· 40 ·

DOI: 10. 13382/j. jemi. B2205857

改进 YOLOv5s 的风力涡轮机表面缺陷检测*

张银胜^{1,2} 杨宇龙1 吉 茹1 蓝天鹤2 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:针对传统方式检测风力涡轮机表面缺陷时出现的精度不足、泛化性较差问题,提出了一种改进 YOLOv5s 的风力涡轮机 表面缺陷检测模型。在网络结构方面,首先在主干特征提取网络引入改进的 MobileNetv3 网络,用于协调并平衡模型的轻量化 和精度关系;其次采用 BiFPN 式的融合方式,增强神经网络的多尺度适应能力,提高融合速度和效率;最后为轻量化的自适应 调节特征权重,运用 ECAnet 通道注意力机制,进一步提高神经网络的特征提取能力。在损失函数方面,将边框回归的损失函数 修改为 αloU Loss,进一步提升了 bbox 回归精度。实验结果表明,基于 YOLOv5s 的改进算法可以在复杂环境下快速准确地识别 风机表面的缺陷目标,能够满足实时目标检测的实际应用需求。

Surface defect detection of wind turbine based on YOLOv5s

Zhang Yinsheng^{1,2} Yang Yulong¹ Ji Ru¹ Lan Tianhe² 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: Aiming at the problem of insufficient precision and poor generalization in the traditional way of wind turbine surface defect detection, an improved YOLOv5s wind turbine surface defect detection model is proposed. In terms of network structure, an improved MobileNetv3 network is introduced into the backbone feature extraction network to coordinate and balance the lightweight and accuracy relationship of the model. Secondly, the BiFPN fusion method is adopted to enhance the multi-scale adaptability of the neural network and improve the fusion speed and efficiency. Finally, for the lightweight adaptive adjustment of feature weights, the ECAnet channel attention mechanism is used to further improve the feature extraction ability of the neural network. In terms of loss function, the loss function of bounding box regression is modified to α IoU Loss, which further improves the accuracy of bbox regression. The experimental results show that the improved algorithm based on YOLOv5s can quickly and accurately identify the defect targets on the surface of the wind turbine in complex environments, and can meet the practical application requirements of real-time target detection. **Keywords**; wind turbines; YOLOv5s; lightweight object detection; mechanism of attention; multi-scale fusion

0 引 言

随着全球经济的持续发展,人们对于能源的需求也 日益增加。石油、煤炭、天然气等化石能源伴随着人们无 节制的攫取,其有限性以及环境恶化的问题逐渐凸显出来,这也使如何开发新能源成为了一项全球性热点话题。 风能^[1]开发难度低,对环境污染小,已经成为取代传统化 石能源的首选。在十三五后,我国各行各业都积极贯彻 落实可持续发展理念和绿色发展的方针,风力发电技术

收稿日期: 2022-09-26 Received Date: 2022-09-26

^{*}基金项目:国家自然科学基金(62071240,62106111)、江苏省一流本科课程《电路分析基础》无锡学教学改革重点课题(JGZD202109)项目 资助

日益成熟,风力涡轮机^[2]在我国大量投入使用。随着风 力涡轮机服役年限的增加,一方面风机叶片本身受力条 件复杂,包括翼面向弯曲载荷、惯性力以及扭转载荷:另 一方面风机塔架又不可避免地受到飓风、盐雾、雷暴、风 沙、雨雪等各种恶劣气候条件的影响[3],导致风机表面产 生不同程度的缺陷损伤,许多风机都达到了使用上限。 风力涡轮机一般高达近百米,导致风力涡轮机的检修工 作较难实施^[4],如何在风力涡轮机缺陷出现初期,检测出 缺陷类型和位置信息,显得尤其重要。近年来国内外风 力涡轮机表面缺陷检测方法主要分为两种,一是无损检 测方法如红外热成像、超声等,二是基于无人机平台的可 见光缺陷成像,其中,红外热成像是常用的无损检测方 法。齐林等^[5]通过稳态热分析和瞬态热分析等红外热成 像无损检测方式进行风机叶片缺陷检测。德国的 Tavner 等^[6]给出了一种被动式红外热成像技术进行检测的例 子,通过昼夜温差变化,观察风机表面出现的气泡缺陷。 康爽等[7]利用热传导方程推导出风机叶片缺陷所在区 域,测出各种预制缺陷的热扩散系数,根据温度数据划分 满足温度阈值的缺陷及定位缺陷的位置。但总体来说红 外检测的方法耗时耗力,并且图像对比度低,分辨细节能 力较差,尤其不适用于风力涡轮机的野外在线运行缺陷 检测。

基于无人机平台的可见光缺陷成像检测具有成本 低、检测速度快的优点,其中缺陷检测关键技术之一是利 用深度学习技术识别出缺陷。现如今诸多研究人员运用 卷积神经网络(convolutional neural network, CNN)到工业 检测这一领域中来,分为 Two-Stage 结构和 One-Stage 结 构。Two-Stage 结构首先生成一系列的目标候选区域,再 进行目标分类和校准,代表的算法有 R-CNN^[8]、Faster-RCNN^[9]、残差神经网络(ResNet)^[10]等。向宽等^[11]通过 在 Faster-RCNN 主干网络加入特征金字塔网络 (feature pyramid network, FPN)结构,引入感兴趣区域校准(ROI Align)算法来代替粗略的感兴趣区域池化(ROI pooling) 算法,得出更适应缺陷目标的锚框,实验结果表明平均精 度均值(mAP)比原 Faster-RCNN 网络提高了约 16%。茅 宇琳^[12]采用基于 ResNet-101 的级联 R-CNN 特征提取网 络作为检测模型,在检测风机表面缺陷时引入迁移学习 思想使模型能更快收敛。但引入 ResNet 网络后,训练后 期不够稳定,容易造成图形失真。另一类则是 One-Stage 算法,典型算法包括 SSD^[13](single shot multibox detector) 和 YOLO^[14-18](you only look once) 系列等。该类算法是 将目标检测看作回归问题,能够在保证较高检测精度的 同时具有良好的实时性。郝帅等^[19]提出将原始 YOLOv5 检测框架颈部网络中的金字塔注意力网络^[20-21](pyramid attention network, FPN+PANet)结构替换为加权双向特征 金字塔网络^[22] (bidirectional feature pyramid network,

BiFPN)结构,使目标多尺度特征能够有效融合,增强检测网络对遮挡情况下故障目标的检测能力。Qiu等^[23]结合YOLO与CNN模型,将逆卷积神经网络应用于特征金字塔的高级特征,利用CNN的中间层丰富小目标的特征表达,将提取到的多尺度卷积特征在分类模型中训练,风机表面多种缺陷检测平均精确率能达到91.3%。

目标处在复杂环境下时,综上算法往往难以对目标 特征进行有效的提取,网络模型对多尺度目标特征融合 能力尚有不足,目标检测的精度有待提高。针对传统算 法对于复杂环境中待检测缺陷形状尺寸各异造成检测精 度较差、检测要求较高的问题,提出一种基于注意力机 制、多尺度特征融合与改进损失函数的轻量级 YOLOv5s 的风力涡轮机缺陷检测方法。

1 基本网络模型

YOLOv5 包含 YOLOv5s、YOLOv5l、YOLOv5m 和 YOLOv5x 这4种网络模型。YOLOv5s 是这4种模型中网 络深度和宽度最小的模型,后3种模型虽然检测精度提 升,但是模型尺寸越大,检测速度也越慢。为了实现检测 模型的轻量化,选择 YOLOv5s 作为基础模型。

YOLOv5s 相比于 YOLOv4 主干网络中新增加了 Focus 模块和跨阶段局部网络^[24](cross stage partial network,CSPNet)模块。Focus 结构对输入图片进行切片 操作,达到扩充输入通道数的效果。主干网络中使用带 有残差结构的 CSP1_X,使网络层之间反向传播时,梯度 值得到增强,以防出现梯度消失现象,并减少了模型参 数量。

颈部网络(Neck)中 FPN 就是把深层的语义特征传 到浅层,而 PANet 则是把浅层的定位信息传导到深层,从 不同的主干层对不同的检测层进行特征融合。颈部网络 中使用 CSP2_X,增强网络特征融合的能力。FPN+PANet 结构如图 1 所示。



最新 YOLOv5 的 bbox(bounding box)回归损失函数 为 CIOU Loss,有效地解决了前期 YOLO 系列边界框不重

合引出的问题,并考虑了边界框宽高比的尺度信息。 YOLOv5 使用加权非极大值抑制(non-maximum suppression,NMS)解决预测框的冗余问题。

2 改进型网络模型

2.1 主干网络改进

YOLOv5s 使用的 CSPNet 主干网络能有效地提取深 度信息,但实际检测过程中风力涡轮机图像往往处于复 杂场景中,会对图像中目标捕捉造成较大的干扰,缺陷目 标在图像中所占的比例通常很小,像素较低,经过反复的 上采样和下采样后容易导致小目标信息的丢失。对于场 景中出现目标混叠时,目标的漏检问题则比较严重。因 此在 YOLOv5s 主干网络中引人改进的 MobileNetv3 轻量 级网络,保留更多小目标的语义信息,并尝试降低模型的 参数,达到网络检测轻量化、精度、速度的协调平衡。改 进后的 YOLOv5s 网络结构图如图 2 所示。

MobileNet^[25]作为轻量级 CNN 网络的代表被广泛应 用于目标检测当中,在 2017年由 Google 团队提出。 MobileNetv3 在保持精度不减的情况下,将 MobileNetv2 使 用 32 个滤波器的 3×3 的卷积层,滤波器降为 16 个, MobileNetv3 使用 h-swish 激活函数取代 MobileNetv2 使用 的 swish 激活函数,在量化模式下回提高大约 15% 的效 率。swish 函数如式(1)所示;h-swish 函数中给 ReLU 函 数加一个上界为 6,即 ReLU6,如式(2)所示。

swish
$$(x) == x \cdot sigmoid(\beta x)$$
 (1)

$$h - swish (x) = x \frac{\text{ReLU6}(X+3)}{6}$$
(2)





Fig. 2 YOLOv5s _ MEB network structure diagram

MobileNetv3的Bottleneck 层被用于每个特征层的特征提取,尝试对Bottleneck 层进行改进,输入端图片经过CBH 层降维,CBH 函数由Conv 层、BN 归一化、h-swish 函

数组成,第1层 Bottleneck 通过 DW 卷积提取特征,引入 h-swish 激活函数与 SENet(squeeze-and-excitation)注意力 机制结合,提升对小目标关键特征的提取能力。再使用 1×1 卷积层实现降维。去除了原始 Bottleneck 层中的冗 余结构,通过改变卷积层和卷积方式,在减少网络参数的 前提下提升了网路运算速度,使网络关注更加有用的通 道信息,从而调整每个通道的权重,如图 3(a)所示。其 余的 Bottleneck 层,先使用 1×1 卷积实现升维,再通过 DW 卷积提取特征,再引入 SE 注意力机制并与 h-swish 激活函数结合,提升局部通道信息的捕获能力,抑制一些 对当前任务无用的特征信息,最后使用 1×1 卷积层实现 降维,最大程度上减少模型的参数以及计算量,对检测精 度影响较小。其余 Bottleneck 层如图 3(b)所示。



2.2 注意力机制改进

风力涡轮机表面缺陷图像多数通过无人机拍摄,图像背景信息比较复杂,部分风机表面的标签和划线的外观特征与缺陷特征较为相似;由于缺陷表面表现出的金属色会受光照等自然因素影响,会降低图像的清晰度;而且其中出现的缺陷目标的大小形状颜色各异。为了提高风机表面缺陷目标的检测精度,YOLOv5s_MEB在Bottleneck深度卷积过程中已经引入SENet注意力机制前提下,还在主干网络与颈部网络间引入了ECAnet^[26](efficient channel attention module)高效的相关性通道注意力模块,增强了神经网络的表达能力。

SENet 是现阶段常用的通道注意力机制,采用全局 池化的方式,降低参数量,防止该层出现过拟合现象。 ECAnet 在计算量减少时,对关键信息表征能力的提升效 果优于 SENet。主干网络与颈部网络信息的传播在卷积 神经网络中至关重要,ECAnet 承接 Bottleneck 层输出的 特征图,并在颈部网络 C3 模块上采样,下采样过程中引 人 ECAnet,共计7个 ECAnet 引入点。ECAnet 在网络层 之间捕获局部通道信息,获得每个特征通道中的重要程 度,并且抑制对当前获取信息过程中无用的特征信息。 首先对输入特征图进行全局平均池化(global average pooling,GAP)操作,将 $W \times H \times C$ 特征向量转化为1×1× C向量。根据特征图的通道数计算得到尺寸为k的一维 卷积来进行跨通道交互,得到特征图每个通道的权重,最 后归一化处理再逐通道相乘,得到具有通道注意力的特 征图。ECAnet 在不降低通道维数,以轻量级的方式来进 行跨通道信息交互,减少了模型的计算成本,带来了明显 的性能增益。ECAnet 网络结构图如图 4 所示。



Fig. 4 ECAnet network structure diagram

2.3 多尺度特征融合改进

风机表面缺陷目标的形状大小尺寸各异,同一张风 机表面图像通常存在多种尺度的缺陷目标,容易出现漏 检的现象。因为 YOLOv5s_MEB 中颈部网络由 BiFPN 加 权双向特征金字塔网络取代了 FPN + PANet 网络。 BiFPN 删除了只有一条输入边却没有特征融合的节点, 从而简化双向特征网络, BiFPN 在处于同一层的原始输 入节点和输出节点之间添加一条额外的边,即横向连接, 在不增加成本的情况下融入更多特征。BiFPN 会重复处 理每个双向路径路径作为一个特征网络层,以实现更高 层次的特征融合。从主干网络的 Bottleneck 层提取出特 征3种不同尺度的特征,在第4层、第5层 Bottleneck 层 网络输出之前使用带权重的通道融合,将其通道数压缩 统一后送入 BiFPN 网络, C3 层通过上采样承接 Bottleneck 层并引入 ECAnet 注意力通道,经过上采样下 采样结构与 CBL 层结合,经过多组 Concat 后的卷积计 算,增强主干网络的特征提取能力,最后将不同尺度的 Bottleneck 层送入检测,分别检测出大、中、小目标。 BiFPN 网络结构如图 5 所示。

2.4 损失函数改进

YOLOv5s 模型采用 CIOU Loss 作为损失函数,如式 (3) 所示:

$$L_{\alpha loU} = 1 - IoU^{\alpha} + \frac{P^2(B, B^{\alpha})}{c^{2\alpha}} + (\beta v)^{\alpha} \beta =$$

(1 - IoU) + c





$$v = \frac{4}{\pi^2} (\arctan \frac{w^{g^t}}{h^{g^t}} - \arctan \frac{w}{h})^2$$
(3)

其中, P 为 B 和 Bst 之间的欧氏距离, c 为 B 和 Bst 之 间最小外接长方形对角线的长度, v 为 B 和 Bst 之间长宽 比的相似性, wst、hst 表示真实检测框的宽和高, w 和 h 表 示预测检测框的宽和高, β 是一种权重系数。CloU Loss 加入惩罚项来减轻梯度消失的问题,在惩罚条件下进一 步考虑了预测框和真实框之间的中心点距离和长宽比。

YOLOv5s_MEB 模型基于现有的 CIOU Loss 提出 αIOU Loss,引入 power 变换,将 power Iou Loss 记为 α, αIoU Loss 用于精确的 bbox(bounding box)检测框回归和 目标检测,是基于 IoU 的现有损失的统一幂化;诸多学 者^[27]通过大量的实验和模型演算对 αIoU 次序保留、损 失、梯度重加权等一系列性质的分析,表明 α>1 时可以 通过自适应地提高 IoU 对象的损失和梯度的加权来提高 bbox 回归精度;本文选择 α 为 3,引入 αIoU 损失后检测 效果优于现有基于 CIoU 的损失,不会引入额外的参数、 训练时间。为缺陷检测提供更强的鲁棒性。αIoU Loss 如式(4)所示:

$$L_{\alpha loU} = 1 - IoU^{\alpha} + \frac{P^{2}(B, B^{gt})}{c^{2\alpha}} + (\beta v)^{\alpha}$$
(4)

3 实验结果分析

3.1 数据采集与处理

本文训练使用的操作系统为 Windows 10。CPU 型号为 Intel(R) Core I7-10700F, GPU 型号为 Nvidia GeForce RTX3060。深度学习测试的框架为 Pytorch1.9.0,使用 Python 语言进行编程,并使用 CUDA11.3.1 版本并行计 算框架搭配 CUDNN8.2.2 版本的深度神经网络加速库 对 GPU 进行加速。

本文使用的数据集由 Roboflow 网站提供的公开无人 机拍摄下风力涡轮机表面缺陷数据集和户外场景中视频 帧获得的风机图片组成,对叶片和塔架进行多角度拍摄, 包含了风力涡轮机塔架、发动机舱、叶片、风向标等结构, 增加了许类似于风机塔架与叶片衔接处图片的数量,图 片尺寸为608×608,部分实验中出现的缺陷目标图像如 图6所示。



EIO 政府日本国 Fig. 6 Defect target diagram

采集到的数据集预处理操作,YOLOv5s 模型中包含 对数据进行 HSV 增强、旋转、缩放、平移、剪切、透视、翻 转操作。本文针对复杂环境下风机表面缺陷检测增加了 图像模糊算法,模拟恶劣天气下所摄图片;增加了亮度对 比度变换,模拟昏暗光线下所摄图片;并在部分图像数据 集中添加高斯噪声,完成对数据集的增广。在训练过程 中提高检测模型的鲁棒性,和对小目标和目标堆叠时的 检测成功率。图效变换效果对比如图 7 所示。



将获取到的 7 995 张表面图片进行目标的筛选和标 注,按照 8:1:1 的比例将数据集分为训练集、验证集和 测试集,其中训练集 6 396 张图片,验证集 800 张图片,测 试集 799 张图片。分为掉漆等原因出现的较大面积缺陷 (crack),因为风沙等原因出现的脏污(dirt);因为自然腐 蚀出现的孔洞、缝隙(void);各组件粘接处出现的偏窄长 型缺陷(erosion);缺陷长时间未得到处理生出铁锈 (rust);雷暴等恶劣天气对风机形成损害造成的缺陷 (thunderstrike)共 6 类检测标签。生成与各标签类别名 一一对应的 XML 标签,标签文件中包含标签类别、预测 框坐标等信息。YOLOv5s_MEB 检测模型部分预处理结 果如图 8 所示。

3.2 评估标准

本文采用如下性能指标评估本风力涡轮机缺陷检测 的算法性能,采用平均精度(average precision)、准确率 (Precision)、召回率(Recall)和帧速大小(FPS)等角度衡 量检测效果。其中 T_p 指预测为缺陷实际也为缺陷的数 量, F_p 则是预测为缺陷但实际被误检的数量, F_N 代表缺 陷未被检测出的数量。P(准确率)是衡量改进后模型精 确性的度量,表示被分为缺陷中实际也为缺陷的比例。R(召回率)是覆盖面的度量,计算有多少个缺陷目标,通 过计算不同召回率下最高的精确率可绘制曲线 P - R, 该曲线围成的面积即为该类别的 AP 值。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 式如式(5)所示。

$$P = \frac{T_p}{T_p + F_p} \qquad \qquad R = \frac{T_p}{T_p + F_N}$$
$$P_{AP} = \int_0^1 P(R) \, \mathrm{d}R \qquad \qquad P_{mAP} = \frac{\sum_{i=1}^N AP_i}{N} \qquad (5)$$

本文还将检测速度作为判断模型性能的关键性指标,通过每秒检测帧速(FPS)作为速度指标,其表达式如式(6)所示。

 $xFPS = FCount/T \tag{6}$

批量大小(Batch-size)设为16,学习率(Learning-rate) 为0.01,迭代轮数(Epochs)为300次。随着模型的训练不 断深化,训练集的box_loss(位置损失)和cls_loss(类别损 失)都不断下降,训练集的obj_loss(位置损失)在经过200 轮训练周期后最终稳定在0.015左右。验证集的位置损 失、置信度损失在200轮训练周期后,都稳定在0.01左 右,类别损失稳定在0.001左右,改进后模型检测准确率 在250轮后趋近于0.9,召回率则能达到80%以上,mAP 值则达到85%左右。每次训练均保存一次权值文件,在 所有300轮训练完成后,得到损失值最小的权重文件。 YOLOv5s_MEB 检测模型预处理结果如图9所示。

图 7 图效变换效果对比图





图 8 YOLOv5s_MEB 检测模型部分预处理结果

Fig. 8 YOLOv5s_MEB pretreatment results of detection model

(注:crack 标为0, dirt 标为1, void 标为2, erosion 标为3, rust 标为4, thunderstrike 标为5)



3.3 消融实验

YOLOv5s_MEB 模型对 YOLOv5s 模型的特征提取能 力、注意力机制和多尺度特征融合方法进行了改进,并引 入了新型损失函数。为评估不同模块改动和不同模块组 合对于算法性能优化的程度,设计了消融实验,消融实验 数据如表1所示。从消融实验中可以看出,使用任一模 块对检测精度都有提升,但网络越复杂,检测速度也随之 下降。模型的性能并不随着模块的排列组合而线性提升,在逐步改进 YOLOv5s 的网络模型的过程中,模型的 检测能力也在逐步提升。实验1和实验2对比实验如 表1所示。在 YOLOv5s 的主干网络基础上融入轻量级 网络 MobileNetv3后,减少了模型参数量,检测实时速度 提升约13FPS,提升显著。从实验1和实验3对比实验 可知,引入 ECAnet 高效通道注意力机制后,提升了通道 注意力的特征表达能力,检测精度和召回率都明显提升, mAP 增加了 2.2%。由实验 1 和实验 4 对比,融合 BiFPN 双向特征网络后,提升了对风机表面缺陷的检测能力。 不仅 mAP 值相较于原 YOLOv5 网络提升了 2.37%,帧速 也提升了约 10 FPS,提升效果最佳。由实验 1 与实验 5 对比可知,引入 alou Loss,对 mAP 值也有一定的提升。 不同策略的融合,对原模型都有正向的优化效果。由实 验 6 和实验 10 对比可以发现,ECAnet 无论与 MobileNetv3 还是与 BiFPN 的结合,对精度以及召回率的 提升都是显而易见,因为引入注意力机制后,模型划分各 类缺陷的分类性能得到明显提升,更关注目标本身。对 比实验 13 和实验 16,引入 BiFPN 结构之后,mAP 与帧速 都显著提高,这验证了 BiFPN 融合于 YOLOv5s_MEB 模 型中时比处于 YOLOv5s 模型中时有更佳的特征融合作 用。对比实验 15 与实验 16,得出使用 MobileNetv3 轻量 级网络,虽然对检测精度提升并不明显,但降低了模型计 算量和参数量,极大提升了检测速率。

通过4种策略的不同组合,得到的优化效果也各不相同。例如实验9,虽然 mAP 提升了约5%,但检测速率 却并不理想。采用 YOLOv5_MEB 模型虽然会某种程度 上消弱某一单一策略的优化程度,但取得了精度、检测速 度、模型大小的协同最优值。

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

尔哈库早	MobileNety3	FCAnot	R;FDN	alou	D/0/2	P / 0%	mAD/0/a	帖油/FDS
天视厅 5	MobileIvetv5	ECAnet	DIFFN	alou	F7 %0	R/ %	MAF / %	顿座/115
1					82.32	73.45	82.56	58.39
2					83.44	73.63	82.63	71.37
3		\checkmark			82.32	75.43	84.76	62.36
4			\checkmark		83.14	74.76	84.93	68.34
5				\checkmark	82.48	73.69	83.68	60.37
6	\checkmark	\checkmark			82.29	75.34	84.66	70.36
7	\checkmark		\checkmark		81.81	74.49	83.83	73.12
8	\checkmark				81.49	74.32	83.32	71.24
9		\checkmark	\checkmark		84.80	77.06	87.51	63. 53
10		\checkmark			85.11	76.42	86.53	64.31
11			\checkmark		84.22	76.33	86.12	63.33
12	\checkmark	\checkmark	\checkmark		86.59	76.78	87.54	72.43
13	\checkmark	\checkmark			84.98	76.74	86.60	63.96
14	\checkmark		\checkmark		85.13	77.17	86.95	70.61
15		\checkmark	\checkmark		89.28	80.45	88.13	64.23
16	\checkmark	\checkmark	\checkmark		89.66	80.68	88.45	71.78

注:√:代表采用了此策略

3.4 对比实验

在相同的风机表面缺陷数据集基础上,YOLOv5s_ MEB 算法的精度相比于 SSD、Faster-RCNN、YOLOv4、 YOLOv5s 模型明显优化效果更好,SSD 作为 One-Stage 检 测模型的代表,虽然在检测精度方面表现尚可,但 SSD 的 低级特征卷积层较少,而且本文的缺陷目标以小目标为 主,所以导致特征提取不充分,目标漏检率较高。Faster-RCNN 在测试阶段仍需要从特征区域提取特征向量,所 以达不到实时检测效果。YOLO 系列检测模型在上述方 面则有明显的改善,检测精度和目标漏检率提升在 3%及 以上,YOLOv5s_MEB 相比于 Faster-RCNN 模型检测速度 提升了约 14 倍,相较于 YOLOv4 模型检测速度也提高了 2 倍多,而且在模型精度方面,YOLOv5s_MEB 的 mAP 相 比于余下 4 种模型都有不同程度提升,这其中相较于 SSD 模型提升了约 18%,相较于 YOLOv4、YOLOv5s 模型 提升了约6%~8%。而 YOLOv5s_MEB 模型的目标漏检 率达到最低的 6.47%,这得益于 BiFPN 中引入了 ECAnet,提升了特征提取能力,有效实现了对大、中、小不 同尺度的缺陷预测,又进一步提升了复杂环境中对小目 标的检测精度。

YOLOv5s 相较于 YOLOv4 虽然精度、漏检率提升并 不明显,然而 YOLOv5s_MEB 模型的体积也是最小的,这 主要得益于 YOLOv5s 网络模型相较于 YOLOv4 网络模 型就有极大的改进,在不降低检测精度和速度的情况下, 模型参数量降低到原来的约 1/17, YOLOv5s_MEB 模型 在 YOLOv5s 的基础上,模型体积又降低了 3.92 M。综上 所述,YOLOv5s_MEB 模型相较于其余模型,其检测精度、 检测效率都有明显提升,这说明 YOLOv5s_MEB 模型有 更佳的优化效果,并达到各检测指标平衡作用的效果。5 种模型性能的对比如表 2 所示。

 Table 2
 Performance comparison of five models
 模型 mAP/% Params/M 帧速/FPS 目标漏检率/% SSD 70.56 100.14 61.21 32.79 Faster-RCNN 77.64 105.87 4.96 20.65 YOLOv4 80.49 239.65 35.57 15.63 YOLOv5s 82.56 13.68 58.39 12.58 YOLOv5s_MEB

9.76

表 2 5 种模型的性能对比

从图 10 中对比发现,第1 组图中 5 种模型都成功检 测出了风机表面出现的 dirt、crack 目标,检测精度从左到 右递增,这也得益于出现的 dirt、crack、rust 目标通常面积 较大,crack 由于风机表面油漆脱落后暴露出内部原有的 金属色,或 crack 长期未得到修复生锈转变成 rust,一般 经过深度训练后的模型都可检测出。void 目标通常表现 为细小深的孔洞,易出现漏检的情况,SSD 模型不仅出现 void 缺陷未被检测出的情况,还出现多种缺陷出现在同 一张图片而频繁误检。Faster-RCNN 模型虽然检测效果

88.45

尚可,但检测如 void 等小目标时会出现误检的状况。 YOLOv4 和 YOLOv5 模型在检测各类缺陷目标时,风机缺 陷检测置信度较高。本文改进后的 YOLOv5s_MEB 模型 保留了更多多尺度特征融合后的目标特征信息,从而提 高了全局特征提取能力,检测精度相较于其他4种模型 表现最优,减少 YOLOv5s_MEB 模型可能出现的漏检和 误检现象,也让模型鲁棒性能更好,基本满足实际工业中 对于风力涡轮机表面缺陷的检测要求。

71.78



图 10 模型检测结果对比

Fig. 10 Model checking results comparison diagram

结 论

本研究为了实现风力涡轮机表面缺陷的实时检测, 提出了一种基于改进 YOLOv5s 的检测算法。首先针对 实际检测过程中遇到的各种复杂检测场景,对实验数据 集做了模糊化、添加高斯噪声等处理;其次在网络结构方 面,主干特征提取网络中改进了 MobileNetv3 轻量级网络 模型,降低了模型体积;然后在主干网络和颈部网路之间 引入 ECAnet 通道注意力机制,增强了风机表面区域的显 著度:紧接着通过 BiFPN 替换 FPN+PANet 结构,使得模 型在应对多种类型目标特征时能得到更有效地表达;在 损失函数方面,引入 alou Loss,这一做法能够进一步提升 bbox 的回归精度,提升小尺寸目标的召回率。改进后的 YOLOv5s_MEB 模型检测缺陷目标时准确率、召回率、

mAP、帧速等性能指标下相较于其他模型都有不同幅度 的提升,能完成复杂环境中的风机表面缺陷检测工作,在 工业部署中有一定的应用价值。

本研究提出的一种基于改进 YOLOv5s 的检测算法 提高了缺陷识别的精度和速度,但是在恶劣天气等复杂 环境中的泛化能力有待进一步研究。

参考文献

- [1] LIU F, GAO S J, REN M M. Research on the power tracking control of permanent magnet synchronous wind turbine with losses considered [J]. Science Discovery, 2021,9(4):160.
- LIU Q X, WANG Z H, LONG S G, et al. Research on [2] automatic positioning system of ultrasonic testing of wind turbine blade flaws [J]. IOP Conference Series: Earth and Environmental Science, 2017, 93(1);012074.

6.47

- [3] CASTELLANI F, ASTOLFI D, NATILI F. SCADA data analysis methods for diagnosis of electrical faults to wind turbine generators [J]. Applied Sciences, 2021, 11(8):3307.
- [4] YANG Z Y, ZHANG H Y, GUAN P, et al. Test of offshore wind generator pile foundation based on distributed Brillouin optical fiber sensing [J]. Optics Frontiers Online 2020: Distributed Optical Fiber Sensing Technology and Applications, 2021, 11607.
- [5] 齐林. 基于红外热成像技术的风力发电机叶片缺陷 检测研究[D].长沙:湖南大学,2021. QI L. Research on defect detection of wind turbine blade

based on infrared thermal imaging technology [D]. Changsha: Hunan University, 2021.

- TAVNER P, EDWARDS C, BRINKMAN A. Influence [6] of wind speed on wind turbine reliability [J]. Wind Engineering, 2006, 30(1):75-80.
- [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.

KANG SH, CHEN CH ZH, ZHOU B, et al. Infrared detection research on wind turbine blade defects identification based on temperature threshold [J]. Acta Energiae Solaris Sinica, 2020, 41(8): 337-341.

- SHUANG F, HUANG H Z, LI Y, et al. AFE-RCNN: [8] Adaptive feature enhancement RCNN for 3D object detection[J]. Remote Sensing, 2022, 14(5):1176.
- [9] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards rea L-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis & amp; Machine Intelligence, 2017, 39(6): 1137-1149.
- 张珂,冯晓晗,郭玉荣,等.图像分类的深度卷积神经 [10] 网络模型综述[J]. 中国图象图形学报, 2021, 26(10): 2305-2325.

ZHANG K, FENG X H, GUO Y R, et al. Overview of deep convolutional neural networks for image classification [J]. Journal of Image and Graphics, 2021, 26(10):2305-2325.

向宽,李松松,栾明慧,等.基于改进 Faster RCNN 的铝 [11] 材表面缺陷检测方法 [J]. 仪器仪表学报, 2021, 42(1):191-198.

> XIANG K, LI S S, LUAN M H, et al. Surface defect detection method in aluminum based on improved YOLOv4 [J]. Chinese Journal of Scientific Instrument, 2021,42(1):191-198.

茅宇琳. 基于无人机采集图像的风机叶片多种表面缺 [12] 陷检测研究[D].北京:北京交通大学,2020.

MAO Y L. Research on detection of multi-type surface

defects of wind turbine blades based on images collected by UAV [D]. Beijing Beijing Jiaotong University, 2020.

- 周晓彦,王珂,李凌燕.基于深度学习的目标检测算法 [13] 综述[J]. 电子测量技术, 2017, 40(11): 89-93. ZHOU X Y, WANG K, LI L Y. Review of object detection based on deep learning [J]. Electronic Measurement Technology, 2017, 40(11):89-93.
- 龙乐云,周腊吾,刘淑琴,等.改进 YOLOv5 算法下的 [14] 输电线路外破隐患目标检测研究[J].电子测量与仪 器学报, 2022, 36(11): 245-253. LONG L Y, ZHOU L W, LIU SH Q, et al. Identification of hidden damage targets by external forces based on domain adaptation and attention mechanism [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(11): 245-253.
- [15] CHEN K, LI H T, LI C S, et al. An automatic defect detection system for petrochemical pipeline based on cycle-GAN and YOLO v5 [J]. Sensors, 2022, 22(20):7907.
- [16] WU H F, HU Y L, WANG W J, et al. Ship fire detection based on an improved YOLO algorithm with a lightweight convolutional neural network model [J]. Sensors, 2022, 22(19):7420.
- SUN L S, XU Y, RAO Z K, et al. YOLO algorithm for [17] long-term tracking and detection of escherichia coli at different depths of microchannels based on microsphere positioning assistance [J]. Sensors, 2022, 22(19):7454.
- ZHANG Y, GUO Z Y, WU J Q, et al. Real-time vehicle [18] detection based on improved YOLO v5 [J]. Sustainability, 2022, 14(19):12274.
- [19] 郝帅,杨磊,马旭,等.基于注意力机制与跨尺度特征 融合的 YOLOv5 输电线路故障检测 [J/OL]. 中国电机 工程学报:1-12[2022-11-02]. HAO SH, YANG L, MA X, et al. YOLOv5 transmission line fault detection based on attention mechanism and cross-scale feature fusion [J/OL]. Proceedings of the CSEE:1 -12[2022-11-02].
- [20] LIU Y J, YANG F B, HU P. Parallel FPN algorithm based on cascade R-CNN for object detection from UAV aerial images [J]. Laser & Optoelectronics Progress, 2020, 57: 201505.
- [21] WANG Y P. Symposium title: The fronto-parietal network (FPN): Supporting a top-down control of executive functioning [J]. International Journal of Psychophysiology, 2021,168;S39.
- [22] ZHANG T, JIN B, JIA W J. An anchor-free object detector based on soften optimized bi-directional FPN[J]. Computer Vision and Image Understanding, 2022, 218: 103410.

- [23] QIU Z, WANG S, ZENG Z, et al. Automatic visual defects inspection of wind turbine blades via YOLO-based small object detection approach [J]. Journal of Electronic Imaging, 2019, 28(4):43023. 1-43023. 11.
- [24] ZHANG Y C, YU J Y, CHEN Y, et al. Real-time strawberry detection using deep neural networks on embedded system (rtsd-net): An edge AI application [J]. Computers and Electronics in Agriculture, 2022, 192.
- [25] LIN Z, GUO W X. Cotton stand counting from unmanned aerial system imagery using mobilenet and centernet deep learning models [J]. Remote Sensing, 2021, 13(14):2822.
- [26] 李晓艳,符惠桐,牛文涛,等. 基于深度学习的多模态 行人检测算法[J]. 西安交通大学学报,2022,56(10): 61-70.

LI X Y, FU H T, NIU W T, et al. Multi-modal pedestrian detection algorithm based on deep learning[J]. Journal of Xi'an Jiaotong University, 2022,56(10):61-70.

[27] 李功,赵巍,刘鹏,等. 一种用于目标跟踪边界框回归的 光滑 IoU 损失[J/OL]. 自动化学报:1-19[2022-09-25].
LI G, ZHAO W, LIU P, et al. Smooth-IoU loss for bounding box regression in visual tracking[J/OL]. Acta Automatica Sinica:1-19[2022-09-25].

作者简介



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.



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 West Anhui University, College of Electronic and Information Engineering 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.



单慧琳,2003年于武汉大学获得学士 学位,2009年于南京信息工程大学获得硕 士学位,现为南京信息工程大学和无锡学院 副教授、硕导。主要研究方向为深度学习、 图像处理等。

E-mail:shanhuilin@nuist.edu.cn

Shan Huilin received her B. Sc. degree from WuHan University in 2003, M. Sc. degree from Nanjing University of Information Science and Technology in 2009. Now she is an associate professor and master's supervisor in Nanjing University of Information Science and Technology and Wuxi University. Her main research interests include deep learning and image processing.