

改进 YOLOv11n 的风机叶片缺陷检测算法^{*}王海群 关 美 于海峰 潘 创
(华北理工大学电气工程学院 唐山 063200)

摘 要: 针对风机叶片巡检任务中易受复杂背景环境干扰、目标尺度差异大、类别多样且分布不均等因素导致检测精度低的问题,提出了一种改进 YOLOv11n 的风机叶片缺陷检测算法。首先,创新性地提出了高效多尺度卷积 EMSConv,并对 C3k2 重新设计,使模型高效地捕获输入特征图信息,提升检测准确性;其次,引入大可分离核注意力机制和 Residual-Conv 设计 SPPF_LSKR 模块替换原金字塔池化模块,丰富上下文信息提升模型多尺度特征提取和融合能力;再次,采用重参数共享卷积检测头(RSCD),通过共享参数减少头部参数数量和计算量,提升缺陷检测任务的速度与精度;最后,借鉴 MPDIoU、Inner_IoU、Wise_IoU 的思想,提出了一种损失函数 Inner-Wise-MPDIoU,平衡不同尺度缺陷的检测,加速模型收敛速度。实验结果表明,改进 YOLOv11n 模型 mAP 达到 89.2%,较原算法提升了 2.9%,该结果表明所改进模型可以满足对风机叶片缺陷进行高效、精准检测的需求。

关键词: 风机叶片;YOLOv11n;高效多尺度卷积;重参数共享卷积检测头;注意力机制;损失函数;缺陷检测

中图分类号: TP391.4;TN919.8 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Improve the wind turbine blade defect detection algorithm of YOLOv11n

Wang Haiqun Guan Mei Yu Haifeng Pan Chuang

(School of Electrical Engineering, North China University of Science and Technology, Tangshan 063200, China)

Abstract: In order to solve the problem of low detection precision caused by complex background environment, large target scale difference, various categories and uneven distribution, an improved YOLOv11n defect detection algorithm for fan blades is proposed. Firstly, an efficient multi-scale convolution EMSConv was innovatively proposed, and C3k2 was redesigned to enable the model to efficiently capture the input feature map information and enhance the detection accuracy; secondly, introduce the large separable kernel attention mechanism and Residual-Conv design SPPF_LSKR module to replace the original pyramid pooling module, enrich the context information and improve the multi-scale feature extraction and fusion capabilities of the model; thirdly, the re-parameter shared convolution detection head (RSCD) is adopted to reduce the number of parameters and computational load of the head by sharing parameters, thereby enhancing the speed and accuracy of the defect detection task; finally, a loss function Inner-Wise-MPDIoU is proposed based on the ideas of MPDIoU, Inner_IoU and Wise_IoU, which balances the detection of defects of different scales and accelerate the convergence speed of the model. The results of the experiments indicate that the modified YOLOv11n model attains an mAP value of 89.2%, which is 2.9% higher than that of the original model. The results show that the improved model can meet the needs of efficient and accurate detection of fan blade defects.

Keywords: wind turbine blades; YOLOv11n; efficient multi-scale convolution; re-parameterized shared convolution detection head; attention mechanism; loss function; defect detection

0 引 言

近年来,全球范围内能源供需矛盾加剧,能源危机问题愈发突出。风能作为一种兼具清洁性与再生性的能源类型,其发电利用不仅能缓解能源压力,更能为城市建设与社

会可持续发展提供有力支撑^[1]。风机叶片是风力发电机的核心组成部分,其结构完整性、性能稳定性是保障风力发电系统可靠运行的关键。风机叶片大多安装于偏远山区,如山区、沙漠、海上,长期工作在复杂自然环境中,叶片极易出现裂缝、生锈、变形等缺陷,这些缺陷如果不进行及时维修

将会影响发电效率。因此,定期对风机叶片缺陷进行检测具有重要意义。

传统风机叶片缺陷检测主要依靠人工巡检的方式,该方式存在高空作业风险高、检测效率低、主观性强等局限,为解决这一问题,研究人员基于超声波、振动和传感器等技术提出多种检测方法^[2]。Arcos Jiménez 等^[3]基于超声波无损测试监测系统,通过小波变换进行信号滤波来检测叶片上的泥浆污染。Deng 等^[4]提出了一种基于改进的 LPSO 算法和 log-Gabor 滤波器的自适应滤波器,使用 HOG+SVM 分类器确定风机叶片图像的缺陷类型,该方法可以有效地获取缺陷的特征信息,但特征提取结果会受到滤波角度和带宽的影响,容易造成分类错误和处理时间长等问题。大型化风场的普及使风电机组的检测和维护工作面临极大挑战,随着机器学习技术的发展,基于深度学习的目标检测算法成为各类缺陷检测的主要方法^[5],核心算法主要分为两类:一类是基于候选区域生成的两阶段检测算法;另一类是基于回归思想的单阶段检测算法。两阶段算法的流程为先从输入图像中生成候选区域,再对区域进行目标分类与边界框位置校正。常见的两阶段算法有 R-CNN^[6]、Faster R-CNN^[7]、Mask R-CNN^[8]、Cascade R-CNN^[9]等,它们虽拥有较高的精度和较强的泛化能力,但检测速度较慢,不适合风机叶片的实时检测。相较于两阶段检测算法,YOLO、SSD 等单阶段算法在检测速度上具备

明显优势,这类算法无需单独的区域提议(region proposal)步骤,通过单次网络前向传播即可直接预测图像中各类目标的类别与位置,可以满足风机叶片缺陷检测实时性的需求。Yang 等^[10]提出了基于深度学习的风机叶片多类缺陷检测模型,该模型能自动判断叶片表面是否存在多种缺陷,但该研究未实现对各类缺陷的分类与定位,无法评估缺陷发展态势及严重程度。范晨亮等^[11]提出了一种基于深度学习区域卷积神经网络的风机叶片裂纹检测方法,实现对风机叶片裂纹缺陷的定位,但实际的风机叶片表面存在其他的常见缺陷,包括燃烧、剥落等,该方法无法对风机叶片表面多种缺陷进行检测。以上方法在一定程度上提升了风机叶片的检测性能,但在实际运用中仍然存在挑战。

此外,面对复杂背景干扰、微小尺度缺陷(尺寸<10 mm 且图像表面积<0.5%)时还存在检测精度低和漏检误检的问题。因此,针对上述问题,提出一种改进 YOLOv11n 的风机叶片缺陷检测模型。

1 YOLOv11n 网络结构

YOLOv11 是 2024 年 9 月开源的新一代目标检测框架,包含 n、s、m、l、x 五个版本,各个版本通过调整网络深度和宽度来平衡精度与效率,以满足不同场景的需求。原始 YOLOv11n 模型由主干(Backbone)、颈部(Neck)、头部(Head)网络 3 个部分组成,YOLOv11n 结构如图 1 所示。




图 1 YOLOv11n 结构
Fig.1 Structure of YOLOv11n

相较于 YOLOv8 模型,YOLOv11 利用 C3k2 模块替换 C2f 模块,增强模型特征提取能力;为获得全局特征信

息,并减少计算量,YOLOv11 在空间金字塔池化(spatial pyramid pooling fast, SPPF)模块后边增加 C2PSA 结构,

该结构是在 YOLOv10 中 PSA 结构上进行改进得到的,保留了获取全局特征信息的能力,同时因为采用 CSP 结构,使得计算量进一步下降;颈部网络采用路径聚合网络(path aggregation network, PAN)架构,并集成 C3k2 单元,有效实现多个尺度整合特征,优化了特征传递的效率,使模型在不同尺度的目标检测上都具有出色表现;对分类检测头进行结构优化,新增两个深度可分离卷积层(DWConv),该改进显著减少模型的参数量和计算量,既增强模型的轻量化特性,又维持原有的特征提取性能。

为解决风机叶片缺陷检测任务中存在的问题,对算法进行有针对性的改进。引入高效多尺度卷积(efficient multi-scale conv, EMSConv),解决因叶片缺陷差异大、位置重叠造成的特征提取不完善的问题,并对 C3k2 模块重新设计,将

高效多尺度卷积嵌入 Bottleneck 模块中,增强模型主干特征提取能力。利用 LSKA 注意力机制和残差卷积(Residual-Conv)改进空间金字塔池化模块,将主干中获取的精准化多尺度特征进行融合的同时,丰富上下文信息,使模型更加高效。针对模型参数冗余问题,基于多元化分支块(diverse branch block, DBB)提出重参数共享卷积检测头(rep shared convolutional detection, RSCD),将不同尺度缺陷的检测分支的部分卷积参数共享,减少模型的计算量和参数量;基于 Inner-IoU 辅助边框尺度自适应思想与 Wise-IoUv3 非单调动态梯度调制机制,对 MPDIoU 损失函数进行优化,得到 Inner-Wise-MPDIoU 损失函数,强化模型对目标边界框的精准定位能力,进一步提升模型训练收敛效率,改进后的网络结构如图 2 所示。




图 2 改进 YOLOv11n 结构

Fig. 2 Structure of the improved YOLOv11n

2 改进 YOLOv11n 算法

2.1 构建 C3k2_EMSC 模块

传统网络采用大量标准卷积,易造成提取特征时计算量参数冗余的问题。风机叶片缺陷检测任务具有复杂性和特殊性,高空检测时终端设备计算资源有限,为解决资源受限的问题,MobileNet 模型先采用深度卷积完成空间维度的特征捕捉,再通过逐点卷积(pointwise convolution, PwConv)实现跨通道特征融合,以更少的参数量和计算量实现高效地特征提取。Ghostconv 模型先通过普通卷积从特征图中提取核心特征,降低计算成本,再对每张特征图进行廉价的线性变换,生成与核心特征高度相似的“Ghost

特征”(即冗余特征),Ghost 特征无需增加额外的参数就能补充细节信息,降低卷积层的计算量。本文借鉴 Mobilenetv1, Mobilenetv2 和 Ghostconv 的思想提出一种高效多尺度卷积 EMSConv,网络结构如图 3 所示。

EMSConv 通过引入大小不同的卷积并行操作进行多尺度特征的提取。 1×1 卷积获取输入特征图的通道数,经通道切分(Channel Split)操作将输入特征分为两部分 $\mathbf{Z}_{cheap}$ 和 $\mathbf{Z}_{group}$ 。 $\mathbf{Z}_{cheap}$ 部分直接连接到下一层, $\mathbf{Z}_{group}$ 部分对通道分别输入感受野为 $3 \times 3, 5 \times 5$ 的卷积。EMSConv 模块原理表达式如式(1)~(3)所示。

$$\mathbf{Z}_{group}, \mathbf{Z}_{cheap} = S_{split}(\mathbf{Z}_i) \quad (1)$$

$$\mathbf{Z}_{g1}, \mathbf{Z}_{g2} = S_{split}(\mathbf{Z}_{group}) \quad (2)$$




图 3 EMSConv 模块结构
Fig. 3 EMSConv module structure

$$f_{\text{EMSC}}(\mathbf{Z}_i) = f_1(\text{Concat}(\text{Concat}(f_3(\mathbf{Z}_{g1}), f_5(\mathbf{Z}_{g2})), f_{\text{cheap}})), \quad (3)$$

其中， $\mathbf{Z}_i$ 代表输入特征图；Concat($\bullet$) 代表多个特征图的信息融合操作； f_n 代表卷积核为 $n \times n$ 的卷积操作； $f_{\text{EMSC}}(\bullet)$ 代表输出特征图。

通过分组卷积机制对网络各层特征通道进行针对性特征提取，特征提取过程在各独立特征通道上分别完成，不同通道间的特征信息保持相对独立性，适用于风机叶片缺陷存在的多尺度差异^[12]。最后使用 1×1 的 PwConv 将各组提取的特征信息融合，实现全局信息的交叉融合。因此，EMSCConv 只对特征图的一半通道进行并行卷积操作，有效减少了参数量和计算量，在检测精度 mAP50、mAP50-90 方面均有所提升，具体结果如表 1 所示。

表 1 EMSConv 与 YOLOv11n 对比实验结果
Table 1 Comparative experimental results of EMSConv and YOLOv11n

网络	mAP50	mAP50-90	Params/M	GFLOPs
YOLOv11n	0.863	0.561	6.7	2.86
YOLOv11n+ EMConv	0.872	0.587	6.4	2.49

C3k2 模块主要任务是将不同尺度、不同层级的特征图进行融合，以增强模型提取小目标与模糊特征的能力。针对风机叶片缺陷形状尺寸差异显著、位置重叠的问题，

利用 EMSConv 与 C3k2 中的 Bottleneck 结合，C3k2_ EMSConv 模块结构如图 4 所示。




图 4 C3k2_EMSC 模块
Fig. 4 C3k2_EMSC module

本文使用卷积核为 3×3 和 5×5 的 EMSConv 与 C3k2 模块中的多个 Bottleneck 结合。结合多尺度特征捕捉机制的 C3k2_EMSCConv 模块，通过动态通道切分与跨尺度卷积核并行运算捕获不同尺度缺陷的关键特征，对叶片缺陷的空间分布信息进行精准表征，从而解决传统 C3k2 模块在处理叶片缺陷尺度差异大、背景干扰问题时特征提取不充分的问题，进一步强化了网络对叶片多类型缺陷的细粒度特征提取与跨通道融合能力。

2.2 SPPF_LSKR 模块

SPPF 是一种用于解决卷积神经网络 (convolutional neural networks, CNN) 输入图像特征提取技术，原始 SPPF 使用 3 种不同尺度的池化内核对特征图进行处理。但在风机叶片缺陷检测任务中，目标遮挡是一个常见问题，不同缺陷之间的遮挡会导致局部混合和特征缺失。针对此问题，引入 LSKA 注意力机制，结合多尺度池化弱化背景区域，提高网络特征提取能力，增强对遮挡目标的检测^[13]。基于大核注意力 (large kernel attention, LKA)，如图 5(a) 所示，改进 LSKA^[14] 采用大卷积核分离式操作在增强叶片缺陷特征的表达能力的不增加计算复杂度，提升模型对遮挡目标的检测精度。LSKA 网络结构如图 5(b) 所示，SPPF_LSKA 结构如图 5(c) 所示。

LKA 模块中随着卷积核尺寸的增大深度卷积层的参数量与计算量呈二次方增长，且大感受野易导致局部遮挡细节特征丢失，对风机叶片表面细小裂纹等微尺度缺陷的特征表征能力不足。设计 LSKA 模块，对深度卷积层中的




图 5 改进的 SPPF 结构

Fig. 5 Improved SPPF structure

2D 卷积核进行维度分解,重构为级联的水平 1D 卷积核与垂直 1D 卷积核。通过这一分解策略,有效抑制参数规模与计算复杂度随 LKA 卷积核尺寸增大而产生的二次增长趋势,减少计算资源的消耗,可在保障捕获全局信息的基础上,进一步缓解大感受野易引发的局部遮挡细节特征丢失问题^[15]。LSKA 模块工作原理如式(4)~(7)所示。

$$\mathbf{F} \in \mathbf{R}^{C \times H \times W} \quad (4)$$

$$\begin{cases} \text{Attention} = \text{Conv}_{1 \times 1}(\text{DWDCnv}(\text{DWConv}(\mathbf{F}))) \\ \text{Output} = \text{Attention} \otimes \mathbf{F} \end{cases} \quad (5)$$

$$\text{DWConv}(\mathbf{F}) = \sum_{H,W} \mathbf{W}_{(2d-1) \times 1}^C * (\sum_{H,W} \mathbf{W}_{1 \times \lceil \frac{k}{d} \rceil}^C * \mathbf{F}^C) \quad (6)$$

$$\begin{aligned} & \text{DWDCnv}(\text{DWConv}(\mathbf{F})) = \\ & \sum_{H,W} \mathbf{W}_{1 \times \lceil \frac{k}{d} \rceil}^C * (\sum_{H,W} \mathbf{W}_{1 \times \lceil \frac{k}{d} \rceil}^C \times \bar{\mathbf{Z}}^C) \end{aligned} \quad (7)$$

式(4)中 $\mathbf{F}$ 为给定特征图, C 表示特征图的通道数, H 和 W 分别表示特征图的宽度和高度。LSKA 输出如式(5)所示, Attention 表示注意力图, $\otimes$ 表示逐元素相乘。DWConv 的结果如式(7)所示, DWConv($\mathbf{F}$) 的运算过程如式(6)所示,符号 $*$ 表示卷积操作, DWConv 通过将大小为 $(2d-1) \times 1$ 的卷积核应用于输入特征图 $\mathbf{F}$ 得到深度卷积输出^[16]。式(6)中, DWConv($\mathbf{F}$) 使用尺寸为 $(2d-1) \times 1$ 的卷积核执行深度卷积的结果,通过这一计算过程捕获局部空间信息。式(7)中,膨胀卷积的卷积核大小为 $1 \times \lceil \frac{k}{d} \rceil$,其中 k 是卷积核的感受野, d 为扩张率。

SPPF_LSKA 模块在保留 SPPF 模块多尺度特征融合核心优势的前提下,引入注意力机制动态分配特征图中不

同区域的权重,增强模型对遮挡缺陷细节信息的捕捉能力,优化多尺度遮挡缺陷的特征提取与融合效果,提升风机叶片遮挡缺陷检测的精准度。但经过多次池化操作与分组卷积处理后,特征维度与信息量的变化会导致反向传播过程中梯度不稳,在深层网络中易出现梯度消失或爆炸问题。而残差链接作为深度神经网络中的经典优化策略,能够有效缓解深度网络训练过程中的梯度消失问题,且能够增强网络对原始特征信息的保留能力^[17]。引入 Residual_Conv,结构如图 6(a)所示。

通过构建残差连接通路设计 SPPF_LSKR 模块,使深层网络反向传播时梯度能够通过直接映射路径高效传递,避免梯度在多次卷积与激活操作中持续衰减或异常放大,有效缓解深层网络的梯度消失或爆炸问题,保障模型训练稳定性;同时借助残差结构进一步强化不同尺度缺陷特征的跨层传递与融合,增强对缺陷遮挡部分的提取和融合能力。SPPF_LSKR 网络结构如图 6(b)所示。




图 6 Residual_Conv 和 SPPF_LSKR 模块结构

Fig. 6 Residual_Conv and SPPF_LSKR module structure

2.3 重参数共享卷积检测头(RSCD)

为了解决风机叶片缺陷检测中检测头参数冗余问题,设计轻量化检测头 RSCD, RSCD 通过共享卷积减少参数量,使模型更加轻便。然而风机叶片缺陷检测中包含不同尺度的目标且缺陷形状多样,共享参数可能会限制模型的表达能力,考虑到精度损失可能对风电系统造成严重损害,引入共享可重参数化卷积以获取更多的学习参数并减少参数数量,使模型能够更高效地提取缺陷的共同特征,为模型提供无损的优化方案。

RSCD 由 Conv_GN, Conv2d 和 DBB (diverse branch block) 模块组成,结构如图 7 所示,由于批量归一化(batch

normalization, BN)^[18]受批量大小的影响,本文利用组归一化(group normalization, GN)替代批量归一化。GN 对特征通道分组并在各组内实现稳定的特征预处理。P3、P4、

P5 特征融合部分的输出 3 层特征图分别输入到 3 个 Conv_GN 模块执行维度约简与归一化操作,处理后的特征图进一步传递至共享的多元分支模块。




图 7 RSCD 检测头结构

Fig. 7 Structure of the RSCD detection head

DBB 模块^[19]是 RSCD 检测头的核心组成部分,结构如图 8 所示,该模块通过多个分支,对输入特征进行融合,强化了模型对多尺度目标的适应能力与小目标特征的提取能力。训练过程中,并行部署 1×1 卷积和 $1 \times K$ 卷积、 $K \times 1$ 卷积,并对各分支的输出特征进行动态融合,从而高效捕捉不同尺度的损伤特征。各分支卷积核保持自身原始尺寸,最终加权求和得到特征输出。多分支原理定义如式(8)、(9)所示。

$$\begin{cases} Y_1 = \text{BN}_1(\text{Conv}_{1 \times 1}(x)) \\ Y_2 = \text{BN}_2(\text{Conv}_{k \times k}(\text{BN}_1(\text{Conv}_{1 \times 1}(x)))) \\ Y_3 = \text{BN}_3(\text{AvgPool}(\text{BN}_1(\text{Conv}_{1 \times 1}(x)))) \\ Y_4 = \text{BN}_1(\text{Conv}_{k \times k}(x)) \end{cases} \quad (8)$$

$$O_t = Y_1 + Y_2 + Y_3 + Y_4 \quad (9)$$

式中: Y_1, Y_2, Y_3, Y_4 分别表示图 8 中 4 个分支的输出; O_t 代表训练过程的总输出; x 为训练过程的输入; $\text{Conv}_{1 \times 1}(x)$ 、 $\text{Conv}_{k \times k}(x)$ 分别表示 $1 \times 1, k \times k$ 卷积层的计算公式; BN_1 表示对 4 个分支卷积层的输出结果进行归一化处理; AvgPool 代表平均池化; BN_2 表示对第 2 分支 BN_1 输出的特征通过 $k \times k$ 卷积计算后再次归一化; BN_3 表示对第 3 分支输出的 BN_1 特征通过平均池化操作后再进行归一化^[20]。

推理时,将多分支卷积核等效为单个卷积层,降低计算成本。融合后的特征图通过 3 个分类卷积层(Conv_Cls)和 3 个回归卷积层(Conv_Reg),Conv_Cls 负责输出损伤类别的分类概率分布,Conv_Reg 负责预测目标的边界框回归参数。最后 Scale 层执行特征尺度映射,生成大、中、小 3 个尺度的目标分类结果与精准的尺度位置定位信息。运用 RSCD 检测头使模型更加全面学习缺陷的相关特征,减少模型参数量。




图 8 DBB 模块

Fig. 8 DBB module

2.4 Inner-Wise-MPDIoU 损失函数

目标检测中边界框回归损失函数至关重要, YOLOv11n 模型使用完全交并比(complete intersection over union, CIoU)损失函数进行边界框的回归预测,公式如式(10)~(12)所示。

$$L_{\text{CIoU}} = 1 - \text{IoU} + \frac{p^2(b, b^{\text{gt}})}{c^2} + \alpha\nu \quad (10)$$

$$\alpha = \frac{\nu}{(1 - \text{IoU}) + \nu} \quad (11)$$

$$\nu = \frac{4}{\pi^2} (\arctan \frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{w}{h})^2 \quad (12)$$

式中: L_{CIoU} 代表 CIoU 损失函数, IoU 为预测边界框和真实边界框的交并比; b 为预测边界框中心点坐标; b^{gt} 代表真

实框中心点坐标; c^2 表示两边框最小外接矩形对角线距离的平方; α 为平衡参数; ν 为宽高比差异的惩罚项; w^{gt} 、 h^{gt} 分别表示真实框的宽度和高度; w 、 h 分别为预测框的宽度和高度。由式(12)可知, CIoU 损失函数使用时存在局限性, 当真实框和预测框的宽高相同时, 宽高比的惩罚项 $\nu = 0$, 此时惩罚项失去优化效果, 导致模型检测速度与精度降低。

为解决上述问题, 本文引入 MPDIoU_Loss 改进 CIoU_Loss, MPDIoU^[21] 是一种基于最小点距离的边界框相似性度量, 使损失函数在优化过程中能够更加关注边界框精准定位, 其实现原理如图 9 所示。




图 9 MPDIoU 实现原理

Fig. 9 The implementation principle of MPDIoU

图 9 中 h 和 w 分别为输入图像的高和宽, 绿色框为真实框, 左上角和右下角坐标分别为 (x_1^{gt}, y_1^{gt}) 和 (x_2^{gt}, y_2^{gt}) , 橙黄色框为预测框, 左上角和右下角坐标分别为 (x_1^{prd}, y_1^{prd}) 和 (x_2^{prd}, y_2^{prd}) , d_1 和 d_2 分别代表真实框与检测框左下角和右下角之间的欧式距离^[22]。

为进一步提升模型的收敛速度, 借鉴 Inner_IoU 辅助

边界框原理和 Wise_IoU 动态非单调聚焦机制的思想优化损失函数 MPDIoU_Loss 为 Inner-Wise-MPDIoU 损失函数。Inner-Wise-MPDIoU 计算公式为:

$$L_{\text{Inner-Wise-MPDIoU}} = r \times (L_{\text{MPDIoU}} + \text{IoU} - \text{IoU}^{\text{Inner}}) \quad (13)$$

其中, r 为 Wise-IoU 中的动态聚焦系数, L_{MPDIoU} 为 MPDIoU Loss, IoU 为预测框和真实框之间的交并比, $\text{IoU}^{\text{Inner}}$ 为 Inner-IoU 中辅助框的预测边界框和真实边界框之间的交并比^[23]。

该损失函数融合 Inner-IoU、Wise-IoU、MPDIoU 3 种损失函数的核心优势, 串联各组件的关键功能形成协同效应, 在风机叶片损伤检测数据集上展现出极为出色的性能。Inner-Wise-MPDIoU 不仅收敛速度更优, 还能实现更低的损失函数值。并且该改进损失函数无需对网络结构进行任何调整, 不会额外增加计算负担, 是一种零成本的性能提升方案。

3 实验结果与数据分析

3.1 数据集介绍

风机叶片的质量对风力发电系统稳定运行至关重要, 细微的损伤也可能引发难以预料事故, 加之缺陷类型难以明确划分, 至今仍未出现针对风机叶片缺陷检测的专用数据集^[24]。

本文使用的叶片数据集是由工作人员利用无人机巡检时拍摄的高清图像, 包含多种复杂巡检作业场景, 共含 4 467 张图片, 为防止因图像数量较少导致模型在实验过程中出现过拟合现象, 通过调整亮度、水平旋转、引入掩码等方法对数据集中图像进行数据增强, 最终得到 8 869 张图片, 按照 7:2:1 的比例将数据集随机划分为训练集、验证集和测试集, 缺陷类别为 7 种, 分别是燃烧、裂缝、污垢、变形、油渍、剥落、生锈, 缺陷类别如图 10 所示。



图 10 缺陷类别

Fig. 10 Defect categories

实验环境配置:操作系统为 Ubuntu 20.04,深度学习框架为 Pytorch 1.11.0,Python 版本 3.8,CUDA 版本 11.8,训练 CPU 为 14 vCPU Intel(R) Xeon(R) Gold 6330 CPU@2.00 GHz。所有模型的训练、测试和验证过程使用的超参数均保持一致,以保证实验可靠性,实验具体参数如表 2 所示。

表 2 实验具体参数

Table 2 Specific parameters of the experiment

参数	设置值
优化器	SGD
输入图像大小	640×640
学习率	0.001
epoch	300
批处理大小	32

3.2 评价指标

针对改进 YOLOv11n 网络结构,本文选取准确率 (precision, P)、召回率 (recall, R)、平均精度均值 (mean average precision, mAP)、浮点计算量 (GFLOPs) 和模型参数量 (Params) 作为评价指标^[25]。 P 、 R 、mAP 的公式如式(14)~(16)所示。

$$P = \frac{TP}{TP + FP}$$

(14)

$$R = \frac{TP}{TP + FN}$$

(15)

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

(16)

式中:TP 为预测正确的正样本数量;FP 为预测错误的正样本数量;FN 为预测错误的负样本数量; AP_i 表示第 i 类目标的平均精度值; k 代表检测任务中所有目标类别的总数量。

3.3 空间金字塔池化模块对比实验

为验证 SPPF_LSKR 模块对风机叶片缺陷检测的有效性,在 YOLOv11n 模型上进行,选取 EMA、CPCA、MPCA、AFGC、LSKA 注意力机制进行对比,分别引入 SPPF 模块的相同位置。结果如表 3 所示。

由表 3 可知,LSKA 模块相比其他注意力机制表现最佳,在不增加算法参数量、计算量的同时,mAP50 较基线提升 0.6%,引入残差链接后 mAP50 较基线提升 1.0%,参数量略有增加,但计算量下降了 0.4 G,相较于其他模块在风机叶片缺陷检测中更有优势,验证了设计的 SPPF_LSKR 模块对风机叶片缺陷检测任务的有效性。

3.4 损失函数对比

不同回归损失函数对目标检测性能影响不同,为验证不同损失函数对模型检测性能的影响,在相同的实验环境下,将 CIoU、EIoU、SIoU、ShapeIoU、MPDIoU、Inner-IoU、Wise-MPDIoU、Inner-Wise-MPDIoU 损失函数分别引入到

表 3 空间金字塔池化模块对比试验

Table 3 Comparative experiment of spatial pyramid pooling modules

方法	mAP50	FLOPs/G	Params/M
无	0.863	6.7	2.86
SPPF_EMA	0.855	6.7	2.63
SPPF_CPCA	0.830	7.1	3.04
SPPF_MPCA	0.857	6.5	3.90
SPPF_AFGC	0.861	6.4	2.85
SPPF_LSKA	0.869	6.7	2.86
SPPF_LSKR	0.873	6.3	2.88

模型中进行对比实验,综合评估各类损失函数对模型性能的影响,实验结果如表 4 所示。

表 4 损失函数对比实验

Table 4 Comparative experiments of loss functions

损失函数	P	R	mAP50
CIoU	0.871	0.818	0.863
EIoU	0.878	0.794	0.862
SIoU	0.896	0.801	0.876
ShapeIoU	0.865	0.824	0.875
MPDIoU	0.885	0.834	0.869
Inner-IoU	0.879	0.829	0.873
Wise-MPDIoU	0.898	0.831	0.871
Inner-Wise-MPDIoU	0.891	0.820	0.878

根据表 4 实验数据显示,分别引入不同损失函数 CIoU、EIoU、SIoU、ShapeIoU、MPDIoU、Inner-IoU、Wise-MPDIoU、Inner-Wise-MPDIoU 后,EIoU 的 mAP50 降低 0.1%,其他损失函数的检测性能均有提高。MPDIoU 损失函数在 mAP50 方面提升了 0.6%,准确率提升了 1.4%,召回率提升了 1.6%,Inner-IoU 在准确率、召回率、mAP50 方面分别提升了 0.8%、1.1%、1.0%。Wise-MPDIoU 准确率、召回率、mAP50 方面分别提升了 2.7%、1.3%、0.8%。基于 MPDIoU、Wise_IoU、Inner_IoU 思想设计的 Inner-Wise-MPDIoU 检测效果最优,在准确率和 mAP50 方面较原始模型分别提升了 2%、1.5%。该损失函数融合 MPDIoU、Wise_IoU、Inner_IoU 3 种损失函数的优势,具有更快的收敛速度,更小的损失函数值,在风机叶片数据集上表现优异。

3.5 消融实验

为了深度分析各个改进模块对 YOLOv11n 网络性能的影响,进行消融实验,实验结果如表 5 所示,“√”代表每次实验引入的模块。

实验 1 为原始 YOLOv11n 模型。实验 2 引入重参数共享卷积检测头 RSCD,mAP50 较原始模型增加了 1%,参

表5 消融实验
Table 5 Ablation experiment

序号	RSCD	SPPF_LSKR	EMSCConv	Inner_Wise_MPDIoU	P	R	mAP50	FLOPs/G	Params/M
1					0.871	0.818	0.863	6.7	2.86
2	✓				0.862	0.831	0.873	6.8	2.83
3		✓			0.883	0.822	0.873	6.7	2.86
4			✓		0.880	0.812	0.872	6.4	2.49
5				✓	0.875	0.802	0.878	6.7	2.86
6	✓	✓			0.878	0.875	0.881	6.9	2.88
7	✓	✓	✓		0.886	0.879	0.887	6.6	2.52
8	✓	✓	✓	✓	0.888	0.883	0.892	6.6	2.52

数量降低了 0.03 M。实验 3 为改善缺陷遮挡的引入 SPPF_LSKR 模块,加强网络对遮挡缺陷的学习能力和多尺度特征融合能力,检测精度相较于原始模型提升了 1.0%。实验 4 是对模型中的标准卷积替换为 EMSCConv,并将 C3k2 与 EMSCConv 进行融合,与原始模型相比检测精度提升了 0.9%,计算量和参数量分别降低了 0.3 G 和 0.37 M。实验 5 为引入损失函数 Inner_Wise_MPDIoU,相较于其他引入模块 Inner_Wise_MPDIoU 损失函数提升效果最好,较原始模型提升了 1.5%。实验 6 为同时引入 RSCD 检测头和 SPPF_LSKR 模块,mAP50 较原始模型提升了 1.8%。实验 7 在实验 6 的基础上引入 EMSCConv,mAP50 较原始模型提升了 2.4%,同时兼顾检测速度和检测精度。实验 8 为引入所有改进模块 mAP50 提升了 2.9%,计算量下降了 0.1 G,参数量下降了 0.34 M。以上实验效果说明各个改进模块对原始模型均有所提升。

后 3 组实验采用依次累加各个改进模块的原则进一步评估模型检测性能,说明模块之间可以融合的很好,综合改进可以满足风机叶片缺陷检测要求。

3.6 对比实验

实验部分将改进后的算法与主流单阶段算法(如 TOOD、YOLOX、YOLOv11n、YOLOv10n、YOLOv9t、YOLOv8、YOLOv7-tiny、YOLOv5、YOLOv3)、主流双阶段算法(Faster-RCNN、Mask-RCNN、Cascade_RCNN)进行对比,实验结果如表 6 所示。

实验结果表明,改进算法与两阶段算法 Faster-RCNN、Mask-RCNN、Cascade_RCNN 相比在 mAP50 方面分别提升了 6.8%、2.8%、5.5%,在参数量和计算量方面均大幅降低;与 TOOD 算法相比在检测精度、计算量、参数量方面均有明显提升;与 YOLO 系列算法相比,改进算法在 MAP50 方面分别提升了 1.4%、2.9%、4.8%、7.5%、4.5%、18.3%、5.5%、1.3%,在计算量方面小于除了 YOLOv5 以外的其他算法,在参数量方面小于除 YOLOv5、YOLOv9t 以外的其他算法;与文献[12]所提出的改进算法相比,在 mAP50 方面提升了 3.6%,计算量降低了 1.9 G,参数量下降了 1.99 M,检测性能更优,适用于

表6 对比实验

Table 6 Comparative experiments


算法	mAP50	Params/M	GFLOPs
Faster-RCNN	0.824	41.15	206.69
Mask-RCNN	0.864	44.17	260.14
Cascade_RCNN	0.837	66.32	233.50
TOOD	0.842	30.89	183.40
YOLOX	0.878	5.21	18.80
YOLOv11n	0.863	2.86	6.70
YOLOv10n	0.844	2.71	8.40
YOLOv9t	0.817	1.77	6.70
YOLOv8	0.847	2.69	6.90
YOLOv7-tiny	0.709	6.28	13.10
YOLOv5	0.837	2.19	5.90
YOLOv3	0.879	103.70	281.20
文献[12]	0.856	4.51	8.20
本研究	0.892	2.52	6.30

风机叶片缺陷检测任务。

综上所述,与原算法及各类目标检测算法对比,本文改进 YOLOv11n 检测算法,在保持较低参数量和计算量的同时检测精度最优,整体性能满足风机叶片缺陷检测的需求。

3.7 实验结果可视化分析

为了更加充分地验证改进算法的有效性,选取部分有代表性的图像进行验证。如图 11 所示,图 11(a)为 YOLOv11n 检测效果,图 11(b)为本文所提改进模型检测效果。通过图片对比,可以得出在不同场景的叶片缺陷检测任务中原网络模型存在误检、漏检和检测精度低的问题。与之相比,本文的改进算法不仅具有较高的检测精度,且改善了模型面对复杂背景时的误检、漏检情况,由此可说明,本文的改进算法对尺度大小不同的缺陷具有更强的学习能力,更能满足风机叶片缺陷检测的需求。



(a) YOLOv11n检测图
(a) Detection diagram of YOLOv11n



(b) 改进YOLOv11n检测图
(b) Improve the detection graph of YOLOv11n

图 11 数据集样图

Fig. 11 Sample image of the dataset

4 结 论

本研究针对风机叶片缺陷检测中叶片缺陷形状各异、复杂背景干扰导致误检、漏检以及检测精度低的问题,基于 YOLOv11n 检测算法进行改进,借鉴分组卷积的思想创新性地提出了高效多尺度卷积,并与 C3k2 融合,减少复杂背景的干扰带来的误检、漏检问题,进一步增强模型的特征提取能力;基于 LSKA 注意力机制引入残差卷积链接后引入到空间金字塔池化模块中,丰富上下文信息,使模型多尺度特征融合能力得到提升;针对原模型检测头参数冗余问题,基于 DBB 模块提出了重参数共享卷积检测头 RSCD,通过共享卷积减少参数数量和计算量,提升模型的检测精度与速度;最后,利用 MPDIoU、Inner_IoU、Wise_IoU 对 CIoU 进行优化损失函数为 Inner-Wise-MPDIoU,优化模型的定位精度,加速模型收敛进程。

通过消融实验,验证了各个改进模块的有效性,通过主流算法对比实验表明本文改进算法更有优势,较原始模型相比,在减少参数数量与计算量的同时,mAP50 提高了 2.9%,满足风机叶片缺陷检测实际需求。尽管如此,该模型在检测精度方面仍有提升空间,未来的研究将进一步优化模型结构,在降低参数数量和计算量的同时实现更高的检测精度。

参考文献

[1] 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 on surface defect detection of wind turbine blades based on unmanned aerial vehicle aerial photography[J]. Chinese Journal of Scientific Instrument, 2024,45(10):1-25.

[2] 张泽辰,姚顺春,梁骁俊,等. 基于小目标感知增强的风

机叶片缺陷智能检测[J]. 仪器仪表学报,2025,46(9): 159-172.

ZHANG Z CH, YAO SH CH, LIANG X J, et al. Intelligent detection of wind turbine blade defects based on small target perception enhancement [J]. Chinese Journal of Scientific Instrument, 2025,46(9): 159-172.

[3] ARCOS JIMÉNEZ A, GÓMEZ MUÑOZ C Q, GARCÍA MÁRQUEZ F P. Dirt and mud detection and diagnosis on a wind turbine blade employing guided waves and supervised learning classifiers[J]. Reliability Engineering and System Safety, 2019,184: 2-12.

[4] DENG L W, GUO Y G, CHAI B R. Defect detection on wind turbine blade based on digital image processing[J]. Processes,2021,9(8): 1452-1473.

[5] 王瑞,汤占军. 基于多特征融合与集成学习的风机叶片缺陷检测方法[J]. 计算机科学,2025,52(S1): 470-477.

WANG R, TANG ZH J. Defect detection method for wind turbine blades based on multi-feature fusion and ensemble learning [J]. Computer Science, 2025, 52(S1):470-477.

[6] 黄磊,陈玥,李赵春,等. 基于三维激光点云的船舶检测与跟踪[J]. 激光与红外,2025,55(5):686-693.

HUANG L, CHEN Y, LI ZH CH, et al. Ship detection and tracking based on 3D laser point cloud[J]. Laser & Infrared, 2025,55(5):686-693.

[7] GIRSHICK R. Fast R-CNN[C]. IEEE International Conference on Computer Vision, 2015: 1440-1448.

[8] REN SH Q, HE K M, 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(6):1137-1149.

[9] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. ArXiv preprint arXiv:2004.10934, 2020.

[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] 范晨亮,李国庆,马长啸,等. 基于深度学习的风机叶片裂纹检测算法[J]. 科学技术创新,2020(13): 72-75.

FAN CH L, LI G Q, MA CH X, et al. Crack detection algorithm for wind turbine blades based on deep learning[J]. Science and Technology Innovation, 2020(13): 72-75.

[12] 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 in defect detection of wind turbine blades [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(8):26-35.
- [13] 全卫国,蔡天娇,王用沛,等.基于YOLOv8改进的风机叶片小尺度缺陷检测算法[J].电气工程学报,2026, 21(2):339-348.
- TONG W G, CAI T J, WANG Y P, et al. An improved small-scale defect detection algorithm for wind turbine blades based on YOLOv8[J]. Journal of Electrical Engineering, 2026, 21(2):339-348.
- [14] XIANG X ZH, MA ZH SH, LI X H, et al. Vehicle re-identification with large separable kernel attention and hybrid channel attention[J]. Image and Vision Computing, 2025, 155: 105442.
- [15] QIU SH J, GAO J, HAN M Y, et al. Sorghum spike detection method based on gold feature pyramid module and improved YOLOv8s[J]. Sensors, 2024, 25(1): 104.
- [16] 许德刚,郭玉涛,李滨,等.基于改进YOLOv8的粮虫目标检测算法[J/OL].南京信息工程大学学报,1-11 [2025-12-02]. <https://link.cnki.net/urlid/32.1801.n.20250710.1310.002>.
- XU D G, GUO Y T, LI B, et al. Grain insect target detection algorithm based on improved YOLOv8[J/OL]. Journal of Nanjing University of Information Science and Technology, 1-11 [2025-12-02]. <https://link.cnki.net/urlid/32.1801.n.20250710.1310.002>.
- [17] 李书莲,高正中,张经龙,等.基于改进YOLOv11的钢轨缺陷检测实验研究[J].实验技术与管理, 2025, 42(9):111-119.
- LI SH L, GAO ZH ZH, ZHANG J L, et al. Experimental study on rail defect detection based on improved YOLOv11 [J]. Experimental Technology and Management, 2025,42(9): 111-119.
- [18] WU Y X, HE K M. Group normalization [C]. European Conference on Computer Vision (ECCV), 2018:3-19.
- [19] DING X H, ZHANG X Y, HAN J G, et al. Diverse branch block: Building a convolution as an inception-like unit [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021:10886-10895.
- [20] 赵静,李京谦,杨蕾,等.基于PConv-CGLU与重参数检测头的轻量化膜下棉苗实时检测算法[J].农业工程学报,2025,41(18):151-162.
- ZHAO J, LI J Q, YANG L, et al. Real-time detection algorithm for lightweight cotton seedlings under film based on PConv-CGLU and heavy parameter detection head [J]. Transactions of the Chinese Society of Agricultural Engineering, 2025, 41(18):151-162.
- [21] 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 [2025-10-13]. <https://doi.org/10.13700/j.bh.1001-5965.2024.0228>.
- TANG ZH J, ZHANG CH J, WANG J, et al. Researchon defect detection of wind turbine blades based on improved YOLOv7 [J/OL]. Journal of Beijing University of Aeronautics and Astronautics, 1-15 [2025-10-13]. <https://doi.org/10.13700/j.bh.1001-5965.2024.0228>.
- [22] 王海群,王文科,于海峰.改进YOLOv10n的输电线路部件缺陷检测算法[J].电子测量技术, 2025, 48(10): 62-72.
- WANG H Q, WANG W K, YU H F. Defect detection algorithm for transmission line components based on improved YOLOv10n [J]. Electronic Measurement Technology, 2025,48(10):62-72.
- [23] 周翔,王可庆,周新翔,等.基于改进YOLOv10n的电动车头盔佩戴检测算法[J].电子测量技术, 2025, 48(5):40-49.
- ZHOU X, WANG K Q, ZHOU X X, et al. Electric vehicle helmet wearing detection algorithm based on improved YOLOv10n [J]. Electronic Measurement Technology, 2025,48(5):40-49.
- [24] ZHANG H, XU C, ZHANG SH J. Inner-IoU: More effective intersection over union loss with auxiliary bounding box [J]. ArXiv preprint arXiv: 2311.02877, 2023.
- [25] 朱广,顾晨,徐立云,等.改进YOLOv8的风机叶片多尺度缺陷检测[J].光学精密工程, 2025, 33(9): 1496-1514.
- ZHU G, GU CH, XU L Y, et al. Multi-scale defect detection of wind turbine blades based on improved YOLOv8[J]. Optics and Precision Engineering, 2025, 33(9):1496-1514.

作者简介

王海群,副教授,硕士,主要研究方向为智能控制与应用、深度学习。

E-mail:wanghq0604@163.com

关美(通信作者),硕士研究生,主要研究方向为深度学习、目标检测。

E-mail:guanmei1027@163.com

于海峰,博士,主要研究方向为深度学习、图像处理。

E-mail:2584464748@qq.com

潘创,硕士研究生,主要研究方向为研究方向为检测技术及智能装置。

E-mail:15130630579@163.com