

# 机器学习在粉末冶金中的应用研究

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

**摘要:** 粉末冶金是实现金属构件高性能近净成形的重要技术, 其应用范围涵盖航空航天、生物医疗、汽车制造等高端领域。然而, 粉末冶金涉及的材料体系复杂、工艺参数众多, 材料成分—工艺—组织—性能之间的关系呈现典型的高维非线性特征, 传统的试错法研发模式效率低下且难以实现工艺窗口的精准控制。机器学习作为人工智能的核心技术, 为粉末冶金领域的成分设计、过程控制和性能预测提供了数据驱动的新范式。本文系统综述了机器学习在粉末冶金中的应用研究进展, 从粉末原材料表征、成形过程建模与优化、构件质量预测与控制三个维度梳理了典型应用场景, 分析了监督学习、无监督学习、深度学习等算法在其中的适用性与优势, 深入讨论了数据稀疏性、模型可解释性、跨场景泛化能力等当前面临的挑战, 并展望了物理信息机器学习、多目标优化、数字孪生等未来发展方向。研究表明, 机器学习能够有效挖掘粉末冶金过程中的高维非线性关系, 与粉末冶金知识的深度融合将是推动该领域智能化发展的关键路径。

**关键词:** 粉末冶金; 机器学习; 成分设计; 过程控制; 性能预测; 深度学习

## 一、引言

粉末冶金是一种以金属粉末为原料, 通过成形和烧结制备高性能构件的先进制造技术。与传统的铸造和加工相比, 粉末冶金能够实现复杂几何形状的近净成形, 材料利用率高, 且可制备传统工艺难以加工的合金体系, 如高熔点金属、难互溶合金、金属基复合材料<sup>[1]</sup>。基于这些优势, 粉末冶金技术在航空航天发动机热端部件、生物医用植入体、汽车结构件、模具制造等高端领域占据着不可替代的战略地位<sup>[6]</sup>。尽管粉末冶金技术已取得长足进步, 但其过程机理的复杂性仍是制约工艺优化和质量控制

的核心瓶颈。粉末冶金过程涉及从微观到宏观的多尺度物理化学现象<sup>[3]</sup>: 在粉末尺度上, 原料粉末的粒度分布、颗粒形貌、球形度、流动性等特性直接影响铺粉均匀性和堆积密度<sup>[4]</sup>; 在成形尺度上, 其中涉及传热、传质、流体流动、相变等复杂物理过程<sup>[6]</sup>; 在制件尺度上, 逐层凝固轨迹构成了最终的复杂构件, 涉及热应力累积、变形开裂、孔隙形成、微观组织演变等多重问题<sup>[3]</sup>。这一多尺度过程的复杂性导致粉末冶金研究面临以下挑战: 第一, 高维参数空间的优化困难, 参数间的交互作用复杂, 传统的单因素实验设计或正交实验设计难以穷举最优组合<sup>[8]</sup>; 第二,

过程—组织—性能映射关系的非线性特征显著，传统的经验公式和统计模型难以准确描述这种复杂关系<sup>[1]</sup>；第三，实验成本高、周期长，特别是对于高温合金、难熔金属等昂贵材料，大量试错的研发模式在经济上不可行<sup>[10]</sup>；第四，实时监测与闭环控制的挑战，传统的离线质量检测只能在过程完成后发现问题，无法实现实时调控<sup>[3]</sup>。

近年来，人工智能技术的快速发展为材料科学与工程领域带来了新的方法论突破。机器学习作为人工智能的核心技术，已经广泛应用于自然语言处理、生物、医药等多个领域。能够从高维数据中自动学习隐含规律和复杂映射关系，在材料成分设计、工艺参数优化、缺陷智能检测等方向展现出显著潜力<sup>[6]</sup>。从方法论角度，粉末冶金中常用的机器学习算法可分为监督学习、无监督学习、深度学习和强化学习等几大类，其中监督学习用于建立输入特征与输出标签之间的映射关系，是最常用的方法<sup>[8]</sup>；无监督学习用于发现数据中的内在结构和模式<sup>[7]</sup>；深度学习通过多层神经网络结构自动提取数据的层次化特征，在处理图像、序列等高维数据时表现优异；强化学习通过智能体与环境的交互学习最优决策策略，在工艺参数自适应控制等场景具有潜在应用价值。粉末冶金领域的过程监测系统 and 数据采集技术日益完善，为机器学习算法的应用提供了数据基础。

本研究深入探讨机器学习在粉末冶金技术中的多方面应用。既分析如何结合材料科学知识，精准选择相关参数以构建高效的机器学习模型，又详细论述机器学习在预测粉末冶金构件中冶金缺陷和性能方面的应用，涵盖孔隙、裂纹缺陷的预测以及构件的力学性能预测，并进一步阐述粉末冶金过程中原位监控与实时预测技术的集成与优化。此外，还系统梳理机器学习在粉末冶金中的研究现状，分析典型应用场景中的算法选择策略，探讨当前面临的挑战和未来发展方向，对于推动该领域的智能化转型具有重要的理论和实践意义。

## 二、机器学习在粉末原材料表征与材料设计中的应用

### 2.1 粉末原材料的精准表征

粉末原料的特性直接决定后续成形工艺的稳定性 and

最终制件的质量。研究表明，粉末颗粒的形态特征对铺粉均匀性、堆积密度乃至熔池动力学行为均有显著影响<sup>[5]</sup>。粉末的流动性和堆积密度决定了粉床的均匀性和致密度，球形度高的粉末颗粒具有更好的流动性和更高的堆积密度，能够形成均匀的粉层，而异形颗粒、卫星球、粘连颗粒可能导致铺粉缺陷和局部密度不均<sup>[4]</sup>。因此，建立粉末原料的精准表征方法，量化粉末颗粒的形态特征和统计分布，对于粉末质量评价、工艺窗口设计以及粉末循环利用评估具有重要意义。传统的粉末颗粒表征主要依赖激光衍射法和扫描电子显微镜结合人工观察，激光衍射法能够快速获得粉末的粒径统计信息但无法提供单个颗粒的形貌特征，SEM 观察可以获得高分辨率的颗粒图像但传统的数据处理方式存在明显局限性：传统的数字图像处理方法在处理颗粒粘连、卫星球、重叠颗粒等情况时精度有限；形貌特征的多维性和统计分布特征尚未得到充分利用；高通量分析的缺失导致无法充分捕捉粉末批次内的颗粒异质性和分布特征。深度学习特别是实例分割算法的发展，为粉末显微图像的自动化分析提供了强大的工具。华中农业大学<sup>[9]</sup>研究提出了一种基于深度学习实例分割的金属粉末微观结构自动表征方法，采用多种实例分割模型对镍基高温合金粉末的扫描电镜图像进行对比研究，实验结果表明，YOLOv9-seg 模型在复杂颗粒分布条件下具有更好的分割性能和边界识别能力，在测试数据集上获得超过 95% 的 F1-score，这一结果体现了单阶段目标检测算法在密集颗粒场景下的优势，与两阶段模型相比，YOLO 系列算法采用端到端的检测范式能够更好地处理颗粒粘连和重叠情况，边界识别更为精确。另一项研究探索了基于机器学习技术的粉末颗粒分类方法<sup>[4]</sup>，以 316L、AlSiMg 和 TiAlV 三种增材制造常用粉末为对象，开发了结合图像处理和机器学习的自动化分类流程，研究首先应用霍夫圆变换检测 SEM 图像中的颗粒，然后采用主成分分析提取关键特征并降低数据维度，将这些特征转换为表征颗粒特性的向量，评估了多种分类器在颗粒分类中的表现。

监督学习方法依赖于标注数据进行训练而标注过程本身仍需人工参与，无监督学习方法则能够直接从数据中学习内在结构无需标注信息，为实现完全自动化的粉末形

貌分析提供了新途径。Akeweje 等<sup>[7]</sup>开发了一种耦合高通量成像与形状特征提取及聚类的自动化框架，用于规模化分析金属粉末形貌，基于约 126,000 张 316L 不锈钢粉末图像构建数据集，评估了自编码器流程、形状描述符流程和函数数据分析流程三种聚类流程的性能，通过内部效率指标的评估发现傅里叶描述子结合 K-means 聚类的方案效果最优，在标准工作站上可实现亚毫秒级的单颗粒处理速度，为高通量粉末形貌分析提供了可行的技术方案。该研究的创新之处在于实现了完全无监督的粉末形貌分析无需任何人工标注适合大规模工业应用，建立的形状聚类框架为后续研究粉末形貌与流动性、堆积密度以及 SLM 制件质量之间的关系奠定了基础，同时支持跟踪粉末在多次循环使用过程中的形貌演变为粉末循环利用评估提供了量化工具。粉末冶金的前端环节是粉末制备包括雾化法、还原法、机械合金化等多种工艺，粉末制备过程的稳定性直接影响最终粉末的质量一致性，机器学习方法为粉末制备过程的在线质量预测提供了新的可能性。隆德大学的研究者<sup>[2]</sup>针对还原退火过程中的金属粉末质量预测问题开展了系统的研究，利用监督学习方法基于工业炉的时间序列过程数据预测还原退火后金属粉末的六项目标特性包括三项粒度分布参数、两项化学成分特性和一项密度指标，研究探索并实现了多类机器学习方法包括线性方法以弹性网络为代表、基于树的集成方法包括随机森林、梯度提升决策树、XGBoost 等、序列模型主要是长短时记忆网络，系统地调整了各模型的超参数以寻找最佳配置并采用交叉验证评估模型性能。结果显示不同目标变量的最佳预测模型有所差异没有单一模型在所有任务上完全占优，总体而言 LSTM、XGBoost 和弹性网络表现最为突出成功实现了对粉末特性的合理预测。利用 SHAP 分析方法研究者<sup>[2]</sup>识别出对各输出变量影响最显著的特征，一方面帮助理解模型的决策机制增强对模型预测的信任，另一方面揭示了还原退火过程中影响粉末质量的关键过程变量为工艺改进提供了方向。该研究建立了基于时间序列过程数据的预测框架可以推广到其他粉末制备工艺，通过 SHAP 分析提升了模型的可解释性为工业应用扫除了部分信任障碍。

## 2.2 合金成分智能设计与优化

在粉末冶金材料研发领域，合金成分的优化设计是决定材料最终性能的关键环节。传统的“试错法”依赖大量实验，研发周期长且成本高昂。机器学习因其广泛适用性被全面应用于材料研究领域。采用机器学习方法不仅能帮助研究人员高效处理海量数据，还可识别人类大脑无法识别的多维参数空间，并即时获取关键信息。在材料科学中，机器学习最广泛的应用是材料性能预测。此外，将机器学习与理论计算方法相结合可加速材料理论模拟的研究进展。在材料设计相关的机器学习研究中，数据集获取与特征筛选是准确预测材料性能并成功获得理想成分设计方案的关键步骤。这些工作需基于高效的数据构建或采集过程，并对多重影响因素进行精准分析。机器学习技术的引入为合金设计提供了全新的方法论。通过建立成分与性能之间的非线性映射关系，研究者能够从高维成分空间中快速筛选出具有潜在优异性能的合金体系。Si 等<sup>[11]</sup>通过随机森林回归筛选出离子半径、剪切模量差异和电负性差异作为影响 Zr-Ti-Nb-O 固溶体合金强度的关键特征，建立了考虑置换固溶和间隙固溶协同作用的强化模型。Fan 等<sup>[12]</sup>采用随机森林回归识别影响 Ti-Zr-Nb 合金动态压缩断裂应变的关键特征，通过穷举筛选确定 VEC、热导率  $\lambda$  和剪切模量差异  $\Delta G$  三个特征，模型预测精度达 82%。Xu 等<sup>[13]</sup>采用实验反馈迭代策略设计 Cu-Al-Fe-Ni 合金，仅用 75 条二元和三元数据构建 ML 模型，通过多目标综合指数引导搜索，6 轮迭代发现性能优于传统合金的新材料。基于随机森林、支持向量机等算法，可以识别影响材料性能的关键特征参数，揭示微量合金元素的存在形式与强化机制。实验反馈迭代策略的采用，使得在小样本条件下仍能通过多轮优化逼近最优成分区间，显著提升研发效率。这种数据驱动的设计模式不仅加速了新材料发现进程，也为多主元合金、固溶体合金等复杂体系的成分调控提供了理论依据。




图1 机器学习与实验反馈流程在合金成分智能设计与优化的应用框架。流程可归纳为：数据库构建；模型选择；特征筛选；关系建立<sup>[12][13]</sup>。

## 2.3 相形成与组织预测

粉末冶金材料的相组成和微观组织直接决定了其服役性能，然而相形成的热力学与动力学机制复杂，传统实验表征方法难以全面捕捉。机器学习方法通过学习已有实验数据中的隐含规律，能够建立成分—工艺—相组成的预测模型。对于多主元合金、高温合金等复杂体系，仅需少量关键描述符即可实现固溶体、金属间化合物及非晶相等不同相态的准确分类。机器学习对多电子体系（MEA）中生成相态进行预测与密度泛函理论和卡方法计算相比，该方法显著降低了计算成本与时间消耗。该领域首项研究由Islam等人采用神经网络架构对包含118个实例（CCAs）的数据集进行相态预测。尽管预测准确率达83%，但由于数据集规模较小，仍存在过拟合问题。此外利用k最近邻算法（KNN）、人工神经网络（ANN）、支持向量机及自组织映射技术，基于Miracle和Senkov提供的401个高电子体系数据集，预测了固态相、中间相及固态相+中间相混合相态。为了实现高效的相预测，寻找MEA中相的独立描述符变得至关重要。通过粉末冶金（PM）路线

验证MEA相预测的研究较少，Das & Pandey等<sup>[14]</sup>采用ANN、KNN和随机森林算法预测中熵合金的相组成（SS、SS+IM、AM），ANN模型表现最优（准确率87.3%），发现 $\Delta H_{mix}$ 、 $\delta$ 和 $\Lambda$ 三个特征足以实现相分类，提供了一个包含实验数据的最新MEA数据库。此外，机器学习（ML）已成为加速高温合金成分设计的有效工具。但现有数据集构建方法普遍存在数据质量参差不齐、初始成本高昂等问题。为解决这些局限，研究者开发了相图计算与机器学习相结合的协同策略，该策略具有低成本获取稳定数据的优势。因此，机器学习辅助设计为实现粉末冶金高温合金的瞬态液相烧结提供了极具前景的解决方案，通过将遗传算法与神经网络相结合，可以反向设计合金组分以调控微观组织特征。Wu等<sup>[15]</sup>采用遗传算法结合人工神经网络将高温合金拆分为低熔点和高温点组分，通过二元成分分离策略实现瞬态微液相烧结，消除原始颗粒边界缺陷。这种智能化的相预测方法不仅加深了对合金相稳定性的理解，也为避免有害相生成、优化组织均匀性提供了有效工具。




图2 机器学习遗传算法在相形成与组织预测的应用框架<sup>[15]</sup> (a) (b) (c) ; 合金相 (d) (e) ; 遗传算法曲线 (f, g)。

## 2.4 烧结密度预测与材料物性关联

烧结密度受到粉末特性、烧结工艺及材料本征物性的多因素耦合影响，传统烧结理论模型往往难以复现这种复杂关联。机器学习技术通过整合粉末粒度分布、烧结温度曲线、保温时间工艺参数，以及元素熔点、弹性模量、电负性等本征物性，构建了高精度的烧结密度预测模型。MSC 模型在烧结早期阶段对烧结密度的预测能力明显略逊与中后期烧结阶段，这是由于原始 MSC 模型忽略早期阶段表面能与表面扩散效应，而多层感知器（MLP）能够很好的预测合金的烧结密度，同时前馈反向传播网络在预测合金的烧结非线性行为与显微硬度方面具有优异性能。

多层感知机等算法在跨材料体系的小样本条件下仍能实现可靠预测，最大预测误差可控制在极小范围内。Liu 等<sup>[16]</sup>采用 MLP 神经网络预测 W(Mo) 二元合金烧结密度，从粉末粒度、工艺参数和元素物性中提取 36 个描述符，通过 RFE 筛选 9 个关键特征，预测误差小于 0.063。Deng 等<sup>[17]</sup>采用 MLP 模型预测多类粉末冶金合金的烧结密度，引入相变体积变化、液相体积、溶解度比等热力学描述符，对 Cu-9Al 合金预测误差仅 0.7%。更重要的是，通过特征重要性分析，可以定量评估各因素对烧结密度的贡献程度，从而为烧结工艺优化和粉末原料选择提供数据支撑，推动粉末冶金从经验调控走向精准设计。




图3 合金密度烧结的机器学习工作框架框架<sup>[16]</sup>；皮尔逊相关系数矩阵（a，b）；烧结密度预测值与实际值对比（c）<sup>[17]</sup>。

### 三、机器学习在成形过程建模与参数优化中的应用

#### 3.1 成形过程建模

粉末冶金成形过程涉及复杂的多物理场耦合现象，工艺参数的微小变化可能导致温度场分布和凝固行为的显著改变进而影响制件的微观组织和最终性能。粉末冶金成形过程涉及粉末颗粒的重排、变形与致密化，其动力学行为受压制压力、烧结温度、保温时间等多参数非线性耦合影响。机器学习与物理模型的融合为解决这一难题提供了新途径。通过半监督学习框架分析瞬时加工硬化指数的变化规律，可以揭示不同变形阶段的机制转变。Kamal等<sup>[18]</sup>采用 Gurson 模型有限元模拟结合半监督机器学习框架，分析 Cu-15Ni-8Sn 合金压制烧结-锻造过程中高径比对压缩变形各向异性的影响，揭示三个不同加工硬化阶段。Huang等<sup>[19]</sup>采用 RBF-ANN 机器学习方法预测 BCC/B2 结构  $\text{Al}_{1.8}\text{CrCuFeNi}_2$  高熵合金热变形流变应力， $R^2$  达 0.9856，显著优于传统 Arrhenius 本构模型（ $R^2=0.9567$ ）。

结合 Gurson 损伤模型与数据驱动方法，能够有效预测压制—烧结一体化工艺中几何参数对致密化行为的影响。这种混合建模策略不仅提升了过程仿真的精度，也为复杂形状零件的近净成形工艺设计提供了理论指导。

在 LPBF 过程中，熔池是零件成形的基本单元，熔池的几何形态与最终制件质量密切相关，熔池宽度、深度、长度以及熔池的稳定性直接影响熔道连续性、层间结合质量以及孔隙缺陷的形成，研究表明过浅的熔池可能导致层间熔合不足而过深的熔池则可能引发匙孔孔隙，因此建立工艺参数与熔池形态之间的定量关系对于 LPBF 过程的监测和控制具有重要意义。西安交通大学的研究团队<sup>[1]</sup>针对 LPBF 过程中工艺参数与熔池尺寸的关联建模问题提出了一种双向预测框架，该研究首先从已发表的文献中广泛收集数据构建了一个包含 218 个数据点的高质量数据集，每个数据点涵盖激光功率、扫描速度、层厚、扫描间距、光束直径、能量密度、材料类型及热物理性能参数以及对应条件下形成的熔池宽度和深度，该数据集规模是典型单道正交实验数据量的五倍以上有效缓解了因数据量有限

而导致的机器学习模型性能不佳问题。在此基础上研究者提出了一种集成十种机器学习回归算法的双向预测框架,在正向预测任务中以工艺参数和材料性能为输入预测熔池宽度和深度,在反向预测任务中以期望的熔池尺寸为输入预测所需的激光功率和扫描速度,研究系统比较了十种

算法的表现包括线性回归、决策树、随机森林、梯度提升、支持向量机、神经网络等,结果显示最优模型在测试集上的预测精度超过 96%,这一高精度验证了机器学习在建立工艺参数—熔池尺寸关联方面的有效性。




图 4 机器学习建模框架及随机森林分类<sup>[18]</sup>; 随机森林模型的准确率 (a); AR 预测结果 (b, c, d)

### 3.2 工艺参数多目标优化

粉末冶金产品的性能往往涉及多个相互制约的指标,如强度与塑性、硬度与韧性、摩擦系数与磨损率等。传统响应曲面法在处理非线性、高维参数空间时存在局限性。机器学习方法通过构建工艺参数与多性能指标之间的映射模型,结合网格搜索、随机搜索、贝叶斯优化等智能算法,可以在全局范围内快速寻找 Pareto 最优解集。基于机器学习的优化方法在预测精度和搜索效率上均优于传统统计方法,尤其适用于实验数据有限的研究场景。Wen 等<sup>[20]</sup>采用 AdaBoost 算法预测 TiB<sub>2</sub>/B<sub>4</sub>C 双陶瓷改性铜基摩擦材料的摩擦系数和稳定性系数,预测精度分别达 0.9993 和 0.8739,识别扭矩和制动速度为关键影响因素。Surya 等<sup>[21]</sup>综合采用 RSM、网格搜索、随机搜索和贝叶斯优化对 Al7075/TiC 复合材料摩擦性能进行优化,贝叶斯优化效率最高,识别出 TiC 含量为最显著影响因素(贡献率 59%)。Samad 等<sup>[22]</sup>对比 RSM 和多种 ML 模型在 Cu-TiC-GNP 纳米复合材料性能预测中的表现,MLP 模型对密度、硬度和磨损损失预测 R<sup>2</sup> 分别达 0.975、0.934

和 0.948,优于 RSM 的 0.801-0.876。通过特征重要性分析,可以识别对多个性能指标均具有显著影响的关键工艺参数,为工艺窗口的确定提供科学依据。

粉末冶金领域的数据获取成本高小样本场景是常态,集成学习方法通过组合多个基学习器能够有效提升模型的泛化能力。中南大学<sup>[1]</sup>构建了机器学习模型用于预测密度、极限抗拉强度、延伸率和热滞等关键性能指标,研究比较了随机森林、梯度提升、CatBoost、高斯过程回归、支持向量机以及多层感知机等多种算法,通过自助重采样和交叉验证评估模型的泛化能力。实验验证表明基于机器学习识别的优化工艺参数组合能够获得综合性能协同提升的 NiTi 合金制件。该研究提出针对特定 NiTi 合金性能属性构建定制化工艺窗口的方法,集成学习方法能够有效应对小样本高维数据通过组合多个弱学习器降低过拟合风险,多目标优化是粉末冶金工艺优化的实际需求。实际工程应用中粉末冶金制件往往需要同时满足多个性能指标如高强度、高延伸率、高密度、低残余应力等,这些指标之间可能存在权衡关系工艺参数的调整可能提

适当的归一化处理, 帕累托前沿可能呈现复杂形状需要足够的求解代数 and 种群规模才能获得较好的逼近, 模型预测的不确定性需要在优化中予以考虑确定性优化可能将帕累托解选在不稳定区域, 当目标数量超过三个时帕累托前沿的可视化和决策变得困难。在粉末冶金领域物理信息机器学习的一种重要应用是构建多物理场模拟的代理模型, 粉末冶金成形过程中的温度场、流场和应力场演变是决定成形质量的内在机理但直接进行高保真数值模拟计算成本高昂难以用于实时控制和大量参数组合的快速评估。



实验全面表征。机器学习与先进表征技术的结合,为深入理解摩擦磨损机制提供了新视角。通过对摩擦表面和磨屑的微观形貌、元素分布及物相组成进行多模态数据分析,

新材料产业 Issue.01 2026 35

可以揭示摩擦膜的形成与演化规律。结合 XPS、TEM 等表征手段,能够阐明不同陶瓷组分在摩擦过程中的氧化行为及其对摩擦稳定性的影响。Wen 等<sup>[23]</sup>通过 XPS 和 TEM 分析揭示 WC/B<sub>4</sub>C 双陶瓷组分铜基摩擦材料摩擦膜的三层结构(氧化层、变形层、基体层),阐明磨损机制随 WC/B<sub>4</sub>C 比例增加的演化规律。Liu 等<sup>[24]</sup>系统综述 LB-PBF 增材制造中机器学习的应用,按工艺-结构-性能关系将 ML 应用分为四类,将 ML 算法按可解释性和准确性分为可解释 ML、传统 ML 和深度 ML 三类。基于 AdaBoost、随机森林等算法的预测模型,可以识别扭矩、制动速度等工况参数对摩擦系数和稳定性的影响权重,从而为高性能摩擦材料的配方设计和工艺优化提供数据支撑。

## 四、机器学习在制件质量预测与控制中的应用

### 4.1 力学性能预测

粉末冶金材料的硬度、强度等力学性能是其工程应用的基础,然而这些性能受材料组分、烧结工艺及微观组织的复杂耦合影响,传统回归模型难以精确预测。机器学习在这一层面的应用主要体现在两个方向:一是建立从工艺参数到性能指标的直接预测模型实现质量的事前预测,二是实现成形过程的实时闭环控制通过过程监测和在线调整保证质量一致性。通过建立高维特征空间与力学性能之间的非线性映射,实现了对硬度和强度的精准预测。粒子群优化-支持向量机等混合模型在小样本条件下仍能保持良好的泛化能力,通过配对 t 检验和 F 检验可以验证模型的统计显著性和预测可靠性。Sarmah 等人<sup>[25]</sup>采用 PSO-SVM 混合模型预测 Al-SiC-ZrO<sub>2</sub> 杂化复合材料显微硬度,训练集  $R^2=0.995$ ,测试集  $R^2=0.982$ ,通过配对 t 检验和 F 检验验证模型无偏性和预测精度。Ravitej 等<sup>[26]</sup>采用线性回归、多项式回归和随机森林回归预测 Al6061-WC 复合材料硬度,三次多项式回归最佳 ( $R^2=0.9372$ ),5 折交叉验证平均  $R^2=0.915$ ,ANOVA 验证 WC 含量显著影响。特征重要性分析能够定量评估各输入参数对力学性能的贡献,揭示影响性能的关键因素,Manohar 等<sup>[27]</sup>采用随机森林、XGBoost、SVR 和 KNN 预测 Al/SiN 复合材料抗拉强度,随机森林最优 ( $R^2=0.9616$ ),识别 7%SiN、550°C、120min 为最优工艺参数组合。Ramkumar 等<sup>[28]</sup>采用随机森林模型预测 Ti-3Al-2.5V-xWC 复合材料摩擦系数和磨损率,MSE 较决策树和线性回归分别降低 79%-92%

和 36%-47%,通过特征重要性分析确定关键影响因素。这种数据驱动的性能预测模式,为粉末冶金复合材料的配方优化和工艺设计提供了高效工具,显著减少了实验试错成本。

人工神经网络<sup>[10]</sup>是粉末冶金制件性能预测中最常用的机器学习方法之一,研究表明融合粉末特性与工艺参数的混合输入模型其预测精度显著优于仅考虑单一类型变量的模型,这提示粉末冶金全流程数据链的打通对提升模型效能至关重要。针对 Ti-6Al-4V 合金的研究建立了一个系统的过程-微观组织-力学性能建模策略<sup>[6]</sup>,研究者引入深度神经网络构建工艺参数与微观组织特征之间的代理模型并进一步将微观组织特征与力学性能关联,实现对微观组织特征和力学性能的高效经济预测预测值与实际值之间存在强相关性。该研究建立了工艺参数-微观组织-力学性能的链条式预测模型超越了简单的端到端映射增强了模型的可解释性,通过敏感性分析识别出影响微观组织的关键工艺参数为工艺优化提供了方向,深度神经网络的成功应用证明了深度学习在复杂非线性关系建模中的优势。




图6 机器学习预测力学性能<sup>[26][28]</sup>, (成分、压力、温度、时间)之间以及输入参数与输出参数的关系(a); XGBoost 模型得到的回归图与残差图预测值(b)。

### 4.2 疲劳寿命与服役行为评估

粉末冶金零件在交变载荷下的疲劳性能是其服役可

靠性的关键指标,然而疲劳寿命受缺陷分布、表面状态、残余应力等多因素影响,传统基于 S-N 曲线的评估方法难以全面反映其分散性。机器学习方法通过构建包含数百组 S-N 曲线的数据库,采用 LightGBM 等梯度提升树算法,实现了对未知数据疲劳寿命的精准预测,Leininger 等<sup>[29]</sup>提出五种 ML 方法预测粉末冶金零件疲劳寿命,建立 828 组 S-N 曲线数据库,LightGBM 模型表现最优,对未知数据的分散带 T<sub>S</sub> 达 1:1.40,定义 S-N 曲线距离函数,通过定义 S-N 曲线距离函数,可以量化不同工艺条件下疲劳行为的差异。此外,对于滤波器等功能器件,机器学习可辅助建立材料—结构—性能关系,实现高频性能的优化设计。杨鹤功等<sup>[30]</sup>采用粉末冶金工艺制造 5G 通信小型化滤波器,结合广义切比雪夫设计原理和 HFSS、ADS 仿真软件设计 3300-3670MHz 带通滤波器,测试验证射频性能和机械可靠性。这种数据驱动的疲劳评估方法为粉末冶金零件的寿命预测和可靠性设计提供了新思路。




图7 机器学习对疲劳寿命与服役行为评估<sup>[29]</sup>: 决策树工作流程(a); 不同阶段的线性回归(b); 随机森林(c)。

### 4.3 缺陷检测与质量控制

粉末冶金零件在生产过程中易产生裂纹、孔隙等内部缺陷,这些缺陷严重影响产品的服役性能。传统人工目检和常规无损检测方法存在效率低、成本高、难以实现在线检测等问题。基于机器学习的视觉检测技术和声学检测方法为粉末冶金缺陷检测提供了高效解决方案。通过改进的深度学习网络,结合图像金字塔搜索策略和迁移学习,可以实现对表面裂纹的快速准确识别,检测准确率可达 98% 以上。Hadizadeh Isfahani 等<sup>[31]</sup>采用声学共振测试结合 ML 分类器检测粉末冶金油泵定子缺陷,从 20Hz-20kHz 频段提取 20 个频谱特征, RBF 网络对完

好件与缺陷件二分类准确率达 100%。黎鑫泽等<sup>[32]</sup>采用改进 Canny 算法和改进 SSDA 匹配算法结合图像金字塔搜索策略实现零件快速定位,改进 VGG19 网络对粉末冶金零件表面裂纹检测准确率达 98.97%。Szabo 等<sup>[33]</sup>开发基于三维 X 射线 CT 的自动化缺陷识别系统,采用图像配准与减法、图像分割、形态学操作等步骤,实现粉末冶金零件微观裂纹、孔隙、空洞的自动识别。声学共振测试结合频谱特征提取与分类器,能够实现对内部缺陷的无损检测和分类。扩展长短期记忆网络等时序预测模型,可通过烧结炉关键参数预测产品质量。梁潇阳等<sup>[34]</sup>提出 xLSTM 模型预测粉末冶金制动闸片质量,引入标量更新、矩阵记忆和协方差更新规则, xLSTM 较 LSTM 的 R<sup>2</sup> 提升 6.57%; xLSTM-Informer 混合模型进一步优化。这些智能化检测方法的集成应用,为粉末冶金生产的在线质量监控和闭环控制奠定了基础。

实时控制<sup>[17]</sup>是智能制造的核心诉求,在粉末冶金增材制造中由于过程的动态性和不稳定性实现实时闭环控制面临诸多挑战,传感数据的多模态性、缺陷形成的瞬态性、控制的实时性要求等。基于机器学习的闭环控制系统通常包含以下组件:传感模块通过同轴光学监测、红外成像、高速摄像、光电二极管、声发射传感器等手段实时获取过程信号,同轴光学监测可以捕获熔池的可见光或红外图像提供熔池形态和温度分布信息,光电二极管可以监测熔池辐射强度反映熔池的稳定性,声发射传感器可以捕获裂纹形成等事件的特征信号;特征提取与状态识别模块利用深度学习模型如 CNN、LSTM 等从多模态传感数据中提取特征识别当前过程状态检测异常和缺陷。实时控制在工业应用中仍面临若干瓶颈,首先是跨场景迁移性问题在实验室条件下开发的模型移植到工业现场时往往性能下降原因包括设备差异、环境变化、材料批次差异等;其次是模型可靠性问题控制系统的决策直接关系到产品质量模型必须具有极高的可靠性和容错能力;第三是实时性要求控制决策需要在毫秒级时间内完成这对模型的推理速度提出挑战。

粉末冶金过程中的质量相关数据呈现多源、异构、多尺度的特点,有效融合这些多模态数据是提升预测和控制精度的关键<sup>[3]</sup>。多模态数据融合的方法可分为三类:早期融合在特征提取前将不同模态的数据拼接或组合输入统一的模型,这种方法简单直接但要求各模态数据在空间和时间上对齐;中期融合分别从各模态数据中提取特征然

后将特征向量拼接后输入后续模型，这种方法允许各模态使用专用的特征提取网络灵活性更高；晚期融合各模态数据分别建立独立的预测模型然后通过投票、加权平均等方式融合各模型的预测结果，这种方法容错性好但忽略了模态间的交互信息。在粉末冶金质量预测中研究者开始探索多模态融合方法将过程参数、传感数据和材料特性结合起来构建更全面的质量预测模型。

## 五、讨论与展望

尽管机器学习在粉末冶金中的应用已取得显著进展，当前研究仍面临若干共性挑战。一、数据稀疏性与质量问题。粉末冶金实验成本高、周期长导致高质量标注数据的获取困难，现有研究中的数据规模普遍较小这对机器学习模型的训练和泛化能力构成挑战；数据异质性问题突出，不同研究使用的粉末材料、实验设备、测量方法、数据格式存在差异导致数据难以整合利用；标注数据获取困难，监督学习依赖标注数据进行训练而粉末冶金领域的标注往往需要昂贵的表征设备和专家经验。二、模型可解释性不足。粉末冶金涉及复杂的物理化学过程工程师和工艺人员需要理解模型的决策依据才能信任并使用模型的预测结果，当前广泛应用的深度学习模型和集成学习方法本质上属于黑箱模型其内部工作机制难以直观理解，模型预测的失败模式难以诊断当模型出错时不易定位原因，模型缺乏物理基础外推预测可能违背物理规律，机器学习模型的泛化能力是其能否从实验室走向工业应用的关键，当前研究中模型通常在特定材料、特定设备、特定工艺条件下训练和测试其泛化能力存在明显的局限性，跨材料泛化方面针对一种材料训练的模型迁移到另一种材料时性能显著下降原因是不同材料的热物性、凝固行为、缺陷形成机制存在差异。三、多任务与多目标优化的复杂性。粉末冶金铸件往往需要同时满足多重性能指标这些指标之间可能存在权衡关系，多目标优化是粉末冶金工艺参数优化的核心问题但也面临一系列复杂性，目标之间的量纲不一致需要适当的归一化处理，帕累托前沿可能呈现复杂形状需要足够的求解代数和种群规模才能获得较好的逼近趋势，模型预测的不确定性需要在优化中予以考虑确定性优化可能将帕累托解选在不稳定区域，当目标数量超过三个时帕累托前沿的可视化和决策变得困难。

未来，机器学习在粉末冶金领域的发展将呈现多个重要趋势。一、从单一任务建模向全流程数字孪生演进。在粉末冶金领域全流程数字孪生应包含粉末孪生基于粉

末制备和表征数据构建粉末特性的数字表示支持粉末质量评估和批次追踪，实现全流程数字孪生的关键在于打通数据孤岛建立统一的数据模型和信息物理融合架构。二、监督学习向强化学习和主动学习拓展。在粉末冶金过程控制中可以将过程状态作为环境状态工艺参数调整作为动作质量指标作为奖励训练强化学习智能体实现自主控制。主动学习算法能够识别当前模型不确定性高的样本优先建议进行实验验证从而用最少的实验获取最大的信息增益，在粉末冶金工艺优化中主动学习可以指导实验设计减少试错次数。三、与计算材料科学深度融合。纯数据驱动的机器学习模型缺乏物理基础其外推预测可能违背物理规律，与计算材料科学的深度融合是解决这一问题的根本途径。四、数据共享与标准化。未来需要建立行业共享的粉末冶金数据库涵盖粉末特性、工艺参数、传感数据、质量检测结果等多维信息并制定统一的数据格式和元数据标准，同时需要发展隐私计算和联邦学习技术在保护数据隐私的前提下实现跨机构的模型协同训练。五、工业应用与工程化，将机器学习研究成果转化为工业应用还面临工程化的挑战，这包括模型的轻量化以适应边缘计算设备的资源限制，模型的鲁棒性以应对工业现场的噪声和干扰，模型的可维护性支持持续更新和版本管理，人机交互设计使工艺人员能够有效与智能系统协作。大型语言模型和图形化界面的开发将降低非专业用户的使用门槛促进智能化工具在工业场景的推广应用，通过自然语言交互工艺人员可以查询模型预测结果、获取工艺优化建议、理解模型决策依据而不需要深入了解机器学习的技术细节。

## 六、结语

机器学习正在重塑粉末冶金的研究范式。从粉末表征、过程建模到质量控制，数据驱动方法已在多个环节展现出超越传统技术的潜力。本文系统梳理了该领域的研究进展，分析了典型应用场景中的算法策略：在粉末表征领域，深度学习实例分割模型如 YOLOv9-seg 实现了高通量自动化形貌分析在测试数据集上 F1-score 超过 95%，无监督学习框架如傅里叶描述子结合 K-means 支持大规模粉末形貌聚类分析为建立形貌 - 性能关联奠定了基础，基于过程数据的监督学习模型如 LSTM、XGBoost、弹性网络能够有效预测粉末制备过程的质量输出；在过程建模领域，集成学习和神经网络有效挖掘了工艺参数与制件性能之间的非线性关系，双向预测框架实现了熔池尺寸的高精度预测和参数逆向设计，多目标优化方法结合机

器学习代理模型搜索满足多重性能指标的帕累托最优解；在质量控制领域，基于机器学习的闭环控制为实时工艺调整提供了可能神经网络在瞬态阶段的预测性能优于传统传感器方法，深度神经网络建立了工艺参数—微观组织—力学性能的链条式预测模型增强了模型的可解释性，多模

态数据融合正在推动质量预测精度的进一步提升。面向工业应用的实际需求，未来需要着力解决数据共享机制、模型可解释性和跨场景泛化等关键问题，推动机器学习与粉末冶金知识的深度融合构建全流程数字孪生系统实现粉末冶金从试错范式向智能范式的根本转变。

#### 作者简介：

谢焱，工学博士，任西北稀有金属材料研究院宁夏有限公司铍材研究所所长。2014 年硕士毕业于太原理工大学（清华联合培养），2024 年华中科技大学在职博士毕业。主持参与省部级以上科研项目 10 余项，授权专利 9 项，参与国家标准《铍铝合金金相组织检验方法》编制。石嘴山市青年联合会第六届委员会委员。

李志年，工学学士，中色（宁夏）东方集团高级工程师、集团级专家，享受国务院津贴专家。2000 年学士毕业于兰州大学，长期从事铍及铍合金研究，主持参与国防军工及省部级项目 10 余项，获省部级 / 行业奖 10 多项，授权发明专利 20 余件，发表学术论文 10 余篇。成果用于航天航空、核工业领域。

王亚斌，工学硕士，西北稀有金属材料研究院宁夏有限公司工程师。2017-2024 本硕就读于福州大学，承担参与省部级以上项目 2 项，授权公开专利 4 项，发表学术论文（SCI）2 篇。从事稀有金属材料粉末冶金技术研究。

#### 参考文献

- [1] 赵晓白, 王洪锋, 游涛, 等. 机器学习加速增材制造高温合金发展 [J]. 粉末冶金技术, 2025.
- [2] Gimbringer V, Zieheil B. Evaluation of ML potential for modelling and process control of a reduction annealing process[J]. Master's Thesis in Mathematical Sciences, 2026.
- [3] Wang P, Wu Z, Ten J J S, et al. Towards intelligent defect detection in metal powder bed fusion: A review of in situ monitoring, data pre-processing, and machine learning[J]. Materials Science and Engineering: R: Reports, 2026, 167: 101112.
- [4] He S, Tu J, Zhu Y, et al. Instance segmentation and microstructure characterization based on powder microscopic image data[J]. Materials Characterization, 2026, 234: 116051.
- [5] He S, Tu J, Zhu Y, et al. Instance segmentation and microstructure characterization based on powder microscopic image data[J]. Materials Characterization, 2026, 234: 116051.
- [6] Wang P, Wu Z, Ten J J S, et al. Towards intelligent defect detection in metal powder bed fusion: A review of in situ monitoring, data pre-processing, and machine learning[J]. Materials Science and Engineering: R: Reports, 2026, 167: 101112.
- [7] Akeweje E, Kirk C, Chan C W, et al. High-Throughput Unsupervised Profiling of the Morphology of 316L Powder Particles for Use in Additive Manufacturing[J]. Computational Materials Science, 2026, 263: 114433.
- [8] Toprak C B, Dogruer C U. A critical review of machine learning methods used in metal powder bed fusion process to predict part properties[J]. International journal of precision engineering and manufacturing, 2024, 25(2): 429-452.

- [9] Pancholi S, Gupta M K, Bartoszek M, et al. Transforming Additive Manufacturing with Artificial Intelligence: A Review of Current and Future Trends: S. Pancholi et al[J]. Archives of Computational Methods in Engineering, 2025, 32(8): 4691-4722.
- [10] Kumar M S, Yang C H, Ross N S, et al. Data-driven machine learning optimization of DLMS parameters for sustainable AlSi10Mg powder reuse and superior part performance[J]. Powder Technology, 2025: 121628.
- [11] Si S, Fan B, Liu X, et al. Study on strengthening effects of Zr-Ti-Nb-O alloys via high throughput powder metallurgy and data-driven machine learning[J]. Materials & Design, 2021, 206: 109777.
- [12] Fan B, Liu X, Si S, et al. Study on the key features of dynamic compressive fracture strain of Ti-Zr-Nb solid solution alloys through random forest regressor[C]//Journal of Physics: Conference Series. IOP Publishing, 2022, 2355(1): 012078.
- [13] Xu B, Yin H, Zhang R, et al. Experimental Feedback to Improve the Extrapolation of Machine Learning: Application to Design of PM Cu-Al-Fe-Ni Alloys[J]. Transactions of the Indian Institute of Metals, 2023, 76(7): 1781-1787.
- [14] Das P, Pandey P M. Machine learning based phase prediction and powder metallurgy assisted experimental validation of medium entropy compositionally complex alloys[J]. Modelling and Simulation in Materials Science and Engineering, 2023, 31(8): 085015.
- [15] Wu T, Wang W, Ye X H, et al. Transient micro-liquid phase HIP sintering of powder metallurgy superalloys achieved by a binary composition-splitting strategy[J]. Journal of Materials Research and Technology, 2025.
- [16] LIU H X, YANG Y F, CAI Y F, et al. Prediction of sintered density of binary W(Mo) alloys using machine learning[J]. Rare Metals, 2023, 42(8): 2713-2724.
- [17] DENG Z, YIN H, JIANG X, et al. Machine leaning aided study of sintered density in Cu-Al alloy[J]. Computational Materials Science, 2018, 155: 48-54.
- [18] KAMAL T, GOUTHAMA, UPADHYAYA A. FEM and machine learning aided modelling of compressive deformation anisotropy in pressure-less sintered Cu-15Ni-8Sn alloy[J]. Materialia, 2024, 34: 102092.
- [19] BERLADIR K, ANTOSZ K, IVANOV V, et al. Machine Learning-Driven Prediction of Composite Materials Properties Based on Experimental Testing Data[J]. Polymers, 2025, 17(5): 694.
- [20] WEN G, LI Z, WU J, et al. Friction properties and prediction of a novel copper-based powder metallurgy material modified with TiB<sub>2</sub>/B<sub>4</sub>C composite[J]. Ceramics International, 2024, 50: 30763-30775.
- [21] SARMAH P, GUPTA K. Recent Advancements in Fabrication of Metal Matrix Composites: A Systematic Review[J]. Materials, 2024, 17(18): 4635.
- [22] SAMAD A, ARIF S, ANSARI S, et al. Machine learning enabled prediction of tribological properties of Cu-TiC-GNP nanocomposites synthesized by electric resistance sintering: A comparison with RSM[J]. Journal of Materials Research and Technology, 2024, 28: 2290-2312.
- [23] WEN G, LI Z, WU J, et al. The impact of dual ceramic components (WC/B<sub>4</sub>C) on the friction performance of copper-based powder metallurgy friction materials and wear mechanism[J]. Wear, 2024, 552-553: 205461.
- [24] LIU J, YE J, IZQUIERDO D S, et al. A review of machine learning techniques for process and performance optimization in laser beam powder bed fusion additive manufacturing[J]. Journal of Intelligent Manufacturing, 2023, 34: 3249-3275.
- [25] SARMAH P, PAWARN S, GUPTA K. Fabrication of Novel Hybrid Al-SiC-ZrO<sub>2</sub> Composites via Powder Metallurgy Route and Intelligent Modeling for Their Microhardness[J]. Materials, 2025, 18(1): 1-23.

- [26] HADIZADEH ISFAHANI M H, MOEENFARD H, ROHANI A. Non-destructive defect detection in powder metallurgy automotive oil pump stators using acoustic signals and machine learning classification[J]. PLoS ONE, 2025, 20(11): e0334454.
- [27] Ravitej Y. P. Gupta R. Karthik S. B, et al.Efect of Tungsten Carbide Composites on Al6061 Using Powder Metallurgy Technique: Experimental and Machine Learning Approach[J]. Journal of The Institution Engineers India Series D, 2026.
- [28] MANOHAR G, REDDY V, VAISHALI. From fabrication to prediction: unraveling the tensile strength of Al/SiN composites through machine learning[J]. International Journal on Interactive Design and Manufacturing, 2025, 19: 7091-7107.
- [29] RAMKUMAR T, SUDHA V K, SELVAKUMAR M, et al. Prediction of Tribological Performance of Ti-3Al-2.5V-xWC Composite using Machine Learning Models[J]. Journal of Materials Engineering and Performance, 2025, 34(16): 17131-17143.
- [30] 杨鹤功. 基于粉末冶金工艺的小型化滤波器设计与实现 [D]. 哈尔滨: 哈尔滨工业大学, 2024.
- [31] SURYA M S, KUMAR V N, SRIVASTAVA J P, et al. Integrated Optimization and Tribo-Mechanical Evaluation of Al7075/TiC Composites Using RSM and Data-Driven Optimization Techniques[J]. Journal of Materials Engineering and Performance, 2026, 35: 1-13.
- [32] 黎鑫泽. 粉末冶金零件表面裂纹缺陷视觉检测方法研究 [D]. 广州: 广州大学, 2022.
- [33] SZABO I, SUN J, FENG G, et al. Automated defect recognition as a critical element in quality assurance of net-shape parts using industrial X-ray computed tomography[J]. Applied Sciences, 2017, 7(11): 1156.
- [34] 梁潇阳. 基于深度学习的粉末冶金产品质量预测研究 [D]. 北京: 北方工业大学, 2025.