

高速激光熔覆熔池动态捕获与分类判别研究^{*}

杜全斌^①, 王恩博^{②③}, 于亚辉^④, 白洁^{④⑤}, 吴俊峰^⑥, 王成武^⑦, 郭士锐^{②③}

(^①河南机电职业学院河南省超硬材料智能制造装备集成重点实验室, 河南 郑州 451192;

^②中原工学院智能机电工程学院, 河南 郑州 450007;

^③武汉纺织大学数字化纺织装备湖北省重点实验室, 湖北 武汉 430200;

^④中国船舶集团有限公司第七一三研究所, 河南 郑州 450015;

^⑤中船海为高科技有限公司, 河南 郑州 450001; ^⑥黄河科技学院工学部, 河南 郑州 450063;

^⑦浙江师范大学工学院, 浙江 金华 321004)

摘 要: 针对高速熔覆过程中传统熔池监测方法在复杂背景下响应速度慢、效率低且难以适配低算力设备的问题, 提出了一种轻量化 YOLOv5 网络。该网络采用轻量化网络 MobileNetV3 代替原先的主干网络结构, 用于熔池状态的动态捕捉与分类判别。此外, 结合高速熔覆设备自制包含 933 张的熔池图像专用数据集用于深度学习训练, 为熔覆质量控制提供了有效支撑。改进后的 YOLOv5-MT 模型与 YOLOv5s 基线模型相比, $mAP@0.5$ 达到了 95.9%。在保持检测精度的情况下, 参数量大幅减少, 检测速度提升至 288.8 f/s。与 YOLOv8 等主流检测模型相比, 方法在保证准确性的同时, 具有更快的响应性能, 能够满足高速激光加工现场在计算资源有限条件下对熔池状态进行实时监测的实际需求。

关键词: 激光熔覆; 熔池状态; 深度学习; 轻量化; YOLOv5

中图分类号: TG17, TP391.41

文献标识码: A

DOI: 10.19287/j.mtmt.1005-2402.2026.05.016



全文在线

Research on dynamic capture and classification discrimination of melting pool in high-speed laser cladding

DU Quanbin^①, WANG Enbo^{②③}, YU Yahui^④, BAI Jie^{④⑤}, WU Junfeng^⑥, WANG Chengwu^⑦, GUO Shirui^{②③}

(^①Henan Key Laboratory of Intelligent Manufacturing Equipment Integration for Superhard Materials, Henan Mechanical and Electrical Vocational College, Zhengzhou 451192, CHN; ^②School of Intelligent Mechatronics Engineering, Zhongyuan University of Technology, Zhengzhou 450007, CHN; ^③Hubei Key Laboratory of Digital Textile Equipment, Wuhan Textile University, Wuhan 430200, CHN; ^④The 713 Research Institute of CSSC, Zhengzhou 450015, CHN; ^⑤CSSC Haiwei Tech Co., Ltd., Zhengzhou 450001, CHN; ^⑥College of Engineering, Huanghe University of Science and Technology, Zhengzhou 450063, CHN; ^⑦College of Engineering, Zhejiang Normal University, Jinhua 321004, CHN)

Abstract: To address the issues of slow response speed, low efficiency, and difficulty in adapting to low-power devices in traditional melting pool monitoring methods during high-speed cladding, a lightweight YOLOv5 network is proposed. MobileNetV3 is used to replace the original backbone network structure for the dynamic capture and classification of melting pool states. Additionally, a custom dataset

^{*} 河南省超硬材料智能制造装备集成重点实验室开放课题项目 (JDKJ2024-03); 湖北省数字化纺织装备重点实验室开放课题项目 (KDTL2023003); 河南省研究生教育改革与质量提升工程项目 (YJS2025XQLH24, YJS2025AL60); 河南省科技攻关项目 (252102220019, 252102230005); 河南省高等学校重点科研计划项目 (26A460015, 26A460032); 浙江省自然科学基金项目 (LZY23E050003); 中国高等教育学会科学研究规划课题 (25ZF0205)

containing 933 melting pool images, created using high-speed cladding equipment, has been used for deep learning training, providing effective support for cladding quality control. Compared with the YOLOv5s baseline, the improved YOLOv5-MT model achieved a $mAP@0.5$ of 95.9%. While maintaining detection accuracy, the number of parameters was significantly reduced, and the detection speed increased to 288.8 f/s. Compared to mainstream detection models such as YOLOv8, this method offers faster response performance while ensuring accuracy, meeting the practical need for real-time monitoring of melting pool states in high-speed laser processing environments with limited computing resources.

Keywords: laser cladding; melt pool state; deep learning; lightweight; YOLOv5

高速激光熔覆是一种高效的先进表面处理技术,通过高能激光束快速加热粉末或线材至熔融状态,使熔化材料与基材表面熔合,形成高性能的复合涂层^[1]。该技术具有低热输入、低稀释率和高效率等显著优势^[2],广泛应用于航空航天、汽车制造和模具修复等领域。其中,熔池是熔覆的核心区域,包含了丰富的过程特征信息^[3]。在工业生产中,熔池状态直接影响熔覆层的质量。准确捕捉并分类判别熔池状态是获取高质量熔覆涂层的关键。目前,许多激光熔覆企业仍依赖人工识别或后处理等手段判断熔覆质量。然而,受限于操作人员的经验和主观判断,这些方法存在准确性差、效率低、可重复性差等问题^[4]。

近年来,深度学习结合传感器和识别算法,能够快速精确地识别和定位熔池状态,有效支持缺陷检测、工艺反馈和质量控制^[5]。熔池监测方法大致可分为传统监测方法与基于深度学习的智能监测方法。传统方法依赖声学^[6]、光学^[7]和X射线成像^[8]等多种传感器系统,虽能进行一定程度的检测,但存在分辨率低、响应慢以及抗干扰能力弱等局限,难以应对复杂工况。针对以上问题,采用深度学习方法应用于激光熔覆过程,可以有效地提高熔池状态监测的精度和效率。深度学习中的目标检测技术能够精确定位和识别熔池状态,目标检测方法分为一阶段(one-stage)和二阶段(two-stage)两类。一阶段算法如YOLO^[9]、单阶段多框目标检测算法(single shot multibox detector, SSD)^[10]和单阶段密集目标检测算法(RetinaNet)^[11],速度快,适合实时场景,但在复杂背景和小目标检测中精度较低。二阶段算法如R-CNN^[12]、Fast R-CNN^[13]和Faster R-CNN^[14],精度较高,但推理速度较慢。唐禹^[15]等通过YOLOv5网络改进,提高了气缸盖锻件缺陷检测效率和精度。

周翌晨等^[16]提出一种改进的焊缝检测算法,减少参数量并提高了检测速度,为后期软件部署提供了支持。近年来,深度学习技术在熔池状态监测与缺陷检测中取得了显著进展。REN Z等^[17]结合热成像与深度学习实现了熔池孔隙的高精度识别,并揭示了孔隙形成的振荡模式。LI K Q等^[18]提出基于声发射信号与深度神经网络的实时熔覆层状态识别与裂纹检测方法。卷积神经网络(convolutional neural network, CNN)^[19]推动了激光熔覆过程中的智能化,郭士锐等^[20]通过MCL-UNet实现了高精度熔覆层平整度识别,显著提高了检测精度和效率。SNYERS C等^[21]结合高光谱成像技术监测熔池异常,提出了一种新的异常检测方法。李春凯等^[22]通过YOLOv8实现了熔池的实时同步监测,提高了监测的实时性和精度。

然而,激光熔覆容易受外部环境干扰,传统监测方法效果差。为此,本文将轻量化目标检测算法YOLOv5s应用于熔池图像分析,实现了有限算力下的熔池动态捕获与分类判别,提高了熔覆过程的智能化,为高质量熔覆提供解决方案。

1 数据集创建

1.1 实验设备搭建

本文以单道和多道搭接高速激光熔覆过程中采集的熔池状态图像序列为研究对象。由于缺乏公开的大规模数据集,本实验使用的所有数据均来自作者所在课题组自建实验平台,并构建了专用数据集。该高速激光熔覆系统采用iLAM@25Fpt-600多关节型机器人控制,配备6 000 W多模光纤激光器。送粉系统为双管同轴环形送粉器,使用高纯度氮气保护熔池,并配有水冷系统。熔覆材料包括Fe基粉末、Ni基粉末和316 L不锈钢粉末,基材为45号钢。实验装置如图1所示。




图 1 激光熔覆系统示意图

Fig. 1 Laser cladding system schematic diagram

1.2 数据集采集与预处理

图像采集装置使用工业数字相机 MER2-041-302GM-P 并同轴集成于激光器上, 实时观测并采集熔池视频。原始视频经 Photoshop 处理并转换为图像序列, 按照每 5 帧抽取 1 帧并剔除相似图像, 最终构建 933 张图像的数据集, 其中数据集包含 544 张正常熔融图像、279 张过度熔融图像和 110 张不充分熔融图像。为了处理类别不平衡问题, 对较少数量类别的图像进行了过采样, 并在训练过程中调整了类别权重, 确保模型更多关注代表性较少的类别, 并应用 YOLOv5 在线数据增强策略。数据集按 7 : 2 : 1 比例划分为训练集、验证集和测试集。熔池图像标签根据实际熔覆状态划分为 3 类: 正常熔融、过度熔融和不充分熔融。本数据集具有多样性和代表性, 涵盖了实际工业中常见熔池状态。数据集标注采用 Roboflow 在线标注平台完成, 相较于传统的 LabelMe 工具, Roboflow^[23] 无需环境部署, 标注效率高, 支持直接导出适配 YOLO 网络格式的.txt 文件, 为后续模型训练提供便捷支持。

2 目标检测算法

本研究针对设备受限的激光熔覆过程中，在复杂背景下熔池状态的动态捕获与分类判别展开研究，旨在实现高准确性的同时，满足在线监测的实时性需求。综合考虑算法精度与运算效率，本文选取YOLOv5s 算法作为基础框架，并在此基础上进行轻量化与结构改进，以适应工业现场设备资源受限的实时检测需求。

2.1 改进的 YOLOv5s 算法

YOLO 是一种基于卷积神经网络的实时目标检测算法，以较高的检测速度、较高的精度和简洁结构广泛应用于目标检测任务。YOLOv5 是 Ultralytics 于 2020 年提出的改进版本，采用 PyTorch 框架，具

备灵活部署和快速更新优势。本文选取 YOLOv5s 作为基础模型,并对激光熔覆过程中复杂背景下的熔池状态检测需求进行轻量化改进。改进后的 YOLOv5s 网络结构如图 2 所示,包含输入层、MobileNetV3 网络、特征融合层和检测头。采用了包括 Mosaic 拼图增强、HSV 色彩扰动、仿射变换和随机翻转等在线数据增强策略提高模型的稳定性。MobileNetV3 主干网络通过深度可分离卷积,减少计算量并提升特征提取效率。特征融合层采用了适用于多尺度检测的结构,增强了模型在复杂场景下的鲁棒性。检测头使用 anchor-based 机制,通过 3 个尺度的特征图 (P3、P4、P5) 进行预测,输出边界框坐标、置信度和类别概率。在训练过程中,复合损失函数结合了 CIoU 边界框损失、置信度损失和分类损失,协同优化检测精度与定位性能。该改进模型在复杂背景和设备受限场景中表现优异,满足了激光熔覆过程中对熔池状态的实时、精准监测需求,具备较高的应用价值。




图 2 改进的 YOLOv5s 的网络结构图

Fig. 2 Improved YOLOv5s network architecture diagram

2.2 MobileNetV3 网络

MobileNetV3^[24] 是一款为移动端和嵌入式场景设计的轻量级卷积神经网络，在 MobileNetV1 和 V2 的基础上，引入神经网络结构搜索（neural architecture search, NAS）、改进的 Hard-Swish 激活函数，以及 Squeeze-and-Excitation（SE）通道注意力机制等关键技术。MobileNetV3 在保持较高准确率的同时，显著降低了模型参数量和计算复杂度，尤其适用于算力受限或边缘计算环境中的视觉任务。其网络结构如图 3 所示，主要由初始卷积层、多个瓶颈（Bottleneck）模块组成的主干网络，以及尾部的投影层和分类层构成。Bottleneck 模块是 MobileNetV3 的核心结构，采用“扩展-深度可分离卷积-压缩”的三阶段设计：首先通过 1×1 的逐点卷积升维输入通道；接着利用 3×3 的深度可分离卷积（depthwise conv）对每个通道独立执行空间卷积操作，从而显著减少模型参数和计算量；最后，通过 1×1 卷积进行特征压缩，将输出还原至指定通道数。部分模块嵌入 SE 模块以提升通道间特征表达能力，并引入 Hard-Swish 激活函数替代传统 ReLU，增强非线性建模能力。当输入输出通道一致且步幅为 1 时，该结构支持残差连接，提升特征传递效率。网络前端的初始卷积层通常使用步幅为 2 的 3×3 标准卷积进行初步下采样并提取低阶特征；中间主干部分由多个结构配置不同的 Bottleneck 模块串联，逐步提取图像中的多尺度语义信息；在网络尾部，MobileNetV3 通常采用全局平均池化（global average pooling, GAP）将空间维度压缩为全局特征向量，接 1 个 1×1 卷积进行通道扩展，最后通过全连接层输出分类结果。MobileNetV3 提供 Large 和 Small 两种配置版本，分别面向高性能和极致轻量化应用场景。本文采用 MobileNetV3-Small 版本，尾部通道数设定为 1 024，以适配检测任务需求。相较于前代 MobileNet 系列，该结构在计算效率与精度表现之间取得了更优平衡，尤其适用于熔池状态图像的




图 3 MobileNetV3 的整体结构简图

Fig. 3 Schematic diagram of the overall structure of MobileNetV3

轻量级快速分类任务，具备良好的嵌入式部署潜力与实时应用价值。MobileNetV3 的整体结构简图如图 3 所示。

3 实验结果与分析

3.1 环境搭建

本实验使用 Windows11 64 位操作系统，软件环境为 Anaconda 和 Python 3.9 虚拟环境，深度学习框架为 PyTorch 1.12.0 与 CUDA 11.3，编译软件为 PyCharm。硬件配置方面，CPU 为 12th Gen Intel® Core™ i5-12490F，GPU 为 NVIDIA GeForce RTX 4060 Ti 16GB。超参数设置：Batch-size（批量训练图片数）为 32，Epoch（训练轮次）为 100，图片尺寸（image-size）为 640 像素×640 像素，初始学习率（lr0）为 0.01，优化器选用 SGD，SGD 动量因子（momentum）为 0.937，权重衰减（weight-decay）为 0.000 5，其他参数保持默认值。

3.2 评价指标

为了全面评估所提出模型的精度与效率，实验选取了平均精度均值（mAP）、参数量（Params）、推理速度（FPS）和计算复杂度（GFLOPs/G）作为主要性能指标。具体来说，mAP 衡量模型在所有类别上的目标检测精度，FPS 反映模型的推理速度，Params 和 GFLOPs 分别表示模型的规模与计算开销。此外，为进一步分析检测性能，加入了精确率（precision, P）和召回率（recall, R）作为附加评估指标，计算公式如式（1）~式（5）所示。

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (1)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (2)$$

$$AP = \int_0^1 P(R) dR \quad (3)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP(i) \quad (4)$$

$$FPS = \frac{1000}{pre-process + inference + NMS} \quad (5)$$

式中： N_{TP} 表示正确预测为正类别的数量； N_{FP} 表示错误预测为正类别的数量； N_{FN} 表示实际为正类别但预测为负类别的数量； $pre-process$ 为图像预处理时间，ms； $inference$ 为推理速度，ms； NMS 为后处理时间，ms； N 表示类别总数； AP 为单一类别在精确率与召回率（ $P-R$ ）曲线下的面积； $AP(i)$ 为第 i 个类别的平均精度。

3.3 实验结果与分析

改进后的 YOLOv5-MT 模型与 YOLOv5s 原始模型在 R 、 P 和 $mAP@0.5$ 性能指标上的对比如图 4 所示。从整体趋势看, YOLOv5s 在训练初期表现出较快的收敛速度, 各项指标在前 20 个 Epoch 内迅速提升, 但曲线波动较大, 特别是 R 和 P 在中前期存在明显抖动, 反映出模型在复杂背景下的稳定性和鲁棒性不足。相比之下, YOLOv5-MT 由于引入了轻量化主干网络, 在训练初期性能上升较慢, 尤其是 P 在前期表现偏弱, 但随着训练深入, 该模型各项指标持续平稳提升, 最终与 YOLOv5s 在准确性上基本持平, 同时展现出更优的曲线平滑性与收敛一致性。特别是在 P 和 mAP 指标上, YOLOv5-MT 后期波动更小, 说明其在控制误检、稳定输出方面更具优势, 更适用于精度与可靠性要求较高的实际工业场景。综合来看, YOLOv5-MT 虽然牺牲了一定的收敛速度, 但在检测精度、稳定性和部署适应性方面均表现出色, 验证了本文所提出的轻量化改进策略在实际应用中的有效性与工程价值。




图 4 改进前后评价指标可视化结果对比

Fig. 4 Comparison of evaluation metrics visualization results before and after improvement

3.4 对比实验

为全面评估所提出模型在目标检测任务中的性能, 本文选取 SSD、Faster R-CNN、YOLOv5s 和 YOLOv8s 作为对比对象, 从 P 、 mAP 、 FPS 和 $GFLOPs$ 等 4 个维度进行比较, 不同检测模型的比较结果见表 1。结果显示, Faster R-CNN 和 SSD 的参数量分别为 41.0 M 和 24.0 M, 模型较大, 不适合对轻量化要求较高的应用。YOLOv5s 和 YOLOv8s 的参数量为 7.0 M 和 11.1 M, 具有较好的压缩性能。本文

提出的 YOLOv5-MT 模型仅含 1.4 M 参数, 具有显著的参数压缩率, 适合资源受限的工业设备。检测精度方面, YOLOv5s 和 YOLOv8s 的 mAP 均超过 95%, YOLOv5-MT 达到了 95.9%, 超过其他对比模型, 体现了轻量化与高精度之间的良好平衡。在推理速度上, YOLOv5-MT 的帧率为 288.8 f/s, 显著高于其他模型。计算复杂度方面, YOLOv5-MT 的 $GFLOPs$ 为 2.6 G, 低于所有对比模型, 显示出其计算效率优势。综上, YOLOv5-MT 在多个维度上均表现优异, 适合对模型体积和实时性要求较高的边缘计算和工业检测应用。

表 1 不同检测模型的比较结果

Tab. 1 Comparison results of different detection models

模型	Params/M	$mAP/(\%)$	$FPS/(f/s)$	$GFLOPs/G$
SSD	24.0	85.9	68.8	34
Faster R-CNN	41.0	89.4	60.7	182
YOLOv5s	7.0	95.3	102.4	16.5
YOLOv8s	11.1	95.2	90.1	28.7
YOLOv5-MT	1.4	95.9	288.8	2.6

3.5 模型检测效果图

在高速激光熔覆过程中, 如何在设备受限的情况下平衡检测速度与精度至关重要。为评估不同模型的效果, 对 YOLOv5s 和 YOLOv5-MT 模型进行了实验比较, 如图 5 所示。图 5a 所示为正常、过熔和欠熔状态的典型熔池状态图像。YOLOv5s 模型的检测结果 (图 5b) 表明, 在正常熔融和过度熔融状态下, 该模型可以准确识别熔池区域, 置信度普遍在 0.94 以上, 检测精度较高。但在欠熔状态下, 出现了多个冗余框, 表明检测的不准确性。然而, 在 YOLOv5-MT 模型 (图 5c) 中, 3 种状态的检测结果均低于 YOLOv5s, 但在欠熔状态下可以排除一部分飞溅等背景干扰。YOLOv5-MT 在显著提高了检测速度的同时牺牲部分检测精度。尽管 YOLOv5-MT 在精度上稍逊于原基线网络 YOLOv5s, 但通过轻量化改进, 该模型减少了计算量并显著提高了检测速度, 适合在低算力环境下进行实时监测。因此, YOLOv5-MT 在高速激光熔覆过程中, 更能满足实时监测和高效处理的需求, 尤其适合设备受限的场景。

4 结语

本文设计并验证了轻量化目标检测模型 YOLOv5-MT, 基于 YOLOv5s 引入 MobileNetV3 主干网络,

在保证精度的同时显著减小模型参数,提升了实时检测能力与部署适应性。实验结果表明, YOLOv5-MT 在检测精度、推理速度与模型复杂度之间实现了有效平衡, $mAP@0.5$ 达到了 95.9%, 检测速度提升至 288.8 f/s。适用于激光熔覆在线监测等设备受限的工业场景当中, 具有较高的实用性和推广价值。由于模型轻量化而导致精度的下降, 下一步工作可以聚焦于解决这一问题, 以进一步提升检测精度。




图 5 模型检测效果对比

Fig. 5 Comparison of model detection results

参考文献

- [1] SCHMIDT M, MERKLEIN M, BOURELL D, et al. Laser based additive manufacturing in industry and academia[J]. Cirp annals, 2017, 66(2): 561-583.
- [2] 李雪峰, 李海新, 杨柯楠, 等. 超高速激光熔覆研究现状与进展[J]. 材料导报, 2026, 40(4): 100-110.
- [3] LIANG Z M, REN Z, RAO Y Z, et al. Study on the visualization of laser cladding molten pool flow field based on attention mechanism[J]. Journal of manufacturing processes, 2025, 134: 337-347.
- [4] 李晓磊, 黄传庆, 郑博, 等. 基于 YOLO-v5 的 Ti-48Al-2Cr-2Nb 合金高温析出相智能识别[J]. 有色金属工程, 2023, 13(9): 33-41.
- [5] 陈儒森, 吉小超, 张梦清, 等. 机器学习在激光熔覆涂层缺陷检测中的研究现状与进展[J]. 中国表面工程, 2024, 37(5): 112-137.
- [6] HOSSAIN M S, TAHERI H. In situ process monitoring for additive manufacturing through acoustic techniques[J]. Journal of materials engineering and performance, 2020, 29: 6249-6262.
- [7] 汤新臣, 郭国林, 虞剑, 等. 光学传感技术在熔池信息检测中的应用[J]. 机械设计与自动化, 2003, 32(6): 62-65.
- [8] 王奉涛, 杨守华, 吕秉华, 等. 金属增材制造过程熔池动态监测研究综述[J]. 计算机集成制造系统, 2023, 29(7): 2245-2259.
- [9] HUSSAIN M. YOLO-v1 to YOLO-v8, the rise of YOLO and its complementary nature toward digital manufacturing and industrial defect detection[J]. Machines, 2023, 11(7): 677.
- [10] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: single shot multibox detector[C]//European Conference on Computer Vision. Amsterdam: Springer, 2016: 21-37.
- [11] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//Proceedings of the IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 2980-2988.
- [12] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Columbus: IEEE, 2014: 580-587.
- [13] GIRSHICK R. Fast R-CNN[C]//Proceedings of the IEEE International Conference on Computer Vision. Santiago: IEEE, 2015: 1440-1448.
- [14] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 39(6): 1137-1149.
- [15] 唐禹, 方凯, 杨帅, 等. 改进 YOLOv5 的气缸盖锻件缺陷视觉检测方法研究[J]. 制造技术与机床, 2023(8): 166-173.
- [16] 周翌晨, 虞旦, 李佳成, 等. 基于改进 YOLOv5 的焊缝识别算法研究[J]. 制造技术与机床, 2024(7): 19-25.
- [17] REN Z, GAO L, CLARK S J, et al. Machine learning-aided real-time detection of keyhole pore generation in laser powder bed fusion[J]. Science, 2023, 379(6627): 89-94.
- [18] LI K Q, LI T, MA M, et al. Laser cladding state recognition and crack defect diagnosis by acoustic emission signal and neural network[J]. Optics & laser technology, 2021, 142: 107161.
- [19] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. Advances in neural information processing systems, 2012, 25: 1097-1105.
- [20] 郭士锐, 刘银银, 崔陆军, 等. 基于 MCL-UNet 网络的激光熔覆层表面平整度识别[J]. 激光与红外, 2023, 53(5): 685-692.
- [21] SNYERS C, ERTVELDT J, EFTHYMIADIS K, et al. Hyperspectral in-situ monitoring for deep learning-based anomaly classification in metal additive manufacturing[J]. IEEE access, 2024, 12: 178848-178861.
- [22] 李春凯, 潘宇, 石玢, 等. 基于视觉传感的热丝激光金属沉积熔滴—熔池多特征信息同步监测[J]. 焊接学报, 2024, 45(11): 115-120.
- [23] ALEXANDROVA S, TATLOCK Z, CAKMAK M. RoboFlow: a flow-based visual programming language for mobile manipulation tasks[C]//2015 IEEE International Conference on Robotics and Automation(ICRA). Seattle: IEEE, 2015: 5537-5544.
- [24] HOWARD A, SANDLER M, CHU G, et al. Searching for MobileNet-V3[C]//2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019: 1314-1324.

第一作者: 杜全斌, 男, 1983 年生, 博士, 副教授, 研究方向为先进焊接材料与装备、超硬工具制备技术与装备、金刚石热界面材料开发、激光增材表面修复再制造。E-mail: paperduqb@126.com

通信作者: 郭士锐, 男, 1986 年生, 博士, 教授, 研究方向为激光增材制造与再制造、超快激光极端制造、数字化机械设计与优化。E-mail: laser@zut.edu.cn

(编辑 李 静)

(收修改稿日期: 2025-11-24)