

DOI: 10.13382/j.jemi.B2407386

改进 YOLOv8 算法在风机叶片缺陷检测上的应用*

曾勇杰 范必双 杨涯文 蒋冲

(长沙理工大学电气与信息工程学院 长沙 410000)

摘要: 风力发电机叶片,作为风力发电系统的核心组件,其健康状况直接关乎整个发电效率与运行安全。针对叶片缺陷检测的挑战,深入研究了 YOLOv8n 网络,并创新性地提出了高效多尺度卷积模块(EMSCConv),该模块有效替代了传统残差块中的卷积层,通过分组卷积技术显著降低了冗余特征对检测结果的干扰,从而提升了检测的精确性。此外,在检测头部分,融入了 Dynamic Head 的多元化注意力机制,这些自注意力机制协同工作,跨越不同特征层,实现了对目标尺度、空间位置及检测任务的精准感知,极大地增强了目标检测模块的综合能力。还创新性地整合了 Inner-IoU、Wise-IoU 与 MPDIoU,创造性地提出了 Inner-Wise-MPDIoU,以替代传统的 CIoU 损失函数,这一举措不仅提高了网络的检测精度,还加速了收敛过程。在针对自制风机叶片缺陷数据集的测试中,YOLOv8-EDI 展现出了卓越的性能,其 mAP50 值高达 81.0%,相比原始 YOLOv8n 提升了 2.3%;召回率也达到了 76.8%,提升了 3.7%。该模型在提升检测效果的同时,还实现了计算量的降低,降幅达 5.5%,充分满足了工业环境下对风机叶片进行高效、准确、大批量检测的需求。

关键词: 风机叶片;缺陷检测;YOLOv8n;高效多尺度卷积;Dyhead;损失函数

中图分类号: TP183;TN98

文献标识码: A

国家标准学科分类代码: 520.2

YOLOv8 algorithm is improved in the defect detection of wind turbine blades applications

Zeng Yongjie Fan Bishuang Yang Yawen Jiang Chong

(School of Electrical and Information Engineering, Changsha University of Science and Technology, Changsha 410000, China)

Abstract: Wind turbine blades, being the core component of wind power generation systems, have their health status directly impacting the overall power generation efficiency and operational safety. Addressing the challenges of blade defect detection, researchers delved into the YOLOv8n network and innovatively proposed the Efficient Multi-Scale Convolutional module (EMSCConv). This module effectively replaces the convolutional layers in traditional residual blocks, significantly reducing the interference of redundant features on detection results through grouped convolution techniques, thereby enhancing detection accuracy. Furthermore, in the detection head, a diverse set of attention mechanisms from Dynamic Head are incorporated. These self-attention mechanisms work in concert, spanning across different feature layers, to achieve precise perception of target scales, spatial locations, and detection tasks, vastly strengthening the comprehensive capabilities of the target detection module. Moreover, researchers innovatively integrated Inner-IoU, Wise-IoU, and MPDIoU, creatively proposing Inner-Wise-MPDIoU to replace the traditional CIoU loss function. This move not only improved the network's detection precision but also accelerated the convergence process. During testing on a self-made dataset of wind turbine blade defects, YOLOv8-EDI exhibited remarkable performance, achieving an mAP50 value of 81.0%, a 2.3% increase compared to the original YOLOv8n. The recall rate also reached 76.8%, marking a 3.7% improvement. While enhancing detection performance, this model managed to reduce computational requirements by 5.5%, fully meeting the need for efficient, accurate, and large-scale blade defect detection in industrial settings.

Keywords: wind turbine blades; defect detection; YOLOv8n; efficient multi-scale convolution; Dyhead; loss function

0 引言

随着风力发电技术的迅速发展,风机叶片作为风力发电机的核心组成部分,其结构完整性和性能稳定性对系统的可靠运行起着至关重要的作用。然而,叶片在长期运行中受到自然环境和机械应力的影响,可能会出现各种缺陷,如裂纹、划痕、腐蚀等,这些缺陷可能影响风机的性能、降低能量转换效率,甚至危及整个风力发电系统的安全运行。

风力涡轮机叶片的缺陷或损坏不仅会降低风力涡轮机的使用寿命和发电效率,还会增加监控误差、安全风险和维护成本。Du 等^[1]全面回顾了风力涡轮机最先进的损伤检测技术,包括大多数基于应变测量、声发射、超声波、振动、热成像和机器视觉的更新方法。叶片缺陷的差异和叶片缺陷图像的缺失使得风力涡轮机叶片的缺陷识别具有挑战性。Li 等^[2]研究了基于卷积神经网络(CNN)的风电叶片无损检测缺陷分类方法。风机叶片是风机中最昂贵和最暴露的部件,存在许多缺陷,主要是裂纹和侵蚀,这会降低其性能。Rizk 等^[3]描述了高光谱成像在图像采集、处理和缺陷识别以及裂缝和侵蚀检测中的实现。传统的风力发电机叶片缺陷检测方法主要是人工检测和声学无损检测,既不安全又费时,精度低。为了更安全、更方便、更准确地检测风力发电机叶片上的缺陷,Deng 等^[4]研究了一种基于数字图像处理的风力发电机叶片缺陷检测方法。Raišutis 等^[5]研究了一种基于超声导波相速度变化的新型风力涡轮机叶片缺陷估计方法。提出了使用新准则评估风力涡轮机叶片的可靠性,基于最大值和最小值之间的中间值,相速度阈值的计算用于缺陷检测、定位和尺寸确定。及早有效地检测风力涡轮机叶片表面缺陷,可以避免复杂且昂贵的维修问题和严重的安全隐患。Zhang 等^[6]提出了一种基于无人机图像分析 YOLOv5 的风力涡轮机表面缺陷检测高精度模型 SOD-YOLO。由于风力发电机叶片长期暴露在恶劣环境中,非常容易产生缺陷,并可能造成严重的经济损失,因此 Shao 等^[7]提出了一种基于多尺度 Retinex 算法的缺陷检测方法。实验结果良好,能满足风力发电机叶片缺陷检测的实际应用要求。

综上所述,机器视觉在风机叶片缺陷检测方面有很好的应用前景,但目前对微小缺陷和复杂背景下的缺陷检测能力有待提高。当前经典的深度学习目标检测方法通常可以分为两大类^[8]:单阶段目标检测方法和二阶段目标检测方法。单阶段检测器是一类直接从输入图像中预测目标位置和类别的检测器。它们通过在图像上应用一系列的卷积和池化操作,以不同的尺度和宽高比来检测目标。常见的单阶段检测器包括文献[9]中的 SSD 和

文献[10]中的 YOLO(you only look once)系列等。两阶段检测器首先生成一组候选框,然后对这些候选框进行分类和位置精修。第一阶段通常被称为“提取候选框”或“区域生成”,而第二阶段则负责“分类和回归”。这种两阶段的设计使得它们在准确性上通常优于单阶段检测器,但也使得它们相对较慢。常见的两阶段检测器包括 R-CNN 系列(region-based convolutional neural networks)如文献[11]介绍的 Fast R-CNN 和文献[12]介绍的 Faster R-CNN 等,以及一些改进版本如文献[13]介绍的 Mask R-CNN。

因为风机叶片缺陷检测需要足够的检测速度,同时 YOLO 系列模型经过多次发展迭代,已经有了足够的准确率,故选用 YOLOv8n 作为基准模型来进行改进,提出了 YOLOv8-EDI 检测网络,首先优化了残差模块中的卷积操作,使得特征提取时更加的有效率,同时减少了特征冗余的影响;然后在检测头部分加入了尺度、空间、任务感知注意力机制,加强了目标检测模块的表征能力;最后优化了损失函数,与 YOLO 系列算法相比,mAP50 有了明显提高,同时参数量也有了一定的降低。

1 YOLOv8 目标检测算法

YOLOv8 是 YOLO 系列目标检测算法的最具代表性的版本。该算法构建在 YOLOv5 的基础上,通过引入一系列创新和改进,旨在提升模型性能,特别是在目标检测的精度和鲁棒性方面。以下是 YOLOv8 的主要特点:

1.1 头部结构改动

YOLOv8 采用了解耦头结构,将分类头和检测头分离。这种结构的变化使得模型能更好地学习目标类别信息和位置信息。与此同时,采用了 Anchor-Free 检测结构,摒弃了传统的需要预定义 Anchor 框的设计,直接回归目标的位置,提高了检测的鲁棒性。

1.2 损失函数的改进

引入了 Task Aligned Assigner 的动态正样本分配策略,根据任务需求动态分配正样本,提高了模型对不同类别的学习效果。采用 Distribution Focal Loss 作为新的损失函数的一部分,有助于处理难以训练的样本,提高模型在困难样本上的性能。

1.3 新的骨干网络

YOLOv8 的骨干网络借鉴了 YOLOv7 的 ELAN 设计思想。此外,将 YOLOv5 的 C3 结构替换为更丰富梯度流的 C2f 结构,通过调整不同模型的通道数,大幅提高了模型性能。

1.4 训练技巧

引入一些新的训练技巧,包括采用 Mosaic 数据增

强,通过在大图像上进行训练提高模型对目标的上下文理解。此外,在最后的几次迭代中关闭 Mosaic 增强,有效提升了模型的精度。

1.5 多尺度模型

YOLOv8 提供了 N/S/M/L/X 5 种尺度大小不同的

模型,根据网络的缩放系数,以适应不同的应用场景和硬件要求。

总体而言,YOLOv8 力求通过这些改进和创新来全面提高目标检测任务的性能,使其成为全新的 SOTA (State-of-the-Art)模型。YOLOv8n 的结构如图 1 所示。




图 1 YOLOv8 的网络结构
Fig. 1 YOLOv8 network model diagram

2 改进 YOLOv8n 目标检测算法

2.1 高效多尺度卷积 (EMSCnv)

常见的 CNN 神经网络中有许多特征图的冗余,特征图的冗余就是指特征相似的某一维度的卷积输出^[14]。为了减小冗余的特征图对训练的干扰,提出了一种全新的卷积方式,并将其命名为高效多尺度卷积 (efficient multi-scale Conv, EMSCnv)。EMSCnv 在进行卷积时,可

以选择性的忽略一部分特征图,不对它进行任何操作,再将其他的特征图分成 4 个组,分别对这 4 个组的特征图进行 1×1、3×3、5×5、7×7 的卷积特征提取操作,这些特征是在单一的特征通道上完成的,各个通道特征之间的信息是相互独立的。为了将这些通道特征进行融合,本文使用逐点卷积的方式将各个特征信息融合,具体方法^[15]就是用 1×1 卷积将各个卷积提取出来的特征进行特征交换。EMSCnv 运行原理如图 2 所示。




图 2 EMSCnv 运行原理
Fig. 2 EMSCnv operation principle

将 Bottleneck 中第 2 个卷积块替换成 EMSCnv,以此来剔除掉冗余的特征图,因为对于冗余的部分没有进行卷积操作,这样的设计使得计算量变得更少,同时没有冗

余特征的干扰,识别的精确度也有所上升,具体结果如表 1 所示,具体改进结构如图 3 所示。

表 1 EMSConv 与 YOLOv8 的对比实验结果

Table 1 Comparison of experimental results between EMSConv and YOLOv8

网络	mAP50/%	mAP50~95/%	Parameters
YOLOv8n	78.7	55.5	3 006 038
YOLOv8n+EMSConv	79.3	56.2	2 871 382




图 3 改进后的 Bottleneck
Fig. 3 Improved Bottleneck

2.2 动态检测头 (Detect_Dyhead)

动态头机制 (dynamic head)^[16]通过在统一框架内整合尺度感知、空间感知和任务感知的注意力机制,通过在特征的不同维度(层级、空间和通道)上分别部署注意力机制,动态头显著提高了对象检测头的表示能力,而不增加任何计算开销。

动态头的核心是将尺度、空间和任务感知的注意力集成为一个统一的框架,通过在输入特征的 3 个维度上应用自注意力机制来实现。

这种方法包括 3 个关键组件:

1) 尺度感知注意力

仅在层级维度上部署,学习不同语义层级的相对重要性,以便根据对象的尺度适当增强特征。

2) 空间感知注意力

在空间维度(即高度×宽度)上部署,学习空间位置上连贯的区分性表示。

3) 任务感知注意力

部署在通道上,根据不同卷积核对对象的响应,引导不同的特征通道分别偏好不同的任务(如分类、边框回归和中心点学习)。

动态头通过在特征张量的不同维度上应用这些注意力机制,使得每个维度的性能可以相互补充,其核心注意力机制的公式可以表示为:

$$W(F) = \Pi(F) \times F \quad (1)$$

其中, $\Pi(\cdot)$ 表示应用于特征张量 F 的注意力函数。这个函数进一步分解为 3 个连续的注意力,每个注意力针对特征张量的不同维度(层次、空间和通道):

$$W(F) = \Pi_c(\Pi_s(\Pi_L(F))) \times F \times F \times F \quad (2)$$

这些公式展示了动态头是如何基于它们的语义层次、空间位置和与任务相关的通道动态调整特征的焦点和处理,从而使得检测精度大幅度提升。Dyhead 块的结构如图 4 所示。




图 4 Dyhead 的结构
Fig. 4 Structure of Dyhead

综上所述, Dyhead 结构有效的解决了尺度变化、空间位置和多任务处理等挑战。对于风机叶片缺陷检测来说,解决这些问题能够大幅度的提高检测精度,因此,本研究通过将注意力机制整合进目标检测模块中,利用多个自注意力机制之间的协同作用,跨特征层实现尺度、空间以及任务感知,显著增强了目标检测模块的表征能力,同时并未引入额外的计算负担^[17]。将其命名为 Detect_Dyhead,具体结构如图 5 所示。

2.3 改进损失函数

1) Wise-IoU

Wise-IoU^[18]是一种基于交并比(IoU)的改进损失函数,旨在优化目标检测任务中边界框回归的性能。Wise-IoU 通过引入一个动态非单调聚焦机制,能够根据样本的质量动态调整损失函数的权重,特别是针对中等质量的样本,从而减少低质量样本对模型训练的干扰,提高检测准确性。

Wise-IoU 的核心思想是利用锚框的离群度(即样本与其他样本在特征空间中的相对位置)来评估样本的质量,并根据该质量动态调整损失函数中各部分的权重。这种方法允许模型更加关注于那些质量中等,但对模型性能提升有重要贡献的样本。

Wise-IoU 的动态聚焦系数 r 的计算公式为:

$$r = \frac{\beta}{\delta\alpha\beta - \delta} \quad (3)$$

其中, β 表示锚框的离群度,用于区分不同质量的样本; δ 和 α 是控制聚焦系数调整幅度的参数。 β 的计算公式为:

$$\beta = \frac{L_{IoU}^*}{L_{IoU}} \quad (4)$$

其中, L_{IoU}^* 表示调整后的 IoU 值,可能是通过某种方


$$L_{Inner-IoU} = 1 - IoU_{inner} \quad (10)$$




图 8 各类缺陷示意图

Fig. 8 Schematic diagram of defects

表 2 深度学习的实验配置

Table 2 Experimental configuration for deep learning

配置环境	配置名称(版本)
操作系统	Windows10
CPU	AMD Ryzenn Threadripper 3990X 64-Core Processor
GPU	NVIDIA Geforce RTX 4090(24 GB)
编译器	Python 3. 8
深度学习框架	Pytorch 2. 1. 2
加速模块	CUDA 12. 2

表 3 实验超参数的设置

Table 3 Setting of experimental hyperparameters

参数	含义	参数值
epochs	迭代轮数	300
patience	早停触发轮数	50
batch_size	批数量	16
images_size	图像尺度	640
lr	学习率	0. 01
Momentum	学习率动量	0. 937
Optimizer	优化器	SGD

3.3 评价指标

为了评估 YOLOv8n 的改进效果,从 4 个指标对模型进行评估:平均精度 AP、平均精度均值 mAP、精确度 P、召回率 R。

混淆矩阵是对分类问题预测结果的总结。使用计数值汇总正确和不正确预测的数量,并按每个类进行细分,显示了分类模型进行预测时会对哪一部分产生混淆。通过这个矩阵可以方便地看出机器是否将两个不同的类混淆了,把一个类错认成了另一个,混淆矩阵具体如表 4 所示。

表 4 分类结果的混淆矩阵

Table 4 Confusion matrix of classification results

真实情况	预测结果	
	正例	反例
正例	TP	FN
反例	FP	TN

混淆矩阵以矩阵形式将数据集中的记录按照真实的类别与分类模型预测的类别判断两个标准进行汇总。其中矩阵的行表示真实值,矩阵的列表示预测值。

TP(true positive):将正类预测为正类数 即正确预测,真实为 0,预测也为 0。

FN(false negative):将正类预测为负类 即错误预测,真实为 0,预测为 1。

FP(false positive):将负类预测为正类数 即错误预测,真实为 1,预测为 0。

TN(true negative):将负类预测为负类数,即正确预测,真实为 1,预测也为 1。

精确率 P 是指在预测是 Positive 的所有结果中,预测正确的比重。计算公式为:

$$P = \frac{TP}{TP + FP}$$
 (12)

召回率 R 是指在真实是 Positive 的所有结果中,预测正确的比重。计算公式为:

$$R = \frac{TP}{TP + FN}$$
 (13)

AP 是指某类型缺陷的平均精度,计算公式为:

$$AP = \int_0^1 P(R) dR$$
 (14)

mAP 是指所有类型缺陷的平均均度的均值,计算公式为:

$$mAP = \frac{1}{n} \sum_{i=1}^n AP(i)$$
 (15)

其中,n 为缺陷类别的数量。

3.4 消融实验

为了证明提出的改进模型的有效性,在 YOLOv8 的基础上对各个模块进行消融实验。首先将残差模块中的第 2 个卷积替换为高效多尺度卷积模块,然后在检测头部份引入动态头中的尺度感知注意力、空间感知注意力和任务感知注意力,最后将 Ciou 替换成 Inner-Wise-MPDIoU,生成最终的 YOLOv8-EDI 改进模型,与 YOLOv8n 进行对比,采用上一小章的评价指标进行评估。消融实验结果如表 5 所示,表中×代表模型未加入该模块,√则表示添加了该模块。

表 5 消融实验结果

Table 5 Ablation study results

检测模型	EMS-Conv	Dynamic Head	Inner-Wise-MPDIoU	P	R	AP		mAP50
						开裂	腐蚀	
YOLOv8n	×	×	×	0. 801	0. 731	0. 633	0. 911	0. 787
Model 1	√	×	×	0. 78	0. 752	0. 668	0. 917	0. 793
Model 2	√	√	×	0. 82	0. 746	0. 678	0. 92	0. 799
Model 3	√	√	√	0. 812	0. 768	0. 687	0. 932	0. 81

从实验结果可以看到,YOLOv8-EDI 对比 YOLOv8n

检测精度有了较为明显的提升,并且在第 2 章提到,EMSCnv 能够对 YOLOv8n 进行较为有效的蒸馏,同时另外两项改进并不会带来额外的计算负荷,从表 1 可以看出,改进后的网络结构的参数量降低了 5.5%。综上所述,YOLOv8-EDI 网络在减小了计算量的同时,还具有更加精确的检测能力,能够满足风机叶片缺陷检测任务的需求。图 9 为改进后的模型训练过程中的 dfl 损失和 mAP50,可以看出模型已经收敛,图 10 为部分结果的一个置信度评分,表示模型对该检测结果的确信程度,高置信度评分通常意味着检测结果更可信。




图 9 训练过程中的各个参数
Fig. 9 Various parameters in the training process




图 10 检测结果置信度评分
Fig. 10 Test result confidence score

3.5 东北大学钢材表面缺陷检测实验

为了验证 YOLOv8-EDI 模型的推广性,需要选取一个和风机叶片表面缺陷检测类似的数据集进行对比实验。选取了东北大学钢材表面缺陷数据集,使用改进前后的 YOLOv8n 算法在该数据集上进行对比实验。该数据集包含了裂纹、夹杂、斑块、麻点、轧入氧化皮和划痕 6 种缺陷,其中裂纹、夹杂、斑块和麻点缺陷和风机叶片表面缺陷类似,通过对比改进前后的算法对这 4 个缺陷的检测精度,以此验证改进后的算法在其他相似的缺陷检测任务中也能取得良好的效果。

与原始 YOLOv8n 算法相比较,YOLOv8-EDI 在裂纹、夹杂、斑块和麻点 4 种缺陷下的 mAP@ 0.5 分别提高了

18.0%,5.7%,0.1%,5.5%,证明该算法对其他类似的缺陷检测的性能有一定的提升,具体结果如表 6 所示。

表 6 钢材表面缺陷检测实验结果

Table 6 Test results of steel surface defect detection

算法模型	mAP50			
	裂纹	夹杂	斑块	麻点
YOLOv8n	0.614	0.755	0.981	0.94
YOLOv8-EDI	0.794	0.812	0.982	0.995

3.6 模型对比实验

为了评估 YOLOv8-EDI 在风机叶片缺陷检测上的性能,将 YOLOv8-EDI 与 RT-DETR^[21]、YOLOv5n 这些目前主流的目标检测算法以及最新提出的 YOLOv9^[22] 算法进行比较,实验结果如表 7 所示。

表 7 模型对比实验结果

Table 7 Model comparison experimental results

算法模型	P	R	mAP50	Np/106
RT-DETR	0.634	0.572	0.629	28.4
YOLOv5n	0.763	0.719	0.784	2.5
YOLOv8n	-0.801	0.731	0.787	3.0
YOLOv9	0.797	0.741	0.794	4.2
YOLOv8-EDI	0.812	0.768	0.81	2.8

通过上表可以看出,RT-DETR 采用的是 Transformer 的自注意力机制来处理图像数据,这使得模型能够更有效地理解图像中不同部分之间的关系,这种方式对于处理复杂场景和多对象环境时,能够展现出更高的准确性和效率,但显然 RT-DETR 在风机叶片缺陷检测时效果一般,同时还需要巨大的计算量。YOLOv8-EDI 由于优化了残差模块中的卷积操作,使得特征提取时更加的有效率,同时减少了特征冗余的影响;并且在检测头部分加入了尺度、空间、任务感知注意力机制,加强了目标检测模块的表征能力;最后优化了损失函数,与 YOLO 系列算法相比,mAP50 有了明显提高,同时参数量也有了一定的降低。这些数据充分证明了 YOLOv8-EDI 在风机叶片缺陷检测上的优越性能和高效准确度。

4 结 论

目前风机叶片缺陷检测缺乏有效的方法,提出了一种全新的无损检测算法来进行风机叶片缺陷检测,针对大量相似特征的情况提出了一种新的卷积方式减少了计算量,并且消除了冗余特征的影响;针对复杂的风机叶片缺陷,改进了检测头部,结合多个自注意力机制之间的协同作用,跨特征层实现尺度、空间以及任务感知,显著增

强了目标检测模块的表征能力;同时将损失函数进行了替换,提出了全新的 Inner-Wise-MPDIoU,结合3种损失函数的优势,有效提高了收敛速度。通过这些创新性改进,能够显著提升 YOLOv8 模型在风机叶片缺陷检测任务中的性能和应用价值。

YOLOv8-EDI 与原始 YOLOv8n 相比, mAP50 值由 78.7% 提升至 81.0%, 提升了 2.3%; 召回率由 73.1% 提升至 76.8%, 提升了 3.7%; 参数量降低了 5.5%。

在风机叶片缺陷检测精度方面, YOLOv8-EDI 的 mAP50 值和召回率高于 RT-DTER、YOLOv5n 以及最新的 YOLOv9, 并且因为风机叶片缺陷检测需要足够的检测速度, 所以二阶段目标检测网络并不适用于风机叶片缺陷检测。综上, YOLOv8-EDI 对风机叶片缺陷有更好的定位能力和检测精度, 检测速度能够满足工业大批量检测的要求。

在未来的工作中, 研究者将致力于进一步优化 YOLOv8-EDI 模型, 通过轻量化技术提升计算效率, 增强实时性与动态适应性以适应复杂多变的工业环境。同时, 探索多源数据融合与自动化智能化集成, 提升模型在风机叶片缺陷检测中的全面性和准确性。此外, 针对风机内部的缺陷检测, 考虑制作风机叶片热成像数据集到 YOLOv8-EDI 中进行训练, 以此来增强风机叶片缺陷检测的全面性。

参考文献

- [1] DU Y, ZHOU S, JING X, et al. Damage detection techniques for wind turbine blades: A review [J]. Mechanical Systems and Signal Processing, 2020, 141 (prepublish): 106445-106445.
- [2] LI T, YANG Y, WAN Q, et al. Investigation of wind turbine blade defect classification based on deep convolutional neural network [C]. Proceedings of the 9th International Conference on Computer Engineering and Networks. Springer Singapore, 2021: 207-213.
- [3] 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.
- [4] DENG L W, GUO Y G, CHAI B R. Defect detection on a wind turbine blade based on digital image processing [J]. Processes, 2021, 9(8): 1452-1452.
- [5] RAIŠUTIS R, TIWARI K A, ŽUKAUSKAS E, et al. A novel defect estimation approach in wind turbine blades based on phase velocity variation of ultrasonic guided waves [J]. Sensors, 2021, 21(14): 4879.
- [6] ZHANG R, WEN CH B. SOD-YOLO: A small target

- defect detection algorithm for wind turbine blades based on improved YOLOv5 [J]. Advanced Theory and Simulations, 2022, 5(7), DOI:10.1002/adts.202100631.
- [7] SHAO W, TIAN H, CHEN X. Industrial equipment defect detection based on multi-scale retinex algorithm [C]. Sixth International Conference on Computer Information Science and Application Technology (CISAT 2023). SPIE, 2023, 12800: 13-17.
- [8] 邵延华, 张铎, 楚红雨, 等. 基于深度学习的 YOLO 目标检测综述 [J]. 电子与信息学报, 2022, 44(10): 3697-3708.
SHAO Y H, ZHANG D, CHU H Y, et al. Review of YOLO object detection based on deep learning [J]. Journal of Electronics & Information Technology, 2022, 44(10): 3697-3708.
- [9] 赵永强, 饶元, 董世鹏, 等. 深度学习目标检测方法综述 [J]. 中国图象图形学报, 2020, 25(4): 629-654.
- [10] ZHAO Y Q, RAO Y, DONG SH P, et al. Review of deep learning-based object detection methods [J]. Journal of Image and Graphics, 2020, 25(4): 629-654.
- [11] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [12] GIRSHICK R. Fast R-CNN [C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [13] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. Advances in Neural Information Processing Systems, 2017, 39(6): 1137-1149.
- [14] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2961-Z2969.
- [15] HAN K, WANG Y, TIAN Q, et al. GhostNet: More features from cheap operations [C]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2020: 1577-1586.
- [16] SANDLER M, HOWARD A, ZHU M, et al. Mobilenetv2: Inverted residuals and linear bottlenecks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.
- [17] DAI X, CHEN Y, XIAO B, et al. Dynamic head: Unifying object detection heads with attentions [J].

Computer Vision and Pattern Recognition, 2021, DOI: 10.48550/arXiv.2106.08322.

[18] 于范, 张菁. 滑窗注意力多尺度均衡的密集行人检测算法[J]. 计算机科学与探索, 2024, 18(5): 1286-1300.

YU F, ZHANG J. Dense pedestrian detection based on shifted window attention multi-scale equalization[J]. Journal of Frontiers of Computer Science and Technology, 2024, 18(5): 1286-1300.

[19] TONG Z, CHEN Y, XU Z, et al. Wise-iou: Bounding box regression loss with dynamic focusing mechanism[J]. ArXiv preprint arXiv:2301.10051, 2023.

[20] SILIANG M, YONG X. Mpdious: A loss for efficient and accurate bounding box regression[J]. ArXiv preprint arXiv:2307.07662, 2023.

[21] ZHANG H, XU C, ZHANG S. Inner-iou: More effective intersection over union loss with auxiliary bounding box[J]. ArXiv preprint arXiv:2311.02877, 2023.

[22] LYU W, XU S, ZHAO Y, et al. Dets beat yolos on real-time object detection[J]. ArXiv preprint arXiv:2304.08069, 2023.

作者简介



曾勇杰, 2021 年于黑龙江科技大学获得学士学位, 现为长沙理工大学硕士研究生, 主要研究方向为深度学习。
E-mail: 1472199677@qq.com

Zeng Yongjie received his B. Sc. degree from Heilongjiang University of Science and Technology in 2021. He is currently a M. Sc. candidate at Changsha University of Science and Technology. His main research interest includes deep learning.



范必双 (通信作者), 2002 年进入长沙理工大学工作, 2014 年博士毕业于中南大学, 获控制科学与工程专业博士学位, 2014 年晋升副教授, 2016 年在美国田纳西大学做访学学者, 2022 年晋升教授。

E-mail: fanbishuang@qq.com

Fan Bishuang (Corresponding author) He joined Changsha University of Science and Technology in 2002, received a Ph. D. degree in Control Science and Engineering from Central South University in 2014, was promoted to associate professor in 2014, was a visiting scholar at the University of Tennessee in 2016, and was promoted to professor in 2022.