

基于改进 YOLOv8 的轻量化输电线路异物检测模型

李旭阳¹, 王文峰¹, 李凌云¹, 殷跃², 孙争², 葛贤军³

(1. 国网河南省电力公司经济技术研究院, 郑州 450000; 2. 天地电研(北京)科技有限公司, 北京 102206; 3. 电力系统及发电设备控制和仿真国家重点实验室(清华大学电机系), 北京 100084)

摘要: 针对现有输电线路异物检测算法中异物尺度大、背景复杂导致的精度低和实时性差的问题, 提出了一种基于改进 YOLOv8 的轻量化模型。首先设计了一种融合双分支架构注意力机制的 MobileNetV2 的改进特征提取网络, 优化模型的参数量, 增强特征表达能力。同时, 将 CBAM 注意力机制嵌入到 SPPF 和 PANet 模块, 增强异物与环境之间的区分度, 提高模型在复杂背景下对异物的检测能力, 进而提高了检测精度。此外, 引入 WIoU 损失函数, 合理分配梯度增益, 提高模型的泛化能力和检测框定位精度。实验结果表明, 改进 YOLOv8 的检测精度 mAP 达到 96.12%, 推理速度达到 60 帧/s, 整体性能优于 YOLOv8 和其他 5 种主流目标检测模型, 且在不同光照的条件下展现出高稳定性和鲁棒性, 证明其在复杂环境中的实用性。在嵌入式设备上开展了进一步测试验证, 即使在计算资源受限的条件下改进 YOLOv8 仍能实现准确检测。

关键词: 分布式光伏; 超短期功率预测; 相关性信息; 数据隐私性; 联邦学习; 深度学习

Lightweight Foreign Object Detection Model for Power Transmission Lines Based on Improved YOLOv8

LI Xuyang¹, WANG Wenfeng¹, LI Lingyun¹, YIN Yue², SUN Zheng², GE Xianjun³

(1. State Grid Henan Electric Power Company Economic and Technological Research Institute, Zhengzhou 450000, China; 2. Tiandi Dianyan (Beijing) Technology Co., Ltd., Beijing 102206, China; 3. State Key Laboratory of Control and Simulation of Power Systems and Generation Equipments, Department of Electrical Engineering, Tsinghua University, Beijing 100084, China)

Abstract: In response to the issues of low accuracy and poor real-time performance caused by the large scale of foreign objects and complex backgrounds in existing transmission line foreign object detection algorithms, a lightweight model based on improved YOLOv8 is proposed. Firstly, a modified feature extraction network is designed by integrating a dual-branch architecture with attention mechanisms into MobileNetV2, optimizing the model's parameters and enhancing the feature representation capability. Additionally, the CBAM attention mechanism is embedded into the SPPF and PANet modules to enhance the discrimination between foreign objects and the environment, to improve the model's detection capability in complex backgrounds and consequently enhance the detection accuracy. Furthermore, the WIoU loss function is introduced to properly allocate gradient gains, enhancing the model's generalization ability and detection box localization accuracy. Experimental results demonstrate that the improved YOLOv8 achieves a detection accuracy of 96.12% mAP and an inference speed of 60 frames per second. It outperforms YOLOv8 and five other mainstream object detection models in terms of overall performance. Moreover, it exhibits high stability and robustness under different lighting conditions, proving its practicality in complex environments. Further testing on embedded devices confirms that even under limited computational resources, the improved YOLOv8 can still achieve accurate detection.

Key words: transmission line; ultra short term power forecasting; relevant information; data privacy; federated learning; deep learning

基金项目: 国家自然科学基金资助项目(52007095)。

Foundation item: Supported by the National Natural Science Foundation of China (52007095).

0 引言

电力输电线路横跨不同的地理环境,人类和鸟类活动的影响可能导致一些异物悬挂在带电导线或接地塔上,如鸟巢、风筝、气球和垃圾等。这些物体会威胁到供电系统的安全稳定运行,电力公司需要对输电线路进行定期巡检以排除安全隐患。以往的人工巡检方式主要通过工作人员沿着输电线路走廊、登高和无人机(unmanned aerial vehicle, UAV)巡查等方式进行检查,其中无人机巡检的方式因其更加安全和高效的优势而逐渐普及。随着无人机被广泛应用于电力线路巡检,处理由无人机巡检产生的大量视觉图像数据并从中识别异物已成为一个新的研究课题^[1-2]。其主要难点是在计算能力有限的无人机图像采集终端上部署高效的目标检测模型。因此,有必要开发一种具有高准确性和快速检测能力的轻量级模型,用于实时的电力输电线路的异物检测。

目前,悬挂在电力线路上的异物检测方法可以分为两类。一种是传统计算机视觉方法,其结合了图像处理、特征提取和分类器目标识别技术。例如, Jiao 等^[3]使用 K 均值-旋转快速角点和旋转描述子(K-means-oriented FAST and rotated BRIEF, K-ORB)算法实现图像运动补偿,并通过概率密度函数改进的三帧差分方法检测和标记传输线路上的异物。Yao 等^[4]提出了一种基于高斯混合模型和 k-means 聚类的无监督异物检测算法,用于识别传输线路上的鸟巢,使用二值化、形态学操作和渐进概率霍夫变换等图像预处理方法进行特征提取。传统的检测方法需要经过图像处理和复杂的特征定义、提取和筛选过程。对于背景简单的图像具有较好的检测结果,但对于背景复杂的图像准确性较差,难以满足实际应用中的需求。

另一种方法是基于深度学习技术的目标检测方法,它能够自动提取和学习图像特征,并且不易受目标位置的影响,与传统计算机视觉方法相比,具有更强的泛化能力和稳定性。目前基于掩码的卷积神经网络(mask region-based convolutional neural network, Mask RCNN)^[5]、快速的基于区域的卷积神经网络(faster region-based convolutional neural network, Faster RCNN)^[6-7]、单阶段多框检测器(single shot multibox detector, SSD)^[8]、你只

需浏览一次(you only look once, YOLO)^[9]等目标检测方法已被用于输电线路异物检测。例如, Chen 等^[5]使用 Mask RCNN 来检测电力线上的异物, mAP 达到 92.61 %。Guo 等人^[6]使用基于 Faster RCNN 进行改进,实现了风筝、气球等异物的检测, mAP 值达到 91.35 %。Wang 等^[8]比较了 SSD 和 Faster RCNN 在异物检测中的准确性,结果显示 SSD 具有更好的性能,平均精度均值(mean average precision, mAP)为 85.2 %,每秒帧数为 26。Song 等^[9]使用经过 k-means 聚类 and 距离交并比-非极大抑制(distance intersection over union-non maximum suppress, DIoU-NMS)方法优化的 YOLOv4 算法来检测高压线路上的异物,对风筝、气球、塑料、野火和烟雾的检测准确率达到 81.72 %。

先前的研究在异物检测准确性方面进行了较多的探索,但忽略了巡检过程中的实时性要求。现有的深度学习模型如 Faster RCNN、SSD、YOLO 等具有较深的网络结构,需要大量的计算资源。针对边缘智能的需求,有必要压缩目标检测模型,开发适用于边缘计算设备的轻量级模型。此外,输电线路处于野外环境,异物的识别易受到复杂背景元素和不稳定的光照条件干扰,同时大部分异物图像拍摄自无人机巡检,无人机高空作业的方式可能导致图像分辨率较低和异物尺度多变的情况。

鉴于此,本文提出一种基于改进 YOLOv8 的轻量化模型,实现了对电力输电线路沿线异物的实时检测,尤其是在背景复杂、遮挡严重和不同尺寸异物等挑战性条件下。通过在自建输电线路异物数据集上的实验比较和嵌入式平台上的测试,验证了所提模型的性能。

1 输电线路异物检测数据集

实验数据集采集自电力公司无人机输电线路巡检图像,共计 2 124 张 RGB 异物图像,部分图像示例如图 1 所示。这些图像覆盖了 4 种不同的异物,分别为风筝、鸟巢、垃圾和气球,值得注意的是,垃圾的判定主要依据透明或黑蓝色塑料袋,风筝和气球的判定主要依据异物的形状,而鸟巢具有明显的独立特征。

使用 MRLabeler 工具并按照 PASCAL VOC 格式对这些图像样本中的鸟巢、风筝、气球和垃圾进行标注^[10]。具体操作为在目标周围标记一个带有顶

点坐标($x_{\min}$ 、 $x_{\max}$ 、 $y_{\min}$ 、 $y_{\max}$)的最小外接矩形框作为真实框,鸟巢标注为“nest”,风筝标注为“kite”,气球标注为“balloon”,垃圾标注为“trash”。完成标注后,图像尺寸、目标的类别和坐标信息被记录在xml文件中。深度学习模型将使用所有的图像及对应xml文件用于训练和测试,提高模型的泛化能力。




图1 数据集样本示例

Fig. 1 Samples of the proposed dataset

此外,为了增加数据的多样性并提高模型的泛化能力,使用几种数据增强方法和泊松混合进行样本扩充^[11-14],最终生成5 345张图像,将这些图像按照7:2:1的比例进行划分,分别对应训练集、验证集、测试集。首先采用训练集中数据进行模型训练,然后通过验证集对训练结果进行评估,最终模型的性能在测试集上评估。

2 输电线路异物检测模型

本文提出一种基于改进YOLOv8的轻量化输电线路检测模型,旨在实现对异物图像的快速准确检测,检测过程如图2所示。

相对于现有的检测算法的区别是以YOLOv8模型为框架,提出了一种融合双分支架构注意力机制

CloBlock的MobileNetv2作为主干特征提取网络,并通过嵌入卷积块注意力模块(convolutional block attention module, CBAM)注意力机制改进空间快速金字塔池化(spatial pyramid pooling fast, SPPF)模块和路径聚合网络(path aggregation network, PANet)结构。

2.1 构建MobileNetv2-CloBlock

使用YOLOv8进行输电线路异物检测任务对计算能力和存储空间有较高的要求^[15]。为了提高对电力线路上异物的检测速度并平衡检测精度,采用当前主流的轻量级卷积神经网络MobileNetv2,并嵌入CloBlock来改进YOLOv8的结构。

MobileNetv2是一种轻量级卷积神经网络,其在MobileNets的基础上进行改进,通过深度可分离卷积(depthwise separable convolution, DSC)构建了反向残差块(inverted residual block, IRB)和线性瓶颈层,它们的结构差异如图3所示^[16-17]。

具体来说,MobileNetv2在深度卷积(depthwise convolution, DC)之前添加了一个点卷积(pointwise convolution, PC)层,目的是增加特征通道的数量,以提高模型的特征提取能力。DC对输入的每个通道使用一个独立的卷积核,而PC则采用1×1的卷积核对深度卷积的结果进行结合。这种结构的设计使得DSC在保持与标准卷积相似效果的同时,大幅减少了计算量和参数量,进而提高模型的检测速度。

DSC缺乏对通道维度的关注度,而异物具有不同的形状、类型和背景,针对这些特性,轻量级的MobileNetv2特征提取能力有限,且无法很好地区分目标和背景。此外,DSC采用了DC和PC两个步骤进行特征提取,这意味着输入图像的通道信息在




图2 改进的轻量级YOLOv8模型框架

Fig. 2 Improved lightweight YOLOv8 model architecture




图3 MobileNet网络结构

Fig. 3 MobileNet sturcture

计算过程中是分离的,可能会导致一些信息丢失,从而影响到模型的检测精度。基于此,使用CloFormer中的CloBlock模块增强主干网络,为主干网络引入嵌入双分支架构的注意机制,CloBlock的结构如图4所示^[18]。该模块采用双分支注意架构,其中一个分支使用DWconv捕获高频局部信息,然后使用上下文感知权重增强局部特征。在另一个分支中,通过注意力机制获得低频的全局信息,最后,融合两个分支以增强局部特征。

在全局分支中,为了获得低频的全局信息,首先对通过线性变换得到的 K_{global} 和 V_{global} 进行降采样,然后执行标准注意力过程以提取低频全局信息得到全局分支特征图 X_G :

$$\begin{aligned} Q_{global}, K_{global}, V_{global} &= FC(X_{in}), \\ X_G &= Attention(Q_{global}, Pool(K_{global}), Pool(V_{global})) \end{aligned} \quad (1)$$

式中: Q_{global} 为全局查询向量; K_{global} 为全局关键向量; V_{global} 为全局数值向量; $FC(\cdot)$ 为全连接层; X_{in} 为输入; $Pool(\cdot)$ 为池化操作; $Attention(\cdot)$ 为标准

注意力过程。

全局分支不足以处理高频局部信息,为了解决这个限制,引入局部分支。首先,通过线性变换得到 Q_{local} 、 K_{local} 和 V_{local} ,并由深度卷积(deepwise convolution, DWconv)聚合 V_{local} 局部信息。

$$\begin{cases} Q_{local}, K_{local}, V_{local} = FC(X_{in}) \\ V_{DW} = DWconv(V_{local}) \end{cases} \quad (2)$$

式中: Q_{local} 、 K_{local} 和 V_{local} 分别为局部的查询向量、关键向量和数值向量; $DWconv(\cdot)$ 为深度卷积操作; V_{DW} 为经DWconv处理后的数值向量。

接下来,使用两个DWconv分别聚合 Q_{local} 和 K_{local} ,生成对应的特征 Q_L 和 K_L ,然后计算 Q_{local} 和 K_{local} 的Hadamard乘积($\odot$),获得-1和1之间的上下文感知权重,利用生成的权重来增强局部分支特征 X_L ,过程如下。

$$Q_L = DWconv(Q_{local}) \quad (3)$$

$$K_L = DWconv(K_{local}) \quad (4)$$

$$A_L = FC(Swish(FC(Q_L \odot K_L))) \quad (5)$$

$$A = Tanh\left(\frac{A_L}{\sqrt{d}}\right) \quad (6)$$

$$X_L = Attention \odot V_{DW} \quad (7)$$

式中: A_L 为未经激活函数约束的局部注意力响应; A 为局部分支的注意力权重; $Swish(\cdot)$ 和 $Tanh(\cdot)$ 为激活函数。在通道维度将两个输出连接起来得到融合特征 X_C , X_C 经一个全连接层获得最终输出 X_{out} 。

$$X_C = concat(X_G, X_L), X_{out} = FC(X_C) \quad (8)$$

式中: d 为Transformer的token通道数; $concat$ 为连接操作。CloBlock的嵌入可以加强模型对全局信息




图4 CloBlock结构

Fig. 4 CloBlock structure

和局部信息的关注能力,减轻无关背景信息的影响,进而平衡因轻量化导致的检测精度的降低。

2.2 CBAM-SPPF和CBAM-PANet

不同尺度的特征图之间存在不一致性,大目标通常与浅层特征图相关联,而小目标通常与深层特征图相关联。一旦一个异物与具有某个尺度的特征图相关联,其他尺度的特征图对应位置将被视为背景,这种矛盾将降低特征融合网络的有效性。因此,在YOLOv8的SPPF^[19]结构和PANet^[20]网络中嵌入CBAM注意力机制,过滤掉不同尺度之间的矛盾特征信息,增强特征融合效果,提高模型检测多尺度异物的能力和复杂背景下的异物检测能力。

CBAM^[21]注意力机制通过在模型中引入通道注意力模块和空间注意力模块来实现,其结构如图5(a)所示。通道注意力模块专注于通道维度的权重,动态调整不同通道的重要性,突出有用的特征并抑制无关的特征。空间注意力模块通过学习空间权重,动态调整不同空间位置的重要性,从而突出图像中具有重要信息的区域,具体原理如图5(b)和(c)所示。




图5 CBAM注意力机制

Fig. 5 CBAM attention mechanism

对于给定的特征图 F ,执行池化操作;然后分别由两个多层感知机进行特征提取操作,得到细化的采样后特征图,其再经过Sigmoid得到通道方向的权重系数作为通道注意力模块的输出;接下来,将通道注意力模块输出的权重系数与原始的输入特征图 F 进行逐元素乘法运算,得到通道精化特征 F' ,过程如式(9)所示。

$$\begin{aligned} F' &= M_c(F) \times F \\ &= \sigma \left[\text{MLP}(\text{Avgpool}(F)) + \text{MLP}(\text{Maxpool}(F)) \right] \\ &= \sigma \left[W_1(W_0(F_{\text{avg}}^c)) + W_1(W_0(F_{\text{max}}^c)) \right] \end{aligned} \quad (9)$$

式中: M_c 为通道注意力; $\text{MaxPool}(x)$ 和 $\text{AvgPool}(x)$ 分别为最大池化和平均池化; σ 为Sigmoid值; W_0 和 W_1 是多层感知机的共享权重; F_{avg}^c 和 F_{max}^c 分别为平均池化和最大池化后的通道特征向量。

特征 F' 作为空间注意力模块的输入,分别执行最大池化和平均池化操作,将池化后的特征连接和卷积,生成空间注意力权重,最后对该权重应用Sigmoid激活函数,以获得对应权重系数,作为空间注意力模块的输出。结合两通道的输出,最终精化的输出特征 F'' 计算过程如式(10)所示。

$$\begin{aligned} F'' &= M_s(F') \times F' \\ &= \sigma \left[f(\text{Avgpool}(F')) + f(\text{Maxpool}(F')) \right] \quad (10) \\ &= \sigma \left(f^{7 \times 7} \left(\left[(F')_{\text{avg}}^s; (F')_{\text{max}}^s \right] \right) \right) \end{aligned}$$

式中: $f^{7 \times 7}$ 为一个 7×7 的卷积核; M_s 为空间注意力; $(F')_{\text{avg}}^s$ 和 $(F')_{\text{max}}^s$ 分别为平均池化和最大池化后的空间特征向量。

此外,为了控制轻量级模型的网络参数量,在输入和输出通道数量上引入宽度乘数 α 。设输入图像的尺寸为 $D_F \times D_F \times M$,使用标准卷积的参数量对应为 $D_K \times D_K \times M \times N \times D_F \times D_F$,其中 D_K 为卷积核的大小, D_F 为输入特征图的空间尺寸, M 和 N 分别为输入和输出通道的数量。使用深度可分离卷积的参数量为标准卷积的 $1/N + 1/D_K^2$ 倍,即 $D_K \times D_K \times M \times D_F \times D_F + M \times N \times D_F \times D_F$ 。当将模型通道数乘以宽度乘数 α 时,参数量将变为 $D_K \times D_K \times \alpha M \times D_F \times D_F + \alpha M \times \alpha N \times D_F \times D_F$ 。在标准的MobileNetV2中, α 的值为1.0, α 值通常可以设置为0.5、0.75、1.0、1.3等。当 α 值减小时,可以有效降低模型的复杂性。

2.3 WIoU损失函数

YOLOv8边界框的回归损失采用分布式聚焦损失(distribution focal loss, DFL)和完全交并比损(complete intersection over union, CIoU)损失函数,训练过程中DFL负责优化每条边界框,CIoU计算预测框和真实框之间的损失,进而优化预测框整体,CIoU如式(11)所示。

$$L_{\text{CIoU}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \alpha v \quad (11)$$

式中: b 为样本预测框; b^{gt} 为真实框; $\rho^2(b, b^{\text{gt}})$ 为预测框和真实框中心点的距离; c 为两矩形框对角线距离; α 为权重函数; v 用来度量长宽比的相似性。虽然 CIoU 综合考虑了预测框与真实框的长宽比, 但长宽比 v 描述了一个相对值, 定义上存在模糊, 且对回归的准确度、小标记框和低质量标记框的回归仍有一定的局限性。输电线路检测训练数据包含大量成像质量较低的图像, 导致距离和高宽比等几何测量值加剧了对低质量图像的惩罚, 从而降低了模型的泛化性能。

为了解决这一问题, 采用权重交并比 (weighted intersection over union, WIoU) 损失函数优化 YOLOv8 的回归损失部分, 当预测框与目标框重叠良好时, 降低几何测量的惩罚, 从而提高模型的泛化能力, WIoU 的计算公式如式 (12) 所示。

$$\begin{cases} L_{\text{WIoU}} = R_{\text{WIoU}} \cdot L_{\text{IoU}} \\ R_{\text{WIoU}} = \exp\left(\frac{(x - x^{\text{gt}}) + (y - y^{\text{gt}})}{w_g^2 + h_g^2}\right) \end{cases} \quad (12)$$

式中: L_{IoU} 为交并比损失函数; R_{WIoU} 为预测的边界框与真实边界框的中心点之间的标准化距离; x 、 y 为预测框中心点坐标; x^{gt} 、 y^{gt} 为真实框中心点坐标; w_g 、 h_g 分别为最小边界框的宽度和高度。

在训练早期, WIoU 可以保留更高质量的预测框, 增强模型的泛化能力。在训练后期, WIoU 将较小的梯度增益分配给低质量的预测框, 以减少有害梯度, 提高模型的定位性能。

3 实验和分析

3.1 实验环境和配置

实验使用的硬件设备为 Intel (R) Core (TM) i5-13400 处理器, NVIDIA GeForce RTX 3080 显卡, 12G 视频内存和 16G RAM 内存。操作系统为 Windows 10, 深度学习框架为 Tensorflow-GPU 1.13.2 和 Keras 2.1.5。模型训练过程中, 结合阶段性训练、余弦退火和标签平滑方法来增强模型的训练效果和泛化能力^[22-23]。采用迁移学习和提前停止等方法来节省训练资源 and 时间, 其中迁移学习使用在 ImageNet 公共数据集上预训练模型^[24]。模型的训练参数如表 1 所示。

训练分为两个阶段。初始学习率用于预热, 通

表 1 实验配置

Tab. 1 Experiment configuration

参数名	第一阶段	第二阶段
训练轮次 Epochs	50	50
批大小	8	2
初始学习率	0.001	0.000 1
预热轮次 Warmup epochs	10	
标签平滑值	0.01	
最小学习率	1×10^{-6}	
NMS 阈值	0.2	

过余弦退火进行调整, 使模型更加稳定并加快收敛, 模型训练期间的损失曲线如图 6 所示。




图 6 损失函数曲线

Fig. 6 Loss function curves

实验以平均精度 (average precision, AP) 和平均精度均值 (mean average precision, mAP) 作为精度评估指标, 其中 AP 用来衡量每个类别的识别准确度, mAP 是所有类别 AP 的平均值。此外, 为了评价模型的复杂度和资源需求, 选用参数量 (Params) 作为额外的评价指标, 较低的 Params 值意味着模型更轻量。同时通过浮点操作次数 (FLOPs) 和每秒处理帧数 (FPS) 来评估模型的计算效率和实时处理能力, FLOPs 衡量模型处理数据所需计算量, FPS 表示模型每秒处理图像帧数。从减少实际工程中漏检目标的要求出发, 召回率的值应尽可能大, F1 分数可以准确评估精确率和召回率, 鉴于此, 实验还选用 F1 分数指标作为额外评价标准。通过以上指标, 可以综合评价模型性能。检测精度 mAP 和 AP 指标的要求会根据不同的应用场景而有所差异, 在需要准确识别输电线路异物的场景中,

需要达到 90 % 以上。实时性通常根据 FPS 指标评估, 对于视频或图像处理应用, 需要达到 30 帧/s 以上。

为更清晰展示 4 种类别的性能, 绘制 4 种类别在测试过程中的 P - R 曲线, 如图 7 所示。




图 7 四类别 PR 曲线

Fig. 7 PR curves of four categories

3.2 模型检测性能分析

实验首先分析不同的训练策略对模型检测能力的影响, 具体为通过使用不同训练技巧对改进 YOLOv8 模型进行实验, 在测试集上得到它们的检测结果, 如表 2 所示。

从表 2 数据可知, 同时使用 4 种训练策略时, 模型的检测精度最高, mAP 值达到 96.12 %。此外, 鸟巢、风筝、气球和垃圾的 AP 值均超过 95 %, 充分验证轻量化 YOLOv8 模型在异物检测中的优越性能。同时, 使用所有 4 种方法时, 鸟巢、气球和垃圾的 $F1$ 分数均有所提高, 说明漏检目标数量减少, 检测结果更准确。

宽度乘数 α 可以有效地减少参数数量和模型复杂度, 为此, 实验对比 4 个 α 值(0.25、0.5、0.75、

1.0 和 1.25)下的检测结果, 采用上述 4 种训练方法对模型进行训练, 并在相同的测试集上进行异物检测。根据检测结果, 计算得到 AP 和 mAP 的值, 结果如表 3 所示。

当 $\alpha=0.25$ 时, mAP 的值最低, 为 85.54 %, 对应的每个类别异物风筝、鸟巢、气球和垃圾的 AP 值也是最低的。这是因为当 $\alpha=0.25$ 时, 通道数量大大减少, 导致重要特征信息丢失严重, 检测精度急剧下降。当 α 从 0.25 变化到 1 时, mAP 值逐渐增加到 96.12 %。当 $\alpha=1.25$ 时, 鸟巢、风筝、垃圾的 AP 值以及整体 mAP 值均下降, 这表明 α 值应控制在小于 1。垃圾类别在 $\alpha=0.5$ 、0.75、1.0 和 1.25 时的 AP 值最低, 原因是垃圾的形状不规则、且呈透明状, 在野外复杂场景中识别难度增加。总体而言, $\alpha=0.25$ 时, FPS 最大, 模型每秒可以检测 98 张图像, 但 mAP 仅为 85.54 %; $\alpha=0.5$ 时, FPS 和 mAP 分别可以达到 81 和 91.68 %。在实际工程应用中 $\alpha=0.5$ 时, 部署的模型具有快速的异物检测速度, 精确度稍有降低。

3.3 消融实验

基于 YOLOv8 框架的输电线路检测方法的创新改进包括: 融合 CloBlock 和 MobileNetv2 的增强型主干网络, 采用 CBAM 改进的 SPPF 和 PANet 结构优化颈部网络, 以及通过 WIoU 优化损失函数。以上改进旨在实现更精确、高效的输电线路异物检测。为量化这些改进措施对模型的性能影响, 进行消融实验验证各个改进方法的有效性, 结果如表 4 所示。

由表 4 可知, 4 种改进策略分别在模型复杂度和精度方面对模型进行了提升。首先, 采用 MobileNetv2 替换主干网络, 使得模型参数量降低到 2.17M, 相较于基线模型 YOLOv8 下降

表 2 训练策略对模型性能影响

Tab. 2 Evaluation metrics of models trained with different methods

训练策略				AP 值/%				mAP 值/%	F1 值			
Mosaic 数据增强	阶段训练	标签平滑	DnCNN	风筝	鸟巢	气球	垃圾		风筝	鸟巢	气球	垃圾
√				95.13	92.97	94.51	94.51	94.28	0.91	0.90	0.92	0.90
√	√			95.05	92.19	95.04	94.21	94.12	0.89	0.88	0.90	0.89
√		√		95.23	93.17	95.48	94.97	94.71	0.91	0.91	0.93	0.90
√	√	√		96.02	95.10	95.79	95.27	95.56	0.93	0.92	0.95	0.92
√	√	√	√	96.44	95.89	96.26	95.88	96.12	0.95	0.96	0.97	0.94

表 3 不同宽度乘数下的检测结果

Tab. 3 Detection results of different width multiplier

α	AP 值/%				mAP 值/%	FPS 值
	风筝	鸟巢	气球	垃圾		
0.25	88.76	77.12	92.68	85.58	85.54	98
0.5	94.73	92.39	92.19	86.42	91.68	81
0.75	95.66	93.91	93.82	88.14	92.88	70
1.0	96.44	95.89	96.26	95.88	96.12	60
1.25	95.14	93.03	92.97	90.33	92.87	49

表 4 消融实验


Tab. 4 Ablation study

方法	Mobile CloB	Netv2 lock	CBAM- SPPF CBAM- PANet	WIo	mAP 值/%	FPS	Params 值/M	FLOPs 值/G
YOLOv8					95.42	47	11.18	28.53
	√				89.25	103	2.17	5.64
		√			97.38	43	13.79	29.37
			√		95.93	46	11.61	28.65
				√	95.51	47	11.18	28.53
	√	√			93.64	67	3.27	9.27
	√	√	√	√	96.12	60	3.45	10.16


80.59%，实现了大幅度模型压缩。其次，CloBlock 双分支注意力机制的嵌入使得模型 mAP 提高 1.96%，且仅带来 2.61M 参数量和 0.84×10^9 次浮点运算 (FLOPs) 次数的增加，表明该模块有效地加强了模型对异物的关注度，减轻了遮挡等因素的影响，增强了主干网络的特征提取能力。此外，采用 CBAM 改进的颈部模块使得模型的 mAP 略微增加 0.51%，参数量和 FLOPs 几乎没有变动，表明该颈部改进策略具有预期的多尺度适应能力，并有效地增加了模型特征融合能力。最后，WIoU 损失函数使得 mAP 增加 0.09%，这是因为 WIoU 优化了模型检测框的定位精度，且增强了泛化能力。

总体而言，改进的 YOLOv8 轻量化模型 mAP 达到 96.12%，相较于基线 YOLOv8 略微提高 0.70%。参数量和计算量分别达到 3.45M 和 10.16×10^9 次 FLOPs，相较于基线 YOLOv8 大幅降低了 7.73M 和 18.37×10^9 ，模型复杂度和计算复杂度方面取得了大幅的提升，实现了具有高准确度的模型轻量化。为进一步展示不同改进策略在应对输电线路异物检测挑战时对模型的提升，图 8 展示了不同策略的检测可视化结果。


对比图 8 中结果可知，MobileNetV2-CloBlock



(a) 复杂背景下检测结果



(b) 小尺寸目标检测结果



(c) 阴暗条件下检测结果

图 8 可视化结果

Fig. 8 Visualization results

增强型主干网络有效提升了模型检测的准确度;CBAM注意力机制改进的颈部网络使得模型抗背景干扰能力得到加强,使得模型更精确地完成分类和识别;WIoU损失函数使得最终的预测框位置更准确,且小幅提升了检测精度。综合以上分析,本文所提改进策略在复杂背景、小尺寸目标以及不同光照等异物检测挑战中具有良好的表现。

3.4 与主流算法对比实验

为进一步评估改进YOLOv8模型在输电线路异物检测方面的性能,将改进YOLOv8模型与Faster RCNN、SSD、YOLOv7等主流检测算法在输电线路异物检测数据集上进行对比,并与轻量级检测模型YOLOv8n和原始YOLOv8模型进行对比,同时比较通过所提方法改进的YOLOv8n性能。各检测模型的性能指标比较结果如表5所示。

在输电线路异物检测任务中,改进YOLOv8针对4种异物的AP指标分别达到96.44%、95.89%、96.26%、95.88%,其中风筝、鸟巢和垃圾的AP值相较于基线模型YOLOv8分别提高0.41%、0.90%和0.63%,整体检测精度mAP值达到96.12%,相较于YOLOv8提高0.70%,且优于其他先进算法,实现了最佳的检测精度。

计算复杂度方面,改进YOLOv8只需 10.16×10^9 次浮点运算次数就能完成高精度输电线路异物检测,远低于Faster RCNN的 207.15×10^9 次FLOPs,这是因为Faster RCNN从原始图像中提取

大量的区域候选框,然后预测每个候选框的位置和类别,而选择区域候选框的过程会导致庞大计算量。此外,相较于基线YOLOv8的 28.53×10^9 次FLOPs,改进YOLOv8的计算复杂度得到了显著提升,这一优势在实际应用中尤为重要。

在模型参数量方面,改进YOLOv8的参数量仅有3.45 M,远小于Faster RCNN的43.19 M、SSD的25.34 M和YOLOv8的11.18 M,显著减少的参数量意味着改进YOLOv8模型更适用于边缘计算或移动设备部署。

此外,综合性能上,SSD和YOLOv7直接在原始图像中预测位置和类别,虽然它们的mAP值稍低于Faster RCNN,但其FPS值分别提高到33和48。在SSD的基础上,MobileNet-SSD使用轻量级的MobileNetv1作为特征提取网络,减少参数量的同时也会削弱模型的特征提取能力,因此,与SSD相比,它的mAP值降低1.7%,而FPS值增加到97。YOLOv8n通过简化DarkNet53大幅减少模型的复杂性和参数数量,使得YOLOv8n的FPS增加到101,但与YOLOv8相比,mAP值降低6.72%。将所提方法应用于YOLOv8n时,mAP相较于原始YOLOv8n提高了2.48%,而FPS值从101降低到92。从参数量和计算量的增加可以看出,MobileNetV2-CloBlock构成的新主干网络,可以有效提升模型的检测性能,但是相较于YOLOv8n本身的轻量级主干网络DarkNet-tiny,具有更高的模

表5 与主流算法性能对比

Tab. 5 Comparison with mainstream algorithm

方法	主干	融合网络	AP值/%				mAP 值/%	FPS 值	Params 值/M	FLOPs 值/ G
			风筝	鸟巢	气球	垃圾				
Faster RCNN	ResNet50		94.84	94.92	91.47	93.28	93.63	12	43.19	207.15
SSD	VGG16		89.27	91.48	96.77	81.45	89.74	33	25.34	87.73
MobileNet-SSD	MobileNetv1		85.49	90.68	94.68	81.29	88.04	97	5.56	10.64
YOLOv7	CSPDarkNet53	SPPCSPC+PANet	97.00	94.02	91.04	87.46	92.38	48	15.98	23.31
YOLOv8	CPSDarkNet53	SPPF+PANet	96.03	94.99	97.39	93.25	95.42	47	11.18	28.53
YOLOv8n	DarkNet-tiny	PANet	91.82	92.10	86.95	83.93	88.70	101	3.15	8.12
改进YOLOv8n	MobileNetv2-CloBlock	CBAM-SPPF+CBAM-PANet	93.05	94.33	89.21	88.14	91.18	92	3.23	9.24
改进YOLOv8	MobileNetv2-CloBlock	SPPF+PANet	95.87	93.14	95.43	90.11	93.64	67	3.27	9.27
	MobileNetv2-CloBlock	CBAM-SPPF+CBAM-PANet	96.44	95.89	96.26	95.88	96.12	60	3.45	10.16

型复杂度。

综合以上分析,改进YOLOv8在输电线路异物检测任务中表现出卓越性能,在计算复杂度、模型参数量和检测精度方面展现出明显的优势,相较于Faster RCNN、SSD、YOLOv7、YOLOv8及其他轻量级模型,本文所提基于改进YOLOv8的轻量化模型能够更好地满足实时和准确检测的要求。最后,为直观展示所提模型的优越性,选取具有复杂背景、不规则异物和小尺寸异物的图像,将所提模型与Faster RCNN、YOLOv7以及YOLOv8进行检测可视化对比,结果如图9所示。

3.5 模型鲁棒性验证

在电力输电线路的实际场景中,所收集到的异物图像通常具有复杂多样的背景,其会随着季节、天气和地理环境而变化。这种情况下,图像的光强度也会随之改变,不同的光强度对模型的检测准确度会产生影响。鉴于此,为验证所提模型的鲁棒性,将改进YOLOv8与Faster RCNN、YOLOv7以及YOLOv8模型在雾霾、多云和夜间3种阴暗条件下进行比较,不同模型的检测结果如图10所示。

图10(a)中的雾霾环境的检测结果可以观察到,

图像整体对比度和清晰度较低,改进YOLOv8和基线YOLOv8都能正确检测到异物,与之相对的,Faster RCNN和YOLOv7这两个模型未能在这种条件下检测到垃圾目标。在图10(b)中的多云环境中,改进YOLOv8、YOLOv8和YOLOv7均能有效检测到气球异物,且改进YOLOv8的检测准确度最高。图10(c)中的夜间环境中,图像对比度较低,针对输电杆塔上的鸟巢异物,YOLOv8、YOLOv7和Faster RCNN均表现出漏检结果,而改进的YOLOv8模型仍能检测到目标异物,这得益于采用的注意力机制有效地增强了模型位置特征和语义的表达能力,使其在稳定检测任务中表现得更出色。以上结果验证了改进YOLOv8模型的鲁棒性和稳定性,为电力输电线路上的异物检测提供有效解决方案。

3.6 嵌入式设备上异物检测结果

嵌入式端部署目标检测模型是实际工程中的常用方案^[25-27]。鉴于高精度目标检测算法在嵌入式设备部署过程中因计算资源和实时性能有限导致的实际应用难题,选择高性能NVIDIA Jetson Nano开发板为计算平台,验证模型实际应用中的性能,如图




图9 与主流检测方法对比结果

Fig.9 Comparison results with mainstream methods




图 10 阴暗环境下模型检测性能

Fig. 10 Model detection performance under dark environment

11 所示。具体配置为四核 64 位 ARM CPU 和 128 核 NVIDIA Maxwell GPU, 可实现最高 472×109 次浮点运算。




图 11 NVIDIA Jetson Nano 实际部署图

Fig. 11 NVIDIA Jetson Nano actual deployment diagram

为验证改进 YOLOv8 在嵌入式设备中的检测性能和效率, 将训练好的模型部署于 NVIDIA Jetson Nano 中, 通过自制输电线路异物检测数据集进行性能测试, 结果如表 6 所示。

在嵌入式平台, 改进 YOLOv8 在异物检测任务

表 6 嵌入式设备上性能比较

Tab. 6 Performance comparison on embedded devices

模型	mAP 值/%	FPS 值
YOLOv8	95.42	15.7
改进 YOLOv8	96.12	19.4

中 mAP 值达到 95.12 %, 相较于基线 YOLOv8 提高了 0.70 %, FPS 值从 15.7 提高至 19.4, 这表明改进 YOLOv8 模型达成了显著计算效率的提升, 同时实现了有效的精度提升, 具有良好的准确性和实时性。

4 结论

本文提出了一种基于改进 YOLOv8 的轻量化模型, 旨在提高电力输电线路异物检测的准确性和实时性。首先采用融合双分支注意力架构和 MobileNetv2 的特征提取网络作为主干, 提高模型对关键区域的专注度和特征提取效果, 并降低模型的参数量。同时, 引入 CBAM 改进 SPPF 结构和 PANet 结构, 提高模型在复杂环境中的异物检测能力。此外, 采用 WIoU 损失函数优化预测框的定位精度。最后, 通过 4 种训练策略进一步加强模型的特征提取性能, 提高模型的鲁棒性。主要结论如下。

1) 在 4 种训练策略上的实验结果显示, 改进 YOLOv8 检测模型在经过 Mosaic 数据增强、阶段性训练、标签平滑和 DnCNN 策略后, 对风筝、鸟巢、气球和垃圾这 4 类异物的检测精度 AP 指标分别提

高了 1.31 %、2.91 %、2.75 %、1.37 %，平均精度 mAP 提高了 1.84 %。

2) 在自制输电线路异物检测数据集上的实验结果表明，改进 YOLOv8 检测模型能够有效地检测输电线路上的 4 种异物，具有高达 96.12 % mAP 值准确度和 60 帧/s 的检测速度，显著优于基线 YOLOv8 以及其他 5 种主流对比模型。

3) 在阴暗环境下的对比结果表明，改进 YOLOv8 仍能有效地检测到目标异物，且具有较高的检测置信度，保持了模型鲁棒性。此外，在嵌入式平台上的测试结果表明，改进 YOLOv8 能够满足实时异物检测需求。

综上，本文所构建的输电线路异物检测模型可以满足实际电力巡检环境中的需要，为电网系统智能巡检提供技术支持，具有良好的应用前景。随着技术和硬件的发展，未来工作会致力于在研发高效异物检测模型的同时实现输电线路缺陷检测模型的开发。另外，考虑到效率和工程需要，未来工作还会致力于实现嵌入式端模型的训练。

参考文献

- [1] YANG L, FAN J, LIU Y, et al. A review on state-of-the-art power line inspection techniques [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69 (12): 9350 - 9365.
- [2] 梁华尘, 周稳, 倪旭东, 等. 面向多目标联合电力巡检的车载无人机协同巡检路径规划方法[J]. 南方电网技术, 2023, 17 (11): 138 - 147.
LIANG Huachen, ZHOU Wen, NI Xudong, et al. Cooperative inspection path planning method for multi-objective joint power inspection by vehicle-mounted UAV [J]. Southern Power System Technology, 2023, 17(11): 138 - 147.
- [3] JIAO S, WANG H. The research of transmission line foreign body detection based on motion compensation [C]//2016 First International Conference on Multimedia & Image Processing (ICMIP), June 01 - 03, 2016, Bandar Seri Begawan, Brunei. New York: IEEE, 2016: 10 - 14.
- [4] YAO N, ZHU L. A novel foreign object detection algorithm based on GMM and K-Means for power transmission line inspection [J]. Journal of Physics Conference Series, 2020 (1607): 012014.
- [5] CHEN W, LI Y, LI C. A visual detection method for foreign objects in power lines based on mask R-CNN [J]. International Journal of Ambient Computing and Intelligence (IJACI), 2020, 11(1): 34 - 47.
- [6] GUO S, BAI Q, ZHOU X. Foreign object detection of transmission lines based on faster R-CNN [C]//Proceedings of International Conference on Information Science and Applications, December 19, 2019, Springer, Singapore. 2020(621): 269 - 275.
- [7] 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.
WEI Yewen, LI Mei, XIE Yuanlin, et al. Transmission line inspection image detection based on improved Faster-RCNN [J]. Electric Power Engineering Technology, 2022, 41 (2): 171 - 178.
- [8] WANG B, WU R, ZHENG Z, et al. Study on the method of transmission line foreign body detection based on deep learning [C]//2017 IEEE Conference on Energy Internet and Energy System Integration (EI2), November 26 - 28, 2017, Beijing, China. New York: IEEE, 2017: 1 - 5.
- [9] SONG Y, ZHOU Z, LI Q, et al. Intrusion detection of foreign objects in high-voltage lines based on YOLOv4 [C]//2021 6th International Conference on Intelligent Computing and Signal Processing (ICSP), April 9 - 11, 2021, Xi'an, China. New York: IEEE, 2021: 1295 - 1300.
- [10] EVERINGHAM M, GOOL L, WILLIAMS C K, et al. The pascal visual object classes (VOC) challenge [J]. International Journal of Computer Vision, 2010, 88(2): 303 - 338.
- [11] SHI J, GU C, SUN H, et al. Data expansion for foreign object detection in power grid [C]//2019 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC), December 1 - 4, 2019, Macao, China. New York: IEEE, 2019: 1 - 4.
- [12] SHORTEN C, KHOSHGOFTAR T. A survey on image data augmentation for deep learning [J]. Journal of Big Data, 2019 (6): 1 - 10.
- [13] PEREZ P, GANGNET M, BLAKE A. Poisson image editing [J]. ACM Transactions on Graphics (TOG), 2003, 22 (3): 313 - 318.
- [14] ZHONG Z, ZHENG L, KANG G, et al. Random erasing data augmentation [J]. Proceedings of National Conference on Artificial Intelligence (AAAI), 2020, 34(7): 13001 - 13008.
- [15] ORTATAS F, KAYA M. Performance evaluation of YOLOv5, YOLOv7, and YOLOv8 models in traffic sign detection [C]//2023 8th International Conference on Computer Science and Engineering (UBMK), September 13 - 15, 2023, Burdur, Türkiye. New York: IEEE, 2023: 151 - 156.
- [16] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: Inverted residuals and linear bottlenecks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 18 - 23, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 4510 - 4520.
- [17] HOWARD A, ZHU M, CHEN B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications [DB/OL]. [2017 - 4-17]. <https://arxiv.org/abs/1704.04861>.
- [18] FAN Q, HUANG H, GUAN J, et al. Rethinking local perception in lightweight vision transformer [DB/OL]. (2023 - 3-31) [2023 - 6-1]. <https://arxiv.org/abs/2303.17803>.
- [19] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 37(9): 1904 - 1916.
- [20] 林成创, 赵淦森, 尹爱华, 等. AS-PANet: 改进路径增强网络的重叠染色体实例分割[J]. 中国图象图形学报, 2020, 25 (10): 2271 - 2280.
LIN Chengchuang, ZHAO Gansen, YIN Aihua, et al. AS-PANet: A chromosome instance segmentation method based on improved path aggregation network architecture [J]. Journal of

- Image and Graphics, 2020, 25(10): 2271 – 2280.
- [21] WOO S, PARK J, LEE J, et al. CBAM: Convolutional block attention module [C]//Proceedings of European Conference on Computer Vision (ECCV), October 6, 2018, Munich, Germany. Berlin: Springer, 2018: 3 – 19.
- [22] LOSHCHILOV I, HUTTER F. SGDR: Stochastic gradient descent with warm restarts [DB/OL]. (2016 – 8–13) [2017 – 5–3]. <https://arxiv.org/abs/1608.03983>.
- [23] MULLER R, KORNBLITH S, HINTON G. When does label smoothing help? [DB/OL]. (2019 – 6–6) [2020 – 6–10]. <https://arxiv.org/abs/1906.02629>.
- [24] DENG J, DONG W, SOCHER R, et al. ImageNet: a large-scale hierarchical image database [C]//2019 IEEE Computer on Computer Vision and Pattern Recognition (CVPR), June 20 – 25, 2009, Miami, FL, USA. New York: IEEE, 2009: 248 – 255.
- [25] LI D, LU Y, GAO Q, et al. LiteYOLO-ID: a lightweight object detection network for insulator defect detection [J]. IEEE Transactions on Instrumentation and Measurement, 2024(73): 5023812.
- [26] 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 and Instrumentation, 2023, 60(7): 138 – 144.
- [27] 宋智伟, 黄新波, 纪超, 等. 基于PCSA-YOLOv7 Former的输电线路连接金具及其锈蚀检测方法[J]. 中国电力, 2024, 57(6): 141 – 152.
- SONG Zhiwei, HUANG Xinbo, JI Chao, et al. Transmission line connection fittings and corrosion detection method based on PCSA-YOLOv7 former [J]. Electric Power, 2024, 57(6): 141 – 152.

收稿日期: 2024-02-26; 网络首发日期: 2024-11-30

作者简介:

李旭阳(1979), 男, 通信作者, 高级工程师, 硕士, 研究方向为输电线路自动化技术及经济, lixuyang197911@163.com;

王文峰(1981), 男, 高级工程师, 硕士, 研究方向为电力系统变电设计;

李凌云(1989), 女, 经济师, 硕士, 研究方向为电力工程技术经济。

(上接第110页 Continued from Page 110)

- [17] 赵晋泉, 叶君玲, 邓勇. 直流潮流与交流潮流的对比分析[J]. 电网技术, 2012, 36(10): 147 – 152.
- ZHAO Jinquan, YE Junling, DENG Yong. Comparative analysis on DC power flow and AC power flow [J]. Power System Technology, 2012, 36(10): 147 – 152.
- [18] 李虎成, 於益军, 高宗和, 等. 一种提高计算精度的类直流潮流算法[J]. 电力系统自动化, 2013, 37(12): 128 – 133.
- LI Hucheng, YU Yijun, GAO Zonghe, et al. A class DC power flow algorithm with higher calculation accuracy [J]. Automation of Electric Power Systems, 2013, 37(12): 128 – 133.
- [19] 黄子桐, 徐永海, 叶兴杰. 考虑有源配电网运行灵活性的智能储能软开关优化规划[J]. 电力工程技术, 2023, 42(1): 143 – 153.
- HUANG Zitong, XU Yonghai, YE Xingjie. Optimal planning of soft open point integrated with energy storage system considering operation flexibility of active distribution network [J]. Electric Power Engineering Technology, 2023, 42(1): 143 – 153.
- [20] 陈依杭, 李晓露, 柳劲松, 等. 考虑配电网灵活性供需匹配度及网络传输的储能和智能软开关协同规划[J]. 电力建设, 2024, 45(9): 49 – 62.
- CHEN Yihang, LI Xiaolu, LIU Jinsong, et al. Energy storage system and soft open point coordinated planning considering distribution network flexibility supply-demand matching and network transmission [J]. Electric Power Construction, 2024, 45(9): 49 – 62.
- [21] 廖建, 张耀, 张贝西, 等. 考虑电动汽车需求响应的交直流混合配电网智能软开关与储能装置鲁棒联合规划方法[J]. 中国电力, 2025, 58(10): 82 – 96.
- LIAO Jian, ZHANG Yao, ZHANG Beixi, et al. A robust joint planning method for soft open points and energy storage systems in AC/DC hybrid distribution networks considering electric vehicle demand response [J]. Electric Power, 2025, 58(10): 82 – 96.
- [22] ZIMMERMAN R D, MURILLO-SÁNCHEZ C E, THOMAS R J. MATPOWER: steady-state operations, planning and analysis tools for power systems research and education [J]. IEEE Transactions on Power Systems, 2011, 26(1): 12 – 19.

收稿日期: 2024-06-24; 网络首发日期: 2024-12-01

作者简介:

谢明磊(1983), 男, 高级工程师, 硕士, 研究方向为供电可靠性、科技规划, 79103643@qq.com;

罗威(1986), 男, 通信作者, 高级工程师, 学士, 研究方向为配电系统运行控制与保护;

曹德发(1983), 男, 高级工程师, 学士, 研究方向为电力系统分析、运行与控制。