

· 特邀综述 ·

# 基于机器学习的激光定向能量沉积质量预测与工艺参数优化

王振忠<sup>1\*</sup>, 刘超凡<sup>1</sup>, 李毅<sup>1</sup>, 吴俊波<sup>1</sup>, 陈丰<sup>2</sup>

(1. 厦门大学航空航天学院, 福建 厦门 361102; 2. 华侨大学机电及自动化学院, 福建 厦门 361021)

**摘要:** [背景] 激光定向能量沉积(LDED)技术是增材制造中备受关注的工艺之一, 具有加工效率高、成形灵活度高等优点。然而由于沉积过程中多种复杂因素的相互作用, 使得加工过程中熔池的形态特征与影响因素的相互关系难以仅通过传统手段监测得到, 因此, 较难准确预测工件的质量和选择合适的工艺参数。而机器学习(ML)算法具有强大的非线性处理能力和自适应学习能力, 有望实现对加工过程缺陷的检测与预测、工件成形精度和性能预测及工艺参数的逆向求解。[进展] 首先, 本文总结了两种常见 LDED 形式、LDED 加工过程中常见缺陷类型及缺陷产生的原因, 并对四种基于光学相机、温度场监测、光谱分析和声学传感器的数据采集方式进行分类比较; 然后对常用于 LDED 中的监督学习、无监督学习及半监督学习算法进行比较总结, 分析各自适用场景及优缺点; 最后, 从 ML 在 LDED 缺陷检测与预测、成形精度预测、成形性能预测和工艺参数逆向求解四个方面进行综述, 系统阐述如何利用各类传感器并结合 ML 算法对 LDED 工件加工质量进行优化。[展望] 建立多 ML 算法融合的模型、探究信号和缺陷之间的定量关系和实现多传感器数据融合监测, 有望厘清 LDED 工艺参数与沉积质量的关系, 为提升 LDED 沉积质量提供理论指导。

**关键词:** 增材制造; 激光定向能量沉积(LDED); 机器学习; 过程监测

中图分类号: TG 665

文献标志码: A

文章编号: 0438-0479(2025)02-0225-16

## A review of machine learning-based quality prediction and process parameter optimization in laser directed energy deposition

WANG Zhenzhong<sup>1\*</sup>, LIU Chaofan<sup>1</sup>, LI Yi<sup>1</sup>, WU Junbo<sup>1</sup>, CHEN Feng<sup>2</sup>

(1. School of Aerospace Engineering, Xiamen University, Xiamen 361100, China; 2. College of Mechanical Engineering and Automation, Huaqiao University, Xiamen 361021, China)

**Abstract:** [Background] As one of most prominent processes in additive manufacturing, laser directed energy deposition (LDED) technology offers advantages such as high processing efficiency and exceptional flexibility in shaping. However, due to the interaction of multiple complex factors during the sedimentation process, it is difficult to accurately predict the quality of the workpiece and select appropriate process parameters by monitoring the relationship between the morphological characteristics of the molten pool and the influencing factors solely through traditional methods. Machine learning (ML) algorithms combined with LDED, with their powerful nonlinear processing capability and adaptive learning ability, can detect as well as predict defects in the process, forecast the forming accuracy as well as the performance of the workpiece, and solve process parameters inversely. [Progress] First in this paper, we summarize two common forms of LDED, namely the typical defect types encountered in LDED processing and the factors contributing to their occurrence. Four primary data acquisition methods based on optical cameras, thermal field monitoring, spectroscopy, and acoustic sensors are categorized and compared. Second, we provide a comparative analysis of supervised learning,

收稿日期: 2024-09-18 录用日期: 2025-02-09

\* 通信作者: wangzhenzhong@xmu.edu.cn

引文格式: 王振忠, 刘超凡, 李毅, 等. 基于机器学习的激光定向能量沉积质量预测与工艺参数优化[J]. 厦门大学学报(自然科学版), 2025, 64(2): 225-240.

Citation: WANG Z Z, LIU C F, LI Y, et al. A review of machine learning-based quality prediction and process parameter optimization in laser directed energy deposition[J]. J Xiamen Univ Nat Sci, 2025, 64(2): 225-240. (in Chinese)



unsupervised learning, and semi-supervised learning algorithms commonly used in LDED, and discuss their respective application scenarios, strengths, and limitations. Finally, we systematically review four aspects: (a) ML-based defect detection and prediction, (b) shape accuracy prediction, (c) mechanical property prediction, and (d) inverse solving of process parameters. Consequently, we are capable of illustrating how various sensors can be integrated with ML algorithms to optimize the manufacturing quality of LDED components. [Perspective] Establishing a multi-ML algorithm fusion model, exploring the quantitative relationship between signals and defects, and implementing multi-sensor data fusion monitoring are expected to clarify the relationship between LDED process parameters as well as sedimentation quality, and provide theoretical guidance for improving LDED sedimentation quality.

**Keywords:** additive manufacturing; laser directed energy deposition(LDED); machine learning; process monitoring

增材制造(additive manufacturing, AM)技术是一种根据计算机模型逐层构建金属部件的制造技术<sup>[1]</sup>. 与传统减材制造方法相比, AM不仅可以生成复杂结构组件, 还能促进功能梯度材料的合成<sup>[2-5]</sup>, 已被广泛用于航空和医疗等领域<sup>[6-7]</sup>. 其中, 激光定向能量沉积(laser directed energy deposition, LDED)技术被认为是最具应用前景的 AM 方式之一<sup>[8]</sup>, 该技术主要包括材料供给、激光熔覆和材料沉积<sup>[9-12]</sup>, 这 3 个过程直接影响零件的最终成形质量. 在熔融状态下, 金属材料经历反复的加热和冷却, 容易产生气孔和微小裂纹. 这些缺陷不仅削弱了工件的整体强度, 特别是疲劳强度和抗拉强度, 同时还可能成为应力集中点, 导致材料在应力作用下更易断裂<sup>[13-15]</sup>. 气孔和裂纹等缺陷的产生往往具有高度随机性和不确定性<sup>[16]</sup>, 仅采用传统的阈值过滤和 Canny 边缘检测算法很难对其进行有效识别<sup>[17]</sup>. 此外, 由于加工过程的复杂性, 工件精度和性能的一致性难以保证, 对每个工件进行性能测试将增加测试成本. 因此, 如何保证工件的质量和性能已成为当前 LDED 技术的重大挑战.

机器学习(machine learning, ML)能够从大量数据中提取有价值的经验并总结规律, 其在 AM 领域的应用越来越广泛<sup>[18-21]</sup>. 首先, 在缺陷检测与预测方面, 研究人员采用相机等传感器与卷积神经网络(CNN)等算法相结合, 成功实现了对 LDED 构建过程的实时监测<sup>[22]</sup>. 这种方式提高了缺陷检测及预测的准确性, 而且大大提升了响应速度, 减少了人为干预的误差. 此外, 在工件成形精度和机械性能方面, ML 模型可通过大量历史数据及测量结果, 实现对加工过程中沉积层宽度、高度及未知工件残余应力、拉伸性能等机械特性的预测, 大大减少了重复表征及后处理成本<sup>[23-24]</sup>. 另外, 通过人工重复试验确定所需加工参数将耗费大量资金和时间, ML 在实验初期的工艺参数选取上也发挥了重要作用. 基于不同参数下的加工实验结果, 并结合遗传算法等手段, ML 模型可迭代优化、逆向求解出目标结果下的最佳工艺参数, 从而减少了大量重复试验成本<sup>[25]</sup>.

基于以上背景, 本文围绕 ML 在 LDED 中的应用展开详细综述, 重点探讨其在缺陷检测与预测、成形精度预测、成形性能预测及工艺参数逆向求解四个方面的进展与挑战, 旨在为相关领域学者在 LDED 过程中的智能监测、预测及参数优化的研究提供参考.

## 1 LDED 加工方式及缺陷

### 1.1 LDED 加工方式

LDED 技术根据原料供给方式的不同, 主要分为基于送粉的 LDED (laser powder-directed energy deposition, LPDED) 和基于送丝的 LDED (laser wire-directed energy deposition, LWDED) 两种形式<sup>[26]</sup>. LPDED 采用高能激光束, 将被喷嘴通过保护气流送至激光焦点处的金属粉末迅速加热至熔融状态, 冷却后的熔融金属逐层堆积在基板表面, 最终制造出预定的三维模型<sup>[27]</sup>.

在 LPDED 过程中, 高密度的金属粉末容易对监测系统造成遮挡, 影响对熔池和工件表面的观察<sup>[28]</sup>. LPDED 的工艺原理如图 1(a) 所示. LWDED 采用金属丝作为原料, 金属丝通过供丝系统精确输送至激光焦点处, 在激光的高能量作用下熔化, 并逐层沉积形成零件. 相较于 LPDED, LWDED 在制造过程中由于没有粉末引起的遮挡, 光学环境更为稳定, 相机等仪器更能精确地监控熔池大小、温度分布及工件成形情况<sup>[29]</sup>. LWDED 的工艺原理如图 1(b) 所示.

在 LPDED 及 LWDED 过程中, 不同的工艺参数对零件最终的质量及性能将会产生较大影响. 以 LWDED 为例, 激光功率的大小决定了能量的输入, 将直接影响熔池的温度和尺寸. 过高的激光功率会导致过度熔化, 熔池温度过高而出现形态失稳, 进而导致熔道表面氧化或形成气孔; 而过低的激光功率可能导致丝材熔化不充分, 熔池的深度和宽度较小, 沉积层之间的结合较差<sup>[32]</sup>. 其次, 不同的送丝速率也会影响加工质量, 当送丝速率过快时, 丝材未充分熔融将引起丝




图 1 两种直接能量沉积系统<sup>[30-31]</sup>

Fig. 1 Two directed energy deposition systems

材的堆叠;送丝速率不足时将导致激光对已冷却层再次加热,引起熔池温度分布异常<sup>[33]</sup>.可以看出 LDED 中可调的工艺参数主要影响熔池的形貌、温度和加工效率,形貌和温度又和 LDED 缺陷息息相关,并进一

步影响 LDED 加工工件的力学性能.因此在 LDED 中,可以通过对熔池形貌及温度情况来优化加工过程.表 1 总结了 LPDED 与 LWDED 加工过程中多种可供调节的工艺参数.

表 1 LDED 中可调工艺参数及其可能影响

Tab. 1 Adjustable process parameters in LDED and their potential impacts

可调工艺参数	可能造成的直接影响	文献
激光功率	1. 过高导致熔池形态失稳、熔道表面氧化或产生气孔 2. 过低将导致丝材熔化不充分,熔池深度、宽度较小,与基材结合较差	[32,34]
送丝/粉速率	1. 过快导致材料堆叠,熔池不均匀 2. 不足导致材料供应不及时,加工效率低,熔池深度减小,甚至出现温度分布异常	[33]
扫描策略	1. 过快导致熔融不充分,熔池宽度和深度减小 2. 过慢导致熔池材料和热累积严重,加工效率低 3. 路径不合理导致热累积	[35-36]
保护气流速	1. 过大引起熔池形状异常,产生气孔 2. 过小导致材料氧化	[37]
激光光斑尺寸	1. 过大导致能量密度不足、熔池较浅 2. 过小导致熔覆不均,熔池较小	[38]

## 1.2 LDED 缺陷

缺陷是影响 LDED 工件性能和服役寿命的主要因素,其形成由原料、输入能量、基材和环境之间异常的相互作用所致<sup>[39]</sup>.在 LDED 过程中,熔池在重力、表面张力和温度梯度的共同作用下流动,熔池的形貌和温度分布决定了结构凝固的形态、晶粒生长和内部缺陷.缺陷的存在不仅会损害零件表面的完整性,还会削弱工件的整体强度<sup>[40-42]</sup>.例如,温度较高的熔池会导致较慢的冷却速率,从而生成粗大的晶粒,降低材

料的拉伸和疲劳强度<sup>[43]</sup>.LDED 中常见的缺陷有气孔、裂纹和材料未完全融合等<sup>[44-46]</sup>,这些缺陷的形成也与熔池的情况密不可分.

以气孔为例,气孔可分为层间孔和层内孔,层间孔形状不规则,通常沿层边界拉长,主要由熔池温度分布不均匀所导致;而层内孔主要由熔池内溶解或截留的气体因冷却过快而没有足够的时间逸出所致<sup>[47]</sup>.无论是熔池温度分布异常还是冷却速率不佳都容易导致在工件加工过程中产生孔隙.除气孔外,LDED 中常见的缺陷还有裂纹,裂纹的萌芽与扩展主要由熔

覆层内的应力引起,而应力的产生很大程度取决于工件成形过程中的熔池的冷却速率和温度梯度<sup>[48]</sup>.因此在 LDED 过程中对熔池的温度、保护气的流速等参数

进行监测,了解并构建熔池参数与缺陷产生的对应关系是优化 LDED 工件性能的基础. LDED 中常见的缺陷类型及影响因素如表 2 所示.

表 2 LDED 过程常见缺陷类型  
Tab. 2 Common defect types in LDED process

缺陷种类	引起缺陷的可能工艺参数	潜在风险	文献
气孔	1. 材料供给不均匀 2. 激光能量输入不足或过高	1. 减弱工件的整体强度 2. 增加疲劳裂纹的风险	[49-51]
裂纹	1. 扫描策略不佳引起热应力 2. 激光功率过大引起热应力	1. 增加工件脆性和失效风险 2. 降低工件的抗拉强度	[52]
缺乏融合	1. 激光功率过小无法熔化原料 2. 扫描速度过快 3. 粉末或丝材供给过快	1. 降低工件的结构强度 2. 增加裂纹的产生	[32,53]
球化	1. 激光功率过小熔覆不均 2. 粉末颗粒尺寸不均	1. 增加零件表面粗糙度 2. 可能导致未熔合缺陷	[54]
飞溅	1. 激光功率过大 2. 保护气流速过大	1. 表面质量和精度下降 2. 造成丝材浪费,增加成本	[55]
几何变形	1. 扫描策略不合理引起热积累 2. 激光束光斑过大	1. 可能造成零件无法使用 2. 增加后处理成本	[56-59]

## 2 LDED 数据采集及处理方式

在 LDED 加工过程中引入实时监测,不仅可以实时监测加工参数,还可以利用后期检测出的缺陷与实时加工参数构建加工参数标注的缺陷数据库,进一步利用 ML 方法建立加工参数时空特征与缺陷的关系,对工件的成形质量进行预测,从而在线调控工艺参数,优化工件的性能及成形精度;此外,基于已有数据库,还能利用先进算法求解出合适的加工参数组合.相对于传统依赖生产后检查 LDED 工件缺陷的手段,这类方法不需要对工件进行破坏性实验,同时降低了工件的后处理成本.本节介绍了 LDED 加工过程中和加工结束后的数据采集方式及各自特点,并对基于 ML 的数据处理方式进行比较和总结.

### 2.1 LDED 主要数据采集方式

#### 2.1.1 加工参数采集

在 LDED 过程中,高能激光和丝材等原料的相互作用会产生大量的光、热、声等数据,这些数据中包含了丰富的加工信息.近几年的研究中,基于捕获光信号的视觉成像系统得到广泛应用,主要原因在于光学相机成本相对较低,却能较好地捕获熔池整体形态参

数,同时基于 ML 的图像处理算法近些年发展迅速,图像数据识别准确率和效率大幅提升.基于同轴相机的监测系统能够连续跟踪熔池并提供二维图像,再利用 ML 模型对熔池图像进行分割提取,不仅可以识别熔池面积、长度和宽度,还能根据熔池的灰度占比对原料熔融情况进行定性分析,相机监测系统示意图如图 2(a)所示<sup>[60]</sup>.在多层薄壁件中,热积累会对熔池特性产生显著影响.随着层数增加,热积累会导致熔池内部对流更加剧烈,引起沉积宽度不均匀或高度低于目标值,还可能造成因热应力引发的工件尺寸变形<sup>[60]</sup>.在加工过程中,对熔池温度数据的采集主要依靠温度热电偶和热成像仪等传感器,以采集熔池或沉积层单点的温度分布及变化情况来调控激光功率等加工参数,还可以根据加工过程的热历史数据优化加工路径,避免 LDED 过程中的热积累现象,工件加工过程的熔池热力图如图 2(b)所示.另外,薄壁结构工件更容易受到细微缺陷、开裂和变形的影响,而超声波在检查 LDED 制造的薄壁结构时沿结构传播的衰减很小,能够覆盖大范围检查区域,对细微缺陷的敏感性更好,因此在打印薄壁件时,基于声信号的数据采集手段应用更为广泛<sup>[61]</sup>.当超声波检测到缺陷时,其频率往往会发生改变,缺陷与异常声信号的关系如图 2(c)所示.

### 2.1.2 缺陷与性能参数采集

除了对加工过程进行数据采集,当加工过程结束后,还需对工件内部缺陷位置及性能参数进行表征,以获得在特定工艺参数下工件的特征数据,用于创建实验数据集.其中,X射线扫描常用于对工件内部缺陷及材料均匀性进行检查,不仅可以为现场监测数据提供最真实标签,还能在事后锁定各个微小孔隙的空间位置,用作评判加工结果的指标.X射线穿透工件时与材料的微观结构相互作用,缺陷区域(如气孔、裂纹)吸收X射线较少,使透射信号衰减降低,X射线图则含有工件的缺陷信息,再利用图像处理算法即可提取缺陷区域并构建相应数据库,其检测示意图如图2(d)所示<sup>[62]</sup>.但X射线辐射存在一定安全风险,会增加监测

过程的复杂性和成本.此外,激光线扫描也常用于LDED工件的形貌数据采集,通过将线激光投射到物体表面并计算偏移量,系统可以生成工件形貌的3D点云数据集,并对工件表面突起和凹痕区域进行像素级别识别<sup>[63]</sup>.虽然激光线扫描在LDED检测中前景巨大,但如何设计先进算法对庞大的点云数据进行高效处理是目前面临的挑战之一.另外,在采集加工工件内部质量数据时还常采用显微镜对缺陷部位进行标记或对晶粒生长情况进行评价,并与加工过程中采集的图像或声信号建立相应关系以此来构建目标数据库.针对工件的各种机械特性的性能参数,仍常采用万能试验机、硬度计和钻孔法等后处理方法,并用于提升ML方法的预测性能.

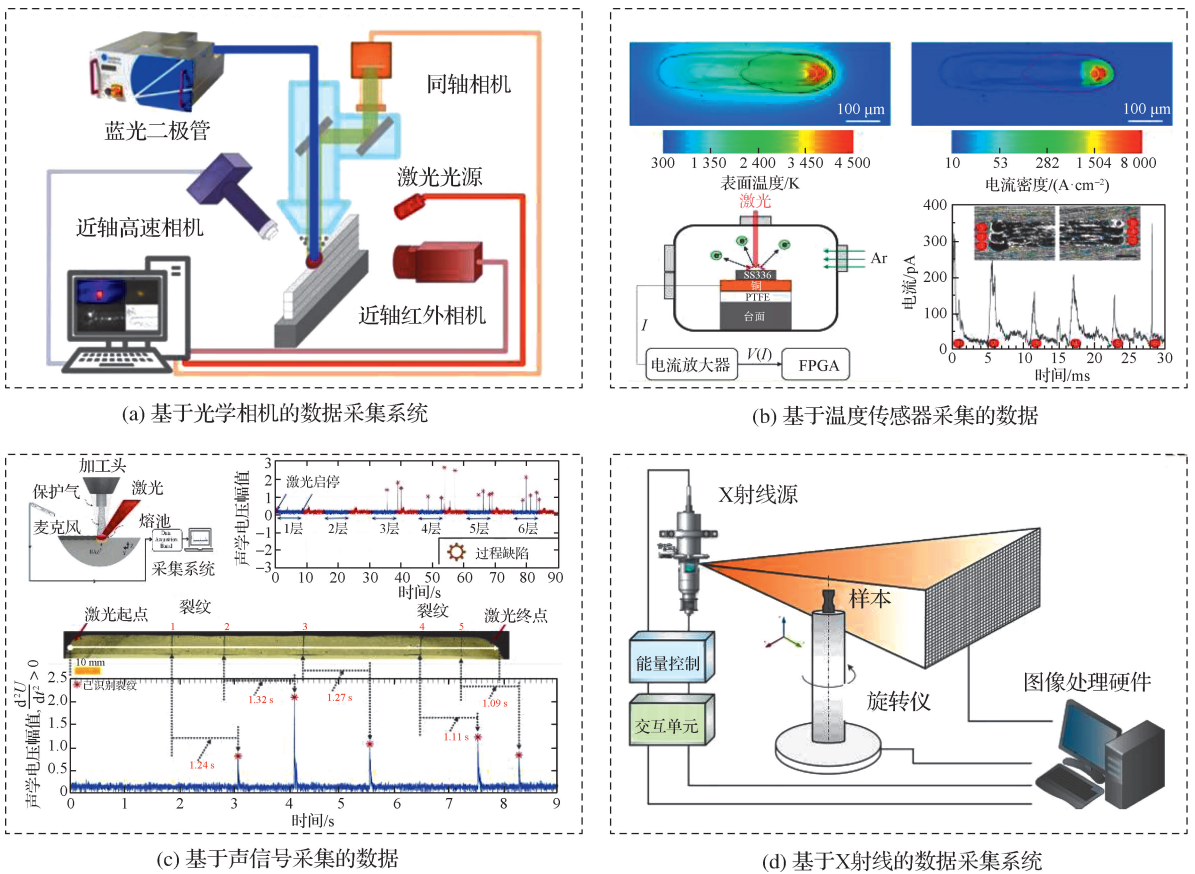


图 2 LDED 主要监测手段<sup>[60,64-66]</sup>

Fig. 2 Main monitoring methods for LDED

## 2.2 基于 ML 的数据处理方式

传统的数据分析和处理方式主要是基于时域、频域和傅里叶变换<sup>[67]</sup>,这些方法在处理低维信息时非常有效,但在处理 LDED 监测过程中的高维度、多模态复杂数据时往往表现较差<sup>[68-69]</sup>.为了弥补传统数据处理方法的不足,ML 逐渐被引入 LDED 监测数据的分析与处理.常见的 ML 方法主要分为 3 大类:监督学

习、无监督学习以及半监督学习.其中,监督学习基于大量经过标注的数据集训练模型,再结合相机或声学传感器对加工过程中的数据进行原位识别,达到实时监测的目的.常见的监督学习有支持向量机(SVM),主要用于分类和回归任务,在 LDED 中可用于划痕和凹坑缺陷的分类<sup>[70]</sup>.无监督学习是在缺乏数据标注的情况下,通过自动聚类发现异常数据,如 K 均值聚类

就是一种常用的无监督学习,常用于对熔池形态进行标准分类<sup>[71]</sup>. 半监督学习是在标注数据较少的情况下,结合少量标注数据和大量未标注数据进行训练,有效降低了对标注样本量的依赖,减少了标注成本,主要用于基于已知工艺参数对沉积宽度的预测等<sup>[72]</sup>. 表 3 总结了各种 ML 算法在 LDED 过程中的应用情况.

尽管监督式机器学习的准确率比传统数据处理手段的准确率更高,但其仍然存在明显的缺点:1) 特

征数据的定义和提取必须手动进行,容易受到人为判断的干扰;2) 必须建立在庞大的标注数据上,需要耗费较大的时间成本构建数据集. 而半监督学习有效降低了对缺陷标注样本量的依赖,减少了标注成本,特别适用于缺陷标注数据稀缺的情况,但其在数据分布复杂的情况下存在一定的不确定性. 无监督学习可以自动发现不同工艺参数和材料性能之间的潜在关联,更适用于复杂数据集,如指导工艺参数的选择或提供参数调优的初步方向.

表 3 机器学习算法在 LDED 中的应用总结

Tab. 3 Application summaries of machine learning algorithms in LDED

机器学习类别	使用算法	输入数据	应用场景	文献
监督学习	支持向量机	熔池图像	表面质量检测	[70]
	决策树与随机森林(RF)	工艺参数	疲劳性能预测	[73]
	K 近邻算法	合金成分	加工路径规划	[74]
	朴素贝叶斯网络	温度数据	局部温度预测	[75]
无监督学习	<i>t</i> 分布聚类算法	图像数据	熔池特征可视化	[71]
	自编码器	发射光谱	区分沉积质量	[76]
	自组织映射	几何特征	残余应力评估	[77]
半监督学习	CNN	熔池图像	熔池宽度控制	[72]
	高斯混合模型	拉伸测试数据	缺陷识别	[78]

### 3 ML 在 LDED 中的应用

目前,ML 的应用主要集中在 LDED 工件的缺陷检测与预测、成形精度及性能预测和工艺参数逆向求解等关键领域. 在缺陷检测与预测方面,ML 算法能够基于传感器数据,及时识别加工过程中可能引发的缺陷和异常,例如 CNN 等深度学习模型已广泛应用于孔隙和裂纹的自动识别. 在成形精度预测方面,ML 模型通过工艺参数及监测数据来实现对熔覆层宽度及高度的预测,从而将预测值作为补偿依据,以此来优化加工精度. 在成形性能预测方面,基于加工过程数据与测量得到的残余应力值和机械特性,ML 可实现基于已知工艺过程完成对未知工件局部应力和机械特性的预测,节约了表征成本. 在工艺参数逆向求解方面,结合贝叶斯优化、遗传算法等技术,ML 算法可基于基础实验数据通过迭代优化求解出最佳工艺参数范围,从而提高实验效率.

#### 3.1 缺陷检测与预测

随着 LDED 技术的不断发展,对工件加工过程的

原位监测已成为研究的重点,原位监测可有效检测与预测加工过程中产生的缺陷,有助于避免缺陷的产生和扩大. Mi 等<sup>[79]</sup>采用 MEMRECAM ACS-1 高速相机以 30 000 帧/s 的帧率拍摄了 700 张 LDED 过程中不同激光功率和扫描速度下熔池与熔液飞溅的图像,并使用基于 CNN 开发的深度 CNN 半监督学习模型提取熔池和熔液飞溅图像的特征,实现了对复杂熔池形貌特征和超小飞溅物的原位监测,模型的识别准确率高达 94.71%. Chen 等<sup>[80]</sup>利用 LDED 过程中采集的原位声学信号,并结合显微光学图像对内裂纹和锁孔位置进行事后标记,寻找出缺陷产生时的异常声学信号,再将缺陷声学特征输入至 CNN 进行训练,实现了对缺陷 93% 的原位检测率. Hespeler 等<sup>[81]</sup>提出了一种无损同步检测方法,该方法使用同步收集的低采样率原位图像数据集,结合零件的计算机断层(CT)扫描的非原位评估来创建孔隙、裂纹等缺陷数据集,再将数据输入至 CNN、RF 和 SVM 中,分别对层间质量进行监督学习分类,结果表明 CNN 可以达到 90% 的原位分类准确率,表现最好. Park 等<sup>[82]</sup>基于 ResNet-50 迁移学习架构,构建了在训练数据较少的情况下对

316L 不锈钢金属粉末沉积质量的 CNN 评估模型,并对金属沉积横截面的 3 个内在质量:正常状态、表面毛刺和内部缺陷实现了自动分类检测,结果表明其分类准确率达到 84.91%。缺陷的原位检测可用于评价工件的性能,而缺陷的预测能够为改善工件性能提供基础。光学相机采集的数据能够较好地反映加工过程中的形貌特征,而温度传感器能够及时捕获加工过程中的温度信息,完成对成形过程的进一步分析。Guo 等<sup>[83]</sup>开发了一种基于 VGG16 的混合物理驱动深度学习模型,该团队首先将微型 CT 测量得到的大于 0.05 mm 的孔隙,映射到双波长高温计和红外摄像机收集到的熔池高温图像中进行特征级时空匹配,再以多模态信息输入至 ML 模型进行监督学习,并以工件内特定区域内的缺陷位置为输出,结果表明,该模型对工件的孔隙预测准确率达到 89%。Chen 等<sup>[84]</sup>提出了一种基于多传感器的 LDED 工件质量预测方法,该方法利用同轴相机、声发射器和短波红外热像仪采集熔池实时

数据,再结合光学显微镜进行缺陷特征提取,并将时空融合的数据及标签输入至 ML 模型中训练以预测缺陷位置(图 3),结果表明,该多传感器融合框架实现了 96% 的缺陷预测精度。Abranovic 等<sup>[85]</sup>通过装在机器人手臂上的摄像机收集 LDED 中的熔池图像信息,并将其输入至组合卷积长短期记忆(ConvLSTM)人工神经网络进行训练,经训练的模型架构可通过当前熔池形态信息作为输入预测缺陷是否产生,该网络采用无监督学习方法,仅识别熔池不规则性,而不识别缺陷类型,大大减少训练开销。在 LDED 缺陷检测与预测中,主要通过光学相机、声学传感器或温度仪采集的原位加工数据,再结合 CT 或光学显微镜表征得到的缺陷数据作为数据标签,ML 即可快速建立起加工场景下缺陷与加工数据之间存在的潜在关系,并用于不同场景下缺陷的检测与预测,但对于如何精准调控加工参数从而抑制缺陷的产生和生长仍需要进一步研究。

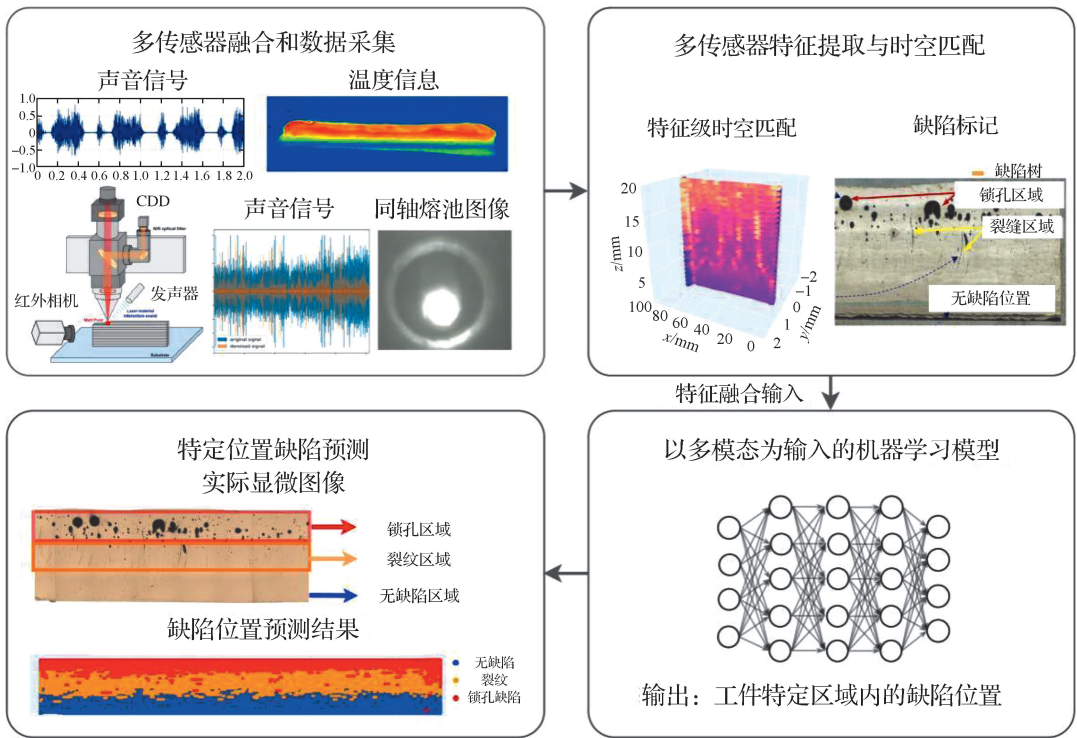


图 3 基于多传感器融合框架的缺陷预测流程

Fig. 3 Defect prediction workflow based on a multi-sensor fusion framework

### 3.2 成形精度预测

LDED 工件由多层熔覆层依次堆叠产生,单个熔覆层的沉积质量决定工件最终的成形精度,因此对每一层的精度控制十分重要。由于熔池溢流(molten pool overflow, MPO)会造成 LDED 工件几何形状的波动, Li 等<sup>[86]</sup>采用测温模块和光学相机收集熔池温度场和

速度场数值信息,并使用 Keyence LJ-V7200 高速轮廓测量仪来获取有关熔覆层的几何信息用于制作标签,建立不同送粉速度下的熔池 MPO 三维数值模型数据库,并在此基础上开发了 RF-长短期记忆网络(RF-LSTM)监督学习模型来预测每层熔覆层高度(图 4),结果表明该模型决定系数  $R^2$  为 0.939 8,并为

实验可视化提供了理论指导. 为了实时监测 LDED 过程的沉积高度, Yu 等<sup>[87]</sup> 基于 GXTECH GXP-4112-23 相机对五轴增减材加工过程进行实时监测, 提出了一种将 YOLO 目标跟踪算法与图像处理技术相结合的实时机器视觉监测方法, 并构建了一种新的自注意时间卷积网络(SA-TCN)监督学习模型, 该模型融合了因果扩张卷积和注意力机制, 对未来沉积高度实现了 99.71% 的预测率. 除了对熔覆层高度的预测, 对沉积轨道的宽度预测也是保证质量的关键. Yu 等<sup>[88]</sup> 提出了一种创新的特征融合深度学习 (FF-DPL) 模型, 该模型融合了动态图像特征、静态处理参数(激光功率、扫描速度和送粉速率)及光学显微镜测量的轨道宽度和高度, 仅使用较小的数据集和更少的数据特征即显著提高了预测精度, 结果表明该方法对 LDED 沉积轨道预测宽度和高度的平均准确率分别为 98.45% 和 93.97%. Mochi 等<sup>[72]</sup> 构建了一种基于熔池图像实时预测沉积轨道宽度的半监督 ML 模型, 该模型以 MarSurf 轮廓仪测量的沉积轨道参数和 12 379 张熔池图像创建标记数据集, 用于训练模型并预测沉积轨道宽度, 结果表明模型拟合的平均绝对误差仅为 4.5%. 由于打印过程层高的

变化会影响激光聚焦, Ribeiro 等<sup>[89]</sup> 提出了一种监督式混合 ML 模型(HMLM), 该模型使用迁移学习将预先训练的 CNN 和支持向量回归(SVR)相结合, 以捕获的熔池图像及加工高度为输入, 输出捕获图像时激光距沉积层距离, 再根据每层高度动态调整加工轴 Z 轴增量, 结果表明, 该方法有效避免了因加工工件高度抬升引起的激光失焦现象, 从而有效抑制了沉积宽度变大引起的几何变形. Li 等<sup>[90]</sup> 对深度学习模型 Mask R-CNN 进行改进, 用于熔池目标场景分割, 利用该模型对熔池图像进行处理后得到熔池的几何特征参数, 最后基于 Stacking 集成学习模型建立工艺参数与熔覆层高度之间的预测模型, 结果表明其高度预测最大平均误差仅为 2.4%. 在成形精度预测中, 过程数据集主要以图像和温度数据为主, 再结合光学显微镜及测量仪测量得到的沉积轨道宽度和高度为数据标签训练 ML 模型, 模型能建立起过程数据与沉积宽度与高度之间的关系. 另外, 对于时序卷积网络(TCN)和 LSTM 的融合网络这类 ML 模型, 在处理动态图像和温度信息时能实现更加准确的加工精度预测效果, 再根据预测结果动态调节部分加工参数, 有利于制造出精度更高的 LDED 工件.

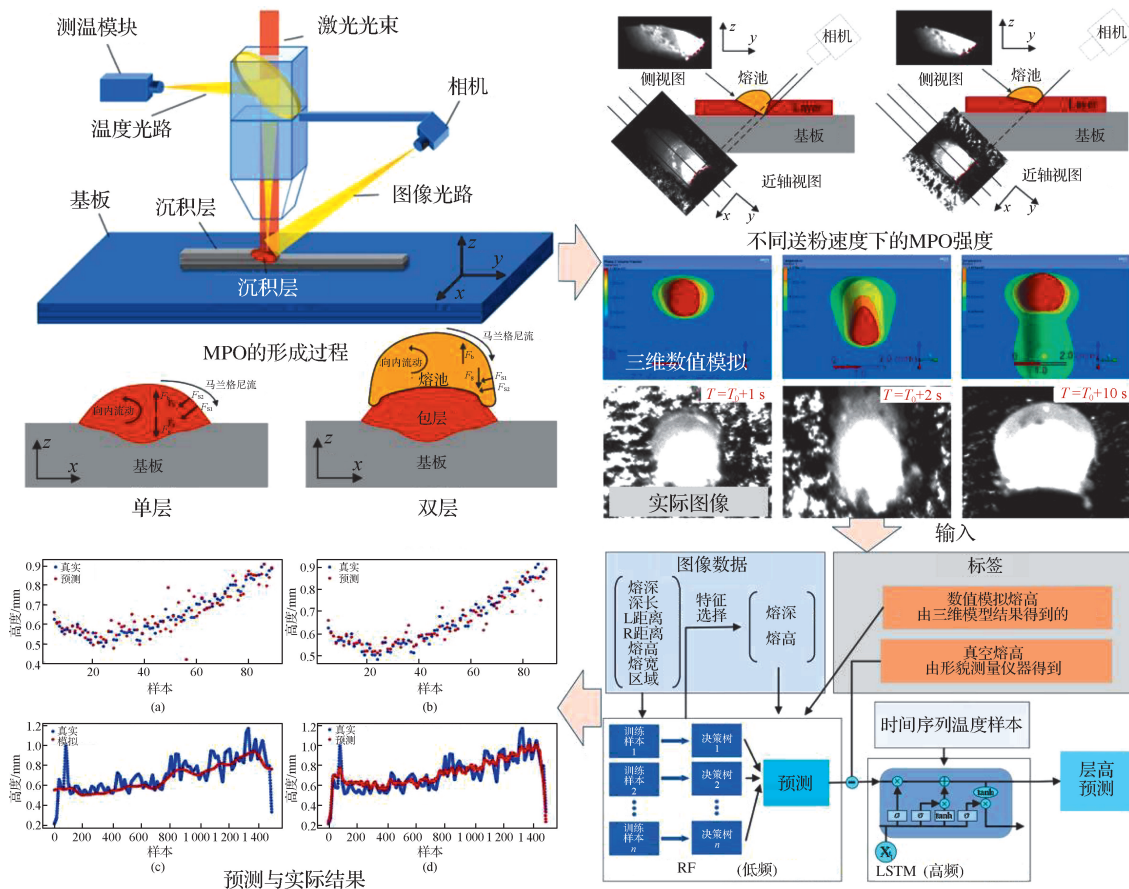


图 4 使用 RF-LSTM 预测成形精度的流程

Fig. 4 Workflow for predicting forming accuracy using RF-LSTM

### 3.3 成形性能预测

在使用 LDED 制造多层工件的过程中,大温度梯度会导致工件内产生较高的残余应力,而较高的残余应力在工件使用过程中将引起变形和开裂,缩短工件的使用寿命;另外在高温熔池快速冷却的情况下,某些合金元素可能在固化过程中发生偏析,导致材料局部成分不均匀,从而影响工件性能. Mirazimzadeh 等<sup>[91]</sup> 基于 X 射线衍射研究了熔化和热量对多接头、多道和多层几何形状中残余应力数据的影响,并提出使用 LSTM 神经网络根据加工温度历史数据来预测局部残余应力,结果表明, LSTM 准确预测了五层立方体部件中间层的中高残余应力. Polyzos 等<sup>[92]</sup> 开发了一种量化残余热应力影响的方法,该方法是将来自数字图像相关法测量的全场实验数据与使用基于 ML 和多项式混沌扩展的数值传热有限元模型相结合,用于预测 LDED 加工的 AISI 316L 薄壁样品的热膨胀系数和预测应力测试中钻孔周围的位移场,结果表明,预测精度在可接受范围内. Mohajernia 等<sup>[93]</sup> 研究了单焊珠包层的几何特性及机械特性,对不同的构建条件进行实验和数值研究,建立单焊珠应力数值模拟数据集用于训练,并使用自适应神经模糊推理系统和前馈反向传播神经网络预测单个激光熔覆珠在一维、二维和三维域中的残余应力. 除了预测工件的残余应力, ML 还可以用于对工件硬度、拉伸强度和屈服强度等机械特性进行预测. Zhang 等<sup>[94]</sup> 提出了一种结合 LDED 工艺和 ML 的高通量技术(图 5),首先基于图像处理方法和仪器微压痕表征合金的微观结构、显微硬度和屈服强度,并在此基础上开发反向传播(BP)神

经网络模型来确定 LDED Ti-Al-V 合金成分与微观结构参数、显微硬度和屈服强度的关系. Era 等<sup>[95]</sup> 应用基于数据驱动的极端梯度提升(XGBoost)和 RF 来预测 LDED 制造的 316L 不锈钢部件的拉伸行为、屈服强度和伸长率等特性,结果表明 XGBoost 模型的预测效果显著优于 RF 模型. 在工件成形性能预测中,基于 XRD 和拉伸测试机等性能表征手段获取标签数据,然后对热的时序和空域数据进行特征提取,将这些特征进行拼接或融合,形成一个统一的特征向量作为模型的输入,使用标注好的训练数据集对设计好的 ML 模型进行训练,进而实现通过加工热历史及图像等数据对未知工件残余应力、拉伸强度和屈服强度等性能的预测,大大减少了表征成本,也可以为工艺参数的选择提供基础.

### 3.4 工艺参数逆向求解

在 LDED 加工过程中,诸多变量都会直接影响工件的最终质量. 因此实验初期需通过大量重复实验寻找合适的工艺参数,不仅耗时,而且成本高昂. 由于机器学习模型在处理多维数据和解决非线性问题方面的优势,结合已知工艺参数进行迭代优化后,可逆向求解出目标样件最佳工艺参数的大致范围,这种方法不仅提高了效率,还能显著减少试验成本和时间,确保更高的加工质量. Cai 等<sup>[96]</sup> 开发了一种 ML 模型和非支配排序遗传算法-II(NSGA-II)组成的高效逆向系统,预测所需层几何形状的所有可行的最佳工艺参数(扫描速度、激光功率、送丝速率)组合,该团队首先将针对不同的过程变量进行实验探究,并测定实验结果中层几何参数和拉伸强度等参数用于构建数据集,再

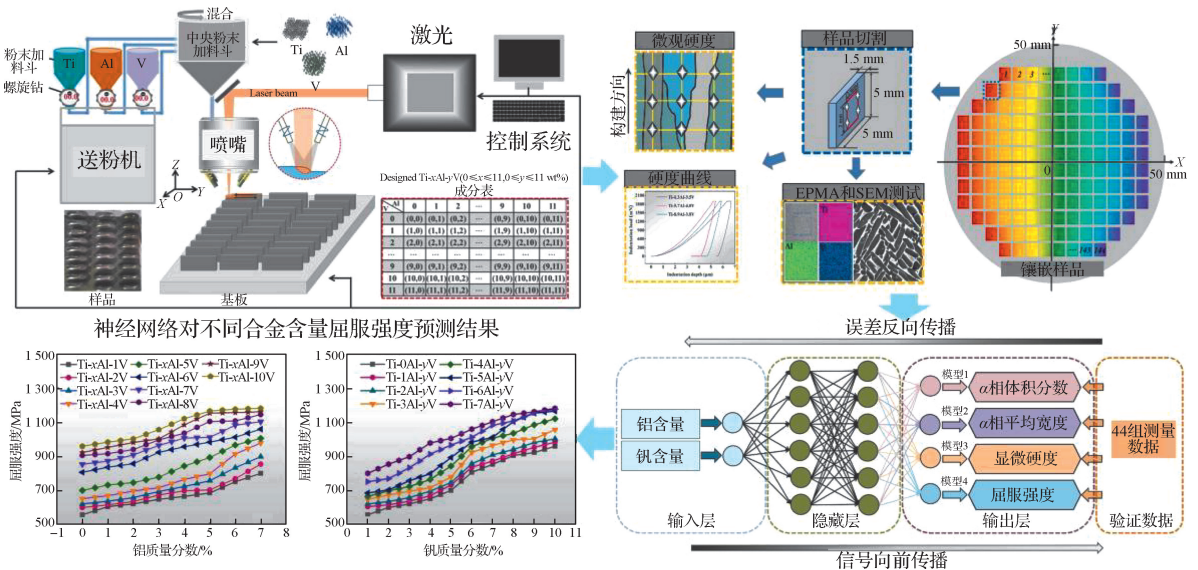


图 5 基于 BP 神经网络预测工件性能框架

Fig. 5 Framework for predicting workpiece performance based on BP neural network

输入至模型进行训练,最终由预测的工艺参数沉积得到的实际层几何形状与目标几何形状之间的最大平均绝对百分比误差(MAPE)小于 5.5%(图 6)。Hermann 等<sup>[25]</sup>利用 379 个单轨道沉积实验训练了高斯回归模型,该模型的优势在于包括不确定性量化策略(UQ),可以利用现有工艺参数预测单个沉积轨道的几何形状,再根据 UQ 迭代优化出目标和实际轨道几何形状之间最小的预期平方差,从而完成对最佳工艺参数的逆向求解。Dharmadhikari 等<sup>[97]</sup>提出了一种基于 Q 学习的非策略强化学习框架,该框架以将熔池深度稳定控制在 1 mm 为目标,寻找最佳激光功率和扫描速度的组合工艺参数。具体地,首先进行不同几何形状、激光功率和扫描速度的工艺实验,随后对这

些样品进行截面分析,提取熔池深度数据,用于构建不同几何形状熔池深度的实验过程数据库,随后将数据输入至多层感知机和 CNN 相结合的模型,逆向求解出特定几何形状下最优的激光功率和扫描速度工艺参数,基于最佳工艺参数能将熔池深度偏差控制在 50  $\mu\text{m}$  以内。在实验初期的工艺参数选择中,ML 模型能够基于已知工艺参数和相应的加工结果,通过结合遗传算法等优化手段进行迭代优化,从而逆向求解出合适的工艺参数。逆向求解策略可以在早期快速推导出目标工件的最佳激光功率、扫描速度及沉积路径的参数范围,减少大量重复试验所带来的时间和物质成本,并为工艺参数选择提供了一种高效的新途径。

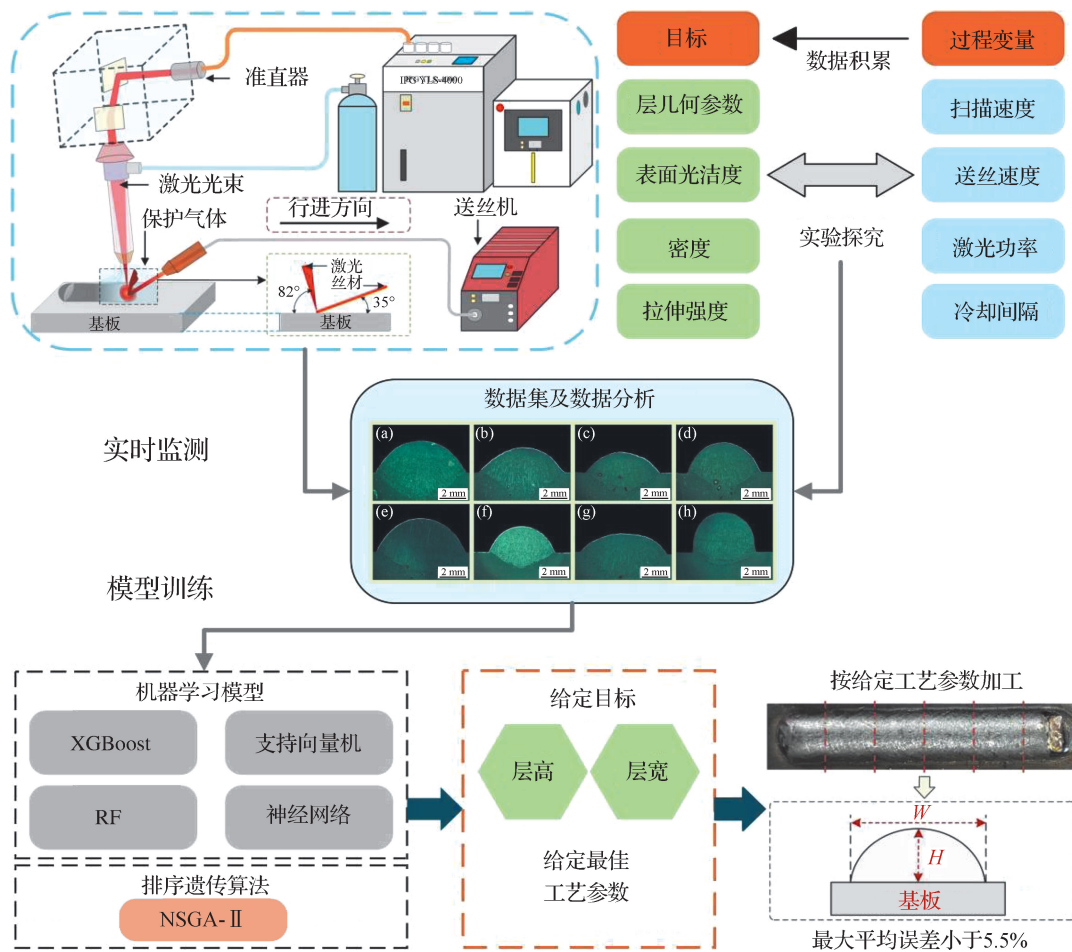


图 6 逆向求解工艺参数的流程

Fig. 6 Workflow for reverse solving of process parameters

### 4 总结、目前工作及展望

本文从 LDED 的加工方式和制造过程中常见的缺陷类型入手,分析了 LDED 加工过程的工艺参数与


加工质量之间的关系,总结了加工过程中主要数据采集方式及处理方式,并比较了不同数据处理方式的优缺点,梳理了 ML 在 LDED 缺陷检测与预测、成形精度预测、成形性能预测及工艺参数逆向求解四个方面的应用。通过对近几年相关文献分析,总结和概括如下:

1) 国内外学者通过高速相机和声学传感器等完成了对 LDED 加工过程的实时监测,但缺乏深入研究缺陷与过程数据的直接关系,信号与缺陷之间的定量关系仍不够明确.另外检测或预测到缺陷后,应采取何种方式去避免缺陷的研究仍相对较少.


2) 目前的研究中,不同传感器采集到的不同类型数据融合较少,检测和预测仍存在一定的局限性.例如可以将相机捕获的图像数据、声学数据和温度数据进行特征融合,以提高模型准确性.因此,如何将不同信号准确融合,并输入至 ML 模型来提高检测精度是目前面临的关键问题.

3) 现有的 ML 模型在逆向求解工艺参数时,迭代优化时间较长,且对于几何形状复杂的样件,求解工艺参数的泛化能力不佳.

目前,本实验室也在尝试在 LDED 加工过程中引入 ML 算法进行优化.由于丝材熔化不均匀会在末端产生熔滴,导致工件表面精度下降,因此开发了基于华睿 A7501MU000 相机,并结合经过改进的 YOLOv5s 模型对加工过程中的熔滴进行实时监测[图 7(a)和(b)].当检测到熔滴后调控加工主轴下降一定高度,从而避免熔滴异常引起加工工件表面精度下降;同时采用 Deeplab v3+模型实现对熔池区域的语义分割,判断熔池尺寸参数是否异常进而优化加工过程图[7(c)],并结合旁轴温度传感器完成对熔池整体温度映射[7(d)],进而对熔池温度分布情况进行分析.这两种基于机器学习的监测和检测手段将有效改善工件表面质量,也为沉积过程中缺陷检测及预测提供基础.




(a) LWDED及监测系统



(b) 基于Yolo v5的熔滴在线识别



(c) 基于Deeplab v3+的熔池轮廓尺寸提取



(d) 熔池整体温度映射

图 7 ML 在 LWDED 系统中的应用

Fig. 7 Applications of ML in LWDED systems

目前,针对 ML 在 LDED 中的应用主要有如下发展趋势:

1) 建立多种 ML 算法融合的模型.目前 ML 模型在图像识别以及特征提取上仍存在一定的局限性,而且缺乏对时序关联数据的处理能力.引入时序卷积算法能够更好地处理时间维度的序列信息,提高模型整体的检测和预测精度,更适合复杂多变的 LDED 制造过程.

2) 探究信号和缺陷之间的定量关系.目前的研究中,主要是对捕获的异常信号进行分类及识别,但过

程监控的最终目标是对异常信号进行实时反馈调控,从根源上避免缺陷的产生和积累.因此建立传感器信号和缺陷的定量关系,以及给出合理的调控手段是 LDED 过程检测的重要方向.

3) 实现多传感器数据融合的监测手段.单一的传感器只能捕获特定类型的数据,容易被噪声干扰,难以反映制造过程中的多维度信息.而通过多传感器数据融合,系统能够获得更加丰富的数据特征,结合 ML 算法提取多模态信息的深层次特征,能够显著提升识别和预测的准确性.因此多传感器数据融合的监测手

段是 LDED 监测方式的发展趋势。

总的来说,ML 方法能够突破传统数据处理技术的局限性,不仅能够提取高维度、多模态数据中的复杂特征,还能对非线性关系进行建模,显著提高 LDED 实时监测及预测的精度和效率,完成精准加工。未来,随着机器学习算法的不断进步,LDED 过程的监测、控制和优化将更加数字化、智能化和自动化。

## 参考文献:

- [1] YUE W W, ZHANG Y C, ZHENG Z X, et al. Hybrid laser additive manufacturing of metals: a review [J]. *Coatings*, 2024, 14(3):315.
- [2] MERCADO RIVERA F J, ROJAS-ARCINIEGAS A J. Additive manufacturing methods: techniques, materials, and closed-loop control applications [J]. *International Journal of Advanced Manufacturing Technology*, 2020, 109(1):17-31.
- [3] WEI C, LI L. Recent progress and scientific challenges in multi-material additive manufacturing via laser-based powder bed fusion[J]. *Virtual and Physical Prototyping*, 2021, 16(3):347-371.
- [4] 熊晓晨,秦训鹏,华林,等.复合式增材制造技术研究现状及发展[J]. *中国机械工程*, 2022, 33(17):2087-2097.
- [5] LI Y, FENG Z Y, HAO L, et al. A review on functionally graded materials and structures via additive manufacturing: from multi-scale design to versatile functional properties[J]. *Advanced Materials Technologies*, 2020, 5(6):1900981.
- [6] LU Z L, CAO J W, SONG Z Q, et al. Research progress of ceramic matrix composite parts based on additive manufacturing technology [J]. *Virtual and Physical Prototyping*, 2019, 14(4):333-348.
- [7] SVETLIZKY D, DAS M, ZHENG B L, et al. Directed energy deposition (DED) additive manufacturing: physical characteristics, defects, challenges and applications [J]. *Materials Today*, 2021, 49:271-295.
- [8] WANG H, LIU W W, TANG Z J, et al. Review on adaptive control of laser-directed energy deposition [J]. *Optical Engineering*, 2020, 59(7):070901.
- [9] LI Z, LI H, YIN J, et al. A review of spatter in laser powder bed fusion additive manufacturing: *in situ* detection, generation, effects, and countermeasures [J]. *Micromachines*, 2022, 13(8):1366.
- [10] MADHAVADAS V, SRIVASTAVA D, CHADHA U, et al. A review on metal additive manufacturing for intricately shaped aerospace components [J]. *CIRP Journal of Manufacturing Science and Technology*, 2022, 39:18-36.
- [11] NAZIR A, GOKCEKAYA O, BILLAH K M M, et al. Multi-material additive manufacturing: a systematic review of design, properties, applications, challenges, and 3D printing of materials and cellular metamaterials[J]. *Materials & Design*, 2023, 226:111661.
- [12] TAN C L, LI R S, SU J L, et al. Review on field assisted metal additive manufacturing[J]. *International Journal of Machine Tools and Manufacture*, 2023, 189:104032.
- [13] HUANG Y Z, FLEMING T G, CLARK S J, et al. Keyhole fluctuation and pore formation mechanisms during laser powder bed fusion additive manufacturing [J]. *Nature Communications*, 2022, 13(1):1170.
- [14] SANAEI N, FATEMI A. Defects in additive manufactured metals and their effect on fatigue performance: a state-of-the-art review [J]. *Progress in Materials Science*, 2021, 117:100724.
- [15] 李毅,王振忠,肖宇航,等.金属激光增材+X 复合制造技术综述[J]. *航空学报*, 2024, 45(13):139-161.
- [16] JI L, LU J P, TANG S Y, et al. Research on mechanisms and controlling methods of macro defects in TC4 alloy fabricated by wire additive manufacturing[J]. *Materials*, 2018, 11(7):1104.
- [17] 郭立杰,许伟春,齐超琪,等.金属增材制造监测与控制技术研究进展[J]. *南京航空航天大学学报*, 2022, 54(3):365-377.
- [18] FU Y Z, DOWNEY A R J, YUAN L, et al. Machine learning algorithms for defect detection in metal laser-based additive manufacturing: a review [J]. *Journal of Manufacturing Processes*, 2022, 75:693-710.
- [19] JIANG J C. A survey of machine learning in additive manufacturing technologies [J]. *International Journal of Computer Integrated Manufacturing*, 2023, 36(9):1258-1280.
- [20] MENG L B, MCWILLIAMS B, JAROSINSKI W, et al. Machine learning in additive manufacturing: a review [J]. *JOM*, 2020, 72(6):2363-2377.
- [21] ZHOU H R, YANG H, LI H Q, et al. Advancements in machine learning for material design and process optimization in the field of additive manufacturing [J]. *China Foundry*, 2024, 21(2):101-115.
- [22] LI W H, ZHANG H O, WANG G L, et al. Deep learning based online metallic surface defect detection method for wire and arc additive manufacturing [J]. *Robotics and Computer-Integrated Manufacturing*, 2023, 80:102470.
- [23] CHERNYAVSKY D, KONONENKO D Y, HAN J H, et al. Machine learning for additive manufacturing: predicting materials characteristics and their uncertainty [J]. *Materials*

- & Design, 2023, 227: 111699.
- [24] 亓欣波, 李长鹏, 李阳, 等. 基于机器学习的电子束选区熔化成形件密度预测[J]. 机械工程学报, 2019, 55(15): 48-55.
- [25] HERMANN F, MICHALOWSKI A, BRÜNNETTE T, et al. Data-driven prediction and uncertainty quantification of process parameters for directed energy deposition[J]. Materials, 2023, 16(23): 7308.
- [26] DASS A, MORIDI A. State of the art in directed energy deposition: from additive manufacturing to materials design[J]. Coatings, 2019, 9(7): 418.
- [27] CHEN Y T, ZHANG X C, PARVEZ M M, et al. A review on metallic alloys fabrication using elemental powder blends by laser powder directed energy deposition process[J]. Materials, 2020, 13(16): 3562.
- [28] TAN H, FANG Y B, ZHONG C L, et al. Investigation of heating behavior of laser beam on powder stream in directed energy deposition [J]. Surface and Coatings Technology, 2020, 397: 126061.
- [29] GIBSON B T, BANDARI Y K, RICHARDSON B S, et al. Melt pool size control through multiple closed-loop modalities in laser-wire directed energy deposition of  $Ti_6Al_4V$ [J]. Additive Manufacturing, 2020, 32: 100993.
- [30] GUNER A, BIDARE P, JIMÉNEZ A, et al. Nozzle designs in powder-based direct laser deposition: a review [J]. International Journal of Precision Engineering and Manufacturing, 2022, 23(9): 1077-1094.
- [31] SCHNEIDER J A, PUERTO G, WALKER E, et al. Wire based directed energy deposition of JBK-75 [J]. Metallurgical and Materials Transactions A, 2024, 55(4): 1098-1110.
- [32] PREIS J, WANG Z X, HOWARD J, et al. Effect of laser power and deposition sequence on microstructure of GRCo42-Inconel 625 joints fabricated using laser directed energy deposition [J]. Materials & Design, 2024, 241: 112944.
- [33] ZHOU Y, NING F D. Directed energy deposition with coaxial wire-powder feeding: melt pool temperature and microstructure[J]. Journal of Manufacturing Science and Engineering, 2023, 145(8): 081004.
- [34] SHIN G, YOON J H, KIM D W, et al. A study on the influence of laser power on the microstructure and mechanical properties of functionally graded materials produced by direct energy deposition[J]. Korean Journal of Metals and Materials, 2020, 58(11): 782-792.
- [35] SINGH V, VISHWANADH B, PAUL C P, et al. Effect of laser power and scan speed on the microstructure and texture evolution in CR claddings developed over V substrate using laser-induced directed energy deposition [J]. Metallurgical and Materials Transactions A, 2024, 55(6): 1988-2003.
- [36] JIA T H, ZOU B, LIU W B, et al. Effect of process parameters on mechanical properties of Inconel 718 superalloy fabricated by directional energy deposition[J]. International Journal of Advanced Manufacturing Technology, 2023, 128(7): 2863-2883.
- [37] BERNAUER C, MEINZINGER L, ZAPATA A, et al. Design and investigation of a novel local shielding gas concept for laser metal deposition with coaxial wire feeding[J]. Applied Sciences, 2023, 13(8): 5121.
- [38] SHIN S G, LEE J H, KIM S W, et al. Effect of the laser beam spot size and process parameters on the cross section of SUS316L parts using DED (directed energy deposition) [J]. Journal of Welding and Joining, 2019, 37(5): 508-513.
- [39] HERZOG T, BRANDT M, TRINCHI A, et al. Process monitoring and machine learning for defect detection in laser-based metal additive manufacturing[J]. Journal of Intelligent Manufacturing, 2024, 35(4): 1407-1437.
- [40] BAYAT M, THANKI A, MOHANTY S, et al. Keyhole-induced porosities in laser-based powder bed fusion (LPBF) of  $Ti_6Al_4V$ : high-fidelity modelling and experimental validation[J]. Additive Manufacturing, 2019, 30: 100835.
- [41] KHAIRALLAH S A, ANDERSON A T, RUBENCHIK A, et al. Laser powder-bed fusion additive manufacturing: physics of complex melt flow and formation mechanisms of pores, spatter, and denudation zones[J]. Acta Materialia, 2016, 108: 36-45.
- [42] LEUNG C L A, MARUSSI S, ATWOOD R C, et al. *In situ* X-ray imaging of defect and molten pool dynamics in laser additive manufacturing [J]. Nature Communications, 2018, 9(1): 1355.
- [43] GUO M, HUANG G J, XI L X, et al. Effects of laser printing parameters on molten pool formation, microstructure evolution and mechanical properties of laser directed energy deposition of difficult-to-process tungsten heavy-alloy [J]. CIRP Journal of Manufacturing Science and Technology, 2022, 39: 401-413.
- [44] HE Y, LU H, ZHANG X H, et al. Study on *in situ* laser shock modulation of molten pool and defects in wire-feed laser additive manufacturing of steel to aluminum alloy [J]. Thin-Walled Structures, 2024, 204: 112326.
- [45] LIU M, KUMAR A, BUKKAPATNAM S, et al. A review of the anomalies in directed energy deposition (DED) processes & potential solutions-part quality &

- defects[J]. *Procedia Manufacturing*, 2021, 53:507-518.
- [46] WU C Y, LU M C, YANG W C, et al. Experimental study of balling defect generation and audible sound analysis in directed energy deposition metal additive manufacturing[J]. *International Journal of Advanced Manufacturing Technology*, 2024, 134(1):205-221.
- [47] ZHANG P Y, ZHOU X, CHENG X, et al. Elucidation of bubble evolution and defect formation in directed energy deposition based on direct observation [J]. *Additive Manufacturing*, 2020, 32:101026.
- [48] HAGENLOCHER C, O'TOOLE P, XU W, et al. The effect of heat accumulation on the local grain structure in laser-directed energy deposition of aluminium[J]. *Metals*, 2022, 12(10):1601.
- [49] MAHTABI M, YADOLLAHI A, STOKES R, et al. Effect of build interruption during laser powder bed fusion process on structural integrity of  $Ti_6Al_4V$ [J]. *Engineering Failure Analysis*, 2023, 153:107626.
- [50] YAO D Z, WANG J, LUO H, et al. Thermal behavior and control during multi-track laser powder bed fusion of 316L stainless steel [J]. *Additive Manufacturing*, 2023, 70:103562.
- [51] YUAN K, GUO W, LI P, et al. Influence of process parameters and heat treatments on the microstructures and dynamic mechanical behaviors of Inconel 718 superalloy manufactured by laser metal deposition[J]. *Materials Science and Engineering A*, 2018, 721: 215-225.
- [52] LEE T, JEONG W, CHUNG S, et al. Role of  $B_4C$  in the directed energy deposition of aluminum alloy 6061/ $B_4C$  composite using core-shell powder for crack annihilation, pore mitigation, and grain refinement [J]. *Additive Manufacturing*, 2023, 72:103622.
- [53] PAES L E D, PEREIRA M, XAVIER F A, et al. Lack of fusion mitigation in directed energy deposition with laser (DED-L) additive manufacturing through laser remelting[J]. *Journal of Manufacturing Processes*, 2022, 73:67-77.
- [54] 冯一琦, 谢国印, 张璧, 等. 激光功率与底面状态对选区激光熔化球化的影响[J]. *航空学报*, 2019, 40(12): 234-243.
- [55] KHAIRALLAH S A, MARTIN A A, LEE J R I, et al. Controlling interdependent meso-nanosecond dynamics and defect generation in metal 3D printing[J]. *Science*, 2020, 368(6491):660-665.
- [56] CAIAZZO F, ALFIERI V, BOLELLI G. Residual stress in laser-based directed energy deposition of aluminum alloy 2024: simulation and validation[J]. *International Journal of Advanced Manufacturing Technology*, 2022, 118(3):1197-1211.
- [57] DILL J, SOSHI M, YAMAZAKI K. A study on the effect of directed energy deposition substrate energy on clad geometry [J]. *International Journal of Advanced Manufacturing Technology*, 2020, 109(1):315-333.
- [58] DOUELLOU C, BALANDRAUD X, DUC E. Assessment of geometrical defects caused by thermal distortions in laser-beam-melting additive manufacturing: a simulation approach[J]. *Rapid Prototyping Journal*, 2019, 25(5): 939-950.
- [59] GAO S, TAN Z, LAN L, et al. Experimental investigation and numerical simulation of residual stress and distortion of  $Ti_6Al_4V$  components manufactured using selective laser melting [J]. *Journal of Materials Engineering and Performance*, 2022, 31(10):8113-8123.
- [60] TANG Z J, WEI Q L, GAO Z Y, et al. 2 000 W blue laser directed energy deposition of  $AlSi_7Mg$ : process parameters, molten pool characteristics, and appearance defects[J]. *Virtual and Physical Prototyping*, 2023, 18(1):e2120405.
- [61] WEN F Z, GAO S M, SONG X, et al. Piezoelectric-laser ultrasonic inspection and monitoring of thin-walled structure fabricated by directed energy deposition process based on guided waves[J]. *Ultrasonics*, 2024, 138:107255.
- [62] SALARIAN M, TOYSERKANI E. The use of nano-computed tomography (nano-CT) in non-destructive testing of metallic parts made by laser powder-bed fusion additive manufacturing[J]. *International Journal of Advanced Manufacturing Technology*, 2018, 98(9/10/11/12):3147-3153.
- [63] MUHAMMAD W, KANG J D, IBRAGIMOVA O, et al. Experimental investigation and development of a deep learning framework to predict process-induced surface roughness in additively manufactured aluminum alloys [J]. *Welding in the World*, 2023, 67(4):897-921.
- [64] ANSARI M J, ARCONDOULIS E J G, ROCCISANO A, et al. Optimized analytical approach for the detection of process-induced defects using acoustic emission during directed energy deposition process[J]. *Additive Manufacturing*, 2024, 86:104218.
- [65] KHOSRAVANI M R, REINICKE T. On the use of X-ray computed tomography in assessment of 3D-printed components[J]. *Journal of Nondestructive Evaluation*, 2020, 39(4):75.
- [66] MAZZARISI M, ANGELASTRO A, LATTE M, et al. Thermal monitoring of laser metal deposition strategies

- using infrared thermography[J]. *Journal of Manufacturing Processes*, 2023, 85: 594-611.
- [67] 曹龙超,周奇,韩远飞,等. 激光选区熔化增材制造缺陷智能监测与过程控制综述[J]. *航空学报*, 2021, 42(10): 199-233.
- [68] BREITENBACH J, SEIDENSPINNER F, VURAL F, et al. A systematic literature review of machine learning approaches for optimization in additive manufacturing [C]// *International Computers, Software, and Applications Conference (COMPSAC)*. Piscataway: IEEE, 2022: 1147-1152.
- [69] PATURI U M R, PALAKURTHY S T, CHERUKU S, et al. Role of machine learning in additive manufacturing of titanium alloys: a review[J]. *Archives of Computational Methods in Engineering*, 2023, 30(8): 5053-5069.
- [70] CHEN W, ZOU B, SUN H W, et al. Research on curved parts surface quality detection during laser-directed energy deposition based on blurry inpainting network[J]. *Advanced Engineering Materials*, 2023, 25(21): 00898.
- [71] LIU H R, YUAN J L, PENG S T, et al. *In-situ* monitoring melt pool states in direct energy deposition using ResNet[J]. *Measurement Science and Technology*, 2022, 33(12): 124007.
- [72] MOCHI V H, NÚÑEZ H H L, RIBEIRO K S B, et al. Real-time prediction of deposited bead width in L-DED using semi-supervised transfer learning[J]. *International Journal of Advanced Manufacturing Technology*, 2023, 129(11): 5643-5654.
- [73] ZHAN Z X, LI H. Machine learning based fatigue life prediction with effects of additive manufacturing process parameters for printed SS 316L[J]. *International Journal of Fatigue*, 2021, 142: 105941.
- [74] ALLEN M, ARROYAVE R, MALAK R, et al. Deep ensembles for modeling uncertain phase constraints in compositionally graded alloy design[C]// *International Design Engineering Technical Conferences & Computers and Information in Engineering Conference*. Louis: ASME, 2022: 89091.
- [75] KARKARIA V, GOECKNER A, ZHA R J, et al. Towards a digital twin framework in additive manufacturing: machine learning and Bayesian optimization for time series process optimization[J]. *Journal of Manufacturing Systems*, 2024, 75: 322-332.
- [76] REN W J, WEN G R, ZHANG Z F, et al. Quality monitoring in additive manufacturing using emission spectroscopy and unsupervised deep learning[J]. *Materials and Manufacturing Processes*, 2022, 37(11): 1339-1346.
- [77] MIRAZIMZADEH S E, PAZIREH S, URBANIC J, et al. Unsupervised clustering approach for recognizing residual stress and distortion patterns for different parts for directed energy deposition additive manufacturing [J]. *International Journal of Advanced Manufacturing Technology*, 2023, 125(11): 5067-5087.
- [78] OKARO I A, JAYASINGHE S, SUTCLIFFE C, et al. Automatic fault detection for laser powder-bed fusion using semi-supervised machine learning [J]. *Additive Manufacturing*, 2019, 27: 42-53.
- [79] MI J Q, ZHANG Y K, LI H, et al. *In-situ* monitoring laser based directed energy deposition process with deep convolutional neural network[J]. *Journal of Intelligent Manufacturing*, 2023, 34(2): 683-693.
- [80] CHEN L Q, YAO X L, TAN C L, et al. *In-situ* crack and keyhole pore detection in laser directed energy deposition through acoustic signal and deep learning[J]. *Additive Manufacturing*, 2023, 69: 103547.
- [81] HESPELER S, DEGHAN-NIRI E, JUHASZ M, et al. Deep learning for *in-situ* layer quality monitoring during laser-based directed energy deposition (LB-DED) additive manufacturing process [J]. *Applied Sciences*, 2022, 12(18): 8974.
- [82] PARK H, KANG Y S, CHOI S K, et al. Quality evaluation modeling of a DED-processed metallic deposition based on ResNet-50 with few training data[EB/OL]. [2024-09-01]. <http://doi.org/10.1007/s10845-024-02408-0>.
- [83] GUO W H, TIAN Q, GUO S H, et al. A physics-driven deep learning model for process-porosity causal relationship and porosity prediction with interpretability in laser metal deposition[J]. *CIRP Annals-Manufacturing Technology*, 2020, 69(1): 205-208.
- [84] CHEN L Q, BI G J, YAO X L, et al. Multisensor fusion-based digital twin for localized quality prediction in robotic laser-directed energy deposition[J]. *Robotics and Computer-Integrated Manufacturing*, 2023, 84: 102581.
- [85] ABRANOVIC B, SARKAR S, CHANG-DAVIDSON E, et al. Melt pool level flaw detection in laser hot wire directed energy deposition using a convolutional long short-term memory autoencoder [J]. *Additive Manufacturing*, 2024, 79: 103843.
- [86] LI X, ZHU K H, CHEN H B. Numerical-assisted prediction model of layer height for Co-Cr-Ni-alloy direct energy deposition [J]. *Additive Manufacturing*, 2024, 83: 104060.
- [87] YU M, ZHU L D, NING J S, et al. Machine vision and novel attention mechanism TCN for enhanced prediction of future deposition height in directed energy deposition

- [J]. *Mechanical Systems and Signal Processing*, 2024, 216:111492.
- [88] YU M, ZHU L D, YANG Z C, et al. *In situ* monitoring and innovative feature fusion neural network for enhanced laser-directed energy deposition track geometry prediction and control[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73:5022110.
- [89] RIBEIRO K S B, NÚÑEZ H H L, VENTER G S, et al. A hybrid machine learning model for in-process estimation of printing distance in laser directed energy deposition[J]. *International Journal of Advanced Manufacturing Technology*, 2023, 127(7):3183-3194.
- [90] LI X, DAI R L, CHEN S B, et al. Offline planning optimization and formation prediction of laser directed energy deposition process[J]. *Optics and Laser Technology*, 2023, 164:109510.
- [91] MIRAZIMZADEH S E, MOHAJERNIA B, PAZIREH S, et al. Investigation of residual stresses of multi-layer multi-track components built by directed energy deposition: experimental, numerical, and time-series machine-learning studies[J]. *International Journal of Advanced Manufacturing Technology*, 2024, 130(1):329-351.
- [92] POLYZOS E, PULJU H, MÄCKEL P, et al. Measuring and predicting the effects of residual stresses from full-field data in laser-directed energy deposition [J]. *Materials*, 2023, 16(4):1444.
- [93] MOHAJERNIA B, MIRAZIMZADEH S E, PASHA A, et al. Machine learning approaches for predicting geometric and mechanical characteristics for single P420 laser beads clad onto an AISI 1018 substrate [J]. *International Journal of Advanced Manufacturing Technology*, 2022, 118(11/12):3691-3710.
- [94] ZHANG F Y, HUANG K S, ZHAO K X, et al. Directed energy deposition combining high-throughput technology and machine learning to investigate the composition-microstructure-mechanical property relationships in titanium alloys [J]. *Journal of Materials Processing Technology*, 2023, 311:117800.
- [95] ERA I Z, GRANDHI M, LIU Z C. Prediction of mechanical behaviors of L-DED fabricated SS 316L parts via machine learning [J]. *International Journal of Advanced Manufacturing Technology*, 2022, 121(3):2445-2459.
- [96] CAI Y H, WANG Y X, CHEN H, et al. Searching optimal process parameters for desired layer geometry in wire-laser directed energy deposition based on machine learning[J]. *Virtual and Physical Prototyping*, 2024, 19(1):e2352066.
- [97] DHARMADHIKARI S, MENON N, BASAK A. A reinforcement learning approach for process parameter optimization in additive manufacturing [J]. *Additive Manufacturing*, 2023, 71:103556.

(责任编辑:任滢滢)