

基于改进 YOLO11 的风机叶片表面缺陷检测研究

李松霖 唐 玲

(北京邮电大学智能工程与自动化学院 北京 100876)

摘要: 为解决无人机巡检中风机叶片缺陷特征弱化与定位困难的问题,提出了一种基于改进 YOLO11 的轻量化高精度检测算法。首先,在主干网络引入混合局部通道注意力(MLCA),通过局部纹理与全局上下文的协同建模,强化模型在复杂光照下对微小缺陷的响应;其次,采用 ADown 渐进式下采样替代标准卷积,在降低分辨率的同时最大限度保留缺陷边缘完整性;最后,构建多尺度注意力特征金字塔网络(MAFPN),通过跨层级特征聚合提升对不同尺度缺陷的表征能力。基于真实巡检数据集的实验表明,该方法在参数量减少 22.5%、GFLOPs 降低 9.5%的前提下,mAP@0.5 与 mAP@0.5:0.95 分别提升 4.0%与 5.6%,达到 85.7%与 61.1%。结论显示,该算法显著降低了复杂场景中的漏检与误检,与 I-YOLOv8n、O-YOLO11 等主流模型相比实现了更优的精度-效率平衡,更适合部署于无人机等资源受限的端侧设备。

关键词: 风机叶片缺陷检测;YOLO11;混合局部通道注意力;ADown 下采样;多尺度注意力特征金字塔网络

中图分类号: TN911.7 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Research on wind turbine blade surface defect detection based on improved YOLO11

Li Songlin Tang Ling

(School of Intelligent Engineering and Automation, Beijing University of Posts and Telecommunications, Beijing 100876, China)

Abstract: To address the issues of weakened defect features and localization difficulties in wind turbine blade drone inspections, this paper proposes a lightweight, high-precision detection algorithm based on the improved YOLO11 framework. Firstly, a mixed local channel attention (MLCA) module is introduced into the backbone to collaboratively model local texture details and global context, enhancing sensitivity to minor defects under complex lighting. Secondly, ADown progressive downsampling replaces standard convolutions to effectively preserve defect edge integrity while reducing feature map resolution. Finally, a multi-scale attention feature pyramid network (MAFPN) is constructed to improve semantic representation through cross-level feature aggregation. Experimental results on a real-world inspection dataset demonstrate that the proposed method achieves mAP@0.5 and mAP@0.5:0.95 scores of 85.7% and 61.1% (improvements of 4.0% and 5.6%, respectively), while reducing parameters by 22.5% and GFLOPs by 9.5%. The conclusion indicates that the algorithm significantly reduces missed and false detections in complex scenarios. Compared with representative models such as I-YOLOv8n and O-YOLO11, it achieves a superior accuracy-efficiency trade-off, making it highly suitable for deployment on edge devices like UAVs.

Keywords: wind turbine blade defect detection; YOLO11; mixed local channel attention; ADown downsampling; multi-scale attention feature pyramid network

0 引言

随着风能行业的快速发展,风电装备的稳定性与安全性成为确保风电场高效运行的关键因素。风电装备的关键部件(如叶片、塔筒等)长期暴露在复杂和恶劣的环境中,容易

出现裂纹、雷击、磨损等缺陷,这些缺陷如果未能及时发现并修复,可能导致设备故障甚至停机。风电机组的典型损伤主要表现为表皮脱落、涂层破损、砂眼及裂纹等,这些损伤的产生原因不一,对风机的损伤程度也不相同。有数据显示,风力发电机组的主要故障部位为叶片,占到了机组总事故率的

30%以上,是风能发电系统中最脆弱的部分^[1]。

过去风电机组表面缺陷巡检主要依赖人工(如望远镜远观与吊篮/绳索作业),但存在记录缺失、覆盖不足、效率低且风险高等问题^[2]。宋晔等^[3]系统综述了基于无人机航拍的叶片检测方法,指出将无人机航拍与机器视觉结合是解决传统巡检痛点的有效途径。随着无人机技术和图像处理技术的进步,基于无人机的图像采集缺陷检测技术因其成本低、操作简便以及无损检测等优点受到广泛研究^[4]。例如,Tan 等^[5]针对无人机图像对比度低的问题,提出利用改进直方图均衡化增强图像细节,结合传统阈值分割技术实现叶片表面缺陷的提取。然而,传统方法在复杂背景下的泛化能力有限,因此基于深度学习的表面缺陷检测技术逐渐广泛应用在风机叶片缺陷检测中^[6]。早期研究多基于两阶段检测框架或传统候选区域方法;例如,有学者在 Faster R-CNN 框架上引入改进的 ResNet 骨干和多尺度特征融合策略,并在特征层中嵌入注意力机制以突出关键缺陷区域,在无人机航拍数据上的平均准确率较原始 Faster R-CNN 提升约 8%^[7];付军军等^[8]则针对海上风机叶片早期缺陷尺寸小、检测难的问题,在 EfficientNet 中引入混合空间通道注意力与 BiFPN 特征融合模块,有效提升了分类与定位精度;也有工作采用“Haar-AdaBoost 候选区域+CNN 分类”的分层识别网络,在保证较高召回率的同时兼顾了在线检测的计算开销^[9]。此外,还有研究对 YOLOv3、YOLOv4 和 Mask R-CNN 等典型检测模型进行系统比较,并结合图像增强、数据增广与任务定制化调参与评价指标改进,在一定程度上缓解了数据规模受限带来的性能瓶颈^[10]。总体而言,这些方法验证了深度学习在风机叶片表面缺陷检测中的有效性,但在模型轻量化、实时性以及复杂背景和多尺度缺陷的鲁棒性方面仍存在明显不足。

随着 YOLO 系列目标检测算法在工业视觉领域的广泛应用,越来越多学者开始围绕风机叶片表面缺陷检测场景对 YOLO 结构进行针对性改进。一类研究以 YOLOv5/YOLOv8 等版本为基础,重点面向轻量化与复杂背景下的鲁棒性。例如,李大华等^[11]在 YOLOv8n 框架中引入 MobileNetV2 的关键模块,提出 Extra-IB 与 C2f-Extra-IB 结构用于减少模型参数量并提升浅层特征质量;同时设计自适应高效多尺度空间金字塔(adaptive efficient multi-scale feature pyramid, AEMFP)替换传统快速空间金字塔池化(spatial pyramid pooling fast, SPPF),在颈部网络中嵌入高效局部注意力(efficient local attention, ELA),增强多尺度特征融合与小目标检测能力。该方法在风机桨叶表面缺陷数据集上的 mAP 提升 5.1%,参数量和 FLOPs 分别降低约 22%,实现了较好的精度-轻量化折中,适合部署于无人机等算力有限平台;张泽辰等^[12]同样基于 YOLOv8 构建了小目标感知增强网络,通过动态通道空间卷积与多尺度 Transformer 模块的协同设计,强化模型对叶片细微缺陷的语义理解与定位能力,显著优于 RT-DETR 等模型。

尽管上述方法在风机桨叶缺陷检测的轻量化或检测精度上各有建树,但它们仍基于 YOLOv8,对最新 YOLO11 架构中骨干与颈部的改进潜力尚未充分挖掘。

随着 YOLO11 的发布,其在特征提取与实时性方面的优势使其逐渐成为风机叶片缺陷检测的研究新热点。YOLO11 在骨干网络中引入 C3k2 模块和 C2PSA 并行空间注意力结构,并在颈部采用改进的 SPPF 等组件,在保证检测精度的同时显著提升了推理速度^[13-14]。在此基础上,越来越多研究开始尝试在 YOLO11 上进行定制化改进,以进一步提升叶片缺陷检测性能。孙斌^[15]面向风机叶片与光伏板缺陷检测任务,在 YOLO11 模型基础上引入卷积注意力模块(convolutional block attention module, CBAM)和小波变换卷积(wavelet transform convolution, WTConv)单元,以增强多尺度特征融合与纹理细节提取能力。实验结果表明,YOLO11+CBAM 与 YOLO11+WTConv 均能带来一定精度提升,而两者联合时 mAP 相比原始 YOLO11 提升 3.3%,说明通道-空间注意力与频域卷积结合有助于提升复杂背景下的缺陷检出率。但该方法主要关注注意力与卷积核形式的改造,对下采样策略与特征金字塔结构的优化涉及较少,且模型复杂度有所增加,对无人机端部署的实时性影响仍有待进一步评估。

针对 YOLO11 在叶片缺陷检测中的下采样与小目标表征问题,部分研究从特征提取和类别不平衡两个层面进行改进。文献[16]提出一种优化的 YOLO11 模型,引入源自 YOLOv9 的 ADown 双路径下采样模块,以在特征提取阶段保留更多细粒度边缘信息;设计 EdgeAttention 机制强化复杂背景下小裂纹和边缘分布缺陷的响应;在损失函数层面提出双重选择机制(dual selection mechanism, DSM),通过动态排序与加权策略增强对稀有且难检类别的学习能力。实验表明,该方法在风机叶片缺陷数据集上的 mAP@0.5 达到 86.9%,对难检缺陷类别的检测性能提升约 10%,说明改进下采样与类别选择机制对叶片缺陷检测具有显著效果。但该方法引入多种新模块,整体结构相对复杂,训练与部署成本较高,且对模型轻量化与推理效率的系统性分析相对不足。

此外,还有研究关注多尺度注意力与结构轻量化的协同设计。文献[17]提出 SNMSDA-YOLO11,将多尺度空洞卷积与膨胀注意力(multi-scale dilated attention, MSDA)嵌入 YOLO11,以提升对不同尺度裂纹、剥落及表面磨损的特征提取能力,同时采用 SlimNeck 结构优化颈部网络,在保证精度的同时显著降低计算开销。实验结果显示,该方法在自建风机叶片缺陷数据集上的检测准确率达到 94.9%,FPS 约 110,在一定程度上兼顾了检测性能与推理速度。但该方法主要从注意力与颈部轻量化两方面进行优化,对下采样过程中的细节保留策略与浅层-深层特征的协同融合仍有改进空间。

综合上述研究可以看出,现有基于改进 YOLO,特别

是改进 YOLO11 的风机叶片缺陷检测方法,主要从 3 类思路展开:1)通过引入 CBAM、多尺度空洞注意力等模块增强特征表征能力;2)采用 ADown 等新型下采样结构和改进损失机制改善小目标和难检缺陷的检测;3)结合 SlimNeck、轻量级骨干或 MobileNet 模块实现模型轻量化。

这些方法在各自关注的方面取得了显著效果,但仍存在以下不足:1)多数工作倾向于对单一结构模块进行改造,缺乏从 Backbone 下采样、Neck 多尺度融合到注意力建模的系统性协同设计;2)部分方法在引入复杂注意力或多分支结构后,模型参数量和 FLOPs 明显增加,与无人机平台的实时性和能耗约束存在矛盾;3)在复杂光照、多视角拍摄条件下,如何在轻量化前提下同时兼顾局部弱小缺陷特征的保留和背景光照干扰的抑制,当前研究仍未给出较为完善的解决方案。

在实际巡检应用中,受环境因素、机组结构复杂性及尺寸巨大等影响,无人机拍摄图像的定位精度和分辨率有限,缺陷识别与定位仍面临诸多挑战,如拍摄角度及风速变化导致缺陷尺寸估计误差,强反光、阴影、逆光及天气变化使表面纹理弱化和伪影产生,微小缺陷易被掩盖或与复杂背景(如污渍、涂层修补)混淆。此外,标准下采样与深层网络处理易损失细节,造成裂纹等结构断裂或漏检,且机载算力与能耗限制对模型的轻量化和实时性提出了更高要求。由此,现有基于深度学习的检测方法仍难以充分适应风电机组表面图像的复杂性和多样性。

针对风机叶片无人机巡检中因视角多变、光照复杂导致的缺陷特征弱化与定位偏差问题,以及现有改进 YOLO/YOLO11 方法多聚焦于单一模块改造、对下采样

细节保留与多尺度特征协同融合考虑不足的现状,本文在 YOLO11 框架上设计了一种面向风机叶片表面缺陷的轻量化高精度检测模型。不同于仅在 YOLO11 中引入单一注意力模块或单一下采样/金字塔结构的改进策略,本文从 Backbone 下采样、Neck 多尺度融合和注意力建模 3 个层面提出三级协同优化方案:

1)自适应特征聚焦机制:在骨干网络中嵌入混合局部通道注意力(mixed local channel attention, MLCA)模块,融合局部纹理细节与全局上下文信息,通过局部平均池化与全局平均池化的联合建模以及一维卷积通道重标定,增强模型对复杂光照扰动下微小裂纹、剥落等局部缺陷的敏感性,同时抑制背景高光与阴影干扰;

2)高效下采样结构:有选择地引入 ADown 渐进式下采样模块替代部分标准 stride=2 卷积,使特征图分辨率逐级降低的同时尽可能保留缺陷边缘与细节纹理信息,缓解深层网络处理中裂纹结构断裂和小目标漏检的问题;

3)多尺度特征增强骨架:在颈部网络中采用轻量化改造的多尺度注意力特征金字塔网络(multi-scale attention feature pyramid network, MAFPN),通过浅层辅助特征(shallow auxiliary feature, SAF)与自适应注意力融合(adaptive attention fusion, AAF)的跨层级特征聚合与空间加权,加强对不同尺度裂纹、剥落及污渍等缺陷的语义捕获能力。

1 YOLO11 算法基础

YOLO11 的网络结构主要由骨干网络(Backbone)、颈部网络(Neck)和检测头(Head)这 3 部分组成^[13-14]。YOLO11 网络结构如图 1 所示。




图 1 YOLO11 网络结构

Fig. 1 YOLO11 network structure

1.1 Backbone

Backbone 部分负责特征提取,采用了一系列卷积和反卷积层,同时使用了残差连接和瓶颈结构来减小网络的大小并提高性能。YOLO11 使用 C3K2 块来处理主干不同阶段的特征提取。较小的 3×3 内核允许更有效地计算,同时保留模型捕获图像中基本特征的能力。YOLO11 主干的核心是 C3K2 块,它是早期版本中引入的跨阶段部分连接(cross stage partial,CSP)瓶颈的演变。C3K2 结构如图 2 所示,它利用多个

小卷积替代大卷积以提升速度与参数效率^[18]。CSP 思想通过在跨阶段对特征图进行分割,仅对其中一部分施加瓶颈变换,并在阶段末进行融合,从而在控制计算量的同时保持梯度流动与特征多样性^[19]。C3K2 模块通过分割特征图并应用一系列较小的内核卷积(3×3)来优化网络中的信息流,这比较大的内核卷积更快,计算成本更低。通过处理较小的独立特征图并在几次卷积后合并它们,C3K2 模块与 YOLOv8 的 C2f 模块相比,使用更少的参数来改进特征表示。




图 2 C3K2 结构
Fig. 2 Structure of C3K2

C2PSA 块使用两个部分空间注意力(partial spatial attention,PSA)模块,它们在特征图的不同分支上操作,然后连接起来,类似于 C2F 块结构。这种设置确保模型专注于空间信息,同时保持计算成本和检测精度之间的平衡。C2PSA 模块通过在提取的特征上应用空间注意力来细化模型选择性地关注感兴趣区域的能力。C2PSA 结构如图 3 所示。

了特征聚合过程的速度和性能。注意力机制:YOLO11 通过 C2PSA 更加关注空间注意力,这有助于模型聚焦于图像中的关键区域,从而实现更好地检测。

1.3 Head

Head 是目标检测的决策部分,直接产生最终的分类与回归结果。现代单阶段检测器常采用解耦检测头(分类/回归分支分离)以改善优化过程与收敛性质,从而带来更稳定的训练与更好的精度-速度权衡^[20]。Head 检测头结构如图 4 所示。




图 3 C2PSA 结构
Fig. 3 Structure of C2PSA

1.2 Neck

Neck 网络位于主干网络和头部网络之间,颈部负责聚合不同分辨率的特征并将它们传递给头部进行预测。它通常涉及不同级别的特征图的上采样和连接。YOLO11 将颈部的 C2f 块替换为 C3k2 块。这一变化提高




图 4 Head 检测头结构
Fig. 4 Head detection head structure

2 YOLO11 算法的改进

2.1 整体网络框架

在 YOLO11 的基础上,针对无人机巡检中因光照扰动与视角多变导致的小缺陷弱化、下采样引发的边缘细节丢失以及多尺度语义对齐不足等问题,本文构建了“混合注意力-渐进下采样-多尺度骨架”的整体改进方案。与部分仅在 YOLO11 中引入单一注意力模块或仅替换下采样/颈部结构的工作不同^[15-17],本文从 Backbone 下采样、Neck 多尺度融合和注意力建模 3 个层面进行协同设计与轻量化约束,以适配无人机端算力有限、视角多变和光照复杂的

综合场景需求。

具体而言,在骨干网络中嵌入 MLCA 模块,对浅中层特征进行自适应特征聚焦,突出微小缺陷并抑制光照伪影;在 Backbone 的若干关键下采样层引入 ADown 渐进式下采样模块,有选择地替换部分 stride=2 卷积,在降低分辨率的同时最大化保留裂纹与边缘轮廓;在颈部结构中采用轻量化改造的 MAFPN 替代原有融合路径,通过跨层聚合与注意力加权实现多尺度语义对齐与小目标强化。整体信息流为:输入→改进骨干(MLCA+ADown)→MAFPN→解耦检测头。在轻量

化与端侧实时性约束下,该框架旨在显著提升风机叶片缺陷的检测精度,增强复杂光照与背景干扰场景下的鲁棒性。改进后的 YOLO11 网络结构如图 5 所示,Backbone 中仅在特征图下采样至 1/8 和 1/16 的两个阶段使用 ADown 替代标准 stride=2 卷积,其余下采样采用常规卷积;MLCA 插入于第 1 个 1/8 尺度 C3k2 模块之后,用于对中层特征进行自适应通道重标定。来自 1/8、1/16 及最深层(分别记为 P3、P4、P5)的特征被送入轻量化改造的 MAFPN 进行多尺度融合,并通过 3 层解耦检测头完成不同尺度缺陷的检测。




图 5 改进后的 YOLO11 网络结构

Fig. 5 Improved YOLO11 network structure

在上述设计中,MLCA 主要应对复杂光照与局部弱小缺陷的特征聚焦问题,ADown 重点解决下采样阶段的细节保留与轻量化需求,而 MAFPN 负责在多尺度空间中重组浅层细节与深层语义。构建的整体框架并非简单堆砌模块,而是针对风机叶片无人机巡检场景的有机协同优化。

2.2 MLCA 机制

风机叶片表面缺陷检测常受限于无人机拍摄时的视角变化、复杂光照等现场干扰,导致同一类缺陷(如裂纹)在不同图像中表现出显著的方向、位置及外观差异。传统深度网络特征学习在处理细微缺陷和不稳定环境时往往容易丢失关键信息。因此,为提升 YOLO11n 模型在复杂场景下的鲁棒性和细粒度特征感知能力,本文引入了 MLCA 机制进行结构改进。MLCA 机制结构如图 6 所示。

MLCA 是一种轻量级注意力模块,旨在在不显著增加模

型计算量的前提下,有效提升对关键缺陷区域及其空间位置的敏感性^[21]。其核心机制为:

1) 多尺度特征提取

局部平均池化(local average pooling, LAP):采用固定窗口(如 5×5)滑动提取局部区域均值,强化对缺陷的细粒度特征和邻域相关性的感知,提升对微小纹理变化的捕捉能力。

全局平均池化(global average pooling, GAP):计算整图全局特征均值,捕获场景整体上下文,为通道重要性建模提供全局信息支撑。

2) 特征交互与转换

对原特征、LAP 输出和 GAP 输出分别进行融合(如逐元素相加或拼接),将局部细节与全局特征进行协同建模,弥补单一池化方式的不足。融合后的特征经高效 1D 卷积进行通道关系建模。1D 卷积结构在保证建模能力的同时




图 6 MLCA 结构

Fig. 6 Structure of MLCA

显著降低了参数量和计算开销。

3) 信息恢复与注意力权重生成

对降维后的特征通过上采样或反池化还原至原始空间尺寸,从而生成兼具空间和通道敏感性的注意力权重,实现精确特征重标定,从而突出关键缺陷区域、抑制背景干扰。

与仅依赖全局平均池化的挤压-激励(equeeze-and-excitation, SE)、高效通道注意力(efficient channel attention, ECA)等模块相比,MLCA 在权重生成过程中显式引入 LAP,通过滑动窗口捕获邻域纹理变化,使得模型在复杂光照和高反光背景下仍能感知叶片表面细小裂纹、轻微剥落等局部弱小缺陷;与需要额外二维卷积操作的 CBAM 相比,MLCA 采用 1D 卷积建模通道关系,并通过上采样/反池化实现空间敏感性,在不显著增加参数量和 FLOPs 的前提下实现通道-空间联合重标定,更适合部署于算力受限的无人机平台。

2.3 引入 ADown 下采样模块

由于改进后的模型需要部署到无人机等移动设备上,进行风机叶片表面缺陷检测,因此在保证检测精度的同时必须严格控制计算量和参数量。传统的 stride=2 卷积或池化操作在降低特征图分辨率的同时,往往会造成细小裂纹和边缘纹理信息的严重丢失,不利于微小缺陷的捕捉。为此,本文在 YOLO11 Backbone 中有选择地引入 ADown 渐进式下采样模块^[22],以在兼顾轻量化和细节保留的前提下实现高效下采样。ADown 下采样模块结构如图 7 所示。

ADown 模块的原理:

1) 自适应空间压缩

ADown 模块基于可变卷积核尺寸、步长及动态通道




图 7 ADown 下采样模块结构

Fig. 7 ADown downsampling module structure

融合机制,实现特征图空间分辨率的自适应压缩。与传统池化或规则卷积下采样方式不同,ADown 能够灵活控制信息流,较好地保留关键信息,尤其优化了对小目标特征的分辨能力,降低信息丢失风险。

2) 多尺度特征融合

该模块融合了局部浅层细节与深层语义信息,通过并行的卷积、平均池化和最大池化路径实现多尺度特征的提取与聚合。部分分支可引入通道注意力机制,实现不同维度信息的有效交互,有利于增强细粒度缺陷与大尺度语义的联合感知能力。

3) 轻量化设计

在结构上,ADown 采用分组卷积、深度可分离卷积和通道混洗等轻量化算子,极大减少了参数及计算消耗。特别是分组和可分离卷积策略,降低了通道间冗余计算,提

升推理效率,适合嵌入式、移动端等资源受限场景。

与部分工作在所有下采样层统一采用 ADown 的做法不同^[16],本文仅对 Backbone 中两个关键信息尺度转换层(对应特征图下采样至 1/8 和 1/16 的阶段)使用 ADown 替换标准 stride=2 卷积;一方面,在靠近输入端的浅层保持常规下采样,避免过早引入多分支结构带来的显存与计算开销;另一方面,在中高层特征阶段采用渐进式下采样,有助于更好地保留叶片裂纹轮廓和缺陷边缘等关键信息。

ADown 模块通过并行的卷积分支、平均池化分支和最大池化分支完成自适应空间压缩与多尺度特征融合:卷积分支负责提取局部纹理及结构信息,平均池化分支保留全局平滑背景,最大池化分支突出强响应区域,从而在下采样的同时尽量保留多种尺度与类型的特征。为满足无人机端轻量化部署需求,本文在实现时沿用其分组卷积、深度可分离卷积和通道混洗等轻量化设计,并通过 1×1 卷积对多分支输出进行通道压缩与融合,进一步降低了参

数量与 FLOPs。

2.4 改进特征金字塔网络结构 MAFPN

风机叶片表面缺陷呈现明显的多尺度特性,不同类型缺陷(如小孔洞、裂纹与大面积剥落)在空间尺寸及形态分布上差异显著。此外,同类缺陷在不同拍摄场景下也因成像距离和角度变化表现出多样的尺度分布。传统特征金字塔网络(feature pyramid network, FPN)虽可部分缓解多尺度检测难题,但在浅层与深层特征协同、上下文融合和注意力聚焦能力上依然存在不足。为此,本文引入并针对风机叶片检测场景进行轻量化改造的 MAFPN^[23],以提升多尺度风机叶片缺陷的检测性能。与部分直接在所有尺度上堆叠 MAFPN 的改进 YOLO11 方法不同^[17],本文仅在 {P3, P4, P5} 3 个关键尺度上构建 MAFPN 分支,并通过通道压缩和共享权重策略控制额外引入的计算量,使其更适合在 YOLO11n 这类轻量化骨干上部署。MAF-YOLO 网络结构如图 8 所示。




图 8 MAF-YOLO 网络结构

Fig. 8 MAF-YOLO network structure

MAFPN 主要包括以下两个核心子模块:

1) SAF 模块

引入浅层分支特征,经 1×1 卷积调控通道数量,有效控制浅层信息在融合阶段的比重,既保留空间定位细节,又抑制噪声敏感性,避免对主干深层语义的干扰。浅层特征通过融合上采样与下采样操作,与深层特征实现多维度的信息交互与补充,保持特征梯度流畅,增强小目标等细粒度表征能力。

2) AAF 模块

整合高分辨率浅层、低分辨率浅层、同层输出及前序层级等多源特征,通过 1×1 卷积对各分支特征自适应参数化赋权,实现动态融合,防止单一路径特征主导,增强模

型对不同尺度目标的学习能力。通道数均衡设计保证各类特征平等参与输出,提升多尺度上下文的全面表征。

与原始 MAFPN 结构相比,本文在通道维度和层级数量上进行了裁剪,仅保留对风机叶片缺陷检测最为关键的中高层特征融合路径,同时配合 MLCA 对浅层局部特征的增强和 ADown 对细节的保留,使浅层-深层特征在更紧凑的特征金字塔中得到有效重组。

3 实验数据与分析

3.1 实验环境和参数设置

本文的试验环境如下:操作系统为 Windows 11, CPU 型号为 Intel(R) Core(TM) i7-14700HX, 内存为 32 GB,

GPU 型号为 NVIDIA GeForce RTX 4070 Laptop GPU。采用的深度学习框架为 PyTorch2.4.1 和 CUDA12.1,编程语言为 Python 3.8。模型训练的参数设置如下:批量训练图片数(Batch-size)为 16,训练轮次(Epoch)为 300,图片尺寸(image-size)为 640×640 ,初始学习率(lr)为 0.01,SGD 动量因子(momentum)为 0.937,优化器为 SGD,优化器权重缩减(weight-decay)为 0.000 5,验证指标无改进的等待 epoch 数(patience)为 40,使用 NVIDIA GPU 进行模型训练。

3.2 评估指标

为了验证所提方法的有效性,采用多项评估指标进行验证,包括精确率(precision, P)、召回率(recall, R)、平均精度均值(mean average precision, mAP)、模型参数量(parameters, Params)和模型计算量(floating point operations per second, FLOPs)等^[24]。

P 代表模型预测为正类的样本中真实正类的比例。计算公式为:

$$P = \frac{TP}{TP + FP} \quad (1)$$

其中,TP(true positive)为正确检测的正样本数量,FP(false positive)为错误检测的负样本数量。 P 越高,表明模型的误检率越低。

R 代表真实正类中被模型正确预测的比例。计算公式为:

$$R = \frac{TP}{TP + FN} \quad (2)$$

其中,FN(false negative)为漏检的正样本数量。 R 越高,表明模型的漏检率越低。

平均精度均值 mAP 代表个类别平均精度(average precision, AP)的均值。AP 为 P - R 曲线与坐标轴所包围的面积,指模型对某一类缺陷的平均精度值,计算公式为:

$$AP = \int_0^1 P(R) dR \quad (3)$$

mAP 计算公式为:

$$mAP = \frac{1}{c} \sum_{i=1}^c AP_i \quad (4)$$

其中, c 为缺陷类别的数量。

Params 代表模型中可训练参数的总数。Params 越大,模型复杂度越高,对硬件资源的需求也越大。

FLOPs 代表模型进行一次前向推理所需的浮点运算次数,单位为 GFLOPs(十亿次),GFLOPs 值越大表示需要更多的计算资源来执行检测任务。

由此构成了一个全面的评价框架,以评估改进方法在实际应用中的效能及资源消耗情况^[25]。

3.3 数据集

本文使用的叶片数据集是由现场人员利用无人机巡检时拍摄的高清叶片图像,涵盖不同时间、天气条件和光

照条件,数据集的复杂性较高,与实际场景的吻合性较高,更适用于验证改进的缺陷检测方法在各种实际场景中的表现,每幅图像的分辨率为 640×640 。该数据集包含 4 467 张高分辨率的风力涡轮机叶片表面缺陷图像,这些图像涵盖了多样化的背景,确保了数据集的广泛适用性和真实性。数据集包含 7 种标签:燃烧(burning)、裂缝(crack)、变形(deformity)、污垢(dirt)、油渍(oil)、剥落(peeling)、生锈(rusty),按照 7:2:1 的比例将数据集随机划分为训练集、验证集和测试集。数据集中的部分图片抽样如图 9 所示。



图 9 数据集部分图像

Fig. 9 Sample images from the dataset

4 实验结果与分析

4.1 注意力实验

为定量分析所提出的 MLCA 模块在风机叶片缺陷检测任务中的实际效果,在保持原始网络结构、参数量均一致的前提下,将 MLCA 与主流注意力机制 SE^[26]、TripletAttention^[27]、CPCA^[28]、LSKA^[29] 进行对比,所有模块均插入模型相同位置。主要评价指标包括 P 、 R 、mAP@0.5 及 mAP@0.5:0.95 等,试验结果如表 1 所示。

由表 1 可知,MLCA 模块在多项性能指标上表现优异。引入 MLCA 后,模型的 P 由 83.2% 提升至 87.2%,提升 4.0%;mAP@0.5 与 mAP@0.5:0.95 分别达 83.1% 与 56.4%,均为最高。虽然 R 略有下降(下降 1.5%),但整体检出能力依然处于较高水平。 P 的提升归因于 MLCA 更有效地抑制了误检(false positives, FP),而 R 的轻微下降则与注意力聚焦特定通道、对部分非关键区域特征敏感性降低有关。

为进一步验证各注意力模块的差异,采用 Layer-CAM 算法^[30]对检测过程中的特征热力进行可视化,如图 10 所

表 1 不同注意力机制对比

Table 1 Comparative analysis of different attention mechanisms				%
注意力机制	P	R	mAP@0.5	mAP@0.5:0.95
无注意力	83.2	77.2	81.7	55.5
SE	85.7	77.6	82.4	55.5
TripletAttention	85.6	79.8	83.1	55.7
CPCA	86.8	74.6	81.0	54.1
LSKA	85.2	79.3	83.0	55.9
MLCA	87.2	75.7	83.1	56.4




图 10 不同注意力可视化对比

Fig. 10 Visualization comparison of different attention mechanisms

示。从热力图对比结果看,SE、TripletAttention、CPCA 和 LSKA 主要聚焦于裂纹主干区域,但对裂纹端点、轮廓等

细微位置识别敏感性较弱,且背景区域仍存在明显高响应,误激抑制不足。MLCA 热力集中在裂纹全局及上下边缘,区域更紧凑,背景(如山地、杂乱纹理)热力响应显著降低,能够有效引导网络聚焦于真实缺陷区域,抑制环境干扰。仅个别非目标区域有轻微热点,整体干扰不大。

实验结果表明,引入 MLCA 注意力模块能在保证召回能力的前提下,显著提升缺陷检测的准确性和 mAP 指标,并有效改善模型的特征聚焦能力与背景噪声抑制效果,充分证明了 MLCA 设计在风机叶片缺陷检测任务中的应用优势。

4.2 消融实验

为验证本文所提出的 3 种改进策略对模型性能的影响,本文对基础网络 YOLO11n 进行消融试验,1)添加 MLCA 机制;2)引入 ADown 下采样模块;3)改进特征金字塔网络结构 MAFPN。其中,“×”表示未加入此模块,“√”表示模型加入了相应的模块,在实验环境和参数保持不变的基础上,设计了 8 组消融实验,实验结果如表 2 所示。

表 2 YOLO11n 改进前后的消融实验结果分析

Table 2 Ablation experimental results analysis of YOLO11n before and after improvement									
实验	MLCA	ADown	MAFPN	P/%	R/%	mAP@0.5/%	mAP@0.5:0.95/%	Params/M	FLOPs/G
1	×	×	×	83.2	77.2	81.7	55.5	2.58	6.3
2	√	×	×	87.2	75.7	83.1	56.4	2.58	6.3
3	×	√	×	86.1	80.6	84.5	59.2	2.10	5.3
4	×	×	√	86.0	77.4	83.2	56.1	2.70	7.1
5	√	√	×	92.0	76.7	84.3	59.8	2.10	5.3
6	√	×	√	89.0	75.7	84.0	57.4	2.70	7.1
7	×	√	√	89.5	79.9	85.4	61.0	2.00	5.7
8	√	√	√	91.3	79.8	85.7	61.1	2.00	5.7

第 1 组实验为基础算法 YOLO11n,P 为 83.2%,R 为 77.2%,mAP@0.5 为 81.7%,mAP@0.5:0.95 为 55.5%,Params 为 2.58 M,GFLOPs 为 6.3。将其作为基准模型和后续实验进行对比。

第 2~4 组实验分别添加了一种模块进行实验,从表 2 中可以看到效果最显著的是在主干网络中引入 ADown 下采样模块的实验组,相较于基准模型 P 提升 2.9%(由

83.2%提升至 86.1%),R 提升 3.4%(由 77.2%提升至 80.6%);mAP @ 0.5 提升 2.8%(由 81.7%提升至 84.5%),mAP@0.5:0.95 显著提升 3.7%(由 55.5%提升至 59.2%);同时,Params 减少 18.6%(由 2.58 M 减少至 2.10 M),GFLOPs 减少 15.9%(由 6.3 减少至 5.3)。这表明 ADown 通过高效下采样优化了特征提取,不仅全面提升检测性能(尤其是 R 和 mAP),还显著降低模型复杂

度和计算开销;添加 MLCA 机制后,与基准相比: P 提升 4.0%(由 83.2%提升至 87.2%), R 下降 1.5%(由 77.2%下载至 75.7%); $mAP@0.5$ 提升 1.4%(由 81.7%提升至 83.1%), $mAP@0.5:0.95$ 提升 0.9%(由 55.5%提升至 56.4%);Params 和 GFLOPs 不变。这表明 MLCA 有效提升了 P 和 mAP , R 轻微下降。整体上,MLCA 对精度有正向贡献;改进特征金字塔网络结构 MAFPN 后,相较于基准模型 P 提升 2.8%(由 83.2%提升至 86.0%), R 几乎不变(由 77.2%提升至 77.4%,+0.2%); $mAP@0.5$ 提升 1.5%(由 81.7%提升至 83.2%), $mAP@0.5:0.95$ 提升 0.6%(由 55.5%提升至 56.1%);但 Params 增加 4.7%(由 2.58 M 增加至 2.70 M),GFLOPs 增加 12.7%(由 6.3 增加至 7.1)。这表明 MAFPN 有效提升了精确度和 mAP ,但 R 改善有限,且增加了计算负担。所有策略单独加入时,均提升 $mAP@0.5$ (MLCA 提升 1.4%,ADown 提升 2.8%,MAFPN 提升 1.5%) 和 $mAP@0.5:0.95$ (MLCA 提升 0.9%,ADown 提升 3.7%,MAFPN 提升 0.6%),证明每种策略独立有效。

第 5~7 组实验分别同时对模型进行了两种改进,其中引入 ADown 下采样模块和改进特征金字塔网络结构 MAFPN 的实验组效果显著,ADown 的资源节省抵消了 MAFPN 的开销,并大幅提升 mAP ,表明二者在特征提取和融合上协同效应强。相较于基准模型 P 提升 6.3%(由 83.2%提升至 89.5%), R 提升 2.7%(由 77.2%提升至 79.9%); $mAP@0.5$ 提升 3.7%(由 81.7%提升至 85.4%), $mAP@0.5:0.95$ 显著提升 5.5%(由 55.5%提升至 61.0%);Params 减少 22.5%(由 2.58 M 减少至 2.00 M),GFLOPs 减少 9.5%(由 6.3 减少至 5.7)。

第 8 组为结合了 3 种改进方式的实验组,模型在 P 、 R 、 $mAP@0.5$ 和 $mAP@0.5:0.95$ 上相较于基准模型分别提升了 8.1%、2.6%、4.0% 和 5.6%,达到了 91.3%、79.8%、85.7% 和 61.1%,说明改进后的模型具有显著的精度优势和更好的模型稳定性。同时模型在 Params 和 GFLOPs 上相较于基准模型分别降低了 0.58 M 和 0.6,达到了 2.00 M 和 5.7,说明改进后的模型具有更小的计算开销,更适合嵌入式部署。

消融实验充分表明,3 种改进策略无论单独还是协同应用,均可有效提升 YOLO11n 在风机叶片缺陷检测任务中的 P 、 R 与 mAP 表现,且搭配合理时可几乎不增加,甚至降低模型体量和计算负载。

4.3 对比实验

为验证所提算法在风机叶片表面缺陷检测任务中的综合性能,本文分别从基础检测模型与代表性改进 YOLO 模型两个层面开展对比实验。基础模型包括 SSD、Faster R-CNN 以及 YOLOv6n、YOLOv8n、YOLOv9t、YOLOv10n 和 YOLO11n 等主流目标检测算法;改进 YOLO 模型则选取了近期风机叶片缺陷检测领

域具有代表性的 3 类方法:

1)改进 YOLOv8n 的风机桨叶表面缺陷轻量化检测网络(记为 I-YOLOv8n)^[11];

2)引入 ADown、EdgeAttention 和 DSM 的优化 YOLO11 模型(记为 O-YOLO11)^[16];

3)基于 SlimNeck 和多尺度空洞注意力的 SNMSDA-YOLO11 模型(记为 SNMSDA-YOLO11)^[17]。

其中,I-YOLOv8n 代表了以 YOLOv8 为核心的轻量化改进思路,O-YOLO11 和 SNMSDA-YOLO11 则是当前针对 YOLO11 的两类典型改进方向:前者侧重下采样与类别不平衡优化,后者侧重多尺度注意力与颈部轻量化设计。

为了保证公平性,本文在自建风机叶片表面缺陷数据集上对所有对比模型进行了统一训练与测试,各模型在输入分辨率、训练轮数、优化器及数据增强策略等方面尽量保持一致。性能评价指标方面,选取 P 、 R 、 $mAP@0.5$ 和 $mAP@0.5:0.95$ 作为检测精度指标,Params 和 FLOPs 作为模型复杂度与推理效率的衡量指标。

对比结果如表 3 所示。本文算法(改进的 YOLO11n)在叶片数据集上 P 、 R 、 $mAP@0.5$ 和 $mAP@0.5:0.95$ 分别达到了 91.3%、79.8%、85.7% 和 61.1%,模型的参数量和计算量为 2.00 M 和 5.7 G。与各类对比方法相比,具有如下特点:

1) 相较基础 YOLO 系列与传统检测模型

精度方面:改进 YOLO11n 的 $mAP@0.5$ 为 85.7%,较最优基线 YOLOv8n(82.6%)提升 3.1%,较原始 YOLO11n(81.7%)提升 4.0%; $mAP@0.5:0.95$ 为 61.1%,较 YOLOv8n(57.5%)和 YOLO11n(55.5%)分别提升 3.6 和 5.6%。 P 达 91.3%,为所有基础模型中最高(次优 YOLOv8n 为 84.7%)。

效率方面:改进 YOLO11n 的 Params 为 2.00 M,相较原 YOLO11n(2.58 M)减少 22.5%,FLOPs 为 5.7 G,相较原 YOLO11n(6.3 G)降低 9.5%,为表 3 中所有模型中最低。尽管 YOLOv9t 的 Params 略低(1.73 M),但其 $mAP@0.5:0.95$ 仅为 53.2%,远低于本文方法的 61.1%。传统模型 SSD 与 Faster R-CNN 的 $mAP@0.5$ 分别为 73.8% 和 76.2%,落后本文方法 11.9% 和 9.5%,同时 FLOPs 高达 88.3 和 105.2 G,是本文方法的 15.5 倍和 18.5 倍,难以满足无人机端实时检测需求。

2) 相较代表性改进 YOLO 模型

与 I-YOLOv8n 相比:I-YOLOv8n 在本数据集上的 $mAP@0.5$ 为 83.0%, $mAP@0.5:0.95$ 为 58.5%,在保持较低的 Params(2.10 M)和 FLOPs(5.4 G)的前提下较 YOLOv8n 有明显提升。但本文改进的 YOLO11n 在 $mAP@0.5$ 和 $mAP@0.5:0.95$ 上依然分别高出 2.7% 和 2.6%, P 也提升 4%,同时 FLOPs 仅略高于 I-YOLOv8n,整体在精度-效率权衡上更为优越。

表 3 常见算法性能比较

Table 3 Performance comparison of common algorithms

模型	$P/\%$	$R/\%$	$mAP@0.5/\%$	$mAP@0.5:0.95/\%$	Params/M	FLOPs/G
SSD	75.2	69.5	73.8	42.1	22.67	88.3
Faster R-CNN	78.5	71.3	76.2	45.6	41.43	105.2
YOLOv6n	72.8	60.8	68.4	38.8	4.16	11.5
YOLOv8n	84.7	78.8	82.6	57.5	2.69	6.8
YOLOv9t	81.4	78.3	81.6	53.2	1.73	6.4
YOLOv10n	75.9	77.1	79.9	51.4	2.27	6.5
YOLO11n	83.2	77.2	81.7	55.5	2.58	6.3
I-YOLOv8n	88.0	77.0	83.0	58.5	2.10	5.4
O-YOLO11	88.5	80.0	86.9	60.0	2.20	6.0
SNMSDA-YOLO11	89.0	78.5	84.5	58.0	2.30	5.9
改进的 YOLO11n	91.3	79.8	85.7	61.1	2.00	5.7

与 O-YOLO11 相比: O-YOLO11 引入 ADown、EdgeAttention 与 DSM 后,在本数据集上 $mAP@0.5$ 为 86.9%, $mAP@0.5:0.95$ 为 60.0%,对难检小缺陷类别的召回率有所提升,但模型 Params 和 FLOPs 分别为 2.20 M 和 6.0 G。本文方法在 $mAP@0.5:0.95$ 上略优(61.1%),同时参数量和 FLOPs 均低于 O-YOLO11,说明本文在下采样与注意力改进的基础上,还额外兼顾了模型轻量化设计。

与 SNMSDA-YOLO11 相比: SNMSDA-YOLO11 通过多尺度空洞注意力与 SlimNeck 在本数据集上取得了 84.5%的 $mAP@0.5$ 和 58.0%的 $mAP@0.5:0.95$ 。但本文改进的 YOLO11n 在 P 和两项 mAP 指标上均有 1.2%~3.1%的提升,且 Params 与 FLOPs 进一步降低,说明在保持实时性的基础上,本文方法对复杂背景与多尺度弱小缺陷的表征能力更强。

综合来看,本文提出的改进 YOLO11n 模型在风机叶片表面缺陷检测任务中,同时优于基础 YOLO 系列模型和多种代表性改进 YOLO 模型,在检测精度、模型轻量化和推理效率之间实现了更为理想的综合平衡,更适合部署在无人机等计算资源受限的实际工程场景中。

4.4 可视化结果分析

为更加直观地展示各检测算法在不同缺陷类别上的表现,本文从测试集中选取了包含 burning、crack、deformity、dirt、oil、peeling、rusty 七类典型风机叶片缺陷的图片样例,对 YOLOv8n、YOLO11n、I-YOLOv8n、O-YOLO11、SNMSDA-YOLO11 以及本文改进 YOLO11n 的检测结果进行逐类对比,可视化如图 11 所示。图中每一列对应一种缺陷类别,每一行对应一种检测算法,便于在相同场景下比较不同方法的检测差异。

从图 11 可以看出,各算法在不同类别缺陷上的检测性能存在明显差异。

1)YOLOv8n 与 YOLO11n 的表现

YOLOv8n 作为当前应用广泛的 YOLO 系列代表,在

burning、oil 等较为显著的缺陷类别上能够给出较完整的检测框,但在 crack、peeling 等细长或密集小目标场景中,存在部分框偏移、漏检和重复检测现象。YOLO11n 在小目标检测方面相对 YOLOv8n 有一定改进,例如在 crack 和 deformity 场景中能检测出更多细小裂纹和变形区域,但在 dirt、rusty 等背景纹理复杂或对比度较低的缺陷上,仍可见到漏检和错误分类,部分检测框与真实缺陷边缘贴合度不高。

2)代表性改进 YOLO 模型的表现

I-YOLOv8n 得益于轻量化骨干和多尺度特征融合结构,相比 YOLOv8n 在 crack、peeling 等细粒度缺陷上的检出率有所提升,误检数量有所减少,检测框更贴近缺陷边界。但在 burning 与 rusty 等光照不均或表面纹理复杂的场景中,仍存在少量漏检和置信度偏低的问题。

O-YOLO11 结合 ADown 与 EdgeAttention,在 crack、peeling 场景中对细长裂纹和翼缘边缘缺陷的检测较为敏感,检出的小目标数量多于 YOLOv8n 和 YOLO11n;但在 dirt、rusty 场景中,由于背景纹理复杂,偶尔会将非缺陷纹理误判为缺陷,表现为“伪缺陷框”,整体误检率略高。

SNMSDA-YOLO11 通过多尺度空洞注意力增强了对 deformity、oil 等中大尺度缺陷的响应,在这些类别中检测框较为稳定、完整;但在 dirt、peeling 等大量细小目标并存的场景中,仍会出现漏检部分小目标或将相邻小目标合并为单一检测框的情况,对极小缺陷的区分能力有待提高。

3)本文改进 YOLO11n 模型的优势表现

与上述方法相比,本文提出的改进 YOLO11n 在各类缺陷上的检测结果更为稳定、准确,主要体现在:

(1)小目标与细长裂纹检测更完整:在 crack、peeling 场景中,依托 ADown 渐进式下采样对边缘和纹理信息的保留以及 MAFPN 对多尺度特征的强化,本文模型能较好地覆盖裂纹和剥落的整体形态,检测框连续、数量合理,明显减少了裂纹被分段或端部漏检的情况。




图 11 不同算法检测可视化对比

Fig. 11 Visualization comparison of detection by different algorithms

(2)复杂光照和弱对比度场景下误检更少:在 burning、dirt、rusty 等受强光、阴影和背景纹理影响较大的场景中,MLCA 有效抑制了高光、阴影边界和非缺陷纹理的无效响应,使检测框集中于真实缺陷区域,背景区域几乎无多余框,相比 O-YOLO11、YOLOv8n 的“虚警框”显著减少。

(3)多类别、多尺度缺陷的兼顾能力更强:在 deformity、oil 等同时包含大型损伤和周围小缺陷的图像中,本文模型能够同时检出大面积变形/油污区域和局部小缺陷,且各类目标定位精度较高;相较 SNMSDA-YOLO11 将部分相邻小目标合并的情况,本文模型在目标划分上更加细致。

综上,通过图 11 中对 7 类典型缺陷的可视化对比可以看出,本文改进 YOLO11n 模型在复杂光照、纹理干扰和多尺度目标并存等典型无人机巡检场景下,较 YOLOv8n、YOLO11n 以及 I-YOLOv8n、O-YOLO11、SNMSDA-YOLO11 等代表性改进 YOLO 模型表现出更低的误检率、更完整的小缺陷检测以及更准确的多类别定位。结合表 3 的定量评估结果,本文方法在保证模型轻量化和推理效率的前提下,有效提升了风机叶片表面缺陷检测的综合性能,更适合集成到实际风电场的无人机巡检系统中。

5 结 论

本文针对风机叶片缺陷检测中因无人机拍摄角度多变、光照条件复杂导致的缺陷特征丢失与定位困难问题,基于 YOLO11 提出三级协同优化的改进模型:在骨干中引入 MLCA 实现自适应特征聚焦,采用 ADown 渐进式下采样以降低细节损失,并以 MAFPN 替代原有融合骨架以强化多尺度语义表达。在真实巡检场景数据集上开展对比与消融实验,评估模型的精度、定位与部署效率。

本研究利用无人机拍摄的实际风电叶片图片数据集进行实验,实验结果表明,改进后的模型在精度提升、资源压缩、泛化性增强 3 方面达成平衡,为工业场景下轻量化高精度视觉检测系统提供了有效解决方案:mAP@0.5:0.95 提升 5.6%(由 55.5%提升至 61.1%),显著降低复杂场景下的漏检与误检率;参数量减少 22.5%(由 2.58 M 减少至 2.00 M),GFLOPs 降低 9.5%(由 6.3 降低至 5.7),适用于无人机边缘设备部署;MLCA 增强了对光照/角度干扰的适应性,ADown+MAFPN 保障了多尺度缺陷的稳定检出。与多种代表性改进 YOLO 模型(包括 I-YOLOv8n、O-YOLO11、SNMSDA-YOLO11 等)在同一数据集上的对比结果进一步表明,本文协同设计的 MLCA+

ADown+MAFPN 框架在 mAP 与 FLOPs 上取得了更优的精度-效率折中,体现出较强的综合优势和工程应用价值。

虽然改进后的算法相较于原算法的性能有所提升,但是由于无人机采集的叶片缺陷数据集数量相对较少,对各种天气情况和光照条件的检测应用仍存在局限。当前模型在极端天气(浓雾/强降雨)样本上的泛化性仍受限,现有数据未充分包含恶劣天气条件样本。在未来的工作中,需要继续扩充数据集,构建多气候缺陷数据集,覆盖雨、雾、雪等场景,丰富数据集中风电叶片缺陷的种类和数量,以满足实际应用需求。

参考文献

- [1] 张城玮. 基于机器视觉的风机叶片损伤检测系统研究[D]. 哈尔滨:东北农业大学,2025.
ZHANG C W. Research on a machine-vision-based wind-turbine blade damage detection system [D]. Harbin: Northeast Agricultural University, 2025.
- [2] 刘奇. 无人机在风电巡检的应用[J]. 电子元器件与信息技术, 2020, 4(11): 76-77.
LIU Q. Application of UAV in wind-power patrol inspection[J]. Electronic Components & Information Technology, 2020, 4(11): 76-77.
- [3] 宋晔, 吴一全. 基于无人机航拍的风力发电机叶片表面缺陷检测综述[J]. 仪器仪表学报, 2024, 45(10): 1-25.
SONG Y, WU Y Q. Review of surface defect detection of wind turbine blades based on UAV aerial photography[J]. Chinese Journal of Scientific Instrument, 2024, 45(10): 1-25.
- [4] 令狐进, 郑跃骏. 基于无人机影像的风机叶片缺陷检测[J]. 测绘工程, 2025, 34(5): 52-57.
LINGHU J, ZHENG Y J. Blade-defect detection of wind turbines based on UAV imagery[J]. Surveying & Mapping Engineering, 2025, 34(5): 52-57.
- [5] TAN X G, ZHANG G M. Research on surface defect detection technology of wind turbine blade based on UAV image[J]. Instrumentation, 2022, 9(1): 41-48.
- [6] 张森. 基于深度学习的风机叶片表面缺陷检测算法研究[D]. 杭州:杭州电子科技大学,2025.
ZHANG M. Research on deep-learning-based surface-defect detection algorithms for wind-turbine blades [D]. Hangzhou: Hangzhou Dianzi University, 2025.
- [7] 全卫国, 仪小龙, 李冰, 等. 融合多尺度特征与注意力机制的风机桨叶缺陷检测方法[J]. 电子测量技术, 2022, 45(24): 166-172.
TONG W G, YI X L, LI B, et al. Fan-blade defect detection method combining multi-scale features and attention mechanism [J]. Electronic Measurement Technology, 2022, 45(24): 166-172.
- [8] 付军军, 陈林, 童华敏, 等. 基于改进 EfficientNet 的海上风机叶片早期缺陷检测及分类[J]. 电子测量技术, 2024, 47(16): 110-119.
FU J J, CHEN L, TONG H M, et al. Early defect detection and classification of offshore wind turbine blades based on improved EfficientNet[J]. Electronic Measurement Technology, 2024, 47(16): 110-119.
- [9] GUO J H, LIU C, CAO J F, et al. Damage identification of wind turbine blades with deep convolutional neural networks[J]. Renewable Energy, 2021, 174: 122-133.
- [10] ZHANG J J, COSMA G, WATKINS J. Image-enhanced mask R-CNN: A deep learning pipeline with new evaluation measures for wind turbine blade defect detection and classification[J]. Journal of Imaging, 2021, 7(3): 46.
- [11] 李大华, 吴超强, 高强, 等. 改进 YOLOv8n 的风机桨叶表面缺陷轻量化检测网络[J]. 电子测量与仪器学报, 2025, 39(8): 145-155.
LI D H, WU C Q, GAO Q, et al. Improved YOLOv8n lightweight detection network for wind turbine blade surface defects[J]. Journal of Electronics Measurement and Instrumentation, 2025, 39(8): 145-155.
- [12] 张泽辰, 姚顺春, 梁晓俊, 等. 基于小目标感知增强的风机叶片缺陷智能检测[J]. 仪器仪表学报, 2025, 46(9): 159-172.
ZHANG Z C, YAO S C, LIANG X J, et al. Wind turbine blade intelligent defect detection based on small object perception enhancement [J]. Chinese Journal of Scientific Instrument, 2025, 46(9): 159-172.
- [13] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2016: 779-788.
- [14] KHANAM R, HUSSAIN M. YOLOv11: An overview of the key architectural enhancements[J]. ArXiv preprint arXiv:2410.17725, 2024.
- [15] 孙斌. 基于改进 YOLOv11 的风机叶片与光伏板缺陷检测[J]. 中国新技术新产品, 2025(10): 11-14.
SUN B. Defect detection of wind-turbine blades and photovoltaic panels based on improved YOLOv11[J]. China New Technology & New Products, 2025(10): 11-14.
- [16] LIU C X, LIU N, ZHUANG X F, et al. Optimized YOLO11 for accurate wind turbine blade defect detection[C]//2025 International Joint Conference on

- Neural Networks(IJCNN), 2025:1-8.
- [17] XU W J, YAO J C, WANG Y X, et al. Wind turbine blade damage identification using lightweight YOLO11 with multi-scale dilated attention[J]. Applied Soft Computing, 2025, 185: 114042.
- [18] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2016: 2818-2826.
- [19] WANG C Y, LIAO H Y, WU Y H, et al. CSPNet: A new backbone that can enhance learning capability of CNN[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2020:1571-1580.
- [20] GE Z, LIU S T, WANG F, et al. YOLOX: Exceeding YOLO series in 2021[J]. ArXiv preprint arXiv:2107.08430, 2021.
- [21] YARINEZHAD R, SARABI A. MLCA: A multi-level clustering algorithm for routing in wireless sensor networks[J]. Journal of Communication Engineering, 2019, 8(2):249-265.
- [22] WANG C Y, YEH I H, LIAO H Y. YOLOv9: Learning what you want to learn using programmable gradient information [J]. ArXiv preprint arXiv: 2402.13616, 2024.
- [23] YANG Z Q, GUAN Q, ZHAO K, et al. Multi-branch auxiliary fusion YOLO with re-parameterization heterogeneous convolutional for accurate object detection[C]//Chinese Conference on Pattern Recognition and Computer Vision (PRCV), 2024:492-505.
- [24] YANG S Z, WANG W, GAO S, et al. Strawberry ripeness detection based on YOLOv8 algorithm fused with LW-Swin Transformer[J]. Computers and Electronics in Agriculture, 2023, 215: 108360.
- [25] 张晖耀,黄力湘,陈继清,等. 基于改进 YOLOv5s 的草莓成熟度检测算法[J]. 南京农业大学学报, 2025, 48(4):990-999.
- ZHANG H Y, HUANG L X, CHEN J Q, et al. Surface-defect detection algorithm for strawberry maturity based on improved YOLOv5s[J]. Journal of Nanjing Agricultural University, 2025,48(4):990-999.
- [26] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [27] MISRA D, NALAMADA T, ARASANIPALAI A U, et al. Rotate to attend: Convolutional triplet attention module [J]. 2021 IEEE Winter Conference on Applications of Computer Vision, 2021:3138-3147.
- [28] HUANG H J, CHEN Z G, ZOU Y, et al. Channel prior convolutional attention for medical image segmentation[J]. Computers in Biology and Medicine, 2024, 178: 108784.
- [29] LAU K W, PO L M, REHMAN Y A U. Large separable kernel attention: Rethinking the large kernel attention design in CNN [J]. Expert Systems with Applications, 2024, 236: 121352.
- [30] JIANG P T, ZHANG C B, HOU Q B, et al. LayerCAM: Exploring hierarchical class activation maps for localization[J]. IEEE Transactions on Image Processing, 2021, 30: 5875-5888.

作者简介

李松霖,硕士研究生,主要研究方向为目标检测、图像处理。

E-mail:2773161651@bupt.edu.cn

唐玲(通信作者),高级工程师,硕士,硕士研究生导师,主要研究方向为机器人智能导航与控制、机器人动力学、目标检测。

E-mail:tangling@bupt.edu.cn