

DOI: 10.19666/j.rlfed.202412241

基于改进 YOLOv5 的风机叶片 表面缺陷检测方法

白家宇, 沙玲, 魏丹, 雷菊阳
(上海工程技术大学机械与汽车工程学院, 上海 201620)

[摘要] 针对风机叶片表面缺陷复杂, 传统卷积神经网络涉及阈值筛选和非极大值抑制过程而增加计算的复杂性且不利于模型部署等问题。提出一种结合 RT-DETR (real-time-detection transformer) 与 YOLOv5 算法的风机叶片的缺陷检测方法。首先基于 RepVGG 和 FasterNet 对 YOLOv5 的主干神经网络进行重新设计, 降低模型计算复杂程度; 考虑到检测任务中存在小尺寸目标, 在颈部网络中的特征融合部位引入高效注意力机制 (efficient channel attention, ECA), 从而增强对输出特征的表达能; 最后采用 RT-DETR 中的 Decoder 重构原网络的检测头, 减少非极大值抑制对模型的影响。实验结果表明: 改进的 YOLO-RT 检测模型在自制风机叶片表面缺陷数据集上的平均检测精度为 87.2%, 准确率为 92.7%, 相比原 YOLOv5 模型分别提高 4.4 个百分点和 8.0 个百分点; 检测速率达到 118.3 帧/s, 优于其他检测模型。改进后的算法能有效提高检测精度和速率, 更适合应用在风机叶片表面缺陷的检测任务。

[关键词] 缺陷检测; 风机叶片; YOLOv5; 注意力机制; RT-DETR

[引用本文格式] 白家宇, 沙玲, 魏丹, 等. 基于改进 YOLOv5 的风机叶片表面缺陷检测方法[J]. 热力发电, 2025, 54(9): 95-103. BAI Jiayu, SHA Ling, WEI Dan, et al. Surface defect detection method for wind turbine blade based on improved YOLOv5[J]. Thermal Power Generation, 2025, 54(9): 95-103.

Surface defect detection method for wind turbine blade based on improved YOLOv5

BAI Jiayu, SHA Ling, WEI Dan, LEI Juyang

(School of Mechanical and Automotive Engineering, Shanghai University of Engineering Science, Shanghai 201620, China)

Abstract: In light of the intricate nature of surface defects in wind turbine blades, conventional convolutional neural networks face problems such as threshold screening and non-maximum suppression processes, which increase computational complexity and are not conducive to model deployment. A novel defect detection model that integrates real-time-detection transformer (RT-DETR) with YOLOv5 algorithm is proposed. Firstly, the backbone network of YOLOv5 is redesigned based on RepVGG and FasterNet to reduce the computational complexity of the model. Recognizing the presence of small-sized targets within the detection tasks, an efficient channel attention (ECA) mechanism is integrated into the neck network's feature fusion component, thereby augmenting the expressiveness of the output features. Finally, the detection head of original network is reconstructed with the Decoder from RT-DETR, minimizing the effect of non-maximum suppression on the model's performance. The experimental results show that, the average detection accuracy and accuracy of YOLO-RT are 87.2% and 92.7%, respectively, on a self-constructed dataset of wind turbine blade surface defects, reflecting improvements of 4.4 and 8.0 percentage points over the original YOLOv5 model. The detection rate reaches 118.3 frames per second, surpassing that of alternative detection models. The enhancements introduced in

收稿日期: 2024-12-05

基金项目: 国家自然科学基金项目 (62101314)

Supported by: National Natural Science Foundation of China (62101314)

第一作者简介: 白家宇 (1999), 男, 硕士, 主要研究方向为计算机视觉、风机叶片修复机器人, 1583730773@qq.com。

通信作者简介: 沙玲 (1970), 女, 硕士, 副教授, 主要研究方向为机器视觉、CAD/CAM 技术及应用, shaling@sues.edu.cn。

this algorithm significantly improve both detection accuracy and speed, making it highly suitable for practical applications in detecting surface defects on wind turbine blades.

Key words: defect detection; wind turbine blade; YOLOv5; attention mechanism; RT-DETR

风能是许多国家新能源体系的核心组成部分,而风力发电则是利用风能的主要方式。在风力发电中,叶片的状态良好与否直接影响着风机的性能和发电效率^[1]。叶片因承受较大载荷且长期暴露在野外环境中,受自然因素影响,易产生涂层破损、孔洞、尖端剥落、裂纹等缺陷。如果在早期进行准确的检测,并采取相应的维护措施,可延长叶片寿命,提高风力发电系统的可靠性^[2]。

传统的风机叶片表面缺陷检测方法有 2 种^[3]:

第 1 种是人工巡检来实现风机叶片表面缺陷检测,巡检人员通过望远镜或攀爬风机对叶片进行观测并记录下叶片表面缺陷的位置;第 2 种主要基于各种传感器进行检测,如振动传感器、红外光传感器、声发射传感器和应变传感器等^[4]。邹宜金等^[5]提出了一种风力发电机组叶片异常检测方法,通过分析声纹诊断故障,但未对异常类型进行细分。Rizk 等人^[6]采用高光谱成像技术识别光谱特征以检测裂纹和侵蚀,但该技术对光照和背景噪声要求较高。Tiwari 等人^[7]使用超声信号处理分析脱粘型缺陷,需要定制参数设置,从而增加了实施难度。Sarraf 等人^[8]提出基于相位的运动估计和运动放大算法的非接触式检测方法,但该方法在复杂环境中对噪声敏感,影响检测结果。传统的检测方式虽然能够实现风机叶片表面缺陷检测,但涉及的部件较多,耗费的人力和资金成本较大,对检测环境有不同要求,且风险系数高,不适于大范围推广使用^[9]。

近几年,基于深度学习的目标检测算法在缺陷检测领域具有较大的优势,如基于区域的卷积神经网络双阶段检测神经网络(convolutional neural networks, CNN)^[10]和单阶段检测神经网络(you only look once, YOLO)^[11],在风机叶片表面缺陷的检测中都取得了良好的效果,何赞泽等^[12]采用一种基于热成像技术和深度学习的风机叶片缺陷检测方法,利用双光图像数据进行缺陷提取与识别。刘启栋^[13]采用一种基于声学信号和 CNN 的叶片损伤检测算法,利用了声学信号和深度学习的结合,达到叶片损伤检测的效果。郭迎福等^[14]提出一种基于三维振动信息融合的卷积神经网络风机叶片裂纹诊断方法,对传统方法效率低、精度差的情况有所改善。Liu 等人^[15]研究提出一种基于注意力机制的轻

量级特征融合神经网络模型,通过双向特征融合网络增强 YOLOX 神经网络,采用非极大值抑制(soft non-maximum suppression, Soft-NMS)方法消除冗余检测框,实现了风机叶片表面缺陷检测。上述算法的提出和应用为风机叶片表面缺陷检测提供了新的思路,但这些模型在进行风机叶片表面缺陷检测时仍存在一定问题,如检测速度和精度达不到工业要求,且模型的参数量仍然很大,不适用于集成部署。

综上所述,本文基于 YOLOv5,提出改进的检测模型 YOLO-RT。针对模型计算复杂,参数量较多的问题,在主干网络引入全新设计的重参数化模块 C3-RP,替换主干网络中的 C3 模块^[16],在不丢失精度的同时降低模型参数量;针对微小缺陷特征不易被提取的问题,在颈部网络中引入高效注意力机制模块(efficient channel attention, ECA)^[17],加强模型对特征的提取能力;其次,结合 RT-DETR 的 Decoder^[18]机制重构 YOLOv5 的检测头,减少非极大值抑制(NMS)的影响,提升模型缺陷检测速度。最后,通过实验对所提出的 YOLO-RT 模型的性能进行验证。

1 YOLOv5 算法概述

YOLO 系列算法的核心思想是将目标检测与分类问题转化为数值回归的问题。为了实现检测任务中精度、速度和模型规模的最佳平衡,本研究选择了 YOLOv5 作为主要算法进行改进,YOLOv5 神经网络结构主要包括 3 个部分:1)主干网络(backbone),采用带有残差结构的 C3 模块对图像进行特征提取;2)颈部网络(neck),使用路径聚合网络(path aggregation network, PAN)^[19]对主干网络提取后的特征进行融合;3)检测器头(head),对输出 3 个不同尺度的特征图通过非极大值抑制(NMS)筛选目标框并使用损失函数对图像特征进行预测。

2 改进 YOLOv5 算法模型

2.1 YOLO-RT 算法

针对实时风机叶片表面缺陷检测的需求,提高缺陷检测的速度和精度,同时降低误检率,本文基于 YOLOv5 算法进行改进。首先在主干网络中利用

RepVGG (Re-parameterizing-your-convolutions-for-visual-recognition)^[20]和 FasterNet Block^[21]相结合的设计思想对 C3 模块进行改进,降低网络计算复杂程度;其次在颈部网络中的特征融合部位添加 ECA

注意力机制,从而增强对微小缺陷特征的表达能力;最后采用 RT-DETR 中的 Decoder 替换检测头,消除对 NMS 等后处理步骤的依赖,提高网络检测速率,改进后的 YOLOv5 网络结构如图 1 所示。

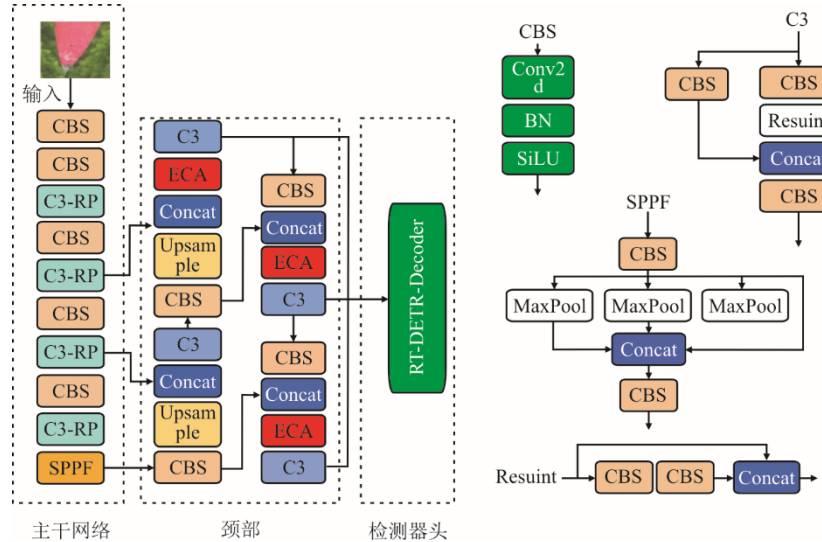


图 1 改进后的 YOLOv5 网络结构
Fig.1 Structure of the improved YOLOv5 network

2.2 结构重参数化

结构重参数化是 RepVGG 的核心思想,其目的是通过将网络结构在训练模式时的参数在推理模式进行不同的参数化,从而提升模型性能。采用 RepConv (结构重参数模块)在训练过程中为模型添加额外的分支来提升性能,之后通过等效转换将训练结构简化为原始模型的结构用于推理。RepConv 训练模式和推理模式结构如图 2 所示。在训练模式时,RepConv 通过恒等连接、3×3 卷积层和 1×1 卷积层 3 个分支来处理输入,每个分支都会

进行批量归一化 (batch normalization, BN) 操作。然后,将 3 个分支输出逐元素求和,并通过激活函数层得到最终结果。恒等连接分支仅在输入与输出通道维度相同且卷积步长为 1 时才有效。在推理模式时,将 3 个分支融合后的卷积层权重和偏置叠加,最终得到 1 个 3×3 的卷积层。由此可见,结构重参数化前的多个参数经过重参数化后只剩下 1 个 3×3 的卷积层。通过结构重参数化,不仅减少了参数数量,还提升了模型的推理速度。

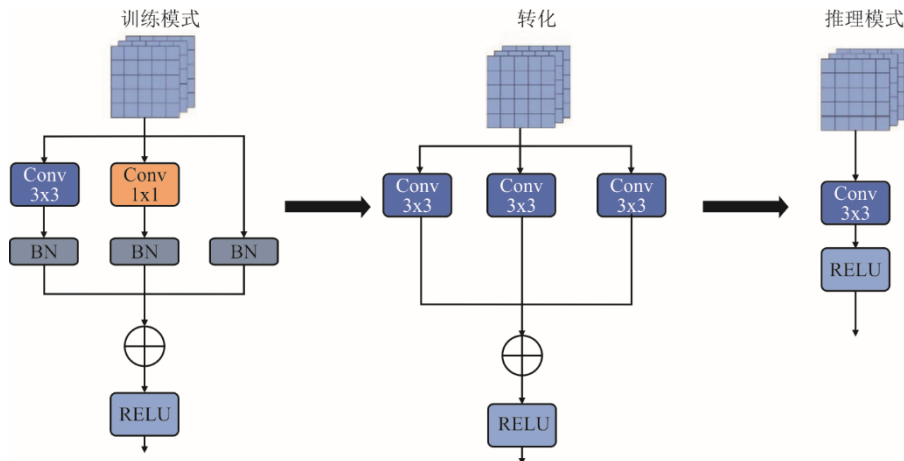


图 2 RepConv 训练模式和推理模式结构
Fig.2 Structure of the RepConv training mode and inference mode

2.3 基于部分卷积的改进

本文将 CNN 中的局部建模与 Transformer 的全局建模能力相融合，采用结构重参数化的思想对 FasterNet 中的部分卷积模块（partial convolution, PConv）进行改进，PConv 模块结构如图 3 所示。PConv 模块只需要在输入和输出通道的一部分应用常规 Conv（常规卷积）进行空间特征的提取，并保持其余通道大小不变。对于连续或规则的内存访问，将第一个或者最后一个连续的通道视为整个特征图的代表进行计算。在保持一般性的前提下则认为输入和输出特征图具有相同数量的通道。

$$S = h \cdot w \cdot k^2 \cdot c_p^2 \quad (1)$$




图 3 PConv 模块结构

Fig.3 Structure of the PConv module

当卷积操作的通道数为 $c_p=1/4$ 时，PConv 的计算量如式(1)所示，仅为常规卷积的 1/16。其内存访问量（memory access cost, MAC）如式(2)所示：

$$\eta_{MAC} = h \times w \times 2c_p + k^2 \times c_p^2 = h \times w \times 2c_p \quad (2)$$

式中： h 为通道的高； w 为通道的宽； c_p 为连续的网络通道数； k 为卷积核大小。

经过改进后的模块 C3-RP 结构如图 4 所示。




图 4 改进后的 C3-RP 结构

Fig.4 Structure of the improved C3-RP

由图 4 可见，在模型训练时，C3-RP 模块在基于 PConv 的基础上减少模型的冗余计算并通过 RepConv 为模型添加额外的分支来提高特征提取能

力，在推理时可通过结构重参数机制将原模块结构等效为单个 3×3 卷积核，将训练时的结构对应参数转换为推理时结构对应参数来简化模型并提高检测速率，并用其替换主干网络中的 C3 模块。

2.4 ECA 模块

通道注意力机制主要关注不同通道间的相互依赖性及其对网络性能的影响，通过网络在训练过程中的迭代优化，实现对各通道权重系数的动态调整，有助于提高关键特征的权重。ECA 通道注意力机制的工作原理如图 5 所示。首先，ECA 通过通道维度 C 的函数自适应确定卷积核大小 M ，并利用局部跨通道交互，减少了模型的复杂性。




图 5 ECA 结构

Fig.5 Structure of the ECA

具体如式(3)所示，在平均池化结束后，使用 1×1 卷积层，去除了全连接层，将每个通道得到的二维特征压缩为一个实数，然后分别进行卷积后与得到的子特征图进行合并，以此增强目标特征（涂层破损、孔洞、尖端剥落、裂纹）的表示，得到最终的输出特征图。

$$M = \psi(C) = \left\lceil \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rceil \quad (3)$$

式中：一维卷积核 M ，作为自适应参数，通过函数 $\psi(C)$ 计算得出； C 为通道总数； γ 和 b 是预设的超参数， γ 设置为 2， b 为向上取整的最小奇数。最后使用 Sigmoid 函数得到各个通道的权重。ECA 模块对输入特征进行的全局平均池化操作不会降低通道的维度，但有效地简化了通道注意力机制的实现，同时提升了模型的感知能力，使其在保持高效的同时合理地增强了网络性能，各图像特征热力图如图 6 所示。

2.5 检测头改进

在 YOLOv5 网络中，检测头依赖非极大值抑制（NMS）算法来筛选冗余的边界框，保留最具代表性的候选框。然而，NMS 虽然能够有效地去除重复边界框，但其存在显著的缺点：首先，NMS 的计算量较大，会在推理过程中带来速度延迟，尤其是在实时检测任务中影响较为明显；其次，NMS 需要手

动调整超参数才能实现最优性能，这增加了模型调 优的复杂性，并降低了其鲁棒性。

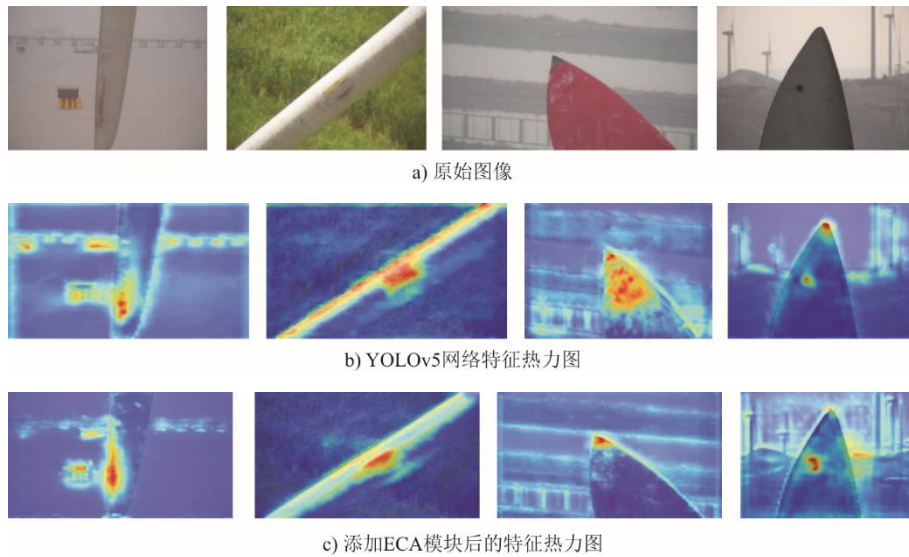


图 6 特征热力图
Fig.6 Feature heat map

为克服上述局限性,将 YOLOv5 的检测头替换为 RT-DETR 检测头。RT-DETR 通过引入 Transformer 解码器,采用端到端的检测方法,无需使用 NMS 后处理。其核心在于利用自注意力机制直接捕捉图像中的目标特征关系,实现对边界框的一对一预测,从根本上解决了 NMS 带来的延迟问题。RT-DETR 检测头如图 7 所示,由多尺度可变形注意力机制、多头自注意机制以及前馈神经网络 (FFN) 组成。

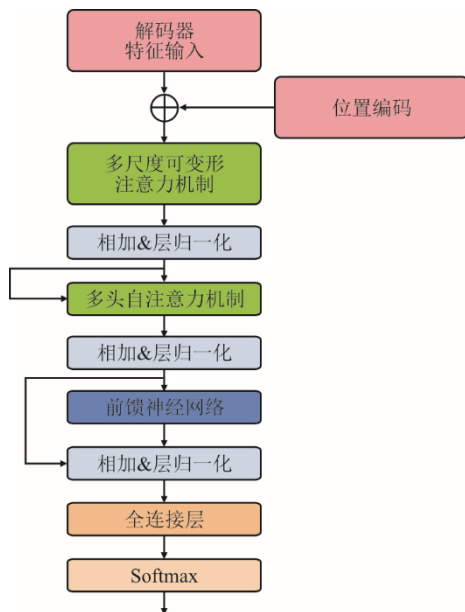


图 7 RT-DETR 检测头
Fig.7 The RT-DETR decoder

其中,多尺度可变形注意力机制聚合多尺度特

征图,增强了模型对不同尺度目标的检测能力,无需依赖传统的特征金字塔网络 (FPN);多头自注意机制则通过关系建模,精确定位并识别图像中的目标;前馈神经网络则负责生成最终的检测结果。通过这些组件的结合,RT-DETR 实现了在不依赖 NMS 的情况下可提高检测精度和推理速度的目标。

3 实验设计与分析

3.1 评价指标

为验证改进后模型的性能,本文采用平均精度均值 (mean average precision, δ_{MAP})、召回率 (recall, R)、平均精度 (average precision, δ_{AP})、检测准确率 (precision, P) 以及检测帧率 (frames per second, δ_{FPS}) 作为判断指标。

$$\delta_{MAP} = \frac{\sum_{i=1}^n \delta_{AP}(i)}{n} \tag{4}$$

$$P = \frac{TP}{TP+FP} \tag{5}$$

$$R = \frac{TP}{TP+FN} \tag{6}$$

式中:FP (false positive) 代表模型错误地将负样本预测为正样本的次数;FN (false negative) 代表模型错误地将正样本预测为负样本的次数;TP (true positive) 代表被模型正确预测分类的正样本数; P 代表在所有被模型预测为正样本的样本中,实际为正样本的比例,准确率越高,表示模型的误检率低;

R 代表模型成功预测到的正样本所占的比例, 通常通过 $P-R$ 曲线, 来更全面地评估模型的性能。曲线下方的面积越大, 说明模型的总体表现优秀。

3.2 数据集介绍

数据集来源于上海某风场采集的风机叶片图像数据。数据集涵盖 1 204 张 2 048×1 024 像素的常见缺陷样本图像, 其中包括涂层破损 (TC)、尖端剥落 (JD)、孔洞 (KD) 和裂纹 (LW) 4 种常见缺陷类型, 如图 8 所示。为提高模型的鲁棒性, 降低模型对图像的敏感度, 防止结果过拟合, 采用了数据增强技术来处理图片。本文采用了旋转、添加高斯噪声、Cutout、翻转、改变亮度等方法来扩充数据集, 扩充后的数据集共计 7 433 张图片, 使用 Labellmg 工具进行标注后依照 8:2 的比例划分了训练集和验证集, 同时又选择了同尺寸的另外 957 张风机叶片表面缺陷图片作为测试集, 共计 8 390 张图片。




图 8 常见风机叶片表面缺陷
Fig.8 Surface defects of common wind turbine blades

3.3 实验参数及结果

本文所有模型的实验环境见表 1。

表 1 实验参数设计
Tab.1 Experimental parameter settings

| 配置名称 | 版本/参数 |
|--------|------------------------|
| 操作系统 | ubuntu20.04 |
| CPU | Intel Xeon Gold 5218 |
| GPU | NVIDIA TITAN RTX(24G) |
| 内存 | 46G |
| Python | 3.8 |
| 深度学习框架 | PyTorch 2.2.0&Cuda12.1 |

进行训练超参数设置, 训练轮次 100 代, 采用 Adam 优化器, 每批次处理的图像数量为 16, 数据加载时的工作线程为 8, 初始学习率为 0.000 1, 除

特别说明外, 其他训练超参数均采用默认值, 改进后模型的 $P-R$ 曲线如图 9 所示。




图 9 YOLO-RT 检测的 $P-R$ 曲线
Fig.9 The $P-R$ curves detected by YOLO-RT

由图 9 可得, 4 类常见缺陷的 $P-R$ 曲线覆盖的面积较大, 平均精度值也较高, 即改进后的模型检测性能出色。其中, LW、KD、TC、JD 的平均精度分别为 0.746、0.912、0.914 和 0.917。由数据表明, 改进后的模型在不同类型缺陷的检测中具有卓越的表现。

3.4 对比实验

为了进一步分析本文改进的模型 YOLO-RT 对提高叶片表面缺陷识别效果性能, 将其与其他主流一阶段检测模型进行对比^[22-25]。所有模型均在相同的数据集上进行训练, 得到最优模型之后, 在测试集上进行测试, 各个目标检测算法模型对叶片表面缺陷识别的各项性能指标见表 2, 其中 δ_{FPS} 为推理速度。

由表 2 可知, 主流的 YOLO 系列模型 (YOLOv5、YOLOv6、YOLOv8、YOLOv9)^[22] 和 RT-DETR 模型在风机叶片表面缺陷检测中均表现出良好的识别效果, 但相较于改进后的 YOLO-RT 模型, 各模型的平均精度均值和推理速度存在明显差异。YOLO-RT 在平均检测精度和推理速度方面具有显著优势。相较于 YOLOv5 和 YOLOv6, YOLO-RT 平均检测精度分别提高了 4.4 百分点、4.2 百分点; 相较于 YOLOv8 和 YOLOv9, YOLO-RT 平均检测精度分别降低 1.0 百分点和 0.8 百分点; 但 YOLO-RT 的推理速度也远高于其他模型, 分别比 YOLOv5、YOLOv6、YOLOv8 和 YOLOv9 提升了 15.2%、12.9%、11.9% 和 8.1%。说明改进后的 YOLO-RT 模型在检测速度和精度之间取得了更好

的平衡。与 RT-DETR 模型相比，尽管 RT-DETR 在检测精度上略高，平均检测精度达到 91.8%，但其推理速度明显较慢，仅为 54.2 帧/s，而 YOLO-RT

的推理速度达到了 118.3 帧/s，几乎是 RT-DETR 的 2 倍，表明在需要实时检测的工业应用中，YOLO-RT 模型具备更强的实用性和适应性。

表 2 不同模型的检测性能对比
Tab.2 Comparison of detection performance between different models

| 算法模型 | $\delta_{AP}/\%$ | | | | P/% | $\delta_{MAP}/\%$ | R/% | $\delta_{FPS}/(\text{帧}\cdot\text{s}^{-1})$ |
|---------|------------------|------|------|------|------|-------------------|------|---|
| | JD | KD | TC | LW | | | | |
| YOLOv5 | 84.0 | 79.5 | 73.8 | 93.8 | 84.7 | 82.8 | 78.7 | 102.7 |
| YOLOv6 | 64.2 | 81.0 | 94.6 | 92.4 | 86.7 | 83.0 | 72.1 | 104.8 |
| YOLOv8 | 80.7 | 80.5 | 98.8 | 92.8 | 89.1 | 88.2 | 82.6 | 105.7 |
| YOLOv9 | 79.1 | 79.3 | 97.6 | 96.1 | 89.9 | 88.0 | 83.7 | 109.4 |
| RT-DETR | 84.8 | 89.7 | 99.0 | 93.6 | 93.7 | 91.8 | 87.5 | 54.2 |
| YOLO-RT | 91.7 | 91.2 | 91.4 | 74.6 | 92.7 | 87.2 | 83.3 | 118.3 |

3.5 消融实验

表 3 为消融实验结果。在表 3 中，“√”表示在 YOLOv5 模型基础上引入了对应的改进方案，“—”表示未引入该改进方案。实验 1 作为基线模型，未进行任何改进，实验 1 显示出相对较好的检测效果，准确率为 84.7%，平均检测精度为 82.8%，但其参数量和计算量分别为 7.93 M 和 16.0 G，推理时间为 20.5 ms，存在额外的计算开销。

实验 2 引入 C3-RP 模块，参数量和计算量显著下降至 5.29 M 和 9.9 G，说明该模块在简化模型结构方面发挥了作用，由于仅引入该模块，模型的检测精度有所下降，准确率为 83.8%，平均检测精度为 82.7%，表明 C3-RP 虽然优化了模型复杂度，但单独使用时对检测精度贡献有限。

实验 3 中，进一步引入 ECA 模块后，模型的检测性能有了显著提升，准确率达到 87.0%，平均精度均值提高至 83.1%，参数量和计算量略微增加至 5.34 M 和 10.1 G，表明 ECA 模块对模型的特征提取能力进行了有效增强，弥补了单独引入 C3-RP 模块带来的精度下降。

实验 4 中，将 RT-DETR 检测头引入后，准确率和平均精度均值分别提升至 91.5% 和 86.5%，在

参数量仅为 5.28 M、计算量为 10.3 G 的情况下，性能显著提升，证明了 RT-DETR 检测头在提高检测精度方面的优势。

实验 5 中，通过综合引入 C3-RP、ECA 和 RT-DETR 检测头，模型性能达到最优，准确率为 92.7%，平均精度均值为 87.2%，参数量和计算量分别为 5.51 M 和 10.7 G，模型参数量减少了 30.5%，计算量减少了 33.1%，推理时间降至 15.6 ms。该实验结果表明，不同模块的组合能够有效提升模型的检测性能，尤其是 RT-DETR 检测头的引入对模型的精度和鲁棒性贡献最大，而 C3-RP 和 ECA 模块的引入则在降低计算复杂度的同时进一步优化了模型的特征提取能力。这一组合实现了检测精度和模型复杂度的最佳平衡，充分证明了改进模型在风机叶片表面缺陷检测任务中的有效性和实用性。图 10 对比了 YOLOv5 和 YOLO-RT 的检测结果。由图 10 可以看出，YOLO-RT 能够准确地识别 4 种缺陷样本，得到精准的检测框，而 YOLOv5 在检测时存在冗余的检测框，并有误检的情况。消融实验结果显示，通过逐步引入不同改进模块，模型的参数量和计算量显著减少，同时检测精度和速度均得到提升，证明了本文所提改进策略对模型的检测性能有很大提升。

表 3 消融实验结果
Tab.3 The ablation experiments results

| | 方法 | | | 结果 | | | | |
|------|-------|-----|-----------------|------|-------------------|-------|-------|---------|
| | C3-RP | ECA | RT-DETR Decoder | P/% | $\delta_{MAP}/\%$ | 参数量/M | 计算量/G | 推理时间/ms |
| 实验 1 | — | — | — | 84.7 | 82.8 | 7.93 | 16.0 | 20.5 |
| 实验 2 | √ | — | — | 83.8 | 82.7 | 5.29 | 9.9 | 19.6 |
| 实验 3 | √ | √ | — | 87.0 | 83.1 | 5.34 | 10.1 | 15.7 |
| 实验 4 | √ | — | √ | 91.5 | 86.5 | 5.28 | 10.3 | 15.5 |
| 实验 5 | √ | √ | √ | 92.7 | 87.2 | 5.51 | 10.7 | 15.6 |




图 10 YOLO-RT 和 YOLOv5 检测结果对比

Fig.10 Comparison of detection results between YOLO-RT and YOLOv5

4 结 论

本文针对风机叶片表面缺陷检测任务, 提出基于改进的 YOLOv5 的检测模型 YOLO-RT。首先利用 RepVGG 和 FasterNet 相结合的设计思想对主干网络中 C3 的模块进行改进, 以降低网络计算复杂程度; 其次为了提高模型对微小缺陷的特征提取能力, 在颈部网络中的特征融合处添加 ECA 注意力机制; 最后消除 NMS 对模型检测速率的影响, 采用 RT-DETR 中的 Decoder 替换检测头, 使模型的检测速率得到进一步提升。

实验结果表明, 本文提出的改进的 YOLO-RT 模型, 准确率相较于原始模型 YOLOv5 提高了 8.0 个百分点, 高达 92.7%, 平均精度值也提高了 4.4 个百分点, 为 87.2%, 模型参数量显著减少了 30.5%, 同时计算量也减少了 33.1%, 检测速率得到大幅度提升, 达到了 118.3 帧/s。相比 4 种主流的 YOLO 检测模型, 其检测精度和速度都有明显的提升。

未来研究将进一步优化模型结构, 在保持轻量化的同时采集更全面的数据集, 包括叶尖开裂、叶根断裂等其他可能出现的缺陷类型, 以增强模型的泛化能力, 更好地满足风电场智能化运维的多样化需求。

[参 考 文 献]

- [1] N'DIAYE L M, PHILLIPS A, AS M M, et al. Residual and wavelet based neural network for the fault detection of wind turbine blades[C]//2022 Intermountain Engineering, Technology and Computing (IETC). IEEE, 2022: 1-5.
- [2] 许淳瑶, 葛立超, 冯红翠, 等. 风力发电现状及叶片组成与回收利用综述[J]. 热力发电, 2022, 51(9): 29-41.
XU Chunyao, GE Lichao, FENG Hongcui, et al. Review on status of wind power generation and composition and recycling of wind turbine blades[J]. Thermal Power Generation, 2022, 51(9): 29-41.
- [3] 王道累, 肖佳威, 刘易腾, 等. 风电机组叶片损伤检测技术研究与进展[J]. 中国电机工程学报, 2023, 43(12): 4614-4631.
WANG Daolei, XIAO Jiawei, LIU Yiteng, et al. Research and development of wind turbine blade damage detection technology[J]. Proceedings of the CSEE, 2023, 43(12): 4614-4631.
- [4] SONG X, XING Z, JIA Y, et al. Review on the damage and fault diagnosis of wind turbine blades in the germination stage[J]. Energies, 2022, 15(20): 7492.
- [5] 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 Yijin, LIAN Yinghua, HUANG Xinyu, et al. High generalization in anomaly detection of wind turbine generator based on voiceprint[J]. Journal of University of Electronic Science and Technology of China, 2021, 50(5): 795-800.
- [6] RIZK P, YOUNES R, ILINCA A, et al. Wind turbine blade defect detection using hyperspectral imaging[J]. Remote Sensing Applications: Society and Environment, 2021, 22: 100522.
- [7] TIWARI K A, RAISUTIS R. Post-processing of ultrasonic signals for the analysis of defects in wind turbine blade using guided waves[J]. The Journal of Strain Analysis for Engineering Design, 2018, 53(8): 546-555.
- [8] SARRAFI A, MAO Z, NIEZRECKI C, et al. Vibration-based damage detection in wind turbine blades using phase-based motion estimation and motion magnification[J]. Journal of Sound & Vibration, 2018, 421: 300-318.
- [9] MEMARI M, SHAKYA P, SHEKARAMIZ M, et al. Review on the advancements in wind turbine blade inspection: Integrating drone and deep learning technologies for enhanced defect detection[J]. IEEE Access, 2024, 12: 33236-33282.
- [10] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Computer Science, 2014, 1409: 1556.
- [11] HUSSAIN M. YOLO-v1 to YOLO-v8, the rise of YOLO and its complementary nature toward digital manufacturing and industrial defect detection[J]. Machines, 2023, 11(7): 677.
- [12] 何赞泽, 李响, 王洪金, 等. 基于可见光和热成像的风机叶片全周期无损检测综述[J]. 机械工程学报, 2023, 59(6): 32-45.
HE Yunze, LI Xiang, WANG Hongjin, et al. A review: full-cycle nondestructive testing based on visible light

- and thermography of wind turbine blade[J]. *Journal of Mechanical Engineering*, 2023, 59(6): 32-45.
- [13] 刘启栋. 基于卷积神经网络的风机叶片损伤检测[J]. *热力发电*, 2023, 52(3): 88-93.
- LIU Qidong. Wind turbine blade damage detection based on convolutional neural network[J]. *Thermal Power Generation*, 2023, 52(3): 88-93.
- [14] 郭迎福, 全伟铭, 王文韞, 等. 基于三维振动信息融合的卷积神经网络风力机叶片裂纹诊断方法[J]. *光学学报*, 2020, 40(22): 140-148.
- GUO Yingfu, QUAN Weiming, WANG Wenyun, et al. Crack diagnosis method of wind turbine blade based on convolution neural network with 3D vibration information fusion[J]. *Acta Optica Sinica*, 2020, 40(22): 140-148.
- [15] LIU Y, ZHENG Y, SHAO Z, et al. Defect detection of the surface of wind turbine blades combining attention mechanism[J]. *Advanced Engineering Informatics*, 2024, 59: 102292.
- [16] PARK H, YOO Y, SEO G, et al. C3: concentrated-comprehensive convolution and its application to semantic segmentation[J/OL]. (2019-07-28) [2024-12-05]. <http://arxiv.org/pdf/1812.04920>.
- [17] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. IEEE, 2018: 7132-7141.
- [18] ZHAO Y, LV W, XU S, et al. Detsr beat YOLOs on real-time object detection[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. IEEE, 2024: 16965-16974.
- [19] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. IEEE, 2017: 2117-2125.
- [20] DING X, ZHANG X, MA N, et al. RepVGG: making VGG-style convNets great again[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. IEEE, 2021: 13733-13742.
- [21] CHEN J, KAO S, HE H, et al. Run, don't walk: chasing higher FLOPS for faster neural networks[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. IEEE, 2023: 12021-12031.
- [22] 邱天衡, 王玲, 王鹏, 等. 基于改进 YOLOv5 的目标检测算法研究[J]. *计算机工程与应用*, 2022, 58(13): 63-73.
- QIU Tianheng, WANG Ling, WANG Peng, et al. Research on object detection algorithm based on improved YOLOv5[J]. *Computer Engineering and Applications*, 2022, 58(13): 63-73.
- [23] 游越, 伊力哈木·亚尔买买提, 吐松江·卡日. 基于 YOLOv6 的输电线路电力部件识别及缺陷检测算法研究[J]. *高压电器*, 2024, 60(5): 194-205.
- YOU Yue, YILIHAMU·Yaermaimaiti, TUSONGJIANG Kari. Research on power component identification of transmission line and defect detection algorithm based on YOLOv6[J]. *High Voltage Apparatus*, 2024, 60(5): 194-205.
- [24] 袁博雅, 李尧, 叶青. 面向输电线路绝缘子的 GER-YOLO 缺陷检测算法[J]. *激光与光电子学进展*, 2024, 61(22): 149-159.
- YUAN Boya, LI Yao, YE Qing. GER-YOLO fault-detection algorithm for transmission-line insulators[J]. *Laser & Optoelectronics Progress*, 2024, 61(22): 149-159.
- [25] ZOU J, WANG H. Steel surface defect detection method based on improved YOLOv9 network[J]. *IEEE Access*, 2024, 12: 124160-124170.

(责任编辑 杜亚勤)