

基于改进 YOLOv10n 的风机叶片缺陷检测研究

陈治锐¹, 焦良葆^{1,2}, 孟琳¹, 高阳¹, 顾嘉伟¹

(1. 南京工程学院 计算机工程学院, 南京 211167;

2. 江苏省智能感知技术与装备工程研究中心, 南京 211167)

摘要: 针对风机叶片缺陷检测中存在的多尺度目标敏感度低、复杂背景干扰严重、定位精度不足等问题, 现提出一种改进 YOLOv10n 的缺陷检测算法, 在 SPPF 模块中嵌入大核注意力机制 LSKA, 构建多尺度特征增强网络, 有效解决了叶片表面反光导致的误检问题; 设计通道优先注意力机制 CPCA, 通过建立跨维度交互通道选择模型提升了对微小缺陷特征的响应能力; 将模型原损失函数替换为 Wise-MPDIoU 损失函数, 融合动态权重调整策略与形状感知约束; 实验结果表明, 在无人机采集的风机叶片数据集上, 改进算法 $mAP@0.5$ 达到 84.1%, 较基准模型提升 2.9 个百分点, 为风电设备智能运维提供了可靠的技术方案。

关键词: 目标检测; 风机叶片表面缺陷; 深度学习; 注意力机制; 损失函数

Research on Defect Detection of Wind Turbine Blades Based on Improved YOLOv10n

CHEN Zhirui¹, JIAO Liangbao^{1,2}, MENG Lin¹, GAO Yang¹, GU Jiawei¹

(1. School of Computer Engineering, Nanjing Institute of Technology, Nanjing 211167, China;

2. Jiangsu intelligent perception technology and equipment Engineering Research Center, Nanjing 211167, China)

Abstract: To address the issues of low sensitivity to multi-scale targets, severe complex background interference, and insufficient localization accuracy in wind turbine blade defect detection, an improved YOLOv10n defect detection algorithm is proposed. In the SPPF module, a large-kernel attention mechanism (LSKA) is embedded to construct a multi-scale feature enhancement network, effectively solving the problem of false detections caused by reflections on the blade surface. A channel-priority attention mechanism (CPCA) is designed to enhance the response to small defect features by establishing a cross-dimensional interaction channel selection model. The original loss function of the model is replaced with the Wise-MPDIoU loss function, which integrates dynamic weight adjustment strategies and shape-aware constraints. Experimental results show that on a dataset of wind turbine blades collected by drones, the improved algorithm achieves an $mAP@0.5$ of 84.1%, representing a 2.9 percentage point improvement over the baseline model. This provides a reliable technical solution for the intelligent operation and maintenance of wind power equipment.

Keywords: object detection; blade surface defects of wind turbines; deep learning; attention mechanism; loss function

0 引言

风力发电作为清洁能源的重要组成部分, 风机的健

康状态对能源供应的稳定性和安全性至关重要^[1]。风机叶片作为风力发电机的关键部件, 在长期使用运行的过程中会受到材料疲劳、表面氧化、环境影响, 从而在其

收稿日期: 2025-07-30; 修回日期: 2025-08-28。

基金项目: 江苏省产学研合作项目 (BY20230656)。

作者简介: 陈治锐 (1999-), 男, 硕士研究生。

焦良葆 (1972-), 男, 教授, 硕士研究生导师。

孟琳 (1989-), 女, 副教授, 硕士研究生导师。

高阳 (1988-), 男, 副教授, 硕士研究生导师。

引用格式: 陈治锐, 焦良葆, 孟琳, 等. 基于改进 YOLOv10n 的风机叶片缺陷检测研究[J]. 计算机测量与控制, 2026, 34(1): 59-66, 93.

叶片表面形成如裂纹、变形、污垢等缺陷,会严重影响风力发电效率和设备寿命。因此,对风机叶片进行有效的缺陷检测是保障风力发电系统可靠性的重要环节。研究数据表明,风机叶片的运维成本大约可以占到全部成本的 15%~35%^[2-4]。因此,采用深度学习技术实现自动化检测是当前的重要发展方向。

因为风机叶片缺陷存在多样性和复杂性的特点,目前主要的检测方法有人工视觉检测,应变检测,超声波检测,红外检测等。传统的人工检测包括有绳索通道的人工检查,但人工巡检存在主观性强、高空作业风险大、容易发生漏检等问题^[5]。应变检测通过分解振动信号识别叶片损伤度,在实验室稳态工况下可实现毫米级缺陷定位,但在工业现场容易受噪声影响往往存在显著适用性瓶颈。目前常用的应变传感器主要为光纤布拉格光栅传感器,凭借小巧轻便、抗电磁干扰的特点,克服了电子应变片无法连续监测的局限,但其实际应用仍面临挑战:传感器通常需嵌入叶片复合材料中,对制造工艺要求高,可能增加生产成本与周期,且因局部监测特性需部署多个传感器,进一步提升成本与系统复杂度;其性能易受温度变化、机械应力等环境因素影响,长期使用可能导致精度下降。文献 [6] 提出基于小波包分析的风机叶片损伤检测方法,能够识别损伤梯度,但在复杂环境中的适用性仍需研究,且小波分析受噪声影响较大。超声波检测通过发射超声波并分析回波信号,实现叶片内部分层、脱粘等缺陷的定量检测,是目前少数能穿透复合材料的无损检测技术之一。但在实际工程中超声波检测面临传感器布置、信号衰减及操作一致性问题:传感器需高密度布置以覆盖检测区域,导致成本与维护难度上升,非优化布局易形成盲区;短波长超声波分辨率高但衰减显著,长波长则穿透强但分辨率低,存在检测性能矛盾;温湿等环境变化会影响传感器稳定性与信号衰减特性,尤其在极端条件下导致检测准确性与可靠性下降。文献 [7] 利用超声波检测风机叶片缺陷,但该方法对于设备装设位置要求高,若安装位置不当难以得到良好的检测数据。红外检测通过捕捉缺陷区域与基体的温度差异成像,结合图像拼接算法实现叶片表面缺陷的可视化检测。但该方法的检测结果易受环境温度、湿度、风速等因素影响,未校正时会降低检测准确性与可靠性;此外,该技术存在图像细节分辨率较低、表面反射易干扰检测效果的局限。文献 [8] 提出一种基于形态学改进的红外风机叶片图像拼接算法,改进后的算法提高了拼接的精度,并有很好的鲁棒性。深度学习凭借其强大的特征表示和学习能力,已成为目标检测领域的重要技术支撑。当前主流的目标检测算法主要分为一阶段 (one-stage) 和二阶段 (two-stage) 两类。二阶段方法以 R-CNN (Regions with Convolutional Neural

Network) 为代表,通过首先生成候选区域再进行分类和回归,虽然检测精度较高,但由于需要对每个候选区域单独处理,计算复杂、速度慢,难以满足实时检测需求。相比之下,一阶段方法如 YOLO (You Only Look Once)^[9] 和 SSD (Single Shot Multibox Detector)^[10] 直接从图像中预测目标位置和类别,省去了候选区域生成步骤,在保持较高精度的同时大幅提升了检测速度,更适合实时应用场景。早期的 YOLOv1-v4 奠定了基本框架, YOLOv5 进一步优化训练策略和模型轻量化,而 YOLOv8 则在精度和速度之间取得了更好的平衡,采用更高效的网络设计和动态标签分配策略。YOLOv10 在 YOLOv8 基础上引入自适应加权特征金字塔,实现不同尺度特征的融合,提高了对大小缺陷的检测效果^[11],结合 Transformer 模块和卷积网络,增强了复杂背景下的检测能力,并优化边界框回归,采用混合损失策略,增强了模型的鲁棒性和可靠性^[12]。文献 [13] 通过正交通道空间注意力模块,设计 GMS-C2f 来增强模型对于小目标缺陷的检测能力,缓解了误识别的问题,但优化后模型的检测速度仍有待提升。文献 [14] 通过高效多尺度卷积模块并在检测头部分融入 Dynamic Head 注意力机制提升模型的识别能力,但召回率较低。文献 [15] 将 YOLOv8 的检测头替换为轻量化共享卷积检测头,减少模型参数量提高检测帧率。文献 [16] 通过在 YOLOv7 网络中添加设计的 CSM 注意力模块并引入了 BiFPN 特征融合模块,增强网络对特征的提取效率,提高对于多尺度缺陷的识别能力。

为了满足更高的精度和效率要求,有效提高风机叶片表面缺陷的检测准确度与精度,本文将对 YOLOv10n 版本进行改进。首先,在 SPPF 模块中嵌入大核注意力机制 LSKA (Large Separable Kernel Attention),构建多尺度特征增强网络,有效解决了叶片图片过曝导致的误检问题;其次,在颈部网络中加入通道优先注意力机制 CPCA (Channel Prior Convolution Attention),通过建立跨维度交互通道选择模型提升了对微小缺陷(如裂缝、污垢)特征的响应能力;最后,提出 Wise-MPDI-oU 损失函数,融合动态权重调整策略与形状感知约束。

1 YOLOv10n 模型

YOLOv10^[17],由清华大学研究团队基于 Ultralytics 开发,汇集了 YOLO 系列先前版本的优点,并引入了多项创新特性和显著的性能提升。该系列提供了六种不同规模的模型版本,包括 n 、 s 、 m 、 b 、 l 和 x ,这些版本根据模型的深度和宽度,参数量和计算需求逐步增加,以适应从资源受限的设备到高性能计算平台的广泛需求。其中, YOLOv10n 作为最轻量级的版本,以其高分辨率和高效率的特点被选为风机叶片缺陷检测的基准

模型, 网络结构如图 1 所示。YOLOv10n 的架构由 3 个主要部分组成: 骨干网络 Backbone、颈部网络 Neck 和检测头 Head。骨干网络负责从输入图像中提取特征; 颈部网络则融合不同层级的特征, 增强特征表示; 最后, 检测头负责输出目标的分类和定位预测。这样的设计使得 YOLOv10n 不仅在资源受限的环境中表现出色, 而且在检测精度上也能满足工业应用的高标准要求。

骨干网络 Backbone 核心模块包括部分自注意力 (PSA, partial self-attention) 模块、C2fCIB 和空间一通道解耦下采样 (SCDown, spatial-channel decoupled downsampling) 模块^[18], SCDown 通过点卷积和深度卷积的串联实现空间通道分离下采样, 有效降低特征图维度并保持计算效率。C2fCIB 改进了 C3 模块, 进一步优化计算效率。YOLOv10n 还引入了快速空间金字塔池化结构 (SPPF, spatial pyramid pooling fast), 显著减少计算资源消耗, 增强模型的灵活性。SPPF 采用三个并行最大池化层来增强多尺度特征的捕捉能力, 使模型适应性和处理效率进一步提升^[19]。

颈部网络 Neck 融合了 FPN (Feature Pyramid Network) 和 PAN (Path Aggregation Network) 架构, 以增强多尺度特征的表达和融合能力。FPN 采用自顶向下的特征金字塔结构, 有效整合了不同层次的特征信息, 解决了多尺度目标检测中的挑战。FPN 通过将高层的语义信息与低层的细节信息相结合, 构建了一个多尺度的特征金字塔, 使得网络能够同时捕捉到小目标和大目标的特征; 而 PAN 通过双向路径融合进一步优化了这一结构, 增强了特征表达能力^[20], 通过引入双向

路径融合, 不仅保留了 FPN 的自顶向下信息流, 还增加了自底向上的信息流。这种双向融合策略使得 PAN 能够更全面地利用不同层次的特征信息, 从而增强了特征的表达能力。自底向上的路径使得网络能够保留更多的细节信息, 而自顶向下的路径则提供了丰富的语义信息, 两者的结合使得 PAN 在处理多尺度目标检测任务时, 能够更准确地识别出不同大小的目标。这种组合既保留了 FPN 的多尺度优势, 又结合了 PAN 的多路径交互特性, 显著提升了模型对不同尺寸目标的检测性能, 特别是在小目标检测方面表现突出。

YOLOv10n 的检测头采用轻量化双分支设计, 结合一对一分配 (one-to-one head) 和一对多 (one-to-many head) 实现高效检测。其中一对多分配在训练阶段为每个目标生成多个预测以提供丰富监督信号, 而一对一分配在推理阶段输出单一最优预测以提高效率。该网络采用解耦头结构和无锚框方案, 通过一致性双重分配策略直接输出检测结果, 这种设计使得在训练阶段无需依赖于非极大值抑制 (NMS) 算法, 而在推理时也可以避开 NMS, 从而在保证检测精度的同时显著降低了计算复杂度。这种创新设计不仅提升了训练效果, 优化了推理性能, 而且在准确性和效率之间达到了更好的平衡。通过减少对 NMS 的依赖, YOLOv10n 能够在保持高准确率的同时, 显著提高检测速度, 这对于需要实时处理的应用场景尤为重要。此外, 轻量化的设计也使得模型更适合在资源受限的设备上部署。

2 改进的 YOLOv10n 算法

YOLOv10n 作为当前主流的目标检测算法, 在检测速度和准确率方面表现出色, 具有广泛的适用性。然而在实际应用中, 模型在不同数据集上的表现存在显著差异, 特别是在背景复杂的情况下对于目标识别效果欠佳, 且在光线条件不理想 (如叶片反光) 的情况下检测精度低。针对这些问题, 本文通过对 YOLOv10n 改进 SPPF 模块、引入注意力机制、修改损失函数从而优化模型在反光情况下对于缺陷的识别能力以及对裂缝、污垢等特殊目标的检测性能, 在保证实时性的同时提高检测精度。具体改进方案如下。

2.1 SPPF-LSKA 模块

风机叶片数据集在经过数据预处理后, 因光照、拍摄角度等外界因素影响, 部分叶片图像仍存在曝

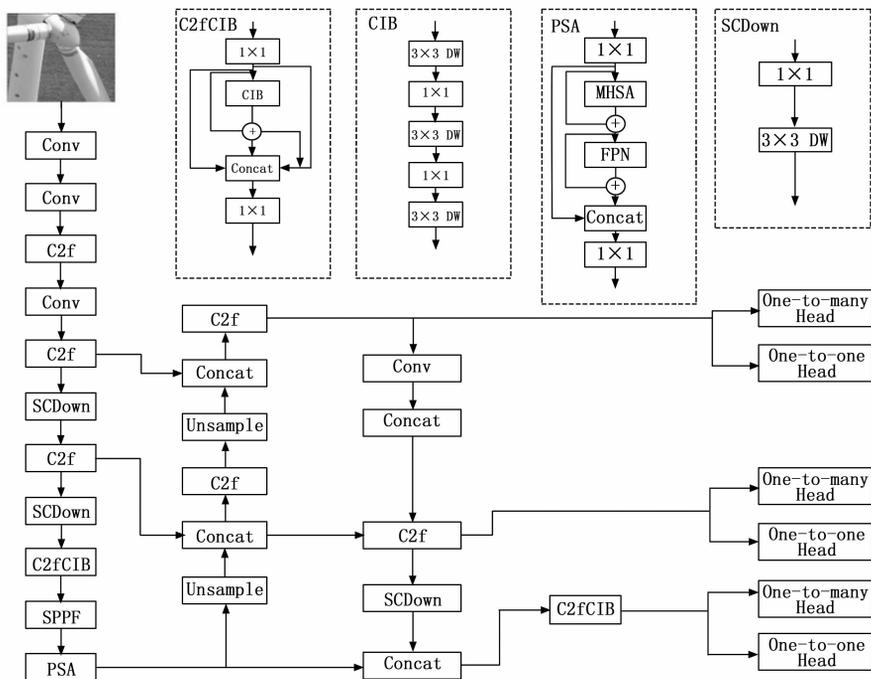


图 1 YOLOv10n 网络结构

光过度以及缺陷部分与背景相似等问题，导致模型在训练过程中，提取到的特征缺乏代表性和区分度，进而影响模型准确性和泛化能力。为了解决上述问题，提高模型对风机叶片代表性特征信息的提取能力，在 SPPF 模块中引入大型可分离核注意力（LSKA, large separable kernel attention）模块^[21]。将其命名为 SPPF-LSKA，改进后的结构如图 2 所示。

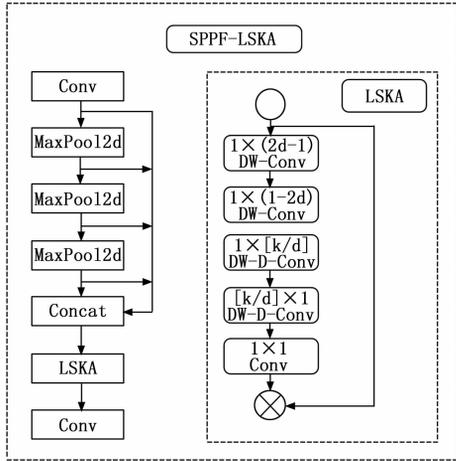


图 2 SPPF-LSKA 结构图

该结构的组成及工作机制如下：首先通过二维深度卷积（DW-Conv）提取图像的局部上下文特征；接着利用带有大感受野内核的二维扩张深度卷积（DW-D-Conv）模块模拟长程依赖关系；随后经由 1×1 卷积模块完成特征变换；最终与原始输入特征图进行哈达玛积运算，其具体计算过程可由下述公式表示：

$$\bar{Z}^C = \sum_{H,W} W_{(2d-1) \times 1}^C * \left(\sum_{H,W} W_{1 \times (2d-1)}^C * F^C \right) \quad (1)$$

$$Z^C = \sum_{H,W} W_{Lk/d \times J \times 1}^C (W_{1 \times Lk/d}^C * \bar{Z}^C) \quad (2)$$

$$A^C = W_{1 \times 1} * Z^C \quad (3)$$

$$\bar{F}^C = A^C \otimes F^C \quad (4)$$

其中： Z^C 表示深度卷积后的输出， H 和 W 表示特征图的高度和宽度， A^C 表示注意力权重矩阵， $\lfloor \cdot \rfloor$ 表示向下取整操作， d 表示扩展率， k 是卷积核大小， $*$ 表示卷积， \otimes 表示哈达玛积， F^C 表示输入特征图， C 表示输入通道数。

LSKA 注意力机制的工作流程可以从结构图中清晰地展现。该机制首先采用深度可分离卷积（DW-Conv）对输入图像进行特征提取，生成初始注意力分布图，使模型更好聚集关键区域。接着通过具有不同扩张率的空间扩张卷积（DW-D-Conv）进一步扩大感受野，增强模型获得更多上下文信息的能力。最终，经过特征融合生成的注意力图与原始特征图进行逐元素相乘，从而突出重要特征并抑制无关信息，有效提升模型在复杂背景下的识别性能。LSKA 采用级联一维卷积核替代传统二

维卷积核的设计，在保持优异特征提取能力的同时显著降低了计算复杂度。当将该机制集成到 SPPF 模块时，不仅显著提升了风机叶片缺陷的检测精度，而且没有引入额外的计算负担。这种平衡性能与效率的特性。

以往大核注意力机制多采用二维大尺寸卷积核（如 11×11 、 21×21 ）直接扩大感受野，其核心逻辑是通过单一二维卷积同时捕捉局部细节与长程依赖。但在风机叶片高反光场景中，这种设计会导致反光区域的均匀高光噪声与缺陷的非均匀纹理特征被共同聚合（例如叶片逆光时的高光区域与细微裂缝的边缘特征在二维卷积中被混合），难以区分噪声与有效缺陷特征，进而引发误检。而 LSKA 采用级联一维卷积核替代传统二维大核，将二维卷积的空间信息提取拆解，这种设计能分离局部纹理与长程依赖的提取过程，减少反光导致的误检；处理特征时，以往大核注意力机制多通过全局池化或单一卷积操作对特征进行无差别聚合。LSKA 则通过局部上下文提取，特征加权融合的分层逻辑处理特征，动态强化缺陷特征，抑制反光噪声。

总体来说，LSKA 机制通过结合深度可分离卷积与空间扩张卷积，有效地丰富了上下文信息，并强化了网络对关键特征的关注度，这显著提升了模型在对于风机叶片缺陷识别的性能及鲁棒性。应用 LSKA 改进 SPPF 模块使得模型在保留多尺度特征整合优势的同时，还进一步增强了对风机叶片缺陷的表达能力，在工业缺陷检测等实际应用中展现出显著优势。

2.2 CPCA 注意力机制

通道优先卷积注意力（CPCA, channel prior convolutional attention)^[22] 是一种先进的注意力机制模块，它结合了通道注意力和空间注意力，能够在通道和空间两个维度动态分配权重，快速聚焦于图像中的重要信息通道和区域，从而显著提升网络的定位能力。CPCA 的设计使得它在处理部分遮挡和异物干扰等复杂场景时，能够更加有效地聚焦于风机叶片缺陷特征区域，减少无关干扰因素的影响。CPCA 结构图如图 3 所示。

CPCA 的工作流程分为通道注意力与空间注意力两个阶段。在通道注意力阶段，其首先对输入特征图分别执行最大池化与平均池化操作，前者用于捕捉图像中具有显著差异的特征，后者则侧重获取整体层面的信息。这两种池化结果会被输入到一组共享权重的多层感知器（MLP, shared multi-layer perceptron）中。经处理后，MLP 的输出通过元素相加操作进行融合，再经 Sigmoid 函数归一化，生成表征通道重要性的权重向量。该权重向量随后与原始输入特征图进行逐元素相乘，最终得到蕴含通道先验信息的特征。

深度卷积网络提取空间依赖关系的完整过程可以系统地描述如下：首先，输入特征图进入深度卷积模块

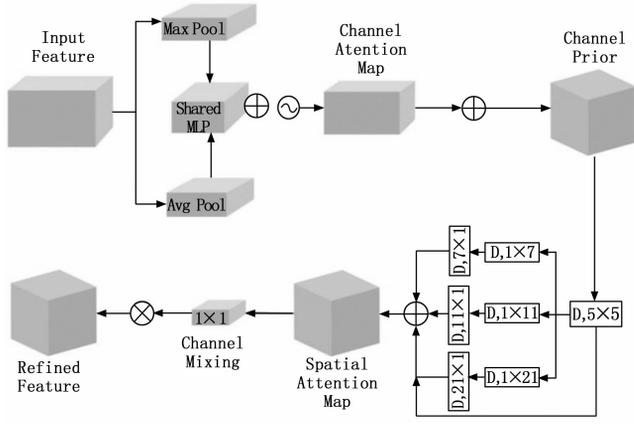


图 3 CPCA 注意力机制网络结构图

时, 会先经过一个 5×5 的卷积核进行初步特征提取, 为后续的多尺度特征提取奠定基础。每个分支都包含两个深度带状卷积层, 这种设计巧妙地模拟了大尺寸标准深度卷积的效果。这种分解策略使得网络能够高效地提取特征信息而不会造成计算资源的急剧增加。后续经过 3 个大小尺度的卷积核捕获不同的信息。 $D, 7 \times 1$ 卷积核其形状在空间上延伸, 能捕捉长范围特征; $D, 11 \times 1$ 卷积核可获取广泛上下文, 融合风机叶片缺陷周边信息; $D, 21 \times 1$ 卷积核尺寸最大, 获取宏观上下文, 整合远处特征, 用于评估大面积缺陷, 形成多尺度特征提取。接着, 使用 1×1 卷积进行通道混合, 增强特征提取能力。最后, 将通道混合后的特征与通道先验的特征逐元素相乘, 得到细化的特征作为输出, 显著降低了计算量。公式如下所示:

$$F_C = C_A(F) \otimes F \quad (5)$$

$$\hat{F} = S_A(F_C) \otimes F_C \quad (6)$$

$$C_A(F) = \sigma(MLP(AvgPool(F)) + MLP(MaxPool(F))) \quad (7)$$

$$S_A(F) = Conv_{1 \times 1} \left(\sum_{i=0}^3 Branch_i(DwConv(F)) \right) \quad (8)$$

传统的通道注意力机制, 像 SE 仅关注通道维度的注意力, 通过全局平均池化得到通道统计信息, 生成固定的通道权重, 无法根据空间位置的不同动态调整通道权重。CBAM 虽然结合了通道和空间注意力, 但在输出特征的所有通道上强制一致的空间注意力分布, 这就导致无法针对不同通道在空间上的重要区域进行精细化关注。而 CPCA 支持在通道和空间两个维度动态分配权重。在通道注意力阶段, 通过平均池化和最大池化操作聚合特征图的空间信息, 再经共享 MLP 处理生成通道注意力图, 这一过程能够动态学习每个通道的重要性。在空间注意力阶段, 使用多尺度深度卷积模块, 根据不同通道的特征在空间上动态分配注意力权重, 避免了在每个通道的空间注意力图中强制一致性, 使得网络

可以根据图像内容的变化, 灵活地在不同通道和空间位置上分配注意力, 更精准地聚焦于重要信息。

CPCA 的通道注意力机制能够自动识别数据中最重要特征通道, 并赋予这些通道更高的权重。网络通过这种动态的权重调整就能更专注于关键特征, 同时减少噪声干扰。同时利用多尺度可分离卷积模块, 提取多个尺度和方向的特征信息并与整体特征相融合。这种设计既能帮助网络快速定位目标, 减小无干扰因素的影响。

2.3 损失函数的改进

在目标检测任务中, 边界框回归的质量是评估模型性能的重要指标。YOLOv10n 的损失函数由三部分组成:

$$Loss = Loss_{box} + Loss_{dfl} + Loss_{cls} \quad (9)$$

其中: $Loss_{box}$ 是预测框的回归损失, $Loss_{dfl}$ 是偏移量的位置损失, $Loss_{cls}$ 是类别分类损失。原模型 YOLOv10n 使用的是 CIoU, CIoU 不仅考虑了预测框与真实框的重叠面积, 同时引入了中心点距离以及长宽比, 其计算公式如下:

$$L_{CIoU} = 1 - IoU + \frac{p^2(b, b^{gt})}{c^2} + \alpha v \quad (10)$$

$$\alpha = \frac{v}{(1 - IoU) + v} \quad (11)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right) \quad (12)$$

其中: v 表示长宽比, α 表示平衡参数, $p^2(b, b^{gt})$ 表示预测框与真实框中心点之间的欧氏距离, b 表示预测边界框, b^{gt} 表示真实边界框, c 表示归一化因子。然而 CIoU 在宽高比的定义上比较模糊, 质量好的回归样本难以进一步优化, 导致正负样本不均衡。且 CIoU 无法反应长宽位置与置信度之间的实际差距, 当实际检测框与预测框中心重合从而导致长宽比一致时, CIoU 会失效。且在多个预测框有较大面积重合时, 无法反应实际情况。为解决上述问题, 本文引用一种新的边界回归的损失函数 Wise-MPDIoU 替换 CIoU。

WIoU 通过预测框和真实框之间的区域进行加权, 通过自适应权重调整机制提升检测性能, 这种机制能够在面对多尺度目标时, 动态的调整权重, 提高收敛速度。解决了 IoU 可能存在的偏差问题, 其计算公式如下:

$$R_{WIoU} = \exp \frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)} \quad (13)$$

$$\beta = \frac{L_{IoU}^*}{L_{IoU}} \quad (14)$$

$$\gamma = \frac{\beta}{\delta \alpha^{\beta - \delta}} \quad (15)$$

式中, R_{WIoU} 表示损失函数, H 和 W 分别表示真实框和预测框最小外接矩形的长和宽。 β 表示表示离群度, L_{IoU}^* 表示 IoU 损失的梯度增益, δ 表示 IoU 损失的滑动平均,

θ 和 δ 是用于构造系数非单调性的超参数, γ 表示非单调动态聚焦系数。

MPDIoU 的核心思想是计算预测框和真实框对角线上两点之间的距离, 并将其与它们的交集结合起来, 优化模型实现更准确的边界框定位。这种方法在风机叶片缺陷目标检测任务中表现出了更高的准确性和鲁棒性, 有效地提升了定位精度。

本文运用 WIoU 的改进思想改进 MPDIoU, 运用改进后的 Wise-MPDIoU 代替原始网络中的 CIoU。Wise-MPDIoU 是一种直接最小化预测框和真实框对应左上角、右下角间点距离的改进算法, 对小目标的检测定位上更为准确, 具有更好的鲁棒性, 其计算公式如下:

$$MPDIoU = IoU - \frac{\rho^2(P_1^{pred}, P_1^{gt})}{w^2 + h^2} - \frac{\rho^2(P_2^{pred}, P_2^{gt})}{w^2 + h^2} \quad (16)$$

$$Wise - MPDIoU = WIoU - \frac{\rho^2(P_1^{pred}, P_1^{gt})}{w^2 + h^2} - \frac{\rho^2(P_2^{pred}, P_2^{gt})}{w^2 + h^2} \quad (17)$$

Wise-MPDIoU 引入离群度 β , 当预测框为离群样本 ($IoU < 0.3$) 时, β 趋近于 0, 降低其梯度贡献; 当 $IoU > 0.7$ 时, β 趋近于 1, 强化优质样本的优化。同时通过对角线距离替代 CIoU 的中心点距离, 更精准描述细长形缺陷的形状差异。

在风机叶片缺陷检测任务中, 改进后的损失函数通过动态梯度调节机制, 有效降低了噪声对模型训练的干扰。它能自动平衡不同类别样本的梯度贡献, 避免某些样本主导优化过程, 从而提升模型在复杂场景下的泛化能力, 最终实现更精准的缺陷定位。

3 实验与分析

3.1 数据集的构建

本次实验使用无人机对风机进行过多维度影像采集, 所获取的图像包含风机叶片、旋转罩、塔架、机舱等多个关键结构部件的外观特征。涵盖不同气象条件(晴朗/多云)与光照环境(顺光/逆光)下的成像场景, 通过无人机平台的姿态控制实现对目标对象的俯仰、侧视、环绕等多角度拍摄, 亦覆盖不同污染程度下的设备表面影像数据获取, 构建了包含光照条件、观测角度、污染状态等多变量的风机视觉数据集, 同时对图片进行旋转增加数据的多样性。共获得有效的图片一共 4467 张。数据集包含六类标签, 分别为: 裂缝 (crack)、变形 (deformity), 污垢 (dirt), 油渍 (oil), 剥落 (peeling), 生锈 (rusty)。数据集部分图片如图 4 所示。

3.2 数据集的处理

首先, 使用 Labelimg 软件对图像进行标注, 并在 labels 目录中存储标注后的 XML 文件。随后, 通过 Python 脚本将 XML 文件转换为 TXT 文件。将图片和对

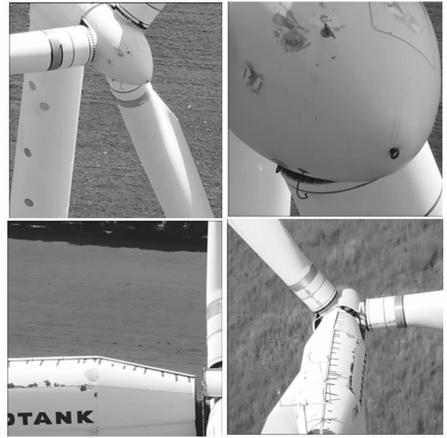


图 4 数据集中部分图像实例

应的标注文件按照 8 : 1 : 1 的比例分配至训练集、验证集和测试集中, 数量分别为 3 573、447 和 447。

3.3 实验平台

服务器相关配置如下: 实验操作平台为 Ubuntu18.04.6、CPU 为 AMD Ryzen threadripper 3970x 32-core processor x64, GPU 为 NVIDIA GeForce RTX3090 显卡 * 3, 显存 24 G, 内存 128 G, 编程环境为 Python 语言。

实验所使用的参数指标: 精准率 P (Precision)、召回率 R (Recall)、mAP (Mean Average Percision)。其中 P、R、mAP 参数指标计算公式如下所示:

$$P = \frac{TP}{TP + FP} \quad (18)$$

$$R = \frac{TP}{TP + FN} \quad (19)$$

$$mAP = \frac{\sum_{i=1}^N AP_i}{N} AP = \int_0^1 P(R) dR \quad (20)$$

在目标检测性能评估体系中, 关键指标的定义如下: TP (True Positives) 代表被正确检测到的目标数量; FP (False Positives) 表示被错误识别为目标的实际目标。查准率 P 反映了模型预测结果的准确性, 其计算方式为正确检测目标数占全部预测目标数的比例。而 mAP 作为综合评价指标, 通过综合考量不同置信度阈值下的检测表现, 能够更全面地评估模型性能。一般来说, mAP 数值越高, 代表模型的整体检测能力越强。输入图片尺寸为 640 * 640, 初始学习率设置为 0.01。

3.4 实验结果

为了验证所提算法改进后的性能及优势, 采用上述数据集训练后, 用原始 YOLOv10n 模型和改进后模型对原始数据集进行测试并对比结果, 每个结果中左侧是原始 YOLOv10n 模型的检测结果, 右侧是所提改进后模型的检测结果; 从对比分析结果可以明显观察到, 改进后的网络有较好的识别效果, 对多类目标识别的置信

度都有所提高。原网络在识别灰尘此类小目标时容易出现漏检问题, 改进后的模型能够准确识别所有目标; 在识别剥落时原始模型出现多处漏检, 改进后模型不仅识别全面而且准确度较之前有明显提升, 这是由于复杂背景干扰, 且叶片缺陷和风机颜色相近, 叶片表面反光等因素, 导致图像获取的内容过多, 从而对缺陷的准确检测造成了明显的干扰。同时之前可被检测出来的目标也有着更高的置信度; 最后, 原始的检测模型对于光线要求比较高, 位于阴影中的缺陷未被检测出来, 而改进后的模型可以识别出裂缝并且有较高的置信度。在改进 SPPF 模块, 加入注意力机制, 修改损失函数后, 提高了网络的特征获取能力, 更好的聚焦于缺陷的特征, 提高了识别精度

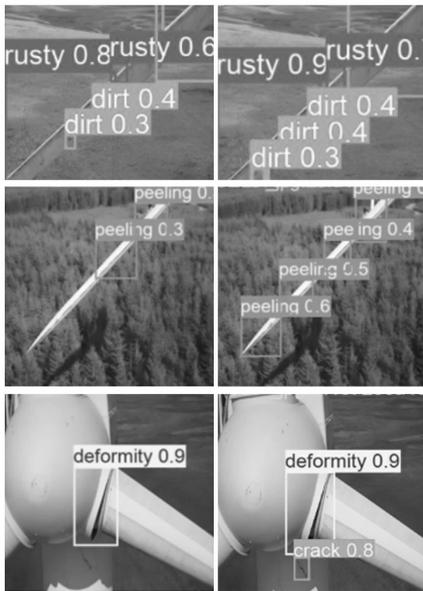


图 5 检测效果对比

3.5 评估分析

对比 YOLOv10n 原网络, 本实验进行了三点改进: 利用 LSKA 注意力机制改进 SPPF, 在 Neck 网络中加入 CPCA 注意力模块, 最后用 Wise-MPDIoU 替代原损失函数 Ciou。为探究各改进模块组合对模型性能的影响, 现将 SPPF-LSKA 模块、CPCA 注意力机制、Wise-MPDIoU 损失函数这 3 个改进部分进行消融实验, 对比不同方案下的模型表现, 表 1 展示了消融实验结果。

表 1 消融实验

编号	SPPF-LSKA	CPCA	Wise-MPDIoU	Precision /100%	Recall /100%	mAP0.5 /100%	Parameter /M
0				80.7	73.6	81.2	2.3
1	✓			81.6	74.3	82.1	2.5
2		✓		78.6	77.8	82.4	2.4
3			✓	81.9	76.6	83.3	2.3

观察表 1 中的数据能够看出 3 组优化对模型检测性

能有不同影响。第一组实验中, 在 YOLOv10n 模型中引入 SPPF-LSKA 模块, 各项指标相较于原始模型都有所上涨, 其中; 第二组实验中, 在原网络的 Neck 部分引入 CPCA 注意力机制, 虽然相较于原始网络, Precision 下降了 2.1%, 但 Recall、mAP0.5 这两个指标分别提升了 3.5%、1.5%, 所以总体来说, 其综合性能仍是有一定的提升; 第三组实验中, 将 YOLOv10n 模型的 Ciou 损失函数更改为 Wise-MPDIoU, 各项指标相较于原始模型都有了不错的提升, mAP 提升了 2.1%。同时可以看出改进 SPPF-LSKA 和加入 CPCA 注意力机制模块后在提升模型检测性能的同时并没有大幅提升参数量, 较原模型仅提升 0.1 和 0.2。

1) 注意力机制实验对比:

为了证明更换 CPCA 注意力机制的有效性, 本实验将 CPCA 注意力模块增加到 Neck 网络。并与加入 EMA、CAFm、CBAM 模块进行对比实验, 实验结果如表 2。实验结果表明, 加入 CPCA 注意力模块, 模型能得到较高的 mAP 提升 1.2%, 但在查准率方面较原网络会小幅度降低 2%。加入 CBAM 模块后, 虽召回率有所提升, 但在查准率方面损失较大, 最终 mAP 提升效果不明显。EMA、CAFm 模块在 mAP 方面也各有提升, 综合对比精准率、召回率以及模型参数量等结果后, 将 CPCA 注意力机制加入原网络。

表 2 注意力机制对比实验结果

算法	Precision /100%	Recall /100%	mAP0.5 /100%	Parameter /M
YOLOv10n	80.7	73.6	81.2	2.3
YOLOv10n+EMA	76.1	76.3	81.0	2.5
YOLOv10n+CAFm	78.3	74.8	81.5	2.6
YOLOv10n+CBAM	75.7	78.7	81.6	2.2
YOLOv10n+CPCA	78.6	77.8	82.4	2.4

模型对于裂缝、污垢的召回率提升最显著, 因 CPCA 通过跨维度交互聚焦微小特征通道 (如裂缝的边缘梯度通道、污垢的颜色差异通道), 解决了传统模型对小目标的漏检; 油渍的提升主要来自 LSKA, 其抗反光机制减少了油渍反光区域被误判为背景的情况。

2) 损失函数实验对比:

为验证不同损失函数对模型性能的影响, 本实验在保持网络其他结构不变的前提下, 分别采用 EIou、SIou、MPDIoU、Wise-MPDIoU 替代原网络的 Ciou 损失函数进行对比实验, 结果如表 3 所示。数据显示: 使用 EIou 时, 模型 mAP 较原网络下降 0.6%; SIou 和 MPDIoU 虽使 mAP 有所提升, 但增幅有限; 而 Wise-MPDIoU 的提升效果最为显著, mAP 较原网络提高 2.1%。综合各项指标对比, 最终选择 Wise-MPDIoU 作为替代 Ciou 的损失函数。

表 3 损失函数对比实验结果

算法	Precision /100%	Recall /100%	mAP0.5 /100%
YOLOv10n	80.7	73.6	81.2
YOLOv10n+EIoU	79.3	72.2	80.6
YOLOv10n+SIoU	77.4	77.5	82.4
YOLOv10n+MPDIoU	80.2	75.3	82.1
YOLOv10n+Wise-MPDIoU	81.9	76.6	83.3

Wise-MPDIoU 是一种综合性的边界框回归损失函数，其创新性地整合了多维度评估指标。该损失函数不仅考虑了预测框与真实框之间的重叠区域和非重叠区域，还同时纳入了中心点距离和宽高比差异等关键因素。在计算效率方面，Wise-MPDIoU 通过优化算法复杂度实现了高效运算。其核心机制是通过最小化预测框与真实框对角线顶点之间的距离，这种设计使得边界框回归过程更加精准高效。相比传统损失函数，Wise-MPDIoU 在保持计算简便性的同时，提供了更全面的评估维度。

3) 算法对比:

为进一步验证本文所提改进后算法的优越性及有效性，选取了一些主流算法进行对比，例如 Faster-RCNN、YOLOv5、YOLOv7、YOLOv8。在控制变量的前提下，将各网络在平均精度、精确率、召回率方面进行了对比，具体结果见表 4 所示。

表 4 多种算法对比

算法	Precision /100%	Recall /100%	mAP0.5 /100%	Parameter /M
Faster-RCNN	75.7	72.6	76.4	28.2
YOLOv5	77.8	69.7	78.6	2.5
YOLOv7	79.4	73.5	79.5	6.0
YOLOv8	80.2	74.1	80.7	3.2
YOLOv10n	80.7	73.6	81.2	2.3
本文算法	82.5	78.9	84.1	2.6

根据表 6 直观的展现出本文改进后的模型相较于 YOLOv10n 原始模型 mAP0.5 增加了 2.9%，精确率和召回率分别提升了 1.8% 和 5.3%，虽在参数量上较原模型略有提升，但因模型本身的参数量并不大使得改进后的模型在资源受限的边缘计算器的部署成为可能；与 Faster R-CNN 以及一系列 YOLO 改进模型相比，在各个指标都有较明显的提升。对于评价模型性能的综合指标 mAP0.5 来说分别提升了 7.7%、5.5%、4.6%、3.4% 和 2.9%，检测结果验证了改进后模型的有效性，符合风机叶片缺陷检测准确度的要求。改进后的模型准确率在不同场景下存在波动。对于逆光场景，因 LSKA 抑制了反光噪声导致的假阳性，改进后的模型可以更好的识别出油渍部分，提高精准度；对于密集缺陷场景，如叶片根部多处生锈，因 CPCA 增强了微小缺陷响应，

导致部分低置信度预测被保留，使假阳性略有增加，但召回率的上升主导 mAP 整体的上升。

4 结束语

为了更加准确、快速地识别出风机叶片上的裂缝、污垢等缺陷，提出了一种基于 YOLOv10n 的改进模型。通过在 SPPF 模块中嵌入大核注意力机制 LSKA，构建了一个多尺度特征增强网络，可以在复杂图像的各类信息时更好的捕捉重要信息，有效解决了叶片表面反光导致的误检漏检问题。同时，设计的通道优先注意力机制 CPCA 通过动态调整不同通道的权重，实现了对输入特征的自适应加权，有效融合多个尺度和方向的信息，增强了模型对裂缝和污垢等微小缺陷的检测精度。此外，提出的 Wise-MPDIoU 损失函数通过梯度修正机制有效抑制离群样本引起的异常梯度幅值和有害扰动，实现跨类别样本的梯度均衡，从而增强模型对未知数据域的泛化能力，并最终达到高精度的目标定位效果。通过理论分析和在无人机采集的风机叶片数据集上的实验结果表明，改进算法在 mAP@0.5 指标上达到了 84.1%，相较于基准模型提升了 2.9 个百分点，显示出了显著的性能提升。同时，与目前比较常用的多种典型模型相比，各项指标也有不小的提升。综合理论和实验结果分析表明，所提改进模型对风机叶片缺陷检测，有较好的效果，优于 YOLOv10n 模型。未来将收集更丰富的图像数据进一步扩充数据集，深入探讨分辨率低，光照条件不好下的模型识别能力，提升模型的鲁棒性和泛化性，进一步优化模型。

参考文献:

- [1] 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.
- [2] 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.
- [3] 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.
- [4] DIMITROVA M, AMINZADEH A, MEIABADI M S, et al. A survey on non-destructive smart inspection of wind turbine blades based on industry 4.0 strategy [J]. Applied Mechanics, 2022, 3 (4): 1299-1326.
- [5] CARNERO A, MARTiN C, DiAZ M. Structural health and intelligent monitoring of wind turbine blades with a motorized telescope [C] // Proceedings of the 2022 21st IEEE International Conference on Machine Learning and Applications. Piscataway: IEEE, 2022: 105-112.

(下转第 93 页)