

DOI:10.19651/j.cnki.emt.2519615

# 基于 HCDNet-YOLO11 的输电线路关键部位及缺陷检测算法\*

崔克彬<sup>1,2</sup> 吕思怡<sup>1</sup> 杨立然<sup>1,2</sup>

(1. 华北电力大学计算机系 保定 071003; 2. 复杂能源系统智能计算教育部工程研究中心 保定 071003)

**摘要:** 无人机巡检是输电线路检测的重要方式之一。针对现有的输电线路检测算法目标尺度变化大、小目标检测困难、复杂场景下难以有效捕捉缺陷细节等问题,提出一种 YOLO11 改进模型 HCDNet-YOLO11。首先,设计 HCDNet 网络代替原始的特征金字塔网络,降低模型的参数量,增强模型对不同尺度特征的表达;其次,构建 MulCAA 注意力模块,通过平均池化和最大池化的双分支结构提取关键信息,减少信息损失,通过长距离像素间的依赖关系削弱复杂背景对检测目标的干扰;最后,引入重参数化卷积 RepConv 实现 Rep\_C3k2 模块,增强模型的非线性特征建模能力,提升检测精度和推理速度。实验结果表明,HCDNet-YOLO11 算法在输电线路自建数据集上准确率提升了 1.9%,召回率提升了 6.5%,mAP50 提升了 5.7%,参数量减少了 24.42%,该算法在减少参数量的前提下取得了很好的性能。在公共数据集 VisDrone2019 上,HCDNet-YOLO11 算法在 val 集和 test 集上 mAP50 分别提升 6.5% 和 4.6%,验证了其对于复杂空域场景的强泛化能力。

**关键词:** 输电线路;HCDNet-YOLO11;多尺度特征融合;注意力机制;重参数化卷积

**中图分类号:** TP391.41; TN919.8 **文献标识码:** A **国家标准学科分类代码:** 520.6040

## Key parts and defect detection of transmission line based on HCDNet-YOLO11

Cui Kebin<sup>1,2</sup> Lyu Siyi<sup>1</sup> Yang Liran<sup>1,2</sup>

(1. Department of Computer Science, North China Electric Power University, Baoding 071003, China;

2. Engineering Research Center of Intelligent Computing for Complex Energy Systems, Ministry of Education, Baoding 071003, China)

**Abstract:** Drone inspection is one of the important methods for power transmission line detection. To address the issues of large target scale variations, difficulty in detecting small targets, and the inability to effectively capture defect details in complex scenarios with existing power transmission line detection algorithms, an improved YOLO11 model, HCDNet-YOLO11, is proposed. Firstly, the HCDNet network is designed to replace the original feature pyramid network, reducing the model's parameter count and enhancing its expression of features at different scales. Secondly, the MulCAA attention module is constructed, which extracts key information through a dual-branch structure of average pooling and max pooling, reducing information loss and weakening the interference of complex backgrounds on detection targets through long-range pixel dependencies. Finally, the RepConv reparameterization convolution is introduced to implement the Rep\_C3k2 module, enabling the model to introduce a larger receptive field during the training phase, enhancing its nonlinear feature modeling ability. Experimental results show that the HCDNet-YOLO11 algorithm has increased the accuracy by 1.9%, recall by 6.5%, and mAP50 by 5.7% on the self-built power transmission line dataset, with a 24.42% reduction in parameters. The algorithm attains good performance on the premise of reducing the number of parameters. On the public VisDrone2019 dataset, the HCDNet-YOLO11 algorithm has increased mAP50 by 6.5% and 4.6% on the val set and test set, respectively, verifying its strong generalization ability in complex aerial scenarios.

**Keywords:** transmission line; HCDNet-YOLO11; multiscale feature fusion; attention mechanism; repeated convolution

## 0 引言

输电线路作为电力系统的核心组成部分,其运行状态

直接影响到电力系统的可靠性。然而,在实际运行过程中,输电线路上的各种基础设施,如绝缘子、防震锤、间隔棒等,往往会受到恶劣天气、环境污染、设备老化等多种因素的影

收稿日期:2025-08-16

\* 基金项目:河北省自然科学基金青年科学基金项目(F2024502002)、中央高校基本科研业务费专项资金面上项目(2024MS127)资助

响,这些都可能成为导致输电线路故障的原因。因此,对输电线路定期巡检至关重要。由于架空输电线路分布范围广且环境复杂,人工巡检存在效率低、成本高、安全性差等问题,难以满足日常检测的需求<sup>[1]</sup>。目前,搭载智能检测算法的无人机巡检技术已成为线路巡检的重要方式。

近年来,得益于计算机视觉的快速发展,基于深度学习的目标检测算法在输电线路智能巡检领域展现出显著的应用优势。当前主流算法主要有 Cascade R-CNN<sup>[2]</sup>、Faster R-CNN<sup>[3]</sup>等二阶段检测算法和 YOLO、SSD<sup>[4]</sup>等单阶段检测算法。阎光伟等<sup>[5]</sup>通过设计对比学习网络和并行注意力机制改进 Cascade R-CNN 算法,以提高对防震锤脱落目标的检测能力;胡冠华等<sup>[6]</sup>提出基于改进 U-Net 的输电线路分割算法,实现复杂图像中输电线的高效分割。上述方法均有良好的精度表现,但基于二阶段的目标检测算法复杂度较高,检测速度较慢,难以满足嵌入式设备对轻量化和实时性的需求。周景等<sup>[7]</sup>在 RT-DETR 的基础上引入 StarNet 轻量级网络和 Harr 小波变换下采样模块实现模型的轻量化并实现低高频信息的高效融合;刘敏等<sup>[8]</sup>提出全局感知增强的输电线路多目标检测方法,显著提高了检测精度;王彦海等<sup>[9]</sup>引入全维动态卷积模块增强模型的全局特征融合能力,引入长距离注意力机制增强廉价操作模块降低模型的参数量。这些模型虽然在一定程度上提高了检测精度,但输电线路检测仍面临诸多挑战:首先,输电线

路巡检中多类别检测目标在空间尺度上存在显著差异;其次,受限于无人机的安全巡检距离,拍摄图像中防震锤、间隔棒等关键部件常呈现小目标特性,导致有效特征提取困难;此外,输电设施多分布于森林、山丘等复杂地形,背景中植被覆盖、光照变化及相似目标干扰显著影响目标辨识。

针对上述问题,本文提出一种基于 YOLO11 的改进算法 HCDNet-YOLO11。主要工作包括:

- 1)设计高层筛选网络(HCDNet)代替传统的颈部网络,利用高层特征筛选低层特征,提升不同尺度特征的融合与表达能力,尤其对小目标精度提升有明显作用。
- 2)提出双分支注意力模块 MulCAA,提取关键特征和全局特征,使模型更加关注目标本身和其边界,抑制背景干扰,尤其对细长形状的物体有显著优势。
- 3)引入重参数化卷积设计 Rep\_C3k2 模块,使其在训练阶段使用多分支结构提升特征提取能力,在推理阶段将其合并为单分支结构,以减少计算开销、提升推理速度。

### 1 HCDNet-YOLO11 改进算法

针对 YOLO11 算法在输电线路巡检中对小目标识别不敏感、多尺度特征融合能力有限、复杂背景下易误检漏检等问题,提出 HCDNet-YOLO11 网络模型,其网络结构如图 1 所示。针对输电线路中目标尺度变化大和小目标检测困难的问题,构建 HCDNet 颈部网络代替原始的特征金字

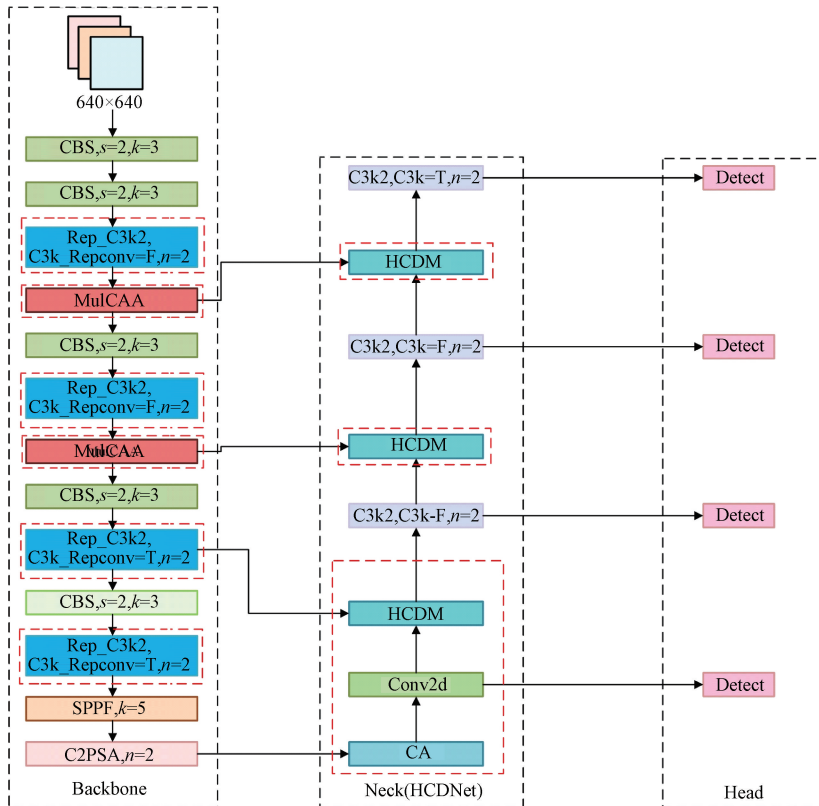


图 1 HCDNet-YOLO11 网络结构

Fig. 1 HCDNet-YOLO11 network structure

塔,从而提升网络的多尺度特征融合和小目标检测能力;针对输电线路图像中背景复杂、相似目标易被漏检、错检的问题,在主干网络的第 3 和第 6 层引入两个 MulCAA 模块,增强模型对关键目标区域的关注能力,提升在复杂场景下的检测鲁棒性;针对 C3k2 模块两层卷积导致的特征提取能力有限的问题,设计 Rep\_C3k2 模块,提高推理速度和检测精度。

### 1.1 颈部网络改进为 HCDNet

输电线路包含多种关键目标与缺陷类型,各类别在尺度上天然存在显著差异。为有效应对尺度差异带来的检测挑战,以提升对不同尺度目标尤其是小目标的检测效果,参考 HSFPN<sup>[10]</sup>模型,融合坐标注意力机制(coordinate attention, CA)<sup>[11]</sup>和轻量化上采样器(dynamic sampling, DySample)<sup>[12]</sup>设计 HCDM (HSFPN with coordinate

attention and dysample module, HCDM)轻量化模块,同时将原有的 3 层网络结构改进为 4 层网络结构,构造 HCDNet 颈部网络,在减少模型参数量的同时,增强模型的多尺度特征表达能力和小目标检测能力。

YOLO11 的特征融合模块 PANet 结构示意图如图 2(a)所示,其采用自顶向下和自底向上的双层特征融合方式,将不同尺度的特征直接拼接,容易造成特征冗余;图 2(b)为 HSFPN 网络的示意图。其创新性的引入特征选择模块,采用通道注意力机制筛选不同尺度特征图的关键特征,并仅采用单向特征融合策略,从而既能高效融合,又能减少计算开销。但通道注意力机制通常会忽略特征图的空间位置信息,导致目标定位不准,而且 HSFPN 在进行特征融合时直接从最高层向下融合,容易丢失细节信息。




图 2 改进前后特征融合模块结构示意图

Fig. 2 Structural diagram of improved front and rear feature fusion module

为了改善上述问题,本文结合 YOLO11 和 HSFPN 的优势提出 HCDNet 网络,其网络示意图如图 2(c)所示,具体改进为:

1)在特征选择过程中,使用坐标注意力机制替换 HSFPN 中的通道注意力,通过在特征图上引入位置信息,更准确地捕捉具有空间分布特征的目标。

2)在特征融合过程中,采用 DySample 的轻量化上采样方式,进一步降低模型的复杂度和计算成本。

3)在特征融合时采用逐层传递的融合方式,有利于多尺度特征融合和小目标检测。

HCDM 模块如图 3 所示。

有两个输入,Input1 为来自主干网络的低层特征图,该特征图首先经过坐标注意力机制筛选重要特征。坐标注意力机制采用空间信息编码、坐标信息嵌入和空间注意力生成的方式,实现了对目标对象空间位置的精准定位。传统的通道注意力机制的编码过程为:

$$\mathbf{F}(c) = \frac{1}{H \cdot W} \mathbf{X}(c, h, w), \mathbf{F} \in \mathbf{R}^{C \times 1 \times 1} \quad (1)$$

其中,  $H$  表示特征图的高度,  $W$  表示特征图的宽度,  $\mathbf{X}(c, h, w)$  表示输入特征图第  $c$  通道上位置  $(h, w)$  处的像素值,  $\mathbf{F}(c)$  表示第  $c$  个通道的输出,其结果是一个大小为  $C \times 1 \times 1$  的张量。这种方式可以获取通道维度上的全局上下文信息,但会完全丢失位置信息。

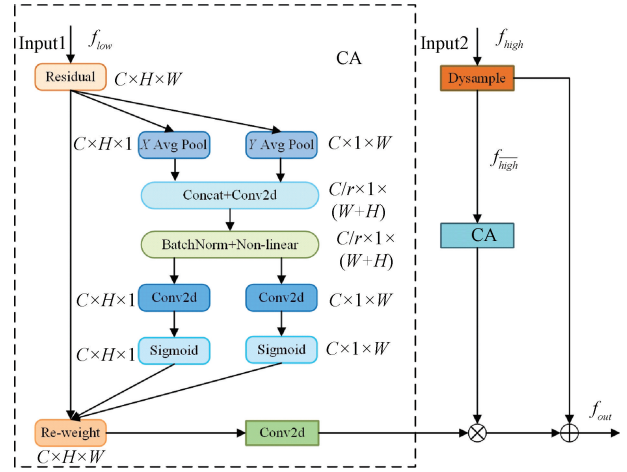


图 3 HCDM 网络结构

Fig. 3 HCDM network structure

为了保留位置信息,坐标注意力机制将式(1)分解为一对一维特征编码操作,得到具有方向感知的特征图。分解过程为:

$$\mathbf{F}_h(c, h) = \frac{1}{W} \sum_{w=1}^W \mathbf{X}(c, h, w), \mathbf{F}_h \in \mathbf{R}^{C \times H \times 1} \quad (2)$$

$$\mathbf{F}_w(c, w) = \frac{1}{H} \sum_{h=1}^H \mathbf{X}(c, h, w), \mathbf{F}_w \in \mathbf{R}^{C \times 1 \times W} \quad (3)$$

通过这种方式,可以沿一个空间方向捕捉长程依赖

性,同时在另一个空间方向保留精确的位置信息。

Input2 为来自上一层的高级特征,首先经过 DySample 模块进行上采样。DySample 的上采样方式借助可学习的偏移量 Offset 为每一个像素动态生成采样位置,从而实现精细化的特征重建。随后,利用坐标注意力机制将高级特征转换为相应的注意力权值,在获得具有一致维数的特征后,对特征选择后的低层次特征进行过滤,实现低层特征的语义增强。最后,将过滤后的低级特征与高级特征融合,增强模型的特征表示。特征融合过程如式(4)所示。

$$f_{out} = f_{low} \times CA(f_{high}) + f_{high} \quad (4)$$

其中,  $f_{low}$  表示输入低级特征, CA 表示坐标注意力机制,  $f_{high}$  表示上采样后的输入高级特征,  $f_{out}$  表示输出特征。

### 1.2 MulCAA 注意力机制

输电线图像的背景复杂性是影响检测精度的重要因素之一,引入注意力机制能够提升网络在复杂背景下的特征提取性能。注意力机制本质上是一种自适应的特征加权策略,能够通过权重分配强化输入数据中的显著特征,从而提高目标区域的定位与分类准确性。上下文锚点注意力机制(context anchor attention, CAA)<sup>[13]</sup>作为一种轻量级的结构,利用两个一维条带卷积捕捉远距离像素间的上下文依赖关系,在捕捉细长目标(如输电线路中的导线、绝缘子等)结构方面具有天然优势。但 CAA 模块仅依赖全局平均池化提取特征图的全局信息,平均池化操作如式(5)所示。

$$M(i, j) = \frac{1}{k \times k} \sum_{u=0}^{k-1} \sum_{v=0}^{k-1} A(i \times s + u, j \times s + v) \quad (5)$$

其中,  $M(i, j)$  表示输出特征图的第  $(i, j)$  个元素,  $k$  是池化窗口大小,  $u$  和  $v$  是窗口范围内的变化索引,  $s$  表示步长。平均池化操作虽能通过通过对每个通道所有像素的平均聚合,最大限度保留特征完整性,但其在对关键区域的响应上存在不足,容易忽略特征图中最具判别性的关键信息。




图 4 MulCAA 模块结构

Fig. 4 MulCAA structure

### 1.3 重参数化结构 Rep\_C3k2

在输电线检测系统中,由于无人机工作在室外场景,其获取的可见光图像常常受到复杂光照条件、地形起伏以及环境遮挡等因素的影响,容易出现图像噪声、畸变及清晰度下降等退化现象,这对目标检测算法的特征提取能力提出了更高的要求。YOLO11 中的 C3k2 模块内部采

用标准的 Bottleneck 瓶颈结构。然而,该结构由于其仅采用两层卷积操作,特征提取能力相对有限。为进一步提升模型的特征提取能力,引入 RepConv<sup>[14]</sup>重参数化卷积改进原始的 C3k2 结构,构建 Rep\_C3k2 模块。

$$M(i, j) = \max_{u=0}^{k-1} \max_{v=0}^{k-1} A(i \times s + u, j \times s + v) \quad (6)$$

为弥补这一缺陷,参考 CAA 注意力机制的设计原理,提出 MulCAA 注意力机制(multi-branch context anchor attention, MulCAA)。MulCAA 采用全局平均池化与全局最大池化并行的双分支结构。前者通过式(5)捕捉特征图的全局分布信息,反映目标与背景的整体关联;后者则通过计算每个通道内的最大值,强化局部显著特征。两种池化策略的互补性,既避免了信息损失,又突出了关键判别特征,为后续空间注意力建模提供了更全面的基础。最大池化操作如式(6)所示。

在特征提取阶段, MulCAA 针对双分支输出特征,引入水平条带卷积与垂直条带卷积代替传统的二维卷积。主要有两点原因:1)由于条带卷积本质上是一维卷积,因此对于提取细长形状物体特征具有显著优势,能够更好地满足本研究在输电线检测任务中的结构性特征提取需求。2)条带卷积具有轻量化的特性。假设输入特征图的通道数为  $C$ ,卷积的卷积核为  $kb$ ,则二维深度卷积的参数总量为  $C \times kb^2$ 。将二维卷积分解为两个一维核的张量积,分解后的参数总量为  $2 \times C \times kb$ ,因此使用条带卷积可使参数量减少到原来的  $2/kb$ ,有效实现了模型的轻量化。

随后将两个分支在通道维度进行拼接融合,经 Sigmoid 激活函数生成归一化注意力图。最终,注意力图通过逐通道加权与原始特征图  $\mathbf{X}$  相乘,实现对目标区域特征的自适应增强与背景抑制。最终输出特征可表示为:

$$M(\mathbf{X}) = \mathbf{X} \otimes \text{sigmoid}(\text{CDW}(\text{AvgPool}(\mathbf{X})) + \text{CDW}(\text{MaxPool}(\mathbf{X}))) \quad (7)$$

其中,  $\mathbf{X}$  表示输入特征, CDW 表示池化操作后的一系列卷积操作,  $M(\mathbf{X})$  为输出特征图。该设计能更精准地聚焦关键目标,尤其适用于航拍场景中遮挡目标和小目标的检测任务,在抑制复杂背景干扰的同时,显著提升模型对目标边缘、轮廓等判别性特征的建模能力。MulCAA 网络结构如图 4 所示。

多分支结构具有更好的特征提取能力,检测效果优于单分支结构,但同时也会带来更大的计算量和参数量。如

图 5(a)所示,RepConv 模块在训练阶段使用  $3 \times 3$  卷积、 $1 \times 1$  卷积和批归一化的 3 个并行分支结构,增强模型的非线性特征提取能力。在推理阶段,首先将卷积层和批归一化层融合为带偏置的卷积层,如图 5(b)所示,具体融合公式为:

$$\text{Conv}(x) = W(x) + b \tag{8}$$

$$\text{BN}(x) = \gamma \times \frac{x - \text{avg}(x)}{\sqrt{\sigma^2(x)}} + \beta \tag{9}$$

$$\begin{aligned} \text{BN}(\text{Conv}(x)) &= \gamma \times \frac{\text{Conv}(x) - \text{avg}(x)}{\sqrt{\sigma^2(x)}} + \beta = \\ &= \gamma \times \frac{W(x) + b - \text{avg}(x)}{\sqrt{\sigma^2(x)}} + \beta = \frac{\gamma \times W(x)}{\sqrt{\sigma^2(x)}} + \\ &+ \left( \frac{\gamma \times (b - \text{avg}(x))}{\sqrt{\sigma^2(x)}} + \beta \right) \end{aligned} \tag{10}$$

其中,  $\text{Conv}(x)$  表示卷积层,  $W(x)$  表示卷积层权重,  $b$  表示卷积层偏置,  $\text{BN}(x)$  表示批归一化层,  $\gamma$  是缩放参数,  $\beta$  是偏置参数,  $\text{avg}$  表示滑动均值,  $\sigma$  表示滑动方差。由式(10)可得,将  $\frac{\gamma \times W(x)}{\sqrt{\sigma^2(x)}}$  和  $\frac{\gamma \times (b - \text{avg}(x))}{\sqrt{\sigma^2(x)}} + \beta$  分

别看作融合后卷积的权重和融合后卷积偏置。 $1 \times 1$  卷积转化成  $3 \times 3$  卷积是通过零填充操作实现的。

如图 5(c)所示,在推理阶段最终合并所有分支的权重和偏置,得到一个等效的  $3 \times 3$  卷积,以此消除多分支计算开销,提高推理效率。




图 5 RepConv 网络结构

Fig. 5 RepConv network architecture

C3k2\_RepConv 模块如图 6 所示。采用集成了 RepConv 重参数化结构的 BasicBlock 模块代替传统的 Bottleneck 单元,从而有效提升模型的特征提取能力。这种重参数化的思想使得模型在训练阶段能够充分利用多分支结构带来的性能增益,而在部署进行推理时,则能够自动简化为高效的单路径结构,提高推理速度,节省内存开销。

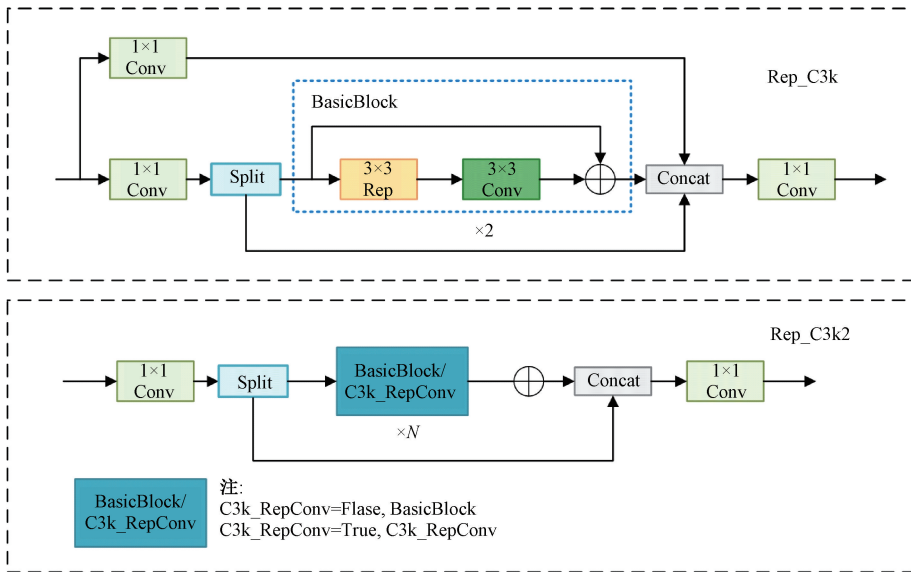


图 6 Rep\_C3k2 模块

Fig. 6 Rep\_C3k2 module

## 2 实验设计

### 2.1 实验数据集

本文数据集包含 5 479 张由无人机拍摄的架空输电线路真实场景图片,其中训练集 4 898 张,测试集 581 张。数据集中包含正常绝缘子(insulator\_normal, In)、未知绝缘子(insulator\_unknown, Iu)、缺陷绝缘子(insulator\_defect, Id)、防震锤(damper, Dp)、间隔棒(spacer-rod, Sr)5 个类别,其中未知绝缘子是指因遮挡或距离太远而无法判断绝

缘子是否有缺陷。在图像采集方面,无人机搭载高清摄像设备,在输电线路通道上方沿线路飞行采集图像,飞行高度约为 30~80 m,图片的原始分辨率为  $1\ 280 \times 720$ 。为增强模型的鲁棒性,图像采集过程中覆盖了多种天气与光照条件,包括晴天、阴天及薄雾天气等;部分样本还存在强光、逆光、遮挡等复杂场景。整体数据集既包含近距离的部件特写图像,也涵盖远距离的整塔视角,背景环境丰富多样。

此外,为验证模型的泛化能力,进一步在第 2 个输电

线路数据集(insulator, defect, line and rust, IDLR)和公共数据集 VisDrone2019 上进行泛化性实验。IDLR 数据集包括正常绝缘子(insulator),缺陷绝缘子(defect),导线散股(line)和塔台锈蚀(rust)4 个类别,其中正常绝缘子和缺陷绝缘子来自中国国家电网公司提供的公开数据集 CPLID。VisDrone2019 数据集是由天津大学等团队开源的大型无人机视角的数据集,包括训练集 6 471 张、验证集是 548 张、测试集 1 610 张,涵盖了车辆、行人等 10 个类别。该数据集因其场景多样化、目标尺度变化大、遮挡频繁等严峻挑战而广受关注。

## 2.2 实验环境

本实验是在 ubuntu 操作系统下完成的,采用的 GPU 为 NVIDIA GeForce RTX 2080 Ti,显存为 12 GB,CPU 为 Intel(R) Core (TM) i7-9700 CPU。深度学习框架为 Pytorch1.13.1,编程语言为 Python3.10,CUDA 版本为 11.6。

实验的训练参数设置如下,图像的输入尺寸为 640×640,epoch 设置为 600 轮,batch 设置为 16,优化器使用系统确定的最佳优化器 SGD,初始学习率设置为 0.01,动量为 0.9,其他参数使用 YOLO11 默认的参数。在进行 VisDrone2019 数据集训练时,epoch 设置为 300 轮,batch 设置为 8。

## 2.3 实验评价指标

本文使用各类别的准确率(precision, P)、召回率(recall, R)、各类别平均精度(average precision, AP)、平均精度均值(mean average precision, mAP)、参数量(Parameter)、计算量(FLOPs)、模型体积(Size)、每秒帧率(frames per second, FPS)作为模型的评价指标。具体的计算公式为:

$$P = TP / (TP + FP) \times 100\% \quad (11)$$

$$R = TP / (TP + FN) \times 100\% \quad (12)$$

$$AP = \int_0^1 P(R) dR \quad (13)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP(i) \times 100\% \quad (14)$$

其中,TP 指模型预测为正样本且实际上是正样本的数量,FP 表示模型预测为正样本但实际上是负样本的数量,FN 表示模型预测为负样本但实际上是正样本的数量。

## 3 实验结果分析

针对输电线路场景检测中普遍存在的小目标密集、背景干扰严重以及目标尺度变化大等问题,提出改进 YOLO11 模型。为充分验证其在输电线路检测任务中的性能,设计了 5 组实验:1)对比改进前后颈部网络结构,验证 HCDNet 网络的优越性;2)分析不同注意力机制对于模型性能的影响,选择最佳的注意力机制;3)设计模块化消融实验,评估各模块的独立贡献及协同效应;4)与目前主流的目标检测算法对比,验证改进模型的有效性;5)在其他输电线路数据集和公共数据集上,验证改进模型在输电线路领域的跨数据集泛化能力及其在通用目标检测任务中的适应性。

### 3.1 颈部网络对比实验

基于无人机进行输电线路检测是电力巡检系统中的重要且具有挑战性的任务,难点在于需在山地、林区等复杂背景中准确识别尺度差异显著的多类关键部件与缺陷目标。将 YOLO11 的颈部网络替换为 HSFPN 网络和基于 HSFPN 改进的 HCDNet 网络,以更好地适应输电线路场景下的多尺度检测需求,对比实验结果如表 1 所示。

表 1 颈部网络对比实验

Table 1 Neck network comparison experiment

| 颈部网络        | P/%         | R/%         | mAP50/%     | Params/M    | GFLOPs     | Size/MB    |
|-------------|-------------|-------------|-------------|-------------|------------|------------|
| PANet+P345  | 84.0        | 71.2        | 77.0        | 2.58        | <b>6.3</b> | 5.2        |
| PANet+P2345 | 85.1        | 74.0        | 79.7        | 2.62        | 9.8        | 5.4        |
| HSFPN       | 84.1        | <b>75.4</b> | 80.4        | 1.98        | 13.3       | 4.2        |
| HCDNet      | <b>85.2</b> | 75.1        | <b>81.2</b> | <b>1.86</b> | 10.8       | <b>4.0</b> |

注:加粗数据为最优值

将 YOLO11 的颈部网络替换为 HSFPN 网络后,模型的平均精度提升了 3.4%,模型的召回率更是提升了 4.2%,参数量减少 0.6 M,模型体积减少 1.0 MB,初步体现了 HSFPN 模块在特征融合和轻量化方面的强大性能。

进一步将颈部网络改进为 HCDNet,显而易见,改进后模型准确率、召回率、平均精度、轻量化方面相比于 PANet 和 HSFPN 网络均有非常显著的改善。

同时,为了验证改进后模块的多尺度特征融合能力,

本文还分析了不同尺度下检测目标的平均准确率和平均召回率,实验结果如表 2 所示。其中,小目标是指分辨率小于 32 pixel×32 pixel 的目标,中等目标的分辨率介于 32 pixel×32 pixel 至 96 pixel×96 pixel 之间,而大目标的分辨率则超过 96 pixel×96 pixel。实验结果表明,相较于传统的 3 层 PANet 和 4 层 PANet 网络结构,HCDNet 网络在中小尺度目标的 AP 和 AR 指标上均展现出显著优势。与原始的 3 层 PANet 网络相比,改进模型在小尺度目

标上 AP 值提升 11.1%, AR 值提升 10.6%, 可见改进网络对小目标的检测性能尤其明显。改进模块通过坐标注意力机制对高层语义信息进行高效筛选, 并将其作为权重实现对低层特征的过滤, 进一步强化了低分辨率特征

图中小目标的表征能力。同时, 该算法中等目标和大目标上也保持了良好的检测精度, 证明 HCDNet 能够在不同目标尺度上平衡精度表现, 避免了对某一尺度特征的过度依赖。

表 2 多尺度特征融合能力对比实验

Table 2 Multi-scale feature fusion capability comparison experiment

| 颈部网络        | AP-small    | AP-medium   | AP-large    | AR-small    | AR-medium   | AR-large    |
|-------------|-------------|-------------|-------------|-------------|-------------|-------------|
| PANet+P345  | 68.7        | 67.8        | 88.2        | 84.1        | 83.2        | 91.4        |
| PANet+P2345 | 78.3        | 68.4        | <b>88.3</b> | 93.0        | 84.3        | 91.9        |
| HCDNet      | <b>79.8</b> | <b>68.9</b> | 88.2        | <b>94.7</b> | <b>89.3</b> | <b>94.0</b> |

注:加粗数据为最优值

### 3.2 MulCAA 模块分析

为了验证 MulCAA 模块在算法中的有效性, 选取目前主流的注意力机制, 在引入 HCDNet 网络的基础上设计了六组对比试验。考虑到输电线路图像中存在大量小目标, 将注意力机制放在主干网络更加浅层的 P2 层和 P3 层, 即网络的第 4 层和第 7 层。浅层特征图具有较高的空间分辨率和丰富的细节信息, 对小目标的定位与识别尤为关键。

在浅层位置引入注意力机制, 可以在特征提取初期引导网络聚焦于关键区域与显著细节, 从而增强小目标特征的表征能力, 减少高层语义抽象过程中细节信息的丢失, 为后续特征融合与检测提供更具判别力的特征支撑。对比实验结果如表 3 所示。综合考虑准确率、召回率、模型精度、模型复杂度等各指标, 选择 MulCAA 模块, 在增加少量参数的同时大幅提高检测精度。

表 3 不同注意力机制对比实验

Table 3 Comparative experiments of different attention mechanisms

| 注意力机制                 | P/%  | R/%  | mAP50/% | Params/M | GFLOPs | Size/MB |
|-----------------------|------|------|---------|----------|--------|---------|
| SE <sup>[15]</sup>    | 84.2 | 75.6 | 80.6    | 1.86     | 10.8   | 4.0     |
| simAM <sup>[16]</sup> | 85.2 | 75.4 | 80.9    | 1.86     | 10.8   | 4.0     |
| CBAM <sup>[17]</sup>  | 85.6 | 75.6 | 81.0    | 1.88     | 10.8   | 4.0     |
| CAA                   | 83.8 | 77.4 | 81.6    | 1.91     | 11.8   | 4.0     |
| MulCAA                | 85.7 | 76.6 | 82.2    | 1.93     | 12.3   | 4.1     |

此外, 为了更直观的展示各种注意力机制的改进效果, 从测试数据中挑选了一张含有细长型目标、小目标和干扰目标的图片, 以热力图的形式进行可视化处理, 测试结果如图 7 所示。可以看出, SE、simAM 两种注意力机制易受细长型导线、塔杆的干扰, CBAM 注意力机制对目标本身的关注度不够, 而 CAA、MulCAA 注意力机制更加关注目标本身和其边界, 对相似物体的辨别能力更为突出, 能够有效抑制复杂背景的干扰, 且 MulCAA 模块对关键目标的关注更明显。

### 3.3 消融实验

为了验证改进方法在模型性能提升方面的有效性, 设计了 6 组消融实验, 实验结果如表 4 所示。表中模块 A 表示 HCDNet; 模块 B 表示 ICAA; 模块 C 表示 Rep\_C3k2。由表可知, 实验 2 替换 YOLO11 的颈部网络为 HCDNet 后, 模型的 P、R 和 mAP 值分别实现了 1.2%、3.9% 和 4.2% 的性能提升, 模型的参数量和体积也有所减少; 实验 3 引入 MulCAA 模块后, 增强了模型对复杂背景下小目标的特征提取能力, R 和 mAP 分别提升 2.6% 和 0.6%; 实

验 4 将 C3k2 模块替换为 Rep\_C3k2 后, 模型的 P、mAP 分别提升 2.3% 和 0.6%, 模型的参数量、计算量和体积基本不变, 但模型的召回率降低了 2.5%, 这一现象主要源于输入特征中高分辨率细粒度信息不足, 导致模型在特征筛选过程中小目标的置信度较低, 部分小目标未被有效识别。值得注意的是, 在实验 5 中, 当 Rep\_C3k2 模块与 HCDNet、MulCAA 模块联合使用时, 召回率提升至 77.7%, 这得益于 HCDNet 中引入的 P2 层能够提供的高质量细粒度特征, 弥补了单独使用 Rep\_C3k2 时的小目标信息损失, 从而进一步发挥出 Rep\_C3k2 模块在特征提取方面的优势; 对比实验 2、3 和实验 5, HCDNet 颈部网络搭配 MulCAA 注意力机制使 P、R 和 mAP 指标达到分别提升 1.5%、5.4% 和 5.2%, 组合效果优于单独使用任一模块, 验证了两模块的协同作用对性能提升的有效性; 最后实验 6 为 HCDNet-YOLO 改进算法, 模型的准确率达到 85.9%, 召回率为 77.7%, 平均精度为 82.7%, 参数量和模型体积仅有 1.95 M 和 4.1 MB, 充分验证了改进后算法高效性。

综上所述, 引入 HCDNet 网络对模型精度的提升有非




图 7 注意力机制对比图

Fig. 7 Comparison diagram of attention mechanism

表 4 不同模块的消融实验

Table 4 Ablation experiments of different modules

| 实验序号 | A | B | C | P/%         | R/%  | mAP50/%     | Params/M    | GFLOPs     | Size/MB    |
|------|---|---|---|-------------|------|-------------|-------------|------------|------------|
| 1    | — | — | — | 84.0        | 71.2 | 77.0        | 2.58        | <b>6.3</b> | 5.2        |
| 2    | ✓ | — | — | 85.2        | 75.1 | 81.2        | 1.86        | 10.8       | <b>4.0</b> |
| 3    | — | ✓ | — | 82.2        | 73.8 | 77.6        | 2.65        | 7.7        | 5.3        |
| 4    | — | — | ✓ | <b>86.3</b> | 68.7 | 77.6        | 2.59        | 6.6        | 5.3        |
| 5    | ✓ | ✓ | — | 85.5        | 76.6 | 82.2        | <b>1.93</b> | 12.3       | 4.1        |
| 6    | ✓ | ✓ | ✓ | 85.9        | 77.7 | <b>82.7</b> | 1.95        | 12.3       | 4.1        |

注:加粗数据为最优值;—表示不添加模块,✓表示添加模块

常显著的作用,同时在参数和模型体积轻量化方面也做了巨大贡献;MulCAA 注意力机制和 Rep\_C3k2 模块通过协同优化,进一步增强了模型的特征提取能力。多模块共同作用,使得模型在保持轻量化的同时,实现了检测精度的显著提升。

### 3.4 不同模型对比试验

为全面评估所提出模型的检测性能与部署效率,选取了多个代表性目标检测模型,包括经典的两阶段方法 Faster R-CNN,单阶段方法 SSD,以及当前主流的 YOLO 系列框架 (YOLOv7-tiny、YOLOv8n、YOLOv9t、YOLO11n、YOLOv12n、Gold-YOLO、YOLO-world) 进行对比实验。

由表 5 可知,所提 HCDNet-YOLO11 算法在输电线路多目标检测任务中,多数类别的检测精度均优于现有主流算法。尤其是对于检测难度较高的未知绝缘子和间隔棒两类目标,该算法的精度提升尤为明显,充分验证了 HCDNet-YOLO11 在精度提升方面的有效性。

其中,针对未知绝缘子类别进一步分析可知,HCDNet-YOLO11 算法在该类目标上的检测精度达到了 71.3%,显著高于其他对比模型。未知绝缘子通常由于拍摄距离较远或遮挡严重,呈现出尺寸较小、边缘模糊、特征不完整等特点,导致传统检测模型在该类目标上的识别效果较差。而 HCDNet-YOLO11 算法引入具备特征选择机

表 5 各类别检测精度对比结果

Table 5 Comparison of detection accuracy results for various categories

| 算法模型         | %           |             |             |             |             |
|--------------|-------------|-------------|-------------|-------------|-------------|
|              | In          | Iu          | Id          | Dp          | Sr          |
| Faster R-CNN | 83.3        | 23.5        | 76.3        | 40.3        | 39.2        |
| SSD          | 89.0        | 52.0        | 84.0        | 73.0        | 63.0        |
| YOLOv7-tiny  | 96.0        | 56.7        | 91.7        | <b>83.3</b> | 60.1        |
| YOLOv8n      | 94.9        | 56.3        | 89.7        | 79.9        | 61.8        |
| YOLOv9t      | 94.8        | 53.3        | 89.1        | 79.0        | 57.1        |
| YOLO11n      | 95.9        | 59.9        | 89.8        | 80.3        | 59.4        |
| YOLO12n      | 94.7        | 51.8        | 90.1        | 77.9        | 56.2        |
| YOLO-world   | 95.5        | 53.6        | 91.7        | 79.3        | 62.5        |
| 本文           | <b>97.1</b> | <b>71.3</b> | <b>92.1</b> | 82.3        | <b>70.8</b> |

注:加粗数据为最优值

制的 4 层 HCDNet 网络,实现了小尺寸目标的特征增强;结合 MulCAA 模块的双分支注意力结构进一步在空间和上下文层面增强了模型对关键特征和边缘细节的响应;同时,Rep\_C3k2 模块通过结构重参数化策略增强了对边缘细节、小目标及局部纹理信息的提取能力。多模块共同作用,实现了对未知绝缘子检测精度的显著提升。

由表 6 可知,与 Faster R-CNN 和 SSD 算法相比,改进

后算法在各项指标上均取得明显优势。与 YOLO 系列算法相比,改进算法在 mAP50、参数量和模型体积上均取得最优值,mAP50 分别提升了 4.5%、6.0%、8.1%、5.3%、8.6%、5.2%、5.3%;参数量分别减少了 4.02、1.00、0.02、

0.58、0.61、3.61、2.05 M;模型体积分别下降了 7.5、1.9、0.3、1.1、1.1、19.6、3.9 MB;模型的计算量和速度保持适中。所提出的模型在保持轻量化和稳定运行速度的同时,有效提升了目标检测的整体性能。

表 6 不同模型对比试验

Table 6 Comparative experiments of different models

| 算法模型                       | P/%         | R/%         | mAP50/%     | Params/M    | GFLOPs     | Size/MB    | FPS          |
|----------------------------|-------------|-------------|-------------|-------------|------------|------------|--------------|
| Faster R-CNN               | 48.7        | 57.9        | 53.0        | 41.0        | 195.2      | 108.3      | 12.0         |
| SSD                        | 83.3        | 55.6        | 71.9        | 24.3        | 176.2      | 92.7       | 30.7         |
| YOLOv7-tiny                | 87.5        | 70.9        | 77.6        | 6.0         | 13.1       | 11.6       | 124.1        |
| YOLOv8n                    | 80.4        | 71.4        | 76.5        | 3.0         | 8.1        | 6.0        | 145.0        |
| YOLOv9t                    | 79.4        | 69.5        | 74.6        | 1.97        | 7.6        | 4.4        | 80.4         |
| YOLO11n                    | 84.0        | 71.2        | 77.0        | 2.58        | <b>6.3</b> | 5.2        | 130.3        |
| YOLOv12n                   | 77.8        | 68.8        | 74.1        | 2.56        | <b>6.3</b> | 5.2        | 103.7        |
| Gold-YOLO <sup>[18]</sup>  | 84.2        | 69.5        | 76.9        | 5.61        | 12.1       | 23.6       | <b>138.8</b> |
| YOLO-world <sup>[19]</sup> | 82.3        | 69.8        | 76.5        | 4.05        | 14.1       | 8.0        | 132.9        |
| 本文                         | <b>85.9</b> | <b>77.7</b> | <b>82.7</b> | <b>1.95</b> | 12.3       | <b>4.1</b> | 105.4        |

注:加粗数据为最优值

3.5 可视化对比结果

为了更直观的比较原始 YOLO11 和 HCDNet-YOLO11 算法的性能差距,分别使用两种算法进行测试。

在实际巡检中,为了提高巡检效率,无人机远距离巡检和近距离巡检通常是相互配合的。远距离巡检会导致目标尺寸较小,细节信息缺失,增加了检测难度;而近距离巡检由于输电线路多尺度的特点天然存在一些

小尺寸目标。如图 8 第 1 行所示,图中原始标签均为未知绝缘子,椭圆框标注的为漏检情况。在密集型远距离未知绝缘子检测任务中,改进后算法检测效果由优于原算法,漏检率更低;如图 8 第 2 行所示,在近距离小目标的检测中,原始算法由于图像背景复杂,也出现漏检的情况,而改进后算法则能够有效克服复杂背景的干扰,提高了检测的准确性。

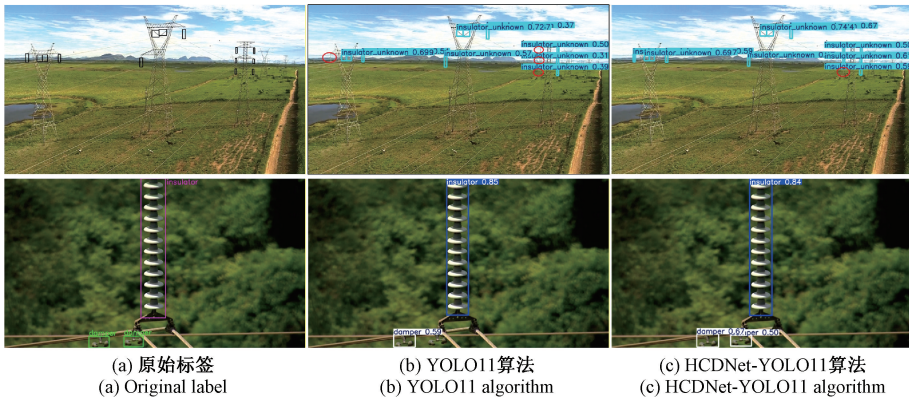


图 8 输电线路小目标检测结果对比图

Fig. 8 Comparison of small target detection results of transmission lines

由于间隔棒的中空特性,当背景出现与间隔棒类似形状的干扰目标时,YOLO11 易将背景误检为间隔棒;由于绝缘子破损区域较小,模型难以区分破损区域和正常区域,导致 YOLO11 算法将缺陷绝缘子错检为正常绝缘子。如图 9 所示,原算法中存在较多的漏检、错检问题。改进后算法引入 MulCAA 注意力机制,通过聚合锚点周围的上下文特征,显著提升了对检测目标与相似目标的辨别

性能。

3.6 泛化性实验

为了验证改进后模型的有效性和泛化性,在输电线路数据集 IDLR 和公共数据集 VisDrone2019 上进行泛化性对比实验。实验结果分别如表 7 和 8 所示。

由表 7 可知,在 IDTR 数据集上,改进算法的 R 和 mAP 分别提升了 1.1% 和 1.0%,其中正常绝缘子和缺陷

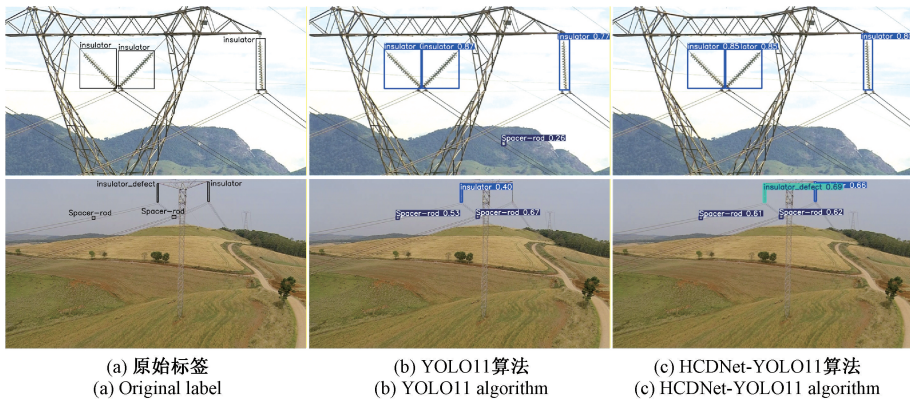


图 9 相似目标检测结果对比图

Fig. 9 Comparison of similar target detection results

表 7 IDLR 数据集实验结果对比

Table 7 Comparison of experimental results of IDLR dataset

| 算法模型   | P    | R    | mAP50 | insulator | defect | line | rust |
|--------|------|------|-------|-----------|--------|------|------|
| YOLO11 | 96.1 | 93.1 | 95.9  | 99.4      | 99.3   | 90.6 | 94.4 |
| 本文     | 96.2 | 94.2 | 96.9  | 99.4      | 99.2   | 93.6 | 95.2 |

表 8 VisDrone2019 数据集实验结果对比

Table 8 Comparison of experimental results of VisDrone2019 dataset

| 算法模型   | test 集 |      |       | val 集 |      |       |
|--------|--------|------|-------|-------|------|-------|
|        | P      | R    | mAP50 | P     | R    | mAP50 |
| YOLO11 | 40.1   | 29.6 | 27.7  | 44.8  | 33.9 | 33.9  |
| 文献[20] | —      | —    | —     | 49.7  | 38.7 | 39.8  |
| 文献[21] | 42.1   | 32.4 | 31.0  | 48.9  | 36.8 | 38.1  |
| 文献[22] | 41.7   | 30.8 | 29.8  | 45.6  | 35.7 | 36.1  |
| 本文     | 43.0   | 33.7 | 32.3  | 50.7  | 38.8 | 40.4  |

绝缘子来自中国国家电网公司提供的公开数据集,由于图像尺寸较大,其检测精度接近 100%,导线散股的精度提升了 3.0%,塔台锈蚀的精度提升了 0.8%,改进前后

检测效果如图 10 所示。实验结果表明本文算法在处理输电线路目标检测任务中表现出良好的跨数据集泛化能力。

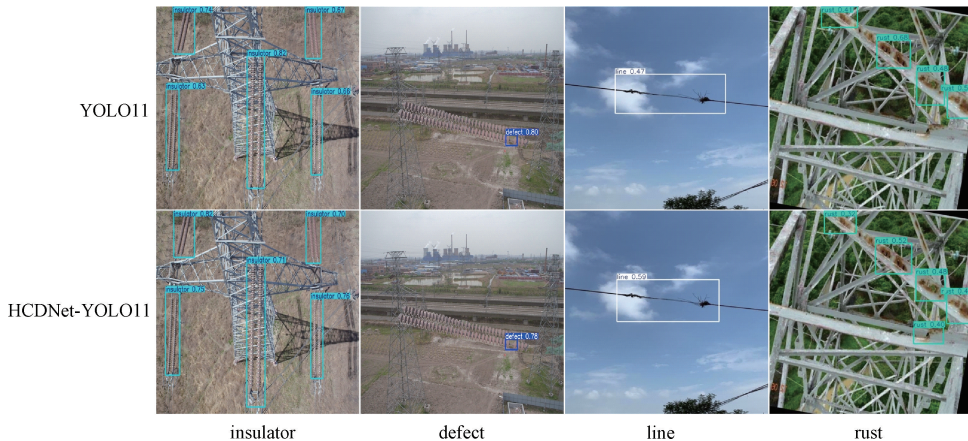


图 10 IDLR 数据集对比检测结果

Fig. 10 Partial detection results of IDLR dataset

针对 VisDrone2019 数据集的特性差异, test 集具有目标密集度高、遮挡严重的特点,而 val 集虽然数据分布更均匀但样本规模较小,导致训练结果在 test 集和 val 集上相差甚大,因此为了更全面的展示本文算法的性能,分别对 test 和 val 集进行验证。由表 8 可知,在更具挑战性的 test 集上,改进算法的 P、R 和 mAP50 分别提升 2.9%、4.1% 和 4.6%。在 val 集上,改进后算法的 P、R 和 mAP50 分别提升 5.9%、4.9% 和 6.5%。此外,与文献[20]、文献[21] 和文献[22]等优秀的算法模型相比,本文算法也取得了更好的效果,充分证明了本文所提出的改进算法在不同检测场景下的有效性。

## 4 结 论

为了解决输电线路目标检测任务中小目标检测困难,检测精度低的问题,提出了 HCDNet-YOLO11 算法。该算法通过构建 HCDNet 颈部网络,增强对不同尺度目标的特征融合与特征表达能力;通过改进 CAA 注意力机制构建 MulCAA 模块,提升模型对复杂场景中小目标及相似目标的辨别能力;引入 RepConv 重参数化卷积改进主干网络的 C3k2 模块,加强网络的特征提取能力,提高检测精度和推理速度。

将本文所提出的算法在真实场景下的输电线路数据集上进行测试,实验结果表明,本文所提出的算法与其他先进算法相比,能够有效解决目前输电线路航拍图像的小目标、多尺度问题和背景复杂问题,在检测精度提高的同时,参数量和模型大小也有所下降,同时检测速度也保持在 100 fps 以上,基本可以满足输电线路日常巡检的需求。同时,本文改进算法在其他输电线路数据集和公共数据集上也取得了较好的效果,验证了本文算法具有很好的泛化性和通用性。在未来,本研究将进一步推进模型在计算量方面的轻量化,以增强其在资源受限的无人机嵌入式平台上的部署可行性。并继续探索该算法在实际输电线路巡检任务中的应用潜力,通过实际案例分析和效益评估,为输电线路巡检提供更加高效、经济的解决方案。

## 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.
- [2] LIU CH Y, WU Y Q, LIU J J. 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.
- [3] CAI ZH W, VASCONCELOS N. Cascade R-CNN: Delving into high quality object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018: 6154-6162.
- [4] 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.
- [5] LIU W, ANGUOLOV D, ERHAN D, et al. SSD single shot multiBox detector [C]. European Conference on Computer Vision, 2016:21-37.
- [6] 阎光伟,刘润泽,焦润海,等. 基于改进 Cascade RCNN 的输电线路防振锤脱落检测方法[J]. 图学学报, 2023, 44(5): 849-860.
- [7] YAN G W, LIU R Z, JIAO R H, et al. Detection method of dropped anti-vibration hammer for transmission line based on improved Cascade RCNN[J]. Journal of Graphics, 2023, 44(5): 849-860.
- [8] 胡冠华,张永雷,申立群. 基于改进 U-Net 的轻量级输电线分割算法[J]. 电子测量与仪器学报, 2024, 38(1): 211-218.
- [9] HU G H, ZHANG Y L, SHEN L Q. Lightweight transmission line conductor segmentation algorithm with improved U-Net [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(1): 211-218.
- [10] 周景,刘心,唐振洋,等. SDH-DETR 轻量化绝缘子缺陷检测算法[J]. 电子测量技术, 2025, 48(11): 88-104.
- [11] ZHOU J, LIU X, TANG ZH Y, et al. SDH-DETR lightweight insulator defect detection algorithm [J]. Electronic Measurement Technology, 2025, 48(11): 88-104.
- [12] 刘敏,陈明,武明虎,等. GAE-YOLO: 全局感知增强的输电线路外破隐患目标检测方法[J]. 仪器仪表学报, 2025, 46(2): 267-278.
- [13] LIU M, CHEN M, WU M H, et al. GAE-YOLO: Global awareness enhanced method for detecting external force damage in power transmission lines[J]. Chinese Journal of Scientific Instrument, 2025, 46(2): 267-278.
- [14] 王彦海,郭宸昕,尹恒伟,等. 输电线路机械外破隐患目标旋转检测方法[J]. 国外电子测量技术, 2023, 42(12): 16-22.
- [15] WANG Y H, GUO CH X, YIN H W, et al. Transmission line mechanical damage hidden danger target rotation detection method [J]. Foreign Electronic Measurement Technology, 2023, 42(12): 16-22.
- [16] CHEN Y F, ZHANG CH Y, CHEN B, et al. Accurate leukocyte detection based on deformable-DETR and multi-level feature fusion for aiding diagnosis of blood

- diseases [J]. Computers in Biology and Medicine, 2024, 170:107917.
- [11] HOU Q B, ZHOU D Q, FENG J SH. Coordinate attention for efficient mobile network design [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021:13708-13717.
- [12] LIU W Z, LU H, FU H T, et al. Learning to upsample by learning to sample [C]. IEEE/CVF International Conference on Computer Vision, 2023: 6004-6014.
- [13] CAI X H, LAI Q X, WANG Y W, et al. Poly kernel inception network for remote sensing detection [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 27706-27716.
- [14] DING X H, ZHANG X Y, MA N N, et al. RepVGG: Making VGG-style ConvNets great again [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021:13728-13737.
- [15] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [16] 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, 2021:11863-11874.
- [17] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]. European Conference on Computer Vision (ECCV), 2018: 3-19.
- [18] WANG CH CH, HE W, NIE Y, et al. Gold-YOLO: Efficient object detector via gather-and-distribute mechanism [J]. ArXiv preprint arXiv: 2309.11331,2023.
- [19] CHENG T H, SONG L, GE Y X, et al. Yolo-world: Real-time open-vocabulary object detection [J]. ArXiv preprint arXiv:2401.17270,2024.
- [20] 孙冰男,于思恺,张宇,等. 融合动态多尺度轻量化无人机小目标检测算法 [J]. 电子测量技术, 2025, 48(21):199-206.
- SUN B N, YU S K, ZHANG Y, et al. Lightweight UAV small target detection algorithm based on dynamic multi-scale fusion [J]. Electronic Measurement Technology,2025,48(21):199-206.
- [21] ZHANG ZH X. Drone-YOLO: An efficient neural network method for target detection in drone images [J]. Drones, 2023, 7(8): 526.
- [22] 孙佳宇,徐民俊,张俊鹏,等. 优化改进 YOLOv8 无人机视角下目标检测算法 [J]. 计算机工程与应用, 2025, 61(1): 109-120.
- SUN J Y, XU M J, ZHANG J P, et al. Optimized and improved YOLOv8 target detection algorithm from UAV perspective [J]. Computer Engineering and Applications, 2025, 61(1): 109-120.

### 作者简介

**崔克彬**(通信作者),博士,副教授,主要研究方向为数字图像处理与模式识别。

E-mail:ncepuckb@163.com

**吕思怡**,硕士研究生,主要研究方向为计算机视觉、图像处理、目标检测。

E-mail:clong202403@163.com

**杨立然**,博士,讲师,研究方向为机器学习与数据挖掘、计算机视觉、迁移学习。

E-mail:3192073273@qq.com