应用科技研究

2026 年 11 月 第 1 卷第 5 期

智能增材制造中的物理信息学习研究进展

薛辉 [1*]，赵红宇 [1]，张萌萌 [2]，张志佳 [2*]

1. 天津工业大学机械工程学院，天津市；2. 天津工业大学材料科学与工程学院，天津市

摘　要｜物理信息学习已用于增材制造的状态估计与工艺决策，其工程价值在于能否支持有效的工艺调整并改善成形质量。本文以金属熔融增材制造为主，梳理残差约束、结构融合和仿真代理的应用，结合观测条件比较其在闭环中的适用性，并提出六维工程评价框架。现有研究为温度等状态预测、离线工艺筛选和仿真反馈提供了验证，但这些结果尚不足以确认金属 PINN 的实机闭环效果。物理先验可补充有限观测，也可能因热源、物性或边界描述失配而引入偏差。判断其控制价值，应考察状态估计是否改变了工艺动作，以及动作是否改善了独立测量的成形质量。全链时延、跨工况适用性和风险恢复能力则决定了模型部署前还需完成哪些验证。

关键词｜智能增材制造；物理信息学习；原位监测；工艺决策；闭环控制

Copyright © 2026 by the author(s).
This article is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.
https://creativecommons.org/licenses/by-nc/4.0/

1 引言

增材制造通过逐层沉积材料与可编程能量输入实现复杂构件成形，但质量一致性与可重复性仍制约其工程应用[1,2]。在激光粉末床熔融和定向能量沉积中，局部热输入、熔池演化与凝固相互耦合，工艺参数通过热历史影响结构与性能[1,3]。功率、速度、材料供给和层间停留时间决定热输入，前序热积累又随层数、扫描位置及几何变化影响后续响应，因此固定的初始参数难以在整个构建过程中维持相同状态[4,5]。孔隙、未熔合等缺陷的控制还受观测能力、过程不确定性和模型误差影响[1,2,6]。构建前的参数筛选难以及时应对过程中的状态偏移，识别出异常也不意味着能够直接给出规避、缓解或修复动作[7]。为此，需要将状态监测、工艺调整和制造效果评价衔接起来。

原位监测为分析热输入、材料响应和质量形成提供了过程数据[1,2,3]。物理信息学习将控制方程、材料与工艺先验同观测数据结合，用于建立工艺参数与状态之间的映射[8,9]。相关研究已涉及温度场预测[10,11,12]、熔池流动求解[13]、组织演化[14]和变形响应预测[15]。这些预测能否用于制造，还取决于模型输出是否足以支持参数选择或调整策略[7]。模型选型因此需要同时考虑物理假设、可用观测和目标任务，而不能只比较预测误差。

将上述模型用于控制，需要回答三个问题：现有观测是否足以估计隐藏状态，预测结果如何转化

基金项目：国家自然科学基金资助项目（52472235；52102291）；新金属材料全国重点实验室开放基金资助项目（2026-Z08）
作者简介：薛辉，天津工业大学机械工程学院讲师，硕士生导师，主要从事激光增材制造、多尺度模拟计算及机器学习、新一代高温合金及磁性材料等方向的研究；张志佳，天津工业大学材料科学与工程学院教授，博士生导师，主要从事电化学能源存储与转化、金属集流体及金属基复合材料等方向的研究。
文章引用：薛辉, 赵红宇, 张萌萌, 张志佳. 智能增材制造中的物理信息学习研究进展[J]. 应用科技研究, 2026, 1（5）：211-227.
https://doi.org/10.68070/axh0qg44

为设备动作，以及反馈策略能否适应工况变化[2,7,8,9]。估计误差和不确定性可能传递至决策环节，使预测精度的提高未能带来质量改善[6,7]。

本文关注状态估计能够支持哪些工艺决策，以及如何验证由此带来的质量改善。综述以金属激光与电弧熔融增材制造为核心，按物理知识融合机制、验证对象和反馈环境比较相关研究；陶瓷、聚合物及通用方法用于补充对照，并明确其与核心研究对象的差异。

本文采用定向叙述性综述，以已有文献库为起点，于 2026 年 10 月 23 日开展 Crossref 公开题录补充检索，并在 Zotero 库中按题名检索及回溯相关文献。选材以 2020—2026 年研究为主，并补充必要的基础方法与概念文献；在线发表文献以检索日可获取版本为界。检索将 additive manufacturing 或 3D printing 与 physics-informed、thermal/neural operator/surrogate、monitoring/adaptive control/digital twin、uncertainty quantification 及 error detection/correction 等词组分别组合；Crossref 使用题录关键词相关性查询，每组核查前 50 条结果，而非布尔字段全量检索。题录按 DOI 去重，同一研究优先采用正式发表版本。

纳入的研究须与状态感知、质量映射、工艺决策或工程评价直接相关，且能够明确物理知识的引入方式、验证对象或反馈环境。综述文献用于介绍背景与分类，具体技术判断优先依据原始研究。与目标任务无直接联系、重复发表的版本，以及无法核实所引结论的材料，不作为技术判断的依据。非 PINN 方法用于对照测量、数据驱动诊断、仿真代理或物理模型控制；陶瓷与聚合物案例用于讨论特征融合或设备反馈，通用不确定性方法则不视为已经验证的制造应用。同类研究依据机制差异和验证信息的代表性选取，本文不追求穷尽全部文献，也不以文献数量判断领域成熟程度。

2 智能增材制造闭环的功能架构

物理信息学习将物理知识引入学习模型，物理信息神经网络（PINN）是其中一类。经典 PINN 结合方程残差与初始、边界或观测约束，求解状态及相关反问题[16]。物理知识也可通过网络结构、数据增强和仿真样本引入，因此以仿真样本训练模型并不等同于施加方程残差约束[8,9]。残差求解依赖方程和边界描述，结构融合受所嵌入机制的限制，仿真代理则受样本覆盖和仿真偏差影响。选用这些方法时，需要先明确待求状态及所需的响应预测范围。

2.1 反馈链与功能模块

闭环控制要求观测参与决策，动作作用于过程，而后续响应继续用于修正决策。图 1 给出原位感知、状态估计、质量诊断、工艺决策与设备执行之间的联系。可测变量可直接参与决策，隐藏状态则需要估计；是否校准参数或重新训练模型，应由误差来源决定。仅在数字环境内进行的反馈属于仿真闭环，制造观测与实际设备动作相连接才构成设备闭环。数字模型、数字影子和数字孪生应依据实体与数字表示之间的数据交互方向及自动化程度区分[17]，仅凭离线或在线运行方式不足以命名。即使已经建立控制接口，仍需通过独立质量评价检验制造效果。

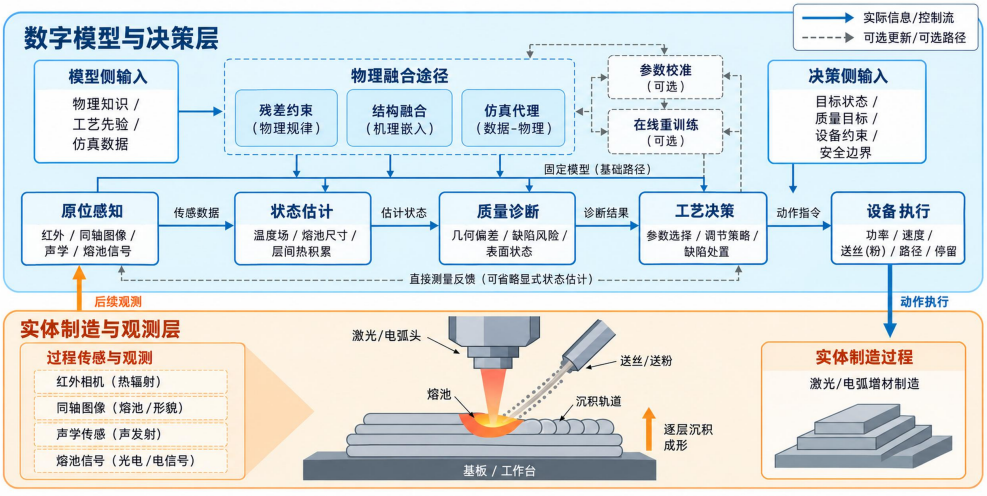


图 1 物理信息学习支撑的智能增材制造闭环架构。

Figure 1. Closed-loop architecture of intelligent additive manufacturing supported by physics-informed learning.

上、下部分别为数字模型与决策层、实体制造与观测层；实线表示实际信息或控制流，虚线表示可选更新或可选路径。参数校准和在线重训练为可选功能，实体示意不限定设备结构。该图由本文绘制。

2.2 控制相关状态与工艺尺度

红外热像、同轴图像与声学信号反映不同的过程响应，表面辐射和熔池形态并不直接给出内部温度、熔深或最终质量[2]。状态能否被观测、能否被估计，以及能否由执行器调节，需要分别判断。熔池调节关注局部快速响应，路径管理需考虑空间位置与热历史，层间控温则可利用停留阶段实施调整。动作选择应与目标状态及设备接口相匹配。从采样到执行器响应的总时间，即全链时延，应小于任务允许的动作窗口；若执行前状态已显著改变，仅缩短模型推理时间仍难以保证调整有效。

3 物理信息学习支撑智能增材制造闭环的核心技术

3.1 状态感知与质量诊断

3.1.1 稀疏观测下的状态估计

残差 PINN 以时空坐标为输入预测温度等状态，通过自动微分计算方程残差，并结合初始、边界和观测约束求解[11,12,13]。参数化模型还可将工艺或材料参数作为输入，但这与从观测中辨识未知参数是不同任务。无监督单轨模型依据给定热源求解热响应[11]。图 2(a)将其中考虑温度相关热物性的 PINNs-II 与有限元进行比较，包括六组稳态温度散点及沿扫描路径的温度剖面，用于检验给定物理描述下的数值一致性。热流模型同时求解温度与流动[13]，混合模型则融合局部温度观测[12]。物理假设和观测覆盖共同限制了隐藏状态的估计范围，残差收敛与观测拟合并不能排除未观测区域的偏差。

物理信息卷积长短期记忆网络（PI-ConvLSTM）利用温度序列和热通量矩阵预测二维温度场，并通过有限差分施加物理残差约束[18]。三维迁移模型先用仿真数据预训练，再用单个二维观测面的温度序列微调[19]；其输入是一段时间序列，而非单张图像，内部温度场也尚缺独立体内测量验证。文献[18]表 3 报告，在 40 轮训练、同时采用物理输入和物理损失的配置下，实验平均绝对误差（MAE）为 11.3 ℃。平均指标可能掩盖局部偏差，例如全域均方误差可能主要反映大面积缓变区域的误差[20]，因此控制评价还应检查峰值、熔池边界和冷却过程。机器学习辅助的啁啾光纤布拉格光栅解调可测得沿埋入光纤的位置—时间温度分布[21]，如图 2(c)所示，为表面观测提供补充。不过，该测量来自另一项研究，不能作为上述 PINN 内部场的独立验证。

不同建模方式对物理过程的处理有所区别：热流 PINN 同时约束质量、动量和能量守恒[13]；结构展开方法将热模型的迭代过程映射为网络层[22]；采用随机合成数据训练的模型则以离散方程残差学习下一步响应[23]。后两类方法需要检查步长、边界条件及递推误差的影响。导热近似可以满足部分热响应预测任务，但若目标涉及熔池流动，就需补充相应物理描述，而非单纯增加网络复杂度。

3.1.2 在线校准与过程扩展

模型适应现场条件的方式主要包括参数校准和权重更新。混合模型在数值案例中辨识参数，并在薄壁实验中融合红外观测[12]；在线模型经有限元预训练后，随着未见定向能量沉积（DED）仿真数据的到达更新权重[24]。相邻层迁移利用热响应的相似性复用已训练权重。Uhrich 等[25]报告初次训练约需 400 s，后续层平均约需 20 s，图 2(b)比较了各层训练的初始与最终损失及耗时。该结果表明，逐层迁移降低了已测试构件的模型更新成本，但没有直接说明单次推理速度或完整控制周期能否满足要求；原研究也尚未在真实生产厂中验证实时仿真与异常检测。实施更新前，应先检查传感异常与模型结构失配。由于多组参数可能解释同一表面观测，仅凭拟合误差降低，仍难以确认参数辨识的可靠性。

多层构建中的热积累与扫描中断，使状态预测从单轨响应扩展到更大的空间域和更长的时间范围。多层和分域 PINN 采用数值基准评价停留及扫描中断条件下的预测[4,26]，电弧代理则考察固定几何下采样与分辨率变化的影响[27]。长时预测模型利用 1.25 s 历史数据预测未来 1.25 s，并在有限元与电弧薄壁实验中评价[28]；其约 12 ms 的预测时间来自配备 RTX 4050 GPU 的平台，不包含从采样到执行的全部时延。图 2 中的三组结果分别考察温度响应一致性、逐层更新成本和亚表面观测能力，来自不同研究，应按各自的验证目的解读。

https://doi.org/10.68070/axh0qg44

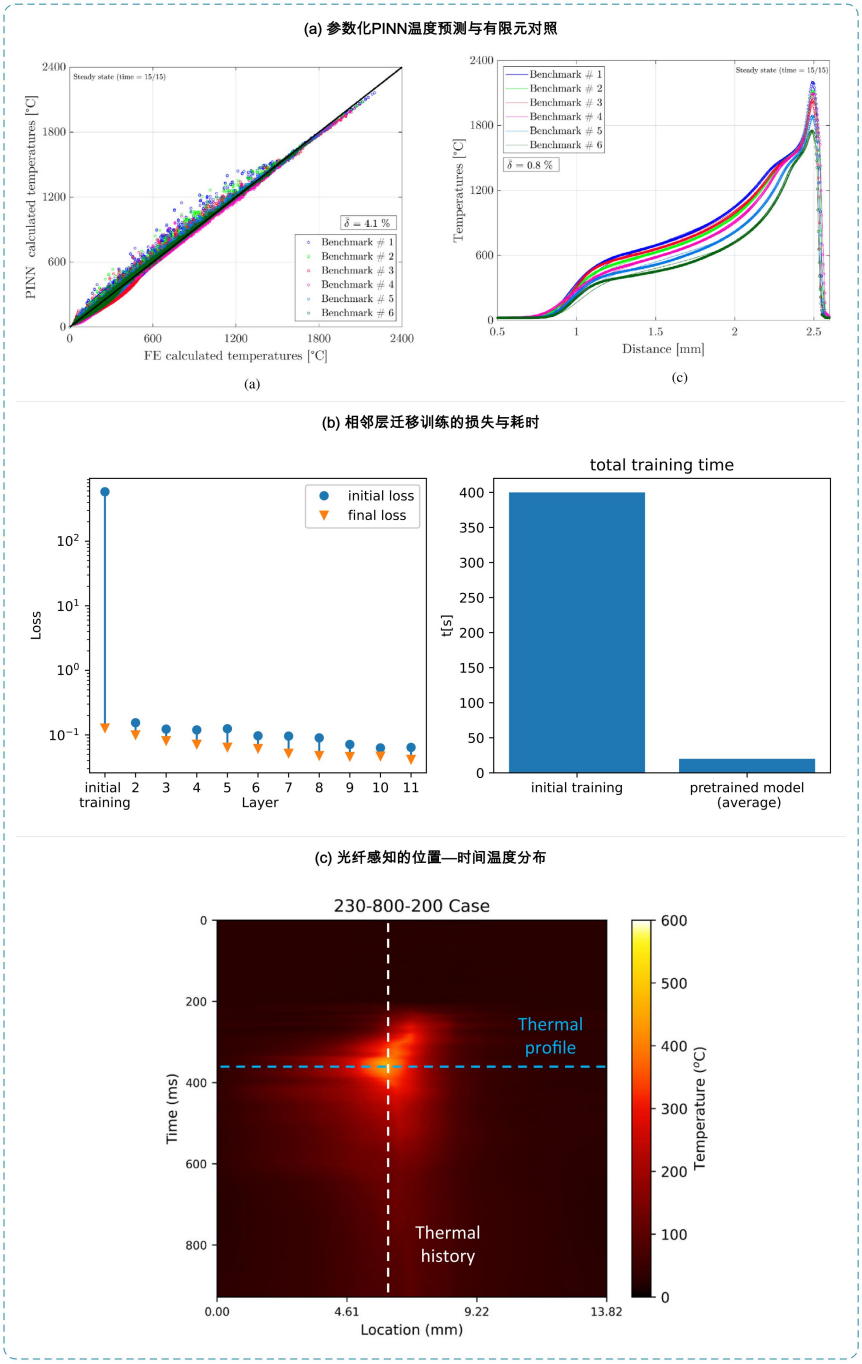


图 2 物理信息温度预测、逐层迁移与亚表面测量参照。

Figure 2. Physics-informed temperature prediction, layer-wise transfer, and subsurface measurement reference.

(a)六组基准工况下 PINNs-II 与有限元的稳态温度散点（左）及沿激光路径温度剖面（右），原内部编号为(a)、(c)，温度单位为℃，距离单位为 mm；(b)相邻层迁移训练的初始与最终损失（左）及初次训练与后续层平均训练时间（右），时间单位为 s；(c)机器学习解调得到的亚表面位置—时间温度分布，横轴为位置，纵轴为时间，色标为温度。面板(a)为数值对照，(b)为训练代价比较，(c)为非 PINN 测量参照，不构成同一模型的联合验证。各面板节选自 Hosseini 等[11]图 7(a)和(c)、Uhrich 等[25]图 18、Wang 等[21]图 7，依次对应(a)—(c)。©2023 Hosseini 等、©2024 Uhrich 等及 Wang 等，依据 CC BY 4.0 使用（https://creativecommons.org/licenses/by/4.0/）；进行了裁切、重新编排，增加中文标题、分隔线和外框，保留原图例、单位及内部编号。

3.1.3 从状态到质量指标

将状态预测用于质量诊断，需要提取与成形目标直接相关的特征。热场可提供温度梯度和冷却速

率[13]；合成同轴图像可用于三维熔池重建及仿真体积控制[29]；经实验标定的显式熔池几何模型可扩充样本，覆盖传导、过渡与钥孔状态[30]。两阶段焊道模型先估计温度，再通过热物性分布预测截面轮廓[31]，见图 3(a)、(b)。上述方法分别关注隐藏几何、样本覆盖和质量映射，需要相应检查仿真与实测图像的差异、增强样本的物理条件及各阶段的误差。其中，焊道轮廓对照结合了六个实测数据点，尚未提供未参与拟合的构建或工况下的泛化验证。

多模态诊断需要明确训练与部署时能够使用哪些传感信号。陶瓷选择性激光熔化（SLM）研究将声发射与 PINN 重建的高频表面温度时序特征融合，用于故障分类[32]，可作为跨工艺特征融合的参考。同一研究中的激光定向能量沉积（LDED）数据缺少热模态，主要用于验证时空融合分支。音视频迁移方法允许在预测阶段移除源模态[33]；表面监测方法将算术平均高度 Sa 分为四类[34]；在机计量代理则连续预测熔池尺寸、温度和工作距离，并在未见构件上评价[35]。分类结果便于按类别触发处置规则，连续估计则能够给出偏差幅度。对于上述多模态研究，仍需区分整体分类表现与物理约束温度特征的贡献，整体结果本身不足以说明物理融合带来了多少增益。

分类标签还需要独立的成形表征加以解释。视频视觉 Transformer 研究从高速成像中提取熔池动态特征以识别工艺状态，并以成形后表征作为对照[36]。图 3(c)展示未熔合、理想成形、球化和钥孔状态的截面与俯视形貌，说明类别标签所对应的物理状态，而非分类准确率。这项非 PINN 研究提供了诊断方法的对照，但形貌能够区分类别，并不意味着模型已经识别出相应的形成机制。

热状态预测也可作为组织与力学响应模型的输入。例如，用熔池几何校准 PINN 热源后，再驱动元胞自动机估计组织演化[14]；图算子则利用稀疏温度预测固定材料与工艺条件下的仿真变形[15]。温度估计误差会传递至下游模型，因此组织或变形预测仍需单独验证。

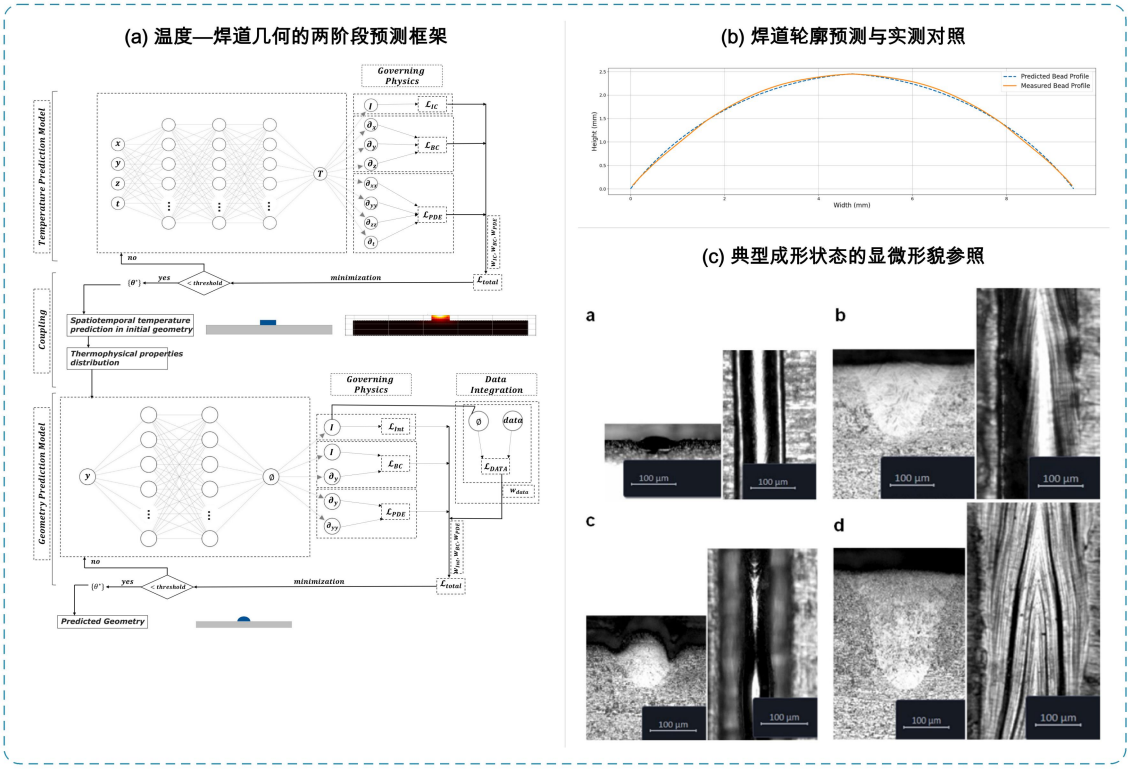


图 3 物理信息焊道几何预测与成形状态表征。

Figure 3. Physics-informed weld bead geometry prediction and formation state characterization.

(a)温度估计与焊道截面几何预测的两阶段框架；(b)预测与实测焊道轮廓对照，模型结合六个实测数据点，该对照不构成完全独立的测试验证，坐标单位为mm；(c)Ti-6Al-4V单道成形的截面与俯视显微图，内部原面板a—d分别表示未熔合、理想成形、球化和钥孔状态，比例尺为100 μm。面板(c)为成形状态的形貌参照，非PINN分类或消融结果。各面板节选自Rashid等[31]图3及图15、Guirguis等[36]图4，分别对应(a)、(b)和(c)。©2025 Rashid等、©2024 Guirguis等，依据 CC BY 4.0 使用（https://creativecommons.org/licenses/by/4.0/）；进行了裁切、重新编排，增加中文标题、分隔线和外框，保留原比例尺与内部编号。

https://doi.org/10.68070/axh0qg44

3.2 逆向工艺设计与控制决策

3.2.1 从目标状态反求参数

逆向设计通过反复调用正向模型，寻找满足目标状态的工艺参数。层间温度设计研究以指定冷却时刻的单轨温度为代理目标，先用实验标定换热参数，再训练参数化 PINN，在固定停留时间下搜索功率与速度，最后通过有限元复核[5]。图 4(a)展示的是离线参数筛选结果，多层实机控温效果仍待验证。多激光规划研究利用热模拟比较分区和扫描组织方案[37]，双激光实验尚属后续工作。前者调整局部工艺参数，后者安排空间能量分配，模型的用途随设计目标而异。

参数化 PINN 能够查询不同参数下的响应，但文献[38]尚未实施优化。迁移模型考察了单层导热条件下路径、参数和光束变化时的模型复用[39]，质量标签驱动的工艺窗口搜索则直接以质量指标为目标[40]。前两类方法依赖状态响应模型，后一类依赖质量标签的覆盖范围；选出候选工艺后，都需要考虑进一步复核的成本。

逆向设计的解通常不唯一。相同的名义线能量可能对应不同的作用时间与温度历程，因此需要明确目标是某一时刻的温度、完整热历史，还是最终质量，并同时约束设备动作幅度、变化率和生产效率。接近训练范围边缘时，优化器可能利用代理模型的误差，选出预测上有利而实际效果不佳的参数组合。设计流程因而应包括适用范围检查和候选工艺复核。

3.2.2 状态到动作的反馈策略

反馈策略依据观测或估计状态产生动作，再利用后续响应修正决策；强化学习可通过与环境交互学习这类策略[7]。一项熔池控制研究采用图网络与循环网络预测温度，以半解析热模型构建环境，并由卷积智能体输出功率动作以调节熔深[41]。其验证限于仿真环境，迁移至设备时还需处理观测偏差、动作滞后与环境失配。作为非 PINN 设备反馈案例，材料挤出研究将热像分为五级相对流量类别，再据此调整流量，报告的检测与反馈时间约为 3 s[42]。这一时间涵盖的环节与文献[28]的局部预测时间不同，二者不宜直接比较。

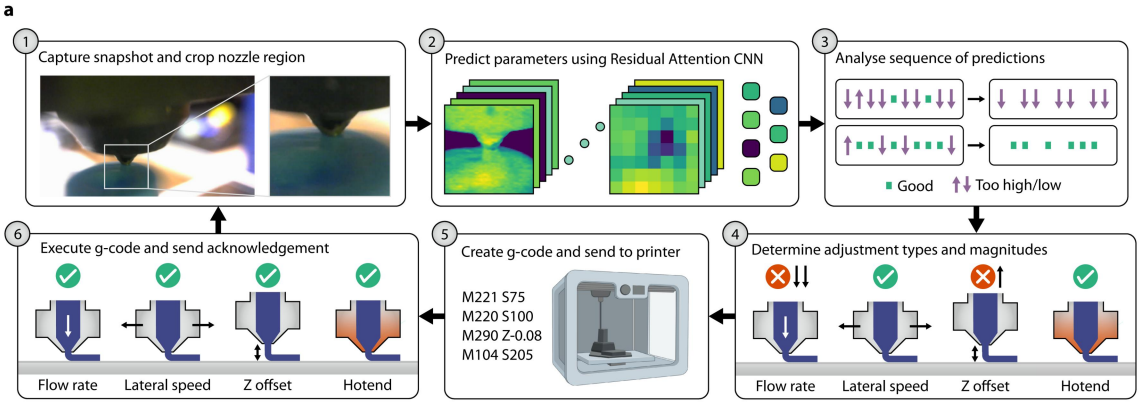
另一项材料挤出研究将喷嘴附近图像输入多头神经网络，分别判断流量、横向速度、Z 偏移与热端温度的类别，并将连续预测结果转化为设备调整指令[43]。反馈流程包含指令执行确认，图 4(b)、(c)分别展示该流程，以及参数扰动、不同材料和构件条件下的纠偏对照。该案例在聚合物工艺中连接了观测、动作与后续响应，可用于讨论设备反馈的实现方式；其结果限于材料挤出，不能直接推及金属制造物理信息模型。

模型预测控制（MPC）在有限时间窗口内预测响应并优化动作，其效果受模型误差和在线求解开销影响。金属 DED 研究将自适应一维热模型用于 MPC，在五层壁实验中比较开环、单输入单输出与多输入多输出方案，联动调节激光功率和移动速度，并通过层高和硬度表征评价成形结果[44]。该研究提供了非 PINN 物理模型控制的实验对照，PINN 或学习代理能否与此类控制器有效集成，仍需验证。强化学习用于设备控制时，也需要检验训练环境与真实过程的一致性。此外，诊断输出应与设备能够执行的处置动作相匹配：规避、缓解和修复对预测视野、定位及执行能力的要求不同[7]，停机不等于修复，仅有异常类别也不足以确定局部修复动作。

(a) 离线功率—速度选择与数值复核

Case	Target T_{IL} (°C)	Dwell (s)	P (kW)	V (m/s)	T_{IL}^{PINN} (°C)	T_{IL}^{FE} (°C)	Error PINN (°C)	Error FE (°C)
1	100	10	2.12	0.0142	95.4	104.0	4.6	−4.0
2	130	10	2.51	0.0116	126.7	136.6	3.3	−6.6
3	160	10	2.17	0.0081	154.4	165.6	5.6	−5.6

(b) 机器视觉驱动的设备反馈流程



(c) 材料挤出的参数纠偏与构件对照

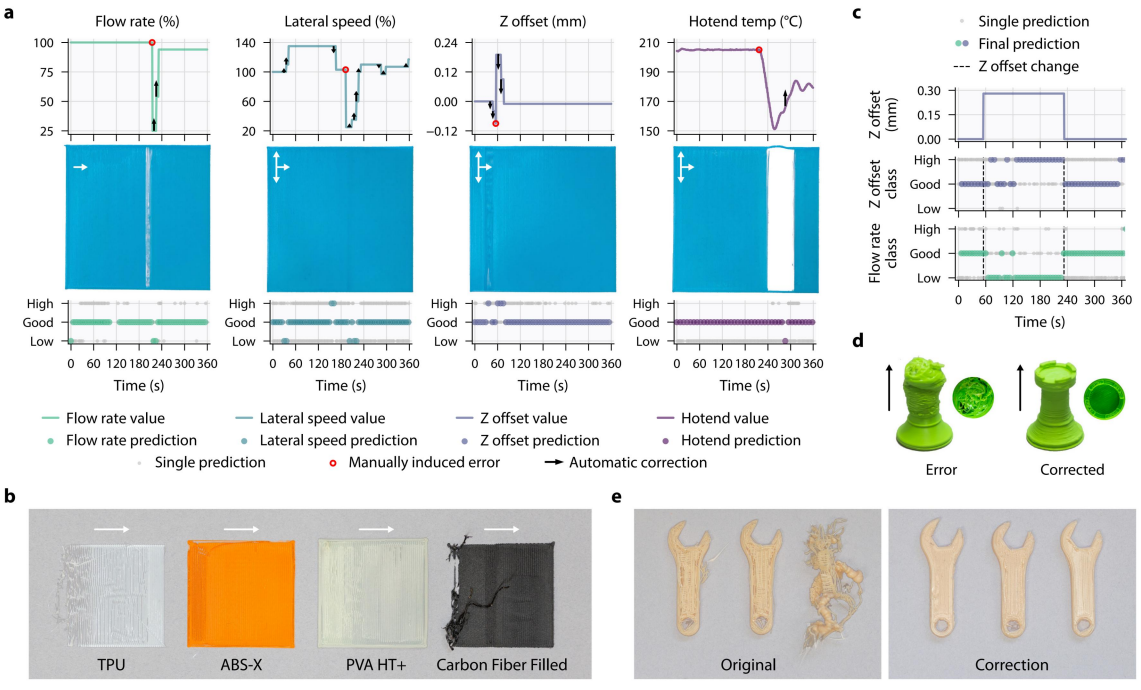


图 4 离线工艺参数设计与设备反馈纠偏参照。

Figure 4. Offline process parameter design and equipment feedback-based correction reference.

(a)依据目标层间温度选择功率和速度后的 PINN 与有限元复核结果，节选原表 2；(b)机器视觉反馈流程，包括图像采集、参数判断、序列分析、调整量确定、指令生成与执行确认；(c)材料挤出研究中的参数扰动纠偏、不同热塑性材料测试及有无纠偏的构件对照，内部 a—e 为原图编号。面板(a)为金属制造的离线数值复核，(b)、(c)为非 PINN 材料挤出的设备反馈参照。各面板节选自 Hasan 等[5]表 2、Brion 与 Pattinson[43]图 3(a)和图 4，依次对应(a)—(c)。©2026 Hasan 等、©2022 Brion 与 Pattinson，依据 CC BY 4.0 使用（https://creativecommons.org/licenses/by/4.0/）；进行了裁切、重新编排，增加中文标题、分隔线和外框。

https://doi.org/10.68070/axh0qg44

3.3 数字孪生与可信闭环

3.3.1 快速代理与孪生集成

快速代理通过学习并复用响应关系，降低反复求解的成本。深度算子网络（DeepONet）学习输入函数到解场的映射，可用于温度与应力预测[45]；傅里叶神经算子（FNO）用于局部热演化与跨几何预测[20]。图 5(a)比较 PINN 与有限元的温度剖面[27]，图 5(b)比较残差 U 形网络（ResUNet）型与普通 DeepONet 在几何差异增大时的温度和应力外推误差，图 5(c)展示前者的 von Mises 应力场对照[45]。原研究依据相对参考几何的差异排序划分训练集与测试集，因此该外推结果反映的是特定几何划分下的适用范围，尚不能说明跨材料或跨设备的泛化能力。数值响应一致性与几何外推对应不同的评价问题，典型样本不能代表全部测试表现，算子结构本身也不等同于残差约束。神经算子孪生研究连接物理计算、FNO 代理、熔池特征与参数优化[46]，提出离线微调与在线材料校准，并利用图像提取的熔池长度分布校准吸收率概率分布。其中，反馈优化仅在合成数据上进行了虚拟演示，尚无实机在线闭环验证。

几何特征、序列网络和有限元样本也被用于建立热历史代理[47,48,49]，这些模型的物理信息来自仿真样本，而非方程残差约束。实验温度重建用于评价场预测[50]，开放神经网络交换格式（ONNX）导出则用于检查软件转换[51]。数值场对照、独立测量，以及模型导出前后的一致性检验各有用途，其中导出一致性只说明转换前后输出是否一致，并不证明过程预测准确。代理模型的计算收益则取决于训练开销能否由后续重复调用所节省的求解时间抵偿。

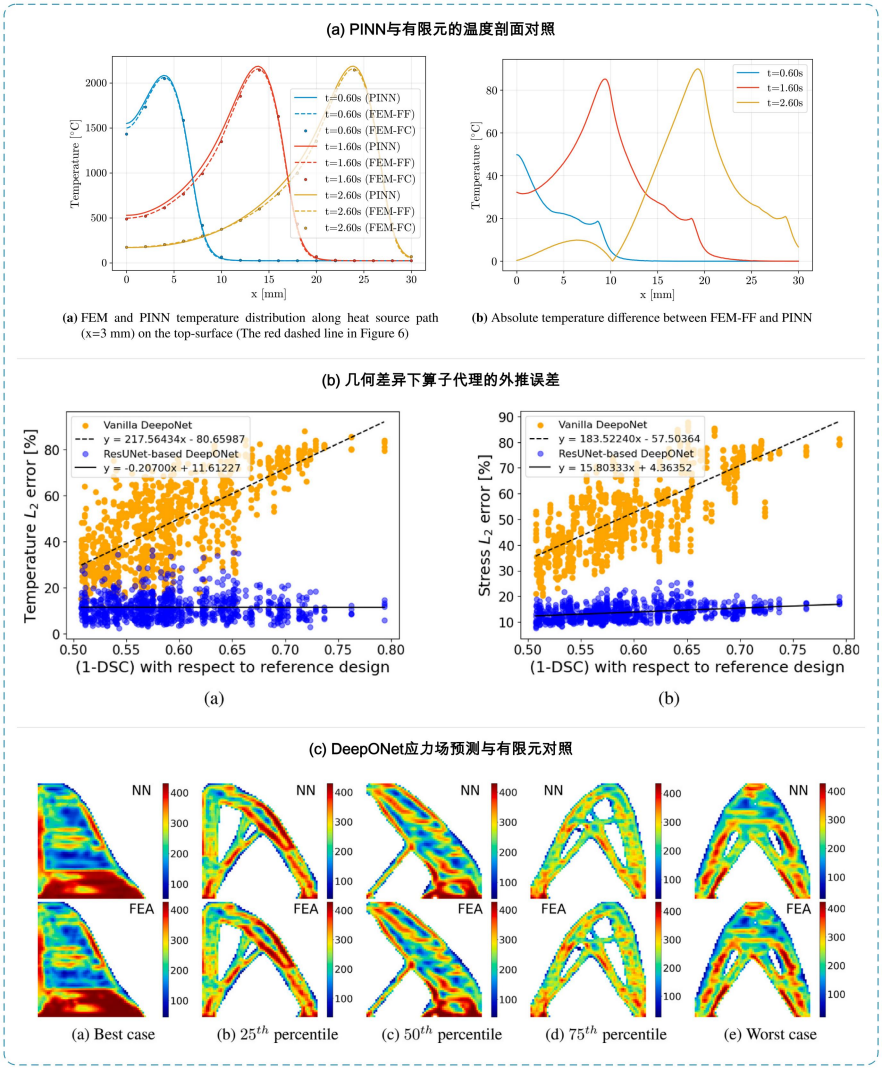


图 5 物理信息模型与算子代理的响应一致性及几何外推评价。

Figure 5. Evaluation of response consistency between physics-informed models and operator surrogates, and geometric extrapolation performance.

(a)0.6、1.6 和 2.6 s 时 PINN 与两种有限元参考模型的温度剖面，以及 PINN 与 FEM-FF 的绝对温差, 横轴为位置, 单位为 mm, 温度及温差单位为℃。FEM-FC 为空间步长 0.1 mm、时间步长 200 ms 的有限元参考模型, FEM-FF 在相同空间步长下将时间步长细化至 5 ms；(b)ResUNet 型与普通 DeepONet 的几何外推对比，横轴为相对参考几何的 1−DSC，DSC 为 Dice 相似系数，左、右子图的纵轴分别为温度与应力相对 L_2 误差（%），内部(a)、(b)为原图编号；(c)ResUNet 型 DeepONet 与有限元的 von Mises 应力场对照，按原文测试样本的应力相对 L_2 误差展示最佳、25%、50%、75%分位及最差样本，应力单位为 MPa。各面板节选自 Ryan 等[27]图 13、Kushwaha 等[45]图 19 和图 16，依次对应(a)—(c)，均采用数值参考，不构成独立实验或设备闭环验证。©2025 Ryan 等、©2024 Kushwaha 等，依据 CC BY 4.0 使用（https://creativecommons.org/licenses/by/4.0/）；进行了裁切、重新编排，增加中文标题、分隔线和外框，保留原图例与色标。

3.3.2 不确定性与动作准入

不确定性量化需要区分测量噪声、参数不确定性和模型结构偏差。相关研究结合仿真与美国国家标准与技术研究院增材制造基准实验（AM-Bench），通过序贯贝叶斯校准评价熔池和孔隙预测[6]。通用保形预测方法利用校准误差构建预测区间，空间自适应方法则考虑不同区域的误差差异[52]。这些方法在方程基准测试中对预测区间覆盖率的解释以样本可交换性为前提，即样本联合分布在顺序置换后保持不变。制造过程中的时间相关性和工况变化可能破坏这一前提，因此需要在具体工况下检查区间的覆盖率与宽度，再判断其适用范围，不能直接将其视为制造反馈的风险保证。

动作准入用于判断候选动作是否允许执行，预测可信并不意味着设备动作安全。例如，即使预测区间较窄，给出的动作仍可能超出设备限制。执行前应同时检查输入是否处于适用范围、动作幅度与变化率是否合规，以及不确定性是否会改变目标判断。依据不足时，可增加观测或采用保守策略，但不能用置信度代替设备硬约束。具体的证据记录和恢复要求见第 4 章。

3.4 不同建模范式的闭环适用性与方法选择

为比较三类方法对闭环控制的支撑作用，本文从其采用的模型及模型与控制环节的衔接展开讨论，重点考察状态估计、在线计算、动作约束和质量验证。纯数据驱动、传统机理和物理信息学习模型在闭环中的适用性，取决于数据条件、物理描述与控制任务。表 1 比较三类模型的建模依据、状态估计、计算成本和失效来源。MPC 属于利用模型预测并优化动作的控制策略，可以采用机理模型，也可以采用学习模型，因此与 PINN 并非互斥关系。

表 1 三类建模范式在增材制造闭环控制中的适用性比较

Table 1. Comparison of the Applicability of Three Modeling Paradigms in Additive Manufacturing Closed-Loop Control.

比较维度	纯数据驱动模型	传统机理模型	物理信息学习模型
建模依据	依赖样本覆盖与标签质量	依赖方程、参数与边界；通常需标定	融合数据与物理先验；效果取决于先验是否有效
状态估计	学习观测与状态的映射，受样本覆盖限制	由机理和观测估计状态，受模型精度与可辨识性限制	可融合部分观测与物理关系估计状态[12]；隐藏状态的可辨识性仍需单独检验
计算与更新	需离线训练；在线成本随模型与更新方式变化	高保真求解成本较高；低阶模型可支持部分实时任务	需计入训练、约束计算、更新与优化成本；推理时间不等于控制周期
工况变化	需检查训练与部署分布差异	需检验方程、参数和边界在新工况下的有效性	同时受数据覆盖及物理假设有效性限制
主要短板	数据偏差、样本不足及分布变化	机制遗漏、参数偏差及模型简化	数据误差、物理失配，以及物理项与数据项的权重和尺度选择困难
控制保障	依靠控制律、动作约束及闭环验证	需结合具体模型与控制方法分析稳定性	物理约束不等同于设备约束或稳定性保证
适用条件	数据较充分，目标关系可由样本学习	机理较清楚，可建立满足周期要求的模型	观测有限、部分物理关系可信，且融合增益可验证

注：依据本文所讨论的物理信息建模研究[5,12,18,22]、数据驱动设备反馈参照[42,43]及机理模型控制案例[44]归纳。控制保障和适用条件为本文提出的评价与选型建议，不代表原研究已完成相应验证。不同研究的工艺、数据及验证对象不同，本表不作跨研究数值排名。

https://doi.org/10.68070/axh0qg44

观测有限时，物理信息学习可借助可信的物理关系补充状态估计。文献[18]比较了物理输入与物理损失的不同配置，文献[22]则将热计算过程嵌入网络结构，两者从不同途径考察物理知识的作用。判断其增益，需要保持训练数据和测试条件一致；若热源、物性或边界描述与实际过程不符，物理约束也可能引入系统偏差。纯数据驱动方法可直接从图像识别工况并触发纠偏[42,43]，但部署条件与训练条件的差异仍需检查。因此，选型时应先明确控制是否需要重建内部状态，再判断已有数据和物理描述是否足以完成这一估计。

传统机理模型也可通过简化和在线校准适应控制任务。文献[44]将自适应一维热模型用于金属 DED 的 MPC，在五层壁沉积实验中比较了开环、单输入单输出和多输入多输出控制。因此，评价学习模型的控制价值时，应将低阶机理模型纳入对照。物理信息学习可用于参数辨识和重复响应查询[5,12]，但计算成本需要涵盖训练、更新和在线优化。残差较小并不自动保证闭环稳定性，仍需结合控制律、执行时延和设备约束检验。若机理清楚且低阶模型已满足控制周期，采用更复杂的学习模型就应说明其在精度或适用范围上的额外收益。

公平比较三类方法，需要尽量统一传感配置、工况、执行器约束和质量评价，并分别报告建模或训练成本、完整控制周期、扰动后的响应及独立测量的成形质量。现有材料挤出数据驱动纠偏[42,43]、金属机理模型 MPC[44]与金属物理信息状态预测[18,28]的验证对象不同，本文所纳入的上述研究尚未提供在共同条件下对三类方法的直接比较。表 2 进一步归纳各技术路线的适用条件与验证重点。

表 2 核心技术路线的适用条件与验证重点

Table 2. Applicability Conditions and Validation Priorities of Key Technical Approaches.

路线及依据	可考虑的任务与条件	主要代价或边界	优先验证项
残差 PINN[11,12,13]	金属状态预测；标签有限、方程与边界可规定的状态求解	优化开销，物理失配，隐藏状态不确定性	独立状态测量、热源和边界敏感性
时序物理信息模型[18,28]	金属状态预测；温度序列支持二维场估计[18]，历史窗口支持未来场预测[28]，非设备反馈	对传感配置的依赖、输入输出的时间关系及递推误差	峰值误差、数据同步、预测窗口与未见工况
结构展开与离散约束[22,23]	结构融合或离散约束的状态预测；可将物理迭代或离散过程嵌入模型	结构与离散假设限制	步长、边界变化与长期稳定性
参数化或算子代理[5,20,45]	离线参数筛选或数值场查询；PINN 与非 PINN 算子代理分别判断，不等于设备闭环	前期训练成本，训练覆盖范围	未见条件、候选解的独立复核
反馈决策[41,42,43,44]	金属仿真反馈[41]；非 PINN 金属 MPC[44]及聚合物设备反馈参照[42,43]，不作跨任务排名	仿真迁移、滞后与动作风险	同工况基线、响应时间、最终质量

4 面向目标任务的工程评价

数字孪生研究曾按代理建模、原位感知、硬件控制与智能策略划分四级体系[53]，但功能层级本身并不规定具体任务的验收条件。本文结合所讨论的制造任务，归纳六个评价维度和五类功能证据，用于记录已有验证及其缺口。这是一套定性分析框架，尚未经跨任务验证，不用于加权评分或成熟度排名；各项判断均以所考察的任务、材料、几何和设备条件为限。

4.1 评价维度与功能证据

六个评价维度依据过程监测、不确定性与自适应控制的工程需求归纳[2,6,7]。观测充分性关注现有信号能否支持所需的状态估计，跨工况泛化明确模型的适用范围；实时性与执行可行性检查动作能否在

允许时间内作用于过程；不确定性以及安全与恢复分别涉及误差对决策的影响和失效后的处置。表 3 列出各维度的核查要点。五类功能证据标识已经验证的环节，可同时涉及多个评价维度。这里的观测充分性检查不构成严格的可观测性证明，在线更新和设备反馈也只在任务需要时纳入评价。

表 3 六维工程评价
Table 3. Six-Dimensional Engineering Evaluation.

维度	验证要点
观测充分性	检查传感标定与同步、观测缺失及隐藏状态的独立验证；明确现有观测能否支撑任务，不代替可观测性证明
跨工况泛化	按构建或工况分组测试未见参数、路径、几何、材料或设备；不能以相邻帧随机划分替代跨工况验证
实时性	将采样至执行器响应的总时延及其波动与动作窗口比较；局部推理时间不等于完整控制周期
不确定性	报告适用工况下的区间覆盖与宽度，检查模型失配、分布变化和越界；置信度不替代硬约束
执行可行性	核对设备接口、动作幅度与变化率，保留指令、实际执行及后续响应的对应记录
安全与恢复	说明异常触发条件、拒绝动作、接管与回退，并检查失效处置结果；未测试时不认定已具备恢复能力

评价时，先限定任务、工况及允许误差或动作窗口，再选取适用维度并记录文献证据。证据满足明确要求时，记为“已支持”；实测结果违背要求时，记为“不满足”；缺少必要测试或要求不清时，记为“未确认”；任务无需该功能时，记为“不适用”。未报告结果不等于不满足要求。若文献没有给出阈值，则只判断已经展示的功能或效果，不据此认定工程验收达标。例如，固定模型可以不要求现场更新，离线设计可以不要求在线周期，但仍需说明适用范围并复核候选工艺。

五类功能证据包括预测验证、周期适配、现场适应、设备反馈和风险恢复。每条记录至少应包含任务与工况、评价维度、要求、证据出处、观测结果、判定及尚缺的验证，表 4 给出记录示例。若要说明制造质量得到改善，还应提供同工况基线、实际动作及后续响应记录、未参与训练或参数标定的独立质量测量、重复试验或结果变异，以及动作与质量变化的时序对应。图 6 将上述评价用于动作准入与风险处置；未测试的拒绝、接管或回退能力，仍记为“未确认”。

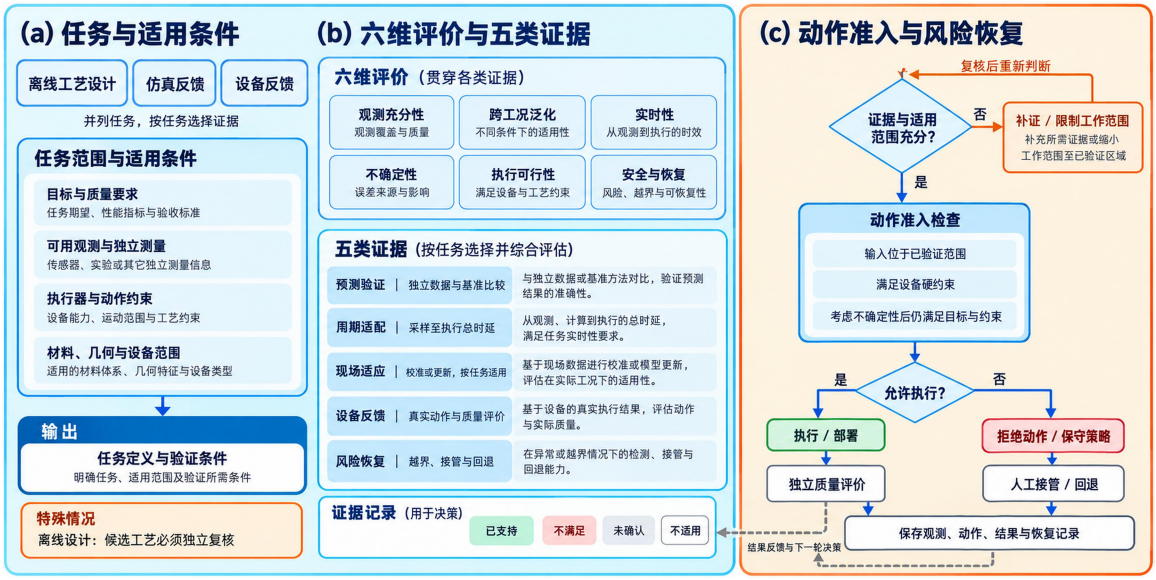


图 6 面向制造任务的工程验证与风险恢复框架。
Figure 6. Engineering Validation and Risk Recovery Framework for Manufacturing Tasks.

(a)限定任务和工况范围；(b)按六维要求检查五类功能证据；(c)判断动作准入，依据不足时补证，不能执行时采用拒绝、保守策略或接管回退。该图为本文的工程分析框架。

https://doi.org/10.68070/axh0qg44

4.2 代表性案例的工程评价

4.2.1 金属沉积的离线温度目标设计

金属线材定向能量沉积研究[5]开展了离线温度目标设计，以单轨首层末端探针在沉积后停留 10 s 的温度为目标，搜索功率与速度。目标温度为 100、130 和 160 ℃时，所选参数经校准后的有限元模型复核，得到 104.0、136.6 和 165.6 ℃，对应绝对偏差为 4.0、6.6 和 5.6 ℃。这些结果支持训练范围内的数值筛选。但有限元与 PINN 采用了相同的校准物理描述，因此所选工艺仍需独立实验验证，也尚未形成设备闭环。

该案例的证据来自原文表 2，可记录的结果是三个温度目标的有限元复核偏差。由于没有工业验收阈值，只能确认候选参数经过数值复核，不能据此判断生产达标。在线周期、现场更新和设备反馈不属于这一离线任务的要求，应记为“不适用”，而非将其缺失判为设计失败。该结果的适用范围受单轨校准、末端探针目标及固定几何限制；若用于多层控温，还需补充独立温度或质量测量、实际动作及风险处置验证。

4.2.2 材料挤出的设备反馈参照

材料挤出研究[42]利用热像识别相对流量类别并调整设备流量，可作为非 PINN、非金属的设备反馈案例。CNN-SelfAttention 在验证集上的准确率为 99.25%。对于 50%与 150%的相对流量偏移，启用控制后，相对基准构件的体积偏差分别由 11.72%降至 1.05%、由 19.67%降至 1.25%，纠偏结果以三个独立样本验证。原文闭环实验及图 16 支持已测试条件下的几何纠偏效果，但没有据此验证内部缺陷、力学性能或金属 PINN 的控制收益。报告的约 3 s 检测与反馈时间，也不足以判断完整周期是否适配任务。表 4 据此分别记录已展示的效果和尚缺的工程验收依据。

表 4 材料挤出设备反馈参照的功能证据记录示例[42]

Table 4. Example of Functional Evidence Documentation for Material Extrusion Equipment Feedback Reference [42].

功能证据	相关维度	支持状态与依据	判断边界或补证方向
预测验证	观测充分性、泛化、不确定性	验证集分类准确率 99.25%已报告；独立泛化、区间校准及工程验收阈值未确认	依据原文模型比较；分类结果不等于质量改善，也不等于满足工业精度要求
周期适配	实时性、执行可行性	约 3 s 检测与反馈时间已报告；采样到执行器响应的完整周期适配未确认	依据原文闭环实验描述；需对照动作窗口补充总时延、时延波动和实际执行记录
现场适应	泛化、不确定性	对本文限定的不更新模型方案不适用；不据此判断在线适应能力不足	任务限定为固定模型反馈；仍需验证固定模型的工况与材料范围
设备反馈	观测充分性、执行可行性	设备纠偏效果已支持，限已测试的 50%与 150%相对流量偏移；工业验收未确认	依据原文闭环实验及图 16、基准构件和三个独立样本；仅支持相应几何纠偏
风险恢复	安全与恢复	未确认，所用文献证据未充分展示故障触发、处置与恢复测试	需补传感缺失、越界、执行失败和接管测试；未报告不等于实际不具备该能力

上述案例检验的是不同对象：金属离线设计[5]检验数值冷却目标，聚合物设备反馈[42,43]检验实际纠偏效果，金属熔池策略[41]检验仿真熔深。非 PINN 金属 MPC 研究[44]补充了设备反馈与成形表征，但其效果不能直接归于 PINN 控制。表 4 中的“已支持”据此限定于已展示的功能或效果，并非整机部署合格。将方法迁移至另一任务时，关键是重新建立代理目标、设备动作与独立质量结果之间的验证关系。

5 关键挑战与研究展望

状态预测与反馈研究[18,28,41,42]留下了三个相互关联的问题：如何从观测误差中区分参数偏移与模型失配，估计改进能否通过设备动作改善质量，以及反馈改变数据分布后如何评价模型与策略。这些问题分别涉及可辨识性、收益归因和动态评价，也是将局部预测能力用于制造任务时需要解决的困难。

5.1 物理模型失配与跨工况适用性

物理先验是否有效，取决于方程、热源、材料属性和边界条件能否描述实际过程。参数辨识、观测融合与迁移学习已被用于温度预测和变化条件下的模型复用[12,19,39]，但参数偏移、传感偏差与机制缺

失可能表现为相似的预测误差。若模型结构不变，参数校准无法显式补入缺失的流动或相变机制，提高残差权重也难以弥补这种缺失。后续研究需要结合独立测量、敏感性分析和分组测试，区分可通过校准修正的偏差与需要扩展模型的失配，据此确定跨材料、几何和设备的适用范围。

5.2 状态预测与控制收益之间的联系

估计器与控制策略对质量改善的贡献需要分别考察。离线温度设计[5]、仿真熔深控制[41]和流量纠偏[42]中的状态与质量关系不同。估计更准确可能并未改变动作，也可能因执行滞后而错过调整窗口；稳健策略则可能容忍一定的估计误差。可先固定策略比较估计器，再固定估计器比较策略，以分析两者的贡献及交互作用。对于层间控温，还需检验温度偏移与几何、组织或性能的关系，避免仅因某个状态便于预测，就将其选作控制目标。

5.3 闭环数据与可复现评价

场预测考察给定输入下的响应[20,28,45]，设备纠偏却会同时改变输入与后续状态[42]。在闭环中，数据分布受策略影响，模型更新又会改变动作，因此历史数据上的低误差未必能够延续到另一种策略下。评价基准应以完整构建或工况为测试单位，减少将相邻帧分到训练集与测试集造成的信息泄漏，并分别考察固定模型、模型更新和策略变化的影响。动态轨迹还应与独立质量测量对应，以区分模型或控制行为的作用与数据划分、工况选择带来的差异。

6 结论

物理信息学习为增材制造中的有限观测提供了补充，但其作用取决于所引入物理描述的有效性。残差约束、结构融合和仿真代理分别依赖方程与边界、嵌入的计算过程以及仿真样本覆盖，物理特征与数据增强可配合这些途径使用。选型时应先明确目标状态和可用观测，再判断哪种物理信息能够补足估计所需的信息。

本文讨论的金属研究已覆盖状态预测、离线工艺筛选与数值复核，以及仿真反馈；金属 PINN 的实机闭环效果仍缺少充分验证。非 PINN 金属机理模型控制和聚合物设备纠偏提供了可供借鉴的验证方式。对学习模型而言，后续比较应纳入能够满足控制周期的低阶机理模型，并在相同任务条件下考察质量改善与建模、更新成本，从而判断引入学习模型的实际收益。

本文提出的六维工程评价框架以五类功能证据记录预测、反馈与部署各环节的验证缺口，适用性仍需在更多材料、几何和设备条件下检验。后续研究可围绕三个具体问题展开：区分物理模型失配与可校准偏差；通过固定估计器或固定策略的对照，分析各自对质量改善的贡献；以完整构建或工况划分测试数据，并将反馈轨迹与独立质量测量对应。这些工作有助于解释模型为何在某些任务中有效，以及在什么条件下失效。

参考文献

[1] WANG P, YANG Y, 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. DOI: 10.1016/j.jmapro.2021.11.037.

[2] CHEN L, BI G, YAO X, 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. DOI: 10.1016/j.jmsy.2024.04.013.

[3] GUO S, AGARWAL M, COOPER C, et al. Machine learning for metal additive manufacturing: Towards a physics-informed data-driven paradigm[J]. Journal of Manufacturing Systems, 2022, 62: 145-163. DOI: 10.1016/j.jmsy.2021.11.003.

[4] PENG B, PANESAR A. Multi-layer thermal simulation using physics-informed neural network[J]. Additive Manufacturing, 2024, 95: 104498. DOI: 10.1016/j.addma.2024.104498.

[5] HASAN F, HAMRANI A, DOLMETSCH T, et al. Inverse Thermal Process Design for Interlayer Temperature Control in Wire-Directed Energy Deposition Using Physics-Informed Neural Networks[J]. Journal of Manufacturing and Materials Processing, 2026, 10(2): 52. DOI: 10.3390/jmmp10020052.

[6] WANG Z, JIANG C, LIU P, et al. Uncertainty quantification and reduction in metal additive manufacturing[J]. npj Computational Materials, 2020, 6(1): 175. DOI: 10.1038/s41524-020-00444-x.

[7] GUNASEGARAM D R, BARNARD A S, MATTHEWS M J, et al. Machine learning-assisted in-situ adaptive strategies for the control of defects and anomalies in metal additive manufacturing[J]. Additive Manufacturing, 2024, 81: 104013. DOI: 10.1016/j.addma.2024.104013.

[8] YANG S, PENG S, GUO J, et al. A review on physics-informed machine learning for monitoring metal additive manufacturing process[J]. Advanced Manufacturing, 2024(2): 0008. DOI: 10.55092/am20240008.

[9] FARRAG A, YANG Y, CAO N, et al. Physics-Informed Machine Learning for metal additive manufacturing[J]. Progress in Additive Manufacturing, 2025, 10(1): 171-185. DOI: 10.1007/s40964-024-00612-1.

[10] SHARMA R, RAISSI M, GUO Y B. Physics-Informed Machine Learning for Smart Additive Manufacturing[J]. Procedia CIRP, 2026, 138: 650-655. DOI: 10.1016/j.procir.2026.01.112.

[11] HOSSEINI E, SCHEEL P, MÜLLER O, et al. Single-track thermal analysis of laser powder bed fusion process: Parametric solution through physics-informed neural networks[J]. Computer Methods in Applied Mechanics and Engineering, 2023, 410: 116019. DOI: 10.1016/j.cma.2023.116019.

[12] LIAO S, XUE T, JEONG J, et al. Hybrid thermal modeling of additive manufacturing processes using physics-informed neural networks for temperature prediction and parameter identification[J]. Computational Mechanics, 2023, 72(3): 499-512. DOI: 10.1007/s00466-022-02257-9.

[13] ZHU Q, LIU Z, YAN J. Machine learning for metal additive manufacturing: predicting temperature and melt pool fluid dynamics using physics-informed neural networks[J]. Computational Mechanics, 2021, 67(2): 619-635. DOI: 10.1007/s00466-020-01952-9.

[14] TANG J, SCHEEL P, MOHEBBI M S, et al. On the calibration of thermo-microstructural simulation models for Laser Powder Bed Fusion process: Integrating physics-informed neural networks with cellular automata[J]. Additive Manufacturing, 2024, 96: 104574. DOI: 10.1016/j.addma.2024.104574.

[15] CHEN Z, MU H, ZHANG Z, et al. Graph neural operator: A DeepONet-based framework for learning thermo-mechanical distortion in metallic additive manufacturing[J]. Additive Manufacturing, 2026, 115: 105063. DOI: 10.1016/j.addma.2025.105063.

[16] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. Journal of Computational Physics, 2019, 378: 686-707. DOI: 10.1016/j.jcp.2018.10.045.

[17] KRITZINGER W, KARNER M, TRAAR G, et al. Digital Twin in manufacturing: A categorical literature review and classification[J]. IFAC-PapersOnLine, 2018, 51(11): 1016-1022. DOI: 10.1016/j.ifacol.2018.08.474.

[18] SAJADI P, DEHAGHANI M R, TANG Y, et al. Two-dimensional temperature field prediction with in-situ data in metal additive manufacturing using physics-informed neural networks[J]. Engineering Applications of Artificial Intelligence, 2025, 150: 110636. DOI: 10.1016/j.engappai.2025.110636.

[19] PENG S, YANG S, GAO B, et al. Prediction of 3D temperature field through single 2D temperature data based on transfer learning-based PINN model in laser-based directed energy deposition[J]. Journal of Manufacturing Processes, 2025, 138: 140-156. DOI: 10.1016/j.jmapro.2025.02.015.

[20] CHEN J, XU W, BALDWIN M, et al. Capturing Local Temperature Evolution During Additive Manufacturing Through Fourier Neural Operators[J]. Journal of Manufacturing Science and Engineering, 2024, 146(9): 091001. DOI: 10.1115/1.4065316.

[21] WANG R, WANG R, DOU C, et al. Sub-surface thermal measurement in additive manufacturing via machine learning-enabled high-resolution fiber optic sensing[J]. Nature Communications, 2024, 15: 7568. DOI: 10.1038/s41467-024-51235-7.

[22] GHUNGRAD S, FAEGH M, GOULD B, et al. Architecture-Driven Physics-Informed Deep Learning for Temperature Prediction in Laser Powder Bed Fusion Additive Manufacturing With Limited Data[J]. Journal of Manufacturing Science and Engineering, 2023, 145(8): 081007. DOI: 10.1115/1.4062237.

[23] CHEN J, PIERCE J, WILLIAMS G, et al. Accelerating Thermal Simulations in Additive Manufacturing by Training Physics-Informed Neural Networks With Randomly Synthesized Data[J]. Journal of Computing and Information Science in Engineering, 2024, 24(1): 011004. DOI: 10.1115/1.4062852.

[24] SAJADI P, RAHMANI DEHAGHANI M, TANG Y, et al. Physics-Informed Online Learning for Temperature Prediction in Metal AM[J]. Materials, 2024, 17(13): 3306. DOI: 10.3390/ma17133306.

[25] UHRICH B, PFEIFER N, SCHÄFER M, et al. Physics-informed deep learning to quantify anomalies for real-time fault mitigation in 3D printing[J]. Applied Intelligence, 2024, 54(6): 4736-4755. DOI: 10.1007/s10489-024-05402-4.

[26] PENG B, PANESAR A. Multi-layer thermal history prediction framework for directed energy deposition based on extended physics-informed neural networks (XPINN)[J]. Additive Manufacturing, 2025, 110: 104953. DOI: 10.1016/j.addma.2025.104953.

[27] RYAN M, BAQERSHAHI M H, MOSHAYEDI H, et al. Physics-informed machine learning surrogate for scalable simulation of thermal histories during wire-arc directed energy deposition[J]. Additive Manufacturing Letters, 2025, 15: 100327. DOI: 10.1016/j.addlet.2025.100327.

[28] TIAN M, MU H, LIU T, et al. Physics-informed machine learning-based real-time long-horizon temperature fields prediction in metallic additive manufacturing[J]. Communications Engineering, 2025, 4(1): 168. DOI: 10.1038/s44172-025-00501-7.

[29] LIAO S, XUE T, CAO J. Deep learning based reconstruction of transient 3D melt pool geometries in laser powder bed fusion from coaxial melt pool images[J]. Manufacturing Letters, 2024, 40: 50-53. DOI: 10.1016/j.mfglet.2024.02.005.

[30] LIU S, LI R, ZHOU J, et al. Physics-Based Data Augmentation Enables Accurate Machine Learning Prediction of Melt Pool Geometry[J]. Applied Sciences, 2025, 15(15): 8587. DOI: 10.3390/app15158587.

[31] RASHID A, VATANDOUST F, KOTA A, et al. Bead geometry prediction in wire arc directed energy deposition using physics-informed machine learning and low-fidelity data[J]. Additive Manufacturing, 2025, 109: 104881. DOI: 10.1016/j.addma.2025.104881.

[32] XU H, LV R, ZI B. A Multimodal Spatiotemporal Fusion Network With Physical-Data-Driven Learning for Additive Manufacturing Fault Diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 1-15. DOI: 10.1109/TIM.2025.3633352.

[33] XIE J, SAFDAR M, CHEN L, et al. Audio-visual cross-modality knowledge transfer for machine learning-based in-situ monitoring in laser additive manufacturing[J]. Additive Manufacturing, 2025, 101: 104692. DOI: 10.1016/j.addma.2025.104692.

[34] TOORANDAZ S, TAHERKHANI K, LIRAVI F, et al. A novel machine learning-based approach for in-situ surface roughness prediction in laser powder-bed fusion[J]. Additive Manufacturing, 2024, 91: 104354. DOI: 10.1016/j.addma.2024.104354.

[35] JUHASZ M, CHIN E, CHOI Y, et al. Harnessing on-machine metrology data for prints with a surrogate model for laser powder directed energy deposition[J]. Additive Manufacturing, 2025, 105: 104745. DOI: 10.1016/j.addma.2025.104745.

[36] GUIRGUIS D, TUCKER C, BEUTH J. Accelerating process development for 3D printing of new metal alloys[J]. Nature Communications, 2024, 15: 582. DOI: 10.1038/s41467-024-44783-5.

[37] FAEGH M, GHUNGRAD S, HAGHIGHI A. A physics-informed neural network framework for decomposition and path planning in multi-laser additive manufacturing[J]. Manufacturing Letters, 2025, 44: 1129-1138. DOI: 10.1016/j.mfglet.2025.06.133.

[38] DEPAOLI F, FELICIONI S, PONZIO F, et al. Physics-Informed Neural Networks: A Step Towards Data-Driven Optimization of Additive Manufacturing[C]//2024 IEEE 29th International Conference on Emerging Technologies and Factory Automation (ETFA). [出版地不详]: IEEE, 2024: 1-4. DOI: 10.1109/ETFA61755.2024.10710827.

[39] FAEGH M, SANVELLY R R, ARABPOOR R, et al. Physics-informed neural networks for thermal modeling transferable across paths, print parameters, and beam profiles[J]. Additive Manufacturing, 2026, 116: 105060. DOI: 10.1016/j.addma.2025.105060.

[40] MONTALBANO T, NIMER S, DAFFRON M, et al. Machine learning enabled discovery of new L-PBF processing domains for Ti-6Al-4V[J]. Additive Manufacturing, 2025, 98: 104632. DOI: 10.1016/j.addma.2024.104632.

[41] CAO X, DUAN C, LUO X, et al. Deep learning-based rapid prediction of temperature field and intelligent control of molten pool during directed energy deposition process[J]. Additive Manufacturing, 2024, 94: 104501. DOI: 10.1016/j.addma.2024.104501.

[42] SADAF A I, AHMED H. Spatiotemporal deep learning using infrared thermography for real-time monitoring and process parameter adjustment in material extrusion[J]. Journal of Intelligent Manufacturing, 2026, 37(9): 3713-3732. DOI: 10.1007/s10845-025-02702-5.

[43] BRION D A J, PATTINSON S W. Generalisable 3D printing error detection and correction via multi-head neural networks[J]. Nature Communications, 2022, 13: 4654. DOI: 10.1038/s41467-022-31985-y.

[44] VAN BLITTERSWIJK R H, BOTELHO L A, KHAJEPOUR A. Real-time multivariable control of directed energy deposition via adaptive model predictive control[J]. Additive Manufacturing, 2025, 111: 104941. DOI: 10.1016/j.addma.2025.104941.

[45] KUSHWAHA S, PARK J, KORIC S, et al. Advanced deep operator networks to predict multiphysics solution fields in materials processing and additive manufacturing[J]. Additive Manufacturing, 2024, 88: 104266. DOI: 10.1016/j.addma.2024.104266.

[46] LIU N, LI X, RAJANNA M R, et al. Deep neural operator enabled digital twin modeling for additive manufacturing[J]. Advances in Computational Science and Engineering, 2024, 2(3): 174-201. DOI: 10.3934/acse.2024010.

[47] ROY M, WODO O. Data-driven modeling of thermal history in additive manufacturing[J]. Additive Manufacturing, 2020, 32: 101017. DOI: 10.1016/j.addma.2019.101017.

[48] REN K, CHEW Y, ZHANG Y F, et al. Thermal field prediction for laser scanning paths in laser aided additive manufacturing by physics-based machine learning[J]. Computer Methods in Applied Mechanics and Engineering, 2020, 362: 112734. DOI: 10.1016/j.cma.2019.112734.

[49] LE V T, BUI M C, PHAM T Q D, et al. Efficient prediction of thermal history in wire and arc additive manufacturing combining machine learning and numerical simulation[J]. The International Journal of Advanced Manufacturing Technology, 2023, 126(9-10): 4651-4663. DOI: 10.1007/s00170-023-11473-3.

[50] YANG S, LIAO Z, WANG Z, et al. Physics-informed Fourier-Gaussian-Laplacian neural network for temperature field reconstruction and accurate prediction in laser wire additive manufacturing[J]. Journal of Manufacturing Processes, 2026, 157: 871-900. DOI: 10.1016/j.jmapro.2025.12.031.

[51] YOUSFI L, GUIZANI A, HAMMADI M, et al. Physics-Informed Neural Networks for Fast Thermal Simulation in Laser Wire Additive Manufacturing[C]//2025 15th France-Japan & 13th Europe-Asia Congress on Mechatronics (MECATRONICS) / 23rd International Conference on Research and Education in Mechatronics (REM). [出版地不详]: IEEE, 2025: 1-6. DOI: 10.1109/MECATRONICS-REM67547.2025.11349643.

[52] YU Y, HO C H, WANG Y. A conformal prediction framework for uncertainty quantification in physics-informed neural networks[J]. Journal of Computational Physics, 2026, 561: 114979. DOI: 10.1016/j.jcp.2026.114979.

[53] PHUA A, DAVIES C H J, DELANEY G W. A digital twin hierarchy for metal additive manufacturing[J]. Computers in Industry, 2022, 140: 103667. DOI: 10.1016/j.compind.2022.103667.

Advances in Physics-Informed Learning for Smart Additive Manufacturing

Xue Hui[1*], Zhao Hongyu[1], Zhang Mengmeng[2], Zhang Zhijia[2*]

1. School of Mechanical Engineering, Tiangong University, No. 399 BinShuiXi Road, XiQing District, Tianjin ; 2. School of Materials Science and Engineering, Tiangong University, No. 399 BinShuiXi Road, XiQing District, Tianjin

Abstract: Physics-informed learning has been used for state estimation and process decision-making in additive manufacturing. Its engineering value depends on whether it supports effective process adjustments and improves part quality. Focusing on metal fusion-based additive manufacturing, this review examines residual constraints, structural integration, and simulation-trained surrogates, compares their suitability for closed-loop applications under different observation conditions, and proposes a six-dimensional engineering evaluation framework. Existing studies provide evidence for state prediction, including temperature, offline process screening, and simulated feedback, but do not yet establish the effectiveness of equipment-level closed-loop control using PINNs in metal additive manufacturing. Physical priors can supplement limited observations, but mismatches in heat sources, material properties, or boundary conditions can also introduce bias. Assessing their control value requires examining whether state estimates change process actions and whether those actions improve independently measured part quality. End-to-end latency, performance across operating conditions, and risk recovery capabilities define the further validation needed before deployment.

Keywords: smart additive manufacturing; physics-informed learning; in situ monitoring; process decision-making; closed-loop control

https://doi.org/10.68070/zp2t4444