

基于无人机航拍图像的电力系统微小缺陷检测算法

郑松源¹, 潘岐深¹, 张壮领¹, 陈彩娜¹, 胡秀珍¹, 戴宪华²

(1. 广东电网有限责任公司 应急及风险管理中心, 广州 510620;

2. 中山大学 网络空间安全学院, 广东 深圳 518107)

摘要: 电力系统的安全稳定运行依赖于对关键部件状态的实时感知与精准的缺陷检测。传统的人工检测方法效率低、成本高,且作业人员面临较大的安全风险,而基于无人机的自动化巡检技术凭借其高安全性与低成本优势,已成为电力运维的主流方向。然而,在实际工程应用中,无人机高空拍摄获取的图像往往存在目标尺度极小、背景复杂等问题。现有主流通用目标检测算法在处理此类任务时,受限于主干网络的连续步进卷积下采样机制,绝缘子裂纹、锈蚀等微小缺陷的细粒度特征在深层特征图中极易被过度压缩甚至丢失,从而引发漏检。针对这一问题,提出一种基于协同增强策略的改进YOLOv8检测模型,该模型在多尺度特征融合网络中构建了前端特征保真与后端精细解析的结构性耦合机制。具体而言,在网络前端引入无损下采样模块SPD-Conv替代传统步进卷积,通过将空间维度信息无损映射至通道维度,在降低分辨率的同时,完整保留微小缺陷的细粒度特征;在网络后端设计并增加一个专用的高分辨率检测头,该检测头通过特征金字塔网络与路径聚合网络的双向信息融合,专门用于解析前端保留下来的细节信息。这种设计旨在通过两者的协同效应,实现对微小目标的高精度检测。实验结果表明,该模型在VisDrone2019数据集上展现了优异的综合性能。与基线模型YOLOv8相比,改进模型在精确率、召回率与平均精度均值上分别提升了3%、1.57%和1.54%,平均精度均值达到38.75%。此外,在仅使用约424万个参数数量的情况下,其检测精度优于TIB-Net、YOLOv5s及YOLOv7等主流模型,同时推理速度高达233 FPS,兼具低参数数量与高帧率的优点,满足边缘设备部署的实际需求。综上,该协同增强策略能有效提升电力系统微小缺陷的检测性能,具备较强的工程应用潜力。

关键词: 微小缺陷检测; 无人机航拍图像; 电力系统; 特征融合; YOLOv8

中图分类号: TP391.41; TM7

文献标志码: A

文章编号: 1004-3918(2026)02-0252-10

Tiny Defect Detection Algorithm for Power System Based on Drone Aerial Images

ZHENG Songyuan¹, PAN Qishen¹, ZHANG Zhuangling¹, CHEN Caina¹, HU Xiuzhen¹, DAI Xianhua²

(1. Emergency and Risk Management Center, Guangdong Power Grid Co. Ltd., Guangzhou 510620, China;

2. School of Cyber Science and Technology, Sun Yat-sen University, Shenzhen 518107, Guangdong China)

Abstract: The secure, stable, and reliable operation of power transmission systems depends on the real-time perception and precise detection of defects in critical components. Traditional manual inspection methodologies are frequently characterized by low operational efficiency, high economic costs, and the presence of significant safety risks. In stark contrast, automated inspection technology based on unmanned aerial vehicles (UAVs), leveraging its superior advantages of high safety standards and low operational costs, has successfully emerged as the mainstream direction in the field of electric power operation and maintenance. However, in the context of practical engineering

收稿日期: 2025-12-29

修回日期: 2026-01-08

接受日期: 2026-01-30

基金项目: 南方电网公司科技项目(036500KK52220003)

作者简介: 郑松源(1985-),男,高级工程师,硕士,主要研究方向为电力应急管理

通信作者: 戴宪华(1964-),男,教授,博士,主要研究方向为无线通信、人工智能深度学习算法和生物信息处理,E-mail: issdxh@mail.sysu.edu.cn

引用格式: 郑松源,潘岐深,张壮领,等. 基于无人机航拍图像的电力系统微小缺陷检测算法[J]. 河南科学, 2026, 44(2): 252-261.

Zheng S Y, Pan Q S, Zhang Z L, et al. Tiny defect detection algorithm for power system based on drone aerial images [J]. Henan Science, 2026, 44(2): 252-261.

applications, the images acquired by drones from high-altitude aerial perspectives frequently encounter substantial challenges, such as the extremely diminutive scale of targets and highly complex background environments. When processing such challenging tasks, existing mainstream general-purpose target detection algorithms are severely limited by the continuous strided convolution downsampling mechanisms inherent in their backbone networks. This structural limitation inevitably leads to a situation where the fine-grained features of tiny defects such as insulator cracks and corrosion are excessively compressed or even completely lost within deep feature maps, thereby directly resulting in missed detections. To effectively address and mitigate this specific problem, this paper proposes an improved YOLOv8 detection model based on a collaborative enhancement strategy. This model constructs a structural coupling mechanism that integrates frontend feature fidelity with backend fine-grained parsing within the multi-scale feature fusion network. To be specific, at the frontend of the network architecture, the non-destructive downsampling module, known as SPD-Conv, is introduced to replace the traditional strided convolution layers. By mapping information from the spatial dimension non-destructively directly into the channel dimension, this module is able to meticulously preserve the fine-grained features of tiny defects while simultaneously reducing the resolution. At the backend of the network, a dedicated high-resolution detection head is designed and incorporated. This additional detection head utilizes the bidirectional fusion capabilities of the feature pyramid network and the path aggregation network to specifically parse and reconstruct the detailed information that has been preserved by the frontend. This design is explicitly intended to achieve the end-to-end, precise capture of tiny targets through the synergistic effect generated by the collaboration of both components. Extensive empirical experiments conducted on the VisDrone2019 benchmark dataset demonstrate that the proposed model exhibits superior comprehensive performance. Compared with the baseline YOLOv8 model, the improved model achieves substantial improvements of 3%, 1.57%, and 1.54% in precision, recall, and mean average precision(mAP), respectively, ultimately reaching an mAP of 38.75%. Furthermore, with only about 4.24 million parameters, its detection accuracy outperforms mainstream models such as TIB-Net, YOLOv5s, and YOLOv7, while the inference speed reaches 233 FPS. Featuring both low parameter count and high frame rate, it meets the practical needs for deployment on edge devices. In conclusion, this collaborative enhancement strategy can effectively boost the detection performance for tiny defects in power systems, possessing strong and robust potential for practical engineering applications.

Key words: tiny defect detection; drone imagery; electric power systems; feature fusion; YOLOv8

0 引言

输变电网络的安全稳定运行依赖于对线路、杆塔、绝缘子等关键部件的定期检查^[1]。传统的人工巡检方式,以及早期采用的载人直升机、攀爬机器人等技术手段,普遍存在效率低、成本高、安全风险大或应用场景受限等问题^[2-5]。近年来,无人机(Unmanned Aerial Vehicles, UAVs)凭借操作安全性高、成本低和机动性强等优势,已成为电力巡检的主流手段,但其采集的海量影像数据也为自动化分析带来了新的挑战^[6]。目前已有大量研究针对通用无人机目标检测和电力设备专用检测进行优化。在通用无人机目标检测方面,为平衡计算效率与检测精度,Sun等^[7]引入循环路径与空间注意力模块,增强了对微小人脸目标的特征提取能力;Ye等^[8]提出轻

量级特征增强网络,实现了对低空飞行物的实时预警;Wastupranata和Munir^[9]则探索了基于web应用程序的检测部署方案;针对无人机影像中的复杂背景干扰,He等^[10]利用Res2Net提取多感受野特征,并结合分层多尺度融合策略提升网络性能;相关研究^[11]采用FPN多尺度预测结构,有效改善了复杂城市背景下无人机目标检测的效果。在电力设备巡检的应用场景中,YOLO系列算法凭借其卓越的速度与精度优势已成为主流选择,彭曙蓉等^[12]通过改进YOLOv4算法实现了架空线路电力设备的故障检测,验证了该系列模型在电力场景中的适用性;为克服复杂背景与遮挡干扰,马峻等^[13]与Liu等^[14]分别在PP-YOLO与YOLOv5中引入注意力机制,有效增强了模型对绝缘子等关键部件在部分遮挡条件下的特征提取能力;近年来,针对边缘侧部署对模型轻量

化与高精度的双重需求,Zhang等^[15]通过引入融合注意力机制的深度可分离卷积并结合轻量化卷积,提出了一种基于改进YOLOv7的轻量化绝缘子缺陷检测方法;Wang等^[16]则利用可变形卷积增强特征提取能力,设计重参数化结构以压缩模型参数,构建了针对输电线路多类型缺陷的YOLOv8检测模型。然而上述方法多侧重于对绝缘子串、杆塔等整体性目标的检测,标准YOLO架构的32倍下采样结构导致小于 32×32 像素的微小缺陷特征严重衰减甚至消失^[17]。

为实现无人机对电力设备微小缺陷的高效、准确识别,克服高空视角下的目标尺度瓶颈至关重要。遵循MS COCO数据集的定义^[18],本文所研究的微小缺陷指在无人机高空巡检视角下,绝对像素尺寸小于 32×32 像素的目标。具体到电力巡检场景,主要包括绝缘子表面的微裂纹、金属配件的早期锈蚀点以及导线的局部断股等。然而,通用目标检测算法应用于无人机电力巡检时,面临一个根本性的矛盾:为了提取高级语义特征,卷积神经网络(Convolutional Neural Network, CNN)的主干网络需进行多次下采样,而这一过程会不可避免地损失对于缺陷判断至关重要的细节和空间信息。由于微小缺陷目标的像素尺度极小,其关键特征在CNN下采样过程中极易损失。例如,绝缘子上的微小裂纹、螺栓的轻微锈蚀等细节特征,在经过初始下采样操作后就可能被严重模糊甚至完全消除,导致后续网络无物可检。为了解决小目标特征在下采样中损失的问题,Sunkara和Luo^[19]提出了SPD-Conv(Space-to-Depth Convolution)方法,通过空间到深度的转换替代步进卷积,有效保留了细粒度信息;Gu等^[20]提出的YOLO-SSFS模型将YOLOv5主干网络中的步长卷积层全部替换为SPD-Conv模块,mAP提升了7.63%,通过保留浅层语义信息,有效缓解了密集环境下的目标漏检问题。受此启发,为系统性解决微小缺陷特征丢失问题,并兼顾实际工程部署对模型效率的要求,本文提出一种基于YOLOv8的高效协同增强策略。该策略的核心思想是构建前端特征保真与后端精细检测的协同机制:在前端引入SPD-Conv模块以避免下采样过程中的信息损失,在后端增设高分辨率检测头以增强对微小目标的感知能力。本文系统地验证了该协同设计的有效性,为高精度、高效率的电力系统微小缺陷目标检测提供一种精准且实用的优化方案,主要贡献如下:

1)构建了面向微小缺陷检测的协同增强架构:

针对现有算法因下采样导致细粒度特征损失的问题,设计了前端特征保真与后端精细解析的协同机制,有效解决了微小缺陷目标的漏检问题。

2)揭示并修复了下采样对标签分配的制约机制:理论分析与实验表明,特征细节的过早损失是导致YOLOv8中任务对齐分配策略在微小目标上失效的根本原因。通过前端特征保真,解决了因特征缺失导致的样本匹配失效问题,为微小目标检测提供了必要的底层特征支撑。

3)实现了检测精度与边缘部署效率的良好平衡:在VisDrone2019数据集上,提出的模型以约424万的极低参数量实现了38.75%的mAP,在精度上超越了TIB-Net、YOLOv5s和YOLOv7-tiny等主流轻量模型,且帧率满足电力巡检的实时性要求,具备良好的工程应用价值。

1 关键技术

1.1 YOLOv8架构

YOLOv8是当前目标检测领域主流的单阶段检测器之一,凭借其优异的综合性能与良好的灵活性,为本研究提供了坚实且具有高度优化潜力的基础。其整体架构如图1所示,由主干(Backbone)、颈部(Neck)和头部(Head)三部分构成,各部分协同工作,高效地完成特征提取、特征融合和最终检测的全过程。其中的关键模块,包括C2f和Spatial Pyramid Pooling-Fast(SPPF)等模块的内部结构如图2所示。

主干网络作为模型的核心组件,负责从输入图像中提取多尺度特征图。YOLOv8的主干网络在此前YOLO系列的基础上进行了优化改进,以C2f模块为基本构建单元,并在末端引入SPPF模块以增强多尺度上下文感知能力。C2f模块的设计思想借鉴了YOLOv7中的ELAN结构^[21]与YOLOv5中的C3模块,通过将输入特征图在通道维度按1:1的比例分为两个分支,其中一个分支经过 n 个Bottleneck堆叠(n 值在基线模型中分别为1,2,2,1),另一个分支通过跳跃连接直接融合,从而获得了更丰富的梯度流信息。这使得模型在训练过程中能够学习到更多样化、更鲁棒的特征表示,同时在设计上依然保持了轻量化的优势。而SPPF模块则是空间金字塔池化(Spatial Pyramid Pooling, SPP)^[22]的改进版本,用于增强网络对不同尺度目标的感受野。与SPP并行使用多个不同尺寸的池化核不同,SPPF通过串联多个小尺寸的MaxPool层来达到同样的效果。这种设计在保持多




图1 YOLOv8结构图

Fig.1 YOLOv8 structure diagram




图2 YOLOv8主要模块详细结构图

Fig.2 Detailed structural diagram of YOLOv8's main modules

尺度特征融合能力的同时,计算效率更高,特别适合在边缘设备上部署。

颈部网络作为特征融合的关键环节,负责整合主干网络输出的多尺度特征。YOLOv8采用特征金字塔网络(Feature Pyramid Networks, FPN)^[23]与路径聚合网络(Path Aggregation Network, PAN)^[24]相结合的经典结构。FPN通过自顶向下的信息流,将深层的强语义特征与浅层的高分辨率特征融合,增强了浅层特征的上下文感知能力。在此基础上,PAN则增加了一条自底向上的信息流,将浅层的强定位信息传递至深层,进一步提升了特征金字塔的整体定位精度。

头部网络作为模型的最终输出端,负责对融合后的特征进行解析并生成检测结果。YOLOv8的头部网络采用了无锚框设计(Anchor-Free)和任务对齐分配策略。前者摒弃了传统锚框,直接预测目标的中心点和边界,简化了检测头结构并增强了模型的泛化能力;后者则通过动态选择正样本,提升了模型的整体性能。

1.2 无损下采样技术

在对YOLOv8等现代检测器的架构分析中发现,其整体设计虽然已高度优化,但仍然延续了CNN的传统下采样机制,即通过步长大于1的卷积或池化操作减少特征图的分辨率。当输入图像分辨率较

高且目标尺寸适中时,此类下采样策略能够在降低计算复杂度的同时有效提取判别性特征。然而,在无人机高空视角下的微小目标检测场景中,由于目标尺度有限且边界模糊,过早的下采样容易导致关键信息严重损失,从而削弱模型的检测性能。

为缓解这一问题,本研究在主干网络前端引入了一种替代传统步进卷积的SPD-Conv模块。其核心思想是在降低特征图空间分辨率的同时,最大限度地保留细粒度信息。SPD-Conv包含两个步骤:首先,通过空间到深度重排,将输入特征图的空间维度信息无损映射到通道维度,从而在缩小空间分辨率的同时完整保留原始信息;然后,利用步长为1的标准卷积对重排后的特征图进行特征提取。图3展示了从输入特征图切分、通道拼接到卷积处理的整个流程。

这种先无损重排后卷积提取的策略,有效平衡了压缩分辨率与信息保留之间的矛盾。已有研究^[19]证明,将SPD-Conv引入YOLOv5的主干与颈部结构中,能够显著提升模型在处理低分辨率图像和微小目标检测等复杂任务中的性能。

2 协同增强的微小缺陷检测模型构建

2.1 整体协同策略

尽管YOLOv8采用了无锚框设计和任务对齐分配策略,以缓解传统锚框模型中小目标正样本匹配不足的问题,但这一优化机制有效发挥作用的前提是目标的关键特征在深层特征图中仍然保留。在无人机电力巡检场景下,绝缘子微裂纹等微小缺陷通常仅占数个像素。YOLOv8的主干网络连续使用步长大于1的卷积进行下采样,在降低空间分辨率的同时,不可避免地导致这些微小目标的细节特征信息损失。而一旦关键特征在下采样过程中丢失,YOLOv8针对小目标的优化机制也难以发挥作用,从而引发漏检。




图3 SPD-Conv 结构图

Fig.3 SPD-Conv structure diagram

因此,本文针对YOLOv8下采样机制导致微小目标关键特征丢失这一核心挑战,在特征表达层面进行优化,与YOLOv8原生的任务对齐分配优势结合,提升微小缺陷的检测能力。本文提出一种“前端无损保真、后端精细解析”的协同增强策略。该策略的核心思想在于:避免在网络深层对已退化的特征进行补偿,转而在特征提取的初始阶段保障关键信息的完整性。具体而言,通过对YOLOv8进行目的明确的结构耦合改造,在前端引入无损下采样机制,确保底层特征的完整性,为任务对齐分配策略提供高保真输入;在后端增设精细解析模块,专门解析保留的细粒度特征,充分发挥无锚框机制在高空间分辨率下的优势。

2.2 前端特征保真模块

为实现前端特征保真,本文采用第1.2节所详述的SPD-Conv模块,替换YOLOv8主干网络中前两次下采样阶段的传统步进卷积层。在YOLOv8的原始架构中,输入图像在主干网络中经历5次下采样,分别生成P1至P5五个层级的特征图。由于前两次下采样对微小目标的特征损失最为严重,我们将主干网络中的前两个步长为2的卷积下采样层(即原架构中用于生成P1和P2特征图的Conv模块)替换为SPD-Conv模块。为保持与YOLOv8主干网络的通道一致性,第一个SPD-Conv模块的输出通道数设置为64,第二个SPD-Conv模块的输出通道数设置为128。这一改进确保在生成P1和P2这两个高分辨率特征图的过程中,图像的细粒度信息能够通过“空间-深度”变换被完整地保留下来,为后续网络提供高质量、高保真的特征流,从根本上解决信息源头丢失的问题。

2.3 后端精细解析模块

为有效利用前端模块完整保留的细粒度特征,本文在后端引入一个微小目标专用检测头。如图4所示,在YOLOv8原有面向P3、P4、P5特征图的三个检测头的基础上,新增一个针对高分辨P2特征图的检测头。该检测头基于主干网络第二次下采样后输出的P2特征图,可保留更丰富、完整的空间细节和位置信息。

在颈部网络中,新增的检测头被无缝地整合进第1.1节所述的FPN和PAN的双向信息流中。具体而言,在FPN路径中,高层语义信息通过上采样与来自主干的P2原始特征图进行融合,为P2层特征图




图4 头部网络改进

Fig.4 Head network improvement

注入上下文感知能力;同时,P3特征图也在此过程中融合了这些高级语义信息;随后,在PAN路径中,融合后的新P2特征图通过下采样参与到更高层特征的聚合中;最终传递至高分辨率微小检测头的特征图,既保留了原始精细细节,又获得了高层语义指导。与标准检测头相比,该检测头显著提升了对微小目标的解析能力。

2.4 多尺度特征融合与协同机制

本文提出的协同增强策略,核心在于实现前端特征保真与后端精细解析的高效协同,其结构基础是YOLOv8颈部网络中所采用的FPN与PAN多尺度特征融合机制。

该融合机制作为模型的核心枢纽,将前端特征保真与后端精细解析有机整合,形成了一条完整、高效的信息处理通路。具体信息流如下:输入图像首先经由主干网络处理,其中微小缺陷的细粒度特征通过SPD-Conv模块被完整保留在P2特征图中,为后续实现高精度检测奠定基础。随后,在自顶向下的语义注入阶段(FPN路径),P5、P4、P3特征图的高层语义信息逐级向上采样后与底层特征融合,最终增强P2特征图的语义表征能力。接着,在自底向上的定位强化阶段(PAN路径),携带了丰富细节和语义信息的P2特征图经下采样后逐级向上传递,进一步强化了P3、P4等中层特征图的定位精度。最后,在后端精细解析阶段,新增的高分辨率检测头所接收的,并非原始P2特征图,而是经过FPN和PAN双向信息流充分融合后增强的综合性特征表示,从而能显著提升对微小目标的解析能力。

综上所述,前端SPD-Conv模块保障了高质量的特征表示,后端高分辨率检测头提供了针对性的解

析能力,而颈部的FPN-PAN结构则成为实现两者高效协同的桥梁。该机制有效耦合了特征提取阶段的信息保真与检测阶段的精细解析,从而显著提升了微小目标的检测性能。

3 实验结果与分析

3.1 数据集

VisDrone2019数据集由中国天津大学机器学习与数据挖掘实验室的AISKEYE团队收集。数据集集中的图像和视频由多种型号的无人机摄像头采集,覆盖了不同地理位置、环境条件和天气情况。该数据集共包含10 209张图像,划分为6471张训练图像,548张验证图像和3190张测试图像。其标注涵盖pedestrian、people、bicycle、car、van、truck、tricycle、awning-tricycle、bus和motor共10个类别,总计260万个标注实例。VisDrone2019虽未包含电力系统缺陷图像,但其具有高空俯瞰视角、目标尺度微小且分布密集的特性。数据集中大量目标在图像中的像素占比低于1%,部分甚至低于0.1%,且呈密集分布,这与电力巡检中绝缘子微裂纹、螺栓锈蚀等微小缺陷的视觉特征高度契合。鉴于目前缺乏大规模公开电力系统缺陷数据集,本文将VisDrone2019作为代理数据集,验证所提模型在微小目标检测任务中的有效性,其实验结论对电力巡检场景具有重要的迁移参考价值。

3.2 实验环境和评价指标

实验在Ubuntu20.04操作系统上进行,配备2块NVIDIA GeForce RTX 3090 GPU,内存为64 GB,Python版本为3.9.7,PyTorch版本为1.11.0。训练参数如表1所示。损失函数与官方YOLOv8一致,如式(1)所示,其中边界框回归损失Loss_{box}、分布焦点损

失 $Loss_{\text{dfl}}$ 和分类损失 $Loss_{\text{cls}}$ 的权重系数 a 、 b 、 c 分别设置为 7.5、1.5 和 0.5。

$$Loss = a \cdot Loss_{\text{box}} + b \cdot Loss_{\text{dfl}} + c \cdot Loss_{\text{cls}}。$$

(1)

表1 训练参数

Tab.1 Training parameters

参数	值	单位
迭代次数	150	次
批量大小	16	批次
图片尺寸	640×640	px
初始学习率	0.01	
动量	0.937	
权重衰减系数	0.000 5	

为了验证模型的性能,本文采用精确率(P)、召回率(R)、平均精度均值(mean Average Precision, mAP)、参数个数和帧率(Frames Per Second, FPS)作为评价指标。

精确率和召回率的计算如式(2)和式(3)所示:

$$P = \frac{TP}{TP + FP} \times 100\%,$$

(2)

$$R = \frac{TP}{TP + FN} \times 100\%,$$

(3)

式中:TP(True Positive)表示正确检测的真实目标数量;FP(False Positive)表示误检目标数量;FN(False Negative)表示漏检的真实目标数量。

PR 曲线(Precision-Recall Curve)所包围的区域表示平均精度(Average Precision, AP),计算公式如式(4)所示。

$$AP = \int_0^1 p(r) d(r)。$$

(4)

mAP 是所有类别平均精度(Average Precision, AP)的平均值,mAP 越高,表明模型性能越优,其计算公式如式(5)所示。

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i,$$

(5)

式中: N 是数据集中的类别数,用于衡量模型在多类别目标检测任务中的综合性能。

3.3 实验结果与分析

3.3.1 与主流模型对比

为验证模型的综合性能,本文选取 TIB-Net、YOLOv5s、YOLOX-s 及 YOLOv7-tiny 等多个具有代表性的轻量级或高精度目标检测器在同一实验条件下进行对比,结果如表 2 所示。

从实验结果可以看出,本文提出的模型在 P 、 R 和 mAP 三项核心指标上均显著优于其他所列对比模型。TIB-Net 虽然在参数量上达到了极致的轻量化,但其推理速度仅为 10 FPS,远不能满足无人机实时检测的性能要求。YOLOv5s 凭借其简洁高效的结构,在 FPS 上表现最佳,但其 mAP 比本文模型低,反映了其在处理微小目标时仍存在精度局限。值得注意的是,本文模型的参数量仅为 YOLOv5s 的 60%,且计算量(GFLOPs)低至 10.2,且其在 P 、 R 和 mAP 指标上全面超越 YOLOv5s。这充分证明了本文所提出的协同增强策略并非单纯依靠增加计算复杂度来换取精度,而是通过优化结构设计,在精度与效率之间取得了更优的平衡。较低的 GFLOPs 指标也意味着更低的硬件能耗,使模型即使在算力受限的边缘设备上也能满足工程巡检要求的推理速度,具备实际工程应用的潜力。

为了进一步评估模型在当前目标检测前沿方法中的竞争力,本文还将其与最新 SOTA 模型在 VisDrone2019 数据集的性能进行对比。现有研究表明,YOLOv9s 在 VisDrone2019 上的 mAP 为 35.7% 左右^[25],参数量约为 720 万个;而 RT-DETR 的 mAP 为 36.2%^[26]。相比之下,本文模型仅使用约 424 万个参数,取得了 38.75% 的 mAP,在精度与参数效率上都展现出显著优势。

3.3.2 消融实验

为了验证两项改进策略的独立有效性及其协同效应,本节设计了消融实验,结果如表 3 所示。与基线模型相比,本文提出的协同改进模型在精度(P)、召回率(R)与平均精度均值(mAP)上分别提升了

表2 不同模型对比结果

Tab.2 Comparison results of different models

模型	$P/\%$	$R/\%$	mAP/%	参数量/万个	帧率/FPS	计算性能/GFLOPs
TIB-Net	42.23	34.25	32.9	16.3	10	0.6
YOLOv5s	45.47	34.28	34.8	701.3	262	16.5
YOLOX-s	43.7	35.63	34.2	900	128	26.8
YOLOv7	45.62	33.2	33.6	3648	107	105
YOLOv7-tiny	46.78	32.1	32.8	600.7	238	13.2
本文模型	50.8	37.8	38.75	423.8	233	10.2

表3 消融实验结果

Tab.3 Results of ablation experiment

模型	P/%	R/%	mAP/%	参数量/万个	帧率/FPS
本文模型	50.8	37.8	38.75	423.8	233
单独引入SPD-Conv模块	48.2	37.37	37.92	412.3	255
单独引入微小目标检测头	48.6	36.44	37.89	376.8	254
基线模型YOLOv8	47.8	36.23	37.21	365.3	277

3%、1.57%和1.54%。

消融实验结果进一步清晰地揭示了各模块的独立贡献与协同机制。与基线模型相比,单独引入微小目标检测头时,模型召回率仅提升0.21%,mAP提升0.68%。这表明,单纯增加检测尺度并不能有效解决微小目标漏检问题,其根本原因在于前端下采样过程造成了特征信息的严重丢失,导致深层特征图中缺乏必要的细粒度信息,从而限制了高分辨率检测头的性能。相比之下,单独引入SPD-Conv模块后,模型召回率显著提升1.14%,证实了特征保真策略的基础性作用。SPD-Conv通过无损下采样保留了关键的几何特征,有效改善了输入特征图的质量,使得YOLOv8的任务对齐分配器能够基于保留的特征为微小目标正确分配正样本,从而显著降低漏检率。当两个模块协同工作时,模型mAP达到38.75%,较基线模型提升1.54%,显著高于两个模块单独改进后效果的线性叠加。这一非线性的性能增益来源于前后端的高效协同:前端SPD-Conv保障了微小目标特征的完备性,为系统提供了高质量的特征输入;后端检测头则有效利用由前端模块保留下来的细节信息,在更高空间分辨率下进行精准解析,从而实现整体性能的显著提升。

3.3.3 场景适配性分析

尽管本实验基于VisDrone2019数据集,但其检测结果对电力设备巡检场景具有明确的工程参考价值。实验结果表明,改进后的模型在以下两类典型场景中表现出显著优势,这些场景与电力系统缺陷检测任务高度相似。

1)极微小目标检测。在VisDrone2019测试集中,模型成功检测出远距离视角下尺寸小于32×32像素的行人和非机动车,这一能力与电力巡检中高空成像条件下检测绝缘子微裂纹的任务需求高度相关。前端SPD-Conv模块通过有效保留微弱边缘特征,有效缓解了传统下采样中细节特征丢失的问题。

2)复杂背景抗干扰。实验表明,在树木遮挡或光照不均的背景下,模型依然保持较高的召回率,有效模拟了电力巡检中常面临的树障遮挡或逆光拍摄环境。P2层高分辨率检测头使得模型能够利用浅层纹理信息,从复杂背景中识别出与螺栓锈蚀类似的低对比度目标。

综上所述,虽然实验基于通用微小目标数据集,但模型展现出的特征保持能力与抗干扰能力,充分验证了其在电力系统缺陷检测中具有良好的适用性。

4 结论

针对无人机巡检中电力设备微小缺陷难以检测的问题,本文提出了一种基于YOLOv8的高效协同增强策略。该策略通过将无损下采样模块SPD-Conv与高分辨率检测头深度耦合,系统性地解决了因下采样导致的细粒度特征丢失问题,并在满足边缘设备部署的情况下,实现对电力系统中微小缺陷的高精度检测。具体而言,一方面,在特征提取阶段,采用SPD-Conv模块代替Conv模块提取多尺度特征,减少细粒度信息的损失,增强模型对微小目标的特征提取能力;另一方面,在检测头部分增加了高分辨率检测头,提高对微小缺陷的检测能力。实验结果表明,改进后的模型在精确度、召回率和平均精度均值上均有明显提升,且其推理速度与模型复杂度满足边缘设备部署要求,在检测精度与运行效率之间取得了良好的平衡。综上所述,本文提出的方法为解决特定工业场景下的微小目标检测问题提供了有效且实用的技术路径,具备良好的工程应用前景。

尽管本文提出的协同增强模型在微小目标检测任务上取得了显著进展,但仍存在一定的局限性,主要体现在以下几个方面:

1)数据域的迁移偏差。本研究基于VisDrone2019数据集验证了模型对极微小目标的捕捉能力,但该数据集在纹理复杂度与背景噪声上与真

实电力系统缺陷的分布仍存在差异。在实际部署时,模型可能需要针对特定的绝缘子或金具样本进行少量的迁移学习或微调,以消除数据域偏差带来的误检或漏检。

2) 极端环境的鲁棒性验证。实际的电力巡检常面临大雾、雨雪、强逆光等极端环境,在这些低信噪比场景下,SPD-Conv 是否仍能有效保留特征,以及高分辨率检测头是否会引入过多的背景噪声,仍需进一步验证。

3) 边缘设备推理的优化。本文模型相比大型 Transformer 架构具有显著的轻量化优势,但 P2 高分辨率检测头的引入不可避免地增加了计算开销,在算力极度受限的微型无人机平台上,该模型的实时性可能受到限制。未来工作将探索更高效的模型剪枝与量化技术,以适应更严苛的边缘部署需求。

参考文献:

- [1] Xu B Y, Zhao Y L, Wang T, et al. Development of power transmission line detection technology based on unmanned aerial vehicle image vision [J]. SN Applied Sciences, 2023, 5(3): 72.
- [2] Jalil B, Leone G R, Martinelli M, et al. Fault detection in power equipment via an unmanned aerial system using multi modal data[J]. Sensors, 2019, 19(13): 3014.
- [3] Xie X W, Liu Z J, Xu C J, et al. A multiple sensors platform method for power line inspection based on a large unmanned helicopter[J]. Sensors, 2017, 17(6): 1222.
- [4] Katrasnik J, Pernus F, Likar B. A survey of mobile robots for distribution power line inspection[J]. IEEE Transactions on Power Delivery, 2010, 25(1): 485-493.
- [5] Li Z R, Liu Y E, Walker R, et al. Towards automatic power line detection for a UAV surveillance system using pulse coupled neural filter and an improved Hough transform[J]. Machine Vision and Applications, 2010, 21(5): 677-686.
- [6] Li X, Li Z J, Wang H Z, et al. Unmanned aerial vehicle for transmission line inspection: Status, standardization, and perspectives[J]. Frontiers in Energy Research, 2021, 9: 713634.
- [7] Sun H, Yang J, Shen J Q, et al. TIB-net: Drone detection network with tiny iterative backbone[J]. IEEE Access, 2020, 8: 130697-130707.
- [8] Ye T, Zhao Z Y, Zhang J, et al. Low-altitude small-sized object detection using lightweight feature-enhanced convolutional neural network [J]. Journal of Systems Engineering and Electronics, 2021, 32(4): 841-853.
- [9] Wastupranata L M, Munir R. UAV detection using web application approach based on SSD pre-trained model [C]// 2021 IEEE International Conference on Aerospace Electronics and Remote Sensing Technology (ICARES), 2021: 1-6.
- [10] He J, Liu M, Yu C. UAV reaction detection based on multi-scale feature fusion [C]// 2022 International Conference on Image Processing, Computer Vision and Machine Learning (ICICML). IEEE, 2022: 640-643.
- [11] Li H, Yang J H, Mao Y, et al. A UAV detection algorithm combined with lightweight network [C]// 2021 IEEE 5th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), 2021: 1865-1872.
- [12] 彭曙蓉, 刘登港, 何洁妮, 等. 基于改进 YOLOv4 的架空线路电力设备故障检测[J]. 电力科学与技术学报, 2023, 38(5): 169-176.
- [13] Peng S R, Liu D G, He J N, et al. Fault detection for overhead line power equipment based on improved YOLOv4[J]. Journal of Electric Power Science and Technology, 2023, 38(5): 169-176.
- [14] 马峻, 姚震, 徐翠锋, 等. 基于改进 PP-YOLO 和 DeepSORT 的多无人机实时跟踪算法[J]. 计算机应用, 2022, 42(9): 2885-2892.
- [15] Ma J, Yao Z, Xu C F, et al. Multi-UAV real-time tracking algorithm based on improved PP-YOLO and DeepSORT[J]. Journal of Computer Applications, 2022, 42(9): 2885-2892.
- [16] Liu J, Hu M M, Dong J Y, et al. The application of a lightweight model FA-YOLOv5 with fused attention mechanism in insulator defect detection[J]. Frontiers in Energy Research, 2023, 11: 1283394.
- [17] Zhang Y L, Li J Z, Fu W, et al. A lightweight YOLOv7 insulator defect detection algorithm based on DSC-SE[J]. PLoS One, 2023, 18(12): e0289162.
- [18] Wang Y, Zhang L H, Xiong X Z, et al. A lightweight and efficient multi-type defect detection method for transmission lines based on DCP-YOLOv8[J]. Sensors, 2024, 24(14): 4491.
- [19] Chatzargyros G, Papakonstantinou A, Kotoula V, et al. UAV inspections of power transmission networks with AI technology: A case study of Lesbos island in Greece [J]. Energies, 2024, 17(14): 3518.
- [20] Lin T Y, Maire M, Belongie S, et al. Microsoft coco: Common objects in context [C]// European conference on com-

- puter vision. Cham: Springer International Publishing, 2014:740–755.
- [19] Sunkara R, Luo T. No more strided convolutions or pooling: A new CNN building block for low-resolution images and small objects[C]//Joint European conference on machine learning and knowledge discovery in databases. Cham: Springer Nature Switzerland, 2022:443–459.
- [20] Gu Z C, Zhu K, You S T. YOLO–SSFS: A method combining SPD–conv/STDL/IM–FPN/SIoU for outdoor small target vehicle detection[J]. Electronics, 2023, 12(18):3744.
- [21] Li Y T, Fan Q S, Huang H S, et al. A modified YOLOv8 detection network for UAV aerial image recognition[J]. Drones, 2023, 7(5):304.
- [22] He K, Zhang X, Ren S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE transactions on pattern analysis and machine intelligence, 2015, 37(9):1904–1916.
- [23] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017:2117–2125.
- [24] Liu S, Qi L, Qin H F, et al. Path aggregation network for instance segmentation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018:8759–8768.
- [25] Zhang H, Peng Y, Liu Y L. UAV aerial photography target detection based on improved YOLOv9[J]. The Journal of Supercomputing, 2025, 81(3):492.
- [26] Kong Y N, Shang X F, Jia S J. Drone–DETR: Efficient small object detection for remote sensing image using enhanced RT–DETR model[J]. Sensors, 2024, 24(17): 5496.

(编辑 关欣佳)