

DOI: 10.19650/j.cnki.cjsi.J2514251

基于小目标感知增强的风机叶片缺陷智能检测^{*}

张泽辰^{1,2}, 姚顺春³, 梁晓俊², 袁宝义⁴, 张超波²

(1. 华南理工大学未来技术学院 广州 510006; 2. 鹏城实验室 深圳 518055; 3. 华南理工大学电力学院 广州 510006; 4. 中国能源建设集团国际工程有限公司 北京 100025)

摘要:当前风机叶片检测存在图像分辨率高、叶片缺陷目标小和形态复杂等问题,导致其表面缺陷难以准确识别和定位。为了解决以上问题,提出一种基于小目标感知增强的风机叶片缺陷检测方法。首先,构建了动态通道空间卷积模块来改进YOLOv8检测网络,利用空间重构模块和通道重构模块,减少模型运算量和降低特征提取冗余,进而提高模型的检测性能。其次,设计了一个小目标感知增强网络,该网络由多尺度 Transformer 模块、特征融合模块和小目标检测头构成,其多尺度 Transformer 模块能协助网络理解小目标周边区域的语义,具体包括多尺度融合模块、多层次感知机和查询选择模块,进而实现小目标缺陷特征的粗提取。随后,利用双线性插值和上下文引导注意力融合机制,实现缺陷浅层-深层特征的尺寸与语义对齐,以提升模型对小目标缺陷的感知。最后,引入自适应分布交并比损失函数来提升缺陷定位精度,并降低类别不平衡对检测精度的影响。在海上风电机组自建叶片数据集进行实验验证,结果表明本文提出的缺陷检测网络平均精度可达 0.815,相比较 YOLOv8 模型和 RT-DETR 模型,分别提高了 0.134 和 0.182,且在 RTX3090 GPU 上推理速度为 14 fps,满足实时检测的要求,进一步证明了其在风机叶片缺陷检测应用上的潜力。

关键词:风机叶片;缺陷检测;动态通道空间卷积;注意力多尺度;小目标感知增强

中图分类号: TP391 TH161.1 文献标识码: A 国家标准学科分类代码: 520.20

Wind turbine blade intelligent defect detection based on small object perception enhancement

Zhang Zechen^{1,2}, Yao Shunchun³, Liang Xiaojun², Yuan Baoyi⁴, Zhang Chaobo²

(1. School of Future Technology, South China University of Technology, Guangzhou 510006, China; 2. Peng Cheng Laboratory, Shenzhen 518055, China; 3. School of Electric Power Engineering, South China University of Technology, Guangzhou 510006, China; 4. China Energy Engineering Group International Engineering Co., Ltd., Beijing 100025, China)

Abstract: At present, wind turbine blade inspection suffers from high-resolution imagery, extremely small defects, and complex morphologies, making accurate identification and localization of surface flaws difficult. To address these challenges, this article proposes a small object perception-enhanced defect detection method for turbine blades. Firstly, a dynamic channel spatial convolution module is constructed to improve the YOLOv8 detection network. By using spatial and channel reconstruction modules, the computational load of the model is reduced and feature extraction redundancy is lowered, thereby enhancing the detection performance of the model. Secondly, a small object perception enhancement network is designed, which consists of a multi-scale Transformer block, a feature fusion module, and a small object detection head. The multi-scale Transformer block assists the network in understanding the semantics of the surrounding areas of small objects, including a multi-scale fusion module, a multi-layer perceptron, and a query selection module, to achieve coarse extraction of small object defect features. Subsequently, bilinear interpolation and context-guided attention fusion mechanisms are employed to align the size and semantics of shallow and deep defect features, enhancing the model's perception of small object defects. Finally, an adaptive distribution powerful IoU Loss function is introduced to improve defect localization accuracy and reduce the impact of class imbalance on detection accuracy. Experiments implemented on a self-built offshore wind turbine blade dataset

demonstrate that the proposed defect detection network achieves an average precision of 0.815. Compared with the YOLOv8 and RT-DETR models, it shows improvements of 0.134 and 0.182, respectively. Moreover, it achieves an inference speed of 14 frames per second on an RTX3090 GPU, meeting the requirements for real-time detection and further proving its potential for application in wind turbine blade defect detection.

Keywords: wind turbine blades; defect detection; dynamic channel spatial convolution; attention multi scale; small object perception enhancement

0 引言

风电作为清洁能源的重要组成部分,在全球节能减排的方向下,获得迅速发展。叶片作为风力发电机组的关键部件,其结构和运行状态对系统稳定和发电效率起着至关重要的作用^[1]。然而,叶片也是风力发电机组中最脆弱的部件,特别是机组通常部署在偏远且环境恶劣的地区,极易出现如开裂、划痕和腐蚀等缺陷,并具有类型多样、尺寸多变的特点,难以及时维护。随着风机容量逐年扩增,风机部署数量也迅速增涨,不仅提高了人工成本和各类检测的安全隐患,也加大了叶片缺陷检测的难度,带来了检测效率低和停机检测成本高的问题^[2]。因此,采取有效的检测手段,尽早发现叶片表面缺陷,对降低事故风险、减少经济损失具有重要的意义。

目前,传统的风机叶片缺陷检测由人工巡检和传感器信号采集来完成。但人工目视法受限于人员主观经验及叶片复杂曲面结构,难以实现表面全覆盖,导致缺陷漏检情况严重。为突破此局限,基于传感器的信号采集方法被广泛使用,涵盖红外热成像^[3]、声发射技术^[4]、超声波^[5]、振动检测^[6]、电磁检测^[7]等,采用频域/时域分析提取特征信号以识别缺陷^[8]。但此类方法需要在风机停机状态下部署传感器,采集结果也易受复杂环境干扰,导致运维成本增加和误判率上升。

当前人工智能技术已在缺陷检测领域普遍应用,基于机器学习算法可自动从采集的叶片图像中检测缺陷。Wang 等^[9]提出了一种针对低分辨率叶片图像的无监督异常检测方法,采用无监督学习支持向量机的框架,但存在误检率严重的问题。Yang 等^[10]采用迁移学习增强的随机森林分类器方法,能有效检测叶面是否存在缺陷,但无法判断缺陷的种类。Deng 等^[11]提出了一种基于改进的线性粒子群算法自适应滤波器,使用方向梯度直方图和支持向量机分类器来确定风机叶片图像中的缺陷类型,但容易导致分类错误和处理时间过长等问题。以上基于传统机器学习的方法虽然提升了叶片缺陷检测的效率,但均需要手动定义提取的特征,在面对复杂背景的缺陷情况时,存在检测精度不足的问题。

深度学习作为机器学习的分支,无需设计专门的特征提取器,可直接从大量风机叶片缺陷数据中学习有效的特征并进行检测。Memari 等^[12]综述了基于深度学习增强的风机叶片故障诊断方法,具体涵盖了航拍图像自动检测、机器学习图像处理和叶片的疲劳性分析。朱佳伟等^[13]采用基于卷积神经网络(convolutional neural network, CNN)架构的单发多框检测(single-shot multibox detector, SSD)方法预测叶片缺陷位置,对于低分辨率图像仅能检测和展示部分缺陷,容易因为拍摄照片不完全导致缺陷缺失,影响检测精度。Qiu 等^[14]基于 CNN 架构的 YOLO(you only look once)^[15],设计了 YOLO 小目标检测方法(YOLO-based small object detection approach, YSODA),能对叶面裂纹、油污和砂面小缺陷进行自动检测,但也存在叶片缺陷类型不够全面等问题。Ran 等^[16]引入了注意力机制和特征平衡方法改进 YOLO 缺陷检测,从特征提取和特征融合方面进一步提升了网络的检测精度,增强小目标缺陷的实时检测能力。

除了检测缺陷所在位置框,还可通过语义分割技术在像素级层面判断叶片缺陷形态及类别。如 Yu 等^[17]设计了层次分裂深度可分卷积的 U-Net 网络,结合 Haar 小波注意力和多元信息感知网络,提取训练数据的深层抽象特征,实现叶片缺陷的像素级分割。Hang 等^[18]设计了多变量信息感知模块,提高对缺陷边缘的提取能力。但上述缺陷检测技术主要针对低分辨率图像设计,在面对高分辨率航拍图像与复杂小目标缺陷时,检测精度较低且实时检测困难^[19]。

随着无人机拍摄技术的持续提升,所获取的高分辨率航拍图像可同时包含多类型、多尺度缺陷。Zhang 等^[20]综述了无人机搭载各类检测技术用于叶片检测的应用,指出复杂干扰环境下实现高精度、强鲁棒性的在线缺陷检测仍是主要挑战。相关学者针对该问题,通过高分辨率图像预处理、小目标特征增强和注意力机制引导等方法,实现叶片缺陷的分类和定位^[21-22]。但现有方法面对航拍图像上的复杂小缺陷,仍然存在检测速度慢或精度不足的问题,难以在实际工业现场应用。

因此,本研究提出一种小目标感知增强的检测方法,具有计算资源占用低和检测精度高的特点,适用于风机叶片高分辨率航拍图像的缺陷检测。该研究首先搭建基于动态通道空间卷积(dynamic channel spatial

convolution, DCSCConv) 的特征提取模块,降低模型复杂度的同时增强模型对叶片特征的提取能力;其次,构建了小目标感知增强网络 (small object perception enhancement network, SOPEN),由多尺度 Transformer 模块 (multi scale Transformer block, MSTB), 特征融合模块和小目标检测头构成,用于小目标缺陷的特征粗提取及小目标浅层-深层特征融合;接着,引入自适应分布交并比损失函数 (adaptive distribution powerful intersection over union loss, ADPIOU),旨在降低类别不平衡对检测结果的影响;最后,在高分辨率风机叶片缺陷数据集上进行验证和测试,并与常用模型在检测精度、模型大小等方面进行对比。

1 相关工作

目标检测网络根据是否使用锚框可分为有锚框算法和无锚框算法两大类。有锚框算法进一步可划分为两阶段和单阶段检测算法。典型的两阶段算法如快速区域卷积网络 (faster region-based convolutional neural network, Faster R-CNN)^[23],首先以像素点为中心,按固定纵横比生成候选区域,再进行分类和回归操作以确定目标对象的类别和具体位置。Li 等^[24-25]利用 Faster R-CNN 分别在混凝土路面和施工路面进行智能检测,获得完整的裂纹检测边界框,但该方法训练过程依赖大量标记数据。单阶段算法如 SSD^[26] 和 YOLO^[27],可直接预测物体位置和类别,具有速度和部署优势,适合工业应用场景。Lu 等^[28-29]采用优化的 SSD 模型,分别在遥感目标检测和叶片缺陷检测场景,设计多尺度先验框进行训练,实现目标特征自主学习及定位。然而,上述算法的锚框纵横比、宽高超参数依赖人为设计,难以适应复杂形状的叶片缺陷。无锚框算法的代表性模型有 Transformer 检测 (detection Transformer, DETR)^[30],YOLOv8^[31]与全卷积单步目标检测 (fully convolutional one-stage object detection, FCOS)^[32]。例如,Li 等^[33]提出了基于 DETR 的全局自注意力表面缺陷检测方法,提升了模型对缺陷的检测精度和检测速度。Hoanh 等^[34]提出一种结合多层次聚焦网络与 Transformer 结构的检测模型,利用数据稀疏性平衡目标分析与计算效率。这类无锚框检测算法可显著减少超参数并简化训练过程,适合在大范围无人机巡检的工业场景中使用。

小目标检测作为目标检测的子任务,因目标物理尺寸小,占据图像像素少,导致模型在检测时需要在有限的像素信息下准确地定位和分类。相关学者针对上述问题,采用滑动窗口法^[20]提前剔除冗余信息区域,再利用检测模型确定缺陷位置,但该方法容易把图像内的单个缺陷分为多个部分,导致目标误检。Gao 等^[35]为避免目

标误检和漏检,搭建动态区域网络 (dynamic zoom-in network, DZN),提出粗细检测器分级检测,将原图下采样输入粗糙检测器生成缺陷概率图并预检区域坐标,再按坐标裁剪原图区域送入精细检测器。但该方法需要利用数据集分别训练两个检测器,不仅占用较多计算资源,且检测时间较长^[36]。为解决该问题,Jiang 等^[37]针对航拍高分辨率图像,采用多尺度特征融合与小目标预测头,避免训练多个检测器并提升小目标精度;但该网络仅聚焦局部特征,难以利用全局上下文增强小目标置信度。为此,童小钟等^[38](水下检测)和 Li 等^[39](印刷电路板缺陷检测)引入注意力机制改进多尺度特征融合网络,自适应增强了浅层空间信息特征和深层语义信息特征,提高模型特征表征能力,能在复杂背景中准确识别小目标,但该类方法的模型复杂度高,导致部署成本显著增加。

本文参考多尺度浅-深层特征融合思路,基于当前较为流行的 YOLOv8 模型,提出了一个无锚框单阶段的叶片小目标缺陷检测网络,通过设计新颖的卷积网络和 Transformer 模块,降低模型计算量并改进其特征提取能力,实现叶片小缺陷的高精度定位。

2 叶片缺陷检测网络设计

本文提出了一种针对风机叶片小目标缺陷的检测网络,其整体架构如图 1 所示。网络主要由 4 个部分组成:主干网络 (backbone), 颈部网络 (neck), 检测头 (head) 和小目标感知增强网络。其中,前 3 部分基于 YOLOv8 的主体结构^[40-41],并采用动态通道空间模块进行优化。小目标感知增强网络基于 Transformer 架构设计,融合颈部网络的相关特征,实现小目标缺陷特征有效捕捉和检测准确率提升。

2.1 动态通道空间模块

卷积模块 (convolution, Conv) 计算作为 YOLOv8 的重要组成部分,在每个卷积层只学习单个静态卷积核。而动态卷积的研究表明,学习 n 个卷积核的线性组合,并对特征输入进行加权计算,可以显著提高卷积的精度,同时保持一定推理速度^[42]。然而,这种方法只关注卷积核数,未能充分考虑卷积的空间大小、卷积核的输入通道数和输出通道数,在共享相同权重的情况下,限制了卷积获取上下文信息的能力^[43]。为解决这一问题,在保持卷积“平移不变性”的基础上,设计 DCSCConv, 替换双卷积跨阶段瓶颈模块 (cross-stage partial bottleneck with two convolutions, C2f) 中传统卷积,由此构建了 DCSCBlock (dynamic channel spatial block) 模块,旨在增加卷积局部感知能力,更好地捕捉图像特征^[44],具体结构原理如图 2 所示。

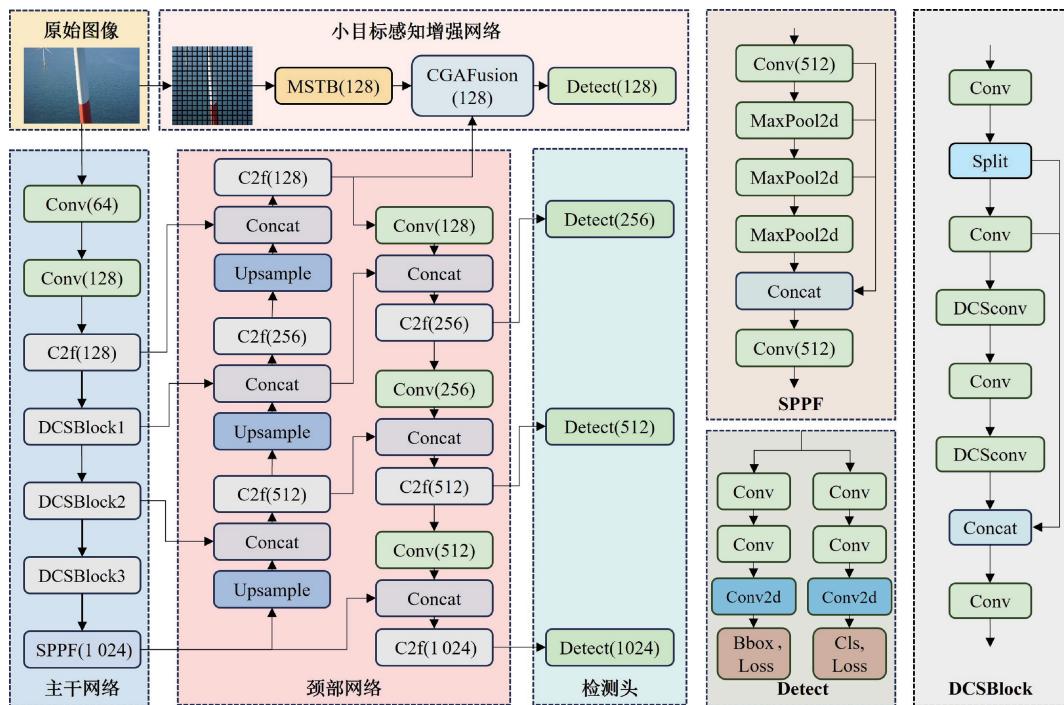


图1 检测网络架构

Fig. 1 Detection network framework

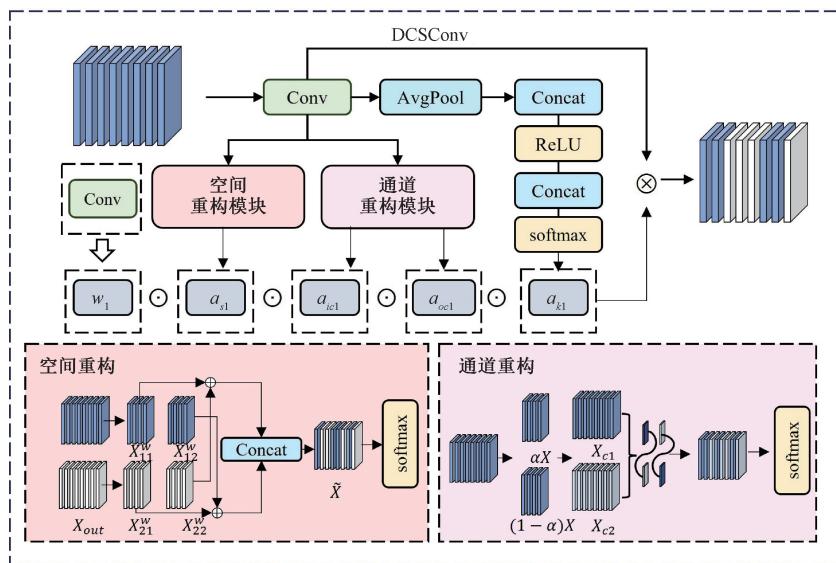


图2 DCSConv 结构

Fig. 2 DCSConv structure

传统动态卷积通过卷积核 w_1 和注意力函数 $\pi_{wi}(x)$ 来计算动态注意标量 a_{ki} , 但该方法忽略了卷积核的空间维数及输入输出通道的影响^[45]。基于此, 提出四维计算机制, 涵盖空间核大小 ($k \times k$)、输入输出通道数 (c_{in}, c_{out}) 以及卷积核数 n , 具体等式为:

$$y = (w_1 \odot a_{s1} \odot a_{oc1} \odot a_{ic1} \odot a_{ki}) \cdot x \quad (1)$$

式中: x 和 y 为特征输入和输出; $a_{ki} \in \mathbb{R}$ 代表卷积核的注意力标量; $a_{ic1} \in \mathbb{R}^{c_{in}}$ 为每个卷积的输入通道所分配的关注标量; $a_{oc1} \in \mathbb{R}^{c_{out}}$ 为输出通道卷积所分配的关注尺度; $a_{s1} \in \mathbb{R}^{k \times k}$ 为 $k \times k$ 个空间位置的卷积所分配的不同注意力标量。

为了减少传统的空间运算和通道运算带来的信息冗

余,我们引入空间通道重构运算机制,减少模型参数和运算量,提高特征表示的能力^[46]。该机制包括空间重构模块(spatial reconstruction)和通道重构模块(channel reconstruction)两部分,旨在优化特征提取过程中的冗余现象。

1) 空间重构模块:空间重构模块用于减弱特征的空间冗余。首先,我们将信息丰富的特征图与空间内容对应的特征图分离。利用组归一化(group normalization, GN)层中的比例因子来评估不同特征图的信息含量。具体来说,给定一个中间特征映射 $X \in \mathbb{R}^{N \times C \times H \times W}$, 其中 N 为批次轴, C 为通道轴, H 和 W 为空间高度和宽度轴。平均值 μ 并除以标准差 σ , 获得标准化特征输出值为:

$$X_{out} = GN(X) = \gamma \frac{X - \mu}{\sqrt{\sigma^2 + \varepsilon}} + \beta \quad (2)$$

式中: μ 、 σ 分别为标准差平均值; ε 是随机小的正常数; γ 和 β 为可训练参数, 用于调整每个批次和通道的空间像素方差, 并通过归一化权重增强不同特征的映射效果, 表达式为:

$$W_\gamma = \frac{\gamma_i}{\sum_j \gamma_j}, \quad i, j = 1, 2, \dots, C \quad (3)$$

接下来, 将特征权值通过 Sigmoid 函数映射到 [0, 1] 范围, 并应用阈值门控处理。

$$W = Gate(\text{Sigmoid}(W_\gamma(GN(X)))) \quad (4)$$

式中: 设置门控权重阈值为 0.5, 大于此阈值的权重为 1, 反之为 0.5。然后, 将特征 X 分别与两个特征权重相乘, 获得完整特征 X_1^w 和冗余特征 X_2^w , 接着对这两类特征进行交叉重构, 获得拼接重构后的特征 \tilde{X}_1^w 和 \tilde{X}_2^w , 以及新的空间重构特征 \tilde{X} , 使用 Softmax 模块, 提取出对应注意力标量 a_{sn} , 实现特征的空间重构提取。

$$\begin{cases} X_1^w = X_{11}^w \oplus X_{12}^w \\ X_2^w = X_{21}^w \oplus X_{22}^w \end{cases} \rightarrow \begin{cases} \tilde{X}_1^w = X_{11}^w \oplus X_{22}^w \\ \tilde{X}_2^w = X_{21}^w \oplus X_{12}^w \end{cases} \quad (5)$$

2) 通道重构模块: 针对标准卷积在重复过程中导致的通道维度冗余问题。本研究设计了通道重构模块, 首先设置分割因子 $\alpha \in [0, 1]$, 将特征 X 分为 αX 和 $(1 - \alpha)X$, 分别进行 $k \times k$ 的深度可分离卷积(depthwise separable convolution, DSConv)和 1×1 点卷积, 得到两个通道特征输出为:

$$\begin{cases} X_{c1} = DS(\alpha X) \\ X_{c2} = PWC((1 - \alpha)X) + (1 - \alpha)X \end{cases} \quad (6)$$

然后利用全局平均池化统计全局信息, 即:

$$S_m = Pooling(X_m) = \frac{1}{H \times W} X_m(i, j), \quad m = 1, 2 \quad (7)$$

之后, 通过通道软注意运算生成特征重要性向量 $\boldsymbol{\beta}_1$ 和 $\boldsymbol{\beta}_2$, 自适应合并 X_{c1} 和 X_{c2} , 获得最终通道特征 X_c , 公式为:

$$X_c = \boldsymbol{\beta}_1 X_{c1} + \boldsymbol{\beta}_2 X_{c2} \quad (8)$$

$$\left\{ \begin{array}{l} \boldsymbol{\beta}_1 = \frac{e^{s_1}}{e^{s_1} + e^{s_2}} \\ \boldsymbol{\beta}_2 = \frac{e^{s_2}}{e^{s_1} + e^{s_2}} \end{array} \right. \quad (9)$$

最后, 依靠 Softmax 模块提取特征通道输入和输出所对应的标量, 实现特征的通道重构提取。

3) 模型集成: 鉴于 YOLOv8 骨干网络主要由卷积模块堆叠构成, 导致不能很好地区分目标和背景。将所设计的 DCSConv 替换骨干网络中原本的常规卷积模块, 并和 C2f 模块相融合, 从而构建 DCSBlock 模块, 降低模型计算量。再经过特征融合模块, 在提取多尺度特征信息的同时, 关注网络全维度信息, 便于进行端到端的训练, 进一步提高模型的预测精度。

2.2 小目标感知增强网络

风机叶片缺陷在不同尺寸下的图像特征中会存在显著差异, 例如, 大尺寸缺陷通常包含丰富的语义信息, 适合进行高级特征处理^[47]; 小尺寸缺陷则具有较小的感受野, 包含较多的空间细节信息, 更适用于低级特征映射; 直接提取所有特征则会增加模型复杂度, 还可能影响模型性能^[48]。鉴于叶片缺陷具有多尺度的特点, 基于 Transformer 架构设计了小目标感知增强网络, 包括多尺度 Transformer 模块, 特征融合模块和小目标检测头, 网络的具体结构如图 3 所示。

在进行小目标特征提取和融合前, 首先对下采样图进行分块和平铺, 并对这些块进行统一编号, 然后送入多尺度 Transformer 模块, 增强特征映射的表示能力。该模块由 3 个子层组成: 注意力多尺度融合模块(attention multi scale fusion block, AMSFB)、多层次感知机和查询选择模块(query selection), 有助于当前节点不仅关注当前像素, 还能获得上下文语义。

AMSFB 模块具体包含 3 个组件: 通道注意力模块(channel attention block, CAB)、空间注意力模块(spatial attention block, SAB) 和多尺度混合模块(multi-scale fusion, MSF)。整体模块采用双路径的设计思想, 首先处理空间特征信息, 通过点卷积降低通道数, 并利用均值池化和最大池化聚合空间特征, 提取图中最显著的特征。然后使用 Sigmoid 激活后的特征映射进行 7×7 卷积, 获得空间注意力权重。接着处理通道特征信息, 分别对池化后的特征进行点卷积, 并通过元素相加获得通道注意力权重。该权重和空间注意力权重进行逐元素相乘, 生成了更精细的空间通道信息特征, 经过多尺度融合, 包含深度可分离卷积(3×3 、 5×5 和 7×7)、批归一化和 ReLU 激活函数, 求和等操作, 最终得到多尺度注意力聚合的特征信息。AMSF 可用公式表示为:

$$AMSF(X) = MSF(SAB(X) \otimes CAB(X)) + X \quad (10)$$

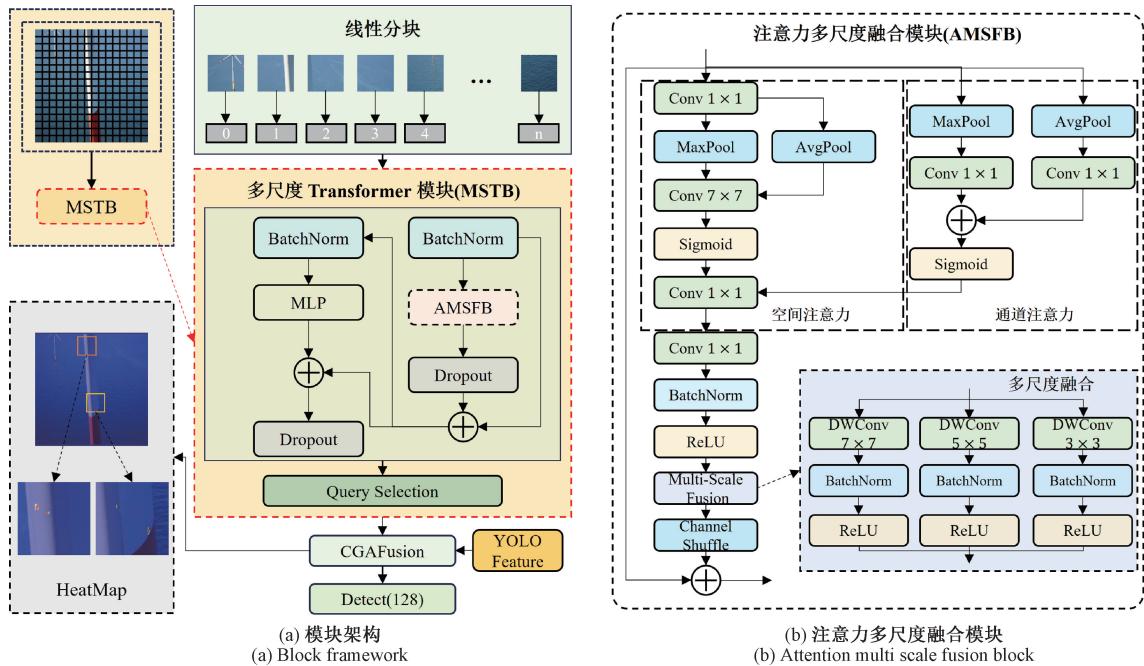


图 3 小目标感知增强网络

Fig. 3 Small object perception enhancement network

$$CAB(X) = \text{Sigmoid}(C_1(P_a(X)) \oplus C_1(P_m(X))) \quad (11)$$

$$SAB(X) = C_7(P_a(C_1(X)) \oplus P_m(C_1(X))) \quad (12)$$

$$MSF(X) = \text{ReLU}(BN(DWC_3(X))) \oplus$$

$$\text{ReLU}(BN(DWC_5(X))) \oplus \text{ReLU}(BN(DWC_7(X))) \quad (13)$$

式中:CAB 和 SAB 分别代指通道注意力块和空间注意力块;MSF 代表多尺度融合过程; P_a 和 P_m 为平均池化和最大池化; C_1 和 C_7 分别为 1×1 和 7×7 的标准卷积; DWC_3 、 DWC_5 和 DWC_7 为 3×3 、 5×5 和 7×7 的深度可分离卷积运算。通过引入多尺度融合机制下的空间 - 通道注意力结构,模型能够有效获取更丰富的特征信息,同时缓解空间通道注意力带来的冗余信息问题,从而显著提升网络对全局特征图信息的理解能力。

随后,该特征送入查询选择模块,查询键为注意力关注的小目标缺陷位置,查询值为用于检测小目标缺陷的特征,通过查询选择操作生成稀疏值特征映射^[49]。查询选择模块以特征信息 X_l 为输入,输出为小目标缺陷权重 $Y_l \in \mathbb{R}^{H \times W}$ 。定义尺寸阈值 s_l 为特征 X_l 的最小回归值,小于预设尺寸阈值的目标对象被分类为小目标,计算其中心位置 (x_o, y_o) 与特征图每个位置间的欧式距离,以此来编码查询选择模块。一旦某个位置的距离小于设定尺寸阈值 s_l ,则将其视为潜在的小目标 k_l 。随后,收集特征图 X_l 上所有潜在小目标 $\{k_l\}$,提取对应特征信息。但潜在小目标特征只能粗略估计小目标缺陷所在位置,还需融

合 YOLO 模型经过多轮卷积提取的深层特征,才能用于模型的进一步优化和小目标缺陷精确定位。

为实现空间维度的一致性,我们采用双线性插值进行两种特征的尺寸对齐。随后,通过上下文引导注意力融合机制(content-guided attention fusion, CGAFusion)^[50] 实现特征语义对齐,并对特征逐元素加权融合,为模型提供更丰富的特征表示。该特征显著增强了小目标的表征能力。为进一步提升模型对小目标的检测性能,在 YOLOv8 原生架构的 3 个检测头基础上,增加一个同结构的小目标检测头,用于模型更专注于小目标特征,且有助于模型以较高的置信度定位同类缺陷,减少因特征表征不足或混淆导致的误检现象。

2.3 改进损失函数

边界框回归(bounding box regression, BBR)其性能高度依赖于所选用的损失函数,而 YOLO 网络采用的 IOU 损失函数可能导致锚框在回归过程中出现不必要的膨胀,减缓收敛速度^[51]。为了解决这一问题,综合考虑锚框和目标框的对预测目标的影响,引入一种目标尺寸自适应惩罚因子的梯度调节函数(powerful IoU, PIoU)^[52],具体形式如式(14)~(16)所示。

$$L_{PIoU} = L_{IOU} + 1 - e^{P^2}, \quad 0 \leq L_{PIoU} \leq 2 \quad (14)$$

$$L_{IOU} = 1 - \frac{I}{U}, \quad 0 < L_{IOU} < 1 \quad (15)$$

$$P = \left(\frac{dw_1}{w_{gt}} + \frac{dw_2}{w_{gt}} + \frac{dh_1}{h_{gt}} + \frac{dh_2}{h_{gt}} \right) / 4 \quad (16)$$

式中: w_{gt} 和 h_{gt} 分别为锚框的宽和高; dw_1 和 dh_1 为目标框距离边界的距离; dw_2 和 dh_2 为锚框距离边界的距离。PIOU 原理如图 4 所示。

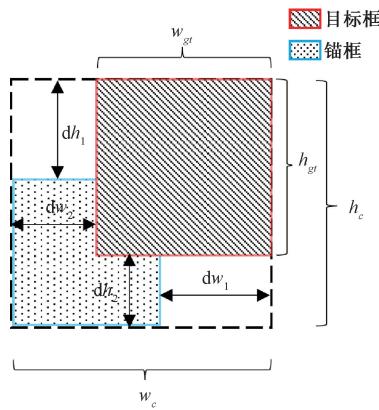


图 4 PIOUS 损失函数原理

Fig. 4 PIOUS loss function principle

此外,针对目标检测类别不平衡问题,Li 等^[53]设计了分布焦点损失函数(distribution focal loss, DFL),促使预测值趋近标签 y 。然而,处理风机叶片图像时发现由于目标与背景之间的严重不平衡,以及随着标签概率降低导致网络对困难样本的学习能力减弱问题,我们进一步提出了自适应分布焦点损失函数(adaptive distribution focal loss, ADFL)。该方法设置阈值 $t \in [0,1]$,当预测概率大于此阈值时($p_i > t$),维持 DFL 的计算不变;反之,则根据具体情况调整计算方式。ADFL 将标准 Focal Loss 的 γ 替换为动态调整参数 $-\ln(p_i)$,究其原因是考虑到随着预测概率的上升, γ 将逐渐趋近于 0。在网络训练的后期,为了确保对困难样本的关注度,采用指数平滑技术调整标签 y 的预测概率,并利用自适应机制来调整损失权重,使模型更专注于叶片缺陷特征。综合上述公式,ADFL 为:

$$DFL(p_i, p_{i+1}) = -((y_{i+1} - y)\log(p_i) + (y - y_i)\log(p_{i+1})) \quad (17)$$

$$p_i = \frac{y_{i+1} - y}{y_{i+1} - y_i} \quad (18)$$

$$\hat{y} = \sum_{j=0}^n p_j y_j = p_i y_i + p_{i+1} y_{i+1} = \frac{y_{i+1} - y}{y_{i+1} - y_i} y_i + \frac{y - y_i}{y_{i+1} - y_i} y_{i+1} = y \quad (19)$$

$$ADFL(p_i, p_{i+1}) = \begin{cases} -((y_{i+1} - y)\log(p_i) + (y - y_i)\log(p_{i+1})), & p_i > t \\ -(\lambda - p_i)^{-\ln(p_i)} \log(p_i), & p_i \leq t \end{cases} \quad (20)$$

式中: $\lambda > 1$; 正样本 y_{i+1} 和 y_i 的概率大小关系为 $y_i \leq y \leq y_{i+1}$

$y_{i+1}; p_i$ 是全局最小值达到的最优状态,通过扩大标签的概率分布,实现回归目标无限接近标签。将 PIOUS 损失(式(14))和 ADFL(式(20))相结合可得 ADPIOU,即:

$$L_{ADPIOU} = L_{PIOU} + ADFL(p_i, p_{i+1}) \quad (21)$$

这种综合损失函数集成了 ADFL 和 PIOUS 两种损失函数的优势,能够在风机叶片缺陷数据集上实现更快速且准确的边界框预测,显著提升模型的整体性能。

3 实验验证

3.1 数据集与实验平台

本文使用经纬 M300 RTK 无人机搭载禅思 H30 云台相机,于非雨天(包括晴天、阴天等正常天气)条件下对某风电场风机叶片进行航拍,获得原始图像共 1 006 张,原始分辨率为 6 000×4 000。原始数据集按训练、验证和测试划分,比例为 7:2:1。为兼顾计算资源和图像保真度,在保证原始宽高比的情况下,将图像统一缩放至 1 600×1 600,并采用 Letterbox 边缘填充策略,以灰度值 114 填充边缘区域,确保张量维度统一。在缩放的基础上进一步实施图像增强,包括水平翻转、垂直翻转和 Mosaic 增强等方法,以提升模型对不同视角及光照条件下缺陷检测的泛化能力。

根据现场经验将缺陷划分为 7 个类别,分别是表面掉漆(peeling paint, Pp),麻面(surface voids, Sv),表面划痕(scratches and gouges, Sg),表面污染(contamination, Con),前缘腐蚀(erosion, Er),前缘保护膜损坏(leading edge protective film damage, Lepfd)和前后缘开裂(leading and trailing edge crack, Ltec)。所有图片均采用 labelImg 标注,共包含标注缺陷 2 953 个。单类缺陷的数量和形态分布如图 5、6 所示。

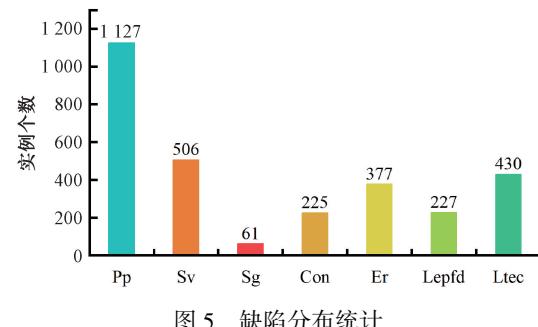


图 5 缺陷分布统计

Fig. 5 Defect distribution statistics

根据图 5,表面划痕的样本量显著少于其余缺陷,这表明数据集中存在类别不平衡的问题。由图 6 可知,7 类缺陷仅麻面和前缘保护膜损坏的缺陷形态较为相似,其余缺陷的形态和尺寸均存在差异,导致缺陷特征学习困难。特别是表面划痕、麻面和前缘保护膜损坏等

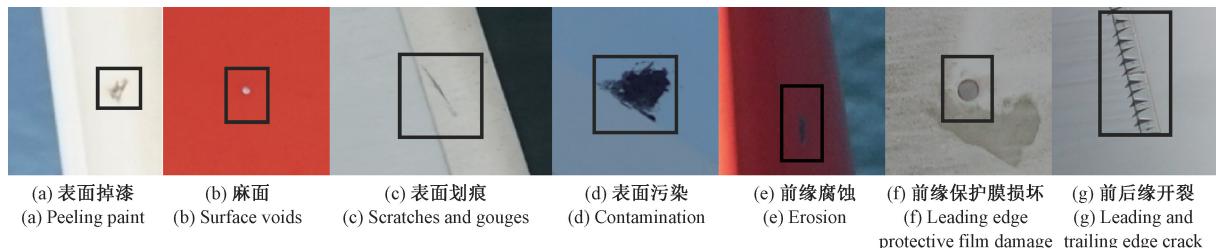


图 6 缺陷类别

Fig. 6 Defect class

小目标缺陷像素尺寸分布为 20 pixels×20 pixels 至 100 pixels×100 pixels, 在本实验的无人机图像采集条件下对应真实物理尺寸约为 0.2 cm×0.2 cm 至 1 cm×1 cm, 在相同分辨率的图片中, 最易出现漏检情况。

为了证明本文所设计模型能解决上述数据集问题, 搭建实验平台, 采用 Windows10 操作系统, GPU 为 NVIDIA 3090 24.0 GB, 编译器为 Python 3.8, 深度学习框架为 Pytorch 2.1.0, 设置模型在该平台运行的超参数如表 1 所示。

表 1 超参数设置

Table 1 Hyperparameter setting

参数	值
Epochs	200
Batch_size	4
Image_size	1 600
Learning_rate	0.01
Momentum	0.9
Optimizer	Adam

3.2 评价指标

根据风机叶片缺陷的检测需求, 采用每秒帧数(frames per second, FPS), 浮点运算量(floating-point operations per second, FLOPS)及模型参数量(parameters)对模型检测速度和部署能力进行评价, 采用准确率(precision, P), 召回率(recall, R)和平均预测精度(mean average precision, mAP)对模型检测精度进行评估。

$$P = \frac{TP}{TP + FP} \quad (22)$$

$$R = \frac{TP}{TP + FN} \quad (23)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n \int_0^1 P[R(i)] dR \quad (24)$$

其中, 真阳性(true positives, TP)为模型预测并正确预测的正样本数量; 假阳性(false positives, FP)表示模型预测但预测错误的正样本数量; 真阴性(true negatives,

TN)表示模型预测的假样本结果与真值一致的情况的数量; 而假阴性(false negatives, FN)表示模型预测假样本结果但与事实不符的数量; n 为缺陷类别的数量。

3.3 损失函数对比

为了验证 ADPIOU 对模型性能的提升, 在相同实验条件下, 统计 ADPIOU 和 IOU 在 200 轮训练过程中的损失变化, 结果如图 7 所示。

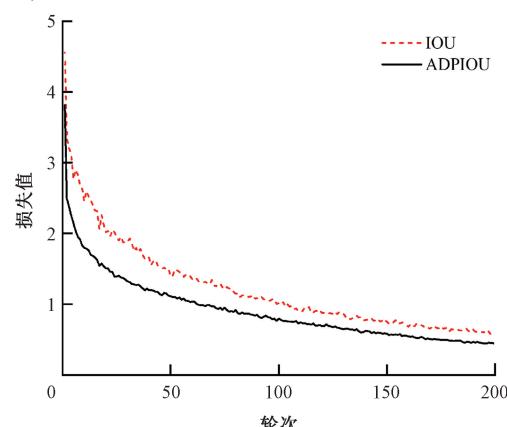


图 7 损失函数对比

Fig. 7 Loss function comparison

由图 7 可知, APIOU 损失函数相比较 IOU 损失函数, 在相同轮次下展现出更快地下降速度和更低的损失值, 从而实现模型更快的收敛。

3.4 实验结果

参照 Ultralytics 官方提供的 YOLOv8 预训练权重, 涵盖微型(YOLOv8n)、小型(YOLOv8s)和超大型(YOLOv8x)。在实验条件与初始参数保持一致的情况下进行训练, 对比结果如表 2 所示。

由表 2 的 3 个预训练模型实验结果可知, YOLOv8n 由于模型参数量最少, 导致平均预测精度最低, YOLOv8x 的平均预测精度最高但模型参数量最大。而 YOLOv8s 模型的 mAP 为 0.681, 相比较 YOLOv8n 模型在增加少量模型参数的同时提高了 0.089 的平均预测精度。类似地, 对比 YOLOv8x 模型, YOLOv8s 模型在参数量上减少 57.1 M 的同时, 精度仅降低 0.033。

表2 对比实验结果

Table 2 Comparative experimental results

模型	P	R	mAP	GFLOPs/ G	FPS	Parameters/ M
YOLOv8n	0.554	0.562	0.592	8.2	25	3.2
YOLOv8s	0.741	0.585	0.681	28.7	11	11.1
YOLOv8x	0.761	0.602	0.714	258.2	8	68.2
YOLOv9s	0.714	0.595	0.665	26.7	15	7.2
YOLOv11s	0.682	0.581	0.643	21.5	14	9.4
RT-DETR ^[30]	0.724	0.538	0.633	42.1	18	52.1
本文	0.825	0.683	0.815	34.9	14	12.2

为了比较 YOLO 系列迭代版本在本数据集的适配性,本实验继续选取同量级小模型 YOLOv8s 模型, YOLOv9s 模型和 YOLOv11s 模型进行对比。结果表明, YOLOv8s 模型的平均预测精度最高,相较于 YOLOv9s 和 YOLOv11s 分别增加了 0.016 和 0.038。YOLOv9s 模型的参数量最少,较 YOLOv8s 降低了 3.9 M,且推理速度略高于 YOLOv8s。YOLOv11s 的 GFLOPs 计算量属于 3 个模型中最低,但在优先考虑平均预测精度的条件下,确定基线模型为 YOLOv8s。

表 2 中进一步对比了单阶段网络实时检测 Transformer 网络 (real time detection Transformer, RT-DETR) 和本文所设计网络。RT-DETR 采用 Transformer 架构提取图像特征,通过解耦尺度内交互和跨尺度融合来处理多尺度特征,能有效地理解图像全局特征关系^[30],也具有较好的推理速度,可达到 18 fps。但 RT-DETR 网络对缺陷的平均精度欠佳,原因在于小目标信息在提取过程中被背景干扰。本文所设计的小目标感知增强的风机叶片缺陷检测网络平均预测精度为 0.815,对比基线网络的平均预测精度提升了 0.134,参数量仅增加了 1.1 M,且推理速度可达到 YOLOv11s 水平,表明该模型可有效满足缺陷检测任务对于高准确率的要求。

为进一步全面评估 YOLOv8s 模型和本文所设计网络在各类缺陷上的检测性能,本文统计了二者在 7 类缺陷上的精度分布情况,如图 8 所示。所设计网络的 7 种缺陷检测精度全部优于基线网络,特别是麻面缺陷在基线网络时的检测精度为 0.331,使用改进网络后提升了 0.47。原因是 YOLOv8s 模型很难处理单图内数量多的小缺陷,容易造成误检和漏检,而改进后的网络进行了缺陷粗定位,能降低误检的概率。前缘保护膜损坏和前后缘开裂的精度分别达到了 0.924 和 0.932,说明该改进网络更适用于这两个缺陷的检测。图 8 中展示的其余 4 类缺陷检测精度,改进网络相对于 YOLOv8s 也有不同程度的提升,证明了改进网络具有更强的分类和定位能力。

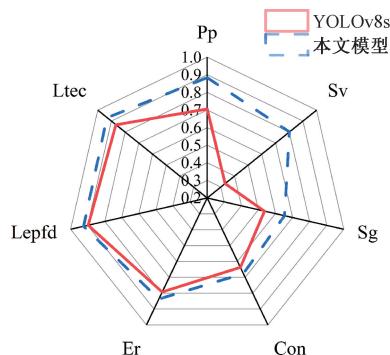


图 8 缺陷精度分布

Fig. 8 Defect accuracy distribution

所设计网络虽然提升了风机叶片缺陷检测的平均精度,但未能解释每个模块对网络精度提升的贡献,还需实验验证和分析所设计模块的有效性。为此,在相同实验条件下,使用同一风机叶片缺陷数据集进行消融实验。模型 1 将主干网络中的 C2f 模块替换为 DCSBlock;模型 2 在模型 1 的基础上新增了 SOPEN,并引入注意力多尺度聚合模块。模型 3 在模型 2 基础上将 IOU 替换为 ADPIOU,构建的模型均采用 3.3 节的评价指标进行评估,实验结果如表 3 所示。

表3 消融实验结果

Table 3 Ablation experimental results

模型	P	R	mAP	GFLOPs/G	Parameters/M
1	0.817	0.583	0.727	27.4	10.6
2	0.809	0.652	0.788	34.9	12.2
3	0.825	0.683	0.815	34.9	12.2

从表 3 的实验结果可知,增加 DCSBlock 的模型 1 能够提取更丰富的多维特征信息,相比基线模型的平均预测精度提升了 0.046。同时,该模块通过重构计算简化了卷积操作,降低了模型 0.5 M 参数量和 0.3 GFLOPs 计算量,但在减少误检和漏检方面仍存在不足。为此,引入了 SOPEN 对潜在的小目标进行预判,并结合浅层与深层特征进行融合,相比基线模型提升了 0.107 的平均预测精度。最后,针对模型中存在的类别不平衡问题,采用 ADPIOU 损失函数,增强了模型对少样本缺陷的关注度,相比基线模型提升 6.4 GFLOPs 的情况下,平均预测精度提升了 0.134,准确率和召回率分别提升了 0.064 和 0.081。随后,将缺陷测试图片送至训练完成的模型内进行检测,结果如图 9 所示。

图 9 左栏为原图检测结果,右栏为原图像中对应缺陷位置的裁切图。图 9(b)-①展示了麻面缺陷的检测结果,该类缺陷像素极少,导致传统方法出现误检的情况,

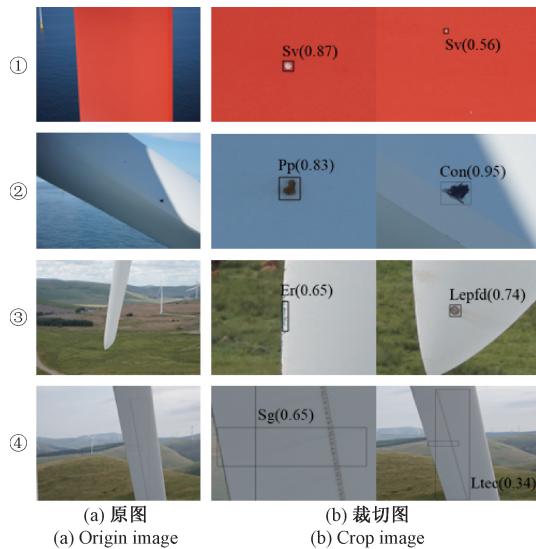


图 9 改进模型叶片缺陷检测效果

Fig. 9 Improved model leaf defect detection effect

采用改进模型可检测出大部分该类缺陷。图 9(b)-②包含了表面掉漆和表面污染的缺陷,两类缺陷的边界清晰,均能被网络以高置信度检测出。图 9(b)-③则包含了叶片前缘存在的腐蚀缺陷和保护膜损坏问题,其中保护膜损失和麻面缺陷在形态上较为类似,但网络仍然能准确分类两类缺陷。图 9(b)-④展示了叶片后缘划痕和开裂的缺陷,且存在缺陷重叠部分,改进的模型却能准确定位两类缺陷的位置。由上述检测结果表明,本文所设计模型面对形态复杂多变的缺陷时,能实现准确检测。在此基础上,选用两张包含多个缺陷的同尺寸叶片图像,分别用基线网络和改进模型进行推理,结果如图 10 所示。

图 10(a) 图中共标注了 4 处表面缺陷。采用 YOLOv8s 模型仅能检测出其中 3 个较为明显的缺陷,且检测结果的置信度仅为 0.1 左右,存在明显的漏检和置信度偏低问题;而本文提出的改进网络则能准确识别全部 4 处缺陷,且置信度相较于 YOLOv8s 有显著提升。

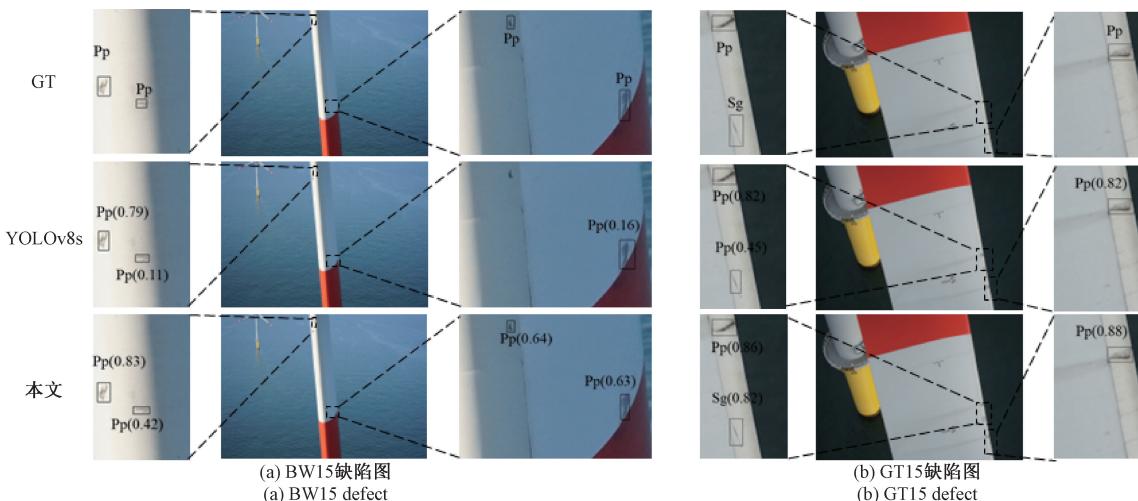


图 10 缺陷检测效果对比

Fig. 10 Comparison of defect testing results

图 10(b) 中包含 2 处表面掉漆缺陷和 1 处表面划痕缺陷,YOLOv8s 和改进网络均能精准确定缺陷位置,但 YOLOv8s 将表面划痕缺陷误检为表面掉漆,而改进网络则有效避免了此类误检现象出现。

4 结 论

为实现风力发电机风机叶片小缺陷的精准检测,保证风力设备的安全高效运行,本文提出一种小目标感知增强的深度学习网络结构。该方法在主干网络中采用动态通道空间卷积替代传统卷积操作,在保证特征表达能力的同时降低了模型复杂度;此外,引入小目标感知增

强网络提高对高分辨率图像多尺度特征的感知能力,显著提升了小目标缺陷的检测精度;最后,引入自适应分布交并比损失函数缓解类别不平衡问题,加快了模型收敛速度。实验结果表明,所提方法在风机叶片缺陷检测任务中相较于主流算法 RT-DETR 及 YOLOv8,具有更优的性能表现,平均检测精度达到 0.815,检测速度为 14 fps,基本满足工程应用中对准确性和实时性的双重需求。

目前方法主要针对叶片表面可见缺陷的识别,仍存在一定局限性。未来将探索射线、声发射等无损检测技术与深度学习技术融合的新范式,构建适用于叶片内部结构缺陷的智能检测框架,进一步推动风电设备智能运维的发展。

参考文献

- [1] 汤占军, 张朝杰, 王健, 等. 基于改进 YOLOv7 的风机叶片缺陷检测研究[J/OL]. 北京航空航天大学学报, 1-15[2025-08-25].
- TANG ZH J, ZHANG CH J, WANG J, et al. Based on improved YOLOv7 fan blades defect detection research [J/OL]. Journal of Beijing University of Aeronautics and Astronautics, 1-15[2025-08-25].
- [2] 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 wind turbine blade surface defect detection based on UAV aerial photography [J]. Chinese Journal of Scientific Instrument, 2024, 45(10): 1-25.
- [3] GALLEGUILLOS C, ZORRILLA A, JIMENEZ A, et al. Thermographic non-destructive inspection of wind turbine blades using unmanned aerial systems [J]. Plastics, Rubber and Composites, 2015, 44(3): 98-103.
- [4] LIU P F, XU D, LI J G, et al. Damage mode identification of composite wind turbine blade under accelerated fatigue loads using acoustic emission and machine learning [J]. Structural Health Monitoring-an International Journal, 2020, 19(4): 1092-1103.
- [5] MUÑOZ C Q G, JIMÉNEZ A A, MÁRQUEZ F P G. Wavelet transforms and pattern recognition on ultrasonic guided waves for frozen surface state diagnosis [J]. Renewable Energy, 2018, 116: 42-54.
- [6] LIU Z P, ZHANG L, CARRASCO J. Vibration analysis for large-scale wind turbine blade bearing fault detection with an empirical wavelet thresholding method [J]. Renewable Energy, 2020, 146: 99-110.
- [7] LI ZH, HAIGH A, SOUTIS C, et al. Microwaves sensor for wind turbine blade inspection[J]. Applied Composite Materials, 2017, 24(2): 495-512.
- [8] 周求湛, 牟岩, 武慧南, 等. 基于 RBVS 和 CBCNN 的风机叶片故障检测和分类方法[J/OL]. 吉林大学学报(工学版), 1-11[2025-08-25].
- ZHOU Q ZH, MOU Y, WU H N, et al. Fault detection and classification method for wind turbine blades based on RBVS and CBCNN [J/OL]. Journal of Jilin University (Engineering and Technology Edition), 1-11[2025-08-25].
- [9] WANG Y N, YOSHIHASHI R, KAWAKAMI R, et al. Unsupervised anomaly detection with compact deep features for wind turbine blade images taken by a drone [J]. IPSJ Transactions on Computer Vision and Applications, 2019, 11(1): 3.
- [10] YANG X Y, ZHANG Y F, LYU W, 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.
- [11] DENG L W, GUO Y G, CHAI B R. Defect detection on a wind turbine blade based on digital image processing [J]. Processes, 2021, 9(8): 1452.
- [12] MEMARI M, SHAKYA P, SHEKARAMIZ M, et al. Review on the advancements in wind turbine blade inspection: Integrating drone and deep learning technologies for enhanced defect detection [J]. IEEE Access, 2024, 12: 33236-33282.
- [13] 朱佳伟, 文传博. 基于改进 SSD 的风机叶片缺陷检测[J]. 复合材料科学与工程, 2022(3): 38-44.
- ZHU J W, WEN CH B. Defect detection of wind turbine blades based on improved SSD [J]. Science and Engineering of Composite Materials, 2022(3): 38-44.
- [14] QIU Z F, WANG SH X, ZENG ZH X, et al. Automatic visual defects inspection of wind turbine blades via YOLO-based small object detection approach [J]. Journal of Electronic Imaging, 2019, 28(4): 043023.
- [15] 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, 2016: 779-788.
- [16] RAN X K, ZHANG SH, WANG H T, et al. An improved algorithm for wind turbine blade defect detection [J]. IEEE Access, 2022, 10: 122171-122181.
- [17] YU J F, HE Y Z, LIU H, et al. An improved U-Net model for infrared image segmentation of wind turbine blade [J]. IEEE Sensors Journal, 2023, 23(2): 1318-1327.
- [18] HANG X Y, ZHU X X, GAO X X, 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.
- [19] 祁雷, 李宁, 梁伟, 等. 基于注意力机制的 U-Net 叶

- 片缺陷图像分割 [J]. 中国安全科学学报, 2024, 34(5): 139-146.
- QI L, LI N, LIANG W, et al. U-Net blade defect image segmentation based on attention mechanism [J]. Chinese Journal of Safety Science, 2024, 34(5): 139-146.
- [20] ZHANG SH CH, HE Y Z, GU Y F, et al. UAV based defect detection and fault diagnosis for static and rotating wind turbine blade: A review [J]. Nondestructive Testing and Evaluation, 2025, 40(4): 1691-1729.
- [21] LU Q H, LIN J M, LUO L F, et al. A supervised approach for automated surface defect detection in ceramic tile quality control [J]. Advanced Engineering Informatics, 2022, 53: 101692.
- [22] HOU X Q, LIU M Q, ZHANG S L, et al. Canet: Contextual information and spatial attention based network for detecting small defects in manufacturing industry [J]. Pattern Recognition, 2023, 140: 109558.
- [23] GIRSHICK R. Fast R-CNN [J]. ArXiv preprint arXiv: 1504.08083, 2015.
- [24] LI R X, YU J Y, LI F, et al. Automatic bridge crack detection using Unmanned aerial vehicle and Faster R-CNN [J]. Construction and Building Materials, 2023, 362: 129659.
- [25] XU X Y, ZHAO M, SHI P X, et al. Crack detection and comparison study based on Faster R-CNN and Mask R-CNN [J]. Sensors, 2022, 22(3): 1215.
- [26] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. Computer Vision-ECCV 2016, 2016: 21-37.
- [27] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection [J]. ArXiv preprint arXiv:2004.10934, 2020.
- [28] LU X C, JI J, XING ZH Q, et al. Attention and feature fusion SSD for remote sensing object detection [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-9.
- [29] 应俊, 刘迅, 曾学仁, 等. 基于 SSD 算法优化的风机叶片缺陷检测研究与应用 [J]. 浙江电力, 2021, 40(8): 47-52.
- YING J, LIU X, ZENG X R, et al. Research and application of wind turbine blade defect detection based on SSD algorithm optimization [J]. Zhejiang Electric Power, 2021, 40(8): 47-52.
- [30] ZHAO Y, LYU W Y, XU SH L, et al. DETRs beat YOLOs on real-time object detection [C]. 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 16965-16974.
- [31] WANG G, CHEN Y F, AN P, et al. UAV-YOLOv8: A small-object-detection model based on improved YOLOv8 for UAV aerial photography scenarios [J]. Sensors, 2023, 23(16): 7190.
- [32] TIAN ZH, SHEN CH H, CHEN H, et al. FCOS: A simple and strong anchor-free object detector [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(4): 1922-1933.
- [33] LI D J, JIANG CH H, LIANG T L. REDef-DETR: Real-time and efficient DETR for industrial surface defect detection [J]. Measurement Science and Technology, 2024, 35(10): 105411.
- [34] HOANH N, PHAM T V. Focus-attention approach in optimizing DETR for object detection from high-resolution images [J]. Knowledge-Based Systems, 2024, 296: 111939.
- [35] GAO M F, YU R CH, LI ANG, et al. Dynamic zoom-in network for fast object detection in large images [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 6926-6935.
- [36] DONG ZH P, WANG M, WANG Y L, et al. Object detection in high resolution remote sensing imagery based on convolutional neural networks with suitable object scale features [J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 58(3): 2104-2114.
- [37] JIANG L J, YUAN B X, DU J W, et al. MFFSODNet: Multi-scale feature fusion small object detection network for UAV aerial images [J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-14.
- [38] 童小钟, 魏俊宇, 苏绍璟, 等. 融合注意力和多尺度特征的典型水面小目标检测 [J]. 仪器仪表学报, 2023, 44(1): 212-222.
- TONG X ZH, WEI J Y, SU SH J, et al. Typical small target detection on water surfaces fusing attention and multi-scale features [J]. Chinese Journal of Scientific Instrument, 2023, 44(1): 212-222.
- [39] LI K, ZHONG X, HAN Y. A high-performance small target defect detection method for PCB boards based on a novel YOLO-DFA algorithm [J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 1-12.
- [40] 王天洋, 刘路, 王太勇, 等. 基于改进 YOLOv8s 的轻

- 量级 PCB 缺陷检测算法 [J]. 电子测量与仪器学报, 2025, 39(3): 44-52.
- WANG T Y, LIU L, WANG T Y, et al. A lightweight PCB defect detection algorithm based on improved YOLOv8s [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(3): 44-52.
- [41] MIAO Q, WANG T, WANG R. Intelligent factory vehicle detection algorithm based on improved YOLOv8 [J]. Instrumentation, 2025, 12(2): 60-70.
- [42] CHEN Y P, DAI X Y, LIU M CH, et al. Dynamic convolution: Attention over convolution kernels [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11027-11036.
- [43] LI CH, ZHOU AO J, YAO AN B. Omni-dimensional dynamic convolution [J]. ArXiv preprint arXiv: 2209.07947, 2022.
- [44] CHEN J, WANG X J, GUO Z CH, et al. Dynamic region-aware convolution [C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 8060-8069.
- [45] MATHE S, PIRINEN A, SMINCHISESCU C. Reinforcement learning for visual object detection [C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition, 2016: 2894-2902.
- [46] 曾勇杰, 范必双, 杨涯文, 等. 改进 YOLOv8 算法在风机叶片缺陷检测上的应用 [J]. 电子测量与仪器学报, 2024, 38(8): 26-35.
- ZENG Y J, FAN B SH, YANG Y W, et al. Application of improved YOLOv8 algorithm for wind turbine blade defect detection [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(8): 26-35.
- [47] GOHAR I, HALIMI A, SEE J, et al. Slice-aided defect detection in ultra high-resolution wind turbine blade images [J]. Machines, 2023, 11(10): 953.
- [48] CHEN Z X, HE Z W, LU ZH M. DEA-Net: Single image dehazing based on detail-enhanced convolution and content-guided attention [J]. IEEE Transactions on Image Processing, 2024, 33: 1002-1015.
- [49] PAN X R, YE T ZH, XIA ZH F, et al. Slide-Transformer: Hierarchical vision Transformer with local self-attention [C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 2082-2091.
- [50] RAHMAN M M, MUNIR M, MARCULESCU R. EMCAD: Efficient multi-scale convolutional attention decoding for medical image segmentation [C]. 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 11769-11779.
- [51] GEVORGYAN Z. SIoU loss: More powerful learning for bounding box regression [J]. ArXiv preprint arXiv: 2205.12740, 2022.
- [52] LIU C, WANG K G, LI Q, et al. Powerful-IoU: More straightforward and faster bounding box regression loss with a nonmonotonic focusing mechanism [J]. Neural Networks, 2024, 170: 276-284.
- [53] LI X, LYU CH Q, WANG W H, et al. Generalized focal loss: Towards efficient representation learning for dense object detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(3): 3139-3153.

作者简介



张泽辰,2019 年于湖北汽车工业学院获得学士学位,2023 年于安徽工业大学获得硕士学位,目前于华南理工大学攻读博士学位,主要研究方向为复杂工业场景的视觉检测。

E-mail:zhangzch@pcl.ac.cn

Zhang Zechen received his B. Sc. degree from Hubei University of Automotive Technology in 2019, and M. Sc. degree from Anhui University of Technology in 2023. He is currently pursuing his Ph. D. degree at South China University of Technology. His main research interests include visual inspection in industrial complex scenarios.



姚顺春,2011 年于华南理工大学获得电站系统及其控制专业博士学位。现为华南理工大学电力学院教授,博士生导师,主要研究方向为面向能源清洁低碳安全高效利用的智能传感和在线监测。

E-mail:epscyao@scut.edu.cn

Yao Shunchun received his Ph. D. degree in Power Station Systems and Their Control from South China University of Technology in 2011. He is currently a professor and a Ph. D. supervisor at the School of Electric Power, South China University of Technology. His main research interests include intelligent sensing and online monitoring for clean, low-carbon, safe and efficient utilization of energy.



梁晓俊,2012 年于清华大学获得工程力学和航空航天学士学位,2017 年获得宾夕法尼亚大学机械工程和应用力学博士学位。现为鹏城实验室副研究员,主要研究方向包括工业复杂系统建模与分析、工业人工智能技术。

E-mail:liangxj@pcl.ac.cn

Liang Xiaojun received his B. Sc. degree in Engineering Mechanics and Aerospace Engineering from Tsinghua University in 2012, and his Ph. D. degree in Mechanical Engineering and Applied Mechanics from the University of Pennsylvania in 2017. He is currently an associate researcher at Peng Cheng Laboratory. His main research interests include modeling and analysis of industrial complex systems and industrial artificial intelligence technologies.



袁宝义,1995 年于武汉水利电力大学获得学士学位,现为中国能源建设集团国际工程有限公司高级工程师,主要研究方向为风电、光伏等领域的关键技术研究。

E-mail:yuanbaoyi@ceec.net.cn。

Yuan Baoyi received his B. Sc. degree from Wuhan University of Hydraulic and Electric Engineering in 1995. He is currently a senior engineer at China Energy Engineering Group International Engineering Co., Ltd. His main research interests include key technology studies in the fields of wind power, photovoltaic power, etc.



张超波(通信作者),2017 年和 2020 年于香港科技大学获得土木工程硕士和博士学位。现为鹏城实验室助理研究员,主要研究方向为包括智能传感,大数据分析,深度学习和工业应用的计算机视觉。

E-mail:zhangchb@pcl.ac.cn

Zhang Chaobo (Corresponding author) received his M. Sc. and Ph. D. degrees in Civil Engineering both from the Hong Kong University of Science and Technology in 2017 and 2020, respectively. He is currently a research associate at Peng Cheng Laboratory. His main research interests include intelligent sensing, big data analysis, deep learning, and industrial applications.