

文章编号 1004-924X(2024)21-3222-09

基于改进 YOLOv8 模型的增材制造微小气孔 缺陷检测及其尺寸测量

蔡引娣*, 张殿鹏, 孙梓盟, 王宇轩, 朱祥龙, 康仁科
(大连理工大学 机械工程学院, 辽宁 大连 116024)

摘要:针对增材制造零件表面小缺陷检测中存在的准确率低和尺寸测量困难的问题,基于改进的 YOLO v8 提出了一种缺陷检测方法。在 YOLOv8 模型的检测头部引入高效通道注意力机制模块,同时采用加权交并比损失函数替换原有损失函数,减少低质量样本影响,提升检测精度。针对高分辨率图像数据集训练困难且易出现过拟合的问题,在训练阶段对包含目标缺陷的局部特征以中心为基准进行裁剪的方法生成训练集。在推理阶段,采用滑窗切分法将待测高分辨率图像裁剪成一组小图像进行预测,从而得到缺陷图像块。检测后的缺陷图像块被视为感兴趣区域,并通过计算机视觉中的边缘检测方法实现缺陷尺寸的精密测量。实验证明,改进模型的准确率达 94.3%,召回率为 93.3%,mAP50 达到 97.3%,缺陷尺寸的测量精度可达到 40 μm ,显著提升了增材制造零件表面缺陷的检测准确率。

关键词:精密测量;计算机视觉;深度学习;缺陷检测;高分辨率图片

中图分类号:TP394.1;TH691.9 **文献标识码:**A **doi:**10.37188/OPE.20243221.3222

YOLOv8 model-based additive manufacturing micro porosity defect detection and its dimension measurement

CAI Yindi*, ZHANG Dianpeng, SUN Zimeng, WANG Yuxuan, ZHU Xianglong, KANG Renke

(College of Mechanical Engineering, Dalian University of Technology, Dalian 116024, China)

* Corresponding author, E-mail: caiyd@dlut.edu.cn

Abstract: To address challenges related to low detection accuracy and poor dimensional measurement precision of small defects on metal additive manufacturing surfaces, this study proposes a novel defect detection method based on the You Only Look Once (YOLO) v8 model. The Efficient Channel Attention (ECA) module is integrated into the detection head of the YOLOv8 framework, and the Complete Intersection Over Union (CIoU) loss function is replaced with the Wise Intersection Over Union (WIoU) loss function, effectively mitigating the impact of low-quality samples and enhancing detection performance. To overcome difficulties associated with training on high-resolution image datasets, which often lead to overfitting, local features containing target defects are cropped during the training phase to generate the training dataset. During inference, high-resolution test images are divided into smaller sub-images using a sliding window approach for defect prediction. Detected defect sub-images are marked as regions of interest, and precise defect size measurement is achieved through edge detection techniques in computer vision. Experimental results demonstrate that

收稿日期:2024-07-10;修订日期:2024-08-28.

基金项目:国家重点研发计划资助项目(No. 2022YFB4600903);国家自然科学基金联合基金集成项目(No. U23B6005);中央高校基本科研业务费资助项目(No. DUT24MS005)

the improved model achieves a detection accuracy of 94.3%, a recall rate of 93.4%, and an mAP50 of 97.3%, significantly outperforming traditional methods. Furthermore, the dimensional measurement accuracy for small defects reaches $40\text{ }\mu\text{m}$, highlighting the effectiveness of the proposed approach.

Key words: precision measurement; computer vision; deep learning; defect detection; high-resolution images

1 引言

增材制造是一种通过逐层添加材料构建物体的制造技术,广泛应用于航空航天、医疗器械、汽车制造和新能源等领域。在增材制造过程中,熔池中的液态金属受温度梯度、材料特性等因素影响,常会产生缺陷^[1]。传统的缺陷检测方法包括人工检测、超声检测和激光扫描检测,但这些方法存在着耗时、低效和精度不高的问题。

近些年,基于深度学习的目标检测算法发展迅速。Wang^[2]等提出了一种改进的 Faster R 卷积神经网络 (Convolutional Neural Network, CNN) 缺陷检测方法,通过加入金字塔结构 (FPN) 以及可变卷积网络,提高了模型的检测精度以及速度。Kwon^[3]等针对缺陷的尺寸和纵横比,提出一种基于孪生模型与上下文感知图像调整的缺陷检测方法,自适应地处理不同尺度的待测图像。姚睿^[4]等针对移位窗口变换器进行改进,在主干网络中引入门控并行膨胀卷积层,提高了全局上下文信息的提取能力。吴承俊^[5]等在 ResNet 中引入 SRM 注意力机制,修改损失函数,添加分类训练特征编码器,提高特征提取能力。YOLO^[6-10]系列模型的演进也显著提升了目标检测的效果,通过结合注意力机制^[11]和交并比损失函数^[12-13]优化模型性能。Zhang^[14]等基于 YOLOv8 改进得到了 S-YOLO 模型,引入对小目标敏感的动态卷积,使用上下文增强模块替换 SPPF 模块,提高了特征图的质量。

尽管已有大量研究针对增材制造中的缺陷检测,但由于增材制造气孔缺陷具有形态多样、数量稀少、尺寸微小等特点,目前的研究大多集中在较大尺寸缺陷的检测上,未涉及微小尺寸气孔缺陷的测量。然而,气孔是增材制造中最常见的缺陷之一,其存在会减少结构的有效工作截面,并增加应力集中,从而降低结构的静强度和疲劳性能^[15]。为了准确检测增材制造中的微小气孔缺陷并实现高精度尺寸测量,本文采用高分

辨率工业相机对增材制造样件进行拍摄,获取清晰的微小气孔缺陷图像。针对高分辨率图像数据集训练困难且易过拟合的问题,结合原始数据集标注文件将数据集中包含缺陷的局部特征进行裁剪,形成易于模型训练的数据集。在推理阶段,使用滑窗切分法将待测图像裁剪成一组图片进行推理预测。此外,在 YOLOv8 检测头前嵌入高效通道注意力机制 (Efficient Channel Attention, ECA),将原有损失函数替换为 WIoU 损失函数,改善了原始模型检测精度不足的问题。

2 增材制造缺陷数据集采集

为了采集增材制造微小气孔缺陷数据集,设计的实验装置如图 1 所示,它主要由条形光源、待测件夹具和工业相机组成。




图 1 增材制造微小气孔缺陷检测实验装置

Fig. 1 Experimental setup for additive manufacturing microporosity defect detection

由于生产成本和时间效率的限制,制造大量带气孔缺陷的样本并不现实,导致收集的增材制造缺陷图像数据量有限,无法满足深度学习大数据集的训练需求。同时,高分辨率工业相机虽可捕获缺陷细节,但高分辨率图像直接训练模型计算成本高,容易产生过拟合。针对上述问题,本文首先采集 730 张 $4\ 504\times 4\ 096$ 的高分辨率图像。

利用数据集标注工具 LabelImg 对气孔缺陷位置信息进行标注,如图 2 所示。

根据标注的缺陷位置,以目标缺陷坐标中心为基准进行中心对齐裁剪,裁剪出尺寸为 $1\,472 \times 1\,472$ 的局部特征子图,确保每张子图中至少包含一个缺陷,从而将原始高分辨图像数据集转换成一个新的数据集。最终,共获得 4 721 张包含缺陷的图像数据集,以 8:2 的比例将其分为训练集和验证集,训练集共有 3 777 张图像,验

证集共有 944 张图像。

3 基于改进 YOLOv8 模型的缺陷检测

基于改进 YOLOv8 模型的微小气孔缺陷检测与尺寸测量流程如图 3 所示。首先,利用高分辨率工业相机采集图像。然后,使用专门的标注工具对图像中的微小缺陷进行精确标注。根据标注文件中的缺陷信息,对原始图像进行第 2 节所述的裁剪处理,将高分辨率图像划分为多个局部特征图像块。之后,将分块后的微小缺陷数据集输入到改进 YOLOv8 模型中进行训练。改进 YOLOv8 模型中增加 ECA 机制,并优化了其损失函数,从而提升了对微小缺陷的检测性能。在推理阶段,将高分辨率工业相机采集到的待测高分辨率图像进行滑窗分块处理,然后将子图像逐个送入目标检测模型中,以提取缺陷信息。最后,将检测到的缺陷信息映射回原图,从而确定具体的缺陷图像块。为了进一步分析微小缺陷,使用视觉算法对缺陷图像进行处理,检测微小气孔缺陷的边缘轮廓进而拟合缺陷轮廓的外接圆,以准确测量微小缺陷的尺寸。




图 2 数据集制作
Fig. 2 Dataset production

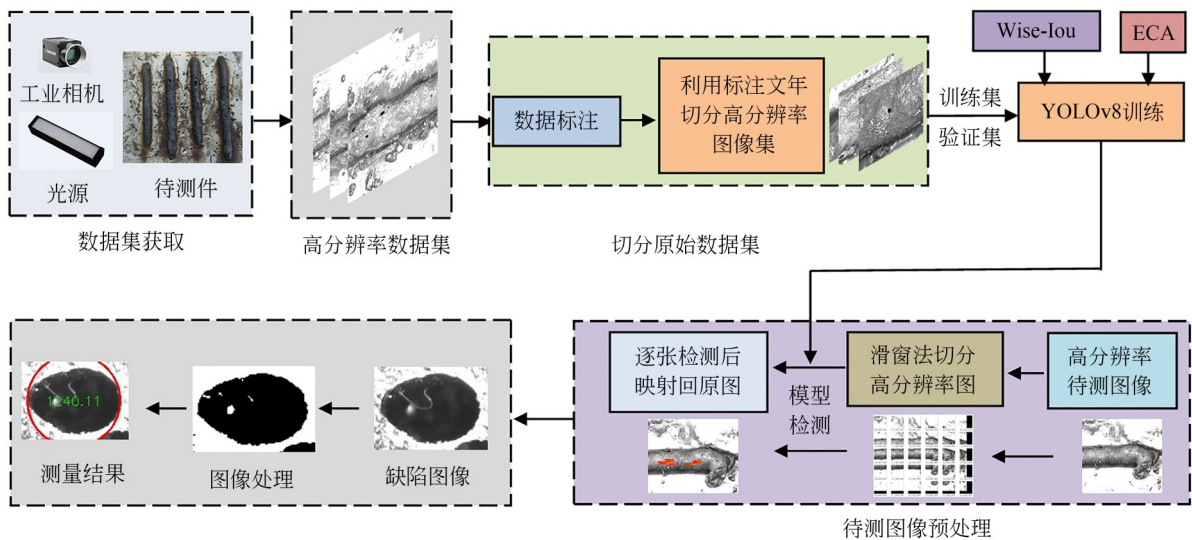


图 3 增材制造微小缺陷检测以及尺寸测量整体流程
Fig. 3 Workflow of proposed additive manufacturing defect detection and size measurement methods

YOLO 模型是一种基于深度卷积神经网络的实时目标检测模型。YOLOv8 模型由 Backbone,

Neck 和 Head 三部分组成,如图 4 所示。其中,Backbone 部分负责从输入的缺陷图像中提取多尺

度特征,这是特征提取的核心阶段。Neck 部分对提取到的特征进行融合和增强处理,以提高特征表示的丰富性和判别力。增强后的特征图被送入 Head 部分,在这一阶段,模型执行目标位置的回归和目标类别的分类,从而实现对微小缺陷的精

确定位和识别。尽管 YOLOv8 模型在目标检测任务中表现优异,但为了进一步提升它在微小缺陷检测中的性能,本文引入 ECA 机制,并优化了损失函数,为工业应用提供更加可靠和精确的检测工具。改进后的 YOLOv8 模型如图 5 所示。




图 4 YOLOv8 模型结构示意图

Fig. 4 Structure of YOLOv8 model




图 5 改进 YOLOv8 模型结构示意图

Fig. 5 Structure of improved YOLOv8 model

3.1 ECA 模块

针对增材制造气孔缺陷尺寸微小,难以检测的问题,在 YOLOv8 模型检测头中嵌入 ECA 机制。ECA 模块采用自适应方法调整通道特征的权重,使网络更加关注与缺陷相关的通道信息,减少了背景冗余信息的干扰。相比于常用的 SE 和 CBAM 注意力机制,ECA 具有较低的计算复杂度和较少的参数量,能够有效地提升特征表达能力,同时避免计算资源的过度消耗。

在 ECA 模块中,首先对输入的缺陷特征图进行全局平均池化,将原始 (N, C, H, W) 形式的特征图压缩为 $(N, C, 1, 1)$ 形式,以实现全局上下文信息的交互。接着,使用尺寸为 k 的一维卷积核对压缩后的特征图进行处理,确保跨通道交互的覆盖范围与通道维度成比例。其中,一维卷积核 k 影响感受野的范围和通道间依赖的捕捉能力。较小的 k 值捕捉局部信息,计算效率高;较大的 k 值捕捉全局信息,但计算开销更大。 k 值^[11]为:

$$k = \sigma \left(\frac{\log(C)}{\gamma} + \frac{b}{\gamma} \right), \quad (1)$$

其中: $\sigma(X)$ 为取整函数, C 为输入的通道数, γ 和 b 为常数,取值分别为 2 和 1。

使用一维卷积计算得到每个通道的权重,并通过激活函数将权重映射到 0~1 之间。最终,将得到的权重值通过乘法加权到原始的输入特征图中,从而增强特征表达能力。

模型的 Neck 部分对缺陷特征进行融合和增强处理后,生成 3 个不同尺度的特征图。这些特征图经过 ECA 模块处理,进一步增强了特征表示的有效性。最后,处理后的 3 个尺度的特征图被送入模型检测头部分,实现对微小缺陷的精确检测。

3.2 损失函数优化

针对缺陷检测模型收敛缓慢以及预测精度低的不足,本文使用 WIoU 损失函数替换 CIoU 损失函数。WIoU 通过引入加权因子,更加灵活地调整对重叠区域和非重叠区域的关注,能够有效平衡样本难易程度,提高模型的收敛速度和预测精度。

IoU 损失函数可以表示为:

$$L_{IoU} = 1 - \frac{A \cap B}{A \cup B}, \quad (2)$$

其中: A 表示真实边界框, B 表示预测边界框, $A \cap B$ 表示 A 和 B 的交集, $A \cup B$ 表示 A 和 B 的并集。

图 6 为 WIoU 损失函数的几何关系示意图。根据真实边界框和预测边界框的质心坐标以及包含这两个框的最小外接矩的几何尺寸,WIoU 的系数 R_{WIoU} 可以表示为:

$$R_{WIoU} = \exp \left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*} \right), \quad (3)$$

其中: x_{gt}, y_{gt} 表示真实边界框的中心坐标, x, y 表示预测边界框的中心坐标, W_g 和 H_g 分别表示包含两个边界框的最小外接矩的长度和宽度。

因此,WIoU 损失函数可以表示为:

$$L_{WIoUv1} = R_{WIoU} L_{IoU}. \quad (4)$$

真实边界框的质量可以用异常值来描述,其中异常值 β 定义如下:

$$\beta = \frac{L_{IoU}^*}{L_{IoU}} \in [0, \infty). \quad (5)$$

根据 β 构造一个非单调聚焦因子,并将该非单调聚焦因子应用于 WIoU 损失函数。因此,式 (4) 可以修改为:

$$L_{WIoUv3} = \frac{\beta}{\delta \alpha^{\beta - \delta}} L_{WIoUv1}, \quad (6)$$

其中 α 和 δ 为常数,取值分别为 2.5 和 2。




图 6 WIoU 几何示意图

Fig. 6 Geometric schematic of WIoU

WIoU 损失函数通过引入真实边界框离群度的定义,动态地分配梯度增益,从而优化检测模型的性能。具体而言,真实边界框的 β 值越小,代表该缺陷样本的质量越高;反之, β 值越大,代表该缺陷样本的质量越低。通过将高质量边界框分配更高的梯度增益,而将低梯度增益分配给低

质量真实边界框,模型能够更加精确地关注高质量样本。这一策略在增材制造微小气孔缺陷检测中尤为重要,因为缺陷的形态复杂多样,通过动态分配梯度增益,高质量缺陷样本可以在模型训练中获得更高的权重占比,有效提高缺陷预测的准确性,从而提升模型在实际应用中的性能和可靠性。

3.3 推理阶段

虽然本研究采用 WIoU 损失函数改善模型收敛缓慢和预测精度不足的问题,并使用分块处理后的低分辨率图像数据集进行增材制造微小缺陷检测模型训练以提高计算速率,但是,在推理阶段仍然需要对原始高分辨率图像进行识别。如图 7 所示,采用从上往下,从左往右有重叠的滑窗切分方法,将待测缺陷图像切分成一组符合缺陷检测模型输入尺寸的图像。




图 7 滑窗切分待测高分辨率图像

Fig. 7 Sliding window slicing of high-resolution images to be measured

然后,将该组低分辨率图像逐张送入目标检测模型,获取每张低分辨率图像的缺陷类别、置信度和坐标信息。针对每一组图像的缺陷信息,应用非极大值抑制进行筛选。非极大值抑制首先根据目标框的置信度对候选目标框进行排序,并按照置信度从高到低的顺序选择置信度最高的检测框作为参考框。然后,计算其余所有检测框与当前参考框的重叠程度,将重叠程度超过预设阈值的检测框从候选框列表中删除。最后,从剩余的候选框中选择下一个最高置信度的检测框作为新的参考框,重复上述过程,直至处理完所有候选框。非极大值抑制确保了检测结果的准确性和唯一性,从而得到最终的缺陷位置坐标信息。随后,将筛选后的坐标信息映射回高分辨

率原图上相应的坐标位置,准确还原缺陷的位置信息。此外,根据这些坐标信息,将包含缺陷的图像块部分裁剪保存,以便进行后续的尺寸测量和分析操作。这种处理流程不仅保留了原始图像的高分辨率信息,还能有效定位和分析图像中的缺陷区域,为后续的处理和分析提供可靠的依据。

4 缺陷尺寸测量

为了实现微小气孔缺陷的高精度尺寸测量,本文设计的边缘检测算法流程如图 8 所示。在获取增材制造微小缺陷的具体图像块后,首先利用相机标定信息进行去畸变处理,以校正图像中的几何畸变,如图 8 所示。接着,采用高斯滤波方法,通过权重中心的像素及其邻域内像素的加权平均去除图像中的随机噪声,以提高图像质量。同时,通过直方图均衡化重新分配图像的灰度级别,使得图像亮度更加均匀,提升边缘细节的清晰度,从而使得微小的缺陷在图像中更加显著。在此基础上,使用大津法对增强图像进行二值化处理,以有效分离缺陷区域和背景。随后,对二值图像应用形态学操作,如腐蚀和膨胀,以去除小的增材制造背景干扰物并保留主要缺陷特征。最后,




图 8 缺陷边缘检测算法流程

Fig. 8 Flowchart of defect edge detection algorithm

采用 Canny 算子通过计算图像梯度来识别并精确定位微小气孔缺陷的边缘信息,实现对微小气孔缺陷的边缘检测,并通过外接圆拟合计算气孔的直径,从而实现了对微小缺陷尺寸的精确测量。

5 实验结果与分析

5.1 缺陷识别实验

为了进一步验证基于改进 YOLOv8 模型的

增材制造微小气孔缺陷检测的有效性和精度,采用常用的 DETR 模型、Faster R-CNN 模型、YOLOv5 模型、YOLOv8 模型、增加 ECA 机制 YOLOv8 模型和增加 WIoU 损失函数 YOLOv8 模型对相同的训练集和验证集中的缺陷进行识别。上述几种模型的可视化结果如图 9 所示。由图 9 可知,对于增材制造中微小气孔缺陷,现有模型存在漏检的问题,改进的 YOLOv8 模型的缺陷检测准确率最高。




图 9 多种识别模型可视化结果对比
Fig. 9 Comparison of model results visualisation

同时,采用目标检测中的准确率(Precision, P)、召回率(Recall, R)以及平均精度(mean Average Precision at $\text{IoU}=0.50$, mAP50)作为评估指标,进一步比较几种模型的有效性和精度,结果如表 1 所示。由表 1 可知,改进的 YOLOv8 模型在各项指标上均最优。

表 1 多种缺陷识别模型评估指标对比

Tab. 1 Comparison of evaluation index among different defect detection models (%)

模 型	P	R	mAP50
DETR	81.4	81.6	84.1
Faster R-CNN	85.7	85.8	91.4
YOLOv5	84.5	82.8	89.3
YOLOv8	92.5	91.1	96.6
YOLOv8+ECA	92.4	91.4	96.0
YOLOv8+WIoU	93.2	93.1	96.9
改进 YOLOv8	94.3	93.3	97.3

5.2 测量精度验证

在获取 4 组包含缺陷的图像块后,首先转换为灰度图,并使用高斯滤波去除随机噪声。随后,针对微小气孔缺陷采用最小二乘法拟合外接圆,以准确测量其尺寸,如图 10 所示。




图 10 尺寸测量结果
Fig. 10 Size measurement results

表 2 为本文微小气孔缺陷测量结果与 500 nm 空间分辨率以及精度为 $18\text{ }\mu\text{m}$ 的 Xradia 610 Versa X 射线显微镜的拟合测量结果的对比。结果表明,本文方法对增材制造微小气孔缺陷的尺寸测量精度可以达到 $40\text{ }\mu\text{m}$,相对误差为 15.9%。

表 2 不同方法的尺寸测量结果对比
Tab. 2 Comparison of size measurements between different methods

组别	Xradia / μm	Ours / μm	Error / μm	Relative error/%
一	220	184.87	35.13	15.9
二	590	563.18	26.82	4.5
三	700	718.95	18.95	2.7
四	1 256	1 240.11	15.89	1.2

6 结 论

本文基于 YOLOv8 提出了改进 YOLOv8 微小气孔缺陷检测模型,实现了对增材制造的微小气孔缺陷的测量。改进 YOLOv8 模型通

过引入 ECA 机制提高对重要信息的关注度,将 CIoU 换成 WIoU 提高检测的精度以及稳定性,其检测微小气孔缺陷的精准率、召回率和平均精度值 mAP50 分别为 94.3%,93.3%,97.3%。将本文模型与 DETR 模型、Faster R-CNN 模型、YOLOv5 模型、YOLOv8 模型、增加 ECA 注意力机制 YOLOv8 模型和增加 WIoU 损失函数 YOLOv8 模型进行性能对比,实验结果表明,精准率、召回率和平均精度值 mAP50 均优于其他模型,检测性能最好,微小气孔缺陷的尺寸测量精度可以达到 40 μm 。本研究的重点是提升微小缺陷检测的准确率,在下一步研究中,将在保证检测准确率的前提下,进一步对微小缺陷检测模型进行轻量化改进,以提升检测时效性。

参考文献:

[1] 郭政亚,熊振华. 金属增材制造缺陷检测技术[J]. 哈尔滨工业大学学报, 2020, 52(5): 49-57.
GUO Z Y, XIONG ZH H. Defect detection technology in metal additive manufacturing[J]. *Journal of Harbin Institute of Technology*, 2020, 52(5): 49-57. (in Chinese)

[2] WANG J Y, MU C Y, MU S, *et al.* Welding seam detection and location: deep learning network-based approach[J]. *International Journal of Pressure Vessels and Piping*, 2023, 202: 104893.

[3] KWON J E, PARK J H, KIM J H, *et al.* Context and scale-aware YOLO for welding defect detection[J]. *NDT & E International*, 2023, 139: 102919.

[4] 姚睿,郎宪明,袁开欣,等. 基于改进的 Swin Transformer 的输油管道微小缺陷检测模型[J]. 管道技术与设备, 2024(3): 35-42, 47.
YAO R, LANG X M, YUAN K X, *et al.* Detection model of oil pipeline tiny defects based on improved swin transformer[J]. *Pipeline Technique and Equipment*, 2024(3): 35-42, 47. (in Chinese)

[5] 吴承俊,方夏,王杰,等. 基于改进 ResNet 两阶段训练模型的转子焊锡缺陷检测[J]. 工业控制计算机, 2023, 36(4): 115-116, 119.
WU CH J, FANG X, WANG J, *et al.* Rotor solder defect detection based on improved ResNet two stage training model[J]. *Industrial Control Computer*, 2023, 36(4): 115-116, 119. (in Chinese)

[6] REDMON J, FARHADI A. YOLO9000: better, faster, stronger [C]. 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. July 21-26, 2017. Honolulu, HI. IEEE, 2017: 6517-6525.

[7] REDMON J, FARHADI A. YOLOv3: an incremental improvement [J]. *arXiv e-prints*. 2018. <https://doi.org/10.48550/arXiv.1804.02767>, 2018.

[8] BOCHKOVSKIY A, WANG C Y, LIAO H. YOLOv4: optimal speed and accuracy of object detection [J]. *arXiv e-prints*. 2020. <https://doi.org/10.48550/arXiv.2004.10934>, 2020.

[9] LI C Y, LI L, JIANG H L, *et al.* YOLOv6: a single-stage object detection framework for industrial applications[J]. *ArXiv abs/2209.02976*, 2022.

[10] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]. 2023 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 17-24, 2023. Vancouver, BC, Canada. IEEE, 2023: 7464-7475.

[11] WANG Q L, WU B G, ZHU P F, *et al.* ECA-net: efficient channel attention for deep convolutional neural networks[C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 13-19, 2020. Seattle, WA,

- USA. IEEE, 2020: 11531-11539.
- [12] YU J H, JIANG Y N, WANG Z Y, *et al.* Unit-Box: an advanced object detection network [C]. *Proceedings of the 24th ACM international conference on Multimedia. Amsterdam The Netherlands*. ACM, 2016: 516-520.
- [13] ZHENG Z H, WANG P, LIU W, *et al.* Distance-IoU loss: faster and better learning for bounding box regression[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34 (7) : 12993-13000.
- [14] ZHANG Y, NI Q J. A novel weld-seam defect detection algorithm based on the S-YOLO model[J]. *Axioms*, 2023, 12(7): 697.
- [15] 张学军, 陈冰清. 航空典型金属材料增材制造组织、缺陷、表面、构型研究进展[J]. *航空材料学报*, 2024, 44(1): 1-14.
- ZHANG X J, CHEN B Q. Research progress on microstructure, defects, surface and configuration of additive manufactured typical aviation metals [J]. *Journal of Aeronautical Materials*, 2024, 44 (1): 1-14. (in Chinese)

作者简介:



蔡引娣(1988—),女,甘肃武威人,副教授,2012年于重庆大学获得硕士学位,2017年于日本东北大学获得博士学位,主要从事精密/先进测量技术、装备精度提升技术等研究。E-mail: caiyd@dlut.edu.cn



张殿鹏(1999—),男,安徽滁州人,硕士研究生,2021年于河南理工大学获得学士学位,主要从事目标检测,视觉精密测量方面的研究。E-mail: zhang-dianpeng@mail.dlut.edu.cn