

基于 YOLOv8 改进算法的电力绝缘子缺陷检测方法

孙冉¹, 冯田宇², 裴煜³, 王洋³

(1. 山西大学 电力与建筑学院, 太原 030031;

2. 太原科技大学 电子信息工程学院, 太原 030024;

3. 国网太原供电公司, 太原 030009)

摘要: 在野外利用无人机等设备对绝缘子巡检时, 绝缘子因体积小、种类多、材质和外观差异大, 且尺度不一, 影响了巡检过程中的检测准确率, 为此提出了一种改进的 YOLOv8 算法, 以提升多类型、多尺度绝缘子缺陷检测的准确性; 改进算法中, 在回归损失计算中引入了 WIoU, 降低了图像质量引起的梯度增益, 增强了模型的定位性能和泛化能力; 主干网络的特征提取和预测阶段采用多尺度混合注意力机制 MHA 模块, 提高了对小目标重要特征的学习能力; 为有效全面提取图像中多尺度层级的上下文特征信息, 在主干网络末端引入多尺度可分离卷积以增强 SPPF, 并引入多尺度空间敏感模块 MS3M; 实验结果表明, 改进的 YOLOv8 算法在绝缘子缺陷检测中的 *mAP* 值达到 97.3%, 相较于基线 YOLOv8 提升了 6.2%, 对于不同类型、不同尺度大小的绝缘子, 改进的 YOLOv8 算法的缺陷检测效果更好, 有利于提升实际应用中无人机在野外对绝缘子巡检和维护的准确性与效率。

关键词: 无人机巡检; 绝缘子缺陷; 注意力; 多尺度特征; YOLOv8

Defect Detection Method for Power Insulators Based on Improved YOLOv8 Algorithm

SUN Ran¹, FENG Tianyu², PEI Yu³, WANG Yang³

(1. School of Electric Power, Civil Engineering and Architecture, Shanxi University, Taiyuan 030031, China;

2. School of electronic information engineering, Taiyuan University of Science and Technology, Taiyuan 030024, China;

3. State Grid Taiyuan Electric Power Supply Company, Taiyuan 030009, China)

Abstract: With drones and other equipment inspecting insulators in the field, the insulators have the characteristics of small targets, multiple types and large scale differences, which affect the detection accuracy during the inspection process. Therefore, an improved YOLOv8 algorithm is proposed to improve the accuracy of multi-type and multi-scale insulator defect detection. In the improved algorithm, the weighted intersection over union (WIoU) is introduced in the regression loss calculation, which reduces the gradient gain caused by image quality and enhances the positioning performance and generalization ability of the model. The multiscale-hybrid attention mechanism (MHA) is used in the feature extraction and prediction stage of the backbone network to improve the learning ability of important features for small targets. To fully extract multi-scale information containing contextual features of the images, multi-scale deep separable convolution is introduced at the end of the backbone network to enhance the SPPF module, and a multi-scale spatial sensitive module (MS3M) is introduced. Experimental results show that the *mAP* value of the improved YOLOv8 algorithm in insulator defect detection reaches 97.3%, which is 6.2% higher than that of baseline YOLOv8, and performs better in multi-type and multi-scale insulator defect detection. It is conducive for drones to improve the inspection and maintenance efficiency of insulators in the field.

Keywords: drone inspections; insulator defects; attention; multi-scale features; YOLOv8

收稿日期:2024-07-20; 修回日期:2024-09-14。

作者简介:孙冉(2003-),女,大学本科。

引用格式:孙冉,冯田宇,裴煜,等.基于 YOLOv8 改进算法的电力绝缘子缺陷检测方法[J].计算机测量与控制,2025,33(9):74-82.

0 引言

绝缘子是高压输电系统中不可或缺的关键部件,其主要用于电气隔离和机械固定电线。由于长期暴露于复杂恶劣的环境中,绝缘子容易发生老化、破损等问题,从而出现诸如闪络或者短路等意外情况,对于野外输电线路的正常、稳定、安全运行造成了巨大的隐患。在电力系统故障统计中,因绝缘子缺陷而引起的事故占比最高。传统的绝缘子检测方法主要依靠人工巡检,但这种方式工作量大、效率低,难以满足大规模输电线路的巡检需求。此外,依靠人工经验判断,容易出现漏检误检的情况,存在效率低、安全风险高等问题^[1-2]。随着无人机(UAVs, unmanned aerial vehicles)的快速发展,无人机巡检输电线路绝缘子缺陷检测技术逐渐成为研究热点^[3-4]。无人机巡检不仅能够有效降低人工巡检的风险,而且还能提高巡检效率。然而,目前基于无人机航拍图像的绝缘子缺陷检测主要依靠人工判读,难以满足大规模输电线路的巡检需求。因此,在巡检过程中,使用绝缘子缺陷自动化检测技术是实现高效巡检的关键。

当前,深度学习与电力行业结合,将深度学习应用在绝缘子的缺陷检测中,受到越来越多研究学者的重视,逐渐形成趋势^[5-6]。使用无人机拍摄绝缘子缺陷的图像,属于图像领域中的目标检测问题。在深度学习基础上的目标检测研究中,算法模型通常分为两大类:一阶段模型(One-stage)和二阶段模型(Two-stage)。

一阶段模型通过端到端的方式进行训练,直接输出最终的检测结果,典型代表包括SSD^[7]和YOLO^[8]系列。这类模型检测速度快,适合背景对目标干扰较小的场景,但在识别精度上相对较低,特别是对于小目标的检测效果不够理想。

二阶段模型则首先在输入图像中生成一组候选目标区域,然后对每个候选区域进行进一步处理,分类目标并精细化边界框,从而得到最终的检测结果。常见的二阶段模型包括RCNN^[9]、Fast RCNN^[10]和Faster RCNN^[11]等。这类模型在目标识别精度上表现优异,但由于需要更长的训练时间,且在实际应用中检测速度较慢,因此不如一阶段模型高效。

通过对比可以看出,一阶段模型和二阶段模型各有优劣,在实际的绝缘子缺陷检测中选择合适的模型需综合考虑检测速度和精度的要求。

输电线路绝缘子图像通常包含复杂背景,例如杆塔、山体、河流、草地和农田等。此外,实际巡检环境下的拍摄图像还会受到不断变化的环境光照条件影响,呈现出不同的视角。因此,在背景复杂、环境光影响较大的场景中,图像的处理过程较为复杂,且容易造成误检。

为了提高输电线路绝缘子缺陷检测的精度和速度,

需要进一步研究针对复杂背景和尺度变化的鲁棒性更强的绝缘子定位算法,以及针对小目标识别精度更高的缺陷识别算法。文献[12]中提出了基于Mask RCNN的绝缘子串分割模型,在获取的掩模图像中引入最小外接矩形提取绝缘子串图像,检测绝缘子串中的自爆缺陷所在的位置。文献[13]中提出一种基于Transformer架构的DETR目标检测模型,通过优化损失函数,提升了绝缘子缺陷检测的准确性。文献[14]中提出一种以YOLOv3作为基础框架,融合空间金字塔池化(SPP)和MobileNet网络的轻深度卷积神经网络(DCNN)模型,可以消除复杂背景的干扰,从而准确地实现绝缘体定位。文献[15]中提出了一种基于深度卷积自编码器(DCAE)的算法,结合无监督学习的优点,实现对绝缘子自爆缺陷检测。

当前输电线路绝缘子缺陷检测算法中,以基于深度学习的目标检测技术为主要研究方向,仍存在待解决的问题。受限于无人机拍摄距离,绝缘子在图像中通常表现为小目标,现有算法对小目标的检测精度和召回率普遍较低,难以满足实际应用需求。此外,复杂背景容易造成误检,导致算法泛化性不佳。最后,现有算法模型复杂度较高,难以满足边缘端侧设备有限算力的要求,无法实现实时检测。

针对上述研究面临的困境,本文提出一种基于改进YOLOv8的绝缘子故障检测算法。在本文中,在回归损失计算中使用WIoU,降低图像质量引起的梯度增益,增强了模型的定位性能和泛化能力;在主干网络的特征提取和预测阶段,引入多尺度混合注意力机制(MHA, Multiscale-hybrid Attention),增强了网络模型学习小目标重要特征的能力;在主干网络末端,使用多尺度深度可分离卷积来增强SPPF模块,形成多尺度空间敏感模块(MS3M, Multi-Scale-Space Sensitive Module),能够充分提取含有上下文特征的多尺度信息。通过对基线YOLOv8算法框架的改进,提升了绝缘子故障检测的准确率。

1 系统结构及原理

YOLO系列目标检测算法自提出以来,凭借其快速、高效的特点,被广泛应用在工业界的多个领域中。为了进一步提升YOLO算法的性能,研究人员不断进行改进和创新,推出了众多经典模型。YOLOv8算法是由Ultralytics公司于2023年1月10日发布的最新版本,在目标检测的精度和速度方面均取得了显著提升,代表着该领域的先进前沿水平^[16-17]。

在YOLOv8网络框架中,主要由主干网络(Backbone)、颈部(Neck)模块和检测头(Head)三部分组成,如图1所示。




图1 YOLOv8 框架结构图

1.1 主干网络 (Backbone)

YOLOv8 算法使用了经过改进的 CSPDarknet53 作为主干网络, 主要由卷积层、C2f 模块和 SPPF 模块组成。该网络能够提取 5 个不同尺度的特征图 ($B_1 \sim B_5$) 以实现目标检测。C2f 模块通过梯度分流连接实现, 在保持网络轻量化的同时增强了特征提取的信息流动。C2f 模块内部包含 CBS 模块, 首先对输入信息进行卷积处理, 接着执行批归一化操作, 最终通过 SiLU 激活函数输出结果。SPPF 模块采用空间金字塔池化快速算法处理输入特征图, 获取一系列对应不同池化尺寸的子特征图。然后将这些子特征图组合成一个更大的特征图, 使算法能够捕获不同尺度的上下文信息, 同时最大限度地减少信息损失和计算量。通过改进 CSPDarknet53 网络结构并引入 C2f 和 SPPF 模块, YOLOv8 主干网络能够有效提取图像的多尺度特征信息, 并保持轻量化, 为目标检测任务提供良好的基础。

1.2 颈部 (Neck)

YOLOv8 算法在颈部模块采用了 PAN-FPN 结构。该结构构建了一个自顶向下和自底向上的网络, 通过特征融合, 有效结合了浅层位置信息和深层语义信息, 实现了互补效果, 从而提供了更加丰富和完整的特征信息。PAN-FPN 结构首先通过采样图像来创建特征金字塔, 然后通过 FPN 将强语义特征向下级联, 最后通过 PAN 将独特的定位特征向上传播。PAN-FPN 结构使 YOLOv8 能够使用具有多尺度感知能力的特征金字塔, 从而增强其检测各种尺寸和形状目标的能力, 并提高目标检测精度。通过采用 PAN-FPN 结构, YOLOv8 算法能够有效地融合浅层和深层特征, 并获得多尺度感知能力, 为目标检测任务提供良好的基础。

1.3 检测头 (Head)

YOLOv8 算法的检测模块采用解耦合 Head 结构。该结构使用两个独立的分支, 分别承担了目标分类任务和预测的边界框回归任务。YOLOv8 同时使用分布式焦点损失 (DFL, distribution focal loss) 和 CIoU 损失。DFL 能够衡量边界框回归的分布差异, 并针对分类和定位两种任务使用不同的损失函数。对于分类任务,

YOLOv8 用二元交叉熵损失函数 (BCE Loss), 该函数能够有效区分目标和背景。CIoU 不仅关注边界框的重叠部分, 还综合考虑了框的位置和形状, 它能够更好地衡量预测框与真实框之间的距离, 从而更有效地抑制背景噪声的干扰。YOLOv8 是一个无锚框检测模型, 能够简洁地指定正负样本, 避免了锚框设置带来的误差。YOLOv8 采用了任务对齐分配器 (Task-Aligned Assigner) 进行动态样本分配, 该分配器能够根据目标的难易程度进行分配, 使得模型更加关注难检测的目标。通过采用解耦合 Head 结构、无锚框检测和任务对齐分配器, YOLOv8 算法能够有效提高目标检测精度和鲁棒性。

2 基于改进 YOLOv8 的电力绝缘子缺陷检测算法

基于无人机航拍图像进行绝缘子缺陷检测时存在诸多挑战, 包括复杂背景容易干扰模型, 导致误检率高; 缺陷目标占比小, 模型容易漏检小尺度缺陷; 模型对缺陷目标的纹理、边缘等细节特征提取能力不足, 难以与正常部位区分等问题。针对上述问题, 本文以 YOLOv8 为基础模型, 从损失函数、注意力机制和多尺度上下文敏感等 3 个方面进行改进, 改进模型的框架结构如图 2 所示。

首先, 本文提出了一种多尺度混合注意力模块, 该机制可以提取不同尺度的特征信息, 并通过注意力机制进行融合, 使得模型能够更有效地捕捉小目标的细粒度特征, 抑制非关键信息, 如图 2 (a) 中所示的 MHAModule。

其次, 本文选择 WIoU 代替 CIoU 作为边界框回归损失函数。WIoU 引入了动态非单调机制, 能够自适应地调整回归损失, 并设计了合理的梯度增益分配策略, 有效减少了极端样本带来的影响, 使模型能够更加关注普通质量的样本, 从而提高了模型在应用中的泛化能力和整体性能, 如图 2 (d) 中所示。

最后, 通过结合绝缘子整体与局部特征, 提升了缺陷检测精度。引入深度可分离卷积扩展感受野, 增强特




图 2 改进 YOLOv8 的框架结构图

征传递, 精准捕捉不同尺度的缺陷, 保留细粒度信息, 避免局部特征导致的误检。在实际应用中, 能够有效检测出绝缘子的小尺度缺陷, 如图 2 (e) 中所示。

2.1 损失函数优化

针对无人机航拍的绝缘子缺陷目标体积小, 优化损失函数设计, 可以显著提高模型的检测性能。在原有 YOLOv8 算法中, 使用 CIoU 作为损失函数。但 CIoU 没有考虑样本检测难易程度不同的问题, 且使用长宽比作为损失函数的惩罚因子之一, 惩罚项无法反映长宽不同但比值相同的目标的差异, 另外, CIoU 公式的计算涉及到反三角函数, 会增加模型算力的消耗。

为此, 引入了 WIoU 作为改进 YOLOv8 算法的损失函数代替 CIoU。WIoU 综合考虑方位、质心距离和重叠面积, 并引入动态非单调聚焦机制, 通过调整锚框损失权重, 增强模型对中等质量样本的关注, 提升整体性能。WIoU 计算公式如公式 (1) 所示:

$$L_{WIoU} = r \times \exp \left[\frac{(b_{cx}^{gt} - b_{cx})^2 + (b_{cy}^{gt} - b_{cy})^2}{(c_w^2 + c_h^2)} \right] \times (1 - IoU) \quad (1)$$

公式 (1) 涉及的部分参数如图 3 所示。IoU (Intersection over Union) 表示预测边界框与真实边界框的交集比, h 和 w 表示预测边界框的高度和宽度, h^{gt} 和 w^{gt} 表示真实边界框的高度和宽度, b_{cx} 和 b_{cy} 表示预测边界框的中心位置, b_{cx}^{gt} 和 b_{cy}^{gt} 表示真实边界框的中心位置, c_h 和 c_w 表示预测框和真实边界框形成的最小包围边界的高度和宽度。

其中: r 为 WIoU 中的非单调聚焦因子, β 定义为




图 3 损失函数参数示意图

衡量边框质量的异常值, δ 和 α 是超参数, 可以调整以适应不同的模型:

$$r = \frac{\beta}{\delta \alpha^{\beta-\delta}} \quad (2)$$

WIoU 采用动态非单调机制来评估锚框的质量, 这使得模型更加关注普通质量的锚框, 提高了模型定位目标的能力。对于无人机航拍绝缘缺陷检测任务, WIoU 可以动态优化小目标的损失权重来提高模型的检测性能。

2.2 多尺度混合注意力机制 (MHA, multiscale-hybrid attention)

1) 空间注意力机制:

空间注意力机制使卷积神经网络能够有效地识别和

学习需要注意的区域^[18]。基于空间注意力机制可以将空间信息从原始图像映射到替代空间,从而保留关键的图像特征,其结构示意图如图 4 所示。MaxPooling 以自适应方式为突出边缘轮廓等局部特征分配更高的权重,而 AvgPooling 则是优先考虑显著区域内的全局特征。通过结合 MaxPooling 和 AvgPooling,网络可以自适应地捕获有区别的全局和局部特征。




图 4 空间注意力模块

2) 通道注意力机制:

通道注意力机制通过为多个通道的特征图分配权重来评估每个通道特征图的重要性^[19],如图 5 所示。较高的权重表示通道的特征图包含更多关键特征,值得更多关注。借助结合 MaxPooling 和 AvgPooling,网络可以自适应地捕获有区别的全局和局部特征。之后使用两个全连接层构建一个 Bottleneck 结构,可以增强了 CA 稳健的非线性学习的能力,从而产生了更有效的模型。

3) 多尺度混合注意力机制 (MHA):

多尺度混合注意力机制融合了空间注意力机制和通道注意力机制,用以增强算法模型在不同尺度上对目标检测的能力。首先,以特征图 $T \in R^{c \times h \times w}$ 作为输入,将特征图张量 T 输入到空间注意力模块,生成特征图张量 $S \in R^{w \times h \times c}$,使用 $4c$ 个 1×1 卷积核 S 进行卷积,输出降维后的特征图 $D \in R^{w \times h \times 4c}$,以减少计算量。接着,通过 4 个分支对 D 进行多尺度特征提取,得到多尺度特征图 $P1, P2, P3, P4 \in R^{w \times h \times 4c}$,并通过 Concat 操作融合 $P1, P2, P3, P4$,生成特征图 $Q \in R^{w \times h \times c}$ 。然后,将 Q 输入到通道注意力模块,添加通道注意力,生成特征图张量 $C \in R^{w \times h \times c}$ 。最后,使用 Add 操作融合特征图 S 和 C ,生成最终的输出特征图张量 H ,其结构如图 6 所示。

多尺度注意力机制采用 4 个分支从输入特征图中进行多尺度特征提取。它利用维度为 1×3 和 3×1 的内核,以及维度为 1×5 和 5×1 的内核,分别完成两次顺序卷积运算。通过这种级联非对称卷积运算的结合,可以有效减少网络的参数数量,同时还引入了额外的非线性激活层,从而增强了其非线性学习能力。此外,考虑到空间和通道维度,它有助于捕获与特征图张量内的小目标相关的判别特征,减少了图像中非必要信息的影响而导致的潜在失真,最终增强了网络模型从小目标特征中学习的能力。

2.3 多尺度空间敏感模块 (MS3M, multi-scale spatial-sensitive module)

在绝缘子缺陷检测任务中,缺陷区域面积较小导致信息减少,影响检测精度。分析表明,本文研究的 4 种缺陷类型在原始图像中的占比通常低于 1%,属于小尺度目标。图像标准化为 640×640 分辨率后,缺陷区域被压缩至 80×80 以内,可能在多层卷积处理中丢失关键信息。为了解决这一问题并提升小尺度缺陷的检测性能,本文重点研究了增强此类目标特征提取能力的相关方法。

SPPF 模块显著扩大感受野,使网络捕获更多语义信息。但原始 YOLOv8 架构中依赖最大池化操作,可能导致细节缺陷信息丢失,进而影响检测性能。为了解决这一问题并更好地利用上下文信息,本文提出了一种基于多尺度深度可分离卷积的增强型 SPPF 结构,构建了一个多尺度空间敏感模块 (MS3M, multi-scale spatial-sensitive module)。

如图 7 所示,MS3M 以 B5 层生成的绝缘子特征图作为输入,并分为两个分支处理。一个分支通过最大池化扩展感受野捕捉整体特征,另一个分支用深度可分离卷积提取细粒度缺陷特征,最终通过 Concat 操作融合生成多尺度输出特征图。这种方法在扩大感受野的同时保留了图像的分辨率,从而能够在绝缘子缺陷检测中更全面、准确地捕捉目标特征。

MS3M 模块结合深度可分离卷积,构建了计算开销较小的多尺度空间敏感模块。该模块扩展感受野的同




图 5 通道注意力模块




图 6 多尺度混合注意力模块

时, 强化了语义级别间的特征传递, 有效捕捉不同尺度的绝缘子缺陷特征, 保留精细空间信息。通过结合缺陷与绝缘子的语义特征, MS3M 避免了局部特征导致的检测错误, 显著提升了小尺度缺陷的检测能力。

3 实验与结果分析

3.1 数据集

本文实验所用数据集为自建数据集, 图像数据来源于太原国网检修公司通过无人机巡检拍摄获取。该数据集中, 完好绝缘子的图片数量为 673 张, 以及 812 张涵盖自爆、变形、破损等 3 种不同缺陷类型的绝缘子图片。

在本研究中, 图像标注采用标注工具 LabelImg 对绝缘子目标进行分类标注。在标注过程中, 标注人员根据绝缘子的状态 (完好、自爆、变形、破损) 对图像中的目标进行识别和分类。对于每个绝缘子目标, 标注人员手动绘制边界框, 并精确记录其在图像中的位置和大小。在图像标注完成后, 所有标注结果都经过复核, 以确保数据的准确性和一致性。

为解决数据集规模有限和标签不平衡问题, 本研究采用数据增强与样本平衡技术, 通过裁剪、旋转、缩放及亮度等变换, 提升模型泛化能力, 支持有效的缺陷检测。

图像增强后, 获得了 2 721 张图像, 对图像进行标

注, 构成了本研究的实验数据集。数据集中, 检测的目标物体分别为绝缘子、具有自爆缺陷的绝缘子、具有损伤缺陷的绝缘子和具有变形缺陷的绝缘子。标注过程产生了 6 812 个带标签的边界框, 如表 1 所示。图 8 提供了从构建的高压输电线路绝缘子数据集中获取的图像示例。

表 1 样本数量与分布统计

	图片/张	标签	标注框/个
常规绝缘子	673	绝缘子	1 215
缺陷绝缘子	2 048	绝缘子	2 357
		自爆	1 131
		破损	1 267
		变形	842

3.2 模型训练和评估

在模型训练中, 学习率决定神经网络在训练期间更新权重的步长, 影响模型学习最小化其损失函数的速度, 在本文中, 模型训练使用了 Adam 优化算法, 设置学习率为 0.001, batch size 为 16, 权重衰减因子为 0.000 5, 总训练时长为 300 个 epoch, 确保模型在整个训练过程中能够有效学习和保持良好性能。

为了评估本文所提方法的有效性, 使用精度、召回率、平均精度 (mAP) 等指标来完成评估。精确度衡量模型所做出的所有阳性预测中真正样本所占的比例。其定义如公式 (3) 所示:

$$Precision = \frac{TP}{TP + FP}$$
 (3)

召回率是计算所有正确预测目标的百分比, 其定义如公式 (4) 所示:

$$Recall = \frac{TP}{TP + FN}$$
 (4)

其中: TP 表示正确预测为正的样本数, FP 表示预测为正但实际上为负的样本数, FN 表示预测为负但实际上为正的样本数。




图 7 多尺度空间敏感 MS3M 模块结构框图




图 8 UAV 采集的输电线路绝缘子缺陷类型

AP 的定义为精度-召回率曲线下的区域面积, 计算公式如公式 (5) 所示:

$$AP = \int_0^1 p(r) dr \quad (5)$$

mAP 是对所有样本类别的 AP 值进行加权平均得到的结果, 用于衡量模型在所有类别上的检测性能, 其公式如式 (6) 所示:

$$mAP = \frac{\sum_{i=1}^N AP_i}{N} \quad (6)$$

本文研究的实验选用英特尔 (R) 酷睿 (TM) i9-10980HK CPU 和 NVIDIA GeForce RTX 3080 显卡上作为实验的硬件平台, 软件环境包括 CUDA 11.1、cuDNN 8.0.4, 并在 PyTorch 1.9 深度学习框架内进行实施。

本文在 YOLOv8 的基础上进行改进, 在回归损失计算中引入了 WIoU, 在主干网络的特征提取和预测阶段采用多尺度混合注意力机制 MHA 模块, 以及在主干网络末端, 引入多尺度深度可分离卷积增强 SPPF 模块。上述改进策略, 显著增强了模型的定位性能和泛化能力, 以及提升了对小目标识别的准确性。

模型完成训练之后, 在模型推理阶段, 使用自建数据集, 基于已搭建的实现环境进行对比测试和结果分析。

3.3 实验结果

3.3.1 基线与改进 YOLOv8 的对比实验

为了评估改进 YOLOv8 的性能, 本文将其与基线模型 YOLOv8 进行了比较。

改进的 YOLOv8 和基线 YOLOv8 算法在自建的绝缘子数据集上训练, 对应的 Loss 曲线如图 9 所示。经过 220 轮迭代后, 使用 WIoU 损失函数的改进 YOLOv8 的损失值从初始的 0.16 收敛到 0.024 附近, 使用 CIoU

损失函数的基线 YOLOv8 的损失值从初始的 0.17 收敛到 0.038 附近。使用 WIoU 损失函数的 YOLOv8 模型可以更准确地通过梯度回传误差并更新网络权重。因此, 与基线 YOLOv8 相比, 改进的 YOLOv8 模型更快地收敛, 并且收敛值更小。




图 9 改进 YOLOv8 和基线 YOLOv8 训练 Loss 曲线

两种算法模型对绝缘子缺陷检测结果可视化对比如图 10 所。表 2 显示了每个类别的 AP 值和两个模型的总体 mAP。




图 10 改进与基线的 YOLOv8 算法模型对绝缘子缺陷检测结果可视化对比

由表 2 可知,改进的 YOLOv8 算法模型在绝缘子缺陷检测结果中的 mAP 为 97.3%。相比基线 YOLOv8,改进的 YOLOv8 算法模型在 mAP 上提高了 6.2%。各个类别的 AP 值也有所提高,其中行自爆、形变和破损的 AP 值提高了 6%以上。

表 2 改进 YOLOv8 与基线 YOLOv8 的对比实验

模型	基线 YOLOv8	本文
绝缘子	96.4	98.7
自爆	93.1	99.5
形变	86.5	93.6
破损	88.3	97.2
所有类别	91.1	97.3

绝缘子和自爆缺陷因轮廓清晰,特征易提取, AP 值高,误检漏检少。形变绝缘子因伞裙尺寸和变形差异大, AP 值为 93.6%,相对较低。

结合图 10,相比于基线 YOLOv8 模型,本文提出改进 YOLOv8 算法模型在小目标、背景复杂等场景中,对绝缘子缺陷检测具有更高的识别准确性,是因为在改进 YOLOv8 算法模型引入多尺度通道-空间注意力机制 MHA,通过与主干的特征提取网络和预测端融合,增强了网络模型学习小目标重要特征的能力。从整体来看,本文提出的方法在实验中所有类别目标的整体准确率高达 97.3%,证明本文提出的方法在户外场景下绝缘子缺陷检测的任务中,能够准确有效地识别和定位绝缘子及其缺陷,特别是针对小尺寸的目标、复杂背景等情况。

3.3.2 不同算法模型的对比实验

改进的 YOLOv8 算法作为应用于电力绝缘子缺陷的目标检测算法,为了充分分析算法模型的性能,与 YOLOv5、Faster RCNN、SSD 和 DETR 等一些深度学习方法进行,如表 3 所示。

表 3 改进 YOLOv8 与基线 YOLOv8 的对比实验

模型	Precision/%	Recall/%	mAP /%	FPS
YOLOv5	88.7	83.6	89.1	33.7
Faster RCNN	93.4	90.7	92.2	9.5
SSD	90.3	88.1	90.7	31.8
ECAP-YOLO ^[21]	93.1	89.3	91.4	30.7
DETR	90.1	82.5	89.8	6.4
本文	97.6	96.7	97.3	31.4

由表 3 可知,在绝缘子缺陷检测中,本文所提出的方法在数据集上的综合性能指标 mAP 优于其他算法。其中,YOLOv5 的 mAP 为 89.1%,Faster RCNN 达到了 92.2%,SSD 获得了 90.7%的 mAP ,ECAP-YOLO^[21] 的 mAP 达到了 91.4%,DETR 获得 mAP 为 89.8%。对比之下,本文所提出的方法在数据集的

mAP 值为 97.3%,高于其他算法。实验结果证实了本文所提方法的有效性,且检测速度也处于相对较高水平。

根据表 3 结果,YOLOv5 在精度和速度上表现良好,但深度增加时容易丢失小目标信息,导致小尺度缺陷检测精度下降。Faster RCNN 使用单层低分辨率特征图,NMS 和 RoI 池化的两次取整降低了检测精度,且计算量大,速度较慢。因此,对于部分遮挡的多尺度、小目标绝缘子缺陷检测任务并不太适合。DETR 网络在电力巡检中常用,采用自注意力机制,但计算复杂度高,推理和检测速度较慢,且训练时间较长。ECAP-YOLO^[21]引入 ECA 注意力机制,提升了小目标的检测能力,但在多目标、多尺度的复杂电力巡检任务中检测准确性较低,不能满足高精度检测的需求。SSD 具备采用端到端训练方式,直接从原始图像中学习特征,较高实时性和较好的检测准确性,在电力巡检场景中能够快速响应,但是对于绝缘子中目标较小、目标密集等场景时,识别准确性下降,影响检测精度。本文采用改进的 YOLOv8 算法,在算法模型中,在改进的结构中,引入 MHA 模块和 SPPF 模块,并在回归损失计算中使用 WIoU,增强了网络模型学习小目标重要特征的能力。综合结果表明,相较于其他先进算法,在检测精度和计算速度方面,本文提出的方法在绝缘子缺陷检测任务中取得了良好的结果,能够更准确地识别和定位多类型、多尺度绝缘子及其缺陷。

3.3.3 消融实验

为了验证文中所提出改进策略的有效性,本文采用消融实验方法对基线模型进行评估,量化各个关键模块在算法模型中的作用,具体实验结果如表 4 所示。

表 4 基于改进 Yolov8 算法模型的消融实验

模型	Precision	Recall	mAP
YOLOv8	91.9	87.3	91.1
YOLOv8+WIoU	93.6	89.7	92.6
YOLOv8+ MHA	94.8	92.4	94.7
YOLOv8+MS3M	94.3	90.9	93.5
YOLOv8+WIoU+MHA	95.9	93.8	95.5
YOLOv8+WIoU+MS3M	94.7	92.6	94.2
YOLOv8+MHA+MS3M	97.3	95.8	96.7
YOLOv8+WIoU+MHA+MS3M	97.6	96.7	97.3

通过有选择地删除关键部分和重新训练算法,可以衡量 WIoU、多尺度混合自注意力机制 MHA 和多尺度空间敏感模块 MS3M 对整体性能的影响。

由表 4 的实验结果可知,所提出的各项改进策略在应用于基线模型后,均在不同程度上提升了检测性能。WIoU 引入了预测框回归损失,通过更优的样本分配策略改善了模型的定位能力,使 mAP 提升了 1.5%。在

Yolov8+WIoU 的结构中引入了多尺度注意力模块,高效的注意力机制能够更好地关注特征图中的关键信息,使 mAP 继续提高了 2.9%。引入 MS3M 后, mAP 提升 1.8%,表明其充分利用了局部和全局特征,提升了检测性能。

实验验证了 YOLOv8 改进的合理性与有效性,模型检测精度显著提升,满足无人机电力巡检的需求。

4 结束语

本文提出了一种用于航拍绝缘子多类别缺陷识别的改进 Yolov8 算法。在本文提出的算法中,在基线 Yolov8 的基础上,采用 WIoU 作为回归损失函数,降低数据集中图像质量梯度变化问题,提升模型的定位性能和泛化能力;在主干网络的特征提取部分,引入并融合了多尺度混合注意力机制 (MHA),增强了网络模型提取小目标重要特征的能力;在主干网络末端的 SPPF 模块中插入深度可分离卷积,充分提取多尺度的空间特征信息。本文提出的改进 Yolov8 算法在多类别缺陷目标检测中的 mAP 达到了 97.3%,相比于基线 Yolov8 高出 6.2%,提升了绝缘子故障检测的准确率。

参考文献:

- [1] 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.
- [2] GAO Z, YANG G, LI E, et al. Novel feature fusion module-based detector for small insulator defect detection [J]. IEEE Sensors Journal, 2021, 21 (15): 16807–16814.
- [3] YANG Z, XU Z, WANG Y. Bidirection-fusion-YOLOv3: An improved method for insulator defect detection using UAV image [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1–8.
- [4] ZHANG T, ZHANG Y, XIN M, et al. A light-weight network for small insulator and defect detection using UAV imaging based on improved YOLOv5 [J]. Sensors, 2023, 23 (11): 5249.
- [5] LIU J, HU M M, DONG J Y, et al. Summary of insulator defect detection based on deep learning [J]. Electric Power Systems Research, 2023, 224: 109688.
- [6] LIU Y, LIU D, HUANG X, et al. Insulator defect detection with deep learning: A survey [J]. IET Generation, Transmission & Distribution, 2023, 17 (16): 3541–3558.
- [7] LIU X, LI Y, SHUANG F, et al. Issd: Improved ssd for insulator and spacer online detection based on uav system [J]. Sensors, 2020, 20 (23): 6961.
- [8] JIANG P, ERGU D, LIU F, et al. A review of yolo algorithm developments [J]. Procedia computer science, 2022, 199: 1066–1073.
- [9] BHARATI P, PRAMANIK A. Deep learning techniques—r-cnn to mask r-cnn: a survey [J]. Computational Intelligence in Pattern Recognition: Proceedings of CIPR 2019, 2020: 657–668.
- [10] GIRSHICK R. Fast r-cnn [C] //Proceedings of the IEEE international conference on computer vision, 2015: 1440–1448.
- [11] CAO C, WANG B, ZHANG W, et al. An improved faster r-cnn for small object detection [J]. IEEE Access, 2019, 7: 106838–106846.
- [12] 汪 琦,刘向阳. 基于 Mask RCNN 的绝缘子自爆缺陷检测 [J]. 计算技术与自动化, 2022, 41 (1): 52–58.
- [13] CHENG Y, LIU D. An image-based deep learning approach with improved DETR for power line insulator defect detection [J]. Journal of Sensors, 2022, 2022 (1): 6703864.
- [14] YANG L, FAN J, SONG S, et al. A light defect detection algorithm of power insulators from aerial images for power inspection [J]. Neural Computing and Applications, 2022, 34 (20): 17951–17961.
- [15] DENG F, LUO W, WEI B, et al. A novel insulator defect detection scheme based on deep convolutional auto-encoder for small negative samples [J]. High Voltage, 2022, 7 (5): 925–935.
- [16] MA S, LU H, LIU J, et al. LAYN: lightweight multi-scale attention YOLOv8 network for small object detection [J]. IEEE Access, 2024.
- [17] WANG G, CHEN Y, AN P, et al. UAV-YOLOv8: a small-object-detection model based on improved YOLOv8 for UAV aerial photography scenarios [J]. Sensors, 2023, 23 (16): 7190.
- [18] CHEN J, FU Z, CHENG X, et al. An method for power lines insulator defect detection with attention feedback and double spatial pyramid [J]. Electric Power Systems Research, 2023, 218: 109175.
- [19] HAN G, ZHAO L, LI Q, et al. A lightweight algorithm for insulator target detection and defect identification [J]. Sensors, 2023, 23 (3): 1216.
- [20] TONG Z, CHEN Y, XU Z, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism [J]. ArXiv Preprint ArXiv: 2301.10051, 2023.
- [21] KIM M, JEONG J, KIM S. ECAP-YOLO: Efficient channel attention pyramid YOLO for small object detection in aerial image [J]. Remote Sensing, 2021, 13 (23): 4851.