

# 基于 SAFPN-YOLO 的风机表面缺陷检测方法<sup>\*</sup>

金鑫 井瑞 蒋宜辰

(江苏师范大学电气工程及自动化学院 徐州 221116)

**摘要:** 针对传统检测方法对风力发电机表面缺陷检测能力不足的问题,本文提出一种基于 SAFPN-YOLO 的风机表面缺陷检测算法。首先,针对航拍目标多尺度的问题,使用基于渐近融合思想的 SAFPN 网络替代了经典的特征金字塔融合网络,减小特征融合时信息的语义差距;其次,为了应对检测背景信息冗余的问题,在算法主干网络的深层嵌入改进的卷积模块替换原有的 SCDown 模块,使得模型保留对局部特征关键信息的同时,在更广阔的视野范围内提取特征;最后,为了解决纹理型缺陷难以检测与定位的问题,提出了一种可以加强空间特征交互能力和特征表达能力的注意力机制,进一步改善模型的检测性能。实验结果表明,基于 SAFPN-YOLO 的风机表面缺陷检测算法的 mAP50 达到了 82.4%,相较于基线模型提高了 3.3%,能够实现更加准确的风机表面缺陷检测。

**关键词:** 风机表面;缺陷检测;特征融合;信息冗余;纹理型缺陷

**中图分类号:** TP391.4;TN957.52 **文献标识码:** A **国家标准学科分类代码:** 520.6040

## Surface defect detection method for wind turbine based on SAFPN-YOLO

Jin Xin Jing Rui Jiang Yichen

(School of Electrical Engineering and Automation, Jiangsu Normal University, Xuzhou 221116, China)

**Abstract:** In order to solve the problem that traditional detection methods cannot detect surface defects of wind turbines sufficiently, the paper proposes a surface defect detection algorithm for wind turbines based on SAFPN-YOLO. Firstly, in order to solve the problem of difficulty in multi-scale object detection, the SAFPN network based on the idea of asymptotic fusion is used to replace the classical feature pyramid fusion network, so as to reduce the semantic gap of information during feature fusion. Secondly, in order to solve the problem of redundancy of background information, the original SCDown module was replaced by the NAMBlock module embedded in the deep embedding of the algorithm backbone network, so that the model could extract features in a broader field of view while retaining the key information of local features. Finally, in order to solve the problem that textured defects are difficult to detect and locate, an attention mechanism is proposed to strengthen the spatial feature interaction ability and feature expression ability, and further improve the detection performance of the model. The experimental results show that the mAP50 based on SAFPN-YOLO fan surface defect detection algorithm reaches 82.4%, which is 3.3% higher than that of the baseline model, and can achieve more accurate defect detection on the surface of the fan.

**Keywords:** the surface of wind turbines; defect detection; feature fusion; redundancy of information; textured defects

## 0 引言

风力发电是目前风能利用的最主要方式,也是当前清洁能源中最具潜力和最具规模化开发条件的发电方式之一<sup>[1]</sup>。随着“双碳目标”的日益推进<sup>[2]</sup>,我国的风电累计装机容量持续增加,有关风电设备的运行维护问题也随之受到广泛关注<sup>[3]</sup>。目前,国内的风电建设主要集中在大漠戈壁滩以及近海地区,风电设备所处环境恶劣,易受干湿热空

气、强紫外线、强力风沙以及盐雾天气的环境影响,造成风力发电机表面出现缺陷<sup>[4]</sup>。风力发电机的叶片是风电机组中核心部件,叶片存在缺陷直接影响整体的发电性能<sup>[5]</sup>,甚至会直接导致风力发电机报废。因此,为了保证风力发电机在服役期间能够正常工作,需要对风机表面进行缺陷检测,其具有现实的经济价值和工程意义。

传统的人工检测方法主要通过地面敲击辩音、地面望远镜观察及吊车辅助绳索垂降观察的手段<sup>[6]</sup>,不仅对检测

工人的水平有较高的要求,而且检测的效果也不尽人意。此外,基于电子传感器测量技术<sup>[7]</sup>、超声波检测技术<sup>[8]</sup>及红外成像技术<sup>[9]</sup>的风机叶片故障检测技术也不断地涌现,但是这类技术受环境因素影响较大并且部署检测困难,故障类别也难以判断<sup>[10]</sup>。随着计算机视觉以及无人机技术的发展,目标检测技术在风力机表面缺陷检测方面的应用已经逐渐成为主流。当前,目标检测算法主要分为一阶段(one-stage)和两阶段(two-stage)两类算法。与两阶段算法相比,一阶段算法凭借其端到端的推理快速性,在工业应用中更受青睐。在当前的一阶段算法中,YOLO 系列因其优异的综合性能,被广泛用于各类工程实践中,同时为弥补 YOLO 算法在检测精度上的不足,众多学者提出了各类改进方法。

针对风机缺陷检测精度不高的问题,文献[11]基于 YOLO 系列中的 YOLOv8 算法,在主干网络和颈部网络中分别引入 C2F-FocalNextBlock 模块和 ResNet-EMA 模块,并在颈部网络中引入细颈结构,提高了模型对于风机缺陷特征的提取和融合能力,虽然检测精度确实有所提升,但并不显著;文献[12]依照空间状态模型设计了 MBlock 替代 YOLOv8 的 C2f 结构,并构建了螺旋式图像扫描机制,实现了平均精度和检测速度的双重创新,但是模型在“表面损伤”缺陷定位上表现并不佳。

此外,文献[13]基于 YOLOv10,使用 RepNMSC 替代 C2f 并将主干网络的输出直接和检测头拼接,减小特征信息的丢失,同时使用 ERepGFPN 作为融合网络以等同优先级处理各级信息,最后去除了大目标检测头,添加了一个小目标检测头,虽然该算法可以提高对于小尺度目标的精度,但并不适用于风机缺陷中的大尺度目标检测;文献[14]在双向特征融合网络(bidirectional feature pyramid network, BiFPN)基础上构造出了 BIMAFPN 结构提高了网络对于复杂特征的融合能力,并引入轻量化 LSCD 检测头,以及对损失函数进行了优化,实现了轻量化的目标检测,但是对于风机缺陷类型中的纹理型缺陷并不适用。尽管上述 YOLOv10 的改进算法对通用目标检测任务提供了新的思路,但是风机表面缺陷的背景复杂,缺陷特征信息难以提取,检测精度偏低;缺陷尺度多样,目标定位困难,检测难度比较大。鉴于此,本文为了应对风机缺陷定位困难以及检测精度偏低的问题,基于 YOLOv10 提出了 SAFPN-YOLO 算法。首先,针对无人机拍摄角度差异以及缺陷类型共同导致检测目标尺度差异性的问题,本文结合渐近融合网络<sup>[15]</sup>(asymptotic feature pyramid network, AFPN)的思想以及 YOLOv10<sup>[16]</sup>的结构,构造出了全新的特征融合网络 SAFPN,能够很好的改善因缺陷尺度多样性导致特征难以融合的问题;其次,针对检测背景复杂,主干网络不能很好的提取风机表面缺陷特征的问题,本文对主干网络进行改进,使用自行设计的 NAMBlock 卷积模块替代主干深层网络中的

SCDown 模块,能够在不增加计算成本的情况下,提高网络对于复杂背景下提取风机表面缺陷的鲁棒性;最后,为了能够在主干网络中更好地提取纹理型缺陷的特征,本文还设计了一种自适应注意力机制 AS<sup>2</sup>-MLP,能够很好地捕获全局场景上下文,提高模型空间特征交互能力和特征表达能力,从而实现检测精度的提升。本文提出的 SAFPN-YOLO 算法,能够以较低的计算成本实现风机在服役期间较高精度的缺陷检测与分类,有利于实现风力发电机巡检与维护工作。

## 1 YOLOv10 目标检测算法

### 1.1 相关算法原理

YOLOv10 是 2024 年新提出的一阶段目标检测算法,现有 n、s、m 和 l 四个版本,各个版本之间的结构相差几乎无异,只是尺寸大小有所不同。基于检测目标在实际应用中部署的需求,本文围绕四个版本中尺寸最小的 YOLOv10n 模型开展研究。YOLOv10n 算法主要由输入图像预处理、主干提取网络、颈部融合网络以及头部检测网络四个部分组成,其具体的结构如图 1 所示。

输入图像预处理将输入的图像统一像素格式,再结合自适应锚框计算和数据增强技术<sup>[17]</sup>,可以显著提高算法的鲁棒性。主干提取网络负责将经过预处理的图像转化为语义丰富的特征图,在集成了 Conv、C2f 以及 SPPF 等高效的特征提取模块的基础上,还提出了新的下采样 SCDown 模块以及 PSA 模块;颈部融合网络仍是采用 YOLO 系列最常用的特征金字塔网络<sup>[18]</sup>(feature pyramid network, FPN)与路径融合网络<sup>[19]</sup>(path aggregation network, PAN)结合的结构,实现多尺度特征融合,其还引入了 C2fCIB 结构,可以优化梯度流;YOLOv10 相较之前 YOLO 算法最大的创新,就是其头部检测网络采用了无非最大值抑制的一致双重分配策略,该策略结合一对一分配和一对多分配的优点,避免了训练和推理过程中对 NMS 的依赖,减少了计算成本和推理延迟。其中,一对多分配(one-to-many assignment)会为每个真实边界框分配多个预测边界框作为正样本,这样一来就可以丰富监督信号,从而优化模型的收敛效果;一对一分配(one-to-one assignment)只会每个真实边界框分配一个预测边界框作为预测正样本,这样每个目标只有一个正样本,从而可以在训练过程中使模型更高效学会选择最佳的预测边框,大大提高模型的收敛速度和精度。

### 1.2 SAFPN-YOLO 的模型结构

SAFPN-YOLO 具体的模型结构,如图 2 所示。

本文针对风机表面缺陷的背景复杂导致缺陷特征信息难以提取以及尺度多样导致目标定位不准的问题,对 YOLOv10 的主干提取网络、特征融合网络以及检测头部分进行改进,具体的模块改进细节在第 2 节中详述。

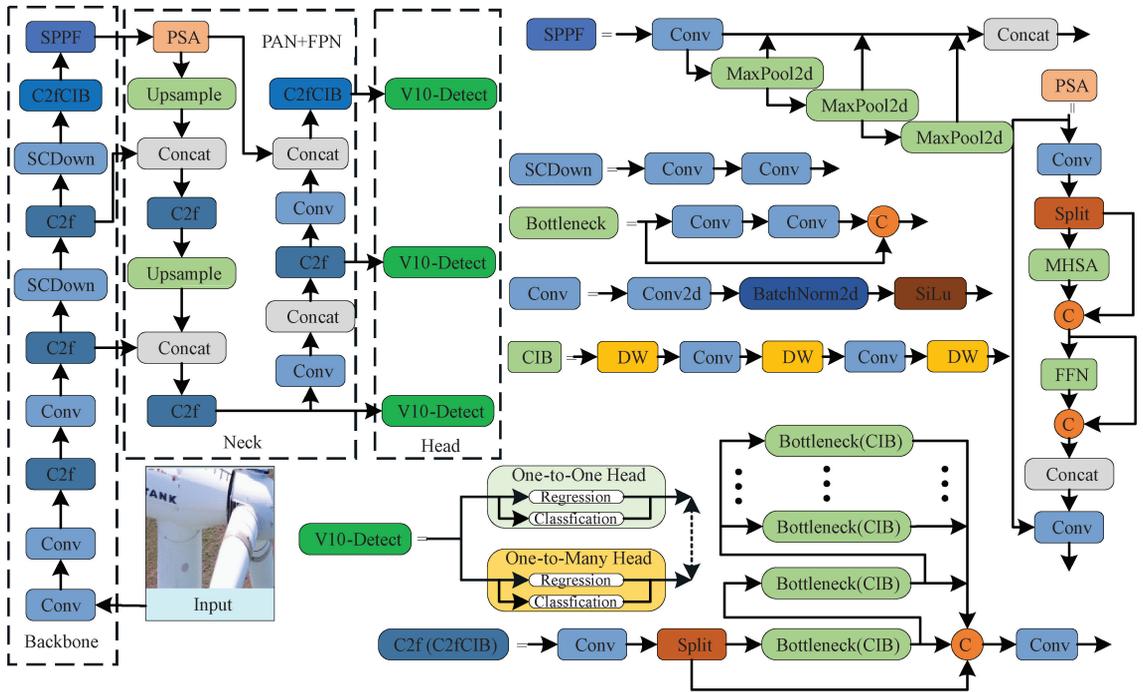


图 1 YOLOv10 整体结构  
Fig. 1 Overall structure of YOLOv10

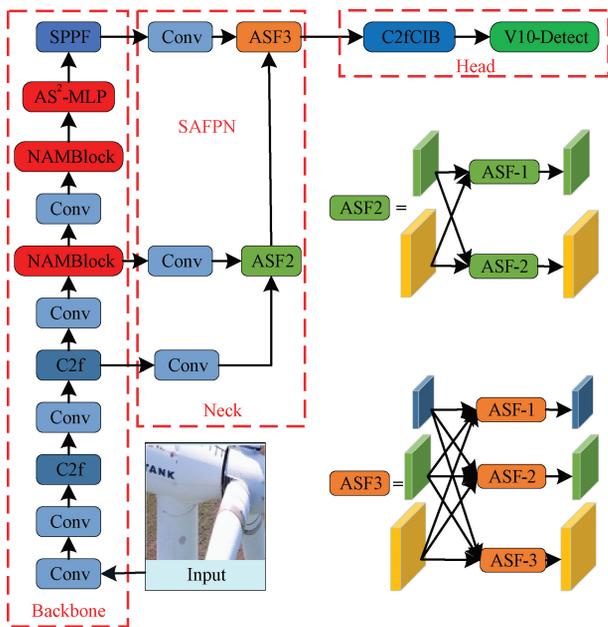


图 2 SAFPN-YOLO 整体结构  
Fig. 2 Overall structure of SAFPN-YOLO

的检测能力。本文并没有沿用该结构,而是采用了基于渐近融合思想所改进的 SAFPN,其具体的操作如图 3 所示。首先将两个相邻的低级特征融合,然后将高级特征也逐渐融入。渐近融合方式,能够在减少因生成不同尺度特征图造成信息丢失的同时,避免非相邻层之间较大的语义差距,依此来提高网络对于不同角度拍摄和目标尺度多样图像的检测能力。本文依照渐近融合的思想,在其基础上进行改进,构造出了新的特征融合网络,其具体操作如图 2 中的 Neck 部分所示。

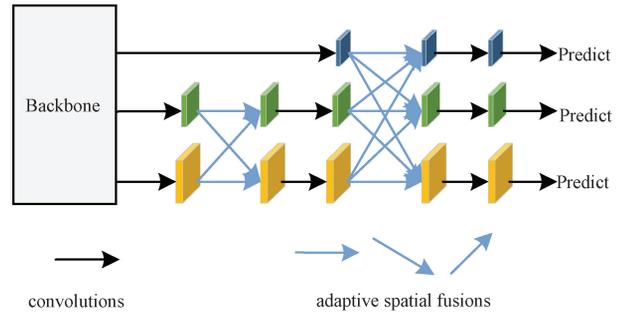


图 3 渐近融合原理  
Fig. 3 Principle of AFPN

## 2 SAFPN-YOLO 算法的实现

### 2.1 SAFPN 特征融合网络

YOLOv10 的基线模型采用经典的 FPN+PAN 的特征金字塔结构,将主干网络提取的特征信息进行多尺度融合后传递到检测层,有效地提高了模型对于不同尺度信息

在基线模型的主干特征提取网络中一共有 5 次下采样,由于第 1 次下采样和第 2 次下采样的结果中所包含语义信息并不丰富,对于信息融合帮助并不大,并且会造成额外的计算开销,因此并没有对前两次的下采样结果进行特征融合。SAFPN 对包含语义更丰富的第 3 次和第 4 次下采样进行信息融合,将获得的特征图进行  $1 \times 1$  的卷积后,

再对其进行自适应空间融合操作<sup>[20]</sup> (adaptively spatial feature fusion, ASFF), 将两个不同尺度的特征图进行融合, 然后加入第 5 次下采样的结果。由于进行自适应融合后语义已经发生变化, 为了进一步减小融合特征的差距, SAFPN 并没有同 AFPN 一样, 在第 2 次特征融合时, 还对低级融合后的特征加入卷积操作, 而是直接进行融合操作, 减小计算成本的同时, 还能实现更好的特征融合。此外, SAFPN-YOLO 将融合过后的特征图在输入到检测网络之前全都引入了 C2fCIB 结构, 帮助检测头捕获更多细粒度的特征信息。

为了验证 SAFPN 特征融合网络的有效性, 本文也将 YOLOv10 的特征融合网络替换为其他的特征融合网络在本文数据集上进行训练, 其具体的实验结果如表 1 所示。

表 1 YOLOv10 替换不同特征融合网络的精度对比

Table 1 Comparison of the accuracy of YOLOv10 in replacing different feature fusion networks

特征融合网络	mAP50/%
PAN+FPN	79.1
Slim-neck by GSConv	78.4
AFPN	77.5
Giraffe FPN	76.3
SAFPN	80.4

由表 1 的对比结果, 可以明显地看出 YOLOv10 模型在结合不同类型特征融合网络的平均检测精度表现, 相较于其他的特征融合网络, SAFPN 的表现达到了最高, 这说明了 SAFPN 网络更适合用于风力发电机表面缺陷的检测, 证明了该改进策略的有效性。

### 2.2 NAMBlock 模块

在面对风机表面缺陷检测任务时, 普通卷积难以从背景复杂、冗余信息过多的图像中准确地将目标特征提取, 这就会造成信息融合过程中会出现无关的特征, 弱化关键特征, 特别是在处理小目标的检测对象时, 往往随着主干提取网络的加深, 小目标特征会逐渐淡化, 在检测结果的表现上就是无法识别检测对象。为了解决风力发电机表面缺陷检测任务中, 因背景复杂造成小目标难以识别的问题, SAFPN-YOLO 使用本文提出新的轻量 NAMBlock 卷积模块替代传统的 SCDown 模块, 通过在特征信息提取过程中, 为关键通道信息分为更多权重, 弱化冗余信息, 实现对图像特征高效率的提取, 从而提高目标检测任务的性能和效果, NAMBlock 卷积模块的原理如图 4 所示。

NAMBlock 采用经典的瓶颈嵌套结构, 能够在不增加网络参数量的情况下, 加深网络深度从而提高特征提取能力。由图 4 可以看出, 与传统的 C2f 与 SCDown 结构不同的是, NAMBlock 在卷积模块中引入了 NAM<sup>[21]</sup> 结构, 其将输入的特征图像的通道进行归一化处理, 然后计算归一化

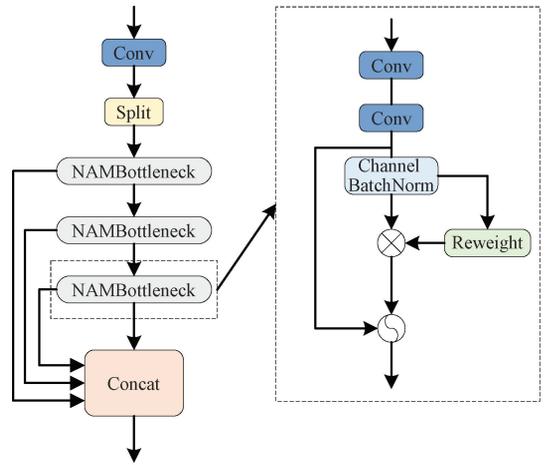


图 4 NAMBlock 结构

Fig. 4 Structure of NAMBlock

后通道的权重值, 再将通道的归一化值与权重值进行加权, 这样就可以筛除冗余信息, 保留关键特征, 最后再通过瓶颈嵌套结构加强关键特征权重, 从而实现高效率的特征提取。

SAFPN-YOLO 在基线模型的主干网络保留了前两层高效的 C2f 模块, 充分利用卷积操作在捕捉图像局部特征的天优势, 在特征提取的前期对图像原有的特征进行保留, 而在后续层级中使用 NAMBlock 模块替代了传统的 C2f 模块, 这一举措使模型在保证小目标特征信息充分保留的前提下, 从更广阔的感受野中提炼关键特征, 从而实现了在全局层面检测的精度与可靠性的提升。为了验证 NAMBlock 模块对于关键特征提取的有效性, 进行了主干网络特征提取的热力图对比实验, 如图 5 所示。

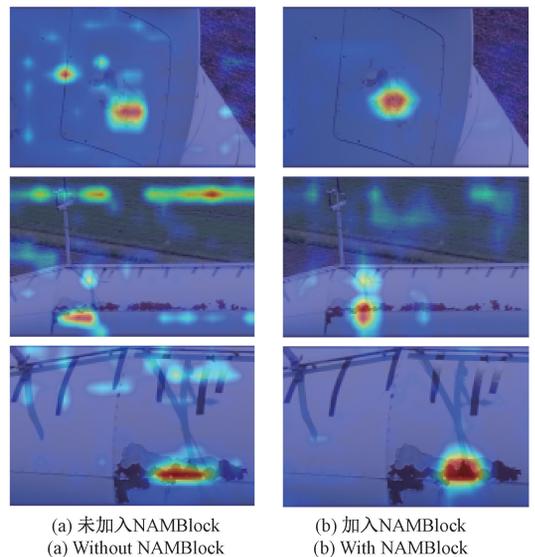


图 5 主干网络提取效果热力图对比

Fig. 5 Comparison of heat maps of backbone network extraction effects

由图 5 (a) 与 (b) 对比, 可以轻易地看出, 在加入

NAMBlock 模块后的主干网络,在弱化冗余信息、提取关键信息方面有更好的表现,相较于未加入该模块的主干网络,可以实现更高效地特征提取。

### 2.3 AS<sup>2</sup>-MLP 注意力机制

为了能够提高模型对风力发电机缺陷中的“表面损伤”缺陷的检测能力,本文基于 S<sup>2</sup>-MLP<sup>[22]</sup> 注意力机制设计了一个新的注意力机制 AS<sup>2</sup>-MLP,可以在增强空间特征的交互性的同时,提高通道特征的表达能力,从而实现空间和通道注意力的协同作用。S<sup>2</sup>-MLP 与 AS<sup>2</sup>-MLP 的结构分别如图 6(a)和(b)所示。

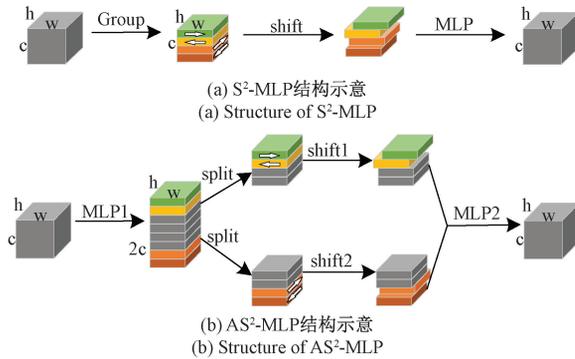


图 6 S<sup>2</sup>-MLP 与 AS<sup>2</sup>-MLP 的结构对比

Fig. 6 Structural comparison between S<sup>2</sup>-MLP and AS<sup>2</sup>-MLP

“表面损伤”缺陷是典型纹理型目标,这类目标通常没有清晰的边界或固定的形状,依赖细微于的纹理、图案、颜色变化等特征来识别,而不是物体的整体结构,这就要求模型有很强的空间特征交互能力和特征表达能力,因此本文在 SAFPN-YOLO 中引入 AS<sup>2</sup>-MLP 注意力机制。

相较于 S<sup>2</sup>-MLP 注意力机制只有拆分与位置变换,可能会导致图像部分特征的丢失,本文在 AS<sup>2</sup>-MLP 中引入了残差结构的思想,能够有效防止信息丢失。AS<sup>2</sup>-MLP 首先对输入的特征图进行 MLP 通道拓展,将特征图的通道数拓展为原通道数的两倍,一半通道进行 Shift1 水平方向的位移,一半通道进行 Shift2 垂直方向的位移,从而实现水平方向和垂直方向的信息交互,并且还保留了完整特征通道,防止交互过程发生信息丢失的情况,最后再对变换后的通道进行 MLP 通道拼接,聚合通道特征信息,可以有效提高对于“表面损伤”缺陷的检测能力。

## 3 实验结果验证与分析

### 3.1 数据集

风机表面缺陷数据集来源于文献[23]提供的风力发电机无人机巡检的公共数据集,该数据集中一共包括了 13 470 张有关风力发电机表面的图片,主要包括风力发电机的叶片、机舱、塔架以及转子 4 个部位照片,数据集中的部分图像如图 7 所示。

本文从中筛选 2 995 张主要包括“表面损伤”缺陷即对

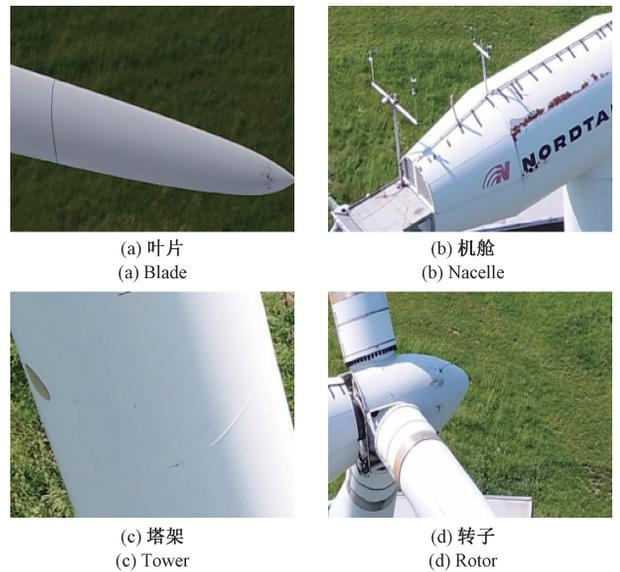


图 7 数据集中的部分图像

Fig. 7 Partial images in the dataset

应标签为“damage”以及“表面脏污”缺陷即对应标签为“dirt”两类缺陷类型,按照 8 : 2 的比例随机划分为训练集和验证集。这两类缺陷在目标检测任务中很具有代表性,“表面损伤”属于纹理型目标,其没有固定形状,通常更小且分布更密集,“表面脏污”通常更大且分布更广泛,两类缺陷对模型的检测能力都有很高的要求,需要模型拥有很好的泛化性和鲁棒性。

### 3.2 实验环境与评估指标

本文实验在 ubuntu20.04 的操作环境下运行,显卡采用 RTX3090,显存为 24 GB,CUDA 的版本为 11.8,使用的计算机语言是 Python3.8,深度学习开发框架为 Pytorch2.0.0,模型训练的具体参数如表 2 所示。

表 2 模型训练参数

Table 2 Parameters of model training

参数	配置
Images size	640×640
Batch size	64
Epoch	200
Initial Learning Rate	0.01

为了能够更全面地评估 SAFPN-YOLO 的性能,本文使用参数量(Param)、吞吐量(Flops)和平均精度均值(mAP)作为模型评价指标。一般而言,参数量越小,表示模型越轻,对部署设备的性能要求就越低;吞吐量是指每秒浮点运算次数,越大表示的就是计算时间越长;平均精度均值是分类任务中所有类别精度的平均,全面反映模型在多分类任务的综合识别能力,越大代表效果越好。其具体的计算公式如式(1)~(4)所示。

$$P = \frac{TP}{TP + FP} \quad (1)$$

$$R = \frac{TP}{TP + FN} \quad (2)$$

$$AP = \int_0^1 P(R) dR \quad (3)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (4)$$

其中,  $P$  表示查准率,即被正确检测的数量占检测出数量的比值。 $R$  表示召回率,即被正确检测的数量占数据集所有检测对象数量的比值。 $TP$  表示被正确检测数量, $FP$  表示被误检的检测对象数量, $FN$  表示被误检的非检测对象数量。 $n$  为检测的类别数, $AP_i$  表示第  $i$  个类别的精确

率,本实验检测的类别数为 2。

### 3.3 消融实验

为验证 SAFPN-YOLO 中提出的 SAFPN 融合网络、NAMBlock 模块以及  $AS^2$ -MLP 的有效性,本文设计了对应的消融实验,结果如表 3 所示,其中“√”表示引入该模块。模型 1 为 YOLOv10n 的基线模型;模型 2 为单独引入 SAFPN 特征融合网络的改进模型;模型 3 为单独引入 NAMBlock 模块的改进模型;模型 4 为单独使用  $AS^2$ -MLP 注意力机制的改进模型;模型 5~模型 7 为引入 SAFPN 特征融合网络、NAMBlock 模块以及  $AS^2$ -MLP 两两组合的改进模型;模型 8 是将 3 个改进点全都融合的改进模型。

表 3 消融实验结果

Table 3 Results of ablation experiments

模型	SAFPN	NAMBlock	$AS^2$ -MLP	mAP50/%	Params/M	Flops/G
模型 1				79.1	2.59	7.7
模型 2	√			80.4	3.06	7.9
模型 3		√		81.0	2.59	7.7
模型 4			√	81.0	2.83	8.6
模型 5	√	√		81.2	3.12	7.9
模型 6	√		√	81.9	3.23	8.7
模型 7		√	√	81.9	2.84	8.6
模型 8	√	√	√	82.4	3.23	8.7

从表 3 中,由模型 1 和模型 2 对比可以得到,使用改进的 SAFPN 融合网络替代经典的 PAN+FPN 结构,模型在参数量只增加了 0.24 M,吞吐量增加了 0.9 G 的情况下,mAP50 值实现了 1.9% 的增长突破,虽然较之 PAN+FPN 结构,SAFPN 显得较为复杂,计算成本有所增加,但是其在减小信息融合时的语义差距从而提高精度的作用不可忽略;由模型 1 和模型 3 对比可以看出,将 SCDown 模块替换成本文的 NAMBlock 轻量化卷积模块后,模型的参数量和计算吞吐量均没有明显变化,而平均检测精度 mAP50 却实现了 1.9% 显著提高,证明了 NAMBlock 模块从复杂背景下提取关键特征的有效性;由模型 1 和模型 4 对比能够发现,在主干网络中加入  $AS^2$ -MLP 注意力机制,mAP50 值提高了 1.3%,模型的参数量和计算吞吐量分别只增加了 0.47 M 和 0.2 G,证明了  $AS^2$ -MLP 注意力机制在牺牲少量计算成本的前提下,确实可以提高模型对于空间特征交互能力和表达能力,从而提高检测的精度;模型 5 到模型 7,将改进的模块两两进行组合,平均检测精度 mAP50 相较于单独引入均有所提升;模型 1 和模型 8 对比,将所有改进点融合到一起,模型在参数量和吞吐量增加并不明显的情况下,平均检测精度 mAP50 均得到了显著提升。实验结果表明,SAFPN-YOLO 的改进是有效果的,尽管参数量和计算成

本略微有些增加,但是改进后的模型平均精度实现了从 79.1% 到 82.4% 的显著提升,可以更准确地实现对风电设备表面缺陷的分类和定位。

### 3.4 对比实验

为了进一步证明本文提出的 SAFPN-YOLO 模型在用于风机表面缺陷检测的优越性,在使用相同的数据集的前提下,与一些经典的目标检测模型 Faster RCNN、SSD、YOLOv5、YOLOv6 和当前一些较新的检测模型 YOLOv7、YOLOv8、YOLOv9 和 YOLOv10 及该领域的新模型,进行了对比实验。为了保证对比实验的公平性,对于有多个版本的模型,本文选择模型参数量版本与本文模型相近的模型作为对比实验对象,此外同样是以平均检测精度 mAP50,参数量和吞吐量作为性能评估指标,其具体表现如表 4 所示。

通过表 4 所展现的对比实验结果可以看出,与经典的模型 Faster RCNN 以及 SSD 相比,SAFPN-YOLO 在参数量和吞吐量远低于他们的情况下,平均检测精度 mAP50 分别超过它们 29.2% 和 16.3%。与其他 YOLO 系列模型进行比较时,均将模型的深度设置为 0.33,宽度设置为 0.25。目前,工业上应用最为广泛的 YOLO 算法是 YOLOv5,SAFPN-YOLO 虽然在吞吐量和参数量上略高于 YOLOv5n,但是其平均检测精度却比之高出了 7.9%,本

表 4 对比实验结果

Table 4 Results of comparative experiments

模型	mAP50/%	Params/M	Flops/G
Faster RCNN	53.2	45.1	148.9
SSD	66.1	23.0	28.5
YOLOv5n	74.6	2.5	7.2
YOLOv6	74.5	4.2	11.9
YOLOv7	80.3	6.0	13.2
YOLOv8n	76.0	3.0	8.2
YOLOv9-T	81.0	2.6	10.7
YOLOv10n	79.1	2.59	7.7
文献[11]	79.9	3.01	7.8
文献[12]	81.9	3.2	8.4
SAFPN-YOLO	82.4	3.23	8.7

文的改进算法更适合用于精度需求高,但部署设备要求也不高的场景。在与 YOLOv6 和 YOLOv7 算法进行对比时,SAFPN-YOLO 的各项评估指标均要优于它们。同时实验也与当前较新的通用模型进行了对比,SAFPN-YOLO 在各项评估指标上均有不错的表现,尤其平均检测精度分别比 YOLOv8, YOLOv9 算法高出 6.4% 和 1.4%。此外,也将 SAFPN-YOLO 与当前最新的有关风机表面缺陷检测领域的模型进行了对比,在参数量以及吞吐量相当的情况下,SAFPN-YOLO 平均检测精度均达到了最高的。SAFPN-YOLO 的各个损失指标随迭代次数的增加如图 8 和 9 所示。由图 8 和 9 可知,随着模型的训练迭代次数的增加,训练集的一对一分配与一对多分配的边界框、分类

以及分布焦点损失逐渐减小并趋于稳定,说明 SAFPN-YOLO 在迭代过程中已充分完成收敛。

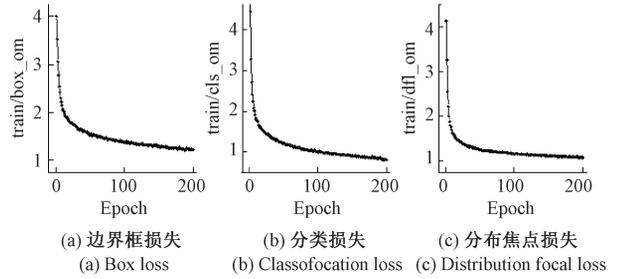


图 8 SAFPN-YOLO 一对多分配的损失曲线

Fig. 8 Curves of SAFPN-YOLO one-to-many assignment losses

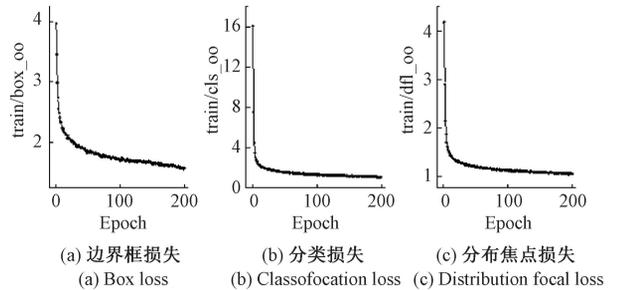


图 9 SAFPN-YOLO 一对一分配的损失曲线

Fig. 9 Curves of SAFPN-YOLO one-to-one assignment losses

为了具体地展现改进模型在实际应用场景中相较于其他模型性能的优越型,本文在数据集中挑选了明暗情景下的“表面脏污”与“表面损伤”缺陷用于进行推理验证,其具体的可视化结果如图 10 所示。

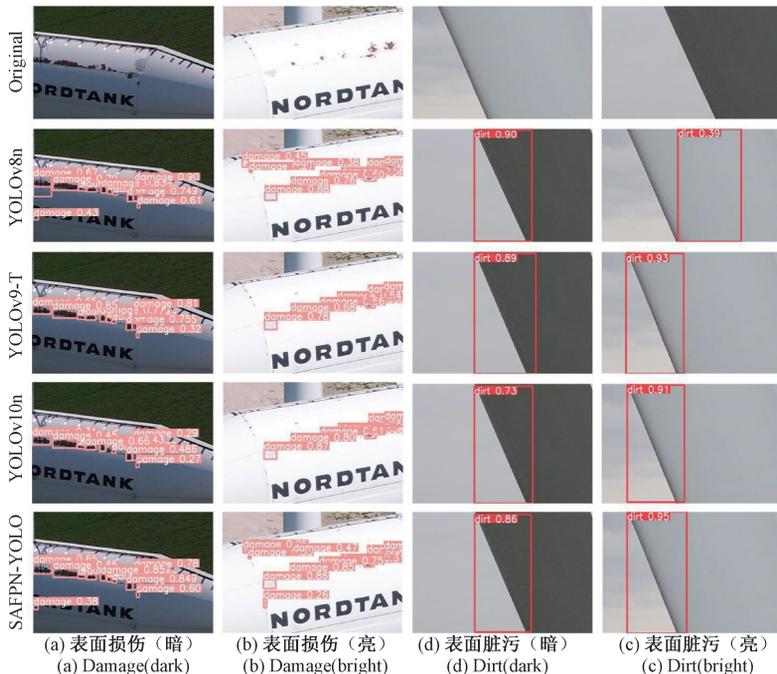


图 10 SAFPN-YOLO 与其他模型实际应用的可视化对比

Fig. 10 Visual comparison of the practical application of other models with SAFPN-YOLO

由图 10(a)可以明显地看出来,在检测光线不足情况下的“表面损伤”缺陷时,改进模型与其他模型的检测效果有明显的差别,其原因是该缺陷在图片中所占据的像素过少且形状大小各异,YOLOv9 与 YOLOv10 模型不能充分地图像中的缺陷特征提取并融合,从而出现漏检的情况,而 SAFPN-YOLO 与 YOLOv8 均没有出现漏检的情况,还表现出极佳的定位效果;如图 10(b)推理图片中,检测光线充足情况下的“表面损伤”,YOLOv8 也出现了漏检的情况,而 SAFPN-YOLO 依然可以实现精确检测,证明本文改进模型在特征提取上优异的鲁棒性;由图 10(c)和(d)所示,对于“表面脏污”这种尺度较大缺陷类型的检测,SAFPN-YOLO 与其他模型都展现出不错的检测效果,除了 YOLOv8 出现定位不准的情况,这是由于目标多尺度造成的。综上所述,本文改进模型在实际的应用中,检测效果上要优于较新的 YOLO 模型。

## 4 结 论

本文结合风力发电机缺陷类型以及无人机采集数据的特点,提出了一种基于 SAFPN-YOLO 的风机表面缺陷检测算法,相较于基线模型与当前主流模型,其在平均检测精度上都有更好的表现,为风力发电机缺陷的目标检测提供了一种新的方法。此外,通过实验分析验证,可以得到以下结论:SAFPN 可以显著提高网络对于不同尺寸信息的融合能力,尤其是解决针对无人机不同拍摄角度所引起的目标多尺度问题;在主干提取网络的深层嵌入 NAMBlock 模块,可以提高网络从复杂信息背景中提取特征的能力,使模型更加关注缺陷的位置;AS<sup>2</sup>-MLP 注意力机制能够有效增强空间特征交互能力和特征表达能力,从而提高模型对于“纹理型”目标的检测能力。

综上所述,本文所提出的 SAFPN-YOLO 模型,在风机表面缺陷检测上,有更高的精度和鲁棒性,能够准确识别风机表面缺陷。在接下来的研究中,将进一步挖掘风机表面其他缺陷类型的特点,提高对于风机表面各种缺陷类型的识别能力,以期实现更全面的风机表面缺陷检测方法。

## 参考文献

- [1] 张银胜,杨宇龙,吉茹,等.改进 YOLOv5s 的风力涡轮机表面缺陷检测[J].电子测量与仪器学报,2023,37(1):40-49.  
ZHANG Y SH, YANG Y L, JI R, et al. Surface defect detection of wind turbine based on YOLOv5s[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 40-49.
- [2] 张鸿泰,杨书仪,何先龙,等.陆上风力发电机塔架振动监测研究进展[J].电子测量技术,2023,46(7):172-179.  
ZHANG H T, YANG SH Y, HE X L, et al. Research progress of tower vibration monitoring for onshore wind turbine [J]. Electronic Measurement Technology, 2023, 46(7): 172-179.
- [3] PENG H, ZHANG H, FAN Y S, et al. A review of research on wind turbine bearings' failure analysis and fault diagnosis[J]. Lubricants, 2022, 11(1): 14.
- [4] ZHAO Y, ZHANG Y J, LI Z Q, et al. AI-enabled and multimodal data driven smart health monitoring of wind power systems: A case study [J]. Advanced Engineering Informatics, 2023, 56: 102018.
- [5] KONG K, DYER K, PAYNE CH, 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.
- [6] 张建斐.基于机器视觉的风力发电机叶片表面缺陷检测研究[D].兰州:兰州理工大学,2018.  
ZHANG J F. Study on detecting surface defects of wind turbine blade based on machine vision [D]. Lanzhou: Lanzhou University of Technology, 2018.
- [7] 张保钦,雷保珍,赵林惠,等.风机叶片故障预测的振动方法研究[J].电子测量与仪器学报,2014,28(3):285-291.  
ZHANG B Q, LEI B ZH, ZHAO L H, et al. Research on vibration method of fan blade fault forecasting[J]. Journal of Electronic Measurement and Instrumentation, 2014, 28(3): 285-291.
- [8] 张晨辉.基于空时联合处理与深度学习的风机叶片故障声学检测[D].杭州:浙江大学,2023.  
ZHANG CH H. Acoustic detection of wind turbine blade faults with spatial-temporal joint processing and deep learning[D]. Hangzhou: Zhejiang University, 2023.
- [9] 张朋,张玉,崔锟,等.基于修正热弹性应力分析的风机叶片热红外温度检测[J].激光与光电子学进展,2023,60(15):211-218.  
ZHANG P, ZHANG Y, CUI K, et al. Inspection of wind turbine blades based on modified thermoelastic stress analysis using thermal detection of infrared radiation [J]. Laser & Optoelectronics Progress, 2023, 60(15): 211-218.
- [10] 何赆泽,李响,王洪金,等.基于可见光和热成像的风机叶片全周期无损检测综述[J].机械工程学报,2023,59(6):32-45.  
HE Y Z, LI X, WANG H J, et al. A review: Full-cycle nondestructive testing based on visible light and thermography of wind turbine blade [J]. Journal of Mechanical Engineering, 2023, 59(6): 32-45.
- [11] LIU L ZH, LI P R, WANG D H, et al. A wind

- turbine damage detection algorithm designed based on YOLOv8 [J]. Applied Soft Computing, 2024, 154: 111364.
- [12] PENG J SH, MA H N, CHEN Q H, et al. Diagnosis method for surface defects of fans based on MB-YOLOv8[J]. Power Generation Technology, 2024: 1, DOI:10.12096/j.2096-4528.pgt.24164.
- [13] 高立鹏, 周孟然, 胡锋, 等. 基于 REIW-YOLOv10n 的井下安全帽小目标检测算法[J/OL]. 煤炭科学技术, 1-13 [2025-02-26]. <http://kns.cnki.net/kcms/detail/11.2402.td.20240919.1902.003.html>.  
GAO L P, ZHOU M R, HU F, et al. Small target detection algorithm for underground helmet based on REIW-YOLOv10n [J/OL]. Coal Science and Technology, 1-13 [2025-02-26] <http://kns.cnki.net/kcms/detail/11.2402.td.20240919.1902.003.html>.
- [14] 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 bike helmet wearing detection algorithm based on improved YOLOv10n [J]. Electronic Measurement Technology, 2025,48(5):40-49.
- [15] YANG G Y, LEI J, ZHU ZH K, et al. AFPN: Asymptotic feature pyramid network for object detection[J]. ArXiv preprint arXiv: 2306.15988, 2023.
- [16] WANG AO, CHEN H, LIU L H, et al. YOLOv10: Real-time end-to-end object detection [J]. ArXiv preprint arXiv: 2405.14458, 2024.
- [17] YUN S, HAN D, CHUN S, et al. Cutmix: Regularization strategy to train strong classifiers with localizable features [C]. IEEE/CVF International Conference on Computer Vision, 2019: 6023-6032.
- [18] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2117-2125.
- [19] HE K M, ZHANG X Y, REN SH Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern analysis and Machine Intelligence, 2015, 37(9): 1904-1916.
- [20] LIU S T, HUANG D, WANG Y H. Learning spatial fusion for single-shot object detection [J]. ArXiv preprint arXiv: 1911.09516, 2019.
- [21] LIU Y CH, SHAO Z R, TENG Y Y, et al. NAM: Normalization-based attention module [J]. ArXiv preprint arXiv: 2111.12419, 2021.
- [22] YU T, LI X, CAI Y F, et al. S<sup>2</sup>-MLP: Spatial-shift MLP architecture for vision[C]. IEEE/CVF Winter Conference on Applications of Computer Vision, 2022: 297-306.
- [23] FOSTER A, BEST O, GIANNI M, et al. Drone footage wind turbine surface damage detection[C]. 2022 IEEE 14th Image, Video, and Multidimensional Signal Processing Workshop (IVMSP). IEEE, 2022: 1-5.

### 作者简介

**金鑫**(通信作者), 副教授, 硕士, 硕士研究生导师, 主要研究方向为智能巡检机器人、煤矿机电设备控制。

E-mail:6020060009@jsnu.edu.cn

**井瑞**, 硕士研究生, 主要研究方向为目标检测、图像处理。

E-mail:1606330304@qq.com

**蒋宜辰**, 硕士研究生, 主要研究方向为电力电子与电力拖动。