

CESL-YOLO: 基于改进 YOLOv8 的 风电叶片表面缺陷检测算法^{*}

韩 鸿 王金明 张 飞 李忠虎

(内蒙古科技大学自动化与电气工程学院 包头 014000)

摘 要: 针对风电机组叶片表面的微小缺陷检测精度低以及模型参数数量大的问题,提出一种基于 YOLOv8n 改进的新型检测框架 CESL-YOLO。首先,在骨干网络中引入卷积块注意力机制(CBAM)注意力机制,增强模型在特征提取过程中对微小缺陷的关注能力;其次,将颈部特征融合网络重构为 EfficientFPN,利用重参数卷积提升多尺度特征的融合效率;随后,采用 Siou 边界框回归损失函数加快模型的收敛速度;最后,设计轻量级稀疏可分离卷积分支检测头(LSSB),提高缺陷定位精度。实验结果表明,CESL-YOLO 相比原模型的精确率、召回率以及 mAP 分别提升了 2.7%、4.8% 和 5.3%,模型的参数量由 3.01 M 下降至 2.82 M,更加适用于风电机组叶片表面缺陷检测任务。

关键词: 风电机组;叶片;深度学习;缺陷检测;YOLOv8n

中图分类号: TN911.73;TN911.74 **文献标识码:** A **国家标准学科分类代码:** 520.6040

CESL-YOLO: An improved YOLOv8-based algorithm for surface defect detection of wind turbine blades

Han Hong Wang Jinming Zhang Fei Li Zhonghu

(School of Automation and Electrical Engineering, Inner Mongolia University of Science and Technology, Baotou 014000, China)

Abstract: To address the challenges of low detection accuracy for small-scale defects and excessive model parameters in wind turbine blade surface inspection, this paper proposes an improved detection framework, CESL-YOLO, based on YOLOv8n. First, the convolutional block attention module (CBAM) is integrated into the backbone to enhance the model's focus on defect regions during feature extraction. Second, the neck structure is redesigned as an EfficientFPN, where re-parameterized convolution is employed to improve multi-scale feature fusion efficiency. Third, the Siou bounding box regression loss function is adopted to accelerate model convergence. Finally, a lightweight sparse-separable branch (LSSB) detection head is developed to improve defect localization accuracy. Experimental results demonstrate that CESL-YOLO outperforms the baseline model, achieving gains of 2.7%, 4.8% and 5.3% in precision, recall and mAP, respectively. Moreover, the model size is reduced from 3.01 M to 2.82 M parameters, making it more suitable for practical wind turbine blade surface defect detection tasks.

Keywords: wind turbines; blades; deep learning; defect detection; YOLOv8n

0 引 言

风电机组叶片表面缺陷检测旨在对风电叶片表面出现的裂纹、侵蚀、破损、涂层脱落等缺陷进行识别与定位^[1]。然而,裂纹、破损类缺陷通常具有尺寸微小和形态多样的特点,传统图像处理的检测方法在多种光照条件和复杂背景下难以保持稳定的检测性能。特别是在大尺度叶片图像中,微小缺陷的像素占比低,导致检测模型难以充分提取关键特征,从而影响缺陷的识别精度^[2]。因此,研究一种高精度且高效

的风电叶片表面缺陷检测算法,对于提升风电机组的运行安全和维护效率具有重要的研究价值与工程意义。

基于深度学习的目标检测方法凭借强大的特征学习能力,能够准确识别出不同类型的缺陷^[3]。目前,基于深度学习的目标检测方法主要分为两类:分别是基于区域选择的二阶段检测方法和基于回归的一阶段检测方法。二阶段检测方法以 Faster R-CNN^[4]、Mask R-CNN^[5] 及 Sparse R-CNN^[6] 为代表,首先通过区域提议网络生成候选区域,然后对候选区域进行分类与边界回归。以 YOLO^[7] 和 SSD^[8]

收稿日期:2025-10-15

^{*} 基金项目:国家自然科学基金(62161042)、内蒙古自然科学基金(2024LHMS06002)、高校基本科研业务费项目(2024QNJ005)资助

为代表的一阶段检测方法,摒弃了生成候选框的步骤,直接将检测任务视为一个单一的回归问题,从而实现端到端输出检测结果。随着深度学习技术的不断发展,一阶段检测因其较快的检测速度与可观的检测精度,得到广泛应用。朱佳伟等^[9]通过将 ResNet 和 ResNeXt 两种残差网络代替传统 SSD 的骨干网络,从而对大目标缺陷的检测精度显著提升,但对于油污类小目标缺陷的检测精度提升有限。李锦达等^[10]提出一种基于多特征融合的 YOLOv4-Tiny 检测方法,有效提高了算法对带钢表面微小缺陷的检测精度。王俊等^[11]提出一种基于 YOLOv5 改进的风电机组叶片表面缺陷检测算法,通过渐进特征金字塔网络优化 Backbone 的结构,使 mAP 提升了 4.8%,但是无法区分缺陷的具体类别。付军军等^[12]通过在 EfficientNet 的特征提取网络中引入非对称卷积提高网络对微小缺陷的检测精度。Ma 等^[13]在 YOLOv8n 中采用一种双向特征金字塔网络优化风电叶片缺陷检测效果,改进后的网络 mAP 提升 1.7%,但其检测能力主要聚焦于灰尘类缺陷,缺乏对多类别缺陷检测的研究。Zou 等^[14]则将 YOLOv8n 的下采样方式替换为特征重组下采样并在 Backbone 中引入动态可分离卷积,从而增强风电叶片表面缺陷检测精度,但模型参数量由 3.01 M 提升至 3.35 M,降低了模型在嵌入式设备的部署能力。

上述算法对于大尺度缺陷具有较高的检测准确率,但存在模型参数量大小目标缺陷的检测精度低等问题。YOLOv8 作为 YOLO 系列算法中体系最为完善且生态最成熟的版本,其 Backbone 采用的 C2f 特征提取结构能够在不显著增加模型复杂度的情况下提升小目标缺陷特征的表达质量^[15]。特别地,其轻量级版本 YOLOv8n 在检测精度与模型体量之间取得了良好的平衡且具有较高的模型稳定性。因此,本文选用 YOLOv8n 作为基线模型并进行改进,以提升其在风电机组叶片表面缺陷检测中的综合性能。首先,在 Backbone 中引入卷积块注意力机制(convolutional block attention module, CBAM)^[16],增强模型对微小缺陷特征的提取能力;然后,将 Neck 的结构重构为 EfficientFPN,从而提升多尺度特征融合的效率;其次,采用 SiOU^[17]边界框回归损失函数加快模型的收敛速度并提升定位精度;最后,设计轻量级稀疏可分离卷积分支检测头(lightweight sparse-separable branch detection head, LSSB),在降低模型参数量的前提下保持缺陷的检测精度。通过实验验证 CESL-YOLO 在风电机组叶片表面缺陷检测任务中的性能。

1 YOLOv8 算法

YOLOv8 算法的网络整体结构由 Input、Backbone、Neck 和 Head 4 个部分组成,网络结构如图 1 所示。其中,Input 部分利用马赛克增强(mosaic data augmentation)、混合增强(mixup data augmentation)、随机尺度缩放(random

scaling)、随机裁剪(random cropping)和颜色扰动(HSV augment)等方法对输入图像进行预处理。Backbone 部分采用标准卷积层与 C2f 模块提取图像中的特征。Neck 部分采用特征金字塔网络(feature pyramid network, FPN)^[18]与路径聚合网络(path aggregation network, PAN)^[19]相结合的 PANet 结构,实现多尺度的特征融合,从而提升模型对小目标与大尺度目标的检测能力。Head 部分采用解耦头(decoupled head)设计,将分类与回归任务分离,以提升边界框定位精度。




图 1 YOLOv8 网络结构

Fig. 1 YOLOv8 network architecture

2 CESL-YOLO 算法

CESL-YOLO 针对 YOLOv8 的 Backbone、Neck、边界框回归损失函数和检测头进行改进,图 2 为 CESL-YOLO 的网络结构示意图。首先,针对 Backbone 的特征提取层引入 CBAM,建模通道与空间维度的特征权重分布,引导模型关注缺陷所在区域的特征,增强对小目标缺陷的检测能力;其次,对于 Neck 部分,将 YOLOv8 的 PANet 结构替换为结构更紧凑的 EfficientFPN,利用重参数化卷积与跨尺度特征交互机制,提升多尺度特征的融合效率;随后,在边界框回归损失函数方面,通过 SiOU 损失函数,引入角度、距离与形状约束,使预测框具备方向性引导与更快的收敛速度;最后,设计 LSSB 检测头,通过稀疏卷积与深度可分离卷积有效降低模型参数量并保持检测精度。

2.1 引入 CBAM 注意力机制

YOLOv8 的 Backbone 通过堆叠卷积层和 C2f 模块来提取缺陷特征,这种结构的固有局限在于对通道与空间维度的特征权重分配缺乏自适应性。风电机组叶片表面缺陷往往表现为多尺度、空间分布离散且背景复杂的特点,若在




图 2 CESL-YOLO 网络结构

Fig. 2 CESL-YOLO network architecture

特征提取过程中未充分关注缺陷区域,则容易导致漏检或检测精度低。因此,本文在 YOLOv8 的 Backbone 部分引入 CBAM 机制,该机制能够在通道维度自适应地分配通道权重,同时在空间维度引导模型聚焦于缺陷区域,从而提升网络对细粒度缺陷特征的表达能力。CBAM 结构如图 3 所示。




图 3 CBAM 注意力机制网络结构

Fig. 3 CBAM attention mechanism network architecture

CBAM 的核心思想是对输入特征图 $F \in \mathbf{R}^{C \times H \times W}$ 提取通道特征并聚焦缺陷的空间位置信息。其特征提取过程可以分为两个阶段:首先通过通道注意力模块提取包含缺陷信息的通道特征;然后通过空间注意力模块聚焦缺陷的空间位置并提取尺度信息。

通道注意力模块对输入特征图 F 分别进行全局平均池化和全局最大池化,得到两组通道描述向量 F_{GAP} 与

F_{GMP} :

$$F_{\text{GAP}}^c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F_{c,i,j} \quad (1)$$

$$F_{\text{GMP}}^c = \max_{i,j} F_{c,i,j} \quad (2)$$

其中, c 为通道维数; H 表示特征图的高; W 表示特征图的宽。

接着,将通道向量 F_{GAP}^c 与 F_{GMP}^c 依次输入到多层感知机(multilayer perceptron, MLP)进行特征变换得到 M_1 和 M_2 , 逐元素相加后利用 Sigmoid 激活函数得到通道注意力权重 M_c :

$$M_c = \sigma(\text{MLP}(F_{\text{GAP}}^c) + \text{MLP}(F_{\text{GMP}}^c)) \quad (3)$$

其中, σ 表示 Sigmoid 激活函数。

最后,将 M_c 与输入特征图 F 进行逐元素相乘得到经过通道加权后的特征图 F' :

$$F' = M_c \otimes F \quad (4)$$

空间注意力模块利用通道加权后的 F' 作为输入,分别在通道维度上进行平均池化和最大池化操作得到两个二维特征图 F_{GAP}^s 和 F_{GMP}^s , 平均池化能够反映空间位置整体响应趋势,而最大池化则刻画了不同位置上最显著的相应区域。将这两个特征图在通道维度拼接后,通过一个 7×7 卷积实现跨尺度特征交互,最后由 Sigmoid 激活函数得到空间注意力权重 M_s :

$$F_{\text{GAP}}^s = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F'_{c,i,j} \quad (5)$$

$$F_{\text{GMP}}^s = \max_{i,j} F'_{c,i,j} \quad (6)$$

$$M_s = \sigma(\text{Conv}_{7 \times 7}(\text{Concat}(F_{\text{GAP}}^s, F_{\text{GMP}}^s))) \quad (7)$$

其中, $\text{Conv}_{7 \times 7}$ 表示卷积核为 7 的卷积层; Concat 为通道维度拼接。

最后,将 M_s 与 F' 逐元素相乘,得到 CBAM 的输出特征 F'' :

$$F'' = M_s \otimes F' \quad (8)$$

2.2 EfficientFPN 特征融合网络

EfficientFPN 是一种基于重参数化的高效特征融合网络。图 4 为 EfficientFPN 特征融合网络的结构示意图, C3、C4、C5 表示来自 Backbone 部分不同尺度的特征图输入, P3、P4、P5 表示经过特征融合后大、中、小尺度的特征图输出。

与 PANet 相比, EfficientFPN 在多尺度特征交互过程中引入了 RepVGG 重参数化卷积模块,使网络能够通过多分支卷积增强特征表达能力。本文将 YOLOv8 的颈部结构替换为 EfficientFPN, 并结合转置卷积(transpose convolution, TConv)模块替换传统上采样,对特征融合过程进行优化,提升网络对风电机组叶片表面缺陷的检测性能。

RepVGG 重参数化卷积模块结构如图 5 所示。RepVGG 卷积模块在训练阶段采用多分支结构,通过并行的卷积分支与恒等映射分支提升特征表达能力。首先,输入特征图




图 4 EfficientFPN 网络结构

Fig. 4 EfficientFPN network architecture

$\mathbf{X}$ 分别经过 1×1 卷积分支、恒等映射分支和 3×3 卷积分支, 得到 3 组特征映射 $\mathbf{X}_1, \mathbf{X}_2, \mathbf{X}_3$ 。这些特征在输出端进行逐元素相加, 得到融合后的特征 $\mathbf{Y}$:

$$\mathbf{X}_1 = \text{BN}_{1 \times 1}(\text{Conv}_{1 \times 1}(\mathbf{X})) \quad (9)$$

$$\mathbf{X}_2 = \text{BN}_{\text{Id}}(\text{Id}(\mathbf{X})) \quad (10)$$

$$\mathbf{X}_3 = \text{BN}_{3 \times 3}(\text{Conv}_{3 \times 3}(\mathbf{X})) \quad (11)$$

$$\mathbf{Y} = \delta(\mathbf{X}_1 + \mathbf{X}_2 + \mathbf{X}_3) \quad (12)$$

其中, $\text{Conv}_{1 \times 1}$ 用于增强通道间的交互关系; $\text{Id}(\mathbf{X})$ 表示恒等映射, 用于确保输入特征信息梯度传递的稳定性; $\text{Conv}_{3 \times 3}$ 用于捕获空间上下文信息。




图 5 RepVGG 模块网络结构

Fig. 5 RepVGG module network architecture

在模型推理阶段, RepVGG 卷积模块将训练时的多分支等效转化为单分支结构实现重参数化。将卷积层与批归一化层进行融合, 并将 1×1 卷积核通过插值填充为 3×3 卷积核, 然后与恒等映射分支以及原始 3×3 卷积核进行逐元素相加, 得到单一分支的等效卷积核 $\tilde{w}$ 和偏置 $\tilde{b}$, 最终, 通过一次 3×3 卷积即可得到与模型训练阶段相同的特征变换 $\mathbf{Y}$:

$$\tilde{w} = w_{3 \times 3} + \text{Pad}(w_{1 \times 1}) + w_{\text{Id}} \quad (13)$$

$$\tilde{b} = b_{3 \times 3} + b_{1 \times 1} + b_{\text{Id}} \quad (14)$$

$$\mathbf{Y} = \delta(\text{BN}_{3 \times 3}(\text{Conv}_{3 \times 3}(\mathbf{X}))) \quad (15)$$

其中, Pad 表示卷积核填充操作; w 和 b 分别代表模型训练阶段 RepVGG 模块不同分支的权重和偏置。

EfficientFPN 中的 TConv 通过在输入特征图相邻元素之间进行插值填充, 并利用卷积核进行计算, 从而得到分辨率更大的特征图。这种方式相比传统最近邻插值和双线性插值的传统上采样方式, 能够通过卷积核在上采样时结合通道信息进行加权, 以提升细粒度特征的表达。TConv 的输出特征图计算公式为:

$$Y_{C,H,W} = \sum_{i=1}^{C_{in}} \sum_{u=1}^k \sum_{v=1}^k X_{i,H,W} \cdot w_{c,i,u,v} \quad (16)$$

其中, $Y_{C,H,W}$ 表示输出特征图在第 c 个通道高度 H 宽度 W 处的像素值; $w_{c,i,u,v}$ 为卷积核权重参数。

2.3 边界框损失函数改进

边界框损失函数 IoU 的定义是真实框与预测框的交集与并集之比, YOLOv8 在边界框回归中, 引入了结合真实框与预测框中心点距离和长宽比的 CIoU 作为损失函数, 其计算公式为:

$$\text{Loss}_{\text{CIoU}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + av \quad (17)$$

$$a = \frac{v}{(1 - \text{IoU}) + v} \quad (18)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{w}{h} \right)^2 \quad (19)$$

其中, b 和 b^{gt} 分别代表预测框与真实框的中心点, $\rho(b, b^{\text{gt}})$ 代表两个中心点之间的欧氏距离; c 表示包含预测框与真实框最小外接矩形对角线的长度; $w^{\text{gt}}, h^{\text{gt}}$ 和 w, h 分别表示真实框与预测框的宽高。

CIoU 使用欧氏距离平方作为位置约束, 这种方式无法反应偏移方向的差异, 会导致边界框回归会缺乏方向性引导。因此, 引入具有角度约束、距离约束与形状约束的 SIoU 作为本文模型的边界框回归损失函数, SIoU 损失函数的原理如图 6 所示。




图 6 SIoU 计算原理

Fig. 6 SIoU computation principle

根据图 6 中显示的参数, 可得角度约束 Δ 的计算公式:

$$\Delta = 1 - 2\sin^2 \left(\arcsin \left(\frac{c_h}{\sigma} \right) - \frac{\pi}{4} \right) \quad (20)$$

$$\frac{c_h}{\sigma} = \sin(\alpha) \quad (21)$$

$$\sigma = \sqrt{(b_{c_x}^{gt} - b_{c_x})^2 + (b_{c_y}^{gt} - b_{c_y})^2} \quad (22)$$

$$c_h = \max(b_{c_y}^{gt}, b_{c_y}) - \min(b_{c_y}^{gt}, b_{c_y}) \quad (23)$$

式中: $(b_{c_x}^{gt}, b_{c_y}^{gt})$ 为真实框的中心坐标; (b_{c_x}, b_{c_y}) 为预测框的中心坐标; c_h 表示真实框与预测框中心点之间的高度差; σ 为真实框和预测框中心点的距离; α 表示真实框与预测框中心点连线与虚线框水平方向的夹角。由此可知,在训练过程中当 α 为 0 或 $\frac{\pi}{2}$ 时, Δ 为 0 失去约束作用,而当

$0 < \alpha < \frac{\pi}{4}$ 时,则最小化 α 对预测框进行水平偏移,反之最小化 β 进行垂直偏移,实现最优收敛路径。

距离约束的计算公式为:

$$\Delta = \sum_{t \in x, y} (1 - e^{-\gamma \rho_t}) \quad (24)$$

$$\rho_x = \left(\frac{b_{c_x}^{gt} - b_{c_x}}{c_x} \right)^2 \quad (25)$$

$$\rho_y = \left(\frac{b_{c_y}^{gt} - b_{c_y}}{c_y} \right)^2 \quad (26)$$

$$\gamma = 2 - \Delta \quad (27)$$

式中: Δ 为距离约束; γ 表示调节系数; c_x 和 c_y 分别代表真实框与预测框最小外接矩形的宽和高; ρ_x 为归一化后的真实框与预测框水平距离的平方; ρ_y 为归一化的垂直距离的平方。由距离公式可知,距离约束通过对真实框与预测框中心点偏移量的归一化度量,并引入调节系数,从而在方向矫正的基础上进一步缩小真实框与预测框的中心差距。

形状约束的计算公式为:

$$\Omega = \sum_{t=w, h} (1 - e^{-\omega_t})^\theta \quad (28)$$

$$\omega_w = \frac{|\omega - \omega_{gt}|}{\max(\omega, \omega_{gt})} \quad (29)$$

$$\omega_h = \frac{|h - h_{gt}|}{\max(h, h_{gt})} \quad (30)$$

式中: Ω 为形状约束; ω_t 为真实框与预测框的尺寸差异; θ 为控制形状惩罚敏感度的超参数; (ω, h) 和 (ω_{gt}, h_{gt}) 分别表示真实框与预测框的宽高。由形状公式可知,同时引入检测框的宽高作为约束,能够引导预测框在宽高维度上逐步逼近真实框实现几何匹配。

最终,SIoU 损失函数的计算公式为:

$$\text{Loss}_{\text{SIoU}} = 1 - \text{IoU} + \frac{\Delta + \Omega}{2} \quad (31)$$

SIoU 在 CIoU 的基础上引入了角度约束 Δ , 将 α 作为优化目标,使得检测框的回归过程具备方向指导;结合距离约束 Δ 对中心点偏移进行归一化约束,进一步缩小了预测框与真实框的中心差距;引入形状约束 Ω 实现宽高差异的度量,使预测框在几何尺度上逐步逼近真实框。通过引入这 3 种约束,使模型能够实现更快的收敛速度和检测精度。

2.4 检测头的改进

为了保证检测精度的同时降低模型的参数量,本文在 YOLOv8 的原始检测头基础上设计了一种 LSSB 检测头,其结构如图 7 所示。在回归分支中,引入空间稀疏卷积 (spatially sparse convolution, SPConv) 提升边界框回归效率,同时结合 SIoU 与分布式焦点损失 (distribution focal loss, DFL) 提高边界框的预测精度;在分类分支中,将深度可分离卷积 (depthwise separable convolution, DWConv) 替换标准卷积,降低计算开销,然后采用二值交叉熵损失 (binary cross entropy loss, BCE) 进行分类。




图 7 LSSB 检测头网络结构

Fig. 7 LSSB detection head network architecture

LSSB 检测头在延续回归与分类双分支结构的基础上,通过引入 SPConv 与 DWConv 有效降低模型的参数量,在保持检测精度的同时进一步提升了风电机组叶片表面缺陷的检测性能。

3 实验结果与分析

3.1 数据集

本文在风电机组停机维护期间,通过 DJI Mavic3 Classic 无人机平台搭载哈苏相机共采集到 1 244 张原始风机叶片图像。采集工作在晴天及阴天不同光照条件下完成。为提升缺陷检测模型在复杂风场环境下的鲁棒性与泛化能力,对原始图像进行了裁剪、旋转变换以及对比度调整等数据增强手段,数据增强效果如图 8 所示,其中,裁剪操作以图像中心为基点分别进行水平方向与垂直方向裁剪,然后筛选出含叶片区域的图像;旋转变换对图像顺时针 90° 和 180° 旋转,以模拟无人机在不同飞行姿态下的视角变化;对比度调整通过线性变换的方法实现,用以模拟风场中复杂的光照环境。最终数据集扩充至 5 601 张。

所有图像均利用 Make Sense 工具完成缺陷标注,其中包括风电叶片表面常见的 9 种典型缺陷:裂纹 (cracking)、灰尘 (dirt)、导流条缺失 (missing part)、侵蚀 (erosion)、破损 (breakage)、雷击 (lightning)、涂层脱落 (paint)、胶带残留 (tape) 以及不规则污渍 (stains)。按照 8:1:1 的比例,将数据集划分为训练集、验证集与测试集。

3.2 实验环境

实验环境配置硬件平台采用 NVIDIA GeForce RTX 3080 Ti GPU 与 Intel(R) Xeon(R) Silver 4210 CPU,操作系统为 Ubuntu 18.04.6 LTS。编程语言使用 Python 3.9,




图 8 数据增强效果

Fig. 8 Data augmentation results

深度学习框架选用 PyTorch 2.0.1, 基于 CUDA 11.8 进行加速。模型训练迭代轮次为 200 轮, 初始学习率为 0.01, 动量参数为 0.937, 批量大小为 16, 权重衰减系数为 0.000 5。

3.3 模型评价指标

为了客观评估 CESL-YOLO 模型的性能, 采用精确率 (precision, P)、召回率 (recall, R)、平均精度 (average precision, AP) 和交并比 (intersection of union, IoU) 为 0.5 的均值平均精度 (mean average precision, mAP) 来衡量 CESL-YOLO 模型的缺陷检测性能。采用模型参数量 (parameters, Param) 评价模型的体量大小, 各指标定义为:

$$P = \frac{TP}{TP + FP} \tag{32}$$

$$R = \frac{TP}{TP + FN} \tag{33}$$

$$AP = \int_0^1 P(R) dR \tag{34}$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \tag{35}$$

式中: TP 为模型正确识别的正样本数量; FP 表示模型误检的正样本数量; FN 为模型漏检的正样本数量; N 表示正样本的类别数量; P 用于衡量模型检测结果的准确性; R 反应模型对检测对象的漏检程度; mAP 综合反应模型对每个类别的检测性能表现。

3.4 消融实验结果分析

表 1 为在 YOLOv8n 基础上逐步引入 4 种改进方法后的消融实验结果, 其中 A 表示 CBAM 注意力机制, B 表示 EfficientFPN 颈部网络, C 表示 SiIoU 损失函数, D 表示 LSSB 检测头。

实验结果表明, 单独引入 CBAM 注意力机制后, mAP 为 82.3%, 相比 YOLOv8n 提升了 3.9%, 说明注意力机制

表 1 消融实验结果

Table 1 Ablation experiment results					%
基线模型	改进方法	P	R	mAP@0.5	
YOLOv8n	—	81.7	71.1	78.4	
YOLOv8n	+A	85.3	74.1	82.3	
YOLOv8n	+B	84.5	73.2	81.7	
YOLOv8n	+C	83.4	73.7	81.1	
YOLOv8n	+D	83.6	73.2	80.1	
YOLOv8n	+AB	84.2	74.6	82.5	
YOLOv8n	+ABC	83.5	75.7	82.9	
YOLOv8n	+ABCD	84.4	75.9	83.7	

有效增强了网络的特征表达能力; 采用 EfficientFPN 后, mAP 达到 81.7%, 较基线提升 3.3%, 验证了改进后的颈部特征融合结构能够更好捕获多尺度信息的能力; 引入 SiIoU 损失函数后, mAP 为 81.1%, 虽然提升幅度略小于前两者, 但仍有效表明该改进有助于提升边界框回归的定位精度。采用 LSSB 检测头后, P 、 R 、mAP 分别提升 1.9%、2.1%、1.7%。

当同时采用 CBAM 与 EfficientFPN 时, mAP 达到 82.5%, 召回率提升至 74.6%, 较单独改进更具优势, 验证了注意力机制与特征融合结构在降低漏检率方面具有互补性。继续引入 SiIoU 损失函数后, mAP 提升至 82.9%, 召回率进一步提升至 75.7%。当 4 种改进方法同时引入时, 模型达到了最优性能, 精确率、召回率和 mAP 分别提升至 84.4%、75.9% 和 83.7%, 相比基线模型分别提高了 2.7%、4.8% 和 5.3%, 充分验证了 CESL-YOLO 的有效性。

3.5 改进注意力机制效果分析

为了进一步验证本文注意力机制改进的优越性, 在 Backbone 中分别引入高效通道注意力 (efficient channel attention, ECA)、全局注意力 (global attention mechanism, GAM)、空间注意力 (spatial attention, SA) 以及卷积核注意力 (selective kernel convolution, SK) 等主流注意力机制进行对比, 实验结果如表 2 所示。由表 2 中数据可知, ECA 对模型的参数量影响最低, 但是精度提升有限; SA 和 SK 的 mAP 分别达到 80.3% 和 80.9%。然而, SK 的参数量由 3.01 M 增加至 8.56 M, 计算开销较大; 相比之下, CBAM 在几乎保持参数量不变的情况下, 精确率、召回率和 mAP 分别提升至 85.3%、74.1% 和 82.3%, 显著优于其他注意力机制。

3.6 改进 Neck 网络效果分析

表 3 为不同特征融合网络对 Neck 网络的性能优化对比。渐进特征金字塔网络 (asymptotic feature pyramid network, AFPN) 虽然使模型的参数量显著减少, 但对 mAP、精确率和召回率的提升均弱于 EfficientFPN。

表 2 注意力机制效果对比

Table 2 Comparison of the effects of attention mechanisms

模型	$P/\%$	$R/\%$	$mAP@0.5/\%$	Param/M
YOLOv8n	81.7	71.1	78.4	3.01
+ECA	79.3	74.8	79.4	3.01
+GAM	81.7	71.9	79.5	3.44
+SA	80.7	73.9	80.3	3.01
+SK	81.3	73.8	80.9	8.56
+CBAM	85.3	74.1	82.3	3.02

表 3 Neck 网络优化对比

Table 3 Neck network optimization comparison

模型	$P/\%$	$R/\%$	$mAP@0.5/\%$	Param/M
YOLOv8n	81.7	71.1	78.4	3.01
+AFPN	82.1	71.4	78.6	2.29
+EfficientFPN	84.5	73.2	81.7	2.83

3.7 改进损失函数效果分析

为了评估改进边界框损失函数对模型收敛性能的优化效果,对训练过程中的 Loss 曲线进行对比分析。图 9 为改进前后的 Loss 曲线,CIoU 和 SIoU 在训练初期均处于较高水平,随着迭代轮次的增加,SIoU 表现出更快的收敛速度和更平稳的收敛轨迹。在训练后期,CIoU 损失曲线下降至稳定区间,但存在一定的波动,而 SIoU 则能够进一步收敛并趋于稳定,展现了更强的收敛性和平稳性。综上,改进后的 SIoU 损失不仅加速了模型的收敛速度,而且在最终收敛阶段表现出更低的损失值,相比原始损失函数能够更有效地提升模型的检测性能。




图 9 Loss 曲线对比

Fig. 9 Comparison of Loss curves

3.8 模型改进前后效果对比

本文通过对比 YOLOv8n 与改进模型 CESL-YOLO 对各类缺陷的平均精度,以验证 CESL-YOLO 模型对不同类型缺陷的检测效果,实验结果如表 4 所示。

根据实验结果可知,对于 Cracking、Missing part 和


表 4 模型改进前后 AP@0.5 对比

Table 4 AP@0.5 comparison before and after improvement

缺陷类型	AP@0.5/%	
	YOLOv8n	CESL-YOLO
Cracking	64.1	74.5
Dirt	98.4	97.9
Missing part	75.3	94.7
Erosion	65.8	68.7
Breakage	69.9	77.5
Lightning	93.3	93.5
Paint	84.7	88.0
Tape	71.9	73.4
Stains	82.5	84.6

Breakage 等细粒度特征明显且检测难度较大的缺陷,改进模型的平均精度分别提升了 10.4%、19.4%和 7.6%,验证了改进模型能够更好地捕捉裂纹、导流条缺失和破损类缺陷的局部细节特征。对于 Paint、Tape、Stains 等类型缺陷,改进模型也表现出稳定的精度提升。对于 Dirt 和 Lightning 等面积较大的缺陷类别,模型的精度基本保持稳定,表明改进模型在提升微小缺陷识别率的同时,未对大尺度类别缺陷的检测精度造成负面影响。

图 10 为模型改进前后的检测效果,左侧为 YOLOv8n 的检测效果,右侧为改进模型 CESL-YOLO 的检测效果,






图 10 检测效果对比

Fig. 10 Comparison of detection results

对比发现 CESL-YOLO 对各类型缺陷的检测精度更高,尤其是对图 10(b) 的第 4 行图片中的 Cracking 类缺陷, CESL-YOLO 成功检出 3 处而 YOLOv8n 仅检出 2 处。这进一步验证了本文 CESL-YOLO 对风电机组叶片表面微小缺陷检测性能提升的有效性。

3.9 不同模型实验结果对比

为了更全面地验证改进模型在风电叶片表面缺陷检测中的性能优势,本文将 CESL-YOLO 与其他主流目标检测算法进行对比实验,实验结果如表 5 所示。由表 5 中数据可知,基于两阶段的 FasterR-CNN 参数量达 41.39 M,计算开销较大。TOOD 的召回率达到 76.1%,但精确率与 mAP 均低于 CESL-YOLO。ATSS 与 YOLOv11 的精确率接近,但整体检测精度和召回率仍不及 CESL-YOLO。

表 5 不同算法实验结果对比

Table 5 Experimental results of different algorithms

模型	P/%	R/%	mAP@0.5/%	Param/M
Faster R-CNN	82.5	71.5	79.5	41.39
TOOD	82.9	76.1	82.3	32.04
ATSS	81.5	72.5	78.9	38.92
YOLOv3-Tiny	79.1	68.2	75.3	8.68
YOLOv8n	81.7	71.1	78.4	3.01
YOLOv5n	81.9	73.3	79.4	1.77
YOLOv7-Tiny	78.1	76.5	81.5	6.04
YOLOv10n	78.4	69.1	76.8	2.71
YOLOv10s	79.6	72.8	80.5	8.04
YOLOv11	82.6	72.8	79.1	2.59
CESL-YOLO	84.4	75.9	83.7	2.82

在轻量化模型中 YOLOv5n 的参数量最小,仅为 1.77 M,但其模型的精确率、召回率以及 mAP 均落后于 CESL-YOLO。YOLOv7-Tiny 与 YOLOv10 系列在部分指标上有所提升,但精确率与召回率均存在一定不足。相比之下,CESL-YOLO 在几乎保持模型参数量的情况下,精确率、召回率以及 mAP 分别为 84.4%、75.9%和 83.7%,实现最佳综合性能,展现出在风电叶片表面缺陷检测任务中的显著优势。

4 结 论

本文针对风电机组叶片表面微小缺陷难以检测的问题,提出一种基于 YOLOv8n 改进的检测框架 CESL-YOLO。通过在 Backbone 网络中引入 CBAM 注意力机制,增强模型对微小缺陷的特征表达能力;Neck 网络采用 EfficientFPN 结构提升多尺度特征融合的效率;替换边界框损失函数为 SIoU,以加快模型收敛速度和缺陷定位精度;设计 LSSB 检测头,在降低模型参数量的同时能够保持缺陷检测精度。实验结果表明,CESL-YOLO 相比 YOLOv8n 在参数量下降 6.3%的情况下,精确率、召回率和 mAP 均显著提升,与其他主流检测模型相比,仍保持较好的检测效果,更加适合风电机组叶片表面缺陷检测任务。

参考文献

[1] KATSAPRAKAKIS D A, PAPADAKIS N, NTINTAKIS I. A comprehensive analysis of wind turbine blade damage[J]. Energies, 2021, 14(18): 5974.

[2] 张泽辰,姚顺春,梁晓俊,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 C, YAO S C, LIANG X J, et al. Wind turbine blade intelligent defect detection based on small object perception enhancement [J]. Chinese Journal of Scientific Instrument, 2025, 46 (9): 159-172.

[3] 敖良忠,牟晋仟. 面向发动机叶片缺陷检测的轻量化 YOLOv11 改进方法研究[J]. 电子测量技术, 2025, 48(20): 48-58.

AO L Z, MOU J Q. Research on lightweight improved YOLOv11 method for aero-engine blade defect detection[J]. Electronic Measurement Technology, 2025, 48(20): 48-58.

[4] REN S 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.

[5] HE K M, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[C]//2017 IEEE International Conference on Computer Vision (ICCV), 2017: 2980-2988.

[6] SUN P Z, ZHANG R F, JIANG Y, et al. Sparse R-CNN: End-to-end object detection with learnable proposals [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021: 14449-14458.

[7] CHEN Q, WANG Y M, YANG T, et al. You only look one-level feature [C]//2021 IEEE/CVF

- Conference on Computer Vision and Pattern Recognition(CVPR), 2021: 13034-13043.
- [8] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]//Computer Vision-ECCV 2016, 2016: 21-37.
- [9] 朱佳伟, 文传博. 基于改进 SSD 的风机叶片缺陷检测[J]. 复合材料科学与工程, 2022(3): 38-44.
ZHU J W, WEN C B. Defect detection of wind turbine blade based on improved SSD[J]. Composites Science and Engineering, 2022(3): 38-44.
- [10] 李锦达, 汤勃, 孙伟, 等. 多特征融合的 YOLOv4-tiny 带钢表面缺陷检测方法研究[J]. 计算机应用与软件, 2024, 41(12): 208-213, 254.
LI J D, TANG B, SUN W, et al. Research on strip surface defect detection method based on multi-feature fusion YOLOv4-tiny[J]. Computer Applications and Software, 2024, 41(12): 208-213, 254.
- [11] 王俊, 高贵兵. 一种改进 YOLOv5s 算法的风机叶片表面缺陷检测方法[J/OL]. 中国机械工程, 1-11 [2026-05-07]. <https://link.cnki.net/urlid/42.1294.th.20250403.1149.002>.
WANG J, GAO G B. Surface defect detection method for wind turbine blades based on improved YOLOv5s algorithm[J/OL]. China Mechanical Engineering, 1-11 [2026-05-07]. <https://link.cnki.net/urlid/42.1294.th.20250403.1149.002>.
- [12] 付军军, 陈林, 童华敏, 等. 基于改进 EfficientNet 的海上风机叶片早期缺陷检测及分类[J]. 电子测量技术, 2024, 47(16): 110-119.
FU J J, CHEN L, TONG H M, et al. Early defect detection and classification of offshore wind turbine blades based on improved EfficientNet[J]. Electronic Measurement Technology, 2024, 47(16): 110-119.
- [13] MA L M, JIANG X Y, TANG Z Z, et al. Wind turbine blade defect detection algorithm based on lightweight mes-YOLOv8n[J]. IEEE Sensors Journal, 2024, 24(17): 28409-28418.
- [14] ZOU L, CHEN A Q, LI C Z, et al. DCW-YOLO: An improved method for surface damage detection of wind turbine blades [J]. Applied Sciences, 2024, 14(19): 8763.
- [15] 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 S, 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.
- [16] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//Computer Vision-ECCV 2018:3-19.
- [17] GEVORGYAN Z. SiLU Loss: More powerful learning for bounding box regression[J]. ArXiv preprint arXiv: 2205.12740, 2022.
- [18] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 936-944.
- [19] LIU S, QI L, QIN H F, et al. Path aggregation network for instance segmentation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 8759-8768.

作者简介

韩鸿, 硕士研究生, 主要研究方向为风电机组叶片表面缺陷检测、深度学习、目标检测。

E-mail:1724876048@qq.com

王金明(通信作者), 博士, 副教授, 主要研究方向为风电机组状态检测。

E-mail:ybl5661510224@163.com