

基于机器学习的铝合金电弧增材薄壁构件成形质量预测及多目标优化

彭逸琦^{1,2}, 高悦芳³, 华谭智³, 张思睿³, 赵宇凡^{1,2}, 林鑫^{1,2}

(1. 西北工业大学 凝固技术全国重点实验室, 陕西 西安 710072)

(2. 西北工业大学 金属高性能增材制造与创新设计工业和信息化部重点实验室, 陕西 西安 710072)

(3. 西北工业大学 材料学院, 陕西 西安 710072)

摘要: 电弧增材制造 (WAAM) 在航空航天领域具有重要应用价值, 但其热输入不稳定性导致铝合金薄壁构件几何符合度差与内部缺陷多的问题突出。针对传统方法在多物理场耦合优化中的局限性, 本研究提出数据驱动解决方案: 通过构建工艺参数 (电流、扫描速率、送丝速率) 与成形质量 (路径/层间壁厚一致性、孔隙率) 的数据集, 建立反向传播 (BP) 神经网络模型, 并融合遗传算法 (GA) 优化原始模型, 结合第二代非支配排序遗传算法 (NSGA-II) 进行成形质量多目标寻优。结果表明: 优化后的 GA-BP 模型显著提升了沿路径壁厚一致性和孔隙率的预测精度, 但层间壁厚一致性预测优化效果有限。通过 NSGA-II 获得的 50 组 Pareto 解集提出 4 类优化策略, 验证试验结果表明模型预测误差为 8.89%, 准确地实现了成形质量指标的协同优化。

关键词: 电弧增材制造; 机器学习; 多目标优化; 铝合金; 成形质量

中图分类号: TG146.21; TP181

文献标识码: A

文章编号: 1002-185X(2026)01-0105-11

1 引言

电弧增材制造 (wire arc additive manufacturing, WAAM) 作为一种金属增材制造技术, 近年来在航空航天、汽车、船舶以及能源领域引起了广泛关注并得到了广泛应用^[1-3]。与传统制造工艺相比, WAAM 具有较高的材料利用率、较短的生产周期以及较低的生产成本, 尤其适用于钛合金、铝合金、钢材等金属材料的中低复杂度零部件制造^[4-6]。然而, 由于 WAAM 工艺中存在较大且不稳定的热输入, 每一层熔覆层在加热和冷却过程中经历复杂的热历史, 使得熔覆层的几何形状难以稳定控制, 同时也为优化工艺参数与抑制缺陷的形成提供了重要的改进空间^[7-8]。在这些挑战中, 用于航空航天轻量化支撑结构的铝合金薄壁墙形态及其缺陷控制尤为困难, 由于热输入的不稳定性, 熔道几何形状的不稳定性会随着每一层的叠加而逐渐累积, 最终导致薄壁墙的成形质量难以保障^[9-10]。此外, 薄壁墙对工艺参数的敏感性较高, 热输入、送丝速率等参数的微小变化都会直接影响其几何形状和力学性能。在增材制造过程中, 稍有不当的热输入或工艺调节便可能导致熔池的不稳定、构件形变与裂纹等缺陷, 从而影响薄壁墙的力学性能和使用寿命^[11-12]。传统

的工艺参数优化方法主要依赖经验性调整或试错法, 这些方法不仅周期长、成本高, 而且在面对复杂的工艺要求时, 往往难以实现高效优化。此外, WAAM 过程涉及多个极端物理场的相互作用, 使得这些传统方法难以有效应对复杂的多目标优化需求^[13-14]。

为克服现有研究的局限性, 大量研究开始探索基于数据驱动的机器学习方法以优化电弧增材制造工艺。机器学习能够从大量实验数据中提取潜在规律, 建立精确的预测模型, 从而快速、低成本地优化工艺参数^[15-17]。同时, 结合多目标优化算法, 可以在考虑多个成形优化目标的同时, 平衡不同目标之间的权重, 实现更加精准的工艺调节效果^[18]。例如, Oh 等人^[19]通过支持向量机 (SVM) 模型优化 WAAM 工艺参数, 显著降低了起弧区与稳定区之间的几何形态差异; Le 等人^[20]研究了 316L 不锈钢在电弧增材制造中的单道工艺参数优化, 采用贝叶斯神经网络模型预测焊缝几何特性, 并结合遗传算法和 TOPSIS 方法进行多目标优化, 显著提升了焊缝的几何质量。此外, Le 等人^[21]进一步利用 WAAM 热循环有限元 (FE) 模型, 基于不同热输入水平下的热模拟数据, 对前馈神经网络模型 (FFNN-SM) 进行了训练和验证, 该模型能够准确、快速地预测温度演变。郭灿等人^[22]进一步应用机器学习

收稿日期: 2025-03-21

基金项目: 陕西省教育厅服务地方专项计划 (24JC086)

作者简介: 彭逸琦, 男, 2002 年生, 博士生, 西北工业大学凝固技术全国重点实验室, 陕西 西安 710072, E-mail: yiqipeng@mail.nwpu.edu.cn

方法研究了镁合金电弧增材制造中的多层成形质量,分析了不同工艺参数对多层成形质量的影响,并通过优化确定了最佳工艺参数范围。目前,现有研究受限于有限样本数据,难以有效训练复杂模型,导致电弧增材制造薄壁构件成形质量预测精度不足,且无法满足复杂服役性能条件下构件成形质量多目标优化需求。

本研究提出了一种铝合金电弧增材制造薄壁构件成形质量多目标优化方法。通过建立成形质量遗传算法-反向传播(GA-BP)预测模型,采用第二代非支配排序遗传算法(NSGA-II)对工艺参数进行多目标优化。验证实验模型具有良好的预测精度,优化工艺参数显著提升了成形质量。该方法为高精度 WAAM 制造提供了有效解决方案。

2 实验

在电弧增材制造铝合金薄壁墙成形试验中,基板选用 2024 铝合金,长宽高尺寸为 100 mm×100 mm×10 mm,焊丝选用 2219 铝合金,其直径为 1.6 mm,基板与焊丝的具体成分见表 1。

电弧增材制造实验中,使用同轴送丝设备进行沉积。实验过程中采用高纯氩气作为保护气体,维持低氧惰性环境,以提高焊接质量和稳定性。实验前固定基板在沉积平台上,预热至 200 ℃。确保系统正常运行后,接入保

护气体。实验开始时,焊机和送丝喷头沿基板表面同轴直线运动,沉积丝材,每道沉积层预设长度为 100 mm。完成一层沉积后,关闭预热装置,为了兼顾沉积效率与成形质量,保证层间冷却 2 min,并手动调整 z 轴抬升量,确保层间熔合良好。

通过路径和层间壁厚均匀性评估薄壁墙的几何形态稳定性(图 1a、1b)。沿路径等距测量 10 个位置壁厚,每个点独立测量 3 次,计算平均壁厚标准差来评估路径方向壁厚均匀性(S-Straight);层间壁厚均匀性(D-Straight)则通过制备 3 个代表性横截面试样金相,沿沉积方向等距选取 10 个测量点,同样计算 3 组数据平均标准差进行评价。路径方向和层间壁厚均匀性的标准差计算方法如式(1)所示。

$$S = \sqrt{\frac{\sum_{i=1}^n (L_i - \bar{L})^2}{n - 1}}$$

(1)

式中 S 表示样本数据标准差, n 表示样本数量, L_i 样本测量长度, \bar{L} 表示样本测量长度平均值。

针对内部缺陷特征,重点量化构件的孔隙率(图 1c)。采用光学显微镜观察横截面试样金相表面,结合图像二值化处理精确计算 3 组试样孔隙率均值 ϕ , 计算方式如式(2)所示。该多指标评价体系通过重复测量确保数据可靠性以系统性评估试样的内部质量和成形稳定性。

表 1 2024 铝合金基板与 2219 铝合金焊丝的化学成分

Table 1 Chemical composition of 2024 aluminum alloy substrate and 2219 aluminum alloy welding wire (wt%)

Material	Cu	Mg	Si	Mn	Fe	Zr	Ti	Zn	Al
2024 substrate	4.52	1.63	0.50	0.35	0.50	<0.01	0.15	0.25	Bal.
2219 welding wire	5.97	0.052	0.028	0.31	0.116	0.20	0.12	<0.01	Bal.

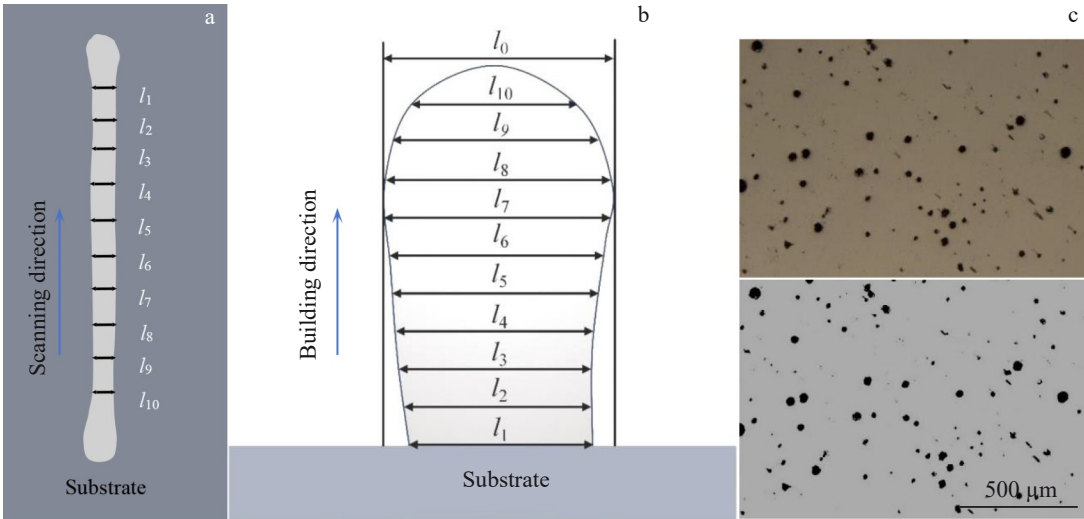


图 1 薄壁墙成形质量测试示意图

Fig.1 Schematic diagrams of thin-wall formation quality testing: (a) straightness of wall thickness along the scanning direction; (b) straightness of wall thickness along the deposition direction; (c) porosity

$$\phi = \frac{A_p}{A_t} \times 100\%$$

(2)

式中 A_p 表示孔隙面积, A_t 表示金相总面积。

本实验选取3种电弧增材制造关键工艺参数: 电流 (current, I)、扫描速率 (travel speed, TS) 和送丝速率 (wire feed speed, WFS) 作为机器学习模型的输入, 采用三因素三水平全因子试验设计, 共27组工艺参数组合, 具体参数范围如表2所示。

3 机器学习模型

3.1 GA-BP神经网络构建

本研究采用单隐含层BP神经网络构建预测模型, 输入层(电流、扫描速率、送丝速率)与输出层(路径/层间壁厚标准差及孔隙率)均为3节点, 针对27组试验数据按8:2比例划分训练集与测试集。通过经验公式确定隐含层节点数范围为4~12, 经节点数遍历与精度评估后选定5节点, 形成3-5-3网络结构(图2)。模型采用tansig函数增强非线性映射, 输出层使用purelin函数保持连续预测特性, 结合Levenberg-Marquardt算法加速收敛, 并通过[0,1]归一化抑制噪声干扰。针对训练集样本少的问题, 本研究采用5折交叉验证方式, 以提升模型的泛化能力, 缓解小样本条件下模型拟合的过拟合风险。

$$l = \sqrt{n + m} + a$$

(3)

式中, n 为输入层节点数, m 为输出层节点数, a 为1~10的任意实数。

为解决传统BP模型易陷局部最优问题, 引入遗传算法构建GA-BP混合模型^[23]。采用实数编码生成52维染色体(对应网络权阈值), 设置50种群规模迭代100次, 以训练集均方根误差(RMSE)为适应度基准, 通过0.2交叉概率和间隔3代动态变异策略平衡全局搜索与局部优

化。该框架通过遗传算法全局粗调网络参数, 再经反向传播精修, 形成双阶段优化机制。通过平均绝对误差(MAE)、RMSE、均方误差(MSE)、平均绝对百分比误差(MAPE)和拟合优度(R^2)这5类指标综合评价模型精度, 为后续多目标优化奠定基础^[17]。

3.2 NSGA-II多目标优化算法构建

针对电弧增材制造过程中工艺参数热输入引发的多目标优化问题(大热输入虽可降低孔隙率但易导致层间塌陷, 小热输入虽能抑制熔道铺展却会恶化壁厚均匀性), 建立了基于电流、扫描速率和送丝速率3个决策变量的多目标优化模型, 优化目标包括路径/层间壁厚标准差及孔隙率。研究采用NSGA-II, 充分利用其分层非支配排序机制、精英保留策略和基于拥挤距离的多样性保持方法, 将GA-BP神经网络作为适应度函数嵌入优化框架, 构建了NSGA-II算法结合GA-BP神经网络的混合模型(图3)。模型通过迭代搜索生成Pareto最优解集, 解析工艺参数与质量目标的非线性映射关系, 结合多目标权重配比实现动态权衡优化, 最终输出满足相应优化策略的工艺参数配置方案。

4 结果与分析

4.1 工艺参数与成形质量相关性

经过对薄壁墙试样的沿路径宽度测量与对金相试样的层间宽度与孔隙率测量后, 所获数据集如表3所示。

基于薄壁试样测量数据, Pearson相关性分析(图4)揭示成形质量与工艺参数间的非线性耦合关系。图中相关系数 $r=1$ 表示完全正相关, $r=-1$ 表示完全负相关, $|r|$ 值越大说明相关性越强, 越接近0则表示相关性越弱。结果显示, 沿路径方向壁厚标准差主要与电流呈负相关($r=-0.34$); 沉积方向壁厚标准差与扫描速率呈显著负相关($r=-0.52$), 同时与电流呈正相关($r=0.37$)。孔隙率主要受电流与送丝速率的影响, 其中电流增大有助于降低孔隙缺陷($r=-0.29$), 而送丝速率提升加剧孔隙率($r=0.25$)。工艺参数对成形质量的影响表现出复杂的耦合关系, 单一参数的优化难以实现整体成形质量的全面提升, 需要多目标优化参数协同优化成形质量。

因此, 扫描速率对沉积方向成形质量具有显著调控

表2 全因子试验因素水平表

Table 2 Factor-level table for full-factorial experiment

	Parameter	Level-1	Level-2	Level-3
A	I/A	150	170	190
B	$TS/mm \cdot min^{-1}$	200	250	300
C	$WFS/m \cdot min^{-1}$	4	5	6




图2 单隐含层BP神经网络结构示意图

Fig.2 Schematic diagram of the single-hidden-layer BP neural network structure

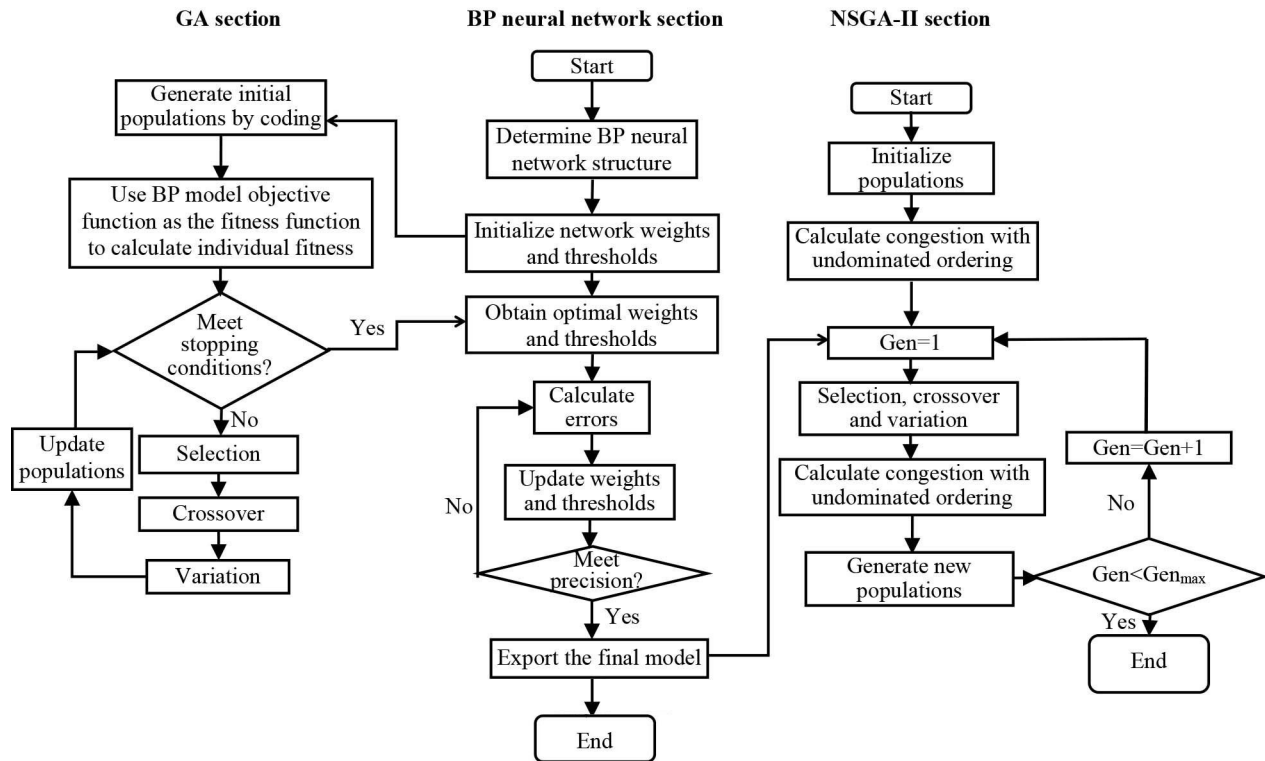


图3 NSGA-II算法结合GA-BP神经网络的混合模型流程图

Fig.3 Hybrid model flowchart of NSGA-II combined with GA-BP neural network

表3 全因子试验结果

Table 3 Full-factorial experiment results

Sample	I/A	TS/ mm·min ⁻¹	WFS/ m·min ⁻¹	S-Straight	D-Straight	Porosity/%
1	170	300	5	0.4595	0.4727	1.443
2	170	300	4	0.3561	0.8728	0.738
3	170	300	6	0.2588	0.6525	1.613
4	170	250	5	0.0676	0.6290	2.136
5	170	200	5	0.3032	0.7480	1.144
6	150	300	5	0.4151	0.5947	1.872
7	190	300	5	0.2612	0.5171	1.868
8	170	200	6	0.8484	1.1099	2.009
9	170	200	4	0.2588	0.7914	1.162
10	170	250	6	0.1401	0.8249	1.729
11	170	250	4	0.2367	0.7553	1.710
12	190	300	6	0.1314	0.6969	1.102
13	190	300	4	0.2206	0.5039	1.005
14	150	300	6	0.9220	0.2394	2.632
15	150	300	4	0.8277	0.6317	1.547
16	150	200	5	0.1425	0.6850	0.794
17	190	200	5	0.4916	0.8520	1.536
18	150	250	5	0.1610	0.5122	1.790
19	190	250	5	0.2521	0.6768	0.845
20	190	200	6	0.2824	0.7263	1.315
21	190	200	4	0.2902	0.7098	0.632
22	190	250	6	0.1755	0.8066	1.879
23	190	250	4	0.1829	0.6977	1.555
24	150	200	6	0.3597	0.4336	0.906
25	150	200	4	0.2607	0.8007	2.151
26	150	250	6	0.4519	0.3849	1.566
27	150	250	4	0.3281	0.5266	1.096

作用,而电流对孔隙率与扫描方向精度呈反向调控作用,送丝速率则主要影响孔隙率。工艺参数与成形质量之间表现出非线性、弱相关的复杂耦合特性,传统线性模型难以准确表征其内在关联。这一结论为后续构建GA-BP模型提供理论依据,表明通过机器学习方法能够有效挖掘工艺参数与成形质量之间的隐含非线性映射关系。

4.2 基于GA优化的BP神经网络预测模型性能

基于20组训练样本的建模结果表明,BP神经网络在沿路径壁厚一致性、层间壁厚一致性及孔隙率预测中,训练集RMSE分别为0.1309、0.1098和0.2273(图5),根据回归拟合图(图6)反映BP模型测试集预测性能显著劣化,其整体回归系数 R 值仅0.74346,测试集 R 值更跌至0.61468,暴露出传统模型在复杂非线性关系建模中的缺陷,而BP模型通过GA算法优化后,3种工艺参数的RMSE分别降低至0.1018、0.059和0.0232(图5),验证了GA算法在小样本条件下对于复杂工艺关系下对预测模型优化的能力。

GA-BP模型中所选取的训练集数据与测试集数据与BP神经网络模型所选取的相同。图7所示的适应度迭代曲线揭示了遗传算法在参数空间搜索中的动态特性。当以BP神经网络权值阈值作为适应度函数时,算法的全局搜索能力通过交叉变异操作逐步逼近最优解。当种群多样性降低时,GA算法通过变异因子重新引入新特征,最终在第173代收敛至全局最优适应度0.593,较



图 4 成形质量与工艺参数的 Pearson 相关系数

Fig.4 Pearson correlation coefficients between forming quality and process parameters: (a) S-Straight; (b) D-Straight; (c) porosity

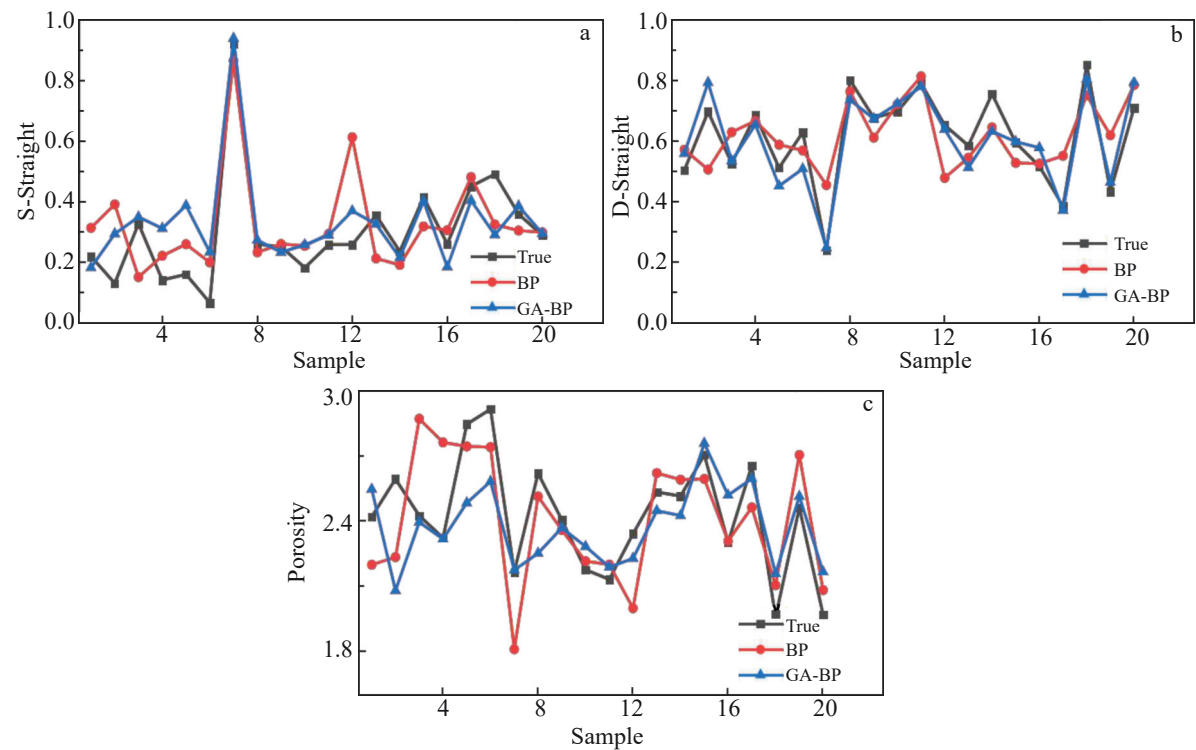


图 5 BP 与 GA-BP 神经网络训练集输出值与样本值对比

Fig.5 Comparison between output values and sample values of three forming quality parameters from BP and GA-BP neural network training sets: (a) S-Straight; (b) D-Straight; (c) porosity

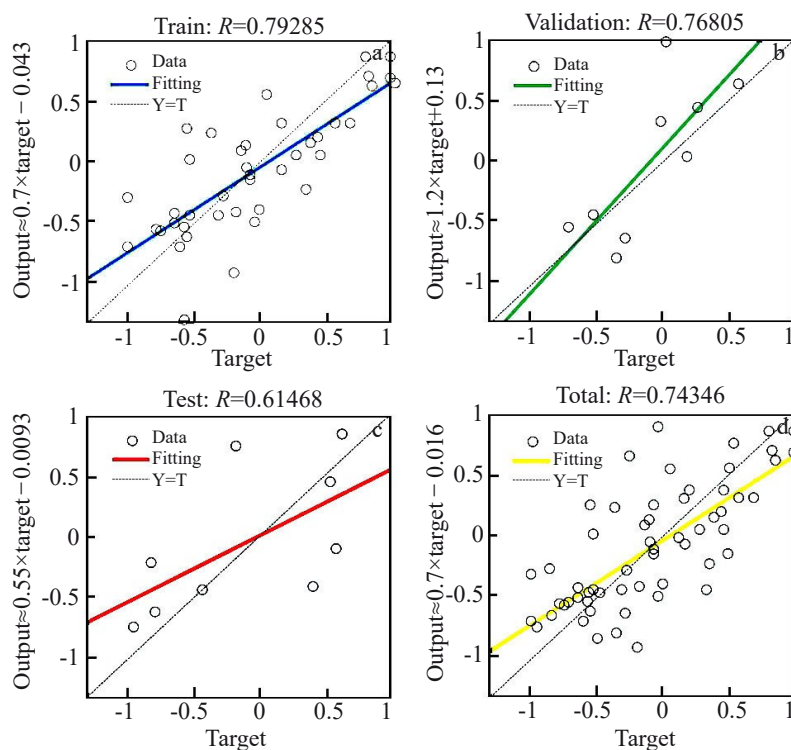


图6 BP神经网络模型训练、验证、测试及总体数据集预测值与目标值的回归拟合图

Fig.6 Regression fitting plots of predicted versus target values of BP neural network model: (a) training, (b) validation, (c) test, and (d) total datasets




图7 遗传算法迭代过程中最佳适应度变化示意图

Fig.7 Schematic diagram of the change in best fitness during GA iteration process

初始值降低约4.7%。

进一步对比BP模型与GA-BP模型迭代过程(图8), BP模型训练集与测试集分别在8轮和2轮后终止优化, 过早收敛现象揭示了两大问题: 其一, 20组样本的数据规模不足以支撑简单BP神经网络参数的有效学习, 模型在未充分探索解空间时即陷入局部最优; 其二, 训练过程中验证误差未设置早停机制, 导致模型在初始阶段即丧失优化动力。对比显示, GA-BP神经网络在训练集第11

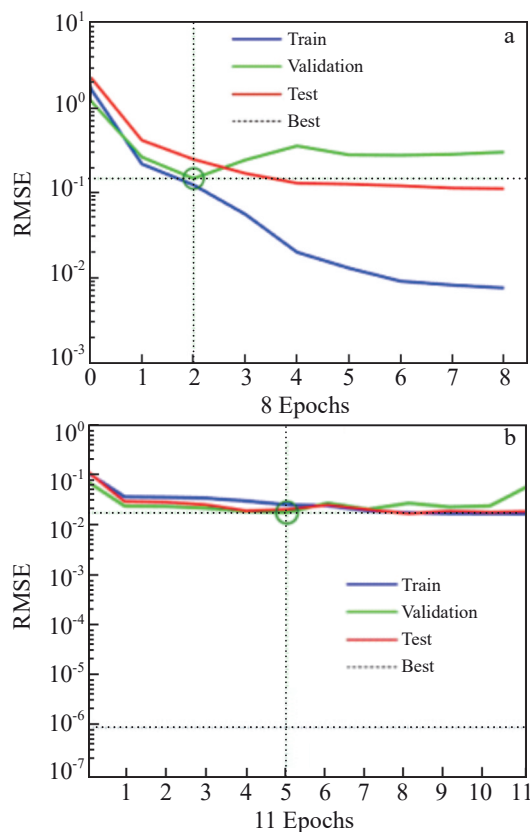


图8 BP神经网络模型和GA-BP神经网络模型的迭代误差示意图

Fig.8 Schematic diagram of model iteration error of BP (a) and GA-BP (b) neural network models

轮完成收敛,而测试集在第5轮即达到最小均方误差,表明遗传算法优化加速了模型收敛过程,其定向搜索机制能有效规避鞍点陷阱。

BP神经网络的“浅层学习”特性直接反映在测试集预测性能的严重劣化,即沿路径壁厚一致性、层间壁厚一致性及孔隙率的测试RMSE分别飙升至0.3256、0.2454和0.4018(图9),较训练误差增长77%~149%,尤其是孔隙率预测误差突破0.4,表明模型对熔池动态行为、气体逸出路径等关键物理机制的映射存在系统性偏差。将7组数据导入GA-BP模型进行测试,验证GA算法对BP模型的预测优化功能,表4展示GA算法优化后模型预测值、未优化模型预测值与样本值的对比与误差。GA-BP模型对沿路径方向壁厚一致性、沉积方向壁厚一致性、孔隙率预测分别如图9a、9b和9c所示,RMSE分别为0.1553、0.2387、0.1229。

综合表5显示各输出变量预测值RMSE对比可以发现,GA-BP模型的工艺参数预测优化中,3种成形质量指标预测准确度均得到优化,沿路径壁厚一致性和孔隙率的预测效果显著提升,其中沿路径壁厚一致性RMSE从0.3256降至0.1553,变化率-52.30%;孔隙率RMSE从0.4018降至0.1229,变化率-69.41%。相比之下,层间壁厚一致性的预测效果提升有限,RMSE从0.2454降至0.2387,变化率-2.73%。

误差指标综合分析(表6)进一步验证了GA算法的优化功能:GA-BP模型在孔隙率和沿路径壁厚一致性预测中的显著改进,反映了该模型对WAAM过程中熔池流

表4 BP及GA-BP模型测试集预测结果
Table 4 Prediction results of test sets of BP and GA-BP models

Group	S-Straight			D-Straight			Porosity		
	True	BP	GA-BP	True	BP	GA-BP	True	BP	GA-BP
1	0.459	0.305	0.344	0.472	0.519	0.389	2.36	2.383	2.425
5	0.303	0.357	0.298	0.748	0.708	0.730	2.887	2.308	2.749
8	0.848	0.390	0.625	1.109	0.606	0.619	2.36	2.616	2.316
10	0.140	0.272	0.320	0.824	0.541	0.848	2.414	2.339	2.399
15	0.828	0.140	0.928	0.631	0.557	0.349	2.581	2.877	2.312
20	0.282	0.299	0.380	0.726	0.660	0.982	2.721	2.358	2.796
22	0.176	0.300	0.408	0.806	0.535	0.723	3.187	2.476	3.138

动特性的精确建模能力。从物理机制来看,孔隙率主要受熔池湍流强度控制,而沿路径壁厚一致性则与熔池流动的铺展能力和稳定性密切相关,这2个指标都与熔池流动特性存在直接关联。相比之下,层间壁厚一致性的预测精度提升有限,这一现象揭示了当前模型在表征热流场耦合效应方面的局限性。具体而言,层间一致性不仅取决于单层熔池的流动行为,更受到逐层沉积过程中热积累效应的显著影响,这种跨时间尺度的热-流耦合过程超出了当前模型对熔池流动特性的单一表征范围。综合而言,GA算法的优化能力主要体现在提升对熔池流动特征的捕捉能力,而对于与热历史密切相关的层间一致性内在机理提取能力不足,限制了该模型在该指标上的预测能力。

尽管层间壁厚一致性预测精度提升效果有限,但




图9 BP与GA-BP神经网络模型测试集预测值和样本值对比
Fig. 9 Comparison between predicted values and sample values of testing sets from BP and GA-BP neural network models: (a) S-Straight; (b) D-Straight; (c) porosity

表5 GA算法优化前后BP模型RMSE误差
Table 5 RMSE errors of BP model before and after GA optimization

Error indicator	RMSE before optimization	RMSE after optimization	Ratio of change/%	Optimization effect
S-Straight	0.3256	0.1553	-52.30	Significant improvement
D-Porosity	0.2454	0.2387	-2.73	Mild improvement
Porosity	0.4018	0.1229	-69.41	Significant improvement

表 6 BP 与 GA-BP 神经网络模型误差指标综合对比

Table 6 Comprehensive comparison of error metrics between BP and GA-BP neural network models

Error metrics	S-Straight		D-Straight		Porosity	
	BP	GA-BP	BP	GA-BP	BP	GA-BP
MAE	0.2325	0.1361	0.1837	0.1821	0.3287	0.0938
RMSE	0.3256	0.1553	0.2454	0.2225	0.4018	0.1231
MSE	0.1060	0.0241	0.0602	0.0495	0.1614	0.0151
MAPE	109.71%	31.49%	32.05%	31.85%	13.33%	3.74%
R^2	-0.4252	0.6757	-1.0205	-0.5127	-3.5298	0.8183

GA-BP 模型综合性能优于原始 BP 模型,这证明了 GA 遗传算法对 BP 神经网络模型的优化效果。

4.3 NSGA-II 成形质量多目标优化与验证结果

如图 10 所示,利用 NSGA-II 算法经过 200 代遗传迭代寻优后获得的 50 组成形质量 Pareto 最优解集(表 7),Pareto 前沿的分布特征表明,其近似平面的散点分布形态反映了各质量指标间存在显著的协同竞争机制。

根据实际应用需求,提出 4 类差异化优化策略:

(1)孔隙率主导型(图 10 黄球):需维持高能场条件(扫描速率 ≥ 285 mm/min,送丝速率 ≥ 5.9 m/min,电流 ≥ 187 A),通过增强熔池湍流效应促进气体逸出,孔隙率可降低至 2% 以下。

(2)层间一致性主导型(图 10 青球):宜采用中高扫速(270~300 mm/min)配合较低电流(150~160 A),通过减小热输入可有效避免热积累引起的塌陷,层间壁厚标准差可以控制在 0.5 以下。

(3)沿路径一致性主导型(图 10 蓝球):需降低送丝速率至 4.9~5.3 m/min 以稳定熔池铺展,配合较高的热输入($I/TS>0.63$)形成准稳态热循环,路径壁厚标准差可以减少至 0.13。

(4)多目标均衡型(图 10 红球):需要在较高送丝速率和中等扫速与中等电流相互搭配,通过热累积-耗散平衡实现质量指标协同优化。

进一步分析各优化目标制约关系可以分析出:在孔隙率约束域($<2\%$),路径与层间壁厚一致性呈现显著负相关,其物理本质在于低热输入导致首层熔池不连续,形成离散焊珠结构,虽有利于层间一致性,但路径方向材料堆叠均匀性下降;在层间一致性约束域(<0.5),孔隙率与路径壁厚一致性存在极为复杂的作用关系,存在一定工艺窗口可以在保证层间壁厚一致性的同时,使孔隙率和路径壁厚一致性均优;在沿路径一致性约束域(<0.13),层间一致性与孔隙率的负向相关源于高热输入促进熔池产生湍流效应促使气体溢出,而高热积累促使后续沉积层熔融塌陷降低层间一致性。

为验证模型的多目标优化能力与精度,从 50 组工艺参数组合中选取优化策略为多目标均衡型,且保证沿路径壁厚一致性优于 0.4,层间壁厚一致性优于 0.6 和孔隙率优于 2.5%,3 种优化策略尽可能均衡,得到 1 组工艺参数组合($I=179$ A, $TS=300$ mm/min, $WFS=5$ m/min)。在其余工艺条件保持不变的情况下,利用所求得优化后的工艺参数组合制取验证试样,图 11 为验证试样宏观外形与二值化金相,优化参数下可以保证薄壁墙兼具良好的沿路径壁厚一致性、层间壁厚一致性和孔隙率,模型具有较好的参数优化能力。

此外,表 8 展示了验证试样的实验样本值与模型预测值的对比结果,预测值与实际测量值基本一致,其中沿路径壁厚一致性(S-Straight, y_1)和层间壁厚一致性(D-Straight, y_2)的误差分别为 4.61% 和 15.77%,孔隙率(y_3)误差为 6.23%,平均误差约为 8.89%。该结果表明,所建模型在多目标优化中不仅能够平衡各项指标,同时具备较高的预测精度和可靠性,为工艺参数优化提供了有力的支持。

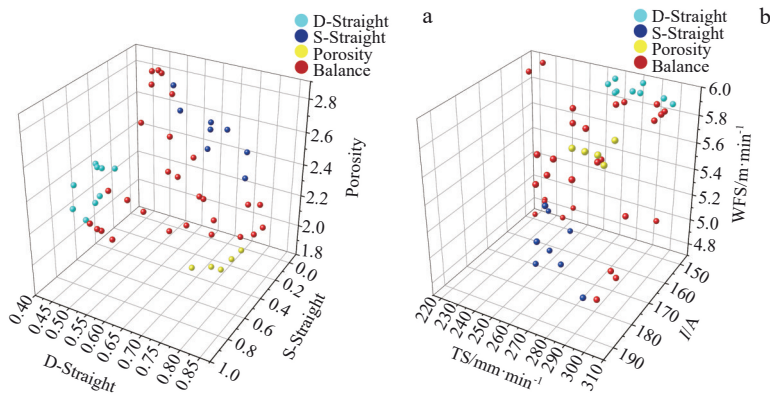


图 10 NSGA-II 多目标寻优所得成形质量 Pareto 最优解集及 GA-BP 模型预测对应工艺参数组合

Fig.10 Pareto optimal solution sets of forming quality obtained by NSGA-II multi-objective optimization (a) and corresponding process parameter combinations predicted by GA-BP model (b)

表 7 成形质量 Pareto 解集及其对应工艺参数组合

Table 7 Pareto solution sets of forming quality and corresponding process parameter combinations

Sample	I/A	TS/ mm·min ⁻¹	WFS/ m·min ⁻¹	S- Straight	D- Straight	Porosity/%
1	150	300	5.9	0.8351	0.4751	2.322
2	150	284	6.0	0.7263	0.446	2.394
3	150	270	5.9	0.5806	0.4709	2.451
4	150	246	4.9	0.2062	0.5259	2.823
5	150	228	4.9	0.1427	0.5288	2.885
6	151	270	6.0	0.5569	0.4594	2.454
7	151	270	5.9	0.5676	0.4802	2.444
8	151	229	4.9	0.137	0.5363	2.87
9	151	229	6.0	0.2547	0.5077	2.602
10	153	225	4.8	0.14	0.51	2.87
11	155	300	5.9	0.8015	0.5107	2.239
12	155	279	5.9	0.6248	0.5133	2.353
13	155	270	6.0	0.5073	0.4998	2.426
14	155	236	4.9	0.1146	0.5634	2.803
15	156	300	5.1	0.651	0.5734	2.35
16	156	300	6.0	0.7921	0.4969	2.246
17	156	288	6.0	0.7028	0.4981	2.307
18	156	284	6.0	0.6623	0.4997	2.33
19	156	246	4.9	0.1312	0.5641	2.757
20	157	300	5.9	0.786	0.5258	2.207
21	158	229	6.0	0.2791	0.5944	2.576
22	160	300	6.0	0.7604	0.53	2.185
23	161	300	5.9	0.7508	0.5569	2.144
24	161	256	4.9	0.1276	0.5858	2.667
25	165	284	6.0	0.5467	0.5886	2.233
26	172	284	5.7	0.4166	0.6746	2.137
27	172	269	5.9	0.3095	0.6952	2.265
28	172	269	6.0	0.3183	0.6859	2.279
29	172	256	4.9	0.0327	0.6492	2.591
30	175	300	5.4	0.4755	0.6419	2.108
31	176	267	4.9	0.041	0.6501	2.55
32	179	300	5.0	0.3143	0.5983	2.377
33	179	256	4.9	0.0092	0.6893	2.558
34	180	290	5.8	0.312	0.725	2.15
35	180	284	6.0	0.3467	0.7279	2.078
36	182	300	5.1	0.2856	0.6181	2.343
37	182	300	6.0	0.4864	0.7073	1.923
38	185	270	5.7	0.1642	0.7847	2.216
39	186	270	5.5	0.0895	0.7588	2.33
40	187	300	5.9	0.4025	0.7413	1.906
41	189	300	5.0	0.1817	0.6367	2.428
42	190	300	6.0	0.3739	0.7616	1.886
43	190	294	5.0	0.1077	0.6582	2.462
44	190	294	6.0	0.3165	0.7775	1.935
45	190	288	5.8	0.2312	0.7815	2.038
46	190	288	6.0	0.2723	0.7935	1.981
47	190	279	5.9	0.2119	0.813	2.067
48	190	271	5.9	0.1991	0.833	2.12
49	190	270	5.3	0.0141	0.746	2.452
50	190	270	5.7	0.1357	0.8109	2.218




图 11 验证试样的宏观外形和二值化金相图

Fig.11 Macro-appearance (a) and binarized metallographic image (b) of validation sample

4. 4 模型误差分析与改进

基于误差溯源分析,本研究构建的NSGA-II算法结合GA-BP神经网络的混合模型主要误差来源包括测量系统误差、数据驱动模型局限性以及工艺过程扰动因素。在测量系统方面,成形质量多维度测量存在系统性误差,其中沿路径和层间的几何一致性评价指标尤为显著。传统接触式测量方法在精确度和全面性方面存在不足,建议后续研究引入激光三维轮廓扫描技术,以实现成形件表面形貌的精确量化表征。对于孔隙率测量,当前基于金相截面孔洞面积的方法具有局部偶然性,可采用阿基米德排水法结合X射线扫描技术,实现试样体积内孔隙分布的三维定量评估。

在数据驱动建模方面,本研究受限于27组单壁墙实验样本的小样本约束,虽然已经采用5折交叉验证,仍存在欠拟合风险与过拟合倾向。为提升模型在有限数据条件下的泛化能力。未来,可在GA-BP神经网络架构中引入物理信息神经网络(PINN)框架,通过嵌入WAAM控制方程,构建具有物理约束的损失函数,同时引入长短期记忆网络(LSTM)捕捉热历史的时序依赖性信息,从而构建多尺度耦合的智能预测模型。同时,结合数据增强方法增加可信样本数目、采用贝叶斯优化框架进行超参数自适应调整,并引入迁移学习策略利用相关工艺数据库进行预训练,进一步强化模型的物理可解释性、预测准确性与泛化能力。

在工艺层面上,电弧增材制造设备存在较多人为因素和设备因素对试验结果扰动,如喷头距离、沉积区域温度、电流稳定性和送丝均匀性等,使得获取的样本数据存在一定的偏差。为提高电弧增材制造的工艺稳定性,需提升设备自动化程度。通过高精度传感器实时监测喷头距离、熔池温度等关键参数,结合智能控制算法将机器学习算法与设备集成,实现动态调整工艺参数,利用数字化平台实现实时监控与智能决策,减少人为误差,确保成形质量一致性。

表 8 验证试样在各成形质量指标上的实际值与预测值对比及其误差

Table 8 Comparison between actual values and predicted values of forming quality indexes of validation samples and corresponding errors

Sample	S-Straight, y_1	D-Straight, y_2	Porosity, $y_3/\%$	y_1 error/%	y_2 error/%	y_3 error/%	Average error/%
Predicted value	0.2712	0.5911	1.959				
Actual value	0.2843	0.5105	2.089	4.61	15.77%	6.23	8.89

5 结 论

1) Pearson 相关系数表明, 电流(I)与沿路径壁厚一致性(S-Straight)呈负相关, 即增大 I 可抑制扫描方向尺寸波动; 扫描速率(TS)与层间壁厚一致性(D-Straight)负相关, 即提高TS改善高度方向均匀性; 孔隙率受电流与送丝速率(WFS)协同调控, I 增大降低孔隙率, WFS增加则加剧缺陷。

2) 相较于传统BP模型, GA-BP模型显著提升了沿路径壁厚一致性(RMSE从0.3256降至0.1553, 降幅52.30%)和孔隙率(RMSE从0.4018降至0.1229, 降幅69.41%)的预测精度, 但层间壁厚一致性预测改善有限(RMSE仅降2.73%), 归因于GA算法增强了对熔池流动特性的捕捉能力, 而对热累积效应与层间热历史的动态耦合关系表征不足。

3) 通过NSGA-II算法结合GA-BP神经网络的混合模型对WAAM成形工艺参数进行多目标寻优得到50组Pareto最优解集, 提出4类优化策略: 孔隙率主导型、层间一致性主导型、路径一致性主导型及多目标均衡型。以均衡型策略验证模型精度, 结果表明, 工艺参数组合($I=179$ A, $TS=300$ mm/min, $WFS=5$ m/min)能够满足均衡型指标(S-Straight <0.4 , D-Straight <0.6 , Porosity $<2.5\%$), 预测值与实际值的平均误差为8.89%, 验证了混合模型在多目标优化中的有效性与准确性。

参考文献 References

[1] Omiyale B O, Olugbade T O, Abioye T E *et al. Materials Science and Technology*[J], 2022, 38(7): 391
[2] Chakraborty D, Tirumala T, Chitral S *et al. Journal of Materials Engineering and Performance*[J], 2022, 31(8): 6149
[3] Taşdemir A, Nohut S. *Ships and Offshore Structures*[J], 2021, 16(7): 797
[4] Guo Xinxin, Zhang Yongheng, Zhang Shuaifeng *et al. Rare Metal Materials and Engineering*[J], 2023, 52(5): 1643
[5] Gürol U, Kocaman E, Dilibal S *et al. CIRP Journal of Manufacturing Science and Technology*[J], 2023, 47: 215

[6] Çam G. *Materials Today: Proceedings*[J], 2022, 62: 77
[7] Li Quan(李 权), Wang Guoqing(王国庆), Luo Zhiwei(罗志伟) *et al. Rare Metal Materials and Engineering*(稀有金属材料与工程)[J], 2020, 49(11): 3969
[8] Dinovitzer M, Chen X H, Laliberte J *et al. Additive Manufacturing*[J], 2019, 26: 138
[9] Jorge V L, Teixeira F R, Wessman S *et al. Metals*[J], 2024, 14(6): 717
[10] Zhao R J, Yang L. *Construction and Building Materials*[J], 2025, 459: 139793
[11] Sarıkaya M, Önler D B, Dağlı S *et al. Journal of Materials Research and Technology*[J], 2024, 33: 5643
[12] Tomar B, Shiva S, Nath T. *Materials Today Communications*[J], 2022, 31: 103739
[13] Wu B T, Pan Z X, Ding D H *et al. Journal of Manufacturing Processes*[J], 2018, 35: 127
[14] Peng Lizhen(彭力真), You Guoqiang(游国强), Wang Lei(王 磊) *et al. Rare Metal Materials and Engineering*(稀有金属材料与工程)[J], 2023, 52(5): 1800
[15] Hamrani A, Agarwal A, Allouhi A *et al. Journal of Intelligent Manufacturing*[J], 2024, 35(6): 2407
[16] He F Y, Yuan L, Mu H C *et al. Robotics and Computer-Integrated Manufacturing*[J], 2023, 82: 102525
[17] Zhao Fengyuan, Ye Yicong, Zhang Zhouan *et al. Rare Metal Materials and Engineering* [J], 2023, 52(4): 1192
[18] Ye Y J, Wang Q T, Chen C R *et al. Journal of Materials Engineering and Performance*[J], 2025, 34: 13476
[19] Oh W J, Lee C M, Kim D H. *Journal of Materials Research and Technology*[J], 2022, 20: 4283
[20] Le V T, Nguyen T-T, Nguyen V C. *Neural Computing and Applications*[J], 2024, 36(35): 22547
[21] Le V T, Nguyen H D, Bui M C *et al. Manufacturing Letters*[J], 2022, 32: 28
[22] Guo Can(郭 灿), Nie Shuai(聂 帅), Zhang Zhongming(张忠明) *et al. Foundry Technology*(铸造技术)[J], 2024, 45(11): 1025
[23] Xiang D D, Wang D, Wang S *et al. Surface and Coatings Technology*[J], 2024, 493: 131186

Machine Learning-Based Forming Quality Prediction and Multi-objective Optimization of Aluminum Alloy Thin-Walled Components in Wire Arc Additive Manufacturing

Peng Yiqi^{1,2}, Gao Yuefang³, Hua Tanzhi³, Zhang Sirui³, Zhao Yufan^{1,2}, Lin Xin^{1,2}

(1. State Key Laboratory of Solidification Processing, Northwestern Polytechnical University, Xi'an 710072, China)

(2. MIIT Key Laboratory of High Performance Additive Manufacturing and Innovative Design of Metal Structure,
Northwestern Polytechnical University, Xi'an 710072, China)

(3. School of Materials Science and Engineering, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: Wire arc additive manufacturing (WAAM) holds significant application value in the aerospace field, but the instability of heat input leads to prominent issues such as poor geometric conformity and numerous internal defects in aluminum alloy thin-walled components. To address the restrictions of traditional methods in multi-physics coupling optimization, this study proposed a data-driven solution by constructing a dataset of process parameters (current, scanning speed and wire feed rate) and forming quality (path/interlayer wall thickness consistency and porosity). A back propagation (BP) neural network model was established and optimized using the genetic algorithm (GA), combined with the non-dominated sorting genetic algorithm II (NSGA-II) for multi-objective optimization. The results show that the optimized GA-BP model significantly improves the prediction accuracy of path wall thickness consistency and porosity, but its optimization effect on interlayer wall thickness consistency prediction is restricted. Four types of optimization strategies are proposed based on the 50 Pareto solution sets obtained through NSGA-II, and validation tests indicate the model prediction error of 8.89%, accurately achieving the collaborative optimization of forming quality indicators.

Key words: wire arc additive manufacturing; machine learning; multi-objective optimization; aluminum alloy; forming quality

Corresponding author: Peng Yiqi, Candidate for Ph. D., State Key Laboratory of Solidification Processing, Northwestern Polytechnical University, Xi'an 710072, P. R. China, E-mail: yiqipeng@mail.nwpu.edu.cn; Zhao Yufan, Ph. D., Professor, State Key Laboratory of Solidification Processing, Northwestern Polytechnical University, Xi'an 710072, P. R. China, E-mail: zhyf90215@nwpu.edu.cn