

DOI: 10.13382/j.jemi.B2508419

基于跨维度特征交互的风机叶片异常状态 检测轻量化模型*

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:针对现有风机叶片表面异常状态检测模型参数量大、计算开销高以及对微小缺陷检测精度不足的问题,设计了一种轻量化检测模型 CDFNet。该模型以 YOLOv10n 为基础,通过在骨干网络中引入特征增强下采样模块 FED,以增强模型对复杂异常区域的细粒度特征提取能力;设计跨维度协同注意力机制 CCA,通过融合空间位置信息与通道语义信息,提升模型对微小缺陷的定位与识别能力;采用快速双向特征金字塔网络 FBIFPN 替换原颈部网络,以提高模型的多尺度特征融合效率并降低模型复杂度。基于自建风机叶片表面异常状态数据集开展实验,并与多种主流目标检测模型进行对比验证。结果表明,CDFNet 的 mAP@0.5 达到 83.2%,较基线模型提升了 6.4 个百分点,模型参数量为 2.02×10^6 ,较基线模型下降 25.5%,对裂纹、导流条缺失和破损等微小缺陷的检测精度较基线模型分别提升 21.3、11.6 和 11.1 个百分点。实验结果表明,CDFNet 在检测精度与模型轻量化之间实现了较好平衡,适用于风机叶片表面异常状态检测。

关键词: 风机叶片;深度学习;异常状态检测;特征交互;特征融合;轻量化

中图分类号: TP391.41;TN911.73 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Lightweight model for abnormal state detection of wind turbine blades based on cross-dimensional feature interaction

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 large parameter count, high computational overhead, and poor minor-defect detection in existing wind turbine blade surface anomaly detection models, this paper designs a lightweight detection model named CDFNet. The model takes YOLOv10n as the baseline and introduces a feature enhancement downsampling (FED) module into the backbone to enhance fine-grained feature extraction for complex anomaly regions. A cross-dimensional collaborative attention (CCA) mechanism integrates spatial location with channel semantic information to improve minor-defect localization and recognition. The method also replaces the original neck with a fast bidirectional feature pyramid network (FBIFPN) to boost multi-scale feature fusion efficiency and reduce model complexity. Experiments on a self-built dataset of wind turbine blade surface anomalies show that CDFNet achieves a mAP@0.5 of 83.2%, which is 6.4 percentage points higher than the baseline. CDFNet contains 2.02×10^6 parameters, a 25.5% reduction compared to the baseline. For minor defects, CDFNet improves detection accuracy over the baseline by 21.3 percentage points for cracks, 11.6 for missing diversion strips, and 11.1 for surface damages. These results demonstrate that CDFNet strikes a favorable balance between detection accuracy and model lightweightness, making it suitable for wind turbine blade surface anomaly detection.

Keywords: wind turbine blades; deep learning; abnormal-state detection; feature fusion; feature interaction; lightweight

收稿日期:2025-05-27 Received Date: 2025-05-27

* 基金项目:国家自然科学基金(62161042)、内蒙古自治区重点研发和成果转化计划项目(2025YFHH0061,2025YFHH0025)、内蒙古自然科学基金(2024LHMS06002)、高校基本科研业务费项目(2024QNJ005)资助

0 引言

风机叶片在运行过程中受机械应力和极端天气的影响^[1],其表面很容易产生脱漆、裂纹和侵蚀等多种典型异常^[2]。这些异常会影响叶片的气动性能,导致机组发电量减少^[3]。因此,快速、精准地检测叶片异常状态对降低机组运维成本、提高发电效率至关重要。

传统风机叶片异常检测主要包括人工巡检、超声检测以及红外热成像检测等^[4-6]。随着叶片尺寸越来越大,人工巡检效率低的问题愈发明显。邹宜金等^[7]通过聚类和中值收敛技术处理叶片声纹信号以检测风机叶片的异常状态,但缺乏对异常状态的深入分析,无法准确识别异常状态的类别。尹玉等^[8]通过红外热成像技术针对叶片表面的裂纹和磨损进行检测,检测效果容易受到环境温度影响。

基于深度学习的目标检测方法,拥有强大的特征学习能力,并且能够准确识别不同异常状态^[9]。祁雷等^[10]针对叶片异常区域边界模糊的问题,提出一种融合注意力机制的语义分割网络,通过在编码器与解码器之间加入卷积注意力模块有效提升网络对叶片表面4种异常状态的分类准确率。付军军等^[11]将改进的 EfficientNet 模型用于海上风机叶片异常状态检测,通过在特征提取网络中引入非对称卷积提高网络对微小异常点的检测精度。上述算法虽具有较高的准确率,但模型参数量大且检测速度较慢,随着 YOLO 系列目标检测算法的发展,YOLOv10^[12]采用双重标签分配策略,实现了较快的检测速度和便于部署到嵌入式设备的模型参数量,但对于小目标异常点的检测精度略显不足。

综上,目前风机叶片异常检测存在模型参数量与精度不平衡以及小目标异常点检测精度低的缺点,针对以上问题,本文基于 YOLOv10n 提出一种基于跨维度特征交互的轻量化检测模型(cross-dimensional fusion network, CDFNet)。在 YOLOv10 算法的骨干网络中构建特征增强下采样模块(feature enhancement downsampling, FED),引导模型在下采样时保留更多复杂异常区域的细粒度特征。通过设计跨维度协同注意力模块(cross-dimensional collaborative attention, CCA),增强模型对小目标异常的空间位置和语义表达能力。构建快速双向特征金字塔网络(fast bidirectional feature pyramid network, FBiFPN),提高模型的多尺度特征融合效率。最后通过实验验证 CDFNet 在风机叶片异常检测中的有效性。

1 YOLOv10 算法

YOLOv10 算法的模型结构分为 Input、Backbone、

Neck 和 Head 4 个部分。图 1 所示为 YOLOv10 网络结构。其中 Input 部分采用马赛克增强(mosaic)、混合增强(mixup)、随机扰动(random perspective)以及颜色扰动(HSV augment)对输入图像进行预处理。Backbone 部分负责提取图像中的多尺度特征。Neck 部分将来自 Backbone 中不同尺度的特征图进行融合。Head 针对 Neck 融合后的多尺度信息输出不同尺度目标的检测结果。Backbone 中的局部自注意力机制(partial self-attention, PSA)将特征图划分为两部分,并将其中一部分输入到多头自注意力模块(multi-head self-attention, MHSA)和前馈网络(feed-forward network, FFN)中,这样仅关注空间域内的局部关系,缺乏建模通道域内跨层级的特征交互,将导致浅层细节特征与深层语义信息的割裂问题。Neck 网络结构采用路径聚合网络(path aggregation network, PANet),通过自底向上的特征融合路径,聚合不同层级间的语义和细节特征,但参数量大不适合模型轻量化。

2 CDFNet 算法

本文基于 YOLOv10n 提出跨维度特征交互的轻量化检测模型 CDFNet,图 2 为 CDFNet 网络结构。

CDFNet 在 YOLOv10 的 Backbone 中引入特征增强下采样模块 FED,增强模型对浅层细粒度特征的保留。将局部自注意力机制 PSA 替换为跨维度协同注意力 CCA,通过建模空间信息和语义信息间的交互关系,引导模型更加精准地聚焦于叶片异常区域,为多尺度特征融合提供更优质的特征表达。将 Neck 网络的 PANet^[13]结构替换为更高效的快速双向特征金字塔网络 FBiFPN,通过跨层级的双向连接实现深层语义信息向浅层节点的逆向传播,同时建立浅层细节特征向深层节点的正向传递路径,从而增强 Neck 网络的多尺度特征融合效率与模型整体的轻量化水平。

2.1 特征增强下采样模块

Backbone 网络通过空间通道解耦(spatial-channel decoupled downsampling, SCDown)对特征图进行下采样,这种下采样方式主要关注特征图分辨率的压缩,缺乏对特征图语义信息的保留。为此,本文提出特征增强下采样(feature enhancement downsampling, FED)模块,通过逐点卷积与组卷积,保留叶片异常区域的细粒度特征并增强语义表达,其结构如图 3 所示。

首先,通过逐点卷积对输入特征图 X 进行通道升维,增强网络对异常区域特征的表达能力。接着使用通道维度不变的逐点卷积与分组数为通道维度一半的 3×3 核组卷积,得到通道特征的语义描述 X_1 和空间尺度信息 X_2 。然后将 X_1 和 X_2 按通道维度进行混洗,打破组间信息隔




图 1 YOLOv10 网络结构

Fig. 1 YOLOv10 network structure

离,使组间信息得到通道语义补充。最后,通过最大池化操作完成下采样,得到输出特征图 X^{out} :

$$X_1 = GConv_{1 \times 1} [Conv_{1 \times 1}(X)] \quad (1)$$

$$X_2 = GConv_{3 \times 3} [Conv_{1 \times 1}(X)] \quad (2)$$

$$X^{out} = M[Shuffle(X_1, X_2)] \quad (3)$$

式中: $GConv_{3 \times 3}$ 为卷积核为 3 的组卷积; M 为最大池化操作; $Shuffle$ 表示将输入特征图按照通道维度进行混洗。

2.2 跨维度协同注意力

图 4 为跨维度协同注意力机制 CCA 结构。为了保留通道信息的同时减少模型的计算开销,将输入特征图沿通道维度进行分组重构,然后利用通道注意力与空间注意力生成包含语义信息的通道注意力特征图,以及包含位置和尺度信息的空间注意力特征图。最后通过权重激活和矩阵乘积操作,实现特征间的跨维度交互。

特征图分组子特征是为了保留每个通道特征完整性

的同时,降低网络的计算开销。将输入特征图 $X \in \mathbf{R}^{B \times C \times H \times W}$ 沿通道维度重构为通道维数减半的 $X_1 \in \mathbf{R}^{(B \cdot 2) \times (C/2) \times H \times W}$ 。

通道注意力机制如图 5 所示,首先通过全局平均池化将 X_1 的空间维度压缩为一维特征 X_2 ;接着利用一维卷积建模局部跨通道交互 W_1 ,同时,使用两个全连接层对特征降维再升维,以建立通道间的长程依赖关系 W_2 ;最后,将 X_1 、 W_1 、 W_2 进行点积得到加权后的通道注意力特征表示 X_c :

$$X_2 = GAP(X_1) \quad (4)$$

$$W_1 = \delta[Conv1d(X_2)] \quad (5)$$

$$W_2 = \delta\{F_2\{\delta[F_1(X_2)]\}\} \quad (6)$$

$$X_c = X_1 \times W_1 \times W_2 \quad (7)$$

式中: GAP 表示全局平均池化操作; F_1 、 F_2 为全连接层; δ 为 SiLU 激活函数; $Conv1d$ 表示一维卷积操作。

空间注意力机制如图 6 所示,首先对 X_1 采用 5×5 深




图2 CDFNet 网络结构

Fig. 2 CDFNet network structure




图3 特征增强下采样模块

Fig. 3 Feature enhancement downsampling module

度卷积初步提取局部空间特征得到 S_1 ; 随后分别使用 7×7 、 11×11 和 21×21 深度卷积继续捕获多尺度空间特征 S_2 、 S_3 、 S_4 ; 将各尺度特征 S_1 、 S_2 、 S_3 、 S_4 相加融合空间信息后, 通过逐点卷积和 SiLU 激活函数生成空间注意力权重 Z ; 最后将 X_1 与 Z 进行点积得到加权后的空间特征表示 X_s :

$$Z = \delta[\text{Conv}_{1 \times 1}(S_1 + S_2 + S_3 + S_4)] \quad (8)$$

$$X_s = X_1 \times Z \quad (9)$$

式中: δ 表示 SiLU 激活函数; $\text{Conv}_{1 \times 1}$ 为逐点卷积。

跨维度特征交互是对 X_c 和 X_s 分别进行全局平均池化, 得到聚合通道语义信息的向量 G_1 与整合空间尺度特征的向量 G_2 , 同时, 通过 Softmax 激活函数对 X_c 和 X_s 进

行归一化, 生成通道注意力权重分布 Q_1 与空间注意力权重分布 Q_2 ; 然后, 将 Q_1 与 G_2 进行矩阵相乘操作, 实现通道信息对空间位置的语义引导, 将 Q_2 与 G_1 进行矩阵相乘, 建模空间信息对语义类别的感知; 最终, 将两类交互权重相加并通过 Sigmoid 激活函数得到原始输入特征 X 的跨维度特征交互 X^{out} :

$$X^{\text{out}} = \sigma(Q_1 \times G_2 + Q_2 \times G_1) \quad (10)$$

其中, σ 表示 Sigmoid 激活函数。

2.3 快速双向特征金字塔网络 (BiFPN)

YOLOv10 的 Neck 网络结构 PANet 如图 7(a) 所示, $P_1 \sim P_5$ 表示不同尺度的特征融合层。PANet 通过将输入特征采样到相同分辨率, 然后按通道维度进行拼接来实现特征融合, 然而这种方式可能引入冗余信息和噪声, 降低融合特征的质量。

BiFPN^[14] 通过移除 PANet 中对特征融合贡献较低的冗余节点, 并在各层级之间建立跨层级连接机制, 实现了更加充分的多尺度特征融合, 其网络结构如图 7(b) 所示。然而 BiFPN 的加权融合机制会倾向于关注具有更强语义信息的深层特征, 这导致 BiFPN 在特征融合时浅层特征的贡献被弱化。

针对上述问题, 构建具有小、中、大 3 种尺度特征融合层的快速双向特征金字塔网络 FBiFPN。为了避免浅层细粒度特征在跨层融合时丢失, 设计快速特征融合模




图 4 CCA 注意力机制

Fig. 4 Cross-dimensional collaborative attention




图 7 特征融合网络

Fig. 7 Feature fusion network




图 8 快速特征融合模块结构

Fig. 8 Fast feature-fusion module structure

FBiFPN 利用跨层连接的信息流实现浅层特征与深层特征的双向传递,通过 FFM 模块对输入特征进行融合。首先通过卷积运算将来自不同层的输入特征统一通道维度;其次,通过采样操作将特征图统一分辨率再进行元素加和;最后,通过 SiLU 激活函数引入非线性,有效抑制融合后特征的背景噪声并增强高频细节。各节点融合过程如式(11)~(14)所示。

$$P_1^{\text{out}} = \delta \{ P_1^{\text{in}} + D[\text{Conv}(P_2^{\text{ts}})] \} \quad (11)$$




图 5 通道注意力机制

Fig. 5 Channel attention mechanism





图 6 空间注意力机制

Fig. 6 Spatial attention mechanism

块 (fast feature-fusion module, FFM) 替换 BiFPN 中的加权融合机制,FBiFPN 的网络结构如图 7(c) 所示, $P_1^{\text{in}}, P_2^{\text{in}}, P_3^{\text{in}}$ 为输入特征, $P_1^{\text{out}}, P_2^{\text{out}}, P_3^{\text{out}}$ 表示经过 FBiFPN 网络融合后的输出特征。FFM 结构如图 8 所示, X_1, X_2, X_3 为输入节点, X^{out} 为输出节点。

(c) 快速双向特征金字塔网络
(c) FBiFPN

$$P_1^{\text{ts}} = \delta \{ P_2^{\text{in}} + D[\text{Conv}(P_3^{\text{in}})] \} \quad (12)$$

$$P_2^{\text{out}} = \delta \{ P_2^{\text{in}} + P_2^{\text{ts}} + U[\text{Conv}(P_1^{\text{out}})] \} \quad (13)$$

$$P_3^{\text{out}} = \delta \{ P_3^{\text{in}} + U[\text{Conv}(P_2^{\text{out}})] \} \quad (14)$$

式中: P_2^{ts} 表示中间层经过初次特征融合的过渡节点; D 为下采样操作; U 为上采样操作。

3 实验结果与分析

3.1 数据集

本文使用自建数据集。原始数据由 DJI Mavic 3 Classic 无人机搭载哈苏 L2D-20c 相机,以视频形式采集,视频分辨率为 3 840×2 160。数据涵盖晴天与阴天两种光照条件。在数据集构建过程中,为了保留缺陷细节并

降低模型计算开销,采用对视频进行抽帧与裁剪的方式,筛选出叶片区域完整且清晰的关键帧。最终得到统一分辨率为 1 280×1 080 的 1 244 张有效图像。随后通过旋转变换和对比度增强等数据增强手段,将数据集扩充至 5 601 张。所有图像均使用 Make Sense 完成标注,并按照 8 : 1 : 1 的比例划分为训练集、验证集和测试集。缺陷种类如图 9 所示,缺陷信息如表 1 所示。




图 9 缺陷类别示意图

Fig. 9 Schematic diagram of defect categories

表 1 缺陷类别及统计信息

Table 1 Defect categories and statistics

缺陷类别	缺陷数量	缺陷长度/cm	缺陷宽度/cm
cracking	327	10~30	0.5~2
dirt	1 374	150~1 000	5~30
missing part	105	20~30	2~5
erosion	2 610	10~50	3~20
breakage	1 087	10~20	2~5
lightning	1 118	15~30	2~8
paint	1 574	15~40	5~20
tape	4 465	10~60	2~6
scratches	1 320	15~30	3~10

3.2 实验环境

实验硬件配置采用 NVIDIA GeForce RTX 3080 Ti GPU 和 Intel(R) Xeon(R) Silver 4210 CPU,操作系统采用 Ubuntu18.04.6 LTS,编程语言为 Python3.9,深度学习框架为 Pytorch2.0.1,CUDA 版本为 11.8。模型参数设置训练轮次为 200 轮,采用带动量的随机梯度下降(stochastic gradient descent,SGD)优化器加速模型收敛,初始学习动量为 0.937,初始学习率为 0.01,批处理大小为 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 CDFNet 模型的性能,采用目标检测领域常用的精确率(precision,P)、召回率(recall,R)和交并比(intersection over union,IoU)阈值为 0.5 的均值平均精度(mean average precision,mAP)来衡量 CDFNet 模型的检测性能。采用模型参数量(params)、浮点计算量(GFLOPs)以及每秒帧数(frames per second,FPS)评判模型的轻量化程度,各评价指标定义如式(15)~(18)所示。

P = TP / (TP + FP) (15)

R = TP / (TP + FN) (16)

AP = ∫₀¹ P(R) dR (17)

mAP = 1/N ∑ᵢ APᵢ (18)

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 反映模型对检测对象的漏检程度;mAP 综合反映模型对每个类别的检测性能表现。

3.4 消融实验

采用逐步添加和组合添加的方式,评估 FED、CCA 和 FBiFPN 3 种改进方法对模型整体性能的提升效果,引入特征增强下采样模块 FED 记为改进方法 A,跨维度协同注意力机制 CCA 记为改进方法 B,快速双向金字塔特征融合网络 FBiFPN 记为改进方法 C。实验结果如表 2 所示,√表示已采用的方法。

表 2 消融实验结果

Table 2 Ablation experiment results (%)

模型	A	B	C	P	R	mAP@0.5
YOLOv10n				78.4	69.1	76.8
YOLOv10-A	√			81.1	73.7	79.9
YOLOv10-B		√		81.2	72.2	79.8
YOLOv10-C			√	82.4	73.5	80.4
YOLOv10-AB	√	√		78.2	74.6	81.3
YOLOv10-AC	√		√	82.9	73.4	81.9
YOLOv10-BC		√	√	83.3	73.2	80.8
CDFNet	√	√	√	83.8	75.4	83.2

由实验结果可知,原网络模型 YOLOv10n 的 mAP 为 76.8%,单独加入 FED、CCA 和 FBiFPN 后,mAP 分别提高了 3.1、3 和 3.6 个百分点,其中 FBiFPN 对模型的综合性能提升最佳,验证了多尺度特征融合网络改进的有效性。Backbone 中采用的下采样改进方法 FED 对原网络模型召回率提升 4.6 个百分点,显著降低了模型的漏检

率。CCA 注意力机制使得模型的准确率、召回率、mAP 均有明显提升。

当两种改进方法组合使用时, YOLOv10-AB 和 YOLOv10-AC 均取得了较高的召回率, 进一步证明了 FED 对降低模型漏检率的贡献。YOLOv10-BC 相比 YOLOv10-AB 和 YOLOv10-AC 精确率最高, 由此可见 CCA 与 BiFPN 协同使用的优越性。最后, 3 种改进方法组合使用的 CDFNet 达到最佳性能, 与 YOLOv10n 相比, 精确率提升 5.4 个百分点, 召回率提升 6.3 个百分点, mAP 提升 6.4 个百分点。

3.5 对比试验

1) 优化器效果对比

优化器通过调整模型参数来最小化损失函数, 从而加速模型收敛, 本文通过对比 SGD 优化器和自适应矩估计 (adaptive moment estimation, Adam) 优化器在模型训练过程中的 Loss 曲线, 以验证本文优化器选择的合理性。SGD 优化器在模型每次迭代时使用一个小批量来引入随机性, 随后沿梯度反方向更新模型参数。Adam 优化器通过为每个参数自适应调整学习率并利用梯度的动量和方差进行参数更新。图 10 所示为 SGD 和 Adam 两种优化器在相同实验环境下的 Loss 曲线对比。




图 10 两种优化器 Loss 曲线对比
Fig. 10 Comparison of the Loss curves of the two optimizers

由图 10 可知, Adam 优化器在模型初始训练阶段取得相对 SGD 优化器更低的 Loss 值, 在接近 10 轮迭代时两种优化器的 Loss 曲线产生交会, 随着训练轮次增加, SGD 的收敛速度超过 Adam。通过实验对比验证了 SGD 更加适合作为本文模型的优化器。

2) Backbone 网络优化对比

本文在 Backbone 网络中分别引入 GhostConv^[15]、SPPFCSPC^[16]、GSCConv^[17] 以及主流的主干网络改进方法, 验证本文改进方法 FED 的有效性, 实验结果如表 3 所示。由实验结果可知, FED 相比其他改进方法实现了最高的召回率和均值平均精度, 分别较原始模型提升了 4.6 和 3.1 个百分点。GSCConv 和 FasterNet 虽然分别在精确率和参数量方面略优于 FED, 但其他指标均不及

FED, 相比之下, FED 不仅大幅提升了模型的均值平均精度还显著增强了模型的检测准确率, 实现了更为全面的模型性能优化。

表 3 Backbone 网络优化对比

模型	P/%	R/%	mAP@ 0. 5/%	Param/(×10 ⁶)
YOLOv10n	78. 4	69. 1	76. 8	2. 71
+GhostConv	80. 8	71. 5	78. 8	2. 83
+FasterNet	76. 1	67. 2	75. 6	2. 57
+SPPFCSPC	79. 9	71. 2	78. 9	4. 09
+GSCConv	82. 1	70. 3	78. 6	2. 69
+BiFormer	76. 7	69. 1	77. 6	2. 96
+FED	81. 1	73. 7	79. 9	2. 68

3) 不同注意力机制效果对比

为进一步分析本文提出的 CCA 注意力机制对模型性能的提升效果, 在 YOLOv10n 模型的基础上添加其他主流注意力机制与 CCA 进行对比, 实验结果如表 4 所示。

表 4 不同注意力机制对比

模型	P/%	R/%	mAP@ 0. 5/%	Param/(×10 ⁶)
YOLOv10n	78. 4	69. 1	76. 8	2. 71
+EMA	76. 1	70. 4	76. 9	2. 47
+SE	76. 5	70. 1	77. 4	2. 45
+MSCA	79. 1	69. 4	77. 1	2. 54
+ECA	79. 8	70. 5	79. 4	2. 45
+CBAM	80. 7	70. 2	78. 3	2. 51
+CCA	81. 2	72. 2	79. 8	2. 67

通过对比表 4 实验结果可知, 主流注意力机制虽然参数量控制表现良好, 但对模型的精确率和召回率提升有限。相比之下, CCA 对均值平均精度、精确率以及召回率实现了更显著的提升, 具体而言, CCA 相比原网络模型在保持参数开销基本不变的情况下, 使 mAP 提升了 3 个百分点, 精确率提升 2.8 个百分点, 召回率提升 3.1 个百分点, 有效验证了 CCA 在提升模型检测精度方面的显著优势。

4) Neck 网络优化对比

表 5 为不同特征融合网络对 Neck 网络的性能优化对比。对比发现, 渐进特征金字塔网络 (asymptotic feature pyramid network, AFPN)^[18] 和级联融合网络 (cascade fusion network, CFNet)^[19] 虽然使模型的参数量显著减少, 但均值平均精度、精确率和召回率皆明显降低。相反, BiFPN 使原网络模型的均值平均精度、精确率以及召回率分别提高 2.4、1.5 和 4.3 个百分点, 模型参数量下降 12%, 在此基础上本文通过改进 BiFPN 所提出

的 FBiFPN 实现了最优性能,相比原网络模型均值平均精度、精确率和召回率分别提升 3.6、4 和 4.4 个百分点,模型参数量下降 24.3%。

表 5 Neck 网络优化对比

模型	P/%	R/%	mAP@ 0.5/%	Param/(×10 ⁶)
YOLOv10n	78.4	69.1	76.8	2.71
+AFPn	73.8	64.8	72.1	1.86
+CFNet	73.5	65.2	73.7	2.35
+BiFPN	79.9	73.4	79.2	2.38
+FBiFPN	82.4	73.5	80.4	2.05

5) 模型改进前后实验结果对比

如图 11 所示为模型改进前后的检测结果对比,左侧为原模型 YOLOv10n 的检测结果,右侧为本文改进模型 CDFNet 的检测结果,不难发现,CDFNet 相比 YOLOv10n 对各类型异常状态的检测精度均有提升,特别是对 cracking、breakage、missing part 等小目标异常进行检测时,CDFNet 具有更高的检测精度和识别定位能力。

表 6 为模型改进前后的 AP@ 0.5 对比,通过数据对比可知,CDFNet 模型对各类叶片表面异常的检测平均精度皆有提升,其中 cracking、missing part 和 breakage 等小目标异常的检测效果提升最明显,分别提升 21.3、11.6 和 11.1 个百分点,进一步验证 CDFNet 模型对提升小尺度异常检测精度的有效性。

表 6 平均精度对比

Class	YOLOv10n	CDFNet
cracking	63.4	84.7
dirt	97.2	97.9
missing part	78.1	89.7
erosion	63.6	64.4
breakage	64.5	75.6
lightning	90.6	92.9
paint	82.4	84.2
tape	71.5	72.6
scratches	81.8	86.7

6) 不同模型实验结果对比

为进一步验证 CDFNet 在风机叶片表面异常状态检测中的优势,与主流目标检测模型 Faster R-CNN^[20]、TOOD^[21]、ATSS^[22] 以及轻量化检测模型 YOLOv8n、YOLOv10n、YOLOv10s、YOLOv11n、RT-DETR^[23] 进行对比,实验结果如表 7 所示。




图 11 检测结果对比
Fig. 11 Comparison of detection results

表 7 不同模型结果对比

Table 7 Comparison of results from different models

模型	mAP@0.5/%	Params/($\times 10^6$)	FPS	GFLOPs
Faster R-CNN	79.5	41.39	32	208
TOOD	82.3	32.04	24	199
ATSS	78.9	38.92	36	110
YOLOv8n	78.4	3.01	104	8.1
YOLOv10n	76.8	2.71	122	8.2
YOLOv10s	80.5	8.04	94	24.5
YOLOv11n	79.1	2.59	106	6.4
RT-DETR	77.9	32.01	77	103.5
CDFNet	83.2	2.02	110	9.7

由实验结果可知, CDFNet 相较于原网络模型 YOLOv10n 参数量下降 25.5%, mAP 提升 6.4 个百分点。与其他目标检测模型 YOLOv8n、YOLOv10s、YOLOv11n 以及 RT-DETR 相比, CDFNet 实现了更高的帧数, 且 mAP 分别提升了 4.8、2.7、4.1 和 5.3 个百分点。此外, 主流两阶段目标检测算法 Faster R-CNN 及一阶段算法 ATSS 和 TOOD 的 mAP 值分别为 79.5%、78.9%、82.3%, 但相比 CDFNet 存在模型参数量大和检测速度慢的问题。综上, CDFNet 更加适合风机叶片表面异常检测。

3.6 模型泛化性实验分析

本文在相同实验环境的前提下采用 NEU-DET 热轧钢带公开数据集^[24]进行 CDFNet 模型的泛化性实验, NEU-DET 数据集包括开裂 (cracking)、夹杂物 (inclusion)、斑块 (patches)、麻面 (pitted surface)、氧化皮 (rolled-in scale) 和划痕 (scratches) 共 6 种钢带异常。其中开裂和划痕与本文风机叶片表面异常中的 cracking 具有较为相似的视觉特征, 适合用于验证 CDFNet 模型的泛化性, 表 8 为模型改进前后各类别 AP@0.5 对比, 表 9 为检测性能对比。

表 8 模型泛化性实验

Table 8 Model generalization experiment (%)

Class	YOLOv10n	CDFNet
cracking	34.3	40.4
inclusion	77.1	78.9
patches	91.6	89.4
pitted surface	85.3	85.7
rolled-in scale	64.1	66.8
scratches	80.8	90.5

表 9 模型检测性能对比

Table 9 Comparison of model detection performance (%)

模型	P	R	mAP@0.5
YOLOv10n	67.2	64.9	72.2
CDFNet	72.5	69.3	75.3

由表 8 可知, 除斑块类型异常外, 其他异常的检测平均精度均有提升, 尤其是开裂和划痕类小尺寸异常的平均精度分别提升 6.1 和 9.7 个百分点。由表 9 可知, CDFNet 在 P、R、mAP@0.5 方面的表现均优于基线模型, 表明 CDFNet 具有较好的模型泛化能力。

4 结 论

针对现有风机叶片表面异常检测算法模型参数量大以及微小尺寸异常难以检测的问题, 本文提出一种基于 YOLOv10n 的跨维度特征交互轻量化检测网络 CDFNet。通过在 Backbone 网络中引入 FED 模块和 CCA 注意力机制, 在保留浅层细节信息的同时增强网络对叶片表面小尺寸异常区域的定位识别能力。针对不同类别异常的尺度差异大的特性, 将 Neck 网络构建为 FBiFPN 结构, 有效建立跨层级连接的多尺度特征融合。实验结果表明, 结合 FED、CCA、FBiFPN 3 种改进方法的 CDFNet, mAP 值达到 83.2%, 较 YOLOv10n 提升 6.4 个百分点, 模型参数量减少 25.5%。与其他主流目标检测模型相比, CDFNet 在检测精度与模型轻量化方面表现出较优的综合性能, 在风机叶片表面异常状态检测任务中取得了较好的检测效果。

参考文献

[1] TONG G Q, YANG S B, LI Y, et al. Effects of blade tip flow on aerodynamic characteristics of straight-bladed vertical axis wind turbines [J]. Energy, 2023, 283: 129105.

[2] 王洪金, 刘香怡, 何赞泽, 等. 基于改进 NCC 算法的大尺寸原位风机叶片可见光图像拼接 [J]. 电子测量与仪器学报, 2024, 38(7): 1-12.

WANG H J, LIU X Y, HE Y Z, et al. Visible image stitching of large-scale in-situ wind turbine blades based on improved NCC algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(7): 1-12.

[3] 刘珂, 缪维跑, 李春, 等. 湍流风场下水平轴风力机尾流气动特性研究 [J]. 中国电机工程学报, 2026, 46(3): 1133-1143.

LIU K, MIAO W P, LI CH, et al. Study on aerodynamic characteristics of horizontal axis wind turbine wake in turbulent wind field [J]. Proceedings of the CSEE, 2026, 46(3): 1133-1143.

[4] JULEN M, ITSASO C, IRATXE A, et al. Defect detection in wind turbine blades applying convolutional neural networks to ultrasonic testing [J]. NDT and E International, 2025, 154: 103359.

[5] 何赞泽, 张帆, 刘昊, 等. 风机叶片无人机红外热图像拼接方法 [J]. 电子测量与仪器学报, 2022, 36(7):

- 44-53.
- HE Y Z, ZHANG F, LIU H, et al. UAV infrared thermal image stitching method for wind turbine blades[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(7): 44-53.
- [6] 彭一誉,何赟泽,虞俊锋,等. 风机叶片内部缺陷日光激励动态热成像方法研究[J]. 电子测量与仪器学报, 2024, 38(1): 64-71.
- PENG Y Y, HE Y Z, YU J F, et al. Research on solar-excited dynamic thermal imaging method for internal defects of wind turbine blades [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38 (1): 64-71.
- [7] 邹宜金,连应华,黄新宇,等. 基于声纹的高泛化性风机叶片异常检测方法研究[J]. 电子科技大学学报, 2021, 50(5): 795-800.
- ZOU Y J, LIAN Y H, HUANG X Y, et al. Research on generalized abnormal detection method for wind turbine blades based on voiceprint [J]. Journal of University of Electronic Science and Technology of China, 2021, 50(5): 795-800.
- [8] 尹玉,张永,王健,等. 基于热红外图像的风力机叶片损伤识别方法研究[J]. 太阳能学报, 2022, 43(2): 492-497.
- YIN Y, ZHANG Y, WANG J, et al. Research on wind turbine blade damage identification method based on thermal infrared image [J]. Acta Energiæ Solaris Sinica, 2022, 43(2): 492-497.
- [9] 苗力恒,田莹. 改进 YOLOv8n 的多尺度轻量化水下目标检测[J]. 电子测量与仪器学报, 2025, 39(4): 141-151.
- MIAO L H, TIAN Y. Multi-scale lightweight underwater object detection based on improved YOLOv8n [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(4): 141-151.
- [10] 祁雷,李宁,梁伟,等. 基于注意力机制的 U-Net 叶片缺陷图像分割[J]. 中国安全科学学报, 2024, 34(5): 139-146.
- QI L, LI N, LIANG W, et al. Blade defect image segmentation based on attention-mechanism U-Net [J]. Journal of Safety Science and Technology, 2024, 34(5): 139-146.
- [11] 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.
- [12] WANG A, CHEN H, LIU L, et al. YOLOv10: Real-time end-to-end object detection [J]. ArXiv preprint arXiv: 2405. 14458, 2024.
- [13] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 8759-8768.
- [14] TAN M, PANG R, LE Q V. EfficientDet: Scalable and efficient object detection[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 10778-10787.
- [15] HAN K, WANG Y H, TIAN Q, et al. GhostNet: More features from cheap operations [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 1577-1586.
- [16] 齐向明,柴蕊,高一萌. 重构 SPPCSPC 与优化下采样的小目标检测算法[J]. 计算机工程与应用, 2023, 59(20): 158-166.
- QI X M, CHAI R, GAO Y M. Small object detection algorithm based on reconstructed SPPCSPC and optimized downsampling [J]. Computer Engineering and Applications, 2023, 59(20): 158-166.
- [17] LI H, LI J, WEI H, et al. Slim-neck by GSConv: A better design paradigm of detector architectures for autonomous vehicles [J]. ArXiv preprint arXiv: 2206. 02424, 2022.
- [18] YANG G Y, LEI J, ZHU Z K, et al. AFPN: Asymptotic feature pyramid network for object detection [J]. ArXiv preprint arXiv: 2306. 15988, 2023.
- [19] ZHANG G, LI Z Y, LI J M, et al. CFNet: Cascade fusion network for dense prediction [J]. ArXiv preprint arXiv: 2302. 06052, 2023.
- [20] GIRSHICK R. Fast R-CNN[C]. 2015 IEEE International Conference on Computer Vision (ICCV), 2015: 1440-1448.
- [21] FENG C J, ZHONG Y J, GAO Y, et al. TOOD: Task-aligned one-stage object detection [J]. ArXiv preprint arXiv: 2108. 07755, 2021.
- [22] ZHANG S F, CHI C, YAO Y Q, et al. Bridging the gap between anchor-based and anchor-free detection via adaptive training sample selection [J]. ArXiv preprint arXiv: 1912. 02424, 2020.
- [23] ZHAO Y, LYU W, XU S, et al. DETRs beat YOLOs on real-time object detection [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2024: 16965-16974.
- [24] BAO Y Q, SONG K C, LIU J, et al. Triplet-Graph

reasoning network for few-shot metal generic surface defect segmentation [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-11.

作者简介



韩鸿, 2022 年于潍坊理工学院获得学士学位, 现为内蒙古科技大学硕士研究生, 主要研究方向为目标检测。

E-mail: 1724876048@qq.com

Han Hong received his B. Sc. degree from Weifang Institute of Technology in 2022.

He is now a M. Sc. candidate at Inner Mongolia University of Science and Technology. His main research interest includes object detection.



王金明(通信作者), 2004 年于吉林大学获得学士学位, 2007 年于吉林大学获得硕士学位, 2012 年于吉林大学获得博士学位, 现为内蒙古科技大学副教授, 主要研究方向为风电机组状态检测方面的研究。

E-mail: yb15661510224@163.com

Wang Jinming (Corresponding author) received his B. Sc. degree in 2004, M. Sc. degree in 2007, and Ph. D. in 2012, all from Jilin University. He is now an associate professor at Inner Mongolia University of Science and Technology. His main research interests include wind turbine condition monitoring.