

基于改进 YOLOv8 的风机桨叶缺陷检测算法^{*}

李冰 张易牧 魏乐涛 王月 翟永杰

(华北电力大学自动化系 保定 071003)

摘要: 叶片作为风力发电机组的重要部件,容易受到自然环境的影响,导致出现侵蚀、裂纹、胶衣脱落等损伤,从而影响风力发电效率和机组的安全运行。针对复杂环境下风机桨叶缺陷检测精度较低的问题,提出了一种改进 YOLOv8 的风机桨叶缺陷检测算法。通过对骨干特征提取网络中的单一模块 SPPF 融入 LSKA 注意力机制,以增强网络对于重要特征的关注度,提高模型的性能;其次,Neck 部分采用加权双向特征金字塔 Bi-FPN 结构,并使用 FasterBlock 改进 C2f 模块,提出了 Bi-YOLOv8-faster 轻量级网络结构,增强模型多尺度特征融合能力,提高小目标检测精度;最后,采用辅助边框计算损失的 Inner-IoU 方法对损失函数进行优化,提高模型缺陷检测的准确率和泛化能力。通过对风机桨叶图像进行缺陷检测实验,结果表明,所提方法对缺陷检测的精确率提升了 7.3%、mAP50 提升了 3.3%、参数量降低了 27%。

关键词: 风机桨叶;YOLOv8;注意力机制;缺陷检测;Inner-IoU

中图分类号: TN911.73;TP391.4 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Fan blade defect detection algorithm based on improved YOLOv8

Li Bing Zhang Yimu Wei Letao Wang Yue Zhai Yongjie

(Department of Automation, North China Electric Power University, Baoding 071003, China)

Abstract: As an important component of wind turbines, blades are easily affected by the natural environment, leading to damage such as erosion, cracks, and detachment of rubber coats, thereby affecting the efficiency of wind power generation and the safe operation of the unit. A modified YOLOv8 fan blade defect detection algorithm is proposed to address the issue of low accuracy in detecting blade defects in complex environments. The single module SPPF in the backbone feature extraction network is integrated into the LSKA attention mechanism to enhance the network's attention to important features and improve the performance of the model; Secondly, the Neck section adopts a weighted bidirectional feature pyramid Bi-FPN structure and use FasterBlock to improve the C2f module. The Bi-YOLOv8-faster lightweight network structure is proposed to enhance the multi-scale feature fusion ability of the model and improve the accuracy of small target detection; Finally, the Inner-IoU method, which assists in calculating the loss of bounding boxes, is used to optimize the loss function and improve the accuracy and generalization ability of the model's defect detection. Through the experiment of defect detection on the image of fan blades, the results show that the proposed method improves the accuracy rate of defect detection by 7.3%, mAP50 by 3.3%, and reduces the number of parameters by 27%.

Keywords: fan blades; YOLOv8; attention mechanism; defect detection; Inner-IoU

0 引言

可再生能源的风能因其环保、清洁、低碳而备受全球关注,推动了风力发电技术的快速发展和风电机组装机规模的持续扩大。随着双碳目标的提出,风能发电在我国清洁

能源体系中扮演关键角色^[1]。风机桨叶在风能发电中不仅担任着将风能转化为机械能的重要能量转换角色,而且还是风机的主要负载部分,对整个风机的安全运行至关重要。然而,由于户外环境复杂多样,导致风机桨叶表面出现侵蚀、裂纹、胶衣脱落等损伤缺陷,影响机组的发电效率,甚至

收稿日期:2024-04-18

^{*} 基金项目:国家自然科学基金面上项目(62373151)、国家自然科学基金联合项目(U21A20486)、中央高校基本科研业务费项目(2023JC006)、河北省自然科学基金(F2020502009, F2021502008)项目资助

危害风机的安全和使用寿命^[2]。

传统风电机组叶片缺陷采用人工巡检方式,存在劳动强度大、效率低、主观性强以及危险性高等问题^[3]。因此,实现对叶片缺陷的实时、高效和准确检测已成为风机叶片缺陷识别的迫切需求。随着卷积神经网络的发展、无人机技术的进步以及 GPU 算力的提升,无人机航拍与目标检测技术被广泛应用于风机桨叶的缺陷检测^[4]。现阶段目标检测算法可以归为两大类,一类是将图像输入模型,直接返回目标的边界锚框、位置、类别信息的单步检测算法,如 RetinaNet 算法^[5]、SSD 算法^[6]和 YOLO 系列算法^[7-10]。另一类是先定位物体区域,再对区域进行分类的两步检测算法,主要有 R-CNN 系列^[11-13]。目前,各国学者针对风机桨叶的缺陷检测和检测算法的优化进行了深入研究。Zhang 等^[14]通过选择多个卷积核对 ResNet-18 残差结构的主分支进行特征提取,加入池化层和 Aadm、Sgdm 和 Rmsprop 优化算法,提高了风机检测模型的鲁棒性和检测能力。张超等^[15]提出了一种改进 Mask RCNN 的风机叶片缺陷检测方法,使用 ResNet-50 结合 FPN 网络的方法提升了风机缺陷的检测效果。曲忠侃等^[16]设计了一种基于风机缺陷图片数据增广的 Faster R-CNN 胶衣脱落缺陷图像多点检测系统,取得了良好的检测效果。

YOLO 系列算法因其处理小目标能力强、扩展性和适应性强而得到了快速的发展,算法的优化方法也日益多样化。主要包括网络结构的优化、引入注意力机制、改进损失函数等。武宇平等^[17]在 YOLOv3-Tiny 中采用跨越式特征联合网络结构和引入 Inception 模块结构,提高了桨叶缺陷的检测精度。高文俊等^[18]将 YOLOv4 原有的特征提取网络更换为 GhostNet 特征提取网络,轻量化桨叶检测模型的同时又保持了良好的检测精度。郑启山等^[19]提出一种由 YOLOv5s 作为基准模型进行改进的的风机叶片缺陷检测方法。通过替换骨干网络部分中的快速空间金字塔池化 SPPF 结构和引入卷积注意力机制 CBAM 模块加强来提高模型的检测精度。李冰等^[20]提出了一种 HSCA-YOLOv7 的风电机组叶片缺陷检测算法,解决风机桨叶图像缺陷尺度不一的问题。苏佳等^[21]通过在 YOLOv5 模型中设计一种多尺度特征融合机制,从而提升对小目标的检测效果。付锦焱等^[22]提出了一种改进小目标检测算法 CA-YOLOv8,通过嵌入聚合能力模块 CAM 和改进 C2f 模块,提升检测目标多尺度细节特征的获取能力。王铮帅等^[23]为解决复杂环境中检测精度低的问题,以 YOLOv5 为基准模型,加入 Scoring module 注意力机制来对每个通道的特征打分,过滤低分的特征融合高分的特征,从而提高特征融合能力和检测精度。张福豹等^[24]改进 YOLOv3 算法,增加 FPN 结构特征输出图层,利用 K-means 聚类算法对先验框参数重新聚类,并引入 GIoU 损失函数来提高小目标的缺陷检测精度。张猛等^[25]通过在 YOLOv5 中引入 SimAM 注意机制,提高了模型的特征提取能力。王素珍等^[26]在

YOLOv5s 的网络结构基础上,结合带有大尺寸深度可分离卷积的 DWCSF 模块和 CA 注意力模块设计了 DWCSF-CA 结构替换了原本的骨干网络结构,增加了特征提取时的感受野,在保证检测速度的同时提高了检测精度。

上述研究在模型优化和风机桨叶缺陷识别方面取得了一定进展,但由于风机桨叶航拍图的背景复杂且存在各种画面缺陷干扰,风机桨叶缺陷形态多样、大小不一、在提取检测目标的有效特征时存在较大困难。尤其是航拍风机桨叶图像中的缺陷多为小目标,其特征融合能力较差,限制了目标检测算法对缺陷的全面识别能力^[27]。本文以 YOLOv8n 为基础模型,提出了用于风机桨叶缺陷检测的方法,主要创新包括以下 3 个方面:1)改进骨干网络中 SPPF 模块,通过引入大可分离核注意力机制(large separable kernel attention,LSKA),增强骨干网络特征提取能力,提升网络模型的性能;2)引入了 C2f-faster 模块,并融入 Bi-FPN 特征金字塔网络结构,提出了 Bi-YOLOv8-faster 的结构,使模型轻量化的同时又提升了特征融合能力;3)使用 Inner-IoU 优化原模型的损失函数,进一步提高模型精度和泛化能力。

1 YOLOv8 算法

YOLO(you only look once),是一种目标检测算法,最初由 Joseph Redmon 和 Ali Farhadi 于 2015 年提出。YOLOv8 的核心思想是利用图像的全局信息,在每个网格单元中同时预测物体的边界框和类别^[28]。这种设计使得该算法在实时目标检测应用中表现出色,能够在短时间内完成目标检测任务。其网络结构如图 1 所示。

YOLOv8 模型包括 Input、Backbone、Neck 和 Head 四部分。Input 方面使用了马赛克(Mosaic)数据增强方法,丰富数据集并提升模型泛化能力和鲁棒性。在骨干网络 Backbone 方面,采用跨阶段局部网络 CSP 模块的思想,并使用全新的 C2f 模块替代 YOLOv5 中的 C3 模块,从而实现了进一步的轻量化。其延续了 YOLOv5 中的 SPPF 模块,并对不同尺度的模型进行了精心微调,从而显著提升了模型性能。在特征融合 Neck 方面,通过采用 FPN+PAN 的结构,增强多个尺度上的语义表达和定位能力。Head 部分采用了解耦头结构,将分类和检测头分离。采用 Anchor-Free 方法提升检测速度。在损失函数 Loss 计算方面,YOLOv8 使用 VFL Loss 作为分类损失,使用 CIOU Loss 和 DFL Loss 作为回归损失。本文针对风机桨叶的场景复杂度和提升精度的目的下,采用轻量化的 YOLOv8n 版本为基础进行改进。

2 改进的 YOLOv8 算法结构

2.1 改进后网络模型

改进内容如上文所述,首先在骨干网络中的 SPPF 模块融入 LSKA 注意力机制,增强网络对于重要特征的关注度;其次在 Neck 部分改进了 Bi-FPN 结构并将原有 C2f 模

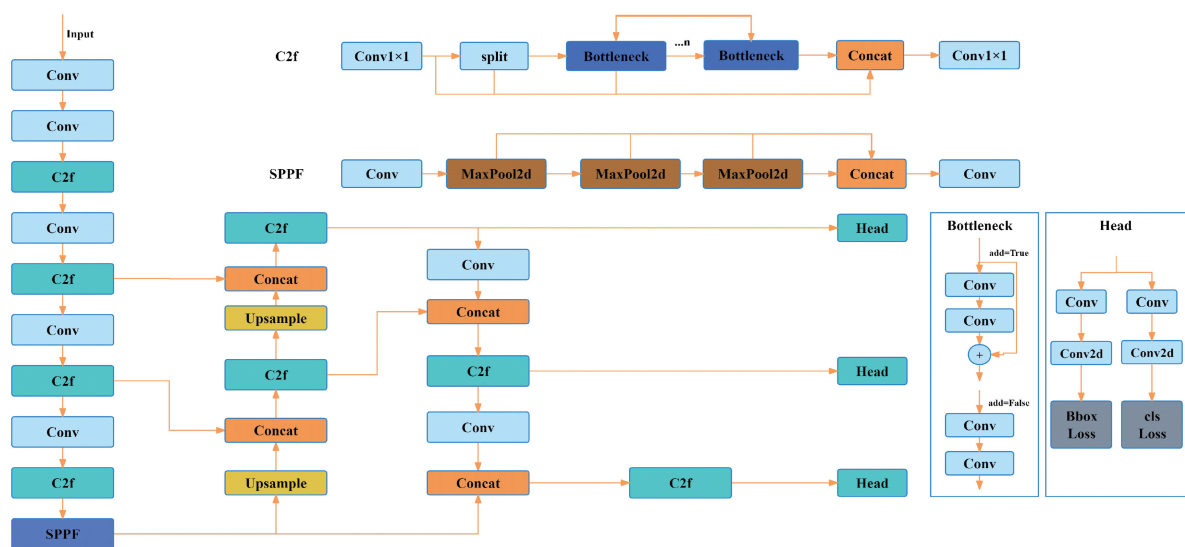


图 1 YOLOv8 网络结构

Fig. 1 YOLOv8 network structure

块升级为 C2f-faster 模块,提出了 Bi-YOLOv8-faster 轻量化结构,增强了模型多尺度特征融合能力;最后,使用

Inner-IoU 优化原网络的损失函数,提高了模型的准确率和检测效率。改进后模型如图 2 所示。

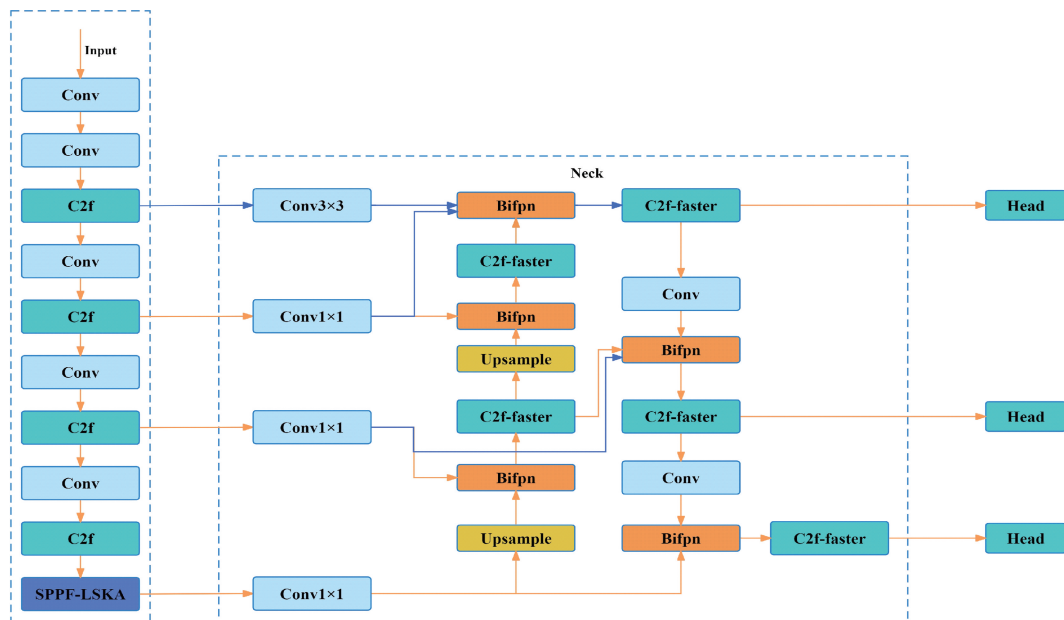


图 2 改进后 YOLOv8 网络结构

Fig. 2 Improved YOLOv8 network structure

2.2 骨干网络的改进

注意力机制在计算机视觉中发挥重要作用,能够使模型聚焦于检测对象的相关特征,从而捕获局部重要信息。风机叶片的航拍图像背景复杂,缺陷尺度不一,为提高模型对风机桨叶缺陷特征的提取能力,在 YOLOv8 骨干网络中的 SPPF 模块融入 LSKA^[29] 注意力机制。LSKA 注意力机制通过利用大且可分离的卷积核以及空间扩张卷积来捕捉图像的广泛上下文信息,生成注意力图,并通过该注

意力图加权原始特征,以此强化网络模型更加关注重要特征,从而提高模型的性能。其过程和结构如图 3 所示。

LSKA 中包含标准深度卷积(DW-Conv)、扩展深度卷积(DW-D-Conv)和 1×1 卷积,首先将一个 $k \times k$ 的卷积分解为 $(2d-1) \times (2d-1)$ 深度卷积、 $k/d \times k/d$ 深度扩张卷积和 1×1 卷积,其次将 2D 的深度卷积核与深度扩张卷积核继续分解为 1D 的水平(横向)卷积核与垂直(纵向)卷积核,最后将分解后的卷积核依次串联。其中 k 表示最大感

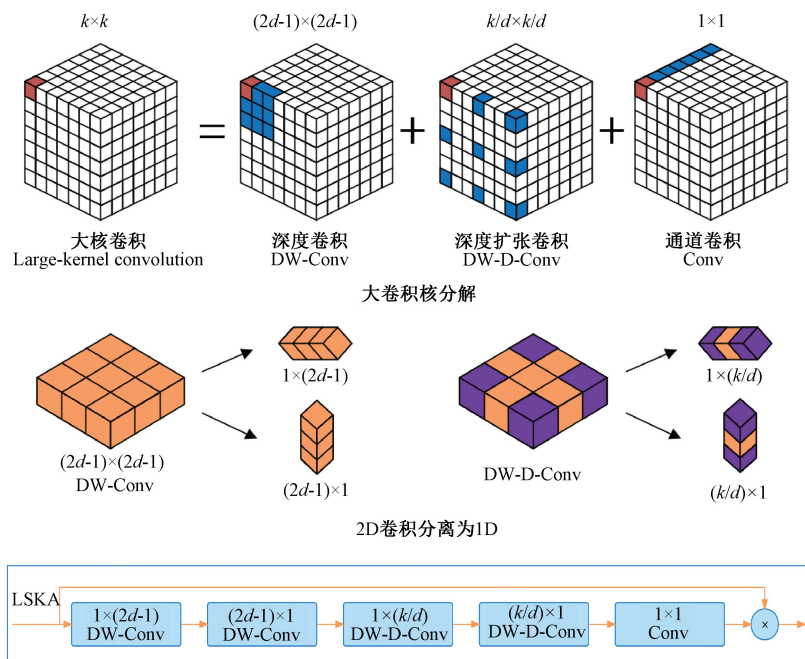


图 3 LSKA 原理与结构

Fig. 3 The principle and structure of LSKA

受野, d 表示扩张率。LSKA 可以即使在更大的卷积核下, 依旧保持较高的计算性能。

在原模型 SPPF 的结构中, 将 LSKA 模块添加在至所有最大池化层(MaxPool2d)操作完成后和第 2 个卷积层(Conv)

之前。输入首先通过一个卷积层, 然后连续通过 3 个最大池化层。这些层的输出被连接(Concat)在一起, 然后整个连接后的输出被送入 LSKA 模块。LSKA 模块处理完毕后, 输出被送入最后一个卷积层。改进后 SPPF 模块如图 4 所示。



图 4 SPPF-LSKA 模块

Fig. 4 SPPF-LSKA module

2.3 Neck 部分的改进

1) Bi-FPN

当前风机桨叶目标检测的主要问题是小目标检测精度不足^[30]。YOLOv8 采用 FPN+PAN 结构, 在特征提取的过程中, 下采样进程被大目标主导, 导致目标区域的小目标特征表示被混淆或模糊化, 从而影响了小目标的检测效果^[31]。为了解决这一问题, 引入更为高效的双向特征金字塔网络 Bi-FPN, 通过加权融合特征和跨尺度连接方式对多尺度特征进行融合, 从而提高检测精度^[32]。

本文在原模型的基础上, 采用 Bi-FPN 的思想, 增加跨尺度的连接方式和特征融合方法, 设计出新的特征融合网络 Bi-YOLOv8, 如图 5 所示。其中蓝色圆圈代表小型目标检测器, 绿色圆圈代表中型目标检测器, 黄色圆圈代表大型目标检测器。

在 Bi-FPN 的基础上, 本文进一步提出了一种新的跨尺度连接方法。这种方法针对第 2 层和第 3 层的原始特征, 分别添加额外的 3×3 和 1×1 常规卷积 Conv, 使得图片尺寸统一为 80×80 , 并相应地调整了匹配通道数, 以便

与相应规模的输出进行连接。此外, 还在输入节点与中间节点之间添加了 1×1 卷积, 并采用加权特征融合方法, 如图 2Neck 部分所示。

2) C2f-faster

Bi-YOLOv8 的 Neck 原模块为 C2f 模块, 由于骨干网络的改进在提升性能的同时一定程度上增加了模型的复杂度。FasterNet^[33] 提出了一种简单快速的卷积方法 PConv, 因此选用 PConv 替换 Conv 来简化模型, 仅对少数几个输入通道应用常规卷积提取特征, 以减少计算和内存的访问。将第 1 个或最后 1 个 c_p 通道看作整个特征图的代表进行计算, 其余的通道保持不变, 其原理如图 6 所示。

FasterNet Block 由 1 个 PConv 层和 2 个 1×1 Conv 层组成, 使用 FasterNet Block 模块改进 C2f 中的 Bottleneck, 得到 C2f-faster 模块, 如图 7 所示。

2.4 损失函数的改进

1) CIoU Loss

YOLOv8 原模型使用 CIoU Loss 作为边界框回归损失函数, 设真实框为 $\vec{B}_{gt} = [x_{gt}, y_{gt}, w_{gt}, h_{gt}]$, 预测框




图 5 YOLOv8、Bi-FPN、Bi-YOLOv8 网络示意图

Fig. 5 YOLOv8, Bi-FPN, Bi-YOLOv8 network schematic diagram




图 6 PConv 原理

Fig. 6 The principle of PConv




图 8 参数定义

Fig. 8 Definition of parameters




图 7 C2f-faster 模块

Fig. 7 C2f-faster module

为 $\vec{B} = [x, y, w, h]$, 其中 x 和 y 表示边界框中心坐标, w 和 h 表示边框尺寸, 原 CIoU Loss 定义式如下:

$$LCIoU = LIoU + \frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g + H_g)^2} + \alpha v \quad (1)$$

$$LIoU = 1 - IoU = 1 - \frac{WiHi}{wh + w_{gthgt} - WiHi} \quad (2)$$

$$\partial = \frac{v}{LIoU + v} \quad (3)$$

$$v = \frac{4}{\pi^2} (\tan^{-1} \frac{w}{h} - \tan^{-1} \frac{w_{gt}}{h_{gt}})^2 \quad (4)$$

式中: $LIoU$ 用于衡量预测框与真实框的重叠度, α 是平衡参数, v 用来衡量长宽比的一致性, 其余参数定义如图 8 所示。

2) Inner-IoU

现有的基于 IoU 的边框回归仍然侧重于通过增加新的损失项来加速收敛, 而忽略了 IoU 损失项本身的局限性。在风机桨叶缺陷检测的实际应用中, 原边框回归过程无法根据不同的检测器和检测任务进行自我调整, 对于密

集小目标或复杂环境多尺度情况下检测效率与准确率较低。为了解决这一问题, 选择使用 Inner-IoU Loss^[34], 它通过辅助边界框来计算 IoU Loss。对于不同的数据集和检测器, 可以通过尺度因子来控制计算损失的辅助边界框的尺度大小。Inner-IoU 的定义如下:

$$b_l^{gt} = x_c^{gt} - \frac{w^{gt} \times ratio}{2}, b_r^{gt} = x_c^{gt} + \frac{w^{gt} \times ratio}{2} \quad (5)$$

$$b_t^{gt} = y_c^{gt} - \frac{h^{gt} \times ratio}{2}, b_b^{gt} = y_c^{gt} + \frac{h^{gt} \times ratio}{2} \quad (6)$$

$$bl = x_c - \frac{w \times ratio}{2}, br = x_c + \frac{w \times ratio}{2} \quad (7)$$

$$bt = y_c - \frac{h \times ratio}{2}, bb = y_c + \frac{h \times ratio}{2} \quad (8)$$

$$inter = (\min(b_r^{gt}, b_r) - \max(b_l^{gt}, b_l)) \times (\min(b_b^{gt}, b_b) - \max(b_t^{gt}, b_t)) \quad (9)$$

$$union = (w^{gt} \times h^{gt}) \times (ratio)^2 + (w \times h) \times (ratio)^2 - inter \quad (10)$$

$$IoU^{inner} = \frac{inter}{union} \quad (11)$$

Inner-IoU Loss 及相关参数如图 9 所示, 变量 $ratio$ 对应的是尺度因子, 通常取范围为 $[0.5, 1.5]$ 。传统的 IoU 计算方法是考虑预测边界框与整体边界框的重叠区域, Inner-IoU 则通过更关注边界框的核心部分来对重叠区域进行更精确的判断。

与 IoU 损失相比, 当 $ratio < 1$, 辅助边框尺寸小于实际边框, 其回归的有效范围小于 IoU 损失, 但其梯度绝对值

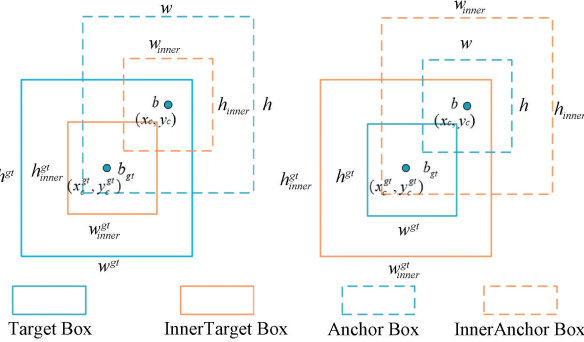


图 9 Inner-IoU 示意图

Fig. 9 Inner-IoU schematic diagram

大于 IoU 损失所得的梯度,能够加速高 IoU 样本的收敛。与之相反,当 $ratio > 1$,较大尺度的辅助边框扩大了回归的有效范围,对于低 IoU 的回归有所增益。对于本文实验数据集, $ratio$ 值设定为 1.2。将 Inner-IoU 应用至原模型损失函数中,定义如式(12)所示。

$$L_{Inner} - CIoU = LCIoU + IoU - IoU^{inner} \quad (12)$$

3 实验结果与分析

3.1 实验数据集

自建数据集为无人机在风电机组现场拍摄采集,主体为风机桨叶且能够清晰展现桨叶缺陷的图片,原图分辨率为 $1\,296 \times 972$ 。本实验的数据集共有 784 张,将其随机按照 7 : 2 : 1 分配训练集验证集和测试集。数据集分为 3 种缺陷,分别为凝胶漆涂层脱落 (gelcoat_off)、裂纹 (cracks) 和表面侵蚀 (surface_erosion)。根据风机数据集的特征及计算资源的限制,图像大小均调整为 640×640 。

3.2 实验环境及参数配置

本实验的实验环境如表 1 所示。

优化器选择动量参数为 0.937 的 SGD, cache 设为 True, epochs 设为 200, batch 设为 16, 最后 10 轮禁用马赛克增强, works 设为 8, 初始学习率 0.01, 最终学习率 0.000 1,

表 1 实验环境配置

Table 1 Experimental environment configuration

配置环境	配置名称(版本)
操作系统	Ubuntu-18.04
CPU	Intel(R) Xeon(R) Gold 6148
GPU	NVIDIA Geforce RTX 3090
编译器	Python-3.10
深度学习框架	Pytorch-2.1.2
加速模块	CUDA-12.2

IOU 值为 0.5。

3.3 实验评价指标

为了验证本文算法的改进效果,从 4 个指标:精确率 P、召回率 R、平均精度 AP、平均精度均值 mAP 来对模型进行评价定义:

$$P = \frac{TP}{TP + FP} \quad (13)$$

$$R = \frac{TP}{TP + FN} \quad (14)$$

$$AP = \int_0^1 P(R) dR \quad (15)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP(i) \quad (16)$$

式中: n 为预测框类别的总数。

3.4 结果对比与分析

1) 不同数量的 C2f-faster 对比结果与分析

改进 Bi-FPN 结构后的 YOLOv8 的 Neck 部分有 5 个 C2f 模块,不同数量的 C2f-faster 模块叠加对网络性能和轻量化程度有不同的影响,为能确定达到最优性能时的改进模块数量,以 YOLOv8n+Bi-FPN 为基准算法,分别改进第 1 个、前 2 个、前 3 个、前 4 个和所有 Bi-FPN-C2f 模块,并将改进不同 C2f-faster 数量的网络性能进行对比,其中模块改进顺序按照网络结构层级顺序进行,实验结果如表 2 所示。

表 2 不同 C2f-faster 数量的模型性能

Table 2 Performance of models with different C2f-faster numbers

方法	P/%	R/%	mAP50/%	mAP50-95/%	GFLOPs	Params/M
YOLOv8n+Bi-FPN	75.4	66.0	73.5	43.1	7.1	1.99
C2f-faster * 1	72.5	67.8	72.7	44.2	7.1	1.98
C2f-faster * 2	73.5	67.9	71.9	43.3	6.9	1.96
C2f-faster * 3	81.9	65.9	74.9	45.4	6.7	1.95
C2f-faster * 4	82.5	65.3	75.2	44.4	6.7	1.92
C2f-faster * 5	84.5	65.8	75.8	45.4	6.7	1.92

由表 2 实验结果表明,随着 C2f-Faster 改进模块数量的提升,模型的轻量化程度也随之提升,这是因为随着

C2f-faster 模块的增多,更多的 PConv 参与运算,减少了冗余计算和内存访问,进而提升模型的性能。综上所述本文

选择改进 5 处 C2f-faster 模块。

2) 消融实验结果与分析

为了验证每个改进点对所提算法的贡献,开展消融实

验。在相同的实验条件下,以 YOLOv8n 为基线模型,在此基础上依次添加各项改进措施,进行一系列消融实验,结果如表 3 所示。

表 3 消融实验结果
Table 3 Results of ablation experiment

实验	AP			P/	R/	mAP50/	mAP50-95/	GFLOPs	Params/ M
	surface_erosion	cracks	gelcoat_off	%	%	%	%		
v8n 原模型	91.1	66.5	83.8	80.4	65.3	73.3	44.1	8.1	3.0
v8n+LSKA	95.0	74.0	87.9	85.6	64.2	74.8	46.0	8.3	3.3
v8n+Neck 改进	82.5	82.8	88.2	84.5	65.8	75.8	45.4	6.7	1.9
v8n+Inner-IoU	89.2	75.6	82.6	82.4	64.2	73.9	44.2	8.1	3.0
v8n+LSKA+Neck 改进	90.2	83.6	88.1	87.3	64.9	74.5	46.1	6.9	2.2
v8n+LSKA+Inner-IoU	86.3	84.5	75.2	82.0	65.4	73.1	45.9	8.3	3.3
v8n+Neck 改进+Inner-IoU	87.0	80.8	77.5	81.7	64.5	74.0	45.4	6.7	1.9
本文模型	93.4	83.8	86.0	87.7	65.4	76.6	46.5	6.9	2.2

由表 3 实验结果对比可知,在骨干网络 SPPF 模块中引入 LSKA 注意力机制,3 类缺陷的识别精度分别提升了 3.9%、7.5%、4.1%,表明该改进能够增强骨干特征提取网络的特征提取能力;使用 Bi-FPN 结构以及改进 C2f-faster 模块改进基线模型的 Neck 部分,虽然表面侵蚀缺陷的识别精度降低了但是整体精确度得到了提升,其余主要指标均有提升且轻量化效果明显,体现新 Neck 结构提升了改进模型的特征融合能力;使用 Inner-IoU 优化原模型损失函数,侵蚀缺陷的识别精度略有下降但整体精度与其他各项指标均稳中有升,进一步提高了模型精度和泛化能力。将 LSKA 与 Neck 改进相结合,模型精度提升了 6.9%;将 LSKA 与 Inner-IoU 两点改进相结合,模型精度提升了 1.6%;将 Neck 改进与 Inner-IoU 两部分改进相结合,模型精度提升了 1.3%,验证了任意两部分改进相结合对模型的精度提升都起到了积极作用。将 3 个改进点相结合,3 类缺陷的识别精度分别提升了 2.5%、17.3%、2.2%,总体精确度提升 7.3%,mAP50 提升 3.3%,参数量降低了 27%,表明本文改进模型达到了提升模型检测性能和轻量化的效果。

3) 泛化能力与鲁棒性评估

泛化能力在目标检测领域可以通过模型对新数据集的识别能力体现,鲁棒性在目标检测领域是指模型在不同场景和不稳定条件下的可靠性,可以通过对复杂背景和不同角度的数据集的识别能力体现。为了评估本文所提算法模型的泛化能力与鲁棒性,选择 50 张未经过训练的风机桨叶缺陷数据集,该数据集包含不同角度和复杂背景的图片,使用本文模型对该数据集进行检测实验,结果如表 4 所示。


由表 4 实验可知,本文模型对于新数据集的识别正确率最高,进而体现本文模型泛化能力和鲁棒性相较于原模

表 4 评估结果

Table 4 Evaluation results

实验	正确识别 张数	识别 正确率/%
v8n 原模型	27	54
v8n+LSKA	35	70
v8n+Neck 改进	33	66
v8n+Inner-IoU	31	62
v8n+LSKA+Neck 改进	37	74
v8n+LSKA+Inner-IoU	29	58
v8n+Neck 改进+Inner-IoU	27	54
本文模型	39	78

型有较大提升,部分识别效果对比展示如图 10 所示,其中正常情况下对比图片如图 10(a)和(b)所示,复杂背景下缺陷检测的对比图片如图 10(c)所示,水平和垂直角度对缺陷检测的对比图片如图 10(d)和(e)所示。






图 10 新数据集识别效果

Fig. 10 The recognition effect of the new dataset

4) 主流算法结果对比与分析

为了进一步验证本文改进模型对风机桨叶缺陷检测的性能优势,与当前经典 YOLO 系列目标检测算法模型进行对比,各模型均采用默认网络参数,本文模型设定的参数则保持相同,实验结果如表 5 所示。

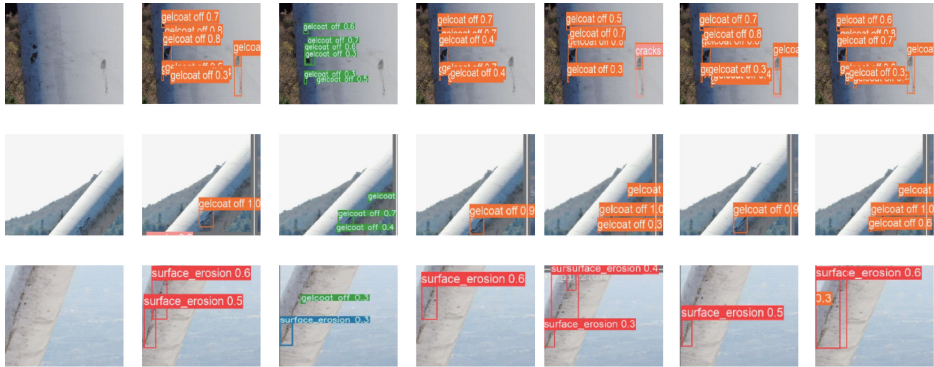
由表 5 实验结果可知,本文所提算法相较于大部分经典的算法,本文改进的算法精确度, mAP50, mAP50-95 都有明显提升。而对于 YOLOv8m,本文算法精确度虽然降低 2.4%,但参数量和 GFLOPs 则远远小于 YOLOv8m。对于 YOLOv8s,本文算法虽然在召回率降低 1.9%,但同样参数量和 GFLOPs 远远小于 YOLOv8s,实际的应用价值和性能上更具优势。对于 YOLOv9,其模型在 GFLOPs 和参数量上都远大于本文模型,但各项指标的运算效果却不如本文算法。综上所述,本文算法能够在提升模型精度的同时轻量化网络,表现出本文算法的实用性和性能的优越性。

为了更直观地体现本文改进算法与其他主流 YOLO 系列算法改进前后检测效果对比,将不同场景的检测结果进行对比展示如图 11(a)~(g)。第一行为小目标密集分布场景,第 2 行与第 3 行为复杂背景场景,对比可知本文算法与其他算法相比漏检率误检率都较低,识别精度高。

表 5 对比实验结果

Table 5 Results of comparative experiments

算法	P/%	R/%	mAP50/%	mAP50-95/%	GFLOPs	Params/M
YOLOv7-tiny	66.8	59.7	59.2	29.6	13.2	6.0
YOLOv7	63.4	66.7	64.9	33.2	105.2	37.2
YOLOv5n	68.3	64.7	67.5	37.0	4.1	1.8
YOLOv5m	66.3	65.0	68.2	36.6	47.9	20.9
YOLOv8n	80.4	65.3	73.3	44.1	8.1	3.0
YOLOv8s	76.0	67.3	74.1	46.8	28.4	11.1
YOLOv8m	90.1	62.1	78.4	47.7	78.7	25.8
YOLOv9	81.1	65.0	75.3	46.9	266.2	60.8
YOLOv10n	68.8	63.5	67.5	36.5	8.2	2.7
YOLOv10m	75.4	63.7	68.6	38.8	63.4	16.5
本文算法	87.7	65.4	76.6	46.5	6.9	2.2






图 11 改进前后检测效果对比

Fig. 11 Comparison of detection performance before and after improvement

4 结 论

风机桨叶航拍图像缺陷检测在电力行业中有着重要的应用价值。为解决现有风机叶片缺陷检测算法对小目标检测精度较低及其所面临的模型环境复杂等现实问题,本文提出了一种改进 YOLOv8 的风机桨叶缺陷检测算法。通过在风机叶片缺陷数据集上进行实验,本文提出的算法相比于 YOLOv8n 基准模型,精确率提升了 7.3%、mAP50 提升了 3.3%、参数量降低了 27%,泛化能力与鲁棒性均得到提升,与其他先进的目标检测算法相比在精度上和速度上均得到了提升,表明本文算法模型的先进性和有效性,实现了更高性能的风机桨叶缺陷检测。但是对于召回率指标,本文提出的改进模型对此并没有较为明显的提升,后续可根据此项不足继续进行研究实验。

参考文献

- [1] 蔡继峰,胡高硕,石浩. 国内外风能资源评估标准研究综述[J]. 风能, 2021(12): 56-63.
CAI J F, HU G SH, SHI H. Review of research on evaluation standards for wind energy resources at home and abroad [J]. Wind Energy, 2021 (12): 56-63.
- [2] 胡让. 风力发电机叶片故障诊断研究及实现[D]. 兰州: 兰州交通大学, 2016.
HU R. Research and implementation of fault diagnosis of wind turbine blades[D]. Lanzhou: Lanzhou Jiaotong University, 2016.
- [3] 贺斌,贾建华,赵峰,等. 无人机在风机叶片检测中的应用[J]. 电工技术, 2019(13): 64-65.
HE B, JIA J H, ZHAO F, et al. Application of UAV in detection of wind turbine blade [J]. Electric Engineering, 2019(13): 64-65.
- [4] 马敏敏,刘昊,高毓欣,等. 基于无人机与人工智能的风机叶片全自主巡检[J]. 电气时代, 2023(2): 44-48.
MA M M, LIU H, GAO Y X, et al. Fully autonomous inspection of wind turbine blades based on drones and artificial intelligence [J]. Electric Age, 2023(2): 44-48.
- [5] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss

for dense object detection [C]. IEEE International Conference on Computer Vision, Venice, 2017: 2980-2988.

- [6] LIU W, ANGELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. European Conference on Computer Vision, 2016: 21-37.
- [7] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, 2016: 779-788.
- [8] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger [C]. IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, 2017: 6517-6525.
- [9] REDMON J, FARHADI A. YOLOv3: An incremental improvement [J]. ArXiv preprint arXiv: 1804.02767, 2018.
- [10] BOCHKOVSKIY A, WANG C, LIAO H M. YOLOv4: Optimal speed and accuracy of object detection [J]. ArXiv preprint arXiv: 2004.10934, 2020.
- [11] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. IEEE Conference on Computer Vision and Pattern Recognition, Columbus, 2014: 580-587.
- [12] GIRSHICK R. Fast R-CNN [C]. IEEE International Conference on Computer Vision, Santiago, 2015: 1440-1448.
- [13] REN SH Q, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39: 1137-1149.
- [14] ZHANG H F, WANG F. Fault identification of fan blade based on improved ResNet-18 [J]. Journal of Physics: Conference Series, 2022, 2221 (1). DOI: 10.1088/1742-6596/2221/1/012046.
- [15] 张超,文文博. 基于改进 Mask R-CNN 的风机叶片缺陷检测[J]. 可再生能源, 2020, 38(9): 1181-1186.

- ZHANG CH, WEN CH B. Defect detection of wind turbine blades based on improved Mask R-CNN[J]. Renewable Energy Resources, 2020, 38 (9): 1181-1186.
- [16] 曲忠侃,李学峰,李凤俊,等. 基于 Faster R-CNN 的风机叶片缺陷图像多点检测系统设计[J]. 电子设计工程, 2021, 29(4): 57-61.
- QU ZH K, LI X F, LI F J, et al. Design of fan blade defect image multi-point detection system based on Faster R-CNN [J]. Electronic Design Engineering, 2021, 29(4): 57-61.
- [17] 武宇平,刘海旭,吴劲芳,等. 改进的 YOLOv3-Tiny 网络在风机叶片损伤检测中的应用[J]. 河北工业科技, 2021, 38(5): 401-408.
- WU Y P, LIU H X, WU J F, et al. Application of improved YOLOv3-Tiny network in fan blade damage detection[J]. Hebei Journal of Industrial Science and Technology, 2021, 38(5): 401-408.
- [18] 高文俊,张海峰. 基于改进 YOLOv4 风机叶片缺陷检测方法[J]. 农业装备与车辆工程, 2023, 61(8): 94-98.
- GAO W J, ZHANG H F. Wind turbine blade defect detection based on improved YOLOv4 [J]. Agricultural Equipment & Vehicle Engineering, 2023, 61(8): 94-98.
- [19] 郑启山,朱少红,陈长红,等. 基于改进 YOLOv5s 的风机叶片缺陷检测方法[J]. 信息与电脑(理论版), 2023, 35(16): 14-18.
- ZHENG Q SH, ZHU SH H, CHEN CH H, et al. A defect detection method for fan blades based on improved YOLOv5s [J]. Information & Computer, 2023, 35(16): 14-18.
- [20] 李冰,白云山,赵宽,等. 基于 HSCA-YOLOv7 的风电机组叶片表面缺陷检测算法[J]. 中国电力, 2023, 56(10): 43-52.
- LI B, BAI Y SH, ZHAO K, et al. Surface defect detection algorithm for wind turbine blades based on HSCA-YOLOv7[J]. Electric Power, 2023, 56(10): 43-52.
- [21] 苏佳,秦一畅,贾泽,等. 基于 ATO-YOLO 的小目标检测算法[J]. 计算机工程与应用, 2024, 60(6): 68-77.
- SU J, QIN Y CH, JIA Z, et al. Small object detection algorithm based on ATO-YOLO [J]. Computer Engineering and Applications, 2024, 60(6): 68-77.
- [22] 付锦焱,张自嘉,孙伟,等. 改进 YOLOv8 的航拍图像小目标检测算法[J]. 计算机工程与应用, 2024, 60(6): 100-109.
- FU J Y, ZHANG Z J, SUN W, et al. Improved YOLOv8 small target detection algorithm in aerial images[J]. Computer Engineering and Applications, 2024, 60(6): 100-109.
- [23] 王铮帅,邱联奎,李迎港. 复杂环境下的 YOLOv5s 烟火检测方法[J]. 电子测量技术, 2023, 46(24): 149-156.
- WANG ZH SH, QIU L K, LI Y G. Smoke and flame detection method with YOLOv5s in complex environment[J]. Electronic Measurement Technology, 2023, 46(24): 149-156.
- [24] 张福豹,吴婷,赵春峰,等. 基于弱光增强与 YOLO 算法的锯链缺陷检测方法[J]. 电子测量技术, 2024, 47(6): 100-108.
- ZHANG F B, WU T, ZHAO CH F, et al. Saw chain defect detection system based on low-light enhancement and YOLO algorithm [J]. Electronic Measurement Technology, 2024, 47(6): 100-108.
- [25] 张猛,尹丽菊,周辉,等. 基于 SimAM-Ada YOLOv5 的太阳能电池表面缺陷检测[J]. 电子测量技术, 2023, 46(22): 17-25.
- ZHANG M, YIN L J, ZHOU H, et al. Surface defect detection of solar cells based on SimAM-Ada YOLOv5 [J]. Electronic Measurement Technology, 2023, 46(22): 17-25.
- [26] 王素珍,吕基岳,邓成禹,等. 基于改进 YOLOv5 的钢铁表面缺陷检测算法[J]. 国外电子测量技术, 2023, 42(10): 43-50.
- WANG S ZH, LYU J Y, DENG CH Y, et al. Improved YOLOv5-based surface defect detection algorithm for steel [J]. Foreign Electronic Measurement Technology, 2023, 42(10): 43-50.
- [27] 张立丽,佟强,刘秀磊. 无人机小目标检测综述[J]. 计算机仿真, 2023, 40(12): 1-7.
- ZHANG L L, TONG Q, LIU X L. Overview of small target detection of UAV [J]. Computer Simulation, 2023, 40(12): 1-7.
- [28] 杨飞帆,李军. 面向自动驾驶的 YOLO 目标检测算法研究综述[J]. 汽车工程师, 2023(11): 1-11.
- YANG F F, LI J. Research review of YOLO target detection algorithm for autopilot [J]. Automotive Engineer, 2023(11): 1-11.
- [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. 1-121352. 15.
- [30] 辛彦,吴国新,左云波. 基于 EfficientDet 的风机叶片缺陷检测方法[J]. 电子测量技术, 2022, 45(5): 124-131.
- XIN Y, WU G X, ZUO Y B. Defect detection method of wind turbine blade based on EfficientDet [J].

- Electronic Measurement Technology, 2022, 45(5): 124-131.
- [31] 程换新, 乔庆元, 骆晓玲, 等. 基于改进 YOLOv8 的无人机航拍图像目标检测算法[J]. 无线电工程, 2024, 54(4): 871-881.
- CHENG H X, QIAO Q Y, LUO X L, et al. Object detection algorithm for UAV aerial image based on improved YOLOv8 [J]. Radio Engineering, 2024, 54(4): 871-881.
- [32] TAN M X, PANG R M, LE Q V. EfficientDet: Scalable and efficient object detection[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Virtual: IEEE, 2020: 10778-10787.
- [33] CHEN J R, KAO S H, HE H, et al. Run, don't walk: Chasing higher flops for faster neural networks [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Vancouver: IEEE, 2023: 12021-12031.
- [34] ZHANG H, XU C, ZHANG S H J. Inner-IoU: More effective intersection over union loss with auxiliary bounding box [J]. ArXiv preprint arXiv:2311.02877, 2023.
- ### 作者简介
- 李冰**, 副教授, 主要研究方向为模式识别与计算机视觉。
E-mail: li_bing_hb@126.com
- 张易牧**, 硕士研究生, 主要研究方向为模式识别与计算机视觉。
E-mail: zhangym991024@126.com
- 魏乐涛**, 硕士研究生, 主要研究方向为模式识别与计算机视觉。
E-mail: wlt13792808712@163.com
- 王月**, 硕士研究生, 主要研究方向为模式识别与计算机视觉。
E-mail: 18963495082@163.com
- 翟永杰**(通信作者), 教授, 主要研究方向为模式识别与计算机视觉。
E-mail: zhaiyongjie@ncepu.edu.cn