

doi: 10.11933/j.issn.1007-9289.20240827001

基于改进型 YOLOv5 算法的 IN718 镍基合金激光熔覆孔隙高精度检测及其控制方法

盛杰¹ 王勇¹ 徐天翊¹ 林相奇¹ 孟宪凯¹
周建忠¹ 陈峰² 李果³ 黄舒¹

(1. 江苏大学机械工程学院 镇江 212013;

2. 苏州大学机电工程学院 苏州 215137;

3. 伯肯森自动化技术(苏州)有限公司 苏州 215009)

摘要: 为了提升激光熔覆损伤修复件中孔隙的检测精度,以调整激光熔覆工艺参数,从而减少熔覆层气孔、开裂等缺陷,提升激光熔覆层质量,开展 IN718 镍基合金不同工艺参数下的激光熔覆试验,并开发一种改进型 SP-YOLOv5 孔隙检测算法。在输入层与卷积层之间增加 Coordatt 注意力机制模块,从而增强特征图的空间位置信息权重;改写 YOLOv5 网络结构,以增强网络模型对孔隙类小目标的检测能力;采用 Soft-NMS 代替原有 NMS (非极大值抑制) 进行检测结果后处理,进一步降低网络漏检率;将 SP-YOLOv5 算法孔隙检测结果与 YOLOv5、FasterRCNN、RCNN 以及 ImageJ 软件分析结果进行对比,得出 SP-YOLOv5 算法模型比其他算法模型的精度最高提升了 10.57%;在此基础上,通过对激光熔覆熔池温度、熔池面积及熔覆层横截面孔隙率、熔宽、熔高、熔深等的测量,基于 Stacking 算法建立激光熔覆工艺参数与孔隙率的回归预测模型,并采用目标优化算法获得了较优激光熔覆工艺参数组合(激光功率 1 330 W、扫描速度 460 mm/min、送粉率 13 g/min),对熔覆件进行孔隙参数测量,结果显示,在这些优化参数下,Stacking 模型预测的孔隙率与实际测量值的一致性达到 97.5%,验证了优化方法的有效性,研究结果可为激光熔覆层孔隙缺陷的有效控制提供理论依据。

关键词: 激光熔覆; 孔隙; 计算机视觉; 深度学习; 目标; 优化

中图分类号: TH142

High Precision Detection of Porosity and its Control in Laser Cladding of IN718 Nickel-based Alloy Utilizing an Enhanced YOLOv5 Algorithm

SHENG Jie¹ WANG Yong¹ XU Tianyi¹ LIN Xiangqi¹ MENG Xiankai¹
ZHOU Jianzhong¹ CHEN Feng² LI Guo³ HUANG Shu¹

(1. School of Mechanical Engineering, Jiangsu University, Zhenjiang 212013, China;

2. School of Mechanical and Electrical Engineering, Soochow University, Suzhou 215137, China;

3. Burkensen Automation Technology (Suzhou) Co., Ltd., Suzhou 215009, China)

Abstract: Laser cladding is widely used in the repair of key components of aircraft engines due to its advantages, such as a small heat-affected zone, low dilution rate, good interface metallurgical bonding, and easy implementation of flexible processing. Stress changes induced by rapid heating and cooling during laser cladding and the complex composition of the cladding powder are

基金项目: 国家自然科学基金(52375186, 52375436, 52275430); 江苏省自然科学基金(BK20221365)。

Fund: National Natural Science Foundation of China (52375186, 52375436, 52275430); Jiangsu Natural Science Foundation (BK20221365).

收稿日期: 2024-08-27; 修改日期: 2024-10-12; 接受日期: 2024-11-05; 上线日期: 2024-12-16。

Received August 27, 2024; Revised October 12, 2024; Accepted in revised form November 5, 2024; Available online December 16, 2024.

引用格式: 盛杰, 王勇, 徐天翊, 等. 基于改进型 YOLOv5 算法的 IN718 镍基合金激光熔覆孔隙高精度检测及其控制方法[J]. 中国表面工程, 2025, 38(3): 139-151.

Citation format: SHENG Jie, WANG Yong, XU Tianyi, et al. High precision detection of porosity and its control in laser cladding of IN718 nickel-based alloy utilizing an enhanced YOLOv5 algorithm[J]. China Surface Engineering, 2025, 38(3): 139-151.

important causes of cladding defects. Accurately detecting pores to actively regulate cladding porosity is important for improving the surface quality of cladding parts. To enhance the accuracy of porosity detection within laser cladding repair components and adjust the parameters of the laser cladding process, thereby reducing defects such as porosity and cracking in the cladding layer and improving the quality of the laser cladding layer, laser cladding experiments on IN718 nickel-based alloys with various process parameters were conducted in this study. In addition, an improved SP-YOLOv5 algorithm is developed for porosity detection. Initially, a Coordatt attention mechanism module is integrated between the input and convolutional layers to augment the spatial location information weight within the feature map. Subsequently, the YOLOv5 network structure was restructured to bolster its capability for detecting small targets of the porosity class. Furthermore, soft-NMS was implemented in place of the original Non-Maximum Suppression (NMS) for post-processing the detection results, which further reduced the false negative rate of the network. The porosity detection results yielded by the SP-YOLOv5 algorithm were compared with those of YOLOv5, Faster RCNN, RCNN, and ImageJ software analyses, revealing that the SP-YOLOv5 algorithm model achieved the highest accuracy improvement of 10.57%. Based on these findings, measurements of the laser cladding pool temperature, pool area, porosity rate, melting width, melting height, and melting depth of the cladding layer cross-section were performed. The results showed that the area of the molten pool was positively correlated with the laser power and powder feeding rate. As the laser power increased from 1 000 to 1 400 W, the average area of the molten pool increased from 5.77 to 10.52 mm². On the contrary, the melt-pool area was negatively correlated with the scanning speed. Similarly, the height, width, and depth of the molten pool were positively correlated with the laser power and powder feeding rate, and negatively correlated with the scanning speed. A regression prediction model correlating the laser cladding process parameters with the porosity rate was established using a stacking algorithm, and an optimal set of laser cladding process parameters was derived using a target optimization algorithm. Finally, laser cladding experiments were conducted using the optimal combination of process parameters (laser power of 1 330 W, scanning speed of 460 mm / min, and powder feeding rate of 13 g / min), and the porosity parameters were measured. The experimental results showed that under these optimized parameters, the consistency between the porosity predicted by the stacking model and the actual measured values reached 97.5%, verifying the effectiveness of the optimization method and significantly improving the quality of the cladding layer. The results of this study provide a theoretical foundation for the effective control of porosity defects in laser cladding layers and expand the application of machine vision in thermal repair processes.

Keywords: laser cladding; pore; computer vision; deep learning; target; optimization

0 前言

激光熔覆因具有热影响区小、稀释率低、界面冶金结合良好、易实现柔性化加工等优点,被广泛应用于航空发动机关键部件的修复^[1-3]。然而,激光熔覆过程中会产生孔隙、夹渣和裂纹等缺陷^[4-5],特别是由于保护气卷入熔池、熔覆层间不良熔合和空心粉末等诱发的偶发性孔隙以及熔池中C与O等反应产生的反应型孔隙^[6-8],会降低熔覆层的结构强度;同时,孔隙周围产生的应力集中在高温和循环载荷条件下将降低关键构件的力学性能,缩短其服役寿命,甚至危及设备使用安全^[9]。

已有研究表明,通过优化激光熔覆工艺参数,可有效解决激光熔覆层孔隙、夹渣和裂纹等系列问题^[10-11]。激光熔覆工艺参数优化包括建立工艺参数与质量评价指标的回归分析模型,以及采用单/多目标优化算法求解激光熔覆的最佳工艺参数两个步骤^[12-13]。其中,激光熔覆质量评价指标的选取尤为重要,目前评价指标主要有熔池稀释率、孔隙率、

宽高比、残余应力、显微硬度等,而孔隙率作为激光熔覆质量评价中最直接的外在表征,其高精度检测和控制方法成为业内研究热点。

激光熔覆孔隙的形成与控制是一个复杂的过程,涉及多种因素和工艺参数,通过优化激光功率、扫描速度和送粉速度等主要工艺参数,可以有效降低孔隙率,从而提高熔覆层的质量。激光熔覆层孔隙率的检测可以结合现代计算技术和先进的分析方法来实现,包括计算机断层扫描结合回归卷积神经网络、分子动力学模拟与多功能波函数分析、数值分析与试验测量以及物理信息熔池标记和机器学习等,每种方法都有其独特的优势和适用场景。

近年来,计算机视觉技术的快速发展为孔隙率的高精度检测提供了有效路径。DELCOUSE 等^[14-16]使用横截面显微分析法结合 ImageJ 软件进行孔隙率测量,随后,Image Pro Plus、ImageJ 和 Nano Measurer 等图像处理软件被开发以提升孔隙率检测精度^[17-19],但这些软件在孔隙分割时高度依赖图像的像素阈值而不是孔隙的形态特征,导致在检测过程中会将其他像素值相近的特征(如晶界、脏污、

夹杂等) 误检为孔隙; 此外, 该类方法缺乏分割性能的评价指标, 难以优化孔隙的分割结果, 因此, 只适用于孔隙分布均匀、孔隙几何形状规则的材料, 在分割形状复杂、结构多样化的孔隙时精度受限。

随后, ZHANG 等^[20]开发了一种基于深度学习的孔隙率检测方法, 设计了卷积神经网络模型来学习激光熔池图像与熔池孔隙分布之间的关系, 通过训练模型完成了增材制造过程中孔隙率属性分析。ZHOU 等^[21]使用 DeepLabV3+卷积神经网络研究了原始图像与孔隙标记图像之间的相关性。与传统成像方法相比, 基于深度学习的模型在孔隙率分析时可提升检测效率和精度。然而, 目前激光熔覆层孔隙率检测大多仍直接采用 ImageJ 等软件进行简单的图像预处理计算出孔隙率, 而深度学习方法则主要用于孔隙率与其他形态参数之间的关系分析, 因此, 使用机器学习方法直接实现孔隙率的高精度检测, 对于优化激光熔覆工艺参数以提升熔覆件质量具有重要意义。

文中针对激光熔覆层孔隙率特征优化算法结构, 开发了一种改进型 SP-YOLOv5 孔隙检测算法, 通过增加 Coordatt 注意力机制模块、改写 YOLOv5 网络结构等方法增强模型对孔隙类小目标的检测能力, 采用 Soft-NMS 代替原有 NMS(非极大值抑制) 进行检测结果后处理以降低网络漏检率; 开展 IN718 镍基合金激光熔覆系列试验, 选取激光功率、扫描速度和送粉率为主要工艺参数, 通过对熔池温度、熔池面积及熔覆层横截面孔隙率、熔宽、熔高、熔深等的测量, 将 SP-YOLOv5 算法孔隙检测结果与 YOLOv5、FasterRCNN、RCNN 以及 ImageJ 软件分析结果进行对比, 以评估所开发模型的精度; 在此基础上, 基于 Stacking 算法建立激光熔覆工艺参数与孔隙率的回归预测模型, 并采用目标优化算法实现激光熔覆层孔隙率的有效控制。

1 试验材料与方法

1.1 试验材料

选用航空发动机部件常用材料 IN718 镍基合金(上海隆进特殊钢有限公司提供) 作为修复基材, 基材尺寸为 40 mm×60 mm×6 mm, 试样熔覆面用 320#~1000#砂纸打磨平整, 随后用酒精清洗, 烘干后备用。试验所用的修复材料为沈阳稀有金属研究

所制备的 IN718 球形金属粉末, 粒径为 53~150 μm, 粉末和基体 SEM 形貌见图 1, 其成分见表 1。试验前将粉末置于 80 °C 的烘干箱内连续烘烤 5 h 并自然冷却以除去粉末表面的水汽。




图 1 IN718 粉末和基体 SEM 形貌

Fig. 1 SEM profile of IN718 powder and IN718 substrate

表 1 IN718 镍基合金基体材料与 IN718 粉末的化学成分
(质量分数 / %)

Table 1 Chemical composition of IN718 substrate and IN718 powder (wt. %)					
Material	Fe	Al	Ti	Nb	Cr
Substrate	20.17	0.54	0.80	5.00	18.41
Powder	18.10	0.54	0.97	4.92	19.20
Material	Mo	Si	C	Mn	Ni
Substrate	2.97	0.30	0.035	0.13	Bal.
Powder	3.19	0.20	0.045	0.04	Bal.

1.2 激光熔覆试验装置

采用的激光熔覆设备为 YLS-2000-TR 光纤激光器, 额定功率为 2 kW, 运动机构为 KUKA 机械手臂, 采用同轴送粉方式输送 IN718 合金粉末, 采用氩气作为载气和保护气体, 其中激光熔覆制造装置如图 2 所示。设计三因素五水平正交试验表如表 2 所示, 其中, 因素 A、B、C 分别为激光功率、送粉率和扫描速度。




图 2 激光熔覆制造装置

Fig. 2 Laser cladding manufacturing device

表 2 激光熔覆工艺参数正交试验设计表
Table 2 Orthogonal test design table of laser cladding process parameters

Factor	Level				
	1	2	3	4	5
A	1 000	1 100	1 200	1 300	1 400
B	10	11	12	13	14
C	400	425	450	475	500

1.3 微观 SEM 图像采集

采用 S-3400N 型扫描电子显微镜观察 IN718 激光熔覆试样的横截面微观结构特征，其采样流程如图 3 所示，为保证孔隙率测量的稳定性，按图 3d 所示路径，选择统一放大倍数 350 倍进行图像采集。




图 3 SEM 图像采集流程

(a) 激光熔覆路径图；(b) 线切割加工示意图；(c) 熔覆层横截面示意图；(d) SEM 取点示意图

Fig. 3 SEM image of acquisition process

(a) Laser cladding path diagram; (b) Schematic diagram of wire-cut specimen; (c) Schematic of cross-section of the cladding layer; (d) Schematic of SEM acquisition path

1.4 熔池特征监测

采用大恒图像研发的工业面阵数字相机 MER2-041-302GM-P 进行熔池监测，由于在激光熔

覆过程中，熔池的亮度极高，故相机镜头前方设置无极调光 ND2-ND400 减光镜。

1.5 熔池截面形貌检测

激光熔覆试验后，使用线切割机将试样沿垂直于激光扫描方向切割取样，然后将取出的试样镶嵌、磨抛及超声波清洗。采用基恩士的 VHX-1000 型超景深显微镜进行熔覆样截面熔池形貌的测量。

1.6 深度学习模型训练

1.6.1 数据增强

较优的神经网络模型往往需要大量的数据做支撑，只通过原始试验方法获取数据需要花费大量的成本，因此，通过数据增强的方式扩充原始数据集数量。通过数据增强可以使模型在有限的训练数据中学习更多的特征和变化情况，提高模型的泛化能力和鲁棒性，也可有效减轻过拟合现象，并防止模型出现过于依赖训练数据的问题。

1.6.2 图像标注

文中共采集了 226 张 IN718 镍基合金激光熔覆层试样截面有效 SEM 图像，采用标记工具 Label Studio 对图像孔隙位置、种类进行标记，随后，将标注完成的数据导出 YOLO 的 Label 数据格式，以备后续网络训练。

1.6.3 改进型 SP-YOLOv5 网络结构

卷积神经网络（Convolutional neural networks, CNN）的诞生解决了传统机器学习方法进行图像识别过程中人工提取特征单一、片面和局限的问题，目前已成为图像识别领域最重要的深度学习方法之一。在深层神经网络结构中，细节特征会在多次降采样过程中丢失，本网络使用的 YOLOv5 框架基于 CNN 网络，并加以改进，如图 4 所示。对原始输入




图 4 改进型 SP-YOLOv5 网络结构

Fig. 4 Improved SP-YOLOv5 network architecture

图片增加了一个四倍下的采样过程, 随后送入到特征融合网络得到新尺寸的特征图, 该特征图感受野较小, 可以提升细节特征的检测精度; 同时, 由于孔隙目标具有体积小的特征, 为了提升激光熔覆层孔隙检测精度, 引入 Coordatt 注意力机制模块, 通

过修改图像的权重值强化重要特征提取能力, 以提升网络对小目标特征信息的关注度, 如图 5 所示; 此外, 引入矩形框损失函数 CIOU loss, 通过结合目标框的位置、形状和大小等特征, 以提供更准确和鲁棒的目标框回归。




图 5 Coordatt 注意力机制结构
Fig. 5 Structure of Coordatt’s attention mechanism

1.6.4 先验框尺寸设置

网络输出尺寸最小的特征图感受野最大, 故用其来检测大目标, 选用大尺度的先验框进行预测框的回归; 网络输出大尺寸特征图的感受野较小, 故用其检测小目标, 采用小尺寸的先验框; 网络结果输出三种不同尺寸的特征层, 其中特征图尺寸大小 S_t 与先验框尺寸 S_x 的对应关系如表 3 所示。在 YOLOv5 特征融合部分引入一个尺寸较大的输出特征层进行相互融合, 可有效提升模型对小目标的检测效果, 保持模型的高精度和泛化能力。此外, 增加大尺寸特征图的同时, 删减骨干网络中最小尺寸的特征图, 可实现检测精度和检测速度的同步提升。

表 3 特征图大小与先验框尺寸对应关系

Table 3 Correspondence between feature map size and a priori frame size

S_t	S_x		
26×26	[30, 61]	[62, 45]	[59, 119]
52×52	[10, 13]	[16, 30]	[33, 23]
104×104	[5, 6]	[8, 14]	[15, 11]

Where S_t is feature map size, S_x is priori frame size.

模型具有较好的泛化能力。与此同时, 通过交叉验证和学习曲线分析, 可以观察到模型在训练集和验证集上的性能稳定性, 表明 226 张图像的使用已足以使模型收敛并达到预期的准确性。此外, 考虑到孔隙率检测中样本标签的稀疏性和复杂性, 本文采用适度的图像数量结合数据增强技术, 能够进一步提升模型的鲁棒性。

图 6 为训练过程中 SP-YOLOv5、YOLOv5、FasterRCNN 以及 RCNN 的准确性和损失过程。由


2 结果与讨论

2.1 孔隙检测结果


2.1.1 四种模型训练结果对比分析

将标注好的数据分成五等分, 其中训练集与测试集比例约为 4 : 1 (172 : 44), 分别采用 SP-YOLOv5、YOLOv5、FasterRCNN 以及 RCNN 对训练集数据进行模型训练。在各个模型的训练过程中, 采用随机搜索策略, 系统地抽样并评估超参数组合, 最终确定了 SP-YOLOv5、YOLOv5、FasterRCNN 以及 RCNN 模型的最佳超参数配置, 以保证各个模型均接近其最佳检测效果。

此外, 针对 226 张图像数据这一数据集规模能够有效地涵盖孔隙率变化的不同场景和类型, 确保



(a) Training accuracy



(b) Training loss

图 6 四种网络结构训练精度与训练损失
Fig. 6 Training accuracy and training loss for four network structures

图 6 可以发现,四个网络训练至 20 Epoch 时,训练精度与训练损失都处于稳定状态,准确率与训练损失都只在小范围内上下波动。其中,SP-YOLOv5、YOLOv5、FasterRCNN 以及 RCNN 的训练精度分别为 94.53%、84.64%、87.56%和 85.95%;其训练损失分别为 0.07、1.04、1.33 和 1.16。可见,所提出的 SP-YOLOv5 在训练精度上相对于 YOLOv5、FasterRCNN 与 RCNN 分别提升 8.89%, 6.97%和 8.58%;与此同时,SP-YOLOv5 相对于其他三种网络模型,其训练损失大幅度降低。

图 7 为四种网络结构验证精度。由图 7 可以发现,四个网络验证结果与训练结果的发展趋势较为一致,在第 15~20 Eopch 时,网络的验证精度趋于稳定,SP-YOLOv5、YOLOv5、FasterRCNN 以及 RCNN 的验证精度可达 93.38%、82.81%、85.28%和 83.46%,可见 SP-YOLOv5 算法模型比其他算法模型的验证精度最高提升了 10.57%;相较于训练精度,验证精度分别降低 1.15%、1.83%、2.28%、2.49%。SP-YOLOv5 网络训练集精度与测试集精度差相较于 YOLOv5、FasterRCNN 以及 RCNN 的更小,表明 SP-YOLOv5 模型具有更好的泛化能力,这也意味着该模型相对于其他模型能够更好地适应未知的数据,且不易出现过拟合的问题。




图 7 四种网络结构验证精度

Fig. 7 Verify accuracy of the four network structures

SP-YOLOv5 针对激光熔覆孔隙较小的特征,首先添加了 Coordatt 注意力模块,通过引入坐标编码信息,使得模型能够识别图像不同位置的全局特征加权融合局部特征,相较于传统的卷积神经网络,可提高图像特征的全局表达和局部判别能力,避免小目标在多次卷积操作中被模糊、淹没或丢失,从而提高了熔覆层孔隙检测准确率;在激光束照射基材时,金属粉末瞬时熔化形成熔池。如果熔池存在不稳定性或温度分布不均匀,气体夹杂物(如水蒸

汽和氧气)有可能被封闭于熔覆层内部。此外,粉末颗粒的不完全熔化、沉降现象、激光能量的波动以及熔覆工艺参数的设置不当均可能导致小孔隙的形成,在 YOLO 算法中引入注意力机制可以显著提升其小目标孔隙检测的性能,通过动态选择和加权重要特征,增强模型对小目标的关注,提高检测精度和鲁棒性,从而降低误检率并更好地适应复杂场景。其次,基于感受野的变化优化网络结构,增大网络输出层的结构尺寸,减小输出层感受野尺寸,提升了激光熔覆层孔隙类小目标的检测精度。

2.1.2 Soft-NMS & NMS 后处理方法对比

采用 Soft-NMS 替换原有的 NMS (非极大值抑制) 进行后处理,图 8 为 Soft-NMS 与 NMS 结果对比。当检测多目标重叠或者间距较小时,NMS 只选择得分最高的目标,而将其他置信度稍低、但表示另一个物体的预测框删除;Soft-NMS 则采用衰减函数调整多目标权重,通过降低置信度得分的方式保留重叠的目标框,从而提高了目标检测的召回率,具有更好的泛化性能,可以处理各种复杂场景和遮挡情况,使得目标检测结果更加准确和鲁棒。




图 8 Soft-NMS 与 NMS 后处理结果对比

Fig. 8 Post-processing results comparison between soft-NMS and NMS

可见,在孔隙率检测场景中,由于存在大量临近的小孔隙,传统的非最大抑制(NMS)方法可能导致一些重要目标被忽略或误判,从而影响检测结果的准确性。因此,Soft-NMS 在此背景下展现出更显著的优势。

2.1.3 模型检测效果验证

随机选取未经训练的激光熔覆形貌图像,放入

不同的模型中进行预测, 进一步验证改进型孔隙算法的有效性, 如图 9 所示。ImageJ 软件仅通过像素阈值判断孔隙, 其统一将阈值区域内特征全部检测为孔隙, 易将其他缺陷特征误认为孔隙。如图 9 中白色圆圈所示, 仅根据像素阈值将脏污误识别为孔隙, 从而造成孔隙测量的误差, 且像素阈值需手动设置, 在多次测量时, 易受人为因素的影响导致测量标准存在较大偏差, 从而造成测量结果的偏差;




图 9 模型检测效果验证
Fig. 9 Model detection effect verification

相比之下, 基于深度学习的孔隙测量方法能够自动提取图像中的孔隙信息, 在判断各区域特征是否属于孔隙之后再行进行阈值分割, 无需进行手动绘制区域, 可提升孔隙检测的准确率。

对比分析 SP-YOLOv5、YOLOv5、FasterRCNN 和 RCNN 等基于深度学习方法的孔隙检测结果, 发现四种模型对于区域特征是否为孔隙的判断都准确无误, 能正确识别出 ImageJ 软件误识别的区域, 孔隙检测准确度皆优于 ImageJ 软件; 相较于 YOLOv5、FasterRCNN 和 RCNN 的检测结果, SP-YOLOv5 可检测出其他三种深度学习网络未检测出的小目标孔隙, 如图 9b 所示。由于 SP-YOLOv5 算法模型对于小目标的检测精度明显高于其他模型, 同时对于中、大尺寸目标的检测精度亦不低于其他模型, 所以 SP-YOLOv5 算法模型可显著提升熔覆层孔隙率的检测准确度和检测精度。

2.2 激光熔覆熔池特征检测及分析

在激光熔覆过程中, 熔池区域清晰准确的分割是影响熔池特征提取结果的最直接因素。当处理特殊的熔池图像时, 如火花飞溅、粉末遮挡等, 传统依靠调整阈值的图像分割方法难免会产生误差。

因此, 采用二阶段检测方式以提升熔池区域的提取精度, 即第一阶段深度学习粗略检测熔池区域, 减小图像处理范围; 第二阶段采用计算机图像处理方法精准测量熔池面积, 可实现在复杂环境下实时监测激光熔覆熔池区域的长度、宽度、高度及面积等。由于熔池检测种类单一、特征较为明显, 一阶段深度学习检测熔池区的网络模型采用经典卷积神经网络模型, 并对此做出一定的优化, 其网络模型结构如图 10 所示, 其图像检测与分割结果如图 11 所示。




图 10 熔池区域检测网络模型结构
Fig. 10 Structure of molten pool area detection network model




图 11 熔池区域分割部分结果

Fig. 11 Partial splitting results of molten pool area


2.2.1 激光功率对熔池面积的影响

图 12 为激光功率与熔池面积的关系图。由图可知, 随着激光功率不断增大, 熔池面积随之增大。当激光功率从 1 000 W 增加到 1 400 W 时, 熔池平均面积由 5.77 mm^2 增加至 10.52 mm^2 ; 随着激光功率的增加, 单位质量熔覆基体与金属粉末吸收的热量增加, 增加的热量向熔池四周扩散传递, 从而导致熔池


面积增加; 同时, 由于激光器熔覆的光斑直径保持恒定, 当熔池面积接近光斑面积时, 随着激光功率的增大, 熔池的温度会随之升高, 但其向四周扩散的温度会迅速衰减, 从而导致熔池向外扩张的速度有所减缓, 当达到一定功率阈值时, 熔池面积便不再增大。

2.2.2 扫描速度对熔池面积的影响

图 13 为激光扫描速度与熔池面积的关系图。由




(a) Correlation between molten pool area and laser power




(b) Correlation between molten pool area and molten time

图 12 激光功率与熔池面积的关系

Fig. 12 Correlation between laser power and molten pool area



(a) Correlation between molten pool area and scanning speed



(b) Correlation between molten pool area and molten time


图 13 扫描速度与熔池面积的关系

Fig. 13 Correlation between scanning speed and molten pool area


图可知, 随着扫描速度的增加, 熔池平均面积明显减小。这是因为随着扫描速度的增大, 单位质量基体吸收的能量减少, 从而导致熔池边缘材料达不到熔点, 熔池面积减小。

2.2.3 送粉率对熔池面积的影响

图 14 表明随着送粉速率从 10 g / min 增加到 14 g / min, 熔池面积逐渐增大。随着粉末输入增多, 更多粉末被熔化和凝固在工件表面上, 增大了熔池。当送粉速率增大时, 更多的粉末会进入熔池, 熔池的面积会随之增大。值得注意的是, 当送粉率达到一定程度时, 激光束的穿透能力下降, 从而导致熔覆基体与金属粉末吸收热量减少, 反而会导致熔池面积的减小。



(a) Correlation between molten pool area and power delivery rate



(b) Correlation between molten pool area and molten time

图 14 送粉率与熔池面积的关系

Fig. 14 Correlation between powder delivery rate and molten pool area

2.3 激光熔覆层形貌测量及分析

2.3.1 激光功率对熔高、熔宽、熔深的影响

图 15 所示为激光功率与熔池特征尺寸的关系。随着激光功率的增大, 熔池在长度、宽度、深度和面积上呈现相同的趋势。这是因为在激光功率

不够大时激光光斑是高斯光斑, 只有在激光中心的熔覆基体才能达到熔点, 导致熔池的面积比激光光斑面积小, 热源梯度分布比较明显。在激光辐照不足的地方, 试验材料无法达到熔点, 所以形成的熔池的熔高、熔宽、熔深都较小。随着激光功率的增大, 熔池温度变大, 超过熔覆粉末熔点后, 粉末材料的利用率随之增大, 相应的熔高、熔宽也会随之增大。同时, 随着激光熔覆功率的增大, 单位时间能量输入增大, 注入基体的热量增大, 从而导致熔深增加。




图 15 激光功率与熔池形貌的关系

Fig. 15 Correlation between laser power and molten pool morphology

2.3.2 扫描速度对熔高、熔宽、熔深的影响

图 16 为扫描速度与熔池形貌的关系。由图可知, 随着扫描速度的增加, 熔池长度、宽度和深度都随之降低, 这是由于较高的扫描速度意味着激光照射时间更短, 材料接受的热输入时间减少, 同时粉末材料的累积也会更少。相同的热输入被更快地




图 16 扫描速度与熔池形貌的关系

Fig. 16 Correlation between scanning speed and molten pool morphology

传递到材料中，因此，熔化深度减少，熔池形成的长度也会相应缩短，而单位时间粉末材料的累积变少也会直接导致熔高变低。此外，高扫描速度下，激光的能量辐射时间短，熔池在短时间内形成后也更快地被冷却，快速凝固有助于减少熔池的扩散，这也限制了熔池熔宽、熔深的增长。

2.3.3 送粉率对熔高、熔宽、熔深的影响

当送粉率未达到一定阈值时，增加送粉率会导致熔高的增加。随着送粉率的提高，会存在更多的粉末材料在激光照射下熔化并形成熔层。熔层的厚度随着送粉率的增加而增加，同时熔高也会随之增加。而当送粉率达到一定阈值后，激光透光率下降，这会导致基体吸收透光能量的线密度减小，熔覆材料的加热温度也会降低，熔层的厚度、熔高和熔深反而随着送粉率的增加而降低。但激光熔覆试验工艺参数是在已有研究基础上，根据初步优化的 IN718 镍基合金激光熔覆工艺参数进行再拓展，因此并未出现理论上的拐点，如图 17 所示。




图 17 送粉率与熔池形貌的关系

Fig. 17 Correlation between powder delivery rate and molten pool morphology

2.4 回归预测结果分析

基于正交试验法获得的 25 组激光熔覆试验数据，以激光熔覆主要工艺参数（激光功率、扫描速度、送粉率）作为输入值，同时以衍生参数熔池面积（ S ）、熔池温度（ T ）、熔高（ H ）、熔深（ D ）和熔宽（ W ）等参数作为输入值，获得输入值与响应目标（孔隙率 P_1 ）之间的非线性关系，试验检测结果归一化处理后如表 4 所示。

表 4 激光熔覆试验结果预处理表

Table 4 Pre-processing table for laser cladding test results

Group	S / mm^2	$T / ^\circ\text{C}$	H / mm	D / mm	W / mm	$P_1 / \%$
1	0.21	0.16	0.24	0.00	0.24	1.22
2	0.00	0.00	0.34	0.50	0.00	4.70
3	0.47	0.39	0.39	0.73	0.51	2.41
4	0.62	0.27	0.67	0.52	0.65	0.81
5	0.31	0.15	0.65	0.38	0.35	4.88
6	0.28	0.42	0.17	0.48	0.32	2.51
7	0.34	0.47	0.27	0.31	0.38	0.51
8	0.61	0.44	0.32	0.73	0.64	2.17
9	0.50	0.50	0.52	0.63	0.54	2.01
10	0.67	0.41	1.00	0.77	0.71	2.80
11	0.35	0.54	0.19	0.50	0.39	1.70
12	0.39	0.58	0.23	0.54	0.43	0.34
13	0.34	0.68	0.31	0.50	0.38	6.46
14	0.81	0.74	0.86	0.88	0.83	0.86
15	0.79	0.64	0.85	0.85	0.81	2.17
16	0.38	0.70	0.04	0.54	0.42	3.55
17	0.35	0.82	0.25	0.75	0.39	4.53
18	0.79	0.89	0.65	0.85	0.81	3.78
19	1.00	0.71	0.72	1.00	1.00	6.35
20	0.79	0.82	0.69	0.85	0.81	1.09
21	0.43	0.92	0.00	0.58	0.46	0.48
22	0.70	1.00	0.41	0.79	0.73	5.72
23	0.64	0.96	0.43	0.75	0.67	2.35
24	0.89	0.94	0.54	0.94	0.91	2.33
25	0.82	0.93	0.54	0.90	0.84	0.87

Where S is molten pool area; T is temperature, H is molten pool height, D is molten pool depth, W is molten pool width, P_1 is porosity.

分别利用基于梯度提升树的 LightGBM、XGBoost 以及 BP 神经网络来表达上述关系，对比其回归预测精度。随后，通过训练三种集成学习模型，形成能够准确表达激光熔覆工艺参数与孔隙率之间映射关系的黑盒函数，再利用粒子群法 PSO 智能寻优算法对该黑盒函数进行孔隙率最小值优化，最终实现激光熔覆工艺参数的优化。对构建好的 XGBoost (XGB)、LightGBM (LGB)、BP network 和 Stacking 回归模型进行对比分析，各模型的指标结果如表 5 所示。

表 5 不同模型评价指标对比

Table 5 Comparison of evaluation indicators for different models

Model	R^2	MAE	RMSE	MAPE	MSE
LightGBM	0.763 4	0.455	0.913	0.275	0.833
XGBoost	0.811	0.690	0.815	0.633	0.665
BP Network	0.633	1.888 3	2.375 9	0.499	5.645 3
Stacking	0.920	0.355	0.528	0.278	0.279

Where R^2 is goodness-of-fit, MAE is mean absolute error, RMSE is root mean square error, MAPE is mean absolute percentage error, MSE is mean square error.

由表 5 可以发现 Stacking 模型在数据集中, 其拟合优度 R^2 为 0.920, 平均绝对误差 MAE 为 0.355, 均方根误差 RMSE 为 0.528, 平均绝对百分比误差 MAPE 为 0.278, 均方误差 MSE 为 0.279, 是预测激光熔覆层孔隙率最为理想的回归模型。因此, Stacking 可以作为后续粒子群优化算法的适应度函数。

2.5 工艺参数优化及试验验证

经过测试, 最终使用 Stacking 模型作为回归算法。为了依据孔隙率结果反推出最优参数, 需要选择适用的优化算法。最终选择粒子群 PSO 智能寻优算法对该黑盒函数进行孔隙率最小值优化。

PSO 算法在寻优过程中, 需要给定适应度函数, 将 2.4 节建立的 Stacking 预测回归模型作为粒子群优化算法的适应度函数, 利用粒子群优化算法对 Stacking 预测回归模型进行迭代优化。其中目标函数为:

$$f(x) = \min(P) \tag{1}$$

式中, P 为最终结果的损失。

自适应算法的超参数设置分别为种群大小 N 为 100、迭代次数为 100、惯性权重 ω 为 0.9, 如表 6 所示。

表 6 粒子群算法超参数

Table 6 Particle swarm algorithm hyperparameters

Hyperparameter	Original value	Meaning
Learning rate	100	Population size
Learning momentum	100	Iterations
ω	0.9	Inertia weight
Popsiz	16	Number of individuals in a group

Where ω is inertia weight.

利用 python 编程求解可得, 量纲一化后激光功率、扫描速率、送粉率分别为 0.824 144 13、0.750 323 82, 0.602 505 05 时, 量纲一化逆转换后取整得激光功率、扫描速率、送粉率分别为 1 330 W、

460 mm / min、13 g / min, 激光熔覆孔隙率取得最小值。根据图 18 可知, 在最优参数组合下, 模型预测激光熔覆孔隙率的最小值为 0.21‰。




图 18 种群迭代结果

Fig. 18 Results of population iterations

2.6 激光熔覆工艺参数优化结果及试验验证

采用通过粒子群优化算法得出的 IN718 镍基合金激光熔覆最佳参数组合进行熔覆试验 (激光功率为 1 330 W、送粉率为 13 g / min、扫描速度为 460 mm / min)。采用超景深显微镜测量得到试验结果如图 19 所示, 对比试验值和预测结果, 可知 Stacking 模型的激光熔覆孔隙率预测精确度为 97.5%, 表明在优化参数条件下激光熔覆孔隙率预测的置信度可达到 73%以上。Stacking 预测模型对于未知数据具有良好的泛化能力, 能够为激光熔覆试验的参数优化提供指导。





图 19 优化参数后激光熔覆样横截面超景深图像


Fig. 19 Super depth of field image of laser cladding sample on cross-section after optimization of parameters

激光熔覆试验后, 通过线切割去除激光熔覆制造的基材, 得到厚度超过 2 mm 的板坯, 随后用 150#~2000# 的砂纸逐步去除多余的层, 以获得 2 mm 的完全平板; 在 SEM 观测前, 选用比例为 3 : 1 的 HCl-HNO₃ 腐蚀液对观察面进行腐蚀, 腐蚀

时间为 35 s。图 20 为采用优化激光熔覆参数组合的试样熔覆层与基体界面结合的微观 SEM 图,可以看出,基体与修复区底部、两侧之间形成了良好的冶金结合,修复区域未发现组织缺陷,修复成型质量较高。



(a) Before optimization



(b) After optimization

图 20 熔覆样横截面 SEM 图

Fig. 20 SEM image of the cross-section of laser cladding sample

3 结论

(1) 开发了一种改进型 SP-YOLOv5 算法模型,用于高精度测量激光熔覆孔隙率。在与 YOLOv5、FasterRCNN、RCNN 以及 ImageJ 软件的对比试验中,SP-YOLOv5 算法模型的检测精度显著高于其他模型,显示出对小目标孔隙的较高检测能力。

(2) 通过试验研究了激光熔覆工艺参数对熔池特征和孔隙率的影响,利用基于 Stacking 算法建立了回归预测模型,以及采用目标优化算法确定了最优工艺参数组合。在最优参数下,预测的激光熔覆孔隙率最小值为 0.21‰。

(3) 提出了一个二阶段监测模型,首先通过深度学习模型进行熔池区域的粗略检测,然后应用计算机图像处理技术进行精准测量,实现在复杂环境下对激光熔覆熔池区域的实时监测,提升了熔池特征提取的精度。

(4) 使用粒子群优化算法得出的最佳工艺参数组合(激光功率 1 330 W、扫描速度 460 mm/min、

送粉率 13 g/min) 进行激光熔覆试验。试验结果显示,在这些优化参数下,Stacking 模型预测的孔隙率与实际测量值的一致性达到 97.5%,验证了优化方法的有效性,显著提高了熔覆层的质量。

参 考 文 献

- [1] BYKOVSKIY D P, PETROVSKIY V N, POLSKIY V I, et al. Development of the recovery technology for nickel superalloy blades of the aircraft engine by laser cladding[C]//II Conference on Plasma & Laser Research and Technologies, January 25-27, 2016, Moscow, Russia. Moscow: Journal of Physics: Conference Series. IOP Publishing, 2016, 747(1): 012056.
- [2] LIU J M, WU L S, SONG M J, et al. Crack resistance behaviour of aluminium alloy for aircraft skin with bionic coupling units processed by laser cladding[J]. Fatigue & Fracture of Engineering Materials & Structures, 2020, 43(11): 2756-2760.
- [3] 刘雪丽, 李和智, 卿颖, 等. 激光修复 GH4169 合金零部件关键技术研究[J]. 稀有金属, 2021, 45(6): 758-762. LIU Xueli, LI Hezhi, QING Ying, et al. Key technology of laser repairing GH4169 alloy parts[J]. Chinese Journal of Rare Metals, 2021, 45(6): 758-762. (in Chinese)
- [4] TAKUTO Y, KEIGO T, HIDEKI H, et al. Porosity reduction in WC-12Co laser cladding by aluminum addition[J]. International Journal of Refractory Metals and Hard Materials, 2023, 110: 106020.
- [5] WANG J, SHEN J B, SHEN Z S, et al. Analysis of the crack initiation and short crack propagation of laser cladding IN718 enduring fretting fatigue at 650 °C[J]. Tribology International, 2024, 19: 109484.
- [6] DEBROY T, WEI H L, ZUBACK J S, et al. Additive manufacturing of metallic components-process, structure and properties[J]. Progress in Materials Science, 2018, 92: 112-224.
- [7] 姚喆赫, 姚建华, 向巧. 激光再制造技术与应用发展研究[J]. 表面工程与再制造, 2020, 20(5): 23-27. YAO Zhehe, YAO Jianhua, XIANG Qiao. Research on laser remanufacturing technology and application development[J]. Surface Engineering & Remanufacturing, 2020, 20(5): 23-27. (in Chinese)
- [8] WANG F, LI G H, LIU M, et al. Acquisition of heterogeneous constitutive relationship of Ni60 laser cladding layer based on nano-indentation experiment[J]. Materials Today Communications, 2023, 34: 105049.
- [9] SHLYANNIKOV V, SULAMANIDZE A, YARULLIN R.

- Fatigue and creep-fatigue crack growth in aviation turbine disk simulation models under variable amplitude loading[J]. *Engineering Failure Analysis*, 2022, 131: 105886.
- [10] BAX B, RAJPUT R, KELLET R, et al. Systematic evaluation of process parameter maps for laser cladding and directed energy deposition[J]. *Additive Manufacturing*, 2018, 21: 487-494.
- [11] YU T B, YANG L, ZHAO Y, et al. Experimental research and multi-response multi parameter optimization of laser cladding Fe313[J]. *Optics and Laser Technology*, 2018, 108: 321-332.
- [12] XU P X, LI P Y, CHEN Y S, et al. Optimization of process parameters for laser cladding Stellite6 cobalt-based alloy[J]. *Materials Today Communications*, 2024, 28: 108430.
- [13] LI Z Q, DU Y B, HE G H, et al. Parameters optimization for single-track laser cladding based on MPA-SVR and A-NSGA-III[J]. *Optics & Laser Technology*, 2024, 169: 110069.
- [14] DELCUSE L, BAHY S, GUNPUTH U, et al. Effect of powder bed fusion laser melting process parameters, build orientation and strut thickness on porosity, accuracy and tensile properties of an auxetic structure in IN718 alloy[J]. *Additive Manufacturing*, 2020, 36: 101339.
- [15] HOSSEIN E S, SUHYUN M, LIANG X Z, et al. Controlling crack formation and porosity in laser powder bed fusion: alloy design and process optimisation[J]. *Additive Manufacturing*, 2020, 34: 101360.
- [16] KAZEMIPOUR M, MOHAMMADI M, MFOUMOU E, et al. Microstructure and corrosion characteristics of selective laser-melted 316L stainless steel: the impact of process-induced porosities[J]. *JOM*, 2019, 71: 3230-3240.
- [17] CHEN S, CAI W H, WU J M, et al. Porous mullite ceramics with a fully closed-cell structure fabricated by direct coagulation casting using fly ash hollow spheres / kaolin suspension[J]. *Ceramics International*, 2020, 46(11): 17508-17513.
- [18] LIANG J W, LIU W, YANG G, et al. Rapid preparation of hierarchically porous ceramic microspheres based on UV-curing-assisted molding[J]. *Journal of the European Ceramic Society*, 2021, 41(16): 232-238.
- [19] WANG Y X, ZHU S F, ZHOU X Z, et al. Effect of sintering process on micro-structure and properties of mullite porous ceramics containing magnesium oxide[J]. *Journal of Physics: Conference Series*, 2021, 2206: 012037.
- [20] ZHANG B, LIU S Y, SHIN Y C. In-process monitoring of porosity during laser additive manufacturing process[J]. *Additive Manufacturing*, 2019, 28(4): 497-505.
- [21] ZHOU S X, SHENG W, WANG Z P, et al. Quick image analysis of concrete pore structure based on deep learning[J]. *Construction and Building Materials*, 2019, 208(5): 144-157.

作者简介: 盛杰, 男, 1981 年出生, 博士, 硕士研究生导师。主要研究方向为激光先进制造技术。

E-mail: shengjie@ujs.edu.cn

黄舒 (通信作者), 女, 1983 年出生, 博士, 研究员, 博士研究生导师。主要研究方向为激光先进制造技术。

E-mail: huangshu11@sina.com