

DOI: 10.16410/j.issn1000-8365.2025.4203

# 基于机器学习与多目标优化算法的 电弧增材制造过程优化研究

刘少杰<sup>1,2</sup>, 彭逸琦<sup>1,2</sup>, 赵宇凡<sup>1,2</sup>, 杨海欧<sup>1,2</sup>, 林鑫<sup>1,2</sup>

(1. 西北工业大学凝固技术国家重点实验室, 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)

**摘要:** 在电弧增材制造中, 工艺参数之间存在复杂相互作用, 难以寻找最优参数组合以获得最佳的成形质量与预期的几何结构。为了加速工艺参数优化过程, 在 3 因素 3 水平全因素实验的基础上, 明确了电流、送丝速度和扫描速度对熔道熔宽、熔高和稀释率的影响规律, 建立了神经网络、支持向量机和高斯回归分析模型来预测熔宽、熔高和稀释率。对比分析表明, 高斯过程回归模型对熔宽的预测性能最好, 神经网络模型对熔高的预测性能最好, 支持向量回归对稀释率的预测性能最好。基于这 3 种机器学习模型, 采用多目标遗传算法(NSGA-II), 实现了以熔宽和熔高最大、稀释率最小为目标的电弧增材制造多目标优化, 最后对优化结果进行了实验验证。

**关键词:** 电弧增材制造; 机器学习; 多目标优化; 2219 铝合金

中图分类号: TG665

文献标识码: A

文章编号: 1000-8365(2025)01-0029-10

## Parameter Optimization of Wire Arc Additive Manufacturing via Machine Learning and a Multiobjective Optimization Algorithm

LIU Shaojie<sup>1,2</sup>, PENG Yiqi<sup>1,2</sup>, ZHAO Yufan<sup>1,2</sup>, YANG Haiou<sup>1,2</sup>, LIN Xin<sup>1,2</sup>

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

**Abstract:** In wire arc additive manufacturing (WAAM), the intricate interactions among process parameters complicate the task of finding the best settings for manufacturing metal components with superior molding quality and desired geometries. To expedite parameter optimization, this study investigates the effects of the welding current, wire-feed speed (WFS), and travel speed (TS) on the melt width ( $W$ ), melt height ( $H$ ), and dilution ratio ( $D$ ) via 3-factor and 3-level full-factor tests. Artificial neural network (ANN), support vector regression (SVR), and Gaussian process regression (GPR) models are developed to predict these metrics. Comparative analysis indicates that GPR is most effective for predicting the melt width, ANN excels in predicting the melt height, and SVR is superior for assessing the dilution ratio. Multiobjective optimization, which uses the nondominated sorting genetic algorithm-II (NSGA-II), maximizes the melt width and height while minimizing the dilution ratio. The optimized parameters were validated experimentally, confirming the accuracy and effectiveness of the approach.

**Key words:** wire arc additive manufacturing; machine learning; multiobjective optimization; 2219 aluminium alloy

电弧增材制造技术(wire arc additive manufacturing, WAAM)作为金属增材制造的重要分支, 凭借其

高效、低成本的特点, 在大型一体化金属零部件制造领域展现出独特优势<sup>[1-3]</sup>。该技术通过电弧热源将金

收稿日期: 2024-10-17

基金项目: 国家重点研发计划(2023YFB3712000); 广东省重点领域研发计划(2023B0909020002); 凝固技术国家重点实验室自主研究课题(2023-TS-10); 陕西省科技计划(QCYRCXM-2022-225、2023KXJ-232); 西安市科技计划(23GXFW0091)

作者简介: 刘少杰, 2000 年生, 硕士生。研究方向为电弧增材制造。Email: liushaojie@mail.nwpu.edu.cn

通信作者: 赵宇凡, 1990 年生, 博士, 教授。研究方向为金属增材制造。Email: zhyf90215@nwpu.edu.cn

林鑫, 1971 年生, 博士, 教授。研究方向为金属增材制造。Email: xlin@nwpu.edu.cn

引用格式: 刘少杰, 彭逸琦, 赵宇凡, 杨海欧, 林鑫. 基于机器学习与多目标优化算法的电弧增材制造过程优化研究[J]. 铸造技术, 2025, 46(1): 29-38.

LIU S J, PENG Y Q, ZHAO Y F, YANG H O, LIN X. Parameter optimization of wire arc additive manufacturing via machine learning and a multiobjective optimization algorithm[J]. Foundry Technology, 2025, 46(1): 29-38.

属丝材逐层熔化堆积,形成所需几何构形的零件。电弧增材制造中产生的较大且不稳定热输入严重制约了零件尺寸精度的可控性及整体制造质量。其中,零件尺寸精度依赖于对熔道几何形貌的精确控制,而熔道几何形貌受多种工艺参数及条件影响,包括电压、送丝速度、扫描速度和层间冷却策略等<sup>[4-5]</sup>。各种工艺参数间复杂相互作用进一步增加工艺快速优化难度,进而影响成形过程稳定性与精确性。

由于电弧增材制造工艺涉及众多参数,并且这些参数与成形质量间存在高度复杂的非线性关系,传统的试错、经验、物理建模方法在实现形性预测和控制方面面临高昂的人力和时间成本<sup>[7]</sup>。同时,由于对电弧增材制造动态物理机制的认知局限性,使得现有仿真模型难以全面捕捉多物理场的复合作用与机制<sup>[8]</sup>。近年来,机器学习技术因其直接从数据中学习规律而无需关注输入输出间内在关联机制的能力,在电弧增材制造领域崭露头角<sup>[9]</sup>。通过收集和金属零部件打印过程中的大量数据,机器学习可以缩短实验周期、减少计算成本,并有效预测和优化工艺参数<sup>[10-11]</sup>。例如,Muralimohan<sup>[12]</sup>利用机器学习模型实现了电弧增材制造过程中的原位缺陷监测;Xia等<sup>[13]</sup>开发了多种机器学习模型以预测表面粗糙度;Xiao等<sup>[14]</sup>利用机器学习实现了电弧增材制造几何形貌的预测。有研究基础表明,基于机器学习的电弧增材制造单变量预测与优化趋于成熟,然而在电弧增材制造中,不同的优化目标之间往往存在矛盾与制约关系,使得难以同时获得所有优化目标的最优解,传统的单目标优化方法已难以满足日益复杂的工业应用需求<sup>[15]</sup>。

非支配排序遗传算法 II (non-dominated sorting genetic algorithm II, NSGA-II)是 Deb 等<sup>[16]</sup>开发的一种多目标优化算法,已广泛应用于多目标优化问题。NSGA-II 算法的优势在于可以平衡不同优化目标之间的矛盾与制约,使其获得优化目标的折中解。NSGA-II 算法结合数学模型有很好的效果。例如,Yang 等<sup>[17]</sup>以热丝激光焊为研究对象,结合 Kriging 插值法和 NSGA-II 算法对焊接速度、激光功率和电流等工艺参数进行了优化,以达到最大化深宽比、最小化余高和抗拉强度最大的目标;Zhang 等<sup>[18]</sup>则结合响应面法和 NSGA-II 算法对电弧增材制造

中的扫描速度和送丝速度等工艺参数进行了优化,以获得低表面粗糙度和低孔隙率的 2024 铝合金试样。因此,通过结合高性能的机器学习模型和多目标优化算法,可为电弧增材制造不同性能指标合理分配优化权重,并依据这些权重精准定位满足特定研究需求的最优工艺参数集组合。然而,在电弧增材制造领域,这一结合方式仍处于初步探索阶段,相关研究尚不充分,故而此方向的深入探索不仅具有重要的学术价值,也显得尤为迫切。

基于此,本研究采用机器学习和多目标优化算法相结合的方法,旨在预测电弧增材制造中的最优工艺参数组合。通过设计 3 因素 3 水平全因素实验,以电流(welding current,  $I$ )、送丝速度(wire-feed speed, WFS)和扫描速度(travel speed, TS)作为输入变量,熔道的熔宽(melt width,  $W$ )、熔高(melt height,  $H$ )和稀释率(dilution ratio,  $D$ )作为输出变量,基于机器学习建立回归模型,并利用 NSGA-II 算法结合机器学习模型,将工艺参数作为决策变量,寻求以熔宽和熔高最大、稀释率最小为目标的最佳工艺参数组合。最后,采用模型预测的最优工艺参数组合进行实验验证。

## 1 实验材料与方法

### 1.1 材料

实验采用直径为 1.2 mm 的商用 ER 2219 铝合金丝材,所选基板为 2024 铝合金基板(150 mm×100 mm×10 mm)。丝材与基板的化学成分如表 1 所示。在实验开始之前,用砂纸打磨基板表面并用酒精清洗。

### 1.2 实验方案

图 1 为实验采用的电弧增材制造系统。该电弧增材制造系统由四轴联动数控机床(LPM-408)、送丝机(Tetrix drive 4L)、交直流氩弧焊机(Tetrix521Synergic AC/DC)等部件组成。沉积过程中采用高纯氩气作为保护气体,以保证电弧增材制造过程的低氧惰性环境。

经过预实验后选取电流、送丝速度和扫描速度 3 种对成形效果影响最显著的工艺参数进行研究,每个参数选取 3 个,进行 3 因素 3 水平全因素实验。

表 2 为所选工艺参数,其中电流范围为 170~210 A,送丝速度范围为 4~6 m/min,扫描速度为 200~300 mm/min,保护气体流量为 18 L/min,基板

表 1 基板和焊丝化学成分  
Tab.1 Chemical composition of the substrate and welding wire

	(mass fraction/%)								
Alloys	Cu	Mg	Si	Mn	Fe	Zr	Ti	Zn	Al
Substrate	4.52	1.630	0.500	0.35	0.500	<0.01	0.15	0.25	Bal.
Wire	5.97	0.052	0.028	0.31	0.116	0.20	0.12	<0.01	Bal.

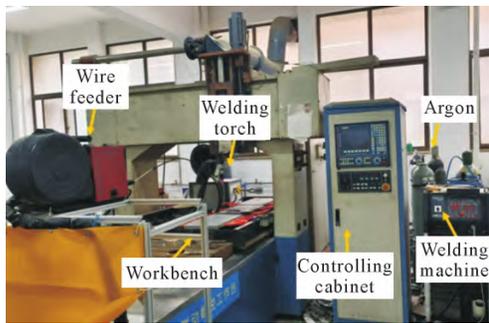


图1 电弧增材制造系统

Fig.1 Wire arc additive manufacturing system

表2 参数选择和设置

Tab.2 Parameter selection and setting

Process parameters	Value
Welding current, /A	170, 190, 210
Wire-feed speed, WFS/(m·min <sup>-1</sup> )	4, 5, 6
Travel speed, TS/(mm·min <sup>-1</sup> )	200, 250, 300
Substrate temperature, T/°C	200
Argon flow, Q/(L·min <sup>-1</sup> )	18

预热温度为 200 °C。根据表 2 给出的电流、送丝速度和扫描速度 3 个工艺参数,可以得到 27 个参数组合作为机器学习训练的训练集,除此之外,还在全因素实验之外随机选取 5 个参数组合作为机器学习模型的测试集。根据每个参数组合来进行单道沉积。

图 2a 给出了用于电弧增材制造单道成形的扫描方案。将沉积后的试样沿纵截面进行切割,用砂纸和 SiO<sub>2</sub> 抛光液对试样表面进行磨抛。在酒精清洗后浸入凯勒试剂中腐蚀 8 s,后利用光学显微镜观察并记录金相形貌。典型的熔道形貌如图 2b 所示。稀释率  $D$  通过下式计算获得:

$$D = \frac{P}{P+H} \times 100\% \quad (1)$$

式中, $W$  为熔宽, $H$  为熔高, $P$  为熔深。

### 1.3 机器学习模型构建及评价标准

本研究选择了神经网络(artificial neural network,

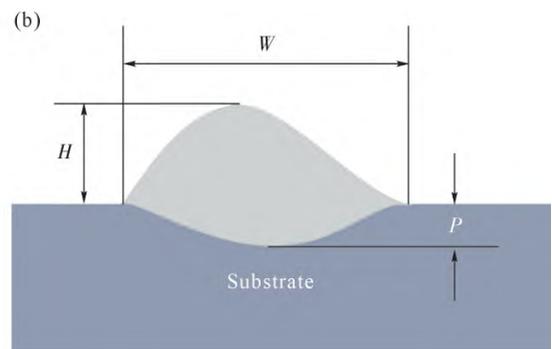
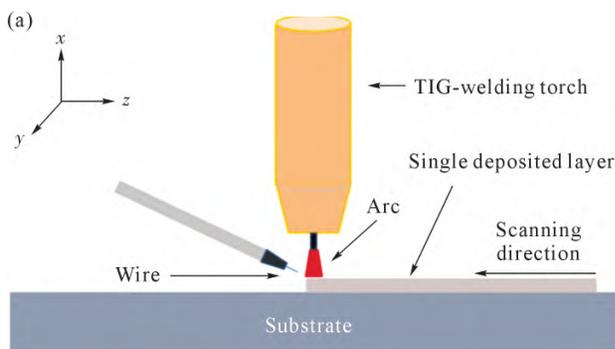


图2 电弧增材制造单道成形示意图与单道成形熔道形貌:(a) WAAM 单道成形示意图;(b) 单道成形熔道形貌

Fig.2 Schematic diagrams of WAAM single-pass deposition and melt pool characterization: (a) schematic diagram of single-pass deposition in WAAM; (b) dimensions of the melt pool for a single melt channel

ANN)<sup>[19]</sup>、支持向量机(support vector regression, SVR)<sup>[20]</sup>和高斯过程回归(Gaussian process regression, GPR)<sup>[21]</sup> 3 种常见的可实现回归分析的机器学习模型来预测熔宽、熔高和稀释率。

在模型训练前,需要对数据归一化处理<sup>[22]</sup>,将数据缩放到[0,1]范围内,具体处理方式如式(2)。降低模型对输入数据中噪声的敏感性,将输入数据调整到相似的范围,加速模型收敛过程,减小梯度问题,提高模型泛化能力。输出时,通过式(3)对数据进行反归一化处理,使其恢复到原始的数据范围内。具体的操作由 mapminmax 函数实现。

归一化操作:

$$Y = \frac{(b-a) \cdot (X - X_{\min})}{X_{\max} - X_{\min}} + a \quad (2)$$

反归一化操作:

$$Y = \frac{(Y-a) \cdot (X_{\max} - X_{\min})}{b-a} + X_{\min} \quad (3)$$

式中, $X$  为原始数据; $Y$  为归一化后的数据; $X_{\min}$  和  $X_{\max}$  分别为最小值和最大值; $a$  和  $b$  分别为目标范围的最小值和最大值。

为了评估上述 3 种机器学习模型的预测准确度,本文选择了评价回归模型准确性的 3 个指标<sup>[23]</sup>,如下所述:

(1)均方根误差(root mean squared error, RMSE),用来衡量预测值与实际值之间差异的统计量,越接近 0 表示模型回归效果越好。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

(2)平均绝对误差(mean absolute error, MAE),用来提供绝对误差损失预期值,越接近 0 表示模型回归效果越好。

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (5)$$

(3)决定系数(determination coefficient,  $R^2$ ),用于

评估回归模型对观测数据的拟合程度，其取值范围从 0 到 1，表示因变量变化的百分比可以由自变量解释的比例，数值越接近 1 表示模型拟合得越好。

$$R^2=1-\frac{\sum_{i=1}^n (y_i-\hat{y}_i)^2}{\sum_{i=1}^n (y_i-\bar{y})^2} \quad (6)$$

### 1.4 多目标优化算法

NSGA-II 是一种用于多目标优化的遗传算法<sup>[6]</sup>。在 NSGA-II 中，首先随机生成初始种群，然后根据非支配排序原则对种群中的每个个体进行排序，计算每个个体的拥挤距离，用于评估个体在种群中的分布密度，以维持种群的多样性。通过选择、交叉和变异产生新的后代种群。父代种群和子代种群合并形成一个更大的种群，然后对其进行排序。从合并后的种群中选出最优的  $N$  个个体以组成新的种群。这个过程不断重复，直到达到最大代数，最终确定最优解。NSGA-II 算法的流程如图 3 所示。

## 2 实验结果及讨论

### 2.1 实验结果分析

基于全因素实验结果，对 3 个工艺参数和 3 个熔道形态指标值进行相关性分析。相关性分析对于明确各个工艺参数对熔道形态指标的影响至关重要，为后续的机器学习建模提供重要的输入信息，从而提高预测精度。研究采用 Pearson 相关系数来衡量 3 个工艺参数与熔道形态特征的相关性分

析。Pearson 相关系数可以精确地衡量两种变量之间的线性相关性<sup>[24]</sup>。Pearson 相关系数由下式计算获得：

$$\rho_{X,Y}=\frac{\text{cov}(X,Y)}{\sigma_X\sigma_Y} \quad (7)$$

式中， $\text{cov}(X, Y)$ 为两种变量的协方差； $\sigma_X$  和  $\sigma_Y$  分别为 2 个变量的标准差。Pearson 相关系数的取值范围在 -1~1 之间。当 Pearson 相关系数为 1 时，表示 2 个变量完全正相关；当 Pearson 相关系数为 -1 时，表示 2 个变量完全负相关；当相关系数接近于 0 时，表示 2 个变量之间几乎没有线性关系。

图 4 是电流、送丝速度和扫描速度与熔宽、熔高和稀释率之间的 Pearson 相关系数矩阵示意图。从图 4a 可以看出，熔宽与电流呈正相关，相关系数为 0.74。即随电流的增大，热输入增大，增加了熔池流动性，导致熔宽增大。熔宽与送丝速度的相关系数为 -0.02，表明两者并不是简单线性关系。熔宽与扫描速度呈负相关，相关系数为 -0.54。即随扫描速度的增大，单位长度的沉积量减小，导致熔宽减小。从图 4b 可以看出，熔高与送丝速度呈正相关，相关系数为 0.58。即随送丝速度的增大，单位长度的沉积量增大，导致熔高增大。熔高与电流呈负相关，相关系数为 -0.72。这是因为在其他因素不变时，随着电流的增大熔宽增大，若沉积质量不变则熔高相应降低。熔高与扫描速度呈负相关，即随着扫描速度的增大，单位长度的沉积质量减小，导致熔高减小。从图 4c 可

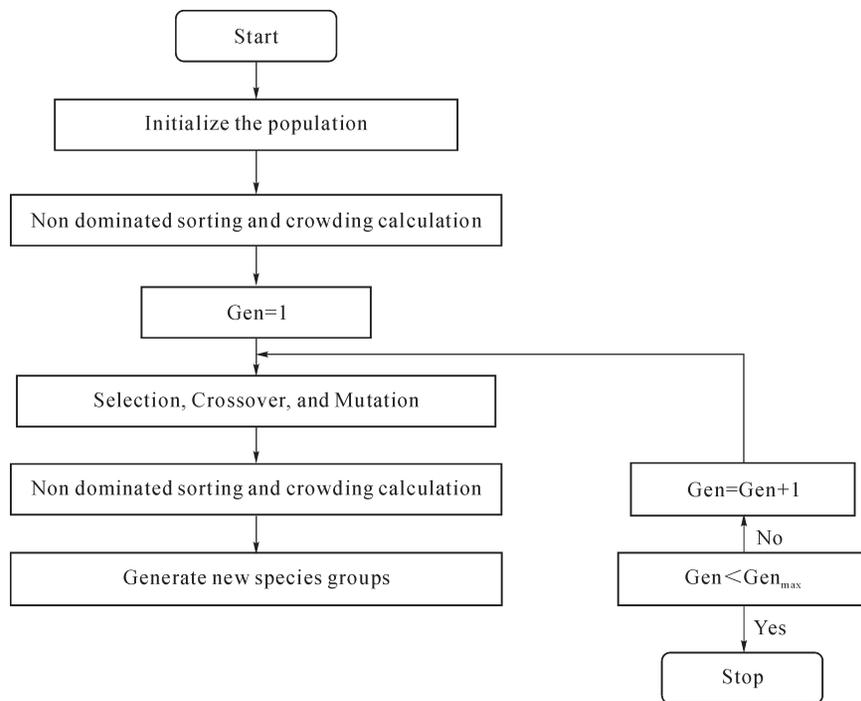


图 3 NSGA-II 算法流程图  
Fig.3 NSGA-II algorithm flowchart

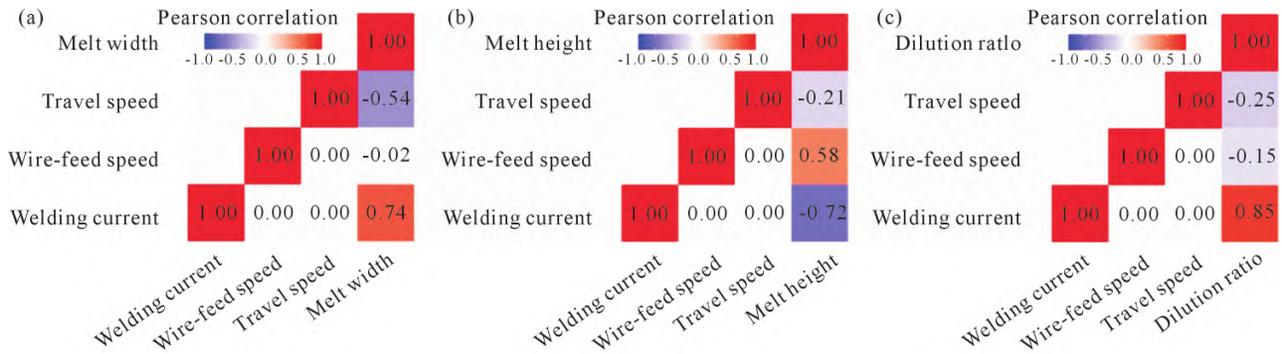


图4 工艺参数与成形指标之间的 Pearson 相关系数矩阵示意图:(a) 熔宽;(b) 熔高;(c) 稀释率

Fig.4 The Pearson correlation coefficient matrix between process parameters and forming indicators: (a) melt width; (b) melt height; (c) dilution ratio

以看出,稀释率与电流呈正相关,相关系数为 0.85,随着电流的增大,热输入增大,加速了丝材与基板的熔化,熔高减小,熔深增大,导致稀释率的增大。稀释率与送丝速度呈负相关,随着送丝速度的增大,熔高增大,熔深减小,导致稀释率的减小。稀释率与扫描速度呈负相关,随着扫描速度的增大,一方面单位长度沉积量降低,熔高减小,一方面热输入减小,熔深减小,综合表现出稀释率减小的趋势。根据以上 Pearson 相关系数的分析结果,可以看出电流、送丝速度和扫描速度这 3 个工艺参数对熔宽、熔高和稀释率具有显著影响,表明它们在电弧增材制造过程中起着重要作用。这些参数的变化能够有效影响熔道的各项特征,因此可以作为机器学习模型的输入变量,用于训练模型并预测目标变量。

2.2 机器学习预测

图 5a 和 b 分别展示了样本值与 GPR 模型、SVR 模型和 ANN 模型在训练集和测试集的预测效果对比。从图 5a 中可以看出,3 种机器学习模型对熔宽的拟合效果总体较好,但个别样本的拟合效果较差,例如样本 1 和 14。这种情况可能与算法的性能或样本存在噪声有关。从图 5b 可以看出 3 种机器学习模型在测试集的表现也较为良好,与样本值的偏差较小。为了选择最佳的熔宽预测模型,对 3 种机器学习模型进行评估,相应的 3 种性能指标如表 3。

在训练集上,3 种机器学习模型的性能指标较为接近,其中 GPR 模型的 RMSE 和 MAE 最小, $R^2$  最大。在测试集中,虽然 ANN 模型的  $R^2$  略高于 GPR 模型,但 RMSE 和 MAE 均大于 GPR 模型和 SVR 模型。考虑到模型的泛化能力,即预测新数据的能力,所以评估机器学习模型时需要兼顾其在训练集和测试集上的性能,进而选择 GPR 模型作为熔宽的预测模型。

表 3 3 种机器学习算法对熔宽的性能指标对比  
Tab.3 Comparison of performance indicators of melt width via three machine learning algorithms

Model	Train set			Test set		
	RMSE	MAE	$R^2$	RMSE	MAE	$R^2$
GPR	0.392	0.260	0.928	0.326	0.291	0.956
SVR	0.431	0.289	0.914	0.369	0.320	0.944
ANN	0.423	0.301	0.915	0.385	0.338	0.961

图 6a 和 b 分别展示了样本值与 GPR 模型、SVR 模型和 ANN 模型在训练集和测试集的预测效果对比。从图 6a 中可以看出,ANN 模型和 SVR 模型对熔高的拟合效果总体较好,而 GPR 模型的拟合效果较差。从图 6b 中可以明显看出 GPR 模型拟合出的点与测试集样本点的偏差很大,说明 GPR 模型对新数据的泛化能力差。为选择最佳的熔高预测模型,对 3 种机器学习模型进行评估,相应的 3 种性能指标如表 4 所示。GPR 模型在测试集和训练集的 RMSE 和 MAE 均为最大, $R^2$  最小,说明该模型的可

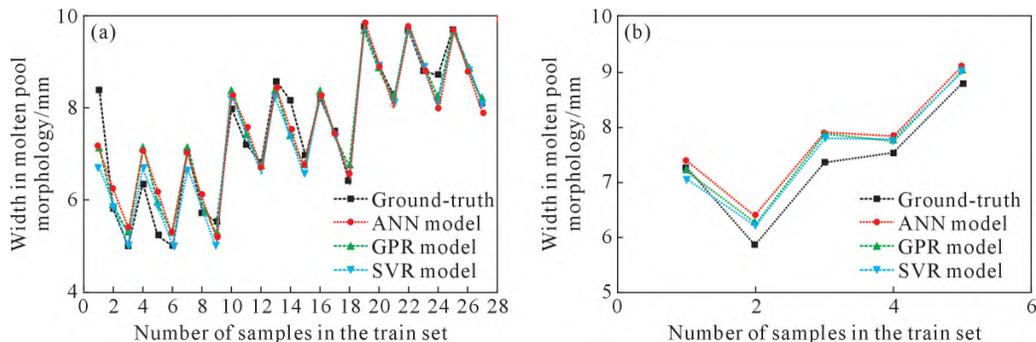


图 5 不同机器学习模型对熔宽的预测效果对比:(a) 训练集;(b) 测试集

Fig.5 Comparison of the prediction performance of different machine learning models for melt width: (a) train set; (b) test set

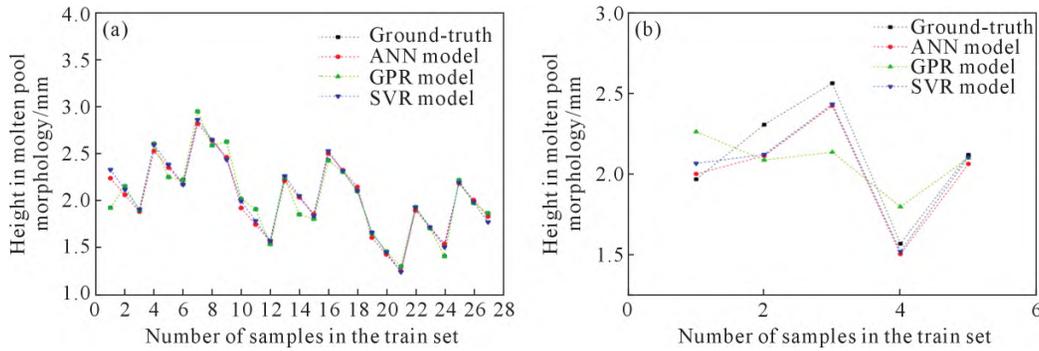


图 6 不同机器学习模型对熔高的预测效果对比:(a) 训练集;(b) 测试集

Fig.6 Comparison of the prediction performance of different machine learning models for melt height: (a) train set; (b) test set

信赖程度较低。在训练集中,SVR 模型的 RMSE 和 MAE 均小于 ANN 模型,且  $R^2$  大于 ANN 模型,表现出最好的预测效果。但在测试集中 ANN 模型表现出最大的  $R^2$ ,且 RMSE 和 MAE 与 SVR 模型差距不大。考虑到模型的泛化能力,进而选择 ANN 模型作为熔高的预测模型。

表 4 3 种机器学习算法对熔高的性能指标对比

Tab.4 Comparison of performance indicators of three machine learning algorithms for melt height

Model	Train set			Test set		
	RMSE	MAE	$R^2$	RMSE	MAE	$R^2$
GPR	0.259	0.222	0.580	0.272	0.238	0.364
SVR	0.109	0.068	0.925	0.117	0.100	0.920
ANN	0.112	0.080	0.921	0.118	0.101	0.943

图 7a 和 b 分别展示了是样本值、GPR 模型、SVR 模型和 ANN 模型在训练集和测试集的预测效果对比。从图 7a 中可以看出,3 种机器学习模型对稀释率的拟合效果总体较好,但个别样本的拟合效果较差,例如样本 1、5、6 和 14,这种情况可能与算法的性能或样本存在噪声有关。从图 7b 中可以看出 3 种机器学习模型在测试集的表现较为良好,与样本值的偏差较小。为了选择最佳的稀释率预测模型,对 3 种机器学习模型进行评估,相应的 3 种性能指标如表 5 所示。在训练集上,3 种机器学习模型的性能指标较为接近。在测试集中,SVR 模型的  $R^2$  最

大,虽然 SVR 模型的 RMSE 和 MAE 高于 ANN 模型但相差不大。同样考虑到模型的泛化能力,进而选择 SVR 模型作为稀释率的预测模型。

表 5 3 种机器学习算法对稀释率的性能指标对比

Tab.5 Comparison of the performance indicators of the dilution rates of the three machine learning algorithms

Model	Train set			Test set		
	RMSE	MAE	$R^2$	RMSE	MAE	$R^2$
GPR	0.051	0.043	0.852	0.030	0.028	0.805
SVR	0.054	0.042	0.845	0.032	0.030	0.867
ANN	0.051	0.042	0.848	0.029	0.023	0.822

综上所述,鉴于不同机器学习模型在处理数据集时的表现差异,本研究采用 GPR 模型进行熔宽预测,ANN 模型进行熔高预测,SVR 模型进行稀释率预测。

### 2.3 多目标优化与验证

实现熔宽和熔高最大、稀释率最小的电弧增材制造工艺优化是一个典型的多目标优化任务。将前文构造的机器学习预测模型作为 NSGA- II 的适应度函数,通过参数寻优找出这 3 个优化目标之间的非劣解。由于本文通过采用最小值求解法来优化工艺参数,需要对熔宽和熔高的目标模型取相反值进而变成求最小值。电弧增材制造工艺参数多目标优化数学模型为:

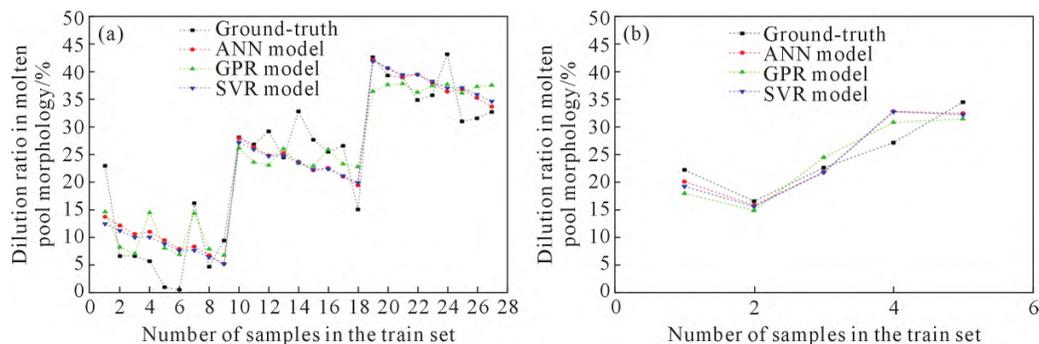


图 7 不同机器学习模型对稀释率的预测效果对比:(a) 训练集;(b) 测试集

Fig.7 Comparison of the prediction performance of different machine learning models on the dilution ratio: (a) train set; (b) test set

$$\begin{cases} \min f(I, WFS, TS) = [-f_1(I, WFS, TS), -f_2(I, WFS, TS), f_3(I, WFS, TS)]^T \\ K = [I, WFS, TS]^T \end{cases} \quad (8)$$

式中,  $f_1$  为基于 GPR 的熔宽预测模型;  $f_2$  为基于 ANN 的熔高预测模型;  $f_3$  为基于 SVR 的稀释率预测模型。

约束条件是电弧增材制造中各工艺参数水平的取值范围, 各工艺参数的约束条件为:

$$s.t. \begin{cases} 170 \leq I \leq 210 \\ 4 \leq WFS \leq 6 \\ 200 \leq TS \leq 300 \end{cases} \quad (9)$$

随后, 对 NSGA-II 算法的参数进行设定, 训练函数为 Gamultiobj, 种群规模为 100, 保存比例为 0.6, 交叉概率为 0.9, 变异概率为 0.15。

经过遗传迭代后, NSGA-II 算法求解得到的包含 60 个非劣解的 Pareto 前沿如图 8a 所示。图 8b 为 Pareto 前沿在熔宽和熔高平面上的投影; 图 8c 为 Pareto 前沿在熔宽和稀释率平面上的投影; 图 8d 为 Pareto 前沿在熔高和稀释率平面上的投影。从图中可以看出, 非劣解分布在带状空间曲面上, 基本涵盖了各个熔宽点、熔高点和稀释率点, 非劣解分布均匀, 没有离散点, 说明具有良好的收敛性。在实际工程应用中, 可以根据不同的需求从 Pareto 前沿中选择合适的工艺参数组合。例如, 为了提高生产效率, 可以选择较大的熔宽和熔高, 以增加单位时间内的

沉积量; 而在对表面质量有较高要求的情况下, 可以选择较大的熔宽和较小的熔高, 从而改善表面平整性和外观质量。

为了使 3 个目标之间尽可能平衡, 从 60 组非劣解中, 以熔宽  $\geq 8$  mm、熔高  $\geq 2$  mm 和稀释率  $\leq 30\%$  为条件进行初步筛选, 得到 15 组初步优化设计方案 (图 8 中蓝色小球), 从这 15 组方案中选取 3 组进行验证 (图 8 中青色小球)。验证实验工艺参数如表 6。

表 6 验证实验工艺参数  
Tab.6 Parameters of the validation experimental process

Group	I/A	WFS/(m·min <sup>-1</sup> )	TS/(mm·min <sup>-1</sup> )
1	185	5.9	204
2	191	5.9	204
3	194	6.0	204

图 9 展示了验证实验的金相图, 其中对熔宽、熔高和熔深进行了精确测量, 并据此计算了稀释率。通过对比这些实际实验结果与机器学习模型的预测结果, 验证了机器学习预测的准确性。表 7 列出了预测结果与实验结果的对比数据, 除了第 3 组验证实验中稀释率的预测相对误差为 7.421% (大于 5%) 之外, 其余预测熔宽、熔高和稀释率的相对误差都小于 5%。这再次证明了所建立的机器学习模型在预测熔

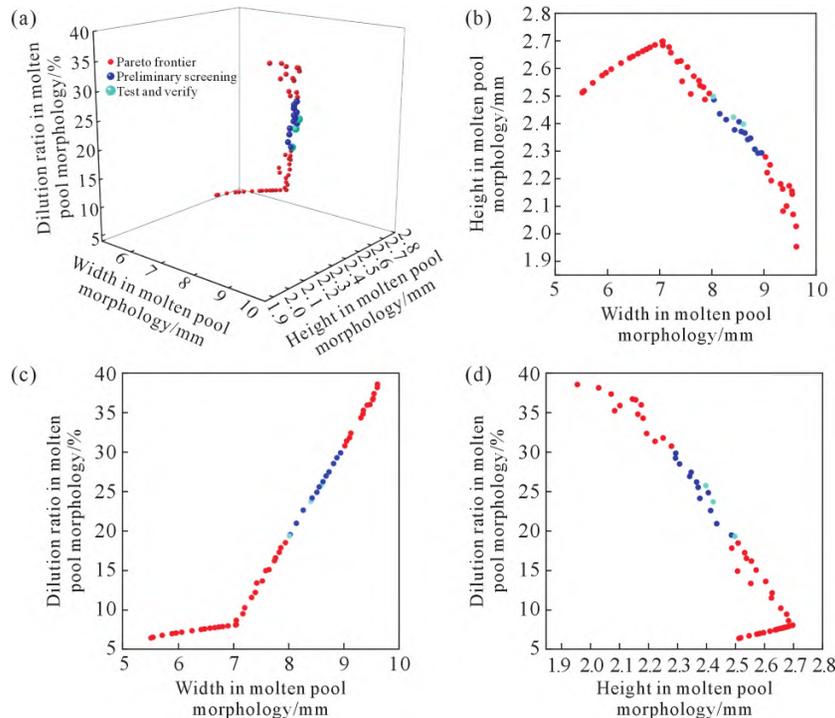


图 8 熔宽、熔高和稀释率的多目标优化结果: (a) Pareto 前沿; (b) Pareto 前沿在熔宽和熔高平面上的投影; (c) Pareto 前沿在熔宽和稀释率平面上的投影; (d) Pareto 前沿在熔高和稀释率平面上的投影

Fig.8 Multiobjective optimization results of the melt width, melt height, and dilution ratio: (a) Pareto frontier; (b) projection of the Pareto frontier on the melt width and melt height planes; (c) projection of the Pareto frontier on the melt width and dilution ratio planes; (d) projection of the Pareto frontier on the melt height and dilution ratio planes

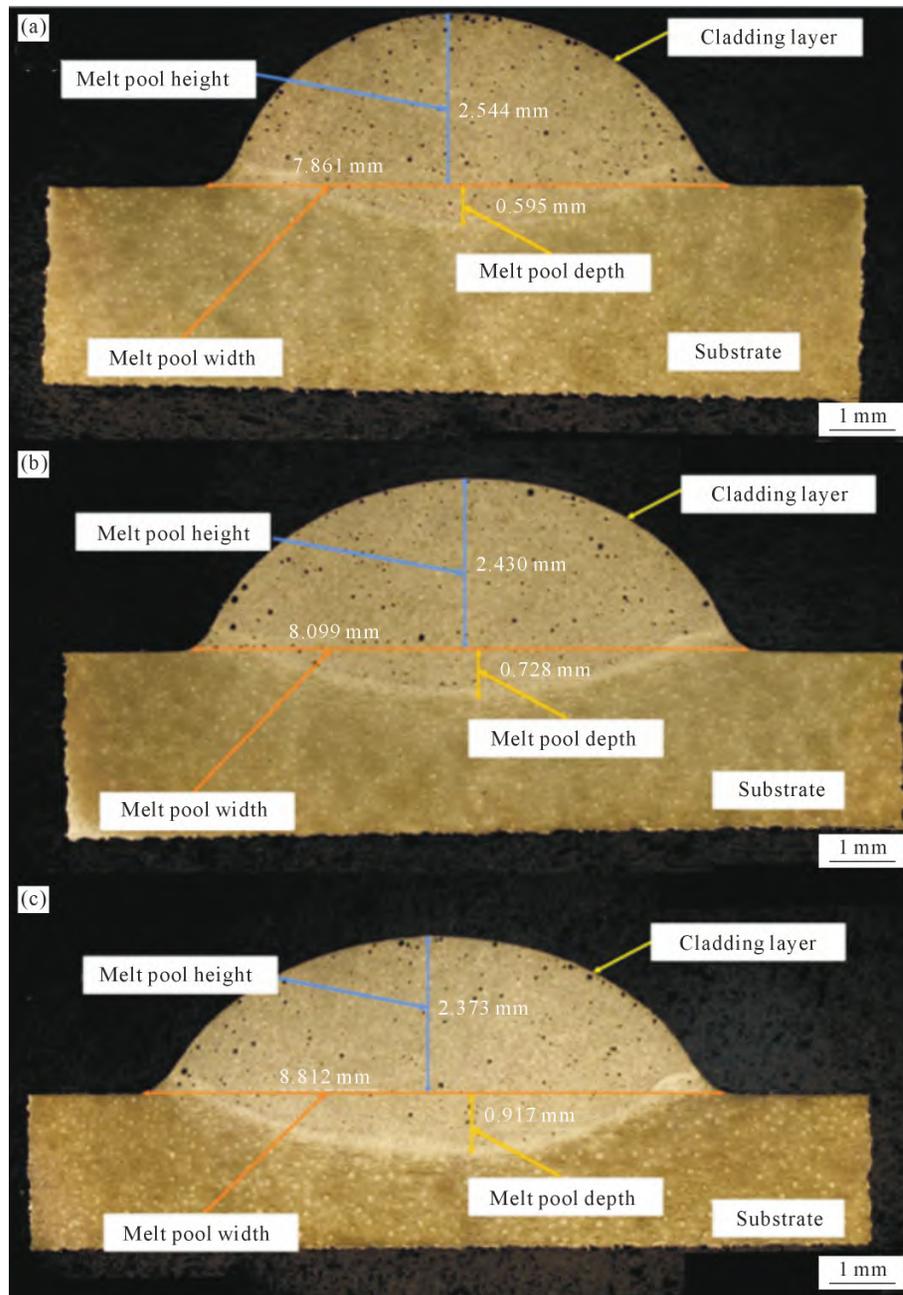


图9 验证实验金相图:(a)验证组1;(b)验证组2;(c)验证组3  
Fig.9 Metallography of three sets of validation experiments: (a) Group 1; (b) Group 2; (c) Group 3

表7 验证实验结果

Tab.7 Results of the verification test

Group	Test results	W	H	D
1	Projected value	8.023 mm	2.498 mm	19.363%
	Experimental value	7.861 mm	2.544 mm	18.944%
	Error	2.057%	1.800%	2.212%
2	Projected value	8.413 mm	2.424 mm	23.744%
	Experimental value	8.099 mm	2.430 mm	23.053%
	Error	3.873%	0.259%	2.997%
3	Projected value	8.604 mm	2.399 mm	25.797%
	Experimental value	8.812 mm	2.373 mm	27.865%
	Error	2.360%	1.070%	7.421%

宽、熔高和稀释率方面具有较高的精度。验证结果还表明,在所选的最优成形区间内,送丝速度与扫

描速度几乎相同,这是由于所选成形几何参数限制了熔宽、熔高和稀释率,从而控制了成形过程中铝合金的总沉积质量,因此图9中三者的沉积总量保持一致。通过对比图9a~c可以看出,在相同沉积量的条件下,通过增大电流来提高热输入,导致熔道的熔宽增大、熔高减小,同时稀释率增大。电弧增材过程中需要保证热输入保持在一定范围内,以确保熔池形态和沉积几何形态的稳定,避免过高或过低的热输入影响最终的几何精度。

### 3 结论

(1)通过进行 Pearson 相关系数分析可以得出:熔宽与电流呈正相关,与扫描速度呈负相关,与送丝

速度的线性关系不明显;熔高与电流和扫描速度呈负相关,与送丝速度呈正相关;稀释率与电流呈正相关,与送丝速度和扫描速度呈负相关。

(2)针对不同数据集,各机器学习模型的预测性能展现出了显著差异。具体而言,在熔宽数据集上,GPR模型综合性能脱颖而出,其训练集  $R^2$  值 0.928,测试集  $R^2$  值更是达到了 0.956,展现了高预测精度。而在熔高数据集上,ANN模型则表现最佳,其训练集  $R^2$  值为 0.921,测试集  $R^2$  值也达到了 0.943,同样表现出了较强的预测能力。此外,在稀释率数据集上,SVR模型综合性能最好,其训练集  $R^2$  值为 0.845,测试集  $R^2$  值也达到了 0.867,为稀释率的预测提供了有力支持。

(3)采用 NSGA-II 算法作为核心优化方法,将电弧增材制造工艺参数视为待优化的变量。为了达成熔宽和熔高的最大化,同时实现稀释率的最小化,引入了 3 种机器学习模型,这些模型在 NSGA-II 算法中扮演了适应度函数的角色,共同推动了电弧增材制造的多目标优化进程。

(4)验证实验中,除第 3 组稀释率的预测相对误差略高于 5%(具体为 7.421%),其余各组对于熔宽、熔高以及稀释率的预测相对误差均控制在 5%以下,有力证明了所提出的多目标优化策略是有效的,能够在保证预测精度的同时,显著提升电弧增材制造的工艺性能。

#### 参考文献:

- [1] HAMRANI A, AGARWAL A, ALLOUHI A, MCDANIEL D. Applying machine learning to wire arc additive manufacturing: A systematic data-driven literature review[J]. *Journal of Intelligent Manufacturing*, 2023, 35: 2407-2439.
- [2] SHI Y S, YAN C Z, SONG B, SU B, WEI Q S, ZHANG L C, WU J M, WEN S F, LIU J, CAI C, YU S F, LI C H, ZHOU Y, CHEN A N, YANG L, CHEN P, ZOU Y, TANG M K, CHEN Y, SHI Y S, WU H Z, ZHANG L, LIU Z F, WANG H Z, WANG C S, WU S Q, LIU G Z, OUYANG Z. Recent advances in additive manufacturing technology: Achievements of the rapid manufacturing center in Huazhong University of Science and Technology[J]. *Additive Manufacturing Frontiers*, 2024, 3(2): 200144.
- [3] WANG C R, LI Y P, TIAN W, HU J S, LI B, LI P C, LIAO W H. Influence of ultrasonic impact treatment and working current on microstructure and mechanical properties of 2219 aluminum alloy wire arc additive manufacturing parts[J]. *Journal of Materials Research and Technology*, 2022, 21: 781-797.
- [4] ZHOU Q, RONG Y M, SHAO X Y, JIANG P, GAO Z M, CAO L C. Optimization of laser brazing onto galvanized steel based on ensemble of metamodels[J]. *Journal of Intelligent Manufacturing*, 2018, 29: 1417-1431.
- [5] RÍOS S, COLEGROVE P A, MARTINA F, WILLIAMS S W. Analytical process model for wire + arc additive manufacturing[J]. *Additive Manufacturing*, 2018, 21: 651-657.
- [6] CAIAZZO F, CAGGIANO A. Laser direct metal deposition of 2024 Al alloy: Trace geometry prediction via machine learning[J]. *Materials*, 2018, 11(3): 444.
- [7] LI Y, YUN Z, ZHANG W T, LONG X, ZHU J J. 3D modelling of layer-by-layer heat and mass transfer in wire arc additive manufacturing[J]. *Additive Manufacturing Frontiers*, 2024, 3(3): 200159.
- [8] WANG C, TAN X P, TOR S B, LIM C S. Machine learning in additive manufacturing: State-of-the-art and perspectives[J]. *Additive Manufacturing*, 2020, 36: 101538.
- [9] KIM D H, KIM T J Y, WANG X L, KIM M, QUAN Y J, OH J W, MIN S H, KIM H, BHANDARI B, YANG I, AHN S H. Smart machining process using machine learning: A review and perspective on machining industry[J]. *International Journal of Precision Engineering and Manufacturing-Green Technology*, 2018, 5: 555-568.
- [10] MENG L B, MCWILLIAMS B, JAROSINSKI W, PARK H Y, JUNG Y G, LEE J, ZHANG J. Machine learning in additive manufacturing: A review[J]. *JOM*, 2020, 72: 2363-2377.
- [11] JUAN Y F, DAI Y B, YANG Y, ZHANG J. Accelerating materials discovery using machine learning[J]. *Journal of Materials Science & Technology*, 2021, 79: 178-190.
- [12] CHEEPU M. Machine learning approach for the prediction of defect characteristics in wire arc additive manufacturing[J]. *Transactions of the Indian Institute of Metals*, 2022, 76: 447-455.
- [13] XIA C Y, PAN Z X, POLDEN J, LI H J, XU Y L, CHEN S B. Modelling and prediction of surface roughness in wire arc additive manufacturing using machine learning [J]. *Journal of Intelligent Manufacturing*, 2021, 33: 1467-1482.
- [14] XIAO X Y, WADDELL C, HAMILTON C, XIAO H B. Quality prediction and control in wire arc additive manufacturing via novel machine learning framework[J]. *Micromachines*, 2022, 13(1): 137.
- [15] SHARMA K S, TEWARI P S, PRAKASH J, SRIVASTAVA B K, SINGH R. Process parameter selection for optimizing the weld pool geometry in the metal inert gas welding of HSLA steel[J]. *International Journal of Applied Engineering Research*, 2010, 5(14): 2383-2392.
- [16] DEB K, PRATAP A, AGRAWAL S, MEYARIVAN T. A fast and elitist multiobjective genetic algorithm: NSGA-II[J]. *IEEE Transactions on Evolutionary Computation*, 2002, 6(2): 182-197.
- [17] YANG Y, CAO L C, ZHOU Q, WANG C C, WU Q, JIANG P. Multi-objective process parameters optimization of Laser-magnetic hybrid welding combining Kriging and NSGA-II [J]. *Robotics and Computer-Integrated Manufacturing*, 2018, 49: 253-262.
- [18] ZHANG Z Q, YAN J P, LU X C, ZHANG T G, WANG H. Optimization of porosity and surface roughness of CMT-P wire arc additive manufacturing of AA2024 using response surface methodology and NSGA-II [J]. *Journal of Materials Research and Technology*, 2023, 24: 6923-6941.
- [19] ASTERIS P G, LEMONIS M E, LE T T, TSAVDARIDIS K D. Evaluation of the ultimate eccentric load of rectangular CFSTs using advanced neural network modeling[J]. *Engineering Structures*, 2021, 248: 113297.
- [20] VAPNIK V N. The nature of statistical learning theory[M]. New

- York: Springer, 2013.
- [21] LEE S, LIM Y, GALDOS L, LEE T, QUAGLIATO L. Gaussian process regression-driven deep drawing blank design method[J]. International Journal of Mechanical Sciences, 2024, 265: 108898.
- [22] LE T T, NGUYEN V H, LE M V. Development of deep learning model for the recognition of cracks on concrete surfaces[J]. Applied Computational Intelligence and Soft Computing, 2021 (1): 8858545.
- [23] HE H, GARCIA E A. Learning from imbalanced data [J]. IEEE Transactions on Knowledge and Data Engineering, 2009, 21(9): 1263-1284.
- [24] SPEARMAN C. The proof and measurement of association between two things[J]. International Journal of Epidemiology, 2010, 39(5): 1137-1150.