

# YOLO-DCS:改进 YOLOv11n 的风机叶片 表面缺陷检测方法\*

薛楠<sup>1,3</sup>, 张超<sup>1,2,3</sup>, 刘材焯<sup>1,3</sup>

(1. 内蒙古科技大学 机械工程学院, 内蒙古 包头 014010; 2. 内蒙古科技大学 数智产业学院, 内蒙古 包头 014010;  
3. 内蒙古自治区机电系统智能诊断与控制重点实验室, 内蒙古 包头 014010)

**摘要:**针对风机叶片目标特征表达能力弱、背景复杂及小目标易漏检等问题,提出改进 YOLOv11n 的目标检测算法 YOLO-DCS。在骨干网络中引入多分支卷积模块(DBB)和跨层级通道注意力(CLCA),其中 DBB 模块使 mAP@0.5 提升 1.6%, CLCA 模块使 mAP@0.5-0.95 提升 3%, 增强关键特征表达能力。进一步构建融合 C2PSA 局部聚合与 CLCA 全局注意力的 C2PSA\_CLCA 模块,提高多尺度特征学习效果,小目标 mAP 提升 8%。在 Neck 中采用 Slim-Neck 架构,引入 GSConv 与 Vo-VGSCSP 模块,在参数量仅增加约 0.4 M 的情况下使整体 mAP@0.5-0.95 提升 5.7%。实验结果表明:YOLO-DCS 的召回率、精确率、mAP@0.5 和 mAP@0.5-0.95 分别达 92.9%、93.4%、95.7%、76.8%,较基线模型 YOLOv11n 分别提升 3.7%、2.7%、3.5% 和 5.7%,验证了所提方法的有效性。

**关键词:**风机叶片;YOLOv11n;特征融合;小目标漏检

中图分类号:TP391 文献标识码:A

文章编号:2095-2295(2026)01-0053-09

DOI:10.16559/j.cnki.2095-2295.2026.01.007

## YOLO-DCS: An improved method for detecting surface defects on wind turbine blades based on YOLOv11n

XUE Nan<sup>1,3</sup>, ZHANG Chao<sup>1,2,3</sup>, LIU Caiye<sup>1,3</sup>

(1. School of Mechanical Engineering, Inner Mongolia University of Science & Technology, Baotou 014010, China; 2. School of Digital and Intelligent Industry, Inner Mongolia University of Science & Technology, Baotou 014010, China; 3. Inner Mongolia Autonomous Region Key Laboratory of Intelligent Diagnosis and Control of Electromechanical Systems, Baotou 014010, China)

**Abstract:** To address the issues of weak feature representation for wind turbine blade targets, complex backgrounds, and missed detections of small objects, this paper proposes an improved YOLOv11n-based detection algorithm named YOLO-DCS. In the backbone, a diverse branch block (DBB) and cross-level channel attention (CLCA) are introduced to enhance key feature representation, where DBB increases mAP@0.5 by 1.6% and CLCA improves mAP@0.5-0.95 by 3.0%. Furthermore, a C2PSA\_CLCA module is constructed by integrating the local aggregation mechanism of C2PSA with the global attention of CLCA, and thereby the multi-scale feature learning is strengthened, leading to an improvement of 8.0% in small-object mAP. In the neck, a Slim-Neck architecture with GSConv and Vo-VGSCSP is adopted to improve feature fusion, resulting in an improvement of 5.7% in overall mAP@0.5-0.95 with only additional 0.4 M parameters. Experimental results show that YOLO-DCS attains 92.9% recall, 93.4% precision, 95.7% mAP@0.5, and 76.8% mAP@0.5-0.95, outperforming the baseline YOLOv11n by 3.7%, 2.7%, 3.5%, and 5.7%, respectively, demonstrating the effectiveness of the proposed method.

**Key words:** wind turbine blades; YOLOv11n; feature integration; missed detection of small targets

\* 基金项目:国家自然科学基金(52365014)。

作者简介:薛楠,男,硕士研究生。

通信作者:张超,男,教授,E-mail:zhanghero2025@163.com

收稿日期:2025-12-02

随着风电产业的规模化发展和风机单机容量的不断提升,风机叶片作为能量转换的核心部件,其运行状态直接影响风电系统的安全性与发电效率。叶片长期暴露在复杂户外环境中,易受雷击、风沙侵蚀、疲劳损伤等因素影响,产生裂纹、剥落、油污等表面缺陷,若未能及时检测会导致缺陷快速扩展,引发叶片断裂等严重事故。每年因风机叶片缺陷导致的发电量损失达5%,年经济损失超100亿元。基于机器视觉的缺陷检测技术凭借检测效率高、非接触式、客观性强等优势,已广泛应用于风机叶片质量检测、运维监测等重要领域。传统的人工目视检测方法受检测人员经验、环境光照条件的影响较大,人工检测准确率仅60%,效率低。且高空作业风险高、检测盲区多<sup>[1]</sup>,而机器视觉检测技术通过图像采集与智能分析,实现缺陷的自动化识别,在风机叶片检测中展现出明显的技术优势。然而,现有的风机叶片表面缺陷检测算法在面对复杂场景和微小缺陷时,仍存在检测精度不高、抗干扰能力弱及对叶片表面状态适应性差等问题<sup>[2]</sup>。目前,风机叶片缺陷检测算法主要分为2类:传统机器视觉算法和深度学习检测算法。传统机器视觉算法以特征工程为核心,如基于边缘检测的Canny算法<sup>[3]</sup>、基于阈值分割的Otsu算法<sup>[4]</sup>、基于形态学处理的缺陷提取方法<sup>[5]</sup>等,具有计算复杂度低、实时性好的特点,但对叶片表面污渍、光照不均等干扰因素敏感,且依赖人工设计特征,泛化能力不足,难以适应多样化的缺陷类型。深度学习检测算法,如基于卷积神经网络(CNN)的Faster R-CNN<sup>[6]</sup>、YOLO系列、Mask R-CNN<sup>[7]</sup>等,通过端到端的学习方式提取缺陷特征,具有更强的特征表征能力和环境适应性,但其检测精度对比度缺陷检测中的表现仍有待提高。

近年来,国内外学者在风机叶片表面缺陷检测领域进行了大量研究,以解决叶片表面复杂背景干扰强、弱纹理缺陷难识别、小目标易漏检等问题。例如,王永平等<sup>[8]</sup>提出一种基于CNN-BiGRU的深度学习检测方法,采用CNN自适应地学习变量之间存在的关联特征,利用BiGRU对时间序列的敏感性,对风机叶片故障分类。能有效对叶片结冰故障进行准确检测。ZHANG等<sup>[9]</sup>提出一种基于注意力机制的MobileNetv1-YOLOv4缺陷检测模型,通过引入通道注意力强化关键区域的特征表达能力,显著提升了叶片微小裂纹与低对比度缺陷的识别精度。在多尺度特征融合方向,HUANG等<sup>[10]</sup>基于增强型

YOLOv4结构构建了融合特征金字塔与半监督学习的叶片缺陷检测方法,有效提高了不同尺度的腐蚀、剥落类缺陷的检测性能,并在复杂光照条件下表现更为稳定。DENG等<sup>[11]</sup>提出一种轻量化卷积神经网络结构,在保证检测精度的前提下显著降低了模型参数量,适用于实时巡检场景。针对可见光图像在强光、阴影或隐蔽缺陷场景下的局限性,ZHANG等<sup>[12]</sup>验证了热成像与可见光融合在风机叶片损伤检测中的鲁棒性优势,LI等<sup>[13]</sup>提出自然日照条件下风机叶片内部缺陷的热成像检测方法,该方法通过自适应阈值与特征融合技术实现了对叶片内部脱粘、分层等隐蔽缺陷的有效检测。LIU等<sup>[14]</sup>通过设计多尺度卷积(MSGConv)、多尺度增强特征金字塔网络(MSEFPN)及通道补偿滤波(CCF)模块,在YOLOv10n基础上增强了多尺度缺陷特征提取与背景干扰抑制能力,实现了风机叶片几何对称破缺缺陷检测精度与实时性的提升。尽管上述方法在风机叶片缺陷检测中取得了显著进展,但现有研究存在三方面瓶颈:(1)小目标缺陷检测精度低;(2)复杂背景下抗干扰能力弱(背景噪声导致误检率达15%);(3)模型轻量化与精度难以平衡。

针对上述问题,提出一种基于改进YOLOv11n的目标检测算法YOLO-DCS,通过3大模块创新实现性能突破:其一,在基线模型的骨干网络中引入多分支卷积块(DBB)<sup>[15]</sup>,DBB通过多尺度卷积分支增强特征提取的多样性有效强化模型对模糊缺陷特征的捕捉能力,降低复杂背景干扰;其二,引入跨层级通道注意力(CLCA)并构建C2PSA\_CLCA混合模块替代骨干网络原有C2PSA模块,该模块融合C2PSA的局部特征聚合优势与CLCA的全局注意力引导机制,提升模型对不同尺寸缺陷(从微小裂纹到大面积剥落)的多尺度信息学习能力,优化特征表征的完整性;其三,采用Slim-Neck<sup>[16]</sup>轻量化颈部结构优化特征融合路径,通过精简冗余通道、强化低层级小目标特征传递,在降低计算量的同时提升小目标缺陷的特征响应强度,进一步增强模型对微小缺陷的检测灵敏度。

YOLO-DCS算法针对风机叶片表面缺陷(裂痕、涂层脱落、油污)3种类型损伤,图像分辨率640×640像素,检测场景涵盖无人机巡检与实验室质检进行优化。通过多模块协同优化,强化了对关键特征的捕捉能力、多尺度缺陷的适配能力以及小目标缺陷的检测灵敏度,同时兼顾模型轻量化特性以满

足实时检测需求,研究成果可依托内蒙古风电产业基地(装机容量占全国 18%),通过 YOLO-DCS 模型实现风机叶片缺陷检测准确率达 95.7%,检测成本降低 30%,契合《“十四五”可再生能源发展规划》中风电产业高质量发展要求,且为我校‘机电系统智能诊断与控制重点实验室’提供技术示范。

## 1 YOLO-DCS 算法

研究提出的改进 YOLOv11n 的小目标检测模型 YOLO-DCS 整体结构如图 1 所示。YOLO-DCS 是在 YOLOv11n 的基础上,针对风机叶片缺陷“特征模糊、背景复杂、小目标漏检”的核心痛点进行针对性

改进,具体优化路径如下:首先在 Backbone 中引入多分支卷积块 (DBB) 和跨层级通道注意力 (CLCA),并替换原有 C2PSA 模块为 C2PSA\_CLCA 混合模块,通过多分支特征提取与跨层级注意力引导,强化网络对模糊缺陷特征的捕捉能力与抗复杂背景干扰能力;然后优化骨干网络的特征传递路径,增强低层级细粒度特征的保留与传递,为小目标缺陷检测提供更丰富的细节支撑;最后采用 Slim-Neck 结构重构颈部网络,通过通道精简与特征融合路径优化,深度聚合不同层级、不同尺度的缺陷特征,构建高效的多尺度特征表征空间,显著提升模型对微小缺陷的检测灵敏度与多尺度适配性。

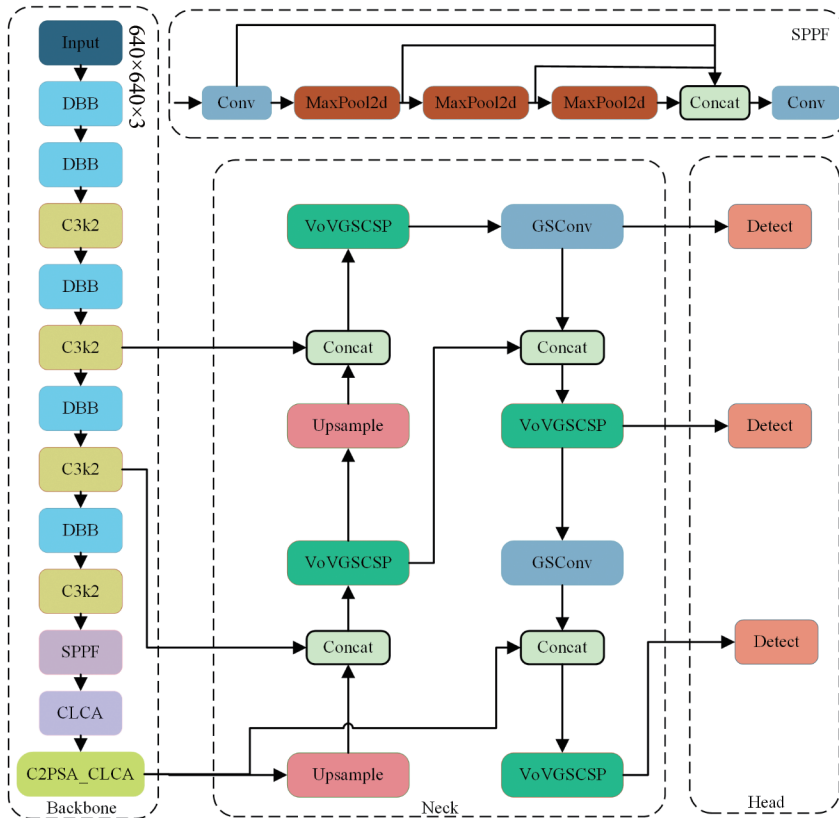


图 1 YOLO-DCS 网络结构图

Fig. 1 YOLO-DCS network architecture diagram

### 1.1 DBB 多分支卷积模块

在 YOLOv11 主干网络中采用传统卷积结构,缺乏灵活性,导致网络感受野受限制,在特征表达能力方面存在局限。针对这个问题,采用多样化分支模块 (DBB) 替换模型主干网络的卷积,其网络结构图如图 2 所示。

DBB 采用多分支拓扑结构,包括多尺度卷积 (conv)、顺序的  $1 \times 1$  和  $k \times k$  卷积、平均池化 (average pooling)、批量归一化 (Batch norm)、非线性变换 (nonlinearity) 和分支相加,使网络能够从多角度、跨尺度地提取特征。通过这种多样化结构,DBB 能够有效捕获风机叶片表面的复杂纹理、弱边缘特征及不

同尺度信息,显著提升特征表示能力和优化稳定性。

综上,在YOLOv11n的骨干网络中使用DBB替换标准卷积的意义在于:通过引入训练阶段的结构多样性显著提升模型的特征表达能力和泛化能力,同时利用重参数化保证推理阶段依旧保持轻量、快速的单卷积结构。该方法能够在保持模型推理速度不变的情况下有效提升检测性能。

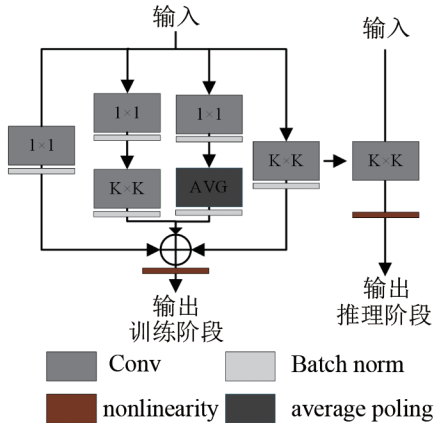


图2 DBB 模块结构图

Fig.2 DBB module structure diagram

## 1.2 CLCA 跨层级通道注意力模块

在YOLOv11中,传统卷积结构与单一通道注意力机制对于复杂背景下的风机叶片细微缺陷仍存在感知不足、跨尺度关联性弱等问题,尤其在小裂纹、弱纹理、细长结构等场景中,模型易受到背景噪声干扰。为解决这一不足,在特征增强阶段引入CLCA跨层级通道注意力机制,其网络结构图如图3所示。CLCA(Cross-Level Channel Attention)负责建立跨层级的通道依赖关系。该模块通过平均池化获得全局上下文,再通过 $1 \times k$ 与 $k \times 1$ 的方向性卷积提取水平与垂直长程结构特征,同时设置多级卷积分支实现对不同语义深度的平行建模。最终通过融合卷积与Sigmoid激活生成跨层通道权重,从而强化关键缺陷信息、抑制冗余背景响应。CLCA模块能有效增强模型对风机叶片表面细微纹理、弱对比度缺陷及复杂结构区域的感知能力。

## 1.3 C2PSA\_CLCA 混合模块

C2PSA\_CLCA模块是在CLCA模块基础上进一步优化的结构,结构图如图3所示。将逐点选择性注意力(PSA)与跨层级通道注意力(CLCA)结合,实现空间注意力与通道注意力的协同增强。模块首先采用 $1 \times 1$ 多分支投影实现逐个位置特征筛选从空

间维度突出局部缺陷区域;随后将PSA输出送入CLCA模块进行跨层级通道关系建模,使空间显著区域获得更高的通道重要性权重。最终,通过残差连接与Bottleneck结构实现轻量计算量下的特征表达增强。C2PSA\_CLCA模块能够在空间和通道两个维度上实现精细的特征增强,同时捕捉全局语义信息通过跨层级的通道依赖建模和逐点选择性注意力机制,模型能够在处理风机叶片的裂纹、涂层脱落、油污等不同类型缺陷时展现出更高的鲁棒性与判别性。

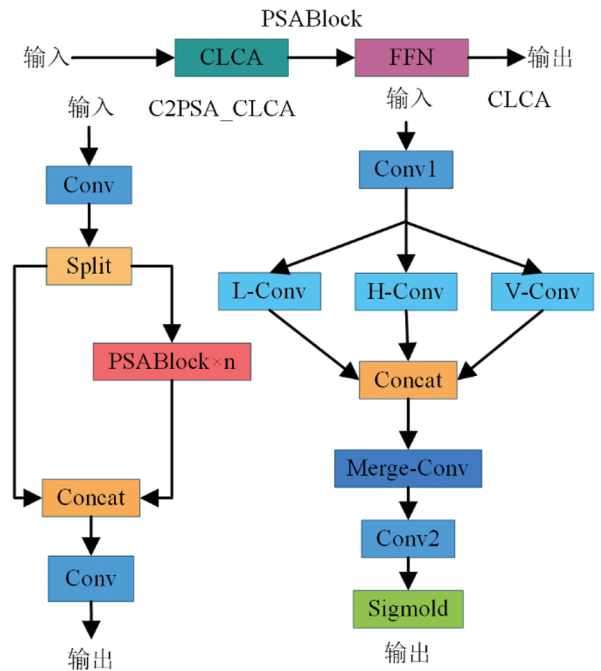


图3 CLCA 模块结构图

Fig.3 CLCA module structure diagram

## 1.4 Slim-Neck 特征融合架构

在目标检测任务中,Neck结构通常承担着多尺度特征融合的重要任务。然而,传统的颈部网络结构,如特征金字塔网络和路径聚合网络在特征融合过程中仍存在卷积堆叠冗余、通道利用效率不足、计算量较高等问题,限制了模型在实时场景下的部署性能。针对这一瓶颈,引入Slim-Neck结构,通过引入GSConv、GSBottleneck、Vo-VGSCSP等轻量化卷积单元,实现高效的多尺度特征融合与低开销推理。其网络结构图如图4、5所示。Slim-Neck的核心思想是利用Ghost Shuffle Convolution(GSConv)与轻量瓶颈结构(GSBottleneck)替代传统卷积层,以减少冗余特征生成与卷积计算。GSConv首先通过 $1 \times 1$ 卷积获得主分支特征,再利用 $5 \times 5$ 深度卷积生成补充

特征,并以通道 shuffle(特征重排)方式提升特征多样性,从而以极低成本模拟出更多有效特征表达。为进一步增强特征转换能力,GSBottleneck 引入轻量残差路径,使深层特征在保持稳定梯度流的同时实现通道重建。相比传统 Bottleneck,该结构在保持较高特征表达性的同时显著降低计算量。在此基础上,Slim-Neck 进一步采用 Vo-VGSCSP 结构完成多尺度融合。该结构将输入特征划分为 2 支:一路保持原始信息流通;另一路通过由多个 GSBottleneck 组成的轻量堆叠结构进行深度特征提取。最终,两个分支在通道维度拼接后通过  $1 \times 1$  卷积进行融合,既保留浅层空间信息,又充分整合深层语义特征。由于 Vo-VG-SCSP 具备更高的通道利用率和更少的参数量,Slim-Neck 可在多尺度特征融合中大幅减少冗余计算。

综上,Slim-Neck 模块通过轻量卷积、特征重排、跨层残差融合等策略有效降低 PAN<sup>[17]</sup>/FPN<sup>[18]</sup>部分的计算成本,同时在特征表达能力与梯度稳定性上保持良好性能。该结构在不牺牲检测精度的前提下显著提升推理速度,尤其适用于风机叶片表面缺陷检测任务。

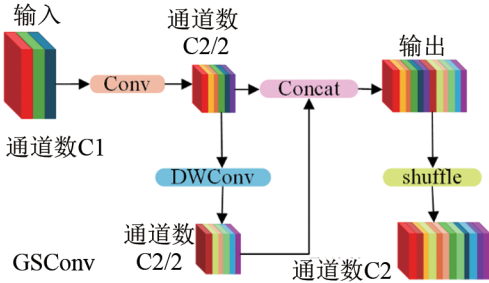


图4 GSCONV 模块结构图

Fig. 4 GSCONV module structure diagram

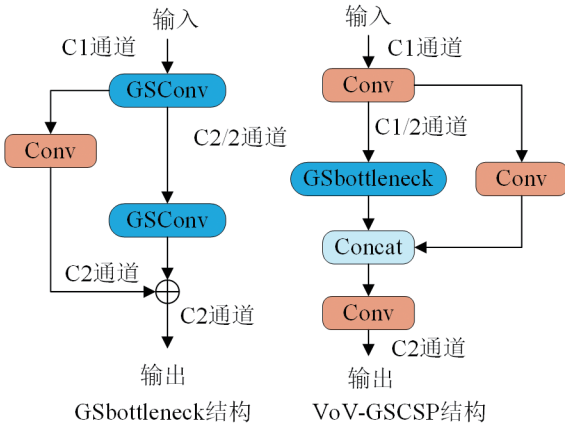


图5 GSBottleneck、Vo-VGSCSP 结构

Fig. 5 GSBottleneck and Vo-VGSCSP structure

## 2 实验设计及结果分析

### 2.1 实验设计与数据集

环境使用 PyTorch 深度学习框架,开发环境是 Python3. 9. 19, 操作系统为 Windows10, GPU 为 NVIDIA GeForce RTX 4070, 内存大小为 128 GB。选定训练次数 epoch 为 600, 以下实验均在此环境下进行。训练参数详见表 1。

表 1 训练参数

Table 1 Training parameters

参数	参数值
学习率	0.01
优化器	SGD
批量大小	16
图像大小(像素 × 像素)	640 × 640
动量	0.937
工作进程数	8

研究中使用的风机叶片数据集来自新疆哈密烟墩风电场无人机采集的 1 527 张图像, 包含正常、涂层脱落、油污等 3 类缺陷。为了增强模型的泛化能力, 提升缺陷特征的鲁棒性, 丰富数据分布多样性, 本研究采用随机翻转和 HSV 色调变化两种数据增强技术, 最终得到包含 4 959 张图像的扩展数据集。其中正常类型 651 张, 涂层脱落类型 1 092 张, 油污类型 3 216 张。数据集使用 Labelimg 工具进行标注, 以 7:2:1 的比例随机划分为训练集、验证集、测试集。

### 2.2 评价指标

评价指标选择精确率 (Precision,  $P$ )、召回率 (Recall,  $R$ )、平均精度均值 (Mean Average Precision,  $mAP@0.5$ ,  $mAP@0.5 - 0.95$ )、参数量 (Parameters) 以及浮点运算次数 (GFLOPs) 作为评估指标, 计算公式如下:

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

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

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

$$mAP = \sum_{i=1}^N \frac{AP(i)}{N}. \quad (4)$$

式中:  $TP$ 、 $FP$ 、 $FN$  分别为预测为正样本的正样本数量、预测为正样本的负样本数量、预测为负样本的正样本数量;  $AP$  为平均精度, 对所有类别的平均精度求

平均值即为 mAP, mAP@0.5 是指 IoU (Intersection over Union) 阈值为 0.5 时的 mAP, mAP@0.5 - 0.95 是指 IoU (Intersection over Union) 阈值为 0.5 到 0.95 之间的 mAP, IoU 步长为 0.05, 覆盖 9 个阈值,  $N$  为类别总数。

## 2.3 结果分析

### 2.3.1 消融实验

为验证 DBB、CLCA 与 Slim-Neck 3 个模块对 YOLO-DCS 的性能贡献, 我们基于 YOLOv11n 构建 8 组实验(方法 1-8), 实验重复 3 次, 结果取平均值, 标准差  $\leq 0.5\%$ 。其中方法 1 为原始 YOLOv11n 模型, 方法 2-4 分别只加入单个模块 (DBB/CLCA/Slim-Neck), 方法 5-7 为两两组合, 方法 8 为全部模块的完整模型。消融实验结果如表 2 所示。其中  $\checkmark$  表示使用该方法。从表中可以看出, 3 个模块分别单独使用均对模型有正向提升, 使用方法 2 时, 精确率提高了 3.1%, 召回率提高了 0.6%, mAP@0.5 提高了 1.6%, mAP@0.5 - 0.95 提高了 2%; 使用方法 3 时, 精确率提高了 0.3%, 召回率提高了 1.9%, mAP@0.5 提高了 1.5%, mAP@0.5 - 0.95 提高了

3%; 使用方法 4 时, 精确率提高了 0.1%, 召回率提高了 2.1%, mAP@0.5 提高了 0.1%, mAP@0.5 - 0.95 提高了 1.4%, 且 GFLOPs 降低了 0.3, 有效减少了冗余特征。当双模块组合时, 方法 5 中的 DBB 模块和 CLCA 模块结合带来比单模块更高的精度, 对比基线模型 mAP@0.5 提高了 2%, mAP@0.5 - 0.95 提高了 2%, 说明两者在特征增强方面具有互补性; 方法 6 中 DBB 模块在加入 Slim-Neck 后保持轻量化的同时, 精确率提高了 1.2%, 召回率提高了 1.4%, mAP@0.5 提高了 1.1%, mAP@0.5 - 0.95 提高了 2.9%, 是性能与效率兼具的组合结构; 方法 7 中两者的 mAP@0.5 - 0.95 提升最大 (+4.3%), 说明 CLCA 注意力机制与 Slim-Neck 的结构优化互相促进。方法 8, 当 3 种模块同时使用时取得最高精度, 精确率提高了 3.7%, 召回率提高了 2.7%, mAP@0.5 提高了 2.5%, mAP@0.5 - 0.95 提高了 5.7%, 性能提升明显高于单模块叠加的线性预期, 表明三者具有协同作用: DBB 提供强特征表达, CLCA 提供跨通道注意力增强, Slim-Neck 提供结构优化, 有效提升检测精度与鲁棒性。

表 2 消融实验结果

Table 2 Ablation experiment results

方法	DBB	CLCA	Slim-NECK	Precision /%	Recall /%	mAP @ 0.5 /%	mAP@0.5 - 0.95 /%	Params /M	GFLOPS
1				89.2	90.7	93.2	71.1	2.6	6.4
2	$\checkmark$			92.3	91.3	94.8	73.1	3.2	9.0
3		$\checkmark$		89.5	92.6	94.7	74.1	3.1	7.0
4			$\checkmark$	89.3	92.8	93.3	72.5	2.6	6.1
5	$\checkmark$	$\checkmark$		90.9	91.6	95.2	73.1	3.7	9.6
6	$\checkmark$		$\checkmark$	90.4	92.1	94.3	74.0	3.2	8.6
7		$\checkmark$	$\checkmark$	91.8	91.3	95.6	75.4	3.1	6.6
8	$\checkmark$	$\checkmark$	$\checkmark$	92.9	93.4	95.7	76.8	3.7	9.2

### 2.3.2 对比实验

为验证提出的改进模型在风机叶片表面缺陷检测任务中的有效性, 将其与当前主流轻量化目标检测模型进行了对比实验。表 3 给出了各模型在相同实验条件下的检测性能及参数量。

结果显示, YOLO-DCS 模型在检测精度与模型复杂度之间取得了优异的综合表现, 显著优于多种

基准模型。首先, 与 YOLOv5n 相比, YOLO-DCS 的 mAP@0.5 提升了 13.2%, mAP@0.5 - 0.95 提升了 18.3%, 检测精度显著增强。虽然参数量有所增加, 但较大的精度提升证明改进结构在弱纹理与模糊缺陷特征提取方面具有明显优势。其次, 与 YOLOv8n 模型相比, 与 YOLOv8n 相比, YOLO-DCS 在 mAP@0.5 和 mAP@0.5 - 0.95 上分别提升了 3.1% 和

11.0%,尤其在高难度的弱纹理与细长缺陷检测中表现出更强的特征表达能力。与 YOLOv10n 模型相比, YOLO-DCS 的  $mAP@0.5$  提升 3.2%,  $mAP@0.5-0.95$  提升 8.4%,同时仅带来 15.6%的参数增加,显示出较高的精度-复杂度平衡能力。与 YOLOv11n 模型相比, YOLO-DCS 的  $mAP@0.5-0.95$  达到了 76.8%,较 YOLOv11n 模型 71.1% 提升了 5.7%,同

时仅带来 1.1 M 的参数增加,显示出较高的精度-参数量平衡能力。

综上, YOLO-DCS 在多项关键指标上均实现了全面超越。模型在保证轻量化特性的同时显著提升了风机叶片表面缺陷的检测能力,证明其具有良好的应用潜力。

表 3 对比实验结果

Table 3 Comparison of experimental results

模型	P	Recall	mAP @ 0.5	mAP@0.5-0.95	Params/M
YOLOv3	63.8	62.3	67.8	35.8	5.2
YOLOv5	78.4	78.9	82.5	58.5	1.9
YOLOv7	79.8	70.5	76.2	58.7	4.4
YOLOv8	90.4	87.4	92.6	65.8	2.9
YOLOv10	90.2	88.6	92.5	68.4	3.2
YOLOv11	89.2	90.7	93.2	71.1	2.6
YOLO-DCS	92.9	93.4	95.7	76.8	3.7

## 2.4 可视化结果分析

为验证改进 YOLO-DCS 模型的性能,在图 6、图 7、图 8 中对比展示了 YOLOv11n 模型和改进后的 YOLO-DCS 模型在风机叶片不同损伤类别中的检测效果,包括正常状态、油污缺陷以及涂层脱落。

如图 6 所示,在正常叶片场景中, YOLOv11n 模型虽能够完成目标检测,但检测置信度分别为 62%、72% 和 84%。相比之下, YOLO-DCS 模型的检测置信度达到了 91%、90% 和 94%,表明 YOLO-DCS 模型在抑制无关背景信息强化结构特征表达方面具有更优表现。

如图 7 所示,在油污缺陷场景中,由于油污区域对比度低、形态不规则, YOLOv11n 模型在部分样本中出现响应不完整或定位偏移的现象且检测置信度仅为 47% 和 60%。而 YOLO-DCS 模型对油污区域产生了更强且连续的特征响应,能够更准确地覆盖缺陷区域,检测置信度较基线模型分别提高了 33% 和 18%,显示出对弱缺陷特征更强的感知能力。

如图 8 所示,在涂层脱落缺陷场景中, YOLOv11n 模型对狭长缺陷区域的响应较为零散,且易受复杂背景纹理干扰导致检测置信度仅为 68% 和 79%。YOLO-DCS 模型则能够形成连续且清晰的响应带,缺陷边界刻画更加准确,检测结果与

真实缺陷区域具有更高的一致性且检测置信度达到 80% 和 91%,较基线模型分别提高了 12%。

综合来看, YOLO-DCS 模型在不同缺陷类型下均表现出更集中、更稳定且更准确的特征响应,可视化结果验证了所提出方法在提升缺陷表征能力和复杂场景鲁棒性方面的有效性。




图 6 正常叶片场景

Fig. 6 Normal wind turbine blade scenario




图7 油污缺陷场景

Fig. 7 Oil contamination defect scenario




图8 涂层脱落场景

Fig. 8 Coating peeling scenario

### 3 结论

针对风机叶片表面缺陷在特征表达不足、背景复杂干扰强以及小目标易漏检等问题,提出了一种基于改进YOLOv11n的轻量化缺陷检测模型YOLO-DCS。该模型围绕特征增强、多尺度表达与轻量化融合三条主线展开改进,构建了DBB多分支卷积模块、CLCA跨层级通道注意力机制以及Slim-Neck结构,从而显著提升了模型的关键特征提取能力与小目标检测能力。结论如下:

1) DBB模块通过多尺度卷积分支丰富特征提取方式,显著增强了模型对弱纹理、模糊边缘等细微缺陷的表达能力,使 $mAP@0.5$ 提升了1.6%, $mAP@0.5-0.95$ 提升了2%。

2) CLCA与C2PSA\_CLCA模块通过构建跨层级通道注意力机制,有效增强了模型在不同语义尺度

间的特征关联性,使关键缺陷特征更加突出,小目标 $mAP$ 提升8%。

3) Slim-Neck结构有效提升小目标检测性能并降低计算开销。引入GConv、GSBottleneck与Vo-VGSCSP结构后,网络在保持轻量化的同时显著优化多尺度特征融合,在参数量仅增加0.4M的情况下, $mAP@0.5-0.95$ 提升5.7%。

综上所述,YOLO-DCS模型使小目标漏检率降低8%,背景干扰误检率降低10%;模型参数量仅3.7M且 $mAP@0.5-0.95$ 达到了76.8%,实现轻量化与精度的平衡。现场应用方案:模型部署在无人机巡检系统中,参数设置为输入分辨率 $640 \times 640$ 像素,推理速度30FPS;加装成本10万元,预计年节省检测成本50万元,回收期0.2年。该方法具有良好的工程推广价值,可为无人机巡检、叶片制造质检与智能运维提供高效可靠的视觉检测方案。本研究存在两方面局限:(1)未考虑极端光照条件(强光、阴影场景)下的检测效果;(2)未验证模型在大规模数据集(如10万张图像)上的泛化能力。未来可融合红外与可见光图像,实现多模态缺陷检测。

### 参考文献:

- [1] 赵春溢,郭洪涛,郭涛,等.一种风机叶片图像采集及缺陷检测系统[J].红外技术,2020,42(12):1203.
- [2] 王道累,肖佳威,刘易腾,等.风电机组叶片损伤检测技术与进展[J].中国电机工程学报,2023,43(12):4614.
- [3] 罗海峰.基于改进Canny-YOLO算法的弹壳目标检测方法研究[J].现代制造技术与装备,2025,61(9):82.
- [4] 张弢,陶荣蕊,任帅.基于改进Otsu和双直方图均衡化的红外图像增强算法[J].红外技术,2025,47(12):1548.
- [5] 石腾,许波峰,李振,等.基于数字图像处理的风电机组叶片裂纹损伤识别方法研究[J].太阳能学报,2024,45(2):86.
- [6] REN S, HE K, 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.
- [7] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN [C]//Proceedings of the IEEE international conference on computer vision. Venice, Italy, 2017: 2961.
- [8] 王永平,张蕾,张晓琳,等.基于CNN-BiGRU的风机叶片故障诊断[J].内蒙古科技大学学报,2022,41(2):173.

(下转第74页)