

DOI:10.19651/j.cnki.emt.2518250

复杂背景下电力杆塔部件隐患检测模型研究^{*}梁伦玮¹ 张小栋^{1,2} 胡宇哲¹ 陶庆¹

(1.新疆大学机械工程学院 乌鲁木齐 830047; 2.西安交通大学机械工程学院 西安 710049)

摘要: 本文基于YOLOv8n模型提出了一种改进的电力杆塔部件隐患检测模型CML-YOLO,旨在解决复杂背景下多尺度电力杆塔部件隐患检测模型精度低、参数量多、计算量高、模型权重大的问题,主要应用于破损绝缘子、锈蚀防震锤和鸟巢等隐患目标的检测。首先,设计了C2f-HEFE模块,通过对检测目标边缘信息增强,提升了背景与目标的区分能力。其次,设计了MSFFPN模块,通过多尺度特征融合,增强了模型对多尺度目标的适应性。最后,设计了轻量化LSBDH模块,降低了模型的参数量和计算量。实验结果表明,CML-YOLO相比基线模型YOLOv8n,平均精度提升了4.4%,参数量、计算量和模型权重分别降低了33.9%、20.9%和26.4%。该模型在提升了检测性能的同时,实现了轻量化,在模型检测精度和模型权重方面实现了较好的平衡。

关键词: 电力巡检;YOLOv8;轻量化;特征融合;目标检测

中图分类号: TP391.41; TN911.73 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Research on power tower components hazard detection model under complex background

Liang Lunwei¹ Zhang Xiaodong^{1,2} Hu Yuzhe¹ Tao Qing¹

(1. School of Mechanical Engineering, Xinjiang University, Urumqi 830047, China;

2. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Based on the YOLOv8n model, this paper proposes a improved hazard detection model CML-YOLO for power tower components. It aims to solve the problems of low accuracy, large number of parameters, high computational complexity and large model weight of multi-scale power tower components hazard detection model under complex background. It is mainly used for the detection of targets such as damaged insulators, rusted dampers and bird nests. Firstly, the C2f-HEFE module is designed to enhance the ability to distinguish between background and target by enhancing the edge information. Secondly, the MSFFPN module is designed, and the multi-scale feature fusion is used to enhance the adaptability of the model to multi-scale targets. Finally, the lightweight LSBDH module is designed to reduce the number of parameters and calculation amount of the model. Experimental results show that compared with the baseline model YOLOv8n, the mean average precision of CML-YOLO is improved by 4.4%, and the number of parameters, calculation amount and model weight are reduced by 33.9%, 20.9% and 26.4% respectively. This model improves detection performance while maintaining its lightweight characteristics, achieving a good balance between model detection accuracy and model weight.

Keywords: power inspection; YOLOv8; lightweight; feature fusion; object detection

0 引言

电力杆塔是电力传输网络的关键组成部分,承担着输电线路的机械负荷,确保电力在长距离输送过程中的稳定性与可靠性。然而,电力杆塔通常位于偏远或高海拔地

区^[1],面临复杂且多变的环境条件,其部件如绝缘子、防震锤和均压环等容易受到风雨、冰雪、雷击等自然因素和鸟类筑巢等外部干扰的影响,进而出现老化、损坏或锈蚀等问题。这些问题不仅影响设备的正常运行,还可能对电力系统的稳定性和安全性造成潜在威胁。因此,检测电力杆塔

收稿日期:2025-03-05

* 基金项目:自治区“天山英才”科技创新领军人才项目(2023TSYCLJ0051)、陕西省秦创原“科学家+工程师”队伍建设项目(2022KXJ-160)资助

部件隐患以及鸟巢对维护电网稳定运行有着极为重要的意义。

传统的电力杆塔巡检主要依赖人工或半人工方式,效率低且存在安全隐患。随着无人机技术的成熟,无人机巡检逐渐取代了传统人工巡检^[2]。无人机航拍图像与深度学习目标检测技术的结合,已成为电力巡检领域的重要研究方向^[3]。

近年来,深度学习目标检测模型在电力杆塔部件隐患识别领域得到了广泛应用。根据检测机制的不同,现有算法主要分为两大类,一类是基于区域提议的两阶段检测算法,如 Faster RCNN、Mask RCNN 等;另一类是基于回归的一阶段检测算法,如 SSD、YOLO 系列等。YOLO 系列算法因其在检测精度与速度之间的优异平衡,成为工程界首选的目标检测算法之一^[4]。

当前,基于 YOLO 的目标检测技术在电力杆塔部件隐患识别中已经有了一定的进展,但仍存在一些问题。郭瑞东等^[5]设计了特征聚焦扩散网络(FFDN),提升多尺度目标的检测能力,但模型复杂度较高,计算量较大。刘航等^[6]提出了一种基于轻量化改进的 YOLOv8n 的绝缘子缺陷检测方法,通过引入小目标检测层和通道剪枝技术,提高了细微缺陷的检测能力。但剪枝过程会破坏特征金字塔层级间信息传递,导致模型训练稳定性下降。郝帅等^[7]提出了一种基于注意力机制和跨尺度特征融合的输电线路故障检测算法,提高了多尺度目标检测精度,但忽视了层间特征信息的交互。杨茜等^[8]通过引入双向特征金字塔网络实现多尺度特征融合,结合可变形注意力机制和融合池化的坐标注意力机制增强特征提取能力,降低了背景噪声对算法精度的影响,但对小尺度目标检测精度和模型压缩方面仍有改进空间。李坤祥等^[9]通过设计 FC2FA 特征融合模块、AIFI 尺度内交互模块和 SEAM-Head 检测头,解决了输电

线路多缺陷检测中目标尺度多样、背景复杂和遮挡严重等问题,但在模型轻量化方面仍有优化空间。

综上所述,当前检测模型主要的问题包括:1)巡检环境复杂多变,密集植被干扰、杆塔结构遮挡以及多变光照条件等因素,严重影响模型的识别精度;2)电力杆塔部件的多尺度特性使得现有模型难以兼顾不同尺度目标的检测精度,且多数模型仅针对单一部件进行模型优化;3)受限于无人机机载处理器性能,现有模型难以同时满足高精度和部署要求,制约了实际工程应用。

因此,亟须一种参数量少、计算量低、权重小,但检测精度高的高性能模型,用于复杂背景下多尺度电力杆塔部件隐患检测场景。为此,本文提出了一种基于 YOLOv8n 改进多隐患检测模型 CML-YOLO。首先,在主干网络,设计分层边缘信息增强模块 C2f-HEFE,增强了在复杂背景下模型对特征的提取能力,提高检测精度的同时降低了模型的计算开销。其次,在颈部网络,充分考虑层间信息关系,设计了多尺度特征聚合网络 MSFFPN,结合轻量化特征提取模块 C2f-Faster,提高了对多尺度目标的特征提取能力。最后,在头部网络,考虑到不同层级之间特征的统计量仍存在差异,设计了共享卷积参数,独立批处理的轻量化检测头 LSBDH,降低了模型的计算量和参数量。

1 基线模型 YOLOv8n

YOLO 系列算法从其出现以来,已经推出了十几个变体。YOLOv8 在边缘部署场景中的性能尤为突出,其网络结构如图 1 所示。其变体因其检测速度、准确度和效率的最佳平衡而受到关注,特别适合资源受限的环境中使用。YOLOv8 共分为 5 个版本:n、s、m、l、x。模型的大小依次递增,相应的模型推理速度依次递减。

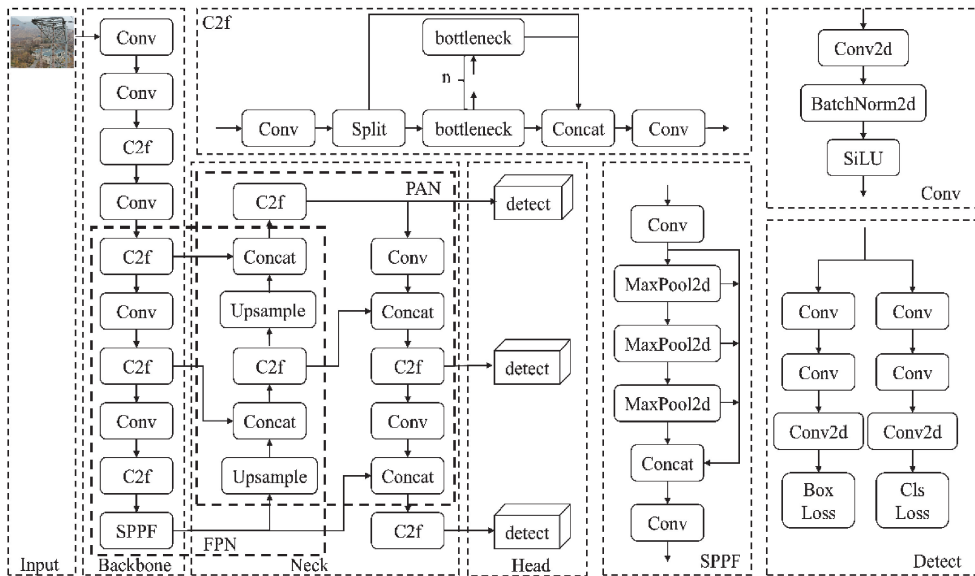


图 1 YOLOv8 网络结构
Fig. 1 Structure of YOLOv8 network

本文选择 YOLOv8n 作为基线模型。其架构主要由 3 个核心模块组成:主干网络采用改进的 CSPDarknet53 结构,通过 SPPF 模块实现高效的特征提取;颈部网络使用 PAN-FPN 架构,实现多层次特征交互;检测头采用解耦式设计,配合动态标签分配策略提升检测精度。

2 改进模型 CML-YOLO

在电力杆塔巡检任务中,使用传统的模型进行电力杆塔部件隐患检测时,面临多尺度目标检测、边缘细节提取不足和

复杂背景干扰等问题,导致模型精度下降且计算量增加。为解决这些问题,本文基于 YOLOv8n 模型框架提出了一种改进的轻量化模型:CML-YOLO。如图 2 所示,首先,在主干网络中,设计了分层边缘特征增强模块(C2f-HEFE)替代原 C2f 模块,用于增强不同尺度目标图像的边缘信息,提高复杂背景下的目标检测性能。其次,设计多尺度特征聚合金字塔网络(MSFFPN)进行特征融合,增强模型对多尺度目标的识别能力。最后,设计轻量化独立批处理检测头(LSBDH),降低计算量并提高检测速度,确保检测过程的高效性。

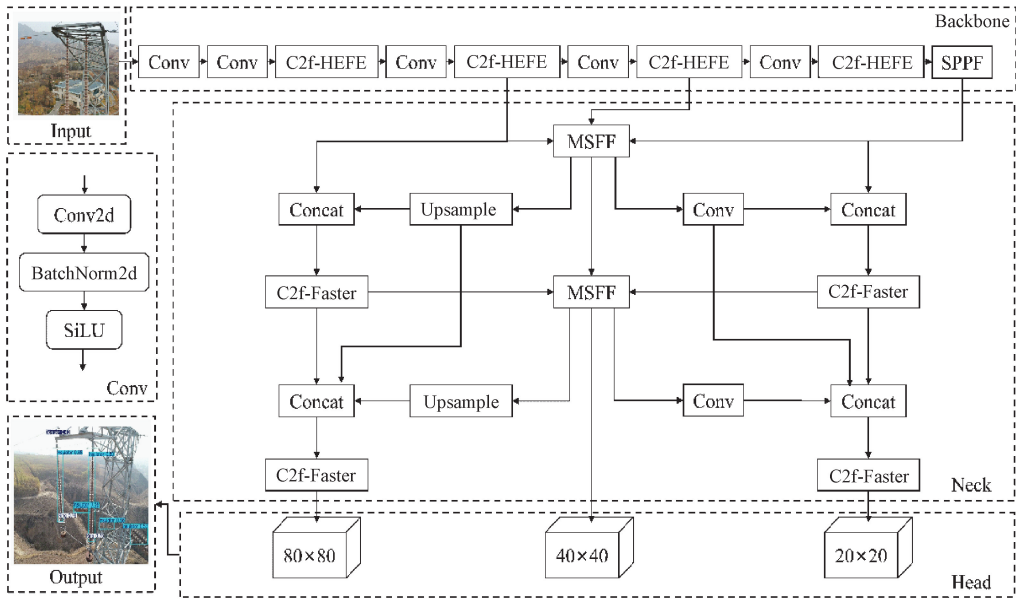


图 2 CML-YOLO 网络结构

Fig. 2 Structure of CML-YOLO network

2.1 分层边缘信息增强模块 C2f-HEFE

航拍图像中的电力杆塔通常位于复杂的环境中,如山区、森林、沙漠戈壁或城市建筑群。背景中的植被,建筑物或其他基础设施与巡检目标部件(如绝缘子、防震锤、均压环等)在颜色和纹理上高度相似,导致目标与背景之间的视觉差异降低。此外,电力杆塔部件可能被部分遮挡,进一步增加了检测难度。因此,利用边缘轮廓信息在该场景中至关重要。这类信息不仅对背景噪声有较强的抵抗力,还能通过突出目标的边界,协助模型过滤掉背景中的干扰因素。即便目标内部特征较为模糊,模型也可依靠边缘数据完成精准的定位与识别。从而有效增强模型对电力杆塔部件的识别能力,减少误检和漏检,提高巡检的准确性和效率。

然而,当前主流的目标检测模型在设计时通常忽略了这一关键因素。传统的特征提取模块 C2f 结构通过堆叠多个 Bottleneck 模块来提取深层特征,但 Bottleneck 模块通常依赖固定尺寸的卷积操作,对于捕捉图像中不同尺度的特征存在一定局限性,且 Bottleneck 结构在边缘信息的提取上较为薄弱。为了解决这些问题,本文设计了 C2f-

HEFE 模块,如图 3 所示。

具体而言,设计 HEFE 模块替换 Bottleneck 模块。首先,输入特征图 F_{in} 通过多个并行分支处理,每个分支对应一个特定的尺度(3×3 、 6×6 、 9×9 、 12×12)。在每个分支中,输入特征图通过自适应平均池化进行下采样,随后依次经过 1×1 卷积和 3×3 卷积操作,提取并细化多尺度特征,得到不同尺度的特征图 F_i :

$$F_i = Conv_{3 \times 3}(Conv_{1 \times 1}(Ad_k(F_{in}))) \quad (1)$$

其中, Ad_k 表示输入特征图 F_{in} 经过自适应平均池化操作,调整为 $k \times k$ 大小的特征图,其中 $k \in \{3, 6, 9, 12\}$, $Conv_{1 \times 1}$ 和 $Conv_{3 \times 3}$ 表示卷积核为 1×1 和 3×3 的卷积操作。

接着,提取的多尺度特征图通过双线性插值恢复到原始分辨率,得到特征图 F'_i , 确保特征图的空间一致性。然后,特征图 F'_i 输入边缘信息增强模块,得到边缘信息增强特征图 F''_i 。具体公式如下:

$$F'_i = U(F_i, (H, W)) \quad (2)$$

$$F''_i = E(F'_i) \quad (3)$$

$$E(F'_i) = F'_i + C2d_{1 \times 1} BS(F'_i - AP(F'_i)) \quad (4)$$

其中, U 表示上采样, E 表示边缘增强模块, H 和 W 分别表示输入特征图 F_{in} 的高和宽, $C2d_{1 \times 1}$ 表示卷积核为

1×1 的二维卷积, S 表示激活函数 Sigmoid, B 表示 BN 操作。AP 表示平均池化。

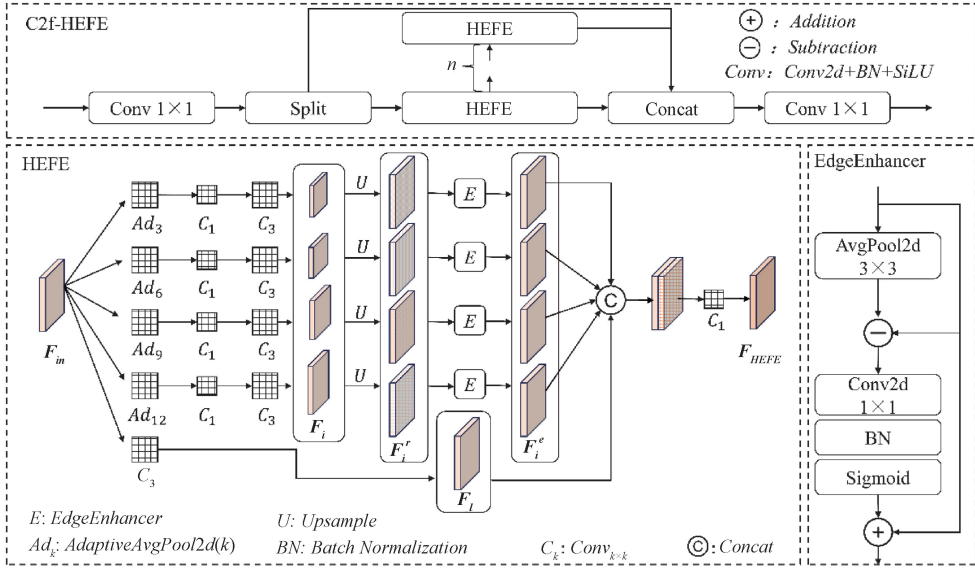


图 3 C2f-HEFE 模块结构
Fig. 3 Structure of C2f-HEFE module

与此同时,输入特征图 F_{in} 经过一个 3×3 卷积层提取局部细节特征,保留高频信息,得到局部细节特征图 F_l 。最后,所有多尺度边缘增强特征图 F_i' 与局部特征图 F_l 在通道维度上拼接,并通过 1×1 卷积进行融合,生成最终的特征图 F_{HEFE} 。具体公式如下:

$$F_l = Conv_{3 \times 3}(F_{in}) \quad (5)$$

$$F_{HEFE} = Conv_{1 \times 1}(Concat(F_l, F_i')) \quad (6)$$

其中, $Concat$ 表示通道拼接操作。

2.2 多尺度特征聚合金字塔网络 MSFFPN

在电力杆塔巡检的航拍图像中,多尺度目标(如绝缘子、防震锤、均压环、鸟巢等)广泛存在。现有方法多采用 PAN-FPN 特征金字塔策略来整合多层次特征,以提升多尺度目标检测能力,如图 4 所示。




图 4 PAN-FPN 结构
Fig. 4 PAN-FPN structure

然而,这类方法在实际应用中存在明显局限性。首先, PAN-FPN 的特征融合仅限于相邻层之间,无法实现跨层特征(如 P3 层与 P5 层)的直接交互,限制了全局信息共享,导致模型难以同时捕捉局部细节与全局结构。其次,低层细节特征与高层语义特征的融合依赖复杂的中间路

径,特征需经过多次非线性变换和下采样,导致信息损耗,细节特征弱化以及语义信息模糊化,降低了多尺度特征的互补优势。这些问题在面对尺度变化显著的检测目标时尤为突出,严重影响了检测精度。为此,本文设计了多尺度特征聚合金字塔网络,如图 5 所示。




图 5 MSFFPN 结构
Fig. 5 MSFFPN structure

该网络通过重构层间连接关系与计算流程,实现了跨层特征的高效交互与信息互补,在保证多尺度特征表达能力的同时显著降低了计算复杂度。

在特征聚合阶段,设计了聚合 3 个层级特征的 MSFF 模块,实现不同层级间信息的直接融合,如图 6(a)所示。

首先,对输入的三层特征图进行独立处理,以保持每层特征的个性化表达。对于 P5 层低分辨率特征图,通过上采样提高分辨率,并利用逐点卷积调整通道数,减少参数量和计算复杂度。P4 层特征则通过逐点卷积调整通道数,确保通道一致性。P3 层高分辨率特征则通过引入下采样模块 ADown^[10]进行分辨率匹配,如图 6(b)所示。处理后的特征图在特征融合过程中采用级联和动态增强方式:首先在通道维度上拼接三层特征图,融合不同分辨率的信

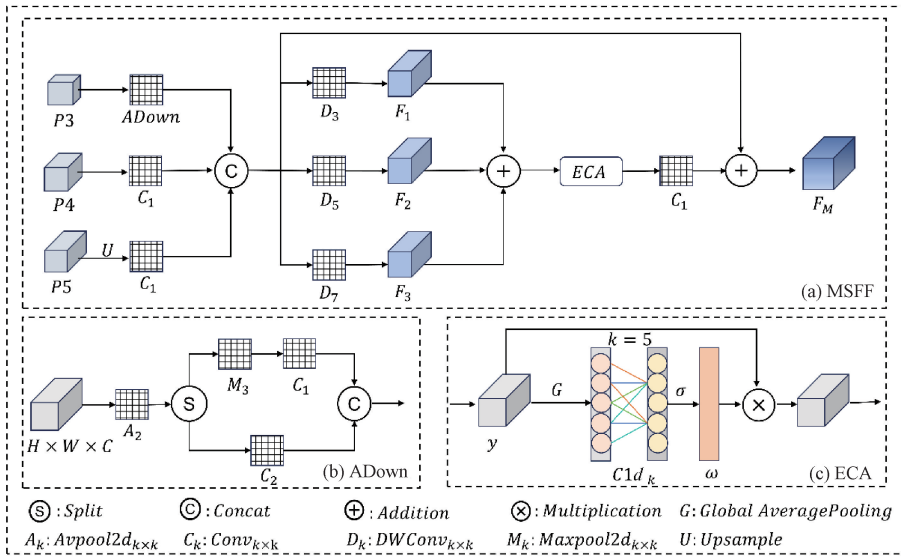


图 6 MSFF 模块结构

Fig. 6 Structure of MSFF module

息得到包含多尺度信息的特征图 F :

$$F = \text{Concat} \begin{pmatrix} A\text{Down}(P3), \\ \text{Conv}_{1 \times 1}(P4), \\ \text{Conv}_{1 \times 1}(U(P5)) \end{pmatrix} \quad (7)$$

然后通过多组深度卷积对拼接后的特征进行多尺度特征提取,小卷积核(3×3)专注于局部细节,捕捉边缘、纹理等细粒度特征;中等卷积核(5×5)提取中等范围的结构信息;大卷积核(7×7)则捕获全局上下文信息,这些不同尺寸的卷积核能够捕捉到不同范围的感受野,从而在同一网络层级上同时提取局部细节特征和全局语义信息。这种多尺度特征的融合使得模型能够构建出更加丰富和全面的特征表示,提升了特征的表征能力。数学公式如下:

$$F_1 = DWConv_{3 \times 3}(F) \quad (8)$$

$$F_2 = DWConv_{5 \times 5}(F) \quad (9)$$

$$F_3 = DWConv_{7 \times 7}(F) \quad (10)$$

其中, $DWConv_{k \times k}$ 代表卷积核大小为 k 的深度卷积。

F_1 、 F_2 、 F_3 代表不同深度卷积操作后的特征图。

为了动态调整各通道的重要性,模块引入了 ECA 注意力机制^[11],如图 6(c)所示,该机制通过全局平均池化和一维卷积生成通道权重,对特征进行加权,从而增强重要特征并抑制不重要特征。具体公式如下:

$$\omega = \sigma(C1d_k(y)) \quad (11)$$

$$k = \psi(C) = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}} \quad (12)$$

其中, $C1d_k$ 表示卷积核大小为 k 的一维卷积, y 表示输入特征图, ω 表示输出特征图, σ 表示激活函数 Sigmoid, k 表示自适应计算一维卷积核大小, C 表示通道数, γ 与 b 表示超参数(本文中 $\gamma = 2, b = 1$), $\lfloor \cdot \rfloor_{\text{odd}}$ 表示 k 只能取奇数。

最终,将加权后的特征与原始特征相加,输出融合后的多尺度特征图。聚合阶段可以用公式表示为:

$$F_M = \text{Conv}_{1 \times 1}(ECA(F_1 + F_2 + F_3)) + F \quad (13)$$

其中, F_M 表示聚合的多尺度特征图。

2.3 C2f-Faster 模块

为了优化 MSFFPN 模块在多尺度特征聚合过程中的性能和效率,增强全局感受野和特征表达能力,同时降低多尺度特征提取时的计算量和参数量,设计了轻量化特征提取模块 C2f-Faster。如图 7 所示, C2f-Faster 使用 FasterNet Block^[12]模块替换 C2f 中的 Bottleneck 模块,从而在保持模型性能的同时实现了高效轻量化设计。

FasterNet Block 模块由一个 3×3 部分卷积(PConv)和两个 1×1 卷积构成。其中, PConv 引入了一种创新的部分通道卷积策略,只对输入特征图的部分通道采用卷积操作进行特征提取,而剩余的通道则通过恒等映射直接保留原始信息。此外, 1×1 卷积用于对通道间的信息进行线性组合和重新分配,从而增强特征表达能力。

2.4 轻量化独立批处理检测头 LSBDH

为了进一步轻量化网络并提升识别精度,本文设计了 LSBDH 模块,如图 8 所示。该模块通过共享卷积、独立批归一化和动态分组特性实现高效的特征处理与目标检测,既提升检测性能,又降低计算开销和参数量。

具体而言,输入特征图首先通过 1×1 卷积统一调整各层特征图的通道数,减少计算复杂度。然后,特征图通过两个 3×3 卷积堆叠而成的共享卷积模块进行处理,捕捉更丰富的上下文信息,同时减少参数冗余。为了避免共享卷积带来的通道间信息混淆,每次卷积后引入独立批归一化操作,独立调整每层特征图的特征分布。该设计在保持轻量化的同时,保留了目标的细粒度特征,提升了检测精度。

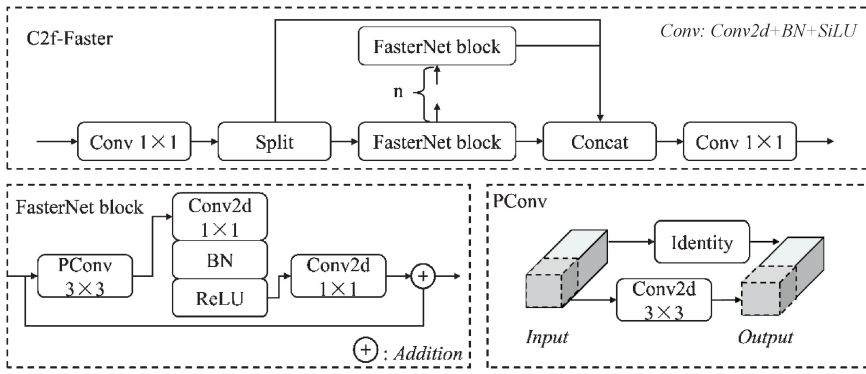


图 7 C2f-Faster 模块结构
Fig. 7 Structure of C2f-Faster module

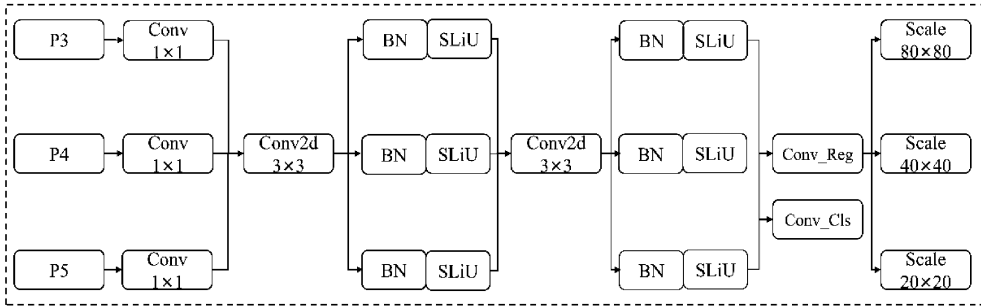


图 8 LSBDH 模块结构
Fig. 8 Structure of LSBDH module

3 实验与分析

3.1 数据集制作

本文所使用数据集一部分来自国网阿克苏供电公司拍摄的电力杆塔部件隐患图像,共有 150 张;另一部分图像来自于网络公开数据集 CPLID,共有 300 张。如图 9 所示,包含绝缘子、缺陷绝缘子、防震锤、锈蚀防震锤、均压环、鸟巢等

6 种类别。使用 LabelImg 软件对隐患样本进行标注,标签类别为: insulator、insulator defect、damper、rust damper、grading ring、nest。同时,为了防止网络在训练过程中产生过拟合,对获得的图像进行数据增强,通过随机添加噪声、旋转、调整亮度和高斯模糊等操作,以提高网络模型的泛化能力。最终,获得的数据集图像数量为 2 350 张。图像数据按照 7:2:1 的比例分为训练集、验证集和测试集。

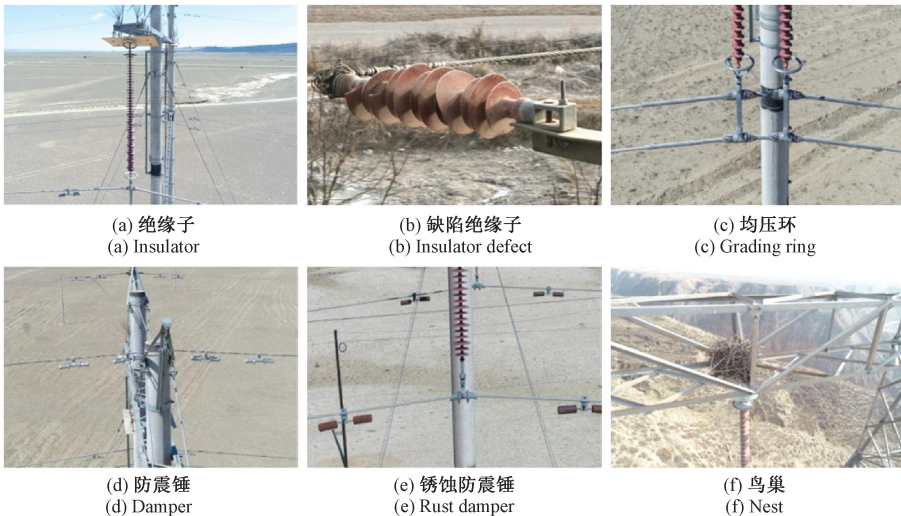


图 9 数据集样本
Fig. 9 Dataset sample

3.2 实验环境

本实验的运行环境在 Ubuntu 22.04 操作系统下配置, GPU 型号为 NVIDIA GeForce RTX 3080 Ti(12 GB), CPU 型号为 Intel Xeon Silver 4214R, 并行计算架构采用 CUDA 12.1, 编程语言为 Python 3.10.8, 基于 PyTorch 2.1.0 深度学习框架进行开发。

模型初始学习率为 0.01, 动量为 0.937, 权重衰减为 0.0005, 训练轮次数量为 300, 每批图像数量为 16, IoU 阈值为 0.5。

3.3 评价指标

本文使用精确率(Precision)、召回率(Recall)、平均精度(mAP@50)衡量模型检测精度;模型权重(Weight)衡量模型部署的难易程度;模型参数量(Parameters)衡量模型空间复杂度;浮点运算次数(GFlops)衡量模型计算复杂度和执行效率。

$$P = \frac{TP}{TP + FP} \quad (14)$$

$$R = \frac{TP}{TP + FN} \quad (15)$$

$$mAP = \frac{\sum_{i=1}^N A_{p,i}}{N} \quad (16)$$

其中, TP 表示模型预测正确的样本数, FP 表示模型将错误样本预测为正确的样本数, FN 表示模型将正确样本预测为错误的样本数。 N 表示数据集中类别的数量, $A_{p,i}$ 表示第 i 类的平均精度。

3.4 与经典的金字塔特征网络对比实验

本文设计了在 YOLOv8n 中加入轻量化多尺度特征聚合金字塔网络(MSFFPN)与加入其它经典金字塔网络模型的对比实验, 对比结果如表 1 所示。

表 1 与其他金字塔网络对比实验

Table 1 Comparison experiments with other pyramid networks

模型	Precision/%	Recall/%	mAP@50/%	Parameter/ 10^6	FLOPs/G	Weight/MB
None	93.0	84.6	90.5	3.15	8.1	5.99
+FDPN ^[13]	94.8	87.4	92.3	3.04	9.4	6.09
+AFPV ^[14]	92.3	79.6	86.1	2.61	8.4	5.36
+BiFPN ^[15]	93.5	81.5	87.8	2.01	7.1	4.07
+GDFPN ^[16]	92.9	85.5	90.0	3.26	8.4	6.58
+MSFFPN	95.0	87.5	92.5	2.91	8.4	5.82

注:加粗数据为最优值

如表 1 所示, 将本文设计的 MSFFPN 模块集成到 YOLOv8n 模型中后, 在与集成其他多种改进的金字塔网络结构进行对比时, 该模型在精确率、召回率和平均精度均排第 1, 参数量排第 3, 计算量排 2, 模型权重排第 3。综上所述, 通过引入 MSFFPN 模块, 不仅提升了模型对多尺度目标的检测能力, 同时有效控制了模型复杂度。模型在精度、计

算量、参数量和模型权重等关键指标上取得有效平衡。

3.5 消融实验

为了验证各改进模块对于网络模型性能提升的有效性, 本文设计消融实验。在基线模型 YOLOv8n 中逐步引入 C2f-HEFE 模块、MSFFPN 模块及 LSBDH 模块。消融实验结果如表 2 所示。

表 2 消融实验

Table 2 The ablation experiments

C2f-HEFE	MSFFPN	LSBDH	P/%	R/%	mAP@50/%	Parameter/ 10^6	FLOPs/G	Weight/MB
			93.0	84.6	90.5	3.15	8.1	5.99
✓			93.5	85.7	91	2.86	7.6	5.88
	✓		95.0	87.5	92.5	2.91	8.4	5.82
		✓	92.9	84.7	90.5	2.56	6.7	5.12
✓	✓		94.8	87.8	93.2	2.76	8.0	5.72
✓		✓	93.5	85.9	91.1	2.21	6.0	4.64
	✓	✓	93.8	87.5	92.8	2.23	7.0	4.52
✓	✓	✓	96.6	90.2	94.9	2.08	6.4	4.41

注:加粗数据为最优值;✓表示使用了该模块

由表 2 可知, 只使用 C2f-HEFE 时, 模型的精确率、召回率和平均精度分别提升 0.5%、1.1% 和 0.5%, 参数量、

计算量和模型权重分别下降了 9.2%、6.1% 和 1.8%。当只使用 MSFFPN 时, 模型的精确率、召回率和平均精度分

别提升 2.0%、2.9% 和 2.0%，参数量和模型权重分别下降了 7.6% 和 2.8%，但是计算量上升了 3.7%。当只使用 LSBDH 时，模型的精确率下降了 0.1%，召回率提升 0.1%，平均精度保持不变，参数量、计算量和模型权重分别下降了 18.7%、17.2% 和 14.5%。同时使用 C2f-HEFE 和 MSFFPN 时，模型的精确率、召回率和平均精度分别提升 1.8%、3.2% 和 2.7%，参数量、计算量和模型权重分别下降了 12.4%、1.2% 和 4.5%。同时使用 C2f-HEFE 和 LSBDH 时，模型的精确率、召回率和平均精度提升 0.5%、1.3% 和 0.6%，参数量、计算量和模型权重分别下降了 29.8%、25.9% 和 22.5%。同时使用 MSFFPN 和 LSBDH 时，模型的精确率、召回率和平均精度分别提升 0.8%、2.9% 和 2.3%，参数量、计算量和模型权重分别下降了

29.2%、13.6% 和 24.5%。同时使用这 3 个模块时，相比于基线模型 YOLOv8n，模型的精确率、召回率和平均精度分别提升 3.6%、5.6% 和 4.4%，参数量、计算量和模型权重分别下降了 33.9%、20.9% 和 26.4%。

如图 10 所示，可以看出随着改进模块的添加，模型的精确率、召回率以平均精度均显著提高。这说明本文所提出的隐患检测模型 CML-YOLO 对于电力杆塔部件的隐患检测是有效的。

3.6 对比实验

为了验证 CML-YOLO 模型的优越性，本文设计了对比实验，将 CML-YOLO 模型与当前主流的目标检测模型以及相关的改进模型在相同实验条件下进行对比。实验结果如表 3 所示。




图 10 CML-YOLO 与基线模型 YOLOv8n 的精确率、召回率、平均精度 mAP@50 对比

Fig. 10 Comparison of precision, recall, mAP@50 between CML-YOLO and the baseline model YOLOv8n

表 3 对比实验

Table 3 Comparison experiments

模型	P/%	R/%	mAP@50/%	Parameter/10 ⁶	FLOPs/G	Weight/MB
YOLOv5n	92.7	82.2	88.5	2.51	7.1	5.05
YOLOv6n	79.0	66.4	71.4	4.16	11.5	8.18
YOLOv7-tiny	93.1	84.4	89.3	6.23	13.9	12.3
YOLOv8n	93.0	84.6	90.5	3.15	8.1	5.99
YOLOv9t	87.3	71.3	78.6	1.73	6.4	4.01
YOLOv10n	90.5	82.0	88.4	2.26	6.5	5.51
YOLOv11n	91.7	82.5	89.1	2.58	6.4	5.25
YOLOv11s	96.1	88.3	93.9	9.42	21.3	18.3
Hyper-YOLO ^[17]	94.0	88.4	93.2	3.63	9.3	7.7
Mamba-YOLO ^[18]	94.7	87.9	92.8	21.7	50.6	37.3
RT-DETR-R1 ^[19]	96.5	89.7	94.5	19.9	57.0	40.5
CML-YOLO(ours)	96.6	90.2	94.9	2.08	6.4	4.41

注：加粗数据为最优值

由表 3 数据可知，与常规模型 YOLOv5n、YOLOv6n、YOLOv7-tiny、YOLOv8n、YOLOv9t、YOLOv10n、YOLOv11n、YOLOv11s、RT-DETR-R18 以及改进模型 Hyper-YOLO 和 Mamba-YOLO 相比，CML-YOLO 的精确率、召回率、

平均精度以及计算量这 4 个指标均优于其他模型。参数量和模型权重仅次于 YOLOv9t 模型。参数量相比于 YOLOv9t 模型增加了 20.2%，模型权重相比于 YOLOv9t 模型增加了 10%。实验结果表明，改进后的模型在电力杆

塔部件隐患识别方面表现出更优的效果。尽管与YOLOv9-tiny模型相比,CML-YOLO模型在参数量和模型权重上有所增加,但在精度和计算量方面的提升,使其在电力杆塔巡检这个特定场景的实际应用中更具优势。

3.7 不同缺陷类别检测精度对比实验

为了验证CML-YOLO的缺陷检测性能,对比了数据集中3种缺陷类别在多个模型上的检测精度差异,实验结果如表4所示。

表4 模型在不同缺陷类别检测效果的对比实验结果

Table 4 Comparison of detection performance across different defect categories for models

模型	Insulator-Defect		Rust-Damper		Nest	
	mAP@50/%	Recall/%	mAP@50/%	Recall/%	mAP@50/%	Recall/%
YOLOv5n	69.2	62.9	87.9	80.4	94.6	91.2
YOLOv6n	66.7	62.1	88.2	82.4	78.5	71.4
YOLOv7-tiny	65.2	61.7	87.1	81.2	83.5	76.9
YOLOv8n	73.7	64.3	90.7	82.1	95.3	91.8
YOLOv9t	76.9	65.2	71.5	62.3	88.8	83.7
YOLOv10n	71.5	62.7	91.1	82.4	90.3	86.8
YOLOv11n	72.3	60.8	88.1	79.1	94.8	90.4
YOLOv11s	81.0	69.9	94.1	86.9	94.9	91.3
Hyper-YOLO	82.2	70.6	92.2	86.7	95.3	92.1
Mamba-YOLO	82.1	69.9	93.2	85.4	92.7	92.2
RT-DETR-R18	87.2	78.1	94.2	87.1	95.1	93.6
CML-YOLO(ours)	87.8	78.5	93.7	87.1	95.4	92.8

注:加粗数据为最优值

通过分析表4数据可知,CML-YOLO模型在缺陷绝缘子、锈蚀防震锤、鸟巢三种类别的检测效果均优于基线模型YOLOv8n。平均精度分别提高了14.1%、3.0%、0.1%,召回率分别提高了14.2%、5.0%、1.0%。相比RT-DETR-R18模型,在锈蚀防震锤的检测上,平均精度降低了0.5%;在鸟巢的检测上,召回率降低了0.8%。但是,CML-YOLO模型的参数量、计算量以及模型权重仅为RT-DETR-R18模型的1/10,这表明CML-YOLO模型在保证检测精度的同时,实现了模型的轻量化,更适合无人机的隐患检测任务。

3.8 热力图可视化对比

目前,在目标检测领域,模型的决策过程往往缺乏透明度。为了增强模型的可解释性,本文采用Grad-CAM技术生成热力图,并将其与原始图像融合,以此直观地揭示网络是否有效地捕捉到了关键特征。如图11所示,相较于原始模型,本研究所提出的改进方法所产生的热力图更加贴合实际样本的特征分布,在识别电力杆塔部件的隐患方面展现了更高的精确度。改进后的模型在关键像素区域产生了更广泛的激活,响应强度也更为显著,从而为模型的检测逻辑提供了清晰的解释。

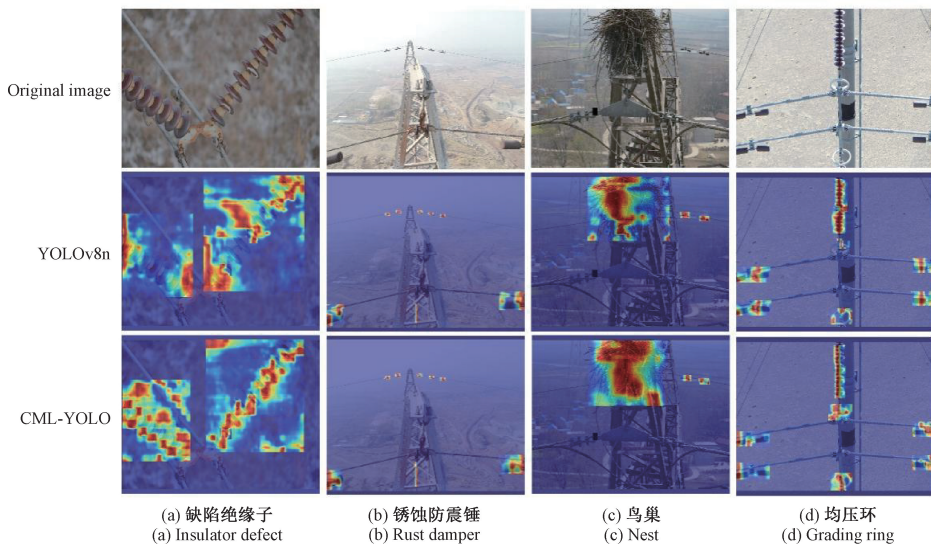


图11 热力图效果对比

Fig. 11 Heat map effect comparison

3.9 识别效果可视化对比

为了直观展示 CML-YOLO 模型的识别效果,选用基线模型 YOLOv8n 与 CML-YOLO 模型进行识别效果对比。

如图 12 所示,电力杆塔的复杂结构导致各部件之间经常出现遮挡现象,尤其在图像拍摄角度不理想或塔身部

件繁多的情况下,YOLOv8n 模型因无法有效捕捉被遮挡部件的特征信息而出现漏检现象。而 CML-YOLO 模型,通过对图像中边缘信息的增强,提高了对遮挡信息的处理能力,从而能够更好地应对复杂场景,成功识别出被遮挡的部件。



图 12 遮挡情况下识别效果对比

Fig. 12 Comparison of recognition effects under occlusion

如图 13 所示,在不同背景下,电力杆塔各部件与周围环境的颜色、形状或纹理相似。YOLOv8n 模型在这种情况下会将背景与部件混淆,导致误检现象。而 CML-YOLO 模型通过

优化网络结构,引入更强的多尺度特征融合和信息增强机制,能够有效区分背景与目标部件之间的细微差异,成功识别出真正的隐患部件,确保了检测的高精度和稳定性。




图 13 不同背景下识别效果对比

Fig. 13 Comparison of recognition effects under different backgrounds

4 结 论

本文提出的轻量化多隐患检测模型 CML-YOLO,与

基线模型 YOLOv8n 相比,在减小计算量、参数量和模型权重的同时,提升了隐患检测的精度。针对电力杆塔巡检任务中出现的多尺度目标、遮挡现象、背景复杂及隐患特征

不明显等挑战,CML-YOLO 通过引入创新的 C2f-HFEF 模块、MSFFPN 网络结构和轻量化检测头 LSBDH,有效提升了特征提取、信息融合和检测能力。特别是在多尺度目标、模糊目标和复杂背景下的隐患检测任务中,表现出了较强的鲁棒性和高效性。实验结果表明,CML-YOLO 的表现优于主流目标检测算法,尤其在保持较低计算开销的同时,有更高的检测精度,体现了该模型在电力杆塔巡检这种需要兼顾高精度与低资源消耗场景中的实际应用潜力。

参考文献

- [1] QIU L, HE L, LU H, et al. Systematic potential analysis on renewable energy centralized co-development at high altitude: A case study in Qinghai-Tibet plateau[J]. *Energy Conversion and Management*, 2022, 267: 115879.
- [2] 郭雨,马美玲,黎大林.基于改进 YOLOv5 的轻量化绝缘子表面缺陷检测[J].*激光与光电子学进展*, 2023, 60(24):222-229.
GUO Y, MA M L, LI D L. Detection of surface defects in lightweight insulators using improved YOLOv5 [J]. *Laser & Optoelectronics Progress*, 2023, 60(24): 222-229.
- [3] BOUGUETTAYA A, ZARZOUR H, KECHIDA A, et al. Vehicle detection from UAV imagery with deep learning: A review[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 33(11): 6047-6067.
- [4] 刘传洋,吴一全,刘景景.无人机航拍图像中绝缘子缺陷检测的深度学习方法研究进展[J].*电工技术学报*, 2025,40(9):2897-2916.
LIU CH Y, WU Y Q, LIU J J. Research Progress of deep learning methods for insulator defect detection in UAV based aerial images[J]. *Transactions of China Electrotechnical Society*, 2025,40(9):2897-2916.
- [5] 郭瑞东,蓝贵文,范冬林,等.基于特征聚焦扩散网络的电力巡检目标检测算法[J/OL].*图学学报*,1-9[2025-04-09]. <http://kns.cnki.net/kcms/detail/10.1034.T.20250305.1839.004.html>.
GUO R D, LAN G W, FAN D L, et al. An object detection algorithm for powerline inspection based on the feature focus & diffusion network[J/OL]. *Journal of Graphics*, 1-9[2025-03-26]. <http://kns.cnki.net/kcms/detail/10.1034.T.20250305.1839.004.html>.
- [6] 刘航,李明,刘志坚,等.基于轻量化改进 YOLOv8n 绝缘子自爆缺陷检测方法[J].*电子测量与仪器学报*, 2025,39(1):57-69.
LIU H, LI M, LIU ZH J, et al. Self-explosion defect detection method of insulator based on lightweight and improved YOLOv8n [J]. *Journal of Electronic Measurement and Instrumentation*, 2025, 39(1): 57-69.
- [7] 郝帅,赵新生,马旭,等.基于 TR-YOLOv5 的输电线路多类缺陷目标检测方法[J].*图学学报*, 2023,44(4): 667-676.
HAO SH, ZHAO X SH, MA X, et al. Multi-class defect target detection method for transmission lines based on TR-YOLOv5[J]. *Journal of Graphics*, 2023, 44(4): 667-676.
- [8] 杨茜,熊炜,孟圣哲,等.基于改进 YOLOv8 的绝缘子缺陷检测方法[J].*电子测量技术*, 2025,48(7):86-97.
YANG Q, XIONG W, MENG SH ZH, et al. Insulator defect detection method based on improved YOLOv8 [J]. *Electronic Measurement Technology*, 2025, 48(7): 86-97.
- [9] 李坤祥,刘大明.改进 YOLOv10 的架空输电线路多缺陷检测方法[J].*电子测量技术*, 2025,48(9):156-167.
LI K X, LIU D M. Detection method of overhead transmission line defects based on improved YOLOv10[J]. *Electronic Measurement Technology*, 2025, 48(9): 156-167.
- [10] WANG C Y, YE H I H, MARK LIAO H Y. Yolov9: Learning what you want to learn using programmable gradient information [C]. *European Conference on Computer Vision*. Cham: Springer Nature Switzerland, 2024: 1-21.
- [11] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 11534-11542.
- [12] CHEN J, KAO S, HE H, et al. Run, don't walk: Chasing higher FLOPS for faster neural networks [C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2023: 12021-12031.
- [13] CHAI Z, ZHENG T, LU F. StarCAN-PFD: An efficient and simplified multi-scale feature detection network for small objects in complex scenarios [J]. *Electronics*, 2024, 13(15): 3076.
- [14] 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)*. IEEE, 2023: 2184-2189.
- [15] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation [C]. *IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 8759-8768.
- [16] WANG C, HE W, NIE Y, et al. Gold-YOLO: Efficient object detector via gather-and-distribute

- mechanism [J]. *Advances in Neural Information Processing Systems*, 2023, 36: 51094-51112.
- [17] FENG Y F, HUANG J G, DU SH Y, et al. Hyper-YOLO: When visual object detection meets hypergraph computation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2025, 47(4):2388-2401.
- [18] WANG Z, LI C, XU H, et al. Mamba YOLO: SSMs-based YOLO for object detection [J]. *ArXiv preprint arXiv:2406.05835*, 2024.
- [19] ZHAO Y, LYU W, XU S, et al. Detsr beat yolos on real-time object detection[C]. *IEEE/CVF Conference*

on computer vision and Pattern Recognition, 2024: 16965-16974.

作者简介

梁伦玮, 硕士研究生, 主要研究方向为输电线智能巡检。

E-mail: 531421389@qq.com

张小栋(通信作者), 教授, 博士生导师, 主要研究方向为智能机器人技术。

E-mail: xdzhang@mail.xjtu.edu.cn

胡宇哲, 硕士研究生, 主要研究方向为输电线智能巡检。

E-mail: 2696003714@qq.com

陶庆, 教授, 博士生导师, 主要研究方向为巡检机器人。

E-mail: xjutao@qq.com