

基于改进 YOLOv8n 的输电线路绝缘子缺陷检测方法

王爽^{1,2}, 李亚威^{1,2}, 阴酉龙^{3,4}, 唐波^{1,2}

(1. 三峡大学电气与新能源学院, 湖北宜昌 443002; 2. 湖北省输电线路工程技术研究中心(三峡大学), 湖北宜昌 443002;
3. 国网安徽省电力有限公司, 合肥 230061; 4. 合肥工业大学管理学院, 合肥 230009)

摘要: 由于无人机航拍巡检图像中绝缘子缺陷存在背景复杂、缺陷目标较小、不同检测目标尺寸相差较大等问题, 目前的目标检测算法对此类目标识别时缺陷特征容易丢失, 导致精度低且误识率高。为此, 提出了一种基于改进 YOLOv8n 的输电线路绝缘子缺陷检测方法。首先, 为了解决小目标绝缘子缺陷特征丢失问题, 设计了 PCFocalNeXt-C2f 模块, 并用其对 YOLOv8n 的 Backbone 进行优化。其次, 为了解决缺陷目标的特征在多级传输中的信息丢失或退化问题, 使用支持在非相邻层次上直接交互作用的渐近金字塔网络(asymptotic feature pyramid network, AFPN), 对 YOLOv8n 的 Neck 进行优化。最后, 引入损失函数 Sigmoid-CIoU, 对 YOLOv8n 中的损失函数进行优化, 并采用 Sigmoid-CIoU NMS 获取检测结果, 提升模型的鲁棒性。实验结果表明, 所提出的算法相较于改进前的 YOLOv8n, F1 值提升 3.3%, 平均检测精度 mAP@0.5 和 mAP@0.5-0.95 分别提高了 3.8% 和 6.1%, 同时参数量降低了 23.9%, 证明了所提出的算法具有更优越的检测性能。

关键词: 无人机巡检; 缺陷检测; YOLOv8n; 小目标检测; AFPN

Defect Detection Method for Transmission Line Insulator Based on Improved YOLOv8n

WANG Shuang^{1,2}, LI Yawei^{1,2}, YIN Youlong^{3,4}, TANG Bo^{1,2}

(1. School of Electrical and New Energy, China Three Gorges University, Yichang, Hubei 443002, China; 2. Hubei Provincial Engineering Technology Research Center for Power Transmission Line, China Three Gorges University, Yichang, Hubei 443002, China; 3. State Grid Anhui Electric Power Co., Ltd., Anhui 230061, China; 4. School of Management, Hefei University of Technology, Hefei 230009, China)

Abstract: Due to the complex backgrounds, small defect targets, and significant size variations among different detection objects of insulator defects in drone aerial inspection images, current object detection algorithms often lose defect features when identifying such targets, resulting in low accuracy and high misidentification rates. To address this, an improved YOLOv8n-based method for detecting insulator defects in transmission lines is proposed. Firstly, to tackle the feature loss issue of small insulator defects, a PCFocalNeXt-C2f module is designed and used to optimize the Backbone of YOLOv8n. Secondly, to mitigate feature information loss or degradation during multi-level transmission, an asymptotic feature pyramid network (AFPN) supporting direct interaction across non-adjacent layers is employed to enhance the Neck of YOLOv8n. Finally, the Sigmoid-CIoU loss function is introduced to optimize the loss function in YOLOv8n, and Sigmoid-CIoU NMS is adopted to obtain detection results, improving the model's robustness. Experimental results show that compared to the original YOLOv8n, the proposed algorithm achieves a 3.3% increase in F1-score, with mAP@0.5 and mAP@0.5-0.95 improving by 3.8% and 6.1%, respectively, while reducing the parameter count by 23.9%, demonstrating superior detection performance.

Key words: unmanned aerial vehicle inspection; defect detection; YOLOv8n; small target detection; AFPN

基金项目: 国家自然科学基金资助项目(72271076); 湖北省重点研发项目(2020BAB110)。

Foundation item: Supported by the National Natural Science Foundation of China(72271076); the Key Research and Development Projects of Hubei Province (2020BAB110).

0 引言

随着电网数字化和智能化水平的不断提高,基于无人机的输电线路智慧巡检已成为线路运维重要手段^[1]。绝缘子缺陷是输电线路最常见的缺陷和安全隐患之一^[2-3],由于无人机航拍得到的巡检图像数据量大且背景复杂,采用人工筛检发现上述缺陷费时费力且效率较低,同时这种方式漏检风险高、判断的准确度难以保证^[4-5],因此,研究基于深度学习的输电线路绝缘子缺陷检测方法可以大幅降低巡检人员的工作强度,提高电网的智慧运维水平,具有重要的工程应用价值。

近年来,随着人工智能技术的飞速发展,基于深度学习的人工智能算法被越来越多的应用于目标检测^[6-7]。目前主流深度学习目标检测算法可以分成两大类:单阶段目标检测算法和两阶段目标检测算法^[7]。单阶段目标检测算法省去了候选区域生成步骤,能够直接在一个阶段内输出物体的类别概率及其位置坐标,典型的单阶段目标检测算法有YOLO^[8-11](you only look once)、SSD^[12](single shot multibox detector)等。李瑞生等人^[13]在SSD中引入残差网络,解决了输电线路复杂背景下销钉缺陷检测能力不足的问题。王宇博等人^[14]使用自注意力主干网络和BiFPN对YOLOv7进行优化,提高了算法对输电导线缺陷的检测精度和检测速度。虽然上述研究都取得了一定成果,但其检测任务针对的大多是单一缺陷目标且特征明显,模型泛化性较差。而两阶段目标检测算法将检测问题划分为两个阶段,第一个阶段先产生包含目标大致位置信息的候选区域,第二个阶段对这些候选区域进行精确分类和位置调整,这类算法的典型代表有R-CNN^[15](Region-based Convolutional Neural Network)、Fast R-CNN、Faster R-CNN、Mask R-CNN等^[16]。魏业文等人^[17]通过ZFnet改进Faster R-CNN,提高了算法对电力设备的识别精度和响应速度。赵振兵等人^[18]使用Faster R-CNN作为基础模型,用相对熵作为损失函数,通过加入数据集中不同金具类目标的形状特征来约束损失函数,从而提高模型的泛化性能和边界框回归能力。上述的两阶段目标检测算法需要生成候选区,导致其检测速度较慢,在输电线路巡检的实时检测适用性方面还有待提高。

由于现有的目标检测算法在面对背景复杂、缺

陷目标较小、不同检测目标尺寸相差较大的输电线路绝缘子缺陷巡检图像时,适用性不强,检测结果容易出现漏检和误检的问题,因此需要进一步的对网络进行优化。

本文提出了一种基于改进YOLOv8n的输电线路绝缘子缺陷检测方法,主要贡献如下:1)根据绝缘子的3种缺陷(自爆、破损、闪络痕迹)以及绝缘子串本身建了一个新的数据集;2)结合PConv、Focal NeXt block和C2f,设计了PCFocalNeXt-C2f模块,该模块可以更好地融合细粒度的局部交互和粗粒度的全局交互,从而提升模型对多尺度特征的提取能力和对小目标的检测能力;3)使用渐近金字塔网络渐近金字塔网络(asymptotic feature pyramid network, AFPN)对YOLOv8n的Neck进行优化,避免了多级传输中的信息丢失或退化问题;4)使用损失函数Sigmoid-CIoU对YOLOv8n中的损失函数进行优化,并采用Sigmoid-CIoU NMS获取检测结果,提升模型的鲁棒性。

1 算法原理

1.1 YOLOv8算法

YOLOv8在继承前代版本卓越性能的基础上,融入了新的功能与改进措施,旨在进一步优化性能和增强灵活性,从而推出了一款全新的模型(如图1所示)。该模型的核心升级包括采用新型骨干网络、引入Anchor-Free检测头以及应用新的损失函数,确保其能够在从CPU到GPU的各类硬件平台上高效运行,同时相较于其他主流目标检测算法,YOLOv8具有更高的检测精度。YOLOv8与YOLOv5一脉相承,通过缩放系数的精妙运用,推出了N/S/M/L/X 5种不同尺度的模型,旨在精准匹配多样化的场景需求,骨干网络和颈部网络使用了梯度流更丰富的C2f结构,这种结构显著增强了卷积神经网络的学习能力,同时降低了计算量并丰富了梯度流,通过对不同尺度模型进行通道数的精细调整,实现了结构的精心微调,从而大幅提升了模型性能^[19]。头部网络相较于YOLOv5进行了较大改动,采用了当前主流的解耦头结构,将分类和检测头分离,并从Anchor-Based转变为Anchor-Free^[20]。在Loss计算方面,引入了Task-Aligned Assigner正负样本分配策略,并结合了Distribution Focal Loss,进一步优化了模型性能^[21]。训练的数

据增强阶段, 引入了YOLOX算法中最后10个epoch关闭Mosaic增强的策略, 这一操作能够有效提升模型的精度^[22]。

1.2 YOLOv8n算法改进策略

由于在进行目标检测时, 检测目标中既包括尺寸较大的绝缘子串本身样本, 又包括尺寸较小的绝缘子缺陷, 两者尺寸相差较大, 为了改善模型对输电线路绝缘子缺陷的检测效果, 本文设计了PCFocalNeXt-C2f模块, 并用其对YOLOv8n算法进行优化, 该模块可以更好地融合细粒度的局部交互和粗粒度的全局交互, 提升模型对多尺度特征的提取能力和对小目标的检测能力; 其次使用支持在非相邻层次上直接交互作用的渐近金字塔网络(AFPN), 对YOLOv8n的Neck进行优化, 解决检测目标的特征在多级传输中的信息丢失或退化问题; 最后将YOLOv8n原始的损

失函数CIoU替换为Sigmoid-CIoU, 并采用Sigmoid-CIoU NMS获取检测结果, 进一步提升模型的检测性能。具体改进内容如下。

1.2.1 FocalNeXt-C2f模块

PConv模块是一种同时减少冗余计算和内存访问, 并且可以有效地提取空间特征的模块。如图2所示, PConv仅在输入通道的一部分上应用常规卷积进行空间特征提取, 同时保持其余通道不变, 对于连续或规则的内存访问, 将第一个或最后一个连续的通道视为整个特征图的代表进行计算, 确保在不损失一般性的前提下, 使输入和输出特征图具有相同数量的通道^[23]。

PConv的浮点运算次数为:

$$h \times w \times k^2 \times c_p \quad (1)$$

PConv的内存访问量为:




图1 YOLOv8n网络结构

Fig. 1 YOLOv8n network structure




图2 PConv模块
Fig. 2 PConv module

$$h \times w \times 2c_p + k^2 \times c_p^2 \approx h \times w \times 2c_p \quad (2)$$

式中: h 和 w 分别为特征图的高度和宽度; k 为卷积核的大小; c_p 为进行常规卷积操作的通道数量。

PConv进行常规Conv操作的通道只占总输入通道的1/4,故PConv的FLOPs只有常规Conv的1/16。此外,PConv的内存访问量较小,其仅为常规Conv的1/4。本文在使用PConv时为了进一步降低其参数量,在对1/4的输入通道进行常规卷积操作时引入了分组卷积,设置参数groups的值等于进行常规卷积的通道数量。

Focal NeXt block^[24]是CFNet网络中设计的一种聚焦块,该模块通过利用全局注意力或大卷积核来扩大感受野,从而在处理大尺寸输入图像时获得更好的性能,其目的是同时融合细粒度的本地交互和粗粒度的全局交互,这使得Focal NeXt block可以更深入有效地融合多尺度特征。如图3所示,图中 $d7 \times 7$ 层表示卷积核为 7×7 的深度卷积, n 为输出特征的通道数, r 为附加卷积的扩张速率, 1×1 层表示卷积核为 1×1 的用来改变通道数的Linear层,LayerNorm层表示进行归一化处理,GELU层表示激活函数高斯误差线性单位。




图3 Focal NeXt block 结构图
Fig. 3 Focal NeXt block structure diagram

Focal NeXt block模块通过融合细粒度和粗粒度的交互来改善预测任务的性能,它通过引入扩展深度卷积和跳跃连接,在保持计算效率的同时融合不同尺度的特征,从而提高了图像处理的效果。

本文设计的PCFocalNeXt-C2f模块如图4所示,

该结构在C2f模块的第一个CBS模块之前和最后一个CBS模块之后各加一个PConv用于提高其特征提取的能力,并使用Focal NeXt block替换C2f模块中的Bottleneck,该模块使模型可以更好地融合细粒度的局部交互和粗粒度的全局交互,有效防止了小目标信息在特征提取时丢失,提高模型对多尺度特征的提取能力和对小目标的检测能力,同时具有更低的参数量。该改进大幅提高了模型对绝缘子缺陷的检测精度。




图4 PCFocalNeXt-C2f模块结构图
Fig. 4 PCFocalNeXt-C2f module structure diagram

1.2.2 渐近金字塔网络(AFPN)

原始YOLOv8n的Neck部分采用的是PAFPN结构,该结构在FPN的基础上增加了自底向上的路径。具体而言,从最低层开始直至最高层,逐步融合当前层与上一层的特征,从而生成增强后的多尺度特征图,新增的自底向上路径作为FPN的补充,有效提升了低层信息向上层传递的能力,进而增强了整体特征金字塔的定位表达能力^[25]。同时,PAFPN结构的自底向上路径也带来了新的问题,即在传播和交互过程中,来自低级特征的详细信息可能会丢失或退化。

渐近金字塔网络(AFPN)结构如图5所示,黑色箭头表示卷积,青色箭头表示适应性空间特征融合。AFPN通过融合相邻的低级特征,并逐步引入高级特征,有效避免了非相邻级别间的显著语义差异,该结构促进了不同层次间的直接交互作用^[23]。针对融合过程中可能出现的多对象信息冲突问题,AFPN采用了自适应空间特征融合技术,以缓解这些不一致性。

AFPN中主要包括CBS模块、BasicBlock模块以及ASFF模块。其中CBS模块主要用于将输入特征图进行通道维度的切分和扩张操作,以增加模型的感受野和有效地提取特征图的信息;BasicBlock模块,主要用于减少参数量,使模型可以更加有效、




图5 渐近金字塔网络(AFPN)结构图

Fig. 5 Asymptotic feature pyramid network (AFPN) structure diagram

直观地进行特征提取；ASFF模块用于融合多个不同层次的特征图，通过动态地选择和融合多层特征图，使得网络能够更好地捕捉目标的多尺度信息。

渐近特征金字塔网络(AFPN)在主干自下而上特征提取过程中分为两个阶段，在第一阶段融合两个不同分辨率的低层次特征(即通过卷积模块初步提取后的特征)，随着进入后期阶段，逐渐将高级特征(即在较低层次特征的基础上通过卷积模块再次提取后的特征)融入到融合过程中，最终与主干的顶部特征(即主干网络最后一层卷积模块提取后的特征)进行融合。这种融合方法可以避免非相邻层次之间存在较大的语义差距，在此过程中，将来自低级特征与高级特征的语义直接交互作用，避免了多级传输中的信息丢失或退化。在整个特征融合过程中，利用自适应空间特征融合操作对多层次融合过程中的特征进行过滤，从而抑制不同层次特征之间的信息矛盾。

1.2.3 Sigmoid-CIoU 损失函数

损失函数是衡量模型预测值与真实值差异程度的关键运算工具，其值越小表示预测信息越接近期望结果。该函数主要应用于模型训练阶段，每当一批训练数据输入模型后，通过前向传播生成预测值；随后，利用损失函数计算预测值与实际值之间的偏差，即损失值。基于此损失值，模型采用反向传播机制调整内部参数，旨在减少真实值与预测值间的差距，促使模型输出更加贴近实际情况，进而实现学习目标。为了使预测值无限接近于真实值，需要将损失值降到最低，所以针对不同的检测任务选择合适的损失函数十分关键。

YOLOv8n模型采纳了CIoU作为其核心损失函数，该函数在DIoU的基础上进行了深度优化。通

过引入预测框与真实框长宽比的差异考量，CIoU显著提升了目标检测的精度与效率。值得注意的是，DIoU存在一个明显的局限性：当真实框与预测框的中心点重合时，即便它们的长宽比存在差异，交并比却保持不变。为了解决这一问题，CIoU引入了一个额外的惩罚项，以更精确地衡量预测框与真实框之间的差异^[26]。

CIoU 损失函数 L_{CIoU} 定义为：

$$L_{\text{CIoU}} = 1 - I_{\text{oU}} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \alpha v \quad (3)$$

$$\alpha = \frac{v}{1 - I_{\text{oU}} + v} \quad (4)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{w}{h} \right)^2 \quad (5)$$

式中： I_{oU} 为真实框和预测框的交并比； b 和 b^{gt} 分别为预测框和真实框的中心点； ρ 为计算两个中心点间的欧式距离； c 为能够同时覆盖目标框和真实框的最小矩形的对角线距离； α 为权重函数； v 为长宽比的相似度； w^{gt} 和 h^{gt} 分别为真实框的宽度和高度。

CIoU 损失函数中的 v 项，通过反正切函数构建矩形框长宽比的惩罚机制。然而，该设计存在鲁棒性不足的问题，对异常值高度敏感，导致损失函数值波动加剧，进而影响其整体性能。此外，反正切函数的值域限制在 $(0, \pi/2)$ 之间，无法直接满足损失函数的规范化需求。为解决这一问题，需引入额外系数以实现惩罚项的数值归一化，但这无疑增加了计算的复杂度。而 Sigmoid-CIoU^[25]可以解决上述问题。

Sigmoid-CIoU 损失函数定义为：

$$L_{\text{Sigmoid-CIoU}} = 1 - I_{\text{oU}} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \beta \theta \quad (6)$$

$$\beta = \frac{\theta}{1 - I_{\text{oU}} + \theta} \quad (7)$$

$$\theta = \left(\frac{1}{1 + e^{-\frac{w^{\text{gt}}}{h^{\text{gt}}}}} - \frac{1}{1 + e^{-\frac{w}{h}}} \right)^2 \quad (8)$$

式中： β 为权重函数； θ 为长宽比的相似度。

Sigmoid-CIoU 的 θ 项使用 Sigmoid 函数形成矩形框长宽比的惩罚项，这使得 Sigmoid-CIoU 的 θ 项比 CIoU 的 v 项更加的平稳和光滑，其函数输出值为 $(0, 0.25)$ ，直接满足了规范化需求。这一改进不仅简化了原始损失函数的复杂度，还显著提升了回归过程中的收敛速度、定位精度及整体模型性能。

能^[27]。并采用Sigmoid-CIoU NMS去除检测图像中的无效目标框,降低模型对所有检测目标的误识率,提高模型的鲁棒性。

改进后YOLOv8n算法如图6所示,使用本文设计的PCFocalNeXt-C2f模块对YOLOv8n的Backbone进行优化,使用AFPN对YOLOv8n的Neck进行优化,使用Sigmoid-CIoU对YOLOv8n的损失函数进行优化,并采用Sigmoid-CIoU NMS获取检测结果。

2 数据集的构建及评价指标

2.1 数据集和实验环境

本文针对绝缘子缺陷制作了一个新的数据集,数据集中包含4种检测目标,即绝缘子自爆(explosion)、绝缘子破损(breakage)、绝缘子闪络痕迹(flashover)和绝缘子串(insulator)。通过收集共获得原始图片数据690张,按8:1:1的比例将原始数据划分为训练集、验证集以及测试集。使用数据增强的方法包括加噪声、调整亮度、裁剪、旋转、平移、镜像等方式,模拟巡检过程中因环境气候或

拍摄角度等因素所导致的巡检图像质量下降,并将原始的690张图像数据扩充为4140张。

本文实验使用的服务器操作系统为Ubuntu 20.04.6 LTS,硬件配置CPU为Intel(R) Xeon Gold 6133、GPU为NVIDIA GeForce RTX 4090,软件环境为CUDA11.8.89和Python3.9,使用的深度学习框架为pytorch2.0.1。

进行模型训练时,设置输入图像尺寸(imgsz)为640×640,批量(batch)为64,训练周期(epochs)为300,进程数(workers)为32,使用的优化器(optimizer)为SGD,初始学习率(lr0)和最终学习率(lrf)均为0.01。

2.2 模型评价指标

本文使用准确率Precision、召回率Recall、F1值、低质量模型精度指标mAP@0.5和高质量模型精度指标mAP@0.5-0.95来评价模型的检测性能,使用参数量Parameters来评价模型的大小,使用FPS来评价模型的检测速度。准确率Precision为预测为正确的数据中真实值为正确的比例,其值用 $S_{Precision}$ 表示;召回率Recall表示查全率,即预测出




图6 改进后YOLOv8n网络结构

Fig. 6 Improved YOLOv8n network structure

来的正确类别框的概率,其值用 S_{Recall} 表示; F1 值表示调和平均值,用来平衡准确率和召回率的指标; $\text{mAP}@0.5$ 表示 IoU 阈值为 0.5 时的所有检测类别的平均检测精度; $\text{mAP}@0.5-0.95$ 表示 IoU 阈值以 0.05 为步长从 0.5 增加到 0.95 时的 10 个 mAP 值的平均值,该指标相较于只考虑 IoU 阈值为 0.5 时的 $\text{mAP}@0.5$ 更能体现出模型的精度; Parameters 表示模型含有的参数量, FPS 表示每秒帧率。上述指标计算公式如下。

$$S_{\text{Precision}} = \frac{T_p}{T_p + F_p} \quad (9)$$

$$S_{\text{Recall}} = \frac{T_p}{T_p + F_N} \quad (10)$$

$$F_1 = \frac{2 \times S_{\text{Precision}} \times S_{\text{Recall}}}{S_{\text{Precision}} + S_{\text{Recall}}} \quad (11)$$

$$A_p = \int_0^1 P(r) dr \quad (12)$$

$$m_{\text{AP}} = \frac{\sum_{i=1}^C AP_i}{C} \quad (13)$$

式中: T_p 为正样本被正确识别的数量; F_p 为正样本未被识别的数量; F_N 为未被识别的负样本数量; A_p 为平均精度; r 为召回率; $P(r)$ 表示将 PR 曲线经过平滑处理; C 为数据集类别数; P_i 为第 i 个类别的准确率。

3 实验结果分析

3.1 PCFocalNeXt-C2f 模块对网络性能的影响

为了验证 PCFocalNeXt-C2f 模块在 YOLOv8n 中不同位置的效果,设计了如表 1 所示的对比试验。

表 1 PCFocalNeXt-C2f 模块不同位置对比结果

Tab. 1 Comparison results of different positions of

算法	PCFocalNeXt-C2f module				%
	Precision 值	Recall 值	mAP 值@0.5	mAP 值@0.5-0.95	
YOLOv8n	97.9	88.3	93	73.5	
In-all	98.5	89.3	94.3	76.4	
In-neck	96.8	89.8	93.6	73.4	
In-backbone	98.1	91.2	94.5	76.5	

In-all、In-neck 分别表示将 YOLOv8n 中所有的 C2f 模块、neck 中所有的 C2f 模块替换为 PCFocalNeXt-C2f 模块; In-backbone 为本文所使用的方法,表示将 backbone 中所有 C2f 模块替换为 PCFocalNeXt-C2f 模块。实验结果表明相较于 In-all

和 In-neck, In-backbone 具有更好的表现,可以使模型性能得到明显提升,这是由于 backbone 中 C2f 主要用于网络的特征提取,而 PCFocalNeXt-C2f 模块可以融合细粒度的本地交互和粗粒度的全局交互,具有更强的特征提取能力,能够很好的提取多尺度特征,防止小目标特征的丢失。因此将 PCFocalNeXt-C2f 模块引入到 backbone 中可以很好地提升模型性能,而 YOLOv8n 的 neck 部分主要用于更好融合和提取 backbone 传来的特征图,而 neck 中的 C2f 模块后为不同尺度的检测头,由于已经获得足够的信息用于目标检测,因此进一步加强其特征提取能力并不能有效地提升模型检测性能。

为了验证 PCFocalNeXt-C2f 模块对 YOLOv8n 性能的影响,比较了将 PCFocalNeXt-C2f 模块引入到 YOLOv8n 的 backbone 前后,平均检测精度的变化,平均检测精度的对比曲线如图 7 所示。




图 7 引入 PCFocalNeXt-C2f 模块前后平均检测精度对比曲线

Fig. 7 Average detection accuracies comparison curves before and after the introduction of PCFocalNeXt-C2f module

由图 7 可知,在当模型训练到 50 次以后,引入 PCFocalNeXt-C2f 模块后的 YOLOv8n 算法在 $\text{mAP}@0.5$ 方面始终优于原始 YOLOv8n 算法;当模型训练到 60 次以后,引入 PCFocalNeXt-C2f 模块后的 YOLOv8n 算法在 $\text{mAP}@0.5-0.95$ 方面始终优于原始 YOLOv8n 算法。这是由于 PCFocalNeXt-C2f 模块可以有效防止小目标信息在特征提取时丢失,提高模型对多尺度特征的提取能力和对小目标的检测能力,将 PCFocalNeXt-C2f 模块引入到 YOLOv8n 的 backbone 中可以明显地提升 YOLOv8n 网络的检测性能。

3.2 AFPN对网络性能的影响

为了验证渐近金字塔网络(APFN)对YOLOv8n性能的影响,比较了引入APFN前后YOLOv8n算法平均检测精度的变化,平均检测精度的对比曲线如图8所示。




图8 引入APFN前后平均检测精度对比曲线

Fig. 8 The average detection accuracy comparison curves before and after the introduction of AFPN

由图8可知,引入APFN前后的YOLOv8n算法的map@0.5分别稳定在93%和94%,当模型训练到120次以后,引入APFN后的YOLOv8n算法在map@0.5方面始终优于原始YOLOv8n算法;引入APFN前后的YOLOv8n算法的mAP@0.5-0.95分别稳定在73.5%和75%,当模型训练到100次以后,引入APFN后的YOLOv8n算法在mAP@0.5-0.95方面始终优于原始YOLOv8n算法。这是由于APFN可以防止多级传输中的信息丢失或退化,引入APFN可以很好地提升YOLOv8n网络的检测性能。

3.3 不同损失函数对网络性能的影响

本文选择Sigmoid-CIoU、EIoU、GIoU、DIOU、SIOU几种不同的损失函数与YOLOv8n原始的损失函数CIoU进行对比实验,Y+(CIoU)、Y+(EIoU)、Y+(SIOU)、Y+(GIoU)、Y+(DIOU)、Y+(Sigmoid-CIoU)分别表示将相应的损失函数引入到YOLOv8n中,验证不同损失函数对网络性能的影响。实验结果如表2所示,实验结果表明相较于YOLOv8n的原始损失函数和其他的几种损失函数,将Sigmoid-CIoU引入YOLOv8n中可以更好地提升网络性能。

为了进一步验证Sigmoid-CIoU损失函数对YOLOv8n性能的影响,比较了引入Sigmoid-CIoU

表2 不同损失函数结果对比

Tab. 2 Comparison of different loss function results %

算法	Precision 值	Recall 值	mAP 值@ 0.5	mAP 值@ 0.5-0.95
Y+(CIoU)	97.9	88.3	93	73.5
Y+(EIoU)	97.8	89.4	94	74.1
Y+(SIOU)	97	88.6	93.6	73.1
Y+(GIoU)	97.7	90.4	93.9	74.5
Y+(DIOU)	97.6	90.3	92.6	73.5
Y+(Sigmoid-CIoU)	98.3	91.1	95.3	75.3

损失函数前后YOLOv8n算法的平均检测精度的变化,平均检测精度的对比曲线如图9所示。由图9可知,在当模型训练到20次以后,引入Sigmoid-CIoU损失函数后的YOLOv8n算法在mAP@0.5方面始终优于原始YOLOv8n算法;当模型训练到60次以后,引入Sigmoid-CIoU损失函数后的YOLOv8n算法在mAP@0.5-0.95方面始终优于原始YOLOv8n算法,说明了将Sigmoid-CIoU损失函数引入到YOLOv8n中可以获得更快的收敛速度、更好的定位结果和模型性能。




图9 引入Sigmoid-CIoU前后平均检测精度对比曲线

Fig. 9 The average detection accuracy comparison curves before and after the introduction of Sigmoid-CIoU

3.4 消融实验对比

为了验证本文改进算法的有效性,建立了如表3所示的消融实验。

其中组别1为初始的YOLOv8n算法;组别2、组别3、组别4分别为将PCFocalNeXt-C2f模块、APFN、Sigmoid-CIoU分别引入到YOLOv8n后的算法;组别5为将PCFocalNeXt-C2f模块和APFN引入到YOLOv8n后的算法;组别6为将

表 3 消融实验结果

Tab. 3 Ablation experimental results

组别	PCFocalNeXt-C2f	AFPN	Sigmoid-CIoU	准确度值/%	Recall 值/%	F_1 值/%	mAP@0.5/%	mAP@0.5-0.95/%	Parameters/M
1				97.9	88.3	92.7	93	73.5	3.01
2	√			98.1	91.2	94.5	94.5	76.5	2.87
3		√		98	90	93.8	94	75	2.42
4			√	98.3	91.1	94.6	95.3	75.3	3.01
5	√	√		98.8	90.3	94.4	95.2	77.2	2.29
6	√		√	98.2	93.6	95.8	96.1	78.4	2.87
7		√	√	98.6	90.5	94.4	94.7	76.6	2.42
8	√	√	√	98.7	93.5	96	96.8	79.6	2.29

PCFocalNeXt-C2f 模块和 Sigmoid-CIoU 引入到 YOLOv8n 后的算法；组别 7 为将 AFPN 和 Sigmoid-CIoU 引入到 YOLOv8n 后的算法；组别 8 为本文提出的算法，表示将 PCFocalNeXt-C2f 模块、AFPN、Sigmoid-CIoU 引入到 YOLOv8n 后的算法。

实验结果表明，改进后的各个算法的检测精度均高于原始的 YOLOv8n 模型，证明了本文设计的 PCFocalNeXt-C2f 模块的有效性，同时也证明了引入的 AFPN 和 Sigmoid-CIoU 的有效性。通过比较本文算法（组别 8）和初始 YOLOv8n 算法（组别 1）可知，本文提出的算法相较于原始的 YOLOv8n 算法，召回率提高了 5.2%， F_1 值提升了 3.3%，mAP@0.5 和 mAP@0.5-0.95 分别提高了 3.8% 和 6.1%，参数量降低了 23.9%，证明了本文的改进策略有效地提高了 YOLOv8n 网络对电力绝缘子缺陷的检测性能。

为了进一步验证本文改进算法的有效性，比较了改进前后 YOLOv8n 算法的平均检测精度的变化，平均检测精度的对比曲线如图 10 所示。

由图 10 可知，在当模型训练到 30 次以后，改进后的 YOLOv8n 算法在 mAP@0.5 方面始终优于原始 YOLOv8n 算法；当模型训练到 40 次以后，改进后的 YOLOv8n 算法在 mAP@0.5-0.95 方面始终优于原始 YOLOv8n 算法，说明了本文的改进策略可以明显提升 YOLOv8n 网络的检测性能。

3.5 实际应用检测效果评价

图 11 与图 12 分别为改进前后 YOLOv8n 算法的实际检测效果，其中改进前 YOLOv8n 算法检测效果的图 11-12(a) 和 (b) 中各有一处较小的绝缘子破损缺陷未被检测出，而改进后 YOLOv8n 算法检测效果的图 11-12(a) 和 (b) 中能够识别出该处的绝缘




图 10 改进前后 YOLOv8n 算法平均检测精度对比曲线
Fig. 10 Average detection accuracies comparison curve of YOLOv8n algorithm before and after improvement

子破损缺陷；改进前 YOLOv8n 算法检测效果的图 11-12(c) 中有一处较小的绝缘子自爆缺陷未被检测出，而改进后 YOLOv8n 算法检测效果的图 11-12(c) 中能够识别出该处的绝缘子自爆缺陷；改进前 YOLOv8n 算法检测效果的图 11-12(d) 中有一处较小的绝缘子闪络痕迹缺陷未被检测出，而改进后 YOLOv8n 算法检测效果的图 11-12(d) 中能够识别出该处的绝缘子闪络痕迹。结果表明，本文改进后的算法相较于初始的 YOLOv8n 算法具有更优越的检测性能，能够更加准确地识别出绝缘子缺陷目标。

由于机巡图像易受环境影响，为了验证本文算法在强光、浓雾、大雨、大雪等恶劣天气下的检测效果，本文使用数据增强的方法对待检测的巡检图片进行处理，从而得到强光、大雪、大雨和大雾天气下的样本图片，并使用本文提出的算法对上述恶劣天气下的样本图片进行检测，检测结果如图 13 所示。




图11 改进前YOLOv8n算法实际检测效果

Fig. 11 Actual detection results of the YOLOv8n algorithm before improvement




图12 改进后YOLOv8n算法实际检测效果

Fig. 12 Actual detection results of the improved YOLOv8n algorithm




图13 改进后YOLOv8n算法恶劣天气下的检测效果

Fig. 13 Detection effect of the improved YOLOv8n algorithm in extreme weather

本文改进后的YOLOv8n算法可以准确的检测出恶劣天气下的绝缘子缺陷,与改进后YOLOv8n算法在正常天气下的检测效果即图12(b)相比,本文改进后的YOLOv8n算法在强光、大雪、大雨和大雾天气下对图中较大的绝缘子破损缺陷的检测精度没有产生明显影响,由原先的78%分别变为78%、80%、77%和84%,而在强光、大雪、大雨和大雾天气下对图中较小的绝缘子破损缺陷的检

测精度有所下降,由原先的78%分别降低到了67%、71%、69%和68%,这是由于小缺陷的特征较少,在极端天气下受到天气因素的影响较大,使得算法对缺陷特征的提取不够充分,从而使得算法对小缺陷的识别精度下降。但相较于改进前YOLOv8n算法在正常天气下的检测效果即图11(b),改进前YOLOv8n算法不能识别出图中较小的绝缘子破损缺陷,而本文改进后的YOLOv8n算法

在恶劣天气下仍能较为准确的检测出图中较小的绝缘子缺陷，证明了本文改进后的 YOLOv8n 算法在恶劣天气下仍具有较好的检测性能。

为了进一步验证本文算法对各检测类别的检测效果，比较了改进前和改进后算法对每种检测类别的检测结果，如表 4—5 所示。

表 4 YOLOv8n 算法各类别检测结果
Tab. 4 Detection results of each category of YOLOv8n algorithm %

检测类型	Precision 值	Recall 值	mAP@0.5	mAP@0.5-0.95
自爆	97.6	85.6	91.1	66.8
破损	97.4	79.5	89.4	64.9
闪络	97	88.3	92.3	67.6
绝缘子	99.6	99.8	99.3	94.8

表 5 改进后 YOLOv8n 算法各类别检测结果
Tab. 5 Detection results of each category of the improved YOLOv8n algorithm %

检测类型	Precision 值	Recall 值	mAP@0.5	mAP@0.5-0.95
自爆	98.2	89.6	96.5	73.9
破算	97	90.8	94.8	74.2
闪络	96.3	93.4	96.6	73.8
绝缘子	99.4	100	99.5	96.6

实验结果表明，本文算法在各个检测类别上的平均检测精度均高于原始算法，其中对绝缘子自爆、绝缘子破损和绝缘子闪络 3 种缺陷的检测效果的提升最为明显。与原始的 YOLOv8n 算法相比，绝缘子自爆的 Recall、mAP@0.5 和 mAP@0.5-0.95 分别提

升了 4 %、5.4 % 和 7.1 %，绝缘子破损的 Recall、mAP@0.5 和 mAP@0.5-0.95 分别提升了 11.3 %、5.4 % 和 9.3 %，绝缘子闪络的 Recall、mAP@0.5 和 mAP@0.5-0.95 分别提升了 5.1 %、4.3 % 和 6.2 %。这是由于数据集中这 3 种缺陷数据中含有大量的小目标，原始的算法并不能很好的对这些小目标进行识别，而本文算法大大提升了模型对多尺度特征的提取能力，避免缺陷特征的丢失或退化，很好地提升了算法对这 3 种缺陷的检测效果。

3.6 不同算法检测结果比较

为了验证本文算法检测效果的优越性，使用本文构建的数据集比较了本文算法与其他主流目标检测算法的检测性能，实验结果如表 6 所示。

使用本文算法与两阶段算法 Faster-RCNN 和单阶段算法 SSD、CenterNet、RetinaNet、YOLOv4、YOLOr、YOLOv5n、YOLOv7tiny、YOLOv8n 等算法进行比较，由图 14 和图 15 不同算法平均检测精度对比曲线可知，本文改进后的 YOLOv8n 算法的平均检测精度明显高于其他几种算法，由表 6 实验数据可知，相较于其他几种算法，本文算法具有更高的检测性能，本文算法的 F1 值、mAP@0.5 和 mAP@0.5-0.95 分别达到了 96 %、96.8 % 和 79.6 %，且模型参数量仅为 2.29MB，改进后的 YOLOv8n 算法的 FPS 达到了 72，满足实际需求。

4 结论

针对输电线路绝缘子缺陷识别时缺陷特征容易丢失，导致精度低且误识率高的问题，提出了一种基于改进 YOLOv8n 的输电线路绝缘子缺陷检测方

表 6 不同算法检测结果对比
Tab. 6 Comparison of detection results of different algorithms

算法	检测精度值/%	Recall 值/%	F_1 /%	mAP@0.5/%	mAP@0.5-0.95/%	Parameters/M	FPS
Faster-RCNN	96.2	90.2	93.1	94.1	74.2	28.32	35
SSD	96.3	82.6	88.9	87	66.3	12.13	79
CenterNet	89.2	79.6	84.1	82.3	59.4	15.22	70
RetinaNet	92.4	80.1	85.8	84.6	62.7	36.3	68
YOLOv4-csp	94.9	88.9	91.8	92.9	65.7	9.12	82
YOLOr-csp	96.1	89.9	92.9	93.4	68.3	9.13	69
YOLOv5n	96.3	88	91.9	92.5	70.4	1.77	93
YOLOv7-tiny	97.5	89	93.1	94	67.8	6.02	53
YOLOv8n	97.9	88.3	92.7	93	73.5	3.01	85
本文算法	98.7	93.5	96	96.8	79.6	2.29	72




图14 不同算法mAP@0.5对比曲线

Fig. 14 mAP@0.5 comparison curves of different algorithms




图15 不同算法mAP@0.5-0.95对比曲线

Fig. 15 mAP@0.5-0.95 comparison curves of different algorithms

法,主要结论如下。

1)本文设计的PCFocalNeXt-C2f模块可以很好地融合细粒度的局部交互和粗粒度的全局交互,解决了小目标绝缘子缺陷特征丢失问题,提高了模型对多尺度特征的提取能力和小目标的检测能力,使改进后的YOLOv8n算法更适用于输电线路绝缘子缺陷的检测。

2)使用渐近金字塔网络(AFPN)对YOLOv8n的Neck进行优化,AFPN支持在非相邻层次上的直接交互作用,将非相邻层次上的特征进行融合,避免了多级传输中的信息丢失或退化问题,使改进后的YOLOv8n算法可以更好地提取绝缘子缺陷特征。

3)相较于原始YOLOv8n算法使用的损失函数CIoU,本文算法所使用的损失函数Sigmoid-CIoU,

可以使改进后的YOLOv8n算法获得更好的定位结果和模型性能,并采用Sigmoid-CIoU NMS去除检测图像中的无效目标框,降低模型对检测目标的误识率,提高模型的鲁棒性。

4)本文提出的算法相较于原始的YOLOv8n算法具有更高的检测性能,其中F1值提高了3.3%,平均检测精度mAP@0.5和mAP@0.5-0.95分别提高了3.8%和6.1%,参数量降低了23.9%,说明了本文设计的PCFocalNeXt-C2f模块以及引入的AFPN和损失函数Sigmoid-CIoU可以很好地提高模型的检测性能。

参考文献

- [1] 刘传洋,吴一全,刘景景.无人机航拍图像中电力线检测方法研究进展[J].中国图象图形学报,2023,28(10):3025-3048.
LIU Chuanyang, WU Yiquan, LIU Jingjing. The growth of UAV aerial images-related power lines detection: a literature review of 2023[J]. Journal of Image and Graphics, 2023, 28(10): 3025-3048.
- [2] 尤敏,徐祥海,田易之,等.基于多尺度特征融合的输电线路故障检测算法[J].南方电网技术,2025,19(12):124-134.
YOU Min, XU Xianghai, TIAN Yizhi, et al. Transmission line fault detection algorithm based on multi-scale feature fusion[J]. Southern Power System Technology, 2025, 19(12): 124-134.
- [3] 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.
- [4] 刘开培,李博强,秦亮,等.深度学习目标检测算法在架空输电线路绝缘子缺陷检测中的应用研究综述[J].高电压技术,2023,49(9):3584-3595.
LIU Kaipei, LI Boqiang, QIN Liang, et al. Review of application research of deep learning object detection algorithms in insulator defect detection of overhead transmission lines[J]. High Voltage Engineering, 2023, 49(9): 3584-3595.
- [5] 刘传洋,吴一全.基于深度学习的输电线路视觉检测方法研究进展[J].中国电机工程学报,2023,43(19):7423-7446.
LIU Chuanyang, WU Yiquan. Research progress of vision detection methods based on deep learning for transmission lines[J]. Proceedings of the CSEE, 2023, 43(19): 7423-7446.
- [6] 杨泽青,张明轩,陈英姝,等.基于机器视觉的表面缺陷检测方法研究进展[J].现代制造工程,2023(4):143-156.
YANG Zeqing, ZHANG Mingxuan, CHEN Yingshu, et al. Review of surface defect detection methods based on machine vision[J]. Modern Manufacturing Engineering, 2023(4): 143-156.
- [7] 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.
ZHAO Zhenbing, JIANG Zhigang, LI Yanxu, et al. Overview

- of visual defect detection of transmission line components[J]. Journal of Image and Graphics, 2021, 26(11): 2545 – 2560.
- [8] REDMON J, FARHADI A. Yolov3: An incremental improvement[DB/OL]. (2018 – 04 – 04). <https://arxiv.org/abs/1804.02767>.
- [9] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection [DB/OL]. (2023 – 04 – 23). <https://arxiv.org/abs/2004.10934>.
- [10] WANG C Y, YE H I H, LIAO H Y M. You only learn one representation: Unified network for multiple tasks [DB/OL]. (2021 – 05 – 10). <https://arxiv.org/abs/2105.04206>.
- [11] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 17 – 24, 2023, Vancouver, BC, Canada. New York: IEEE, 2023: 7464 – 7475.
- [12] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector [C]//Computer Vision – ECCV 2016: 14th European Conference, September 17, 2016, Amsterdam, The Netherlands. Berlin: Springer, Cham, 2016: 21 – 37.
- [13] 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.
- LI Ruisheng, ZHANG Yanlong, ZHAI Denghui, et al. Pin defect detection of transmission line based on improved SSD [J]. High Voltage Engineering, 2021, 47(11): 3795 – 3802.
- [14] 王宇博, 尚军利, 张烨, 等. 基于改进 YOLOv7 的实时输电导线缺陷检测方法[J]. 南方电网技术, 2023, 17(12): 127 – 134.
- WAHG Yubo, SHANG Junli, ZHANG Ye, et al. Real-time transmission wire defect detection method based on improved YOLOv7 [J]. Southern Power System Technology, 2023, 17(12): 127 – 134.
- [15] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23 – 28, 2014, Columbus, OH, USA. New York: IEEE, 2014: 580 – 587.
- [16] FASTER R. Towards real-time object detection with region proposal networks[J]. Advances in neural information processing systems, 2015, 9199(10.5555): 2969239 – 2969250.
- [17] REN S, HE K, 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.
- [18] 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.
- [19] 赵振兵, 李延旭, 甄珍, 等. 结合 KL 散度和形状约束的 Faster R-CNN 典型金具检测方法[J]. 高电压技术, 2020, 46(9): 3018 – 3026.
- ZHAO Zhenbing, LI Yanxu, ZHEN Zhen, et al. Typical fittings detection method with Faster R-CNN combining KL divergence and shape constraints [J]. High Voltage Engineering, 2020, 46(9): 3018 – 3026.
- [20] 李松, 史涛, 井方科. 改进 YOLOv8 的道路损伤检测算法[J]. 计算机工程与应用, 2023, 59(23): 165 – 174.
- LI Song, SHI Tao, JING Fangke. Improved road damage detection algorithm of YOLOv8 [J]. Computer Engineering and Applications, 2023, 59(23): 165 – 174.
- [21] 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.
- PEI Shaotong, ZHANG Xingyuan, HU Chenlong, et al. The defect detection method for cross-environment power transmission line based on the ER-YOLO Algorithm [J]. Transactions of China Electrotechnical Society, 2024, 39(9): 2825 – 2840.
- [22] 陈益方, 张上, 冉秀康, 等. 基于改进 YOLOv8 的 SAR 图像飞机目标检测算法[J]. 电讯技术, 2024, 64(8): 1206 – 1212.
- CHEN Yifang, ZHANG Shang, RAN Xiukang, et al. Aircraft target detection algorithm based on improved YOLOv8 in SAR image [J]. Telecommunication Engineering, 2024, 64(8): 1206 – 1212.
- [23] 袁红春, 陶磊. 基于改进的 Yolov8 商业渔船电子监控数据中鱼类的检测与识别[J]. 大连海洋大学学报, 2023, 38(3): 533 – 542.
- YUAN Hongchun, TAO Lei. Detection and identification of fish in electronic monitoring data of commercial fishing vessels based on improved Yolov8 [J]. Journal of Dalian Ocean University, 2023, 38(3): 533 – 542.
- [24] CHEN J, 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), June 17 – 24, 2023, Vancouver, Canada. New York: IEEE, 2023: 12021 – 12031.
- [25] ZHANG G, LI Z, LI J, et al. Cfnets: Cascade fusion network for dense prediction [DB/OL]. (2023 – 02 – 13). [2023 – 10 – 31]. <https://arxiv.org/abs/2302.06052v1>
- [26] YANG G, LEI J, ZHU Z, et al. AFPN: asymptotic feature pyramid network for object detection [C]//2023 IEEE International Conference on Systems, Man, and Cybernetics (SMC), October 1 – 4, 2023, Honolulu, Oahu, USA. New York: IEEE, 2023: 2184 – 2189.
- [27] ZHENG Z, 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.
- [28] YU J, WU T, ZHANG X, et al. An efficient lightweight SAR ship target detection network with improved regression loss function and enhanced feature information expression [J]. Sensors, 2022, 22(9): 3447.

收稿日期: 2024-05-10; 网络首发日期: 2024-11-30

作者简介:

王爽(1987), 男, 通信作者, 讲师, 博士, 研究方向为输变电设备智能运维和健康管理, wangshuang@ctgu.edu.cn;

李亚威(1998), 男, 硕士研究生, 研究方向为输变电设备故障诊断和图像处理;

阴酉龙(1989), 男, 高级工程师, 硕士, 研究方向为架空输电线路运维检修及无人机智能巡检等方面新技术研究。