

DOI: 10.7512/j.issn.1001-2303.2026.04.04

人工智能代理模型在激光金属增材中的典型应用

邓奥林^{1,2}, 樊思想¹

1. 上海电气集团股份有限公司中央研究院, 上海 200070
2. 核能增材制造四川省重点实验室, 四川 成都 610213

摘要: 增材制造技术以其高度的几何自由度和定制化能力, 在航空航天、汽车、生物医药及高端装备等领域展现出巨大的应用潜力。然而, 对于金属增材制造而言, 如何高效地设计出性能优异且满足特定功能需求的结构, 并准确预测其在复杂工况下的力学行为和服役性能, 仍是制约其进一步迈向大规模产业化的关键瓶颈。本文对近年来基于数据驱动和物理机理约束的人工智能代理模型在激光金属增材中的应用研究进行了简要综述, 主要包括其在结构设计优化、宏观性能快速预测、工艺参数-微观组织-宏观性能关联分析等方面的典型研究应用, 并针对目前激光金属增材与人工智能相结合领域的痛点及应对策略给出了一些建议, 旨在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和启示, 推动金属增材制造向更智能、更高效、更可靠的方向发展。

关键词: 金属增材制造; 人工智能代理模型; 机器学习; 深度学习; 物理信息网络

中图分类号: TH164 文献标识码: A 文章编号: 1001-2303(2026)04-0031-12

Typical applications of Artificial Intelligence Surrogate Models in Laser Metal Additive Manufacturing

DENG Aolin^{1,2}, FAN Enxiang¹

1. Shanghai Electric Group Co., Ltd., Central Academe, Shanghai 200070, China
2. Nuclear Power Additive Manufacturing Key Laboratory of Sichuan Province, Chengdu 610213, China

Abstract: Additive manufacturing (AM) has demonstrated substantial application potential in aerospace, automotive, biomedical, and high-end equipment industries, owing to its exceptional geometric freedom and customization capabilities. However, for metal additive manufacturing, the efficient design of high-performance structures that satisfy specific functional requirements, along with the accurate prediction of their mechanical behavior and service performance under complex working conditions, remains a critical bottleneck hindering its widespread industrial adoption. This paper presents a concise review of recent research on artificial intelligence surrogate models, constrained by both data-driven approaches and physical mechanisms, in laser-based metal additive manufacturing. The review primarily covers typical applications in structural design optimization, rapid prediction of macroscopic properties, and correlation analysis among process parameters, microstructure, and macroscopic properties. Furthermore, several recommendations are provided regarding the current challenges and corresponding strategies in the integration of laser metal additive manufacturing with artificial intelligence. The objective is to offer valuable insights and references for researchers and engineers in related fields, thereby promoting the development of metal additive manufacturing toward greater intelligence, efficiency, and reliability.

Keywords: metal additive manufacturing; artificial-intelligence surrogate models; machine learning; deep learning; physics-informed neural networks

引用格式: 邓奥林, 樊思想. 人工智能代理模型在激光金属增材中的典型应用[J]. 电焊机, 2026, 56(4): 31-42.

Citation: DENG Aolin, FAN Enxiang. Typical applications of Artificial Intelligence Surrogate Models in Laser Metal Additive Manufacturing[J]. Electric Welding Machine, 2026, 56(4): 31-42.

收稿日期: 2025-12-20 修回日期: 2026-02-03

作者简介: 邓奥林(1993—), 男, 博士, 工程师, 主要从事金属增材制造研究。E-mail: dengao@shanghai-electric.com。

通讯作者: 樊思想, E-mail: fanenx@shanghai-electric.com。

0 引言

尽管金属增材制造凭借其高成形精度和良好的力学性能在航空航天、国防军工、医疗器械、汽车工业等领域展现出了广阔的应用前景^[1-3],但该技术在走向大规模工业化应用的道路上依然面临着极其严峻的挑战。其一,制造过程的多物理场强耦合以及工艺参数复杂敏感的问题极易导致各种缺陷的形成,严重影响量产的质量稳定性^[4];其二,传统“试错法”模式需要大量的物理实验和迭代优化,研发周期长、成本高;其三,对于复杂结构创新或新材料的性能预测,严重依赖于高保真度但计算成本极为高昂的有限元计算,难以开展规模化的设计探索^[5]。这种“不稳定”、“仿真慢”和“实验贵”的多重困境,严重制约了金属增材制造技术创新的效率,成为其从“样品”走向“产品”的主要技术壁垒。

在此背景下,将人工智能技术(Artificial Intelligence, AI)融入增材制造的全流程正成为学术界和工业界共同关注的热点。这一新范式旨在利用海量的增材全流程数据(物理制造的实验数据以及设计空间的仿真数据)对构建的专用AI模型进行训练,从而获得能够快速、准确地预测仿真结果、制造过程、结构性能的“代理模型”(Surrogate Model)^[6]。这些AI代理模型一旦构建完成,其推理速度可以比传统的有限元计算和人工数据分析快几个数量级,实现从“小时级”到“秒级”的飞跃,从而大幅提升增材制造的效率及质量。本综述聚焦于近年来的最新研究成果,系统性地探讨基于增材过程数据的AI代理模型如何赋能金属增材制造,分析其核心方法论、典型应用、面临的挑战及未来发展方向,以期为该交叉领域的深入研究和应用提供有价值的参考。

1 AI代理模型在金属增材中的典型应用

目前,根据建模方法与对物理规律融合程度的不同,主流的AI代理模型主要沿三个方向演进:基于传统机器学习的方法(如支持向量机、随机森林等)^[7-8],其依赖特征工程与适量数据,在小样本场景

中表现稳健;基于深度学习的方法(如深度神经网络、卷积神经网络等),其凭借强大的非线性表征能力,适于处理高维、复杂的工艺数据;基于融入物理信息约束的神经网络方法,其进一步将控制方程、边界条件等物理先验嵌入到模型结构与损失函数中,即使在数据稀缺的情况下,也能保持预测结果与物理规律的一致性,显著提升了模型的泛化性与可解释性。这三类方法彼此补充、协同发展,共同推动增材制造向着一体化、智能化的方向迈进。

1.1 基于传统机器学习方法的应用

在深度学习兴起之前,一系列经典的机器学习算法已被广泛用于构建代理模型,以解决工程优化和设计问题。这些方法通常在数据量相对较小或模型可解释性要求较高的场景下具有优势。

成形零件的公差控制与几何偏差的预测是所有增材工艺优化中的关键节点,针对此项难题,Answer等人^[9]从打印尺寸偏差的类型着手,将视角变换与多任务高斯过程回归相融合,建立了一种新的尺寸偏差预测模型,预测准确率高达97%。类似的,Baturynska等人^[10]对四种常见的机器学习模型在不同打印方向上尺寸偏差的预测质量进行了系统的研究,结果表明,各模型的预测精度随打印方向及尺寸特征的不同而有明显差异,说明在实际应用中需根据具体工艺条件与预测目标谨慎选择模型。如图1所示。

缺陷的在线检测与控制是金属增材制造中是至关重要的,它直接影响着成形质量及量产工艺的一致性,如图2所示。针对金属增材中常用的Ti-6Al-4V合金,Paulson等人^[11]通过机器学习方法建立了其激光粉末床熔融(Laser Powder Bed Fusion, LPBF)过程的热历史分布与匙孔孔隙率之间的关联,研究发现不同的温度变化趋势对应着不同的孔隙特征:即低温单调下降常伴随低孔隙率,而先降后升的高温历史则易引发大孔隙,两者之间存在小孔隙率的过渡区,该项研究明确揭示了熔池温度场与孔隙大小的对应关系;Rao等人^[12]则进一步将熔池仿真与实验传感数据融合起来,利用支持向量机模型进行监督机器学习,结果表明,融合仿真预测与真实传感数据的代理模型对熔池缺陷的预测准确率接近90%。这两项工作围绕熔池温度场的时

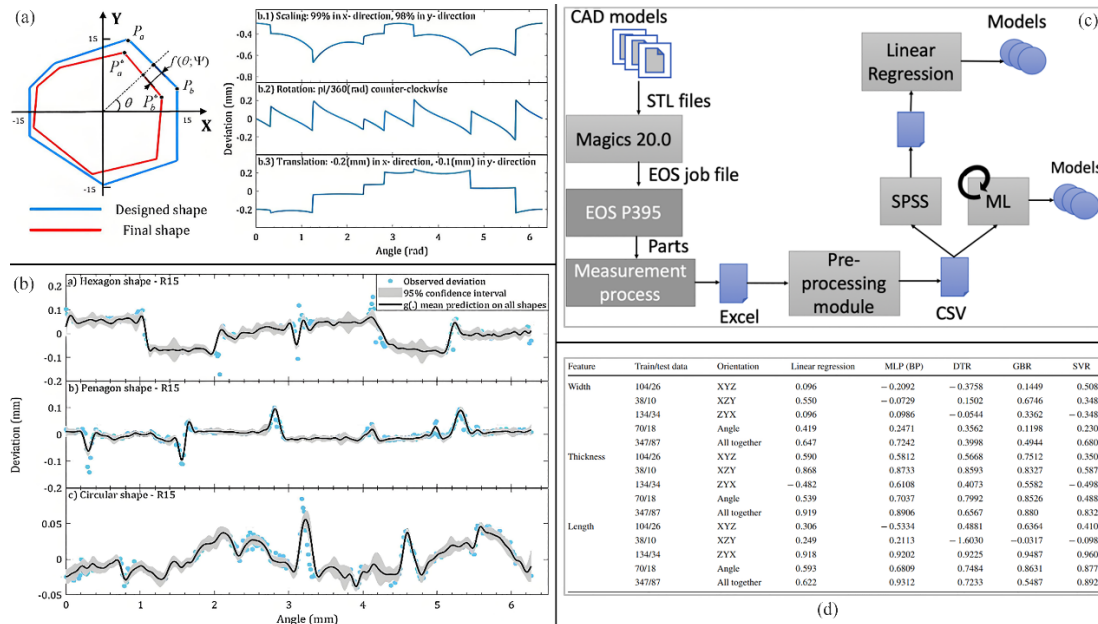


图 1 传统机器学习在增材零件尺寸偏差预测的应用: (a) 六边形在实空间及偏差空间中的尺寸偏差示意^[9]; (b) 实际观测与模型预测的尺寸偏差对比^[9]; (c) 从增材设计到模型预测的过程示意^[10]; (d) 不同预测模型对于不同特征尺寸的预测精度^[10]

Fig. 1 Applications of traditional machine learning in predicting dimensional deviations of additive parts: (a) Schematic diagram of shape deviations of a hexagon in real space and deviation space^[9]; (b) Comparison of shape deviations between actual observations and model predictions^[9]; (c) Schematic diagram of the process from additive design to model prediction^[10]; (d) The prediction accuracy of different prediction models for different feature sizes^[10]

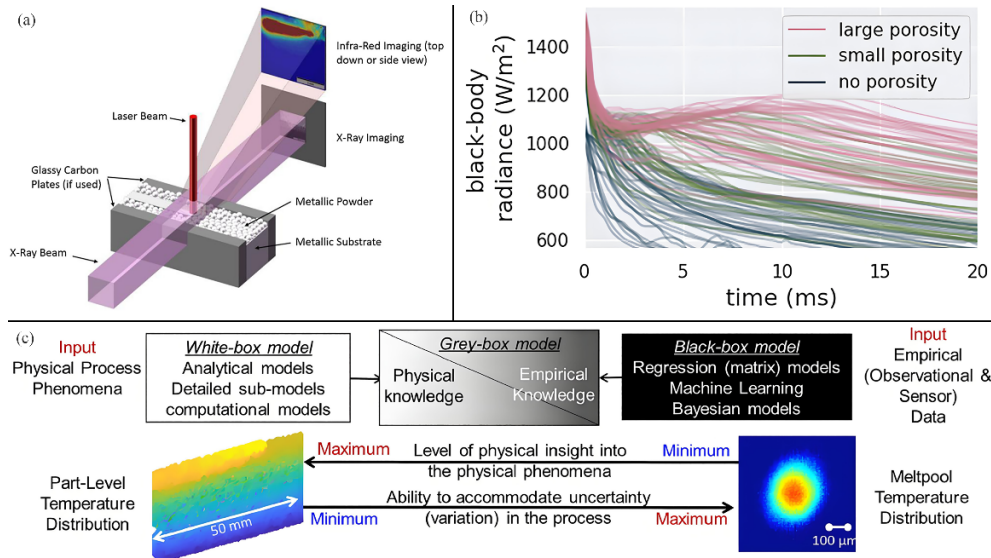


图 2 传统机器学习在增材缺陷预测中的应用: (a) 用于原位记录 LPBF 过程的实验装置示意^[11]; (b) 依据孔隙度类型绘制的时间与温度的历史曲线^[11]; (c) 融合仿真预测与实验传感数据的缺陷预测示意^[12]

Fig. 2 Applications of traditional machine learning in additive defect prediction: (a) Schematic diagram of the experimental setup for in-situ recording of the LPBF process^[11]; (b) Historical curves of time versus temperature plotted based on porosity type^[11]; (c) Schematic of defect prediction integrating simulation and experimental data^[12]

空分布建立了其与零件缺陷之间的映射关系, 也为金属增材过程监控的数字孪生范式提供了初步探索。

增材构件的性能通常是采用打印样棒测试的方法来获得, 而如果能够利用机器学习建立结构-性能之间的关系, 则可以节省大量的测试时间, 大

幅提升研发效率。针对Ti-6Al-4V合金零件的服役性能预测难题,Kusano等人^[13]利用CT、SEM等技术提取的微观结构特征,然后通过力学试验获得相对应的屈服/抗拉强度,随机森林算法(Random Forest, RF)则被用于建立微观结构与宏观性能之间的关联,如图3所示,结果表明,该模型对屈服强度和极限抗拉强度的预测准确率>98%,为后续进行基于微观组织结构的宏观性能预测提供了一条切实可行的路径。

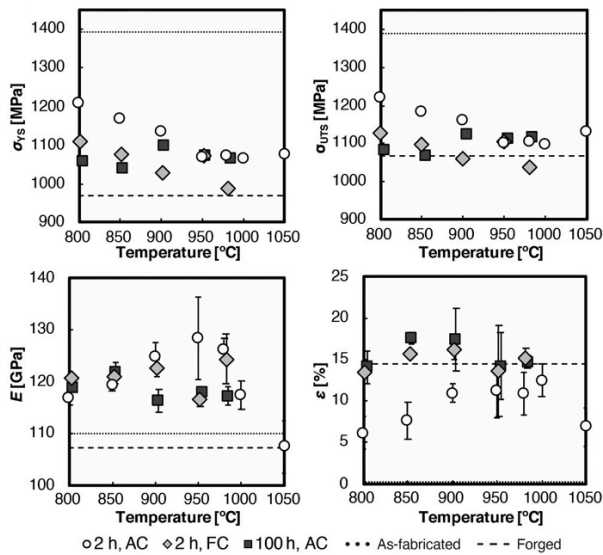


图3 传统机器学习在增材零件性能预测中的应用(图为屈服强度和抗拉强度的实验-预测值的对比^[13])。

Fig. 3 Applications of traditional machine learning in the performance prediction of additive parts, the figure shows the comparison between the experimental values and the predicted values of yield strength and tensile strength^[13]

传统的机器学习模型作为最先应用于增材制造的人工智能技术,虽然取得了很多不错的进展,但其也存在较大的局限性,尤其是在处理增材制造独特的多物理过程、多尺度性和不确定性方面,其对复杂物理机制的表征能力有限,难以有效融合和处理高维跨尺度的异构数据,无法动态部署以在线应用。基于这些难以解决的问题,以神经网络为核心的深度学习模型逐渐兴起,为这一领域带来了新的解决思路。

1.2 基于深度学习技术的应用

随着深度学习技术的飞速发展,以深度神经网络为代表的模型,因其强大的特征学习能力和对复杂非线性关系的卓越拟合能力,正在成为加速增材

制造的新范式。与传统的机器学习模型相比,深度学习学习方法通常被视为“端到端”的学习框架,能够直接从原始的、高维度的输入端数据(如图像、三维体素网格、有限元网格)中自动学习有效的特征表示,并将其映射到输出端。

深度学习算法已被广泛的应用于不同维度的材料结构设计当中,以实现结构和性能的协同优化^[14-21]。如图4所示,针对传统拓扑优化难以集成几何约束的难题,Almasri等人^[22]提出了一种采用双判别器生成对抗网络(Generative Adversarial Networks, GAN)的深度学习方法,可同时融合力学性能与几何形状要求,在显著缩短设计时间的同时生成与传统拓扑优化方法相近的结果,并支持通过调整输入条件进行结构微调;Zhao等人^[14]利用GAN来生成具有极端力学性能的无经验依赖结构设计,通过对超过400种二维结构的模型设计测试,实现了接近理论极限的各向同性弹性刚度。这类深度融合结构数据与生成式模型的方法,为复杂零件的高质量、高性能设计提供了灵活且高效的途径。

打印过程的激光参数原位控制对于提升零件的成形质量有着不言而喻的作用,为此,研究者引入了强化学习来实现工艺自适应优化。Ogoke等人^[23]提出了一种基于深度强化学习(Deep Reinforcement Learning, DRL)的控制框架来动态调整工艺参数,该工艺控制模型可以通过实时调整激光功率、扫描速率等参数实现熔池的稳定,从而有效地减少因过热和熔池不稳定导致的匙孔/裂纹等缺陷;类似的,Dharmadhikari等人^[24]则基于Q强化学习框架,构建了旨在实时优化激光定向能沉积(Directed Energy Deposition, DED)中激光功率与扫描速度的优化模型,该模型对工艺参数的在线优化可确保一个1 mm深度的稳定熔池贯穿整个打印过程,从而有效提升零件成形质量的一致性。

对于增材过程的实时数据监测,多源信号已被应用于识别预测与熔池特征相关的缺陷当中,如图6所示。例如针对熔池的声发射信号,Elbestawi^[25]基于变分自动编码器(Variational Auto-Encoder, VAE)构建了一种通用的深度学习模型,通过对打印过程中熔池的声学信号及对应的缺陷数据进行学习,成功获得了二者之间的关联趋势,为优化机器

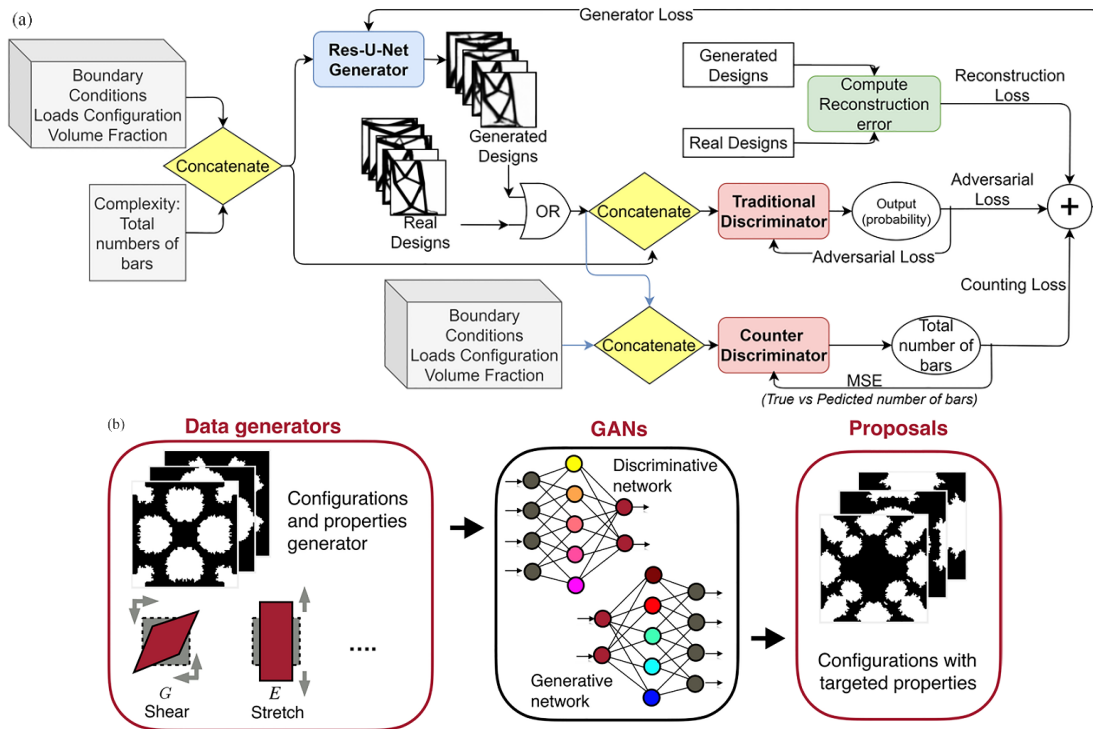


图 4 深度学习在增材设计优化中的应用: (a) GAN 模型的训练步骤^[22]; (b) 利用 GAN 模型进行复杂材料设计的程序示意^[14]
 Fig. 4 Applications of deep learning in additive design optimization: (a) Training steps of GAN model^[22]; (b) Schematic diagram of the program for complex material design using the GAN model^[14]

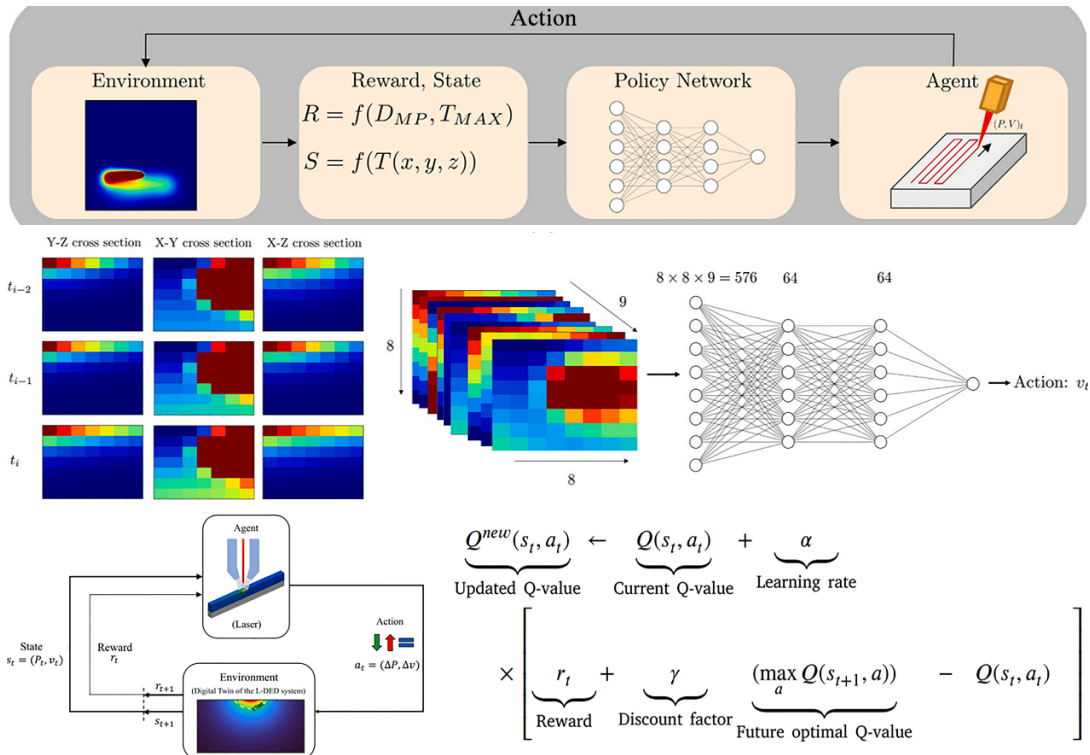


图 5 深度学习在增材工艺优化中的应用: (a, b) 深度强化学习的框架示意^[23]; (c) 基于 Q 学习的深度强化学习框架示意^[24]
 Fig. 5 Applications of deep learning in additive process optimization: (a, b) Schematic diagrams of the framework for deep reinforcement learning^[23]; (c) Schematic diagram of a deep reinforcement learning framework based on Q-learning^[24]

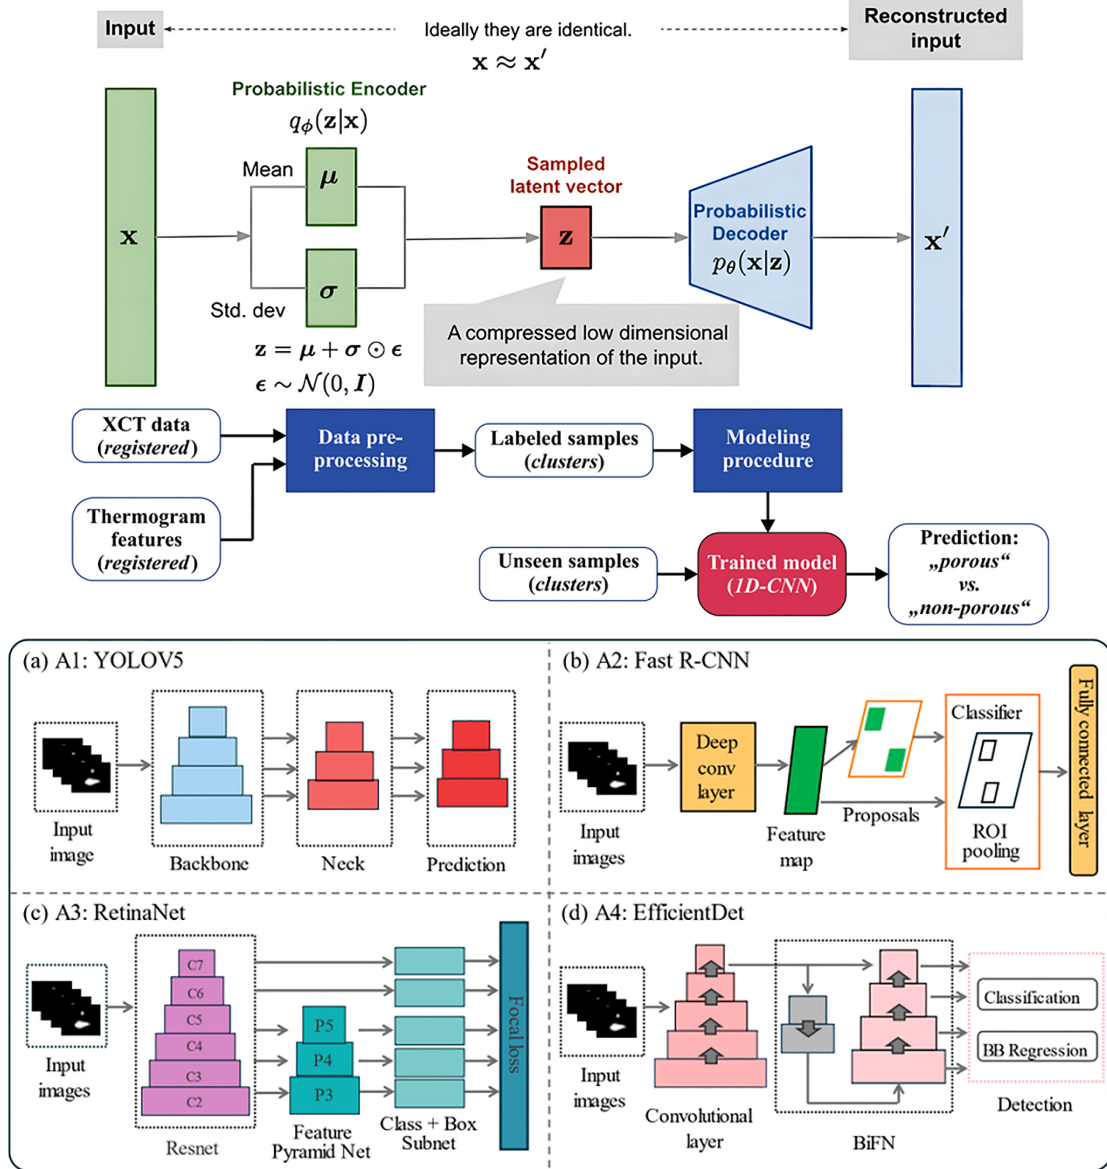


图6 深度学习在增材缺陷预测中的应用: (a)变分自动编码器的框架示意^[25]; (b)局部孔隙度的聚类预测深度学习框架示意^[26]; (c)四种深度学习算法的示意^[27]

Fig. 6 Applications of deep learning in additive defect prediction: (a) Schematic diagram of the framework of the variational autoencoder^[25]; (b) Schematic diagram of the deep learning framework for clustering prediction of local porosity^[26]; (c) Schematic diagrams of four deep learning algorithms^[27]

学习技术在基于声发射特征的LPBF工艺在线监测中的应用迈出了第一步;针对熔池的光学信号, Oster等人^[26]基于熔池的短波红外热成像数据,构建了能够通过热历史重建实现局部孔隙预测的深度学习框架,其预测准确率高达96%;针对熔池的飞溅信号而言, Du等人^[27]利用高速摄像技术记录熔池的动态,并采用不同的深度学习算法提取飞溅与熔池状态间的特征信息,最终揭示了熔池稳定性对飞溅

形成的影响及其与飞溅初速度的关联性。这些工作利用深度学习框架从不同的角度探究了熔池的特征行为与缺陷形成之间的映射关系,为金属增材的在线缺陷预测提供了极具价值的思路。

增材制造中的工艺参数、微观结构与最终性能间的复杂关系,即过程-结构-性能(Process Structure Property, PSP)关系,历来是最难以理解的,这是因为增材构件的微观结构(决定了其性能)对加工

参数、构建方向和后处理高度敏感,通常需要费时费力的实验进行验证。深度学习在P-S-P关系构建中的应用研究如图7所示。为了构建高效的PSP关联与性能预测方法,Gan等人^[28]结合小波变换与卷积神经网络,开发了一款融合多尺度数据的深度学习框架,通过对工艺过程中热历史数据的学习,实现了对零件位置强依赖的局部力学性能的快速精准预测。针对疲劳性能优化,Luo等人^[29]利用基于dropout的神经网络构建了LPBF工艺下Ti-6Al-4V合金构件的表面粗糙度及孔隙特征与疲劳寿命之间的关联模型,并展示出>93%的良好预测精度。在微观结构-性能的关联方面,Harrison等人^[30]利用大量晶体塑性有限元模型(Crystal Plasticity Finite Element, CPFE)的计算数据训练深度神经网络,将计算时间从CPFE的13 h大幅缩短至代理模型的1.27 s,使得能够对与增材制造多相不锈钢的相区域及晶体取向密切相关的拉伸应力-应变曲线进行即

时预测,预测准确率高达91%。Zhang等人^[31]则直接利用零件的金相光学图像开发了一种全新的金相学-性能关系神经网络(Metallography-Property Relationship Neural Network, MPR-Net),直接基于光学金相图像对316L不锈钢的拉伸强度和维氏硬度的预测准确度(R^2)分别为0.96和0.91,实现了低成本与极简实验的力学性能创新预测。通过目标性能逆向进行初始结构的快速设计一直以来是广大设计人员所追求的终极目标,Zou等人^[32]针对此难题将深度学习前向预测与遗传算法逆向搜索相结合,以应力-应变的有限元计算数据为模型训练集,实现了Ti-6Al-4V合金在较大设计空间内与不同屈服强度/弹性模量相对应的结构定制,为定制化的性能-结构设计提供了一条切实可行的路径。

总的来说,相比传统的机器学习模型而言,深度学习神经网络代理模型能够处理复杂的非线性关系,提升制造效率和预测精度,但其也存在一定

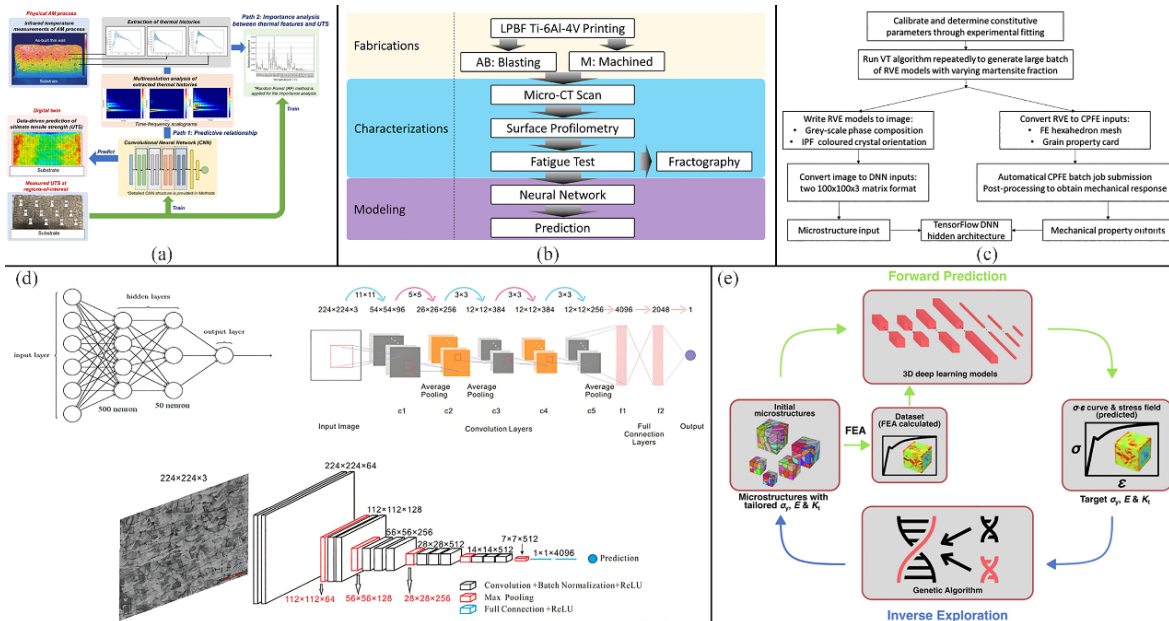


图7 深度学习在过程-结构-性能(P-S-P)关系构建中的应用:(a)基于小波变换和卷积神经网络的多尺度数据驱动框架的示意^[28];(b)基于 dropout 神经网络的深度学习模型对增材构件的表面粗糙度及孔隙特征与疲劳寿命之间的关联的研究过程^[29];(c)晶体塑性有限元-深度学习模型的集成架构示意^[30];(d)基于金相学-性能关系的神经网络架构示意^[31];(e)逆微观结构优化的框架示意^[32]。

Fig. 7 Applications of deep learning in the construction of process-structure-performance (P-S-P) relationship: (a) Schematic diagram of a multi-scale data-driven framework based on wavelet transform and convolutional neural networks^[28]; (b) The research process of the deep learning model based on dropout neural network on the correlation between the surface roughness, pore characteristics and fatigue life of additive components^[29]; (c) Schematic diagram of the integrated architecture of the crystal plasticity finite element - deep learning model^[30]; (d) Schematic diagram of the neural network architecture based on the metallography-performance relationship^[31]; (e) Schematic diagram of the framework for inverse microstructure optimization^[32]

的局限性,如依赖大量标注数据、模型的可解释性较弱、极端工艺条件下的泛化能力局限,特别的对于增材熔池过程的跨尺度问题,依靠由纯数据驱动的AI模型是难以进行高保真的模拟和预测的。

1.3 基于物理信息约束神经网络方法的应用

为了克服纯数据驱动模型(包括机器学习模型和深度学习模型)的固有缺陷,如对海量数据的依赖、泛化能力差和“黑箱”特性,物理信息约束的神经网络方法(Physics-Informed Neural Networks, PINN)应运而生。PINN 介于纯数据驱动和纯物理

仿真的方法之间,其核心创新在于将物理定律(通常由偏微分方程描述)作为软约束或正则化项,直接融入神经网络的损失函数中,这意味着神经网络在训练时不仅要最小化其预测值与训练数据之间的误差,还必须最小化其预测结果在求解域内对物理方程的残差。这种混合方法确保模型遵循物理定律,并准确反映真实增材制造过程中遇到的自然变化,使得物理信息约束的机器学习方法在金属增材制造中得以成功应用。PINN在金属增材熔池温度场预测中的应用研究如图8所示。Zhu^[33]、Xie^[34]、

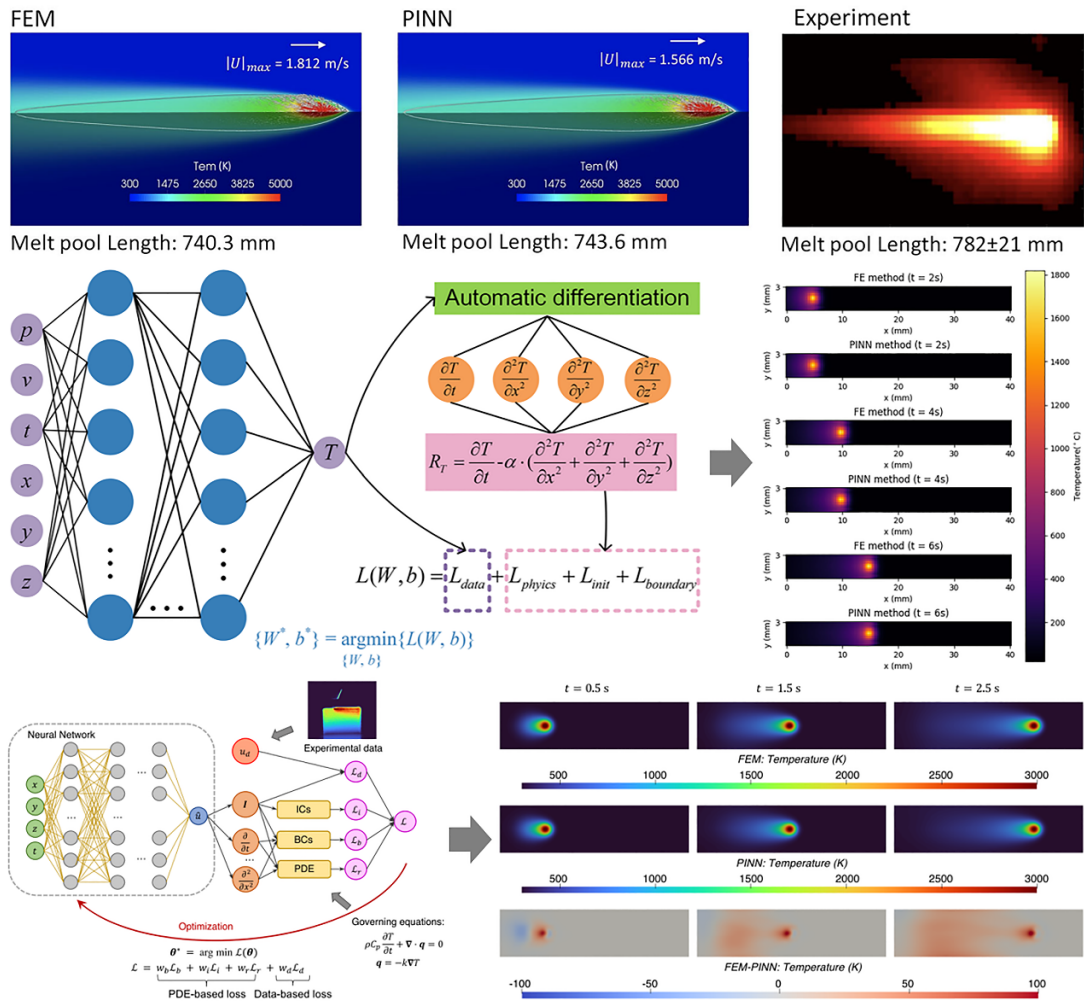


图8 物理信息神经网络(PINN)在金属增材熔池温度场预测中的应用:(a)有限元预测、PINN对增材温度和熔池流体动力学的预测结果与实验结果的对比^[33];(b)用于预测增材定向能沉积温度场的PINN模型示意图及PINN方法与有限元法对温度场的预测结果对比^[34];(c)基于有限元模拟与训练后的PINN模型对熔池温度场的预测结果对比^[35]

Fig. 8 Applications of physical information neural network (PINN) in predicting the temperature field of metal additive molten pools: (a) Comparison of the finite element prediction, PINN's prediction results for additive temperature and molten pool fluid dynamics with the experimental results^[33]; (b) Schematic diagram of the PINN model for predicting the temperature field of additive directed energy deposition and comparison of the prediction results of the temperature field by the PINN method and the finite element method^[34]; (c) Comparison of the prediction results of the molten pool temperature field based on finite element simulation and the trained PINN model^[35]

Liao^[35] 等人在基于物理机理约束嵌入神经网络的方法上做了大量的研究, 通过将第一性物理原理(动量、质量、能量守恒定律)、热传导方程、等物理约束融合到神经网络的损失函数当中, 实现了仅在少量标记数据下(~20% 数据量, 相较于纯数据驱动模型)的熔池温度场与动力学行为的准确预测(准确率>90%), 并且混合模型具备较好的泛化能力, 可复用至不同金属材料的打印过程中。

针对金属增材过程中典型缺陷的分类预测(见图 9), Zhang^[36]、Guo^[37]、Tian^[38]、DebRoy^[39] 等人通过融合工艺物理参量、热成像实测与物理仿真数据, 实现了较高准确率下对孔隙率的分类预测(误差约 10%~26%, 部分模型接近 100% 准确率)以及球化、微裂纹、未融合、孔隙、表面粗糙度等多种缺陷的有效识别与减少, 为工艺质量的控制与优化提供了可靠手段。

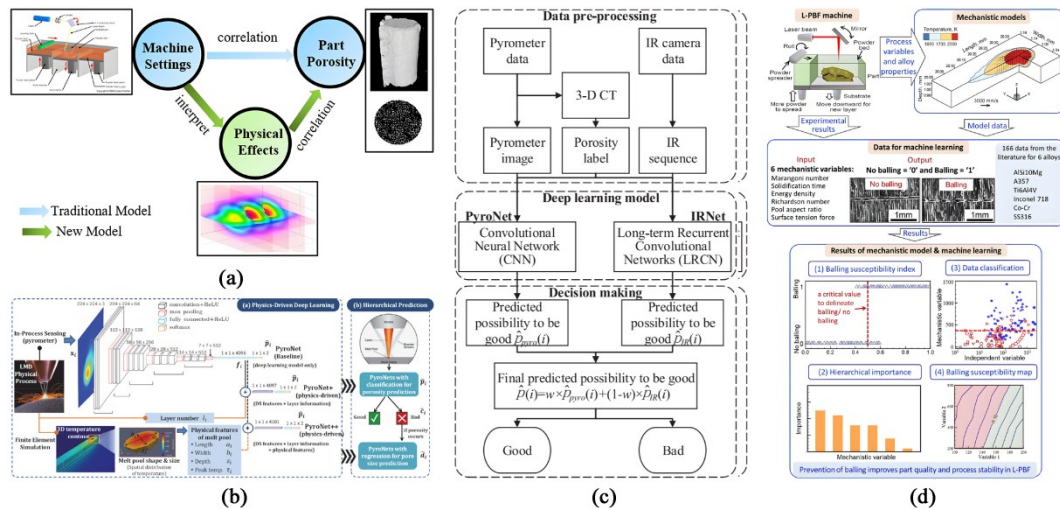


图 9 物理信息神经网络(PINN)在金属增材缺陷预测中的应用:(a)一种新的物理信息数据驱动的神经网络模型示意^[36];(b,c)基于激光-金属材料相互作用的物理效应的 PINN 架构示意^[37,38];(d)基于 PINN、物理机理建模和实验数据相结合的混合模型进行增材缺陷预测的示意^[39]

Fig. 9 Applications of physical information neural network (PINN) in defect prediction of metal additive manufacturing: (a) Schematic diagram of a new neural network model driven by physical information data^[36]; (b, c) Schematic diagrams of the PINN architecture based on the physical effects of laser-metal material interaction^[37, 38]; (d) Schematic diagram of additive defect prediction based on a hybrid model combining PINN, physical mechanism modeling and experimental data^[39]

最近, 一种名为傅里叶物理信息神经算子(Fourier Physics-Informed Neural Operators, FPINO)的新方法被提出^[40-42], 作为物理信息神经网络结构的一个高级变体, 傅里叶物理信息神经算子凭借傅里叶变换能够高效的处理频率分量, 且能够容纳各种输入参数(如工艺参数、材料属性、打印条件等), 从而有效地捕捉和表征增材制造过程中从微观尺度热传递到宏观尺度力学性能的广泛信息, 这对于解决金属增材中超快热力学过程至关重要。如图 10 所示。

相较于单纯数据驱动的机器学习和深度学习代理模型而言, 融入物理机理约束的深度学习模型有效提升了金属增材制造过程预测的准确性、可靠性和物理可解释性, 并显著降低了对大量昂贵实验

数据的依赖。其优势在于能够以比传统数值模拟更快的计算速度, 实现对温度场、熔池动力学乃至力学性能的精准预测和“首件即合格件”的智能优化潜力。然而, 该模型在处理多物理场强耦合的复杂问题时, 存在着面临不同物理损失梯度不平衡导致的训练收敛困难、高维参数空间易陷入局部最优, 以及模型构建严重依赖对物理机理的准确数学描述等挑战, 仍然需要不断地优化和发展新的技术以应对增材数字孪生日益紧迫的需求。

2 当下挑战与未来展望

尽管基于数据驱动和物理机理约束的 AI 代理模型在金属增材制造领域展现出了巨大的潜力和

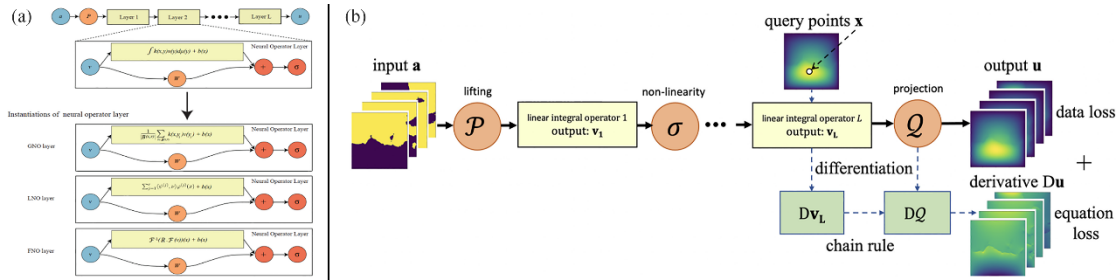


图 10 (a) 傅里叶物理信息神经算子 (FPINO) 模型的架构示意^[40]; (b) 同时使用训练数据和偏微分方程损失函数来训练神经算子的 FPINO 示意^[41]

Fig. 10 (a) Diagram of the architecture of the fourier physical information neural operator (FPINO) model^[40]; (b) A schematic diagram of FPINO for training neural operators using both training data and the loss function of partial differential equations simultaneously^[41]

广阔的应用前景,但在其发展和实际应用的过程中仍面临诸多挑战,但同时也催生了新的研究方向和机遇。深入理解这些挑战并积极探索应对策略,对于推动该技术的成熟和产业化具有深远的意义。

2.1 融合人工智能技术后的独有挑战

对于金属增材与 AI 模型相融合的技术前沿,本研究认为目前主要面临着三大挑战:

(1)数据成本高昂。金属增材,尤其是激光粉末床熔融工艺,其单次实验成本极高(涉及设备、材料、后处理与检测),且过程不可逆。获取包含“工艺参数—熔池动态—最终缺陷/性能”的完整数据需要耗费大量人力与物力,导致高质量、标记清晰的数据库规模极小,难以支撑数据驱动的深度模型。

(2)瞬态多物理场“灰箱”机制。激光与金属粉末的相互作用,在微秒时间尺度和微米空间尺度内,涉及高温熔化、剧烈流动、快速凝固、相变乃至金属蒸气反冲等强耦合物理现象,要实现对这些现象的准确描述,其基础是对其中相互作用的机理有深入理解。

(3)毫秒级实时控制。增材技术发展的最终目标是借助人工智能与数字孪生技术进行打印过程的实时优化调控,实现复杂构件一次打印成功。然而熔池的动态变化极快,有效的工艺调控窗口仅在毫秒量级,这要求从传感信号输入、到模型推理、再到控制信号输出的全链路延迟必须极低,传统的云计算或基于大型神经网络的推理均无法满足。

2.2 应对策略及展望

针对上述三大挑战,本研究给出了几个可能的破局方向:

(1)仿真与试验相结合构建合成数据。针对实

验数据获取成本高昂的问题,可以考虑以实验数据定方向-仿真数据定轨迹的思路,即:在全参数空间选取关键实验点获得代表整个试验走向的物理真实数据,然后利用经过关键实验标定的数值仿真模型进行仿真计算,获得内藏具体试验轨迹的仿真虚拟数据,最后以真实数据训练模型去约束预测方向,以虚拟数据训练模型去锚定精确预测位置。

(2)“机理-数据”混合的“灰箱”模型。熔池的动态过程看不见、复杂算不准、强耦合分不开,其应对策略的核心思想并非寻求单一的“终极理论”,而是构建一套“增强观测、混合认知、高效探索”的融合方法论体系。在多维度试验观测的基础上,利用神经网络充当“机理补丁”:即在已知的物理方程框架(如热传导方程)中,让小型神经网络去表示方程中难以理论确定的关键项(如材料动态属性、蒸发引起的热损失项等)。

(3)“快速-慢速”双环控制。轻量化模型构成的内环负责毫秒级的熔池稳定性维持(如抑制飞溅),基于更全面模型的外环负责秒-分钟级的层间工艺参数优化(如针对热积累调整功率)。

这些策略的本质仍是推动增材制造从“经验试错”向“数字智能”范式的根本性转变,其成功不依赖于单一技术的突破,而在于构建一个数据生成与利用闭环、物理与智能模型深度融合、算法与硬件协同优化的完整技术生态。

3 结论

金属增材制造技术,凭借其无与伦比的设计自由度和快速制造复杂结构的能力,正在深刻地变革

着从航空航天到生物医疗等众多关键产业的面貌。然而,要充分释放其全部潜力,实现从“能制造”到“高质量、高效率、智能化制造”的跨越,就必须克服其在工艺复杂性、质量一致性和设计优化效率方面所面临的固有挑战。本综述系统地阐述了基于数据驱动和物理机理约束的人工智能代理模型如何作为一种强大的赋能技术,为应对这些挑战提供了革命性的解决方案,通过对现有研究的深入分析,我们可以清晰地看到,AI的赋能正在引领金属增材制造迈向一个全新的智能范式。

然而,正如本综述所深入探讨的,这条通往智能化的道路并非一帆风顺。数据层面的稀缺性、熔池机理层面的难理解性、“黑箱模型”的不可解释性、动态部署的困难性等挑战,都是当前亟待解决的关键瓶颈问题。展望未来,AI赋能在金属增材制造中的应用将更加深入和广泛。它不仅仅是提升现有流程效率的工具,更是催生全新设计理念、制造范式和商业模式的关键驱动力,必将引领我们迈向一个更加高效、更加精准、更加可持续的智能制造新纪元。

参考文献:

- [1] FRAZIER W E. Metal Additive Manufacturing: A Review [J]. *Journal of Materials Engineering & Performance*, 2014, 23(6): 1917–1928.
- [2] DONCHEVA E, PETRESKI M, ZDRAVESKI F. Metal additive manufacturing with topology optimization methodology for innovative structural design [C]//19th International Scientific Conference on Industrial Systems, 2023: 100–105.
- [3] KRUTH J P, MERCELIS P, VAN VAERENBERGH J, et al. Binding mechanisms in selective laser sintering and selective laser melting [J]. *Rapid Prototyping Journal*, 2005, 11(1): 26–36.
- [4] DEBROY T, MUKHERJEE T, WEI H L, et al. Metallurgy, mechanistic models and machine learning in metal printing [J]. *Nature Reviews Materials*, 2021, 6(1): 48–68.
- [5] WANG J, PAPADOPOULOS P. Finite element analysis enabled optimization of process parameters in additive manufacturing [J]. *Finite Elements in Analysis and Design*, 2025, 244: 104282.
- [6] SIMPSON T W, POPLINSKI J D, KOCH P N, et al. Metamodels for computer-based engineering design: survey and recommendations [J]. *Engineering with Computers*, 2001, 17(2): 129–150.
- [7] BURGESS J C. A tutorial on support vector machines for pattern recognition [J]. *Data Mining and Knowledge Discovery*, 1998, 2(2): 121–167.
- [8] RODRIGUEZ-GALIANO V F, GHIMIRE B, ROGAN J, et al. An assessment of the effectiveness of a random forest classifier for land-cover classification [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2012, 67: 93–104.
- [9] ZHU Z, ANWER N, HUANG Q, et al. Machine learning in tolerancing for additive manufacturing [J]. *CIRP Annals*, 2018, 67(1): 157–160.
- [10] BATURYNSKA I, MARTINSEN K. Prediction of geometry deviations in additive manufactured parts: comparison of linear regression with machine learning algorithms [J]. *Journal of Intelligent Manufacturing*, 2020, 32(1): 179–200.
- [11] PAULSON N H, GOULD B, WOLFF S J, et al. Correlations between thermal history and keyhole porosity in laser powder bed fusion [J]. *Additive Manufacturing*, 2020, 34: 101213.
- [12] GAIKWAD A, YAVARI R, MONTAZERI M, et al. Toward the digital twin of additive manufacturing: integrating thermal simulations, sensing, and analytics to detect process faults [J]. *IIEE Transactions*, 2020, 52(11): 1204–1217.
- [13] KUSANO M, MIYAZAKI S, WATANABE M, et al. Tensile properties prediction by multiple linear regression analysis for selective laser melted and post heat-treated Ti-6Al-4V with microstructural quantification [J]. *Materials Science and Engineering*, 2020, 787: 139549.
- [14] MAO Y, HE Q, ZHAO X. Designing complex architected materials with generative adversarial networks [J]. *Science Advances*, 2020, 6(17): 4169.
- [15] PAHLAVANI H, TSIFOUTIS-KAZOLIS K, SALDIVAR M C, et al. Deep learning for size-agnostic inverse design of random-network 3D printed mechanical metamaterials [J]. *Advanced Materials*, 2024, 36(6): 2303481.
- [16] SUI F, GUO R, ZHANG Z, et al. Deep reinforcement learning for digital materials design [J]. *ACS Materials Letters*, 2021, 3(10): 1433–1439.
- [17] SUN X, YUE L, YU L, et al. Machine learning evolutionary algorithm enabled design for 4D-printed active

- composite structures [J]. *Advanced Functional Materials*, 2022, 32(10):2109805.
- [18] PAHLAVANI H, AMANI M, SALDÍVAR M C, et al. Deep learning for the rare-event rational design of 3D printed multi-material mechanical metamaterials [J]. *Communications Materials*, 2022, 3(1):46.
- [19] XUE T, WALLIN T J, MENGUC Y, et al. Machine learning generative models for automatic design of multi-material 3D printed composite solids [J]. *Extreme Mechanics Letters*, 2020, 41:100992.
- [20] GOH G D, SING S L, LIM Y F, et al. Machine learning for 3D printed multi-materials tissue-mimicking anatomical models [J]. *Materials & Design*, 2021, 211:110125.
- [21] WANG R, STANDFIELD B, DOU C, et al. Real-time process monitoring and closed-loop control on laser power via a customized laser powder bed fusion platform [J]. *Additive Manufacturing*, 2023, 66:103449.
- [22] ALMASRI W, BETTEBGHOR D, ABABSA F, et al. Deep learning architecture for topological optimized mechanical design generation with complex shape criterion [C]//*Advances and Trends in Artificial Intelligence. Artificial Intelligence Practices*, 2021:222-234.
- [23] OGOKE F, FARIMANI A B. Thermal control of laser powder bed fusion using deep reinforcement learning [J]. *Additive Manufacturing*, 2021, 46:102033.
- [24] DHARMADHIKARI S, MENON N, BASAK A. A reinforcement learning approach for process parameter optimization in additive manufacturing [J]. *Additive Manufacturing*, 2023, 71:103556.
- [25] GHAYOONI MOHAMMADI M, MAHMOUD D, ELBESTAWI M. On the application of machine learning for defect detection in L-PBF additive manufacturing [J]. *Optics & Laser Technology*, 2021, 143:107338.
- [26] OSTER S, BREESE P P, ULBRICHT A, et al. A deep learning framework for defect prediction based on thermographic in-situ monitoring in laser powder bed fusion [J]. *Journal of Intelligent Manufacturing*, 2023, 35(4):1687-1706.
- [27] GADDE D, ELWANY A, DU Y. Deep learning to analyze spatter and melt pool behavior during additive manufacturing [J]. *Metals*, 2025, 15(8):840.
- [28] XIE X, BENNETT J, SAHA S, et al. Mechanistic data-driven prediction of as-built mechanical properties in metal additive manufacturing [J]. *npj Computational Materials*, 2021, 7(1):86.
- [29] MOON S, MA R, ATTARDO R, et al. Impact of surface and pore characteristics on fatigue life of laser powder bed fusion Ti-6Al-4V alloy described by neural network models [J]. *Scientific Reports*, 2021, 11(1):20424.
- [30] TU Y, LIU Z, CARNEIRO L, et al. Towards an instant structure-property prediction quality control tool for additive manufactured steel using a crystal plasticity trained deep learning surrogate [J]. *Materials & Design*, 2022, 213:110345.
- [31] ZHANG Z, MATIVENGA P, ZHANG W, et al. Deep learning-driven prediction of mechanical properties of 316L stainless steel metallographic by laser powder bed fusion [J]. *Micromachines*, 2024, 15(9):1167.
- [32] SHANG X, LIU Z, ZHANG J, et al. Tailoring the mechanical properties of 3D microstructures: a deep learning and genetic algorithm inverse optimization framework [J]. *Materials Today*, 2023, 70:71-81.
- [33] ZHU Q, LIU Z, YAN J. Machine learning for metal additive manufacturing: predicting temperature and melt pool fluid dynamics using physics-informed neural networks [J]. *Computational Mechanics*, 2021, 67(2):619-635.
- [34] XIE J, CHAI Z, XU L, et al. 3D temperature field prediction in direct energy deposition of metals using physics informed neural network [J]. *The International Journal of Advanced Manufacturing Technology*, 2022, 119(5-6):3449-3468.
- [35] LIAO S, XUE T, JEONG J, et al. Hybrid thermal modeling of additive manufacturing processes using physics informed neural networks for temperature prediction and parameter identification [J]. *Computational Mechanics*, 2023, 72(3):499-512.
- [36] LIU R, LIU S, ZHANG X. A physics-informed machine learning model for porosity analysis in laser powder bed fusion additive manufacturing [J]. *The International Journal of Advanced Manufacturing Technology*, 2021, 113(7-8):1943-1958.
- [37] GUO W G, TIAN Q, GUO S, 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*, 2020, 69(1):205-208.
- [38] TIAN Q, GUO S, MELDER E, et al. Deep learning-based data fusion method for in situ porosity detection in laser-based additive manufacturing [J]. *Journal of*