

DOI: 10.13382/j.jemi.B2307068

基于轻量级卷积网络的风力发电机表面缺陷检测研究*

杨宇龙¹ 张银胜^{1,2} 段修贤² 陈 昕² 吉 茹¹ 单慧琳^{1,2}

(1. 南京信息工程大学电子与信息工程学院 南京 210044; 2. 无锡学院电子信息工程学院 无锡 214105)

摘要:风电机组的发电效率和使用寿命与其表面的完好度相关。本研究针对传统风力发电机表面缺陷检测方式出现的检测结果不够精准,检测用时较长的问题,设计了一种风力发电机表面缺陷检测模型。首先,在模型中融合了轻量级卷积技术,有效地增强了通道间信息交互的能力,通过更丰富的特征信息提高小尺寸缺陷的检测效果;其次,在主干网络引入了视觉注意力网络模块,丰富了上下文的信息,提升了卷积神经网络的特征提取的能力;然后,在颈部网络中引入协调注意力机制,通过空间方向捕捉缺陷的位置信息;最后,将边框回归的损失函数修改为 WIoU,从而制定出合适的梯度增益分配策略。实验结果表明,改进后的检测模型相较于原模型检测精确度提高 4.14%,显著提升了细小缺陷的检测能力;同时,改进后的模型的参数量降低了 2.29 M,参数量则是降低了 6.2 G,检测速度提升显著,满足模型实时检测的需求。

关键词: 风力发电机; C_GSConv; WIoU; 注意力机制

中图分类号: TP391.41; TM315 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Research on surface defect detection of wind turbine based on lightweight convolutional network

Yang Yulong¹ Zhang Yinsheng^{1,2} Duan Xiuxian² Chen Xin² Ji Ru¹ Shan Huilin^{1,2}

(1. School of Electronic and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China; 2. School of Electronic and Information Engineering, Wuxi University, Wuxi 214105, China)

Abstract: The power generation efficiency and service life of wind turbines are related to their surface integrity. This study aims to address the issue of inaccurate detection results and long detection time in traditional surface defect detection methods for wind turbines. A surface defect detection model for wind turbines is designed. Firstly, lightweight convolution technology is integrated into the model, effectively enhancing the ability of information exchange between channels and improving the detection effect of small-sized defects through richer feature information. Secondly, the visual attention network module has been introduced into the backbone network, enriching the contextual information and improving the feature extraction ability of convolutional neural networks. Then, a coordinated attention mechanism is introduced into the neck network to capture the location information of defects through spatial orientation. Finally, modify the loss function of bounding box regression to WIoU to develop an appropriate gradient gain allocation strategy. The experimental results show that the improved detection model improves the detection accuracy by 4.14% compared to the original model, significantly enhancing the detection ability of small defects. At the same time, the parameter count of the improved model was reduced by 2.29 M, while the parameter count was reduced by 6.2 G. The detection speed was significantly improved, meeting the real-time detection requirements of the model.

Keywords: wind turbines; C_GSConv; WIoU; mechanism of attention

0 引言

为积极贯彻落实绿色发展的方针,并把握住第 4 次工业革命带来的工业转型的新机会,风力发电因其清洁无污染等优势成为了取代化石能源的首选^[1]。大力开发利用风能对改善能源结构、保护生态环境、保障国家经济可持续发展具有积极的作用^[2]。近年来我国风电行业蓬勃发展,风力发电装机总量也逐年攀升。风机表面由于长期暴露于复杂的环境中,容易产生各种类型的缺陷,若这些缺陷得不到及时有效的处理,可能会进一步恶化,进而给风电场带来巨额的经济损失^[3]。传统风电场技术人员通常依赖目测来判断损伤程度。一旦发现明显缺陷,就意味着风机损伤严重,修复成本高。在风机长达 20 年的运行周期内,减少风机关键部件缺陷的出现频率被认为是改善上述情况的有效途径。

现阶段国内外风力发电机表面缺陷检测方法主要分为红外热成像、超声波技术等无损检测^[4]、基于无人机平台的可见光缺陷成像等方式。何赟泽等^[5]提出一种基于无人机速度信息的风机表面红外图像拼接方法。该方法利用 U-net 网络预测获得叶片掩膜图像,从而去除冗余的背景信息,使图像拼接处过渡平滑,提升检测效率。Moghadam 等^[6]研究材料塑性发生在反向循环塑性区使温度升高,说明温度对裂纹应力强度因子有很大影响,热耗散和材料的热膨胀系统能够引起热应力的产生。郑浩等^[7]通过建立方形永磁体和跑道型线圈的电磁超声换能器,再通过电磁超声检测得到应力云图及波形图,最后对比风机叶片波形分析得到叶片的缺陷情况。但总体来说红外、超声等检测方法尚处于实验室研究阶段,主要适用于小面积缺陷检测,分辨细节能力较差,不适用于野外复杂环境中实时检测。

近年来,深度学习与工业检测领域密切结合,基于无人机平台的可见光缺陷成像检测具有检测速度快,检测成本低等优势,其中主要分为 Two-Stage 和 One-Stage 两种结构。Two-Stage 结构首先生成目标候选区域,再对目标区域进行目标分类和细化,其中代表的算法有 R-CNN^[8]、Mask-RCNN^[9]、Faster-RCNN^[10]。赵文清等^[11]在 Faster-RCNN 主干网络特征提取阶段引入挤压和激励网络(squeeze-and-excitation networks, SENet),减少了无关特征通道。实验结果显示平均精度均值(mean average precision, mAP)比原 Faster-RCNN 网络提高了约 10%。李学军等^[12]基于 SENet 与 Faster-RCNN 融合了 GSConv 卷积设计了多尺度特征融合网络,并且更新了锚选框尺寸,提高了模型对缺陷的定位和识别能力。Liu 等^[13]将残差网络(residual network, ResNet)中普通卷积修改为 16 组分组卷积,通过 16 组 1×1 Conv 实现通道数叠加,将

网络参数量降为普通卷积的 1/16,提升了检测速度。另一类则是 One-Stage 结构,该类算法则是直接从输入图像中预测目标的边界框,不需要生成候选区域,代表算法有 YOLO^[14-18](you only look once)和 SSD^[19](single shot multiBox detector)等。刘闯等^[20]提出重参数化(spatial pyramid pooling, SPP)对 YOLOv5 模型进行改进,加快模型的推理速度,再利用通道修剪(ResRep)进行通道剪枝,减少模型空间占用,相较于 YOLOv5 模型推理速度大幅度提升。李尚平等^[21]采用锚框自由的方法简化了 YOLOv5 的参数,采取解耦检测器解决 YOLOv5s 检测中分类与回归任务冲突的问题。严蓬辉等^[22]通过引入 GhostNetv2 模块卷积方式对骨干网络进行轻量化改进,同时引入全维动态卷积,其网络参数量较原模型下降了 23%,同时检测平均精度能达到 90% 以上。由于风机表面一些细小缺陷与背景特征高度相似,导致卷积神经网络的特征提取能力稍显不足,甚至出现了部分小目标丢失的情况。

但当缺陷检测装置应用于野外时,首先强风、强紫外线等复杂环境会给图像的采集、图像中缺陷目标的捕捉造成干扰;其次风机表面缺陷数据集中具有多种缺陷,大多数图像中缺陷所占的比例通常很小,像素较低,多种缺陷大小形状各异;以上因素都会给缺陷检测工作的开展带来较大的难度。在复杂环境下,上述算法往往难以对风机表面缺陷特征进行有效的提取,网络模型检测精确度、速率尚有不足。为此,提出了一种融合轻量化卷积技术,结合 Transformer 结构,优化损失函数的网络模型,显著提升了与背景相似的缺陷检测精确度,完成复杂环境中有关风机表面缺陷的检测任务。

1 改进网络模型

YOLOv5s_TGW 网络模型如图 1 所示。其中 YOLOv5 在 YOLO 系列算法中又做了进一步改进,并且不断更新中。YOLOv5 模型结构主要为 5 个版本,其主要区别在特定的网络位置上特征提取模块和卷积核的数量。由于缺陷检测对模型的实时性和轻量化要求比较高,因此本研究基于 YOLOv5s 对风机表面缺陷检测模型进行改进。

改进后的 YOLOv5s_TGW 模型结构主要由输入端、主干网络(Backbone)、颈部网络(Neck)、和头部网络(Head)构成。结合上述风机表面缺陷检测的难题和实际场景的需要,在 YOLOv5s 网络模型上进行以下改进:1)在网络中增加了轻量级卷积技术 C_GSConv^[23];2)在主干网络中引入 Transformer^[24]结构,增强主干网络对全局特征的提取能力,通过更丰富的特征信息提高小尺寸缺陷的检测效果;3)引入协调注意力机制(coordinate




图 1 YOLOv5s_TGW 网络模型结构

Fig. 1 YOLOv5s_TGW network model structure diagram

attention, CA);减少无关信息对于模型的干扰,提升模型的检测精度;4)优化的边框回归损失函数 $WIoU^{[25]}$,减小边框损失误差,提高对于缺陷的定位能力和识别能力。

1.1 改进轻量级卷积技术

因风机表面缺陷形状、大小以及颜色各异,同一图片经常出现多种尺度缺陷,导致检测过程中出现误检、漏检的现象。C_GSConv 模块是由 GSConv 模块与卷积神经网络构成。GSConv 是由标准 Conv、深度可分离卷积 (depthwise separable convolution, DSC) 和 Shuffle 3 部分卷积组合,如图 2 所示。GSConv 卷积特征提取能力与传统卷积相仿,但是计算量仅为传统卷积的 1/2 左右,更符合轻量化设计理念。输入特征图经过标准 Conv 降维,再经过 DSC 卷积提取特征,合并双分支 DSC 通道,通过 Shuffle 混合卷积将输入特征图升维,再通过通道混洗的方式重新组合,将标准卷积生成的信息渗透到 DSC 的输出中,实现通道间信息的交互,进而加快模型的推理时间。

虽然 GSConv 最大程度上保留了通道间的信息传递,但网络中多次采取该卷积方式,导致模型参数量直线上升,网络运行速度稍显不足。C_GSConv 模块中采用 1×1 Conv 进行图像特征图降维,降低了模型的参数量,并采用并联 1×1 Conv 的方法,提升了 GSConv 模块的特征提取能力,且不需要再进行通道变换。通过串联两个 GSConv 模块,连接不同尺度的特征图,形成更长的特征向量,增加了模型的多样性。跨级部分用于增加网络深度和非线性能力,同时降低了模型复杂度并提高了精度。




图 2 GSConv 网络结构

Fig. 2 GSConv network structure diagram

总体而言,本文设计的 C_GSConv 模块冗余信息少,保证了目标特征信息的充分提取,达到了网络轻量化的目的,网络结构如图 3 所示。

1.2 主干网络改进

在 YOLOv5s 中,采用 CSPNet 来提取图像的深度信息,但由于在风机缺陷检测任务中,风机缺陷与其周围背景特征极其近似,CSPNet 无法有效得出图像的全局特征;因此本文在主干网络中将 CSPNet 替换为 Transformer 模块,丰富了上下文信息、弥补了局部信息的不足。

Transformer 网络可以分为两大核心模块,分别为多头注意力层 (multi-head attention) 和前馈神经网络 (multilayer perceptron, MLP)。其中 MLP 由两个线性层和一个隐藏层组成,使用了残差模块,实现网络在训练过程中对特征值的拟合。Dropout 操作使网络在训练过程中神经元部分失活,以缓解过拟合问题;最后进行 Layer-norm 操作对每层特征值进行归一化处理,实现层标准




图 3 C_GSConv 网络结构

Fig. 3 C_GSConv network structure diagram

化。计算表达式如式(1)所示。

$$Attention(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right) \mathbf{V} \quad (1)$$

式中: $\mathbf{Q}$ 表示查询向量, $\mathbf{K}$ 表示键向量, $\mathbf{V}$ 表示值向量, 这些向量都属于输入特征的一部分; d_k 则是输入特征的维度。Transformer 首先通过键向量进行转置; 然后通过查询向量和键向量的转置进行矩阵乘积操作, 通过该方式得到的新向量, 可以保存向量间的特征信息; 最后再除以根号下的输入特征维度, 归一化处理后再将矩阵相乘, 得到最终的加权矩阵, 同时有效地避免因为网络中激活函数造成的梯度损失。MLP 网络有效提升了 Transformer 对全局特征的提取能力, 并且抑制了通道中的无关信息, 再通过多头注意力机制丰富了特征子空间的多样性, 不仅关注当前像素点, 还兼顾上下文其他像素点的特征, Transformer 网络结构如图 4 所示。




图 4 Transformer 网络结构

Fig. 4 Transformer network structure diagram

Transformer 不仅提升了算法从不同位置捕获信息的能力, 还通过自注意力机制挖掘图像的潜在特征信息。通过在 YOLOv5s_TGW 模型中多次使用 Transformer 模块, 可以预防训练过程不稳定情况的发生, 增加主干网络对图像深浅特征的全局提取能力。

1.3 注意力机制改进

在对风机缺陷进行检测时, 天气、光线反射、背景噪声等干扰常常给检测带来极大影响。为了减少环境因素干扰, 本文添加了 CA 注意力模块, 不仅能全方位衡量每个通道的信息, 还能通过空间方向捕捉缺陷的位置信息。

CA 注意力机制通过聚合特征的编码过程以及并行网络处理, 将两个方向的特征信息相结合, 再通过卷积、分离等方法, 在提取空间信息的同时提取通道信息, 在通道和空间的关注更为高效。在风机缺陷检测任务中, CA 注意力机制能够将纵横向的位置信息编码到通道注意力中, 并将无关干扰信息剔除, 使得网络模型更好地关注多尺度类型的缺陷目标, 如图 5 所示。




图 5 CA 注意力机制网络结构

Fig. 5 CA attention mechanism network structure diagram

1.4 损失函数改进

YOLOv5s_TGW 模型使用的 WIoU 损失函数, 在 IoU 损失函数的基础上结合了距离注意力机制, 得到了具有 2 层注意力机制的 WIoU, IoU 损失函数如式(2)所示, WIoU 损失函数如式(3)所示。

$$L_{IoU} = 1 - IoU = 1 - \frac{W_i H_i}{wh + w_{gt} h_{gt} - W_i H_i} \quad (2)$$
$$R_{WIoU} = e^{-\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*}}$$

$$L_{WIoU} = R_{WIoU} L_{IoU} \quad (3)$$

其中, L_{IoU} 为 IoU 损失函数, L_{WIoU} 为 WIoU 函数, R_{WIoU} 为 WIoU 的惩罚项, 式中 x 和 y 是锚框左上角的坐标, x_{gt} 和 y_{gt} 是目标框左上角的坐标, W_g 和 H_g 表示最小边界框的宽和高; 同时, 为了消除 R_{WIoU} 阻碍收敛的影响, 将 W_g 和 H_g 从计算图中分离 (上标 * 表示进行此操作)。

2 实验结果分析

2.1 数据采集与处理

本研究训练使用的操作系统为 Windows 10 64 位。实验所配置的 GPU 型号为 Nvidia GeForce RTX3090, 显存为 24 GB, 深度学习框架为 Pytorch。实验设定的整个训练过程为 300 个 epoch, batch-size 设为 16, 优化器为 SGD, 学习率设为 0.01。本研究使用余弦退火算法 (cosine annealing) 动态调整学习率, 平滑学习率的衰减。

2.2 评估标准

本研究针对研究中的缺陷检测任务, 采用平均精度 (average precision, AP)、平均精度均值 (mean average precision, mAP)、准确率 (Precision)、召回率 (Recall) 作为评估算法性能的指标。其中 T_p 指的是样本被正确划分为阳性样本, F_p 则是样本被错误地划分为阳性样本, F_N 代表样本被错误地划分为阴性样本。准确率 (P) 是衡量精确性的度量, 召回率 (R) 是覆盖面的度量, 通过计算不同召回率下最高的精确率可绘制出 $P-R$ 曲线, 曲线面积即为 AP 值。AP 用于衡量某一类精度, mAP 用以衡量识别精度, 由所有类别的 AP 值求均值得到。各指标计算公式如式 (4) 所示。

$$P = \frac{T_p}{T_p + F_p} \quad R = \frac{T_p}{T_p + F_N}$$

$$P_{AP} = \int_0^1 P(R) dR \quad P_{mAP} = \frac{\sum_{i=1}^N AP_i}{N} \quad (4)$$

本研究还用模型参数量 (Params)、计算量 (GFLOPs)、帧速用来反映模型的处理速度, 其中帧速表示模型每秒处理的帧数, 如式 (5) 所示。

$$FPS = FCount / T \quad (5)$$

本研究使用的数据集由 VOC2007 网站提供的公开数据集为基础, 结合无人机拍摄多角度拍摄风机塔架、发动机舱、叶片、风向标等结构组成风机表面缺陷数据集, 图片尺寸为 640×640 , 将获取到 6 876 张风机图片通过 Labelimg 软件进行图像中的缺陷标注工作, 每个标签文件中包含标签类别、预测框坐标等信息, 再按照 8 : 1 : 1 的比例将上述图片随机划分成训练集、验证集、测试集。本研究提取常见 5 类风机缺陷本作为研究对象, 包括了脏污 (dirt)、孔洞 (void)、缺漆 (crack)、缝隙 (erosion)、铁

锈 (rust)。

本模型采用带色彩恢复的多尺度增强算法, 使得缺陷特征在图像中更为突出, 弥补局部区域对比度增强而导致颜色失真的缺陷, 对部分像素有所欠缺的图像进行了相应地恢复。并且采用水平翻转和缩放, 对图像增加或降低 20%~25% 的亮度来进行调整, 以增加数据集的鲁棒性, 进而适应各种光线环境下的输入, 如图 6 所示。




图 6 图像转换效果对比

Fig. 6 Image conversion effect comparison diagram

由图 7 所知, 在前 50 轮迭代中, YOLOv5s_TGW 模型检测 mAP 持续上升, 在迭代超过 100 轮后, 检测 mAP 达到了约 80% 左右, 随后, 模型的 mAP 趋于稳定, 且在此时表现出最佳的置信度, 总共共计 300 轮训练。




图 7 改进后模型与原模型 mAP 曲线对比

Fig. 7 The mAP curve comparison diagram of the improved model and the original model

YOLOv5s_TGW 模型收敛效果显著, 20 轮后达到收敛的稳定区间, 边界框损失稳定在 0.04 以下, 150 轮后稳定在 0.03 左右, 对于边界框回归精度的提升优于原模

型,边界框损失如图 8 所示。




图 8 改进后模型与原模型边界框损失曲线对比
Fig. 8 Comparison chart of boundary box loss curves between the improved model and the original model

2.3 消融实验

YOLOv5s_TGW 模型在 YOLOv5s 基础上对其中的主干网络、注意力机制和卷积方法进行了相应地改进。设

计消融实验的目的是评估 YOLOv5s_TGW 中不同模块对于模型总体性能的影响情况。消融实验如表 1 所示,从实验 1 和实验 2 对比可以发现,模型的检测精度提升了 1.96%,帧率提升了 9.74 fps。这是因为 Transformer 有助于模型捕获特征层中的信息,从而提升了模型的特征提取能力。在不同模块的组合中可以发现,模型的检测能力并不单一的线性提升。由实验 1 和实验 3 对比可知,当模型搭载了 Transformer 和 C_GSConv 时,检测精度达到了 85.63%,帧率为 73.04 fps,相较于 YOLOv5s 模型,检测精度和帧速都有大幅提升。然而对比实验 4 和实验 5,其中实验 4 中检测精度为 84.83%,帧速为 68.12 fps,实验 5 的检测精度为 84.91%,帧速为 73.53 fps,这表明 CA 注意力机制明显提升了模型的特征提取能力,但也会增加模型的参数量。

通过不同策略的组合,得到模型优化效果也各有不同。YOLOv5_TGW 模型不仅在检测精度上取得了不错的优化程度,还在检测速度上取得了优越的优化效果,取得了模型检测精度与速度的平衡。

表 1 消融实验结果对比
Table 1 Comparison of ablation experimental results

实验序号	Transformer	C_GSConv	CA	P/%	R/%	mAP/%	帧率/fps
1				80.3	74.9	82.67	55.63
2	✓			82.4	76.6	84.63	65.37
3	✓	✓		83.9	76.8	85.87	73.04
4	✓		✓	83.8	76.4	84.83	68.12
5		✓	✓	84.0	75.6	84.91	73.53
6	✓	✓	✓	84.5	79.6	86.81	75.51

注:✓代表采用了此策略

2.4 对比实验

从表 2 可知,在相同的图像增强数据集上,将 YOLOv5s 中普通卷积替换为 GSConv 模块或 C_GSConv 模块进行实验。相较于原模型,YOLOv5s_GSConv 在检测精度、速度和参数量上均有不同程度的优化。这主要得益于 GSConv 中双分支 DSC 卷积有更强的特征提取能力,能快速的实现通道间的信息交互,达到提升检测精度的效果。YOLOv5s_C_GSConv 模型在其基础上,与传统 CNN 相结合,并通过两层 GSConv 串联降低了模型的复杂度,提升了通道传递信息的效率,检测精度达到 85.64%,检测帧速为 60.72 fps,模型参数量为 8.15 M,相较于 GSConv 虽然精度提升相仿,但是检测速度提升明显,更适应于野外实时检测需求。

表 2 轻量级卷积网络对比表

模型	Params/M	mAP/%	帧率/fps
YOLOv5s	14.36	82.67	55.63
YOLOv5s_GSConv	14.05	85.50	57.38
YOLOv5s_C_GSConv	13.15	85.64	60.72

由表 3 可知,在相同的图像增强数据集基础上,相较于其余两种常见的注意力机制,CA 注意力机制检测精度最高达到 84.79%,帧率达到 56.09 fps。虽然 ECA 注意力机制对于检测精度提升稍显不足,CBAM 空间与通道注意力机制对于检测精度和速度都有所提升,但结合本实验复杂应用场景的需求,选择了速度提升不高,检测精度提升最明显的 CA 注意力机制。

表 3 注意力机制对比表
Table 3 Attention mechanism comparison table

模型	Params/M	mAP/%	帧率/fps
YOLOv5s	14.36	82.67	55.63
YOLOv5s_CBAM	15.65	83.69	57.63
YOLOv5s_ECA	15.49	82.35	56.47
YOLOv5s_CA	15.24	84.79	56.09

在相同的图像增强数据集基础上,将本研究中采用的 WIoU 损失函数与原有 EIoU 损失函数进行对比实验。实验结果如表 4 所示。使用 WIoU 损失函数 mAP 为

84.62%,参数量为 9.49 M,帧率为 55.15 fps。WIoU 在牺牲少许检测速度的前提下,将检测精度提升了 1.95%。如图 9 为 EIoU 与 WiIoU 损失函数对比训练图。由图 9 可知 WiIoU 损失函数的训练精度明显高于 EIoU,并且在 40 轮后就开始收敛,有更快的收敛效果。WiIoU 更有效地消除了干扰项对于实际检测的影响,更精确的预测了目标框与真实框的重叠度,显著提升了检测精度。

表 4 损失函数对比表

Table 4 Loss function comparison table			
模型	mAP/%	Params/M	帧率/fps
EIoU	82.67	14.36	55.63
WiIoU	84.62	14.49	55.15




图 9 两种损失函数 mAP 曲线对比

Fig. 9 Comparison of two loss function mAP curves

如表 5 所示,在相同的图像增强数据集基础上,相比于 SSD、Faster-RCNN、YOLOv4、YOLOv5s 等模型 YOLOv5s_TGW 算法的检测精度明显有所提升。SSD 模型因其低级特征卷积层较少,模型对于特征提取能力稍显不足,检测精度不高。Faster-RCNN 作为双阶段检测模型的代表,需要从特征区域中使用基础的卷积,再传递信息到后续的全连接层,先生成预选框,再进行目标检测,计算量较大,检测耗时长,无法满足实时目标检测的需求。YOLOv5s_TGW 模型的检测精度达到 86.81%,相较于 YOLOv5s 模型提升了 4.14%,召回率达到几种模型中最高值 79.6%,模型参数量最小为 12.07 M,相较于 YOLOv5s 模型降低了 2.29 M,检测速度则为最快为 75.51 fps。综上所述,本文提出的 YOLOv5s_TGW 模型达到了协同最优的检测效果。

表 5 常见模型对比

Table 5 Common model comparison table					
模型	P/%	R/%	mAP/%	Params/M	帧率/FPS
SSD	70.7	71.9	75.48	99.79	58.22
Faster-RCNN	79.8	76.4	82.83	124.28	5.29
YOLOv4	72.9	66.8	74.64	240.67	40.16
YOLOv5s	80.3	74.9	82.67	14.36	55.63
YOLOv5s_TGW	84.5	79.6	86.81	12.07	75.51

从图 10 中对比发现,左图为 YOLOv5s 模型检测效果图,右图为 YOLOv5s_TGW 模型检测效果图,虽然 YOLOv5s 与 YOLOv5s_TGW 模型都成功检测出了风机表面出现的脏污、缺漆、铁锈等缺陷,但二者模型检测置信度明显不同,YOLOv5s 模型明显在检测缺漆缺陷时,由于缺漆缺陷与风机表面自带金属色颜色相似,在昏暗环境的影响下,原模型检测能力略显不足,缺漆缺陷长期得不到处理容易转变为铁锈缺陷,带来更大的经济损失。YOLOv5s_TGW 相比较而言模型的鲁棒性更好,检测精度能满足实际检测的需求,更适用于野外环境的实时检测场景。




图 10 改进后模型与原模型检测效果对比

Fig. 10 The comparison diagram of the detection effect between the improved model and the original model

2.5 针对缺漆类缺陷的对比实验

表 6 缺漆缺陷对比表

Table 6 Comparison table of paint defects						
模型	crack ;mAP/%	P/%	R/%	Params/M	GFLOPs/G	帧率/fps
YOLOv5s	81.89	79.4	74.5	14.36	16.7	55.63
YOLOv5s_TGW	86.15	84.1	80.1	12.07	10.5	75.51

在相同的图像增强数据集上,针对 YOLOv5s 模型与 YOLOv5s_TGW 模型做出了对比实验,YOLOv5s_TGW 模型的检测 mAP 达到了 86.15%,相较于原模型提升了 4.26%,召回率为 80.1%,相较于原模型提升了 4.7%,


从模型参数量和计算量的对比可以看出,YOLOv5s_TGW 模型的参数量为 12.07 M,计算量为 10.5 G,相较于 YOLOv5s 模型不同程度下降。YOLOv5s_TGW 模型帧率为 75.51 fps,相较于原模型提升了约 20 fps。这使得改进后的 YOLOv5s 模型在保障了检测精度的同时,又兼顾了检测实时性,实现了在嵌入式设备上轻量化部署的目的。

从图 11 对比可知,左侧 YOLOv5s 原模型明显检测精度不足,检测置信度不高。从第 2 行对比图发现,原模型针对缺漆缺陷出现了定位不够精准的问题,误将灰尘覆盖的区域检测成了缺漆类缺陷,显然不能满足实际缺陷检测的要求。由第 3 行对比图可知,改进后的模型锚框定位更为精准,能准确识别出原模型漏检的孔洞类缺陷。孔洞类缺陷是风机运行初期最容易产生的缺陷,提升对细小目标的检测精度能有效防止缺陷的过度演化,这也体现了模型出色的适用性。改进后模型在同一检测场景出现多种类型缺陷时,相比于原模型检测置信度更高,更能满足实际工业检测需求。

3 结 论

本研究针对复杂环境中的风机表面缺陷检测难题,提出了一种结合轻量级卷积技术与自注意力网络的 YOLOv5s 的检测算法。首先针对实际检测过程中遇到的各种恶劣天气条件,对实验数据集做图像增强等处理;其次在网络结构方面,通过将 Transformer 自注意力网络引入主干特征提取网络,提升了模型捕捉特征信息的能力;改进了 GSConv 模块在颈部网络之间的连接,进一步保证了模型在轻量化网络的基础上具备了通道间信息交互的能力;通过 CA 注意力机制,使得模型在应对多种类型目标特征时能得到更有效的表达;在损失函数方面,本研究引入 WIoU 损失函数,提升了边界框的定位能力和对细小缺陷的检测精度。YOLOv5s_TGW 模型在检测精度、速度等多项性能指标相较于原模型都有明显的优势,在风电行业具有一定的研究意义和经济价值。

本研究提出的一种基于轻量级卷积网络的缺陷检测模型一定程度上提高了检测性能。然而,模型在检测细小缺陷时会受到图像角度的影响,从而导致检测效果稍显不足。另外,由于实验图像主要通过无人机设备采集,各种天气原因可能导致图像中的缺陷特征不够清晰。这也表明模型仍有较大的提升空间,有待后续研究的开展。



(a) YOLOv5s (b) YOLOv5s_TGW

图 11 缺漆类缺陷检测效果对比

Fig. 11 Paint defect detection effect comparison diagram

参考文献

[1] REN W, DENG R, ZHOU X H, et al. Compressive behavior of the steel—concrete composite adapter for wind turbine hybrid towers[J]. Engineering Structures, 2023, 280: 115703.

- [2] BERHANU M T, ASSEFA N A, KEDIR F A. Artificial intelligence-based controller for rotor current of doubly fed induction generator in wind turbine system[J]. *Wind Engineering*, 2023, 47(5): 995-1015.
- [3] LAMAN H, KHIKMAT A, GULNAR S. Analysis of operating benefits of modern wind turbines[J]. *Advances in Science and Technology*, 2024: 7139203-208.
- [4] CASTELLANO-ALDAVE C, CARLOSENA A, IRIARTE X, et al. Ultra-low frequency multidirectional harvester for wind turbines [J]. *Applied Energy*, 2023, 334: 120715.
- [5] 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 Y Z, LI X, WANG H J, 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.
- [6] MOGHADAM F K, DESCH N. Life cycle assessment of various PMSG-based drivetrain concepts for 15 MW offshore wind turbines applications[J]. *Energies*, 2023, 16(3): 1499.
- [7] 郑浩, 周丽婷, 王湘明, 等. 电磁超声检测风机叶片缺陷的有限元仿真研究[J]. *电子测量技术*, 2021, 44(23): 24-29.
- ZHENG H, ZHOU L T, WANG X M, et al. Finite element simulation study on electromagnetic ultrasonic detection of fan blade defects [J]. *Electronic Measurement Technology*, 2021, 44(23): 24-29.
- [8] SHUANG F, HUANG H, LI Y, et al. AFE-RCNN: Adaptive feature enhancement RCNN for 3D object detection[J]. *Remote Sensing*, 2022, 14(5): 1176.
- [9] ABOLVAFAEI M, GANJEFAR S. Maximum power extraction from fractional order doubly fed induction generator based wind turbines using homotopy singular perturbation method [J]. *International Journal of Electrical Power and Energy Systems*, 2020, 119: 105889.
- [10] CAI D, GUAN Z, BAMISILE O, et al. Multi-objective tracking for smart substation onsite surveillance based on YOLO Approach and AKCF[J]. *Energy Reports*, 2023, 9: 1429-1438.
- [11] 赵文清, 贾梦颖, 翟永杰, 等. 基于改进 YOLOv5s 的输电线路螺栓缺销检测方法[J]. *华北电力大学学报 (自然科学版)*, 2024, 51(3): 92-100.
- ZHAO W Q, JIA M Y, ZHAI Y J, et al. Detection method for pin-losing-bolts in transmission lines based on improved YOLOv5s [J]. *Journal of North China Electric Power University (Natural Science Edition)*, 2024, 51(3): 92-100.
- [12] 李学军, 权林霏, 刘冬梅, 等. 基于 Faster-RCNN 改进的交通标志检测算法[J/OL]. *吉林大学学报(工学版)*: 1-10 [2023-10-08]. <https://doi.org/10.13229/j.cnki.jdxbgxb.20230553>.
- LI X J, QUAN L F, LIU D M, et al. Improved Faster-RCNN algorithm for traffic sign detection [J/OL]. *Journal of Jilin University (Engineering and Technology Edition)*: 1-10 [2023-10-08]. <https://doi.org/10.13229/j.cnki.jdxbgxb.20230553>.
- [13] LIU J, JIN J D, ZEHNG Q X. Night vehicle detection method based on improving Mask RCNN [J]. *Journal of Transport Information and Safety*, 2023, 41(2): 59-66.
- [14] WU H, HU Y, WANG W, et al. Ship fire detection based on an improved YOLO algorithm with a lightweight convolutional neural network model[J]. *Sensors*, 2022, 22(19): 7420.
- [15] SUN L, XU Y, RAO Z, et al. YOLO algorithm for long-term tracking and detection of escherichia coli at different depths of microchannels based on microsphere positioning assistance[J]. *Sensors*, 2022, 22(19): 7454.
- [16] ZHANG Y, GUO Z, WU J, et al. Real-time vehicle detection based on improved YOLO v5 [J]. *Sustainability*, 2022, 14(19): 12274.
- [17] HUO J, SHI B, ZHANG Y. An object detection method for the work of an unmanned sweeper in a noisy environment on an improved YOLO algorithm [J]. *Signal, Image and Video Processing*, 2023, 17(8): 4219-4227.
- [18] LIU Y, YANG F, HU P. Parallel FPN algorithm based on cascade R-CNN for object detection from UAV aerial images[J]. *Laser Optoelectron. Prog*, 2020, 57(20): 302-309.
- [19] XU L, DONG S, WEI H, et al. Defect signal intelligent recognition of weld radiographs based on YOLO V5-IMPROVEMENT [J]. *Journal of Manufacturing Processes*, 2023, 99: 373-381.
- [20] 刘闯, 李喆, 李曜丞, 等. 基于重参数化 YOLOv5 的输电线路缺陷边缘智能检测方法[J]. *高电压技术*, 2024, 50(5): 1954-1966.
- LIN M, LI ZH, L Y CH, et al. A method for transmission line defect edge intelligent inspection based on re-parameterized YOLOv5 [J]. *High Voltage Engineering*, 2024, 50(5): 1954-1966.
- [21] 李尚平, 卞俊析, 李凯华, 等. 基于改进 YOLO v5s 的复

杂环境下蔗梢分叉点识别与定位[J]. 农业机械学报, 2023, 54(11): 247-258.

LI SH P, BIAN J X, L K H, et al. Identification and localization of sugarcane tip bifurcation points in complex environments based on improved YOLOv5s [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 247-258.

[22] 严蓬辉,陈绪兵,彭伊丽,等. 基于改进 YOLOv5s 的激光软钎焊焊点缺陷检测算法[J]. 激光与光电子学进展, 2024, 61(8): 219-228.

YAN P H, CHEN X B, PENG Y L, et al. Algorithm for detecting laser soldering point defect based on Improved YOLOv5s[J]. Laser & Optoelectronics Progress, 2024, 61(8): 219-228.

[23] YANG Y, CHEN L, ZHANG J, et al. UGC-YOLO: Underwater environment object detection based on YOLO with a global context block [J]. Journal of Ocean University of China, 2023, 22(3): 665-674.

[24] NGUYEN H C, NGUYEN T H, SCHERER R, et al. YOLO series for human hand action detection and classification from egocentric videos[J]. Sensors, 2023, 23(6): 3255.

[25] ZHU X, WANG R, SHI W, et al. Automatic detection and classification of dead nematode-infested pine wood in stages based on YOLOv4 and GoogLeNet[J]. Forests,

2023, 14(3): 601.

作者简介



杨宇龙, 2021 年于皖西学院电子信息工程学院获得学士学位, 现为南京信息工程大学硕士研究生, 主要研究方向为深度学习、图像处理。

E-mail: 978019629@qq.com

Yang Yulong received his B. Sc. degree from College of Electronic and Information Engineering, West Anhui University in 2021. Now he is a M. Sc. candidate in Nanjing University of Information Science and Technology. His main research interests include deep learning and image processing.



张银胜 (通信作者), 1997 年于东北师范大学获得学士学位, 2005 年于东南大学获得硕士学位, 现为南京信息工程大学和无锡学院副教授, 主要研究方向为深度学习、无线通信网络。

E-mail: yorkzhang@nuist.edu.cn

Zhang Yinsheng (Corresponding author) received his B. Sc. degree from Northeast Normal University in 1997, M. Sc. degree from Southeast University in 2005. Now he is an associate professor in Nanjing University of Information Science & Technology and Wuxi University. His main research interests include deep learning and wireless communication network.