

基于改进YOLOv8的输电线路绝缘子缺陷检测

周 思,李俊轩,朱 俊,蔡知寰,邓涛涛

(国网江西省电力有限公司南昌市湾里供电分公司,江西 南昌 330000)

摘 要:为快速准确地检测输电线路绝缘子缺陷,文中基于改进YOLOv8模型,开展对绝缘子缺陷的智能识别检测。首先,根据无人机现场航拍图像构建了输电线路图像数据集2300幅;其次,以YOLOv8作为基础模型,采用可形变卷积AKConv替换模型中的固定卷积,并在特征融合过程中引入坐标注意力(coordinate attention,CA)机制,增强模型对缺陷特征的自适应性及关注度,同时,在模型训练时引入NWD损失函数,提高了模型对缺陷目标的定位精度;最后,利用测试集图像对改进后的模型进行测试。结果表明,改进后模型的mAP可达94.66%,相较于原模型提升了2.83%,将检测结果与SSD、Faster RCNN、YOLOv7等算法模型相比较,验证了所用模型的有效性。

关键词:输电线路;绝缘子缺陷;目标检测;可形变卷积;注意力机制

中图分类号:TM 727 **文献标志码:**A **文章编号:**1006-348X(2025)05-0041-06

0 引言

作为电力传输的重要部件,绝缘子承担着线路的电气绝缘、导线支撑等关键作用,其工作状况对线路的正常运行至关重要^[1]。然而,绝缘子在长期运行过程中,可能因自然环境、机械应力、污染以及温度变化的影响,出现性能退化或损伤,从而影响其正常工作并威胁线路的安全^[2-4]。因此,及时准确地检测绝缘子状态,发现其潜在的缺陷,已成为保障输电线路安全运行的重要任务^[5]。传统的绝缘子检测手段主要依赖人工巡检和定期的物理检查。此类方法在一定程度上能够识别出较为显著的缺陷,但随着电网规模的扩展和线路监测需求的增加,传统手段逐渐暴露出效率低、覆盖范围有限、实时性差等问题,且人工巡检不仅耗时费力,还易受到人为因素的影响,难以确保检测的全面覆盖^[6]。因此,亟需寻求一种高效、精确的自动化检测方法,以满足输电线路绝缘子检测的要求。

随着机器视觉的发展,使用目标检测算法检测耐张线夹、绝缘子等电力设备缺陷,已成为主流手段。如:李俊轩等人针对输电线路耐张线夹压接

图像,构建了一种多尺度(multi-scale,MS)目标检测网络YOLO-MS对压接缺陷进行识别,成功实现了智能化检测,其mAP可达92.57%,模型检测速度为26帧/秒^[7];Chang R等人针对线路中绝缘子的自爆、开裂等缺陷,提出采用一种改进YOLOv7的目标检测算法,其对绝缘子缺陷的检测精度为89.9%^[8];黄新波等人针对玻璃绝缘子在检测过程中相近色干扰的问题,提出将深度学习与灰度化算法相结合,有效提升了对玻璃绝缘子的检测精度,其检测精度可达92%^[9];亢洁等人针对航拍绝缘子目标尺度较大、检测效果不佳的问题,提出采用加权特征金字塔模块对YOLOv7模型进行改进,成功对绝缘子自爆、污损以及破损等缺陷进行检测,其mAP值可达93.9%^[10];李斌等人针对航拍图像中绝缘子缺陷区域像素占比小、尺度差异较大等问题,提出采用反卷积与多分支检测网络构建MSD2Net模型,成功实现了绝缘子缺陷的智能检测^[11]。综上可知,绝缘子各类缺陷可能具有不同的视觉特征,且在微小缺陷的识别上表现不佳,同时,无人机航拍图像中绝缘子缺陷占比较小,拍摄角度不同会导致缺陷目标的变化尺度较大。

为实现快速、准确地检测输电线路绝缘子缺

收稿日期:2024-12-02

作者简介:周思(1991),女,本科,工程师,从事电力视觉研究。

陷,文中提出了一种基于改进YOLOv8的输电线路绝缘子缺陷检测方法。通过某公司无人机拍摄图像与网络公开数据库,构建输电线路绝缘子图像数据集,具体包含“自爆”、“污闪”以及“破损”3类缺陷的绝缘子图像2300幅,并以YOLOv8模型为基础,在缺陷检测时对模型进行优化改进。具体方法如下:1)针对模型在特征提取过程中对输入图像形变不敏感的问题,提出使用可形变卷积AKConv,对输入图像的特征进行自适应调整,增强了模型对绝缘子缺陷特征的提取能力;2)在特征融合过程中,引入坐标注意力(coordinate attention,CA)机制,提升模型对缺陷目标的关注度;3)在模型训练时引入损失函数(normalized wasserstein distance,NWD),提高了模型对缺陷目标的定位精度。该方法可为巡检人员开展绝缘子缺陷的智能检测提供技术参考。

1 基于改进YOLOv8的缺陷检测

1.1 yolov8目标检测网络

YOLOv8^[12]相较于该系列之前的版本,优化了模型的网络架构,并采用自适应多样本匹配,能够更好地处理复杂的图像特征和多样的目标检测任务;同时,采用多堆叠卷积结构C2f模块,优化了特征层通道数,并在减少卷积次数的同时,加快了网络模型的检测速度,可对输入图像直接预测图像中目标的类别

与位置,其模型的网络结构如图1所示。模型由Backbone、Neck以及Head三部分构成。首先,Backbone作为模型对图像特征的提取模块,绝缘子图像输入后先经过Resize操作,将其大小统一为640×640×3,经多个卷积层(Conv)、归一化(batch normalization,BN)以及标准函数(SiLU)后,能够自动从图像中学习并提取出不同层次的特征;其次,Neck作为模型特征融合模块,通过将不同分辨率的特征图融合,确保模型能够同时感知不同尺度大小的目标;最后,Head作为模型对目标分类与定位,能够在图像信息传播过程的同时,得出目标缺陷的定位、置信度以及类别信息。

1.2 模型的优化改进

文中基于YOLOv8目标检测算法,开展对绝缘子缺陷的智能检测。由于无人机航拍图像中绝缘子缺陷占比较小,缺陷目标的变化尺度较大,模型在微小缺陷的识别上表现不佳,因此,采用AKConv、CA注意力机制以及NWD损失函数对模型进行优化改进。

1.2.1 可形变卷积AKConv

普通卷积(标准卷积)在作用时位置固定,只能提取图像当前窗口的局部特征信息,无法有效捕捉图像中其他位置的特征。为了克服这一局限,文中采用可变形卷积AKConv调整模型的采样网格,使得卷积核能够适应图像中物体的形变或不规则结




图1 YOLOv8网络结构图

构,从而提高了网络的灵活性和表现力。同时,AKConv采用一种新的卷积运算方式,通过优化采样策略和减少卷积核参数,在提高模型性能的同时降低了硬件计算的负担,其网络结构如图2所示。首先,AKConv对输入特征层进行初始化采样,用于确定卷积核的初始位置与采样形状;其次,利用卷积操作进行特征提取,在提取过程中为适应目标大小或形状的变化,引入偏移量进行调整;最后,将卷积核在输入特征层中滑动进行特征提取,并将提取结果输入下层网络进一步处理。




图2 AKConv 结构图

1.2.2 CA 注意力机制

CA注意力机制通过将位置信息嵌入到通道注意力,使得网络适应不同位置的图像特征^[13]。首先,对输入的特征层沿着水平坐标与垂直坐标对每个通道进行池化(pooling),分别生成尺寸为 $C \times H \times 1$ 与 $C \times 1 \times W$ 的特征层 z^h, z^w ;然后,对其进行级联运算,并利用 1×1 的卷积进行降维,生成中间特征层 F_i ,具体计算可表示为:

$$F_i = \delta(f^{1 \times 1}([z^h, z^w])) \quad (1)$$

式中: $[z^h, z^w]$ 表示沿着空间维度的级联运算(concatenation operation), δ 为非线性激活函数, $f^{1 \times 1}$ 为卷积运算;沿着空间维度对 F_i 进行分解(spilt),并利用 1×1 卷积进行升维度操作,结合sigmoid函数生成最后的注意力向量 g^h, g^w ,则加入注意力的输出 F_{CA} 可表示为:

$$F_{CA} = F \times g^h \times g^w \quad (2)$$

文中将CA注意力机制引入模型上采样与下采样过程中,从而在特征融合中提升模型对缺陷目标的关注度。

1.2.3 NWD 损失函数

与传统交并比度量模型损失(intersection over union, IoU)不同,NWD主要通过计算两个边界框之

间的高斯分布距离,以此衡量边界框的相似性^[14],并缓解IoU在小目标检测过程中的局限性。文中采用NWD替换原模型中SiLU损失函数,其基本原理如下:首先采用二维高斯分布对模型预测出边界框进行建模,以一组随机边界框为例,假设预测框高斯分布坐标 N_a 为 (x_a, y_a, w_a, h_a) ,对应真实框高斯分布坐标 N_b 为 (x_b, y_b, w_b, h_b) ,此时,引入wasserstein距离衡量边界框的相似度,则 N_a, N_b 二阶wasserstein距离的具体计算方式为:

$$W_2^2(N_a, N_b) = \left\| \begin{bmatrix} cx_a, cy_a, \frac{w_a}{2}, \frac{h_a}{2} \\ cx_b, cy_b, \frac{w_b}{2}, \frac{h_b}{2} \end{bmatrix}^T \right\|_2^2 \quad (3)$$

然而, $W_2^2(N_a, N_b)$ 度量的是距离,不能直接用于衡量相似度,因此,需对其进行归一化处理,具体计算方式为:

$$NWD(N_a, N_b) = e\left(-\frac{\sqrt{W_2^2(N_a, N_b)}}{C}\right) \quad (4)$$

则其损失值可表示为:

$$L_{NWD} = 1 - NWD(N_a, N_b) \quad (5)$$

2 实验结果与分析

2.1 模型的训练与检测

文中开展输电线路绝缘子缺陷检测的实验环境由软件与硬件两部分构成。硬件设施包括处理器 Intel Xeon E5-2678 v3、RTX 3080 Ti 显卡、12G 视频存储器、128G RAM;软件设备使用的是 Windows 10 的操作系统,深度学习框架是 Pytorch 和 Visual Studio Code。基于输电线路无人机航拍巡检,构建了 2300 幅绝缘子图像,其中无缺陷图像 354 幅。“自爆”、“污闪”以及“破损”3 类缺陷图像的数量占比分别为 25.6%、45.8%、28.6%。将图像数据集按 9:1 的比例划分为训练集与测试集,并在训练集中取 10% 作为模型训练过程中的验证集,输入改进的模型后,其训练过程中损失曲线与验证曲线如图 3 所示。由图 3 可知,模型损失值随着模型迭代次数的增加逐渐降低,最终趋于收敛,其中训练损失值降低为 2.917,验证损失值为 3.349。




图3 模型训练损失曲线

训练完成后,加载模型的最优权重,并利用测试集图像对模型进行测试;同时,为验证所用方法的有效性,文中在相同实验环境与参数设置下,将检测结果与SSD、Faster RCNN、YOLOv7等算法模型相比较,其对比结果如表1所示。由表1可知,各类模型对绝缘子3类缺陷的检测性能均在80%以上,其中,“自爆”与“破损”类缺陷的检测精度较高,表明其在图像中的特征较为明显,而“污闪”类缺陷的检测精度相对较低,其平均检测精度的差异主要是由于此类缺陷所引起,通过对检测结果进行分析发现,“污闪”类缺陷的检测受无人机拍摄角度影响较大,光照条件较差、反光等情况下拍摄的图像特征较弱,从而导致此类缺陷产生误检与漏检;同时,文中所提出的改进YOLOv8模型的检测精度最高,其mAP、准确率以及召回率分别可达94.66%、88.95%和96.24%,相较于原YOLOv8模型分别提升了2.83%、0.77%和2.62%,表明模型经改进后,性能的提升主要体现在对漏检率的降低。此外,各模型的检测速度相差较小,但YOLOv8模型经改进后,检测速度略微下降,这是由于所用改进模块的作用方式较为复杂。综上所述,文中所提出的改进YOLOv8模型的综合性能最优。

表1 不同模型的检测结果对比

目标检测模型	AP/%			mAP /%	召回率 /%	准确率 /%	检测速度 (帧/秒)
	自爆	污闪	破损				
SSD	97.34	80.48	87.53	88.45	83.71	92.63	26
Faster RCNN	98.88	82.51	90.39	90.59	85.13	93.68	22
YOLOv7	98.68	84.31	91.88	91.62	85.95	95.16	28
YOLOv8	98.73	86.52	90.24	91.83	86.33	95.47	32
改进YOLOv8	99.12	89.92	94.94	94.66	88.95	96.24	29

以两幅带有缺陷的绝缘子图像为例,分别采用文中所用模型与对比模型进行检测,结果如图4所示。图中不同类别缺陷采用不同颜色的矩形框,数字代表模型对该类缺陷的置信度。由图可知,对比

模型SSD、Faster RCNN以及YOLOv7对绝缘子“污闪”、“破损”类缺陷均产生不同程度的漏检,而原YOLOv8模型相较于其他对比模型漏检数较少,且检测置信度较高,但面对同一图像中的多处缺陷,依然产生了漏检现象。而文中提出的模型经过优化改进后,可一定程度上减少对缺陷的漏检,且检测置信度也高于原模型,表明文中所用方法的有效性。



a) SSD



b) Faster RCNN



c) YOLOv7



d) YOLOv8



e) 改进 YOLOv8

图4 不同模型的检测结果对比


2.2 消融实验

文中基于改进 YOLOv8 模型,开展对输电线路绝缘子缺陷的智能检测,为更好体现所用改进方法的有效性,采用消融实验得出各改进点对模型整体性能的贡献程度,其实验结果如表2所示。由表2可知,组1在原模型加入 AKConv 后,其 mAP 为 93.16%,相较于原模型提升了 1.33%,而检测速度无变化;组2在组1的基础上引入 CA 注意力机制后,其 mAP 为 93.84%,相较于组1提升了 0.68%,但“自爆”与“污闪”类缺陷的检测精度略微降低,“破损”类缺陷的检测精度提升,表明 CA 注意力机制可提升模型对“破损”类缺陷的关注度;此外,组3的检测结果相较于另两组最优,但其检测速度较低,表明 NWD 损失函数在提升模型检测精度的同时引起模型速度的下降。同时,为更好的体现3组消融实验对检测结果的影响,文中采用可视化工具 Grad-CAM^[15]展示模型的决策区域,结果如图4所示,图中颜色越深表明模型对


该区域的关注程度越强。组3的决策区域颜色高于组1与组2,表明了文中所用模型对绝缘子缺陷的检测识别更为有效。

表2 消融实验结果


实验组	所用方法			AP/%			mAP /%	FPS /(帧/秒)
	AKConv	CA 注意力机制	NWD 损失函数	自爆	污闪	破损		
1	√			99.42	88.37	91.69	93.16	32
2	√	√		99.26	88.16	94.11	93.84	32
3	√	√	√	99.12	89.92	94.94	94.66	29



a) 组1



b) 组2



c) 组3

图5 决策区域可视化

此外,文中结合消融实验与模型检测结果进行分析发现,组1、组2和组3在对模型进行改进后,可一定程度减少对缺陷的漏检,但“污闪”类缺陷的漏检率仍然较高,这是由于污闪的发生通常波及的绝缘子区域较大,同一绝缘子缺陷面积较为分散,模型通过矩形框对其进行检测定位时,受模型计算漏检率方

式的影响,导致漏检率数值较高。

3 结语

为快速、准确地检测输电线路绝缘子缺陷,文中提出了一种基于改进YOLOv8的输电线路绝缘子缺陷检测方法。首先,构建了包含“自爆”、“污闪”和“破损”3类输电线路绝缘子缺陷图像2300幅;其次,针对无人机航拍图像中绝缘子缺陷占比小、图像尺寸变化大,以及模型在特征提取过程中,对输入图像形变不敏感的问题,提出引入可形变卷积AKConv、CA注意力机制以及NWD损失函数,对YOLOv8模型进行改进,其mAP可达94.66%,相较于原模型提升了2.83%。同时,通过消融实验,验证所用改进方法的有效性,并分析了模型漏检率较高的原因;最后,将文中所用模型的检测结果与SSD、Faster RCNN、YOLOv7以及YOLOv8相比较,其综合性能最优。该方法可为巡检人员开展绝缘子缺陷的智能检测提供技术参考。

参考文献:

[1] 邱志斌,阮江军,黄道春,等.输电线路悬式瓷绝缘子老化形式分析与试验研究[J].高电压技术,2016,42(04):1259-1267.

[2] QI Y-F, LI Y-M, DU A-Y, et al. Research on an insulator defect detection based on improved YOLOv5[J]. Applied Sciences, 2023, 13(09): 5741-5755.

[3] 王思,熊惠敏,胡蕾,等.基于改进YOLOv7的输电线路绝缘子设备及其缺陷检测算法[J].江西电力,2024,48(01):1-6,20.

[4] 高伟,周宸,郭谋发.基于改进YOLOv4及SR-GAN的绝缘子缺陷辨识研究[J].电机与控制学报,2021,25(11):93-104.

[5] 任欢,苏涛,李朋,等.基于改进CenterNet的输电线路绝缘子缺陷

检测方法[J/OL].南方电网技术,1-11[2024-11-22].<http://kns.cnki.net/kcms/detail/44.1643.tk.20241111.1354.002.html>.

[6] 徐滔.基于深度卷积神经网络的航拍绝缘子目标检测方法研究[D].成都:西南交通大学,2023.

[7] 李俊轩,邱志斌,石大寨,等.基于X-DR图像与YOLO-MS模型的输电线路耐张线夹压接缺陷检测[J/OL].南方电网技术,1-10[2024-09-04].<http://kns.cnki.net/kcms/detail/44.1643.TK.20240424.1456.004.html>.

[8] CHANG R, ZHOU S, ZHANG Y, et al. Research on insulator defect detection based on improved YOLOv7 and multi-UAV cooperative system[J]. Coatings, 2023, 13(05): 880-897.

[9] 黄新波,高玉菡,张烨,等.基于联合分量灰度化算法和深度学习的玻璃绝缘子目标识别算法[J].电力自动化设备,2022,42(04):203-209.

[10] 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(08):3361-3376.

[11] 李斌,屈璐瑶,朱新山,等.基于多尺度特征融合的绝缘子缺陷检测[J].电工技术学报,2023,38(01):60-70.

[12] REIS D, KUPEC J, HONG J, et al. Real-time flying object detection with YOLOv8[EB/OL]. [2023-12-13]. <http://arxiv.org/abs/2305.09972>.

[13] Q Hou, D Zhou, and J Feng, "Coordinate attention for efficient mobile network design," in 2021 IEEE/CVF Conf. Comput. Visi. Pattern Recognit (CVPR). Nashville, TN, USA, 2021, pp.13713-13722.

[14] Wang J, Xu C, Yang W, et al. A normalized gaussian wasserstein distance for tiny object detection. arXiv 2021[J]. arXiv preprint arXiv: 2110.13389.

[15] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization[C]//2017 IEEE International Conference on Computer Vision (ICCV). Venice, Italy: IEEE, 2017: 618-626.