

# 基于改进YOLOv5s的风电叶片表面缺陷检测方法

王 俊 高贵兵\*

湖南科技大学机电工程学院,湘潭,411100

**摘要:**为了提高风电机组叶片健康监测技术的智能化、高效化、便捷化发展,依据目标识别技术提出一种基于改进YOLOv5s算法的风电叶片表面缺陷检测方法。首先将YOLOv5s算法的原始骨干网络用渐进特征金字塔网络(AFPN)替换,增强了网络的学习能力;其次将卷积块注意力模块(CBAM)嵌入到主干提取网络中,提高了模型对叶片表面缺陷特征的提取能力;然后使用最小点距离交并比(MPDIoU)损失函数替换CIoU损失函数,提高了边界框定位精度;最后,采用改进的检测方法对某风电机组叶片进行缺陷检测。检测结果表明,改进后的算法在精确率、召回率和平均精度均值(mAP)等方面分别提高了4.1%、2.9%和4.8%,达到了91.9%、89.3%和93.5%,具有显著的精度优势和更好的模型稳定性。

**关键词:**风电叶片;缺陷检测;渐进特征金字塔网络;卷积块注意力模块

中图分类号:TP391.4

DOI:10.3969/j.issn.1004-132X.2025.09.023

开放科学(资源服务)标识码(OSID):



## A Method for Detecting Surface Defects on Wind Turbine Blades Based on Improved YOLOv5s

WANG Jun GAO Guibing\*

School of Mechanical and Electrical Engineering, Hunan University of Science and Technology, Xiangtan, Hunan, 411100

**Abstract:** In order to improve the intelligent, efficient, and convenient development of wind turbine blade health monitoring technology, a wind turbine blade surface defect detection method was proposed based on improved YOLOv5s algorithm according to target recognition technology. Firstly, the original backbone network of YOLOv5s was replaced with an AFPN to enhance the network's learning ability. Secondly, the CBAM was embedded into the backbone extraction network, which enhanced the model's ability to extract surface defect features of leaves. Then, the minimum point distance intersection over union (MPDIoU) loss function was used to replace the CIoU loss function, improving the precision of bounding box localization. Finally, an improved detection method was used to detect defects in the blades of a certain wind turbine unit. The detection results show that the improved algorithm improves precision, recall and mean average precision (mAP) by 4.1%, 2.9% and 4.8%, respectively, reaching as 91.9%, 89.3% and 93.5%, which has significant precision advantages and better model stability.

**Key words:** wind turbine blade; defect detection; asymptotic feature pyramid network (AFPN); convolutional block attention module (CBAM)

### 0 引言

我国2023年累计并网风电装机4.4亿千瓦,风电装机规模持续扩大,预计到2050年装机容量将达到2.4TW。随着风电装机容量的不断增大,“风电机组出质保”问题的形势非常严峻,每年有约14~18GW风机质保到期,2023年运维市场规模超过200亿元,年复合增长率高达10.29%。据统计,风电叶片维护费用占机组总维护费用的21%<sup>[1]</sup>。准确监测风电机组叶片的健康状态、降

低机组运维费用是我国乃至全世界风电行业亟需解决的技术难题之一。

叶片是风电机组的核心部件,作用重要<sup>[2]</sup>。叶片服役期间,长期运行在恶劣的自然环境中,受到氧化、强风载荷等因素的影响,不可避免地会出现砂眼、磨损、裂纹等缺陷,这些缺陷会缩短叶片寿命,造成巨大的经济损失,甚至引起安全事故,因此,必须对叶片进行缺陷检测<sup>[3-4]</sup>。

传统的风电叶片缺陷检测方法有振动、超声波、红外热成像,这些方法在叶片上安装传感器或外置仪器来获得叶片的相关数据,再对数据进行处理来进行检测。蔺雪峰等<sup>[5]</sup>设计了一种风机叶片状态实时检测系统,根据叶片振动信号实现状

收稿日期:2024-09-27

基金项目:湖南省自然科学基金(2023JJ60145);湖南省杰出青年基金(2024JJ2031);湖南省科技创新计划(2023RC3174)

态检测和故障诊断,但对振动信号的要求较高。章学兵等<sup>[6]</sup>采用超声波对叶片缺陷进行检测,能有效检测出叶片内部缺陷,但效率低且材料性能被破坏。总之,传统检测方法有很大的局限性,应用效果不理想。

随着深度学习技术的发展,基于深度学习的风电叶片缺陷检测方法逐渐普及,主要有单阶段和双阶段两类<sup>[7]</sup>。双阶段检测方法包括Fast R-CNN<sup>[8]</sup>、Faster R-CNN<sup>[9]</sup>、Mask R-CNN<sup>[10]</sup>等。苏步宇等<sup>[11]</sup>基于Mask R-CNN模型对ResNet融合卷积块注意力模块(convolutional block attention module, CBAM)构建残差卷积注意力网络,添加Dice Loss函数优化损失函数,引入Douglas-Peucker算法、精细多边形正则化算法相结合的后处理策略,改进模型的mAP@0.5(交并比为0.5时的平均精度均值)提高了7.74%。冯冰等<sup>[12]</sup>针对图元检测精度低的问题提出一种基于改进Faster R-CNN的变电站电器主接线图图元检测方法,引入深度残差网络结构和特征金字塔网络,改进方法的平均检测精度达到88.9%。上述方法检测精度高,但计算复杂、参数量大,难以满足实时监测的需求。单阶段检测方法包括YOLO系列<sup>[13-16]</sup>、单次多框检测器(single shot multibox detector, SSD)<sup>[17]</sup>、RetinaNet<sup>[18]</sup>等。鄢之麟等<sup>[19]</sup>建立了基于改进YOLOv5算法的铸件表面缺陷检测模型,将CSPDarknet53替换为C2f,引入坐标注意力(coordinate attention, CA)机制,改进模型的精确率由78.2%提高至82.9%。徐东亮等<sup>[20]</sup>针对拉挤板缺陷检测问题,通过改进YOLOv5s模型实现了检测精度和速度的提升。孙铁强等<sup>[21]</sup>通过加入PConv卷积层、跨尺度通道注意力(cross-

scale channel attention, CSCA)机制和使用WIoUv2损失函数等改进YOLOv7模型,用来对钢卷端面缺陷进行检测,提高了精确率和速度。郭桂标等<sup>[22]</sup>提出了一种自注意力(self-attention, SA)-YOLO算法,使油管表面缺陷的平均精度达到93%,提高了3.3%。王林琳等<sup>[23]</sup>提出了一种基于YOLOv5s的带钢表面缺陷检测算法,改进算法的平均精确率达到92.2%,提高了4.7%,帧率(FPS)达到了82。上述检测方法在缺陷检测方面取得了一定成果,但由于无人机拍摄的叶片图像存在大小不一,拍摄的叶片缺陷尺度不一等问题,这些方法很难保证缺陷检测的精度,且缺陷分类不理想。

针对上述问题,本文提出了一种基于改进YOLOv5s算法的风电叶片缺陷检测方法。改进的基本原理是:将YOLOv5s的原始骨干网络替换为渐进特征金字塔网络(asymptotic feature pyramid network, AFPN)以增强网络的学习能力,将CBAM注意力机制加入到主干提取网络中,增强模型对叶片表面缺陷的特征提取能力,使用最小点距离交并比(minimum point distance intersection over union, MPDIoU)损失函数替换CIoU损失函数,提高了边界框定位精度。实验结果验证了本文算法能实现对叶片表面缺陷的检测和分类,有利于叶片的检修维护工作。

### 1 YOLOv5s 算法

YOLOv5s算法主要由输入端(Input)、骨干网络(Backbone)、颈部网络(Neck)和预测层(Prediction)组成,其网络结构图见图1。

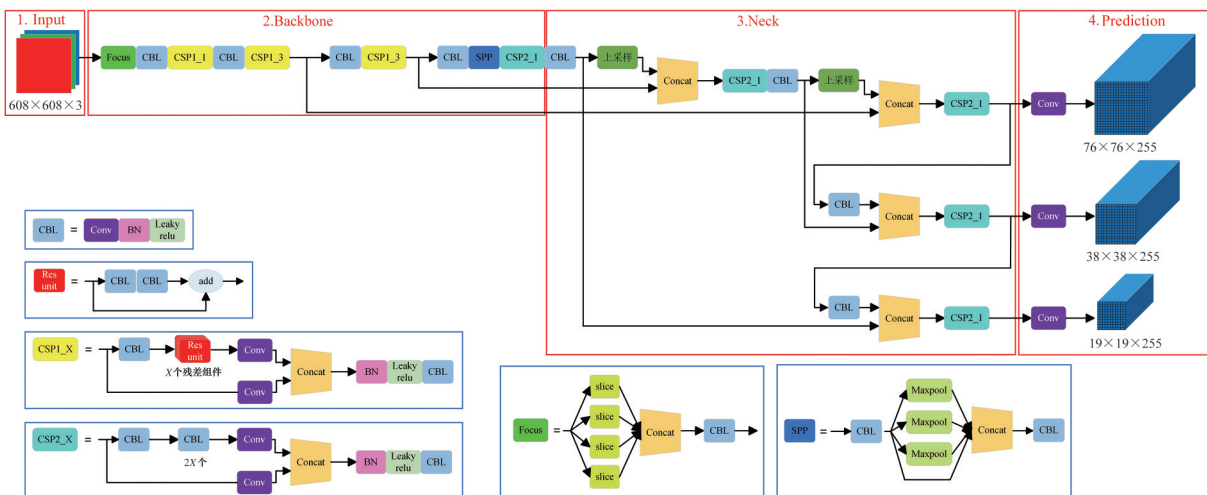


图1 YOLOv5s网络结构图

Fig.1 YOLOv5s network structure diagram

1) 输入端。YOLOv5s 算法在输入端采用 Mosaic 数据增强、自适应锚框计算、自适应图片缩放等方法对输入通道的图片进行预处理。其中 Mosaic 数据增强是对数据集随机缩放、随机剪裁和随机排布,可以有效提高数据集的复杂度,并减少 GPU 的内存使用。自适应锚框计算是指 YOLO 系列检测算法中,针对不同目标均会初始设定好默认长宽的锚框,进行训练时在初始设定好的锚框基础上输出一个预测框,将标注的真实框和预测框进行对比,并且计算它们的差值,之后再反向更新,迭代网络结构中的参数。

2) 骨干网络。特征提取网络由 Focus 结构和 CSP 结构两个主要部分组成。在 YOLOv5s 算法中,Focus 模块的作用是在图片进入 Backbone 前对其进行切片操作。经过切片操作后拼接起来的图片相对于原先的 RGB 三通道模式变成了 12 个通道,最后将得到的新图片再经过卷积操作,最终得到没有信息丢失情况下的二倍采样特征图,在没有信息丢失的情况下提高了计算力。CSPNet 将特征图拆成两个部分,一部分进行卷积操作,另一部分与上一部分卷积操作的结果进行拼接。YOLOv5s 算法中有两种结构的 CSP,一种 CSP\_X 结构应用在 Backbone 主干网络中,另一种 CSP\_X 结构应用在 Neck 中。使用 CSP 模块可以有效增强网络的学习能力,使得训练出的模型既能保持轻量化,又能有较高的准确性,从而可减少计算瓶颈和降低内存成本。

3) 颈部网络。颈部网络采用 FPN+PAN 结构。其中 FPN 为自顶向下结构,通过下采样操作将高层特征信息与低层特征信息进行融合,进而计算出预测的特征图。YOLOv5s 算法中,在 FPN 层后面还添加了一个自下向上的特征金字塔,有两个 PAN 结构,通过下采样操作将低层特征信息与高层特征融合,进而输出预测的特征图。通过自顶向下的 FPN 层传达强语义特征,再通过自底向上的特征金子塔传达强定位特征,从不同的主干层对不同的检测层进行参数融合。

4) 预测层。对提取到的特征进行进一步处理,包括 Bounding box 损失函数的计算和非极大值抑制(non-maximum suppression, NMS),生成最终的预测结果。

## 2 YOLOv5s 算法的改进

### 2.1 改进渐进特征金字塔网络

由于风电叶片部分缺陷较小,在无人机拍摄

的可见光图像中有一定数量的缺陷呈现为小目标,并且较为密集,这就需要在特征融合阶段整合更多的小目标信息,以避免出现缺陷漏检现象。本文采用渐进特征金字塔网络(AFPN)来解决上述问题,如图 2 所示,其中黑色箭头表示卷积操作,蓝色箭头表示自适应空间融合操作。在自下而上的特征提取过程中,从主干网络的每个特征层中提取最后一层特征,得到一组不同尺度的特征,表示为  $\{C_2, C_3, C_4, C_5\}$ 。首先将低层特征  $C_2$  和  $C_3$  输入到特征金字塔网络中进行融合,然后加入  $C_4$ ,最后加入  $C_5$ 。经过特征融合步骤后,可以得到一组多尺度特征  $\{P_2, P_3, P_4, P_5\}$ 。这种融合方式可以避免非相邻层次之间存在的语义差距。在特征融合过程中,模型通过学习空间滤波冲突信息来抑制不一致性,将有利用价值的信息保留后再加以组合,自动地学习权重参数,以渐进的方式将低层特征与高层特征的语义信息和详细信息相互融合,避免了多级传输中的信息丢失或退化,从而提高特征尺度的不变性,且引入的计算开销很小,实现简单。




图 2 AFPN 的结构

Fig.2 AFPN structure

### 2.2 CBAM 注意力机制

由于拍摄角度和光照条件等因素会影响无人机拍摄的图片质量,改进后的模型需要加强对缺陷特征和缺陷位置的敏感性,防止特征丢失,因此,本文在 YOLOv5s 模型的特征提取部分添加了 CBAM 注意力模块,以增强模型对风机叶片表面缺陷的特征提取能力。

CBAM 注意力模块由通道注意力模块(图 3)和空间注意力模块(图 4)组成。通道注意力模块(channel attention module, CAM)首先将输入特征图  $F$  (高度  $H \times$  宽度  $W \times$  通道数  $C$ ) 经过基于通道的最大池化和平均池化,得到两个  $1 \times 1 \times C$  的特征图;其次将最大池化和平均池化的结果用共享的全连接层进行处理,先通过一个全连接层减少通道数,再通过另一个全连接层恢复通道数;然后将共享全连接层得到的结果进行相加,使用 Sigmoid 激活函数生成最终的通道注意力特征,获得输入特征层每一个通道的权重(0~1 之间);

最后将权重通过乘法通道加权到输入特征层上，以生成空间注意力模块需要的输入特征  $F'$ 。




图3 通道注意力模块结构图

Fig.3 Diagram of channel attention module structure




图4 空间注意力模块结构图

Fig.4 Diagram of spatial attention module structure

空间注意力模块 (spatial attention module, SAM) 对输入特征  $F'$  在通道维度下进行最大池化和平均池化，池化后的两张特征图在通道维度堆叠，经过一个  $7 \times 7$  卷积操作，降维为一个通道，得到一个  $H \times W \times 1$  的特征图。卷积后的结果经过 Sigmoid 非线性激活，归一化特征图的空间权重，再将输入特征  $F'$  和权重相乘得到特征  $F''$ 。

具体操作过程为：给出一个中间特征图  $F \in \mathbb{R}^{C \times H \times W}$  作为输入，首先对输入特征图进行全局最大池化和全局平均池化，将池化后的两个一维向量输入到全连接层，相加生成一维通道注意力矩阵  $M_c \in \mathbb{R}^{C \times 1 \times 1}$ ，并将通道注意力矩阵  $M_c$  与输入元素相乘，得到通道注意力调整后的特征图  $F'$ ；然后进行空间注意力计算，将按空间进行全局最大池化和全局平均池化后得到的张量拼接在一起后进行卷积操作和 Sigmoid 非线性激活，归一化特征图的通道权重，生成空间注意力矩阵  $M_s \in \mathbb{R}^{1 \times H \times W}$ ，再将  $M_s$  与  $F'$  逐元素相乘得到  $F''$ 。具体过程可通过下式描述：

$$\left. \begin{aligned} F' &= M_c(F) \otimes F \\ F'' &= M_s(F') \otimes F' \end{aligned} \right\} \quad (1)$$

其中，“ $\otimes$ ”表示逐元素相乘，在相乘之前，通道注意力机制和空间注意力机制分别按照通道维度和空间维度进行广播， $M_c(F)$  和  $M_s(F')$  的计算公式分别为

$$\begin{aligned} M_c(F) &= \sigma(MLP(AvgPool(F))) + \\ &MLP(MaxPool(F)) = \\ &\sigma(W_1(W_0(F_{avg}^C)) + (W_1(W_0(F_{max}^C)))) \end{aligned} \quad (2)$$

$$\begin{aligned} M_s(F') &= \sigma(f^{7 \times 7}([AvgPool(F'); MaxPool(F')])) = \\ &\sigma(f^{7 \times 7}([F_{avg}^S; F_{max}^S])) \end{aligned} \quad (3)$$

其中， $F$  表示输入的特征图； $M_c(F)$  表示最终得到的不同通道的权重矩阵； $MLP(\cdot)$  表示通过多层感知器进行池化计算； $\sigma(\cdot)$  表示 Sigmoid 激活函数； $AvgPool(F)$  表示对  $F$  应用平均池化； $MaxPool(F)$  表示对  $F$  应用最大池化； $W_0$ 、 $W_1$  为两层多层感知机的权值矩阵； $F_{avg}^C$ 、 $F_{max}^C$  分别为经平均池化得到的通道注意力特征和空间注意力特征； $F_{max}^C$ 、 $F_{max}^S$  分别为经最大池化得到的通道注意力特征和空间注意力特征； $f^{7 \times 7}(\cdot)$  表示卷积核为  $7 \times 7$  的卷积； $M_s(F')$  表示得到的空间中不同位置的权重矩阵。

### 2.3 MPDIoU 边界框损失函数

YOLO 算法系列使用的是 CIoU 损失函数。CIoU 损失函数反映的是长宽比的不同，而不是长宽位置与置信度之间存在的实际差距，当实际检测框与预测框中心点重合导致长宽比一致时，CIoU 损失函数就会失效，并且在多个预测框大面积重叠的情况下不能反映出实际情况。CIoU 损失函数的计算公式如下：

$$L_{CIoU} = 1 - R_{IoU} + \frac{\rho^2(B_{gt}, B_{prd})}{l^2} + \alpha v \quad (4)$$

$$R_{IoU} = \frac{B_{gt} \cap B_{prd}}{B_{gt} \cup B_{prd}}$$

$$\alpha = \frac{v}{(1 - R_{IoU}) + v}$$

$$v = \frac{4}{\pi^2} \left( \arctan \frac{W_{gt}}{h_{gt}} - \arctan \frac{W_{prd}}{h_{prd}} \right)^2$$

式中： $R_{IoU}$  为预测框和真实框的交并比； $B_{prd}$ 、 $B_{gt}$  分别为预测框和真实框的中心点坐标； $\rho(\cdot)$  表示预测框和真实框的距离差值； $l$  为预测框和真实框间的最小包围框的对角线长度； $\alpha$  为权衡参数； $v$  为衡量长宽比的一致性的参数； $W_{gt}$ 、 $h_{gt}$  分别为真实框的宽度和高度； $W_{prd}$ 、 $h_{prd}$  分别为预测框的宽度和高度。

为解决上述问题，本文采用一种基于最小点距离的边界框相似度比较度量 (即 MPDIoU)，它包含了 CIoU 损失函数中未考虑的相关因素 (如重叠或非重叠面积、中心点距离以及宽度和高度的偏差)，同时简化了计算过程。该方法直接最小化预测边界框与实际标注框之间的左上角和右下角点距离，其计算公式如下：

$$L_{MPDIoU} = 1 - R_{MPDIoU} \quad (5)$$

$$R_{MPDIoU} = R_{IoU} - \frac{d_1^2}{w^2 + h^2} - \frac{d_2^2}{w^2 + h^2}$$

$$d_1^2 = (x_1^{prd} - x_1^{gt})^2 + (y_1^{prd} - y_1^{gt})^2$$

$$d_2^2 = (x_2^{prd} - x_2^{gt})^2 + (y_2^{prd} - y_2^{gt})^2$$

式中： $w$ 、 $h$  分别为输入图片的宽和高； $(x_1^{prd}, y_1^{prd})$  和  $(x_2^{prd}, y_2^{prd})$  分别为预测框的左上角和右下角点坐标； $(x_1^{gt}, y_1^{gt})$  和  $(x_2^{gt}, y_2^{gt})$  分别为真实框的左上角和右下角点坐标。

$y_2^{pd}$ )分别为预测框的左上角和右下角坐标; $(x_1^g, y_1^g)$ 、 $(x_2^g, y_2^g)$ 分别为真实框的左上角和右下角坐标。

### 3 实验数据与分析

#### 3.1 实验环境和参数设置

本文实验环境基于 Windows Server 2012 R2 Datacenter 操作系统,以 pytorch1.10.0 和 CUDA11.4 为深度学习框架,编译软件为 PyCharm,python 版本为 3.9。CPU 为 Inter(R) Xeon(R) Gold 6138。GPU 为 NVIDIA Quadro P5000。实验采用的超参数如下:批量训练图片数(Batch-size)为 64,训练轮次(Epoch)为 200,线程数(workers)为 10,图片尺寸(image-size)为 384 pixel×384 pixel,初始学习率(lr)为 0.01,随机梯度下降(stochastic gradient descent, SGD)动量因子(momentum)为 0.937,优化器为 SGD 优化器,优化器权重缩减(weight-decay)为 0.0005,其他参数设置默认。

#### 3.2 评估指标

为验证所提方法的有效性,采用多项评估指标进行验证,包括精确率(Precision)、召回率(Recall)、平均精度均值(mean average precision, mAP)、模型参数量(Parameters)和每秒浮点计算量(floating point operations per second, FLOPs)等。以此构成了一个全面的评价框架,用以评估改进方法在实际应用中的效能及其资源消耗情况<sup>[24]</sup>。

精确率  $P$ 、召回率  $R$  和平均精度均值的计算公式如下:

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (6)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (7)$$

$$P_A = \int_0^1 P(R) dR \quad (8)$$

$$P_{mA} = \frac{1}{c} \sum_{i=1}^c P_{Ai} \quad (9)$$

式中: $N_{TP}$ 为正确预测为正类的数目(true positive, TP); $N_{FP}$ 为错误预测为正类的数目(false positive, FP); $N_{FN}$ 为错误预测为负类的数目(false negative, FN); $P_A$ 为模型对某一类缺陷的平均精度值,表示  $P$ - $R$  曲线与坐标轴所包围的面积; $P_{mA}$ 为所有类型缺陷的平均精度的均值; $c$ 为缺陷类别的数量。

#### 3.3 数据集

本文使用的叶片数据集是由现场人员利用无人机巡检时拍摄的高清叶片图像,涵盖不同时间、天气条件和光照条件,数据集的复杂性较高,与实际场景的吻合性较高,更适用于验证改进的缺陷检测方法在各种实际场景中的表现,每幅图像的分辨率为 586 pixel×371 pixel。数据集由 2191 张

图片组成,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。数据集中的部分图片抽样如图 5 所示。



图5 数据集部分图像

Fig.5 Part of the image of the data set

### 4 实验结果与分析

#### 4.1 消融实验

##### 4.1.1 损失函数消融实验

为验证本文损失函数的有效性,在同样的实验环境下,与 YOLO 算法系列原有的 CIoU 损失函数以及主流的 EIoU、Alpha IoU、SIoU、WIoU 和 MPDIoU 损失函数进行对比实验。将这几种损失函数分别应用在 YOLOv5s 模型中,实验结果如表 1 所示。从表 1 中可以看出,使用 MPDIoU 损失函数的模型在边界框定位精度方面的表现最好,较高的 mAP@0.5 值表明模型预测的边界框与真实的边界框高度重合。相比使用 CIoU 损失函数的 YOLOv5s 模型,本文模型的 mAP@0.5 提高了 1.8%,mAP@0.5:0.95 (交并比为 0.50~0.95 时的平均精度均值)提高了 1.2%,这说明使用 MPDIoU 损失函数能够更加精确地定位边界框,预测精度更高,更适用于航拍图像的检测任务。

表1 损失函数对比实验

Tab.1 Loss function comparison experiment %

损失函数	$P$	$R$	mAP@0.5	mAP@0.5:0.95
YOLOv5s+CIoU	87.8	86.4	88.7	66.9
YOLOv5s+EIoU	89.9	87.6	89.5	67.7
YOLOv5s+Alpha IoU	85.0	80.8	84.4	64.5
YOLOv5s+SIoU	88.3	86.5	88.7	66.8
YOLOv5s+WIoU	90.2	88.8	89.9	67.6
YOLOv5s+MPDIoU	88.9	87.5	90.5	68.1

##### 4.1.2 模块消融实验

为验证模型对风电叶片缺陷检测性能的影响,在实验环境和参数保持不变的基础上设计了 8 组消融实验,实验结果如表 2 所示。

表2 YOLOv5s改进前后的消融实验结果分析  
Tab.2 Results of improved YOLOv5s ablation test

实验	AFPN	CBAM	MPDIoU	P/%	R/%	mAP@0.5/%	mAP@0.5:0.95/%	Parameters
1	×	×	×	87.8	86.4	88.7	66.9	7 015 519
2	√	×	×	88.3	86.9	90.3	67.4	7 554 444
3	×	√	×	90.1	87.0	91.0	67.8	7 048 385
4	×	×	√	88.9	87.5	90.5	68.1	7 015 519
5	×	√	√	91.0	87.6	92.7	69.2	7 048 385
6	√	×	√	90.4	86.3	92.3	68.8	7 554 444
7	√	√	×	91.3	87.6	93.0	68.5	7 587 310
8	√	√	√	91.9	89.3	93.5	69.4	7 587 310

注：“×”为未加入此模块；“√”为加入了此模块。

第1组实验为基础算法YOLOv5s,精确率P为87.8%,召回率R为86.4%,mAP@0.5为88.7%,mAP@0.5:0.95为66.9%。将该算法作为基准模型并与后续实验进行对比。

第2~4组实验分别添加了1种模块进行实验,从表2中可以看到精确率提升最大的是在主干网络中添加了CBAM注意力机制的实验组,其精确率达到了90.1%,相较于基准模型提高了2.3%,这说明添加CBAM注意力机制后模型能更有效地捕捉风电叶片缺陷的特征,增强了模型的特征提取能力。此外,通过使用MPDIoU损失函数替代原YOLOv5s的损失函数,使改进后mAP@0.5达到了90.5%,相较于基准模型提高了1.8%,说明MPDIoU损失函数有效优化了计算方式,解决了原始损失函数在模型训练中失效的情况。

第5~7组实验分别同时对模型进行了2种改进,其中将原始骨干网络替换为渐进特征金字塔网络(AFPN)和添加了CBAM注意力机制的实验组在精确率和mAP@0.5上相较于基准模型分别提高了3.5%和4.3%,分别达到91.3%和93%,召回率也提高了1.2%,达到87.6%。

第8组为结合了3种改进方式的实验组,模型在精确率、召回率和mAP@0.5上相较于基准模型分别提高了4.1%、2.9%和4.8%,分别达到91.9%、89.3%和93.5%,说明改进后的模型具有显著的精度优势和更好的模型稳定性。

由消融实验结果可知,结合了3种改进方式的YOLOv5s网络模型在精确率、召回率和mAP@0.5上较原模型性能均得到有效的提升。

4.2 对比实验

为验证所提算法的性能,将改进的算法和YOLOv5s、YOLOv6、YOLOv7和YOLOv8等YOLO系列算法以及SSD算法和Faster R-CNN算法在叶片数据集上进行对比实验。各种检测方

法在实验中的参数设置尽可能保持一致。对比实验结果如表3所示。本文算法在叶片数据集上mAP@0.5达到了93.5%,模型的参数量和计算量为7.59 M和20.3 G,FPS为138,在参数量、计算效率和平均精度方面相较于SSD、Faster R-CNN、YOLOv6、YOLOv7和YOLOv8算法表现出明显优势,且FPS也有明显提高,平均精度均值相比于上述算法分别提高了11.6%、8.1%、10.2%、6%和3%,相较于基准模型YOLOv5s提高了4.8%,各指标达到均衡。相比于YOLOv8,YOLOv5s添加AFPN、CBAM和MPDIoU后(即YOLOv5s-ACM)的FPS降低每秒17帧,网络参数量和计算量分别减少了31.8%和28.5%。对比实验结果表明,所提方法在风电叶片缺陷检测任务中更好地兼顾了检测精度和速度,具有较好的综合性能和泛化能力,更适合实际应用场景。

表3 常见算法性能比较

Tab.3 Common algorithm performance comparison

算法	Parameters/M	FLOPs/G	mAP@0.5	FPS
SSD	22.67	88.26	81.9	94
Faster R-CNN	41.43	105.2	85.4	21
YOLOv5s	7.02	15.8	88.7	112
YOLOv6	9.67	24.84	83.3	122
YOLOv7	37.2	104.7	87.5	86
YOLOv8	11.13	28.4	90.5	155
YOLOv5s-ACM	7.59	20.3	93.5	138

4.3 在WTB数据集上的性能验证

为进一步测试YOLOv5s-ACM的性能,选用上述检测模型在WTB数据集上进行对比实验。该数据集由3584张无人机拍摄的图片组成,确保了实验数据的多样性和实际应用场景的贴近性,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。实验轮次为200,批量训练图片数为64,初始学习率为0.01,其他参数与3.1节中一致。数据集的部分图片抽样如图6所示。常用算法在WTB数据集上的对比如表4所示。



图6 WTB数据集部分图像

Fig.6 Part of the image of the WTB data set

表4 不同数据集算法对比

Tab.4 Comparison of algorithms on different datasets

算法	mAP@0.5/%	FPS
SSD	79.4	90
Faster R-CNN	84.1	17
YOLOv5s	89.6	110
YOLOv6	81.5	116
YOLOv8	90.1	146
YOLOv5s-ACM	93.6	138

实验结果表明, YOLOv5s-ACM算法在WTB数据集上mAP@0.5相较于SSD、Faster R-CNN、YOLOv5s、YOLOv6和YOLOv8算法分别提高了14.2%、9.5%、4%、12.1%和3.5%,在FPS上本文算法也优于SSD、Faster R-CNN等算

法。综上所述, YOLOv5s-ACM算法在WTB数据集上展现了较为卓越的性能。同时通过补充的另一数据集进一步证明了本文改进模型对风电叶片表面缺陷检测的适用性与优势性。

#### 4.4 可视化结果分析

为进一步直观地验证YOLOv5s-ACM模型的检测效果,与YOLOv5s、YOLOv6和YOLOv8在叶片数据集和WTB数据集上进行对比测试,对比结果如图7和图8所示。

在图7中,第一行的图片中YOLOv5s、YOLOv6都漏检了一个缺陷;第二行的图片中YOLOv6和YOLOv8都出现了误检,而改进算法YOLOv5s-ACM则有效避免了这一问题;第三行的图片中其余三种算法都出现了对缺陷定位不精确的问题,而改进算法则能够准确地检测出这些缺陷。由图8可知,第一行的图片中,YOLOv6和YOLOv8在复杂环境中都出现了漏检问题;在第三行的图片中,YOLOv5s漏检了2个缺陷,YOLOv6和YOLOv8漏检了4个缺陷,而改进算法YOLOv5s-ACM则准确地检测出了这些缺陷。

通过直观比较,改进后的算法在感知能力方面具有明显的优势,能够正确检测出目标,具有更低的误检和漏检概率;改进后的算法在检测精度方面也是这几种主流目标检测模型中最高的,同时具有较强的泛化能力,能够在各种复杂情况下表现出良好的性能。综上所述,本文提出的YOLOv5s-ACM算法能够在复杂多元的场景中完成更加高效的风电叶片缺陷检测任务。




图7 叶片数据集检测结果对比

Fig.7 Comparison of detection results for blade data set



图8 WTB数据集检测结果对比

Fig.8 Comparison of detection results for WTB data set

## 5 结论

本文提出了一种风电叶片缺陷检测模型YOLOv5s-ACM。该方法用AFPN替换YOLOv5s的原始骨干网络,以增强模型对叶片缺陷特征的捕获能力,将CBAM注意力机制嵌入主干提取网络,使模型更加关注叶片缺陷中的关键特征信息,用MPDIoU损失函数替换CIoU损失函数,提高边界框的定位精度。实验结果表明,YOLOv5s-ACM的精确率达到91.9%,召回率为89.3%,平均精度均值为93.5%,在检测精度、参数数量和计算效率等方面都有较大的提升和增强。

由于叶片缺陷数据集数量相对较少,在复杂环境下的检测应用还有局限,在未来的工作中,需要继续扩充数据集,丰富数据集中叶片缺陷的种类和数量,以满足实际应用需求;同时,需要进一步提高算法的精确率,并在满足精确率要求的前提下提高检测速度。

### 参考文献:

[1] 陈雪峰,郭艳婕,许才彬,等. 风电装备故障诊断与健康监测研究综述[J]. 中国机械工程,2020,31(2):175-189.  
CHEN Xuefeng, GUO Yanjie, XU Caibin, et al. Review of Research on Fault Diagnosis and Health

Monitoring of Wind Power Equipment [J]. China Mechanical Engineering, 2020, 31(2):175-189.

[2] 胡蓓,吴永康,郭子君,等. 风力发电叶片裂缝监测技术综述[J]. 高压电器,2022,58(7):93-100.  
HU Bei, WU Yongkang, GUO Zijun, et al. Overview of Crack Monitoring Technology for Wind Power Generation Blades [J]. High Voltage Apparatus, 2022, 58(7):93-100.

[3] 周季峰,石腾,许波峰. 风电机组叶片损伤故障检测技术研究进展[J]. 新能源进展,2023,11(6):556-563.  
ZHOU Jifeng, SHI Teng, XU Fengfeng. Research Progress on Blade Damage Fault Detection Technology for Wind Turbines [J]. New Energy Progress, 2023, 11(6):556-563.

[4] DAVIS M, DEJESUS N E, SHEKARAMIZ M, et al. Identification and Localization of Wind Turbine Blade Faults Using Deep Learning [J]. Applied Sciences, 2024,14(14):6319-6319.

[5] 蔺雪峰,赵江,孟秀俊,等. 基于叶片加速度振动信号的风机叶片状态监测系统[J]. 机械设计与制造工程,2024,53(5):96-100.  
LIN Xuefeng, ZHAO Jiang, MENG Xiujun, et al. Wind Turbine Blade Condition Monitoring System Based on Blade Acceleration Vibration Signals [J]. Mechanical Design and Manufacturing Engineering, 2024, 53(5):96-100.

[6] 章学兵,骆国防. 基于风机叶片缺陷的超声波检测

- 方法分析[J]. 河北电力技术, 2022, 41(1): 76-79.
- ZHANG Xuebing, LUO Guofang. Analysis of Ultrasonic Detection Method Based on Wind Turbine Blade Defects[J]. Hebei Electric Power Technology, 2022, 41(1): 76-79.
- [7] 董文轩, 梁宏涛, 刘国柱, 等. 深度卷积应用于目标检测算法综述[J]. 计算机科学与探索, 2022, 16(5): 1025-1042.
- DONG Wenxuan, LIANG Hongtao, LIU Guozhu, et al. A Review of Deep Convolution Applied to Object Detection Algorithms[J]. Computer Science and Exploration, 2022, 16(5): 1025-1042.
- [8] LI R K, DUAN J L, DENG J Y, et al. Pest Detection Based on Lightweight Locality-Aware Faster R-CNN[J]. Agronomy, 2024, 14(10): 2303-2303.
- [9] MAHESHA Y, NAGARAJU C. Spotting Congenital Heart Diseases Using Palm Print Based on Faster R-CNN and Spatial Method[J]. International Journal of Medical Engineering and Informatics, 2024, 16(1): 56-70.
- [10] ALSHAWABKEH S, WU L, DONG D, et al. A Hybrid Approach for Pavement Crack Detection Using Mask R-CNN and Vision Transformer Model[J]. Computers, Materials & Continua, 2025, 82(1): 561-577.
- [11] 苏步宇, 杜小平, 慕号伟, 等. 耦合 Mask R-CNN 和注意力机制的建筑物提取及后处理策略[J]. 遥感技术与应用, 2024, 39(3): 620-632.
- SU Buyu, DU Xiaoping, MU Haowei, et al. Building Extraction and Post-processing Strategy Coupling Mask R-CNN and Attention Mechanism[J]. Remote Sensing Technology and Applications, 2024, 39(3): 620-632.
- [12] 冯冰, 杜岳凡, 金尧, 等. 改进 Faster R-CNN 的变电站电气主接线图图元检测[J]. 哈尔滨理工大学学报, 2025, 30(4): 39-47.
- FENG Bing, DU Yuefan, JIN Yao, etc Improving Faster R-CNN for Substation Electrical Main Wiring Diagram Element Detection[J]. Journal of Harbin Institute of Technology, 2025, 30(4): 39-47.
- [13] XIAO M, GONG Y, WANG H, et al. Defect Detection of Light Guide Plate Based on Improved YOLOv5 Networks[J]. Optoelectronics Letters, 2024, 20(9): 560-567.
- [14] ATREY J, REGUNATHAN R, RAJASEKARAN R. Real-world Application of Face Mask Detection System Using YOLOv6[J]. International Journal of Critical Infrastructures, 2024, 20(3): 216-240.
- [15] LI J, LIU Y, LI C, et al. Pineapple Detection with YOLOv7-Tiny Network Model Improved via Pruning and a Lightweight Backbone Sub-Network[J]. Remote Sensing, 2024, 16(15): 2805-2805.
- [16] CHEN C, CHEN Z, LI H, et al. Research on Defect Detection in Lightweight Photovoltaic Cells Using YOLOv8-FSD[J]. Sensors, 2025, 25(3): 843-843.
- [17] ZHONG X. CAL-SSD: Lightweight SSD Object Detection Based on Coordinated Attention[J]. Signal, Image and Video Processing, 2024, 19(1): 31-31.
- [18] ISLAM T, SARKER T T, AHMED R K, et al. Detection and Classification of Cannabis Seeds Using RetinaNet and Faster R-CNN[J]. Seeds, 2024, 3(3): 456-478.
- [19] 鄢之麟, 钟收成, 孙进, 等. 基于 CCD-YOLOv5 算法的铸件表面缺陷检测模型[J]. 特种铸造及有色合金, 2024, 44(8): 1083-1089.
- YAN Zhilin, ZHONG Cailiang, SUN Jin, et al. A surface Defect Detection Model for Castings Based on CCD-YOLOv5 Algorithm[J]. Special Casting and Nonferrous Alloys, 2024, 44(8): 1083-1089.
- [20] 徐东亮, 赖九衡, 杨会兰. 基于改进 YOLOv5s 的拉挤板缺陷检测[J]. 复合材料科学与工程, 2025(5): 132-141.
- XU Dongliang, LAI Jiuhe, YANG Huilan. Defect Detection of Extruded Plates Based on Improved YOLOv5s[J]. Composite Materials Science and Engineering, 2025(5): 132-141.
- [21] 孙铁强, 秦愿伟, 宋超, 等. 基于改进 YOLOv7 的钢卷端面缺陷检测[J]. 现代制造工程, 2024(7): 117-125.
- SUN Tieqiang, QIN Yuanwei, SONG Chao, et al. Steel Coil End Face Defect Detection Based on Improved YOLOv7[J]. Modern Manufacturing Engineering, 2024(7): 117-125.
- [22] 郭桂标, 邢雪, 刘宇琦, 等. 融合 SA 注意力机制的 YOLO5s 在石油油管表面缺陷检测的应用[J]. 机床与液压, 2024, 52(24): 228-235.
- GUO Guibiao, XING Xue, LIU Yuqi, et al. Application of YOLO5s with SA Attention Mechanism in Surface Defect Detection of Oil Pipelines[J]. Machine Tool and Hydraulic, 2024, 52(24): 228-235.
- [23] 王林琳, 龚昭昭, 梁泽启. 改进 YOLOv5s 算法的带钢表面缺陷检测[J]. 组合机床与自动化加工技术, 2024(12): 181-186.
- WANG Linlin, GONG Zhaozhao, LIANG Zeqi. Improved YOLOv5s Algorithm for Surface Defect Detection of Strip Steel[J]. Combined Machine Tool and Automation Processing Technology, 2024(12): 181-186.
- [24] 张晖耀, 黄力湘, 陈继清, 等. 基于改进 YOLOv5s 的草莓成熟度检测算法[J]. 南京农业大学学报, 2025, 48(4): 990-999.