

Spatial-FineDef: 融合多尺度感知与自适应增强的 风电机组叶片小缺陷检测方法

年嘉伟^{1,2}, 王梓懿¹, 唐灵犀¹, 房方^{1,2*}

(1. 新能源电力系统全国重点实验室(华北电力大学), 北京 102206; 2. 华北电力大学控制与计算机工程学院, 北京 102206)

摘要: 风电机组叶片是实现风能捕获与机械能转换的关键气动结构部件, 其表面缺陷(如裂纹、侵蚀和脱胶)会影响叶片的气动性能进而降低机组的发电功率。实际风场巡检场景中, 叶片表面缺陷通常存在缺陷微小、对比度低、纹理弱等特点, 同时伴随复杂背景、光照变化和噪声侵蚀的干扰, 使得目前的端到端检测方法在风电机组叶片小尺度缺陷检测任务中存在明显的性能受限问题。尽管实验室环境中的基准测试已取得超过99%的定位精度, 但在实际场景中的复杂背景和小缺陷的影响下, 定位与识别任务相耦合, 降低了这类方法的检测精度。针对上述问题, 本文提出一种融合多尺度感知与自适应增强的混合式两阶段检测方法 Spatial-FineDef (Spatial-Fine Defect detection approach), 通过解耦缺陷定位与精细判别过程, 将缺陷候选区域提取与缺陷类别分类分阶段优化, 提升了 Spatial-FineDef 在面对复杂背景和小缺陷问题时的检测精度。第一阶段, 目标空间提取模块 (Spatial-Net) 通过结合定制化数据增强策略与定位增强方法提升了缺陷候选区域筛选的效率。第二阶段, 精细化缺陷判别模块 (FineDef-Net) 在候选区域使用 ConvNext 主干结合轻量化多尺度注意力机制, 在保持较低计算复杂度的前提下强化了精准区分不同缺陷的能力。相较于端到端式的故障检测方法, 通过“先定位、后判别”的两阶段处理策略, Spatial-FineDef 在抑制背景干扰的同时, 实现了小缺陷区域的稳定筛选与精确类别判别。在现场采集的多缺陷风电机组叶片数据集中, Spatial-FineDef 在麻面、涂层脱落、边缘开裂和表面裂纹四类缺陷检测任务中取得96.71%的整体准确率, 并在多项指标上优于多种代表性基线模型。同时, 消融实验验证了两阶段解耦策略与多尺度线性注意力模块在复杂背景下小缺陷检测的有效性。实验结果表明, 本文提出的方法为风电机组叶片现场检测提供了一种可部署的技术方案, 提升实时故障检测能力, 并促进风电机组的可靠性及智能运维。

关键词: 风电机组叶片; 缺陷检测; 端到端监测; 多尺度感知; 自适应增强

基金项目: 国家重点研发计划 (No.2025YFF0515900)

中图分类号: TP391.41; TK83

文献标识码: A

文章编号: 0372-2112(2026)02-0785-14

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250999

Spatial-FineDef: An Approach for Detecting Small Defects in Wind Turbine Blades that Integrate Multi-Scale Perception and Adaptive Enhancement

NIAN Jiawei^{1,2}, WANG Ziyi¹, TANG Lingxi¹, FANG Fang^{1,2*}

(1. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources (North China Electric Power University), Beijing 102206, China; 2. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: Wind turbine blades are the core aerodynamic components responsible for wind energy capture and energy conversion in the wind turbine systems. Surface defects such as cracks, erosion, and delamination can deteriorate aerodynamic performance and consequently reduce power generation efficiency. In real-world wind farm inspection scenarios, blade surface detection is typically characterized with small scales and low contrast, and are often accompanied by complex backgrounds, illumination variation, and imaging noise. These challenges significantly limit the performance of existing end-to-end detection methods exhibit in small-scale defect detection tasks for wind turbine blades. Although the benchmark evaluations under laboratory conditions have achieved localization accuracies exceeding 99%, the strong coupling between localization and classification under strong background interference and micro-cracks makes these methods can hardly be further improved. To overcome these challenges, we propose Spatial-FineDef (Spatial-Fine Defect Detection Approach), a hybrid two-stage detection method incorporating multi-scale perception and adaptive enhancement. Through explicitly de-

coupling defect localization from fine-grained classification, the proposed method optimizes candidate region extraction and defect recognition in a staged manner. In the first stage, Spatial-Net incorporates task-oriented data augmentation strategy and improved localization methods to enhance the accuracy of spatial filtering for potential defects. In the second stage, FineDef-Net utilizes ConvNext backbone with lightweight multi-scale linear attention mechanism which enhances the discrimination capability while maintaining low computational complexity. Compared with end-to-end detection methods, by adopting a two-stage strategy of localization followed by classification, Spatial-FineDef effectively suppresses background interference while enabling stable region selection and defect classification for small-scale defects. On a field-collected wind turbine blade fault dataset, Spatial-FineDef achieves an overall accuracy of 96.71% in the classification of four small-scale defect types including surface pitting, coating shedding, edge cracking, and surface cracking. Experimental results demonstrate outperforming multiple representative baseline models across several evaluation metrics. Ablation studies further validate the effectiveness of the decoupled two-stage strategy and the multi-scale linear attention mechanism in handling small defects under complex backgrounds. The proposed method provides a deployable and reliable solution for on-site blade inspection, facilitating real-time fault diagnosis and enhancing the reliability and intelligent operation and maintenance of wind turbine systems.

Keywords: wind turbine blade; defect detection; end-to-end; multi-scale perception; adaptive enhancement

Foundation Item(s): National Key Research and Development Program of China (No.2025YFF0515900)

0 引言

作为风能转换系统最重要的气动和承载组件,风电机组叶片(Wind Turbine Blade, WTB)的表面缺陷(裂纹、侵蚀及脱胶)会导致翼型气动特性和压力分布的变化,进而影响气动性能造成发电量损失^[1],并且在某些情况下还会演化成结构性损伤,甚至导致叶片折断或者脱落,进而发生安全事故,增大运维费用并引起非计划性停机^[2-4]。随着高比例可再生能源接入的新型电力系统快速发展,系统全局层面的抗干扰能力与稳定裕度指标被显著削弱。风电机组作为该系统架构中具备关键支撑作用的组成单元,其运行过程中的可靠性波动问题对系统整体安全运行状态的影响越发显著^[5]。因此,对风电机组自身运行可靠性水平的提升,以及对覆盖全生命周期的故障监测与诊断机制的系统性构建,对保障风电场运营安全、维持稳定运行状态具有重要工程价值^[6]。

近年来,伴随着人工智能的发展,机器视觉领域中的目标检测技术被广泛应用于工业缺陷检测中,在提高设备可靠性和监测效率等方面取得了良好的应用效果^[7]。Stokkeland等人^[8]提出一种基于无人机的自主机器视觉技术,采用霍夫线变换的方法对WTB进行识别,并且使用卡尔曼滤波器来进行追踪。在风电机组叶片裂纹自动化检测领域中,Wang等人^[9]提出一种基于无人机图片WTB裂纹自动化检测方法,在此过程中引入扩展Haar-like特征以及级联分类器提高检测的准确性和速度。Deng等人^[10]提出了一种融合改进粒子群优化算法与Log-Gabor滤波算子的WTB表面缺陷检测方案。该方案有效解决了传统算法在参数寻优过程中易陷入局部最优解的技术瓶颈,

提升了缺陷检测的准确性与处理效率。然而,受限于机器学习技术自身固有的局限性,上述基于机器学习的检测方法,在复杂背景环境下的泛化能力与抗干扰性能均存在明显局限。

随着深度学习网络的发展,机器学习方法的局限性已得到缓解。近年来,深度学习与计算机视觉的交叉耦合,正成为WTB表面损伤诊断研究的主流策略^[11]。Ran等人^[6]在YOLOv5s的基础上通过加权特征融合机制的嵌入、坐标注意力模块的整合及损失函数的重构,实现了WTB微小缺陷检测性能的提升。Zhou^[12]提出一种新的YOLO-NL检测模型,并通过引入全局动态标签分配策略及优化网络结构,增强了对多尺度对象在复杂场景中的检测能力和鲁棒性。Hang等人^[13]通过提出MIP-YOLO来解决传统YOLO对于风力发电机叶片裂纹边缘特征提取能力弱的问题,并且结合分类、检测和分割的功能大大提高了对裂缝的识别率以及损伤程度的判定水平。Ye等人^[14]在保持YOLOv5s骨干基础上引入动态卷积、检测头与轻量高效卷积技术,提高了准确率,但该方法的高精度建立在大量标注数据与复杂网络模型的前提下,在实际部署时存在困难。Ma等人^[15]提出的轻量化MES-YOLOv8n,利用多核分组卷积跨特征融合的C2f模块、通道注意力机制和SBiFPN,提升了检测小缺陷的能力。但当标注数据受限或环境算力不足时,其检测性能和工程可行性均受到明显制约。Liu等人^[16]则通过优化特征提取与多源数据融合,提升了模型的鲁棒性。尽管已有研究尝试通过改进网络结构提升模型性能,但部分方法依赖于复杂的网络设计,这种复杂的网络难以在风电机组现场实现部署。

蒋兴群等人^[17]提出一种改进的YOLOv3模型,为了模拟现场场景采用亮度变换、镜像旋转等数据扩充手段,将输入图像由1 774幅扩充到5 650幅,在样本数量有限的情况下提升模型的鲁棒性。为了减弱拍摄距离和焦距变化对缺陷尺寸的影响,Guo等人^[18]对图像进行多比例缩放,并在不同尺度下提取局部patch进行训练,使模型能够适应缺陷尺寸的变化,提高检测结果的稳定性。He等人^[19]通过仿射变换、图像滤波和噪声注入等数据增强手段扩充训练样本,提升模型面对不同背景与气象条件下的表现。大规模数据会带来标注成本上升的问题,研究者在模型训练中引入迁移学习方法,以缓解海量样本标注的困难,并进一步提升模型的鲁棒性与泛化能力^[20]。迁移学习是指将一个模型从源任务上获得的知识迁移到目标任务上,以解决目标任务上的训练样本不足或者标注昂贵的问题^[21]。Wang等人^[22]利用迁移学习与DeepLabv3+编码器-解码器架构,对有限元分析得到的图片进行分割,实现了智能故障诊断。Na等人^[23]提出一种用于轨道电路故障预测的异构迁移学习网络,在得到较高精度检测效果的同时,将所需的样本量降低了10%。普智勇等人^[24]少量样本情况下建立EfficientNet-b0-TL迁移学习模型进行风力发电机主轴的缺陷分类,达到较好的分类效果。Yang等人^[25]提出一种将迁移学习与随机森林集成分类器相结合的深度学习方法,在进行图像分割的同时完成对风力涡轮机叶片损伤的检测,较好地处理了复杂背景中检测叶片损伤的问题。Liu等人^[26]提出基于YOLOv5的轻量化多类叶片缺陷检测算法,基于结构裁剪、特征融合增强以及模型重参数化的改进策略提升检测准确性和效率,在UAV拍摄图像上取得较好的多类别小目标缺陷检测效果,是一种可部署的叶片在线巡检方案。Liu等人^[27]提出GFD-YOLOX,使用DFB-BIFPN加强跨尺度特征融合,并引入HFAF模块整合频域与空间域信息,在公开与自建数据集中面对小尺度裂纹、点蚀等缺陷上效果突出。

与传统目标检测任务相比,风电机组叶片(WTB)缺陷检测在真实风场环境中面临更加突出的精度瓶颈。尽管已有研究通过多尺度特征融合、注意力机制或特征增强等手段在一定程度上提升了小目标检测性能,但在实际巡检场景中仍存在明显不足,主要体现在以下三个方面:(1)微小且对比度低的缺陷难以有效表征,如裂纹、点蚀等缺陷通常尺度极小、纹理微弱,易受到复杂背景、光照反射及成像噪声的干扰而被淹没,导致模型难以提取稳定的判别特征;(2)样本不平衡与伪缺陷干扰问题突出,污渍、反光和涂层纹理等伪缺陷在视觉上与真实缺陷高度相似,在真实

缺陷样本数量有限的情况下,现有端到端模型容易产生误判,影响检测可靠性;(3)单阶段检测方法在精细识别层面存在结构性瓶颈,定位与识别任务耦合在同一检测头中,当定位性能趋于饱和后,整体精度往往受限于弱纹理、小尺度缺陷的精细判别能力,单纯增加网络复杂度难以进一步突破性能上限。

近年来,为克服单阶段检测在小目标和弱特征条件下定位与识别高度耦合、性能提升受限的问题,出现了一类粗到细(coarse-to-fine)的两阶段检测方法,通过将候选区域提取与精细识别解耦,使模型在保持较高推理效率的同时,获得更强的小目标表征能力^[28]。现有研究主要从以下几个方向展开:(1)候选区域质量的提升,例如,Yuan等人^[29]提出的CFINet通过coarse-to-fine RPN级联回归生成高质量候选框,有效缓解了小目标特征表达不足的问题;(2)从粗粒度再到细粒度区域的约束与重建,Ali Shah等人^[30]提出的TASAD采用两阶段异常分割策略,先获得粗粒度缺陷区域,再在候选区域内进行精细分割与边界修复,从而提升微小异常的检出率;(3)全局与局部特征的分阶段建模,Liang等人^[31]提出的ToCoAD在两阶段对比学习中,先获取全局粗粒度表征,然后在高疑似区域加入细粒度约束来增强其在少样本缺陷检测场景下良好的泛化性能。从方法关联性角度看,上述工作均证明两阶段结构在小目标与弱特征任务中的有效性,然而其侧重点主要是针对候选框精度、特征融合或是增加判别约束方面,多数端到端检测方法假设定位精度的提升能够自然促进识别性能的增强,但在共享特征空间的条件下,定位与识别任务在优化目标和特征需求上的差异可能引发潜在冲突,这一问题在现有研究中尚未得到充分关注。

针对风电机组叶片小缺陷检测的上述难题,本文提出一种融合多尺度感知与自适应增强的混合式两阶段检测方法——Spatial-FineDef,该方法将定位和识别解耦,提升了对叶片小缺陷故障的可分辨性。该方法的第一阶段是目标空间提取(Spatial-Net)部分,通过数据增强和目标定位策略,使模型能够在复杂背景和噪声干扰条件下,仍然高效准确地提取出风电机组叶片上的候选区域;第二阶段是精细化缺陷判别模块(FineDef-Net),利用ConvNeXt主干网络与多尺度线性注意力机制对候选区域进一步分析,提升对细粒度缺陷的判别能力。其次,考虑到在风场真实环境中光照以及天气状况变化的影响,本文提出了一个自适应的数据增强方法来提升模型对于现场复杂环境的鲁棒性。

基于上述设计,本文在提升小缺陷分辨能力的前提下,还兼顾了模型的计算成本与可部署要求,使

Spatial-FineDef 方法能够在真实风场环境中具备更好的稳定性。本文的主要贡献概括如下:(1)提出了一种解耦“定位—识别”的两阶段检测方法 Spatial-FineDef,该方法将缺陷定位与精细识别过程解耦,使模型可分别针对定位准确性与识别判别性进行优化,在小尺度、弱纹理缺陷场景下缓解端到端检测方法中定位与识别难以兼顾的问题;(2)针对复杂背景条件下叶片区域易受干扰的问题,设计了一种多尺度空间增强的 Spatial-Net,该模块通过在不同尺度下建模叶片结构特征,并合理引入周围空间信息,引导模型在多样成像条件下更加稳定地聚焦于叶片本体区域,降低复杂风场背景对定位结果的影响;(3)设计了一种轻量化的 FineDef-Net 用于细粒度缺陷识别,该模块以 ConvNeXt 为主干,并结合多尺度线性注意力机制,在平衡计算成本与检测精度的前提下增强对弱纹理缺陷特征的区分能力,使其更符合风电巡检场景下的实际部署需求。

1 方法构建

1.1 设计动机

在风电机组叶片缺陷检测领域,基于深度学习的目标检测方法已经得到了广泛应用,现有研究主要通过检测器结构优化与模型设计改进来提升检测性能。然而实际场景中,叶片缺陷存在尺度小、纹理弱等特征,传统单阶段端到端检测方法在此场景下的性能提升已呈现明显的边际递减趋势。为了增强对微小缺陷的感知能力,现有方法往往依赖更复杂的模型设计或特征融合策略,这在一定程度上提高了模型的表达能力,但也同时增加了模型复杂度。考虑到风机叶片诊断系统部署在如机舱、塔筒固定摄像系统和无人机巡检平台这些存在算力与时延受限的边缘平台,单纯依靠堆叠复杂模型来换取有限精度的提升,难以在检测性能提升与工程可部署目标之间取得有效平衡。

通过拆解任务,风电机组叶片缺陷包含两个关键环节:缺陷区域的定位与缺陷类别的识别,其主要挑战体现在以下几个方面:(1)定位阶段,现有模型通常能够较好地覆盖微小裂纹、点蚀及低对比度腐蚀等缺陷的实际位置;(2)识别阶段,由于微小缺陷与背景在外观形态和纹理特征上的高度相似性,候选区域仍易与污渍、反光及涂层纹理等伪缺陷混淆;(3)在复杂成像条件下,风力发电机组叶片的不同姿态以及不同角度、光线下的镜面反射效应,造成同一类图像具有较大的视觉差异性,加剧了虚假缺陷噪声对分类器训练的影响,最后体现为识别过程中的错检率、漏检率增加。

上述分析表明,当前风电机组叶片缺陷检测的性

能瓶颈主要不源于候选区域的定位阶段,而是更集中体现在后续的识别与判定阶段。然而,现有多数端到端检测框架并未显式区分定位与识别环节中的能力约束,其优化策略仍主要围绕整体检测流程展开,缺乏针对识别阶段判别困难的专门建模机制。基于此,本文从任务分解与能力瓶颈分析的角度出发,重新审视风电机组叶片缺陷检测中定位与识别环节的作用边界,并在后续章节中通过系统实验分析对上述推断进行验证。相关定量结果与对比分析统一在 3.2 节设计动机的实验分析中给出。

1.2 Spatial-FineDef 整体框架

为了降低风电机组叶片缺陷识别任务中存在的漏检风险,我们提出了一种混合式两阶段检测方法,该方法被解耦为定位与识别的两阶段流程,并被命名为 Spatial-FineDef。整个方法由目标空间提取模块(Spatial-Net)和精细化缺陷判别模块(FineDef-Net)两个核心部分构成,如图 1 所示。目标空间提取模块整合了轻量级单阶段检测器、定制化数据增强策略以及叶片定位网络,致力于在复杂背景与成像噪声的干扰下,快速且精准地提取风机机组叶片的候选区域。精细化缺陷判别单元则融合 ConvNeXt 及多尺度线性注意力机制以实现细粒度缺陷的判别。利用深度可分离卷积、层归一化以及自适应注意力机制提高了模型的跨通道表征能力,在效率、精度和可部署性之间取得了较好的折中效果,并提供了风电机组叶片小缺陷检测的一个实用方案。1.3 节~1.5 节对 Spatial-FineDef 方法进行了详细的介绍。

1.3 目标空间提取模块(Spatial-Net)

对于风电机组叶片缺陷检测任务而言,鉴于小目标以及低对比度的问题,尤其是裂纹、腐蚀等微小缺陷,在复杂背景下往往具有尺度小、纹理弱的特点,从图像上难以被察觉。因此,传统的基于目标检测的方法对上述小目标及低对比度的缺陷检测困难。针对上述问题,本文提出了一个面向风电机组叶片缺陷检测任务的目标空间提取模块(Spatial-Net),通过解耦定位和识别过程来定位出风电机组叶片图像中的缺陷部位,以支撑后续的细粒度缺陷判别任务。如图 2 所示,Spatial-Net 模块主要由两部分构成:数据增强和缺陷定位。

针对风电机组叶片表面缺陷的特点,传统图像处理方法中的一些常用算法,如基于颜色特征分割的方法及直方图方法,在一些场景中有一定的作用,但是这些方法大多具有过度依赖人工设计的特征以及预处理过程的问题,不能很好地满足风电机组叶片在特殊场景中的多样性和复杂性。针对风电机组叶片表面故障样本数量有限、场景多样性不足的问题,本文

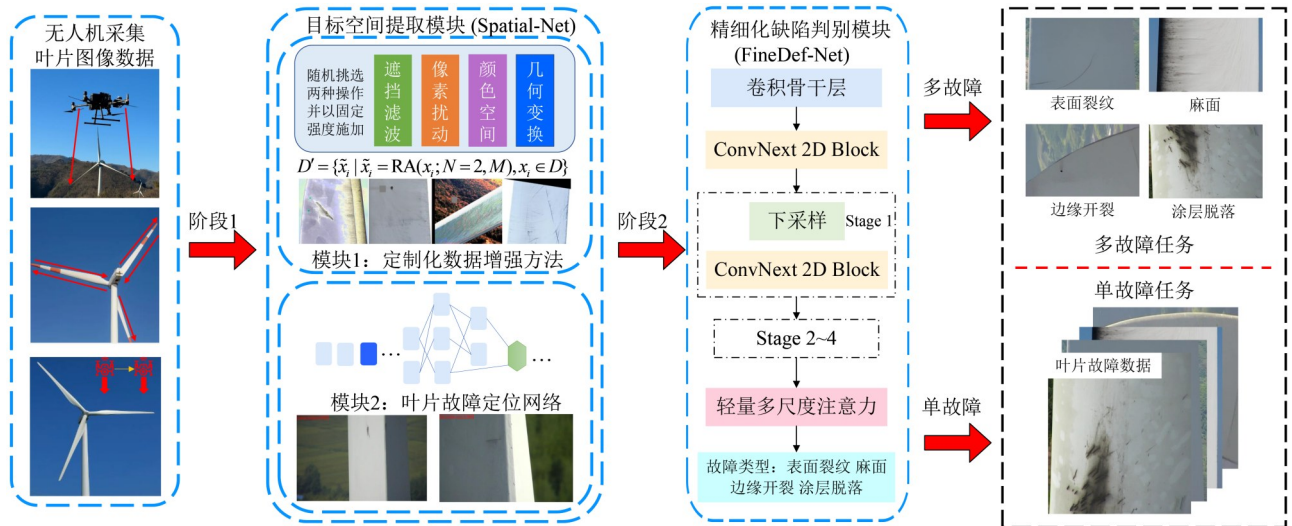


图1 Spatial-FineDef的框架图

Figure 1 The framework of Spatial-FineDef

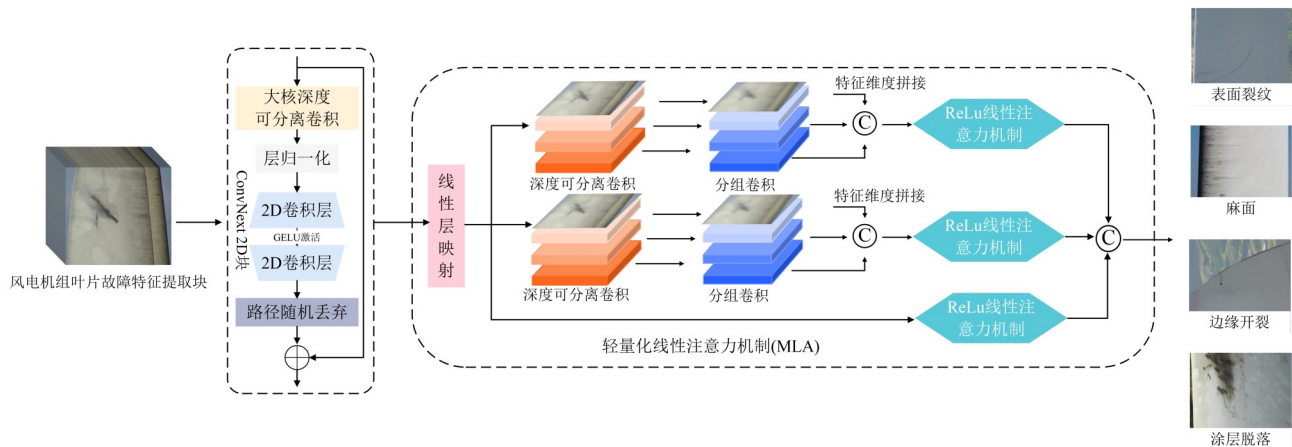


图2 FineDef-Net的结构示意图

Figure 2 The framework of FineDef-Net

在保持标签语义一致性的前提下,引入了一种面向具体检测任务的数据增强策略。该策略通过对遮挡滤波、像素级扰动、颜色空间变换以及几何形态变换等多种操作进行随机选择与组合应用,实现了具有任务相关性的多维度图像扩展。

首先,设原始训练集为 $D = \{x_i\} (i = 1, 2, \dots, N_0)$, 其中 x_i 表示第 i 张叶片图像。记增强子集为 $T = \{T_1, T_2, T_3, T_4\}$, 其中 T_1 表示遮挡滤波(例如高斯模糊、随机擦除), T_2 表示像素扰动(如噪声添加), T_3 表示颜色空间变换(HSV、亮度对比度变化), T_4 表示几何变换(旋转、剪切、镜像等)。在增强过程中,针对每个样本 x_i , 自适应增强函数 $RA(\cdot)$ 随机挑选两种操作并施加固定强度 $M: x'_i = RA(x_i; N = 2, M)$, 从而得到增强样本集 $D' = \{x'_i | x'_i = RA(x_i; N = 2, M), x_i \in D\}$ 。

该设计在保证样本语义一致性的同时,引入多尺度扰动以增强场景鲁棒性,进而提升模型在复杂条件下的泛化能力,与传统随机增强方法形成区别。在进行数据增强的过程中会依据样本的光照、纹理以及故障特性自适应地调节数据增强的方式,使得数据增强的结果更加符合风电场实际拍摄的情况。比如在高反射率或大风力地区的图片中首先应用遮挡和模糊效果,在低对比度的图片中加入色域抖动来生成更加真实的训练分布。

我们将YOLOv8^[32]作为缺陷定位的主干模型,利用其经过改进的骨干网络来进行多尺度特征提取。YOLOv8通过其高效的卷积网络和改进的自注意力机制,增强了特征的表达能力,并通过锚框机制实现目标定位,在检测过程中不需要区域提议网络(Region Proposal Network, RPN),采用了跨阶段部分结构提高

网络学习能力。具体而言,目标空间提取模块采用轻量级的单阶段检测器,在多尺度感知的基础上进一步针对风电机组叶片的图像特性设计候选框生成机制。它不需要像传统的图像分割那样对原图进行复杂的预处理,而是直接从原图中获取感兴趣的目标信息,实现了整个流程的端到端学习。相较于传统图像分割算法,YOLOv8在定位精度与计算效率之间取得了较好的平衡,适用于复杂背景下的小目标缺陷定位任务。

同时,Spatial-Net的设计也充分考虑到了风电机组叶片缺陷检测的场景特性,在解耦定位和识别的过程中,显著提升了对小目标和弱纹理缺陷的可检测性,在保证流程简洁可复用的前提下,各个模块的高效性使得算法可以在计算资源受限的边缘端(如机舱、塔筒摄像系统、无人机平台)运行,实现实时检测。本模块为后续的精细级缺陷判别提供干净、高质量的感兴趣区域作为输入,并提高了检测精度及系统的鲁棒性,进而有利于推动风电机组叶片缺陷检测任务的实时化、智能化。

1.4 精细化缺陷判别模块(FineDef-Net)

在风电机组叶片图像中,微小裂纹、弱纹理侵蚀与复杂背景反光的共存易引发类别间边界的挤压现象,因而削弱缺陷的准确识别。仅依靠传统通用卷积神经网络主干网络中的局部卷积先验很容易产生边界粘连、细节丢失、尺度不匹配等问题。针对上述问题,为提高风电机组叶片缺陷检测精度,尤其是在复杂背景下的细小缺陷识别方面,我们提出了第二阶段的精细化缺陷识别网络(FineDef-Net)。如图2所示,FineDef-Net模块的核心构成部分包含两个单元,分别是ConvNeXt主干网络和轻量多尺度线性注意力机制。

1.4.1 ConvNeXt主干网络

针对风电机组叶片图像中小目标和复杂背景导致的缺陷识别问题,我们选择ConvNeXt作为主干网络,其涵盖了深度可分离卷积(DepthWise Convolution, DWConv)和层归一化(LN)技术。深度可分离卷积的引入在保持高效性的同时,减少了计算复杂度;而层归一化与GELU激活函数的结合,进一步增强了跨通道特征的表征能力,有效提升了风电机组叶片图像中微小裂纹和弱纹理缺陷的识别精度,具体公式如下:

$$U^{(l)} = \text{DWConv}_{k \times k}(X^{(l)}) \quad (1)$$

$$V^{(l)} = \text{LN}(U^{(l)}) \quad (2)$$

$$H^{(l)} = \text{GELU}(W_1 * V^{(l)} + b_1) \quad (3)$$

$$\tilde{X}^{(l)} = W_2 H^{(l)} + b_2 \quad (4)$$

其中: $X^{(l)}$ 与 $X^{(l+1)}$ 分别表示第 l 层与 $l+1$ 层的输入与输出特征; $\Delta X^{(l)}$ 为残差分支输出;DWConv $_{k \times k}(\cdot)$ 表示

通道内深度卷积(本文采用较大卷积核以增强感受野);LN(\cdot)为层归一化算子; W_1 、 W_2 为逐点线性映射矩阵,分别实现通道升维与降维;GELU(\cdot)表示GELU激活函数。 γ 为可学习的通道缩放系数,其维度与通道数一致, $\gamma \cdot \Delta X^{(l)}$ 表示对残差分支输出进行通道级缩放。

该设计通过在空间维度和通道维度上对特征进行重新组织,辅以非线性变换与残差连接的方法,使特征在网络中能够可靠地传播与迭代。在保证较小运算代价和较高训练稳定性的同时,进一步提升了模型对于风电机组叶片表面细小裂缝与较大范围腐蚀区域的综合表达效果。

在满足前述设计指标的前提下,为更好地体现本文提出的方案在计算量方面的优势,将骨干网络中的深度可分离卷积和普通卷积进行比较以定量评估其轻量化特性。

设输入通道数为 C_{in} ,输出通道数为 C_{out} ,特征图尺寸为 $H \times W$,卷积核大小为 $k \times k$,标准卷积的运算量为

$$\text{FLOPs}_{\text{conv}} = HWC_{in}C_{out}k^2 \quad (5)$$

而深度可分离卷积的运算量可近似表示为

$$\text{FLOPs}_{\text{dwconv}} = HW(C_{in}k^2 + C_{in}C_{out}) \quad (6)$$

当卷积核较大时且 C_{in} 与 C_{out} 量级相近时,深度可分离卷积的计算量远远小于标准卷积,这表明在保证足够感受野的条件下,深度可分离卷积能显著降低参数与计算量,实现更高的能效比。这一特性对风电机组叶片图像的在线识别与边缘部署尤为重要,可在保持检测精度的同时有效减少实时推理的资源开销。

1.4.2 轻量化注意力机制

在风电机组叶片图像识别任务中,表面裂纹与腐蚀区域往往同时存在局部细节差异与全局形态特征,因而需要模型兼顾局部与跨区域的信息融合。在EfficientViT^[33]的思想启发下,设计了一种轻量多尺度线性注意力模块(Multi-scale Linear Attention, MLA),作为对常规Transformer注意力机制的轻量化替代方案,用于实现更高效的空间特征融合。其核心思想是通过多尺度卷积聚合与ReLU核函数近似相结合的方式,在保障强特征交互能力的前提下,有效降低计算复杂度。

输入特征 $X \in R^{C \times H \times W}$ 经过线性化映射生成查询、键和值三组映射:

$$Q = XW_Q, \quad K = XW_K, \quad V = XW_V \quad (7)$$

随后,将三者通道维上拼接并输入多尺度卷积单元。设尺度集合为 $S = \{1, 3, 5\}$,则第 S 尺度的变换可表述为

$$Y^{(s)} = \text{Conv}_{1 \times s}^{\text{group}}(\text{DWConv}_{k \times k} \quad s \in S) \quad (8)$$

$$(\text{Concat}(Q, K, V)),$$

其中: $\text{DWConv}_{k \times k}$ 表示深度卷积操作, 用于在通道内聚合空间上下文; $\text{Conv}_{1 \times s}^{\text{group}}$ 为逐点分组卷积, 用于跨尺度特征压缩与解耦。不同尺度的输出经拼接后形成融合特征:

$$F = \text{Concat}(Y^{(1)}, Y^{(3)}, Y^{(5)}) \quad (9)$$

接着通过 ReLU 激活函数实现线性化注意力映射:

$$\begin{cases} \phi(Q) = \text{ReLU}(Q) \\ \phi(K) = \text{ReLU}(K) \\ O = \phi(Q)(\phi(K)^T V) \end{cases} \quad (10)$$

最后利用线性映射 W_o 对输出通道进行压缩, 并且与输入特征残差连接得到最终输出。

$$X_{\text{out}} = W_o O + X \quad (11)$$

通过引入多尺度卷积, 模型能够同时提取不同尺度的特征信息, 并结合线性注意力机制对这些特征进行加权整合, 因而能够更好地兼顾全局与局部细节。相较于传统 Softmax 注意力, 轻量级多尺度注意力不用对大量的特征进行匹配计算, 大大减少了计算量及显存消耗, 在此基础上加入残差结构可以减轻梯度消失现象并可以在一定程度上提高模型的稳定程度。在实际应用中, 该模块能够在有限计算资源的条件下, 对关键特征进行重点建模, 使模型在复杂背景和气象环境下仍能保持相对稳定的性能。

1.4.3 损失函数与训练策略

在模型训练过程中, 考虑到风电机组叶片表面缺陷图像存在类别分布不均衡及边界样本噪声等问题, 若直接采用标准交叉熵损失, 极易造成模型对少数类样本的识别精度下降和特征学习偏移。为此, 本文在端到端训练阶段引入类别加权的标签平滑交叉熵损失函数, 以兼顾样本类别分布的均衡性与模型预测的稳健性。

训练集中第 i 个样本的真实类别标签为 $y_i \in \{1, 2, \dots, K\}$, 其中 K 表示故障类别总数, 平滑系数为 $\alpha \in [0, 1]$ 用于控制真实标签的分布平滑程度, 则经标签平滑后的目标分布可定义为

$$p'_{i,c} = \begin{cases} 1 - \alpha, & c = y_i \\ \frac{\alpha}{K-1}, & c \neq y_i \end{cases} \quad (12)$$

$$\sum_{c=1}^K p'_{i,c} = 1$$

其中, $p'_{i,c}$ 表示样本 i 对类别 c 的目标概率分布。该平滑机制在真实标签的基础上对非目标类别赋予微小权重, 从而在训练过程中降低过度置信导致的模型振荡与过拟合风险。

综合类别不平衡性因素, 本文进一步引入类别加

权策略, 定义损失函数为

$$\begin{cases} L_{CE} = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^K \omega_c p'_{i,c} \log q_{i,c} \\ \omega_c = \frac{1/n_c}{\sum_{j=1}^K 1/n_j} \end{cases} \quad (13)$$

其中: N 为批次样本数量, $q_{i,c}$ 为样本 i 经 Softmax 变换后在类别 c 上的预测概率, ω_c 为基于训练集类别频次自适应计算的类别权重, n_c 表示第 c 类样本在训练集中出现的数量。

该权重采用反比例归一化形式, 使稀有类别在损失计算中的梯度贡献相对放大, 从而有效缓解类别分布不均带来的训练偏置。通过加权机制, 模型在少样本类别上获得更高的判别灵敏度与特征学习稳定性, 实现了对类别层面样本差异的显式平衡。

1.5 两阶段之间的衔接机制

为了明确第一阶段与第二阶段之间的衔接方式, 本节在整体流程图的基础上, 进一步给出了候选区域提取与细粒度识别过程的伪代码描述(见算法 1), 以系统说明从候选区域生成、区域裁剪到第二阶段网络输入的完整流程, 进而避免两阶段之间数据传递与处理方式的歧义。

如算法 1 所示, 在第一阶段中, Spatial-Net 以原始输入图像 I 为输入, 对潜在缺陷区域进行定位, 通过定位模型 Spatial-Net() 获得候选区域 candidate_regions, 并输出多组候选区域的空间坐标信息 region。随后, 算法根据这些候选区域坐标, 直接在原始图像空间中执行区域裁剪操作 crop_image(), 得到对应的局部图像块 cropped_images。该裁剪过程是基于坐标级的区域选择与尺度对齐, 不涉及特征图级的重映射或跨层特征变换, 从而保证了阶段间信息传递的直接性。

算法 1 Spatial-FineDef 两阶段衔接流程

输入: 原始叶片图像 I

输出: 最终裁剪结果 result

```

1 for  $i \in \{1, 2, 3\}$  do
2    $I_i \leftarrow \Phi$ ; cropped_image  $\leftarrow \Phi$ ;
3   result  $\leftarrow \Phi$ ; cropped_images  $\leftarrow \Phi$ ;
4   候选区域 candidate_regions  $\leftarrow$  Spatial-Net( $I_i$ );
5   for region  $\in$  candidate_regions do
6     cropped_image $_i \leftarrow$  crop_image( $I_i$ , region);
7     cropped_images[i].append(cropped_image $_i$ )
8   result  $\leftarrow$ 
[cropped_images[0], cropped_images[1], ..., cropped_images[i]]

```

裁剪得到的候选区域在完成必要的尺度归一化后形成裁剪结果集合 result, 被逐一送入第二阶段的

FineDef-Net,用于执行更加精细的缺陷识别与判别任务。由于裁剪与对齐过程使得输入区域与FineDef-Net的感受野保持一致,第一阶段所学习到的空间先验信息能够在第二阶段的特征提取与判别过程中被有效继承和利用。

上述补充说明表明,Spatial-Net与FineDef-Net之间通过一种简洁、明确且高度可复现的区域裁剪与对齐流程实现有效衔接。该设计既保证了第一阶段所学习到的空间先验信息能够顺利传递至第二阶段,又有效保持了整体两阶段方法的简洁性与轻量化特性,从而在精度提升与计算效率之间取得了良好的平衡。

2 实验验证

2.1 实验设置与评价

2.1.1 实验设置

本实验数据来自中国龙源电力集团的东岭、北海和云南等风电场,采集内容为风电机组叶片表面图像,用于叶片表面故障分析,涵盖涂层脱落、边缘裂纹、中部裂纹、表面坑蚀这四种故障类型。所有输入图像统一调整为 224×224 ,使用AdamW优化器,初始学习率设为 1×10^{-3} 。学习率调度采用余弦退火策略,并在前10个epoch进行线性热身。损失函数为带标签平滑的交叉熵,训练批大小为32,最大迭代50轮。实验运行于NVIDIA GeForce RTX 4060,软件环境为Python 3.10.0配合Pytorch 2.5.1。

2.1.2 评价指标

本文采用的评价指标包括准确率(Acc)、精确率(P)、召回率(R)以及 F_1 分数^[34-35]。在故障样本与正常样本类别不平衡时,仅依赖准确率难以全方位准确评估模型性能,因此本文采用多指标综合评价实验结果。其中,精确率反映衡量模型预测为故障时的可靠性,有助于减少正常图像的误报问题;召回率则反映模型对实际故障的检出能力,有助于减少实际故障的漏检问题; F_1 分数综合考虑精确率与召回率,在误报与漏检之间取得平衡。基于上述指标,可以较为全面地评估模型对麻面、涂层脱落、边缘开裂和表面裂纹的识别能力^[36-37]。

2.2 设计动机的实验分析

为进一步验证1.1节设计动机中关于风电机组叶片小缺陷检测性能瓶颈来源的分析,本节从实验角度对现有方法的检测与识别能力进行系统评估。在统一的数据划分、训练配置和评测协议下,我们选取四种具有代表性的检测与识别模型,涵盖目标检测器与故障分类模型两类方法,并开展对比实验。图3给出了各对照模型在评价指标(Acc)下的性能对比结果。

实验结果表明,即便引入了SHViTs1^[38]和YO-

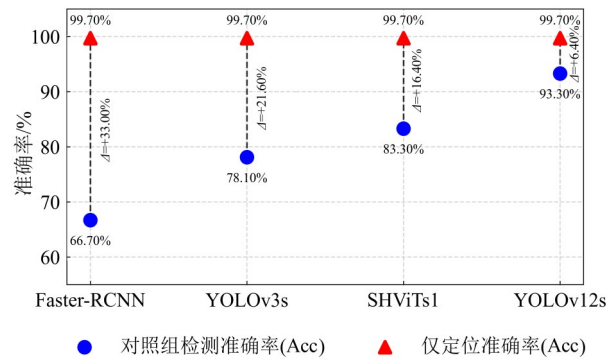


图3 不同检测器在定位任务中的性能对比

Figure 3 Performance comparison of different detectors for the localization task

LOv12s^[39]等先进视觉骨干和检测器结构,在风电机组叶片小缺陷检测任务中的整体识别准确率仍然偏低,该现象在微小裂纹与低对比度腐蚀等典型场景中尤为显著。进一步分析发现,现有模型在复杂风场背景下难以在特征空间中有效分离缺陷区域与背景干扰成分,尤其是在叶片表面小裂纹与弱对比度腐蚀共存的情况下,背景纹理、光照变化与噪声特征易主导特征响应,限制整体性能的持续提升。

为确定现有检测器性能受限的瓶颈,我们设计了一组仅保留定位分支的对照实验。在该实验中,模型仅执行候选框生成与边界框回归过程,而不进行类别判定,将定位能力与识别能力进行分离。实验结果表明,在仅进行定位的情况下,风电机组叶片缺陷的检出成功率可达到99.7%;相比之下,端到端检测模型在完整“定位-识别”流程下的整体成功率不足94%。上述显著差距表明,当前模型性能受限主要不源于候选区域的定位阶段,而是更集中体现在后续的识别与判定阶段。

上述实验结果与设计动机中的分析结论一致,说明在复杂背景和弱纹理条件下,有必要对缺陷区域的定位与缺陷类别的识别进行区分,使模型能够分别对空间定位与判别能力进行优化,为本文采用两阶段检测框架提供了实验依据。

2.3 多故障检测任务性能分析

四种缺陷类型召回率的结果如图4所示,不同缺陷在检测难度上表现出一定差异。其中,麻面与边缘开裂由于具有较为连续的空间结构特征,在测试集中获得了更高的召回率,分别为98.5%和97.5%。相比之下,涂层脱落与表面裂纹的检测性能略有下降,但整体召回率仍保持在较高水平。上述结果表明,缺陷的空间尺度与形态连续性对检测效果具有显著影响。对于结构特征较为完整的缺陷类型,模型能够实现更加稳定的定位;而在小尺度缺陷场景下,仍存在一定





图4 不同故障类型的检测召回率

Figure 4 Recall for different fault types

程度的漏检现象。

图5进一步给出了不同缺陷类型对应的精确率和 F_1 分数结果。整体来看,模型在多故障检测场景下表现较为稳定,各类缺陷的精确率均高于94%, F_1 分数均保持在96%以上。其中,麻面和边缘开裂的 F_1 分数分别为96.24%和96.30%。

图5 不同故障类型的精确率与 F_1 分数Figure 5 Precision and F_1 scores of different fault types

需要指出的是,图5中“表面裂纹”类别的精确率达到100%,该结果仅表明在模型预测为“表面裂纹”的样本中未出现误检情况,并不意味着该类别不存在漏检现象。结合图4可知,该类别的召回率并未达到100%,说明测试集中仍有部分表面裂纹样本未被模型正确识别。

上述现象主要源于当前测试集中表面裂纹在形态和纹理特征上相对清晰,与部分易混淆缺陷类别之间具有更好的区分性。因此,模型在预测该类别时未出现明显的误检样本,从而使精确率取值较高。与此同时,由于裂纹尺度较小且受局部成像条件变化的影响,该类别仍存在一定程度的漏检情况,其影响已在召回率指标中得到体现。

总体来看,该方法能够在多故障检测任务中有效区分风电机组叶片不同的表面缺陷,在保持较高检测精度的同时,对多类别复杂场景表现出较好的稳定性和泛化能力。

2.4 单故障检测任务性能分析

为了评估模型对不同复杂度任务的判别能力,我们在正常-故障二分类数据集上进行了对比实验。通过将原本的多类别故障重新划分为正常和故障叶片两类,简化了任务的复杂度。

实验结果如表1所示,在统一训练条件下,二分类任务中模型整体性能较为突出,所有指标均超过97%。其中 F_1 和Accuracy均达到97.73%,表明模型在故障判别场景下具有较高的可靠性。与多故障任务(F_1 为96.81%,Acc为96.71%)相比,单故障检测任务的性能显著提高,证明了模型的良好判别能力和泛化性能。

表1 单故障检测与多故障检测任务的评价指标比较 单位:%

任务	P	R	F_1	Acc
单故障	97.83	97.73	97.73	97.73
多故障	97.31	96.41	96.81	96.71

总体来看,单故障检测任务只需区分正常叶片与故障叶片,模型能专注学习二者之间的特征。在现场初步检查中,准确地区分正常和故障情况,可以快速筛查潜在风险,为后续的细粒度诊断奠定坚实基础。

2.5 识别成功率——比较实验

为验证所提出模型的出色性能,本文在统一的训练条件下,使用ResNet50^[40]、SHViTs1^[32]、YOLOv12s^[33]、AFB-YOLO^[6]和MES-YOLOv8n^[15]作为对比模型进行实验,实验针对风电机组叶片的四类故障(涂层脱落、边缘开裂、表面裂纹和麻面),评价指标包含精确率(P)、召回率(R)、 F_1 分数和准确率(Acc),结果如表2所示。

从实验结果来看,本文提出的模型在多数缺陷类别上取得了较为稳定且具有竞争力的识别性能。在“涂层脱落”类别中,本文模型的 F_1 值达到97.22%,显著高于ResNet50(91.30%)和SHViTs1(83.3%);在“边缘开裂”类别中,本文模型的 F_1 值为96.30%,优于YOLOv12s(93.70%)和SHViTs1(79.30%);在“表面裂纹”类别中,本文模型的 F_1 值为97.48%,相比于ResNet50(92.80%)提升了4.68个百分点;在“麻面”类别中,本文模型的 F_1 值为96.24%,仍保持领先水平。

值得注意的是,虽然AFB-YOLO与MES-YOLOv8n是针对风电机组叶片缺陷定制的目标检测算法,并且对于某些类别的缺陷得到了相似的检测结果,但是该两种目标检测算法在不同种类缺陷之间的差异性较大,整体稳定性逊于本文方法。相比之下,所提出模型在四个缺陷类别上都保持较高且均衡的 P 、 R 与 F_1 指标,表明本文提出的方法在多缺陷场景下具有更好

表 2 不同模型在风电机组叶片缺陷识别任务中的性能对比

单位: %

Table 2 Performance comparison of different models in the wind turbine blade defect recognition task

unit: %

模型	涂层脱落			边缘开裂			表面裂纹			麻面			Acc
	P	R	F_1	P	R	F_1	P	R	F_1	P	R	F_1	
Resnet50	91.30	91.30	91.30	95.70	91.80	93.80	92.20	93.40	92.80	95.20	98.80	96.90	94.00
SHViTs1	92.10	76.10	83.30	94.40	68.40	79.30	74.50	92.10	82.40	87.50	96.30	91.70	83.30
YOLOv12s	95.40	91.20	93.30	97.80	90.00	93.70	91.40	97.40	94.30	91.90	100	95.80	93.30
AFB-YOLO	90.91	86.96	88.89	95.74	91.84	93.75	90.00	94.74	92.31	93.90	96.25	95.06	93.00
MES-YOLOv8n	93.48	93.48	93.48	96.77	91.84	94.24	90.00	94.74	92.31	93.83	95.00	94.41	93.67
本文提出	100	94.59	97.22	95.15	97.50	96.30	100	95.08	97.48	94.12	98.46	96.24	96.71

的综合性能表现。

2.6 数据增强策略性能分析

为了研究数据增强策略对模型分类精度的影响,本文在统一的训练条件下,进行了消融实验来研究不同数量级训练样本下本文提出方法的表现。在验证集与测试集不变的前提下,仅对训练集采用基于随机变换策略的数据增强,增强倍数分别设置为2倍、5倍和10倍。该方法通过随机组合旋转、平移、剪切、颜色变换、对比度调整、亮度调整、锐度调整及遮挡等

操作,在保证叶片结构特征不变的前提下生成新样本,增强模型的特征表达能力以及泛化性。

实验结果如表3和图6所示。为分析数据增强策略对模型识别性能的影响,本文在固定模型结构与训练参数条件下,对训练集进行不同倍数的扩充实验,包括原始数据、2倍、5倍及10倍增强。表3给出了各类别在不同增强条件下的精确率(P)、召回率(R)、 F_1 值与准确率(Acc),图6进一步展示了整体性能指标的变化趋势。

表 3 不同数据增强策略对模型分类性能的影响

单位: %

Table 3 Effect of different data augmentation strategies on model classification performance

unit: %

类型	原始数据				2倍				5倍				10倍			
	P	R	F_1	Acc	P	R	F_1	Acc	P	R	F_1	Acc	P	R	F_1	Acc
涂层脱落	100	95.00	97.44	96.03	97.14	91.89	94.44	96.30	100	94.59	97.22	96.71	100	94.59	97.22	96.71
边缘开裂	92.68	95.00	93.83		96.25	96.25	96.25		95.12	97.50	96.30		92.94	98.75	95.76	
表面裂纹	96.88	96.88	96.88		96.67	95.08	95.87		100	95.08	97.48		100	91.80	95.73	
麻面	97.06	97.06	97.06		95.59	100	97.74		94.12	98.46	96.24		100	91.80	95.73	
Avg	96.65	95.98	96.30	96.41	95.81	96.08	97.31	96.41	96.81	97.49	96.29	96.80				




图 6 不同数据增强倍数下主要性能指标趋势对比

Figure 6 Comparison of main performance metric trends under different data augmentation multipliers

基于上述实验结果,随着训练样本数量的增加,模型整体性能稳步提升。当训练集扩充至2倍时,模型的精确率、召回率、 F_1 值和准确率分别达到

96.41%、95.81%、96.08%和96.30%,进一步扩充至5倍时,各项指标提升至97.31%、96.41%、96.81%和96.71%,模型表现最优。继续扩充至10倍后,性能略有波动($P=97.49\%$ 、 $R=96.29\%$ 、 $F_1=96.80\%$ 、 $Acc=96.71\%$),这表明不合理的数据增强策略会导致模型训练的边际收益衰减。

从类别层面观察(表3),涂层脱落和麻面等特征较为明显的缺陷类别在增强后识别率提升有限,而边缘开裂和表面裂纹等细节型缺陷受益更显著,表明随机旋转、平移、亮度与对比度变换等增强操作能够有效扩展模型对细粒度缺陷特征的感知范围。总体而言,基于随机变换的数据增强策略显著提高了模型的泛化能力与鲁棒性,其中5倍增强在识别精度与计算开销之间取得了最优平衡。

2.7 MLA与MHSA的参数量与计算复杂度对比分析

为了进一步验证所提出MLA模块在性能与效率上的优势,本文将其与标准Transformer中广泛采用的

多头自注意力 (Multi-Head Self-Attention, MHSA) 进行对比, 分别统计两者的参数量、FLOPs 及在相同网络结构下的检测性能表现。实验结果如表 4 所示。

表 4 Transformer 注意力与 MLA 的性能指标比较

Table 4 Performance comparison between multi-head self-attention and multi-scale linear attention

注意力机制	$P/\%$	$R/\%$	$F_1/\%$	Acc/ $\%$	Attention Params ($\times 10^6$)	Attention FLOPs ($\times 10^6$)
MHSA	96.70	95.36	95.93	96.03	7.088	347.19
MLA	97.31	96.41	96.81	96.71	4.322	1 136.90

由表 4 可知, MLA 的效果整体优于 MHSA, 其中 F_1 分数与 Acc 分别提升 0.88% 和 0.68%。更为突出的是, MLA 将参数量从 7.088×10^6 降至 4.322×10^6 , 在保持性能竞争力的同时提升了参数利用效率, 降低了模型存储开销, 也在一定程度上缓解了过拟合风险。

尽管 MLA 的浮点运算量略有增加, 但它在性能与模型复杂度之间实现了更优权衡, 更适配边缘部署场景。这一结果与方法设计初衷高度契合: MHSA 依赖全局相关性建模, 而 MLA 通过多尺度局部结构增强模块结合线性注意力的形式, 在减少参数量的同时, 能更精准地捕捉局部判别信息。该设计恰好适配风电叶片缺陷普遍存在的弱纹理、小尺度、低对比度特征, 在叶片表面缺陷检测任务中展现出更强的任务适配性与优越性。

2.8 MLA 尺度组合的消融与最优性验证

为验证 MLA 中多尺度卷积尺度组合的合理性, 并分析其在精度与计算开销之间的权衡关系, 本文对不同尺度组合 $\{1, 5, 9\}$ 、 $\{3, 5, 7\}$ 与当前采用的 $\{1, 3, 5\}$ 进行了系统消融实验, 结果如表 5 所示。实验结果显示, 不同的尺度组合在性能和计算量上有较大差别。其中, 组合 $\{1, 5, 9\}$ 与 $\{3, 5, 7\}$ 虽然能够捕获更大感受野, 但大尺度卷积对噪声更加敏感, 导致精确率 (P) 与召回率 (R) 均低于当前尺度配置。同时, 这两组尺度的 FLOPs 更高, 未能在复杂背景下实现更优的纹理建模。

相比之下, $\{1, 3, 5\}$ 这一尺度组合在局部细节建模与中尺度结构感知之间取得了更加合理的平衡。

表 5 MLA 不同尺度集合下的性能指标比较

Table 5 Comparison of performance metrics under different MLA scale sets

MLA 尺度集合	$P/\%$	$R/\%$	$F_1/\%$	Acc/ $\%$	Params ($\times 10^6$)	FLOPs ($\times 10^6$)
$\{1, 5, 9\}$	96.25	95.72	95.92	96.03	32.31	5 614.81
$\{3, 5, 7\}$	95.80	95.81	95.71	96.03	32.25	5 612.10
$\{1, 3, 5\}$	97.31	96.41	96.81	96.71	32.94	5 606.68

该配置既能够有效捕获小尺度、弱纹理缺陷的局部判别特征, 又能够兼顾缺陷的中尺度空间结构信息, 因而在整体检测性能上表现更加稳定。同时, 该尺度组合在保持较高检测精度的同时, 计算复杂度相对较低, 更有利于实际部署与高效推理。

2.9 Spatial-FineDef 的理论依据与作用机理分析

风电机组叶片缺陷通常呈现弱纹理、尺度微小且对比度低等特征, 使其在复杂背景中具有较高的特征可混淆性。在单阶段目标检测方法中, 定位与分类任务共享同一特征空间, 不同任务的梯度方向可能存在不一致性, 从而引发典型的多任务优化冲突, 使得弱纹理缺陷的判别性特征在联合训练过程中被背景特征所淹没。基于此, Spatial-FineDef 采用显式的两阶段解耦策略: 第一阶段专注于候选区域的空间结构与几何信息提取, 相当于引入了一个任务相关的空间先验, 能够有效提升缺陷区域相对于背景的信噪比; 第二阶段在经过空间约束后的局部区域内执行细粒度分类, 在理论上可降低背景干扰带来的特征混叠, 进而增强弱纹理小缺陷的可分性与判别能力。

从表 6 可以看出, 引入空间定位并约束特征学习区域后, 模型在多项性能指标上均取得了稳定提升。具体而言, 在去除背景干扰后, 模型的精确率由 94.77% 提升至 97.31%, 召回率由 93.80% 提升至 96.41%, 对应的 F_1 分数从 94.20% 提升至 96.81%, 整体准确率也由 94.33% 提升至 96.71%。上述结果表明, 定位相关指标的提升并非偶然波动, 而是来源于空间定位机制所带来的整体一致性改善。

表 6 保留与去除背景对空间先验性影响的性能指标比较 单位: %

Table 6 Comparison of performance metrics on the effect of retaining and removing background on spatial prior unit: %

模型	P	R	F_1	Acc
保留背景	94.77	93.80	94.20	94.33
去除背景	97.31	96.41	96.81	96.71

该现象表明, 在复杂真实风场环境中, 引入候选区域定位是定位精度提升的主要来源之一。通过对可能存在的叶片区域进行空间约束, 模型在随后的特征学习过程中可以有效避免与叶片无关的背景信息干扰, 并更多地关注于叶片结构区域的建模, 从而得到更为稳定可靠的定位结果。

此外, 在实际采集到的风电叶片巡检图像中往往还存在大量的高频背景信息, 例如天空、植被、塔筒反光以及成像噪声等, 而上述背景纹理很容易在特征空间内与弱纹理、小尺度缺陷相混淆, 并由此影响最终定位效果。Spatial-Net 候选区域定位有效的限制特征模型只存在于叶片区域空间中, 大大降低了背景信息对于检测的影响效果, 是最终检测精度提高的重要

原因之一。

为分析不同注意力在弱纹理小目标检测中的适应性,本文对比了加法注意力^[41](Efficient Attention)、类 Mamba 的线性注意力^[42](MLLA)以及所提出的多尺度线性注意力(MLA),结果如表 7 所示。Efficient Attention 在本质上仍依赖全局 token 的两两相关性建模,易受背景高频噪声干扰;MLLA 通过线性核映射降低了计算复杂度,但其空间建模尺度单一,对具有多尺度形态差异的叶片缺陷刻画能力有限。MLA 将多尺度卷积与线性注意力融合,多尺度卷积增强不同几何尺度下的局部结构与弱纹理特征,而线性注意力在保持高分辨率的同时有效建模跨区域相关性,降低背景噪声对注意力分布的扰动。两者协同作用,使模型能够在强背景干扰下突出缺陷的判别性纹理模式。

表 7 不同注意力机制的性能指标比较

Table 7 Performance comparison of different attention mechanisms

注意力机制	P/%	R/%	F_1 /%	Acc/ %	Params ($\times 10^6$)	FLOPs ($\times 10^6$)
Efficient Attention	94.83	94.22	95.45	94.24	30.19	9 140.74
MLLA	95.89	94.73	94.45	94.24	27.82	8 909.53
MLA	97.31	96.41	96.81	96.71	32.94	5 606.68

从实验结果可见,MLA 在 Precision、Recall 与 F_1 上均显著优于 Efficient Attention 和 MLLA,且 FLOPs 更低($5\ 606.68 \times 10^6$ 对比 $9\ 140.74 \times 10^6$ 和 $8\ 909.53 \times 10^6$)。这说明多尺度线性注意力不仅提供了更符合叶片缺陷特性的表征机制,也实现了性能与效率的双重提升,构成了本方法中提升细粒度判别能力的关键组成部分。

3 结论

本文针对复杂背景下 WTB 小尺度和低对比度缺陷检测存在的难点和瓶颈,提出 Spatial-FineDef 检测方法用于 WTB 缺陷检测。采用两阶段检测策略分离定位和识别功能,在保证微小缺陷检测精度的同时提高了缺陷的可分辨性。第一阶段的 Spatial-Net 通过定制化数据增强与叶片定位网络的协同设计,有效提高了候选区域的定位准确性;在此基础上,第二阶段的 FineDef-Net 引入轻量化多尺度线性注意力机制,进一步增强了微小缺陷的判别能力。实验结果表明,Spatial-FineDef 在 4 类典型风电机组叶片缺陷(涂层脱落、边缘裂纹、中部裂纹、表面坑蚀)检测中,识别准确率达到 96.71%,明显优于现有基于端到端的检测方法,并且具有更强的鲁棒性,在实际场景下的性能优势更加明显。该方法在保证低计算开销和高效部署的前提下,提出了一个可用于风电机组叶片实时智能监测的新颖可行方案,实现了风电机组叶片检测的

智能化及高效率;在一定程度上缓解了复杂背景下小缺陷检测精度受限的问题,对于风电机组的维护及提高其可靠性有很好的应用价值和技术支撑,具有广泛的应用前景。在实际风电场巡检过程中,叶片上存在一定的局部遮挡、反光及雨雾等不利环境因素的影响,这些因素会导致成像质量下降,进而导致难以稳定地识别微小、弱纹理缺陷,并且各风场间、成像条件间的分布性也可能对模型的泛化能力造成一定影响,这将是本工作今后需关注的重点方向。

参考文献

- [1] 朱海波, 缪维跑, 范士杰, 等. 大型风力机叶片仿生叶脉结构设计及性能分析[J]. 中国电机工程学报, 2025, 45(4): 1521-1531.
Zhu Haibo, Miao Weipao, Fan Shijie, et al. Design and performance analysis of bionic blade vein structure for the large wind turbine blade[J]. Proceedings of the CSEE, 2025, 45(4): 1521-1531. (in Chinese)
- [2] 赵艳, 杜艳强, 王新武, 等. 风力机支撑结构疲劳损伤评估中的不确定性分析[J]. 中国电机工程学报, 2023, 43(16): 6313-6319.
Zhao Yan, Du Yanqiang, Wang Xinwu, et al. Uncertainty analysis in fatigue damage assessment of wind turbine support structure[J]. Proceedings of the CSEE, 2023, 43(16): 6313-6319. (in Chinese)
- [3] Wu Ping, Wang Yixuan, Zhang Xujie, et al. Wind turbine blade breakage monitoring with mogrifler LSTM autoencoder[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 3534610.
- [4] Encalada-Dávila Á, Moyón L, Tutivén C, et al. Early fault detection in the main bearing of wind turbines based on gated recurrent unit (GRU) neural networks and SCADA data[J]. IEEE/ASME Transactions on Mechatronics, 2022, 27(6): 5583-5593.
- [5] 谢小荣, 贺静波, 毛航银, 等. “双高”电力系统稳定性的新问题及分类探讨[J]. 中国电机工程学报, 2021, 41(2): 461-475.
Xie Xiaorong, He Jingbo, Mao Hangyin, et al. New issues and classification of power system stability with high shares of renewables and power electronics[J]. Proceedings of the CSEE, 2021, 41(2): 461-475. (in Chinese)
- [6] Ran Xiukang, Zhang Shang, Wang Hengtao, et al. An improved algorithm for wind turbine blade defect detection[J]. IEEE Access, 2022, 10: 122171-122181.
- [7] Yuan Minghao, Zhou Yongbing, Ren Xiaoyu, et al. YO-LO-HMC: An improved method for PCB surface defect detection[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 2001611.

- [8] Stokkeland M, Klausen K, Johansen T A. Autonomous visual navigation of Unmanned Aerial Vehicle for wind turbine inspection[C]//2015 International Conference on Unmanned Aircraft Systems. Piscataway: IEEE, 2015: 998-1007.
- [9] Wang Long, Zhang Zijun. Automatic detection of wind turbine blade surface cracks based on UAV-taken images[J]. IEEE Transactions on Industrial Electronics, 2017, 64(9): 7293-7303.
- [10] Deng Liwei, Guo Yan'gang, Chai Borong. Defect detection on a wind turbine blade based on digital image processing[J]. Processes, 2021, 9(8): 1452.
- [11] 石腾, 许波峰, 陈鹏, 等. 基于机器视觉的风电机组叶片多类型损伤检测方法研究[J]. 太阳能学报, 2024, 45(6): 487-494.
- Shi Teng, Xu Bofeng, Chen Peng, et al. Study on multi-type damage detection method for wind turbine blades based on machine vision technology[J]. Acta Energetica Sinica, 2024, 45(6): 487-494. (in Chinese)
- [12] Zhou Yan. A YOLO-NL object detector for real-time detection[J]. Expert Systems with Applications, 2024, 238: 122256.
- [13] Hang Xinyu, Zhu Xiaoxun, Gao Xiaoxia, et al. Study on crack monitoring method of wind turbine blade based on AI model: Integration of classification, detection, segmentation and fault level evaluation[J]. Renewable Energy, 2024, 224: 120152.
- [14] Ye Xingyu, Wang Long, Huang Chao, et al. Wind turbine blade defect detection with a semi-supervised deep learning framework[J]. Engineering Applications of Artificial Intelligence, 2024, 136: 108908.
- [15] Ma Limei, Jiang Xingyu, Tang Zizhen, et al. Wind turbine blade defect detection algorithm based on lightweight MES-YOLOv8n[J]. IEEE Sensors Journal, 2024, 24(17): 28409-28418.
- [16] Liu Lizhao, Li Pinrui, Wang Dahan, et al. A wind turbine damage detection algorithm designed based on YOLOv8[J]. Applied Soft Computing, 2024, 154: 111364.
- [17] 蒋兴群, 刘波, 宋力, 等. 基于改进 YOLO-v3 的风力机叶片表面损伤检测识别[J]. 太阳能学报, 2023, 44(3): 212-217.
- Jiang Xingqun, Liu Bo, Song Li, et al. Surface damage detection and recognition of wind turbine blade based on improved YOLO-v3[J]. Acta Energetica Sinica, 2023, 44(3): 212-217. (in Chinese)
- [18] Guo Jihong, Liu Chao, Cao Jinfeng, et al. Damage identification of wind turbine blades with deep convolutional neural networks[J]. Renewable Energy, 2021, 174: 122-133.
- [19] He Yan, Niu Xiaobo, Hao Chuanpeng, et al. An adaptive detection approach for multi-scale defects on wind turbine blade surface[J]. Mechanical Systems and Signal Processing, 2024, 219: 111592.
- [20] Yu Zhengxu, Shen Dong, Jin Zhongming, et al. Progressive transfer learning[J]. IEEE Transactions on Image Processing, 2022, 31: 1340-1348.
- [21] Han Honggui, Meng Yuan, Wu Xiaolong, et al. A transfer learning-based multimodal feature fusion model for bearing fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 3530413.
- [22] Wang Long, Yang Jinxu, Huang Chao, et al. An improved U-Net model for segmenting wind turbines from UAV-taken images[J]. IEEE Sensors Letters, 2022, 6(7): 6002404.
- [23] Na Lan, Cai Baigen, Zhang Chongzhen, et al. A heterogeneous transfer learning method for fault prediction of railway track circuit[J]. Engineering Applications of Artificial Intelligence, 2025, 140: 109740.
- [24] 普智勇, 郭新毅, 刘发炳, 等. 基于无损检测和迁移学习的风电机组主轴缺陷识别[J]. 机电工程, 2025, 42(6): 1084-1092.
- Pu Zhiyong, Guo Xinyi, Liu Fabing, et al. Defect identification of wind turbine spindle based on nondestructive testing and transfer learning[J]. Mechanical & Electrical Engineering Magazine, 2025, 42(6): 1084-1092. (in Chinese)
- [25] Yang Xiyun, Zhang Yanfeng, Wei Lyu, et al. Image recognition of wind turbine blade damage based on a deep learning model with transfer learning and an ensemble learning classifier[J]. Renewable Energy, 2021, 163: 386-397.
- [26] Liu Yuhang, Zheng Yuqiao, Wei Tai, et al. Lightweight algorithm based on you only look once version 5 for multiple class defect detection on wind turbine blade surfaces[J]. Engineering Applications of Artificial Intelligence, 2024, 138: 109422.
- [27] Liu Dandan, Liu Mingjie. Wind turbine blades defect detection based on global and local attention with multi-feature fusion[J]. Applied Soft Computing, 2025, 185: 113914.
- [28] Liu Jinyan, Yan Longbin, Chen Jie. A coarse-to-fine object detection framework for high-resolution images with sparse objects[C]//2021 IEEE 31st International Workshop on Machine Learning for Signal Processing. Piscataway: IEEE, 2021: 1-6.
- [29] Yuan Xiang, Cheng Gong, Yan Kebin, et al. Small object detection via coarse-to-fine proposal generation and imitation learning[C]//2023 IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE, 2023:

- 6294-6304.
- [30] Ali Shah R, Urmonov O, Kim H. Two-stage coarse-to-fine image anomaly segmentation and detection model[J]. Image and Vision Computing, 2023, 139: 104817.
- [31] Liang Yun, Hu Zhiguang, Huang Junjie, et al. ToCoAD: Two-stage contrastive learning for industrial anomaly detection[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 5012009.
- [32] Varghese R, M S. YOLOv8: A novel object detection algorithm with enhanced performance and robustness[C]//2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems. Piscataway: IEEE, 2024: 1-6.
- [33] Liu Xinyu, Peng Houwen, Zheng Ningxin, et al. EfficientViT: Memory efficient vision transformer with cascaded group attention[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2023: 14420-14430.
- [34] Wang Lei, He Yigang, Shao Kaixuan, et al. An unsupervised approach to wind turbine blade icing detection based on beta variational graph attention autoencoder[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 2500912.
- [35] 雷涛, 翟钰杰, 许叶彤, 等. 基于边缘引导和动态可变形Transformer的遥感图像变化检测[J]. 电子学报, 2024, 52(1): 107-117.
Lei Tao, Zhai Yujie, Xu Yetong, et al. Edge guided and dynamically deformable transformer network for remote sensing images change detection[J]. Acta Electronica Sinica, 2024, 52(1): 107-117. (in Chinese)
- [36] Zhu Xiaoxun, Hang Xinyu, Gao Xiaoxia, et al. Research on crack detection method of wind turbine blade based on a deep learning method[J]. Applied Energy, 2022, 328: 120241.
- [37] Chen Zhendong, Feng Xuefeng, Liu Li, et al. Surface defect detection of industrial components based on vision[J]. Scientific Reports, 2023, 13: 22136.
- [38] Yun S, Ro Y. SHViT: Single-head vision transformer with memory efficient macro design[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2024: 5756-5767.
- [39] Tian Yunjie, Ye Qixiang, Doermann D. YOLOv12: Attention-centric real-time object detectors[PP/OL]. V1. arXiv (2025-02-18) [2026-01-26]. <https://doi.org/10.48550/arXiv.2502.12524>.
- [40] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2016: 770-778.
- [41] Shaker A, Maaz M, Rasheed H, et al. SwiftFormer: Efficient additive attention for transformer-based real-time mobile vision applications[C]//2023 IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE, 2023: 17379-17390.
- [42] Han Dongchen, Wang Ziyi, Xia Zhuofan, et al. Demystify Mamba in vision: A linear attention perspective[PP/OL]. V1. arXiv (2024-05-25) [2026-01-26]. <https://doi.org/10.48550/arXiv.2405.16605>.

作者简介



年嘉伟 男,1995年生,博士。主要研究方向为智能发电、故障检测。
E-mail: jwnian@ncepu.edu.cn



王梓懿 男,2002年生,硕士研究生。主要研究方向为风电机组智能检测。
E-mail: ziyiwang@ncepu.edu.cn



唐灵犀 女,2001年生,硕士研究生。主要研究方向为深度学习、故障诊断。
E-mail: tanglingxi_edu@163.com



房方 男,1976年生,博士,教授。主要研究方向为智能发电、先进发电过程建模控制与优化。
E-mail: ffang@ncepu.edu.cn