

PSSN-YOLO: 风机表面缺陷检测模型^{*}

鄢思睿 姚小敏 陈曼龙 柴玉娇 李 伟

(陕西理工大学机械工程学院 汉中 723000)

摘 要: 风力发电机作为清洁能源系统的核心设备,其表面容易产生各种类型的缺陷,会严重影响设备的运行效率与安全性,因此及时发现并处理其表面缺陷至关重要。针对现有算法存在的漏检、误检以及小目标检测精度不足等问题,本文提出了一种改进 YOLOv8 的风机表面缺陷检测算法:PSSN-YOLO。该算法首先新增一个小目标检测层,可以为模型提供更多的尺度信息;使用 Slim-neck 范式作为特征融合网络,提高检测精度的同时减小模型的参数量;在每个检测头前嵌入 SE 注意力机制,使模型更加关注有用的特征通道,增强在复杂环境中对缺陷的检测能力;最后采用归一化 NWD 距离改进损失函数,使模型能更好衡量检测任务中边界框之间的相似性。实验结果表明,改进后的算法相比原算法在精确率 P、召回率 R 和 mAP50 上分别提高 1.1%、4.4% 和 2.6%,在提升检测精度的同时还降低了 8.97% 的参数量,能够更好地满足风力发电机表面缺陷检测的实际需求。

关键词: 风力发电机;缺陷检测;深度学习;YOLOv8

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

PSSN-YOLO: A surface defect detection model for wind turbines

Shan Sirui Yao Xiaomin Chen Manlong Chai Yujiao Li Wei

(School of Mechanical Engineering, Shaanxi University of Technology, Hanzhong 723000, China)

Abstract: As a core component of clean energy systems, wind turbines are prone to various surface defects that severely impact operational efficiency and safety, making timely detection and treatment crucial. To address issues such as missed detections, false alarms, and insufficient accuracy in small target detection, this paper proposes an improved YOLOv8-based algorithm for wind turbine surface defect detection: PSSN-YOLO. The algorithm introduces a small target detection layer to provide multi-scale information, employs the Slim-neck paradigm as the feature fusion network to enhance detection accuracy while reducing model parameters, embeds the SE attention mechanism before each detection head to focus on critical feature channels and improve defect detection in complex environments, and optimizes the loss function using normalized NWD distance to better measure bounding box similarity. Experimental results demonstrate that the improved algorithm achieves increases of 1.1%, 4.4%, and 2.6% in precision (P), recall (R), and mAP50, respectively, while reducing parameter count by 8.97%, better satisfying the practical requirements for wind turbine surface defect detection.

Keywords: wind turbine; defect detection; deep learning; YOLOv8

0 引 言

风能作为一种清洁能源,近年来得到越来越多的关注和应用,已逐渐成为全球能源结构的重要组成部分^[1]。风力发电机作为风能系统的核心设备,其运行状态会直接影响到发电效率和安全性。然而,风力发电机的运行环境通常较为恶劣,其表面常常暴露于强风、雨水、沙尘等复杂环境下,容易产生各种类型的缺陷,若不能及时有效的处理这

些缺陷,不仅会影响风力发电机的运行效率,还可能导致设备故障,进而造成经济损失和安全隐患^[2]。

早期对于风机表面的检测方法是由工作人员使用高倍望远镜观察或攀爬到风力发电机表面的不同部位,通过目视、触摸和敲击等方法对风机表面进行检查^[3],这种方法依赖于经验丰富的专业人员,并且存在检测成本高、效率低以及工作人员安全风险大等诸多问题。所以,开发一种低成本、高效率的智能化检测模型,来对风力发电机表面的缺陷

进行检测并准确分类是很有必要的。

随着无人机技术的发展以及高分辨率摄像设备的应用,使得获取图像变得更加容易,许多研究人员致力于深入研究图像处理技术在风机表面缺陷检测方面的应用,以提高检测的准确性、效率和可靠性。徐灵鑫^[4]通过 8 连通链码法有效提取了风机表面二值图中各类缺陷的外轮廓,并设计了风机表面缺陷模式识别的分类器。翟永杰等^[5]在图像增强以及图像预处理的基础上基于连通域标记原理分析了风机表面裂纹对比度的特点,再结合图像的背景区域特征将风机表面缺陷目标从背景区域中提取出来,有效提升了特征分辨的能力。Zhang 等^[6]基于计算机的视觉检测并结合 Sobel 与 Canny 算法有效提高了风机表面裂纹检测的准确性和效率。但上述方法依赖于人工设计特征提取算法,可能无法捕捉到复杂的缺陷模式,并且泛化能力弱,无法适应不同场景下的检测需求。

近年来,基于深度学习的图像处理技术广泛应用在各种场景中。与传统图像处理技术相比,深度学习可以自动学习图像中的特征,无需手动设计特征提取器,从而具有较强的鲁棒性和泛化能力。李学军等^[7]基于 Faster R-CNN 融合了 GSConv 卷积和 scSE 注意力机制,设计了多尺度特征融合网络,同时更新锚选框尺寸,提高了模型对缺陷的定位和识别能力。辛彦等^[8]对 EfficientDet 算法的主干部分进行改进,并对特征融合网络增加融合路径以提升算法的多尺度特征融合能力,改进后算法在 mAP 值上提升了 3.77%。Yu 等^[9]将 CBAM 注意力机制集成到 YOLOv8 骨干网络中增强对小目标特征的提取能力,然后使用加权双向特征金字塔网络(BiFPN)代替聚合网络(PANet)细化特征融合过程,提升了缺陷检测精度。Qiu 等^[10]将 YOLO 与 CNN 模型相结合,提出了一种基于 YOLO 的多尺度特征金字塔小目标检测方法(YSODA),对风机表面多种缺陷的检测精确率达到 80% 以上。

上述基于深度学习的目标检测算法虽然在风力发电机表面缺陷检测方面取得了一定进展,但由于无人机航拍下的风力发电机图像中缺陷多为小目标,多数模型对小目标缺陷的特征提取能力尚有不足,导致深层特征图中小目标信息丢失严重,漏检率较高^[11]。部分改进模型虽提升了精度,但引入复杂结构导致参数量增加^[12]。本文以 YOLOv8 模型为基础,提出了用于风力发电机表面缺陷检测的方法,主要创新包括以下 4 个方面:(1)新增加了一个 P2 小目标检测层,可以为模型提供更多尺度的特征信息,提高模型对小尺寸缺陷的检测能力;(2)采用 Slim-neck 范式特征融合网络改进 YOLOv8 的颈部网络,使模型能够有效整合来自主干网络不同层级的特征信息,提高模型对目标的检测性能;(3)在 Head 部分每个检测头前嵌入 SE 注意力机制,从而降低背景噪声的干扰,增强复杂环境下对于目标的识别能力;(4)引入归一化 NWD 距离优化损失函数,能更准确的衡量小目标的位置偏差。

1 YOLOv8 算法简介

Redmon 等^[13]于 2016 年首次提出的 YOLO(you only look once)算法是一种基于深度学习的目标检测算法。该算法通过将目标检测任务转化为单次回归问题,实现了端到端的高效检测,特别适合应用于实时目标检测任务。YOLOv8 是 YOLO 系列算法的经典版本,其在精度和速度方面都取得了显著的提升。其网络结构如图 1 所示。

YOLOv8 模型的网络结构主要由 3 个核心部分组成:主干网络(Backbone)、颈部网络(Neck)和头部网络(Head)。Backbone 部分是模型的基础,它由多个卷积层和 C2f 模块组成,负责从输入图像中提取特征;Neck 部分位于主干网络和头部网络之间,负责将来自 Backbone 不同阶段的特征图进行融合和增强;Head 部分将主干网络的特征图与上采样的特征图进行拼接,并进行一系列的卷积操作,产生最终的检测结果。

YOLOv8 提供了多种模型以满足不同应用场景的检测需求,模型的型号分别为 n、s、m、l、x,他们的深度和宽度都有所不同。其中,YOLOv8n 为该系列中体积最小,速度最快的型号。相比之下其他模型在性能方面会优于 YOLOv8n,但它们更大的模型尺寸将会消耗更多的计算资源。通常风力发电机表面缺陷检测对于实时性能要求高,因此选择 YOLOv8n 作为基本模型进行改进。

2 改进 YOLOv8 算法

在风力发电机表面缺陷检测任务中,YOLOv8 仍然存在着漏检、误检以及检测精度不足的问题,本文以 YOLOv8 算法为基准进行改进,提出了一种轻量化的风力发电机表面缺陷检测算法:PSSN-YOLO。改进内容如上文所述,首先在 YOLOv8 模型增加了一个检测尺寸为 160×160 的小目标检测层 P2 来增强对小尺寸缺陷的检测能力;其次将 Neck 部分替换为 Slim-neck 范式特征融合网络,在降低模型参数数量的同时提升模型的特征融合能力;在检测头前嵌入 SE 注意力机制,增强模型对关键特征的关注能力,抑制背景噪声的干扰;最后引入归一化 NWD 损失函数,基于 Wasserstein 距离衡量边界框相似性,提升对小尺寸缺陷的定位精度。改进后网络的结构如图 2 所示。

2.1 小目标检测层 P2

YOLOv8 算法包含有 P3、P4、P5 3 个不同的检测层,分别检测 8×8 、 16×16 、 32×32 以上的目标,能够对目标进行多尺度检测。由于无人机航拍下风力发电机表面的很多缺陷在图像中像素占比很小,而 YOLOv8 的下采样倍数比较大,导致在较深层次的特征图中,小尺寸缺陷的特征信息容易丢失,难以被有效学习和提取。所以 YOLOv8 原有的 3 个检测层在检测这些小尺寸缺陷时,容易发生漏检或误检的问题,难以满足检测要求。

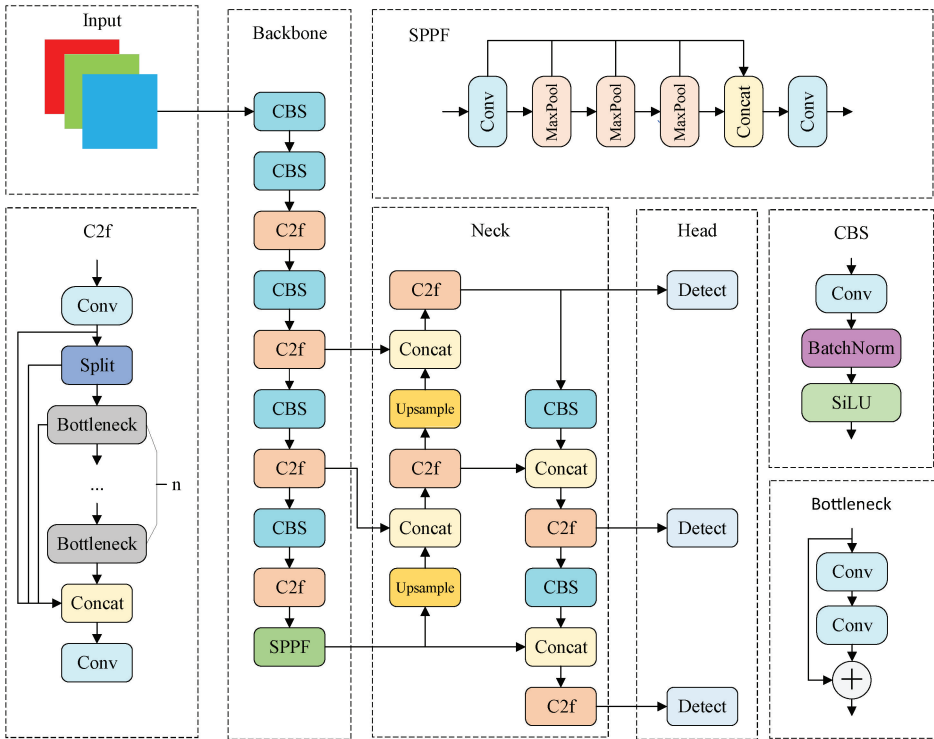


图 1 YOLOv8 网络结构
Fig. 1 YOLOv8 network structure

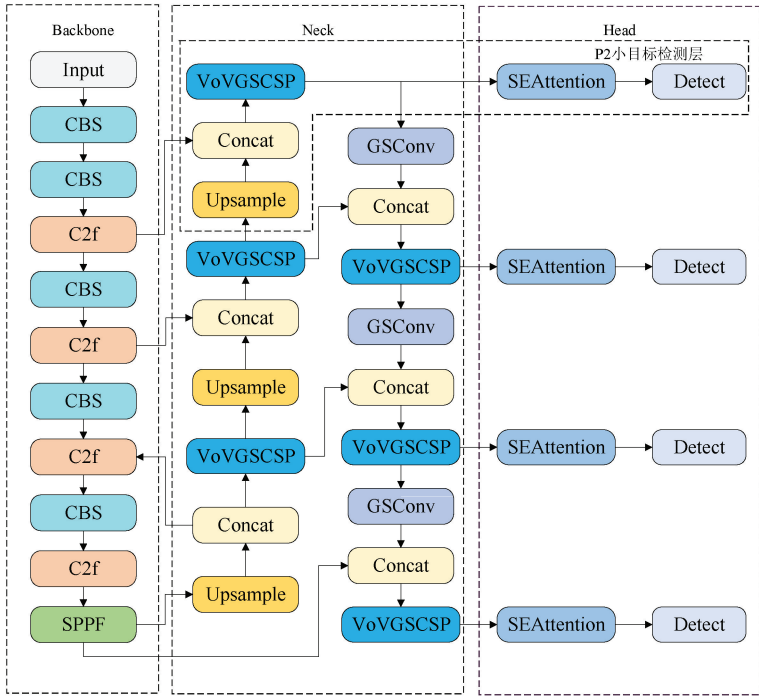


图 2 改进后 YOLOv8 网络结构
Fig. 2 Improvement of YOLOv8 network structure

因此,在 YOLOv8 模型的基础上增加了检测尺寸为 160×160 的小目标检测层 P2 来增强对小目标的检测能力,该检测层下采样倍数为 4,通道数为 128,能够更加准确地检测到 4×4 像素以上的小目标。新增加的小目标检测

层,可以为模型提供更多尺度的特征信息,使网络将更多注意力集中在小目标识别上,极大地提高了风力发电机表面缺陷检测任务中小尺寸缺陷的检测性能。

2.2 Slim-neck 特征融合网络

YOLOv8 的颈部网络主要作用是融合来自主干网络不同层级的特征图,以增强网络对目标的识别能力。但是颈部网络中的 C2f 模块采用了标准卷积 (standard convolution, SC),标准卷积在处理特征时通常是局部关注的,可能无法捕获全局信息,并且随着网络深度的增加,如果继续使用标准卷积, C2f 模块中的参数量会急剧增加,可能会导致模型训练和推理的速度变慢。

Li 等^[14]提出了轻量级卷积技术 GSConv 和轻量级结构 VoV-GSCSP,并将 GSConv 和 VoV-GSCSP 联合应用,构成轻量级特征融合网络 Slim-neck 范式。GSConv 结构如图 3 所示,GSConv 采用混洗策略,将标准卷积(SC)生成的特征渗透到由深度可分离卷积(DSC)生成特征的每个部分中。混洗策略是一种特征通道混合技术,通过交换不同通道上的局部特征信息,使得 SC 的全局特征信息均匀分布到 DCS 的输出中。这种策略不仅保留了 SC 的全局特征提取能力,还利用了 DSC 的高效计算特性,使得 GSConv 更好地平衡了模型的速度和准确性。

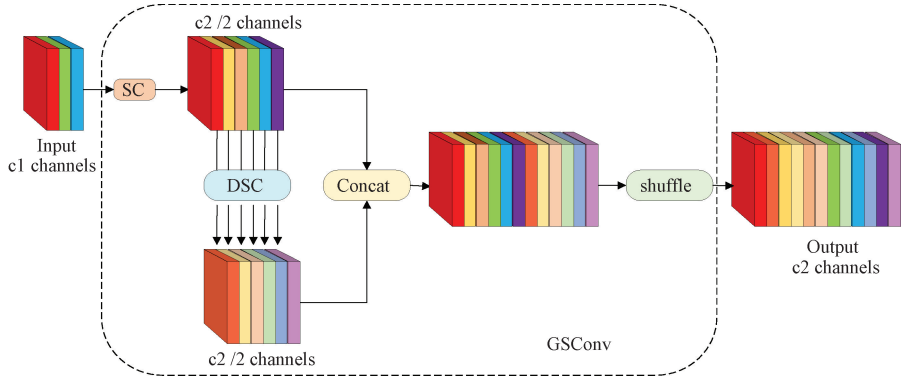


图 3 GSConv 模块

Fig. 3 GSConv module

跨级部分网络模块 VoV-GSCSP 模块结合了 GS bottleneck 模块和一次性聚合的思想,能够实现快速有效的特征整合,其结构如图 4 所示。一次性聚合通过在网络的不同阶段直接整合特征图,可以避免传统多阶段聚合中的信息冗余,从而实现更高效的特征融合。GS Bottleneck 模块由 GSConv 卷积组成,通过高效的特征传递能力,提升网络的非线性表达, VoV-GSCSP 模块在网络不同的阶段整合特征图,增强信息流动和特征表示。

将 YOLOv8 的颈部网络替换为 Slim-neck 范式,不仅能减少颈部网络中的参数量,降低整个模型的复杂度,还能有效地整合来自主干网络不同层级的特征信息,提高模型对目标的检测性能。

2.3 SE 注意力机制

SE 注意力机制^[15]的主要思想是学习得到每个特征通道的权重,从而增强有用的特征通道,减弱无用的特征通道,以提高模型的性能。SE 注意力机制由两部分组成:挤压模块(Squeeze)和激励模块(Excitation),其结构如图 5 所示。挤压模块通过全局平均池化,将每个通道的特征图缩减为一个全局特征向量,这一过程有效地总结了空间信息。激励模块接收挤压模块的输出,使用两个全连接层,通过非线性激活函数 sigmoid 生成每个通道的权重,这些权重代表每个通道的重要性。激励模块通过学习调整通道的重要性,以突出关键特征,学习到权重然后与原始特征图相乘,有效地校准了通道特征响应。

在 YOLOv8 中添加 SE 注意力机制,可以使模型可以更好地关注图像中重要的特征,并抑制不太重要的特征,使得模型能够更好地捕捉特征之间的相关性,从而提升特征的表达能力,有助于提高模型检测的准确性。由于 SE 注意力机制只涉及全局平均池化和少量全连接层,因此在整体计算成本的增加上是相对较小的。在改进的模型中,将 SE 注意力机制加在每个检测头前,帮助模型更好地区

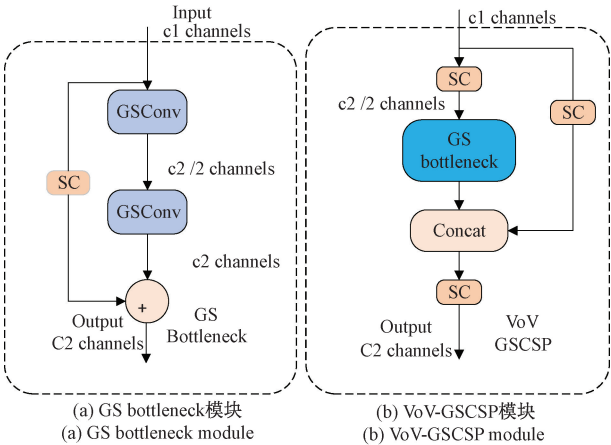


图 4 GS bottleneck 模块与 VoV-GSCSP 模块

Fig. 4 GS bottleneck module and VoV-GSCSP module

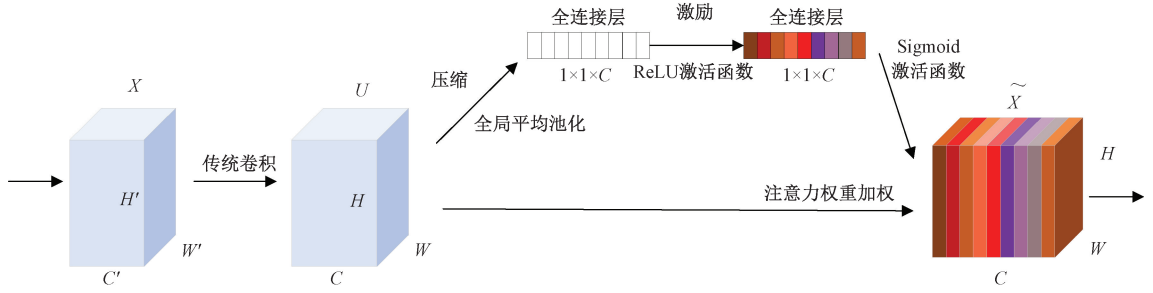


图 5 SE 注意力机制

Fig. 5 SE attention mechanism

分目标特征和背景之间的特征,使模型更加关注特征所在的区域,从而降低背景噪声的干扰,增强复杂环境下对小目标的识别能力。

2.4 损失函数改进

在目标检测任务中,通常使用 IoU^[16] 损失函数来衡量预测结果与真实结果之间的边界框重叠程度。YOLOv8 采用 CIoU 来作为损失函数,其公式如下:

$$IoU = \frac{|M \cap N|}{|M \cup N|} \quad (1)$$

$$CIoU = 1 - IoU + \left(\frac{\rho^2(c, c^{gt})}{C^2} \right) + \alpha \nu \quad (2)$$

其中, IoU 为真实边界框和预测边界框的交集面积与它们的并集面积之比。 $\rho^2(c, c^{gt})$ 表示真实边界框和预测边界框中心点之间欧氏距离的平方; C^2 表示两个边界框的对角线距离的平方; ν 用于惩罚边界框尺寸不一致的项; α 用于平衡 CIoU 损失函数中各项权重的超参数。CIoU 损失函数在处理不同尺度的目标,尤其是小目标时,会存在一些局限性。这是由于 CIoU 损失函数主要关注目标框之间的重叠程度和尺寸差异,而忽略了边界框形状差异的影响。在处理小目标时,这种设计使得模型对尺度变化较为敏感,从而导致检测精度下降。NWD 损失函数相较于传统的 IoU 损失函数在小目标检测上更具优势。这是因为 NWD 损失函数考虑了类别损失和 IoU 损失的组合,通过加权平衡类别信息和位置信息的重要性,从而在一定程度上减少了对目标尺度的敏感性。

NWD(normalized wasserstein distance) 损失函数^[17] 是一种基于 Wasserstein 距离的损失函数,常用于目标检测任务,特别是在处理小目标检测任务时表现出色。对于微小目标而言,其真实框通常并非严格的矩形,其边界框内往往包含很多背景元素。将边界框进行高斯分布建模,可以为边界框的中心赋予最高权重,使得像素的重要性从中心向边界逐渐递减。因此,可以通过计算两个高斯分布之间的距离来衡量两个边界框之间的相似度。NWD 用 Wasserstein 距离来衡量两个高斯分布之间的相似度,该方法的计算公式如下:

$$NWD(N_a, N_b) = \exp\left(-\frac{\sqrt{W_2^2(N_a, N_b)}}{C}\right) \quad (3)$$

3 实验与结果分析

3.1 数据集制作

本文采用的数据集为 Kaggle 官网的公开数据集,该数据集是 Shihavuddin^[18] 等使用无人机多角度拍摄的风力发电机表面图像。在图像中自定义标注了损伤(damage)、腐蚀(erosion)和脏污(dirt)三类缺陷,并按 7:2:1 的比例划分为训练集、验证集和测试集。

3.2 实验环境及参数配置

所有实验均在 PyTorch 深度学习框架下进行,实验的操作系统为 Windows11, GPU 为 NVIDIA GeForce GTX 4060, 编译器为 Python3.11, CUDA 版本 12.3。实验设置训练轮数为 300 轮,批次量为 8,初始学习率为 0.01,选用 SGD 优化器。

3.3 算法评估标准

为了评估对算法的改进效果,本文采用精确率 P(Precision)、召回率 R(Recall)、平均精度 AP、平均精度均值 mAP 和参数量 Parameter 几项指标对算法模型进行评价,这些也是 YOLO 系列算法结果评价的常用指标。各指标具体介绍及计算公式如下:

1) 精确率 P 表示所有预测为正类的样本中,正确预测的比重,计算公式为:

$$P = \frac{TP}{TP + FP} \quad (4)$$

2) 召回率 R 表示真实为正类的样本中,正确预测的比重,用来衡量漏检率,计算公式为:

$$R = \frac{TP}{TP + FN} \quad (5)$$

3) AP 表示某类缺陷的平均精度,计算公式为:

$$AP = \int_0^1 P(R) dR \quad (6)$$

4) mAP 表示所有类型缺陷的平均精度的均值, mAP 值越高,模型性能越好,计算公式为:

$$mAP = \frac{1}{n} \sum_{i=1}^n AP(i) \quad (7)$$

以上公式中, TP 表示实际为正样本且预测为正的数; FP 表示实际为负样本但预测为正的数; FN 表示实

际为正样本但预测为负的数量; n 表示数据的类别数。

3.4 改进点消融实验

为了证明各改进模块的有效性,在 YOLOv8 的基础上

对各个模块进行消融实验,使用 P、R、mAP、Parameter 等指标进行对比。实验结果如表 1 所示,其中“√”表示模型采用了此改进方式,“—”表示模型没有采用该改进方式。

表 1 消融实验结果
Table 1 Ablation experiment

实验序号	P2	Slim-neck	SEAttention	NWD	P/ %	R/ %	mAP50/ %	Para/M
1	—	—	—	—	80.8	73.7	78.5	3.01
2	√	—	—	—	81.6	75.7	79.6	2.97
3	√	√	—	—	81.3	76.4	80.3	2.73
4	√	—	√	—	82.2	75.2	79.9	2.98
5	√	—	—	√	82.1	75.6	80.0	2.97
6	√	√	√	—	84.1	75.5	80.4	2.74
7	√	√	—	√	80.8	77.5	80.0	2.74
8	√	—	√	√	79.5	77.0	80.0	2.98
9	√	√	√	√	81.9	78.1	81.1	2.74

实验 1 为 YOLOv8 基线算法实验结果;实验 2 首先在模型上加入小目标检测层 P2,使得模型可以有效对小尺寸缺陷进行检测,较基准模型精确率 P 提升了 0.8%,召回率 R 提升了 2.0%,mAP50 提高了 1.1%,这证明了加入 P2 层对于捕捉小尺寸缺陷的有效性,后续实验均在此网络结构上对算法模型进行改进。实验 3 将颈部替换为 Slim-neck 范式特征融合网络,有效提升了模型的特征表达能力,使得模型能够将浅层信息和深层信息进行更加有效的融合,相较于实验 2 的 mAP50 提升 0.7%,参数量减少了 0.24 M;实验 4 将 SE 注意力机制嵌入到检测头前,该机制会使模型更加关注有用的特征通道,在处理不同形状和尺度的缺陷时更加鲁棒,相较于实验 2 的结果,在增加极少参数量的情况下 mAP50 提升了 0.3%;实验 5 改进损失函数后,能够更好衡量检测任务中边界框之间的相似性,提高模型的检测精度,在实验 2 的基础上 mAP50 提升了 0.4%。实验 6~8 在添加了小目标检测层的基础上将 Slim-neck 特征融合网络、SE 注意力机制和 NWD 损失函数分别进行两两组合应用,模型的性能均有不同程度的提升。最后,实验 9 将以上 4 种方法同时改进时,精度达到了最高,相较于基线算法精确度 P 提升 1.1%,召回率 R 提升 4.4%,mAP50 提升了 2.6%,同时参数量降低了 8.97%。

3.5 模型对比实验

为了评估改进后算法在风力发电机表面缺陷检测任务上的性能,本文选取了几种主流的目标检测模型进行对比实验。实验结果如表 2 所示。

PSSN-YOLO 与 Faster R-CNN 相比,其检测的准确率更高,参数量更少,且 Faster R-CNN 作为两阶段目标检测算法,实时性较差,并不适用于风机表面缺陷检测任务

表 2 对比实验结果
Table 2 Comparative experiment

模型	P/ %	R/ %	mAP50/ %	Para/M
Faster R-CNN ^[19]	34.1	74.4	61.2	41.20
RT-DETR ^[20]	50.7	47.6	49.3	28.40
YOLOv5n	79.4	74.5	78.4	2.50
YOLOv5s	82.8	72.0	78.6	9.11
YOLOv7-tiny	78.4	74.6	77.6	6.02
YOLOv8n	80.8	73.7	78.5	3.01
YOLOv8s	82.0	74.2	79.2	11.13
YOLOv9s	81.3	74.7	79.9	7.16
YOLOv10n	76.9	71.0	75.5	2.69
YOLO11n	80.8	72.5	77.1	2.58
YOLO11s	79.6	73.0	78.5	9.41
PSSN-YOLO	81.9	78.1	81.1	2.74

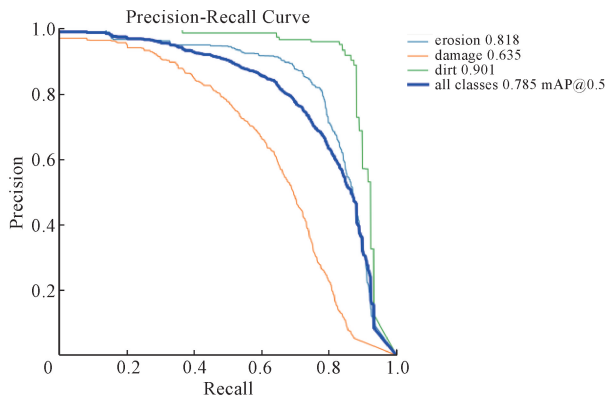
中。RT-DETR 是一种基于 Transformer 架构的目标检测模型,它采用 Transformer 的自注意力机制来处理图像数据,能够更好地理解图像中不同部分之间的关系,特别是在处理复杂场景和多对象环境时,能够更加全面地捕捉目标对象之间的关系。但 RT-DETR 需要巨大的计算量,并且在风机缺陷检测上效果一般。PSSN-YOLO 与原始 YOLOv8n 算法相比在精确率、召回率和 mAP50 值上均有提升。并且 PSSN-YOLO 仅在精确率上略低于参数量较大的 YOLOv5s 和 YOLOv8s,在召回率和 mAP50 上,PSSN-YOLO 均高于 YOLO 系列其他算法。实验结果表明,PSSN-YOLO 在风机表面缺陷检测任务中具有更好的检测效率和更优越的性能。

3.6 可视化分析

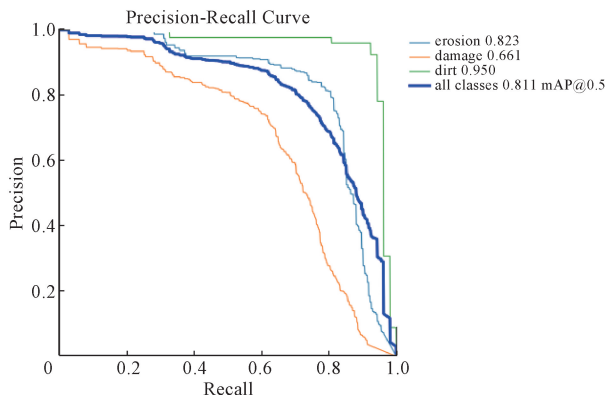
为了更加直观地感受 PSSN-YOLO 相比于 YOLOv8n 的优势,本文给出两种算法的 PR 曲线和检测结果对比图。

PR 曲线表示精确度和召回率之间的关系,PR 曲线与坐标轴围成的面积即为平均精度。图 6 为 YOLOv8n 与 PSSN-YOLO 的 PR 曲线对比图,PSSN-YOLO 的 PR 曲线与坐标轴围成的面积明显大于 YOLOv8n。证明 PSSN-YOLO 算法相较于 YOLOv8n 算法,能够更好地平衡精确度和召回率,从而在风力发电机表面缺陷检测任务中具有更出色的性能。

为了能直观地感受到算法改进后的效果,将 YOLOv8n 基线算法的预测结果与改进后算法 PSSN-YOLO 的检测结果进行对比,得到的检测结果如图 7 所示,其中图 7(a)为 YOLOv8n 检测结果,图 7(b)为 PSSN-YOLO 检测结果。可以观察到,损伤(damage)和腐蚀(erosion)类缺陷通常较小,且分布密集,而脏污(dirt)类缺陷则目标更大,分布更广泛。由对比图中可以看到 PSSN-YOLO 相比于 YOLOv8n 能检测到更多的缺陷,且 YOLOv8n 算法存在将背景中的物品误检为缺陷的情况,而 PSSN-YOLO 对于误检情况有一定的改善。而对于一些目标较大的缺陷则 PSSN-YOLO 检测结果置信度更高。PSSN-YOLO 能够更加准确地提取目标特征信息,具有更好的检测效果。



(a) YOLOv8n的PR曲线
(a) PR curve of YOLOv8n



(b) PSSN-YOLO的PR曲线
(b) PR curve of PSSN-YOLO

图6 PR曲线对比

Fig. 6 PR curve comparison

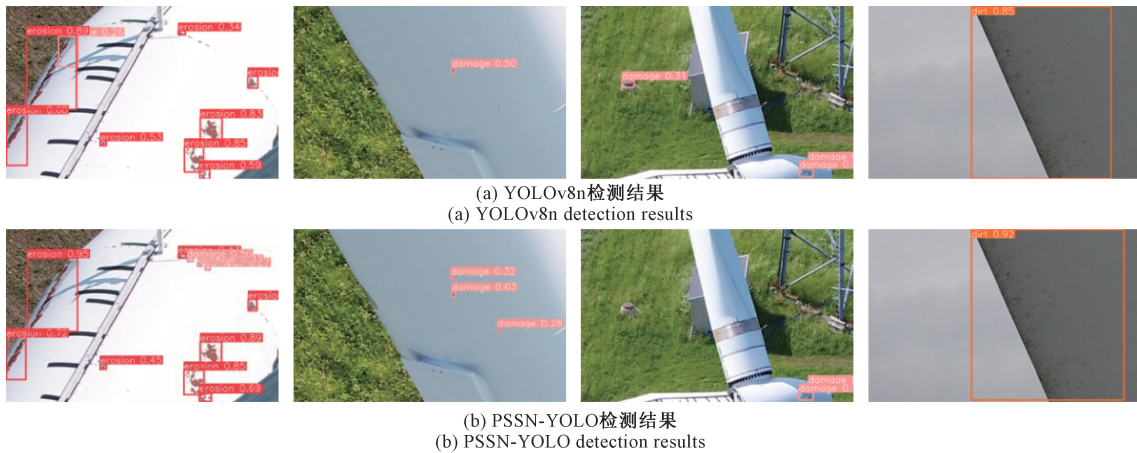


图7 检测结果对比

Fig. 7 Comparison of detection results

4 结论

本文针对风力发电机表面缺陷检测中存在的问题,以 YOLOv8 检测算法为基础进行了优化改进。通过增加小目标检测头、使用 Slim-neck 范式作为特征融合网络、头部嵌入 SE 注意力机制以及使用 NWD 损失函数对原始损失

函数进行优化等一系列措施,显著提升了模型对于缺陷的检测能力。实验结果表明,相较于 YOLOv8n 基线算法,改进后的算法在精确度 P、召回率 R、和平均精度均值 mAP50 上分别提升了 1.1%、4.4% 和 2.6%,且参数量降低了 8.97%,有效降低了缺陷漏检、误检的发生,可以更好的满足实际应用。未来将构建缺陷类别更多样化的数据

集,从而扩大检测范围,并进一步优化算法,以提高检测精度和速度,更好的应用于复杂多变的工业环境。

参考文献

- [1] 王伟刚. 新能源风力发电的研究综述[J]. 电工技术, 2024(4):49-52.
WANG W G. Research progress of wind power generation[J]. Electric Engineering, 2024(4):49-52.
- [2] KONG K, DYER K, PAYNE C, et al. Progress and trends in damage detection methods, maintenance, and data-driven monitoring of wind turbine blades-a review [J]. Renewable Energy Focus, 2023, 44: 390-412.
- [3] DENG L, GUO Y, CHAI B. Defect detection on a wind turbine blade based on digital image processing [J]. Processes, 2021, 9(8):1452.
- [4] 徐灵鑫. 风力发电机叶片表面缺陷检测的研究[D]. 杭州:中国计量学院, 2015.
XU L X. Study on surface defect detection of wind turbine blades [D]. Hangzhou: China Jiliang University, 2015.
- [5] 翟永杰, 李冰, 常启诚. 风机滑动偏航系统的在线监测系统数据分析[J]. 现代电子技术, 2015, 38(21): 123-126.
ZHAI Y J, LI B, CHAN Q CH. Data analysis of on-line monitoring system for fan sliding yaw system[J]. Modern Electronics Technique, 2015, 38(21):123-126.
- [6] ZHANG H, JACKMAN J. A feasibility study of wind turbine blade surface crack detection using an optical inspection method [C]. International Conference on Renewable Energy Research and Applications (ICRERA), IEEE, 2013:847-852.
- [7] 李学军, 权林霏, 刘冬梅, 等. 基于 Faster-RCNN 改进的交通标志检测算法[J]. 吉林大学学报(工学版), 2025, 55(3):938-946.
LI X J, QUAN L F, LIU D M, et al. Improved faster-RCNN algorithm for traffic sign detection[J]. Journal of Jilin University(Engineering and Technology Edition), 2025, 55(3):938-946.
- [8] 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.
- [9] YU H, WANG J, HAN Y, et al. Research on an intelligent identification method for wind turbine blade damage based on CBAM-BiFPN-YOLOV8 [J]. Processes, 2024, 12(1):205.
- [10] 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.
- [11] 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. YOLOv8 algorithm is improved in the defect detection of wind turbine blades applications[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(8):26-35.
- [12] 孙铁强, 魏光辉, 宋超, 等. 基于 YOLO 的多模态钢轨表面缺陷检测方法[J]. 电子测量技术, 2024, 47(21): 72-81.
SUN T Q, WEI G H, SONG CH, et al. Multi-modal rail surface defect detection method based on YOLO[J]. Electronic Measurement Technology, 2024, 47(21):72-81.
- [13] 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, 2016:779-788.
- [14] LI H, LI J, WEI H, et al. Slim-neck by GSConv: A lightweight-design for real-time detector architectures[J]. Journal of Real-Time Image Processing, 2024, 21(3):62.
- [15] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018:7132-7141.
- [16] REZATOFIGHI H, TSOI N, GWAK J Y, et al. Generalized intersection over union: A metric and a loss for bounding box regression[J]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 658-666.
- [17] WANG J, XU C, YANG W, et al. A normalized Gaussian Wasserstein distance for tiny object detection[J]. ArXiv preprint arXiv:2110.13389, 2021.
- [18] SHIHAVUDDIN A, CHEN X. DTU-Drone inspection images of wind turbine[J]. 2018, DOI: 10.17632/hd96prn3nc.2.
- [19] 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, 2016, 39(6):1137-1149.
- [20] ZHAO Y AN, LYU W Y, XU SH L, et al. DETRs beat YOLOs on real-time object detection[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024:16965-16974.

作者简介

鄢思睿, 硕士研究生, 主要研究方向为计算机视觉、缺陷检测。

E-mail: shansirui0726@163.com

姚小敏(通信作者), 讲师, 硕士生导师, 主要研究方向为无人机智能监测系统、无人机图像检测技术。

E-mail: yaoxiaomin0604@163.com