引文格式：王岩, 韩昌骏, 郑博源, 等. 激光选区熔化多源融合在线监测与质量控制技术研究进展[J]. 航空制造技术, 2026, 69(20): 26010033.

WANG Yan, HAN Changjun, ZHENG Boyuan, et al. Research progress on multi-source fusion online monitoring and quality control technology in selective laser melting[J]. Aeronautical Manufacturing Technology, 2026, 69(20): 26010033.

激光选区熔化多源融合在线监测与质量控制技术研究进展

王　岩，韩昌骏，郑博源，蒋仁武，王　迪，李　阳，杨永强

（华南理工大学，广州 510641）

[摘要]　激光选区熔化（Selective laser melting，SLM）技术因能够直接成形复杂精密构件，从而在航空航天、生物医疗等领域的应用展现出显著优势。然而，制造过程中存在的熔池不稳定、缺陷产生随机等问题，直接影响了制件的力学性能和服役可靠性，使质量控制成为制约该技术规模化工业应用的关键瓶颈。引入多源融合在线监测方法实现对工艺过程的实时感知与反馈调控，被视为提升零件质量的重要技术途径。本文围绕SLM多源融合在线监测体系构建、多模态数据处理、质量预测与调控等方面，系统梳理了相关技术发展路径，同时探讨了当前该领域在工程化应用中存在的共性挑战，并对其后续发展所需支撑体系与评估框架进行了展望。通过整合近年来的相关研究成果，本文旨在为该领域的后续研究提供较为系统的学术参考，助力SLM质量控制持续向智能化方向发展。

关键词：激光选区熔化（SLM）；在线监测；多模态融合；缺陷检测；质量控制

中图分类号：V2；TH16　　**文献标志码：**A　　**DOI:** 10.16080/j.issn1671-833x.26010033



王　岩

博士研究生，研究方向为激光增材制造在线监测。

增材制造（Additive manufacturing，AM）又称3D打印，从快速成型技术演进而来，现已成为面向高性能复杂构件的成熟制造工艺[1–3]。作为激光增材制造（L–AM）的核心分支，SLM凭借自身高度的设计自由度、材料利用率与能效优势，制备出的拓扑优化、轻量化且近乎致密的金属部件[4–6]，正广泛服务于对可靠性与可追溯性要求极高的航空航天、汽车与生物医疗等领域[7–10]。然而，SLM过程涉及多物理场–多相耦合、多尺度与复杂热动力学，易受工艺、材料与加工环境扰动的综合影响，引发孔隙、未熔合、球化、裂纹与变形等制造缺陷，进而导致制件质量下降[11–14]。目前，SLM质量控制仍高度依赖后处理与离线检测，尽管能够保障交付质量并支持质量追溯，但通常存在周期长、成本高、材料浪费大以及部分检测手段可能对制件造成不可逆损伤等问题[15–16]。为此，围绕SLM过程可见、缺陷可判、质量可控的工程应用诉求，建立覆盖关键工艺环节的在线监测体系，并基于在线监测数据实现可分析与

收稿日期：2026-03-06；**退修日期：**2026-03-30；**录用日期：**2026-04-09

基金项目：国家重点研发计划（2024YFB4608200）；中央高校基本科研业务费专项资金（2024ZYGXZR079）；广州市科技计划（2025A04J5196）

通信作者：韩昌骏，教授，博士，研究方向为金属增材制造工艺与结构优化设计。

杨永强，教授，博士，研究方向为增材制造装备与工艺开发。

可解释的质量决策，已成为提升其制造稳定性，拓展工程应用范围的核心技术发展方向之一[17–19]。

在金属SLM成形质量控制研究中，学界明确提出两条并行的数据驱动技术路径：一是基于多尺度物理建模与仿真的制造前工艺优化；二是以在线监测数据为核心的制造过程状态评估与反馈控制，本文着重综述后者的研究进展[20–21]。从缺陷形成机理看，孔隙、未熔合与裂纹等往往在多个尺度上经历“萌发—扩展—累积”的演化过程，离线无损检测虽能提供最终缺陷的形态证据，却难以揭示其在构建过程中触发与演化的时序关联。在线监测的价值在于连续记录工艺过程数据，支持缺陷的早期定位与类型判别，并在必要时触发停机、局部修复工艺或参数重规划等策略；同时，在线数据也可反向用于机理验证、参数优化与质量模型构建[22–23]。目前，SLM在线监测传感器体系通常可归纳为两类：辐射类传感器（如光电二极管、单色/双色高温计、可见光/红外热像、层间表面成像等），主要采集熔池辐射强度、温度场分布与表面几何纹理[24–25]；非辐射类传感器（如声发射/声学、激光超声、振动/加速度传感器等），则更适用于感知存在遮挡情况下的成形扰动、亚表面异常及与铺粉相关的动态信息[26–28]。两者共同服务于原位缺陷识别与工艺稳态维持的目标[29–32]。随着统计学与机器学习（Machine learning，ML）方法在制造领域的深入应用，利用在线监测数据提升缺陷识别效率与准确性，已成为改善SLM制造可靠性的关键技术路线[33–34]。同时，有研究也指出，不同传感器对缺陷类型与工况变化的敏感性存在差异，且传感链路的性能上限与可解释性同样决定了模型的泛化能力与工程可用性[35–36]。

现有关于SLM在线监测与质量控制的综述多聚焦于单一传感器或数据形态[31,37–38]，对多源感知融合及面向质量调控的系统性总结相对有限。近年来，随着多源监测平台与多模态融合算法的快速发展，通过多源互补提升缺陷检出能力，以融合决策支撑质量调控的闭环技术路线正受到更广泛关注[39–40]。针对“多源在线监测—缺陷识别—质量调控”这一技术路径，相关研究已逐步形成可复制迁移的技术流程。首先，在制造过程中完成高保真、多模态过程信号的采集，并实现跨模态时空对齐；其次，通过降噪、偏差校正、异常与缺失处理、标准化及样本不平衡矫正等方法改善数据质量。在此基础上，提取具有物理指向性的时–频域特征、图像纹理及几何特征，构建面向特定缺陷或质量任务的多模态表征。随后，依据数据结构、噪声水平与标注成本匹配相应的学习模型，并通过交叉验证与外推评估约束模型过拟合并提升可迁移性[41–42]。最终，将异常判定结果与可控工艺参数及质量指标耦合，载入反馈调控框架，形成可在线执行的工艺修正或缺陷修复方案[43–44]。基于上述研究背景与技术主线，本文系统梳理了当前SLM多源融合在线监测与质量控制的研究进展，剖析了现有方法的适用条件与技术瓶颈，并明确了后续面向工程化应用研究亟须应对的关键挑战与发展方向。

1 SLM多源在线监测系统

1.1 SLM监测对象

金属激光选区熔化过程中存在多种尺度缺陷与异常状态，包括孔隙、未熔合、热裂纹、几何尺寸偏差和表面缺陷等，其形成与局部能量输入、粉末床致密度、熔池流动与飞溅行为、散热条件、工艺环境和设备状态密切相关。围绕激光选区熔化过程中缺陷的形成机理，近年来的研究通常将在线监测对象划分为熔池（飞溅）区域、粉末床、层间熔融区域以及工艺环境与设备状态等层级。不同层级对应的监测模态具有明显差异和互补性，如图1所示，为多源融合在线监测提供了较为清晰的对象分类基础[18,29,45]。

熔池区域作为熔融体迁移与热力交互最为集中的区域，对气孔、未熔合、匙孔失稳以及热裂纹等内部缺陷的形成具有决定性影响。围绕熔池及飞溅行为的可观测关键物理量包括熔池尺寸演化、熔池轮廓波动、熔池表面及近表面温度场分布及峰值、冷却速率与温度梯度、金属蒸汽羽流以及飞溅颗粒的数量、运动轨迹等。熔池监测相关研究表明，这些观测量与成形的孔隙分布、熔道间搭接质量、显微组织结构以及力学性能之间存在显著关联[24]。与之对应的典型监测模态主要包括两类，第一类为光辐射信号，通常采用同轴或近同轴配置的红外光电探测器、高温计等，用于获取熔池辐射强度及等效温度信号[46]；第二类为可见光和温度信号，借助高速可见光相机或红外相机，通过同轴或旁轴的布置实现对熔池形貌、飞溅行为及温度场的二维乃至准三维重建。Gaikwad等[47]构建的多现象熔池监测系统，通过集成高速可见光成像、热成像与光电信号，同步采集熔池几何、温度分布与飞溅动态，显著提升了单道成形缺陷的检测灵敏度。Moshiri等[48]则从计量学角度系统评估了同轴近红外熔池监测系统的空间分辨率、信噪比及其对不同缺陷情形的区分能力，为该类监测模块在工业设备上的部署提供了明确的性能上限。

铺粉质量直接影响熔池形成的初始边界条件，是诱发未熔合缺陷、孔隙团簇以及局部几何畸变的重要因素，因此粉末床可观测物理量主要包括：单层粉末的厚度及其分布均匀性，局部缺粉、粉末堆积与刮刀划痕等宏观缺陷，粉末流动性异常，以及铺粉刀/滚筒的异常等。相应的监测模态主要集中于机器视觉与轮廓测量技术。针对层间二维粉末层图像

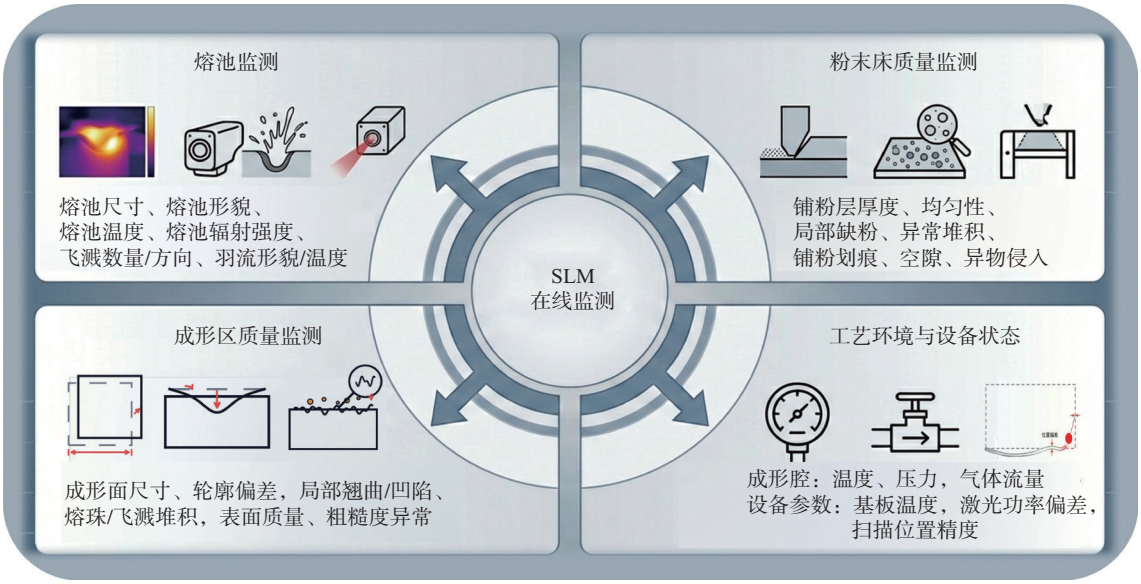


图1　SLM在线监测对象分类[18,29,45]

Fig.1　Categorization of SLM online monitoring objects[18,29,45]

的获取，通常采用线阵或面阵相机在铺粉后进行逐层成像，并通过分析图像灰度、纹理与几何特征识别缺粉区、堆积区和划痕等异常。进一步，还可利用结构光或激光条纹扫描技术重建粉末层的三维厚度信息，从而量化分析粉末层均匀性，并检测局部塌陷等微观形貌偏差。Wei等[49]开发的在线粉末铺设视觉监测系统，借助多光源成像与图像分割算法，实现了对粉末床宏观缺陷的自动识别，为后续与熔池监测信号的联合分析提供了高分辨率的初始工艺状态信息。Bevans等[50]在异构传感数据融合研究中，将粉末床图像与红外热像、飞溅成像数据相结合，用于跨几何形状与工艺条件的多尺度缺陷检测，进一步印证了粉末床信息在多源监测框架中的基础性作用。

层间成形表面与最终构件的几何形貌是粉末床质量、熔池行为及散热条件等多重因素累积作用的直接体现，并直接关联到构件的尺寸精度、表面粗糙度及后加工余量等关键质量指标。其关键可观测物理量包括单层成形轮廓偏差、边缘缺陷、局部翘曲或凸起、表面粗糙度等。常用监测手段是通过层间原位成像系统逐层记录熔化后成形区域的光学图像或厚度映射，或利用激光轮廓扫描快速获取表面三维形貌。Cao等[51]的研究将这些层间数据累积重构成三维几何实体，并与设计模型或最终测量结果进行对比分析。在多源监测框架中，关于目标区域几何尺寸信息通常与熔池、粉床等过程特征在统一坐标系中进行时空对齐，从而综合分析铺粉质量不佳与熔池失稳共同诱发特定层的轮廓偏差的原因，或用于训练从过程特征直接预测层间几何误差的模型。近期，Zhang等[52]关于层间原位监测的工作也表明，通过综合表面形貌与声学、光学等多模态信号的分析，能够有效区分由缺粉、支撑失效或热变形等不同机理引起的尺寸偏差，为在线诊断与工艺调整提供更具针对性的依据。

工艺环境与设备状态为上述过程提供关键工艺边界条件，可监测对象包括成形腔室内气氛成分、压力与流场分布、基板温度、光学窗口洁净度，以及振镜与运动轴的定位误差、动态响应特性、激光输出功率偏差等，这些信息通常通过设备内置传感器与控制日志获取。在相关研究中，Moshiri等[48]对同轴熔池监测系统的性能评估中指出，若未将激光功率波动、光学链路衰减等设备状态信息纳入分析，容易导致将系统性漂移误判为工艺异常。Yavari等[53]将过程监测信号与机床运行日志相结合，构建用于表征工艺一致性的过程特征，以解释不同成形批次间缺陷模式与几何偏差的差异。杨永强等[54]则通过综述分析了优化流场以获得均匀一致的气流对实现大尺寸SLM长时间稳定、高质量成形的重要性。

1.2　SLM多源在线监测系统组成

近年来的多源在线监测研究表明，尽管在具体传感器型号与安装细节上会由于SLM设备空间不同而存在差异，但在系统集成方面已经出现针对不同监测目标具有代表性的集成模式。表1[55–78]中总结了近5年相关研究中传感器类型以及监测特性（可被监测量），主要围绕熔池、飞溅、粉末床、成形/熔融区监测，以及包含与设备、工艺过程日志耦合的多传感系统展开。

围绕熔池区域集成多光学/热力学监测方法，是当前主流的工程实现模式。典型方案是在同轴光路中集成光电二极管、高速相机或高温计，用于获取熔池光辐射强度、熔池形貌及

表1 SLM在线监测传感器配置与特性

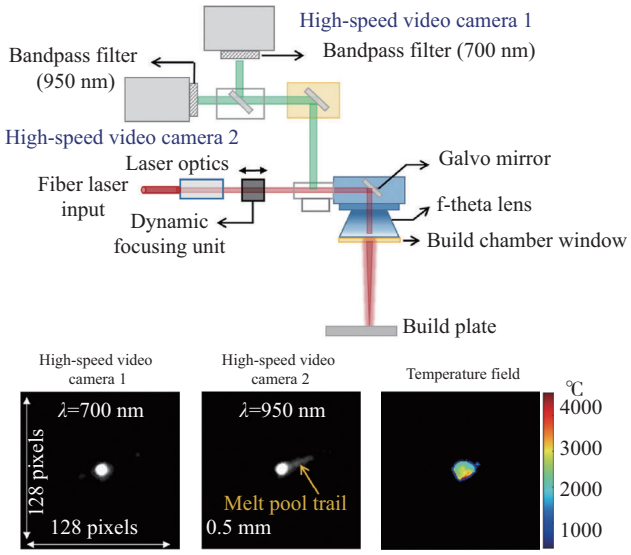
Table 1 Sensor configurations and performance characteristics for SLM monitoring

监测目标	监测方法	监测特性	参考文献
熔池	高速同轴可见光成像与物理模型	熔池宽度/深度的在线估算与演化	Goossens等[55]
	单相机双波长成像测温	熔池辐射温度/温度场随时间变化	Vallabh等[56]
	X射线、高速红外成像	熔池动力学及其热场耦合	Wang等[57]
	高光谱热成像	熔池绝对温度与热场监测	Breese等[58]
	X射线、麦克风	熔池模式转变与不稳定监测	Hamidi等[59]
飞溅	高速相机	飞溅形成机制与飞溅高度演化 羽流–二次加热相关过程图	Ikeshoji等[60] Myers等[61]
	条纹成像	烟羽、飞溅等流场副产物的时空演化	Baehr等[62]
	自由场麦克风	飞溅行为识别/监测	Luo等[63]
粉末床	矩阵相机	层级粉末床图像,用于粉末铺展状态识别	Fischer等[64]
	原位红外热成像、热测量	局部粉层厚度分布	Liu等[65]
	光学相机	识别粉末铺展失败/缺陷等异常	Schmitt等[66]
	条纹投影	重建粉末床/成形面3D形貌用于缺陷监测	Remani等[67]
	光度立体、结构光	3D法向/深度映射并增强缺陷可视化	Zhang等[68]
	光学相机、麦克风	粉末床状态与粉末层厚度监测	Kouprianoff等[69]
成形/熔融区	红外热像、光学断层扫描与工业CT	层内/层间缺陷检测	Mohr等[70]
	层间热历史(温度)、高速可见光成像	悬垂结构的成形状态与热积累演化	Ashby等[71]
	工业相机	粉末铺展后与熔融区表面图像	Ma等[72]
	偏振成像	单次成像重建3D高度图	Lucà等[73]
	可见光、红外多传感图像融合	缺陷特征增强与识别效能	Peng等[74]
	压电声发射传感器	成形区缺陷监测	Seleznev等.[75]
设备、工艺过程日志	过程气氛监测	成形舱含氧量(7 h),零件中含氧量	Pauzon等[76]
	残余氧含量与粉末循环	残余氧含量,粉末状态监测	Emminghaus等[77]
	设备原位监测数据	局部孔隙预测	Feng等[78]

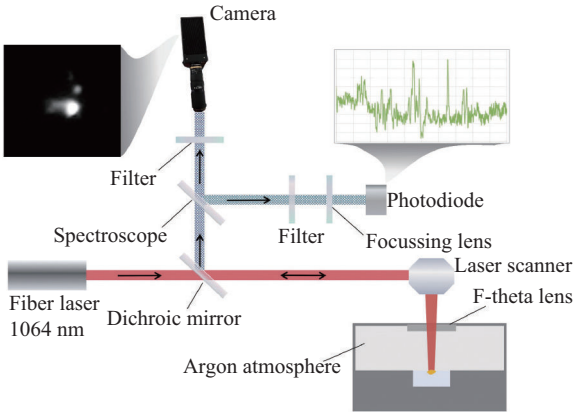
等效温度,如图2(a)[47]~(b)[79]所示;旁轴布置方案多采用高速可见光或红外相机,用于采集熔池几何形貌、金属蒸汽羽流及飞溅行为,图2(c)[80]~(d)[50]所示。Gaikwad等[47]提出的熔池监测系统通过两台高速成像设备和同轴辐射信号同步采集熔池形状、尺寸、飞溅和温度分布,并以多源数据融合提高不同缺陷场景下熔池异常的检出能力。在Lane等[81]早期的工作中则在同一SLM平台上集成热成像、可见光成像和实时功率监控,对熔池及其附近多种过程现象进行联合采集,展示了围绕熔池监测的多通道信号来源的基本硬件构成方案。Zhou等[79]采用光电二极管和半导体摄像机采集熔池同轴辐射信号和图像,采用变分模态分解方法对原始信号进行修正以增强熔池行为特征。

面向跨尺度缺陷检测的研究则倾向于在熔池传感基础上引入粉床与成形表面的多视角成像,形成“粉床/表面–熔池协同监测”的系统结构。Bevans等[50]构建的异构传感数据融合平台结合红外相机、飞溅成像相机和粉末床成像相机,在同一台SLM设备上实现了从粉床铺设到熔池演化再到层间几何畸变的多尺度观测,完成对不同结构制件和工艺条件下孔隙、层间不连续和宏观几何缺陷的形状的相关性检测。类似方案在部分工业系统中,以同轴熔池监测结合层间粉床/熔融区图像的形式实现,为后续构建体素级质量映射关系提供了硬件配置基础。

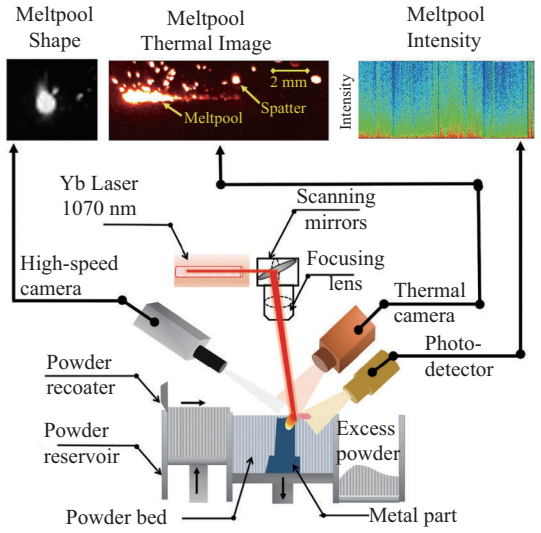
光–声复合监测构型在近年来的多源系统中占据越来越重要的地位。这类系统通常在保留同轴或旁轴光学/热力学监测通道的同时,在成形舱体内(如基板或腔体壁)布置一至多个声发射传感器,如图2(e)所示[82],用于感知裂纹萌生、粉末异常流动和飞溅撞击等高频事件。Pandiyan等[82]在多材料SLM研究通过构建光学–声学监测系统同步采集



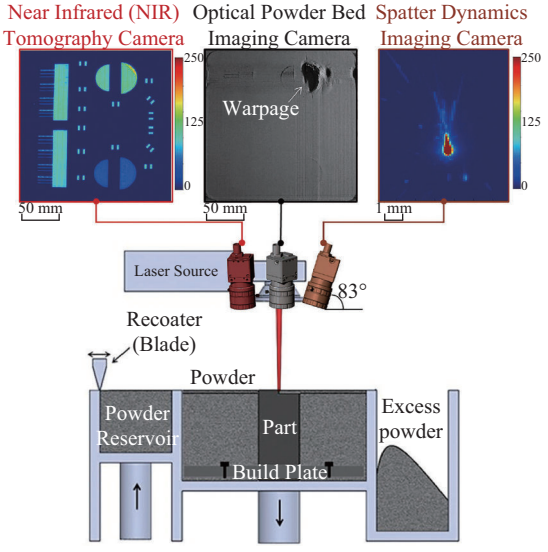
（a）同轴高速相机与热成像[47]



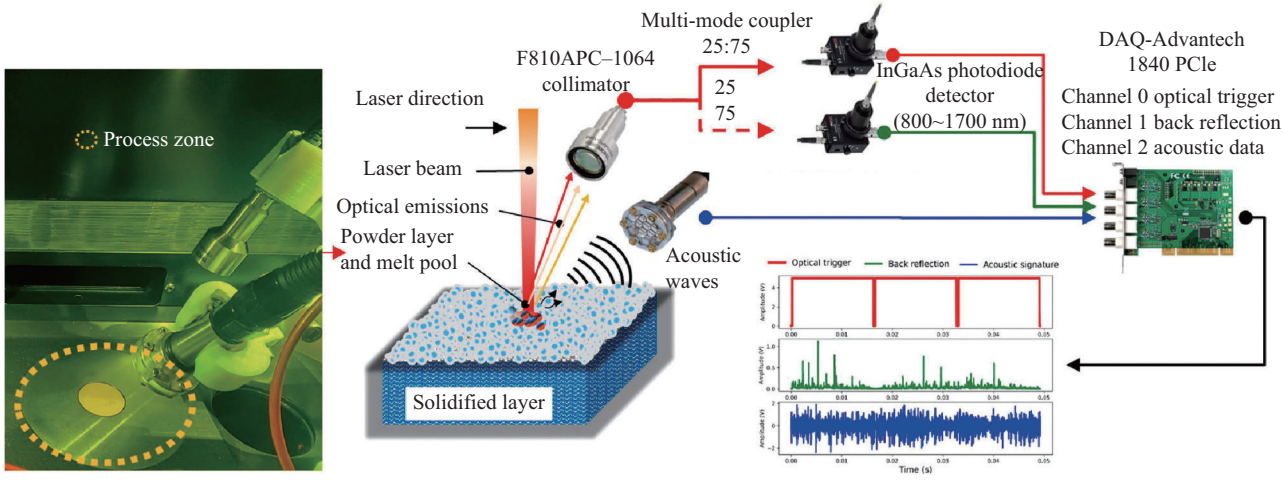
（b）同轴高速相机与光电探测器（光电二极管）[79]



（c）旁轴高速相机，热成像和光电探测器[80]



（d）近同轴红外相机和光学相机[50]



（e）声探测器与其他传感器（如光电二极管、原位X射线等）[82]

图2　激光选区熔化多源在线监测系统典型组成

Fig.2　Typical configurations of multi-sensor online monitoring systems for selective laser melting (SLM)

同轴光辐射信号与声发射信号，实现了多种合金成分区域的在线“qualify-as-you-go”判定，展示了双模态融合在多材料成分监测和过程分区识别中的潜力。Cao 等[51]提出的多传感器融合监测系统则同时集成光电信号、声学信号和可视图像，通过改进的VMD模态分解算法与交叉注意力网络，实现对工艺小幅波动和熔池稳定性变化的高灵敏度识别。这种硬件配置方案在系统复杂度适中的条件下极大地丰富了对SLM过程瞬态行为的表征维度。

在基于上述硬件集成方案的基础上，近年来有部分研究进一步引入工艺环境与过程日志信息，形成与工艺控制深度耦合的多源监测系统。典型做法是在多通道信号采集的同时，记录激光功率与动态反馈、规划路径与扫描速度、铺粉层厚与成形舱内压力等过程数据，并将其与其他监测信号一并纳入监测分析架构之中。Zhang 等[83]针对LPBF超高成形边缘问题开发了图像–声学多源数据融合监测系统，通过双流交叉模态融合网络从可见光图像和声发射信号中提取可解释特征，实现对异常层厚的高精度识别，并为后续自主优化铺粉与扫描策略提供依据。基于上述内容，当前典型多源监测架构在硬件层面具有以下特征：(1)围绕熔池区设置高时间分辨率的光学或热学监测通道，以捕捉关键熔化现象；(2)通过粉末床与层间熔融区域成像，在扩展空间可观测范围的同时补充几何信息；(3)利用声发射等通道增强对内部缺陷生成瞬态信息的敏感性；(4)在此基础上融合设备运行日志和环境监测数据，将工艺参数波动与传感信号联系起来。不同架构之间在空间布置、时间同步方式和可扩展性方面虽存在差异，但均为后续多模态数据融合与面向质量控制的方法建立提供了技术支撑框架。

1.3 SLM多源监测系统的工程应用

通过将单一传感器进行简单叠加，并不能保证多模态、多源在线监测系统具备高可靠性。其工程实现的难点主要在于可观测范围、时间/空间分辨率以及数据储存与处理之间的关系。同时对数据的时空对齐与完整性，测量精度与可检出能力，以及长期稳定运行与工业可集成条件等因素也带来挑战。上述技术瓶颈和问题随着近年的监测手段与计量学研究被逐渐量化和显性化，因此也逐步形成了多源监测系统设计与评价的工程应用框架，如图3所示。

在可观测范围和空间–时间解析度的设计上，多源监测系统必须在监测对象数量和监测精度之间取得平衡。针对可见光相机监测系统，Zhang 等[84]通过U–Net超分辨率增强算法系统分析了分辨率、视场与细节可见度之间的关系，研究指出当相机视场增大以覆盖整个成形区域时，工艺过程中的矢量级现象往往难以分辨，需要借助图像增强与重构策略来弥补硬件分辨率的不足。Penny 等[85]利用构建了具有50 μm空间分辨率的中波红外监测光路，在保持与加工激光共用光学通道的前提下实现了空间分辨率与高动态范围融合，但同时也揭示了光学系统复杂度、信号强度分配与热辐射信号饱和之间的权衡关系。在熔池热像监测中，高速红外相机通常在30 μm量级空间

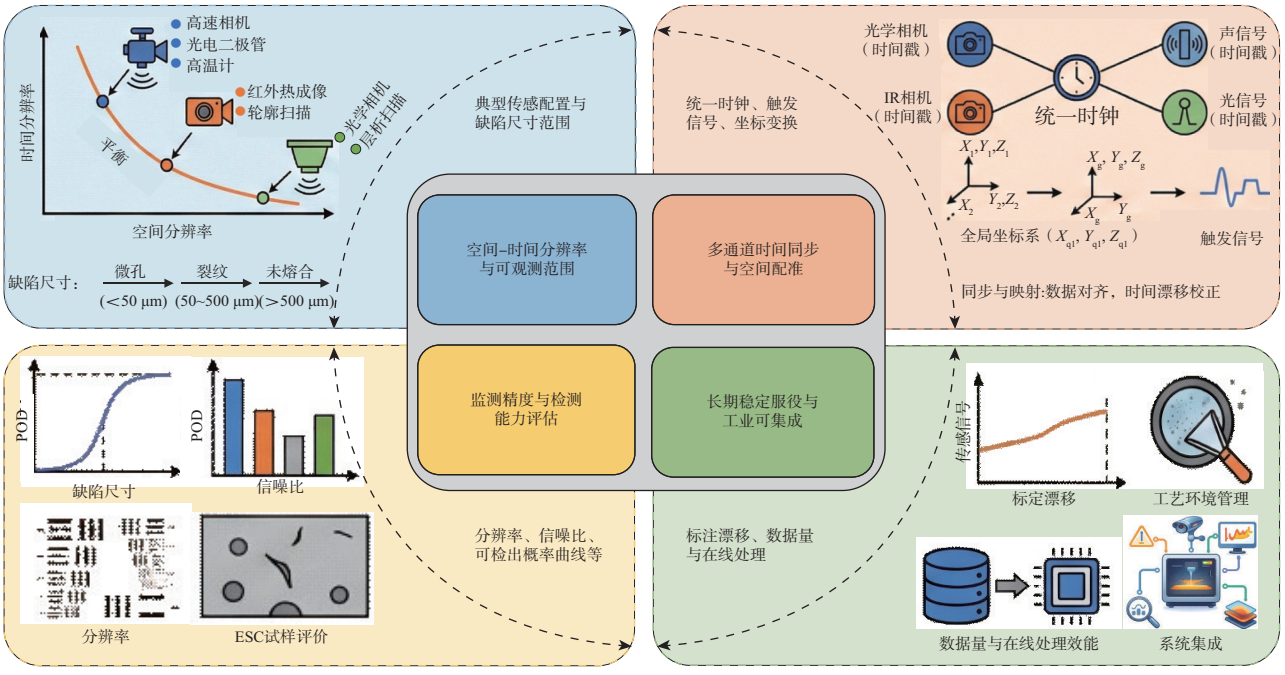


图3 SLM多源在线监测系统的关键工程问题

Fig.3 Key engineering considerations for SLM multi-sensor online monitoring systems

分辨率与毫米级视场之间进行配置，相关研究表明，不同配置下对微小孔隙和局部未熔合缺陷感知的灵敏性存在明显差异[57]。

多源监测的另一个核心问题在于多通道数据的时间同步与空间配准。不同传感器的采样频率、触发机制和数据接口存在显著差异，如果缺乏统一的时空间坐标体系，多模态数据很难在层级或整体质量监测中建立与对象的对应关系。Hocker等[86]针对Ti–6Al–4V成形件提出了系统化的“监测–同步–映射”流程，通过统一时间戳、硬件同步信号和扫描路径记录，将同轴热成像、旁轴CCD成像与设备运行日志映射到同一构建坐标系，实现了层内扫描路径矢量级的时空对齐。Feng等[87]进一步提出了将在线监测数据与工业CT、三维轮廓等离线检测数据进行配准的通用方法，包括坐标变换、形状匹配与误差评估，为评价在线监测信号与真实缺陷空间分布之间的对应关系提供了方案。

监测精度与检测能力评价关系到多源监测数据和分析结果在质量控制中的可信度。早期针对熔池监测的研究已经表明，需要通过对标准化预制标定件的监测试验来量化空间分辨率、信号调制度和信噪比等指标，并分析它们对熔池轮廓识别与特征提取的影响。Lindecke等[88]提出了基于“能量梯度块体”试样的原位过程监测系统通用评价方法，通过改变体积能量密度并记录各类监测信号，构建可跨设备应用的检测性能指标。从制造缺陷识别与判定的技术发展来看，面向零缺陷制造的研究明确提出不同传感系统的最小可检测缺陷尺寸、概率探测曲线（POD）以及误报率等指标，用以比较多种传感器结合对气孔、未熔合和裂纹检测上的性能差异[89]。此外，针对多模态系统如何在计量上实现不确定度的传递与合成，目前已经有研究从检测科学和标准化的视角给出了初步讨论[90]。

推动SLM多源在线监测系统从实验室走向工业生产环境，长期稳定服役与可集成性是必须要面临关键问题。Jensen等[91]通过长期性能监测与力学性能测试，揭示了即使在稳定的工艺参数条件下，随着运行周期的增加，设备/工艺和异常监测标签仍会出现显著偏差，需要通过对长期趋势的分析与周期性的再校准策略来保证过程的一致性。Hyer等[92]在对多种原位监测技术的系统评估中指出，传感器光路污染、温度漂移、机械振动以及设备维护方式都会对监测信号的基准和灵敏度产生累积影响，若缺乏针对性的稳定性设计与定期校准，将难以确保监测结果对质量判定的可靠性。在多模态融合监测系统中，监测通道数量增加还带来了数据量和处理复杂度急剧上升的问题，因此如何在确保信息高保真的前提下降维、筛选关键特征并实现在线处理，已成为数据处理方法相关研究的重点[93]。面向复杂多通道数据，最新的研究工作强调需要在算法层面引入对传感器失效、标定漂移和跨设备差异具有鲁棒性的学习框架，并通过解释性分析明确不同模态在缺陷识别中效能的边际效应，以确保监测系统在工业场景中的可维护和可升级需求[94]。

2 多源监测数据处理与融合方法

2.1 多源监测数据的时空对齐与过程映射

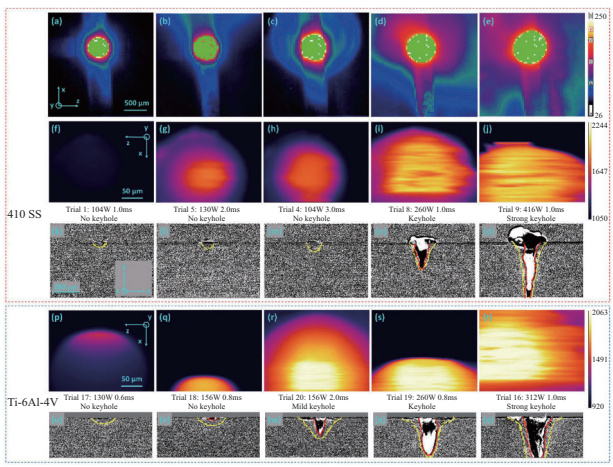
多源在线监测的数据只有在统一的时间基准和空间坐标下才能进行有效融合与开展质量关联分析。时间维度上，需要对不同传感器的采样频率、触发机制和数据接口进行整合，建立可溯源的时间轴；空间维度上，需要将各类图像、信号和过程日志映射到统一的构件坐标系，并进一步在体素或扫描轨迹层级组织数据。近年来的相关研究逐步给出了从采集坐标到构件体素/轨迹的系统化处理流程。

多源监测系统在时间轴对齐方面主要采用硬件触发、统一时间戳或后处理算法修正等策略。针对高帧率熔池监测与高能X射线成像的联合监测，Wang等[57]利用同步触发信号和统一时间基准对高速IR相机与同步辐射X射线成像进行整合，如图4（a）所示，使两类数据在>10 kHz的采样频率下实现逐帧对应，为后续熔池形貌与表面温度场的关联分析提供了支持。在多传感器光学监测系统中，Pandiyan等[35]通过对光电二极管触发和层间时间窗口管理，确保多路光学传感器数据的采集起止、激光开关和扫描路径严格对齐，降低了不同数据流之间的时间偏移误差。在通用场景下，Boer等[95]针对SLM多源融合监测平台提出了基于统一时间戳和延迟标定的同步方法，通过对不同采集通道进行延时标定和数据插值，可以在软件层面完成多通道信号在同一时间轴上完成重建。

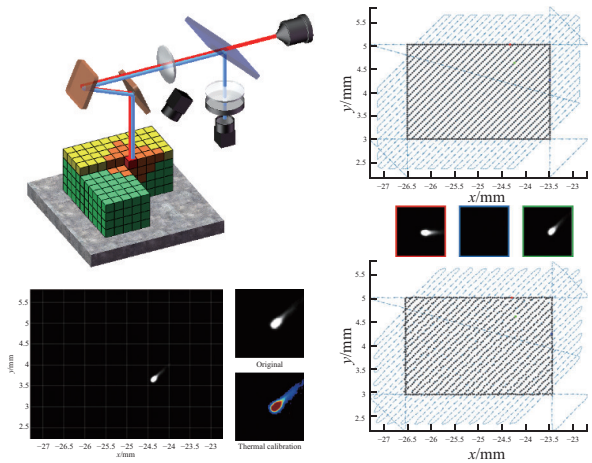
空间对齐通常从传感器成像平面或测量坐标出发，通过相机标定、光路几何建模与成形幅面坐标转换，将特征或测量点映射到构建平面乃至三维构件坐标。针对熔池监测图像，Zhang等[96]提出了大规模熔池监测数据的空间坐标确定与融合方法，利用扫描路径与层切片信息，对熔池光辐射强度、温度和尺寸等关键特征在层级的扫描矢量和几何截面进行重构，从而构建出制件的工艺工程熔池特征场，如图4（b）所示。在NIST发布的多模态在线监测数据集中，研究者通过对相机进行内、外参数标定，利用标志点识别与射线投影，将原本分属不同传感器坐标系的宽视场层间图像、局部熔池图像和扫描路径全部转换到统一的构建平面坐标系，最终形成了一个面向算法开发和性能评估的多模态过程监测数据

库[97]。此外，Kim 等[98]提出的深度学习熔池图像配准方法则实现了直接从原始熔池图像中评估其在成形幅面坐标系中的位置，实现了像素特征在制件构建坐标的快速映射，如图 4（c）所示。

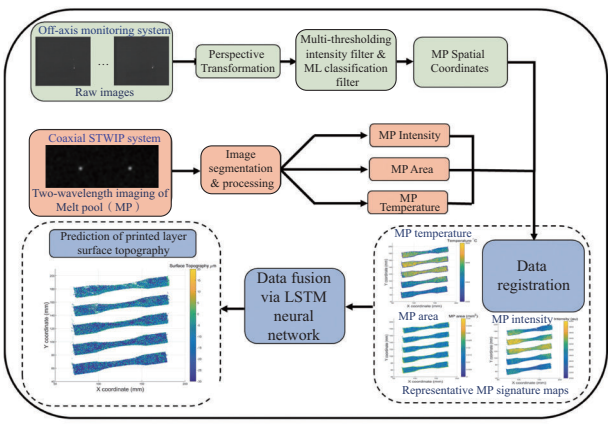
多源监测数据与制造缺陷或几何偏差之间的空间标定，本质上是连接在线过程信号与离线检测结果之间的桥梁，也是构建“熔道–成形层–制件整体”质量标签的关键前提。现有研究可归纳为两个主要方面：（1）面向空间标定方法，重点解决不同传感坐标系与离线检测坐标系之间的可靠对应关系；（2）将对齐后的多模态数据组织为适用于机器学习的数据结构，以实现缺陷预测与检出。围绕这几个方面，Oster 等[100]通过刚体配准、非刚体形变校正与成形区域轮廓匹配，将圆柱试样的序列热成像图与离线 XCT 获取的孔隙分布进行对齐，从而在体素尺度建立了温度信息与孔隙缺件之间的统计关系。Feng 等[87]提出了适用于多种几何形状的原位尺寸检测数据的配准流程，系统性涵盖坐标系标定、特征对齐、误差评估与不确定度分析，为在线监测与 CT、三维轮廓测量等离线检测之间建立可靠的空间对应关系提供了通用框架。Remani 等[67]则通过条纹投影获取逐层轮廓高度，将其按层序列映射到离线 XCT 检测数据中，从而分析粉末铺展或成形表面高度异常与内部孔隙簇的空间相关性。在上述标定与映射的基础上，后一层面研究开始将多模态过程特征进行体素化或轨迹化处理，以支撑监督学习和系统评估。Estalaki 等[101]将熔池及层间监测特征按激光扫描路径与切片网格编码为体素特征向量，并对缺陷和异常状态进行分类，验证了“逐体素”质量预测框架在复杂构件上的可行性。Hyer 等[102]则将层间成像、熔池信号与扫描路径映射至 CAD 切片中，构建异常概率图，并与工业 CT 或金相检测结果对比，用于量化不同传感组合在构件体素尺度上的缺陷检出能力。



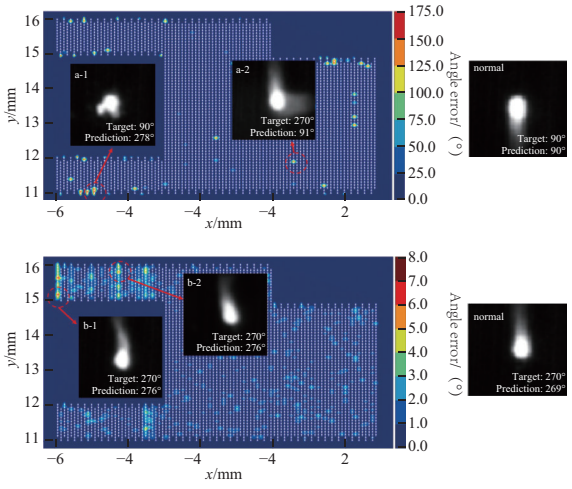
（a）同步触发信号和统一时间基准[57]



（b）基于扫描路径的层间特征重构[96]



（c）基于机器学习方法的图像特征与扫描轨迹融合[98]



（d）采集位置与激光开关、扫描路径配准[99]

图 4　多源在线监测数据从采集坐标到构建体素/轨迹的时空映射流程

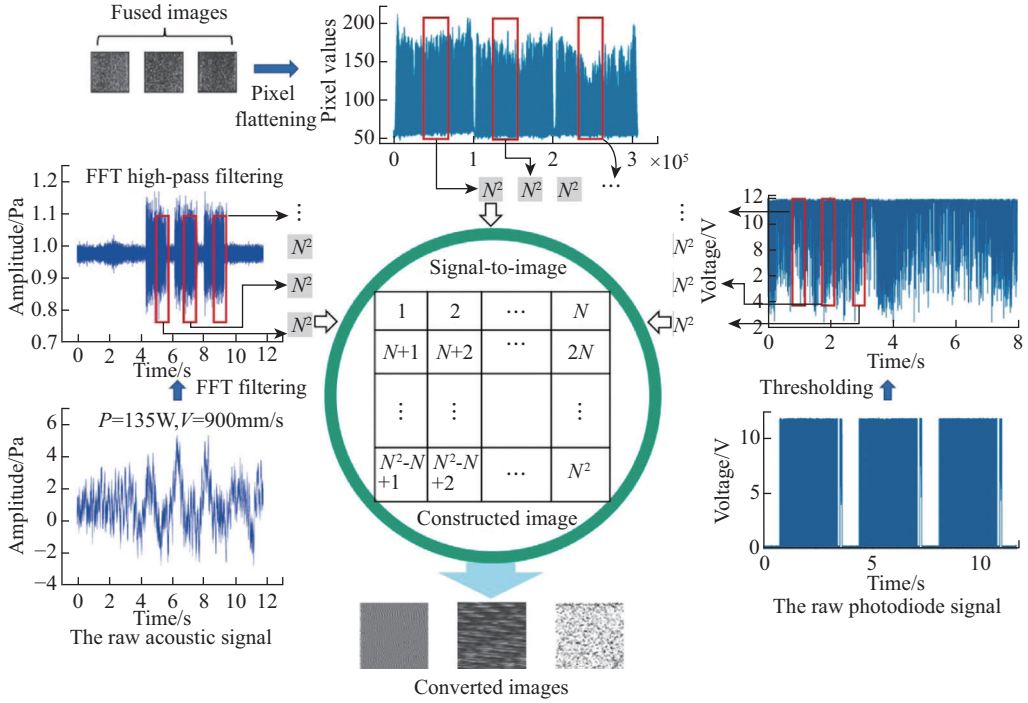
Fig.4　Spatiotemporal mapping workflow for multi-sensor online monitoring data from acquisition coordinates to build voxels/scan tracks

2.2 特征提取与多模态融合策略

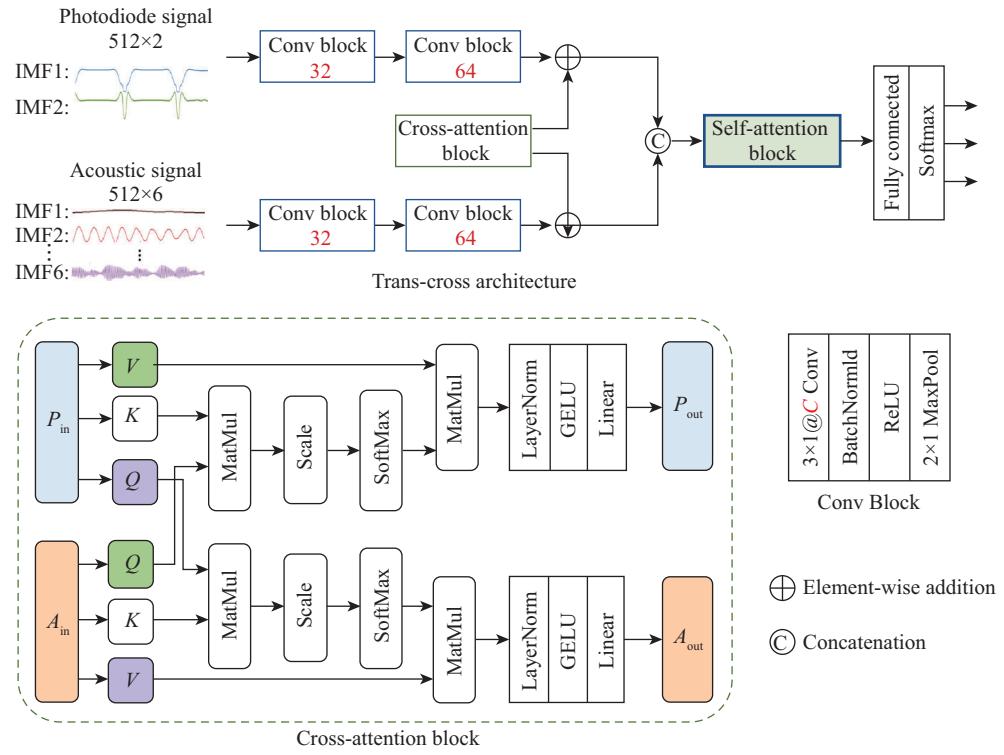
SLM在线监测数据的特征提取的核心任务是将原始监测数据转化为可建模的过程表征，并尽可能保持其对异常缺陷监测的灵敏度和结果的解释性。对于光电/辐射、声学/声发射、温度/高温计等一维时序信号，常见的做法是在路径片段或体素时间窗内，构建时域统计量、频域能量分布及时频表征（如谱图、小波尺度谱），并辅以复杂度指标（如熵）来解释信号的非稳态波动。Gutknecht等[103]在相同工艺场景下同步应用声学、同轴双色高温计与旁轴热成像，系统比较了3类传感器对过程扰动的敏感性与鲁棒性差异，结果发现同类缺陷在不同信号通道中呈现的特征趋势并不相同，表明单一模态的特征性能上限往往受到带宽、视场与辐射一致性等因素制约。Pfaff等[104]针对SLM工艺中通过单色/双色高温计进行温度监测的研究，讨论了发射率与标定对温度测量值的影响，其成果实现了温度相关特征从相对量向更具对比性的物理量的过度。对于同轴熔池近红外光信号监测方法，Moshiri等[48]则对其性能评估与测量局限给出系统的分析框架，为说明同轴光辐射/相机监测的应用边界提供了支持。在图像特征提取方面，层间宽视场图像与熔池局部图像的信息特征差异显著，前者更适用于成形层异常的空间定位与区域统计，而后者则更利于对熔池瞬态形貌与飞溅动力学表征。Scime等[105]提出的面向层间粉床图像的像素级语义分割框架，实现了异常区域的逐层定位与分类。

多源在线监测的关键在于跨模态信息的互补与互证，为此需要进一步确定多模态融合的层级与机制，将信号的动态特征信息、图像的空间信息以及过程日志信息在同一建模框架内融合，从而转化为对具体缺陷监测和质量调控任务的有效判别能力。多模态融合在工程实现中通常可按层级归纳为3类：数据层融合、特征层融合和决策层融合。数据层融合常见于同类数据的互补增强，Peng等[74]将可见光与红外信息进行图像融合，改善缺陷边缘与纹理可辨性，用于提高层间缺陷可检出性与可视化质量。这类工作侧重于为后端识别提供更清晰、信息更密集的输入，优势在于实现链路短、易于工程化，但对视角一致性与配准误差较为敏感，且难以直接适配非图像模态（如声发射、光电信号）。特征层融合是近年来多源监测构建中的主流路径，其典型范式是利用多分支网络分别提取图像与时序信号的特征，然后在中间层进行拼接、交互或注意力加权等处理。如图5（a）所示，Li等[106]构建了集成相机、声学与光电二极管于一体的多源采集系统，将层间图像、声学与光电信号输入CNN融合框架，实现了SLM工艺的原位质量监测。该工作的特点在于将异构模态统一为可训练的数据组织流程，便于复现与改造。后续研究中，他们在更轻量的“声学+光电”配置下开发特征级融合方法，旨在保证监测性能的同时提升系统的可部署性[107]。在算法结构层面，如图5（b）所示，Cao等[51]引入Transformer与交叉注意力机制进行多传感器数据融合，使各模态间信息交互从简单拼接转向可学习的选择性耦合，用于同步表征熔池稳定性与零件质量。Zou等[108]围绕熔池图像与同轴信号的融合，基于数据分区与融合建模的思路，强调通过优化数据组织策略来降低标定误差对特征提取的干扰，提出了融合前数据组织和融合模型并重的技术路线。

决策层融合是各模态（或各子模型）先独立完成缺陷和质量状态的判别和评估，再将风险概率或置信度进行融合并得到最终判定结果。与数据层或特征层融合相比，决策层融合对传感器缺失、通道性能退化和系统扩展的鲁棒性更好，工程部署时也更容易以模块化的方式来实现。其典型融合策略包括简单投票、加权平均、基于不确定度的加权以及以二级模型（stacking）对多路输出进行再学习等。决策层融合的关键问题不是融合方式的选择，而在于让各子模型输出结果具备可比性。如果各模态输出的概率没有经过校准，或不同通道对缺陷的敏感性差异没有被量化，那么输出的结果很容易成为对某一项强势模态信息的重复确认，从而引起虚假报警率升高或跨工况失效。因此，部分研究把决策层融合与检出能力绑定进行评估，Petrich[109]和Snow[110]等将决策层融合与外部参照（CT等）和可度量指标（如PoD）绑定，形成决策层融合输出与真实缺陷检测结果的闭环评估框架，用于比较不同传感组合与融合策略的检出能力，如图6（a）所示。为了使权重分配和置信度校准更具依据，部分研究引入更高可信度的标签来源，如原位X射线成像或离线表征结果，如图6（b）所示，Tempelman等[111]将高温计与声学信号的异常判定结果与X射线成像观测进行对齐，用于识别孔隙。Hamidi等[59]则利用X射线揭示孔洞形成过程中对应的声发射信号响应特征，从而增强缺陷判定的可靠性。此外，面向实际生产中常见的方法迁移问题，Pandiyan等[112]将声发射（AE）监测分析中引入区域自适应框架，通过分布对齐约束使模型训练到对熔化状态/缺陷更敏感，从而降低工艺参数变化引起的判别失效风险。在多模态场景下，同一团队进一步采用光学–声学对比学习，将光学与声学信号在潜在特征空间中融合，用跨模态一致性约束获得更稳定的联合表征，为后续决策层融合的置信度校准与权重分配提供更可靠的依据和基础[82]。



（a）基于图像与光电信号特征提取与融合策略[106]

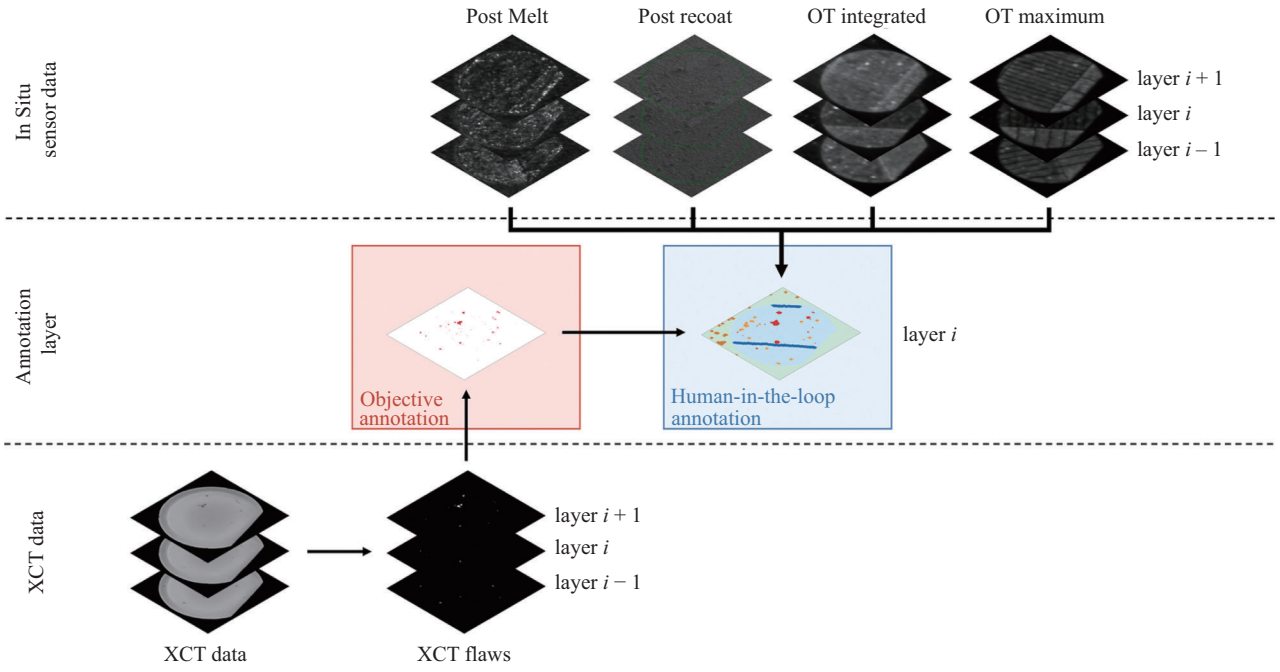


（b）基于深度学习框架的多模态信号特征融合（声信号和光电信号）[51]

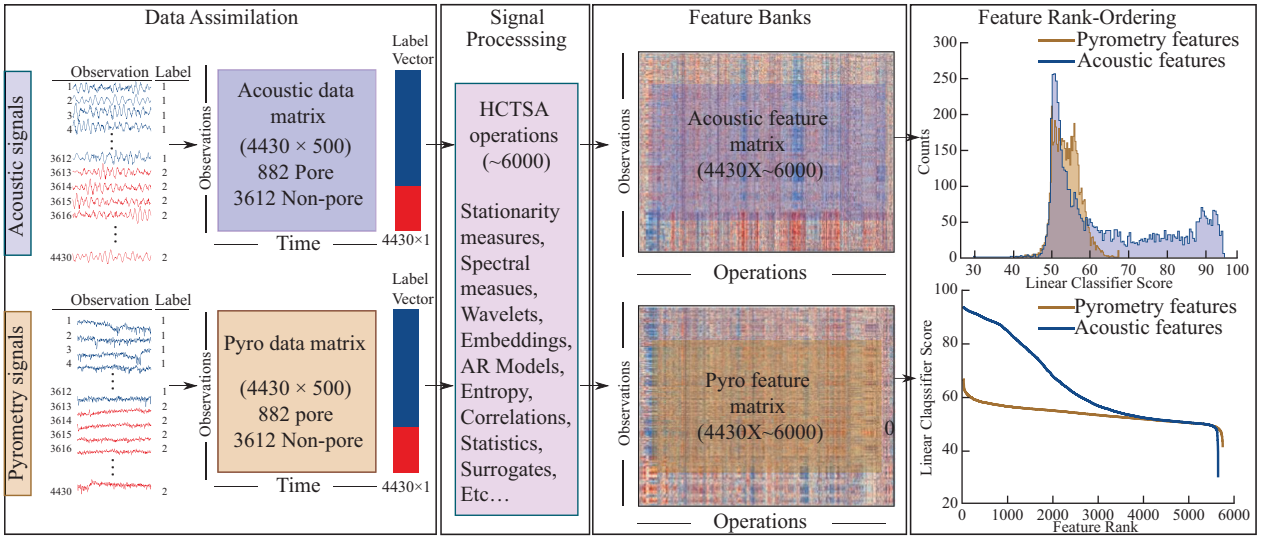
图5　原始信号特征提取与多模态融合策略

Fig.5　Feature extraction from raw signals and multimodal fusion strategies

上述3类多模态融合范式基于各自的特点和局限，在应用层面已逐渐形成较为明确的分支。数据层融合适用于输入同质、配准可靠且追求最大化信息保真的场景；特征层融合则更容易在计算成本与模型性能之间取得平衡，也更有利于处理异构模态与多时间尺度信号；决策层融合对模态缺失与系统扩展更具鲁棒性，但需要更严格的置信度校准与统一评估体系，以避免产生统计意义上的虚假增益。



（a）将离线检测结果作为决策融合模型训练标签以提升准确性[110]



（b）两种传感模态融合策略降低判断模型的错误率[111]

图6　决策层融合范式和优化

Fig.6　Decision-level fusion paradigms and optimization

2.3　混合机器学习与缺陷识别

本节主要探讨基于多源在线监测数据驱动的缺陷识别方法，关键在于将多通道、强噪声且对工况高度敏感的过程信号，基于混合机器学习模型提炼为具备泛化能力的缺陷表征与判别规则，如图7所示。相关研究大致形成3类路径：(1)以人工标注特征为核心的传统机器学习流程；(2)依赖端到端表征学习的深度多模态网络；(3)在模型结构或训练目标中引入物理一致性约束，并结合迁移学习或小样本学习，以增强模型在跨设备、跨材料与跨参数窗口条件下的稳健性。

传统机器学习在多源监测中仍占据重要位置，主要因为传统机器学习对数据规模要求相对较低、训练成本可控且具备较好的工程可解释性。常见做法是围绕缺陷机理构造具有判别力的统计量或谱特征，再借助分类器实现异常/缺陷识别。如图8(a)所示，Ali Khan 等[113]以层内光学断层图像为输入，采用随机森林对异常区域进行分割，并与CT结果对照验证，从而识别气孔与未熔合等缺陷类型。同时通过交叉验证与空间映射

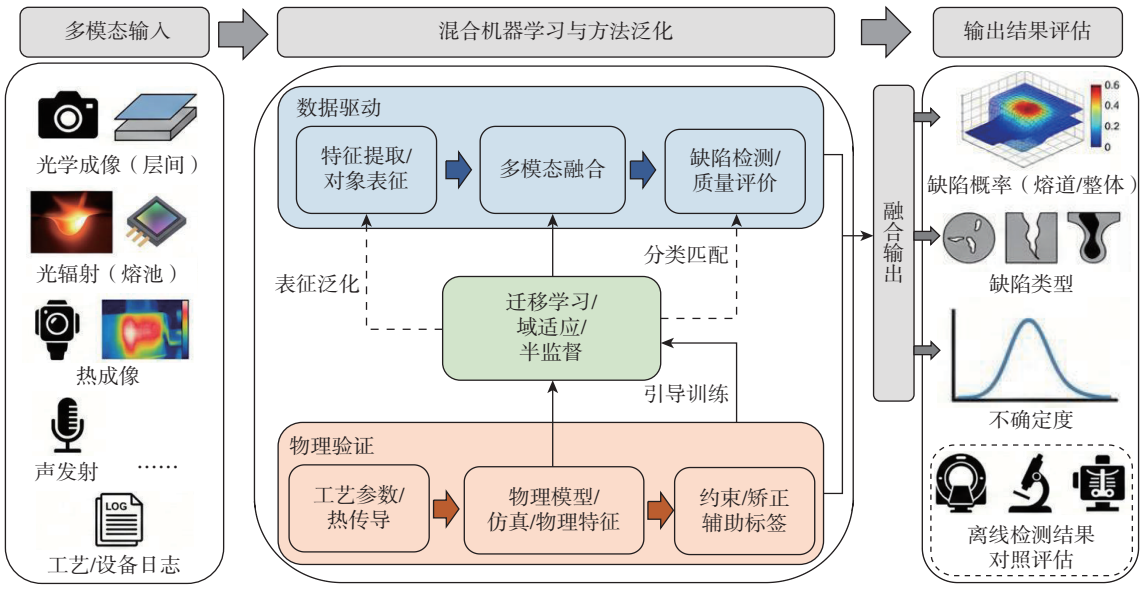


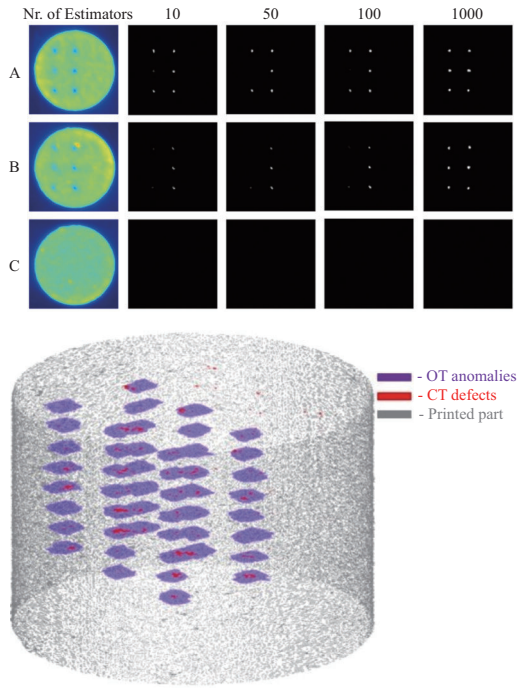
图7　当前在线监测数据的混合机器学习模型开发框架

Fig.7　Current development framework for hybrid machine-learning models using online monitoring data

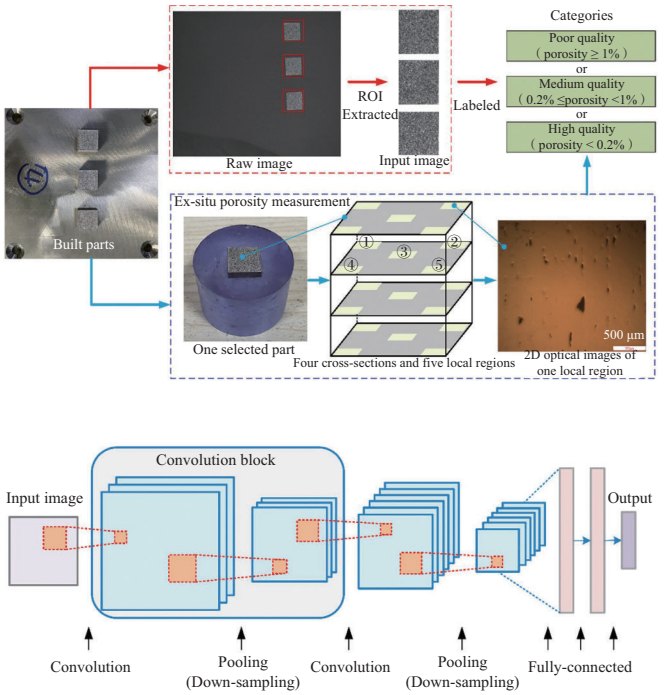
分析降低模型对单一构件或单一工况的依赖。此外，在侧重于从声学或热学信号中挖掘缺陷的“可辨识标记”相关研究中，Tempelman 等[114]结合声学测量与成像参照标定孔洞位置，通过机器学习流程提取与匙孔孔洞相关的低维声学特征，实现对孔洞形成位置的预测，并给出与机理相对应的解释。在多源互补的应用场景中，当单一模态对缺陷不敏感，或受遮挡、监测性能受限等因素影响时，引入第二模态（如高温计/热辐射或声学信号）往往能显著提升特征可分性，从而为后续融合学习提供更可靠的输入[111]。

深度学习在该领域的进展主要集中于两类任务：一类是面向层间/层内图像的缺陷定位与分类；另一类则是面向多源融合的复杂缺陷端到端识别。如图 8(b)所示，Li 等[115]针对逐层可见光图像构建深度迁移学习模型，在不依赖手工特征的条件下实现层间质量分类，体现了 CNN 对纹理、未熔合条带与飞溅相关形貌的表征能力。Mao 等[116]的研究中提出了一种物理引导的时空图，基于时空相关性从熔池图像中提取熔池时间特征节点和空间特征节点，利用图卷积网络和长短期记忆（LSTM）提取传热的时空信息并捕捉熔池的演化模式，如图 8(c)所示。当缺陷标签获取成本高、异常样本稀缺时，半监督与自监督策略逐渐成为重要补充，Nguyen 等[117]以光学在线监测为对象开展半监督异常检测，通过利用大量无标签数据学习稳定 SLM 工艺模式，再识别偏离正常模式产生的异常，从而解决由标注驱动带来的大量数据需求的瓶颈，如图 8(d)所示。在多模态网络结构方面，Cao 等[51]采用 Transformer 与跨注意力机制，将多传感器输入映射到统一表征空间并进行交互建模，用于同时刻画熔池稳定性与成形质量。该方法可显式建模模态间依赖与时间上下文，因此更适配多源同步监测场景。Bevans 等[50]进一步面向多尺度缺陷提出异构传感融合框架，强调跨分辨率、跨数据形态的统一判别，对复杂构件中与形状无关的缺陷检测具有启发意义。

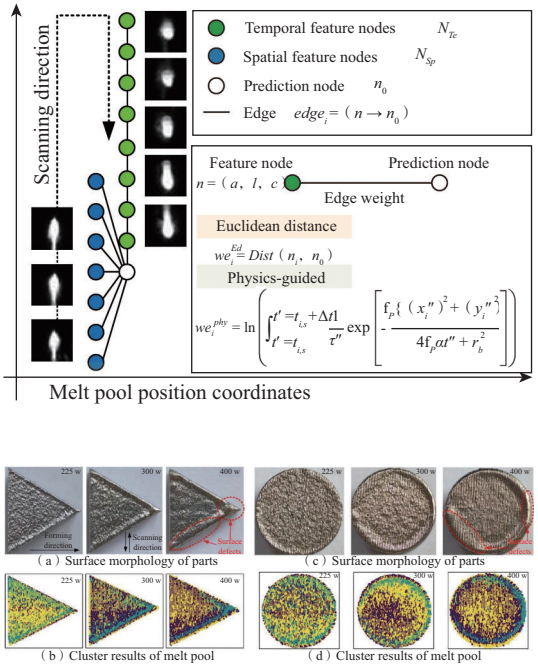
在工程应用落地方面，“物理信息+数据融合”方法正从概念探索逐步发展为可迁移的技术模块。其核心目标并非取代数据驱动，而是将能量输入、热传导、热积累等机理性的物理规律以可被检验的方式嵌入学习过程，从而提升模型在跨工况下的稳定性，并降低对数据中偶然关联的影响。这类方法着力解决的典型工程问题是当工艺窗口切换、粉末批次变更或光路状态改变时，即便缺陷判别目标不变，监测数据的统计分布也会发生系统性偏移，导致原有判别边界失效。Sajadi 等[118]提出的物理信息在线学习框架，通过将物理约束与在线权重更新相结合，使温度场预测模型能够适应新几何、新材料与新加工路径下的演化，直接增强了模型对工况变化的鲁棒性。在更贴近应用的熔池几何预测任务中，Ren 等[119]通过两级机器学习结构引入热历史相关的物理量作为上层预测输入，提升了熔池几何尺寸预测的稳健性，体现了“以物理量作为中间变量”在跨工况知识迁移中的优势。进一步的研究中，物理机理通常通过两类更具体的接口注入时空预测模型：第一类是结构先验，即将扫描轨迹连续性、层间热累积传递等多模态物理关联编码为图网络中的节点和边关系，从而为模型引入源自机理的拓扑约束；第二类是生成约束，即在训练过程中加入物理一致性惩罚项，以避免模型生



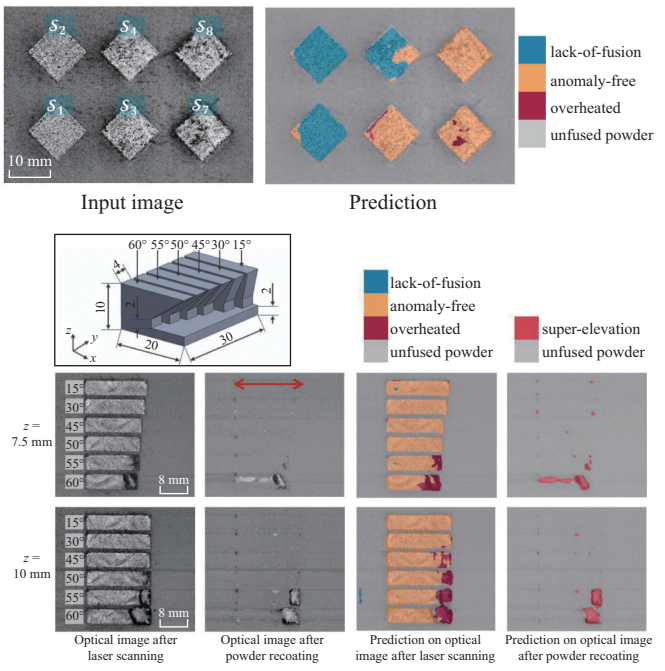
（a）基于光学层析成像数据的缺陷检测机器学习模型，应用CT数据验证准确性[113]



（b）基于分层视觉图像实现SLM质量检测的可行性和有效性[115]



（c）通过物理验证的方法增强深度学习模型的效能[116]



（d）应用半监督机器学习方法实现对监测数据分类[117]

图8　多源监测数据的混合机器学习缺陷识别示例

Fig.8　Examples of defect identification using hybrid machine-learning on multi-sensor monitoring data

成监测信息合理但物理现象失真的结果，例如熔池形貌与能量输入不匹配。Kim等[120]提出的物理引导深度生成模型，以及基于解析传热方程构建图边权重、再结合图网络学习时空相关性的方法，类似的如Mao等[116]的研究均为“热积累”这类难以纯数据学习的物理效应提供了可融合、可解释的建模路径。

跨设备、跨材料与跨工艺参数窗口的泛化能力，是当前多源缺陷识别领域备受关注却极具挑战的前沿方向之一。迁移学习成为应对这一难题的常见策略，其核心方法是将源域中的判别性表征迁移至目标域，并利

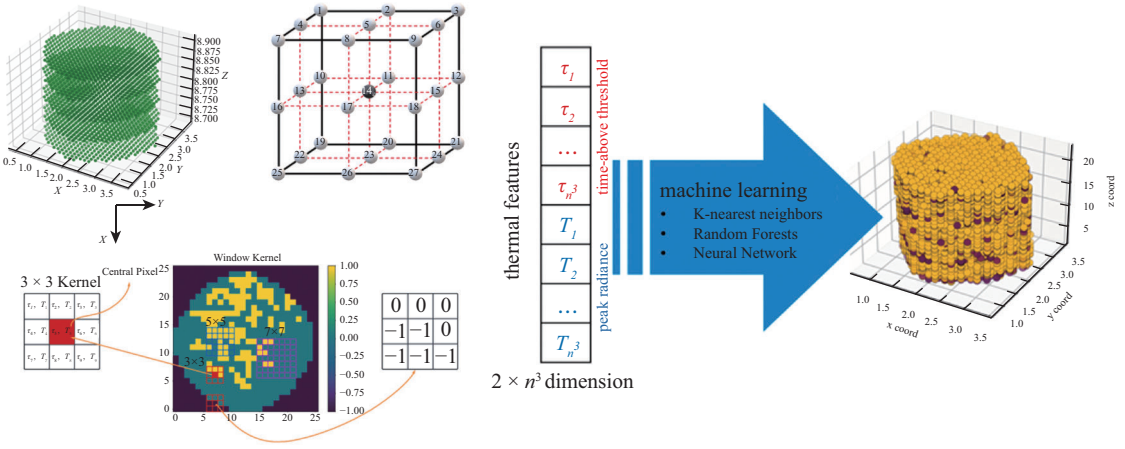
用少量数据进行快速适配。Li等[121]围绕跨材料质量监测开展了迁移学习研究，重点探索在目标域数据有限的条件下如何维持有效的识别性能。与此同时，少样本学习与半监督学习的结合也正加速应用于激光粉末床熔化缺陷识别方向。Ilani等[122]提出了融合迁移学习与少样本/半监督机制的框架，以应对缺陷标注稀缺的难题。此外，面向在线部署的轻量化深度网络研究逐渐增多，Tan等[123]提出的轻量层间缺陷检测范式，旨在推理效率与识别性能之间取得更好平衡。Yan等[124]针对LPBF逐层铺粉图像提出基于通道剪枝的轻量高分辨缺陷检测方法，在保持较高识别精度的同时显著压缩模型规模并缩短推理时间，为实时在线检测提供了更具工程可实施性的方案。Zhao等[125]则进一步基于3D点云与深度学习构建了实时粉床缺陷检测系统，并在实际打印中验证了其闭环缺陷处置潜力，表明在线识别框架已开始由“离线判别”向“实时干预”延伸。对于SLM多源融合监测而言，模型精度并非是进入闭环控制链路的唯一约束，在高频、多维且强时序耦合的数据条件下，算法推理延迟、数据传输开销以及融合计算复杂度同样会直接影响在线应用的可行性。有综述就指出，数据级融合虽然能够保留更完整的信息，但通常伴随更高的带宽与存储负担。相比之下，特征级融合往往能在预测性能与计算成本之间取得更好的平衡。与此同时，轻量边缘模型、嵌入式GPU/FPGA平台部署，以及面向边缘侧的高效Transformer或图网络实现，正成为提升多源高频数据实时处理能力的重要方向[32]。需要强调的是，跨域和迁移学习的有效性高度依赖于统一的标注定义与评估标准，这主要源于缺陷形成过程本身具有随机性与多机理耦合的特点，为此Hamidi等[59]通过结合X射线成像，揭示了声学信号与熔池状态及缺陷演化之间的关联，从而为以可观测的物理过程来约束数据驱动的缺陷判别提供了可靠的证据链条。此外，正如ORNL机构面向核工业应用发布的监测评估报告指出的[102]，传感组合、算法性能与离线检测结果之间的可比性，往往受到数据集定义、数据对齐、标注方式以及不确定度量化方法是否一致的影响，而这也表明，方法性能的优劣在很大程度上取决于这些基础评估条件是否具备统一性与透明度。

3 基于多源在线监测的SLM质量预测与调控

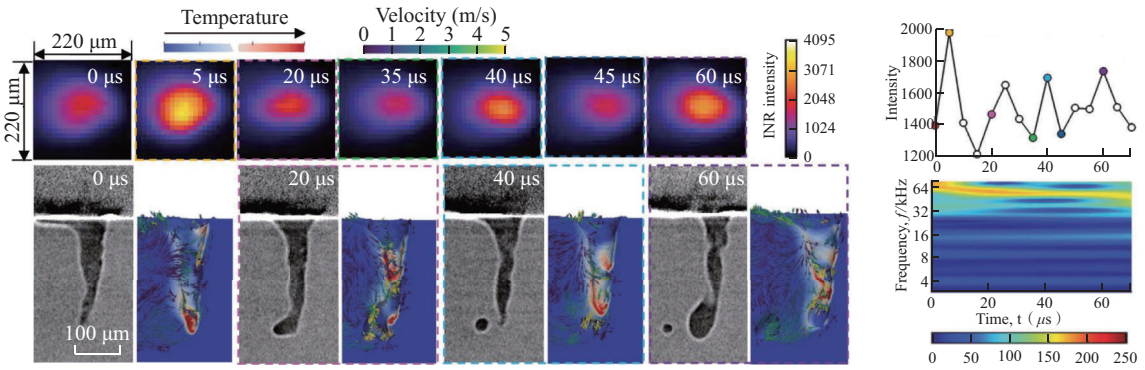
3.1 质量预测

在多源在线监测背景下，质量预测通常呈现由局部到整体、由缺陷到性能的递进目标。首先，在轨迹或体素尺度建立孔隙、未熔合等缺陷的空间化风险表征；随后，在层级尺度预测几何与表面质量偏差；最终，建立过程特征与制件力学性能、残余应力及几何形变之间的映射关系，从而为构建可视化质量图及后续质量控制策略提供依据。在缺陷分布预测方面，体素或区域级的缺陷标记图谱近年成为主流表达形式之一。Estalaki等[101]利用短波热像的温度特征（如超过熔点持续时间、最大辐射强度等）进行体素尺度下微孔隙分布的预测，并进一步引入邻域体素特征以反映热扩散的空间耦合效应，展示了通过热成像数据的体素缺陷预测框架可实现较高的分类性能，如图9(a)所示。Mao等[126]则针对未熔合孔隙提出层级预测思路，利用前几层的热特征来预测后续层的孔隙风险，并通过CT检测验证其预测结果的有效性，从而为层间热累积引发孔隙形成的预测提供了更低误差的建模方法。在异常事件识别方面，如图9(b)所示，Ren等[127]借助同步辐射X射线获取高保真孔隙生成的真实数据，用于训练可在亚毫秒时间分辨率下监测孔隙生成事件的预测模型，并进一步融合声–光多传感器信息实现本地化的快速孔隙检出，实现了基于异常预测与高可信标签的质量预测技术路径[128]。与此同时，裂纹与热裂倾向的预测也逐渐纳入多源在线监测的研究范畴，Kononenko等[129]基于声发射与机器学习提出了原位裂纹检测的概念框架。如图9(c)所示，Li等[130]则从声学信号中提取与缺陷物理机制相关的特征，并构建可解释的深度模型用于孔隙监测，体现了声学模态在“快速异常事件”识别中的潜力。

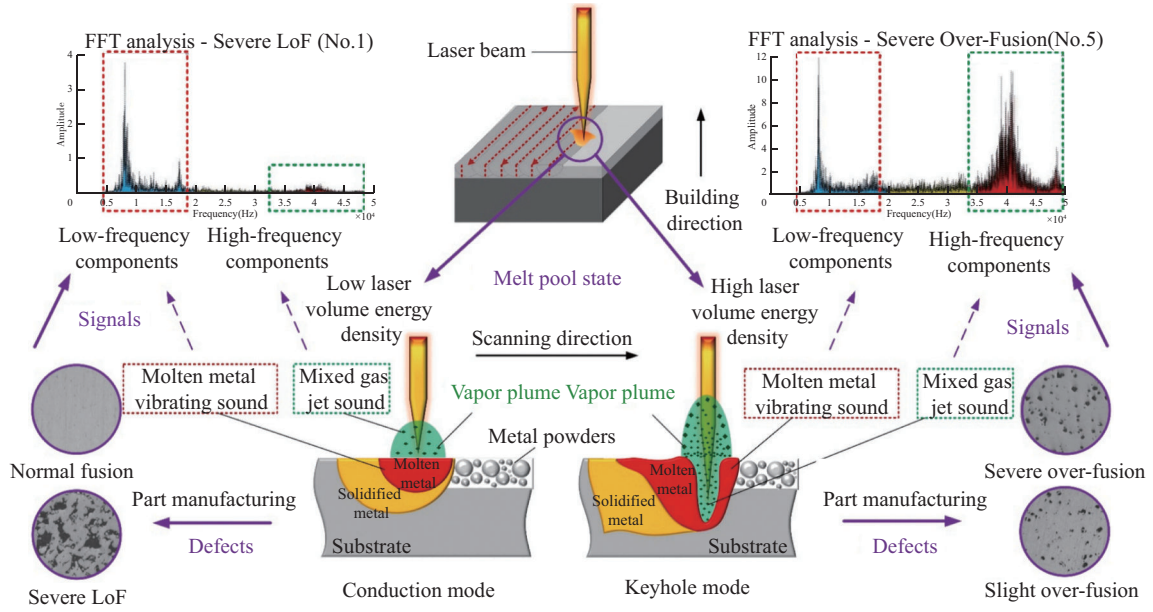
在关于几何尺寸与表面质量预测的研究更关注成形区域几何形貌的空间连续性及度量的可追溯性，典型评价指标包括层间轮廓偏差、边缘翘曲或塌边、成形表面粗糙度以及局部高度异常等。Remani等[67]面向激光粉末床熔化工艺的机内层间监测，提出了基于条纹投影的系统，可输出逐层高度图并用于过程异常识别，体现了主动结构光技术在层间形貌测量中所具备的高分辨率与鲁棒性优势。针对轮廓与边界的定量预测，Zhang等[131]提出了高精度的层间三维轮廓检测方法，如图10(a)所示，着重实现了对边界及几何特征的稳定提取，从而为后续尺寸偏差与翘曲监测提供了技术支持。在此基础上，关于能否在成形舱内直接量化翘曲与几何偏差的问题，已有研究提供了面向激光粉末床熔化的原位三维轮廓测量方案，能够检测常见几何特征的偏差并识别构件边缘翘曲，为几何质量预测奠定了可在线实施的计量基础[132]。在表面粗糙度评估方面，Sen等[133]利用原位光学断层扫描技术对激光粉末床熔化表面粗糙度进行了系统评估，Toorandaz等[134]则进一步提出了面向垂直表面粗糙度的原位预测框架，如图10(b)所示。近年来，He等[135]也开始借助深度学习实现粗糙度及相关缺陷特征的联合表



（a）基于温度特征和扫描路径融合的微孔隙分布预测[101]



（b）基于同步X射线成像、高速热成像和多物理场模拟的高时间分辨率缺陷预测机器学习模型[127]



（c）基于声信号和多尺度空间交互融合的缺陷监测方法[130]

图9　SLM制件缺陷分布预测

Fig.9　Prediction of defect distributions in SLM

征与预测，其中成形层厚作为影响工艺端几何质量与缺陷风险的关键工艺因素，也出现了无需显式标注的学习路径；Kavas等[136]利用同轴高温计信号开展自监督学习，以推断局部层厚的变化，从而为串联层厚、能量输入和缺陷/几何偏差之间的耦合关系提供了一个更易于在线部署的方案。在多模态监测条件下则强调不同模

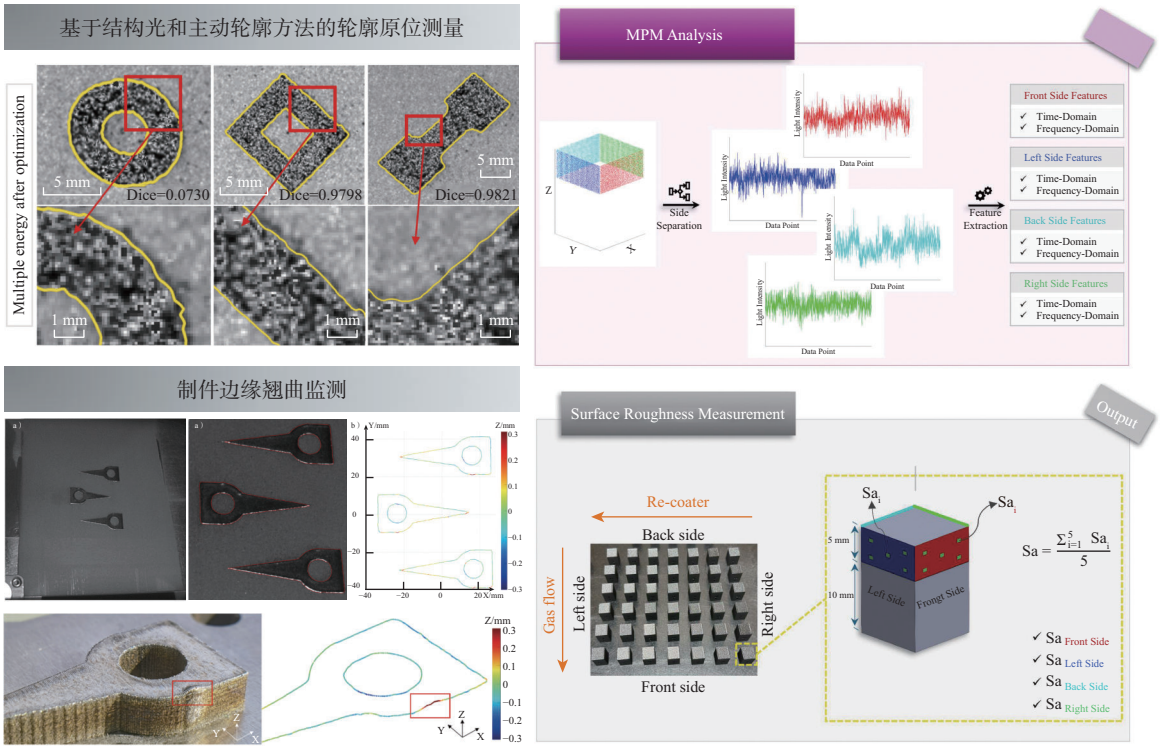
态对几何特征变化的互证与互补，Yang等[97]基于开放架构SLM试验台同步采集同轴熔池图像与层间成像数据，围绕悬垂等典型几何特征开展统计分析，表明在面向几何/表面质量的融合建模中，需要把位置坐标对齐与监测信息增益同时作为设计目标，仅依赖简单拼接无法达成稳定的监测效能。

在从缺陷与几何尺寸预测进一步迈向制件级性能预测的过程中，研究重点正逐步转向建立“过程表征–组织/缺陷–性能指标”之间的跨尺度映射关系，并发展与之相应的可解释建模方法。Nagato等[137]通过引入与过程不稳定相关的飞溅及飞行颗粒动态观测统计量，显著提升了对硬度等力学性能指标的预测精度，这体现了过程异常特征在构建性能代理指标方面的重要价值。Yu等[138]采用可解释机器学习方法对SLM制件的硬度进行预测并分析了各影响因素的贡献度。Luo等[139]则进一步探讨了利用原位过程数据预测AlSi10Mg力学性能的可行性及其跨工况迁移问题，表明性能预测正从传统的经验分析向可解释、可迁移的方向演进。与残余应力及变形相关的预测研究，通常需要与热–力学建模或数字孪生框架紧密结合。Peng等[140]提出一种温度场快速预测方案，先用少量高精度热仿真或实验数据训练“代理模型”，再在成形过程中用该模型实时估计温度分布，并将其集成于数字孪生系统。同时，Wu等[141]的也强调，通过试验、仿真与机器学习相结合的联合路线，可在计算效率与结果可验证性之间取得有效平衡。

关于过程数据能否替代部分传统离线无损检测技术的讨论，当前学界与工程界普遍认为其更有意义的是作为补充性的质量证据一环。具体而言，过程数据主要用于生成缺陷概率图或工艺风险图，借此筛查制造异常的高风险区域，从而为后续抽检及离线检测提供有针对性的采样指导。美国橡树岭国家实验室（Oak ridge national laboratory，ORNL）在公开报告中对原位在线监测技术与算法进行了系统评估。报告指出，若要使缺陷评估结果或异常概率图在工程实践中具备可用性，必须与离线检测结果建立可靠的空间对应关系，同时明确定义缺陷判据与阈值，并最终以可重复的检出概率及不确定度量化结果作为检出能力评估的依据。相关研究也指出，多模态数据融合虽有助于提升缺陷检测的覆盖面，但同时也对数据标定、系统校准以及评估协议的统一提出了更高要求[92,142]。

3.2 质量调控

随着激光粉末床熔融技术向高可靠性与工程化应用发展，制造质量控制已从单一依赖事后检测，转变为基于制造过程信息的实时感知与主动调控。在此背景下，多源监测驱动的质量调控应运而生，其核心目标是通过对关键物理状态的实时或准实时感知，抑制随机扰动对成形质量的



（a）层内凝固区域三维几何监测[131-132]　　（b）基于原位光电信号与机器学习框架的制造过程表面质量预测[134]

图10　层间成形区域质量监测

Fig.10　Layer-wise build-area quality monitoring

放大效应，构建稳定、可复制的制造过程。依据控制策略对过程动态响应的能力差异，现有研究可分为开环调控、闭环调控以及在此基础上演进形成的数字化质量保证体系。

3.2.1 开环质量调控

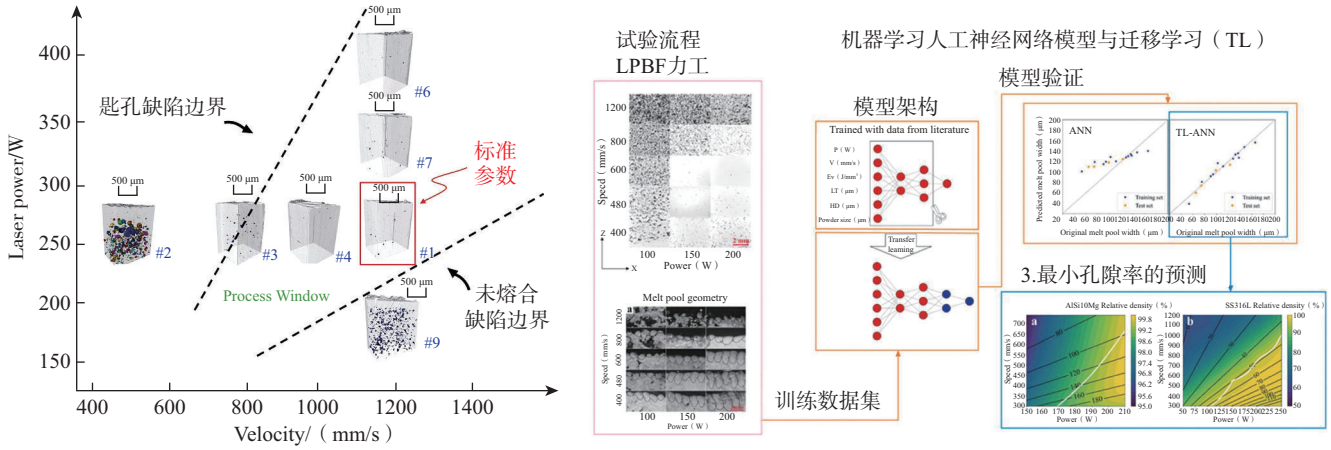
开环调控的核心在于建立工艺参数–熔池/熔合行为–成形质量之间的确定性映射关系，如图11（a）所示[143]，在制造前或制造过程中预先界定稳定的工艺窗口，从而系统性地降低缺陷发生概率。该策略一般以物理机理认知为基础，辅以试验或统计建模手段，如图11（b）所示[144]，强调对典型失稳机制的有意识规避。实现这一目标的前提是对熔池动力学行，粉末床质量及其工艺失稳条件具备准确理解。King等[145]结合高速成像与热传导模型，系统分析了激光功率与扫描速度对熔池模式转变的影响规律，指出当输入能量超过临界阈值时，熔池会从传导模式转变为深熔模式，并诱发蒸汽腔体周期性塌陷，进而形成匙孔型气孔。该研究为工艺参数的安全边界界定提供了明确的物理依据。Khairallah等[146]基于高保真的粉末尺度数值模型，进一步揭示了反冲压力与马兰戈尼对流在熔池流动、飞溅形成及粉末剥离中的主导作用，从机理层面解释了孔洞、飞溅及成形不连续区域的成因。Roberts等[147]通过三维瞬态有限元模拟表明，重复热循环引起的温度梯度与局部过热是热应力积累与残余应力演化的主要驱动力，该结论凸显了在工艺规划阶段控制热输入一致性的重要意义。随着在线监测技术的发展，多源感知信息开始被用于辅助界定开环调控的工艺窗口。Grasso等[148]的工作系统梳理了光学、热成像等信号与气孔、球化等典型缺陷之间的关联，为异常状态识别提供了方法框架。然而，传统的体积能量密度在表征熔池状态时存在明显局限。Scipioni等[149]指出，VED无法反映光斑尺寸变化及熔池内部复杂物理过程，因而对成形区几何形貌的在预测准确性不足。为此，Weaver等[150]提出了基于功率、速度与光斑尺寸的缩放定律，并将吸收率变化纳入分析，显著提高了熔池几何特征预测的普适性。

此外，飞溅行为与缺陷分布的空间异质性也是开环调控需关注的重要因素。Gunenthiram等[151]对316L不锈钢的定量分析表明，大尺寸飞溅随VED增加而显著增多，其主要机理为金属蒸发诱导的高速蒸汽羽流喷射。Moran等[152]进一步揭示了缺陷在成形空间内的不均匀分布，指出受保护气体流场影响，不同位置试样的孔隙率存在显著差异，这对工艺窗口的整体稳定性提出了更高要求。在此背景下，数据驱动方法逐步被引入开环调控框架，以挖掘复杂传感信号与质量指标之间的隐含关联。Yuan等[153]提出基于卷积神经网络的两阶段学习框架，实现了对熔道质量的高精度预测。Coeck等[154]则通过原位光电信号与离线CT结果的系统比对，建立了基于熔池辐射强度波动的孔隙分布概率模型，为内部缺陷的量化预测提供了新的思路。

尽管开环调控能够在较大程度上界定可用工艺窗口并降低典型缺陷的发生概率，但其仍以预设工况与离线验证为基础，难以充分应对制造过程中不可避免的随机扰动、局部热积累及几何突变等动态偏差。因此，为进一步提升SLM系统对过程失稳的响应能力，相关研究重心开始转向实时在线干预，相应地也形成了闭环反馈调控与原位干预技术路线。

3.2.2 闭环反馈调控

为提升SLM系统应对动态工艺偏差的自适应能力，闭环调控通过构建在线测量–在线判定–在线执行的实时反馈控制链路，实现对加工状态



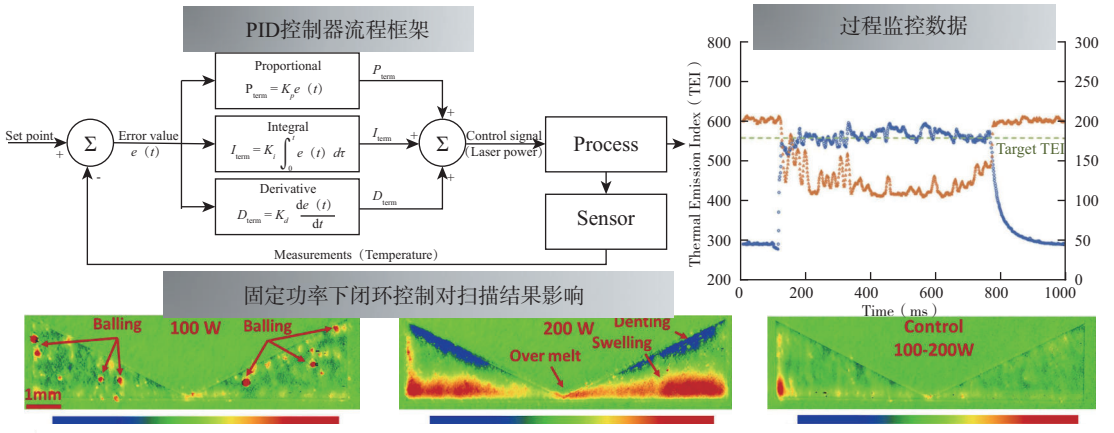
（a）孔洞缺陷工艺参数图谱[143]　　（b）基于熔池几何形状的工艺图谱预测[144]

图11　基于在线监测的SLM质量开环调控

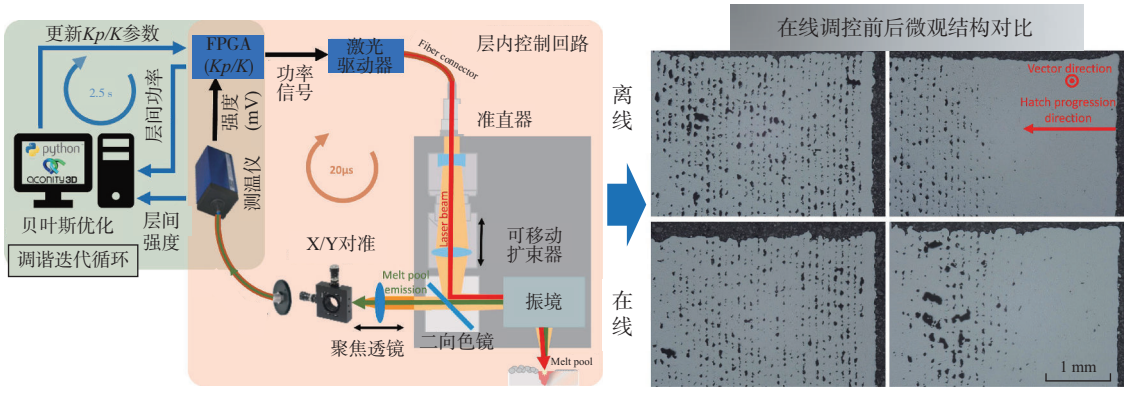
Fig.11　Quality regulation and control in SLM based on online monitoring

的主动干预。根据控制对象与时间尺度不同，闭环调控通常分为层内实时控制与层间决策反馈两类。层内控制强调对熔池瞬态行为的快速响应，对传感系统与控制算法的实时性要求极高。围绕熔池尺度反馈监测，Clijsters 等[155]开发了基于 FPGA 架构的闭环原型系统，采用双光电传感实时监测熔池辐射，并通过动态调节激光功率实现对局部热积累的有效补偿。Shkoruta 等[156]在基于熔池视频流的反馈控制研究中展示了实时图像反馈闭环的可行性，说明在足够高的采样与处理速率下，熔池几何尺寸数据可作为控制量进入控制器设计。如图 12（a）所示，Wang 等[157]进一步给出了基于热辐射发射信号的闭环激光功率控制，用试验展示了在构件导热条件改变的情况下维持熔池稳定性的路径。为进一步提升异常检测的灵敏度与鲁棒性，Zhang 等[158]提出融合熔池、羽流与飞溅特征的多对象视觉监测方法，并利用卷积神经网络实现对复杂工况下异常的识别。需注意的是，传感信号易受加工几何形状干扰，Craeghs 等[159]定量分析了待加工区域几何特征对辐射信号的影响，强调了在控制算法中剥离几何诱导波动的必要性。基于对上述动态关系的深入理解，该研究团队开发了可实时调节激光功率的反馈控制系统，实现了对熔池波动的毫秒级响应，有效抑制了下表面过热与特征尺寸超差等问题[160]。McCann 等[18]进一步指出，实现高效层内控制的关键在于传感系统的时空分辨率须与激光扫描的超高动态特性相匹配，并提出了面向未来发展的模块化系统架构。

相较之下，层间闭环调控更侧重于对已成形层表面状态及铺粉质量的阶段性评估，尤其适用于热积累显著、横截面突变或悬垂区域。Kavas 等[161]提出利用旁轴热像实时获取层间温度，并通过在线优化式控制器逐层更新激光功率参数，从而维持热平衡、抑制过热趋势，体现了层级执行的闭环控制范式。如图 12（b）所示，Kavas 等[162]近期的研究中进一步将激光停留时间纳入闭环调控变量，采用物理感知的调整策略以增强热稳定性，为激光功率与扫描速度之外的非热源工艺参数参与闭环调控提供了具体的技术例证。在控制器工程化方面，Yeung 等[163]针对实时在线功率反馈控制的研究，从系统层面探讨了连续功率调整与熔池面积反馈的实现路径，为高频闭环控制在激光粉末床熔化过程中的可行性提供了直接的试验依据。



（a）闭环调控框架及三维扫描结果对比[157]



（b）层内控制–迭代循环示意图及在线调控微观结构[162]

图 12　基于在线监测的 SLM 质量闭环调控

Fig.12　Quality regulation and control in SLM based on online monitoring

相较于开环优化和闭环调控直接关联到制造过程，质量认证与数字化标准体系则关注监测与调控的结果能否被规范记录、有效解释并形成可信质量依据加以使用。进一步而言，当多源监测数据开始承担质量判定和过程追溯功能时，质量控制问题便不再局限于是否可被监测或调控，而延伸至是否可被验证和被标准化约束。

3.2.3 质量认证与数字化标准体系

随着在线监测与调控技术日趋成熟，增材制造的质量控制体系正朝着数字化、可溯源的方向不断发展。其核心目标在于将多源监测数据转化为具备工程参考价值的质量证据，并建立与之配套的标准化框架。Everton等[17]系统阐述了原位测量技术在质量保证中的作用，提出可通过集成记录多物理场工艺过程数据，形成贯穿零件制造全过程的数字质量证明，为质量追溯提供基础支撑。Smith等[164]发展的空间分辨声学光谱技术，则为微观组织与表面缺陷的无损表征提供了新的物理手段，可用于验证调控策略的实际效果。然而，标准体系的缺失仍是制约该技术规模化应用的主要瓶颈。美国国家标准与技术研究院（National institute of standards and technology，NIST）在相关报告中指出[165]，目前尚缺乏统一的传感器校准规范、数据交换格式与物理量溯源体系。因此，建立跨平台、可交互的过程测控数据标准，是推动原位监测与质量调控数据获得监管认可并作为可靠判定依据的关键前提。未来成熟的质量调控与认证体系将呈现多层次、自适应和可追溯协同的特征。其中，开环调控用于确立SLM工艺参数基础，闭环控制用于维持SLM工艺过程稳定，标准化数字架构则为质量认证提供可信支撑。三者共同构成完整体系，将成为推动SLM技术向高可靠性、智能化制造范式转型的重要基础。

从当前行业研究趋势可以看出，SLM质量控制体系正在由单一的参数优化逐步演进为集工艺窗口构建、实时反馈干预、数字化质量保证标准体系于一体的多层次协同框架。其中，开环调控为制造过程提供稳定的工艺边界与规避异常的依据，闭环调控则着重面向动态偏差实现在线修正，而数字化标准体系则负责将过程监测与调控结果转化为可追溯、可验证、可共享的质量保证依据，三者在工程实施中共同构成从制造前规划，到制造中干预，再到制成后认证的连续技术链条。

4 结论与展望

4.1 结论

本文围绕激光选区熔化多源融合在线监测与质量控制为主线，从多源在线监测构成与工程实现、多模态数据处理与融合、质量预测与调控方法3个方面综述了相关研究进展，主要结果归纳如下。

（1）SLM多源在线监测正在从单一信号判别走向多源监测数据支撑的质量判断。不同模态监测方法在时间分辨率、空间覆盖与缺陷检测效能上各有侧重，集成应用能够更连续完整地表征质量缺陷风险、几何偏差和表面质量等。现阶段多源在线监测系统的关键不仅是传感器数量的增加，更重要在于不同传感器的同步和量化分析路径是否可靠。

（2）跨模态的时间一致与空间对应是多源融合监测能否落地的重要前提。在时间维度与空间维度上建立映射关系和扫描轨迹的关联，直接决定了多模态特征能否形成可供比对的数据组织形式，并进而影响缺陷标签能否准确对应。融合策略已从早期的特征拼接逐渐发展到多分支表征、注意力交互等复杂框架，但如果缺乏统一的评价准则与验证流程，即使基于某些数据集可以获得较高效能指标，也很难在跨工况场景中实现稳定复现。

（3）SLM质量预测与调控呈现出从离线判定走向工艺过程中管理的趋势，制件整体或扫描路径的缺陷监测正在成为连接过程监测与质量判定的重要桥梁。在质量调控层面，开环控制策略更侧重于利用监测信息反推工艺窗口、标定稳定加工区，从而支持工艺库和策略的建立。相较之下，闭环策略主要围绕可控执行量实现在线修复。相应地，触发修复策略的可靠性和执行安全边界仍需进一步研究，质量调控收益的评估与认证体系也有待建立。

4.2 展望

尽管多源融合在线监测与质量控制已取得显著进展，但其工程化应用仍面临若干共性挑战。其中，跨设备、跨工艺和材料的泛化能力不足，导致质量判定模型与规则容易随工况变化而失效的问题尤为突出。此外，高置信度评价标签获取代价较高，且缺陷定义与标注粒度不一致，制约了模型训练与效能评估。与此同时，由在线监测、自主判定和反馈控制组成的在线质量调控技术框架仍缺少统一的不确定度表征与效能边界描述，难以支撑质量评估与结论认证。对于闭环控制而言，目前尚缺少面向不同缺陷种类的分级调控策略及安全认证评估，因此调控收益与风险边界在工程应用中仍难以审验。面向未来发展，多源融合在线监测与质量控制的研究趋势可归纳为以下几方面。

（1）以可追溯的监测数据与评价体系作为行业技术发展共同基准。监测效能的竞争不再仅由某个算法指标决定，而取决于数据是否可信、结论是否可复现、流程是否可审查。围绕传感器校准、数据交互、缺陷判定、质量评价准则与不确定度表达等要素，建立跨平台可比较的通用框架，将成为多源监测走向规模化应用的关键。

（2）以物理一致性约束提升跨场

景可迁移性，并完善基准数据与评估协议。融合模型应更多引入能量输入、热历史与热传导等可解释中间量，作为工艺状态评估与建模的共同约束，降低对偶发相关特征的依赖。同时，推动公开或可共享的多模态标准数据库建设，统一缺陷定义、标签粒度与评价指标，形成可复现的缺陷检出能力，为SLM工艺过程监测数据可替代部分离线检测提供可验证依据。

（3）发展分级执行与安全约束相结合的SLM闭环控制架构，并与质量保证流程关联。其中，闭环控制应优先覆盖低风险、可验证的在线修复任务，并在此基础上逐步引入模型预测控制等更高效的控制框架。与此同时，执行修复的触发规则应与异常判定分级相对应，以明确安全边界和失效模式下的处置策略。此外，还应将多源监测数据记录、存储与质量报告共同纳入质量体系，从而推动质量调控与质量认证形成完整的数据闭环。

（4）加强面向高价值制造场景的数据安全与可信部署研究。伴随多源融合在线监测发展生成海量工艺数据，其数据存储、传输、访问、控制的信息安全问题将日益突出。特别是在航空航天、军工等高价值制造场景中，相关数据将关联工艺知识、制件信息与质量证据，其安全流转与可信使用将直接影响相关技术落地的可行性。未来面向工业应用需求，需进一步围绕数据安全存储、分级传输、权限管理、模型可信部署等关键问题开展研究，为多源融合在线监测与质量控制的工程化应用提供保证。

参 考 文 献

[1] Lewandowski J J, Seifi M. Metal additive manufacturing: A review of mechanical properties[J]. Annual Review of Materials Research, 2016, 46: 151–186.

[2] DebRoy T, Wei H L, Zuback J S, et al. Additive manufacturing of metallic components—Process, structure and properties[J]. Progress in Materials Science, 2018, 92: 112–224.

[3] Yang Y Q, Jiang R W, Han C J, et al. Frontiers in laser additive manufacturing technology[J]. Additive Manufacturing Frontiers, 2024, 3(4): 200160.

[4] Dejene N D, Lemu H G, Gutema E M. Critical review of comparative study of selective laser melting and investment casting for thin-walled parts[J]. Materials, 2023, 16 (23): 7346.

[5] Jawade S A, Joshi R S, Desai S B. Comparative study of mechanical properties of additively manufactured aluminum alloy[J]. Materials Today: Proceedings, 2021, 46: 9270–9274.

[6] Bertocco A, Iannitti G, Caraviello A, et al. Lattice structures in stainless steel 17–4PH manufactured via selective laser melting (SLM) process: Dimensional accuracy, satellites formation, compressive response and printing parameters optimization[J]. The International Journal of Advanced Manufacturing Technology, 2022, 120(7): 4935–4949.

[7] 周运龙, 马毅, 管迎春. 面向航空发动机高性能制造的激光选区熔化技术研究进展[J]. 航空学报, 2024, 45(13): 43–80.

Zhou Yunlong, Ma Yi, Guan Yingchun. Research progress on laser selective melting technology for high-performance manufacturing of aero-engines[J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(13): 43–80.

[8] Sarzyński B, Śnieżek L, Grzelak K. Metal additive manufacturing (MAM) applications in production of vehicle parts and components—A review[J]. Metals, 2024, 14(2): 195.

[9] Zhang G Q, Li J X, Zhang C G, et al. Design Optimization and Manufacturing of bio-fixed tibial implants using 3D printing technology[J]. Journal of the Mechanical Behavior of Biomedical Materials, 2021, 117: 104415.

[10] Liu Q, Zhang Y M, Chen W L, et al. Bioactive and fatigue-resistant Ti–Ta alloy by additive manufacturing for orthopedic applications[J]. Smart Materials in Manufacturing, 2025, 3: 100086.

[11] 闫泰起, 唐鹏钧, 陈冰清, 等. 能量密度对激光选区熔化成形AlSi10Mg合金缺陷及力学性能的影响[J]. 机械工程学报, 2020, 56(24): 96–105.

Yan Taiqi, Tang Pengjun, Chen Bingqing, et al. Effect of energy density on defects and mechanical properties of AlSi10Mg alloy fabricated by selective laser melting[J]. Journal of Mechanical Engineering, 2020, 56(24): 96–105.

[12] Sow M C, De Terris T, Castelnau O, et al. Influence of beam diameter on laser powder bed fusion (L – PBF) process[J]. Additive Manufacturing, 2020, 36: 101532.

[13] Hojjatzadeh S M H, Parab N D, Guo Q L, et al. Direct observation of pore formation mechanisms during LPBF additive manufacturing process and high energy density laser welding[J]. International Journal of Machine Tools and Manufacture, 2020, 153: 103555.

[14] 吕新蕊, 刘婷婷, 廖文和, 等. 高强铝合金7075激光粉末床熔融凝固裂纹的消除与质量控制[J]. 中国激光, 2022, 49(14): 1402209.

Lü Xinrui, Liu Tingting, Liao Wenhe, et al. Solidification crack elimination and quality control of high-strength aluminum alloy 7075 fabricated using laser powder bed fusion[J]. Chinese Journal of Lasers, 2022, 49(14): 1402209.

[15] 赵志斌, 王晨希, 张兴武, 等. 激光粉末床熔融增材制造过程智能监控研究进展与挑战[J]. 机械工程学报, 2023, 59(19): 253–276.

Zhao Zhibin, Wang Chenxi, Zhang Xingwu, et al. Research progress and challenges in process intelligent monitoring of laser powder bed fusion additive manufacturing[J]. Journal of Mechanical Engineering, 2023, 59(19): 253–276.

[16] Li J C, Cao L C, Xu J, et al. In situ porosity intelligent classification of selective laser melting based on coaxial monitoring and image processing[J]. Measurement, 2022, 187: 110232.

[17] Everton S K, Hirsch M, Stravroulakis P, et al. Review of in-situ process monitoring and in-situ metrology for metal additive manufacturing[J]. Materials & Design, 2016, 95: 431–445.

[18] McCann R, Obeidi M A, Hughes C, et al. In-situ sensing, process monitoring and machine control in laser powder bed fusion: A review[J]. Additive Manufacturing, 2021, 45: 102058.

[19] 周安, 刘秀波, 刘庆帅, 等. 选区激光熔化成形过程监测技术研究进展[J]. 中国

表面工程, 2023, 36(4): 36–50.

Zhou An, Liu Xiubo, Liu Qingshuai, et al. Progress of in-process monitoring techniques for selective laser melting[J]. China Surface Engineering, 2023, 36(4): 36–50.

[20] Grasso M, Remani A, Dickins A, et al. In-situ measurement and monitoring methods for metal powder bed fusion: An updated review[J]. Measurement Science and Technology, 2021, 32(11): 112001.

[21] Fang Q H, Xiong G, Zhou M C, et al. Process monitoring, diagnosis and control of additive manufacturing[J]. IEEE Transactions on Automation Science and Engineering, 2024, 21(1): 1041–1067.

[22] Shaloo M, Schnall M, Klein T, et al. A review of non-destructive testing (NDT) techniques for defect detection: Application to fusion welding and future wire arc additive manufacturing processes[J]. Materials, 2022, 15 (10): 3697.

[23] Peng X, Kong L B, An H J, et al. A review of in situ defect detection and monitoring technologies in selective laser melting[J]. 3D Printing and Additive Manufacturing, 2023, 10(3): 438–466.

[24] 李中伟, 张禹泽, 钟凯, 等. 激光粉末床熔融光学原位监测技术综述[J]. 华中科技大学学报(自然科学版), 2022, 50(12): 1–9, 27.

Li Zhongwei, Zhang Yuze, Zhong Kai, et al. In-situ monitoring techniques for laser powder bed fusion additive manufacturing: A review[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2022, 50(12): 1–9, 27.

[25] 王迪, 唐涛, 蒋仁武, 等. 基于光电二极管的激光选区熔化过程监测及信号分析[J]. 中国激光, 2025, 52(8): 0802304.

Wang Di, Tang Tao, Jiang Renwu, et al. Monitoring and signal analysis of selective laser melting process based on photodiodes[J]. Chinese Journal of Lasers, 2025, 52(8): 0802304.

[26] 张赛凡, 李博, 轩福贞. 激光选区熔化过程声发射信号的降噪与分类预测方法[J]. 机械工程学报, 2024, 60(6): 163–176.

Zhang Saifan, Li Bo, Xuan Fuzhen. Signal denoising and classification prediction method for on-line monitoring of acoustic emission during laser melting process[J]. Journal of Mechanical Engineering, 2024, 60(6): 163–176.

[27] 张兴武, 唐甲锋, 谭鲲鹏, 等. 基于声发射信号的激光粉末床熔融在线监测与内部质量智能判别方法[J]. 振动工程学报, 2025, 38(6): 1134–1144.

Zhang Xingwu, Tang Jiafeng, Tan Kunpeng, et al. Online monitoring and intelligent internal quality discrimination method for laser powder bed fusion based on acoustic emission signals[J]. Journal of Vibration Engineering, 2025, 38(6): 1134–1144.

[28] 陈锦堂, 张凯, 刘婷婷, 等. 激光粉末床熔融成形件的翘曲变形监测[J]. 中国激光, 2024, 51(16): 1602306.

Chen Jintang, Zhang Kai, Liu Tingting, et al. Monitoring of warping deformation of laser powder bed fusion formed parts[J]. Chinese Journal of Lasers, 2024, 51(16): 1602306.

[29] AbouelNour Y, Gupta N. In-situ monitoring of sub-surface and internal defects in additive manufacturing: A review[J]. Materials & Design, 2022, 222: 111063.

[30] Wang P, Yang Y R, Moghaddam N S. Process modeling in laser powder bed fusion towards defect detection and quality control via machine learning: The state-of-the-art and research challenges[J]. Journal of Manufacturing Processes, 2022, 73: 961–984.

[31] Cai Y H, Xiong J, Chen H, et al. A review of in-situ monitoring and process control system in metal-based laser additive manufacturing[J]. Journal of Manufacturing Systems, 2023, 70: 309–326.

[32] Papatheodorou A, Papadimitriou N, Stathatos E, et al. Recent advances in sensor fusion monitoring and control strategies in laser powder bed fusion: A review[J]. Machines, 2025, 13(9): 820.

[33] Teles G, Rodrigues J J P C, Rabêlo R A L, et al. Comparative study of support vector machines and random forests machine learning algorithms on credit operation[J]. Software: Practice and Experience, 2021, 51 (12): 2492–2500.

[34] Babu S S, Mourad A I, Harib K H, et al. Recent developments in the application of machine-learning towards accelerated predictive multiscale design and additive manufacturing[J]. Virtual and Physical Prototyping, 2023, 18(1): e2141653.

[35] Pandiyan V, Wróbel R, Leinenbach C, et al. Optimizing in-situ monitoring for laser powder bed fusion process: Deciphering acoustic emission and sensor sensitivity with explainable machine learning[J]. Journal of Materials Processing Technology, 2023, 321: 118144.

[36] Aydogan B, Chou K. Review of in situ detection and ex situ characterization of porosity in laser powder bed fusion metal additive manufacturing[J]. Metals, 2024, 14 (6): 669.

[37] Murtaza A, Shah A, Ayub H, et al. A review of in situ process image monitoring for selective laser melting[C]//Third International Conference on Key Enabling Technologies (KEYTECH2023). Istanbul: AIP Publishing, 2023: 020018.

[38] Archaryagie K C S, Tang Y L. Enhancing powder bed quality in laser powder bed fusion: A review of monitoring, data processing, and adaptive control strategies[J]. Journal of Manufacturing Processes, 2025, 149: 276–304.

[39] Tapia G, Elwany A. A review on process monitoring and control in metal-based additive manufacturing[J]. Journal of Manufacturing Science and Engineering, 2014, 136(6): 060801.

[40] Lin X, Shen A C, Ni D W, et al. In situ defect detection in selective laser melting using a multi-feature fusion method[J]. IFAC–PapersOnLine, 2023, 56(2): 4725–4732.

[41] Zhang Y J, Yan W T. Applications of machine learning in metal powder-bed fusion in-process monitoring and control: Status and challenges[J]. Journal of Intelligent Manufacturing, 2023, 34(6): 2557–2580.

[42] Shdefat A Y, Mostafa N, Al–Arnaout Z, et al. Optimizing HAR systems: Comparative analysis of enhanced SVM and k – NN classifiers[J]. International Journal of Computational Intelligence Systems, 2024, 17 (1): 150.

[43] Chen L Q, Bi G J, Yao X L, et al. In-situ process monitoring and adaptive quality enhancement in laser additive manufacturing: A critical review[J]. Journal of Manufacturing Systems, 2024, 74: 527–574.

[44] Zhang J Y, Yin C, Xu Y Y, et al. Machine learning applications for quality improvement in laser powder bed fusion: A state-of-the-art review[J]. International Journal of AI for Materials and Design, 2024, 1(1): 26.

[45] Hou Z J, Wang Q, Zhao C G, et al. Online monitoring technology of metal powder

bed fusion processes: A review[J]. Materials, 2022, 15(21): 7598.

[46] 陈香媛, 韦辉亮, 刘婷婷, 等. 基于熔池光信号的激光粉末床熔融沉积缺陷在线监测与诊断[J]. 中国激光, 2024, 51(10): 136–149.

Chen Xiangyuan, Wei Huiliang, Liu Tingting, et al. In-situ monitoring and diagnostics for deposition defects in laser powder bed fusion process based on optical signals of melt pool[J]. Chinese Journal of Lasers, 2024, 51(10): 136–149.

[47] Gaikwad A, Williams R J, De Winton H, et al. Multi phenomena melt pool sensor data fusion for enhanced process monitoring of laser powder bed fusion additive manufacturing[J]. Materials & Design, 2022, 221: 110919.

[48] Moshiri M, Pedersen D B, Tosello G, et al. Performance evaluation of in-situ near-infrared melt pool monitoring during laser powder bed fusion[J]. Virtual and Physical Prototyping, 2023, 18(1): e2205387.

[49] Wei B, Liu J Q, Li J, et al. Research on an online monitoring device for the powder laying process of laser powder bed fusion[J]. Micromachines, 2024, 15(1): 97.

[50] Bevans B, Barrett C, Spears T, et al. Heterogeneous sensor data fusion for multiscale, shape agnostic flaw detection in laser powder bed fusion additive manufacturing[J]. Virtual and Physical Prototyping, 2023, 18(1): e2196266.

[51] Cao L C, Guo W T, Li J C, et al. Transformer and cross-attention-based multi-sensor in-situ monitoring of molten pool stability and part quality in laser powder bed fusion[J]. Optics and Lasers in Engineering, 2024, 183: 108522.

[52] Zhang S, Zhang Z F, Chen X Z, et al. Intra-layer and inter-layer monitoring of laser powder bed fusion defects based on airborne acoustic and gn–Res model: Pore and deformation[J]. Virtual and Physical Prototyping, 2024, 19(1): e2360699.

[53] Yavari R, Riensche A, Tekerek E, et al. Digitally twinned additive manufacturing: Detecting flaws in laser powder bed fusion by combining thermal simulations with in-situ meltpool sensor data[J]. Materials & Design, 2021, 211: 110167.

[54] 杨永强, 蒋仁武, 刘子欣, 等. 大尺寸粉末床激光熔融流场分析及在线监控研究进展[J]. 机械工程学报, 2023, 59(19): 389–410.

Yang Yongqiang, Jiang Renwu, Liu Zixin, et al. Research progress of flow field analysis and in-situ monitoring for large-scale laser powder bed fusion[J]. Journal of Mechanical Engineering, 2023, 59(19): 389–410.

[55] Goossens L R, Van Hooreweder B. A virtual sensing approach for monitoring melt-pool dimensions using high speed coaxial imaging during laser powder bed fusion of metals[J]. Additive Manufacturing, 2021, 40: 101923.

[56] Vallabh C K P, Zhao X Y. Melt pool temperature measurement and monitoring during laser powder bed fusion based additive manufacturing via single-camera two-wavelength imaging pyrometry (STWIP) [J]. Journal of Manufacturing Processes, 2022, 79: 486–500.

[57] Wang R X, Garcia D, Kamath R R, et al. In situ melt pool measurements for laser powder bed fusion using multi sensing and correlation analysis[J]. Scientific Reports, 2022, 12: 13716.

[58] Breese P P, Altenburg S J. Absolute temperature determination in laser powder bed fusion (PBF – LB/M) via hyperspectral thermography[J]. Progress in Additive Manufacturing, 2025, 10(7): 4217–4226.

[59] Hamidi Nasab M, Masinelli G, de Formanoir C, et al. Harmonizing sound and light: X-ray imaging unveils acoustic signatures of stochastic inter-regime instabilities during laser melting[J]. Nature Communications, 2023, 14: 8008.

[60] Ikeshoji T T, Yonehara M, Kato C, et al. Spattering mechanism of laser powder bed fusion additive manufacturing on heterogeneous surfaces[J]. Scientific Reports, 2022, 12: 20384.

[61] Myers A J, Gobert C, Beuth J L, et al. High-speed imaging investigation and process mapping of the plume behavior in laser powder bed fusion[J]. Additive Manufacturing, 2025, 106: 104797.

[62] Baehr S, Melzig L, Bauer D, et al. Investigations of process by-products by means of Schlieren imaging during the powder bed fusion of metals using a laser beam[J]. Journal of Laser Applications, 2022, 34(4): 042045.

[63] Luo S Y, Ma X Q, Xu J, et al. Deep learning based monitoring of spatter behavior by the acoustic signal in selective laser melting[J]. Sensors, 2021, 21(21): 7179.

[64] Fischer F G, Birk N, Rooney L, et al. Optical process monitoring in laser powder bed fusion using a recoater-based line camera[J]. Additive Manufacturing, 2021, 47: 102218.

[65] Liu T, Lough C S, Sehhat H, et al. In-situ infrared thermographic inspection for local powder layer thickness measurement in laser powder bed fusion[J]. Additive Manufacturing, 2022, 55: 102873.

[66] Schmitt A M, Sauer C, Höfflin D, et al. Powder bed monitoring using semantic image segmentation to detect failures during 3D metal printing[J]. Sensors, 2023, 23(9): 4183.

[67] Remani A, Rossi A, Peña F, et al. In-situ monitoring of laser-based powder bed fusion using fringe projection[J]. Additive Manufacturing, 2024, 90: 104334.

[68] Zhang Y Z, Zhang P, Li H, et al. In-situ detection of powder bed defects in laser powder bed fusion using 3D surface normals and depth mapping[J]. Journal of Materials Research and Technology, 2025, 39: 792–800.

[69] Kouprianoff D, Yadroitsava I, du Plessis A, et al. Monitoring of laser powder bed fusion by acoustic emission: Investigation of single tracks and layers[J]. Frontiers in Mechanical Engineering, 2021, 7: 678076.

[70] Mohr G, Altenburg S J, Ulbricht A, et al. In-situ defect detection in laser powder bed fusion by using thermography and optical tomography—Comparison to computed tomography[J]. Metals, 2020, 10(1): 103.

[71] Ashby A, Guss G, Ganeriwala R K, et al. Thermal history and high-speed optical imaging of overhang structures during laser powder bed fusion: A computational and experimental analysis[J]. Additive Manufacturing, 2022, 53: 102669.

[72] Ma C G, Wang D, Zhao K, et al. Layer-wise surface quality improvement in laser powder bed fusion through surface anomaly detection and control[J]. Computers & Industrial Engineering, 2024, 191: 110098.

[73] Lucà F, Chiariotti P, Bugatti M, et al. Toward in situ monitoring of 3D surface topography in laser powder bed fusion additive manufacturing via polarized imaging[J]. Progress in Additive Manufacturing, 2025, 10 (11): 9971–9987.

[74] Peng X, Kong L B, Han W, et al. Multi-sensor image fusion method for defect detection in powder bed fusion[J]. Sensors, 2022, 22(20): 8023.

[75] Seleznev M, Gustmann T, Friebel J

M, et al. In situ detection of cracks during laser powder bed fusion using acoustic emission monitoring[J]. Additive Manufacturing Letters, 2022, 3: 100099.

[76] Pauzon C, Dietrich K, Forêt P, et al. Control of residual oxygen of the process atmosphere during laser-powder bed fusion processing of Ti－6Al－4V[J]. Additive Manufacturing, 2021, 38: 101765.

[77] Emminghaus N, Bernhard R, Hermsdorf J, et al. Residual oxygen content and powder recycling: Effects on microstructure and mechanical properties of additively manufactured Ti－6Al－4V parts[J]. The International Journal of Advanced Manufacturing Technology, 2022, 121 (5): 3685–3701.

[78] Feng S, Chen Z E, Bircher B, et al. Predicting laser powder bed fusion defects through in-process monitoring data and machine learning[J]. Materials & Design, 2022, 222: 111115.

[79] Zhou H X, Song C H, Yang Y Q, et al. In situ monitoring of melt pool and signal modification in laser powder bed fusion[J]. IEEE Sensors Journal, 2023, 23(20): 24944–24953.

[80] Montazeri M, Rao P. Sensor-based build condition monitoring in laser powder bed fusion additive manufacturing process using a spectral graph theoretic approach[J]. Journal of Manufacturing Science and Engineering, 2018, 140(9): 091002.

[81] Zalameda J N, Bison P, Lane B, et al. Multiple sensor detection of process phenomena in laser powder bed fusion[C]// Thermosense: Thermal Infrared Applications XXXVIII. Baltimore: International Society for Optics and Photonics, 2016, 9861: 986108.

[82] Pandiyan V, Baganis A, Axel Richter R, et al. Qualify-as-you-go: Sensor fusion of optical and acoustic signatures with contrastive deep learning for multi-material composition monitoring in laser powder bed fusion process[J]. Virtual and Physical Prototyping, 2024, 19(1): e2356080.

[83] Zhang Y J, Fang C N, Zhang J, et al. Multi-source data fusion monitoring system for super-elevation in laser powder bed fusion based on Bi-stream cross-mode fusion network[J]. Optics and Lasers in Engineering, 2025, 186: 108794.

[84] Zhang S, Fu T F, Jahn A, et al. Towards deep-learning-based image enhancement for optical camera-based monitoring system of laser powder bed fusion process[J]. International Journal of Computer Integrated Manufacturing, 2023, 36(9): 1281–1294.

[85] Penny R W, Kutschke Z, Hart A J. High-fidelity optical monitoring of laser powder bed fusion via aperture division multiplexing[J]. npj Advanced Manufacturing, 2025, 2: 28.

[86] Hocker S J A, Zalameda J N, Richter B, et al. In-situ process monitoring, synchronization, and mapping laser powder bed fusion builds of Ti–6Al–4V[R]. NASA Langley Research Center, 2022.

[87] Feng S C, Lu Y, Jones A T, et al. Additive manufacturing in situ and ex situ geometric data registration[J]. Journal of Computing and Information Science in Engineering, 2022, 22(6): 061003.

[88] Lindecke P N J, del Castillo J M D, Tarhini H. A universal method for the evaluation of in situ process monitoring systems in the laser powder bed fusion process[J]. Journal of Manufacturing and Materials Processing, 2025, 9(11): 359.

[89] Wang P, Wu Z C, 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.

[90] Grasso M, Colosimo B M. A review of the current state-of-the-art on in situ monitoring in electron beam powder bed fusion[J]. Progress in Additive Manufacturing, 2024, 9(5): 1449–1466.

[91] Jensen S C, Carroll J D, Pathare P R, et al. Long-term process stability in additive manufacturing[J]. Additive Manufacturing, 2023, 61: 103284.

[92] Hyer H C, Schreiber B J, Sweeney D C, et al. Evaluation of in-situ am process monitoring techniques and roadmap for nuclear applications[R/OL]. https://doi. org/10.2172/2428052.

[93] Liu T, Leu M C, Kinzel E C, et al. In situ monitoring and feature extraction in laser powder bed fusion[M]//Machine Learning for Powder-Based Metal Additive Manufacturing. Amsterdam: Elsevier, 2025: 155–227.

[94] Zhang J Y, Yin C, Farbiz F, et al. Advancing machine learning applications for in-situ monitoring and control in laser-based metal additive manufacturing: A state-of-the-art review[J]. Virtual and Physical Prototyping, 2025, 20(1): e2592732.

[95] Boer J, Magolon M, Elbestawi M. Sensor fusion and control utilizing machine learning in lpbf additive manufacturing[PP/OL]. Available [2026−02−27]. https://ssrn.com/abstract=5887964. SSRN 5887964.

[96] Zhang H L, Vallabh C K P, Zhao X Y. Registration and fusion of large-scale melt pool temperature and morphology monitoring data demonstrated for surface topography prediction in LPBF[J]. Additive Manufacturing, 2022, 58: 103075.

[97] Yang Z, Adnan M, Lu Y, et al. Investigating statistical correlation between multi-modality in situ monitoring data for powder bed fusion additive manufacturing[C]// 2022 IEEE 18th International Conference on Automation Science and Engineering (CASE). Mexico City: IEEE, 2022: 283–290.

[98] Kim J, Yang Z, Ko H, et al. Deep learning-based data registration of melt-pool-monitoring images for laser powder bed fusion additive manufacturing[J]. Journal of Manufacturing Systems, 2023, 68: 117–129.

[99] Lu Y, Yang Z, Kim J, et al. Camera-based coaxial melt pool monitoring data registration for laser powder bed fusion additive manufacturing[C/OL]// ASME 2020 International Mechanical Engineering Congress and Exposition, 2021. https://asmedigitalcollection.asme.org/IMECE/proceedings−abstract/IMECE2020/1098983.

[100] Oster S, Fritsch T, Ulbricht A, et al. On the registration of thermographic in situ monitoring data and computed tomography reference data in the scope of defect prediction in laser powder bed fusion[J]. Metals, 2022, 12 (6): 947.

[101] Estalaki S M, Lough C S, Landers R G, et al. Predicting defects in laser powder bed fusion using in-situ thermal imaging data and machine learning[J]. Additive Manufacturing, 2022, 58: 103008.

[102] Hyer H C, Schreiber B J, Sweeney D C, et al. Evaluation of in-situ AM process monitoring techniques and potential for detecting process anomalies and undesirable microstructures[R]. Oak Ridge National Laboratory (ORNL), Oak Ridge, TN (United States), 2024.

[103] Gutknecht K, Cloots M,

Sommerhuber R, et al. Mutual comparison of acoustic, pyrometric and thermographic laser powder bed fusion monitoring[J]. Materials & Design, 2021, 210: 110036.

[104] Pfaff A, Schäffer S, Jäcklein M, et al. Measuring the cooling behavior of melt pools in L – PBF by pyrometry[J]. Materials, 2023, 16(10): 3647.

[105] Scime L, Siddel D, Baird S, et al. Layer-wise anomaly detection and classification for powder bed additive manufacturing processes: A machine-agnostic algorithm for real-time pixel-wise semantic segmentation[J]. Additive Manufacturing, 2020, 36: 101453.

[106] Li J C, Zhou Q, Cao L C, et al. A convolutional neural network-based multi-sensor fusion approach for in-situ quality monitoring of selective laser melting[J]. Journal of Manufacturing Systems, 2022, 64: 429–442.

[107] Li J C, Zhang X G, Zhou Q, et al. A feature-level multi-sensor fusion approach for in-situ quality monitoring of selective laser melting[J]. Journal of Manufacturing Processes, 2022, 84: 913–926.

[108] Zou Z Y, Zhang K, Liu T T, et al. In situ monitoring with melt pool data based on multi-signal fusion method in laser powder bed fusion[J]. Measurement, 2024, 234: 114877.

[109] Petrich J, Snow Z, Corbin D, et al. Multi-modal sensor fusion with machine learning for data-driven process monitoring for additive manufacturing[J]. Additive Manufacturing, 2021, 48: 102364.

[110] Snow Z, Scime L, Ziabari A, et al. Scalable in situ non-destructive evaluation of additively manufactured components using process monitoring, sensor fusion, and machine learning[J]. Additive Manufacturing, 2023, 78: 103817.

[111] Tempelman J R, Wachtor A J, Flynn E B, et al. Sensor fusion of pyrometry and acoustic measurements for localized keyhole pore identification in laser powder bed fusion[J]. Journal of Materials Processing Technology, 2022, 308: 117656.

[112] Pandiyan V, Wróbel R, Richter R A, et al. Monitoring of laser powder bed fusion process by bridging dissimilar process maps using deep learning-based domain adaptation on acoustic emissions[J]. Additive Manufacturing, 2024, 80: 103974.

[113] Ali Khan I, Birkhofer H, Kunz D, et al. A random forest classifier for anomaly detection in laser-powder bed fusion using optical monitoring[J]. Materials, 2023, 16(19): 6470.

[114] Tempelman J R, Mudunuru M K, Karra S, et al. Uncovering acoustic signatures of pore formation in laser powder bed fusion[J]. The International Journal of Advanced Manufacturing Technology, 2024, 130(5): 3103–3114.

[115] Li J C, Zhou Q, Huang X F, et al. In situ quality inspection with layer-wise visual images based on deep transfer learning during selective laser melting[J]. Journal of Intelligent Manufacturing, 2023, 34(2): 853–867.

[116] Mao Y K, Lin X, Zhu H H, et al. Physics-guided spatiotemporal approach for melt pool size prediction in laser powder bed fusion[J]. Virtual and Physical Prototyping, 2024, 19(1): e2427243.

[117] Nguyen N V, Hum A J W, Do T, et al. Semi-supervised machine learning of optical in-situ monitoring data for anomaly detection in laser powder bed fusion[J]. Virtual and Physical Prototyping, 2023, 18(1): e2129396.

[118] Sajadi P, Rahmani Dehaghani M, Tang Y F, et al. Physics-informed online learning for temperature prediction in metal AM[J]. Materials, 2024, 17(13): 3306.

[119] Ren Y, Wang Q, Michaleris P P. A physics-informed two-level machine-learning model for predicting melt-pool size in laser powder bed fusion[J]. Journal of Dynamic Systems, Measurement, and Control, 2021, 143 (12): 121006.

[120] Kim J, Yang Z, Lu Y. A physics-guided deep generative model for predicting melt pool behavior in laser powder bed fusion additive manufacturing[J]. Journal of Intelligent Manufacturing, 2025, 36(8): 5715–5735.

[121] Li J C, Hu J X, Zhou Q, et al. Transfer learning-based quality monitoring of laser powder bed fusion across materials[J]. Expert Systems with Applications, 2024, 252: 124150.

[122] Ilani M A, Banad Y M. TransMatch: A transfer-learning framework for defect detection in laser powder bed fusion additive manufacturing[PP/OL]. arXiv (2025 – 09 – 01) [2026 – 03 – 02]. https://doi. org/10.48550/arXiv.2509.01754.

[123] Tan K P, Tang J F, Zhao Z B, et al. Efficient and lightweight layer-wise in-situ defect detection in laser powder bed fusion via knowledge distillation and structural re-parameterization[J]. Expert Systems with Applications, 2024, 255: 124628.

[124] Yan H L, Cai J F, Zhao Y J, et al. A lightweight high-resolution algorithm based on deep learning for layer-wise defect detection in laser powder bed fusion[J]. Measurement Science and Technology, 2024, 35(2): 025604.

[125] Zhao J L, Yang Z H, Chen Q P, et al. Real-time detection of powder bed defects in laser powder bed fusion using deep learning on 3D point clouds[J]. Virtual and Physical Prototyping, 2025, 20(1): e2449171.

[126] Mao Y W, Lin H, Yu C X, et al. A deep learning framework for layer-wise porosity prediction in metal powder bed fusion using thermal signatures[J]. Journal of Intelligent Manufacturing, 2023, 34(1): 315–329.

[127] Ren Z S, Gao L, Clark S J, et al. Machine learning-aided real-time detection of keyhole pore generation in laser powder bed fusion[J]. Science, 2023, 379(6627): 89–94.

[128] Ren Z S, Shao J Y, Liu H L, et al. Sub-millisecond keyhole pore detection in laser powder bed fusion using sound and light sensors and machine learning[J]. Materials Futures, 2024, 3(4): 045001.

[129] Kononenko D Y, Nikonova V, Seleznev M, et al. An in situ crack detection approach in additive manufacturing based on acoustic emission and machine learning[J]. Additive Manufacturing Letters, 2023, 5: 100130.

[130] Li Z W, Zhang Z F, Zhang S, et al. In-situ monitoring in laser powder bed fusion based on acoustic signal time-frequency synchrosqueezing transform and multi-scale spatially interactive fusion convolutional neural network[J]. Journal of Manufacturing Processes, 2024, 126: 471–486.

[131] Zhang Y Z, Zhang P, Cheng T, et al. High precision 3D contour detection for laser powder bed fusion in-process layerwise monitoring using active contours driven by multiple energy[J]. Additive Manufacturing, 2025, 105: 104761.

[132] Zhang Y Z, Zhang P, Jiang X, et al. In-situ 3D contour measurement for laser

powder bed fusion based on phase guidance[J]. Theoretical and Applied Mechanics Letters, 2023, 13(2): 100405.

[133] Sen C, Sail G, Subasi L, et al. In-situ surface roughness evaluation of laser powder bed fusion surfaces using optical tomography[J]. Procedia CIRP, 2024, 123: 363–368.

[134] Toorandaz S, Liravi F, Ero O, et al. Pioneering ML – driven framework for in-situ vertical surface roughness prediction in LPBF[J]. Virtual and Physical Prototyping, 2025, 20(1): e2569543.

[135] He P, Huang Y M, Wang W H, et al. Deep learning driven prediction method for roughness and hardness of laser in-situ forging additive manufacturing Ti – 6Al – 4V[J]. Virtual and Physical Prototyping, 2025, 20(1): e2569541.

[136] Kavas B, Richter R A, Tucker M R, et al. Adaptive in-situ monitoring for laser powder bed Fusion: Self – supervised learning for layer thickness monitoring across scan lengths based on pyrometry[J]. Optics & Laser Technology, 2025, 192: 114070.

[137] Nagato K, Ozawa T, Neuenfeldt M, et al. Enhancing the prediction quality of mechanical properties for powder bed fusion with laser beam by dynamic observation of flying particles[J]. Materials & Design, 2023, 227: 111696.

[138] Yu A H, Pan Y, Yue L S, et al. Explainable machine learning for hardness prediction of laser powder bed fused Ti–6Al–4V and assisting in understanding effects of process parameters[J]. Journal of Alloys and Compounds, 2024, 1008: 176566.

[139] Luo Q X, Huang N, Bartles D L, et al. Harnessing of in situ processing data to predict mechanical properties of laser powder bed fusion AlSi10Mg[J]. Journal of Intelligent Manufacturing, 2026, 37(2): 909–931.

[140] Peng X J, Chen Z D, Zhang A M, et al. Digital twin temperature field prediction of laser powder bed fusion through proper orthogonal decomposition with radial basis function[J]. Materials Today Communications, 2024, 38: 107883.

[141] Wu S H, Tariq U, Joy R, et al. Experimental, computational, and machine learning methods for prediction of residual stresses in laser additive manufacturing: A critical review[J]. Materials, 2024, 17(7): 1498.

[142] Snow Z, Scime L, Ziabari A K, et al. Machine learning enabled sensor fusion for in situ defect detection in laser powder bed fusion [R]. Oak Ridge National Laboratory, 2024. https://doi.org/10.2172/2301610.

[143] Yuan B D, Guss G M, Wilson A C, et al. Machine-learning-based monitoring of laser powder bed fusion[J]. Advanced Materials Technologies, 2018, 3(12): 1800136.

[144] Coeck S, Bisht M, Plas J, et al. Prediction of lack of fusion porosity in selective laser melting based on melt pool monitoring data[J]. Additive Manufacturing, 2019, 25: 347–356.

[145] King W E, Barth H D, Castillo V M, et al. Observation of keyhole-mode laser melting in laser powder-bed fusion additive manufacturing [J]. Journal of Materials Processing Technology, 2014, 214(12): 2915–2925.

[146] Khairallah S A, Anderson A T, Rubenchik A, et al. Laser powder-bed fusion additive manufacturing: Physics of complex melt flow and formation mechanisms of pores, spatter, and denudation zones[J]. Acta Materialia, 2016, 108: 36–45.

[147] Roberts I A, Wang C J, Esterlein R, et al. A three-dimensional finite element analysis of the temperature field during laser melting of metal powders in additive layer manufacturing[J]. International Journal of Machine Tools and Manufacture, 2009, 49 (12–13): 916–923.

[148] Grasso M, Colosimo B M. Process defects and in situ monitoring methods in metal powder bed fusion: A review[J]. Measurement Science and Technology, 2017, 28(4): 044005.

[149] Scipioni Bertoli U, Wolfer A J, Matthews M J, et al. On the limitations of volumetric energy density as a design parameter for Selective Laser Melting[J]. Materials & Design, 2017, 113: 331–340.

[150] Weaver J S, Heigel J C, Lane B M. Laser spot size and scaling laws for laser beam additive manufacturing[J]. Journal of Manufacturing Processes, 2022, 73: 26–39.

[151] Gunenthiram V, Peyre P, Schneider M, et al. Experimental analysis of spatter generation and melt-pool behavior during the powder bed laser beam melting process[J]. Journal of Materials Processing Technology, 2018, 251: 376–386.

[152] Moran T P, Warner D H, Soltani – Tehrani A, et al. Spatial inhomogeneity of build defects across the build plate in laser powder bed fusion[J]. Additive Manufacturing, 2021, 47: 102333.

[153] Gordon J V, Narra S P, Cunningham R W, et al. Defect structure process maps for laser powder bed fusion additive manufacturing[J]. Additive Manufacturing, 2020, 36: 101552.

[154] Bahari-Sambran F, Orozco – Caballero A, Carreño F, et al. Predictive processing maps for laser-powder bed fusion using transfer learning and melt pool geometry[J]. Advances in Industrial and Manufacturing Engineering, 2025, 11: 100168.

[155] Clijsters S, Craeghs T, Buls S, et al. In situ quality control of the selective laser melting process using a high-speed, real-time melt pool monitoring system[J]. The International Journal of Advanced Manufacturing Technology, 2014, 75(5): 1089–1101.

[156] Shkoruta A, Mishra S, Rock S J. Real-time image-based feedback control of laser powder bed fusion[J]. ASME Letters in Dynamic Systems and Control, 2022, 2(2): 021001.

[157] Wang R X, Standfield B, Dou C R, et al. Real-time process monitoring and closed-loop control on laser power via a customized laser powder bed fusion platform[J]. Additive Manufacturing, 2023, 66: 103449.

[158] Zhang Y J, Hong G S, Ye D S, et al. Extraction and evaluation of melt pool, plume and spatter information for powder-bed fusion AM process monitoring[J]. Materials & Design, 2018, 156: 458–469.

[159] Craeghs T, Bechmann F, Berumen S, et al. Feedback control of Layerwise Laser Melting using optical sensors[J]. Physics Procedia, 2010, 5: 505–514.

[160] Craeghs T, Clijsters S, Yasa E, et al. Determination of geometrical factors in layerwise laser melting using optical process monitoring[J]. Optics and Lasers in Engineering, 2011, 49(12): 1440–1446.

[161] Kavas B, Balta E C, Tucker M, et al. Layer-to-layer closed-loop feedback control application for inter-layer temperature stabilization in laser powder bed fusion[J]. Additive Manufacturing, 2023, 78: 103847.

[162] Kavas B, Balta E C, Tucker M R, et al. In-situ controller autotuning by Bayesian optimization for closed-loop feedback control

of laser powder bed fusion process[J]. Additive Manufacturing, 2025, 99: 104641.

[163] Yeung H. Toward real-time feedback control for powder bed fusion additive manufacturing[J]. Additive Manufacturing, 2025, 114: 105041.

[164] Smith R J, Hirsch M, Patel R, et al. Spatially resolved acoustic spectroscopy for selective laser melting[J]. Journal of Materials Processing Technology, 2016, 236: 93–102.

[165] Donmez A, Fox J, Kim F, et al. In-process monitoring and non-destructive evaluation for metal additive manufacturing processes[R]. National Institute of Standards and Technology, 2024.

Research Progress on Multi-Source Fusion Online Monitoring and Quality Control Technology in Selective Laser Melting

WANG Yan, HAN Changjun, ZHENG Boyuan, JIANG Renwu, WANG Di,
LI Yang, YANG Yongqiang
(South China University of Technology, Guangzhou 510641, China)

[ABSTRACT] Selective laser melting (SLM) enables the direct fabrication of geometrically complex, high-precision components and offers clear advantages in aerospace, biomedical, and other demanding applications. However, melt-pool instability and the stochastic nature of defect formation during the build process can directly degrade the mechanical properties and in-service reliability of parts. Quality control therefore remains a critical bottleneck that limits large-scale industrial deployment. Multi-source in-situ monitoring with data fusion can provide real-time process awareness and support feedback regulation. It is widely viewed as an effective route to improve part quality. This review systematically summarizes the development of multi-source in-situ monitoring system construction for SLM, multimodal data processing and fusion, and quality prediction and regulation. It also discusses the common challenges that arise in engineering applications, and it provides an outlook on the supporting infrastructure and evaluation frameworks needed in this field. By integrating recent research, this review aims to offer a structured academic reference for future studies and to facilitate the continued transition of SLM quality control toward intelligent manufacturing.

Keywords: Selective laser melting (SLM); Online monitoring; Multimodal data fusion; Defect detection; Quality control

（责编　晓月）