DOI:10.16410/j.issn1000-8365.2024.4186

特邀论文

基于机器学习的镁合金电弧增材制造工艺优化研究

郭　灿[1,2],聂　帅[1],张忠明[1,2],徐春杰[1,2]

(1. 西安理工大学 材料科学与工程学院,陕西 西安 710048;2. 西安市先进镁合金增材制造与精确成形重点实验室,陕西 西安 710048)

摘　要:电弧增材制造克服了传统铸锻技术制备镁合金的不足,是镁合金成形中的新技术。然而,镁合金电弧增材制造过程影响因素较多,工艺控制困难,且存在零件难以成形、易开裂、易产生内部缺陷等问题。为了解决镁合金电弧增材制造工艺控制困难的问题,采用实验结合机器学习的方法建立了工艺参数与试样宏观形貌之间的非线性关系,分析了不同工艺参数对成形质量的影响规律,确定最佳工艺参数范围为:基板温度 160 ℃,送丝速度 12.0~14.5 m/min,焊接速度 8~11 mm/s,摆弧宽度 8~10 mm。以 AZ31 镁合金丝材作为原材料,针对寻优工艺参数进行了单层和多层镁合金电弧增材制造实验。结果表明,该参数条件下熔宽为 13.95 mm,熔高为 3.28 mm,宽高比为 4.25,接触角为 42°,此时镁合金熔融丝材铺展性良好,且试样表面无不成形缺陷。

关键词:镁合金;电弧增材制造;神经网络;工艺优化

中图分类号:TG146.2+2　　**文献标识码**:A　　**文章编号**:1000-8365(2024)11-1025-11

Optimization of Magnesium Alloy Arc Additive Manufacturing Processes Based on Machine Learning

GUO Can[1,2], NIE Shuai[1], ZHANG Zhongming[1,2], XU Chunjie[1,2]

(1. School of Materials Science and Engineering, Xi'an University of Technology, Xi'an 710048, China; 2. Xi'an Key Laboratory of Advanced Magnesium Alloy Additive Manufacturing and Precision Forming, Xi'an 710048, China)

Abstract: Wire-arc additive manufacturing of magnesium alloys overcomes the main shortcomings of traditional casting and forging technology, which is a new technology in the field of magnesium alloy forming. However, the process of wire-arc additive manufacturing of magnesium alloys is affected by many factors, making it difficult to control the forming process. In addition, defects, such as hot cracking and pore defects, are prone to occur during the forming process. To solve this problem, a nonlinear relationship between the process parameters and the macroscopic morphology of the samples was established by combining experimental and machine learning methods. Furthermore, the influence of different process parameters on the forming quality was analysed, and the optimal ranges of process parameters were determined, i.e., 160 ℃ (substrate temperature), 12~14.5 m/min (wire feeding speed), 8~11 mm/s (travel speed), and 8~10 mm (weaving width). Finally, using AZ31 magnesium alloy wire as the experimental raw material, single-layer and multilayer magnesium alloy arc additive manufacturing experiments were conducted with the optimized process parameters. The experimental results reveal that the samples form well when the melt width is 13.95 mm, the melt height is 3.28 mm, the aspect ratio is 4.25, and the contact angle is 42°.

Key words: magnesium alloy; wire-arc additive manufacturing; neural network; process optimization

镁合金具有易回收、比强度和比刚度高、导电性好、减震性及抗电磁辐射优良等特点,被誉为“21 世纪最具发展前景的绿色工程材料”[1],在航空航天、汽车工业、机械设备、电子通信等领域应用前景广阔[2-3]。

收稿日期:2024-09-27

基金项目:陕西省自然科学基金(2023-JC-QN-0573);西安市科技计划(2022JH-RYFW-0026);国家自然科学基金(51801154);陕西省高等学校学科创新引智基地(S2021-ZC-GXYZ-0011)

作者简介:郭　灿,1988 年生,博士,副教授.研究方向为凝固过程微观组织数值模拟、镁合金电弧增材制造研究.Email: cguo@xaut.edu.cn

引用格式:郭灿,聂帅,张忠明,徐春杰.基于机器学习的镁合金电弧增材制造工艺优化研究[J].铸造技术,2024,45(11): 1025-1035.
GUO C, NIE S, ZHANG Z M, XU C J. Optimization of magnesium alloy arc additive manufacturing processes based on machine learning[J]. Foundry Technology, 2024, 45(11): 1025-1035.

中国知网 https://www.cnki.net

但目前镁合金的应用加工仍受到诸多限制，例如，传统的铸造法易产生氧化夹杂等缺陷，镁合金塑性变形能力差导致锻造及轧制等加工困难，并难以生产造型复杂、性能优良的镁合金零部件。因此，发展先进镁合金加工工艺及加工方法是镁合金领域的重要研究课题。电弧增材制造技术(wire-arc additive manufacturing, WAAM)是基于丝材的定向能量沉积方法，电弧将镁丝材熔化，逐层打印出金属结构件[4-5]，该方法可以有效弥补传统加工方法的缺陷，为高强韧复杂结构镁合金零部件加工带来了新技术。

然而，由于WAAM可调工艺参数较多，镁合金电弧增材制造“工艺–成形质量”间的定量关系仍未得到揭示。姚巨坤等[6]利用CMT(cold metal transfer)焊接技术制备了AZ31B镁合金试样，发现随着送丝速度的增大，焊缝熔宽增长趋势较大；随着焊接速度的增加，熔宽和熔高尺寸都呈下降趋势，由于熔宽下降低于熔高，所以宽高比呈增长趋势。Su等[7]使用WAAM-CMT制备了Al-Mg合金试样，发现有效壁宽随送丝速度的增加和焊接速度的减小而增大。占宇航等[8]采用WAAM制备了AZ80镁合金沉积体，研究了工艺参数(焊接电流、焊接速度、送丝速度、基板温度)对沉积体显微组织和抗拉强度的影响，发现抗拉强度随焊接速度的增大呈先增大后减小的趋势，随送丝速度的增加而增加。获得宽高比较大的单层镁合金焊接试样，是制备成形良好镁合金零件的必要条件。但是影响单层镁合金宏观形貌的WAAM工艺参数是一个非线性多输入系统，目前大部分寻优方法主要是单因素实验，很难考虑到工艺参数之间的相互影响。机器学习算法则是在无显著式编程的前提下[9-11]，赋予了机器“自主学习”的能力，这种能力非常适合处理高度非线性问题。目前机器学习已经在成形件质量控制[12-16]、显微组织调控[17-18]及力学性能优化[19-21]等方面取得了初步进展。利用增材制造过程所获得的大量数据、模型能够相对准确的进行预测，不仅节约了人力、物力和财力，而且更快地实现了工艺参数优化，进而实现对成形件质量和性能的调控。

本文采用人工神经网络算法，建立了镁合金电弧增材制造成形工艺参数和单层成形件宏观形貌之间的预测模型，并对工艺参数进行优化。通过正交实验，建立了用于训练和测试的数据集；通过对网络的训练和测试，使预测模型达到一定的精度和泛化性；通过对网络权重矩阵进行计算，研究了各工艺参数对试样宏观形貌的影响占比。最后，对数据进行分析，获得了一种最优工艺参数组合，并进行了实验验证。

1 实验材料及方法

实验选用300 mm×300 mm×50 mm的AZ31镁合金基板，焊接材料选用直径为1.2 mm的AZ31镁合金焊丝，其化学成分如表1所示。

表1 AZ31镁合金焊丝化学成分
Tab.1 Chemical composition of the AZ31 Wire
(mass fraction/%)

Al	Zn	Mn	Si	Fe	Ni	Cu	Mg
2.76	0.83	0.36	0.02	0.004	0.004	0.000 6	Bal.

采用6轴ABB焊接机器人、供气系统、CMT Advanced 4000R焊机等设备来制备镁合金打印试样。为避免样本数据过少，造成神经网络学习不充分、泛化效果较差，故设计了4组正交实验，利用CMT Advanced 4000R焊接设备进行了80组实验。加工参数如表2所示。

表2 WAAM实验方案
Tab.2 The experimental parameters for WAAM deposition

Parameters	Value
Substrate temperature/°C	40, 80, 120, 160
Wire feeding ratem/(m·min^{-1})	6~14.5
Travel speed/(mm·s^{-1})	3~12
Weaving width/mm	4, 6, 7, 8, 10
Protective gas	Ar
Protective gas rate/(L·min^{-1})	20
Arc length correction/%	10
Welding gun swing mode	Z-shaped
Welding gun swing length/mm	4

姚巨坤等[6]在研究电弧增材制造工艺参数对镁合金试样焊缝形貌的影响时，用熔宽、熔高(余高)及熔深来表征镁合金试样的焊缝形貌。因此，本文利用游标卡尺对试样的熔宽和熔高进行测量，取3次平均值。焊道的几何形貌和实物如图1所示。

在本研究中，神经网络的输入有4个工艺参数，分别为基板温度、送丝速度、焊接速度及摆弧宽度；神经网络的输出为镁合金试样的熔宽和熔高。焊道见附图1S，实验数据见附表1S，根据熔池形貌对所获得的样本数据进行分类，在去除宏观不成形数据后，剩余68组数据，将数据集分为训练数据集和测试数据集，并利用测试数据集来评估神经网络模型的预测性能。编号为1~58的样本数据为神经网络模型的训练样本，编号为59~68的样本数据为神经网络模型的测试样本。

2 人工神经网络模型

2.1 模型建立

神经网络输入参数的范围会在一定程度上影响

中国知网 https://www.cnki.net

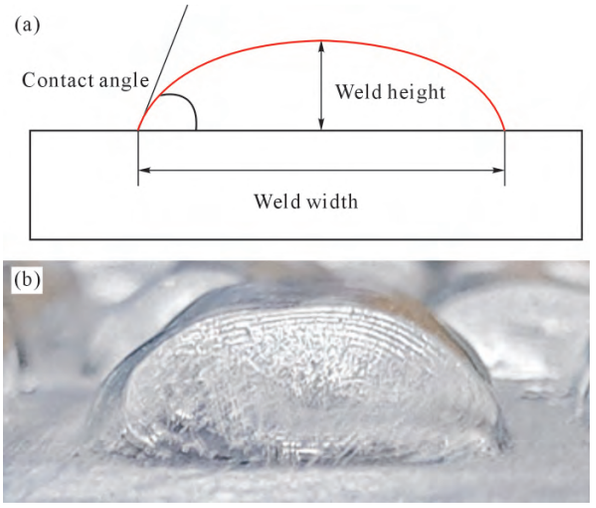

图 1 焊道几何形貌和实物：(a) 几何形貌；(b) 实物
Fig.1 Schematic diagram of the geometric morphology and the physical image of the weld bead: (a) geometric morphology; (b) physical image

网络的收敛速度，为了减少神经网络不同输入之间数量级的差距，就需要对数据集进行归一化处理，使数据映射到[0,1]区间：

$$x_{new}=\frac{x_i-x_{min,j}}{x_{max,j}-x_{min,j}} \tag{1}$$

式中，x_{new} 为归一化后的特征；x_i 为数据集中的某一原始数据；$x_{min,j}$ 和 $x_{max,j}$ 分别为对应特征的最小值和最大值。

BP(back propagation)神经网络是以 Rumelhart 和 McCelland 为首的科学家团队在 1986 年提出，是一种通过误差逆向传播实现网络训练的多层前馈网络，一般包含 3 层网络，即输入层、隐层和输出层。神经网络是通过神经元之间相互连接传递信息，各层神经元的作用各不相同，从而达到处理信号的作用。隐层中神经元的输入由下式获得：

$$a_j=\boldsymbol{W}_{ij}x_i+b_j \tag{2}$$

式中，$\boldsymbol{W}_{ij}$ 为神经网络输入参数的权重；x_i 为神经网络的输入数据，为了提高神经网络的非线性拟合效果，在输入层中加入偏置项 b_j。对于镁合金电弧增材制造，输入层的节点数为 5，包含基板温度、送丝速度、焊接速度和摆弧宽度和偏置项。对于神经网络输出层，镁合金试样宏观形貌的主要测量对象有试样的熔高和熔宽。由于熔高和熔宽的测量范围差距较大，故分别进行预测，即本文共有 2 个 BP 神经网络预测模型，分别为熔高神经网络预测和熔宽神经网络预测，两者的输出层节点数都为 1。

隐层神经元个数主要受输入层节点数、输出层节点数及具体求解问题等因素的影响，隐层神经元个数选取通过下式获得[22]：

$$N=\sqrt{n+m}+a \tag{3}$$

式中，N 为隐层神经元个数；n 为输出层节点数；m 为输入层节点数；a 为 1~10 之间的常数。通过计算得出，熔高和熔宽 BP 神经网络预测模型的隐层神经元个数选择范围均为 3~12 之间，表 3 和 4 为不同隐层神经元个数条件下，熔高和熔宽神经网络的预测精度。

表 3 不同隐层神经元个数条件下熔高预测精度
Tab.3 Prediction accuracy of weld height with different numbers of hidden layer neurons

Sample number	Number of neurons	Mean relative error/%	Sample number	Number of neurons	Mean relative error/%
1	3	6.02	6	8	7.38
2	4	7.09	7	9	5.52
3	5	6.55	8	10	8.95
4	6	6.13	9	11	6.49
5	7	5.10	10	12	6.02

表 4 不同隐层神经元个数条件下熔宽预测精度
Tab.4 Prediction accuracy of weld width with different numbers of hidden layer neurons

Sample number	Number of neurons	Mean relative error/%	Sample number	Number of neurons	Mean relative error/%
1	3	3.52	6	8	4.10
2	4	3.11	7	9	4.46
3	5	3.86	8	10	3.91
4	6	4.54	9	11	3.37
5	7	8.21	10	12	4.14

由表 3 可知，熔高预测的平均相对误差均高于 5%，其中平均相对误差最接近 5%的隐层神经元个数为 7 和 9，考虑到学习时间和拟合程度的需求，最终选择熔高神经网络隐层神经元个数为 7。由表 4 可知，除去隐层神经元个数为 7 时，其余平均相对误差均在 5%以下，考虑到学习时间和拟合程度的需求，最终选择熔宽神经网络隐层神经元个数为 4，文中熔高和熔宽的神经网络结构采用图 2 所示形式。相较于 Sigmoid 函数，Tanh 函数应用于隐层避免了梯度消失的问题，且在反向更新权重时，能更快地传递信号，有利于加速网络训练，因此在隐藏层采用了 Tanh 激活函数。

采用试凑法确定熔高和熔宽神经网络的最终学习速率，在迭代次数 10 000 次的条件下，不同学习速率下的预测精度如表 5 和 6 所示。由表 5 可知，不同学习速率对熔宽神经网络的预测精度具有一定影响，学习速率在 0.10~0.15 之间时，平均相对误差大多低于 5%，考虑学习时间及拟合程度的需求，最终选择熔高神经网络预测模型的学习速率为 0.11。由表 6 可知，熔宽预测模型不同学习速率的预测精度相对熔高较稳定，大多数平均相对误差在 5%左右，

中国知网 https://www.cnki.net

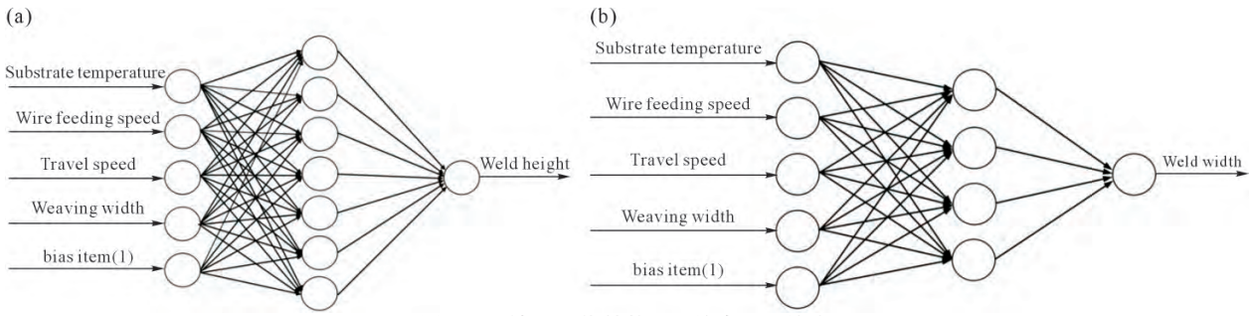

图 2 BP 神经网络结构:(a) 熔高;(b) 熔宽

Fig.2 BP neural network structure: (a) height; (b) width

表 5 不同学习速率时熔高预测精度

Tab.5 Prediction accuracy of weld height at different learning rates

Sample number	Learning rate	Mean relative error/%	Sample number	Learning rate	Mean relative error/%
1	0.06	7.84	6	0.11	2.45
2	0.07	7.56	7	0.12	3.99
3	0.08	5.85	8	0.13	4.21
4	0.09	9.75	9	0.14	7.60
5	0.10	4.73	10	0.15	4.72

表 6 不同学习速率时熔宽预测精度

Tab.6 Prediction accuracy of weld width at different learning rates

Sample number	Learning rate	Mean relative error/%	Sample number	Learning rate	Mean relative error/%
1	0.01	4.01	6	0.06	4.86
2	0.02	4.17	7	0.07	7.17
3	0.03	4.52	8	0.08	6.02
4	0.04	3.78	9	0.09	5.11
5	0.05	4.90	10	0.10	4.91

学习速率在 0.01~0.06 之间时，平均相对误差均低于 5%，选择熔宽神经网络预测模型的学习率为 0.04。

2.2 模型训练和测试

在上述确定的网络参数下，将 10 组测试样本输入熔高和熔宽神经网络预测模型，对预测结果进行反归一化并输出，最终得到熔高和熔宽预测值，将实验测试值与预测值对比，如图 3 和 4 所示。

由图 3 可知，神经网络预测的熔高值与实际试样熔高测量值较为符合，但熔高神经网络预测仍存在一定误差，其中绝对值最大的相对误差为 5.2%，绝对值最小的相对误差为 0.55%，相对误差范围控

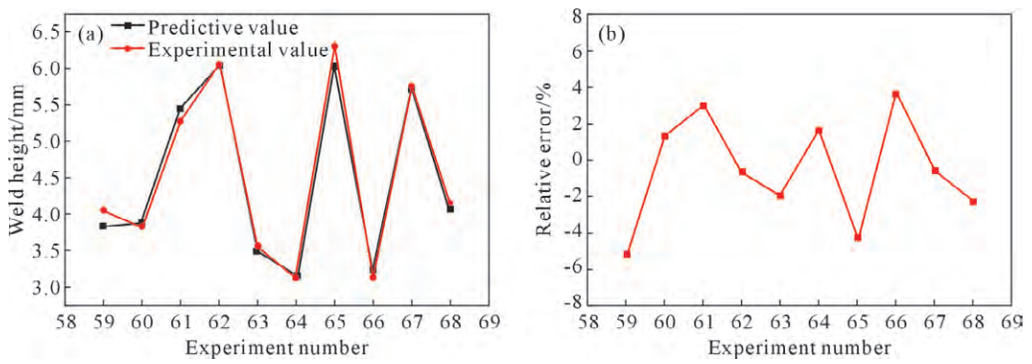

图 3 BP 模型熔高测试结果:(a) 预测值与实验值;(b) 预测值相对误差

Fig.3 The weld height results of the BP model: (a) predicted and experimental values; (b) the relative error between the predicted and experimental values

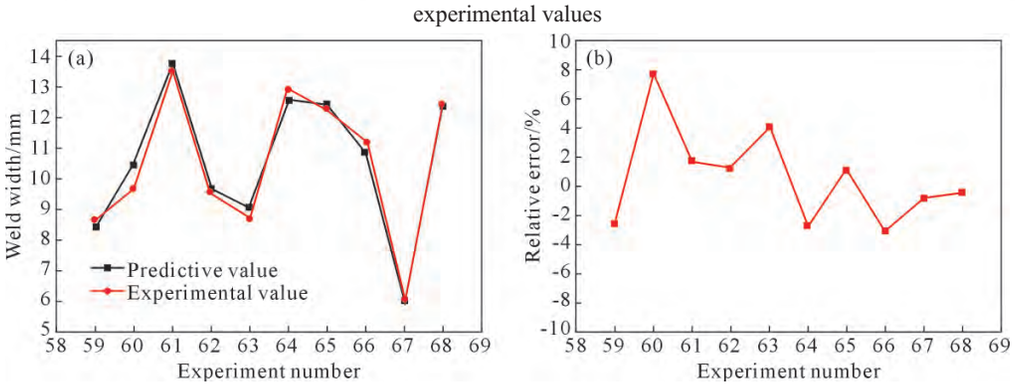

图 4 BP 模型熔宽测试结果:(a) 预测值与实验值;(b) 预测值相对误差

Fig.4 The weld width results of the BP model: (a) predicted and experimental values; (b) the relative error between the predicted and experimental values

中国知网 https://www.cnki.net

制在6%以内。由图4可知，神经网络预测的熔宽值与实际试样熔宽测量值较为符合，但熔宽神经网络仍存在一定误差，其中，绝对值最大的相对误差为7.68%，绝对值最小的相对误差为0.42%，相对误差范围控制在8%以内。以上说明所建立的熔高和熔宽神经网络预测模型具有一定的准确性和泛化性，能够正确反映试样宏观形貌与镁合金电弧增材制造工艺参数之间复杂的非线性关系，适用于镁合金电弧增材制造试样宏观形貌的预测。

3　WAAM工艺参数权重分析

通过对 $\boldsymbol{W}_{ij}$、$\boldsymbol{V}_{jt}$ 权重矩阵的运算，得出每个工艺参数的得分，进而计算出每个工艺参数的影响占比，计算过程如下：

$$Z_1=w_{11}\times\nu_{11}+w_{21}\times\nu_{12}+\cdots+w_{n1}\times\nu_{1n} \tag{4}$$

$$Z_2=w_{12}\times\nu_{11}+w_{22}\times\nu_{12}+\cdots+w_{n2}\times\nu_{1n} \tag{5}$$

$$\cdots\cdots$$

$$Z_n=w_{1n}\times\nu_{11}+w_{2n}\times\nu_{12}+\cdots+w_{nn}\times\nu_{1n} \tag{6}$$

$$K_i=Z_i/(Z_1+Z_2+\cdots+Z_n) \tag{7}$$

在选定的BP神经网络参数下，进行5次平均相对误差在5%以下的熔高和熔宽预测，根据上述公式，求出每个工艺参数的得分，然后对这5次预测下的工艺参数影响占比进行计算，结果如表7和8所示。

由表7可知，对熔高尺寸增长产生抑制作用的工艺参数为基板温度、焊接速度和摆弧宽度，即随这些工艺参数的增加，熔高尺寸呈下降趋势。在这3个工艺参数中，对熔高增长抑制作用最大的工艺参数为焊接速度，抑制影响占比为89.8%；抑制作用最小的工艺参数为基板温度，抑制影响占比为7.3%。对于送丝速度，影响占比为29.2%，说明其对熔高尺寸的增长起促进作用，即随送丝速度增大熔高尺寸呈增大趋势。由表8可知，对熔宽尺寸增长起促进作用的工艺参数为基板温度、送丝速度和摆弧宽度。随着这些工艺参数的增加熔宽尺寸呈增大趋势，其中对熔宽尺寸增长促进作用最大的工艺参数为送丝速度，促进影响占比为81.9%，促进作用最小的工艺参数为基板温度，促进影响占比6.3%。对于焊接速度，其影响占比为-25.98%，说明其对熔宽尺寸的增长起抑制作用。随焊接速度的增大熔宽尺寸呈下降趋势，在镁合金电弧增材制造过程中，为了实现多层焊接，就需要对工艺参数的取值范围进行约束，以期获得熔宽和熔高比值大的单层焊道。

为了验证模型分析所得工艺参数影响占比的正确性，设计了单因素验证实验，通过对单因素验证实验成形件熔高和熔宽的测量，得到熔高和熔宽尺寸随基板温度、送丝速度、焊接速度和摆弧宽度的变化曲线，如图5和6所示。

由于部分工艺参数与熔高和熔宽尺寸之间不是线性关系，所以采用物理学中求平均速度的思想，反映各个工艺参数对熔高尺寸的影响。根据式(8)求解出平均影响，即可计算出试样熔高工艺参数的影响占比：

$$E=\frac{1}{2n}\sum_{i=3}^{n}\left(\frac{y_i-y_{i-2}}{x_i-x_{i-1}}\right) \tag{8}$$

式中，y 为熔高和熔宽测量值；x 为各个工艺参数取值；n 为实验编号。

将模型分析和单因素实验得出的工艺参数对熔高和熔宽尺寸的影响占比进行比较，如图7所示。由图7a可知，BP神经网络预测模型得出的工艺参数对熔高尺寸的影响占比与实验得出的结果较为接近，模型不仅分析出对熔高尺寸起最大影响的工艺

表7　工艺参数对试样熔高尺寸的影响

Tab.7 Influence of the process parameters on the weld height

Process parameter	Sample					Average value/%
	1	2	3	4	5	
Substrate temperature	-5.45	-11.20	-11.65	-2.34	-5.85	-7.3
Wire feeding speed	24.94	38.55	26.86	24.67	30.83	29.2
Travel speed	-86.38	-94.42	-90.40	-89.20	-88.75	-89.8
Weaving width	-33.10	-32.92	-24.80	-33.12	-36.22	-32.1

表8　工艺参数对试样熔宽尺寸的影响

Tab.8 Influence of the process parameters on the weld width

Process parameter	Sample					Average value/%
	1	2	3	4	5	
Substrate temperature	7.45	6.36	8.64	2.07	6.73	6.30
Wire feeding speed	83.92	82.37	77.58	79.53	86.30	81.90
Travel speed	-27.15	-26.69	-24.73	-20.47	-30.84	-25.98
Weaving width	35.77	37.96	38.49	38.86	37.80	37.78

中国知网　https://www.cnki.net

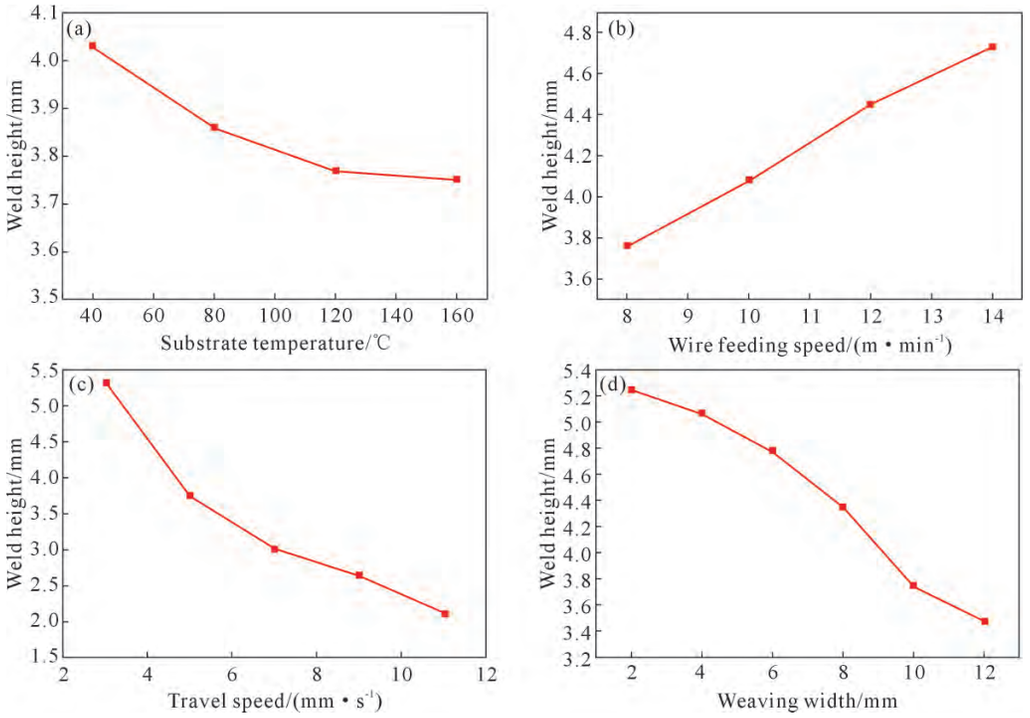

图 5 试样熔高随工艺参数变化:(a) 送丝速度 9 m/min、焊接速度 5 mm/s、摆弧宽度 10 mm;(b) 基板温度 160 ℃、焊接速度 5 mm/s、摆弧宽度 10 mm;(c) 基板温度 160 ℃、送丝速度 9 m/min、摆弧宽度 10 mm;(d) 基板温度 160 ℃、送丝速度 9 m/min,焊接速度 5 mm/s

Fig.5 Influence of process parameters on weld height: (a) wire feeding speed of 9 m/min, travel speed of 5 mm/s, weaving width of 10 mm; (b) substrate temperature of 160 ℃, travel speed of 5 mm/s, weaving width of 10 mm; (c) substrate temperature of 160 ℃, wire feeding speed of 9 m/min, weaving width of 10 mm; (d) substrate temperature of 160 ℃, wire feeding speed of 9 m/min, travel speed of 5 mm/s

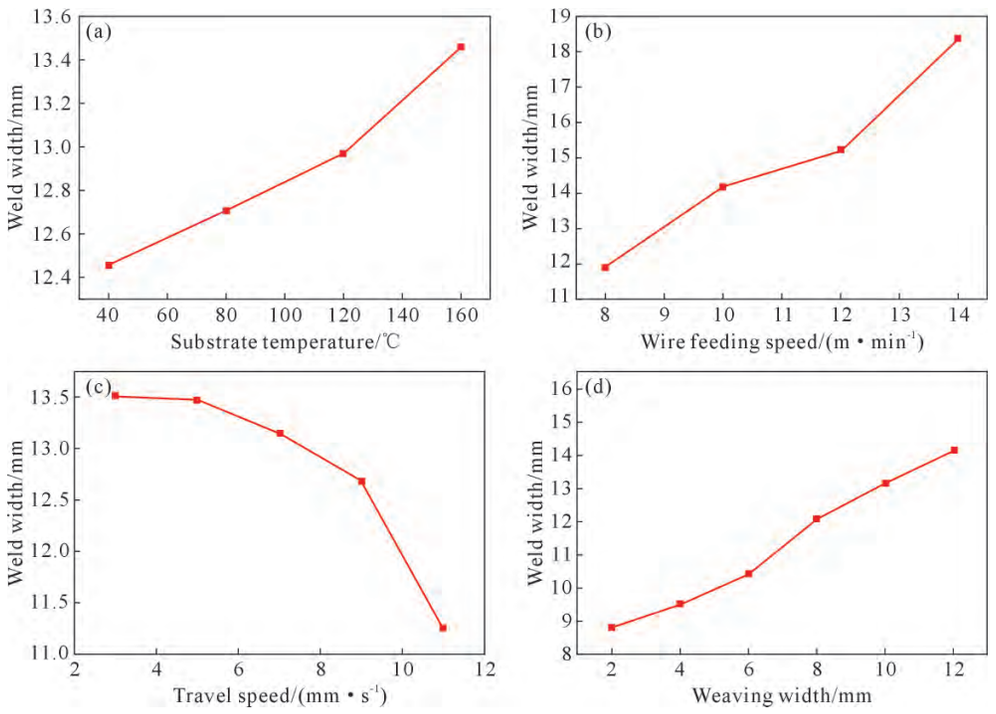

图 6 试样熔宽随工艺参数变化:(a) 送丝速度 9 m/min、焊接速度 5mm/s、摆弧宽度 10 mm;(b) 基板温度 160 ℃、焊接速度 5 mm/s、摆弧宽度 10 mm;(c) 基板温度 160 ℃、送丝速度 9 m/min、摆弧宽度 10 mm;(d) 基板温度 160 ℃、送丝速度 9 m/min,焊接速度 5 mm/s

Fig.6 Influence of process parameters on weld width: (a) wire feeding speed of 9 m/min, travel speed of 5 mm/s, weaving width of 10 mm; (b) substrate temperature of 160 ℃, travel speed of 5 mm/s, weaving width of 10 mm; (c) substrate temperature of 160 ℃, wire feeding speed of 9 m/min, weaving width of 10 mm; (d) substrate temperature of 160 ℃, wire feeding speed of 9 m/min, travel speed of 5 mm/s

中国知网 https://www.cnki.net

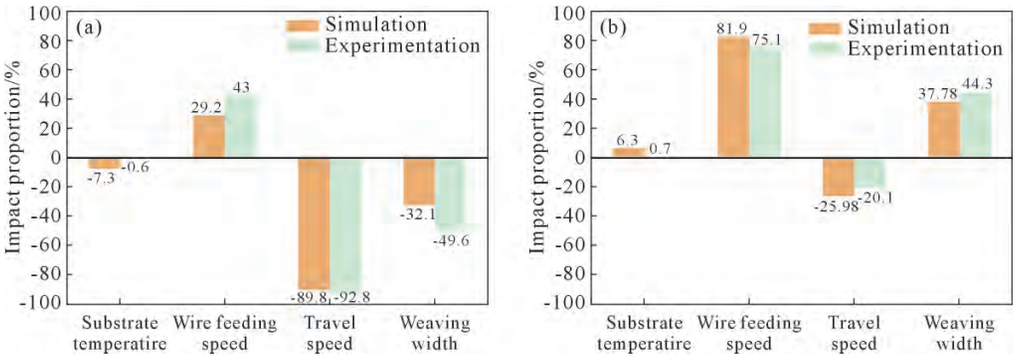

图 7 模拟分析与实验所得工艺参数对熔高和熔宽影响占比：(a) 熔高；(b) 熔宽

Fig.7 Impact proportions of process parameters obtained from BP analysis and experiments on weld height and weld width: (a) weld height; (b) weld width

参数(焊接速度)和起最小影响的工艺参数(基板温度)，而且分析出送丝速度和焊接速度对熔高尺寸的影响程度接近这一现象。对于焊接速度，模型分析和实验结果所得出的影响占比，误差仅有 3%，说明所建立的熔高神经网络模型对工艺参数与熔高尺寸之间的非线性关系有较好的学习效果，而对于送丝速度和摆弧宽度，模型分析与实验得出的工艺参数影响占比误差较大，其原因可能来自两方面，一方面可能由于熔高尺寸变化范围较小，预测精度难以控制，另一方面可能因为未考虑网络激活函数所导致。由图 7b 可知，BP 神经网络预测模型得到的工艺参数对熔宽尺寸的影响占比与实验结果较接近，该模型不仅分析出对熔宽尺寸起最大作用的工艺参数 (送丝速度)和最小作用的工艺参数(基板温度)，而且将模型分析与实验得出的工艺参数影响占比的误差范围控制在 7%以内，说明 BP 神经网络预测模型能正确反映工艺参数与试样熔宽之间的非线性关系。

4　最优工艺参数范围及实验验证

综上所述，影响熔高和熔宽的主要工艺参数为送丝速度和焊接速度。为了易于进行镁合金电弧增材制造多层焊接，要保证单层焊接试样的宽高较大，且不出现不成形缺陷，因此，确定各工艺参数最佳取值范围为：①基板温度。由于基板温度对熔高和熔宽的影响占比较小，且对熔高尺寸增长起抑制作用，对熔宽尺寸增长起促进作用，确定最佳基板温度为 160 ℃。②送丝速度。对试样熔宽尺寸和熔高尺寸的增长均起促进作用，确定送丝速度范围为12~14.5 m/min。③焊接速度。对试样熔高尺寸和熔宽尺寸的增长均起抑制作用，且焊接速度对熔高尺寸的影响程度接近熔宽尺寸的 3.5 倍，高的焊接速度易于获得较大的宽高比，但考虑到焊接速度过大可能导致的试样表面不成形问题，确定焊接速度范围为 8~11 mm/s。④摆弧宽度。对熔高尺寸增长起抑制作用，对熔宽尺寸增长起促进作用，所以高的摆弧宽度容易获得较大的宽高比，但是为了避免由于摆弧宽度太大导致的不成形问题，确定摆弧宽度参数范围为 8~10 mm。

在确定最佳工艺参数范围后，进行等差取值并排列组合，通过神经网络模型预测，对宽高比进行计算比较，最终选择最优工艺参数组合为：基板温度 160 ℃、送丝速度 14.5 m/min、焊接速度 11 mm/s、摆弧宽度 8 mm。在该参数条件下，进行了镁合金电弧增材制造单层打印实验，结果如图 8 所示。测量得出该工艺参数组合下，试样熔宽为 13.95 mm，熔高为 3.28 mm，宽高比为 4.25，接触角在 40°~50°之间，此时镁合金熔融丝材铺展性良好，且试样表面无不成形缺陷。

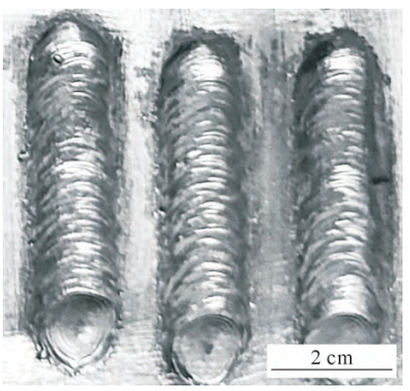

图 8 最优工艺参数组合下的 WAAM 成形件

Fig.8 WAAM parts under the optimal process parameters

进一步研究了该组参数在多层沉积条件下的适用性。图 9 为与图 8 相同工艺参数条件下制备的镁合金单道沉积壁，该沉积壁的制备采用往复堆积的方法，以保证试样两侧高度接近一致，并且层间打印采用连续打印方式，无层间等待时间，单道镁合金沉积壁共进行了 25 层堆叠。

由正面形貌图可知，随着层数增多，试样长度略微增加，长度范围为 70~77 mm，此时层与层之间润湿性保持良好，未见明显未熔合缺陷。由试样侧面形

中国知网　https://www.cnki.net

图 9 单道多层镁合金试样宏观形貌
Fig.9 Macroscopic morphology of the single-channel magnesium alloy deposition wall

貌可以看出，前 20 层试样的宽度未出现明显变化，宽度范围在 14~16 mm 之间，从第 21 层开始，试样的宽度快速增大，从 16 mm 增加到 22 mm，试样在第 24 层出现明显的流边现象，继续沉积可能会因为过热，导致镁合金沉积壁出现严重塌陷，主要原因是层间等待时间极短，随着层数的增多，热量逐渐积累所导致的流边、塌陷现象。通过对比单层和多层沉积结果可知，神经网络预测得到的最优参数对单层试样、多层沉积试样均具有良好适用性，且成形质量较高。

5 结论

(1)对熔高和熔宽 BP 神经网络预测模型的训练及网络各项参数的调节，所建神经网络模型预测结果与实验结果的相对误差范围控制在 8%以内。

(2)基于 BP 神经网络算法，建立了工艺参数与试样宏观形貌之间的非线性关系，通过分析网络权重获得影响试样宏观形貌的主要因素：送丝速度和焊接速度。通过单因素验证实验，证实 BP 神经网络预测模型对工艺参数与试样宏观形貌之间的复杂非线性关系拟合效果良好。

(3)通过分析工艺参数对熔高尺寸和熔宽尺寸的影响占比，最终得出最优工艺参数组合为：基板温度 160 ℃、送丝速度 14.5 m/min、焊接速度11 mm/s、摆弧宽度 8 mm，单层试样宽高比为 4.25，接触角为 42°，这表明试样具有良好的铺展性，且试样表面无不成形缺陷；多层结果与单层结果相一致。

参考文献：

[1] 张津，章宗和. 镁合金及应用[M]. 北京：化学工业出版社，2004.
[2] 丁文江，等. 镁合金科学与技术[M]. 北京：科学出版社，2007.
[3] KULEKCI M K. Magnesium and its alloys applications in automotive industry[J]. The International Journal of Advanced Manufacturing Technology, 2008, 39: 851-865.
[4] FROES F H, ELIEZER D, AGHION E. The science, technology, and applications of magnesium[J]. JOM, 1998, 50: 30-34.
[5] CUNNINGHAM C R, FLYNN J M, SHOKRANI A, DHOKIA V, NEWMAN S T. Invited review article: Strategies and processes for high quality wire arc additive manufacturing[J]. Additive Manufacturing, 2018, 22: 672-686.
[6] 姚巨坤，江宏亮，殷凤良. 镁合金 CMT—电弧增材再制造工艺与组织性能研究[J]. 工具技术，2019, 53(1): 65-69.
YAO J K, JIANG H L, YIN F L. Study on remanufacturing process and microstructure of magnesium alloy CMT-arc additives[J]. Tool Engineering, 2019, 53(1): 65-69.
[7] SU C C, CHEN X Z, GAO C, WANG Y F. Effect of heat input on microstructure and mechanical properties of Al-Mg alloys fabricated by WAAM[J]. Applied Surface Science, 2019, 486: 431-440.
[8] 占宇航，郭阳阳，李章张. 工艺参数对电弧增材制造镁合金组织和性能的影响[J]. 热加工工艺，2022, 51(19): 26-29.
ZHAN Y H, GUO Y Y, LI Z Z. Effect of process parameters on microstructure and properties of magnesium alloy produced by wire arc additive manufacturing[J]. Hot Working Technology, 2022, 51(19): 26-29.
[9] LI Z, MA X F, XIN H L. Feature engineering of machine-learning chemisorption models for catalyst design[J]. Catalysis Today, 2017, 280: 232-238.
[10] BISHOP C M. Pattern recognition and machine learning[M]. New York: Springer, 2006.
[11] MUELLER T, KUSNE A G, RAMPRASAD R. Machine learning in materials science: Recent progress and emerging applications [M]. PARRILL A L, LIPKOWITZ K B. Reviews in computational chemistry. New York: Wiley, 2016: 186-273.
[12] SCIME L, BEUTH J. A multi-scale convolutional neural network for autonomous anomaly detection and classification in a laser powder bed fusion additive manufacturing process [J]. Additive Manufacturing, 2018, 24: 273-286.
[13] KHANZADEH M, CHOWDHURY S, MARUFUZZAMAN M, TSCHOPP M A, BIAN L. Porosity prediction: Supervised-learning of thermal history for direct laser deposition[J]. Journal of Manufacturing Systems, 2018, 47: 69-82.
[14] LEE S, PENG J, SHIN D, CHOI Y S. Data analytics approach for melt-pool geometries in metal additive manufacturing [J]. Science and Technology of Advanced Materials, 2019, 20(1): 972-978.
[15] ZHANG Z Y, LIU Z C, WU D Z. Prediction of melt pool temperature in directed energy deposition using machine learning [J]. Additive Manufacturing, 2021, 37: 101692.
[16] LIU Q, WU H K, PAUL M J, HE P D, PENG Z X, GLUDOVATZ B, KRUZIC J J, WANG C H, LI X P. Machine-learning assisted laser powder bed fusion process optimization for AlSi10Mg: New microstructure description indices and fracture mechanisms[J]. Acta Materialia, 2020, 201: 316-328.
[17] ARISOY Y M, CRIALES L E, ÖZEL T, LANE B, MOYLAN S, DONMEZ A. Influence of scan strategy and process parameters on microstructure and its optimization in additively manufactured nickel alloy 625 via laser powder bed fusion[J]. The International Journal of Advanced Manufacturing Technology, 2017, 90: 1393-1417.

中国知网 https://www.cnki.net

[18] KATS D, WANG Z D, GAN Z T, LIU W K, WAGNER G J, LIAN Y P. A physics-informed machine learning method for predicting grain structure characteristics in directed energy deposition [J]. Computational Materials Science, 2022, 202: 110958.

[19] ZHANG M, SUN C N, ZHANG X, GOH P C, WEI J, HARDACRE D, LI H. High cycle fatigue life prediction of laser additive manufactured stainless steel: A machine learning approach [J]. International Journal of Fatigue, 2019, 128: 105194.

[20] KUSANO M, MIYAZAKI S, WATANABE M, KISHIMOTO S, BULGAREVICH D S, ONO Y, YUMOTO A. Tensile properties prediction by multiple linear regression analysis for selective laser melted and post heat-treated Ti-6Al-4V with microstructural quantification [J]. Materials Science and Engineering: A, 2020, 787: 139549.

[21] TU Y, LIU Z, CARNEIRO L, RYAN C M, PARNELL A C, LEEN S B, HAEEISON N M. Towards an instant structure-property prediction quality control tool for additive manufactured steel using a crystal plasticity trained deep learning surrogate [J]. Materials & Design, 2022, 213: 110345.

[22] 李淑娟,陈文彬,刘永,符柳. 基于神经网络和遗传算法的三维打印工艺参数优化[J]. 机械科学与技术, 2014, 33(11): 1688-1693.
LI S J, CHEN W B, LIU Y, FU L. Optimization of the 3DP printing parameters based on the neural networks based on the neural networks [J]. Mechanical Science and Technology for Aerospace Engineering, 2014, 33(11): 1688-1693.

中国知网　https://www.cnki.net

图 1S 80 组实验焊道
Fig.1S The weld passes of the 80 WAAM experiments

表 1S WAAM 单层成形样本数据
Tab.1S The experimental results by WAAM

Sample number	Substrate temperature/°C	Wire feeding speed/(m·min^{-1})	Travel speed/(mm·s^{-1})	Weaving width/mm	Weld width/mm	Weld height/mm
1	40	6	4	4	7.73	5.83
2	40	10	6	8	10.40	4.58
3	40	12	12	7	8.08	3.78
4	40	14	8	6	12.08	3.90
5	80	6	6	6	5.61	4.33
6	80	8	12	4	5.56	3.37
7	80	10	8	10	11.46	3.29
8	80	12	4	8	13.18	5.42
9	80	14	10	7	10.65	3.39
10	120	8	4	6	7.63	5.21
11	120	10	10	4	7.08	3.30
12	120	12	6	10	11.84	3.47
13	120	14	12	8	11.74	4.25
14	40	7	3	4	7.99	6.54
15	40	11	5	8	12.24	4.86
16	40	13	11	7	12.59	4.75
17	80	7	5	6	6.45	4.67
18	80	9	11	4	7.04	3.20
19	80	11	7	10	13.73	3.80
20	80	13	3	8	13.08	6.98
21	80	14.5	9	7	12.42	4.21
22	160	9	5	7	8.75	4.92
23	160	11	11	6	10.85	3.39
24	160	13	7	4	10.07	4.02
25	160	14.5	3	10	14.52	6.72
26	40	6	3	4	8.00	6.75
27	40	10	5	8	10.18	4.71

中国知网 https://www.cnki.net

续表 1S　WAAM 单层成形样本数据

Tab.1S The experimental results by WAAM

Sample number	Substrate temperature/°C	Wire feeding speed/(m·min^{-1})	Travel speed/(mm/s^{-1})	Weaving width/mm	Weld width/mm	Weld height/mm
28	40	14	7	6	9.64	3.53
29	120	6	7	7	7.38	3.62
30	120	8	3	6	8.34	6.38
31	120	10	9	4	7.77	3.75
32	120	12	5	10	14.18	4.75
33	120	14	11	8	13.57	3.01
34	160	8	5	7	8.09	4.34
35	160	10	11	6	9.52	3.05
36	160	12	7	4	10.92	4.88
37	160	14	3	10	16.03	6.26
38	80	7	6	6	6.14	3.77
39	80	9	12	4	6.10	2.98
40	80	13	4	8	10.95	5.2
41	80	11	8	10	11.84	3.33
42	80	14.5	10	7	11.96	3.19
43	120	7	8	7	7.84	2.92
44	120	9	4	6	8.38	5.68
45	120	11	10	4	9.23	3.46
46	120	13	6	10	14.61	2.44
47	120	14.5	12	8	13.12	2.74
48	160	9	6	7	9.73	4.37
49	160	11	12	6	11.13	2.42
50	160	13	8	4	11.83	4.02
51	160	14.5	4	10	15.92	5.29
52	160	10	12	6	9.76	2.34
53	120	13	5	10	16.42	4.59
54	80	6	5	6	5.31	4.54
55	80	8	11	4	5.71	3.68
56	80	14	9	7	13.11	3.51
57	40	11	6	8	10.71	4.23
58	40	13	12	7	10.97	3.19
59	160	8	6	7	8.64	4.05
60	160	12	8	4	9.66	3.83
61	160	14	4	10	13.50	5.28
62	120	9	3	6	9.56	6.06
63	120	11	9	4	8.69	3.57
64	120	14.5	11	8	12.92	3.11
65	80	12	3	8	12.26	6.31
66	80	10	7	10	11.18	3.12
67	40	7	4	4	6.04	5.76
68	40	14.5	8	6	12.41	4.16

中国知网　https://www.cnki.net