

改进 YOLOv8 的轻量化绝缘子缺陷检测算法

樊计兰¹ 赵飞燕^{1*} 吕跃先¹ 田苏慧敏¹

FAN Jilan ZHAO Feiyan LÜ Yuexian TIAN Suhui

摘要

绝缘子作为输电线路的核心组件,对其潜在缺陷进行及时检测,是保障电力供应稳定可靠的技术关键。针对现有算法在检测中存在的精度不足、漏检率高以及模型复杂度大难以部署等问题,文章提出了一种改进的 YOLOv8 轻量化检测算法,用 SPD-Conv 替换主干网络传统卷积,以增强低分辨率图像的检测能力;Neck 部分引入轻量级卷积 GSCONV,并采用 CSPCC 结构替代 C2f,减少了冗余计算,进而高效提取空间特征。此外,将回归损失函数改为 WIoUv3,增强模型对低质量样本的关注度。实验结果表明,相较于原始 YOLOv8 算法,改进后的算法在绝缘子缺陷检测任务上的 mAP 达到 93.8%,提高了 1.8%,且各类缺陷平均精度均有显著提高,同时模型更加轻量化,有效提升了输电线路智能化维护的效率。

关键词

YOLOv8; 绝缘子; 深度学习; 电力巡检; 缺陷检测

doi: 10.3969/j.issn.1672-9528.2026.04.018

0 引言

绝缘子是电力系统中的关键组件,主要功能在于支撑输电线路和电气绝缘。但长期暴露于复杂多变环境下,经常承受物理应力和化学侵蚀,导致出现自爆、闪络、损坏以及表面裂纹等问题。绝缘子缺陷的潜在危害可能导致区域性乃至整个地区的电网故障,造成不必要的经济损失并影响输电线路的安全。

传统巡检工作主要依赖人工,存在高难度、高风险和效率低等局限性。基于无人机航拍图像的智慧巡检,可以有效地检测和定位绝缘子等电气部件的缺陷或故障^[1]。但输电线路关键部件缺陷的精确检测仍是亟待攻克的技术难题,同时现有检测模型的尺寸和计算需求构成边缘设备部署的难点。近年来,深度学习的发展推动了目标检测算法的演进,主要形成了以 R-CNN 系列为代表的两阶段检测(如 Faster R-CNN、Mask R-CNN)和以 YOLO 系列为代表的单阶段检测两大技术主流。Tao 等^[2]为了解决绝缘子自爆缺失的检测问题,设计了一种新的基于深度卷积神经网络的方法,采用级联结构,对绝缘子缺陷检测具有良好的鲁棒性。李瑞生等^[3]加入残差网络以及多级特征融合方法优化 SSD 网络结构,用于检测输电线路复杂背景下的销钉缺陷。Zheng 等^[4]利用 K-means++ 聚类得到更有利于检测绝缘子的锚盒,提出一种对 YOLOv7 改进的检测方法,实现在复杂背景下

小目标的精确检测。Zhang 等^[5]所提出的 YOLOv8s 改进模型,在基线模型上增加多尺度大核注意力以及 GSC-C2f 模块。在简化计算的同时,也提高了模型对缺陷重要信息提取的能力。在实际应用场景中,模型检测精度越高,一般需要更复杂的网络模型,检测的实时性无法得到保证。以上研究都只在小目标检测精度或降低模型复杂度方面取得了进展,但在兼顾轻量化与检测精度之间的平衡,仍存在进一步优化空间。为了能在边缘设备上高效部署的同时保持检测精度,本文以 YOLOv8n 架构为基础,提出了一种改进的轻量化绝缘子缺陷检测算法。

1 算法原理

YOLOv8 算法包含五种不同的型号。考虑到计算资源要求以及实时检测速度,选择具有快速、准确等特点的 YOLOv8n 作为基准模型。YOLOv8 的主要结构包括主干特征提取网络(Backbone)、特征强化提取网络(Neck)以及检测头(Head)三个部分^[6]。其网络结构如图 1 所示。在 YOLOv5 网络结构基础上,换成了梯度流更为丰富的 C2f 结构,采用无锚分体式检测头,有助于提高准确性和更高效的检测过程。Head 部分采用了目前主流的解耦头结构,将分类和检测头分离,用于缓解分类和定位任务之间的冲突。从 Anchor-Based 换成了 Anchor-Free^[7],对长宽比不规则的目标具有更强的适应性。预测盒边界的回归任务采用分布式聚焦损失(distributed focal loss, DFL)和 CIoU;引入 Task-Aligned Assigner^[8]进行动态样本分配,从而有效提高模型的检测精度。

1. 宁夏师范大学物理与电子信息工程学院 宁夏固原 756099
[基金项目] 宁夏自然科学基金项目(2023AAC03353)




图1 YOLOv8 网络结构

改进后的 YOLOv8 网络结构如图 2 所示，具体改进策略体现在以下四个方面：（1）在主干网络中引入 SPD-Conv 模块，确保对低分辨率图像以及绝缘子破损、飞络等小目标缺陷图像上的准确检测能力；（2）在 Neck 网络区域采用轻量级卷积 GSConv，直接替换原始卷积层，有效减少了深层网络中的信息冗余，计算成本和内存占用较小；（3）将 Neck 中的 C2f 模块全部替换为 CSPPC，网络的参数量显著减少，有效地减少了网络的计算复杂度，同时检测精度并未下降；（4）由于绝缘子缺陷图像中不可避免地存在一些低质量的样本，使用 WIoUv3 损失函数替代 CIoU 损失，缓解对模型泛化能力的负面影响。




图2 改进后的网络结构

1.1 SPD-Conv 模块

卷积神经网络（CNN）在目标较小或处理低分辨率图像的任务时，性能会显著下降。这主要归因于传统卷积神经网络

中的细粒度信息丢失，在学习有效特征表示方面的能力不足。SPD-Conv（空间深度转换卷积）模块的引入为 CNN 架构设计提供了新的可能性^[9]。SPD-Conv 结构如图 3 所示。在 SPD（空间到深度）层中，按照一定比例对输入大小为 $S \times S \times C_1$ 的特征图进行下采样，得到四个子图。然后对子特征图进行沿通道维度的拼接，在此过程中，通道维度中的所有信息得到了完整保留。Conv（非跨步卷积）层使用 C_2 滤波器来调整通道数量。




图3 SPD-Conv 模块结构

1.2 轻量级 GSConv 模块

在绝缘子的智能巡检任务中，复杂度高的模型难以实现实时检测要求。由深度可分离卷积（DSC）构建的轻量级主干网络，在减少模型参数和浮点运算数方面表现出显著效果，但其精度仍不足以满足需求。为此，采用了一种新型的轻量级卷积 GSConv（ghost-shuffle convolution）^[10]，用以降低模型复杂度的同时保持精确度。如图 4 所示，GSConv 结构由标准卷积层、批归一化（BN）和 SiLU 激活函数组成的通道密集卷积（SC）模块处理输入特征图。随后，该特征图通过 DSC 模块进行处理，并与原始特征图在不同通道维度堆叠。混洗（shuffle）操作将 SC 生成的特征均匀渗透到 DSC 生成的特征的每个部分，生成最终的输出特征图。GSConv 采用大核尺寸的深度可分离卷积，有效解决了在浅层网络中无法捕获足够感受野的问题。




图4 GSConv 网络结构

1.3 CSPPC 模块

CSPPC 模块是基于 PartialConv 以及 DualConv 的设计的一种全新结构。部分卷积（PConv）的基本原理是通过减少不必要的计算以及内存使用来高效提取空间特征^[11]。这种

结构相比传统的卷积只在输入的少数通道上使用滤波器，节省计算开销，提高计算速度。图 5 为 C2f 和 CSPPC 结构，CSPPC 将 Bottleneck 中的 Conv 全部替换为 PConv。




图 5 C2f 和 CSPPC 的结构示意图

1.4 损失函数优化

在训练中，不断进行参数优化、调整等，可以得到更精确的预测结果。在基准模型中边界框回归损失函数采用 CIOU 进行衡量预测框和真实框之间的接近程度。但是在预测框与真实框没有重叠时，梯度无法有效反向传播，模型将难以从中学到到有价值的信息。WIoU 损失函数定义为^[12]：

$$L_{WIoUv1} = R_{WIoU} L_{IoU} \quad (1)$$

$$R_{WIoU} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*}\right) \quad (2)$$

$$L_{WIoUv3} = r L_{WIoUv1} \quad (3)$$

$$r = \frac{\beta}{\delta \alpha^{\beta-\delta}} \quad (4)$$

式中： x 、 y 、 x_{gt} 、 y_{gt} 分别为预测框以及真实框中心点坐标； W_g 和 H_g 为预测框与真实框所构成的最小封闭框的宽和高； β 、 r 为离群度和非单调聚焦系数； α 和 δ 为可调整的超参数。

WIoUv3 损失函数采用动态非单调聚焦机制，可以增强模型对低质量样本的关注程度，提高模型的泛化能力。

2 实验准备

2.1 实验环境

本实验使用操作系统是 Ubuntu20.04，运行内存是 24 GB，使用的深度学习框架为 PyTorch，具体配置情况如表 1 所示。在网络训练中，所有输入图像大小统一调整为 640 px×640 px，训练 epoch 设置为 300，batch 大小设为 16，初始学习率设为 0.01，采用 SGD 优化器。在整个实验过程中，保证相同的实验条件以及参数设置。具体超参数选择如表 2 所示。

表 1 环境配置

类别	环境规格
操作系统	Ubuntu 20.04.6 LTS
编程语言	Python 3.9.0
深度学习框架	PyTorch 2.5.0
CPU	Intel(R) Core(TM) i9-14900K
GPU	NVIDIA GeForce RTX 4090
内存	24 GB

表 2 实验参数

参数名称	参数值
训练轮次	300
批量大小	16
初始学习率	0.01
图像输入大小	640 px×640 px
优化器	SGD
动量系数	0.937

2.2 实验数据

本文所用实验数据集由中国输电线路绝缘子数据集（Chinese power line insulator datasets, CPLID）、绝缘子缺陷图像数据集（IDID）^[13] 以及其他公开网络捕获组成。使用多元化的数据组合策略，可以有效减轻单一数据集带来的潜在性能偏差或过拟合问题。绝缘子数据集图像共计 4 420 张，使用 LabelImg 工具进行标注。按照 8:1:1 的比例将数据集划分训练集、测试集和验证集。标签类别包括四种：正常绝缘子、污染闪络、破损和自爆。不同类型的绝缘子缺陷如图 6 所示。




图 6 标签类别示例

2.3 评价指标

在评估绝缘子缺陷检测算法的性能时，本文采用如下指标对其进行比较：精确度（Precision）、召回率（Recall）以及平均精度（mAP）。精确度是所有被分类为正样本的实例中，真正为正样本的比例。对于故障图像占比较少的情

况，仅用此指标无法反映对故障的识别能力。召回率表示被正确识别为正样本占所有实际为正样本的比例。计算公式^[14]为：

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (5)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (6)$$

平均精度是所有类别的平均精度（AP）求平均而得出的，综合考量了精确度（P）和召回率（R）两个指标。计算公式为：

$$\text{AP} = \int_0^1 P(R) dR \quad (7)$$

$$\text{mAP} = \frac{\sum_{i=0}^M \text{AP}_i}{M} \quad (8)$$

式中：TP 是正确检测的样本数；FP 是误检的样本数；FN 是漏检的样本数；M 是数据集的类别数。

为了检验本文方法是否具有实时性，还采用了浮点运算数（FLOPs）以及参数量（Parameters）衡量模型的大小和复杂度。

3 结果与分析

可视化热力图是一种用于可视化数据分布的工具。颜色越深代表置信度越高，即在目标检测过程中对相应位置的关注程度更高。热力图对比结果如图 7 所示，蓝色区域代表背景，橙红色区域代表绝缘子及其缺陷。热力图可视化结果中不仅精准框定了绝缘子缺陷的位置，亦输出了对应的置信度。改进模型的颜色更加集中，检测精度也高于原始模型，在绝缘子缺陷检测任务中更有优势。




图 7 热力图可视化结果

3.1 消融实验


为了验证各个改进模块对绝缘子缺陷检测的效果，本文在绝缘子图像数据集上进行消融实验。实验结果如表 3 所示，“√”表示该模块被使用，“×”表示未使用。

表 3 消融实验比较


实验	GSCnv	CSPPC	SPD-Conv	WIoU	P/%	mAP@0.5/%	参数量 /10 ⁶	FLOPs/10 ⁹
A	×	×	×	×	91.3	92.0	3.0	8.2
B	√	×	×	×	93.0	92.7	2.9	8.1
C	√	√	×	×	91.3	92.2	2.4	7.2
D	√	√	√	×	93.3	93.0	2.4	7.1
E	√	√	√	√	94.0	93.8	2.4	7.1

实验 A 使用 YOLOv8n 进行缺陷检测；实验 B 用一个 GSCnv 模块替换了 Neck 里面原来的卷积，而在没有任何额外计算量的情况下 mAP@0.5 提升 0.7%；实验 C 基于实验 B 的基础上加入一个轻量化 CSPPC 模块替换 Neck 中的 C2f，FLOPs 下降至 7.2×10⁹，相比于基线降低 12.1%；实验 D 再把主干网络中的部分 Conv 替换为 SPD-Conv，从而降低更多计算量以及参数量。经过微调之后，重点针对绝缘子破损、飞络缺陷等小目标，mAP@0.5 提高到 93%，极大地改善了对小尺度目标以及低分辨率图像的检测性能；实验 E 即为本文提出的改进方法，在此基础上对模型进行了轻量化处理，因此其参数量大幅减少，复杂度也较低。其中精确度为 94%，提高了 2.7%，mAP@0.5 值增加了 1.8%，上升至 93.8%，FLOPs 降至 7.1×10⁹，参数量降低了 20%。由此可见，本文提出的方法不仅可以提高模型检测能力，而且可以有效提升模型效率，更加有利于模型在实际应用场景中部署，尤其是资源受限的情况。

为了直观感受 YOLOv8n 与改进模型的差别，对两种模型的性能进行对比，如图 8 所示。精确度 - 召回率（P-R）曲线描述的是不同阈值下精确度和召回率之间的关联。曲线越接近坐标轴的右上角越好。图 8（a）（b）分别为改进前后的 P-R 曲线对比，改进模型的平均精度在各个类别上的百分点都有提高。0.6% 的平均精度增长用于预测正常绝缘子，飞络、破损和自爆绝缘子的缺陷检测分别增长 3.5%、2.0% 和 1.2%。



（a）原始 P-R 曲线



(b) 改进后的 P-R 曲线

图 8 模型性能对比

3.2 不同算法对比

本文将所提方法与当前主流的多种方法进行对比,实验结果均详细记录在表 4 中。实验数据表明,Faster R-CNN 检测精度较高,但结构复杂、计算耗时长。而 YOLOv12 的 FLOPs 最低,为 6.5×10^9 ,但在本研究采用的数据集上达到的检测精度却相对偏低,未能满足对检测准确性的要求。本文方法的精度和模型参数量分别为 93.8% 和 2.4×10^6 ,均优于其他算法,实现了精度与效率的良好平衡。

表 4 不同算法对比


模型	mAP@0.5/%	参数量/ 10^6	FLOPs/ 10^9
Faster R-CNN	92.3	—	—
YOLOv5n	91.2	2.5	7.2
YOLOv8n	92.0	3.0	8.2
YOLOv10n	91.9	2.7	8.4
YOLOv12n	90.8	2.5	6.5
本文方法	93.8	2.4	7.1

3.3 不同复杂场景的对比

为了确保检测结果在实际应用场合的全面性和可靠性,本研究设计了多场景对比实验,涵盖了以下三种不同的测试环境:目标物体与周围环境的对比度较高的单一场景;无人机在密集分布的绝缘子环境中拍摄,图像中绝缘子数量多且分布紧密,背景复杂的多变场景;弱光条件或特殊气象条件下(如雪天)拍摄的特定场景。

在每种场景中,精心挑选出具有代表性的图像进行对比,如图 9 所示。单一场景下,YOLOv8n 对绝缘子破损的检测精度仅为 60%,可见其对小型目标缺陷的提取能力较弱,相比之下,改进模型以 80% 的精度精准定位出绝缘子缺陷;多变场景下,改进的 YOLOv8n 对飞络绝缘子缺陷的检测准确率略高;特定场景(雪天)下,并未出现误检,改进的模型对破损缺陷检测准确率高达 90%。通过这一对比验证,可以得出结论,经过改进的模型的置信度显著优于原始模型,改

进网络的性能也明显优于原始网络。



(a) 单一场景 (b) 多变场景 (c) 特定场景

图 9 不同背景下的绝缘子缺陷检测

4 结语

绝缘子故障对电力系统稳定性构成重大挑战,在巡检过程中现有模型难以在边缘设备上部署,本文基于 YOLOv8n 算法进行轻量化改进,实验结果表明所提方法的有效性:相比于基线模型,改进后的算法在绝缘子缺陷检测任务上的 mAP@0.5 为 93.8%;对于飞络、破损以及自爆绝缘子的小目标缺陷,其平均精度均有明显提升,增强了模型在区分细微缺陷特征方面的能力;浮点运算量和模型大小大幅度降低,实现了更快的检测速度。同时,在面对多种场景考验时,该方法仍能取得良好检测效果,在鲁棒性和普适性上也具有优势,能够满足绝缘子巡检在实际场景中的应用需求。

未来的研究可以提高模型对极端光照、严重污秽及覆冰雪等恶劣情况下的识别率,探索更多的前沿方法来保障电力系统的安全稳定运行。

参考文献:

- [1] 赵振兵,蒋志钢,李延旭,等.输电线路部件视觉缺陷检测综述[J].中国图象图形学报,2021,26(11):2545-2560.
- [2] 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, 2020, 50(4): 1486-1498.
- [3] 李瑞生,张彦龙,翟登辉,等.基于改进 SSD 的输电线路销钉缺陷检测[J].高电压技术,2021,47(11):3795-3802.
- [4] ZHENG J F, WU H, ZHANG H, et al. Insulator-defect detection algorithm based on improved YOLOv7[J].Sensors, 2022, 22(22): 8801.
- [5] ZHANG L, LI B Q, CUI Y, et al. Research on improved YOLOv8 algorithm for insulator defect detection[J/OL].Journal of real-

5G 网络环境下电子信息系统的安全传输机制研究

庄 珊¹ 鹿 璐¹ 刘 洋¹
ZHUANG Shan LU Lu LIU Yang

摘 要

针对 5G 网络边缘计算环境资源受限及数据孤岛带来的安全挑战，文章构建了一个集终端安全代理、边缘安全网关与云端编排中心于一体的纵深防御架构。在边缘侧部署轻量级孤立森林模型对加密流量特征进行提取与推理，实现威胁近源阻断；在云端提出基于检测贡献度感知的自适应联邦聚合算法，通过动态调整节点权重优化全局模型更新策略。同时引入正则化约束机制，解决网络切片场景下数据非独立同分布导致的模型偏差与灾难性遗忘问题。实验结果表明，该机制在保护数据隐私的前提下综合 F_1 分数达到 95.8%，实现云边协同的毫秒级响应与模型持续迭代，为异构网络环境下的电子信息系统安全传输提供兼顾效能与隐私的高效解决方案。

关键词

5G 网络；边缘计算；联邦学习；异常检测；自适应聚合

doi: 10.3969/j.issn.1672-9528.2026.04.019

0 引言

随着 5G 技术在工业互联网及物联网领域的广泛应用，电子信息系统的连接边界急剧扩张，面临着传统集中式防御失效与边缘侧计算资源受限的双重困境。海量异构终端接入导致的网络攻击面扩大，使得基于全流量分析的传统安全手段

难以满足低时延与隐私保护的严苛需求^[1]。针对网络切片场景下数据分布差异显著及未知威胁演进快速的特性，建立一套融合轻量级身份认证、边缘实时检测与云端协同智能的传输机制显得尤为迫切。研究旨在突破传统单点防御局限，利用云边协同架构实现对加密流量特征的深度挖掘与模型自动化迭代，形成感知、分析至响应的安全闭环，对于构建具备自适应能力的内生安全体系具有重要理论意义与实际应用价值。

1. 中电装备山东电子有限公司 山东济南 250109

time image processing,2024[2026-04-10].<https://link.springer.com/article/10.1007/s11554-023-01401-9>.

[6] 周飞,郭杜杜,王洋,等.基于改进YOLOv8的交通监控车辆检测算法[J].计算机工程与应用,2024,60(6):110-120.

[7] 裴少通,张行远,胡晨龙,等.基于ER-YOLO算法的跨环境输电线路缺陷识别方法[J].电工技术学报,2024,39(9):2825-2840.

[8] 王大阜,王静,石宇凯,等.基于深度迁移学习的图像隐私目标检测研究[J].图学学报,2023,44(6):1112-1120.

[9]SUNKARA R, LUO T. No more strided convolutions or pooling: a new CNN building block for low-resolution images and small objects[C]//Machine Learning and Knowledge Discovery in Databases. Berlin: Springer, 2022: 443-459.

[10]LI H L, LI J, WEI H B, et al. Slim-neck by GSConv: A lightweight-design for real-time detector architectures[J/OL]. Journal of real-time image processing,2024[2026-04-10].<https://link.springer.com/article/10.1007/s11554-024-01436-6>.

[11]CHEN J R, KAO S, HE H, et al. Run, don't walk: chasing higher FLOPS for faster neural networks[C]// 2023 IEEE/

CVF Conference on Computer Vision and Pattern Recognition(CVPR). Piscataway: IEEE, 2023: 12021-12031.

[12] 秦伦明,梅温泉,崔昊杨,等.改进YOLOv8s的遥感图像目标检测算法[J].激光与光电子学进展,2025,62(10):317-325.

[13]LIU Y, LIU D C, HUANG X B, et al. Insulator defect detection with deep learning: a survey[J].IET generation, transmission & distribution,2023,17(16):3541-3558.

[14] 赵朗月,吴一全.基于机器视觉的表面缺陷检测方法研究进展[J].仪器仪表学报,2022,43(1):198-219.

【作者简介】

樊计兰（2002—），女，山东临沂人，硕士研究生，研究方向：目标检测。

赵飞燕（1981—），通信作者(email: zfynd@163.com)，女，宁夏固原人，硕士，副教授，研究方向：计算机视觉与图像处理。

（收稿日期：2025-09-11 修回日期：2026-04-15）