

基于改进 YOLOv8 算法的 10 kV 配电线路导线裸露检测

荆启文, 郝思鹏, 李思源

(南京工程学院电力工程学院, 江苏 南京 211167)

摘要: 10 kV 配电线路导线裸露是造成配电网线路运行故障的重要诱因之一, 严重威胁配电网的安全稳定运行。传统人工运维巡视手段往往无法及时发现该类缺陷。针对此问题, 文中提出一种基于改进 YOLOv8 算法的 10 kV 配电线路导线裸露的检测方法, 用以辅助电网运维人员快速高效检测导线裸露缺陷。该算法在主干网络利用全维动态卷积代替原始卷积, 通过多维度特征提取增强对导线裸露的特征捕捉能力; 在颈部网络中, 将注意力嵌入模块与原网络中的跨阶段特征融合模块相结合, 加强高层特征与低层特征之间的联系, 从而更好地分析导线裸露的整体形状和局部细节信息; 在损失函数上, 选用距离交并比和归一化瓦塞尔斯坦距离相结合的方法, 提高无人机拍摄的巡检照片中导线裸露目标的关注度。实验结果表明, 改进算法相较原始算法在准确率、召回率和平均精度上分别提升了 4.8 个百分点、4.2 个百分点、5.2 个百分点, 有效提升了配电网导线裸露的检测能力, 为电力系统的安全稳定运行提供了新的技术手段。

关键词: 10 kV 配电线路; 导线裸露; YOLOv8; 多维度特征提取; 图像特征信息处理; 目标检测优化

中图分类号: TM754

文献标志码: A

文章编号: 2096-3203(2025)03-0201-10

0 引言

10 kV 配电线路是电力系统中重要的输电线路之一^[1-3], 承担着电能输送和分配至用户的关键任务。随着我国经济社会的持续发展, 用户用电需求量不断增长, 10 kV 线路的里程也相应增加。线路长时间运行在外部环境下, 难免会老化、性能劣化甚至绝缘损坏, 导致导线裸露。以华东某地电网为例, 2023 年因导线裸露引起的鸟害、漂浮异物、树碰线导致的单相接地、相间短路等跳闸事件, 占配电网年故障总量的 16.54%, 这其中既包含自然因素, 也涉及非自然因素, 因此需要定期对 10 kV 配电线路进行综合巡视及检测。受限于 10 kV 配电线路数量多、分布广等特点, 传统人工运维巡视存在工作量大、周期长问题, 叠加班组人员老龄化趋势严重等问题, 导致配电网巡视人员承载力愈发不足。近年来配电网通过引入无人机巡视方式提升工作效率, 以“机械化替代”部分缓解了人员承载力问题, 但仍存在无人机巡视图片拍摄完毕后, 需要大量后台人员进行图片缺陷识别的问题, 且部分导线类裸露缺陷在图片中占比较小, 较难通过人眼直观发现, 且往往耗费大量人工。因此, 亟须研究一种用于无人机图片缺陷识别的高效算法, 用以提升缺陷检出率, 进一步保障电力系统安全稳定运行。

主流的目标检测类缺陷识别算法分为两类, 一

类是单阶段目标检测算法, 另一类是双阶段目标检测算法。单阶段算法是直接图像上进行定位, 只需一次前向传播就可以完成目标检测, 其优点在于更快地检测速度、较低的计算复杂度和内存的占用, 而缺点是精确度会有所降低, 代表算法有 SSD^[4-5]、YOLO 系列(YOLOv3、YOLOv5、YOLOv6、YOLOv7、YOLOv8)^[6-8]、EfficientDet^[9]。双阶段算法则需要进行 2 个步骤: 第一步是产生许多的候选区域; 第二步是通过算法对候选区域进行精准分类和定位, 代表算法有区域卷积神经网络(region-based convolutional neural network, R-CNN)^[10]、快速区域卷积神经网络(faster region-based convolutional neural network, Faster R-CNN)^[11-12]。双阶段算法的优点在于识别准确高、处理能力强, 但随之而来的缺点是处理速度慢、计算复杂度高。

目前, 随着深度学习算法的不断发展, 电力行业已将其广泛应用于各类研究中。YOLO 作为一种实时目标检测算法, 能够在低延迟的情况下处理大量数据, 与电力行业适配度较高, 因此受到广泛应用与研究。文献[13]基于 YOLOv3 算法, 通过优化损失函数、提升文本识别的校正及人工合成文本等方式, 显著提升了电力设备铭牌文本识别的效率; 文献[14]在 YOLOv5 算法中引入压缩-激励(squeeze and excitation, SE)注意力机制, 采用高效交并比(efficient intersection over union, EIOU)损失函数替代原有方法, 用全局多卷积(kiltglobal, KG)模块平衡特征金字塔结构, 有效解决了光伏组件红外热成像缺陷检测中特征提取困难、实时性差及检

测精度较低等问题;文献[15]基于改进YOLOv6算法对输电线路异物等缺陷进行检测,使线路异物缺陷的平均检测精度提高12.9%;文献[16]基于改进YOLOv7算法进行输电线路异物检测,使输电线路异物的平均检测精度提高3.34%;文献[17]通过改进YOLOv7算法有效解决了绝缘子检测与定位问题,使绝缘子的平均检测精度提高4.88%。上述研究对YOLO算法在电力设备缺陷检测方面进行一定的探索,提升了算法性能,一定程度上解决了电力巡检中缺陷难以实时识别的难题,但是对于人眼难以识别的隐蔽性缺陷,如导线裸露等,算法识别性能还有待提升。

基于此,文中在YOLOv8算法的基础上,开展配电线路裸露缺陷识别率提升研究:(1)针对传统卷积(Conv)特征提取效率低下的问题,引入全维动态卷积(omni-dimensional dynamic convolution, ODCnv),增强对检测目标信息的提取能力,提高特征融合效率与小尺寸目标的检测性能;(2)针对配电线路复杂场景中小目标导线裸露特征提取难度大的问题,提出一种注意力嵌入模块(attention embedding module, AEM)与跨阶段特征融合(cross stage feature fusion, C2f)模块相结合的改进方法,通过增强算法低层特征的表达能力,提升模型对小目标的检测效果;(3)针对YOLOv8的损失函数对图像目标框的位置偏差及尺度变化较为敏感,导致对裸导线目标拟合效果有限的问题,通过将距离交并比(distance intersection over union, DIoU)损失函数与归一化瓦塞尔斯坦距离(normalized Wasserstein distance, NWD)损失函数相结合,提升算法对于小目标的收敛性能。实验结果表明,该方法可以提高对导线裸露的检测能力,有助于电力系统的安全稳定运行。

1 YOLOv8 算法概述

YOLOv8算法因其简化的网络结构、显著的性能提升以及出色的部署灵活性而广受青睐^[18]。与传统的锚框方法相比,YOLOv8算法采用无锚框检测技术,通过关键点回归直接预测目标边界框,这一改进不仅降低对预设锚框超参数的依赖,还大幅减少预测框数量,从而提升非极大值抑制的效率^[19],加快模型推理速度。YOLOv8算法系列提供5种不同规模的模型(YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l、YOLOv8x),其中YOLOv8n算法参数量最少,推理速度最快,而YOLOv8x算法则具有最大的参数量和最高的识别精度。对于10 kV配电线路

上导线裸露这一实时性要求较高的任务,YOLOv8n算法成为最优选择。

YOLOv8算法网络架构由4个核心模块构成:输入端、主干网络、颈部网络和头部网络。

主干网络由Conv模块、C2f模块和空间金字塔池化与特征融合模块构成。其中,Conv模块由二维Conv层、批量归一化层和Sigmoid线性单元函数组成;C2f模块由2个Conv模块、瓶颈层和拼接层组成,并借鉴高效层聚合网络模块^[20]的设计思想;空间金字塔池化与特征融合模块由2个Conv模块、最大池化层和拼接层组成。

颈部网络采用路径聚合特征金字塔网络,增强模型对不同尺寸目标的检测能力。

头部网络采用创新性地解耦设计,将检测任务分为两个部分:一部分专注于边界框回归,用于边界框的精确预测;另一部分则专注于目标分类,负责目标类别的准确预测。这种设计不仅能提高模型的检测效率,还能提升其在复杂场景下的适应性和准确性。YOLOv8算法网络结构如图1所示。




图1 YOLOv8 算法网络结构
Fig.1 YOLOv8 algorithm network structure

2 YOLOv8 算法改进

由于YOLOv8算法对于小目标的检测效果不

佳, 所以文中针对此问题对 YOLOv8 算法进行改进。在骨干网络中, 选用 ODConv 代替 Conv, 增强对检测目标特征的提取能力; 在 C2f 模块中, 引入 AEM, 将高层特征注意力嵌入低层特征中, 从而增强低层特征的表达能力; 在损失函数中, 采用 DIOU 损失函数和 NWD 函数相结合替代综合交并比损失函数, 并通过引入专门针对小目标的加权参数, 来提高模型对小目标的关注度和检测能力。改进的 YOLOv8 算法网络结构如图 2 所示。




图 2 改进的 YOLOv8 算法网络结构
Fig.2 Improved YOLOv8 algorithm network structure

2.1 ODConv

由于导线裸露部分在不同距离拍摄的图像中呈现不同的尺寸, 传统的 Conv 操作在特征提取方面存在效率低下甚至遗漏关键信息的问题。为了克服这一挑战, 文中在主干网络中引入 ODConv^[21] 以替代传统的 Conv 操作, 从而增强对检测目标信息的提取能力。ODConv 的核心优势在于其能够同时在 4 个维度(空间维度、输入通道维度、输出通道维度和 Conv 核维度)上并行处理, 并对各维度的特征进行动态加权和融合。如图 3 所示, 4 个维度的特征权重矩阵分别为 α_{si} 、 α_{ci} 、 α_{fi} 、 α_{wi} , 其中 $i=1, 2, \dots, n$, n 为变量个数, 每个维度的特征通过相应

的权重进行逐元素相乘, 实现了特征的深度融合。这种多维度的加权机制不仅提高特征融合的效率, 而且有助于捕捉到更加精细的目标信息, 从而提升小尺寸目标的检测性能, 如式(1)所示。

$$y = x \sum_{i=1}^n (W_i \odot \alpha_{si} \odot \alpha_{ci} \odot \alpha_{fi} \odot \alpha_{wi}) \quad (1)$$

式中: y 为输出特征; x 为输入特征; W_i 为权重矩阵; $\alpha_{wi} \in \mathbf{R}$ 、 $\alpha_{si} \in \mathbf{R}^{k \times k}$ 、 $\alpha_{ci} \in \mathbf{R}^{c_{in}}$ 、 $\alpha_{fi} \in \mathbf{R}^{c_{out}}$ 分别为卷积核、空间维度、输入通道维度和输出通道维度的注意力权重, 其中 $\mathbf{R}$ 为实数集, $k \times k$ 为滤波器的大小, c_{in} 、 c_{out} 分别为输入、输出通道数; $\odot$ 为核空间不同维度的乘法运算。




图 3 ODConv 结构
Fig.3 ODConv structure

4 种维度的加权过程如图 4 所示。图 4(a)为 ODConv 在空间维度上利用权重 α_{si} 与尺寸为 $k \times k \times c_{in}$ 的 Conv 核进行逐元素乘法, 在空间中更好地获取导线裸露的位置分布; 图 4(b)为 ODConv 在输入通道维度上利用权重 α_{ci} 与对应通道的 Conv 核进行逐元素乘法, 更好地获取导线裸露的颜色或纹理; 图 4(c)为 ODConv 在输出通道维度上利用权重 α_{fi} 对输出通道的 Conv 滤波器赋予新的权重, 更好地对导线裸露特征进行采集; 图 4(d)为 ODConv 在 Conv 核维度上用权重 α_{wi} 对 Conv 核赋予新的权重, 更好地捕捉图像的全局特征。

通过采用 ODConv 对导线裸露的特征进行提取, 文中模型能够更有效地利用不同通道中提取的特征, 进而在一定程度上提高模型对导线裸露的检测精度。

2.2 AEM

在传统的卷积神经网络(convolutional neural network, CNN)中, 尽管通过多层 Conv 操作能够提取不同层次的特征, 但在配电线路这类复杂场景中, 导线裸露部分作为小目标在图像中的特征提取难度较大, 导致每次 Conv 操作提取的特征差异显著, 难以有效利用高层特征中的语义信息和全局上




图4 4种维度的加权过程

Fig.4 Four dimensions of weighting processes

下文信息,以及低层特征中的细节和位置信息。为此,文中引入了C2f-AEM^[22]方法。该方法旨在通过处理高层特征并将其与低层特征相结合,从而增强低层特征的表达能力,提升模型对小目标的检测效果。

AEM的工作流程如下:首先,将高层特征图分割成多个小块,并进行平均池化处理,在降低特征的空间维度同时保留局部特征;接着,对池化后的特征图施加2次1×1的卷积操作,优化特征图的通道数;之后,将特征图通过Sigmoid函数转换为[0, 1]内的权重系数;然后,对特征图进行上采样处理,使其尺寸或分辨率与低层特征相匹配,并与低层特征进行逐元素相乘,以增强两者共有的特征;最后,将增强后的特征与原始低层特征进行逐元素相加,实现进一步的特征增强。通过此流程,AEM能够获得融合了高层和低层特征的增强特征图,从而更有效地检测小目标,进而提升模型的整体性能。图5为AEM结构图。

2.3 损失函数优化

YOLOv8算法默认采用完全交并比(complete intersection over union, CIOU)^[23]损失函数,其在DIOU^[24]损失函数的基础上增加了预测框和真实框




图5 AEM结构

Fig.5 AEM structure

的宽度与高度的比值差异问题。CIOU损失函数对目标框的位置偏差和尺度变化较为敏感,而裸导线巡检图像存在缺陷本身尺寸较小、拍摄距离不同导致目标尺寸差异较大、人工标注的导线细微裸露存在宽高比误差等问题,这些问题导致CIOU损失函数对裸导线目标的拟合效果有限。针对上述问题,文中对损失函数进行改进,用DIOU损失函数替换CIOU损失函数,并在此基础上引入了NWD函数^[25]。该函数对目标框的尺度变化不敏感,并且对位置偏差的变化更加平滑。为了进一步提高对小目标的关注度,文中引入了目标尺寸系数,使模型在收敛过程中能够更倾向于小目标,一定程度上解决模型对小目标收敛较差的问题,以下称改进后的方法为DIOU-NWD函数。经过优化的损失函数、尺寸系数表达式如式(2)、式(3)所示。

$$L_{\text{DIOU-NWD}} = \alpha [\lambda L_{\text{DIOU}} + (1 - \lambda) L_{\text{NWD}}] \quad (2)$$

$$\alpha = \sqrt{\lg \frac{1}{wh}} \quad (3)$$

式中: $L_{\text{DIOU-NWD}}$ 为DIOU-NWD损失函数; L_{DIOU} 为DIOU损失函数; L_{NWD} 为NWD损失函数; w 、 h 分别为预测框经过归一化处理后的宽度和高度; α 为考虑宽度和高度的系数; λ 为权重因子。

DIOU损失函数考虑了预测框和真实框的交并比 I 以及中心点距离问题,如下:

$$L_{\text{DIOU}} = 1 - I + \frac{\rho^2(a, b)}{d^2} \quad (4)$$

$$I = \frac{A_{\text{pred}} \cap A_{\text{gt}}}{A_{\text{pred}} \cup A_{\text{gt}}} \quad (5)$$

$$\rho(a, a^{\text{gt}}) = \sqrt{(x_c^{\text{gt}} - x_c)^2 + (y_c^{\text{gt}} - y_c)^2} \quad (6)$$

$$d = \sqrt{(w^{\text{gt}} + w)^2 + (h^{\text{gt}} + h)^2} \quad (7)$$

式中: A_{pred} 、 A_{gt} 分别为预测框和真实框的位置; $\rho(a, b)$ 为预测框中心 a 与真实框中心 b 的欧几里得距离; d 为预测框和真实框外接矩形的对角线长度之和; (x_c, y_c) 、 $(x_c^{\text{gt}}, y_c^{\text{gt}})$ 分别为 a 和 b 的归一化坐标; w^{gt} 、 h^{gt} 分别为真实框经过归一化的宽度和高度。

与交并比不同,NWD函数对于边界框的尺度

变化不敏感,并且对位置偏差的响应更加平滑,其提供了更好的区分度,更适用于小目标检测。首先,高斯分布 N_a 和 N_b 由边界框 $A=(c_{x_a}, c_{y_a}, w'_a, h'_a)$ 和 $B=(c_{x_b}, c_{y_b}, w'_b, h'_b)$ 建模得到; (c_{x_a}, c_{y_a}) 、 (c_{x_b}, c_{y_b}) 分别为中心点 a 、 b 的像素坐标, w'_a 、 h'_a 和 w'_b 、 h'_b 分别为 a 、 b 以像素为单位的宽度和高度;然后,通过瓦塞尔斯坦距离计算边界框之间的相似性;最后,进行归一化处理。如下:

$$L_{\text{NWD}} = 1 - N(N_a, N_b) \quad (8)$$

$$N(N_a, N_b) = e^{-\sqrt{W_2^2(N_a, N_b)}/C} \quad (9)$$

$$W_2^2(N_a, N_b) = \left\| \left(\begin{bmatrix} c_{x_a} & c_{y_a} & \frac{w'_a}{2} & \frac{h'_a}{2} \end{bmatrix}^T, \begin{bmatrix} c_{x_b} & c_{y_b} & \frac{w'_b}{2} & \frac{h'_b}{2} \end{bmatrix}^T \right) \right\|_2^2 \quad (10)$$

式中: $W_2^2(N_a, N_b)$ 为二阶瓦塞尔斯坦距离的平方; $N(N_a, N_b)$ 为 NWD; C 为将瓦塞尔斯坦距离作归一化处理的常数。

3 实验验证

3.1 实验数据集

文中实验采用的数据集包含配电线路导线在不同位置出现裸露的图片。所有图片均通过无人机在配电线路的不同角度、距离对裸露导线进行拍摄,共计 1 200 张。为了提高模型的训练效果和检测能力,采用随机旋转、平移等方法对数据集进行增强,共获得 3 623 张,将这些数据按照 8:1:1 的比例划分为训练集(2 899 张)、验证集(362 张)和测试集(362 张),并使用 Labelimg 工具对导线裸露区域进行标注。图 6 为部分场景下导线裸露的图片。



图 6 导线裸露示例

Fig.6 Example of exposed conductors

3.2 实验环境及参数配置

文中的实验环境是在深度学习 Pytorch 2.4.1 框架上进行搭建,操作系统为 Linux 18.04,图形处理器为 NVIDIA GeForce 4090,并使用 CUDA 12.1 对图片进行加速处理。训练参数如表 1 所示。

表 1 训练参数设置
Table 1 Setting of training parameters

参数	数值
训练轮次	300
批量大小	32
图像尺寸	640×640
迭代优化器	SGD

3.3 评价指标

实验采用准确率 P 、召回率 R 、平均精度均值 m 、参数量和浮点数评估模型的性能。 P 、 R 和 m 的计算如下:

$$P = \frac{T_p}{T_p + F_p} \quad (11)$$

$$R = \frac{T_p}{T_p + F_N} \quad (12)$$

$$m = \frac{\sum_{j=1}^N \int_0^1 P_j R_j dR_j}{N} \quad (13)$$

式中: T_p 为检测到正确的样本数; F_p 为检测到错误的样本数; F_N 为未检测出的样本数; P_j 、 R_j 分别为第 j 个检测类别的准确率和召回率,可根据对应类别的准确率-召回率(precision-recall, PR)曲线获得; N 为目标类别的数量。由于实验仅针对单一检测目标,即二分类,因此平均精度均值等于平均精度。

此外,模型的参数量反映其对于计算资源的需求,而浮点数则反映模型的计算复杂度。

3.4 模块对比实验

3.4.1 Conv 对比实验

为验证 Conv 改进的效果,选取不同 Conv 结构进行对比,将 P 、 R 和 m 作为评价指标,结果如表 2 所示。

表 2 Conv 对比实验
Table 2 Comparison of Conv experiment

模块	$P/\%$	$R/\%$	$m/\%$
Conv	83.7	68.2	76.0
双Conv核 ^[26]	87.2	65.7	77.1
幻影Conv	84.7	67.1	76.5
深度可分离Conv ^[27]	86.6	65.8	74.7
ODConv	87.6	68.3	78.1

由表 2 数据可知,除深度可分离 Conv 外,其他

几组 Conv 的平均精度均值 m 均有所提升; ODConv 在保持召回率 R 的情况下, 对比其余几组 Conv 有着更好的表现。说明通过多维度提取导线裸露特征, 能够增强模型对缺陷特征的学习能力, 从而有效提升缺陷识别能力。

3.4.2 注意力机制对比实验

为验证注意力机制与 C2f 模块结合的效果, 选取不同的注意力机制与 C2f 模块相结合, 将 P 、 R 和 m 作为评价指标, 结果如表 3 所示。

表 3 注意力机制对比实验
Table 3 Comparison of attentional mechanisms experiments

模块	$P/\%$	$R/\%$	$m/\%$
C2f	83.7	68.2	76.0
C2f-SE	82.0	69.4	76.8
C2f-高效多尺度注意力 ^[28]	85.1	68.9	77.1
C2f-简单注意力 ^[29]	83.0	65.5	74.9
C2f-AEM	84.7	69.5	77.9

由表 3 数据可知, 文中选用的 C2f-AEM 在平均精度均值 m 上优于其他对比方法, 并且在准确率 P 和召回率 R 的表现上较为均衡。结果表明, 文中所采用的 C2f-AEM 的改进策略更为综合有效。

3.4.3 损失函数对比实验

为验证优化损失函数的效果, 选取不同的损失函数进行对比, 将 P 、 R 和 m 作为评价指标, 结果如表 4 所示。

表 4 损失函数对比实验
Table 4 Comparison of loss function experiments

损失函数	$P/\%$	$R/\%$	$m/\%$
CIoU	83.7	68.2	76.0
DIoU	83.8	66.4	75.8
EIoU	85.6	68.9	78.4
广义交并比	85.1	66.9	77.0
DIoU-NWD	85.0	71.0	79.8

由表 4 数据可知, 文中所选用的 DIoU-NWD 函数在召回率 R 和平均精度均值 m 上相较于其余损失函数有着显著的提升, 综合表现更好。这一结果验证了 DIoU-NWD 函数在小目标检测任务中的有效性。

3.5 消融实验

针对 10 kV 配电线路导线裸露检测问题, 文中提出了面对小目标检测的改进方法。为了验证各改进模块对网络性能的提升, 文中开展了消融实验, 实验结果如表 5 所示。

表 5 消融实验
Table 5 Ablation experiments

组别	ODConv	C2f-AEM	DIoU-NWD	$P/\%$
1	×	×	×	83.7
2	√	×	×	87.6
3	√	√	×	86.2
4	√	√	√	88.5

组别	$R/\%$	$m/\%$	参数量/ 10^6	浮点数
1	68.2	76.0	3.01	8.2
2	68.3	78.1	3.03	7.3
3	70.3	79.2	2.64	6.6
4	72.4	81.2	2.64	6.6

表 5 中, 第 1 组为原始 YOLOv8n 算法的图片检测实验结果; 第 2 组使用 ODConv 替代部分传统 Conv, 在参数量仅小幅增加的情况下, 平均精度均值 m 提高了 2.1 个百分点, 这表明 ODConv 通过多通道特征提取的方式, 能有效提高模型对特征的捕获和训练能力; 第 3 组在第 2 组的基础上引入 C2f-AEM, 不仅召回率 R 和平均精度均值 m 进一步提升, 同时实现参数量和浮点数的双重降低。C2f-AEM 通过融合高层语义特征与低层语义特征, 在保留目标细微特征的同时整合全局上下文信息, 显著改善模型对小尺寸导线裸露目标的检测能力, 提高模型的综合表现; 第 4 组, 也是文中所选用的改进方法, 在准确率 P 、召回率 R 和平均精度均值 m 上都有提升, 说明该损失函数对于目标的尺度变化不敏感, 对于较小目标的检测更加友好, 使得模型的性能得到提升。将最终改进算法(第 4 组)和原始算法(第 1 组)进行比较, 准确率 P 、召回率 R 和平均精度均值 m 分别提升了 4.8 个百分点、4.2 个百分点和 5.2 个百分点。

图 7 为 4 组消融实验训练 300 轮次的准确率 P 、召回率 R 、平均精度均值 m 的对比。图 7(a)中, 第 4 组准确率 P 在 230 轮后达到一个相对稳定的水准, 并且高于其余 3 组; 图 7(b)中, 第 4 组的召回率 R 在 150 轮后高于同一轮次的其余 3 组; 图 7(c)中, 虽然 4 组的收敛速度都很快, 但在经历波动趋于稳定后, 第 4 组的平均精度均值 m 要高于其他 3 组, 直至训练完毕。

3.6 整体对比实验

为了进一步验证改进算法后的模型有效性, 将第 2 章 3 种改进模块融合为 1 个算法模型(以下简称为 YOLOv8-Ours)验证其性能, 文中将其与目前常用的目标检测方法进行对比, 实验数据的对比情况如表 6 所示。




图 7 4 组消融实验的对比

Fig.7 Comparison of four ablation experimental groups

表 6 不同方法对比实验

Table 6 Comparison experiment of different methods

方法	$m/\%$	参数量/ 10^6	浮点数
Faster R-CNN	51.5	136.70	369.8
YOLOv5n	75.9	2.51	7.2
YOLOv6	72.0	4.24	11.9
YOLOv7	70.8	9.08	26.5
YOLOv8n	76.0	3.01	8.2
YOLOv8n-Ours	81.2	2.64	6.6

从实验结果可知,文中检测方法 与双阶段检测方法 Faster R-CNN 相比,平均精度均值 m 提高、模型参数量和浮点数降低;与 YOLOv6、YOLOv7 相比,平均精度均值 m 分别提高 9.2 个百分点、10.4 个百分点;与 YOLOv5n 相比,虽然参数量略

高,但是平均精度均值 m 提高 5.3 个百分点、浮点数降低 8.3%。综上,改进算法后的模型的检测性能更加全面、综合。

3.7 实验结果可视化分析

为直观展示 YOLOv8n-Ours 和 YOLOv8n 的检测效果,文中对测试集进行验证,部分验证结果如图 8—图 12 所示。图中 dx1 为裸露导线的简写,数字表示相应算法认定该位置为裸露导线的置信度值。




图 8 直线杆可视化结果

Fig.8 The visualization result of the straight line pole






图 9 转角杆可视化结果

Fig.9 The visualization result of the corner pole




(a) YOLOv8n




(b) YOLOv8n-Ours

图 10 终端杆可视化结果

Fig.10 The visualization result of the terminal pole



(a) YOLOv8n



(b) YOLOv8n-Ours

图 12 中低压共杆可视化结果

Fig.12 The visualization result of the medium-low voltage shared pole



(a) YOLOv8n



(b) YOLOv8n-Ours

图 11 架空导线可视化结果

Fig.11 The visualization result of the overhead conductor

由实验结果可知,在不同的场景下,改进算法后的模型检测效果有所提升。当导线裸露较为明显时,2种模型都能检测到目标,但改进后的模型能在精度上有所提高。当存在背景干扰或导线裸露以小目标的形式出现时,原始模型的检测会存在丢失导线裸露目标的情况,而改进后的模型则可以有效召回目标。结果表明,相较于原始模型,改进后的模型在配电线路场景下对于导线裸露的检测能力得到提升。

4 结论

10 kV 配电线路普遍存在金属导线裸露的问题,而在无人机拍摄的图像中,导线裸露目标常因背景干扰或目标尺寸小等因素影响检测效果。基于此,文中提出一种改进 YOLOv8 的导线裸露检测算法。

该算法主要包含以下 3 点改进:

(1) 该算法采用 ODConv 代替部分 Conv,通过多维度的方式加强对特征的提取。

(2) 引入 AEM,并与 C2f 相结合,形成 C2f-AEM 机制增强高层特征和低层特征间的信息交互,使低层特征能获得更多导线裸露的细节,从而提高对小目标裸露导线的全局和局部特征感知。

(3) 将 DIOU 损失函数与 NWD 函数相结合,形成 DIOU-NWD 损失函数的方式,取代 CIOU 损失函数。利用 NWD 函数对于目标尺度变化不敏感的特点,结合 DIOU 损失函数的边界框回归优势,并通过引入目标尺寸权重,提高模型对小目标导线裸露的关注度和检测灵敏度。

综上所述,相较原始算法,改进后算法的准确率、召回率和平均精度分别提升了 4.8 个百分点、4.2 个百分点和 5.2 个百分点,可以更好地辅助运维人员识别 10 kV 配电线路导线裸露缺陷,保障电力系统的安全稳定运行。

参考文献:

[1] 杨森,陈天翔,邵千秋,等. 10 kV 配电线路单相树线故障选相

- 研究[J]. 电力系统保护与控制, 2024, 52(18): 169-178.
- YANG Sen, CHEN Tianxiang, SHAO Qianqiu, et al. Fault phase selection of a single-phase tree-line in a 10 kV distribution line[J]. *Power System Protection and Control*, 2024, 52(18): 169-178.
- [2] 裴东锋, 刘勇, 闫柯柯, 等. 一种基于 CNN 与 FFT-ELM 的输电线路故障识别与定位方法[J]. 电力科学与技术学报, 2024, 39(1): 164-170.
- PEI Dongfeng, LIU Yong, YAN Keke, et al. A method based on CNN and FFT-ELM for fault identification and location of transmission lines[J]. *Journal of Electric Power Science and Technology*, 2024, 39(1): 164-170.
- [3] 裴少通, 张善驰. 基于改进 YOLOv5s 的架空输电线路鸟类入侵检测方法[J]. 智慧电力, 2023, 51(6): 100-105.
- PEI Shaotong, ZHANG Shanchi. Bird invasion detection method for overhead transmission lines based on improved YOLOv5s[J]. *Smart Power*, 2023, 51(6): 100-105.
- [4] 王道累, 李明山, 姚勇, 等. 改进 SSD 的光伏组件热斑缺陷检测方法[J]. 太阳能学报, 2023, 44(4): 420-425.
- WANG Daolei, LI Mingshan, YAO Yong, et al. Method of hotspot detection of photovoltaic panels modules on improved SSD[J]. *Acta Energaie Solaris Sinica*, 2023, 44(4): 420-425.
- [5] LIU S, WANG D, WANG Q, et al. NIV-SSD: Neighbor IoU-voting single-stage object detector from point cloud[J]. *Neuro-computing*, 2024, 597: 127987.
- [6] 陈杰, 安之焕, 唐占元, 等. 基于改进 YOLOv4 模型的无人机巡检图像杆塔缺陷检测方法研究[J]. 电测与仪表, 2023, 60(10): 155-160.
- CHEN Jie, AN Zhihuan, TANG Zhanyuan, et al. Research on tower defect detection method of UAV patrol inspection image based on improved YOLOv4 model[J]. *Electrical Measurement & Instrumentation*, 2023, 60(10): 155-160.
- [7] 张焕龙, 齐企业, 张杰, 等. 基于改进 YOLOv5 的输电线路鸟巢检测方法研究[J]. 电力系统保护与控制, 2023, 51(2): 151-159.
- ZHANG Huanlong, QI Qiye, ZHANG Jie, et al. Bird nest detection method for transmission lines based on improved YOLOv5[J]. *Power System Protection and Control*, 2023, 51(2): 151-159.
- [8] 卢志博, 徐澄宇, 杨罡, 等. 基于改进 YOLOv3 的输电线路部件实时检测[J]. 电测与仪表, 2023, 60(7): 138-144.
- LU Zhibo, XU Chengyu, YANG Gang, et al. Real-time detection of transmission line components based on improved YOLOv3[J]. *Electrical Measurement & Instrumentation*, 2023, 60(7): 138-144.
- [9] 宋立业, 刘帅, 王凯, 等. 基于改进 EfficientDet 的电网元件及缺陷识别方法[J]. 电工技术学报, 2022, 37(9): 2241-2251.
- SONG Liye, LIU Shuai, WANG Kai, et al. Identification method of power grid components and defects based on improved EfficientDet[J]. *Transactions of China Electrotechnical Society*, 2022, 37(9): 2241-2251.
- [10] 王殿伟, 胡里晨, 房杰, 等. 基于改进 Double-Head RCNN 的无人机航拍图像小目标检测算法[J]. 北京航空航天大学学报, 2024, 50(7): 2141-2149.
- WANG Dianwei, HU Lichen, FANG Jie, et al. Small target detection algorithm based on improved Double-Head RCNN for UAV aerial images[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2024, 50(7): 2141-2149.
- [11] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137-1149.
- [12] SHEN X L, XING Y L, LU J H, et al. Detection of surface defect on flexible printed circuit via guided box improvement in GA-Faster-RCNN network[J]. *PLoS One*, 2023, 18(12): e0295400.
- [13] 王逸凡, 王佳宇, 仲林林, 等. 基于深度学习的电力设备铭牌文本识别[J]. 电力工程技术, 2022, 41(5): 210-218.
- WANG Yifan, WANG Jiayu, ZHONG Linlin, et al. Text recognition of power equipment nameplates based on deep learning[J]. *Electric Power Engineering Technology*, 2022, 41(5): 210-218.
- [14] 孔松涛, 徐甄泽, 林星宇, 等. 基于改进 YOLO v5 算法的光伏组件红外热成像缺陷检测[J]. 红外技术, 2023, 45(9): 974-981.
- KONG Songtao, XU Zhenze, LIN Xingyu, et al. Infrared thermal imaging defect detection of photovoltaic module based on improved YOLO v5 algorithm[J]. *Infrared Technology*, 2023, 45(9): 974-981.
- [15] 游越, 伊力哈木·亚尔买买提, 吐松江·卡日. 基于 YOLOv6 的输电线路电力部件识别及缺陷检测算法研究[J]. 高压电器, 2024, 60(5): 194-205, 213.
- YOU Yue, YILIHAMU Yaermaimaiti, TUSONGJIANG Kari. Research on power component identification of transmission line and defect detection algorithm based on YOLOv6[J]. *High Voltage Apparatus*, 2024, 60(5): 194-205, 213.
- [16] 严宇平, 杨秋勇, 谢翰阳, 等. 基于改进 YOLOv7 的输电线路异物检测模型[J]. 南方电网技术, 2024, 18(9): 47-58.
- YAN Yuping, YANG Qiuyong, XIE Hanyang, et al. Foreign object detection model of transmission line based on improved YOLOv7[J]. *Southern Power System Technology*, 2024, 18(9): 47-58.
- [17] 张剑锐, 魏霞, 张林鎔, 等. 改进 YOLO v7 的绝缘子检测与定位[J]. 计算机工程与应用, 2024, 60(4): 183-191.
- ZHANG Jianrui, WEI Xia, ZHANG Linxuan, et al. Improving detection and positioning of insulators in YOLO v7[J]. *Computer Engineering and Applications*, 2024, 60(4): 183-191.
- [18] TERVEN J, CORDOVA-ESPARZA D M, ROMERO-GONZÁLEZ J A. A comprehensive review of YOLO architectures in computer vision: from YOLOv1 to YOLOv8 and YOLO-NAS[J]. *Machine Learning and Knowledge Extraction*, 2023, 5(4): 1680-1716.
- [19] SOLAWETZ J, FRANCESCO. What is YOLOv8? a complete guide[EB/OL]. (2023-01-11)[2023-12-01]. <https://blog.roboflow.com/whats-new-in-yolov8/#what-is-yolov8>.
- [20] YANG Z, NI C S, LI L, et al. Three-stage pavement crack localization and segmentation algorithm based on digital image processing and deep learning techniques[J]. *Sensors*, 2022, 22(21): 8459.

- [21] LI C, ZHOU A J, YAO A B. Omni-dimensional dynamic convolution[EB/OL]. 2022: 2209.07947. <https://arxiv.org/abs/2209.07947v1>.
- [22] DING L, TANG H, BRUZZONE L. LANet: local attention embedding to improve the semantic segmentation of remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(1): 426-435.
- [23] 王涛, 黎远松, 石睿, 等. 基于改进 YOLOv8n 的光伏电池缺陷检测算法[J/OL]. 重庆工商大学学报(自然科学版), 2024: 1-12. (2024-06-26) [2024-09-27]. <https://kns.cnki.net/KCMS/detail/detail.aspx?filename=YZZK20240625001&dbname=CJFD&dbcode=CJFQ>.
- WANG Tao, LI Yuansong, SHI Rui, et al. Defect detection algorithm of photovoltaic cells based on improved YOLOv8n[J/OL]. *Journal of Chongqing Technology and Business University (Natural Science Edition)*, 2024: 1-12. (2024-06-26) [2024-09-27]. <https://kns.cnki.net/KCMS/detail/detail.aspx?filename=YZZK20240625001&dbname=CJFD&dbcode=CJFQ>.
- [24] ZHENG Z H, WANG P, LIU W, et al. Distance-IoU loss: faster and better learning for bounding box regression[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(7): 12993-13000.
- [25] WANG J W, XU C, YANG W, et al. A normalized Gaussian Wasserstein distance for tiny object detection[EB/OL]. 2021: 2110.13389. <https://arxiv.org/abs/2110.13389v2>.
- [26] ZHONG J C, CHEN J Y, MIAN A. DualConv: dual convolutional kernels for lightweight deep neural networks[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, 34(11): 9528-9535.
- [27] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA. IEEE, 2017: 1800-1807.
- [28] OUYANG D L, HE S, ZHANG G Z, et al. Efficient multi-scale attention module with cross-spatial learning[C]//ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Rhodes Island, Greece. IEEE, 2023: 1-5.
- [29] YANG L X, ZHANG R Y, LI L D, et al. SimAM: a simple, parameter-free attention module for convolutional neural networks[C]. *International Conference on Machine Learning*, 2021.

作者简介:



荆启文

荆启文(2000), 男, 硕士在读, 研究方向为电力视觉、电力线路缺陷检测 (E-mail: jqw0930@126.com);

郝思鹏(1971), 男, 博士, 教授, 研究方向为电力系统低频振荡、新型电力系统;

李思源(2000), 男, 硕士在读, 研究方向为计算机视觉。

Exposed conductor detection of 10 kV distribution line based on improved YOLOv8

JING Qiwén, HAO Sipeng, LI Siyuan

(School of Electric Power Engineering, Nanjing Institute of Technology, Nanjing 211167, China)

Abstract: Exposed conductors in 10 kV distribution line are one of the major causes with operational faults in distribution lines, continuously affecting the safe and stable operation of the distribution network. Traditional manual inspection methods often fail to detect such defects in a timely manner. A detection method for exposed conductors in 10 kV distribution lines is proposed based on an improved YOLOv8 algorithm, which is designed to assist power grid maintenance personnel detecting conductor exposed defects quickly and efficiently. The algorithm replaces the original convolution with omni-dimensional dynamic convolution in the backbone network, enhancing the features of exposed conductors through multi-dimensional feature extraction. In the neck network, the connection between high-level and low-level features is enhanced by combining attention embedding module with the cross stage feature fusion module of the original network, thereby analyzing both the overall shape and local details of exposed conductors. For the loss function, distance intersection over union with normalized wasserstein distance is combined to increase focus on cases where targets are small or background interference exists in drone inspection photographs. The experimental results demonstrate that the improved algorithm achieves increases of 4.8 percentage points, 4.2 percentage points, and 5.2 percentage points in precision, recall, and mean average precision, respectively, compared to the original algorithm. This effectively enhances the detection capability for exposed distribution conductors, providing a new technical approach for ensuring the safe and stable operation of power systems.

Keywords: 10 kV distribution line; conductor exposed; YOLOv8; multi-dimensional feature extraction; image feature information processing; optimization of object detection

(编辑 吴昊)