

人工智能在增材制造中的应用研究

■ 文 / 杨雪强, 李军义, 谢焱, 王亚斌, 李志年, 乔鹏, 张鹏翔, 田青
西北稀有金属材料研究院宁夏有限公司

摘要: 增材制造技术凭借其设计自由度高、材料利用率优异以及复杂几何构件直接成形能力, 在航空航天、生物医学和能源等高端制造领域展现出广阔的应用前景。然而, 该技术所涉及的工艺过程极为复杂, 呈现出显著的多物理场耦合特性, 加之成形质量稳定性问题, 严重制约了其工业化大规模应用进程。人工智能技术的快速发展为解决上述瓶颈问题提供了全新的研究范式与技术路径。本文系统综述了人工智能在增材制造领域的研究进展与应用现状。首先概述了增材制造的技术特点与核心挑战, 进而阐述了机器学习、深度学习等人工智能算法在增材制造场景中的适用性。在此基础上, 从增材制造设计阶段优化、工艺参数优化、过程监测与缺陷检测、微观组织与力学性能预测四个维度, 详细分析了人工智能赋能增材制造的具体路径与应用案例。特别关注了混合建模策略与数字孪生框架的构建, 深入探讨了可解释人工智能在缺陷—性能关联分析中的应用价值。最后, 展望了生成式模型、自主实验等前沿方向的发展潜力, 并分析了当前面临的数据稀缺性、模型泛化能力等关键挑战。

关键词: 人工智能; 机器学习; 增材制造; 粉末床熔融; 工艺优化; 数字孪生; 缺陷检测

一、引言

增材制造技术历经三十余年的持续发展与技术迭代, 已从早期的快速原型工具演进为能够直接制造功能性高性能构件的颠覆性制造技术^[1]。与传统减材制造工艺相比, 增材制造通过逐层累加的方式直接从数字模型构建实体零件, 突破了传统制造方法对零件几何复杂度的限制, 实现了前所未有的设计自由度和近净成形能力^[2]。在众多增材制造工艺类别中, 粉末床熔融已成为制备高性能金属构件最先进且最具工业相关性的方法之一, 该技术能够实现卓越的几何精度和可定制化的微观组织^[3]。目前, 该技术已广泛应用于钛合金、不锈钢、镍基高温合金以及高熵合

金等先进材料体系, 在航空航天发动机部件、生物医用植入物和能源装备关键零部件等领域取得了显著成效。

然而, 增材制造本质上是一个复杂的、高度非线性的物理化学过程, 受多尺度、多物理场现象的耦合作用支配^[4]。局部高能束输入会导致陡峭的温度梯度、快速凝固行为和瞬态熔池流体动力学现象, 而逐层粉末沉积过程则会引入堆积密度和形貌的随机变异性, 最终导致孔隙、未熔合、匙孔、热裂纹以及组织各向异性等成形缺陷的产生^[5]。上述问题的根源在于工艺参数、瞬态热历史、微观组织演变和残余应力发展之间存在强耦合关系, 使得工艺优化面临巨大挑战。

近年来,人工智能技术的快速发展为解决上述复杂问题提供了新的研究范式。人工智能方法,特别是机器学习与深度学习技术,被证明是执行复杂模式识别和非线性回归分析的有效手段,能够为增材制造领域带来革命性变革^[6]。通过从海量数据中自动学习潜在的模式与规律,人工智能技术能够建立工艺参数、微观组织与宏观力学性能之间的多尺度映射关系,从而实现对增材制造过程的智能感知、精准预测与自适应控制。

本文旨在系统梳理和分析人工智能在增材制造领域的研究进展与应用现状,深入探讨人工智能技术在各制造阶段的作用机制,以期为相关领域的研究人员和工程技术人员提供有价值的参考。

二、增材制造技术概述

2.1 粉末床熔融工艺原理与特点

粉末床熔融是金属增材制造领域中最成熟、应用最广泛的技术类别^[3]。根据能量源类型及粉末结合机制的不同,PBF技术可细分为激光粉末床熔融和电子束粉末床熔融两类^[7]。激光粉末床熔融采用高能激光束作为能量源,在惰性气氛保护环境下运行,依据粉末熔化程度可分为选择性激光烧结和选择性激光熔化,适用于钛合金、镍基高温合金、不锈钢等多种材料的精密成形;电子束粉末床熔融则采用高能电子束作为能量源,在高真空环境下运行,由于电子束具有更快的扫描速度且可对粉末床进行预热处理,有助于降低成形过程中的残余应力,特别适用于钛铝合金等活性金属以及难熔金属的加工^[8]。




图1 AM 工艺流程

PBF工艺的基本流程主要包括以下环节:粉末铺展、能量束选择性扫描熔化、成形缸下降、重复铺粉。整个成形过程在密闭腔室内进行,通常充入高纯惰性气体以严格控制氧含量,防止金属材料高温氧化^[8]。粉末层厚度通常控制在20-100 μm 范围内,能量束依据切片轮廓信息进行

选择性扫描,使金属粉末完全熔化或部分烧结,凝固后与下层形成可靠的冶金结合。PBF过程的复杂性体现在多尺度物理现象的深度耦合:在微观尺度,激光-粉末相互作用涉及能量吸收与转化、热传导、熔池流体动力学等复杂过程;在介观尺度,粉末铺展行为直接影响层厚均匀性和粉末堆积密度;在宏观尺度,逐层累积的热循环导致残余应力累积和宏观变形^[9-10]。




图2 基于激光与电子束的AM工艺示意图

2.2 工艺-结构-性能复杂关联

工艺-结构-性能关联是增材制造研究的核心科学问题,揭示工艺参数如何影响微观组织演化,以及微观组织如何决定宏观力学性能,是实现增材制造构件性能可控制备的关键^[3]。工艺参数与微观组织之间的映射关系呈现高度非线性和多参数强耦合特征,工艺参数通过调控热历史间接影响微观组织的形成与演变。以Ti-6Al-4V合金的典型研究为例:高能量输入导致较慢的冷却速率,促进 $\alpha+\beta$ 层片组织的粗化;而低能量输入则产生更细小的马氏体 α' 组织^[11]。扫描策略的影响同样显著,旋转扫描策略有利于晶体组织的弱化,而双向扫描则可能产生强烈的晶体取向^[7]。




图3 激光粉末床熔融（LPBF）工艺的设计空间示例

微观组织特征与宏观力学性能之间存在经典的Hall-Petch关系，即晶粒细化可以提高材料强度，但过度细化可能导致塑性降低^[12]。增材制造过程固有的方向性热传导导致微观组织和力学性能呈现显著的各向异性。沿构建方向通常呈现柱状晶生长形态，而水平方向则可能形成等轴晶组织，这种组织各向异性直接转化为力学性能的各向异性，表现为不同方向上的强度和延伸率存在明显差异^[3]。此外，残余应力是增材制造领域的另一个核心问题。逐层沉积过程中的周期性热循环导致复杂的残余应力场分布，可能引起构件变形、开裂，并显著影响服役性能和寿命。残余应力的空间分布与扫描策略、构件几何特征和材料热物理性质密切相关^[7]。

三、人工智能算法基础

3.1 机器学习基本范式

机器学习已成为推动增材制造智能化发展的关键使能技术，通过构建深度神经网络可从复杂的多源异构数据中提取有效规律，广泛应用于工艺参数优化、质量预测、缺陷识别与性能评估等关键任务^[13]。机器学习在金属增材制造中的应用涵盖了监督学习、无监督学习、强化学习等多种基本范式。

监督学习是最为常用的机器学习范式，主要用于建立工艺参数与性能指标之间的映射关系，通过学习给定训练数据集中输入与输出变量之间的内在关联，构建具有预测能力的模型^[14]。常用算法包括随机森林、支持向量机、梯度提升树以及人工神经网络等。无监督学习则处理的是没有先验标签的数据，系统通过自主发掘输入数据中的隐含结构、潜在模式或关联关系实现知识发现^[15]，例如聚类分析可用于识别不同缺陷形态，降维技术可用于过程监测数据的特征提取与压缩。强化学习通过智能体与环境持续交互学习最优决策策略，利用试错机制与环境动态互动，根据获得的奖励或惩罚信号调整行为策略，最大化长期累积奖励^[16]，在扫描策略优化、工艺参数动态

调整等序贯决策场景中展现出巨大潜力。已有研究表明，深度强化学习已成功应用于优化LPBF扫描路径生成，实现了均匀热分布和残余应力最小化的目标。

3.2 深度学习与神经网络

深度学习基于多层神经网络架构，其强大的特征提取与表征能力使其在处理图像、时序等非结构化数据时表现尤为优异。主要的深度学习架构包括卷积神经网络、循环神经网络、生成对抗网络和Transformer等。其中，卷积神经网络已被广泛用于熔池图像分析、缺陷识别、微观组织表征等视觉任务；循环神经网络及其变体长短期记忆网络适用于处理工艺过程的时间序列数据，如温度演变曲线、熔池信号监测等^[17]；生成对抗网络在合成缺陷数据、生成优化设计等方面展现出独特优势，能够有效扩充训练数据集；Transformer架构则在处理多源异构数据融合和长程依赖关系建模方面表现突出，为构建统一的多模态感知模型提供了新思路。



图4 卷积运算示意图

四、人工智能在增材制造领域的应用

4.1 人工智能在增材制造设计阶段的应用

面向增材制造的设计旨在充分利用增材制造的设计自由度，同时充分考虑制造工艺约束。机器学习方法可通过学习大量设计案例，辅助设计师进行智能化设计决策，显著提升设计效率与质量。例如，Yao等提出了一种混合机器学习算法，通过层次聚类生成目标组件的树状图表示，为经验不足的设计师提供可行的设计解决方案，有效降低了设计门槛^[18]。Jiang等构建了基于点云数据结构的深度神经网络模型和基于图像的CNN模型，能够深入探索设计变量与性能之间的复杂交互关系，为复杂结构的设计优化提供了新工具^[19]。Zhang等开发的MAR-AM系统可基于材料和工艺参数快速预测给定设计的可制造性，大幅提高了设计迭代效率^[20]。

拓扑优化是实现增材制造轻量化设计的关键技术，但传统拓扑优化方法计算量大、迭代次数多，严重制约了其在工业界的广泛应用。机器学习可显著加速优化过程，例如Banga等利用卷积神经网络实现了二维和三维结构

的“单次”拓扑优化,训练好的模型可直接预测给定边界条件下的最优几何结构,避免了耗时的迭代计算^[21]。Yu等结合 CNN 和 GAN 实现了拓扑优化的超分辨率重建,将粗网格优化结果快速提升至高分辨率,计算时间仅为传统方法的 0.06%,显著提升了优化效率^[22]。Oh 等利用生成对抗网络进行生成式设计,通过学习大量车轮设计案例,网络能够生成兼具美学价值和工程可行性的创新设计,为设计空间探索提供了新范式^[23]。

支撑结构是增材制造中不可或缺的辅助元素,但同时也造成材料浪费和后处理困难。Vaissier 等提出了基于遗传算法的晶格支撑结构优化框架,通过智能识别和移除支撑结构中的冗余单元,在不影响支撑功能的前提下显著减少材料消耗,实现了支撑结构的轻量化设计^[24]。

4.2 在工艺参数优化中的应用

工艺窗口的准确界定是工艺开发的首要任务。增材制造涉及的工艺参数众多,包括激光功率、扫描速度、层厚、扫描间距等,这些参数之间的复杂交互关系使工艺窗口的确定变得极为困难。机器学习方法可基于少量实验数据构建工艺参数与成形质量之间的映射模型,快速预测最优工艺窗口^[25]。Tapia 等基于高斯过程回归建立了 LPBF 工艺中熔池深度的代理模型,仅需少量高保真仿真数据即可准确预测不同工艺参数组合下的熔池形态,为工艺参数快速筛选提供了有效工具^[26]。Chen 等采用 BP 神经网络对 TiB 增强 AlSi10Mg 复合材料的工艺窗口进行预测,成功识别了激光功率和扫描速度的可行域,验证了神经网络在复合材料工艺优化中的适用性^[27]。Zhou 等针对 MnCu 合金的 SLM 成形工艺,提出了一种模拟辅助的原型神经网络模型,用于在有限样本数据条件下建立工艺窗口预测框架,成功证明了基于机器学习的小样本学习方法能够有效预测稳健的 SLM 工艺窗口,实现力学性能媲美锻件的增材制造构件^[28]。




图3 不同机器学习模型的比较: (a) 预测结果的折线图; (b) R2 和平均绝对误差 (MAE)^[29]

华南理工大学团队将人工神经网络、梯度提升回归、核岭回归、弹性网络四个基础模型的预测结果进行综合,成功开发了一种“堆叠集成学习”模型,为高效优化工艺参数提供了智能化“数字助手”,测试结果如图3所示^[29]。

增材制造中常需同时优化多个相互冲突的目标,如致密度与表面粗糙度、制造效率与力学性能等,多目标优化算法结合机器学习可有效解决此类复杂优化问题。Peng 等将禁忌搜索与基因表达式编程相结合,建立了激光熔覆过程中能耗和粉末利用率的预测模型,并采用 NSGA-II 算法求解 Pareto 前沿,实现了能效与材料效率的协同优化^[30]。Asadollahi-Yazdi 等针对 FDM 工艺,以层厚和成形方向为决策变量,利用 NSGA-II 算法实现了零件质量和制造时间的多目标优化,为工艺参数综合优化提供了方法论指导^[31]。石永军教授团队针对镍钛合金增材制造工艺参数优化问题,提出了一种结合遗传算法优化反向传播神经网络和帕累托前沿法的多目标优化框架,有效平衡了多个性能指标^[32]。

熔池作为增材制造中材料演化的基本单元,其形态特征直接决定了成形质量和缺陷形成。塔皮亚团队针对 316L 不锈钢激光粉末床熔融工艺建立了替代模型,该研究致力于仅通过激光功率、速度和光斑尺寸参数来预测单道打印的熔池深度,该模型虽然计算成本较高但精度极高。通过在不同激光功率、速度及光斑尺寸条件下进行粉末床模拟实验,模型成功输出了熔池深度等关键参数^[54]。




图4 Tapia 用于预测激光粉末床熔融技术熔池深度的输入数据、响应面 $y(x)$ 及误差 $e(x)$

Akbari 等开发了基于机器学习的 MeltpoolNet 框架,能够根据材料特性和工艺参数准确预测熔池几何特征,并识别潜在的缺陷类型,为熔池形态控制提供了智能化工具^[33]。Zhu 等系统比较了 SVR、XGBoost 和 BPNN 三

种模型在熔池形态预测中的表现,结果表明 XGBoost 在熔池宽度和深度预测上分别达到 97% 和 96.3% 的准确率,展现出优异的预测性能^[34]。Yang 等提出了一种用于

LPBF 工艺参数与熔池尺寸双向预测的框架,该框架在测试数据集上的预测精度超过 96%,实现了工艺参数与成形质量的逆向映射^[35]。

4.3 在过程监测与缺陷检测中的应用




图 5 基于 SLM 增材制造原理简图

基于图像的缺陷检测方面。增材制造过程中,铺粉不均、熔池异常、飞溅等现象可通过视觉传感器实时捕获。基于深度学习的图像识别技术可实现对各类缺陷的实时检测与准确分类。Scime 和 Beuth 采用多尺度卷积神经网络对 LPBF 过程中的铺粉异常进行检测,实现了铺粉划痕、

铺粉不足、凹陷等六类缺陷的自动识别,总体准确率达到 97%,为粉末床工艺的在线质量控制提供了有效手段^[36]。尚耀明在 Faster R-CNN 基础上引入多尺度特征提取与融合方法,强化缺陷信息的表征能力,对增材制造铺粉表面缺陷的平均检测精度达 93.26%,检测时间仅为 17.49ms,

满足了在线检测的实时性要求^[37]。蔡引娣等针对增材制造微小气孔缺陷检测难题,基于改进的YOLOv8模型引入高效通道注意力机制和WIoU损失函数,检测准确率达94.3%,对微小缺陷的尺寸测量精度可达40 μm ,实现了微小缺陷的精确定量与定位^[38]。王玮以挤出成型3D打印为

对象,通过添加注意力机制和优化损失函数改进YOLOv8模型,对针头刮蹭、孔隙、过量堆积、材料污染四类缺陷的平均检测精度达91.7%,验证了改进模型在多种缺陷检测任务中的有效性^[39]。




图6 AM 基于多传感器融合的数字孪生系统

基于多传感器融合方面。单一传感器难以全面捕捉增材制造过程的复杂信息,多传感器融合已成为重要发展趋势。Chen等构建了基于多传感器融合的数字孪生系统,如图6所示,将声发射传感器、红外热像仪、同轴视觉相机和激光线扫描仪的数据进行时空融合,实现了DED过程中局部质量的在线预测与缺陷校正,显著提升了过程监控的全面性和准确性^[40]。Bevans等将红外相机、飞渡成像相机和PBF成像相机的数据进行深度融合,对LPBF零件中孔隙、几何缺陷和层变形等多种尺度缺陷的检测准确率超过93%,验证了多模态数据融合在复杂缺陷检测中的优越性^[41]。

基于声发射和光谱信号分析方面。声发射和光谱信号能够反映增材制造过程中材料状态的动态变化。Shevchik等利用声发射传感器采集SLM过程中的声学信号,通过光谱卷积神经网络对不同孔隙率的样本进行分类,准确率达83%-89%,为深层缺陷的在线检测提供了新思路^[42]。Ren等结合长短期记忆自编码器和K-means聚类,对

DED过程中的光学发射光谱进行无监督学习分析,实现了沉积质量的自动分类,避免了大量标注数据的需求^[43]。

4.4 在微观组织与性能预测中的应用

微观组织预测方面。增材制造快速凝固过程导致独特的微观组织特征,机器学习可建立工艺参数与组织特征之间的定量映射关系。Ackermann等利用机器学习方法识别金属增材制造中的过程—结构关联,通过SHAP分析揭示了工艺参数对微观组织的影响机制,为工艺—组织关系的可解释性建模提供了新方法^[44]。Miyazaki等采用随机森林算法对SLM制备的Ti-6Al-4V合金微观组织图像进行分割,成功自动识别 α 相和 β 相区域,并精确计算了晶粒尺寸、形态和分布特征,实现了微观组织的自动化定量表征。显微组织形成示意图如图7所示,每个鳞片状显微组织的内部都有 α 马氏体相,颜色表示bcc晶格在 Δ 转变上方的晶体取向,热处理后,二次 α 粒子在大角度晶界析出^[45]。




图 7 Ti6Al4V 在 SLM 工艺及热处理过程中的显微组织形成示意图:

- (a) 激光辐照下的原晶粒长大, (b) SLM 后的鳞片状显微组织, (c) 长时间热处理后的显微组织。

力学性能预测方面。力学性能预测是增材制造零件质量评估的关键环节, Zhan 等结合连续损伤力学和机器学习方法, 建立了增材制造钛合金疲劳寿命预测的 CDM-RF 模型, 预测精度显著优于传统方法, 体现了物理知识与数据驱动方法融合的优势^[46]。周治东基于人工神经网络对增材制造 AlSi10Mg 合金疲劳寿命进行预测, 通过引入遗传算法和天牛须算法优化 BP 神经网络, BAS-BP 模型的相关系数达 0.9921, 预测精度大幅提升, 验证了智能优化算法在神经网络训练中的有效性^[47]。

物理信息神经网络方面。Chen 和 Liu 提出概率物理引导神经网络, 将 S-N 曲线的物理知识作为约束嵌入网络训练过程, 包括低应力水平下寿命分散性增大的统计规律以及疲劳极限附近的渐近行为, 在镍基高温合金和 Ti-6Al-4V 合金的疲劳寿命预测中取得了良好的物理一致性和预测精度, 为物理增强的机器学习建模提供了典范^[48]。

缺陷敏感性分析方面。增材制造零件常表现出明显的各向异性和缺陷敏感性, Li 等基于支持向量回归研究了 SLM 制备 Inconel 718 合金中孔隙特征对疲劳寿命的影响, 系统分析了孔隙尺寸、位置和数量三个特征, 发现孔隙位置对疲劳寿命的影响最为显著, 为缺陷容忍设计提供了重要依据^[49]。Hörnäs 等采用高斯过程和高分辨率同步辐射 X 射线显微断层扫描技术, 对 SLM 制备的 Ti-6Al-4V 样品疲劳寿命进行预测, 定量分析发现缺陷位置对疲劳寿命的影响最大, 形态次之, 尺寸再次之, 深化了对缺陷致疲劳机理的认识^[50]。

五、数字孪生与增材制造的融合

数字孪生作为连接物理世界与数字世界的桥梁, 近年来与增材制造的深度融合已成为智能制造领域的研究热点。Debroy 等构建了第一代增材制造数字孪生系统框架, 系统整合了制造设备、大数据模型、力学模型、控制模型和机器学习算法等核心组成部分, 为增材制造全流程数字化映射奠定了基础^[51]。陶飞等提出的数字孪生五维模型在传统三维模型基础上增加了孪生数据和服务两个维度, 为增材制造数字孪生系统的理论构建提供了完整的体系框架^[52]。Jyeniskhan 等开发了集成机器学习模型的 FDM 打印机数字孪生系统, 采用 EfficientDet-Lite 模型进行在线缺陷检测, 平均精度达 92%, 通过 Unity 客户端实现打印过程的实时监控与远程控制, 展示了数字孪生技术在增材制造中的实际应用价值^[53]。



图 8 机器学习在增材制造质量控制中的未来应用方向^[5]

数字孪生技术的核心价值在于实现物理空间与信息空间的实时交互与动态映射，形成“感知—分析—决策—控制”的闭环优化机制。在增材制造领域，数字孪生系统可集成多源工艺监测数据、多物理场仿真结果和机器学习预测模型，实现对制造过程的全方位感知与智能控制。随着物联网、边缘计算和 5G 通信等使能技术的快速发展，数字孪生系统将向更高保真度、更低延迟和更强自主性的方向持续演进，为增材制造的智能化转型提供关键的技术支撑。

六、结论与展望

人工智能正在深刻改变增材制造技术的研发范式与生产方式。本文系统综述了机器学习、深度学习等人工智能方法在工艺参数优化、过程监测、性能预测、结构设计等方面的研究进展与应用现状。研究结果表明，数据驱动方法能够有效应对增材制造工艺的多参数强耦合、高度非线性等固有挑战，显著提升产品开发效率与质量稳定性。混合建模策略将物理知识与数据驱动方法有机结合，代表了增材制造智能化的重要发展方向。数字孪生技术的引入进一步强化了物理世界与数字世界的双向映射与动态交互，为实现全流程智能控制奠定了基础。

尽管人工智能在增材制造领域已取得显著进展，但仍面临诸多挑战亟待解决。数据稀缺性问题尤为突出，增材制造实验成本高、周期长，导致可用于模型训练的高质量数据极为有限；模型泛化能力不足，训练于特定设备、材料和工艺条件下的模型难以直接迁移至新场景；可解释性欠缺使得人工智能模型在高安全要求的航空航天、医疗等领域的应用受到限制；多物理场耦合机理复杂，单一数据驱动方法难以全面捕捉物理过程的本质规律。

展望未来，以下研究方向值得重点关注：物理—数据融合建模将物理知识与数据驱动方法深度融合，构建兼具物理一致性和预测精度的混合模型，是增材制造智能化的重要路径；生成式模型与自主实验的结合有望突破数据稀缺的瓶颈，通过智能选择最有价值的实验条件，最大化信息获取效率；多尺度多物理场数字孪生将构建涵盖原子尺度到宏观尺度、耦合热—力—流多物理场的数字孪生系统，实现增材制造全过程的精确模拟与智能控制；大语言模型在增材制造知识问答、故障诊断、工艺优化等方面展现出潜力，有望改变人机交互方式，加速知识获取与应用。随着算法持续进步、数据不断积累与跨学科合作深化，人工智能必将在构建下一代增材制造体系中发挥核心作用，推动高性能材料的快速研发与可靠制造。

作者简介：

杨雪强，宁夏大学工学硕士，2024 年 7 月于西北稀有金属材料研究院宁夏有限公司担任工程师，主要从事稀有金属的材料制备及仿真模拟技术研究，工作以来主持参与省部级以上项目 4 项，授权专利 10 余篇。

李军义，正高级工程师，西北稀有金属材料研究院宁夏有限公司副总经理、金属铍研究领域的核心专家和技术领军人物，享受自治区及石嘴山市政府特殊津贴，先后主持参与国家重点计划研发项目多项，牵头制定了《铍铝合金》等多项国标 / 国军标，公开发表学术论文 40 余篇，拥有授权专利 17 项。

乔鹏，研究生学历，西北稀有金属材料研究院宁夏有限公司副高级工程师，金属铍研究领域的核心专家，先后主持参与省部级以上项目 10 项，公开发表学术论文 6 篇，拥有授权专利 20 余项，主导起草行业标准 2 项。

参考文献

- [1] Du Y, Mukherjee T, Li R, et al. A review of deep learning in metal additive manufacturing: Impact on process, structure, and properties[J]. Progress in Materials Science, 2026, 157: 101587.
- [2] Adapa V S K, Kalidindi S R, Saldana C J. Rapid Development of Metal Additive Manufacturing Using Artificial Intelligence/Machine Learning and High-Throughput Material Testing[J]. Annual Review of Materials Research, 2025, 55: 175-201.
- [3] Hu Z, Huang C, Xie L, et al. Machine learning assisted quality control in metal additive manufacturing: A review[J]. Advanced Powder Materials, 2025, 4(6): 100342.
- [4] Kim H, Kim K H, Jeong J, et al. Advancing intelligent additive manufacturing: Machine learning approaches for process optimization and quality control[J]. International Journal of AI for Materials and Design, 2025, 2(2): 27-55.
- [5] Zhang X, Tang J, Tan K, et al. Online monitoring and intelligent internal quality discrimination method for laser powder bed fusion based on acoustic emission signals[J]. Journal of Vibration Engineering, 2025, 38(6): 1134-1144.
- [6] 苏金龙, 陈乐群, 谭超林, 等. 基于机器学习的增材制造过程优化与新材料研发进展 [J]. 中国激光, 2022, 49(14): 1402101.
- [7] Łukasz Łach, Dmytro Svyetlichnyy. Advanced Numerical Modeling of Powder Bed Fusion: From Physics-Based Simulations to AI-Augmented Digital Twins[J]. Materials, 2026, 19(2): 426.
- [8] Hajnys J, Ma P Q, Vandzura R, et al. A review on support-free printing with powder bed fusion method[J]. Progress in Additive Manufacturing, 2025, 11(1): 1-17.
- [9] Nabavi F S, Garmestani H. Multi-scale modeling of metallurgical phenomena in metal laser powder bed fusion additive manufacturing: A comprehensive review[J]. Journal of Manufacturing Processes, 2025, 150: 610-644.
- [10] 潘露, 张恒华, 刘桐, 等. 激光粉末床熔融数值模拟研究进展 [J]. 金属加工 (热加工), 2025, (5): 1-17.
- [11] 代逍遥, 苑仲伯, 赵吕, 等. 基于机器学习的 L-PBF Ti-6Al-4V 疲劳性能预测研究进展 [J]. 金属学报, 2026, 47(1): 1-33.
- [12] Xu Z, Li M, Han Y. Mechanical properties of crystalline-amorphous composites: generalization of Hall-Petch and inverse Hall-Petch behaviors[J]. National Science Review, 2025, 12(9): 326-335.
- [13] 王鑫旭, 闫承琳, 李晓旭, 等. 机器学习在增材制造中的研究进展 [J]. 材料导报, 2025, 39(S2): 574-586.
- [14] Sharifani K, Amini M. Machine Learning and Deep Learning: A Review of Methods and Applications[J]. World Information Technology and Engineering Journal, 2023, 10(7): 3897-3904.
- [15] Renfei C, Zhongwen L. Industrial defect detection for data privacy and domain differences: Based on federated learning and unsupervised domain adaptation[J]. Expert Systems with Applications, 2026, 310: 131265.
- [16] Cuihong Z, Jianjun W, Yiliu T, et al. Robust optimization of 3D printing process parameters considering process stability and production efficiency[J]. Additive Manufacturing, 2023, 71: 103588.
- [17] Vaezi M, Klamert V, Bublin M. Deep Learning for Process Monitoring and Defect Detection of Laser-Based Powder Bed Fusion of Polymers[J]. Polymers, 2026, 18: 629.
- [18] Yao X, Moon K S, Bi G. A hybrid machine learning approach for additive manufacturing design feature recommendation[J]. Rapid Prototyping Journal, 2017, 23(6): 983-997.
- [19] Li Y, Wang F, Jiang Y. Machine-Vision-Based Intelligent Manufacturing by Fine-Grained Point Cloud Identification[J]. Applied Bionics and Biomechanics, 2022, 2022: 5627959.

- [20] Zhang Y, Zhao Y F. A Web-based automated manufacturability analyzer and recommender for additive manufacturing (MAR-AM) via a hybrid Machine learning model[J]. Expert Systems with Applications, 2022, 199: 117189.
- [21] Banga S, Gehani H, Bhilare S, et al. 3D Topology Optimization using Convolutional Neural Networks[J]. arXiv preprint, 2018, arXiv:1808.07440.
- [22] Yu Y, Hur T, Jung J, et al. Deep learning for determining a near-optimal topological design without any iteration[J]. Structural and Multidisciplinary Optimization, 2019, 59(3): 787-799.
- [23] Oh S, Jung Y, Kim S, et al. Deep Generative Design: Integration of Topology Optimization and Generative Models[J]. Journal of Mechanical Design, 2019, 141(11): 111401.
- [24] Vaissier B, Pernot J, Chougrani L, et al. Genetic-algorithm based framework for lattice support structure optimization in additive manufacturing[J]. Computer-Aided Design, 2019, 110: 11-23.
- [25] Li R, Peng Q. Deep learning-based optimal segmentation of 3D printed product for surface quality improvement and support structure reduction[J]. Journal of Manufacturing Systems, 2021, 60: 252-264.
- [26] Tapia G, Khairallah S, Matthews M, et al. Gaussian process-based surrogate modeling framework for process planning in laser powder-bed fusion additive manufacturing of 316L stainless steel[J]. The International Journal of Advanced Manufacturing Technology, 2018, 94(9-12): 3591-3603.
- [27] Chen K, Zhang P, Yan H, et al. A review of machine learning in additive manufacturing: design and process[J]. The International Journal of Advanced Manufacturing Technology, 2024, 135: 1051-1087.
- [28] Zhou H, Ma Y, Li H, et al. Process prediction of M2052 alloy selective laser melting using a prototype network-enhanced SVC[J]. Journal of Alloys and Compounds, 2025, 1041: 183559.
- [29] Han C, Yan F, Yuan D, et al. Machine learning enabling prediction in mechanical performance of Ti6Al4V fabricated by large-scale laser powder bed fusion via a stacking model[J]. Frontiers of Mechanical Engineering, 2024, 19(4): 25.
- [30] Peng S, Li T, Zhao J, et al. Towards energy and material efficient laser cladding process: Modeling and optimization using a hybrid TS-GEP algorithm and the NSGA-II[J]. Journal of Cleaner Production, 2019, 227: 58-69.
- [31] Asadollahi-Yazdi E, Gardan J, Lafon P. Multi-objective optimization approach in design for additive manufacturing for fused deposition modeling[J]. Rapid Prototyping Journal, 2019, 25(5): 875-887.
- [32] Wang S, Shi Y, Cheng W, et al. Multi-objective optimization of additive manufacturing process parameters of nitinol alloys for elastocaloric cooling[J]. Engineering Applications of Artificial Intelligence, 2025, 154: 111012.
- [33] Akbari P, Ogoke F, Kao N Y, et al. MeltpoolNet: Melt pool characteristic prediction in Metal Additive Manufacturing using machine learning[J]. Additive Manufacturing, 2022, 55: 102817.
- [34] Zhu X, Jiang F, Guo C, et al. Prediction of melt pool shape in additive manufacturing based on machine learning methods[J]. Optics and Laser Technology, 2023, 159: 108964.
- [35] Yang A, Zhao Z, Zhang X. A bidirectional prediction framework for melt pool size and process parameters in LPBF[J]. Engineering Research Express, 2025, 7(1): 015549.
- [36] Scime L, Beuth J. A Multi-scale Convolutional Neural Network for Autonomous Anomaly Detection and Classification in a Laser Powder Bed Fusion Additive Manufacturing Process[J]. Additive Manufacturing, 2018, 24: 273-286.
- [37] 尚耀明. 基于深度学习的增材制造铺粉缺陷在线检测方法研究 [D]. 机械科学研究总院, 2022.

- [38] 蔡引娣, 张殿鹏, 孙梓盟, 等. 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[J]. 光学精密工程, 2024, 32(21): 3222-3230.
- [39] 王伟. 基于深度学习技术的挤出成型3D打印缺陷检测研究[D]. 东南大学, 2024.
- [40] Chen L, Bi G, Yao X, 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.
- [41] Bevans B, Barrett C, Spears T, et al. Heterogeneous sensor data fusion for multiscale, shape agnostic flaw detection in laser powder bed fusion additive manufacturing[J]. Virtual and Physical Prototyping, 2023, 18(1): 2196266.
- [42] Shevchik S, Kenel C, Leinenbach C, et al. Acoustic emission for in situ quality monitoring in additive manufacturing using spectral convolutional neural networks[J]. Additive Manufacturing, 2018, 21: 598-604.
- [43] Ren W, Wen G, Zhang Z, et al. Quality monitoring in additive manufacturing using emission spectroscopy and unsupervised deep learning[J]. Materials and Manufacturing Processes, 2022, 37(11): 1339-1346.
- [44] Ackermann M, Haase C. Machine learning-based identification of interpretable process-structure linkages in metal additive manufacturing[J]. Additive Manufacturing, 2023, 71: 103585.
- [45] Miyazaki S, Kusano M, Bulgarevich D S, et al. Image Segmentation and Analysis for Microstructure and Property Evaluations on Ti-6Al-4V Fabricated by Selective Laser Melting[J]. Materials Transactions, 2019, 60(4): 561-568.
- [46] Zhan Z, Hu W, Meng Q. Data-driven fatigue life prediction in additive manufactured titanium alloy: A damage mechanics based machine learning framework[J]. Engineering Fracture Mechanics, 2021, 252: 107850.
- [47] 周治东. 基于人工神经网络的增材制造铝镁合金疲劳寿命预测研究[D]. 南昌大学, 2025.
- [48] Chen J, Liu Y. Probabilistic physics-guided machine learning for fatigue data analysis[J]. Expert Systems with Applications, 2021, 168: 114316.
- [49] Luo Y W, Zhang B, Feng X, et al. Pore-affected fatigue life scattering and prediction of additively manufactured Inconel 718: An investigation based on miniature specimen testing and machine learning approach[J]. Materials Science and Engineering A, 2021, 802: 140693.
- [50] Hörnas J, Behal J, Homola P, et al. Modelling fatigue life prediction of additively manufactured Ti-6Al-4V samples using machine learning approach[J]. International Journal of Fatigue, 2023, 169: 107483.
- [51] DebRoy T, Zhang W, Turner J, et al. Building digital twins of 3D printing machines[J]. Scripta Materialia, 2017, 135: 119-124.
- [52] 陶飞, 刘蔚然, 张萌, 等. 数字孪生五维模型及十大领域应用[J]. 计算机集成制造系统, 2019, 25(1): 1-18.
- [53] Jyeniskhan N, Keutayeva A, Kazbek G, et al. Integrating machine learning model and digital twin system for additive manufacturing[J]. IEEE Access, 2023, 11: 71113-71126.
- [54] N.S. J, P.S. V, A.C. T, et al. Invited Review: Machine Learning for Materials Developments in Metals Additive Manufacturing[J]. Additive Manufacturing, 2020, 36(prepublish): 101641-.DOI:10.1016/j.addma.2020.101641.