

## 基于机器学习的增材制造合金材料力学性能预测研究进展与挑战

胡雅楠, 余欢, 吴圣川, 奥妮, 阚前华, 吴正凯, 康国政

### MACHINE LEARNED MECHANICAL PROPERTIES PREDICTION OF ADDITIVELY MANUFACTURED METALLIC ALLOYS: PROGRESS AND CHALLENGES

Hu Yanan, Yu Huan, Wu Shengchuan, Ao Ni, Kan Qianhua, Wu Zhengkai, and Kang Guozheng

在线阅读 View online: <https://doi.org/10.6052/0459-1879-23-542>

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 金属增材制造中的缺陷、组织形貌和成形材料力学性能

DEFECTS, MICROSTRUCTURES AND MECHANICAL PROPERTIES OF MATERIALS FABRICATED BY METAL ADDITIVE MANUFACTURING

力学学报. 2021, 53(12): 3190-3205

#### 增材制造微结构演化及疲劳分散性计算

COMPUTATIONAL STUDY OF EVOLUTION AND FATIGUE DISPERSITY OF MICROSTRUCTURES BY ADDITIVE MANUFACTURING

力学学报. 2021, 53(12): 3263-3273

#### 数据驱动印度洋海域全局动力学研究

DATA-DRIVEN GLOBAL DYNAMICS OF THE INDIAN OCEAN

力学学报. 2021, 53(9): 2595-2602

#### 增材制造316钢高周疲劳性能的微观力学研究

MICROMECHANICAL STUDY OF THE HIGH CYCLE FATIGUE PROPERTY OF ADDITIVE-MANUFACTURED 316 STEEL

力学学报. 2021, 53(12): 3181-3189

#### 基于数据驱动的流场控制方程的稀疏识别

DATA-DRIVEN SPARSE IDENTIFICATION OF GOVERNING EQUATIONS FOR FLUID DYNAMICS

力学学报. 2021, 53(6): 1543-1551

#### 平纹机织碳纤维复合材料的尺度随机力学性能预测研究

RESEARCH ON MULTISCALE STOCHASTIC MECHANICAL PROPERTIES PREDICTION OF PLAIN WOVEN CARBON FIBER COMPOSITES

力学学报. 2020, 52(3): 763-773



关注微信公众号, 获得更多资讯信息

# 基于机器学习的增材制造合金材料力学性能预测研究进展与挑战<sup>1)</sup>

胡雅楠\* 余欢\* 吴圣川<sup>†,2)</sup> 奥妮<sup>†</sup> 阚前华\* 吴正凯<sup>†</sup> 康国政<sup>\*,3)</sup>

\* (西南交通大学力学与航空航天学院, 成都 611756)

<sup>†</sup> (西南交通大学轨道交通运载系统全国重点实验室, 成都 610031)

**摘要** 增材制造是现代高端装备制造领域的革命性突破技术之一。其中, 增材构件的大批量生产和高可靠应用, 关键在于制造可重复性、质量可靠性与性能可预测性。而在各向异性组织、广域分布缺陷、深部残余应力和复杂表面粗糙度等诸多因素的共同影响下, 基于传统经验模型和有限数据的增材制造金属力学性能预测效率与准确性面临着严峻挑战。近年来, 作为大数据与人工智能发展到一定阶段的必然产物, 机器学习 (machine learning, ML) 方法为有效处理高维物理量之间的复杂非线性关系提供了契机, 在增材制造合金材料力学性能预测领域得到持续关注。文章综述了机器学习在增材制造材料及构件力学性能预测中的国内外研究进展。首先简述了常见的机器学习算法和通用的机器学习流程, 重点分析了融合物理信息的机器学习 (physics-informed machine learning, PIML) 方法的特点与构造方式; 然后概述了增材制造合金材料力学性能 4 大影响因素的形成原因及机器学习在这些影响因素预测中的应用现状; 重点介绍了 ML 和 PIML 在拉伸性能和疲劳断裂性能预测中的代表性研究成果; 最后指出当前机器学习在力学性能预测中的局限性, 并探讨了发展趋势和技术前景。

**关键词** 数据驱动, 机理驱动, 微观组织, 缺陷演化, 疲劳寿命

中图分类号: TG405 文献标识码: A doi: 10.6052/0459-1879-23-542

## MACHINE LEARNED MECHANICAL PROPERTIES PREDICTION OF ADDITIVELY MANUFACTURED METALLIC ALLOYS: PROGRESS AND CHALLENGES<sup>1)</sup>

Hu Yanan\* Yu Huan\* Wu Shengchuan<sup>†,2)</sup> Ao Ni<sup>†</sup> Kan Qianhua\* Wu Zhengkai<sup>†</sup> Kang Guozheng<sup>\*,3)</sup>

\* (School of Mechanics and Aerospace Engineering, Southwest Jiaotong University, Chengdu 611756, China)

<sup>†</sup> (State Key Laboratory of Rail Transit Vehicle System, Southwest Jiaotong University, Chengdu 610031, China)

**Abstract** Additive manufacturing (AM) is a revolutionary breakthrough in the manufacturing of modern high-end equipment. In order to promote the mass production and reliable applications of AM-processed components, the major determining factors include manufacturing repeatability, quality reliability, and performance predictability. However, the combined effects of anisotropic microstructure, randomly distributed defects, internal residual stresses, and surface

2023-11-15 收稿, 2024-01-29 录用, 2024-01-30 网络版发表。

1) 国家自然科学基金 (12202369) 和四川省自然科学基金 (2023NSFSC1303) 资助项目。

2) 通讯作者: 吴圣川, 研究员, 主要研究方向为结构内部损伤跨尺度原位实验、表征及评价。E-mail: wusc@swjtu.edu.cn

3) 通讯作者: 康国政, 教授, 主要研究方向为材料本构关系、疲劳与断裂。E-mail: guozhengkang@swjtu.edu.cn

引用格式: 胡雅楠, 余欢, 吴圣川, 奥妮, 阚前华, 吴正凯, 康国政. 基于机器学习的增材制造合金材料力学性能预测研究进展与挑战. 力学学报, 2024, 56(7): 1892-1915

Hu Yanan, Yu Huan, Wu Shengchuan, Ao Ni, Kan Qianhua, Wu Zhengkai, Kang Guozheng. Machine learned mechanical properties prediction of additively manufactured metallic alloys: progress and challenges. *Chinese Journal of Theoretical and Applied Mechanics*, 2024, 56(7): 1892-1915

roughness pose a challenge for the prediction accuracy and efficiency of mechanical properties through traditional empirical models and limited testing data. Recently, as an inevitable product of the development of big data and artificial intelligence to a certain stage, machine learning (ML) has demonstrated a great potential for modelling the complex nonlinear relationships among high-dimensional physical quantities, which has received continuous attention in the field of predicting the mechanical properties of AM-processed materials. This paper offers a comprehensive review of the research progress in predicting the mechanical properties of AM-processed metals and components using ML methods. First, the common ML algorithms (parametric and non-parametric models) and general ML procedures (data preparation, model establishment, and model application and evaluation) are briefly introduced. Special attention is devoted to exploring the characteristics and construction methods of the advanced physics-informed machine learning (PIML), with specific discussions on the physics-informed model input, construction and output. Furthermore, the reasons for the formation of the four major influencing factors on the mechanical properties of AM-processed materials (anisotropic microstructure, manufacturing defects, residual stresses, and surface roughness), and the current application status of ML in predicting these influencing factors are summarized. This paper focuses on the representative research results of ML and PIML in predicting the tensile and fatigue fracture properties of AM-processed metals. Finally, the limitations of ML in predicting the mechanical properties of AM-processed metals, as well as the hot topics and technological prospects, are pointed out.

**Key words** data-driven, physics-informed, microstructure, defect evolution, fatigue life


## 引言

增材制造 (additive manufacturing, AM) 是一种基于“数字建模、分层制造和逐层叠加”理念,以粉末、丝材和块材为原材料,以激光束、电子束、等离子体、电弧及其组合为热源,逐层熔化堆积成“近净成形”结构的先进制造技术<sup>[1-2]</sup>。以原材料的种类和材料的堆积方式为分类依据,国际标准化组织 (International Organization for Standardization, ISO) 和美国材料与试验协会 (American Society for Testing and Materials, ASTM) 在 ISO/ASTM 52900 标准中定义了 7 种增材制造工艺。而针对金属材料,目前最常用的制造技术为粉末床熔融 (powder bed fusion, PBF) 和定向能量沉积 (direct energy deposition, DED)。

与传统的等材和减材制造相比,增材制造具有材料利用率高、设计自由度高、生产周期短、制造成本低和能量消耗少等优点,是现代装备制造技术的一次革命性突破<sup>[3-4]</sup>。经过近 40 年的发展,增材制造在航空航天、生物医学、汽车工业和轨道交通等领域展示出了巨大的发展和应用潜力<sup>[5-6]</sup>,已成为世界先进制造领域发展最快、技术研究最活跃和关注度最高的学科方向之一,得到了美国、欧洲及中国等工业大国在战略层面上的高度重视与大力支持,出台了众多发展战略规划。

为了推动增材构件大批量生产、高可靠应用及从功能件拓展至主承力件,关键在于制造可重复性、质量可靠性和性能可预测性等方面。而增材构件从最初的结构设计至最终的工程应用往往历经多个环节,如图 1 所示,且每个环节又涉及众多影响因素,这种多流程和复杂性无疑加剧了分析的难度<sup>[7]</sup>。目前,部件设计、增材制造和后处理均已完成了质量认证与标准化,而用于性能评价与工程应用的标准规范亟待补充和加强。一些研究指出,增材构件的静态或准静态服役强度与传统的锻件和铸件相当,而疲劳强度较低,疲劳寿命呈现出极大的离散性,这为其疲劳性能的可靠评估和准确预测及应用带来极大挑战<sup>[8-9]</sup>。因此,为了保障增材构件的长效服役可靠性与安全性,阐明工艺参数-微观变形机制-损伤演化机理-服役性能的关联机制,进而准确地预测疲劳断裂性能是关键,这也是制订增材构件疲劳评价标准规范的重要前提。

与传统的铸造、锻造和焊接技术制造的构件相比,增材构件具有 4 大技术特征:多层、跨尺度、异质的微观组织,广域随机分布的内部缺陷,深部的残余应力及复杂的表面形貌,这也是公认的影响增材构件疲劳性能的 4 要素<sup>[10-11]</sup>。而上述影响因素与制造工艺密切相关,因此,除了明确影响因素与力学性能之间的关联机制,建立影响因素-力学性能关联关系外,从前端工艺角度出发,建立工艺参数-力学性

图1 增材制造从部件设计至工程应用的多个环节<sup>[5]</sup>Fig. 1 Multiple links in AM from component design to engineering application<sup>[5]</sup>


能关系或者工艺参数-影响因素-力学性能关系也是当前增材构件力学性能预测的重要方向<sup>[12]</sup>。然而,传统研究倾向于基于实验分析、理论建模和数值求解等方法构建力学性能预测模型,而这些方法在深入挖掘多因素耦合且机理错综复杂的金属增材制造工艺参数-影响因素-力学性能的关联关系方面仍存在着很大的局限性,导致宏观力学性能预测的精度和效率难以满足要求。

作为科学发展第4阶段-数据驱动科学的典型代表,机器学习(machine learning, ML)为有效处理高维物理数据之间的复杂非线性关系提供了契机,近年来在金属增材制造性能评价中得到广泛应用。

例如,以“additive manufacturing”和“machine learning”为关键词,在Web of Science数据库中,共检索到学术论文600余篇(截至2022年12月)。图2所示为2011—2022年间增材制造机器学习领域研究论文的发表情况。近4年的论文发表量呈近指数式激增。这表明,当今各领域对于增材制造技术的关注度日益增加,并成为各科技强国重点关注的学科方向之一。具体来看,机器学习方法在增材制造材料及构件中的应用主要集中在材料/结构设计、质量控制、缺陷监测与检测、工艺参数优化和力学性能预测等诸多方面<sup>[13-15]</sup>。


机器学习是关于计算机基于数据构建概率统计模型,并运用模型对数据进行预测与分析的一门学科。最初机器学习是基于数据驱动的,即在物理机制未知的前提下从大量数据中挖掘隐含规律<sup>[16-20]</sup>。而这类以数据驱动的机器学习由于缺乏相关的物理约束,导致模型的可解释性差,即通常所说的“黑箱”模型。为了提高机器学习模型的可解释性、透明度和分析能力,近年来,一种融合物理信息的机理驱动的机器学习方法(physics-informed machine learning, PIML)引起了广泛关注<sup>[21]</sup>。

本文围绕基于机器学习的金属增材制造力学性



(a) 论文发表

(a) Academic paper publication



(b) 研究领域

(b) Research field

图2 机器学习在增材制造领域的研究与应用

Fig. 2 Research and application of machine learning in AM



能预测的重要课题, 首先介绍了常见的机器学习算法和通用的机器学习流程, 其中重点阐述了机理驱动的机器学习方法的特点与构造方式. 然后强调了增材制造合金材料力学性能 4 大影响因素的形成原因和机器学习在这些影响因素预测中的应用现状. 重点讨论了 ML 和 PIML 在拉伸性能和疲劳断裂性能预测中的代表性研究成果. 最后展望了发展趋势和应用前景, 指出了当前机器学习在金属增材制造力学性能预测中的局限性或挑战.

## 1 机器学习模型及流程概述

### 1.1 机器学习模型分类

机器学习是一门新兴的多领域交叉学科, 涉及概率论、统计学、信息论、计算理论、最优化理论和计算机科学等, 是大数据和人工智能发展到一定阶段的必然产物. 对机器学习的基本分类为监督学习、无监督学习、半监督学习和强化学习. 其中, 监督学习在增材制造合金材料力学性能预测方面具有广泛的应用, 后文重点介绍监督学习.

监督学习是指从标注数据中学习预测模型的机器学习问题. 标注数据表示输入与输出的对应关系, 预测模型对给定的输入产生相应的输出. 监督学习的本质是学习输入到输出映射的统计规律. 根据输入与输出变量的类型不同, 可将监督学习分为回归和分类, 其中分类主要针对离散型变量, 应用涉及缺陷在线监测等; 而回归主要针对连续型变量, 应用涉及参数优化、质量控制和性能预测等. 此外, 根据模型的参数分布是否假定, 还可将监督学习模型分为参数模型和非参数模型. 参数模型通常适用于简单问题分析; 而对于复杂问题, 非参数模型更加有效. 两类模型中的代表性算法基本原理与优缺点分别如图 3 和表 1 所示.







图 3 常见的机器学习模型结构示意图

Fig. 3 Schematic of common machine learning model structures

#### 1.1.1 经典机器学习模型

线性回归 (linear regression, LR) 是 ML 算法中用于获取输入与输出变量之间显性方程的一种建模方式, 也是较为简单的一种 ML 算法. LASSO 回归 (LASSO regression) 和岭回归 (ridge regression) 则是在普通线性回归的基础上分别加入 L1 和 L2 正则化项. 线性回归在求解输入与输出变量之间存在较强线性关系的情况下具有优秀的预测能力. 而增材制造合金材料力学性能, 特别是疲劳性能, 与之相关的特征参数之间并不是简单的线性关系. 因此, 线性回

表 1 机器学习算法的分类和特点

Table 1 Classification and characteristics of machine learning algorithms

| Types                               | Algorithms | Advantages                                                                                   | Disadvantages                                                                                               |
|-------------------------------------|------------|----------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------|
| parametric models                   | LR         | simplicity, ease of implementation in programming, and strong interpretability               | stringent assumptions required and poor prediction accuracy                                                 |
|                                     | SVM        | feasible for small sample tasks and high-dimensional nonlinear problems                      | limited explanatory of high-dimensional mapping and substantial memory consumption                          |
| non-parametric models               | RF         | quantifiable feature contributions, rapid training speed, and parallel processing capability | susceptibility to overfitting in high-noise scenarios and limited effectiveness in low-dimensional settings |
|                                     | XGBoost    | rapid computation and exceptional performance                                                | excessive parameterization and complex tuning process                                                       |
| parametric or non-parametric models | NN         | high classification accuracy and effective approximation of nonlinear relationships          | high parameter count, limited interpretability, and challenges in locating global minima                    |

归在这类问题的预测上存在明显不足. 目前线性回归主要用于熔池建模、残余应力预测和量化微结构对拉伸性能的影响等<sup>[15,22-23]</sup>.

支持向量机 (support vector machine, SVM) 作为一类比较成熟的算法, 拥有较高的预测精度, 适用于解决高维不平衡问题, 并且为防止过拟合提供了很好的理论支持. 即使数据在原特征空间线性不可分, 只要选取一个适合的核函数, 就能够很好运行. 当用于回归分析时, 也称为支持向量回归 (support vector regression, SVR). 但需要注意的是, SVM 内存耗费较大, 且模型难以解释, 运行和调参较为繁琐. 目前 SVM 主要用于缺陷检测、工艺优化和疲劳寿命预测等<sup>[24-25]</sup>.

随机森林 (random forest, RF) 是一种集成模型. 集成模型通过采用装袋算法 (bagging) 以减少过拟合. 它包含了多颗决策树 (decision tree, DT), 能够处理大数据集的回归和分类问题, 还有助于从众多的输入变量中选择最重要的变量. 但 RF 的不足之处在于当处理具有较大噪声的样本时, 容易陷入过拟合; 应用于小数据或低维数据时, 可能无法得到很好的预测效果; 无法迭代地改进生成模型. 目前 RF 主要用于增材缺陷检测、表面粗糙度建模和疲劳寿命预测等<sup>[26-27]</sup>.

梯度提升算法 (gradient boosting, GB) 是集成算法中提升法的代表性算法, 是极限梯度提升 (extreme gradient boosting, XGBoost) 的基础. XGBoost 目标是让提升树打破自身的计算极限, 以实现快速运算, 提高预测性能. 不论是应用于分类还是回归问题, XGBoost 均具有较好的预测效果. 但其缺点在于模型的参数过多, 调参过程较为复杂. 目前 XGBoost 模型主要用于增材制造工艺优化、熔池预测、晶格结构建模和疲劳寿命预测等<sup>[28-29]</sup>.

神经网络 (neural network, NN) 是深度学习 (deep learning, DL) 的基础. 常见的 NN 模型包括多层感知机 (multilayer perceptron, MLP)、径向基网络 (radial basis function network, RBFN) 和反向传播网络 (back propagation network, BPNN) 等. NN 算法通过模仿生物神经系统的学习过程, 以实现强大的预测功能. 由于是模拟人类大脑, 所以 NN 模型的复杂度很高. 总的来说, NN 模型的预测精度高, 并行分布处理能力强, 学习能力强, 对噪声神经有较强的鲁棒性和容错能力, 能够充分逼近复杂的非线性关系. 但其缺点是需要调节大量参数, 模型的可解释性差, 影响结果的可信度和可接受水平. 目前 NN 模型广泛用于增材制造过程监测、工艺参数优化和力学性能预测等<sup>[30-31]</sup>.

1.1.2 机理驱动机器学习模型

尽管机器学习方法在很多领域取得了突破, 但仍存在以下问题. 首先, 大多数机器学习模型属于“黑箱”模型, 预测过程未知, 缺乏物理可解释性, 对物理过程的理解受到有限数据集和模型结构的限制. 其次, 受到成本限制和环境影响, 搜集的数据集往往不完整, 且存在噪声, 机器学习模型从稀疏和噪声数据中学习极易导致泛化错误, 进而在构建数据集的范围内具有良好的预测精度, 而对于超出构建范围的数据, 预测效果较差.

为了克服传统机器学习模型的局限性, 提升模型的透明度、可解释性和分析能力, 进一步提出了物理信息与数据混合驱动的机器学习方法, 该方法在传统机器学习模型中融入了物理机理/物理信息/物理约束/物理知识/先验知识<sup>[32]</sup>. 这些物理信息的力学表征形式可以是方程、模型、范围和结构等. PIML 具有以下优势: 首先, PIML 突破了传统 ML 模型因

数据信息不够丰富受到的限制, 并为确定模型的最优解指明了方向, 提升了数据的利用率和计算效率。其次, ML 模型通常需要大量的数据, 而 PIML 即使在数据样本很小的情况下, 依然保持着出色的泛化能力。最后, 物理信息的引入丰富了 ML 的理论内涵, 明确了模型的内部预测机制, 在一定程度上提高了模型的可解释性。可见, 与 ML 相比, PIML 在模型的准确度、稳定性、计算效率和可解释性方面均有所提升。

PIML 的本质是将物理信息场集成到机器学习模型中。常见的 3 种集成方法有物理信息模型输入、物理信息模型构建和物理信息模型输出<sup>[33]</sup>。

(1) 物理信息模型输入: 对数据集进行预处理, 以提取隐含的物理信息。根据特定的物理标准, 将与输出目标弱相关的原始特征转化为强相关特征。为了进一步提高数据的可解释性, 将物理模型与具有物理相关性和物理一致性的实验和仿真数据相结合, 增强 ML 模型的训练样本。

(2) 物理信息模型构建: 基于可解释的物理信息限制 ML 模型内部单元的演化, 使其符合物理规律, 从而指导数据驱动建模并构建混合模型。常见的是在损失函数和激活函数中引入物理约束。例如, 采用损失函数惩罚模型中输入与过程变量的偏差, 确保两者物理一致性; 修改激活函数, 使变量达到阈值后, 神经元做出响应。

(3) 物理信息模型输出: 常见的是构造含有物理信息的损失函数, 使得输出变量限制在与输入变量具有物理一致性的空间内。此外, 还可将已知的输入变量和待求解的输出变量之间的关系嵌入损失函数中, 约束模型的预测结果。

## 1.2 机器学习的工作流程

机器学习从数据出发, 提取数据的特征, 抽象出数据的模型, 发现数据的知识, 又回到对数据的分析与预测中。通用的机器学习流程大致分为 3 步: 数据准备 (数据收集和预处理)、模型建立 (算法选择和模型训练)、模型应用和评估。

机器学习研究的对象是数据, 以变量或变量组表示。数据的质量和数量直接决定着模型的预测精度。因此, 要确保收集数据的完整性、准确性与可靠性。进一步, 对数据进行预处理, 即将原始数据转换为用于模型训练数据的过程, 其中涉及数据清洗、特征提取与选择、数据划分 (用于训练模型的训练

集、用于选择模型的验证集、用于评估模型的测试集) 及数据转换和归一化等。

数据准备好后, 根据数据特点, 基于训练数据集, 寻找最能反映数据规律的机器学习模型。根据指定的学习策略, 通常基于损失函数或风险函数, 从假设空间中选择最优模型, 进一步采用合适的超参数优化算法求解最优模型。网格搜索 (grid search, GS)、随机搜索 (random search, RS)、贝叶斯优化 (Bayesian optimization, BO) 和遗传算法 (genetic algorithm, GA) 是常用的超参数优化算法。1.1.1 节介绍的机器学习模型中典型的超参数包括: SVM 中惩罚项参数、核函数类型和核函数参数等; RF 中决策树的超参数 (最大深度、最小分割样本数和最小叶节点样本数)、树的数量和特征子采样比例等; XGBoost 中学习率、树的数量、树的深度和子采样比例等; NN 中学习率、批量大小、隐藏层节点数、层数和激活函数等。

模型构建后, 根据模型的测试误差对模型进行评估, 测试误差小的模型具有更好的预测能力。常见的评估指标有平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean squared error, RMSE)、决定系数 (coefficient of determination,  $R^2$ ) 和平均绝对百分比误差 (mean absolute percentage error, MAPE), 如下式所示

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (1)$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (2)$$

$$R^2 = 1 - \frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{\sum_{i=1}^m (y_i - \bar{y}_i)^2} \quad (3)$$

$$MAPE = \frac{100\%}{m} \sum_{i=1}^m \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (4)$$

式中,  $m$  表示样本量,  $y_i$  为真实值,  $\hat{y}_i$  为预测值,  $\bar{y}_i$  为平均值。

$MAE$  和  $RMSE$  表征测量误差的平均大小, 其中  $RMSE$  对较大的误差进行更大的惩罚, 而  $MAE$  对误差大小进行线性惩罚。 $R^2$  用于衡量预测值与实验结



果的拟合优度.  $MAE$  和  $RMSE$  值越低,  $R^2$  值越高, 意味着模型的预测精度越高.

而如果一味提高对训练数据的预测能力, 所选模型的复杂度往往会比真模型高, 对未知数据的预测效果反而不理想, 这种现象称为过拟合. 为防止出现过拟合, 在进行最优模型选择时, 宜选择复杂度适当的模型, 以达到使测试误差最小的学习目的. 模型选择的典型方法是正则化. 当样本数据不充足时, 可以采用交叉验证方法, 常见的有简单交叉验证、 $K$  折交叉验证和留一交叉验证.

本节简要介绍了常见的机器学习算法和通用的机器学习流程. 后文将详细论述机器学习在金属增材制造力学性能预测中的应用.

## 2 力学性能影响因素概述及预测

微观组织、内部缺陷、残余应力和表面粗糙度, 是公认的影响增材构件疲劳性能的 4 要素. 而上述影响因素又与制造工艺密切相关, 因此, 大量研究基于机器学习建立了工艺参数与影响因素之间的关联关系, 以期深入挖掘两者的关联机制, 进而有助于增材构件工艺优化和质量提升. 本节将简要介绍各类影响因素的形成原因和特点, 以及基于机器学习预测影响因素的研究现状.

### 2.1 各向异性组织

增材制造是以“逐点扫描—逐线搭接—逐层堆积”为成形特征的长周期循环往复过程. 已沉积材料经历了多周期、变循环、剧烈加热和冷却的短时热历程, 这使得与传统制造方法相比, 增材材料的微结构呈现显著的差异性, 表现为典型的多层、跨尺度和异质的微结构特征, 如图 4 所示<sup>[34-35]</sup>.

目前, 已开展了大量基于机器学习的增材制造熔池调控方面的研究. Khanzadeh 等<sup>[36]</sup> 采用自组织

映射神经网络分析熔池图像, 检测定向能量沉积薄壁结构中的异常. Lee 等<sup>[37]</sup> 采用包括工艺参数和材料参数的 23 种输入特征, 以增强数据驱动的机器学习熔池建模. Wang 等<sup>[38]</sup> 还引入了 5 个实验校准的不确定性源作为数据驱动模型的输入, 合理地预测熔池波动. 此外, 也有学者采用高斯过程 (Gaussian process, GP) 回归模型, 基于实验和模拟数据, 建立工艺参数与熔池特征的关联关系. Meng 等<sup>[39]</sup> 开发了一种 GP 回归模型, 采用计算流体动力学模型得到的 24 个模拟数据训练 GP 模型, 预测与激光功率和扫描速度相关的单轨重熔深度. 进一步地, Olleak 等<sup>[40]</sup> 也开发了一种 GP 回归元模型, 用于通过 L-PBF 工艺参数 (激光功率、扫描速度、光斑直径、吸收率和层厚) 预测熔池尺寸. 最近, Ren 等<sup>[41]</sup> 利用激光功率和熔池温度的实验和模拟数据, 采用 GP 对多通道的熔池动力学进行建模, 并将熔池尺寸调节到恒定的参考值.

此外, 晶粒结构的准确建模对于增材制造工艺优化也具有重要意义. 然而, 目前基于机器学习的增材制造晶粒建模研究相对较少. Wang 等<sup>[42]</sup> 通过 Ti-6Al-4V 合金多尺度多物理场仿真模型和 GP 代理模型, 构建了以工艺参数为输入变量的晶粒结构预测模型, 其中晶粒结构由晶粒纵横比的均值和方差描述. 进而, Li 等<sup>[43]</sup> 提出了一种用于预测 DED 过程中晶粒竞争性生长行为的人工神经网络 (artificial neural network, ANN) 方法. 在该研究中, ANN 用于研究晶界倾角与热梯度、晶体取向和 Marangoni 效应之间的关系. 近期, Kats 等<sup>[44]</sup> 采用有限体积法 (finite volume method, FVM) 获得温度场, 同时与元胞自动机结合, 模拟熔池内部的晶粒结构. 再通过网络, 将温度梯度和冷却速率与晶粒尺寸和形貌建立联系, 最后将训练良好的 NN 模型与 FVM 耦合, 以预测 DED 过程中给定工艺参数下的微结构特征, 进而开发了一种基于物理信息的 ML 模型, 可实现 DED 过程中晶粒结构的快速准确预测, 如图 5 所示<sup>[44]</sup>.

目前数据驱动的晶粒结构建模仍处于初期探索阶段, 研究重点是在简单的微观结构描述符与输入特征之间建立映射关系, 难点在于对作为高维物理量的晶粒结构的显式建模. 此外, 还存在其他类型的数据驱动建模, 如晶格结构建模<sup>[45]</sup>、枝晶结构建模<sup>[46]</sup>





图 4 激光选区熔化成形 AlSi10Mg 铝合金微结构特征<sup>[34-35]</sup>

Fig. 4 Microstructural features of L-PBF AlSi10Mg alloy<sup>[34-35]</sup>



图 5 基于机器学习的晶粒结构预测示意图<sup>[44]</sup>Fig. 5 Schematic of the prediction of grain structure by machine learning<sup>[44]</sup>

和双粒子相场微结构建模等。


## 2.2 广域内部缺陷




增材制造缺陷具有全域分布、形态多样、尺寸跨度大及形成机制复杂等特点。气孔和未熔合缺陷是常见的两类增材缺陷,如图 6 所示<sup>[47]</sup>:前者为气体未及时溢出所致,数量较多、尺寸较小且形貌规则,多分布在熔池内部;后者为层间熔合不良所致,数量较少、尺寸较大且形貌复杂,多分布在熔池边缘。采取参数优化和后热处理仅能够在一定程度上降低缺陷水平,这些不易根除的制造缺陷作为应力集中源,会诱导疲劳裂纹形核,导致疲劳性能显著下降和极大的疲劳寿命离散性,为疲劳性能的可靠评估和准确预测带来挑战。

目前已开发了多种用于增材缺陷在线监测与离

线检测的机器学习方法。关于缺陷在线监测,Chen 等<sup>[48]</sup>开发了一种原位点云处理方法,可原位监测 DED 过程中表面缺陷的形成,模型中结合了聚类和多种分类方法以进行缺陷识别。原位识别出缺陷后,设置特定的激光路径对缺陷进行修复,从而可显著降低孔隙率,提升成形质量。但由于数据收集成本昂贵且耗时,Li 等<sup>[49]</sup>提出了基于距离特征构建的三维缺陷点云模型,结合三维数据采集系统,进行增材制造过程中的原位缺陷监测。此外,Li 等<sup>[50]</sup>又引入了离散平均曲率以捕获距离之外的宏观信息,进一步提高了缺陷监测性能。由于半监督学习只需要标记少量数据,近年来在缺陷在线监测中受到关注。例如,Pandiyani 等<sup>[51]</sup>提出了一种半监督模型,基于声学特征分布,有效地区分激光增材制造过程中的无缺陷区与异常区域。

关于离线缺陷检测,Liu 等<sup>[52]</sup>提出了一种基于机理驱动的机器学习模型,预测和解释 L-PBF 中缺陷的产生。该模型在逆向设计工艺参数(如激光功率和扫描速度)以满足零件质量要求方面具有潜力。此外,Zhang 等<sup>[53]</sup>提出了一种基于物理信息神经网络(physics-informed neural network, PINN)的统一框架,用于处理连续体中缺陷几何识别问题。考虑到大量的增材缺陷形成于熔池,Akbari 等<sup>[54]</sup>利用图 7 所示的 8 种机器学习模型,基于工艺参数和材料性能,开展了增材制造熔池几何形状和缺陷类型(匙孔和未熔合缺陷等)预测,为熔池控制和工艺优化奠定基础。其中,在处理输入数据时,采用了多种特征工程

图 6 选区激光熔化成形 AlSi10Mg 铝合金缺陷分布<sup>[47]</sup>Fig. 6 Distribution of defects in L-PBF AlSi10Mg alloy<sup>[47]</sup>

图 7 增材制造熔池几何形状和缺陷类型预测流程<sup>[54]</sup>Fig. 7 Prediction process of melt pool geometry and defect types in additive manufacturing<sup>[54]</sup>(a) 形态参数重要性量化  
(a) Rankings of the morphological parameters in terms of their importance(b) ANN 模型结构  
(b) Architecture of the ANN model图 8 用于缺陷分类的人工神经网络<sup>[55]</sup>Fig. 8 Artificial neural network for defect classification<sup>[55]</sup>

## 2.3 残余应力与粗糙度

增材制造经历表层材料局部快速熔融和凝固过程, 同时伴有一定程度的次表层基体再熔化现象. 熔化-凝固-再熔化热循环导致的不均匀塑性变形是增材制造残余应力的主要来源. 增材构件的顶部、底部和表层区域通常呈现残余拉应力, 而残余拉应力会降低疲劳裂纹的形核和扩展阻力, 进而对材料的疲劳断裂性能十分不利.

Demir 等<sup>[56]</sup>提出了一种扫描策略的直观定量描述符, 即相对时空临近度 (relative spacetime

proximity, RSP) 图. 采用空间和时间标准量化激光扫描路径上点的时空邻近性, 通过评估路径上所有节点的累积时空邻近度从而获得 RSP 图. 在此基础上, 进一步训练 NN 模型, 以由指定路径的描述符准确预测增材制造残余应力分布.

由于未熔合缺陷、气孔和匙孔的形成机制不同, 使其在尺寸、位置及形貌等几何特征方面具有一定的差异. 为了对上述 3 种缺陷类型进行高精度分类, Poudel 等<sup>[55]</sup>提出了一种包含多个形态参数的缺陷分类方法. 通过使用包括长轴长度、圆度、稀疏度和纵横比等 9 个参数, 对缺陷的几何特征进行量化分析, 如图 8 所示. 基于最具辨别力的几何参数, 在 ML 模型上实现增材缺陷高精度分类, 模型准确率大于 99%. 缺陷的准确分类对于理解缺陷对材料和构件服役行为的影响至关重要.

尽管增材制造的特点及优势之一为“近净成形”, 但是逐层熔化和沉积的过程使得材料表面呈现出明显的缺陷特征 (表面球化黏附、局部凹陷、表面不平整和上下表面缺陷非对称等), 导致增材制造表面粗糙度高于传统制造方法. 粗糙的表面作为典型的

方法, 以提高模型对系统复杂性的理解能力. 结果表明, 在分类和回归方面, 神经网络、梯度增强和随机森林的预测性能优于其他模型. 此外, 还提出了一种数据驱动模型识别方法, 用于通过工艺参数和材料性质预测熔池几何形状. 提出的显式模型相对于传统机器学习模型更易解释, 并在熔池几何的预测性能上表现更优.

应力集中源, 会诱导疲劳裂纹形核, 从而大幅度降低材料的疲劳强度及寿命, 对材料的磨损性和腐蚀性也极为不利.

如图 9 所示, Wang 等<sup>[57]</sup> 提出了一种维度增强和物理信息的 ML 模型, 基于 L-PBF 的工艺参数预测成形态 CoCrFeNiMn 高熵合金样品顶层表面粗糙

度和相对密度, 表现出了比其他传统机器学习算法 (如 SVM) 更优的预测能力.

表 2 总结了机器学习在增材制造组织、缺陷、残余应力和粗糙度预测中的代表性应用, 具体内容请详见表中的参考文献.




图 9 基于维度增强和物理信息的 ML 模型<sup>[57]</sup>

Fig. 9 Dimensionally enhanced and physically informed ML model<sup>[57]</sup>

表 2 机器学习在增材制造组织、缺陷、残余应力和粗糙度预测中的应用

| Table 2 Application of ML to prediction of microstructure, defect, residual stress and roughness in additive manufacturing |                 |                                                                                                            |                               |
|----------------------------------------------------------------------------------------------------------------------------|-----------------|------------------------------------------------------------------------------------------------------------|-------------------------------|
| Materials                                                                                                                  | ML models       | Inputs                                                                                                     | Outputs                       |
| Ti-6Al-4V <sup>[42]</sup>                                                                                                  | GP              | preheating temperature, beam power, and scanning speed                                                     | grain structure               |
| Ti-6Al-4V <sup>[43]</sup>                                                                                                  | ANN             | thermal gradient, crystal orientation, and Marangoni effect                                                | grain boundary tilt angle     |
| inconel 718 <sup>[44]</sup>                                                                                                | ANN             | temperature gradient, solidification rate, and cooling rate                                                | grain size and aspect ratio   |
| steel <sup>[58]</sup>                                                                                                      | LR, ANN         | wire feed rate, welding speed, arc voltage, and nozzle-to-plate distance                                   | bead width and height         |
| simulation data <sup>[59]</sup>                                                                                            | LR              | temperature, scanning velocity, melt pool width, depth and length, and the width of the heat-affected zone | grain structure               |
| 17-4 PH stainless steel <sup>[60]</sup>                                                                                    | GP              | laser power and scanning speed                                                                             | porosity                      |
| inconel 718 <sup>[61]</sup>                                                                                                | LR, SVM, ANN    | scanning speed, beam current, substrate temperature, and layer thickness                                   | density                       |
| AlSi10Mg <sup>[62]</sup>                                                                                                   | GP              | laser power and scan speed                                                                                 | density                       |
| Ti5Al5V5Mo3Cr <sup>[63]</sup>                                                                                              | ANN             | laser power, scanning velocity, and hatching distance                                                      | density                       |
| Ti-6Al-4V <sup>[64]</sup>                                                                                                  | LR, NB, SVM     | laser power, scanning speed, energy density, and layer thickness                                           | density                       |
| SS 316, IN 718 and 800 H <sup>[65]</sup>                                                                                   | RF, ANN         | per unit temperature change, heat input, substrate rigidity, and pool volume                               | residual stress               |
| AISI 304L steel <sup>[66]</sup>                                                                                            | ANN             | temperature history of the elements and their spatial coordinates                                          | residual stress               |
| Ti-6Al-4V <sup>[67]</sup>                                                                                                  | BPNN            | laser power, laser scanning speed, layer thickness, and hatch distance                                     | surface roughness and density |
| 316L-Cu steel <sup>[68]</sup>                                                                                              | GP              | laser power, velocity, and hatch spacing                                                                   | surface roughness and density |
| Ti-6Al-4V <sup>[69]</sup>                                                                                                  | ANN             | laser power, scan speed, hatch spacing, laser pattern increment angle, and heat treatment condition        | surface roughness             |
| mild carbon steel <sup>[70]</sup>                                                                                          | SVM, ELM, ANEIS | welding speed, wire feed speed, and overlap ratio                                                          | surface roughness             |



续表 2

| Materials                            | ML models | Inputs                                                               | Outputs                       |
|--------------------------------------|-----------|----------------------------------------------------------------------|-------------------------------|
| inconel 625 <sup>[71]</sup>          | ANN       | laser power, scan velocity, energy density, and scan stripe rotation | surface roughness             |
| 316L stainless steel <sup>[72]</sup> | BN        | laser power, scan speed, hatch spacing, and layer thickness          | surface roughness and density |

Note: LR: logistic regression; NB: naive Bayes; ELM: extreme learning machine; ANFIS: adaptive-network-based fuzzy inference system; BN: Bayesian networks

3 机器学习在性能预测中的应用

3.1 基本力学性能

金属材料的力学性能与其制造工艺、化学成分和微结构特征等密切相关. 而复杂影响因素下的力学性能准确预测是一项重要挑战<sup>[73]</sup>. 近年来, 大量研究基于机器学习构建了加工工艺-微观组织-基本力学性能的关联关系. 具体的研究主要分为 3 个方面: (1) 从工艺到性能建模; (2) 从组织到性能建模; (3) 工艺-组织-性能的集成建模.

(1) 工艺-性能建模: 这类模型将增材制造的工艺参数作为输入变量, 基于 ML 对工艺参数与拉伸性能进行关联预测. 例如, 杨天雨等<sup>[74]</sup>采用 BPNN 对 L-PBF 18Ni300 时效模具钢小样本数据集进行工艺参数与抗拉强度的关联建模. 进一步与遗传算法相结合, 分析了影响材料力学性能的主要因素, 各类因素的重要性从大到小依次为激光功率、扫描速度和扫描间距.


采用集成模型也是提高预测精度的一种方式. 例如, Li 等<sup>[75]</sup>采用 GP, RBF 和 SVM 3 个元模型构建集成模型, 基于工艺参数 (激光功率、层厚和扫描速度) 预测 L-PBF 316L 不锈钢的抗拉强度. 将这 3 个模型的响应输出根据局部权重进行汇总, 作为提出的集成模型的输出. 结果发现, 集成模型将独立算法的预测精度提高了 20% 以上. 为了解决增材制造质量可重复性这一挑战, Huang 等<sup>[76]</sup>采用 LR, SVM, DT, RF 和 XGBoost 等 8 种 ML 模型成功辨识出与 316L 不锈钢制造过程密切相关的下游参数, 促进了增材构件质量的可重复性. 研究发现, 零件位置和腔室后压降的组合效应会显著影响打印零件的拉伸性能, 且与强度相比, 延伸率指标对两者的影响更为敏感. 与传统分析方法相比, 机器学习能够有效地过滤掉不重要的参数, 并直观地可视化重要影响参数的潜在组合效应.

此外, Hertlein 等<sup>[72]</sup>采用 BN, 基于 4 种工艺参数 (激光功率、扫描速度、扫描间距和层厚), 预测

了 L-PBF 316L 不锈钢的密度、硬度、顶层表面粗糙度、平行于建造方向和垂直于建造方向的抗拉强度, 实现从工艺参数至零件质量的建模, 如图 10 所示. 值得注意的是, 文中的数据集源于不同的增材制造设备. 通过引用  $n$  维凸包, 识别潜在不可接受的工艺参数的凸包, 并将已知可接受点之间的边界划分为线性, 从而得出分段线性边界的近似. 提出的贝叶斯网络通过少量的测试打印来学习新增材行为, 并获得工艺参数与力学性能的关联, 包括所有变异源. 这使制造商能够使用预测的概率分布作为参考, 量化其机器的固有变异.


(2) 组织-性能建模: 这类研究以增材制造过程中形成的复杂微结构特征作为输入, 基于机器学习来量化组织特征与力学性能之间的关联. 例如, Sanchez 等<sup>[77]</sup>采用 RF, SVM 和 GB 等多种机器学习模型, 基于工艺参数与从光镜图像中提取的孔隙率, 预测 L-PBF 镍基高温合金 718 的蠕变率, 预测精度  $MAPE$  为 1.40%. 研究发现, 零件密度、孔隙率、建造方向和扫描策略是影响材料蠕变率的重要参数. 此外, Kusano 等<sup>[78]</sup>采用多元线性回归, 基于由扫描电镜得到的微观组织和由 X 射线成像得到的缺陷特征, 预测后热处理 L-PBF Ti-6Al-4V 合金的拉伸性能. 其中, 通过 RF 算法和图像分析技术定量提取扫描电镜图像的微结构特征, 而后将其用于多元线性回归分析, 以预测拉伸性能. 结果表明, 增材 Ti-6Al-4V 合金的拉伸性能与微观组织密切相关, 相关系数为 0.82. 预测模型显示出对屈服强度和抗拉强度具有良好的准确性, 而对伸长率的预测效果并不理想. Muhammad 等<sup>[79]</sup>提出了一种 ANN 框架, 用于预测 L-PBF AlSi10Mg 合金拉伸变形过程中局部应变的演变. 其中, 输入变量为基于电子背散射衍射表征的微结构特征、X 射线成像得到的缺陷分布和数字图像相关测量的局部应变. 这项研究证明了基于机器学习方法由复杂非均质微结构特征预测材料局部变形响应的可行性.

Hu 等<sup>[80]</sup>采用 GB 和 LASSO 回归研究了微缺

图 10 基于 BN 的零件质量预测流程<sup>[72]</sup>Fig. 10 Part quality prediction process based on BN<sup>[72]</sup>

陷与增材制造 AlSi10Mg 和 inconel 625 合金晶格力  
学性能之间的复杂关系, 如图 11 所示。

首先, 将不同的晶格几何形状简化为单个代表


图 11 微缺陷与晶格力学术性能的预测模型<sup>[80]</sup>Fig. 11 Prediction model of microdefects and lattice mechanical properties<sup>[80]</sup>

性梁, 针对不同的边界条件、倾角、长宽比、表面粗糙度和单梁中存在的缺陷数量和大小, 生成仿真模型。然后, 通过机器学习处理生成的模拟数据, 确定决定力学性能的关键特征。研究发现, GB 不仅对这些模拟数据具有较高的预测精度, 而且对早期研究获得的金属晶格实验数据也给出了合理的预测。通过 LASSO 回归对特征的重要性进行排序, 发现表面粗糙度和变形模式 (拉伸/刚性与弯曲/柔性) 是影响桁架格子刚度和强度的重要因素。无论设计类型如何, 粗糙度均会显著降低材料的刚度和强度, 且对弯曲主导结构的影响更为严重。

(3) 工艺-组织-性能建模: Yan 等<sup>[81]</sup> 基于材料的化学成分和工艺参数 (冷却速率、时效温度和时效时间), 通过 GP 模型实现了对增材制造 Ferrium® PH48S 马氏体时效不锈钢屈服强度的快速预测。基于 200 个模拟数据点开发了 4 个 GP 模型, 用 GP 元模型取代了特定位置的物理模型, 如图 12 所示, 从而实现高精度预测, 误差在 0.23% 以内, 预测效率得到了显著提升。以材料的屈服强度为例, 预测时间由 300 s (物理模拟方法) 大幅度缩短至几分之一秒 (机器学习方法)。


### 3.2 疲劳断裂性能

疲劳失效是工程部件在服役过程中最常见的失效形式之一。因此, 疲劳断裂性能的可靠评估与准确预测对于保障工程部件长效服役可靠性与安全性至关重要, 受到广泛关注。疲劳问题的研究经历了以下

图 12 用 GP 元模型取代力学模型的数据驱动框架<sup>[81]</sup>Fig. 12 Replacing the data-driven framework of mechanical models with GP metamodel<sup>[81]</sup>

4 个发展阶段: 第 1 阶段为经验范式, 以实验观察为依据开展疲劳研究; 第 2 阶段为理论范式, 基于演绎法的理论描述疲劳过程; 第 3 阶段为计算范式, 计算机能力的提升与理论模型的完善, 使得复杂疲劳现象的模拟成为可能; 第 4 阶段为数据密集型范式, 随着大数据时代和人工智能的不断发展, 以机器学习为代表的科学成为疲劳分析的一大利器<sup>[33]</sup>. 基于机器学习方法的疲劳断裂性能研究是目前结构完整性分析的一大热点.

金属材料的疲劳断裂过程可大致分为 3 个阶段: 疲劳裂纹萌生、裂纹扩展和失稳断裂. 每个阶段所涉及的物理机制不尽相同. 在循环载荷作用下, 材料局部发生塑性变形, 引发不可逆损伤, 进而形成疲劳裂纹. 常见的疲劳裂纹形核的微观机制为位错增殖和回复、位错亚结构演化、驻留滑移带形成和侵入/挤出致裂纹形核. 而当材料内部存在粗大夹杂相或者孔洞缺陷时, 会造成局部应力集中, 进而加速疲劳裂纹形核<sup>[82]</sup>. 裂纹萌生后, 在其随后的扩展过程中, 随着裂纹长度的增加, 对应的物理机制不断变化, 大体分为由不连续机制、连续性机制和快速断裂主导的 3 个阶段, 如图 13 所示<sup>[83]</sup>. 在不连续机制主导阶段, 裂纹主要为物理短裂纹和近门槛值区裂纹, 该阶段的裂纹尺寸较小, 且裂纹扩展不连续, 裂纹扩展速率与裂纹尖端驱动力应力强度因子幅值  $\Delta K$  的规律不明显, 数据离散性较大. 研究发现, 疲劳裂纹萌生与早期裂纹扩展周期在疲劳寿命中的占比高达 70%~80% 以上. 在连续扩展机制主导阶段, 在双对数坐标系下, 裂纹扩展速率与  $\Delta K$  呈现明显的线性关系, 裂纹扩展速率可借助经典的 Paris 公式描述. 在快速断裂区, 裂纹扩展速率急剧增加, 所经历的循环周次占疲劳寿命的比值极少, 通常可以忽略<sup>[83-84]</sup>.

图 13 疲劳裂纹扩展阶段示意图<sup>[83]</sup>Fig. 13 Schematic of the fatigue crack propagation stages<sup>[83]</sup>

疲劳裂纹萌生寿命与扩展寿命之和为疲劳寿命. 疲劳寿命预测是疲劳研究领域的一个关键课题. 常见的疲劳寿命预测方法有以下 3 类: 第 1 类以常规力学参量 (应力、应变和应变能或者它们的组合) 作为疲劳指标参数, 建立其与疲劳寿命之间的函数关系, 基于确定性或者概率的方法对疲劳寿命进行预测; 第 2 类基于断裂力学理论, 通过实验确定疲劳裂纹扩展速率  $da/dN$  与应力强度因子幅值  $\Delta K$  之间的函数关系, 再通过积分计算寿命; 第 3 类基于连续介质损伤力学理论, 根据可观测的弹性模量  $E$  等材料参数的变化定义疲劳损伤变量  $D$ , 构建损伤演化方程  $dD/dN$ , 当损伤累积达到临界损伤时发生疲劳失效, 从而得到疲劳寿命.

尽管上述疲劳寿命预测方法在工程材料和结构中应用广泛, 但仍存在局限性. 归纳法侧重于对具体实验现象的分析, 理论的通用性不足. 演绎法以物理机制和规律为基础, 强调因果逻辑. 而疲劳失效机制的复杂性, 使得演绎法在建立模型时需要进行假设和理想化, 这会导致理论模型与实验现象之间存在



差异. 此外, 疲劳损伤机制与多因素的耦合, 如尺寸相关性、材料种类、制造工艺和服役条件等, 导致物理模型难以捕捉实际情况中存在的随机性、变异性和非线性等不确定因素的影响, 从而影响疲劳性能的准确描述. 在面对上述挑战时, 近年来一些学者尝试采用机器学习方法处理复杂的疲劳失效机制和多变量因素的影响. 机器学习从大量实验和模拟数据中学习复杂的关系和模式, 从而更灵活地适应实际情况. 其优势在于能够处理数据中的随机性和变异性, 进而提高模型准确性.

而在各向异性组织、广域内部缺陷、深部残余应力和复杂表面形貌等因素的影响下, 金属增材制造的疲劳失效机制更为复杂, 疲劳断裂性能的可靠评估与准确预测面临更大挑战. 研究指出, 增材制造材料内部不易根除的气孔和未熔合等缺陷是导致疲劳性能劣化和疲劳寿命离散性大的重要因素. 进一步发现, 诱导裂纹萌生的临界缺陷的几何特征 (尺寸、位置、形貌和取向) 在很大程度上决定着高周疲劳寿命. 而增材制造缺陷的尺寸、位置、形貌和取向分布与材料类型、试样取向、工艺参数和后热处理制度等密切相关, 缺陷的空间分布规律极具复杂性, 临界缺陷呈现不确定性, 这些行为各异的临界缺陷对疲劳性能的影响又极具个性化<sup>[11]</sup>. 如何在材料内部数量众多的缺陷中准确地辨识出临界缺陷, 进而建立考虑临界缺陷三维几何特征的疲劳寿命预测模型是金属增材制造一大关键力学问题. 尽管采用考虑缺陷几何特征的、基于 Murakami 参数 ( $\sqrt{\text{area}}$ ) 和缺陷容限思想的系列方法在一定程度上提高了增材制造合金材料疲劳寿命的预测精度, 但由于缺陷空间分布的多样性和复杂性, 使得传统力

学模型在深入挖掘缺陷几何特征与疲劳寿命之间隐含的复杂规律方面具有局限性. 在缺乏有效的力学模型的情况下, 机器学习为金属增材制造疲劳断裂性能研究提供了一种可行的技术途径.

目前, 关于金属材料增材制造疲劳断裂性能预测研究主要分为以下两个方面: 数据驱动机器学习建模和机理驱动机器学习建模.

(1) 数据驱动机器学习建模: 这类模型基于实验和仿真数据建立数据集, 再与材料的实测疲劳与断裂性能进行关联建模. 例如, 在疲劳裂纹扩展预测方面, 基于包含多个应力比和应力水平的铝合金 (2024-T3, 7075-T6, 2090-TBE41) 和 Ti-6Al-4V 合金数据集, Mortazavi 等<sup>[85-86]</sup> 开发了两种 ANN 模型 (RBFN 和 ELM), 以预测裂纹扩展速率, 如图 14 所示. 其中, RBFN 在预测短裂纹扩展行为方面更准确, 而 ELM 在外推预测方面性能优越. 但是这两种模型的预测性能均依赖于数据集规模, 选择具有代表性的输入变量和构建大规模数据集对于提高模型的泛化能力具有重要意义.

在疲劳寿命预测方面, Zhang 等<sup>[87]</sup> 基于 L-PBF 316L 不锈钢的高周疲劳实验数据, 采用具有模糊逻辑的 ANN 预测高周疲劳寿命. 其中一种是“基于工艺”的模型, 即由工艺和热处理参数预测疲劳寿命. 另外一种“基于属性”的模型, 即基于抗拉强度和延伸率预测疲劳寿命. 对于当前的数据集, 模型表现出较高的预测精度, RMSE 在 11%~16% 之间. 而将其外推应用于其他文献数据时, 预测精度较差. 例如, 将其用于复合材料层合板的高周疲劳寿命预测时, 训练和测试误差分别达到 25% 和 47%<sup>[88]</sup>. 可见, 机器学习模型的性能和适用性在很大程度上取决于应




图 14 基于机器学习的疲劳裂纹扩展预测框架<sup>[85]</sup>

Fig. 14 Fatigue crack growth prediction framework based on machine learning<sup>[85]</sup>

用场景,有些模型在一个案例研究中能够准确预测,但无法保证其在其他案例中也能获得具有竞争力的结果。

广域内部缺陷被视为增材构件可靠性服役的一大“顽疾”。例如, Luo 等<sup>[89]</sup>通过 LR, SVM 和核岭回归 (kernel ridge regression, KRR), 建立了 L-PBF inconel 718 零件内部缺陷的最大尺寸、位置和数量与疲劳寿命之间的关系。结果表明,随着缺陷尺寸增大、数量增多及缺陷至材料表面距离的减小,疲劳寿命不断降低。且与缺陷的尺寸和数量相比,缺陷位置对疲劳寿命的影响更为显著。 Bao 等<sup>[90]</sup>也研究了缺陷位置、尺寸和形貌对 L-PBF Ti-6Al-4V 合金疲劳寿命的影响。结合 X 射线成像、扫描电镜和高周疲劳实验,获得临界缺陷的几何特征与疲劳寿命数据,采用 SVM 模型进行模型训练。为了加快优化过程,选择具有交叉验证的网格搜索来获取模型的参数。结果表明,预测寿命与实验值的  $R^2$  高达 0.99。进一步地,为了实现对超高周疲劳寿命有效预测, Li 等<sup>[91]</sup>提出了一种易于使用且非冗余的机器学习模型。首先运用蒙特卡罗模拟来扩大数据集规模,再通过 BPNN 研究缺陷尺寸、位置和建造方向对 L-PBF Ti-6Al-4V 合金疲劳寿命的协同影响,如图 15 所示。模型表现出较好的预测能力,预测寿命与实验值的

$R^2$  高达 0.98。而最近 Shi 等<sup>[92]</sup>采用不同插值方法扩大数据集,利用 ANN, SVM 和 RF 建立了 L-PBF AlSi10Mg 合金的缺陷特征与超高周疲劳寿命的映射关系,研究了层厚、应力比、应力幅值、缺陷尺寸、形状和位置对疲劳寿命的协同影响。结果表明,高斯混合模型线性插值能够生成更接近于原始数据分布的虚拟数据集。

Peng 等<sup>[93]</sup>综合运用 RF 和 XGBoost,建立了 L-PBF AlSi10Mg 合金缺陷几何特征 (缺陷尺寸、位置、形貌和取向) 与疲劳寿命的关联关系。具体步骤如下: 首先借助扫描电镜观察高周疲劳断口,辨识临界缺陷,由 ImageJ 图像处理软件统计临界缺陷的几何参数。然后,采用 RF 算法识别出 3 个最重要的几何参数。最后通过 XGBoost 算法建立应力和 3 个缺陷几何参数与疲劳寿命的关联关系。结果表明,对疲劳寿命的重要性由应力、缺陷尺寸和位置至形貌依次递减。XGBoost 模型具有较高的预测精度 ( $R^2 = 0.95$ ), 且呈现出良好的泛化能力。

最近, Li 等<sup>[94]</sup>开发了集成的数据驱动的缺陷临界性分析框架以预测疲劳寿命。该框架将 L-PBF 17-4 PH 不锈钢的缺陷特征提取、相关性分析和缺陷特征-疲劳寿命关系建模与 SVM 相结合,以实现准确且可解释的数据驱动疲劳分析。具体而言,首先通




图 15 缺陷几何特征与疲劳寿命的机器学习建模<sup>[91]</sup>

Fig. 15 Machine learning modeling of geometric features of defects and fatigue life<sup>[91]</sup>

过扫描电镜拍摄疲劳断口, 辨识临界缺陷, 基于图像检索技术提取临界缺陷的尺寸和形态参数. 然后, 通过相关性分析和 SVM 建立缺陷几何特征与疲劳寿命之间的关系. 结果表明, 该框架具有较高的预测精度,  $MAPE$  低至 0.101.

Cutolo 等<sup>[95]</sup> 结合标准试样的疲劳数据 (涉及不同建造方向、后热处理、表面处理、缺口和应力梯度效应)、有限元仿真分析和机器学习方法, 预测具有代表性结构特征 (薄壁、悬臂表面和内部孔) 的 L-PBF Ti-6Al-4V 钛合金构件的疲劳寿命. 增材制造构件疲劳寿命的预测流程如图 16 所示. 在基于有限元分析方法预测疲劳寿命时, 通常根据应力-寿命 ( $S-N$ ) 曲线, 将每个单元的应力状态映射到相应的疲劳寿命. 文中采用高斯回归以建立应力-寿命关系的数学模型. 高斯回归通过考虑每个有限元单元的独特特征集来预测疲劳寿命, 这些特征集包括影响疲劳寿命的表面粗糙度、主应力方向与建造方向之间的夹角及热处理等. 通过将这些局部条件纳入模型, 高斯回归可以更好地捕捉增材构件内部的复杂性和异质性, 从而提高对每个单元和整体构件疲劳寿命的预测准确性.

(2) 机理驱动机器学习建模: 由于传统的机器学习本质上是基于数据驱动的黑箱建模, 缺乏对决策的可解释性. 而物理信息的融入, 为确定模型的最优解指明了方向, 明确了模型内部预测机制, 提升了数据的利用率和计算效率, 且对小规模数据集也具有较高的预测能力和较好的泛化能力, 近年来在增材

制造领域受到青睐.

在物理信息模型输入方面: Zhan 等<sup>[96]</sup> 提出了基于连续损伤力学 (continuum damage mechanics, CDM) 的疲劳模型与 MLP 模型相结合的 CDM-MLP 方法, 用于增材制造 300M-AerMet100 钢疲劳性能预测. 首先通过基于 CDM 的疲劳模型生成足够多的训练数据用于机器学习, 如下式所示. 然后以应力集中因子、应力比和最大名义应力为输入变量, 采用 MLP 预测疲劳寿命. 结果表明, 提出的 CDM-MLP 方法具有较高的预测精度

$$N_f = \frac{1}{1+\beta} \frac{1}{\alpha M_0^{-\beta}} \frac{\langle \sigma_u - \sigma_{e, \max} \rangle}{\langle A_{II} - A_{II}^* \rangle} \left( \frac{A_{II}}{1 - b_2 \sigma_{H, m}} \right)^{-\beta} \quad (5)$$

式中,  $N_f$  为疲劳寿命;  $\alpha$ ,  $\beta$ ,  $M_0$  和  $b_2$  为拟合参数;  $\sigma_u$  为极限强度;  $\sigma_{H, m}$  为平均静水压力;  $\sigma_{e, \max}$  为最大等效应力;  $A_{II}$  为剪切应力幅;  $A_{II}^*$  为疲劳极限标准.

Wang 等<sup>[97]</sup> 基于敏感特征和 CDM, 提出了用于 L-PBF AlSi10Mg 合金疲劳寿命预测的 ML 框架, 采用的 ML 算法为 SVM 和 RF. 为了减轻特征之间因果关系的干扰, 从数据中提取了敏感特征. 而物理信息源于基于 CDM 计算的疲劳寿命, 以表征不同应力幅值下的损伤程度, 如下式所示. 分析发现, 采用敏感特征的物理知识引导的机器学习模型表现出更好的预测能力

$$N_{CDM} = \frac{m^\beta}{(1-\alpha)(1+\beta)} \left[ \frac{\sigma_a (1 + \Delta(E_d, E_{d0}))}{1 - n\sigma_m} \right]^{-\beta} \quad (6)$$

式中,  $N_{CDM}$  为基于 CDM 计算的疲劳寿命;  $\alpha$ ,  $\beta$ ,  $m$  和  $n$  为拟合参数;  $\sigma_a$  为应力幅值;  $\sigma_m$  为平均应力;  $E_d$  为能量密度;  $E_{d0}$  为能量密度的参考值.

在物理信息模型构建方面: Ciampaglia 等<sup>[98]</sup> 采用 PINN, 基于工艺参数 (建造方向、功率、扫描速率、扫描间距、粉末尺寸、激光束直径和基板预热温度) 和热处理工艺 (热处理温度和时间), 预测增材制造 AlSi10Mg 合金的疲劳  $S-N$  曲线. 已有研究表明, 工艺参数影响缺陷尺寸和微观组织, 而热处理影响微观组织. 为了将上述物理知识引入神经网络, 建立了一个新的模块化结构, 如图 17(a) 所示. 其中, 输入参数设置为独立的神经网络分支, 分别考虑缺陷和组织对疲劳寿命的影响. 在模型输出端, 模拟 Murakami 方程, 将网络模块合并到物理层中, 如下




图 16 基于机器学习的增材制造构件疲劳寿命预测流程<sup>[95]</sup>

Fig. 16 Prediction process of fatigue life of additively manufactured components based on machine learning<sup>[95]</sup>






图 17 用于金属增材制造疲劳寿命预测的机理驱动机器学习模型

Fig. 17 Physics-informed machine learning models for predicting fatigue life of additively manufactured metals

式所示

$$\sigma_a = \frac{N^1(\theta; w_\theta, b_\theta) \left( \frac{w_C^1}{N_f} \right)^{w_C^2}}{N^2(\phi; w_\phi, b_\phi) \left( \frac{w_C^1}{N_f} \right)^{w_C^2}} = \frac{\theta \left( \frac{w_C^1}{N_f} \right)^{w_C^2}}{\phi \left( \frac{w_C^1}{N_f} \right)^{w_C^2}} \quad (7)$$

式中,  $\sigma_a$  为应力幅;  $\theta$  为变量矢量 (建造方向、功率、扫描速率、扫描间距、粉末尺寸、激光束直径和基板预热温度);  $N^1$  为预测上述参数对缺陷尺寸

影响的神经网络;  $\phi$  为变量矢量 (热处理温度和时间);  $N^2$  为预测微观结构强度参数的神经网络;  $w_C$  为每个输入变量的权重;  $b$  为神经元的偏差;  $\theta$  和  $\phi$  为潜在的变量。

由于 PINN 考虑了缺陷和微观组织对疲劳响应的综合作用, 因此展现出了更具鲁棒性的预测能力. 与实验疲劳寿命相比, 疲劳寿命预测值的平均误差

为 4%, 最大误差为 17%。

Chen 等<sup>[99]</sup> 基于融合物理信息的神经网络, 构建了考虑应力水平和应力比、工艺参数 (扫描速率、激光功率、层厚、扫描间距) 和后热处理参数 (热处理温度和时间) 影响的概率疲劳寿命预测模型, 如图 17(b) 所示。在神经网络中, 通过适当约束偏差和权重分配, 获得具有物理一致性曲率和非奇异方差的概率疲劳寿命 ( $P-S-N$ ) 关系。先验的物理约束包括: (1) 随着应力水平的降低, 疲劳寿命的离散性增加; (2) 随着应力水平的降低,  $S-N$  曲线的曲率减小; (3) 随着应力比的降低, 平均疲劳寿命增加。上述约束条件的表达式如下所示

$$\frac{\partial \sigma}{\partial S} \leq 0 \quad (8)$$

$$\frac{\partial^2 \mu}{\partial S^2} \geq 0 \quad (9)$$

$$\frac{\partial \mu}{\partial R} \leq 0 \quad (10)$$

式中,  $S$  为应力水平;  $\sigma$  为疲劳寿命的标准差;  $R$  为应力比;  $\mu$  为疲劳寿命的平均值。

Yu 等<sup>[100]</sup> 基于领域知识引导的符号回归 (symbolic regression, SR) 方法, 提出了一种考虑应力水平和缺陷几何特征 (尺寸、位置和形貌) 综合影响的 L-PBF AlSi10Mg 合金疲劳寿命预测模型。为了限制模型的搜索空间, 从考虑缺陷几何特征影响的 Murakami- $Z$  参数和  $X$  参数疲劳寿命经验模型中提取领域知识, 如下式所示

$$c \left[ \frac{2\sigma_a \sqrt{area}^{1/6}}{C(HV + 120)} \right]^m = N_f \quad (11)$$

$$c \left[ \gamma \sigma_a \sqrt{area}^{1/6} D^\beta \right]^m = N_f \quad (12)$$

$$c \left\{ \frac{\sigma_a \sqrt{area}^{1/6} D^\beta}{[area/(\pi L_{max}^2)]^\alpha} \right\}^m = N_f \quad (13)$$

式中,  $(area)^{1/2}$  为 Murakami 参数, 定义为缺陷在垂直于加载方向上的投影面积的平方根值;  $C$  为几何修正因子 (表面缺陷  $C = 1.41$ , 亚表面缺陷  $C = 1.43$ , 内部缺陷  $C = 1.56$ );  $HV$  为材料的维氏硬度;  $\gamma$  为形貌因子 (球形缺陷  $\gamma = 1$ , 二维面缺陷  $\gamma = 0.9$ );  $D$  为位置因子, 表达式为  $D = (d-l)/d$ , 其中  $l$  为缺陷质心至材料

表面的最短距离,  $d$  为试样的直径;  $L_{max}$  为缺陷投影面中心至轮廓的最大距离;  $c$ ,  $m$ ,  $\alpha$  和  $\beta$  均为拟合参数。

由上述经验模型发现,  $\sigma_a \cdot (area)^{1/2}$  为一种固定的搭配。此外, 缺陷几何参数之间呈现指数项相乘形式。基于这些发现可以指导 SR 模型的演变, 如图 17(c) 所示。与经验模型相比, 领域知识集成 SR 模型对不同应力比、生产批次、尺寸和取向的 L-PBF AlSi10Mg 试样均具有较高的预测精度, 对训练集以外的数据也具有较好的泛化能力。

最近, Wang 等<sup>[101]</sup> 充分利用物理模型和自适应 ML 模型在疲劳寿命预测中的优势, 建立了两种物理信息引导的混合 ML 模型, 对 Al-Mg4.5Mn, Ti-6.5Al-2Zr-Mo-V 和 12CrNi2 三种增材制造合金的疲劳寿命进行预测, 如图 17(d) 所示。对于第 1 类模型, 物理信息的引入是通过 Paris 模型对输入的缺陷几何特征进行初始运算, 然后将结果输入到自适应 ML 预测模型中。该框架将独立的 Paris 模型和自适应 ML 模型串行集成。对于第 2 类模型, 将 Paris 模型和自适应 ML 模型通过卡尔曼滤波器并行集成。尽管该集成模型的学习过程不受物理知识约束, 但它可以集成不同模型的信息, 兼具 Paris 模型和自适应 ML 模型的优点。研究表明, 与 SVM 相比, 串行物理引导的 ML 模型具有更好的预测精度; 而并行物理引导的 ML 模型则正好相反。

在实际工程应用中, 增材构件通常会承受变幅载荷的作用, 变幅载荷下构件的剩余寿命准确预测对于设计和维修均具有重要意义。然而, 无论是经验模型、概率模型还是 CDM 模型, 均无法同时提供令人满意的预测性能和实用性。因此, Gan 等<sup>[102]</sup> 提出了将数据驱动的 SR 模型与领域知识集成建模, 从多个半经验损伤模型中提取领域知识, 限制 SR 的搜索空间, 从而指导 SR 公式演变。首先基于 169 组疲劳实验数据 (包含部分增材数据) 挖掘两个加载步下的剩余寿命模型, 如下式所示。然后在半经验损伤模型的框架下将其扩展至更多加载步

$$\ln n_2 = \ln N_2 + g \left( \ln \left( 1 - \frac{n_1}{N_1} \right), \frac{\ln N_2}{\ln N_1}, \frac{\Delta \sigma_1}{\Delta \sigma_2}, V, r, e, 1 \right) \quad (14)$$

式中,  $\Delta \sigma_1$  和  $\Delta \sigma_2$  为两次加载的应力范围;  $N_1$  和  $N_2$  则为与  $\Delta \sigma_1$  和  $\Delta \sigma_2$  对应的疲劳寿命;  $n_1$  为  $\Delta \sigma_1$  下的循环周次;  $V$  为临界损伤, 在半经验损伤模型

中通常为 1;  $r$  和  $e$  用于表征材料对多步加载的敏感性.

与经验模型相比, 领域知识引导的 SR 模型预测精度更高. 一方面, 相较于传统的疲劳建模策略, 由于其数据驱动的自适应性, 可以生成更准确的模型. 另一方面, 由于模型中考虑了公式结构优化, 与纯粹基于数字回归的建模策略相比, 具有更好的推导可解释模型的能力.

在物理信息模型输出方面, 最近 Salvati 等<sup>[103]</sup> 在神经网络模型中引入了基于断裂力学的约束, 提出了一种基于 PINN 的增材制造 AlSi10Mg 合金缺陷特征-疲劳寿命的预测方法. 首先, 基于缺陷容限思想, 构建了考虑缺陷尺寸和位置影响的归一化疲劳寿命驱动力因子  $\delta K$ , 其表达式为

$$\delta K = \frac{\Delta K}{\Delta K_{th}} (HV + 120) = \frac{Y^* \Delta \sigma \sqrt{\pi \sqrt{area}}}{(\sqrt{area})^{1/3}} \quad (15)$$

式中,  $\Delta K$  为应力强度因子幅值;  $\Delta K_{th}$  为应力强度因子幅值门槛值;  $Y^*$  为几何修正系数, 表达式为

$$Y^* = \begin{cases} 0.197\,0 \\ 0.197\,0 \left( \frac{1}{2} + \frac{2}{\pi} \frac{h}{r} \right)^{1/4} \\ 0.180\,5 \end{cases} \quad (16)$$

式中,  $h$  为缺陷质心至材料表面的距离;  $r$  为缺陷的等效半径.

然后, 建立了  $\delta K$  与疲劳寿命  $N_f$  的关联关系, 并将其作为物理约束, 引入模型的损伤函数中. 总的损失函数  $L$  由以下两部分构成

$$L = w^{NN} L^{NN} + w^M L^M \quad (17)$$

式中,  $L^{NN}$  和  $L^M$  分别为神经网络和 PINN 物理分支的损失函数;  $w^{NN}$  和  $w^M$  分别为神经网络和 PINN 物理分支的权重.

融合线弹性断裂力学物理约束的神经网络, 集

成了半经验模型和机器学习模型, 对于小规模数据集展现出较好的预测能力.

针对电子束熔化成形 Ti-6Al-4V 合金和微区原位锻造复合电弧熔丝增材制造 Al-Mg4.5Mn 合金, Wang 等<sup>[104]</sup> 基于 PINN, 建立了增材制造缺陷几何特征与疲劳寿命的关联关系, 如图 17(e) 所示. 在损伤函数中引入了先验的缺陷几何特征对疲劳寿命的影响规律: (1) 疲劳寿命随着缺陷尺寸的增加而降低; (2) 疲劳寿命随着缺陷距材料表面距离的减小而降低; (3) 疲劳寿命随着缺陷形貌复杂度的增加而降低; (4) 随着应力幅值的降低, 疲劳寿命单调递减, 而当应力幅值降低至接近于疲劳极限时, 疲劳寿命随应力的变化趋势呈现出渐近性. 将上述物理知识表示为偏导数的形式, 如下式所示

$$\frac{\partial N_f}{\partial \sqrt{area}} < 0 \quad (18)$$

$$\frac{\partial N_f}{\partial h} > 0 \quad (19)$$

$$\frac{\partial N_f}{\partial Cir} > 0 \quad (20)$$

$$\frac{\partial N_f}{\partial \Delta \sigma} < 0 \quad (21)$$

$$\frac{\partial^2 N_f}{\partial \Delta \sigma^2} > 0 \quad (22)$$

式中,  $Cir$  为缺陷圆度.

结果表明, 融合了缺陷几何特征对疲劳寿命影响规律的神经网络模型, 对于小规模数据集, 也展现出了较高的预测精度和泛化能力. 此外, 该模型还具有进一步量化更多缺陷特征、残余应力和微观组织等对疲劳性能影响的潜力.

表 3 总结了机器学习在金属增材制造力学性能预测中的代表性研究成果. 具体的研究内容请详见表中标注的参考文献.

表 3 机器学习在增材制造合金材料力学行为预测中的应用概况

Table 3 Application of machine learning in predicting mechanical behavior of additively manufactured metallic alloys

| Materials                                | ML models      | Inputs                                                    | Outputs                                                        |
|------------------------------------------|----------------|-----------------------------------------------------------|----------------------------------------------------------------|
| inconel 718 <sup>[105]</sup>             | CNN            | thermal history                                           | ultimate tensile strength                                      |
| 17-4 PH stainless steel <sup>[106]</sup> | ANN            | grain size and shape features                             | ultimate tensile strength, yield strength, and fracture strain |
| Ti-6Al-4V <sup>[107]</sup>               | SNN, DNN, DLNN | strut length, strut diameter, and strut orientation angle | ultimate strength, elastic modulus, and specific strength      |



续表 3

| Materials                                                     | ML models           | Inputs                                                                  | Outputs                                         |
|---------------------------------------------------------------|---------------------|-------------------------------------------------------------------------|-------------------------------------------------|
| 316L stainless steel <sup>[108]</sup>                         | ridge regression,   | morphological and crystallographic features                             | yield strength                                  |
| Ti-6Al-4V <sup>[64]</sup>                                     | XGBoost, CNN        |                                                                         | microhardness, elastic-modulus, yield strength, |
|                                                               | NB, SVM,            | laser power, laser speed, scan hatch spacing, layer thickness,          |                                                 |
| AlSi10Mg <sup>[103]</sup>                                     | logistic regression | mean powder size, and laser energy                                      | ultimate tensile strength, and strain           |
|                                                               | PINN                | defect $\sqrt{area}$ , effective diameter, sphericity, and stress range | fatigue life                                    |
| Ti-6Al-4V <sup>[98]</sup>                                     | PGNN                | building orientation, input power, scan speed, hatch distance,          | fatigue life                                    |
|                                                               |                     | layer thickness, and heating platform temperature                       |                                                 |
| 316L stainless steel, Ti-6Al-4V and AlSi10Mg <sup>[109]</sup> | ANN, RF             | laser power, scan speed, hatch space, layer thickness, maximum          | fatigue life                                    |
|                                                               |                     | stress, and stress                                                      |                                                 |
| 316L stainless steel <sup>[110]</sup>                         | ANN, RF, SVM        | laser power, scan speed, hatch space, and layer thickness               | fatigue life                                    |
| 316L stainless steel <sup>[111]</sup>                         | GP                  | build orientation, heat treatment, surface roughness, density,          | fatigue life                                    |
|                                                               |                     | and stress level                                                        |                                                 |
| Ti-6Al-4V <sup>[112]</sup>                                    | DONN                | surface roughness, pore position, pore density, and pore size           | fatigue life                                    |
| TA2-TA15和TC4-TC11 <sup>[113]</sup>                            | RF                  | stress concentration factor, stress level, and stress ratio             | fatigue life                                    |

Note: CNN: convolutional neural network; DNN: deep neural network; SNN: spiking neural network; DLNN: deep learning neural network; PGNN: physics-guided neural networks and DONN: drop-out neural network

4 总结与展望

由此可见, 增材制造在高端装备主承力件中的广泛应用取决于制造可重复性、质量可靠性和性能可预测性. 例如, 在各向异性组织、广域分布缺陷、通体分布残余应力和复杂表面粗糙度等 4 大因素的影响下, 基于传统的解析解和经验解已经难以准确预测增材制造金属材料及结构的基本力学性能与疲劳断裂性能, 进而为增材构件的大批量生产和高可靠应用带来巨大挑战. 从这一点上来看, 机器学习方法为有效处理先进制造高维物理量之间的复杂非线性关系提供了契机, 在金属增材制造领域得到持续关注. 为此, 本文重点论述了机器学习在增材制造力学性能预测中的研究进展.

首先, 简述了常见的机器学习算法和通用的机器学习流程, 包括线性回归、支持向量机、随机森林、极限梯度提升和神经网络算法的基本原理与特点. 由于传统的数据驱动的机器学习在模型可解释性方面具有很大的局限性, 进一步提出了融合物理信息的机理驱动的机器学习. 常见的有 3 种集成方法, 包括物理信息模型输入、物理信息模型构建和物理信息模型输出. 然后, 概述了增材制造各向异性组织、广域内部缺陷、残余应力和粗糙度的形成原因与机器学习在这些特征预测中的应用现状. 重点介绍了机器学习在金属增材制造力学性能预测中的代表性研究结论. 在拉伸性能方面, 基于机器学习构建工艺-组织-拉伸性能的关联关系, 具体的研究主要分为 3 个方面: 工艺-性能建模、组织-性能建模和工

艺-组织-性能的集成建模. 而关于增材制造疲劳断裂性能预测研究主要分为两个方面: 数据驱动机器学习建模和机理驱动机器学习建模. 总体上看, 有关增材制造材料及构件的拉伸性能研究较为广泛, 重点在于获取微观组织和基本力学性能表现最优的工艺过程. 另外, 增材制造过程的特殊性导致了材料本身的复杂性, 加之在关键承力构件上应用的可能性, 有关其疲劳断裂性能成为近 10 年来的研究重点, 主要体现在目前国内外会议上更多疲劳断裂研究的大量报道与讨论. 尽管如此, 机器学习与增材制造的融合面临着以下挑战.

(1) 大规模高质量数据收集. 数据集的规模与质量对于确保模型的稳健性和准确挖掘物理量之间潜在的复杂关联关系至关重要. 然而, 疲劳数据的收集成本高且耗时长, 这无疑对构建大规模数据集提出了挑战, 也成为机器学习在疲劳性能预测中应用的主要障碍之一. 为此, 学者们提出了通过数据增强与扩容来提高训练样本数量的途径. 数据增强是指通过对原始训练数据进行一系列变换和修改, 生成新的训练样本, 从而扩展训练集的规模和多样性. 而数据扩充是指通过合成新的样本来扩展训练数据集, 不依赖于原始数据的变换, 而是利用一些外部数据或先验知识来生成新的样本.

(2) 物理机制标准化. 机理驱动的机器学习是一种新兴范式, 旨在利用先验知识指导机器学习建模, 以提高模型的可解释性. 为了构建机理驱动的机器学习模型, 需要提前掌握输入与目标变量之间隐含的物理机制, 以选取最为合适的物理知识. 对物理机

制的理解不准确,会使得模型的可解释性和物理一致性难以保证,从而直接影响物理变量之间关联关系的准确描述,降低模型的预测精度.因此,对于物理信息的模型输入、模型构建和模型输出,需要开发一种标准化方法来提取物理信息,以实现机理驱动模型准确构建.

(3) 增材制造构件力学性能建模. 基于机器学习的增材构件疲劳性能预测研究相对较少. 这是因为,一方面,为了训练机器学习模型,需要大规模的实验和模拟数据,而获取和标注足够数量和多样性的增材构件疲劳性能数据是一项挑战. 此外,疲劳性能受到各向异性组织、广域内部缺陷、深部残余应力和表面粗糙度等多因素耦合作用的影响,这增加了模型的复杂性,需要更灵活和适应性更强的机器学习模型. 未来亟待厘清多因素耦合作用下的疲劳失效机理,发展考虑多因素耦合影响、机理驱动的疲劳性能预测模型.

(4) 跨时空尺度的机器学习建模. 基于多时空尺度海量实验、理论解析和数值模拟数据,挖掘提炼不同尺度下材料变形机制与损伤演化机理,通过机理驱动的机器学习,在宏观与微观、短时与长效多个维度下建立增材制造材料工艺-组织-短时力学性能-长效服役性能的跨时空尺度映射关联,以解决目前金属增材制造疲劳裂纹扩展行为与疲劳寿命难准确预测这一难题,为增材构件在重大工程装备中安全可靠服役提供保障.

(5) 随着高端装备的快速发展,关键构件在高应变率、超高温和极低温等极端服役条件下的力学行为与性能衰变引发了广泛关注. 然而,这类极端服役环境下的材料实验耗时且昂贵. 而将先进的高通量实验表征技术与机器学习方法相结合,有助于提高数据集的收集和分析效率,成为研究热点课题. 进一步发展用于极端服役条件下的全场测量技术成为必然要求,如时空干涉仪、三维数字图像相关、基于同步辐射和中子源的原位力学装置等,可以有效地生成大量高保真数据. 将机器学习用于极端力学研究,将有助于更有效、更准确地表征材料的极端力学行为,从而为设计下一代极端服役下高端装备材料提供数据和理论支撑.

## 参 考 文 献

- 1 吴圣川, 胡雅楠, 杨冰等. 增材制造材料缺陷表征及结构完整性评定方法研究综述. *机械工程学报*, 2021, 57(22): 3-34 (Wu Shengchuan, Hu Yanan, Yang Bing, et al. Review on defect characterization and structural integrity assessment method of additively manufactured materials. *Journal of Mechanical Engineering*, 2021, 57(22): 3-34 (in Chinese))
- 2 卢秉恒. 增材制造技术——现状与未来. *中国机械工程*, 2020, 31(1): 19-23 (Lu Bingheng. Additive manufacturing——Current situation and future. *China Mechanical Engineering*, 2020, 31(1): 19-23 (in Chinese))
- 3 Tofail SAM, Koumoulos E, Bandyopadhyay A, et al. Additive manufacturing: scientific and technological challenges, market uptake and opportunities. *Materials Today*, 2018, 21(1): 22-37
- 4 刘伟, 李能, 周标等. 复杂结构与高性能材料增材制造技术进展. *机械工程学报*, 2019, 55(20): 128-151, 159 (Liu Wei, Li Neng, Zhou Biao, et al. Progress in additive manufacturing on complex structures and high-performance materials. *Journal of Mechanical Engineering*, 2019, 55(20): 128-151, 159 (in Chinese))
- 5 Wu ZK, Wu SC, Qian WJ, et al. Structural integrity issues of additively manufactured railway components progress and challenges. *Engineering Failure Analysis*, 2023, 149: 107265
- 6 Kim H, Cha M, Kim BC, et al. Maintenance framework for repairing partially damaged parts using 3D printing. *International Journal of Precision Engineering and Manufacturing*, 2019, 20(8): 1451-1464
- 7 顾冬冬, 张红梅, 陈洪宇等. 航空航天高性能金属材料构件激光增材制造. *中国激光*, 2020, 47(5): 32-55 (Gu Dongdong, Zhang Hongmei, Chen Hongyu, et al. Laser additive manufacturing of high-performance metallic aerospace components. *Chinese Journal of Lasers*, 2020, 47(5): 32-55 (in Chinese))
- 8 Edwards P, Ramulu M. Fatigue performance evaluation of selective laser melted Ti-6Al-4V. *Materials Science and Engineering A*, 2014, 598: 327-337
- 9 易敏, 常珂, 梁晨光等. 增材制造微结构演化及疲劳分散性计算. *力学学报*, 2021, 53(12): 3263-3273 (Yi Min, Chang Ke, Liang Chenguang, et al. Computational study of evolution and fatigue dispersity of microstructures by additive manufacturing. *Chinese Journal of Theoretical and Applied Mechanics*, 2021, 53(12): 3263-3273 (in Chinese))
- 10 敖晓辉, 刘检华, 夏焕雄等. 选择性激光熔化工艺的介-微观建模与仿真方法综述. *机械工程学报*, 2022, 58(5): 239-257 (Ao Xiaohui, Liu Jianhua, Xia Huanxiong, et al. A review of meso-micro modeling and simulation methods of selective laser melting process. *Journal of Mechanical Engineering*, 2022, 58(5): 239-257 (in Chinese))
- 11 廉艳平, 王潘丁, 高杰等. 金属增材制造若干关键力学问题研究进展. *力学进展*, 2021, 51(3): 648-701 (Lian Yanping, Wang Panding, Gao Jie, et al. Fundamental mechanics problems in metal additive manufacturing: A state-of-art review. *Advances in Mechanics*, 2021, 51(3): 648-701 (in Chinese))
- 12 温琦, 刘景麟, 孟祥晨等. 搅拌摩擦增材制造关键技术与装备发展. *焊接学报*, 2022, 43(6): 1-10, 113 (Wen Qi, Liu Jinglin, Meng Xiangchen, et al. Development in key technique and equipment of friction stir additive manufacturing. *Transactions of the China Welding Institution*, 2022, 43(6): 1-10, 113 (in Chinese))
- 13 Wang C, Tan XP, Tor SB, et al. Machine learning in additive manufacturing: State-of-the-art and perspectives. *Additive Manufacturing*, 2020, 36: 101538
- 14 Goh GD, Sing SL, Yeong WY. A review on machine learning in 3D printing: applications, potential, and challenges. *Artificial Intelligence Review*, 2021, 54(1): 63-94
- 15 DebRoy T, Mukherjee T, Wei HL, et al. Metallurgy, mechanistic

- models and machine learning in metal printing. *Nature Reviews Materials*, 2021, 6(1): 48-68
- 16 刘源, 魏世忠. 数据驱动的钢铁耐磨材料性能预测研究综述. *机械工程学报*, 2022, 58(10): 31-50 (Liu Yuan, Wei Shizhong. Review on data-driven method for property prediction of iron and steel wear-resistant materials. *Journal of Mechanical Engineering*, 2022, 58(10): 31-50 (in Chinese))
- 17 Suwardi A, Wang FK, Xue K, et al. Machine learning-driven biomaterials evolution. *Advanced Materials*, 2022, 34(1): 2102703
- 18 Tyanova S, Temu T, Sinitcyn P, et al. The Perseus computational platform for comprehensive analysis of (prote) omics data. *Nature Methods*, 2016, 13(9): 731-740
- 19 周永章, 陈烁, 张旗等. 大数据与数学地球科学研究进展——大数据与数学地球科学专题代序. *岩石学报*, 2018, 34(2): 255-263 (Zhou Yongzhang, Chen Shuo, Zhang Qi, et al. Advances and prospects of big data and mathematical geoscience. *Acta Petrologica Sinica*, 2018, 34(2): 255-263 (in Chinese))
- 20 Jung M, Reichstein M, Ciais P, et al. Recent decline in the global land evapotranspiration trend due to limited moisture supply. *Nature*, 2010, 467(7318): 951-954
- 21 Guo SH, Agarwal M, Cooper C, et al. Machine learning for metal additive manufacturing: Towards a physics-informed data-driven paradigm. *Journal of Manufacturing Systems*, 2022, 62: 145-163
- 22 Giam A, Chen F, Cai JX, et al. Factorial design analytics on effects of material parameter uncertainties in multiphysics modeling of additive manufacturing. *NPJ Computational Materials*, 2023, 9(1): 1-18
- 23 Zhan Y, Liu C, Zhang JJ, et al. Measurement of residual stress in laser additive manufacturing TC<sub>4</sub> titanium alloy with the laser ultrasonic technique. *Materials Science and Engineering A*, 2019, 762: 138093
- 24 Lee JA, Sagong MJ, Jung J, et al. Explainable machine learning for understanding and predicting geometry and defect types in Fe-Ni alloys fabricated by laser metal deposition additive manufacturing. *Journal of Materials Research and Technology*, 2023, 22: 413-423
- 25 Ding DH, He FY, Yuan L, et al. The first step towards intelligent wire arc additive manufacturing: An automatic bead modelling system using machine learning through industrial information integration. *Journal of Industrial Information Integration*, 2021, 23: 100218
- 26 师彬彬, 陈哲涵. 基于图像特征融合的粉末床缺陷检测方法. *航空学报*, 2021, 42(10): 427-438 (Shi Binbin, Chen Zhehan. Defect detection method of powder bed based on image feature fusion. *Acta Aeronautica et Astronautica Sinica*, 2021, 42(10): 427-438 (in Chinese))
- 27 Horñas J, Béal J, Homola P, et al. Modelling fatigue life prediction of additively manufactured Ti-6Al-4V samples using machine learning approach. *International Journal of Fatigue*, 2023, 169: 107483
- 28 Gui YW, Aoyagi K, Bian HK, et al. Detection, classification and prediction of internal defects from surface morphology data of metal parts fabricated by powder bed fusion type additive manufacturing using an electron beam. *Additive Manufacturing*, 2022, 54: 102736
- 29 Zhang ZW, Zhang YY, Wen YT, et al. Data-driven XGBoost model for maximum stress prediction of additive manufactured lattice structures. *Complex & Intelligent Systems*, 2023, 9(5): 5881-5892
- 30 Farias FWC, da Cruz Payão Filho J, Moraes e Oliveira VHP. Prediction of the interpass temperature of a wire arc additive manufactured wall: FEM simulations and artificial neural network. *Additive Manufacturing*, 2021, 48: 102387
- 31 Elhoone H, Zhang TY, Anwar M, et al. Cyber-based design for additive manufacturing using artificial neural networks for industry 4.0. *International Journal of Production Research*, 2020, 58(9): 2841-2861
- 32 Karniadakis GE, Kevrekidis IG, Lu L, et al. Physics-informed machine learning. *Nature Reviews Physics*, 2021, 3(6): 422-440
- 33 Wang HJ, Li B, Gong JG, et al. Machine learning-based fatigue life prediction of metal materials: Perspectives of physics-informed and data-driven hybrid methods. *Engineering Fracture Mechanics*, 2023, 284: 109242
- 34 Zhao L, Song LB, Macías Santos JG, et al. Review on the correlation between microstructure and mechanical performance for laser powder bed fusion AlSi10Mg. *Additive Manufacturing*, 2022, 56: 102914
- 35 Macías Santos JG, Douillard T, Zhao L, et al. Influence on microstructure, strength and ductility of build platform temperature during laser powder bed fusion of AlSi10Mg. *Acta Materialia*, 2020, 201: 231-243
- 36 Khanzadeh M, Chowdhury S, Tschopp MA, et al. In-situ monitoring of melt pool images for porosity prediction in directed energy deposition processes. *IIE Transactions*, 2019, 51(5): 437-455
- 37 Lee S, Peng J, Shin D, et al. Data analytics approach for melt-pool geometries in metal additive manufacturing. *Science and Technology of Advanced Materials*, 2019, 20(1): 972-978
- 38 Wang Z, Jiang C, Liu PW, et al. Uncertainty quantification and reduction in metal additive manufacturing. *NPJ Computational Materials*, 2020, 6(1): 1-10
- 39 Meng LB, Zhang J. Process design of laser powder bed fusion of stainless steel using a gaussian process-based machine learning model. *JOM*, 2020, 72(1): 420-428
- 40 Olleak A, Xi ZM. Calibration and validation framework for selective laser melting process based on multi-fidelity models and limited experiment data. *Journal of Mechanical Design*, 2020, 142(8): 081701
- 41 Ren Y, Wang Q. Gaussian-process based modeling and optimal control of melt-pool geometry in laser powder bed fusion. *Journal of Intelligent Manufacturing*, 2022, 33(8): 2239-2256
- 42 Wang Z, Liu PW, Xiao YH, et al. A data-driven approach for process optimization of metallic additive manufacturing under uncertainty. *Journal of Manufacturing Science and Engineering*, 2019, 141(8): 081004
- 43 Li J, Sage M, Guan X, et al. Machine learning-enabled competitive grain growth behavior study in directed energy deposition fabricated Ti-6Al-4V. *JOM*, 2020, 72(1): 458-464
- 44 Kats D, Wang ZD, Gan ZT, et al. A physics-informed machine learning method for predicting grain structure characteristics in directed energy deposition. *Computational Materials Science*, 2022, 202: 110958
- 45 Hong RC, Zhang L, Lifton J, et al. Artificial neural network-based geometry compensation to improve the printing accuracy of selective laser melting fabricated sub-millimetre overhang trusses. *Additive Manufacturing*, 2021, 37: 101594
- 46 Gan ZT, Li HY, Wolff SJ, et al. Data-driven microstructure and microhardness design in additive manufacturing using a self-organizing map. *Engineering*, 2019, 5(4): 730-735
- 47 Wu ZK, Wu SC, Bao JG, et al. The effect of defect population on the anisotropic fatigue resistance of AlSi10Mg alloy fabricated by laser powder bed fusion. *International Journal of Fatigue*, 2021, 151: 106317
- 48 Chen LQ, Yao XL, Xu P, et al. Rapid surface defect identification for additive manufacturing with in-situ point cloud processing and



- machine learning. *Virtual and Physical Prototyping*, 2021, 16(1): 50-67
- 49 Li R, Jin M, Paquit VC. Geometrical defect detection for additive manufacturing with machine learning models. *Materials & Design*, 2021, 206: 109726
- 50 Li R, Jin MZ, Pei ZR, et al. Geometrical defect detection on additive manufacturing parts with curvature feature and machine learning. *The International Journal of Advanced Manufacturing Technology*, 2022, 120(5): 3719-3729
- 51 Pandiyan V, Drissi-Daoudi R, Shevchik S, et al. Semi-supervised monitoring of laser powder bed fusion process based on acoustic emissions. *Virtual and Physical Prototyping*, 2021, 16(4): 481-497
- 52 Liu R, Liu S, Zhang XL. A physics-informed machine learning model for porosity analysis in laser powder bed fusion additive manufacturing. *The International Journal of Advanced Manufacturing Technology*, 2021, 113(7): 1943-1958
- 53 Zhang ER, Dao M, Karniadakis GE, et al. Analyses of internal structures and defects in materials using physics-informed neural networks. *Science Advances*, 2022, 8(7): eabk0644
- 54 Akbari P, Ogoke F, Kao NY, et al. MeltpoolNet: Melt pool characteristic prediction in metal additive manufacturing using machine learning. *Additive Manufacturing*, 2022, 55: 102817
- 55 Poudel A, Yasin MS, Ye J, et al. Feature-based volumetric defect classification in metal additive manufacturing. *Nature Communications*, 2022, 13(1): 1-12
- 56 Demir K, Zhang ZZ, Ben-Artzy A, et al. Laser scan strategy descriptor for defect prognosis in metal additive manufacturing using neural networks. *Journal of Manufacturing Processes*, 2021, 67: 628-634
- 57 Wang HJ, Li B, Xuan FZ. A dimensionally augmented and physics-informed machine learning for quality prediction of additively manufactured high-entropy alloy. *Journal of Materials Processing Technology*, 2022, 307: 117637
- 58 Xiong J, Zhang GJ, Hu JW, et al. Bead geometry prediction for robotic GMAW-based rapid manufacturing through a neural network and a second-order regression analysis. *Journal of Intelligent Manufacturing*, 2014, 25(1): 157-163
- 59 Popova E, Rodgers TM, Gong XY, et al. Process-structure linkages using a data science approach: Application to simulated additive manufacturing data. *Integrating Materials and Manufacturing Innovation*, 2017, 6(1): 54-68
- 60 Tapia G, Elwany AH, Sang H. Prediction of porosity in metal-based additive manufacturing using spatial Gaussian process models. *Additive Manufacturing*, 2016, 12: 282-290
- 61 元欣波, 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. *机械工程学报*, 2019, 55(15): 48-55 (Yuan Xinbo, Li Changpeng, Li Yang, et al. Machine learning algorithms on density prediction of electron beam selective melted parts. *Journal of Mechanical Engineering*, 2019, 55(15): 48-55 (in Chinese))
- 62 Liu Q, Wu HK, Paul MJ, et al. Machine-learning assisted laser powder bed fusion process optimization for AlSi10Mg: New microstructure description indices and fracture mechanisms. *Acta Materialia*, 2020, 201: 316-328
- 63 Shin DS, Lee CH, Kühn U, et al. Optimizing laser powder bed fusion of Ti-5Al-5V-5Mo-3Cr by artificial intelligence. *Journal of Alloys and Compounds*, 2021, 862: 158018
- 64 Liu S, Stebner AP, Kappes BB, et al. Machine learning for knowledge transfer across multiple metals additive manufacturing printers. *Additive Manufacturing*, 2021, 39: 101877
- 65 Wu Q, Mukherjee T, De A, et al. Residual stresses in wire-arc additive manufacturing—hierarchy of influential variables. *Additive Manufacturing*, 2020, 35: 101355
- 66 Hajializadeh F, Ince A. Integration of artificial neural network with finite element analysis for residual stress prediction of direct metal deposition process. *Materials Today Communications*, 2021, 27: 102197
- 67 Park HS, Nguyen DS, Le-Hong T, et al. Machine learning-based optimization of process parameters in selective laser melting for biomedical applications. *Journal of Intelligent Manufacturing*, 2022, 33(6): 1843-1858
- 68 Rankouhi B, Jahani S, Pfefferkorn FE, et al. Compositional grading of a 316L-Cu multi-material part using machine learning for the determination of selective laser melting process parameters. *Additive Manufacturing*, 2021, 38: 101836
- 69 Khorasani AM, Gibson I, Ghasemi A, et al. Modelling of laser powder bed fusion process and analysing the effective parameters on surface characteristics of Ti-6Al-4V. *International Journal of Mechanical Sciences*, 2020, 168: 105299
- 70 Xia CY, Pan ZX, Polden J, et al. Modelling and prediction of surface roughness in wire arc additive manufacturing using machine learning. *Journal of Intelligent Manufacturing*, 2022, 33(5): 1467-1482
- 71 Özel T, Altay A, Kaftanoğlu B, et al. Focus variation measurement and prediction of surface texture parameters using machine learning in laser powder bed fusion. *Journal of Manufacturing Science and Engineering*, 2020, 142(1): 011008
- 72 Hertlein N, Deshpande S, Venugopal V, et al. Prediction of selective laser melting part quality using hybrid Bayesian network. *Additive Manufacturing*, 2020, 32: 101089
- 73 Yadollahi A, Shamsaei N. Additive manufacturing of fatigue resistant materials: Challenges and opportunities. *International Journal of Fatigue*, 2017, 98: 14-31
- 74 杨天雨, 张鹏林, 尹燕等. 激光选区熔化组织分析及人工神经网络力学性能预测. *焊接学报*, 2019, 40(6): 100-106, 165-166 (Yang Tianyu, Zhang Penglin, Yin Yan, et al. Microstructure based on selective laser melting and mechanical properties prediction through artificial neural net. *Transactions of the China Welding Institution*, 2019, 40(6): 100-106, 165-166 (in Chinese))
- 75 Li JC, Cao LC, Hu JX, et al. A prediction approach of SLM based on the ensemble of metamodels considering material efficiency, energy consumption, and tensile strength. *Journal of Intelligent Manufacturing*, 2022, 33(3): 687-702
- 76 Huang DJ, Li H. A machine learning guided investigation of quality repeatability in metal laser powder bed fusion additive manufacturing. *Materials & Design*, 2021, 203: 109606
- 77 Sanchez S, Rengasamy D, Hyde CJ, et al. Machine learning to determine the main factors affecting creep rates in laser powder bed fusion. *Journal of Intelligent Manufacturing*, 2021, 32(8): 2353-2373
- 78 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. *Materials Science and Engineering A*, 2020, 787: 139549
- 79 Muhammad W, Brahme AP, Ibragimova O, et al. A machine learning framework to predict local strain distribution and the evolution of plastic anisotropy & fracture in additively manufactured alloys. *International Journal of Plasticity*, 2021, 136: 102867
- 80 Hu E, Seetoh IP, Lai CQ. Machine learning assisted investigation of defect influence on the mechanical properties of additively manufactured architected materials. *International Journal of Mechanical Sciences*, 2022, 221: 107190
- 81 Yan F, Chan YC, Saboo A, et al. Data-driven prediction of mech-

- anical properties in support of rapid certification of additively manufactured alloys. *Computer Modeling in Engineering & Sciences*, 2018, 117(3): 343-366
- 82 Dan CY, Cui YC, Wu Y, et al. Achieving ultrahigh fatigue resistance in AlSi10Mg alloy by additive manufacturing. *Nature Materials*, 2023, 22: 1182-1188
- 83 Zerbst U, Bruno G, Buffiere JY, et al. Damage tolerant design of additively manufactured metallic components subjected to cyclic loading: State of the art and challenges. *Progress in Materials Science*, 2021, 121: 100786
- 84 轩福贞, 朱明亮, 王国彪. 结构疲劳百年研究的回顾与展望. 机械工程学报, 2021, 57(6): 25-61 (Xuan Fuzhen, Zhu Mingliang, Wang Guobiao. Retrospect and prospect on century-long research of structural fatigue. *Journal of Mechanical Engineering*, 2021, 57(6): 25-61 (in Chinese))
- 85 Mortazavi SNS, Ince A. An artificial neural network modeling approach for short and long fatigue crack propagation. *Computational Materials Science*, 2020, 185: 109962
- 86 Himmiche S, Mortazavi SNS, Ince A. Comparative study of neural network-based models for fatigue crack growth predictions of short cracks. *Journal of Peridynamics and Nonlocal Modeling*, 2022, 4(4): 501-526
- 87 Zhang M, Sun CN, Zhang X, et al. High cycle fatigue life prediction of laser additive manufactured stainless steel: A machine learning approach. *International Journal of Fatigue*, 2019, 128: 105194
- 88 Vassilopoulos AP, Bedi R. Adaptive neuro-fuzzy inference system in modelling fatigue life of multidirectional composite laminates. *Computational Materials Science*, 2008, 43(4): 1086-1093
- 89 Luo YW, 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. *Materials Science and Engineering A*, 2021, 802: 140693
- 90 Bao HXY, Wu SC, Wu ZK, et al. A machine-learning fatigue life prediction approach of additively manufactured metals. *Engineering Fracture Mechanics*, 2021, 242: 107508
- 91 Li J, Yang ZM, Qian GA, et al. Machine learning based very-high-cycle fatigue life prediction of Ti-6Al-4V alloy fabricated by selective laser melting. *International Journal of Fatigue*, 2022, 158: 106764
- 92 Shi T, Sun JY, Li JH, et al. Machine learning based very-high-cycle fatigue life prediction of AlSi10Mg alloy fabricated by selective laser melting. *International Journal of Fatigue*, 2023, 171: 107585
- 93 Peng X, Wu SC, Qian WJ, et al. The potency of defects on fatigue of additively manufactured metals. *International Journal of Mechanical Sciences*, 2022, 221: 107185
- 94 Li AY, Baig S, Shao S, et al. Defect criticality analysis on fatigue life of L-PBF 17-4 PH stainless steel via machine learning. *International Journal of Fatigue*, 2022, 163: 107018
- 95 Cutolo A, Lammens N, Boer KV, et al. Fatigue life prediction of a L-PBF component in Ti-6Al-4V using sample data, FE-based simulations and machine learning. *International Journal of Fatigue*, 2023, 167: 107276
- 96 Zhan ZX, Ao N, Hu YN, et al. Defect-induced fatigue scattering and assessment of additively manufactured 300M-AerMet100 steel: An investigation based on experiments and machine learning. *Engineering Fracture Mechanics*, 2022, 264: 108352
- 97 Wang HJ, Li B, Xuan FZ. Fatigue-life prediction of additively manufactured metals by continuous damage mechanics (CDM)-informed machine learning with sensitive features. *International Journal of Fatigue*, 2022, 164: 107147
- 98 Ciampaglia A, Tridello A, Paolino DS, et al. Data driven method for predicting the effect of process parameters on the fatigue response of additively manufactured AlSi10Mg parts. *International Journal of Fatigue*, 2023, 170: 107500
- 99 Chen J, Liu Y. Fatigue property prediction of additively manufactured Ti-6Al-4V using probabilistic physics-guided learning. *Additive Manufacturing*, 2021, 39: 101876
- 100 Yu H, Hu YN, Kang GZ, et al. High-cycle fatigue life prediction of L-PBF AlSi10Mg alloys: A domain knowledge-guided symbolic regression approach. *Philosophical Transactions of the Royal Society A*, 2023, 381: 20220383
- 101 Wang LY, Zhu SP, Luo CQ, et al. Physics-guided machine learning frameworks for fatigue life prediction of AM materials. *International Journal of Fatigue*, 2023, 172: 107658
- 102 Gan L, Wu H, Zhong Z. Integration of symbolic regression and domain knowledge for interpretable modeling of remaining fatigue life under multistep loading. *International Journal of Fatigue*, 2022, 161: 106889
- 103 Salvati E, Tognan A, Laurenti L, et al. A defect-based physics-informed machine learning framework for fatigue finite life prediction in additive manufacturing. *Materials & Design*, 2022, 222: 111089
- 104 Wang LY, Zhu SP, Luo CQ, et al. Defect driven physics-informed neural network framework for fatigue life prediction of additively manufactured materials. *Philosophical Transactions of the Royal Society A*, 2023, 381(2260): 20220386
- 105 Xie XY, Bennett J, Saha S, et al. Mechanistic data-driven prediction of as-built mechanical properties in metal additive manufacturing. *NPJ Computational Materials*, 2021, 7(1): 1-12
- 106 Porro M, Zhang B, Parmar A, et al. Data-driven modeling of mechanical properties for 17-4 PH stainless steel built by additive manufacturing. *Integrating Materials and Manufacturing Innovation*, 2022, 11(2): 241-255
- 107 Hassanin H, Alkendi Y, Elsayed M, et al. Controlling the properties of additively manufactured cellular structures using machine learning approaches. *Advanced Engineering Materials*, 2020, 22(3): 1901338
- 108 Herriott C, Spear AD. Predicting microstructure-dependent mechanical properties in additively manufactured metals with machine- and deep-learning methods. *Computational Materials Science*, 2020, 175: 109599
- 109 Zhan ZX, Li H. A novel approach based on the elastoplastic fatigue damage and machine learning models for life prediction of aerospace alloy parts fabricated by additive manufacturing. *International Journal of Fatigue*, 2021, 145: 106089
- 110 Zhan ZX, Li H. Machine learning based fatigue life prediction with effects of additive manufacturing process parameters for printed SS 316L. *International Journal of Fatigue*, 2021, 142: 105941
- 111 Elangeswaran C, Cutolo A, Gallas S, et al. Predicting fatigue life of metal LPBF components by combining a large fatigue database for different sample conditions with novel simulation strategies. *Additive Manufacturing*, 2022, 50: 102570
- 112 Moon S, Ma RM, 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. *Scientific Reports*, 2021, 11(1): 20424
- 113 Zhan ZX, Hu WP, Meng QC. Data-driven fatigue life prediction in additively manufactured titanium alloy: A damage mechanics based machine learning framework. *Engineering Fracture Mechanics*, 2021, 252: 107850