

DOI:10.19651/j.cnki.emt.2210128

融合多尺度特征与注意力机制的 风机桨叶缺陷检测方法^{*}

全卫国 仪小龙 李冰 杨珂

(华北电力大学自动化系 保定 071003)

摘要: 针对传统风机桨叶检测算法在复杂环境存在误检及检测精度低的问题,提出一种融合多尺度特征与注意力机制的风机桨叶缺陷检测方法。首先使用改进的骨干网络 L-ResNet50 进行特征提取,保留更多有效信息;然后对不同尺度特征层嵌入注意力机制模块,增强重点语义信息;最后对提取出的深层特征与浅层特征进行多尺度特征融合,进一步提高模型准确率。通过对无人机航拍采集的风机桨叶图像进行缺陷检测实验,结果表明,所提方法在复杂环境下的风机桨叶缺陷检测中平均准确率较原 Faster R-CNN 模型提高 8.2%。

关键词: 风机桨叶;注意力机制;多尺度特征融合;特征金字塔;缺陷检测

中图分类号: TP391; TP389 文献标识码: A 国家标准学科分类代码: 520.2040

Wind turbine paddle defect detection method incorporating multi-scale features and attention mechanism

Tong Weiguo Yi Xiaolong Li Bing Yang Ke

(Department of Automation, North China Electric Power University, Baoding 071003, China)

Abstract: To address the problems of false detection and low detection accuracy of traditional wind turbine paddle detection algorithms in complex environments, a wind turbine paddle defect detection method integrating multi-scale features and attention mechanism is proposed. Firstly, the improved backbone network L-ResNet50 is used for feature extraction to retain more effective information. Then the attention mechanism module is embedded for different scale feature layers to enhance the focused semantic information. Finally, the extracted deep features and shallow features are fused with multi-scale features to further improve the model accuracy. Through the defect detection experiments on the wind turbine paddle images captured by UAV aerial photography, the results show that the average accuracy of the proposed method in the detection of wind turbine paddle defects in complex environments is improved by 8.2% compared with the original Faster R-CNN model.

Keywords: wind turbine blades; attention mechanism; multi-scale feature fusion; feature pyramid; defect detection

0 引言

风能是一种清洁、低碳的可再生能源,世界各国都十分重视风力发电技术,风电机组装机容量不断提升。随着双碳目标的提出,未来风电将在我国构建的清洁能源体系中发挥重要作用^[1]。近年来风力发电发展迅猛,桨叶是能量转换的重要部件,不仅将风能转变为机械能,还是风机的主要承载部件,对整个风机安全运行起着关键作用。然而,风电机组所处环境恶劣、气候条件复杂多变,长期运行导致风机桨叶表面产生胶衣脱落、裂纹、侵蚀、雷击等严重缺陷,影

响风机使用寿命及发电量,严重时会出现风机倒塔等事故^[2]。

传统桨叶巡检多采用人工完成,存在着效率低、成本高、主观性强以及危险性高等问题^[3]。检测的实时性、高效性和准确性已经成为风机桨叶缺陷识别的基本要求,各国学者针对以上问题进行了深入研究。Bo 等^[4]采用基于盲解卷积分离算法的声发射信号分析方法实现了风机桨叶表面裂纹损伤的识别。李小伟^[5]利用光纤光栅传感器进行了玻璃纤维复合材料的静态检测实验,并提出了基于小波包能量谱算法的损伤识别方法。Wang 等^[6]提出一种电磁超

收稿日期:2022-05-26

*基金项目:国家自然科学基金联合基金项目重点支持项目(U21A20486)资助

声检测技术,利用有限元仿真软件 COMSOL 建立电磁超声换能器,并对各类叶片模型进行电磁超声检测得到应力云图及波形图,最后将缺陷叶片波形与无损叶片波形对比分析出叶片缺陷情况。

近年来,基于深度卷积神经网络的目标识别取得良好的效果。康爽等^[7]提出一种基于温度阈值特征的方法对风机桨叶进行缺陷识别,通过分析和处理温度数据的实验方法证明了该方法在高空风机桨叶缺陷检测的有效性。Yu 等^[8]提出一种基于缺陷语义特征的风电叶片识别方法,通过在标记的叶片图像上进行训练,选择训练好的 DCNN 的前 n 层作为传递特征提取器来提取缺陷语义特征。辛彦等^[9]提出一种基于 EfficientDet 算法的风机桨叶缺陷检测方法,通过对 EfficientDet 算法中的主干特征提取网络进行改进,减少向下采样次数并调整有效特征层从而增强主干特征提取网络对小尺寸缺陷的检测能力。朱佳伟等^[10]通过对 SSD 算法进行改进来检测风机桨叶中所存在的缺陷故障。最后通过实验证明了所提出的方法相较于传统检测方法检测精度和效率都有明显提升。曲忠侃等^[11]提出了基于 Faster R-CNN 的胶衣脱落缺陷图像多点检测系统设计,利用 DCNv2、Giou 两种改进方法进行优化,并验证了所提算法可显著提高胶衣脱落缺陷检测的精度。

上述研究方法虽取得了一定的成果,然而,当目标处于复杂背景时,上述算法难以实现目标特征的有效提取,且对多尺度目标特征融合能力不佳,难以全面地进行风机桨叶的缺陷识别。为了提高复杂环境下风机桨叶缺陷识别速度及定位精度,本文以 Faster R-CNN 为基础模型,提出了融合多尺度特征与注意力机制的风机桨叶缺陷检测方法,主要创新包括以下 3 个方面:

1) 改进残差块结构,使用 LeakyReLU^[12] 函数替换 ReLU 函数得到 L-ResNet50 特征提取网络,能够保留负半轴的有效信息,并调整卷积层、BN 层及 LeakyReLU 激活层的次序,优化模型训练效果;

2) 提出了多尺度特征融合模块,将特征提取网络的输出进行多尺度特征融合,获取丰富图像特征;

3) 通过在多尺度特征融合阶段嵌入注意力机制模块,关注局部重点区域,提高了小尺度缺陷目标的检测精度。

1 相关技术和理论

Faster R-CNN 对目标进行分类和回归的过程:首先将输入图像长宽等比例缩放,然后使用 VGG16 作为骨干网络进行目标的特征提取并得到特征图^[13];其次将提取到的特征图输入区域建议网络(region proposal network, RPN)中,然后通过归一化指数函数(Softmax)分类分支进行正负样本采样,利用边框回归分支获得精确的建议框并且使用 NMS^[14]删除重叠的建议框,将输出得分较高的建议框作为感兴趣区域(ROI);再其次将区域建议网络提取的建议框按固定比例映射到特征图中,然后通过 ROI Pooling 固定到特定尺寸并送到全连接层;最后通过 Softmax 分类和边框回归得到最终的输出结果。

卷积神经网络通过不断卷积池化方式进行特征提取,然而在逐层抽取特征的过程中会丢失一些较小的目标信息,导致检测的精度有所下降。为了解决上述问题并获取表达能力更强的特征图,He 等^[15]提出了特征金字塔网络(feature pyramid networks, FPN),该网络可以将的高层特征以自上而下的方式与低层特征进行加法合并操作,得到包含丰富语义信息的特征图,使得神经网络可以更好地适应与不同尺寸的目标。

2 融合多尺度特征与注意力机制的风机桨叶缺陷检测模型

设计融合多尺度特征与注意力机制的风机桨叶缺陷检测模型如图 1 所示,主要骨干特征提取网络(Backbone)、区域建议网络(regional recommendation network, RPN)和检测子网络由部分组成。

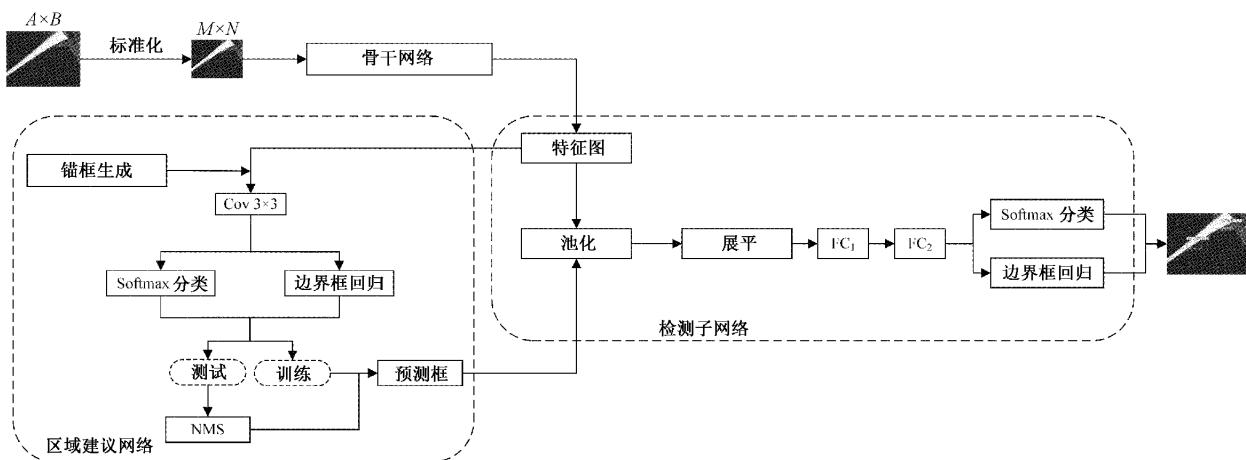


图 1 风机桨叶缺陷检测网络

2.1 骨干网络

传统特征提取网络 VGG16 随着层数的加深能够提取的信息越多,然而网络层数的加深会导致梯度爆炸和梯度消失的问题。ResNet 网络在 CNN 基础上引入残差模块 (Residual-block),使得网络随深度增加而不退化,通过 shortcut 进行输入输出的加叠,这种简单的加法并不会给网络增加额外的参数和计算量,同时却大大增强了模型的训练速度、提升了训练效果^[16]。ReLU 激活函数虽然在网络梯度反向传播过程中收敛速度较快,但在输入为负数时,其输出都将为 0,即陷入“dying ReLU”。本文引入一种 LeakyReLU 激活函数,其表达式为:

$$y_i = \begin{cases} x_i, & x_i \geq 0 \\ \frac{x_i}{a_i}, & x_i < 0 \end{cases} \quad (1)$$

式中: a_i 为 $(1, +\infty)$ 区间内的固定参数,另外在 $x > 0$ 时,不存在梯度消失的情况,而在 $x < 0$ 时,神经元也不会出现“死亡”的情况。

为了防止模型退化问题,更好地优化模型,结合 He 对残差模块的改进,调整 BN 层、激活层及卷积层的次序,并扩大了 shortcut 恒等映射的范围。图 2(a)为改进前网络结构,图 2(b)为改进后网络结构。该结构将激活项分为预激活和后激活,在预激活中使用 BN 能够提高模型的正则化,从而减少过拟合。由于扩大恒等映射范围,优化过程更为简单,使改进后的网络训练效果更佳。本文采用 LeakyReLU 激活函数代替 ResNet50 残差结构中的 ReLU 激活函数,按照 ResNet50 的网络搭建方式提出了 L-ResNet50 网络结构^[17]。

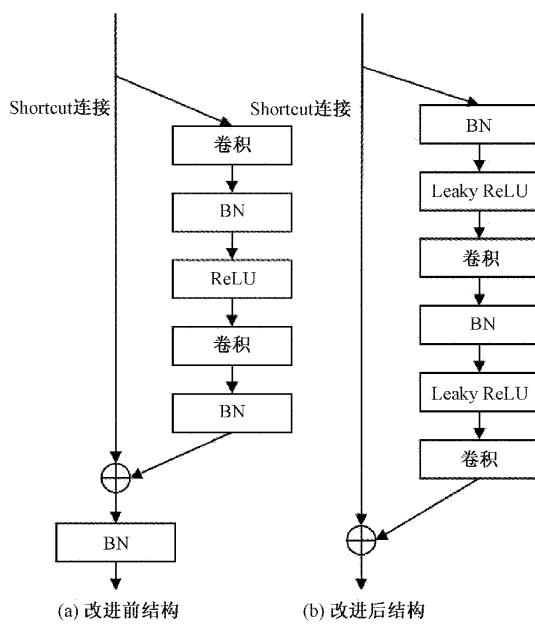


图 2 残差模块结构

2.2 注意力机制模块

为了使网络能够关注风机桨叶缺陷的关键信息而忽

略无关的背景信息,本文引入 CA(coordinate attention)注意力机制模块^[18]。CA 模块由坐标信息嵌入(coordinate information gmbbedding)和坐标注意力生成(coordinate attention generation)模块顺序组成,其网络结构如图 3 所示。

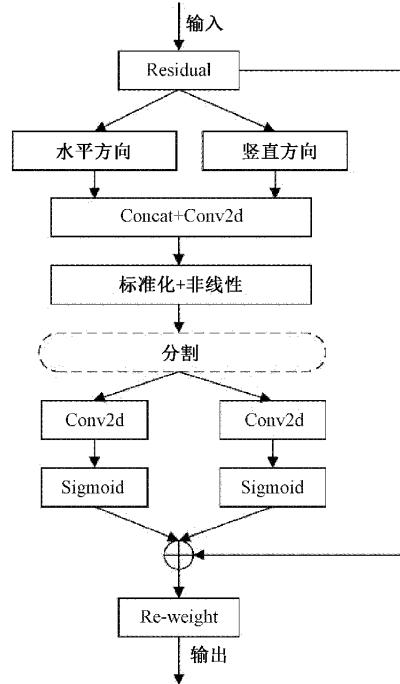


图 3 CA 注意力机制模块结构图

CA 模块可以看做一个增强网络特征表达能力的计算单元,该单元可以将任何中间张量作为输入并输出一个增强了表达能力的相同尺寸的输出。对于坐标信息嵌入模块,为了使注意力机制模块更好地捕获空间上远程交互的精确位置信息,网络采用两个一维特征编码操作代替全局池化。将输入通过尺寸分别为 $(H, 1)$ 和 $(1, W)$ 的池化核,并沿水平和竖直方向对每个通道进行编码,得到高度为 h 宽度为 w 的第 c 个通道的输出,其表达式分别为:

$$z_c^w(h) = \frac{1}{H} \sum_{0 \leq j < H} x_c(j, w) \quad (2)$$

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i < W} x_c(h, i) \quad (3)$$

将上述两种转换分别沿水平和垂直方向进行特征聚合,并产生一对感知方向的特征图。

对于坐标注意力生成模块,第 1 步级联之前模块生成的两个特征图;第 2 步使用一个共享的 1×1 卷积进行变换 F_1 ,并生成一个能在水平和垂直方向都能编码空间信息的中间特征图 ($f \in R^{C/r \times (H \times W)}$),其中 r 表示下采样比例,其表达式如下:

$$f = \delta(F_1([z^h, z^w])) \quad (4)$$

式中: δ 为非线性激活函数。

第 3 步将 f 沿着空间维度分割切分成两个单独的张

量 $f^h \in R^{C/r \times H}$ 和 $f^w \in R^{C/r \times W}$, 再使用两个 1×1 卷积 F_h 和 F_w 将特征图 f^h 和 f^w 变换到与输入相同的通道数, 并得到输出结果。其表达式如下:

$$g^h = \sigma(F_h(f^h)) \quad (5)$$

$$g^w = \sigma(F_w(f^w)) \quad (6)$$

式中: σ 为 Sigmoid 激活函数, 第 4 步对 g^h, g^w 进行拓展并得到最终输出结果。其表达式如下:

$$y_c(i, j) = x_c(i, j) \times g^h_c(i) \times g^w_c(j) \quad (7)$$

2.3 嵌入注意力机制的多尺度特征融合模块

为了进行特征融合的同时并降低背景信息的影响, 本文引入双向特征融合^[19]进行特征提取, 提出一种多尺度特征融合模块, 可以更好的将浅层与深层特征进行融合^[20], 进而得到语义信息更加丰富的特征图。其特征融合过程如图 4 所示。

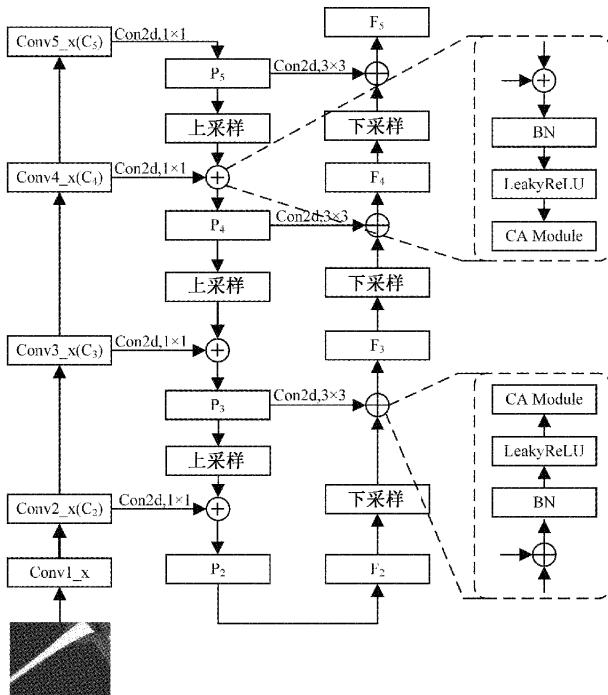


图 4 特征融合过程结构图

本网络结构主要包含以下 3 个步骤:

1) 输入图片经过最左侧线性网络结构进行特征提取, 通过卷积下采样操作得到 4 组不同尺度的特征图 $[C_2, C_3, C_4, C_5]$;

2) 自上向下上特征融合阶段, 此阶段采用双线性插值的方法进行 2 倍上采样操作, 得到与下采样尺度相同的特征图, 将步骤 1) 中下采样特征图进行 1×1 卷积操作并与上采样的结果进行融合, 对融合后的结果使用 3×3 的卷积层消除混叠效应, 通过 CA 模块对消除混叠效应的特征图进行通道更新得到新特征图 $[P_2, P_3, P_4, P_5]$;

3) 自底向上特征融合阶段, 经过此阶段会得到 $[F_2, F_3, F_4, F_5]$ 共 4 个特征图, 采用步长为 2 的 3×3 卷积对

F_i 进行降采样, 将降采样的浅层特征 F_i 与深层特征 $P_{(i+1)}$ 相加融合得到下一层特征 $F_{(i+1)}$, 接着对融合后的结果使用 3×3 卷积和 CA 模块得到特征图 $F_{(i+1)}$, 而 F_2 是直接复制 P_2 的值。为了防止在进行双向融合过程中出现梯度爆炸问题, 在自上向下和自底向上融合过程中, 添加 BN 层, 然后经过 LeakyReLU 激活函数和 CA 注意力机制送入检测网络。

3 实验测试与结果分析

本节将按照数据集制作、模型训练、评价指标及实验结果与分析 4 个方面来阐述。改进的算法流程如图 5 所示。

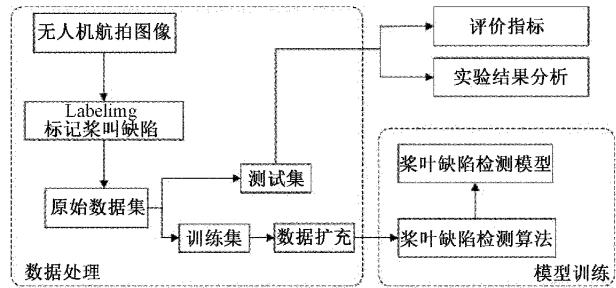


图 5 实验研究流程

3.1 数据集

数据集由无人机在风场现场拍摄采集得到, 为了得到更好的训练效果, 在不影响检测小目标缺陷检测精度的前提下, 采用旋转、平移、镜像等方式对图片处理丰富缺陷数据, 达到增强模型泛化能力的效果。本次实验采用 Labelimg 人工标注, 并保存为 PascalVOC 格式。本实验的数据集共有 450 张, 其中训练集 300 张, 验证集 150 张, 对训练集进行样本扩充到 900 张, 总计 1 050 张图片。数据集分为 3 种缺陷, 分别为胶衣脱落 (coat_off)、裂纹 (crack) 和侵蚀 (erosion)。

3.2 设备及参数设置

本次实验平台参数如表 1 所示。

表 1 软硬件平台参数设置

参数	配置
操作系统	Ubuntu18.04
深度学习框架	Pytorch
CPU	Intel(R) Core(TM) i9-10850K
内存	金士顿 16 G DDR4
显卡	GeForce RTX 2080Ti
硬盘	西数 10 TB

模型训练的其他参数设置如下: IOU 值设置为 0.5, Batch Size 设为 2, 学习率设置为 0.005, Epoch 设为 100。

3.3 评价指标

在目标检测中, 算法检测性能的好坏主要通过准确率

(Precision)与召回率(Recall)曲线来体现,在曲线图中,坐标轴上方面积越大,对应 AP 值越高,即算法检测精度越高。本文将区分正负样本的 IOU 阈值设置为 0.5,用 TP 表示被模型正确预测的正样本,FP 表示被模型错误预测的负样本,FN 表示被模型正确预测的负样本,FP 表示被模型错误预测的正样本。为了衡量算法性能,采用准确率、召回率、平均精度(average precision, AP)与平均类别精度(mean average precision, mAP)作为本文算法评估标准。具体计算公式如下所示。

准确率是衡量模型算法的准确性,计算公式为:

$$Precision = \frac{TP}{TP + FP} \quad (8)$$

召回率是衡量模型算法全面查找正样本的能力,计算公式为:

$$Recall = \frac{TP}{TP + FN} \quad (9)$$

平均精度(AP)是衡量模型算法在每个类别上的好坏,计算公式为:

$$AP = \int_0^1 p(r) dr \quad (10)$$

所有类别平均精度(mAP)由平均精度(AP)求和取平均得到,计算公式为:

$$mAP = \frac{\sum_{k=0}^c AP_k}{C} \quad (11)$$

式中: $\sum_{k=0}^c AP_k$ 是每一个类别的平均精度,C 是总类别数。

3.4 实验结果与分析

为了分析训练样本与网络性能的关系,进行训练样本数目的对比实验。在保持参数量基本一致的情况下,在风机桨叶数据训练集进行扩增分别为 300、600、900 的对比实验,实验结果如表 2 所示。

表 2 训练样本对网络性能的影响

训练样本个数	验证样本个数	测试集识别率 mAP/%
300	150	58.6
600	150	60.7
900	150	62.4

由表 2 可知,网络性能随着训练样本数量的不断增多也不断增强,当训练样本达到 900 个时,测试集识别率达到最高 62.4%,因此在网络训练过程中,应当尽可能保持足够多的训练样本数量,使网络能够学习足够多的信息。

为了验证本文提出的模型的有效性,以骨干网络为基础分别使用不同模块的对比网络进行消融实验。在保持参数量相同的情况下,以改进的残差网络结构 L-ResNet50 作为标准,在风机桨叶缺陷数据集上进行缺陷识别消融实验,分析各个模块对实验结果的影响,其结果如表 3 所示。

表 3 不同方法对精度的影响

L-ResNet50	注意力机制	多尺度特征融合	AR/%	mAP/%
✓			63.1	54.2
✓	✓		65.4	56.3
✓		✓	67.2	59.7
✓	✓	✓	71.5	62.4

由表 3 可知,改进残差结构单元的原始网络在桨叶缺陷数据集上的识别率为 54.2%。当添加注意力机制够可以使平均准确率提高 2.1%,添加多尺度融合模块后可以使平均准确率提升 5.5%,同时添加注意力机制模块和多尺度特征融合模块可以使平均准确率提升 8.2%。

本文模型在风机桨叶缺陷数据集上进行训练,训练集扩充后为 900 张,将测试集结果与主流算法 Faster R-CNN、YOLOv3、SSD 等实验结果对比如表 4 所示。

表 4 测试结果对比

检测算法	AP50/%			mAP/%
	coat_off	crack	erosion	
Faster R-CNN	50.4	53.8	58.4	54.2
SSD	46.1	51.7	56.4	51.4
YOLOv3	47.4	53.4	60.3	53.7
本文算法	58.5	61.2	67.5	62.4

由表 4 可知,本文提出的模型平均准确率较 Faster R-CNN、SSD、YOLOv3 分别提高 8.2%、11%、8.7%。同时改进后的网络对 coat_off 的 AP 值上升幅度较大,这是因为 coat_off 缺陷较小,多尺度特征融合可以增强对小目标特征的捕获能力。图 6 是不同算法的检测图像的对比,其中左侧第一列是原始图片,第一行是对小目标的检测结果,下面两行是在复杂场景下的检测结果,可以看出本文算法对小目标的漏检和复杂环境误检情况有一定程度的改善。

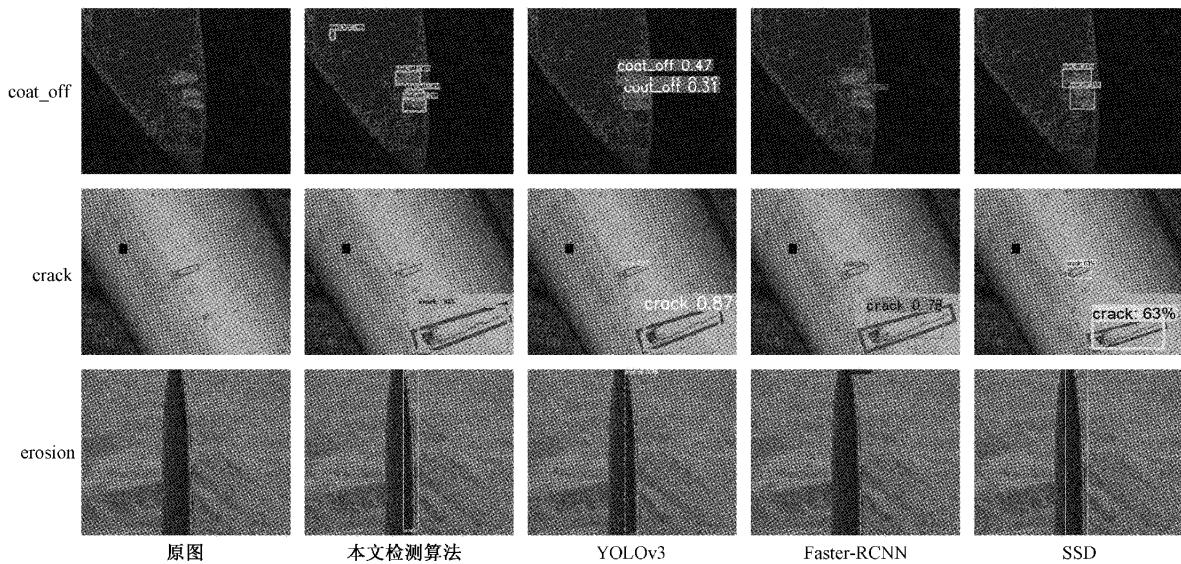


图 6 不同算法检测结果对比

4 结 论

本文提出了一种融合多尺度特征与注意力机制的风机桨叶缺陷检测方法。首先改进 ResNet50 中的残差模块, 克服了 ReLU 激活函数神经元失活的问题。其次考虑到浅层与深层位置信息之间的关系, 与传统特征金字塔结构不同, 利用双向融合的方式进行特征融合, 得到了表达能力更强的多尺度特征图。同时, 将注意力机制嵌入到自上而下和自下而上的双向融合中, 增强了特征融合的效果。经过实验对比, 本文提出的算法模型相较于传统 Faster R-CNN 算法, 在风机桨叶测试集上平均检测精度提高 8.2%, 证明了所提算法的有效性。

参考文献

- [1] 蔡继峰, 胡高硕, 石浩. 国内外风能资源评估标准研究综述[J]. 风能, 2021(12):56-63.
- [2] 胡让. 风力发电机叶片故障诊断研究及实现[D]. 兰州: 兰州交通大学, 2015.
- [3] 贺斌, 贾建华, 赵峰, 等. 无人机在风机叶片检测中的应用[J]. 电工技术, 2019(13):64-65.
- [4] BO Z, YANAN Z, CHANGZHENG C. Acoustic emission detection of fatigue cracks in wind turbine blades based on blind deconvolution separation [J]. Fatigue & Fracture of Engineering Materials & Structures, 2017, 40(6), DOI:10.1111/ffe.12556.
- [5] 李小伟. 基于光纤光栅传感技术的风机叶片检测研究[D]. 南京:南京航空航天大学, 2013.
- [6] WANG L, ZIJUN Z. Automatic detection of wind turbine blade surface cracks based on UAV-Taken images [J]. IEEE Transactions on Industrial Electronics, 2017, 64(9).
- [7] 康爽, 陈长征, 周勃, 等. 基于温度阈值风电叶片缺陷识别的红外检测研究[J]. 太阳能学报, 2020, 41(8):337-341.
- [8] YU Y, CAO H, YAN X, et al. Defect identification of wind turbine blades based on defect semantic features with transfer feature extractor [J]. Neurocomputing, 2020, 376(C).
- [9] 辛彦, 吴国新, 左云波. 基于 EfficientDet 的风机叶片缺陷检测方法[J]. 电子测量技术, 2022, 45(5): 124-131.
- [10] 朱佳伟, 文传博. 基于改进 SSD 的风机叶片缺陷检测[J]. 复合材料科学与工程, 2022(3):38-44.
- [11] 曲忠侃, 李学峰, 李凤俊, 等. 基于 Faster R-CNN 的风机叶片缺陷图像多点检测系统设计[J]. 电子设计工程, 2021, 29(4):57-61.
- [12] XU B, WANG N, CHEN T, et al. Empirical evaluation of rectified activations in convolutional network[J]. CoRR, 2015, abs/1505.00853.
- [13] 郁岩, 齐继阳. 改进 Faster R-CNN 的微型扁平电机 FPC 表面焊点缺陷检测[J]. 电子测量技术, 2022, 45(7): 146-151.
- [14] NEUBECK A, VAN GOOL L. Efficient non-maximum suppression [C]. 18th international conference on pattern recognition(ICPR'06), IEEE, 2006.
- [15] HE K, ZHANG X, REN S, et al. Identity mappings in deep residual networks[C]. European conference on computer vision, Springer, 2016.
- [16] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016.

- [17] 邓飞跃, 丁浩, 郝如江. 基于多尺度特征融合残差神经网络的旋转机械故障诊断[J]. 振动与冲击, 2021, 40(24): 22-28.
- [18] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021.
- [19] 赵文清, 杨盼盼. 双向特征融合与注意力机制结合的目标检测[J]. 智能系统学报, 2021, 16(6): 1098-1105.
- [20] 向宽, 李松松, 栾明慧, 等. 基于改进 Faster RCNN 的铝材表面缺陷检测方法[J]. 仪器仪表学报, 2021, 42(1): 191-198.

作者简介

全卫国,副教授,主要研究方向为先进流量测量。

E-mail: twg@163.com

仪小龙,硕士研究生,主要研究方向为缺陷检测与深度学习。

E-mail: yxlxt@ncepu.edu.cn

李冰(通信作者),讲师,主要研究方向为数字图像处理与机器视觉。

E-mail: 52651520@ncepu.edu.cn

杨珂,硕士研究生,主要研究方向为目标检测与深度学习。

E-mail: yangke@ncepu.edu.cn