T, GOYAL P, GIRSHICK R, HE K M, et al. Focal loss for dense object detection [C] //IEEE International Conference on Computer Vision (ICCV), 2017: 2980-2988.
- [22] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C] //IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770-778.
- [23] HOU Q B, ZHOU D, FENG J S. Coordinate attention for efficient mobile network design [C] //IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2021: 13713-13722.
- [24] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection [C] //IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 10781-10790.
- [25] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C] //AAAI Conference on Artificial Intelligence, 2020, 34 (7): 12993-13000.
- [26] 王巍, 余欣, 缪佳欣, 等. 基于改进 YOLOv5s 太阳能电池片表面缺陷检测算法 [J]. 电子测量技术, 2025, 48 (5): 128-136.
- [27] 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 Conference on Computer Vision and Pattern Recognition (CVPR), 2023: 7464-7475.
- [28] GE Z, LIU S, WANG F, et al. YOLOX: Exceeding YOLO series in 2021 [J]. ArXiv Preprint Arxiv: 2107.08430, 2021.
- [29] DUAN K, BAI S, XIE L, et al. Centernet: Keypoint triplets for object detection [C] //IEEE International Conference on Computer Vision (ICCV), 2019: 6569-6578.
- [30] 王秋忆, 周浩, 郑婷婷. 改进 RetinaNet 的电力设备目标检测方法 [J]. 计算机与现代化, 2024, 37 (1): 47-52.
- [31] 叶力鸣, 陈蔚文. 一种结合语义分割和目标检测的级联式绝缘子缺陷检测方法 [J]. 计算机与现代化, 2023, 38 (6): 82-88.