RDCL-YOLO: 动态特征混合与权值共享的轻量化无人机输电线路小目标检测

吴朝明[1,2]，彭 松[1,2]，艾青松[4]，邓承志[1,2,3†]，孙小惟[1]

(1. 江西水利电力大学 信息工程学院， 南昌 330099；
2. 江西水利电力大学 智慧水利江西省重点实验室， 南昌 330099；
3. 肇庆学院 电子与电气工程学院， 广东 肇庆 526061；
4. 广东创新科技职业学院 经济管理学院， 广东 东莞 523960)

摘 要: 针对输电线路航拍巡检时高噪声图像特征无法有效表达导致小目标难以准确检测的问题, 提出一种基于 YOLOv11 架构的轻量化无人机目标检测网络 RDCL-YOLO. 所提出网络融合多分支特征提取方法与自适应通道特征选择机制. 首先, 设计 DSDC 下采样方法, 使用多线程进行下采样, 将不同采样程度的特征图进行融合, 显著提升模型在高信噪比图像中对目标的细节捕捉能力; 然后, 设计 DRHC-C3k2 模块, 融合动态增量混合卷积与通道广播注意力机制改进传统 C3k2 模块, 使用不同大小的卷积并进行可学习权重分配, 减少计算冗余, 实现多尺度特征的自适应融合, 以低参数量提升模型对多尺度目标特征的融合能力; 最后, 引入卷积权值共享机制以及多向感知模块 PSF 改进检测头, 进一步降低模型的整体参数量并提升模型对多尺度目标的聚焦能力. 实验结果表明, 改进后的模型将 mAP50 提升了 2.76%, mAP50-95 提升了 1.11%, 参数量降低了 24.3%, 计算量与模型大小分别减少了 17.4% 与 11.5%.

关键词: YOLOv11；缺陷检测；小目标检测；通道权重分配；多向感知卷积；权值共享

中图分类号: TP391.41 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2026.0653

引用格式: 吴朝明, 彭松, 艾青松, 等. RDCL-YOLO: 动态特征混合与权值共享的轻量化无人机输电线路小目标检测 [J]. 控制与决策.

RDCL-YOLO: Lightweight UAV transmission line small object detection based on dynamic feature mixing and weight sharing

WU Zhao-ming[1,2]，*PENG Song*[1,2]，*AI Qing-song*[4]，*DENG Cheng-zhi*[1,2,3†]，*SUN Xiao-wei*[1]

(1. School of Information Engineering， Jiangxi University of Water Resources and Electric Power， Nanchang 330099，China；2. Key Laboratory of Smart Water Conservancy in Jiangxi Province，Jiangxi University of Water Resources and Electric Power， Nanchang 330099，China；3. School of Electronic and Electrical Engineering，Zhaoqing University，Zhaoqing 526061，China；4. School of Economics and Management，Guangdong Innovative Technical College，Dongguan 523960，China)

Abstract: In UAV-based aerial inspections of transmission lines, the ineffective feature representation caused by heavy background noise severely hinders the accurate detection of small-scale targets. To address this critical issue, this paper proposes a lightweight UAV object detection network, termed RDCL-YOLO, built upon the YOLOv11 architecture. The proposed framework integrates a multi-branch feature extraction methodology with an adaptive channel feature selection mechanism. The main contributions of this work are summarized as follows: First, a novel DSDC module is engineered. By employing multi-branch downsampling to fuse feature maps across varying sampling granularities, this method significantly enhances the network's capacity to capture target details within images characterized by complex noise. Second, a DRHC-C3k2 module is introduced to refine the traditional C3k2 architecture by synergizing dynamic incremental hybrid convolutions with a channel broadcasting attention mechanism. By utilizing multi-scale convolutional kernels coupled with learnable weight allocation, this module curtails computational redundancy and achieves the adaptive fusion of multi-scale features, thereby bolstering the representation of multi-scale targets while

收稿日期: 2026-07-01；**录用日期:** 2026-09-06.
基金项目: 江西省自然科学基金项目 (20252BAC240112)；江西省教育厅科学技术项目 (GJJ2501401).
责任编委: 王琦.
†通信作者. E-mail: dengchengzhi@126.com.

maintaining a minimal parameter footprint. Finally, the detection head is upgraded by incorporating a convolutional weight-sharing mechanism and a multi-directional perception module (PSF). This integration further minimizes the overall parameter count and bolsters the model's attentional focus on multi-scale targets. Experimental results demonstrate that RDCL-YOLO improves mAP50 by 2.76% and mAP50-95 by 1.11% over the baseline, while reducing parameter count by 24.3%, computational cost by 17.4%, and model size by 11.5%.

Keywords: YOLOV11； defect detection； small object detection； channel weight allocation； multi-directional perception convolution；weight sharing

0 引 言

智能电网建设推动输电线路巡检向自动化、智能化方向转型. 依托无人机灵活机动、作业成本低、高危场景适配性强的优势, 结合深度学习图像识别技术开展线路故障检测, 已成为电力运维领域的主流技术方案, 广泛应用于线路隐患排查、设备状态评估、常态化巡检作业等工程场景[1-2]. 相较于传统人工巡检模式, 无人机巡检可有效规避高空作业风险、覆盖大范围巡检区域, 但野外复杂作业环境给缺陷精准识别带来诸多干扰. 实际巡检过程中, 无人机悬停姿态不固定、拍摄角度随机, 叠加野外背景繁杂、光照强度动态变化等因素, 易造成线路断股、破损、异物等微小缺陷特征模糊、目标形变严重. 与此同时, 无人机机载硬件资源有限, 无法搭载高算力设备, 对检测模型的参数规模与推理速度提出了严格的轻量化要求[3-5]. 因此, 开发适配野外复杂环境、兼顾检测精度与实时性的轻量化检测算法, 是当前输电线路智能巡检技术落地的关键.

目标检测领域主要有两种方法: 一级检测器, 如SSD[6]、Transformer[7]、YOLO 系列和 RetinaNet[8], 以及两级检测器如 R-CNN、Faster R-CNN[9] 和 Cascade R-CNN[10]. 单级检测器虽然比两级检测器的精确度略低, 但在速度和可及性方面具有优势. YOLO 模型相较于其他的单级检测模型在检测精度与场景适应性指标上具有更均衡的优势, 已成为输电线路缺陷检测场景中应用最广泛的算法之一. 在目标检测领域, 融合多尺度特征是一种针对检测目标尺度多样的有效策略. 这种策略可通过引入通道注意力机制或通过上采样创建多尺度图像金字塔, 然后将其转换为特征金字塔, 增强模型对不同尺度目标的感受野. 针对电力巡检场景中目标较小易丢失问题. Chen 等[11] 提出了 FreqDETR, 这是一种基于频域分析的框架. 该模型采用双分支频率增强卷积模块 (FECM) 协同整合空间特征与频率特征, 并结合解耦尺度内部交互块 (DSC-CLO) 将高频局部细节与低频全局信息融合, 从而保留边缘结构并建模全局上下文. Li 等[12] 采用渐进式二部图优化策略进行联邦解耦将图像分离, 结合精细化特征金字塔网络 RefineFPN 加强不同尺度的特征融合提高检测精度. 该方法能有效解决过多下采样可能引起的小目标信息丢失问题. Lei 等[13] 提出的 YOLOv11-MDS, 结合多尺度卷积注意力 (MSCA) 和分布偏移卷积 (DSConv), 协同深度条带卷积和通道注意力机制, 强化多尺度动态特征提取, 同时引入具有量化动态移位机制的 DSConv, 通过较少的参数量改善模型在复杂场景下特征提取不充分的问题, 在保持检测精度的同时显著降低计算复杂度. 针对输电线路场景下特征融合不充分的问题. Yao 等[14] 采用了重新参数化的窗口注意力模块来增强 ResNet-18 的基础模块, 从而扩大了感受野范围. 他们进一步结合空间卷积与深度卷积实现小目标特征融合, 并优化了特征金字塔网络的特征融合机制, 显著提升了整体检测性能. 此外, 近期研究[15] 使用动态可变形卷积自适应捕获输电线路缺陷的多尺度特征并针对这些特征引入多尺度特征金字塔网络 (MSFPN) 替代传统特征提取网络并提出含排除机制的 Repulsive Loss 函数, 在保障计算效率的同时优化多尺度特征表示, 降低误报和边界框重叠, 提升模型的检测精度.

在深度学习目标检测算法中, 轻量化性能的优化占据着重要的地位, 而轻量化性能优化往往依靠更加高效的网络以及计算资源利用率高的模块如深度可分离卷积 DWConv 等实现. 近年流行的主干网络包括 VGGNet、ResNet、MobileNet 和 Star-Net. 为进一步提升模型对有限计算资源的利用率, 大量学者尝试在传统骨干网络的基础上进行创新与完善. 为应对有限的计算资源与目标分布不均及尺度变化极端等挑战, Duan 等[16] 设计了轻量型的 Efficient RepGFPN 结构, 实现高效的信息交互并最大限度降低参数需求. 此外, 他们引入的 SCConv 在提升特征提取能力的同时降低计算冗余. 实现轻量化设计; Zhang 等[17] 将具有全卷积注意模块 (C-SE) 模型的轻量级 GhostNet 嵌入到 YOLOV4 中作为主干特征提取网络, 同时将普通卷积替换为更加轻量的深度可分离卷积, 结合针对性的损失函数优化实现模型的轻量化; Shen 等[18] 在基于 Transformer 架构提出更为轻量的 TinyDef-DETR 架构, 使用边缘增强的 ResNet 主干来加强边界敏感的表示并结合双域多尺度注意力机制与提升对小目标特征灵敏度的

Focaler-Wise-SIoU 回归损失, 在保持优秀检测性能的同时, 实现对模型的轻量化设计; Zhuo 等[19] 通过在颈部结构进行轻量化设计, 通过集成 GSConv 卷积、VoVGSCSP模块与动态采样 DySample, 并配备了微尺度 P2 检测头和自适应细粒度通道注意力模块, 实现更高效的计算资源利用率.

现有方法虽在输电线路检测中取得了一定成效, 但受复杂背景干扰与目标尺度跨度大等因素影响, 尤其是在小目标检测中, 这些方法的检测精度和鲁棒性仍然受到显著影响. 针对上述问题, 本文提出新的 RDCL-YOLO 输电线路检测算法.

1) 设计 DRHC-C3K2 模块, 提升模型多尺度特征提取的灵活性.

2) 引入重参数化机制, 在提取特征时降低模型的参数量并结合新的下采样卷积 DSDC 替代原有下采样卷积, 在降低参数的同时保留更多的关键特征.

3) 设计多向感知共享的轻量化检测头 MPS-Head, 在检测头部分, 引入卷积权值共享机制和多向感知模块 (PSF), 进一步降低计算量并增强模型对多尺度目标的聚焦能力.

1　RDCL-YOLO 模型

YOLOv11[20] 是一种优秀的目标检测算法, YOLOv11 是在 YOLOv8 的基本架构上进行改进, 为进一步提升模型推理速度、降低模型参数量, YOLOv11 较于其他模型, 在保持轻量化特性的同时, 拥有较好的检测精度、推理速度和部署灵活性, 尤其适用于无人机电力巡检、工业缺陷检测等对实时性与检测精度均有要求的场景[21], 是目前输电线路缺陷目标检测领域的主流候选算法之一. 但 YOLOv11 算法结合无人机电力巡检仍存在一定问题. 输电线路缺陷目标像素占比小、尺度范围大、背景环境复杂, 对目标的多尺度特征融合不够充分导致检测精度不佳, 在捕捉细颗粒度信息与局部细节方面仍有改进空间. 针对以上问题, 本文提出一个新的输电线路巡检模型 RDCL-YOLO, 其网络结构如图 1 所示: 该模型以 YOLOv11 作为基础框架, 并将传统 C3k2 模块替换为特征融合能力更强的 DRHC-C3k2 模块、使用更加灵活且轻量的 MPS-Head 检测头替换原有检测头、使用 RepStem + DSDC 下采样替换普通卷积下采样, 在降低大量计算量与参数量的同时提升模型对输电线路场景下的目标检测精度.

1.1　RepStem + DSDC 下采样模块

在 YOLOv11n 基础模块中, 首先对物体进行两次下采样操作, 传统卷积采用固定卷积核尺寸, 易造成部分关键的特征信息丢失. 为提高特征提取效率, 在开始阶段使用 RepStem 替代前两次卷积 (如图 2 所示); RepStem 在开始阶段直接进行 4 倍下采样; 使用 RepMixer 混合器的思路, 在训练阶段采用多分支结构对图像特征进行提取, 在推理阶段进行剪枝, 降低模型的参数并提高模型的推理速度[22]. RepMixer 的设计允许在训练时引入多个卷积, 而推理时可以将这些不同参数的卷积核融合成一个单一的、有效的卷积核. 这种融合操作在部署时可以带来显著的加速, 它将多个卷积核的操作合并成一次, 能够在不

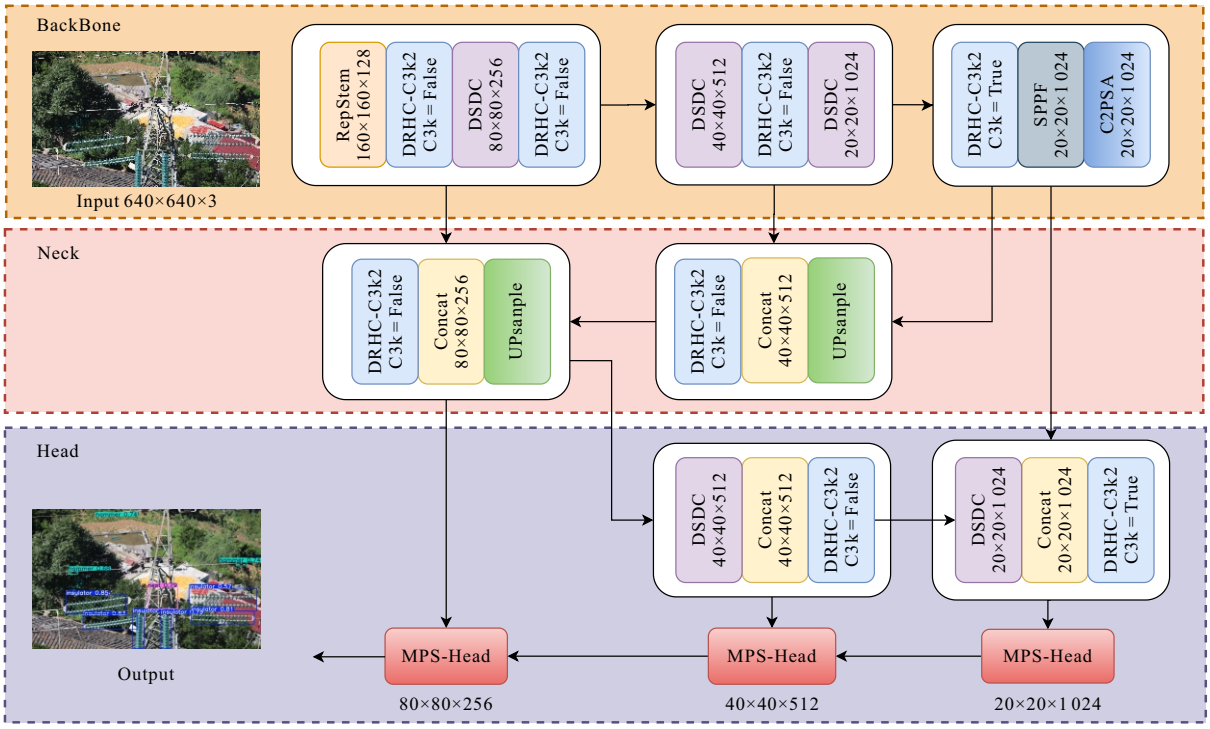

图 1　RDCL-YOLO 模型结构

影响精度的情况下降低一定的计算量, 降低工程部署难度. 传统下采样仅通过普通卷积层实现, 易改变甚至丢弃图片中的基础特征信息, 在处理语义信息丰富的图形时影响采样效果. 针对传统的下采样容易造成关键目标特征损失过多的问题, 本文提出了一种多线程深度平稳卷积 DSDC(如图 2 所示) 替换传统模型中的二倍下采样. 输入特征图 Input 分别通过最大池化、卷积与切割三种不同的采样方式实现多分支下采样, 分别获得不同采样程度的特征图再进行拼接. 拼接后的特征图通过一个卷积核为 1 的卷积进行特征融合, 融合后的特征能够保留大量的图像细节特征.

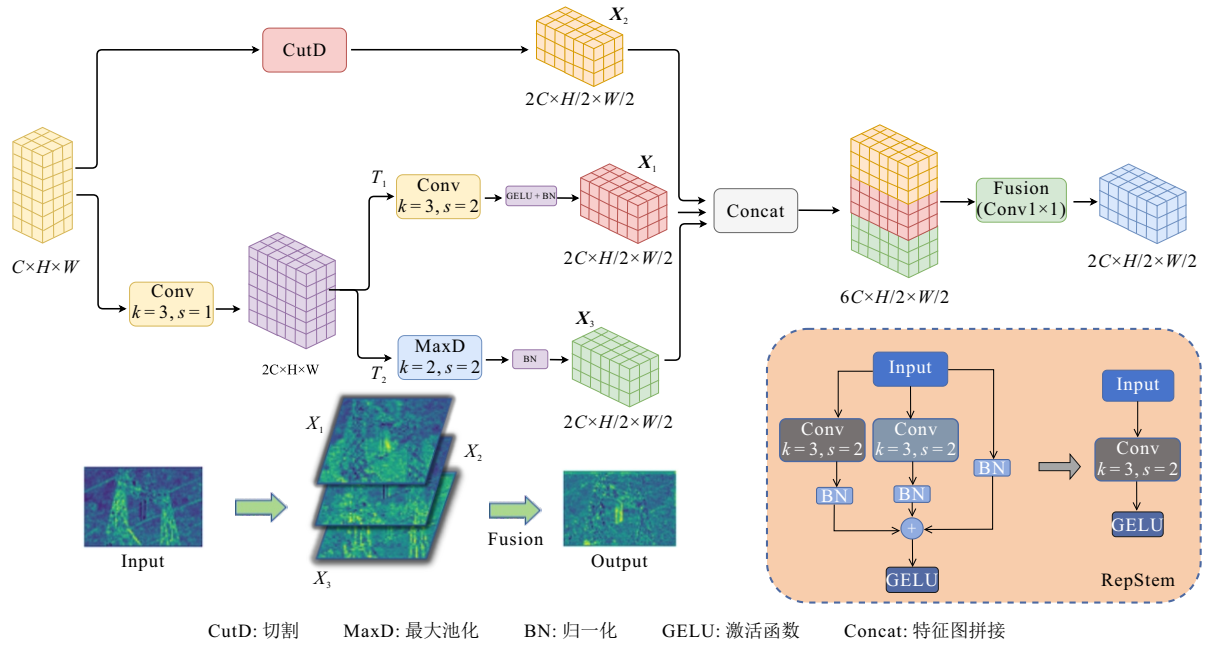

图 2 下采样模块 RepStem 与 DSDC 的模块

输入特征图在X_2分支被切割为空间维度为$[B, 2C, H/2, W/2]$的特征图, 随后经一个$k=3$, $s=1$的卷积, 将通道数由C增至$2C$作为通道 1 与 3 的输入特征图. 如下所示:

$$\mathbf{T}_1, \mathbf{T}_2 = \mathrm{Conv}(\mathbf{In}), \tag{1}$$

$$\mathbf{x}_2 = CutD(\mathbf{In}). \tag{2}$$

(T_1, T_2) 分别作为 Conv与 MaxD 模块的输入; 在通道 1 中, 输入特征图T_1经$k=3$, $s=2$的卷积核再经过 GELU 激活函数与 BN 归一化层, 得出输出特征图X_1; 在通道 3 中, T_2经一个$k=2$, $s=2$的最大池化层与 BN 归一化得到通道 3 的输出X_3. 最后将输出特征图 (X_1, X_2, X_3)进行通道拼接最后融合三个通道的特征得到最终输出特征图 Output. 如下所示:

$$\mathbf{X}_1 = \mathrm{BN}(\mathrm{GELU}(\mathrm{Conv}(\mathbf{T}_1))), \tag{3}$$

$$\mathbf{X_3} = \mathrm{MaxD}(\mathbf{In}) = \mathrm{BN}(\mathrm{Maxpool}(\mathbf{T_2})), \tag{4}$$

$$\mathbf{Output} = \mathrm{Fusion}(\mathrm{Concat}([\mathbf{X}_1, \mathbf{X_2}, \mathbf{X_3}]). \tag{5}$$

1.2 DRHC-C3k2 模块

为解决传统 C3k2 模块在无人机输电线路巡检的实际任务场景中, 受光照随机波动、背景复杂及相似干扰物较多等因素影响, 模型特征表征准确性不足, 进而引发目标误检、关键区域漏检, 造成整体检测精度下降, 设计双残差动态混合卷积网络模块 (DRDIBlock) (如图 3 所示) 替换传统 C3k2 中的 Bottlenet. DRDIBlock 通过引入动态增量混合器 (DIMixer) 将图像特征进行动态融合, 使用动态 Inception 风格的深度可分离卷积, 在保留传统深度可分离卷积轻量化优势的基础上, 增设多尺度卷积分支, 通过结合动态权重分配策略, 能够自适应捕捉输入特征的多维度信息, 提升模型特征适配灵活性; DIMier 结构 (如图 3 所示) 能够结合全局上下文信息对特征图进行权重分配. 为抑制局部噪声干扰, 在动态特征混合前先将输入特征图进行空间维度压缩, 后通过全局平均池化提取每个通道的全局平均信息. 如公式 (6) 所示:

$$\mathbf{Y}_{\mathrm{avg}} = \frac{1}{H \times W} \sum_{\mathrm{i}}^{W} \sum_{\mathrm{j}}^{H} \mathbf{X}_{\mathrm{c}}(\mathrm{i}, \mathrm{j}). \tag{6}$$

式中Y_{avg}表示全局平均池化后第C个通道的特征值; H为输入特征图的高度; W表示输入特征图的宽度, C为通道数; $X_C(i, j)$表示特征图高度为i, 宽度为j, 通道数为C的输入特征值.

输入的特征图Y_{in}在通道维度被均等分割为两个

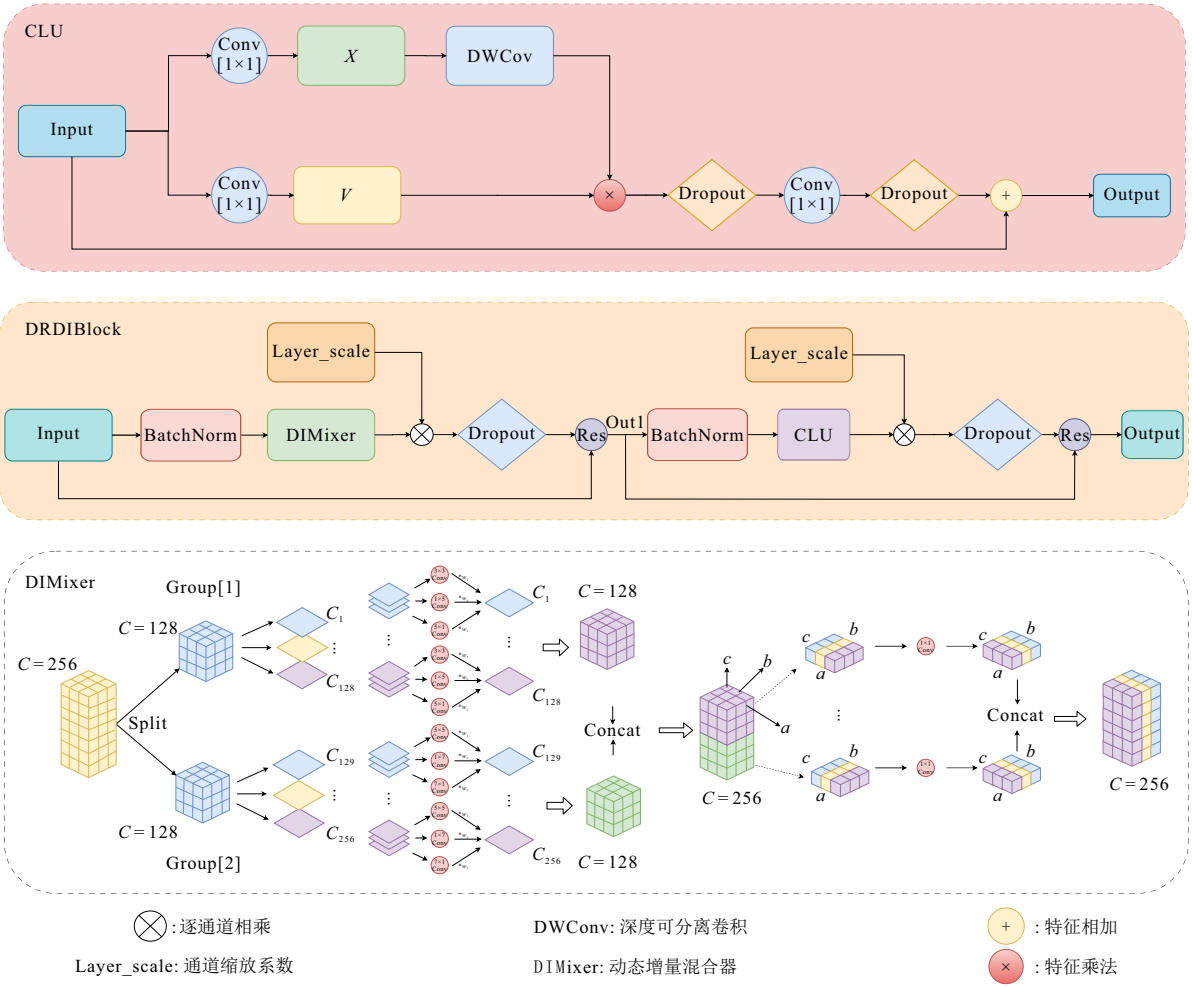

图 3　DRHC-C3k2 结构示意图

子特征图, 前 128 通道分配给$Y_{\text{group[0]}}$, 后 128 通道分配给$Y_{\text{group[1]}}$. 如下所示:

$$\mathbf{Y}_{Group[1]}, \mathbf{Y}_{Group[0]} = \text{Split}(\mathbf{Y}_{\text{in}}). \tag{7}$$

接着, 这两个子特征图并行进入不同的动态卷积分支进行处理, 两组特征图分别通过一组1×1的卷积将每一个通道扩展成三组独立通道, 有

$$\mathbf{Y}_1, \mathbf{Y}_2, \mathbf{Y}_3 = \text{Conv}_{1\times1}(\mathbf{Y}_{Group}). \tag{8}$$

分组完成后分别与卷积核大小分别为K的卷积核处理, 实现对特征图的多尺度特征提取并给每个卷积通道赋予一个独立的权重系数, 如下所示:

$$w_i = \frac{\sum_{K=3}^{K=5} dwK(\mathbf{Y}_1 X_{K\times K}, \mathbf{Y}_2 X_{1\times(K+2)}, \mathbf{Y}_3 X_{(K+2)\times1})}{\sum_{\text{i}}^{3}\sum_{K=3}^{K=5} \text{dwK}(\mathbf{Y}_1 X_{K\times K}, \mathbf{Y}_2 X_{1\times(K+2)}, \mathbf{Y}_3 X_{(K+2)\times1})}. \tag{9}$$

最后, 如式 (10) 所示, 将两个分支输出的特征图在通道维度进行拼接并通过1×1卷积对拼接后的特征进行跨通道信息融合和特征变换, 在保持输入输出空间维度和通道数不变的同时, 有效整合不同尺度卷积提取的特征信息. 此外, DRDIBlock 引入 Lay_scale 通道缩放[23] 机制, 该方法能够通过广播机制调整自身的维度, 与通道维度对齐并根据不同通道的特征赋予其独立的权重, 能够自适应约束特征范围且保留通道之间的差异, 提高特征融合的质量和检测精度.

$$\mathbf{Y_{Out}} = Ct(\text{Conv}_{1\times1}(\sum_{n=1}^{128} w_n \mathbf{Y_n} \sum_{m=129}^{256} w_m \mathbf{Y_m})). \tag{10}$$

见式 (11), Y_{s1}表示经第一次通道缩放后的输出特征; 其中α_C表示第C个通道的权重大小; Y_C表示第C个通道的特征值, Drp表示正则化操作.

$$\mathbf{Y_{S1}} = \text{Drp}(\sum_{1}^{256} \alpha_C \mathbf{Y_C}). \tag{11}$$

在式 (12)、(13) 中, CLU 结构中先将输入Y_{s1}映射成 (Y_X, Y_V). 随后, 对Y_X执行深度可分离卷积运算, 再将其与Y_V进行逐元素相乘, 之后进行两次正则化操作, 该结果通过残差连接回加到Y_{s1}中, 得到输出Y_{CLU}. 上式中$\otimes$表示特征相乘; Drp表示正则化, DWConv表示深度卷积.

$$\mathbf{Y_X}, \mathbf{Y_V} = \text{Conv}_{1\times1}(\mathbf{Y_{S1}}), \tag{12}$$

$$\mathbf{Y}_{\mathrm{CLU}} = \mathbf{Y}_{\mathrm{S1}} + (\mathrm{Drp}(\mathrm{Conv}_{1\times1}(\mathrm{Drp}(\mathbf{Y}_{\mathrm{V}} \otimes \mathrm{DWCov}(\mathbf{Y}_{\mathrm{X}}))))). \tag{13}$$

最后式 (14) 中, Y 表示 $DRDI$ 的最终输出特征值; β_C 表示与 CLU 的输出特征通道对应的第 C 个通道的权值.

$$\mathbf{Y} = \mathbf{Y}_{\mathrm{S1}} + \mathrm{Drp}(\sum_{1}^{256} \beta_C \mathbf{Y}_{\mathrm{CLU}}). \tag{14}$$

1.3 MPS-Head 检测头

传统的轻量化检测头通过引入深度可分离卷积来降低模型的参数冗余, 但深度可分离卷积易丢失部分图像特征, 难以保证模型检测精度. 在复杂目标检测、小目标识别、细粒度分类等任务中, 深度可分离卷积对目标特征的提取和融合能力显著低于标准卷积, 导致检测精度下降. 如 SLCD 检测头[24], 其独特的共享卷积思路能够在一定程度上降低参数量, 但该检测头在特征提取过程中丢失了大量的底层特征. 为了改善传统轻量化检测头容易丢失图像关键特征以及航拍目标朝向随机、方向不固定的问题, 本文创新地设计了一种多头感知共享检测头 MPS-Head (如图 4a 所示). MPS-Head 检测头的核心结构为 MPS 模块 (如图 4b 所示):MPS 模块中的 PSF 对 5 个不同方向的 3x3 卷积核进行权重融合, 实现对特征图多方向细节的增强.

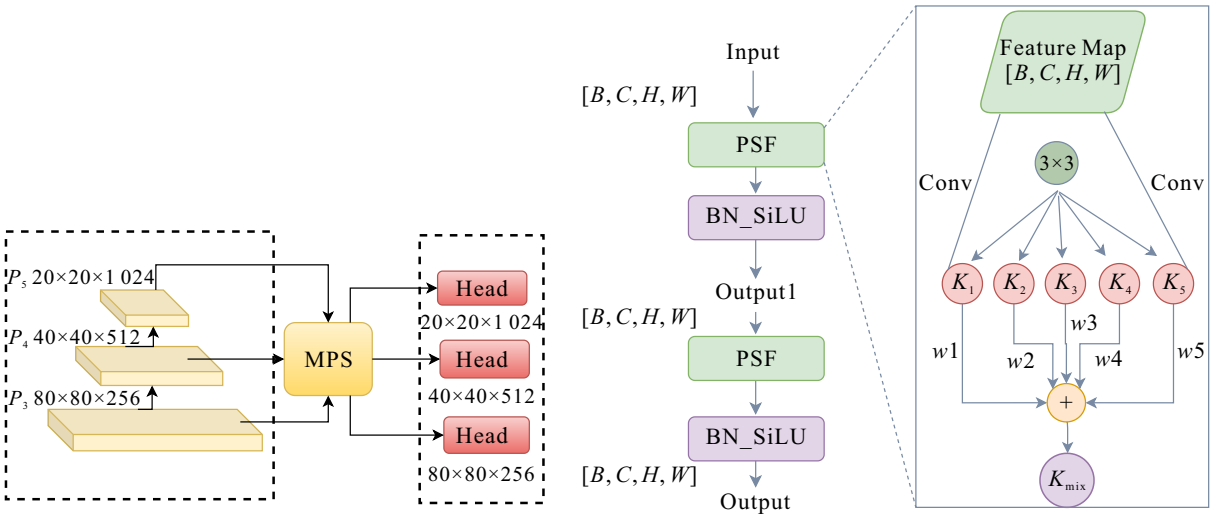

(a) 检测头MPS-Head结构 (b) MPS 模块结构

图 4 检测头 MPS-Head 和 MPS 模块结构

$$K_1 = \begin{bmatrix} 0 & 0 & 0 \\ 1 & 1 & 1 \\ 0 & 0 & 0 \end{bmatrix} \quad K_2 = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 1 & 0 \\ 0 & 1 & 0 \end{bmatrix}$$
$$K_3 = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad K_4 = \begin{bmatrix} 0 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \end{bmatrix}$$
$$K_5 = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \tag{15}$$

如式 (15) 所示, 训练阶段, PSF 将标准 3×3 卷积拆分为 4 个方向分解卷积 (K_1, K_2, K_3, K_4) 来捕捉不同方向的细节特征 (如图 4b).

并为每个不同方向的卷积核赋予独立的权重 $W(i)$ 与偏置 $b(i)$ 最后对其进行加权求和, 如式 (16)、(17) 和 (18) 所示. 部署阶段采用融合后的完整权重卷积核 K_{mix} 与 b_{mix} 进行卷积, 融合后的卷积能够实现多方向的特征融合, 在充分融合不同方向特征的同时降低因五次卷积计算产生的冗余, 提升特征提取效率.

$$\mathbf{W}_i, b_i = \mathrm{GetWeight}(\mathrm{Conv}(\mathbf{K}_{\mathrm{i}})), \tag{16}$$

$$K_{\mathrm{mix}} = \sum_{1}^{5} W_i K_i = \begin{bmatrix} w_1 & w_2 & w_3 \\ w_4 & w_5 & w_6 \\ w_7 & w_8 & w_9 \end{bmatrix}, \tag{17}$$

$$b_{mix} = \sum_{1}^{5} b_i. \tag{18}$$

如式 (19)、(20) 所示, 第一层的输出特征图作为第二层 PSF 的输入并重复上诉步骤, 两层 PSF 结构串联可进一步增强模型对小目标、边缘纹理丰富的目标的特征提取能力.

$$\mathbf{Output1} = \mathrm{SiLU}(\mathrm{BN}(\mathrm{Conv}(\mathbf{Input}, K_{mix}, b_{mix}))), \tag{19}$$

$$\mathbf{Output} = \mathrm{SiLU}(\mathrm{BN}(\mathrm{Conv}(\mathbf{Output1}, K_{mix}, b_{mix}))). \tag{20}$$

得到全权重卷积以及偏置后, 模型对输入特征图进行卷积操作后使用 BN 与 SiLU 激活函数引入非线性提升对小目标特征的灵敏度, 加速模型收敛并降低过拟合风险. MPS-Head 在模型部署时直接使用融合后的卷积核 K_{mix} 进行推理并将冗余的方向卷积 (K_1, K_2, K_3, K_4) 删除, 降低模型参数量和推理

时的内存占用, 消除大量的计算冗余. 在训练过程中, 所有检测层的特征图都会经过 MPS 模块并使用前面检测层的参数. 这种权重系数复用策略能够大幅降低模型的参数量并促使不同尺度的特征图学习统一的特征转换模式, 强化多尺度特征的一致性, 提高模型的鲁棒性与泛化能力.

2　实验结果分析

2.1　数据集

选用的数据集为网络公开数据与实地无人机拍摄图像共同构建, 共 3 960 张图片, 包含绝缘子、绝缘子破损、防震锤、鸟巢、绝缘子闪络, 防震锤生锈等六类. 本文将该数据集中的图片按 7:1:2 的比例随机划分为训练集、验证集和测试集. 为提升数据集的多样性与模型的泛化性并降低因光照强度、天气、拍摄角度等因素对输电线路缺陷检测精度的影响, 本文往少部分图像中添加高斯噪声、调整图像亮度、图像翻转等方法来模拟不同光照、天气、拍摄角度下的无人机成像场景. 这些处理手段不仅能够提升训练数据的有效性, 还能在一定程度上模拟不同天气如阴天、雨天、晴天等不同环境下的无人机成像情况, 不同的场景能够提升模型的鲁棒性与泛化性, 使模型能有效应用在不同的作业环境.

2.2　实验环境与超参数设置

实验在 Windows 11 操作系统上进行, 基于 YOLO 官方文档发布的 Ultralytics 8.3.9, Python 版本为 3.10.18, 使用深度学习框架 torch 2.7.0 和 CUDA12.6 版本. 本文所使用的硬件配置为 Intel i5-12600KF 处理器、32GB 内存、GPU 为 NVIDIA RTX 4060Ti, 配备 16GB 显存. 通过先行训练, 设置最大训练轮次为 350 轮并引入早停机制确保模型充分收敛, 训练批次大小 (Batch size) 为 64 张图片, 同时使用四线程加载数据以提高训练效率.

2.3　评价指标

本实验主要目的为优化无人机输电线路检测算法, 在提升精度的同时保持一定轻量性. 为准确评估实验效果, 本文设定多个评价指标, 具体包括准确率 (P)、召回率 (Recall)、精度均值 (mAP)、计算量 (FLOPs)、参数量 (Parameter)、模型大小 (Modelsize), 这些指标计算公式如下:

$$\mathrm{Precision} = \frac{TP}{TP+FP}, \tag{21}$$

$$\mathrm{Recall} = \frac{TP}{TP+FN}. \tag{22}$$

其中: TP 表示实际为正样本且被准确识别为正样本的个数, FP 表示实际为负样本但被识别为正样本的个数, FN 表示实际为正样本但被准确识别为负样本的个数. P 精度主要用来展示模型准确预测正样本的比例, Recall 召回率主要用来展示在所有目标中被模型成功检测的比例, 召回率越高模型漏检越少. 精度均值 (mAP) 的计算公式为

$$AP = \int_0^1 P(R)dR, \tag{23}$$

$$mAP = \frac{1}{N}\sum_1^n AP(i). \tag{24}$$

AP 为精度 Precision 与召回率 Reacll 曲线所围成的面积, 曲线围成面积越大, 代表模型的综合性能越优, mAP 是所有类别的 AP 取平均值, 故 mAP 被广泛用于模型综合检测性能的判别指标. FLOPs 表示单次前向传播所需的全部的数学运算次数, FLOPS 常用于衡量模型的计算复杂度.

2.4　消融实验

为验证 RDCL-YOLO 输电线路检测算法的综合提升效果, 本文以 YOLOv11n 基线算法为出发点, 进行一系列的消融实验, 实验结果如表 1 所示, 从结果分析, 将 DSDC, DRHC-C3k2, MPS-Head 模块集成到 YOLOv11 中能够显著提升模型的检测精度并大量降低模型参数量. DSDC 结构的集成提升了模型的特征提取能力, 将 mAP50 提升了 1.32%, 降低了部分小目标的遗漏. DRHC-C3k2 的嵌入使 mAP50 比基准模型低 0.12% 但参数量降低了 10.5%, 模型大小降低 5.7%, 计算量降低 9.5%. DRHC-C3k2 的特殊结构能够大幅降低模型参数量并提升模型的多尺度特征融合能力. 与 DSDC 与 DRHC-C3k2 模块进行协同能够显著提升模型的精度并大量降低模型参数与计算量. 为验证权值共享机制、多向感知模块 PSF 与通道缩放机制的有效性, 本文进行了模块内的消融实验如表 1 所示, 与基础模型相比, 使用权值共享机制后, 模型计算量降低 0.7G, 参数量降低 0.16M, 但 mAP50 与 mAP50-95 的值分别下降 0.87% 与 1.74%, 虽展现出卓越的轻量化性能, 但在精度方面依然有所欠缺. 而在与 PSF 模块进行协同后, 模型的计算量虽有 0.4G 地提升, 但模型的 mAP50 与 mAP50-95 的值分别提升 2.38% 与 1.87%, 说明融合了不同方向权重的多向感知模块在输电线路巡检领域能够比灵活性较差的普通卷积发挥出更强劲的检测性能. 相较于微小的计算负担增加, 这种显著的精度提升在实际应用中更具价值. MPS-Head 检测头展现出的强大综合性能证明这两个模块相互兼容, 改进方案可行. DRHC-C3k2 模块在移除通道选择机制后, 模型的计算量无明显变化, 但 mAP50 与 mAP50-95 的值分别下降 0.93% 与 0.56%, 表明通道特征选

表 1 消融实验

Baseline	DSDC	DRHC-C3k2	MPS-Head	Params/M	FLOPs/G	P/%	R/%	mAP50/%	ModelSize/MB	mAP50-95/%
				2.583	6.3	91.56	82.88	90.02	5.2	54.15
	√			2.548	6.1	91.85	84.20	91.34	5.2	54.72
		√		2.31	5.7	89.71	84.09	90.22	4.9	53.20
			√	2.26	6.0	92.48	86.57	91.53	5.0	54.28
	√	√		2.287	5.6	92.09	84.21	91.33	4.9	54.02
		√	√	1.99	5.4	90.52	85.76	91.30	4.6	53.82
	√		√	2.225	5.8	92.27	86.32	92.02	5.0	53.81
	√	√	√	**1.955**	**5.2**	**91.14**	**88.56**	**92.78**	**4.6**	**55.26**
		MPS-Head-PSF		2.421	5.6	89.18	83.17	89.15	4.9	52.41
		DRHC-C3k2-Layer_scale		2.313	5.7	91.26	82.40	89.29	4.9	52.64

择机制通过赋予包含不同价值特征的通道不同的权重, 实现模型对高价值特征的高关注度, 从而提高模型的检测效果并强化特征融合的灵活性.

2.5 对比实验

为验证 RDCL-YOLO 模型的优势, 本文在相同环境下将 RDCL-YOLO 模型与 YOLOv5、YOLOv8、YOLOv9-t、YOLOv10、YOLO12、YOLO13、Hyper-YOLO 以及 YOLO26 等主流目标检测算法进行比较, 对比结果如表 2 所示. 由表 2 可见, YOLOv5、YOLOv10、YOLOv9-t 的综合检测性能相对偏低, Hyper-YOLO 虽然具有较高的检测精度与所提出 RDCL-YOLO 检测性能相近, 但 Hyper-YOLO 是 RDCL-YOLO 参数量的两倍, 计算量的 1.8 倍, 模型大小的 1.58 倍, 难以在资源受限的无人机嵌入式平台上部署; YOLOv8 的 mAP50 值比 RDCL-YOLO 的低 3.24%, 虽然 YOLOv8 精度 P 略高于 RDCL-YOLO, 但 YOLOv8 的参数量却远高于 RDCL-YOLO 模型. YOLO12 的表现在 mAP50 下降 3.29%, 计算量多了 11.5%. YOLO13 的计算量增多 17.3%, mAP50 下降 3.99%. 与最新的 YOLO26 相比, RDCL-YOLO 模型的参数量少了 21.67%, 计算量相同, 模型小了 11.5%, mAP50 高了 5.01%, mAP50-95 高了 5.92%. 为进一步验证 RDCL-YOLO 性能的优越性, 本文在相同环境下与现有先进方法进行了全面的对比实验, 如表 2 所示, 与准确度相近的模型 FYOLOv8 相比, RDCL-YOLO 的 mAP50 值高了 0.32%, map50-95 的值低了 1.31%, 但 RDCL-YOLO 的参数量与计算量对比 FYOLOv8 分别下降 27.2% 与 59.3%, 模型体积也有 16.5% 的降低. 与轻量化程度相近的 YOLO-Air 相比, RDCL-YOLO 的计算量与模型大小分别增加 11.5%, 与 4.3%, 但参数量降低 8.9%, mAP50 与 mAP50-95 分别提高 1.62% 与 2.12%, 在计算资源利用率方面 RDCL-YOLO 更具优势. 综上所述, 以上模型在整体检测性能与计算资源利用率上均不如 RDCL-YOLO 模型. RDCL-YOLO 模型在输电线路检测方面具有明显优势, 以其高效、轻便的设计使其对单位计算花销的利用效率超过了目前的主流检测模型. 为输电线路检测系统提供了一个性能优越、计算资源利用率更高效的检测模型.

2.6 模型有效性验证

2.6.1 DSDC+RepStem 模块的有效性

图 5 直观对比了基线模型与所提出 DSDC + RepStem 模块的检测效果. 为在多种场景下对比下采样模块性能, 研究选取数据集中相同图像开展测试. 由实验结果可见: 在图 5(c) 第 1 种场景中, 受大量背景噪声干扰, 基线模型漏检鸟巢目标, 而 DSDC + RepStem 模块可完成准确检测; 第 2 种场景下, 基线模型无法区分两个相邻目标 (防震锤与绝缘子), 所提模块则可完整检出二者; 第 3 种场景中, 基线模型存在 2 类缺陷: 1) 将完好防震锤误判为锈蚀件产生误检; 2) 漏检另一目标. DSDC + RepStem 模块可同时解决上述 2 类问题. 上述可视化对比结果表明, DSDC + RepStem 模块检测性能显著优于基线模型, 证实该模块能够在下采样过程中有效保留关键特征信息.

2.6.2 DRHC-C3k2 模块的有效性验证

图 6 为嵌入 DRHC-C3k2 模块前后的检测效果对比. 在图 6(c) 的第 1 种场景中, 拍摄视角倾斜且光照充足, 基础模型未能识别出位于图像左上角的防震锤. 第 2 种场景背景杂乱、环境干扰噪声严重, 基础模型漏检了左下角的防震锤, 还将线缆环误判为防震锤目标, 产生了误检框. 第 3 种场景下, 基础模型无法识别被部分遮挡的防震锤. 引入 DRHC-C3k2 模块后, 模型的误检与漏检问题均得到显著改善, 进一步验证了所提出模块具备稳定可靠的多尺度特征融合能力.

2.6.3 MPS-Head 模块的有效性验证

图 7 展示了引入多方向感知共享检测头 (MPS-Head) 后得到的定性检测结果. 在图 7(c) 的第一组场景中, 背景复杂且包含小尺度目标, 基线模型未能识

表 2　对比实验

Model	Params/M	FLOPs/G	P (%)	R (%)	mAP50/%	ModelSize/MB	mAP50-95/%
YOLOv11[25]	2.583	6.3	91.56	82.88	90.02	5.2	54.15
YOLOv5[26]	2.182	5.8	87.63	81.81	87.03	4.4	49.97
YOLOv8[27]	3.006	8.1	92.32	81.93	89.54	6.0	52.95
YOLOv9-t[28]	1.971	7.6	90.20	79.30	87.37	4.4	50.01
YOLOv10[29]	2.266	6.5	88.52	81.51	87.86	5.5	52.80
YOLO12[30]	2.509	5.8	90.73	81.77	88.49	5.2	51.57
YOLO13[31]	2.449	6.1	90.16	82.44	88.79	5.2	52.81
Hyper-YOLO[32]	3.621	9.5	91.11	86.31	91.36	7.3	54.82
YOLO26[33]	2.496	5.2	88.93	80.96	87.77	5.2	49.34
FYOLOv8[34]	2.686	12.8	93.63	86.23	92.46	5.5	56.57
YOLO-Air[35]	2.146	4.6	93.63	86.23	91.16	4.4	53.14
RDCL-YOLO	**1.955**	**5.2**	**91.14**	**88.56**	**92.78**	**4.6**	**55.26**

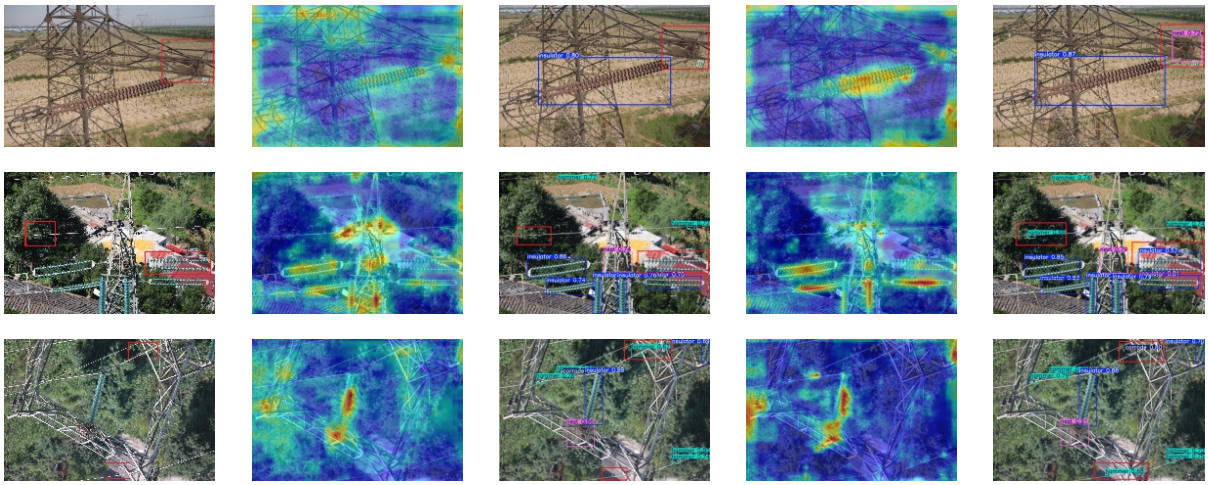

(a) 原始图像　(b) 基础模型热力图　(c) 基础模型检测结果　(d) 改进模型热力图　(e) 改进模型检测结果

图 5　DSDC+RepStem 检测结果可视化效果

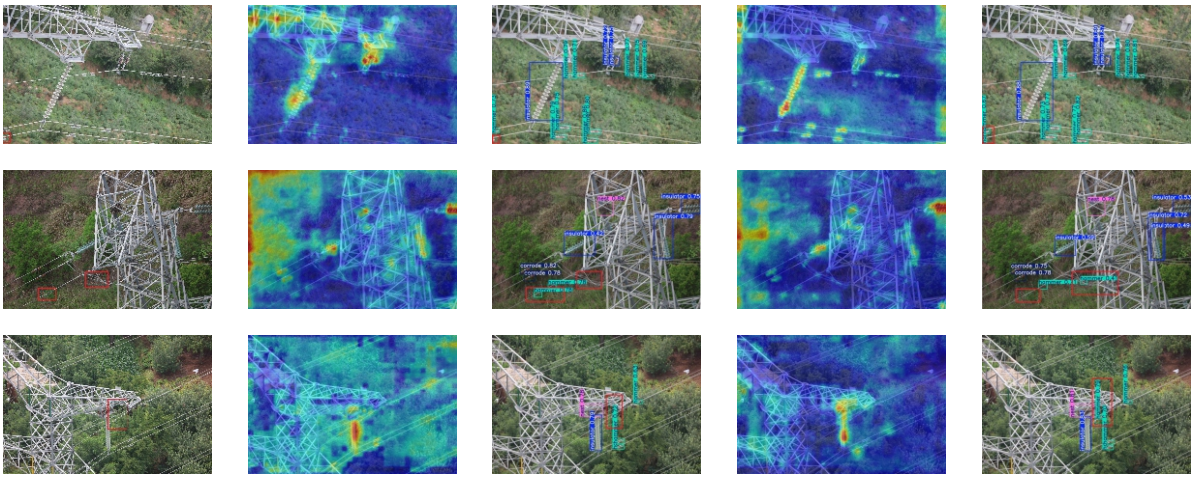

(a) 原始图像　(b) 基础模型热力图　(c) 基础模型检测结果　(d) 改进模型热力图　(e) 改进模型检测结果

图 6　DRHC-C3k2 检测结果可视化效果

别出位于左下角的锈蚀防震锤. 第二组场景地处山地环境, 基线模型漏检了一处与鸟巢空间重叠的防震锤. 此外, 在图 7(c) 中工厂昏暗工业光照的背景下, 基线模型无法定位右下角区域的绝缘子. 综上, 原有检测头极易在各类复杂背景受环境噪声影响产生漏检问题, 而本文提出的 MPS-Head 可大幅减少此类检测失误. 这一全方位性能提升充分验证了 MPS-Head 模块的有效性与鲁棒性.

2.7　泛化实验

为评估 RDCL-YOLO 模型在不同场景及复杂干

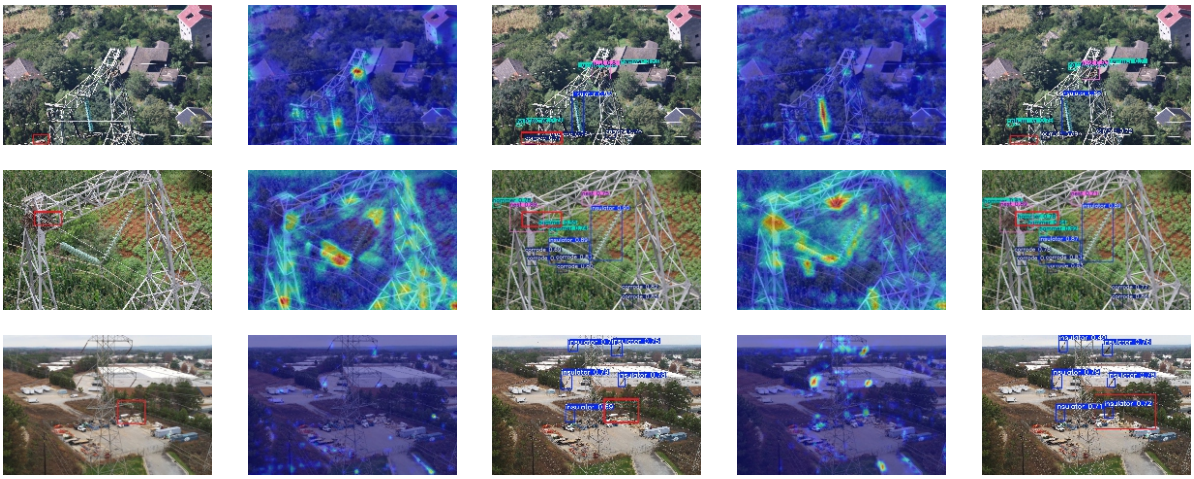

(a) 原始图像 (b) 基础模型热力图 (c) 基础模型检测结果 (d) 改进模型热力图 (e) 改进模型检测结果

图 7 MPS-Head 检测结果可视化效果

表 3 跨数据集泛化实验

Model	Params/M	FLOPs/G	P/%	R/%	mAP50/%	ModelSize/MB	mAP50-95/%
YOLOv11[25]	2.583	6.3	0.7777	0.5815	0.6346	5.2	0.3817
YOLOv8[39]	3.006	8.1	0.8067	0.5591	0.6295	6.0	0.3719
YOLOv10[29]	2.266	6.5	0.8008	0.5679	0.6299	5.5	0.3721
YOLO12[40]	2.509	5.8	0.7689	0.5834	0.6385	5.2	0.3684
RDCL-YOLO	**1.955**	**5.2**	**0.8319**	**0.6348**	**0.6885**	**4.6**	**0.3976**

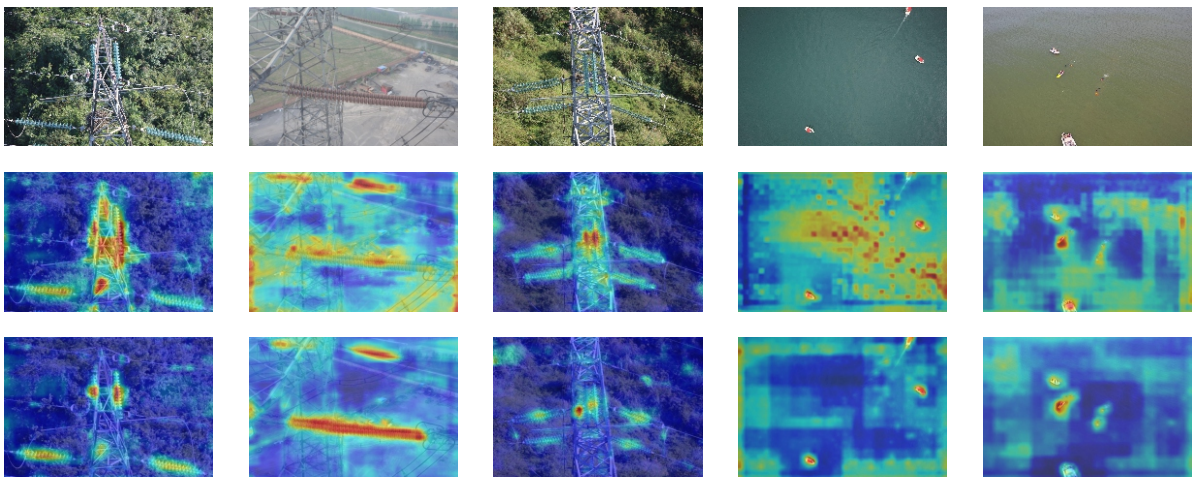

输电线路数据集 Seadroneseav2 数据集

图 8 RDCL-YOLO 与基础模型在不同数据集上的热力图可视化结果比较

扰下的泛化适配性与鲁棒性, 本研究选取 SeaDroneseav2[36] 海上救援公共数据集, 从光照突变、波浪条纹干扰、目标尺度差异大[37-38] 等复杂场景开展跨域泛化实验, 重点验证模型在其他业务场景下的泛化性能与鲁棒性. 基于 Seadroneseav2 数据集的泛化实验结果如表 3, 证明本文的 RDCL-YOLO 在公共数据集 SeaDroneseav2 上, 检测效果较于基础模型具有明显优势, 其中 mAP50 比基础模型高 5.39%, mAP50-95 比基础模型高 1.59%, 参数量减少 24.3%, 计算量与模型大小分别减少了 17.4% 与 11.5%. 表明改进模型 RDCL-YOLO 具有较强的鲁棒性与泛化性能. 通过热力图 (如图 8), 可直观对比不同算法对图像区域的注意力聚焦程度, 特别是在关键目标的识别与定位方面的表现. RDCL-YOLO 改进模型通过优化目标特征捕捉机制, 结合多尺度与多方向特征融合机制, 有效地过滤了背景噪声, 并精确地从小目标中提取特征, 实现了复杂场景下缺陷目标的精准聚焦. 对特征热力图的可视化结果分析, RDCL-YOLO 模型的目标特征聚集度高于基础模型; 面对海上波浪等条纹干扰时, 该模型可有效抑制干扰信息的影响, 具备强劲的抗干扰能力. 实验数据与可视化结果共同证实, 改进模型的鲁棒性与泛

化性能均显著优于基础模型, 为复杂场景下的输电线路缺陷检测提供了更可靠的技术方案.

3 结　论

本文针对传统无人机输电线路巡检环境中存在的小目标数量庞大、目标尺度差异大、背景杂波干扰强、目标特征易被忽视的检测问题[41], 提出 RDCL-YOLO 模型; RDCL-YOLO 模型通过新的特征融合模块 DRHC-C3k2, 将多尺度特征融合与多向卷积融合方法相结合, 提升模型对多尺度目标 (尤其是小目标) 的特征提取能力, 实现了对背景噪声的有效滤除与小目标关键特征的精准提取; 引入重参数化设计 RepStem 结构, 降低模型参数量; 此外, 通过设计一个新的下采样模块 DSDC, 将特征图切割并采用不同深度的卷积进行特征提取再进行特征融合的方式, 改善了传统卷积下采样过程中小目标特征大量丢失的问题, 增强了模型的特征提取能力. 最后, 通过设计多向感知共享的轻量化检测头 MPS-Head, 该模块将权值共享思路与多向感知卷积模块 PSF 进行融合, 在减小模型参数量的同时提高了模型对复杂目标的特征聚集能力, 大幅提升了小目标的检测精度.

实验结果表明, 该模型在输电线路缺陷检测任务中表现卓越. 尽管 RDCL-YOLO 模型在输电线路缺陷检测场景中具有一定的效果, 但目前无人机输电线路巡检的成本依然较高; 未来的无人机部署端对模型轻量程度的需求必定会不断提高, 后续需要对模型进行剪枝蒸馏, 在保证精度不降的同时将模型的轻量化程度再次提高, 降低部署难度以迎合计算能力较低的设备的部署需求[42].

参考文献 (References)

[1] Qu Z H, Liu H Y, Kong W G, et al. LP-YOLO: An improved lightweight pedestrian detection algorithm based on YOLOv11[J]. Digital Signal Processing, 2025, 165: 105343.

[2] Yadav A, Nirala A K, Swetapadma A. Comparative deep learning approaches for insulator condition monitoring in power transmission line[J]. Electric Power Systems Research, 2026, 257: 113020.

[3] Guo X D, Zhou W J, Liu T. Multilevel attention imitation knowledge distillation for RGB-thermal transmission line detection[J]. Expert Systems with Applications, 2025, 260: 125406.

[4] 丁浩晗, 贺万程, 万俊, 等. DI-YOLO: 一种面向无人机航拍图像的高效小目标检测框架[J]. 控制与决策, 2025, 40(10): 3106-3116.
(Ding H H, He W C, Wan J, et al. DI-YOLO: An efficient small object detection framework for UAV aerial imagery[J]. Control and Decision, 2025, 40(10): 3106-3116.)

[5] 田洪坤, 姜囡, 任涛. 基于跨模态交互融合与全局特征校准的无人机电线检测[J]. 控制与决策, 2026, 41(3): 639-650.
(Tian H K, Jiang N, Ren T. UAV transmission line detection based on cross-modal interaction fusion and global feature modulation[J]. Control and Decision, 2026, 41(3): 639-650.)

[6] Liu W, Anguelov D, Erhan D, et al. SSD: Single shot multibox detector[PP/OL]. 2015, arXiv: 1512.02325.

[7] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16x16 words: Transformers for image recognition at scale[PP/OL]. 2020, arXiv: 2010.11929.

[8] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 318-327.

[9] Ren S 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] Cai Z W, Vasconcelos N. Cascade R-CNN: Delving into high quality object detection[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, 2018: 6154-6162.

[11] Chen J Y, Liu N Z, Sun H, et al. Freq-DETR: Frequency-aware transformer for real-time small object detection in unmanned aerial vehicle imagery[J]. Expert Systems with Applications, 2026, 298: 129710.

[12] Li B, Wang B, Hu X. Bridging semantic discretization: DR-YOLO with dual-stream decomposition and dynamic feature weaving for low-light object detection[J]. Information Sciences, 2026, 731: 122896.

[13] Lei G L, Dong J, Jiang Y, et al. Wildfire target detection algorithms in transmission line corridors based on improved YOLOv11_MDS[J]. Applied Sciences, 2025, 15(19): 10688.

[14] Yao X S, Li S Y. An object detection method based on improved detection transformer for insulator defect detection of electrical transmission lines[J]. Electric Power Systems Research, 2026, 256: 112929.

[15] Yu Q, Cui W, Tao Y. Transmission line defect detection algorithm and research based on deep learning[J]. Engineering Letters, 2025, 33(12): 5058-5069.

[16] Duan P T, Zhang X R, Liang X, et al. Foreign object detection in power transmission lines using SESYOLO[J]. Scientific Reports, 2026, 16: 11807.

[17] Zhang S H, Qu C N, Ru C Y, et al. Multi-objects recognition and self-explosion defect detection method for insulators based on lightweight GhostNet-YOLOV4 model deployed onboard UAV[J]. IEEE Access, 2023, 11: 39713-39725.

[18] Shen F, Cui J M, Li W Q, et al. TinyDef-DETR: A transformer-based framework for defect detection in transmission lines from UAV imagery[J]. Remote Sensing, 2025, 17(23): 3789.

[19] Zhuo S L, Bai H, Li X W, et al. Pin defect detection in

power transmission lines via AAV-based automated inspection and a lightweight SADL-YOLOv11 model for edge deployment[J]. IEEE Internet of Things Journal, 2026, 13(6): 10681-10710.

[20] Khanam R, Hussain M. YOLOv11: An overview of the key architectural enhancements[PP/OL]. 2024, arXiv: 2410.17725.

[21] Sulake N R. YOLOv11 demystified: A practical guide to high-performance object detection[PP/OL]. 2026, arXiv: 2604.03349.

[22] Vasu P K A, Gabriel J, Zhu J, et al. FastViT: A fast hybrid vision transformer using structural reparameterization[C]. IEEE/CVF International Conference on Computer Vision. Paris, 2023: 5762-5772.

[23] Singh K, Band N, Adeli E. Curriculum-guided layer scaling for language model pretraining[PP/OL]. 2025, arXiv: 2506.11389.

[24] An J Y, Shi Z C. YOLOv8n-enhanced PCB defect detection: A lightweight method integrating spatial — Channel reconstruction and adaptive feature selection[J]. Applied Sciences, 2024, 14(17): 7686.

[25] Wang Y B, Pan Z Y. A multi-modal information interaction-based detection method for substation equipment using YOLOv11[J]. Electric Power Systems Research, 2026, 259: 113246.

[26] 刘建骐, 闫河, 王潇棠, 等. 改进金字塔和跳跃连接的YOLOv5目标检测网络[J]. 控制与决策, 2023, 38(6): 1730-1736.
(Liu J Q, Yan H, Wang X T, et al. YOLOv5 object detection network with improved pyramid and skip connection[J]. Control and Decision, 2023, 38(6): 1730-1736.)

[27] Jocher G, Chaurasia A, Qiu J. Ultralytics YOLOv8[EB/OL].(2023-01-10)[2026-09-18]. https://github.com/ultralytics/ultralytics.

[28] Mahapatra U, Rahman M A, Islam M R, et al. Adversarial training-based robust model for transmission line's insulator defect classification against cyber-attacks[J]. Electric Power Systems Research, 2025, 245: 111585.

[29] Wang A, Chen H, Liu L, et al. YOLOv10: Real-time end-to-end object detection[PP/OL]. 2024, arXiv: 2405.14458.

[30] Tian Y, Ye Q, Doermann D, et al. YOLOv12: Attention-centric real-time object detectors[PP/OL]. 2025, arXiv: 2502.12524.

[31] Deng P, Yang J J, Bian J. Cross-paradigm evaluation of gaze-based semantic object identification for intelligent vehicles[PP/OL]. 2026, arXiv: 2602.01452.

[32] Feng Y, Huang J, Du S, et al. Hyper-YOLO: When visual object detection meets hypergraph computation[PP/OL]. 2024, arXiv: 2408.04804.

[33] Singh R, Kaur M, Alirezaee S, et al. YOLO26-RipeLoc Lite: A lightweight architecture for tomato ripeness detection and picking point localization in greenhouse robotic harvesting[PP/OL]. 2026, arXiv: 2605.27129.

[34] Feng F, Yang X X, Yang R H, et al. An insulator defect detection network combining bidirectional feature pyramid network and attention mechanism in unmanned aerial vehicle images[J]. Engineering Applications of Artificial Intelligence, 2025, 152: 110745.

[35] Zhang R M, Pan C F, Chen Z H, et al. An improved lightweight YOLOv11 algorithm for weld surface defect detection[J]. Scientific Reports, 2026, 16: 11440.

[36] Jin Z, He T, Qiao L P, et al. MES-YOLO: An efficient lightweight maritime search and rescue object detection algorithm with improved feature fusion pyramid network[J]. Journal of Visual Communication and Image Representation, 2025, 109: 104453.

[37] Li Y S, Yuan H W, Wang Y F, et al. GGT-YOLO: A novel object detection algorithm for drone-based maritime cruising[J]. Drones, 2022, 6(11): 335.

[38] Martinez-Esteso J P, Castellanos F J, Calvo-Zaragoza J, et al. Maritime search and rescue missions with aerial images: A survey[PP/OL]. 2024, arXiv: 2411.07649.

[39] Zhao B G, Zhou Y, Song R, et al. Modular YOLOv8 optimization for real-time UAV maritime rescue object detection[J]. Scientific Reports, 2024, 14: 24492.

[40] 李海, 孙鹏, 张志佳, 等. 基于S-PGA-YOLOv12的复杂场景小目标火灾检测方法[J]. 控制与决策, 2026, 41(3): 728-740.
(Li H, Sun P, Zhang Z J, et al. A method for small target fire detection in complex scenes based on S-PGA-YOLOv12[J]. Control and Decision, 2026, 41(3): 728-740.)

[41] Wang C, Liu Z L, Du J N, et al. A YOLO-based substation defect detection model with enhanced feature extraction and fusion[J]. Electric Power Systems Research, 2026, 252: 112354.

[42] Lv H T, Li C, Dai J B, et al. Lightweight framework for underground pipeline recognition and spatial localization based on multiview 2-D GPR images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2025, 63: 1-15.

作者简介

吴朝明 (1979−), 男, 副教授, 博士, 主要研究方向为视觉伺服、表面缺陷检测与高光谱影像处理, E-mail: 2013994462@juwp.edu.cn;

彭松 (2002−), 男, 硕士生, 主要研究方向为图像处理和无人机目标检测, E-mail: 18174010193@163.com;

艾青松 (1999−), 男, 讲师, 硕士, 主要研究方向为人工智能技术与图像分割, E-mail: hellomnkk@163.com;

邓承志 (1980−), 男, 教授, 博士, 主要研究方向为无人机目标识别、图像分割与高光谱影像处理, E-mail: dengchengzhi@126.com;

孙小惟 (1982−), 女, 讲师, 硕士, 主要研究方向为图像处理和高光谱影像处理, E-mail: 304652253@qq.com.