

DOI: 10.13382/j.jemi.B2407642

# 基于轻量化改进 YOLOv8n 绝缘子自爆缺陷检测方法\*

刘 航 李 明 刘志坚 牛 犇 史智予

(昆明理工大学电力工程学院 昆明 650500)

**摘要:**及时检测绝缘子自爆缺陷对输电线路安全可靠运行具有重要意义。针对深度学习模型对具有小目标特征的绝缘子自爆缺陷检测能力不足、模型结构复杂等问题,提出了一种基于轻量化改进 YOLOv8n 输电线路绝缘子自爆检测方法。以 YOLOv8n 网络为基础模型,通过添加小目标检测模块来捕捉绝缘子自爆的小目标细节信息,提高其检测能力;进一步,引入 SIoU 损失函数,解决原始 CIoU 损失函数未考虑真实框与预测框之间的方向问题,增强目标定位准确性;最后,使用通道剪枝方法,对改进模型进行剪枝,去除模型冗余参数、减少浮点运算量,降低模型计算成本和复杂度。在构建的绝缘子自爆数据集上的实验结果表明,轻量化改进方法的平均准确性均值达到 97.1%,其浮点运算量和体积分别为 4.9 G FLOPS 和 1.82 MB,仅为原始模型的 60.5%和 29.7%,合理兼顾了绝缘子自爆检测的准确性和模型复杂性。在另一个输电线路巡检数据集中,本研究方法对其他类型的小目标检测准确性也较好,具有良好的推广应用前景。

**关键词:**电力巡检;深度学习;缺陷检测;绝缘子自爆;通道剪枝

**中图分类号:** TM93; TN911.73 **文献标识码:** A **国家标准学科分类代码:** 470.4

## Self-explosion defect detection method of insulator based on lightweight and improved YOLOv8n

Liu Hang Li Ming Liu Zhijian Niu Ben Shi Zhiyu

(Faculty of Electric Power Engineering, Kunming University of Science and Technology, Kunming 650500, China)

**Abstract:** Timely detection of insulator self-explosion defects is of great significance to the safe and reliable operation of transmission lines. Aiming at the problems such as insufficient detection ability of insulator self-explosion defect with small target characteristics and complex model structure of deep learning model, proposes a lightweight improved YOLOv8n insulator self-explosion detection method for transmission lines. Based on the YOLOv8n network model, a small target detection module is added to capture the details of the insulator self-exploding small target and improve its detection capability. Furthermore, SIoU loss function is introduced to solve the problem that the original CIoU loss function does not consider the direction between the real box and the predicted box, and the target positioning accuracy is enhanced. Finally, channel pruning method is used to prune the improved model, remove the redundant parameters of the model, reduce the floating point operations, and reduce the calculation cost and complexity of the model. The experimental results on the constructed insulator self-explosion data set show that the average accuracy of the lightweight improved method reaches 97.1%, and its floating point operations and volume are 4.9 G FLOPS and 1.82 MB respectively, which is only 60.5% and 29.7% of the original model, which reasonably balances the accuracy of insulator self-detonation detection and the complexity of the model. In another transmission line inspection data set, the proposed method also has good detection accuracy for other types of small targets, and has a good prospect of popularization and application.

**Keywords:** power inspection; deep learning; defect detection; insulator self-explosion; channel pruning

收稿日期: 2024-07-03 Received Date: 2024-07-03

\* 基金项目: 云南省重点研发计划(202303AA080002)、云南省基础研究计划面上项目(202401AT070356)、云南省基础研究计划青年项目(202201AU070086)资助

## 0 引言

绝缘子是高压输电系统中用于电隔离和支持电线的基本设备,由于绝缘子数量大、种类多、分布广,长期暴露在自然环境下,容易受到鸟害、污秽、高寒等恶劣环境影响,从而发生自爆等缺陷,影响输电线路的安全稳定运行<sup>[1-3]</sup>。因此,开展绝缘子缺陷检测对保证输电线路安全,提高电网可靠性具有重要意义<sup>[4-5]</sup>。

近年来,无人机(unmanned aerial vehicle, UAV)巡检技术在电力行业的普及,大大减轻了检测人员的负担<sup>[6]</sup>。然而,UAV 巡检势必产生海量的巡检图像,采用人工检测的方式识别巡检图像中的绝缘子缺陷,不仅会产生高昂的人力成本,而且检测效率低,容易造成漏检和错检<sup>[7-8]</sup>。

目前,深度学习技术被广泛应用于输电线路绝缘子缺陷自动检测领域,并取得了丰富的研究成果。基于深度学习目标检测模型可以分为两类。一类是两阶段目标检测模型,主要有 Faster RCNN (faster regions with convolutional neural networks)<sup>[9]</sup>, Mask RCNN<sup>[10]</sup> 等。例如文献[11]提出了一种结合改进 Faster RCNN 与深度推土距离(deep earth mover's distance, Deep EMD)的小样本绝缘子缺陷检测方法,在对小样本玻璃绝缘子自爆缺陷检测中取得很好的检测效果。文献[12]针对绝缘子自爆缺陷背景复杂、所占像素比例小的问题,对 Mask RCNN 进行改进,提高了其检测能力。另外一类是单阶段目标检测模型,包括 SSD (single shot multi-box detector)<sup>[13]</sup> 和 YOLO(you only look once)<sup>[14]</sup> 系列。文献[15]基于 SSD 网络进行改进,提出了一种基于多尺度特征融合的绝缘子缺陷检测网络,具有较好的检测性能和泛化能力。文献[16]引入参数量小、推理速度更快的 FasterNet 和 PConv 对 YOLOv5-s 主干特征提取网络进行改进,相对于改进前,改进后的模型检测平均准确性提升 5.67%,速度提升近一倍。文献[17]对 YOLOv8 目标检测模型进行了轻量化改进,最终提高了绝缘子放电严重程度评估的准确性和推理速度,分别达到 87.6% 和 58 Hz。YOLOv8 有 n、s、m、l 和 x 这 5 种变体,其中 YOLOv8n 为 YOLOv8 系列最小且准确性较高的模型。

目前深度学习方法的应用中面临着解决缺陷识别准确性和模型复杂性这一矛盾<sup>[18]</sup>。一方面,绝缘子自爆缺陷数据样本稀缺,并且存在像素比例小、背景复杂和线路遮挡等问题,这些因素使其对绝缘子自爆缺陷检测准确性较低<sup>[19]</sup>。另一方面,深度学习模型结构复杂、浮点运算量和模型体积大的特点,不利于其推广<sup>[20-22]</sup>。

针对上述问题,本研究提出一种轻量化改进的 YOLOv8n 绝缘子自爆缺陷检测方法。以 YOLOv8n 网络

为基础模型,通过添加小目标检测模块来捕捉绝缘子自爆的小目标细节信息,提高其检测能力;进一步,引入 Siou 损失函数,解决原始 CioU 损失函数真实框与预测框不匹配方向的问题,对网络进一步优化,增强目标定位准确性;最后,利用通道剪枝方法对改进后的模型进行剪枝,去除模型冗余参数、减少浮点运算量,实现模型的轻量化。通过构建的绝缘子自爆数据集进行实验,并与 3 种主流的基于深度学习目标检测模型和最新改进模型进行对比,验证了本文所提方法的有效性。在另一个输电线路巡检数据集中验证本研究方法的鲁棒性。

## 1 轻量化改进 YOLOv8n 原理

### 1.1 绝缘子自爆巡检图像特点分析

图 1 展示了 4 张绝缘子自爆巡检图像案例。由图可知,对绝缘子自爆缺陷进行检测时,面临着“小目标”的问题,包括自爆缺陷所占像素比例小、复杂背景干扰和线路遮挡等。小目标容易造成漏检和错检,降低检测结果的准确性,是设计目标检测网络中尤其需要重视的问题。



图 1 绝缘子自爆巡检图像案例

Fig. 1 Insulator self-explosion inspection image case

本研究针对绝缘子自爆“小目标”问题,通过以 YOLOv8n 网络为基础,添加小目标检测模块,改进损失函数,提升了其检测绝缘子自爆缺陷的能力,改进后的结构如图 2 所示,再进一步对改进后的模型进行轻量化,减少其浮点运算和模型体积。图 2 中红虚线框内为增加的小目标检测模块,K 为卷积核大小,S 为步幅。

### 1.2 原始的 YOLOv8n 模型

YOLOv8 是 Ultralytics 公司于 2023 年提出的目标检测模型,其 5 种变体对应的模型浮点运算量和模型体积如表 1 所示。其中 YOLOv8n 为 YOLOv8 系列体积和浮点运算量最小的模型<sup>[23]</sup>。

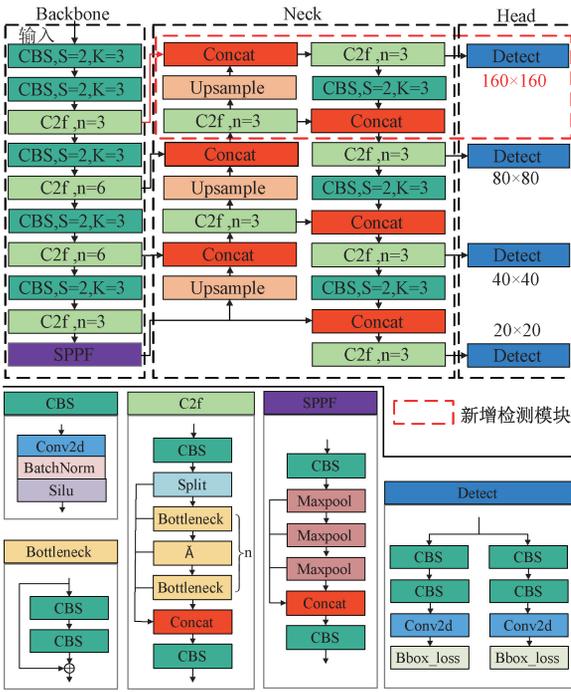


图 2 改进的 YOLOv8n 结构

Fig. 2 Improved YOLOv8n structure diagram

表 1 不同变体的 YOLOv8

Table 1 YOLOv8 in different variants

模型	浮点运算量/G FLOPS	模型体积/MB
YOLOv8n	8. 10	6. 13
YOLOv8s	28. 60	22. 05
YOLOv8m	78. 90	50. 90
YOLOv8l	165. 20	85. 71
YOLOv8x	257. 80	133. 66

由图 2 可知, YOLOv8n 结构由主干 (backbone)、颈部 (neck) 和头部 (head) 3 部分构成, 其结构和功能分别介绍如下。

主干网络主要进行特征提取, 采用 Darknet-53 框架, 并引入 C2f 模块, 将 CBS 卷积模块和 C2f 模块进行串行叠加, 在主干的末端仍然使用最流行的空间金字塔池化融合 (spatial pyramid pooling fusion, SPPF) 模块。

颈部网络主要进行特征融合, 采用路径聚合网络 (path aggregation networks, PAN) 和特征金字塔网络 (feature pyramid networks, FPN) 的结构, 能对不同尺度下的特征信息进行融合和利用, 实现自上向下和自下向上的特征金字塔, 大大提高预测框的产生速度, 节约计算成本。

头部网络主要对目标物体进行检测输出, 不再采用基于锚框的策略, 而是采用基于中心检测模型的无锚框 (anchor-free) 的检测方式, 直接检测物体的中心区域

和边界信息, 将分类和回归解耦为两个子网, 解决了不同尺寸的锚框数量不平衡导致检测效果差的问题。

### 1.3 小目标检测模块

原始 YOLOv8n 模型使用 3 个检测头进行检测, 输出的特征图尺寸分别为  $80 \times 80$ 、 $40 \times 40$  和  $20 \times 20$ , 这 3 个检测头分别对大于  $8 \times 8$ 、大于  $16 \times 16$  和大于  $32 \times 32$  的目标进行检测。然而, 由于绝缘子自爆缺陷尺寸较小, 其宽度和高度小于 8 pixels, 原始模型很难捕捉到自爆缺陷的特征信息, 而且微小物体的特征信息容易被较大的目标物体影响<sup>[24]</sup>。

针对“小目标”问题, 本研究通过在原始 YOLOv8n 模型的基础上增加小目标检测模块来提高小目标的检测能力, 相比于其他方法, 增加小目标检测模块有不丢失信息、对计算机算例和内存要求小、训练成本小等优势。通过对 YOLOv8n 模型添加小目标检测模块, 以提升 YOLOv8n 模型对绝缘子自爆缺陷的检测能力, 添加的小目标检测模块如图 2 右上角红色虚线框所示, 由颈部模块和头部模块组成。

颈部模块融合了原始网络颈部模块中的深层特征与主干网络中的浅层特征。融合流程如下: 首先在原始 YOLOv8n 颈部网络中, 将主干第 2 层 C2f 模块输出的  $80 \times 80$  尺寸特征图与颈部模块上采样层进行连接, 经过 C2f 模块和上采样模块得到具有包含丰富小目标特征信息的特征层; 进一步将得到的特征层与主干网络第 1 层 C2f 模块输出的  $160 \times 160$  尺寸的特征图进行通道维度上的融合, 以提高对具有小目标特征的绝缘子自爆表达能力, 最后经过一个 C2f 模块输出到头部模块。

在头部模块中添加一个针对小目标的检测头, 并将其连接到所添加的颈部模块。该头部模块可以获得更浅层和更高分辨率的特征图, 对小目标更敏感, 并对尺寸大于  $4 \times 4$  的目标进行检测, 与原始网络的 3 个检测头构成 4 个并联检测头结构, 使其更加关注像素值较小的绝缘子自爆缺陷, 从而提高绝缘子及自爆缺陷的检测准确性。

### 1.4 SIoU 损失函数的改进

YOLOv8n 采用 complete intersection over union (CIoU) 作为损失函数, 表达式如式 (1) ~ (5) 所示, 主要参数示意图如图 3 所示。

$$l_{CIoU} = 1 - l_{IoU} + \frac{\sigma^2}{c^2} + \tau v \quad (1)$$

$$\sigma = \sqrt{(b_{c_x}^{gt} - b_{c_x})^2 + (b_{c_y}^{gt} - b_{c_y})^2} \quad (2)$$

$$c = \sqrt{c_w^2 + c_h^2} \quad (3)$$

$$\tau = \frac{v}{(1 - l_{IoU}) + v} \quad (4)$$

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

式中:  $(b_{c_x}, b_{c_y})$  和  $(b_{c_x}^{gt}, b_{c_y}^{gt})$  分别表示预测框与真实框的中心点坐标;  $c_w$  和  $c_h$  分别表示两框最小外接框的宽和高;  $w$  和  $h$  表示预测框的宽和高;  $w^{gt}$  和  $h^{gt}$  表示真实框的宽和高;  $l_{IoU}$  为交并比损失。

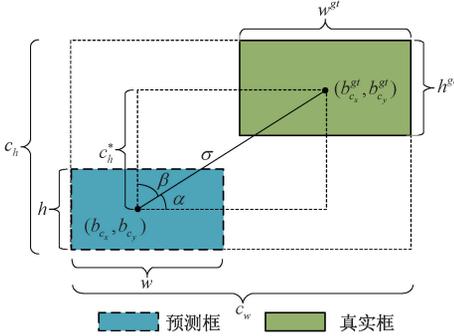


图 3 损失函数参数示意图

Fig. 3 Loss function parameter diagram

然而,使用 CIoU 做损失函数并没有考虑真实框与预测框之间不匹配的方向,导致模型收敛速度慢、准确性低。为了解决以上问题,研究引入 SIoU 作为损失函数,通过考虑预测框与真实框之间的角度对边界框回归的影响,并将角度损失引入到边界框回归损失函数中<sup>[25-26]</sup>,改进后的损失函数  $l_{SIoU}$  的定义如式(6)所示,涉及到的参数示意图如图 3 所示。

$$l_{SIoU} = 1 - l_{IoU} + \frac{\Delta + \Omega}{2} \quad (6)$$

式中:  $\Delta$  表示预测框与真实框的距离损失,  $\Omega$  是定义的形状损失,两种损失定义为:

1) 距离损失  $\Delta$  考虑了预测框与真实框之间的角度损失,定义如式(7)~(13)所示。

$$\Delta = \sum_{t=w,h} (1 - e^{-\xi \rho_t}) \quad (7)$$

$$\rho_w = \left( \frac{b_{c_x}^{gt} - b_{c_x}}{c_w} \right)^2 \quad (8)$$

$$\rho_h = \left( \frac{b_{c_y}^{gt} - b_{c_y}}{c_h} \right)^2 \quad (9)$$

$$\xi = 2 - \Lambda \quad (10)$$

$$\Lambda = 1 - 2 \times \sin^2(\arcsin u - \pi/4) \quad (11)$$

$$u = c_h^* / \sigma = \sin \alpha \quad (12)$$

$$c_h^* = \max(b_{c_y}^{gt}, b_{c_y}) - \min(b_{c_y}^{gt}, b_{c_y}) \quad (13)$$

式中:  $\Lambda$  表示 SIoU 损失函数考虑的角度损失;  $c_h^*$  表示真实框与预测框之间中心点高度差。

2) 形状损失  $\Omega$  描述了真实框和预测框的尺寸差异,定义如式(14)~(16)所示。

$$\Omega = \sum_{t=w,h} (1 - e^{-\omega_t})^\theta \quad (14)$$

$$\omega_w = \frac{|w - w^{gt}|}{\max(w, w^{gt})} \quad (15)$$

$$\omega_h = \frac{|h - h^{gt}|}{\max(h, h^{gt})} \quad (16)$$

式中:  $\theta$  的值控制了对形状成本的注意程度。

### 1.5 通道剪枝算法原理

由表 1 可以看出, YOLOv8n 模型的浮点运算数和模型体积分别为 8.10 G FLOPS 和 6.13 MB, 经过 1.3 和 1.4 节改进 YOLOv8n 模型分别为 12.50 G FLOPS 和 6.27 MB, 尽管改进的 YOLOv8n 模型的浮点运算量和模型体积仍远低于其他变体, 但在绝缘子缺陷检测应用中, 其仍然需要较大的存储空间和计算资源。

为了进一步减少模型复杂度, 降低浮点运算量并提高运行效率, 有必要对模型进行剪枝处理。通道剪枝可以分为结构化剪枝和非结构化剪枝, 通道剪枝是一种典型的结构化剪枝, 本文选用通道剪枝方法对改进后的 YOLOv8n 进行剪枝。

通道剪枝的流程图如图 4 所示, 该过程主要分为 3 个阶段: 稀疏训练, 利用 L1 范数应用于改进后的 YOLOv8n 模型的 BN 层缩放因子, 使模型通道稀疏; 剪枝, 对不重要的通道进行剪枝, 得到更小的模型; 微调, 剪枝后的模型检测准确性较低, 可以通过微调来恢复准确性。



图 4 通道剪枝的流程

Fig. 4 Flow chart of channel pruning

在通道剪枝算法中, YOLOv8n 模型的相邻卷积层之间采用批处理归一化 (batch normalization, BN), 加快了 YOLOv8n 模型的训练速度。归一化操作如式(17)和(18)所示。

$$y_{out} = \gamma \hat{y} + \beta \quad (17)$$

$$\hat{y} = \frac{y_{in} - \mu}{\sqrt{\zeta^2 - \varepsilon}} \quad (18)$$

式中:  $y_{in}$  和  $y_{out}$  分别表示经过正则化前后的输入和输出;  $\mu$  和  $\zeta$  分别表示 BN 层上激活函数输入的平均值和标准差;  $\gamma$  和  $\beta$  分别为缩放因子和偏差因子。

#### 1) 稀疏化训练

为了使用缩放因子  $\gamma$  来评估模型中每个通道的重要性, 首先对 YOLOv8n 模型使用稀疏性训练, 总损失函数如式(19)所示。

$$l = \sum_{(x,y)} l(f(x, \mathbf{W}), y) + \lambda \sum_{\gamma \in \Gamma} g(\gamma) \quad (19)$$

式中: 第 1 项是网络训练的损失项, 第 2 项表示对缩放因子进行 L1 正则化的稀疏处理;  $x$  和  $y$  分别为训练的输入

和目标;  $W$  为网络中的训练权重;  $g(\cdot)$  代表稀疏训练的惩罚项,  $\lambda$  是稀疏正则化系数。

缩放因子用于识别重要通道。通过选择合适的缩放因子, 保留重要的通道, 删除贡献较小的通道, 如图 5 所示。

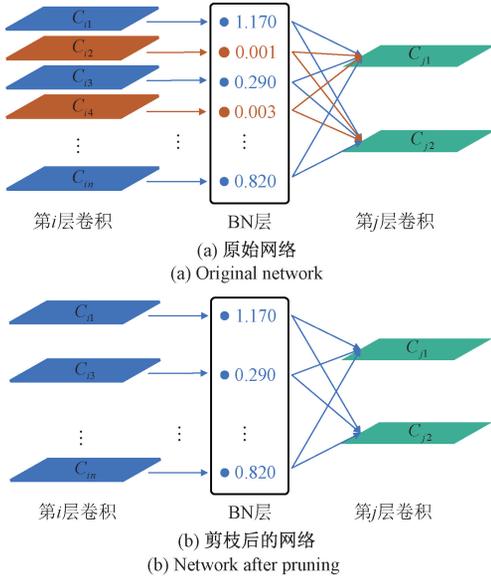


图 5 通道剪枝原理

Fig. 5 Channel pruning schematic

稀疏过程需要考虑准确性与稀疏度的平衡, 主要通过调整  $\lambda$ 。在训练过程中,  $\lambda$  设置的越大, BN 层缩放因子的分布趋近于 0 的速度越快, 但是模型平均识别准确率往往会变得低;  $\lambda$  设置越小, 趋近于 0 的速度就会越慢, 平均识别准确率也会随之收敛的更稳定。

2) 通道剪枝和微调

经过稀疏后, 可以根据权重对通道进行排序。  $\gamma$  较大的通道对应的权重较大, 这些通道在模型训练中具有更高的影响力; 当  $\gamma$  接近于 0 时, 则该通道所对应的权重在网络训练过程中作用较小, 可以剪掉该通道, 如图 5 所示。可以设置一定的剪枝率对不重要的通道进行剪枝, 得到一个占用空间较小的简化模型。

经过剪枝后的模型浮点运算量和模型体积减少, 也会使准确性下降, 可以通过微调来恢复网络准确性, 微调是一种再训练方法, 通过微调的网络准确性甚至比未剪枝前的网络高。

1.6 绝缘子自爆缺陷检测流程

研究首先对数据集进行预处理, 然后针对 YOLOv8n 进行轻量化改进, 最后在构建的输电线路绝缘子自爆缺陷数据集上对所提的方法进行性能评估, 流程如图 6 所示, 关键步骤如下。

1) 针对样本不足的问题, 使用分割、亮度调整和添加

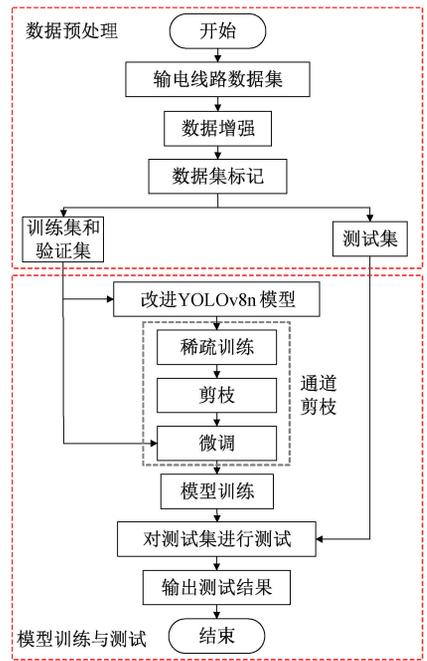


图 6 本研究实验流程

Fig. 6 Experimental flow chart of this study

噪声等增强方法对数据集进行增强, 然后利用 LabelImg 对增强后的数据集进行标记, 将数据集分为训练集、验证集和测试集。

2) 对 YOLOv8n 模型进行轻量化改进, 包括添加检测头, 将原始 CIoU 损失函数替换为 SIoU 损失函数, 使用通道剪枝方法压缩模型。

3) 使用测试集数据对轻量化改进的模型进行性能评估。

2 实验结果与分析

2.1 数据增强

实验采用的数据集来自某电力公司 UAV 拍摄的输电线路绝缘子巡检图像, 共 1 051 张, 其中包含绝缘子自爆缺陷的图像有 496 张。深度学习网络需要大量数据来提高模型泛化能力、防止模型过拟合, 因此本研究对数据集进行增强, 具体流程如下。

1) 为了模拟输电线路绝缘子巡检图像在不同背景下的影响, 采用 GrabCut 算法进行图像分割, 使得绝缘子与背景分离, 将分割后的绝缘子融合到不同背景下<sup>[27-28]</sup>。

2) 为了模拟输电线路绝缘子巡检图像采集过程中面临早晨、傍晚和阴天等场景光线较暗的影响, 采集到的图像存在颜色暗淡、对比度低的情况, 对图像进行亮度调整<sup>[29]</sup>。

3) 为了模拟输电线路绝缘子巡检图像采集过程中面

临抖动影响而导致图像模糊,对图像添加椒盐噪声和高斯噪声<sup>[30]</sup>。

4)最后通过对数据集进行随机翻转<sup>[30]</sup>。以图 1 图像为例,经过增强后的图像如图 7 所示。

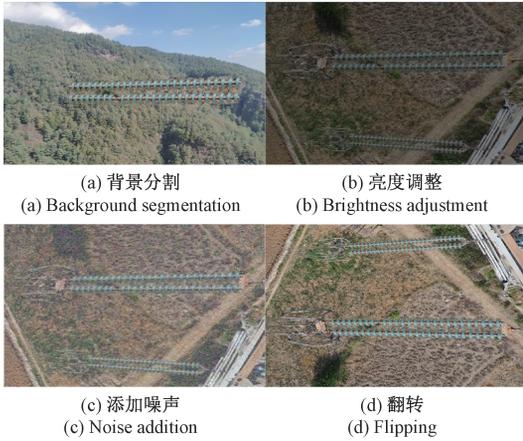


图 7 数据集增强示例

Fig. 7 Data set enhancement example

经过增强后得到 4 176 张绝缘子图像,其中包含 1 912 张带绝缘子自爆缺陷的图像,并使用 LabelImg 来对数据集进行标记,绝缘子标签为 insulator,缺陷标签为 defect。将训练集、验证集和测试集按照 7 : 1 : 2 的比例进行随机划分,分别得到 2 920 张、417 张和 839 张图像。

## 2.2 实验环境和设置

实验环境配置如表 2 所示,消融实验和轻量化改进实验设置如下。

表 2 本文实验环境配置

Table 2 This paper experimental environment configuration

软硬件平台	型号参数
操作系统	Windows 11
CPU	AMD Ryzen 76800H with Radeon Graphics
GPU	GeForce RTX 3050 Laptop GPU
编程语言	Python 3.8.18
深度学习框架	CUDA 11.6, cudnn 8.3.02, Pytorch 1.13.0
Prune	torch-prune 1.3.5

1)消融实验。训练次数为 200 轮,输入图片大小为 640×640 像素;每个批次中的图像数量为 8;网络的优化方式为 SGD;交并比阈值 0.5;初始学习率为 0.01;最终学习率为 0.0001;学习率动量为 0.937;权重衰减系数为 0.0005。

2)轻量化改进实验。稀疏训练次数为 400 轮;微调阶段迭代次数为 250 轮;设置每个批次中的图像数量 4,其余参数与消融实验一致。

## 2.3 模型性能评估指标

本文实验采用准确性均值(average precision, AP)和

平均准确性均值(mean average precision, mAP)作为模型检测准确性评价指标;采用浮点运算量(floating point operations, FLOPs)和模型体积作为模型轻量化评价指标。

### 1)模型检测准确性评价指标

AP 可由 P-R 曲线下面积计算,计算公式如式(20)所示;mAP 是所有单类别 AP 的平均值,计算公式如式(21)所示。

$$AP = \int_0^1 P dR \quad (20)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N (A_p)_i \quad (21)$$

$$P = \frac{T_p}{T_p + F_p} \times 100\% \quad (22)$$

$$R = \frac{T_p}{T_p + F_N} \times 100\% \quad (23)$$

式中: $T_p$  为正例判定为正例的预测正确样本数; $F_p$  为将反例误判为正例的预测错误样本数; $F_N$  为将正例误判为反例的预测错误样本数; $N$  是检测的类别数量,在构建的数据集中对绝缘子和自爆缺陷进行检测, $N=2$ ,在鲁棒性对比实验中对绝缘子、鸟巢和防震锤进行检测, $N=3$ 。

### 2)模型轻量化评价指标

浮点运算量对模型的计算速度和能耗有直接影响,浮点运算量越大,模型运算速度越慢,能耗也越高;模型体积代表占用硬盘空间的大小,体积越大,存储需求也越大。

## 2.4 实验结果分析

### 1)消融实验

为了更好地验证改进的方法对绝缘子及自爆故障识别的有效性,在相同的配置环境和参数下开展以下实验:(1)基准模型,即原始 YOLOv8n 模型;(2)原始模型添加小目标检测模块;(3)原始模型改进损失函数,即将 SIOU 损失函数替换原始模型的 CIOU 损失函数;(4)研究改进模型,同时对原始模型添加小目标检测模块和改进损失函数。实验结果如表 3 所示。

表 3 消融实验性能评估结果

Table 3 Performance evaluation results of ablation experiments

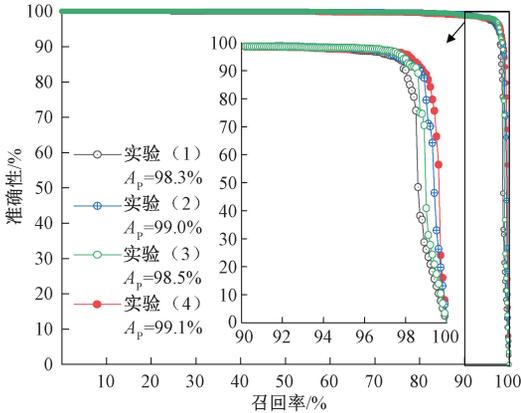
消融实验	AP/%		mAP/%	浮点运算量/ G FLOPs	模型体 积/MB
	绝缘子	自爆缺陷			
(1)	98.3	91.7	95.0	8.10	6.13
(2)	99.0	96.2	97.6	12.50	6.27
(3)	98.5	93.7	96.1	8.10	6.12
(4)	99.1	97.1	98.1	12.50	6.27

由表 3 的对比实验结果,可以得到如下结论:通过实验(1)与(2)、(3)与(4)的实验对比结果可知,添加小目

标检测模块可以有效提高绝缘子及自爆缺陷的  $AP$ , 但会增加模型的浮点运算量和模型体积。通过实验 (1) 与 (3)、(2) 与 (4) 的实验对比结果可知, 将 Siou 损失函数替换原始的 Ciou 损失函数后, 在不增加浮点运算量和模型体积情况下, 有效提高绝缘子和自爆的  $AP$ , 能对模型进一步优化。

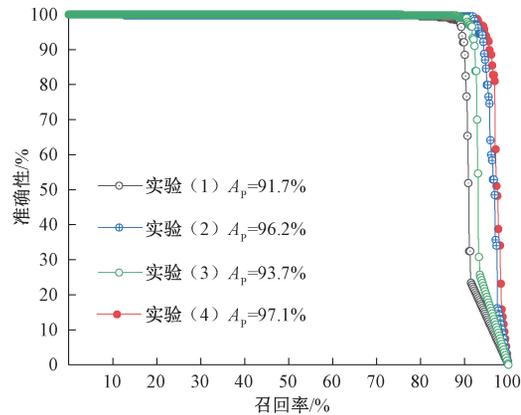
4 个消融实验结果表明, 相比与基准方法和单一的改进方法, 本文提出的改进 YOLOv8n 方法表现出了最优的性能。本文提出的改进方法与实验 (1) 相比, 浮点运算量和模型体积分别增加 4.4 G FLOPS 和 0.14 MB 的情况下, 整体的  $mAP$  提升 3.1%, 绝缘子的和自爆  $AP$  分别提升了 0.8% 和 5.4%。

为了直观展示改进方法的优越性, 利用  $P-R$  曲线进行展示。通过计算  $P-R$  曲线线下面积可以得到模型的  $AP$ , 围成的面积越大, 表明模型效果越好。消融实验中绝缘子及自爆缺陷检测的  $P-R$  曲线如图 8 所示。



(a) 绝缘子检测的  $P-R$  曲线

(a)  $P-R$  curve of insulator detection



(b) 自爆缺陷检测的  $P-R$  曲线

(b)  $P-R$  curve of self-detonation defect detection

图 8 不同模型的  $P-R$  曲线

Fig. 8  $P-R$  curves for different models

由图 8 可以看出, 改进后的模型对绝缘子检测的  $P-R$  曲线线下面积略微大于原始模型, 但对绝缘子缺陷检测

的  $P-R$  曲线线下面积明显大于原始模型。

### 2) 轻量化改进实验

研究使用改进后 YOLOv8n 中 BN 层的缩放因子作为剪枝方法中的通道缩放因子。首先进行网络的稀疏训练, 选择合适的正则化系数应用于改进后的 YOLOv8n 模型, 使模型通道稀疏; 然后, 设置剪枝率, 删除缩放因子较小的通道, 获得剪枝模型; 最后, 对模型进行微调来恢复准确性。

#### (1) 稀疏训练

为了使模型进行稀疏化的同时保持较好的准确性, 采用不同的正则化系数进行实验, 研究采用正则化系数  $\lambda$  从  $[1 \times 10^{-3}, 2.5 \times 10^{-3}, 5 \times 10^{-3}, 7.5 \times 10^{-3}, 1 \times 10^{-2}, 2.5 \times 10^{-2}, 5 \times 10^{-2}]$  中进行选取, 稀疏训练为 400 轮, 不同  $\lambda$  在训练过程中  $mAP$  的变化情况如图 9 所示,  $\lambda$  取值与  $mAP$  和稀疏率关系如图 10 所示。

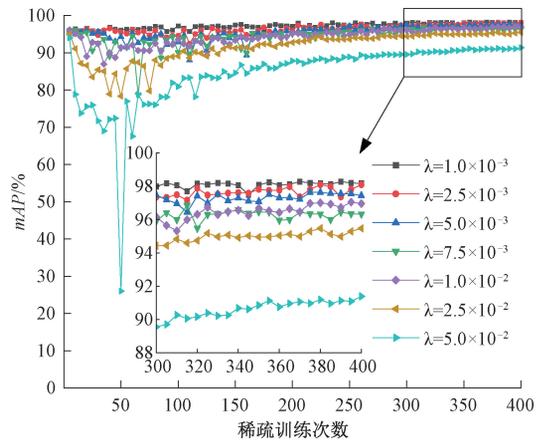


图 9 稀疏训练中  $mAP$  变化曲线

Fig. 9  $mAP$  change curve in sparse training

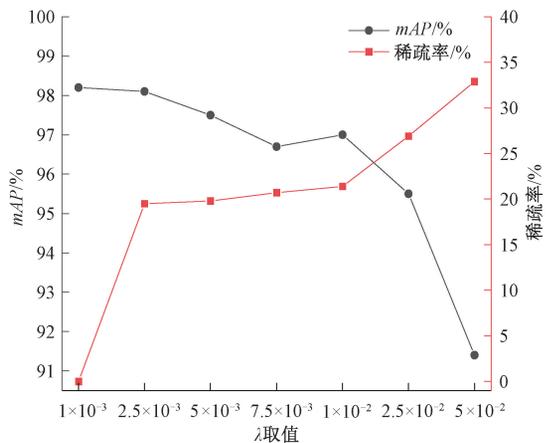


图 10  $\lambda$  取值与  $mAP$  和稀疏率关系

Fig. 10 Relationship between  $\lambda$  value and  $mAP$  and sparse rate

由图 9 可以看出, 稀疏训练 400 轮左右  $mAP$  收敛;

随着  $\lambda$  增大,最终对绝缘子及缺陷检测的  $mAP$  减小,并且与未进行稀疏训练时的  $mAP$  差距越大, $\lambda$  取值在  $1 \times 10^{-3} \sim 2.5 \times 10^{-2}$  之间时,最终的  $mAP$  与未进行稀疏训练时的  $mAP$  相比小于 10%, $\lambda$  取值为  $5 \times 10^{-2}$  时,最终的  $mAP$  与未稀疏模型相比结果相差 10% 左右。由图 10 可以看出, $\lambda$  取值在  $1 \times 10^{-3} \sim 5 \times 10^{-2}$  之间时,随着  $\lambda$  取值的增大稀疏率越高, $\lambda$  取值为  $1 \times 10^{-3}$  时稀疏率为 0, $\lambda$  取值为  $5 \times 10^{-2}$  时稀疏率最高, $\lambda$  取值为  $1 \times 10^{-2}$  时,稀疏率增长较快; $\lambda$  取值为  $1 \times 10^{-3}$  至  $7.5 \times 10^{-3}$  之间时, $mAP$  随着  $\lambda$  增加而下降,在  $\lambda$  取值为  $7.5 \times 10^{-3}$  后增加,并在  $\lambda$  取值为  $1 \times 10^{-2}$  后迅速降低。综合考虑不同  $\lambda$  取值下的稀疏率与准确率关系,本研究选取  $\lambda = 1 \times 10^{-2}$  进行稀疏训练,并通过 Pytorch 框架中的可视化模块 tensorboard 查看未进行稀疏训练和经过稀疏训练的 BN 层缩放因子分布情况,如图 11 所示。

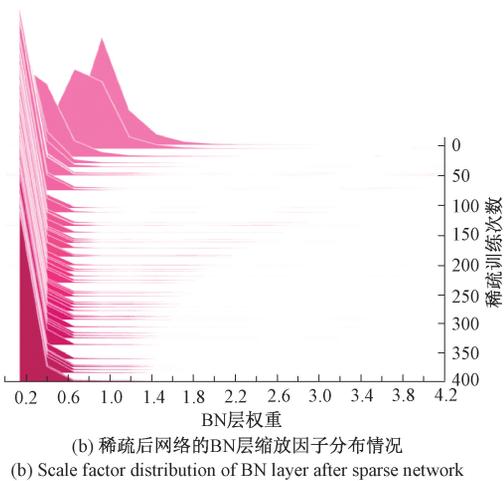
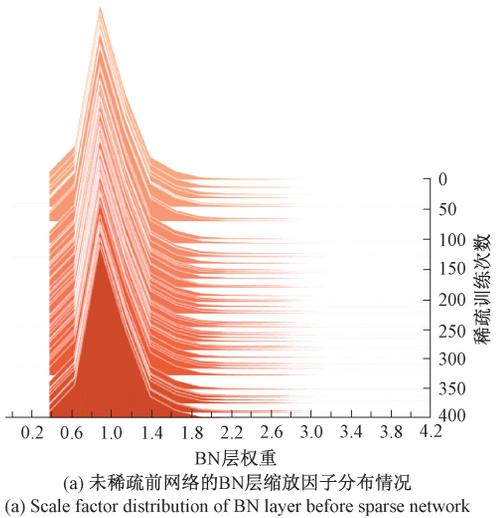


图 11 稀疏训练中 BN 层缩放因子分布情况

Fig. 11 Scale factor distribution in BN layer in sparse training

由图 11 可以看出,原始模型的 BN 层缩放因子近似

于均值为 0.9 的正态分布;经过稀疏训练后,BN 层权重被压缩至接近于 0,稀疏效果明显。

(2) 剪枝和微调

选取  $\lambda = 1 \times 10^{-2}$  进行稀疏训练 400 轮后,模型的 BN 层缩放因子很多被压缩接近 0,然后通过不断设置不同的剪枝率进行实验,本文选择剪枝率为 50% 对改进后的 YOLOv8n 进行剪枝,然后对其进行性能评估,评估结果如表 4 所示,剪枝前后模型的每层卷积通道数量变化如图 12 所示。

表 4 本文方法性能评估结果

Table 4 Performance evaluation results of the method in this paper

方法	$A_p / \%$		$mAP / \%$	浮点运算量/G	模型体积/MB
	绝缘子	自爆缺陷			
本文方法	98.1	96.0	97.1	4.90	1.82

由表 3 和 4 可知,本研究改进模型增加了绝缘子及自爆缺陷的检测精确性,通过对改进模型进行通道剪枝,减少了模型的浮点运算量和体积,与改进后的模型相比,经过轻量化后模型的  $mAP$  仅下降 1% 情况下,模型浮点运算量和模型体积分别下降 60.8% 和 71.0%,模型体积仅为 1.82 MB。

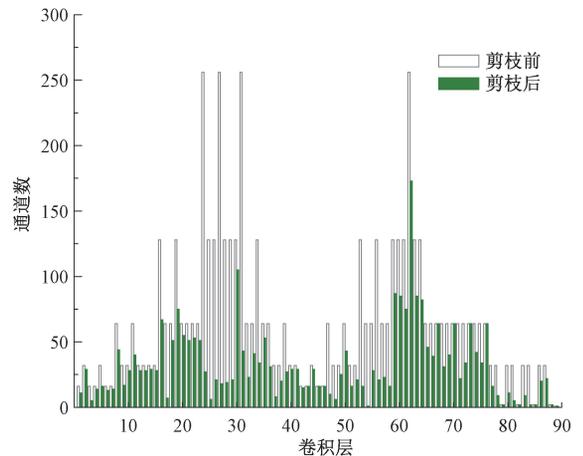


图 12 剪枝前后模型的每层卷积通道数量

Fig. 12 The number of convolutional channels in each layer of the model before and after pruning

3) 不同绝缘子故障检测方法对比分析

根据轻量化改进实验得到最终轻量化改进的 YOLOv8n 模型,为了验证所提方法对真实数据集中绝缘子及自爆缺陷的检测准确性,利用轻量化改进模型进行训练得到的权重对真实数据集的绝缘子及自爆缺陷进行检测,部分检测结果如图 13 和 14 所示。

为验证本研究方法的优越性,在构建的数据集下对比测试不同模型性能,分别选取当前主流模型



图 13 真实数据集部分绝缘子检测结果

Fig. 13 Real data set partial insulator test results

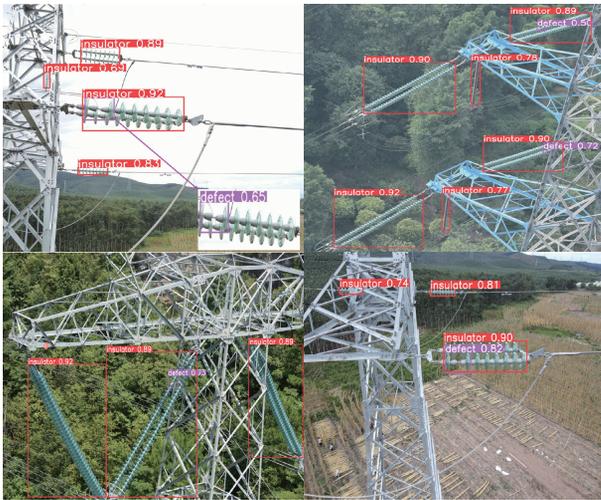


图 14 真实数据集部分绝缘子与自爆缺陷检测结果

Fig. 14 Results of partial insulator and self-explosion defect detection in real data set

由表 4 和 5 可知,本研究轻量化改进模型对绝缘子及自爆缺陷检测的  $AP$  分别为 98.1% 和 96.0%,  $mAP$  为 97.1%, 浮点运算量和模型体积分别为 4.90 G FLOPS 和 1.82 MB, 在浮点运算量略高于 YOLOv5n 情况下, 其他性能指标均高于所对比的模型, 尤其是对绝缘子自爆缺陷的检测, 比对比模型中检测性能最好的 YOLOv8-ResCBAM 模型高 3.9%。分析对比模型的实验结果可知, YOLOv5n 模型的浮点运算量和模型体积都最低, 分别为 4.10 G FLOPS 和 3.37 MB, 但对绝缘子自爆缺陷检测的  $AP$  为 90.7%, 会存在漏检和错检情况。YOLOv8-ResCBAM 模型对绝缘子及自爆缺陷检测  $AP$  分别为 98.0% 和 92.1%,  $mAP$  为 95.1%, 在对比的缺陷检测模型中最高, 但浮点运算量和模型体积也较大。SSD 和 Faster RCNN 模型的浮点运算量和模型体积都较大, 在本研究构建的数据集中检测性能较差。虽然 YOLOv10n 模型是 YOLO 系列中较新的模型, 模型体积略低于 YOLOv8n, 但在本文所构建的数据集中检测性能较差, 对绝缘子自爆缺陷的检测仅为 81.8%。因此, 本文轻量化改进的模型具有优越的小目标检测性能和轻量化性能, 并且在本研究构建的数据集上对绝缘子自爆缺陷检测中没有漏检、错检等情况。

4) 鲁棒性对比分析

目前, 暂无输电线路绝缘子缺陷检测公开数据集。为了验证本文轻量化改进模型的鲁棒性, 本文选用另一个输电线路巡检图像数据集, 该数据集包括绝缘子、鸟巢和防震锤共 3 种检测类型, 共 4 911 张图像, 样本标签数目分别为 8 166、317 和 2 910, 同样将训练集、验证集和测试集按照 7 : 1 : 2 的比例进行随机划分, 分别得到 3 440 张、491 张和 980 张图像。通过本文轻量化改进模型和前面章节对比方法对这 3 种类型的检测准确性进行对比, 以此验证本文方法在其他相似的检测任务中的鲁棒性, 检测结果如表 6 所示。

表 6 鲁棒性对比实验

Table 6 Robustness comparison experiment

对比方法	AP/%			mAP/ %	浮点运算 量/G FLOPS	模型体 积/MB
	绝缘子	鸟巢	防震锤			
本文方法	94.2	88.3	79.4	87.3	5.01	1.99
YOLOv5n	94.0	78.6	64.2	78.9	4.20	3.74
SSD	69.2	78.6	56.2	68.0	62.79	94.01
Faster RCNN	88.0	78.8	64.7	77.2	369.72	111.20
YOLOv8-ResCBAM	96.6	85.2	70.4	84.1	8.20	6.09
YOLOv10n	92.4	71.5	69.3	77.7	8.20	5.60

由表 6 可知, 本文轻量化改进模型在鲁棒性对比数据集的检测精确性、浮点运算量和模型体积与其他模型进行对比有较大优势, 对绝缘子、鸟巢和防震锤的检测

YOLOv5n、SSD 和 Faster RCNN, 以及最新在 YOLOv8n 基础上改进的 YOLOv8-ResCBAM<sup>[31]</sup> 和最新发布的 YOLOv10n<sup>[32]</sup> 模型进行性能对比, 结果如表 5 所示。

表 5 不同缺陷检测模型性能对比

Table 5 Performance comparison of different defect detection model

对比方法	AP/%		mAP/ %	浮点运算 量/G FLOPS	模型体 积/MB
	绝缘子	自爆缺陷			
YOLOv5n	96.5	90.7	93.6	4.10	3.37
SSD	88.0	63.0	75.5	62.75	93.30
Faster RCNN	95.0	41.0	68.0	370.21	110.81
YOLOv8-ResCBAM	98.0	92.1	95.1	8.20	6.12
YOLOv10n	93.1	81.8	87.4	8.20	5.65

AP 分别为 94.2%、88.3% 和 79.4%， $mAP$  为 87.3%，浮点运算量和模型体积分别为 5.01 G FLOPS 和 1.99 MB，对绝缘子检测的 AP 略低于 YOLOv8-ResCBAM，浮点运算量略低于 YOLOv5n，其他性能均优于对比的模型，尤其是防震锤检测 AP 高达 79.4%，相比于其他模型提高 10%~20%，这是由于防震锤在该数据集中像素值较小，使得本研究方法的检测准确性较高。在对比模型中，YOLOv5n 有较小的浮点运算量和模型体积，但对防震锤的检测准确性较差，YOLOv8-ResCBAM 在该数据集中同样取得较好的检测性能，对绝缘子检测的 AP 高达 96.6%，但浮点运算量和模型体积较大。由表 4~6 可知，轻量化改进模型除了对绝缘子自爆缺陷检测有较高的准确性外，对其他小目标检测也有较高的准确性。为了验证本研究方法对绝缘子、鸟巢和防震锤的检测效果，选取部分图像进行检测，检测结果如图 15 所示，其中绝缘子标签为 insulator，鸟巢为 bird\_nest，防震锤为 damper。

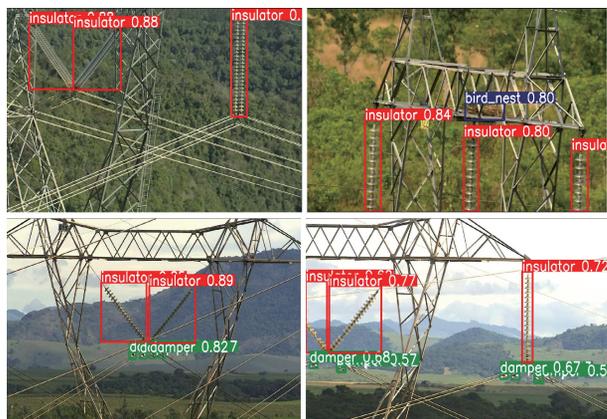


图 15 本文方法在鲁棒性对比实验中的检测效果

Fig. 15 The detection effect of the proposed method in the robustness comparison experiment

### 3 结论

针对深度学习目标检测模型对绝缘子自爆缺陷检测准确性不高，模型体积较大等问题，本文提出了一种轻量化改进的 YOLOv8n 输电线路绝缘子自爆检测方法，并与 YOLOv5n、SSD、Faster RCNN、YOLOv8-ResCBAM 和 YOLOv10n 模型的测试结果进行了对比，得到以下结论。1) 对原始 YOLOv8n 添加小目标检测模块，可以有效改善模型的小目标检测能力，解决绝缘子自爆缺陷检测准确性低的问题；通过添加 Siou 损失函数替代 YOLOv8n 的 Ciou 损失函数，在没有增加任何浮点运算量和体积的情况下，进一步提升了模型性能。2) 通过对改进后的 YOLOv8n 模型进行通道剪枝，在兼顾绝缘子和自爆缺陷的  $mAP$  的情况下，减少模型的浮点运算量及体积。在构

建数据集中，轻量化改进模型与原始模型相比，在绝缘子检测 AP 仅下降 0.2% 情况下，自爆缺陷检测 AP 上升 4.3%，其浮点运算量和体积分别为 4.9 G FLOPS 和 1.82 MB，仅为原始模型的 60.5% 和 29.7%，合理兼顾了准确性和模型复杂性。并且本文方法在所构建的绝缘子自爆数据集中没有出现错检和漏检情况，与其他模型相比，在检测准确性、浮点运算量和模型体积等有较强的优势。3) 在选用的另一个输电线路巡检图像数据集上，本研究对绝缘子、鸟巢和防震锤检测的  $mAP$  达到了 87.3%，尤其是对防震锤检测的 AP 达到 79.4%，高于其他模型。因此，本研究方法在小目标检测中取得了较好的准确性，具有良好的可靠性和鲁棒性。未来的研究将聚焦在与知识蒸馏等方法相结合，进一步提高小目标检测的准确性和模型的轻量化，以期在输电线路检测任务中展现出更高的应用潜力和价值。

### 参考文献

- [1] 黄悦华, 刘恒冲, 陈庆, 等. 基于 USRNet 与改进 YOLOv5x 的输电线路绝缘子故障检测方法[J]. 高电压技术, 2022, 48(9): 3437-3446.  
HUANG Y H, LIU H CH, CHEN Q, et al. Transmission line insulator fault detection method based on USRNet and improved YOLOv5x[J]. High Voltage Engineering, 2022, 48(9): 3437-3446.
- [2] 贾晓芬, 于业齐, 郭永存, 等. 航拍绝缘子自爆缺陷的轻量化检测方法[J]. 高电压技术, 2023, 49(1): 294-300.  
JIA X F, YU Y Q, GUO Y C, et al. Lightweight detection method of self-explosion defect of aerial photo insulator[J]. High Voltage Engineering, 2023, 49(1): 294-300.
- [3] 罗潇, 於锋, 彭勇. 基于深度学习的无人机电网巡检缺陷检测研究[J]. 电力系统保护与控制, 2022, 50(10): 132-139.  
LUO X, YU F, PENG Y. UAV power grid inspection defect detection based on deep learning[J]. Power System Protection and Control, 2022, 50(10): 132-139.
- [4] 王道累, 孙嘉珺, 张天宇, 等. 基于改进生成对抗网络的玻璃绝缘子自爆缺陷检测方法[J]. 高电压技术, 2022, 48(3): 1096-1103.  
WANG D L, SUN J J, ZHANG T Y, et al. Self-explosion defect detection method of glass insulator based on improved generative adversarial network[J]. High Voltage Engineering, 2022, 48(3): 1096-1103.

- [ 5 ] 邹红波, 陈俊廷, 柴延辉, 等. 基于改进的 YOLOv7 的雾天场景下绝缘子及其自爆缺陷检测方法[J]. 国外电子测量技术, 2023, 42(10): 1-11.
- ZOU H B, CHEN J T, CHAI Y H, et al. Detection method of insulator and self-explosion defect in foggy scene based on improved YOLOv7 [ J ]. Foreign Electronic Measurement Technology, 2023, 42 ( 10 ): 1-11.
- [ 6 ] 隋宇, 宁平凡, 牛萍娟, 等. 面向架空输电线路的挂载无人机电力巡检技术研究综述[J]. 电网技术, 2021, 45(9): 3636-3648.
- SUI Y, NING P F, NIU P J, et al. Review on mounted UAV for transmission line inspection[J]. Power System Technology, 2021, 45(9): 3636-3648.
- [ 7 ] 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 CH Y, WU Y Q. Research progress of vision detection methods based on deep learning for transmission lines[J]. Proceedings of the CSEE, 2023, 43(19): 7423-7446.
- [ 8 ] NGUYEN V, JENSSEN R, ROVERSO D. Intelligent monitoring and inspection of power line components powered by UAVs and deep learning[J]. IEEE Power and Energy Technology Systems Journal, 2019, 6(1): 11-21.
- [ 9 ] REN SH 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.
- [ 10 ] WANG B, DONG M, REN M, et al. Automatic fault diagnosis of infrared insulator images based on image instance segmentation and temperature analysis [ J ]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(8): 5345-5355.
- [ 11 ] 白晓静, 谢雅祺, 赵淼, 等. 基于局部特征深度信息的绝缘子小样本缺陷检测 [ J ]. 电网技术, 2024, 48(2): 740-752.
- BAI X J, XIE Y Q, ZHAO M, et al. Few-shot insulator defect detection based on deep information of local features[J]. Power System Technology, 2024, 48(2): 740-752.
- [ 12 ] 苟军年, 杜榛榛, 刘力. 基于改进掩膜区域卷积神经网络的输电线路绝缘子自爆检测 [ J ]. 电工技术学报, 2023, 38(1): 47-59.
- GOU J N, DU S S, LIU L. Transmission line insulator self-explosion detection based on improved mask region-convolutional neural network [ J ]. Transactions of China Electrotechnical Society, 2023, 38(1): 47-59.
- [ 13 ] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [ C ]. Proceedings of the 14th European Conference. Netherlands: Springer, 2016: 21-37.
- [ 14 ] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [ C ]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 779-788.
- [ 15 ] 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(1): 60-70.
- LI B, QU L Y, ZHU X SH, et al. Insulator defect detection based on multi-scale feature fusion [ J ]. Transactions of China Electrotechnical Society, 2023, 38(1): 60-70.
- [ 16 ] 邬开俊, 徐泽浩, 单宏全. 基于 FasterNet 和 YOLOv5 改进的玻璃绝缘子自爆缺陷快速检测方法 [ J ]. 高电压技术, 2024, 50(5): 1865-1876.
- WU K J, XU Z H, SHAN H Q. Improved rapid detection method for self-exploding defects in glass insulators based on FasterNet and YOLOv5 [ J ]. High Voltage Engineering, 2024, 50(5): 1865-1876.
- [ 17 ] 杨阳, 杨帅, 闫敏, 等. 基于 UDD-YOLO 的边缘端绝缘子放电严重程度评估算法 [ J ]. 电子测量与仪器学报, 2024, 38(1): 219-227.
- YANG Y, YANG SH, YAN M, et al. UDD-YOLO based edge-end insulator discharge severity assessment algorithm [ J ]. Journal of Electronic Measurement and Instrumentation, 2024, 38(1): 219-227.
- [ 18 ] 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 K P, LI B Q, QIN L, 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.
- [ 19 ] 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 SH T, ZHANG H Y, HU CH L, 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.
- [20] 张翼, 朱永利. 基于深度-广度联合剪枝的电力设备局部放电轻量化诊断方法[J]. 电工技术学报, 2023, 38(7): 1935-1945, 1955.
- ZHANG Y, ZHU Y L. A lightweight partial discharge diagnosis method of power equipment based on depth-width joint pruning[J]. Transactions of China Electrotechnical Society, 2023, 38(7): 1935-1945, 1955.
- [21] 刘志坚, 何蔚, 刘航, 等. 基于格拉姆角场变换和深度压缩模型的变压器故障识别方法[J]. 电网技术, 2023, 47(4): 1478-1490.
- LIU ZH J, HE W, LIU H, et al. Fault identification method for power transformer based on gramian angular field transformation and deep compression model [J]. Power System Technology, 2023, 47(4): 1478-1490.
- [22] 杨乐, 王金丽, 段祥骏, 等. 基于轻量化改进 YOLOv5 的配网工程质量缺陷检测方法[J]. 电网技术, 2023, 47(9): 3864-3874.
- YANG L, WANG J L, DUAN X J, et al. Quality defect detection of distribution network engineering based on lightweight improved YOLOv5 [J]. Power System Technology, 2023, 47(9): 3864-3874.
- [23] ZHENG ZH H, WANG P, REN D W, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation [J]. IEEE Transactions on Cybernetics, 2022, 52(8): 8574-8586.
- [24] ZHONG R, PENG EN D, LI Z Q, et al. SPD-YOLOv8: A small-size object detection model of UAV imagery in complex scene [J]. The Journal of Supercomputing, 2024, 80(12): 17021- 17041.
- [25] GEVORGYAN Z. Siou loss: More powerful learning for bounding box regression [J]. ArXiv preprint arXiv: 2205. 12740, 2022.
- [26] NIU K, YAN Y. A small-object-detection model based on improved YOLOv8 for UAV aerial images[C]. 2023 2nd International Conference on Artificial Intelligence and Intelligent Information Processing (AIIP), Hangzhou, China, 2023: 57-60.
- [27] 刘传洋, 吴一全, 刘景景. 基于视觉的输电线路金具锈蚀缺陷检测方法研究进展[J]. 仪器仪表学报, 2024, 45(3): 286-305.
- LIU CH Y, WU Y Q, LIU J J. Research progress of vision-based rust defect detection methods for metal fittings in transmission lines [J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 286-305.
- [28] 谢静, 杜耀文, 刘志坚, 等. 基于轻量化改进型 YOLOv5s 的可见光绝缘子缺陷检测算法[J]. 电网技术, 2023, 47(12): 5273-5283.
- XIE J, DU Y W, LIU ZH J, et al. Defect detection algorithm based on lightweight and improved YOLOv5s for visible light insulators[J]. Power System Technology, 2023, 47(12): 5273-5283.
- [29] 王道累, 张正刚, 张世恒, 等. 基于密集连接网络的航拍绝缘子旋转目标精准定位方法[J]. 电力系统保护与控制, 2024, 52(1): 35-43.
- WANG D L, ZHANG ZH G, ZHANG SH H, et al. Accurate positioning method of insulator rotating target in aerial photography based on dense connection network[J]. Power System Protection and Control, 2024, 52(1): 35-43.
- [30] 宋智伟, 黄新波, 纪超, 等. 基于 Flexible YOLOv7 的输电线路绝缘子缺陷检测和故障预警方法[J]. 高电压技术, 2023, 49(12): 5084-5094.
- SONG ZH W, HUANG X B, JI CH, et al. Insulator defect detection and fault warning method for transmission line based on flexible YOLOv7 [J]. High Voltage Engineering, 2023, 49(12): 5084-5094.
- [31] JU R, CHIEN C, CHIANG J. YOLOv8-ResCBAM: YOLOv8 based on an effective attention module for pediatric wrist fracture detection [J]. ArXiv preprint arXiv:2409. 18826, 2024.
- [32] WANG A, CHEN H, LIU L H, et al. YOLOv10: Real-time end-to-end object detection [J]. ArXiv preprint arXiv: 2405. 14458, 2024.

## 作者简介



刘航, 2014 年于重庆大学获得学士学位, 2020 年于重庆大学获得博士学位, 现为昆明理工大学讲师, 主要研究方向为研究方向为高电压技术, 电力设备状态评估与故障诊断。

E-mail: liuhangsheep@163.com

Liu Hang received his B. Sc. degree from Chongqing

University in 2014 and Ph. D. degree from Chongqing University in 2020, respectively. He is now a lecturer at Kunming University of Science and Technology. His main research interests include high voltage technology, power equipment condition assessment and fault diagnosis.



**李明**, 2021 年于昆明理工大学获得学士学位, 现为昆明理工大学硕士研究生, 主要研究方向为电力设备状态评估与故障诊断。

E-mail: 2538075114@qq.com

**Li Ming** received his B. Sc. degree from Kunming University of Science and Technology in 2021. He is now a M. Sc. candidate at Kunming University of Science and Technology. His main research interests include power equipment condition assessment and fault diagnosis.



**刘志坚** (通信作者), 1997 年于山东理工大学获得学士学位, 2000 年于昆明理工大学获得硕士学位, 2010 年于哈尔滨工业大学获得博士学位, 现为昆明理工大学电力工程学院教授, 主要研究方向为电网智能化。

E-mail: 248400248@qq.com

**Liu Zhijian** (Corresponding author), received the B. Sc. degree from Shandong University of Science and Technology in 1997, the M. Sc. degree from Kunming University of Science and Technology in 2000 and the Ph. D. degree from Harbin Institute of Technology in 2010. He is now a professor at the School of Electric Power Engineering, Kunming University of Science and Technology. His main research interest includes power grid intelligence.