

激光与光电子学进展

基于 BP 神经网络的激光熔覆参数多目标优化

邓德伟^{1,3*}, 江浩¹, 李振华¹, 宋学官², 孙奇³, 张勇³¹大连理工大学材料科学与工程学院辽宁省激光 3D 打印装备及应用工程技术研究中心, 辽宁 大连 116024;²大连理工大学机械工程学院, 辽宁 大连 116024;³沈阳鼓风机集团股份有限公司, 辽宁 沈阳 110869

摘要 为了获得 TiC 铁基合金粉末在 316L 不锈钢上的激光熔覆最佳工艺参数, 提出了一种基于遗传算法优化的反向传播(BP)神经网络的激光熔覆参数优化方法。设计三因素五水平的全因子试验, 测量了熔覆层的宏观形貌和平均硬度, 建立输入参数(激光功率、扫描速度、保护气流量)和响应量(熔覆层宽度、熔覆层高度、稀释率、显微硬度)的神经网络模型。以多元非线性回归分析工艺参数对响应量的影响, 并以综合灰关联度表征熔覆层的综合性能, 寻优得到最佳参数。试验结果表明, 激光功率和扫描速度对熔覆层宽度、稀释率和显微硬度的影响明显, 而保护气流量对熔覆层高度影响最显著, 遗传算法优化的 BP 神经网络模型各响应量模型的拟合优度均达到 0.85~0.91 之间, GA-BP 模型精度良好, 当参数为 1090 W, 扫描速度为 4.4 mm/s, 保护气流量为 10 L·min⁻¹, 综合性能最佳, 表明 BP 神经网络算法适用于激光熔覆层质量控制和参数优化。

关键词 激光熔覆; 反向传播神经网络; 遗传算法; 灰关联度; 参数优化

中图分类号 TN249

文献标志码 A

DOI: 10.3788/LOP221821

Multi-Objective Optimization of Laser Cladding Parameters Based on BP Neural Network

Deng Dewei^{1,3*}, Jiang Hao¹, Li Zhenhua¹, Song Xueguan², Sun Qi³, Zhang Yong³¹Research Center of Laser 3D Printing Equipment and Application Engineering Technology (Liaoning Province), School of Materials Science and Engineering, Dalian University of Technology, Dalian 116024, Liaoning, China;²School of Mechanical Engineering, Dalian University of Technology, Dalian 116024, Liaoning, China;³Shenyang Blower Group Corporation, Shenyang 110869, Liaoning, China

Abstract In order to obtain the optimal process parameters for laser melting of TiC iron-based alloy powder on 316L stainless steel, a back propagation (BP) neural network based on genetic algorithm optimization for laser melting parameters optimization is proposed. A three-factor, five-level full factorial experiment was designed to measure the macroscopic morphology and average hardness of the melted layer, and a neural network model was established for the input parameters (laser power, scanning speed, and protective gas flow rate) and response quantities (melted layer width, melted layer height, dilution rate, and microhardness). The effect of the process parameters on the response quantity was analyzed by multiple non-linear regression, and the overall performance of the clad layer was characterized by the integrated gray correlation, and the optimal parameters were obtained. The experimental results show that the laser power and scanning speed have obvious effects on the width of the molten layer, dilution rate and microhardness, while the protective gas flow rate has the most significant effect on the height of the molten layer. The goodness of fit of each response quantity model of the BP neural network model optimized by the genetic algorithm reaches between 0.85 and 0.91, and the GA-BP model has good accuracy. The best overall performance was achieved when the parameter was 1090 W, the scanning speed was 4.4 mm/s, and the protective gas flow rate was 10 L/min, indicating that the BP neural network algorithm was suitable for the quality control and parameter optimization of the laser cladding layer.

Key words laser cladding; back propagation neural network; genetic algorithm; gray correlation; parameter optimization

收稿日期: 2022-06-12; 修回日期: 2022-07-05; 录用日期: 2022-08-05; 网络首发日期: 2022-08-15

基金项目: 辽宁重大装备制造协同创新中心基金(DUT2017031)、高端控制阀产业技术协同创新中心基金(2018WZ003)

通信作者: *cailiaoqingqibing@163.com

1 引言

激光熔覆作为一种表面加工技术,是指利用高能量密度的激光束,使熔覆粉末与金属基材表层一起快速熔凝,形成与基材表面冶金结合状态良好的表面改性技术^[1-2]。与其他表面加工技术相比,激光熔覆层具有良好的韧性、耐热性、抗氧化性、耐冲击性和良好的耐蚀性能。因此,激光熔覆技术在机械、化工、电力、冶金和船舶等领域都有广泛的运用^[3-4]。

304 不锈钢具有优秀的耐腐蚀性、耐高温和机械特性等特点,被广泛应用于建材、化工和食品等领域。但是其屈服强度低、硬度低等缺点,限制了其更加广泛的应用,因此需要对它进行表面强化。研究发现,利用激光熔覆技术在 304 不锈钢的表面制备合金涂层能够显著提升其表面性能。常用的合金粉末有铁基^[5]、钴基^[6]和镍基^[7]合金粉末,其中铁基合金粉末具有润湿性好、成本低的优点,应用范围较广。

激光熔覆技术仍有一些问题需要解决,如存在气孔、裂纹等缺陷,组织成分不均匀,成形质量难以控制等。激光熔覆层最终的成形质量主要是受工艺参数的影响,并且熔覆过程中存在较多的不可控因素,对熔覆层的成形质量控制有更高的要求。另一方面,影响熔覆层质量的工艺参数比较多,如激光功率、扫描速度、光斑直径、送粉量等都是熔覆层质量的主要影响因素。研究发现,这些工艺参数与熔覆层质量之间的关系是非线性的,很难找到一个精确的数学模型来表述。目前获取合适工艺参数,最常用的方法还是通过大量的试验来积累经验,但是这种方法时间成本和经济成本较高。因此,对工艺参数与熔覆层质量之间的相关性研究具有十分重要的现实意义。

目前,在工艺参数与熔覆层质量之间建立联系的主要方法有:响应面法(RSM)^[8]、回归分析法^[9]、反向传播(BP)神经网络法^[10]、遗传算法(GA)^[11-12]等。利用上述优化算法,建立预测模型,从而实现参数优化是目前热门的研究方向。王燕燕等^[13]采用响应面法和非支配排序遗传(NSGA-II)算法相结合的激光熔覆参数优化方法,构建了激光熔覆工艺参数(激光功率、扫描速度、送粉速率)与响应值的预测模型,对工艺参数进行寻优,最终发现最优工艺参数下稀释率、热影响区深度和显微硬度等显著增加。杨思瑞等^[14]运用人工神经网络建立激光工艺参数为输入、熔覆层形貌为输出的预测模型,采用反向传播神经网络和遗传算法相结合的方法对激光熔覆过程的工艺参数进行优化。李琦等^[15]采用试验与仿真相结合的方法,以单道单层熔覆层为研究对象,建立了以加工工艺参数对熔覆层面积和熔覆层气孔率进行预测的基于 BP 神经网络的预测模型,基于 BP 神经网络的预测模型对熔覆层面积的预测和气孔率的预测精度较高。陈书翔等^[16]利用 BP 神经网络建立

单、双隐藏层模型,最终发现,BP 神经网络能很好地预测熔覆层的形貌,而且双隐含层 BP 神经网络模型预测结果的误差波动更小,最大预测误差比单隐含层神经网络大大降低。Wang 等^[17]采用响应面法,基于复合材料中心设计,研究了工艺参数对 AISI 1045 中碳钢 Fe50/TiC 激光熔覆层形貌质量的影响,通过回归分析建立了灰色关联度(GRC)与工艺参数之间的相关性。结果表明,GRC 响应模型具有良好的拟合性和预测性能。范鹏飞等^[18]分别运用多元线性回归分析和人工神经网络方法,建立关键工艺参数与熔覆层宏观形貌之间的关系模型,并将试验结果与模型预测结果进行对比,结果表明,神经网络对熔覆层形貌的预测更精准。

从上述文章的研究结果可以看出,建立工艺参数与熔覆层质量数据之间的模型,利用各种方法优化模型,实现熔覆层质量的预测和工艺参数的优化是近些年主要的研究方向^[19-22]。但是,将神经网络算法和灰关联度相结合,并利用其进行参数多目标优化的研究还比较少。本文选择遗传算法来优化 BP 神经网络,建立 GA-BP 神经网络预测模型,设计 3 因素 5 水平的试验并测量熔覆层高度、宽度、稀释率以及硬度,以熔覆工艺参数为输入,分别以上述 4 种熔覆层性能数据为输出,通过 GA-BP 神经网络算法建立工艺参数和熔覆层性能之间的数学模型并根据试验得到的样本数据进行训练和测试,验证 GA-BP 神经网络模型的预测精度,寻找最优性能的参数组合。并利用综合灰关联度表征综合性能,利用 4 种 GA-BP 神经网络模型预测未知的参数组性能数据,实现在一定参数范围内寻找最佳的综合性能,对制备优形貌高质量的熔覆层具有一定的指导意义。

2 试验材料和方法

2.1 试验材料

试验选择 304 不锈钢作为基板,尺寸为 55 mm×15 mm×13 mm,熔覆前用砂纸打磨表面,并放在无水乙醇中超声清洗 5 min。熔覆粉末选择 Ferro 55 合金粉末与 TiC 粉末的混合物,质量比为 7:3,粉末粒径为 50~430 μm,粉末形貌如图 1 所示,试验前对粉末进行烘干处理。熔覆基板和粉末化学成分如表 1 所示。




图 1 熔覆粉末形貌

Fig. 1 Morphology of cladding powder

表 1 基体和 Ferro 55 合金粉末的化学成分
Table 1 Chemical composition of the substrate and Ferro 55 alloy powder

Material	Mass fraction / %								
	C	Mn	P	S	Si	Cr	Ni	Fe	Mo
304 stainless steel	≤0.08	≤2.00	≤0.045	≤0.030	≤1.00	18.0-20.0	8.0-11.0	Bal.	—
Ferro 55	0.35	1.1	—	—	0.3	7	—	Bal.	2

2.2 试验设备

本试验采用的激光熔覆试验设备为 RS-LCD-4000-D-R 型光纤激光器,图 2 为试验平台示意图。试验设备包括 Laserline 半导体激光器、KUKA 六轴机器人、Precitec 的 YC52 同轴送粉激光熔覆喷嘴和冷水机。激光束由激光器产生,经光纤传输到激光熔覆头后进行聚焦输出,高纯氩气作为保护气体,通过管路输送到熔覆头内部并吹出,防止熔覆层被氧化。

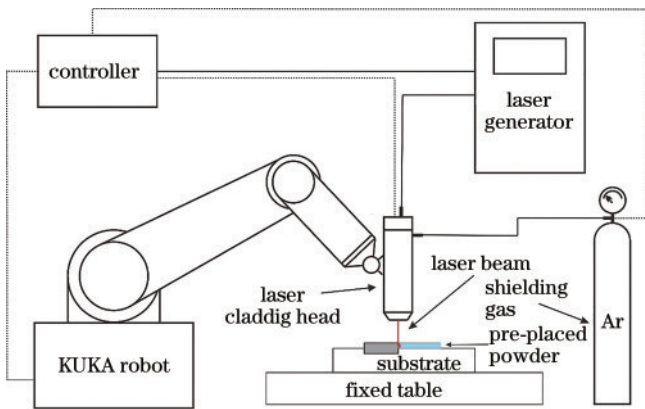


图 2 激光熔覆系统示意图

Fig. 2 Schematic diagram of laser cladding system

2.3 试验方法

本试验采用预置粉方式,预置粉长度为 55 mm,宽

度为 3 mm,厚度为 2 mm,喷嘴距离粉末顶层选定为 15 mm,光斑直径为 3 mm。试验中激光熔覆保护气为氩气,试验温度为室温。本试验设置了 3 个工艺参数,分别为激光功率(LP)、扫描速度(SS)和保护气流量(FG),采用全因子试验设计进行单道激光熔覆试验,试验因素水平表如表 2 所示。然后,选择成形良好无明显缺陷的熔覆层作为样品,熔覆层样品截面示意图如图 3 所示,并将激光熔覆层进行切割、打磨、抛光和腐蚀后,采用 Nikon MA-100 光学显微镜(OM)观察熔覆层形貌特征,使用图像处理软件在金相图片中测定熔覆层高度、宽度和稀释率。采用 MVC-1000B 型维氏硬度计测量熔覆试样横截面的维氏硬度,得到的每个熔覆层的形貌数据和硬度性能数据如表 3 所示。其中, W 表示熔覆层宽度, H 表示熔覆层高度, d 表示熔覆层深度, η 表示熔覆层稀释率, DH 表示熔覆层硬度(维氏)。熔覆层稀释率计算方法为

$$\eta = \frac{H}{H + d} \quad (1)$$

将所有熔覆层的加工参数与各性能测量值建立多元非线性模型,进行非线性回归分析。将所有熔覆层的加工参数作为输入层,各性能测量作为输出层,建立 BP 神经网络模型,分析其训练过程及精度。采用遗传算法优化 BP 神经网络的初始权值和阈值,建立 GA-BP 神经网络模型,分析其训练过程及精度。

表 2 全因子试验水平表

Table 2 Full factor experiment level table

Process parameter	Notation	Level					
Laser power /W	LP	1000	1200	1400	1600	1800	
Scanning speed / (mm·s ⁻¹)	SS	4	5	6	7	8	
Flow rate of protective gas / (L·min ⁻¹)	FG	6	7	8	9	10	

表 3 部分样品的形貌数据和硬度数据

Table 3 Morphological data and hardness data of some samples

No.	LP /W	SS / (mm·s ⁻¹)	FG / (L·min ⁻¹)	W / μ m	H / μ m	η /%	DH /HV
1	1000	4	6	3775.811	1085.781	18.394	893.50
2	1000	4	7	3839.020	1230.670	19.766	640.44
3	1000	4	8	3653.007	1149.451	24.586	816.16
4	1000	4	9	3749.740	1101.470	26.765	631.60
5	1000	4	10	3843.952	963.0877	33.214	643.54
6	1000	5	6	3620.063	1200.113	17.523	878.22
7	1000	5	7	3589.932	1429.445	6.577	951.22
8	1000	5	8	3632.841	1128.766	17.657	847.00

表 3 (续)

No.	LP /W	SS / (mm·s ⁻¹)	FG / (L·min ⁻¹)	W /μm	H /μm	η /%	DH /HV
9	1000	5	9	3633.135	1113.519	20.976	822.62
10	1000	5	10	3395.680	1021.660	23.473	832.60
11	1000	6	6	3378.067	1241.917	11.610	848.58
12	1000	6	7	3380.289	1159.290	13.168	833.76
13	1000	6	8	3549.465	1399.060	3.687	954.66
14	1000	6	9	3596.015	1002.324	20.108	749.00
15	1000	6	10	3431.845	986.5434	23.052	665.12
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
116	1800	7	6	3983.089	1296.855	28.123	705.48
117	1800	7	7	3904.384	1268.997	28.857	667.70
118	1800	7	8	3624.623	1208.514	34.520	566.60
119	1800	7	8	4292.723	1396.216	19.470	821.52
120	1800	7	10	3374.230	746.500	46.727	480.96
121	1800	8	6	3842.054	1322.708	24.122	814.26
122	1800	8	7	3834.420	1294.360	21.603	762.53
123	1800	8	8	3917.358	1266.675	26.265	733.98
124	1800	8	9	3280.512	1314.897	24.122	575.80
125	1800	8	10	3953.457	984.4884	31.864	595.90




图 3 激光熔覆层示意图

Fig. 3 Schematic diagram of laser cladding coating

3 试验结果及分析

3.1 多元非线性回归分析

本文以激光参数为输入量,以稀释率、显微硬度、熔覆层宽度和熔覆层高度为输出变量,建立非线性回归模型。在这类模型中,影响因素与响应量的关联使用函数 a 表示,作为响应函数, ϵ 作为误差,其数学函数表示为 $y = a_0 + a_1x_1 + a_2x_2 + a_3x_3 + a_{11}x_1^2 + a_{22}x_2^2 +$

$$a_{33}x_3^2 + a_{12}x_1x_2 + a_{13}x_1x_3 + a_{23}x_2x_3 + \epsilon, \quad (2)$$

式中: $a_0, a_1, a_2, \dots, a_{23}$ 均为常数,也称为偏回归常数。其中, a_1, a_2, a_3 为与主要参数相关的系数, a_{11}, a_{22}, a_{33} 为二次项系数, a_{12}, a_{13}, a_{23} 为交互系数。借助 MINITAB 19,利用试验数据获得函数各项的系数。所得到的二次模型中激光熔覆层的高度、宽度、稀释率和显微硬度公式为

$$W = 2943 + 2.333P_{LP} - 349P_{SS} + 55P_{FG} - 0.000386P_{LP} \times P_{LP} + 6.4P_{SS} \times P_{SS} - 1.63P_{FG} \times P_{FG} + 0.0379P_{LP} \times P_{SS} - 0.0806P_{LP} \times P_{FG} + 9.36P_{SS} \times P_{FG}, \quad (3)$$

$$H = -205 + 0.487P_{LP} - 45.3P_{SS} + 292.1P_{FG} - 0.000123P_{LP} \times P_{LP} - 1.32P_{SS} \times P_{SS} - 19.74P_{FG} \times P_{FG} - 0.0037P_{LP} \times P_{SS} - 0.0225P_{LP} \times P_{FG} - 0.25P_{SS} \times P_{FG}, \quad (4)$$

$$\eta = -10.1 + 0.0933P_{LP} - 6.23P_{SS} - 6.54P_{FG} - 0.000028P_{LP} \times P_{LP} + 0.368P_{SS} \times P_{SS} + 0.598P_{FG} \times P_{FG} - 0.000483P_{LP} \times P_{SS} - 0.001096P_{LP} \times P_{FG} - 0.358P_{SS} \times P_{FG}, \quad (5)$$

$$D_{DH} = 1225 - 1.119P_{LP} + 150.4P_{SS} + 0.2P_{FG} + 0.000336P_{LP} \times P_{LP} - 9.66P_{SS} \times P_{SS} - 0.66P_{FG} \times P_{FG} + 0.0062P_{LP} \times P_{SS} - 0.0187P_{LP} \times P_{FG} - 0.28P_{SS} \times P_{FG}. \quad (6)$$

3.1.1 对稀释率的方差分析

表 4 显示了稀释率方差分析的结果。表中,df 为自由度,SSD 为平方和,MS 为均方和, F 值为拟合模型的显著性, F 值越大,表明模型拟合度越好, P 值是衡量组间差异大小的指标, P 值越小,表明对象越显著。激光功率项、激光功率平方项和保护气流量平方项的 P 值最小,且均小于 0.05,表明上述几项均为影响稀释率的显著因素,而其他项则影响不显著。表中模型总结显示,拟合优度 R^2 值为 87.21%,说明该模型在预测方面具有较高的精度。图 4(a) 为稀释率的帕累托图,可以看出,超出虚线的直方图也为激光功率项、激光功率平方项和保护气流量平方项,再次表明这三项对稀释率的影响最大。图 4(b) 为各激光参数对稀释率的

表 4 稀释率的方差分析结果

Table 4 Analysis of variance results for dilution rates

Source	df	Adjusted SSD	Adjusted MS	F value	P value
Model	9	13640.0	1515.56	87.10	0.000
LP	1	451.4	451.37	25.94	0.000
SS	1	60.6	60.61	3.48	0.065
FG	1	47.6	47.59	2.74	0.101
LP×LP	1	429.8	429.80	24.70	0.000
SS×SS	1	47.5	47.50	2.73	0.101
FG×FG	1	126.3	126.29	7.26	0.008
LP×SS	1	4.7	4.67	0.27	0.605
LP×FG	1	23.8	23.83	1.37	0.244
SS×FG	1	64.0	64.01	3.68	0.058
Residual	115	2001.0	17.40		
Lack of fit	114	1887.7	16.56	0.15	0.990
Pure error	1	113.3	113.25		
Cor total	124	15641.0			

S=4.17128 R²=87.21% Adjusted R²=86.21% Predicted R²=84.98%

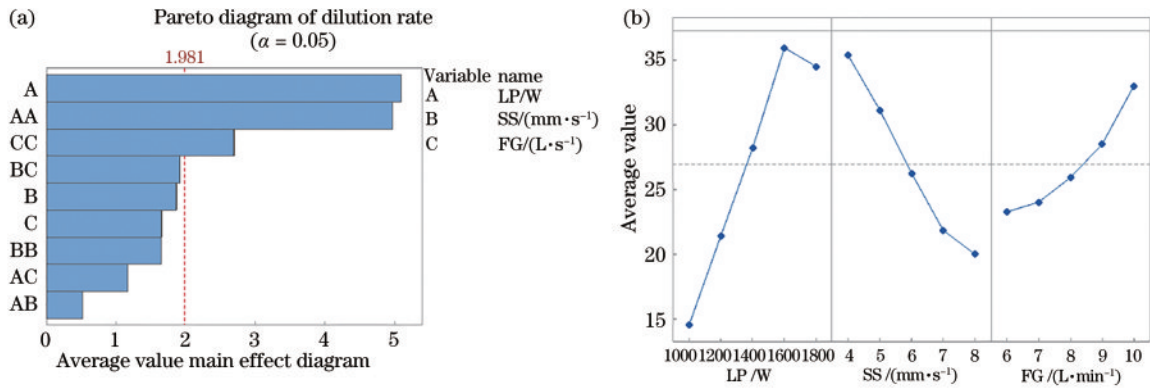


图 4 稀释率帕累托图和主效应图。(a)帕累托图;(b)主效应图

Fig. 4 Pareto and main effects plots of dilution rates. (a) Pareto chart; (b) main effects chart

主效应图,可以看出不同工艺参数对稀释率的影响,稀释率与保护气流量成正比,与扫描速度成反比,与激光功率呈现出先增大后减小的关系。

3.1.2 对显微硬度的方差分析

从表 5 可以看出, F 值较高的为激光功率项、激光功率平方项、扫描速度项,且这三项的 P 值均小于 0.05,说明显微硬度主要受这三项的影响,且影响程度从大到小依次为激光功率、激光功率平方、扫描速度,保护气流量影响极小。图 5(a)为显微硬度的帕累托图,图中超出虚线的部分为激光功率和激光功率的平方项,说明激光功率是显微硬度的最主要影响因素。图 5(b)为各激光参数对显微硬度的主效应图,可以看出不同工艺参数对显微硬度的影响,在一定范围内,稀释率与保护气流量成反比,与激光功率呈现出先减小后增大的关系,与扫描速度呈现先增大后减小的趋势。

3.1.3 对高度的方差分析

表 6 显示了高度方差分析的结果,保护气流量和保护气流量平方项的 P 值最小,且均小于 0.05,而其他项 P 值均大于 0.05,这表明仅保护气流量为影响稀释率的显著因素,而其他项则影响不显著。图 6(a)为高度的帕累托图,可以看出只有保护气流量和保护气流量的平方项超出虚线,再次证实了保护气流量对高度影响程度最大。另一方面,从图 6(b)可以看出,不同工艺参数对稀释率的影响,高度与扫描速度成正比,与保护气流量成反比,而在激光功率作用下上下小幅度波动,说明激光功率对高度影响较小。

3.1.4 对宽度的方差分析

表 7 显示了宽度方差分析的结果,激光功率、扫描速度和激光功率与保护气流量的相关项的 P 值小于 0.05,表明这三项为影响稀释率的显著因素。图 7(a)为宽度的帕累托图,超过虚线的项为激光功率、扫描速度和激光功率与保护气流量的相关项,证实了这三项

表 5 显微硬度的方差分析结果

Table 5 Analysis of variance results for micro hardness

Source	df	Adjusted SSD	Adjusted MS	F value	P value
Model	9	1768213	196468	22.00	0.000
LP	1	64966	64966	7.27	0.008
SS	1	35281	35281	3.95	0.049
FG	1	0	0	0.00	0.998
LP×LP	1	63104	63104	7.07	0.009
SS×SS	1	32684	32684	3.66	0.058
FG×FG	1	153	153	0.02	0.896
LP×SS	1	768	768	0.09	0.770
LP×FG	1	6929	6929	0.78	0.380
SS×FG	1	40	40	0.00	0.947
Residual	115	1027151	8932		
Lack of fit	114	994659	8725	0.27	0.944
Pure error	1	32492	32492		
Cor total	124	2795364			
S=94.5079		R ² =63.26%	Adjusted R ² =60.38%	Predicted R ² =57.00%	

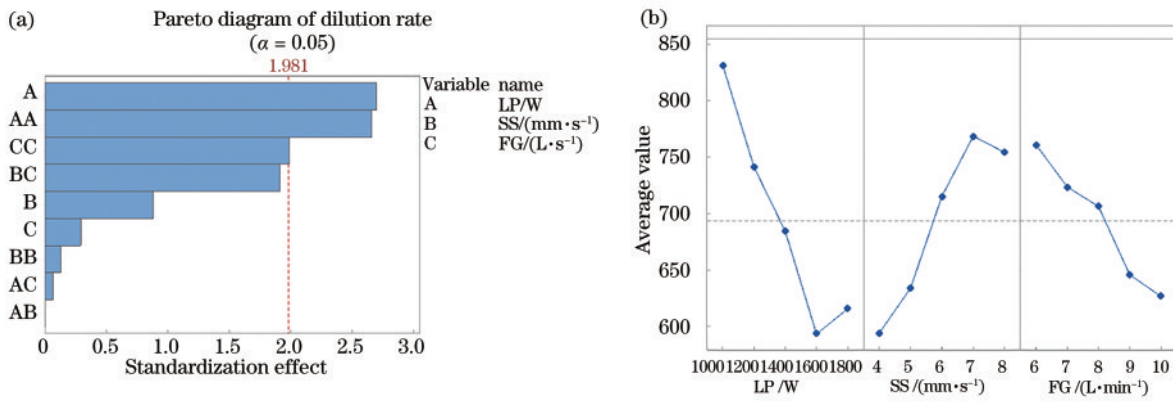


图 5 显微硬度的帕累托图和主效应图。(a)帕累托图；(b)主效应图

Fig. 5 Residual and main effects plots of micro hardness. (a) Pareto diagram; (b) main effect diagram

表 6 高度的方差分析结果

Table 6 Analysis of variance results for height

Source	df	Adjusted SSD	Adjusted MS	F value	P value
Model	9	1114720	123858	12.60	0.000
LP	1	12319	12319	1.25	0.265
SS	1	3196	3196	0.33	0.570
FG	1	95049	95049	9.67	0.002
LP×LP	1	8421	8421	0.86	0.357
SS×SS	1	612	612	0.06	0.803
FG×FG	1	137532	137532	14.00	0.000
LP×SS	1	273	273	0.03	0.868
LP×FG	1	10017	10017	1.02	0.315
SS×FG	1	31	31	0.00	0.955
Residual	115	1130072	9827		
Lack of fit	114	1112456	9758	0.55	0.818
Pure error	1	17616	17616		
Cor total	124	2244792			
S=99.1298		R ² =49.66%	Adjusted R ² =45.72%	Predicted R ² =39.58%	

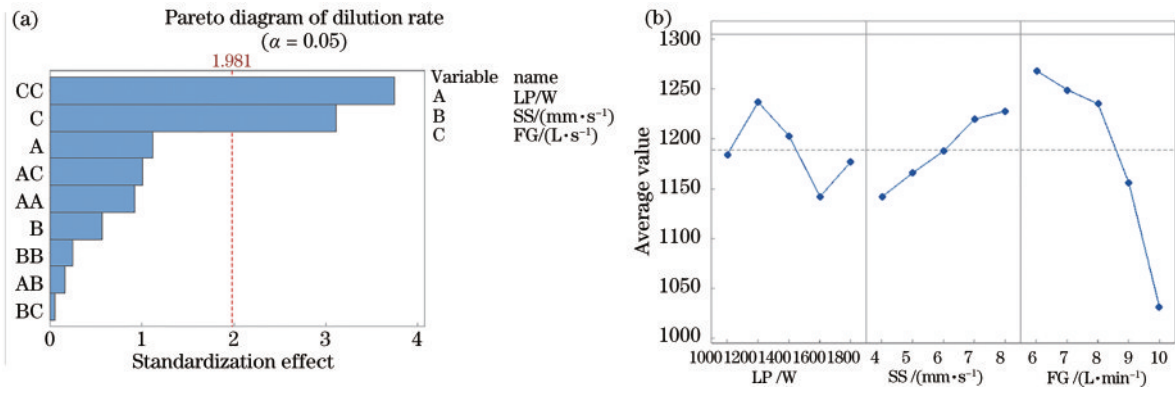


图 6 高度的帕累托图和主效应图。(a)帕累托图;(b)主效应图
Fig. 6 Pareto and main effects plots of height. (a) Pareto chart; (b) main effects chart

影响显著。图 7(b)为主效应图,可以看出不同工艺参数对宽度的影响,宽度与激光功率成正比,与扫描速度

成反比,而宽度随保护气流量变化而上下小幅度波动,说明保护气流量对高度影响较小。

表 7 宽度的方差分析结果

Table 7 Analysis of variance results for width

Source	df	Adjusted SSD	Adjusted MS	F value	P value
Model	9	12073380	1341487	45.55	0.000
LP	1	218954	218954	7.44	0.007
SS	1	123178	123178	4.18	0.043
FG	1	19186	19186	0.65	0.421
LP×LP	1	33293	33293	1.13	0.290
SS×SS	1	154	154	0.01	0.943
FG×FG	1	6926	6926	0.24	0.629
LP×SS	1	28494	28494	0.97	0.327
LP×FG	1	200091	200091	6.79	0.010
SS×FG	1	43861	43861	1.49	0.225
Residual	115	3386568	29448		
Lack of fit	114	3163389	27749	0.12	0.995
Pure error	1	223179	223179		
Cor total	124	15459948			
S=171.605		R ² =78.09%	Adjusted R ² =76.38%	Predicted R ² =74.06%	

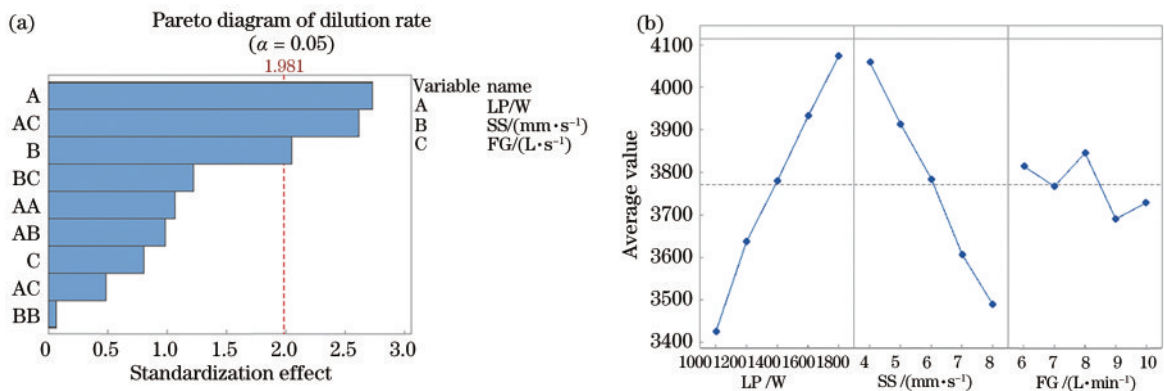


图 7 宽度帕累托图和主效应图。(a)帕累托图;(b)主效应图
Fig. 7 Pareto and main effects plots of width. (a) Pareto chart; (b) main effects chart

3.2 GA-BP神经网络分析

3.2.1 BP神经网络原理

BP神经网络采用误差反向传播算法,通过学习输

入样本和输出样本,根据预测值与真实值的误差比较,进而调整网络连接的权值,使得网络的实际输出逐渐接近真实值。BP神经网络的训练过程由前向传播与

反向传播组成:前向传播由输入层向输出层正向计算各个节点输出值,最终得到网络输出;反向传播基于误差函数的梯度从输出层向输入层反向更新网络参数。在训练过程中,前向传播与反向传播交替进行,直到误差收敛,完成网络训练。

典型的BP神经网络结构原理图如图8所示。




图 8 BP神经网络示意图

Fig. 8 Schematic diagram of BP neural network

神经网络一般分为输入层、隐含层和输出层,其中输入层为外部信号输入部分,隐含层介于输入层与输出层之间,输出层主要负责模型处理后预测结果的输出,且每一层神经元的状态只会对下一层产生影响^[23]。

本文样本参数因子为3,选定输入层层数为3,输出层固定为1,根据经验公式,利用黄金分割法对不同隐含层神经元数目的网络模型进行训练,发现当 m 值为3时,其误差最小,拟合效果最好,故隐含层神经元个数选定为3。

$$h = \sqrt{m + n} + a, \quad (7)$$

式中: m 为输出端神经元数量; n 为输入端神经元数量; a 为[1,10]之间的常数

本文训练四个不同的BP神经网络,分别对熔覆层高度、宽度、稀释率和硬度训练BP神经网络模型,其方法步骤如下:

- 1) 初始化网络参数,初始化每一层的权值和阈值;
- 2) 导入训练集,将所有参数组合和性能数据作为样本训练集;
- 3) 训练集的输入值前向传播得到网络输出值;
- 4) 计算网络预测值和真实值的均方误差;
- 5) 以反向传播的方式计算权值和阈值,并更新;
- 6) 检验误差是否满足设置的需求,如满足,则训练停止,如不满足,则返回第2步再次训练。

3.2.2 GA-BP神经网络模型训练方法

BP神经网络模型的权值和阈值具有随机性,会导致网络训练效果不稳定,训练神经网络容易出现过拟合现象,使得模型陷入局部最优解。结合遗传算法优化神经网络初始的权值和阈值,可以有效避免这一现象,并提升模型的预测精度。遗传算法优化的BP神经网络训练方法具体步骤如图9所示。

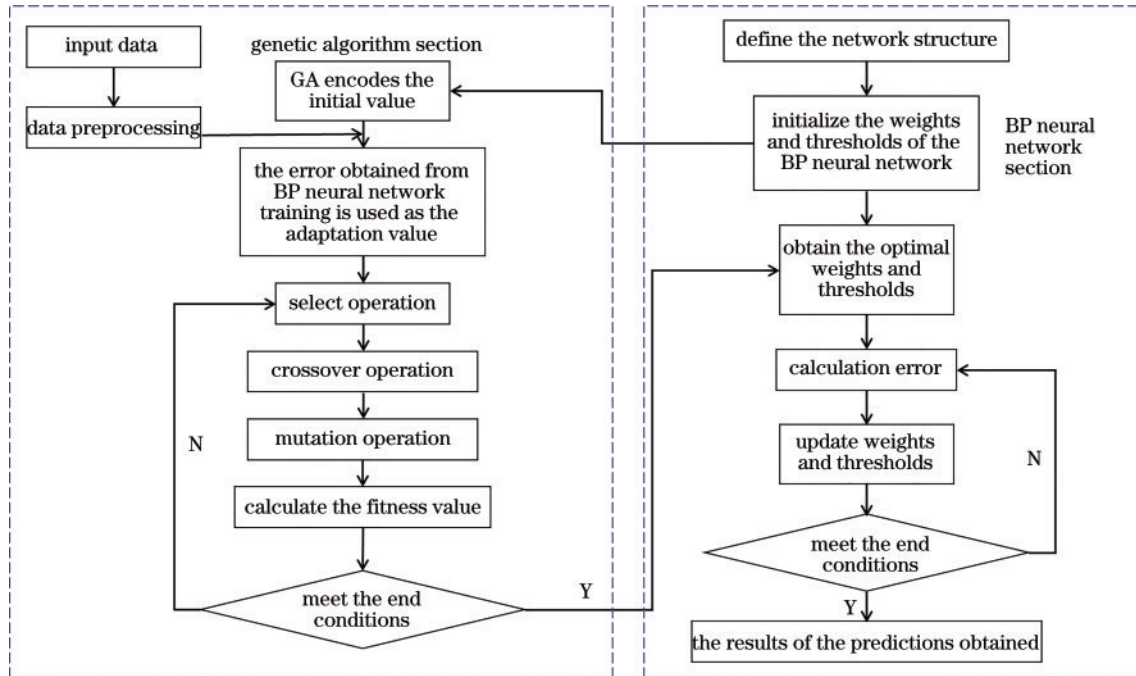


图 9 GA-BP神经网络流程图

Fig. 9 GA-BP neural network flow chart

在训练 BP 神经网络模型之前,需要对各样品参数和性能数据进行归一化处理,为了防止由于各数据量纲不一致而导致差异化过大,无法进行网络训练。将所有数据转化为 $[0,1]$ 之间

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}}, \quad (8)$$

式中: X_{\max} 、 X_{\min} 分别为样本的最大值和最小值。

采用 Levenberg-Marquardt 函数对该网络模型进行训练,迭代次数设定为 1000 次,目标误差设定为 0.000001,学习效率设定为 0.01。将上述试验数据作为训练样本,随机抽取 10 组作为测试样本。将归一化

处理后的数据加载到 BP 神经网络模型后,进行训练,直到满足设定的精度或者达到最大迭代次数为止。

3.2.3 GA-BP 神经网络结果分析

本试验选取 125 组样本数据作为训练样本,选取其中 10 组数据作为测试数据。将所有输入数据和输出数据加载到 GA-BP 神经网络中进行训练,当网络训练结果达到预先设定的精度要求或达到最大迭代次数时训练完成,再利用 10 组测试数据集对神经网络进行测试,验证训练完毕后的 GA-BP 神经网络模型的精度。其中,测试值和预测值的熔覆层宽度、高度、稀释率和硬度的对比曲线与决定系数 R^2 如图 10 所示。

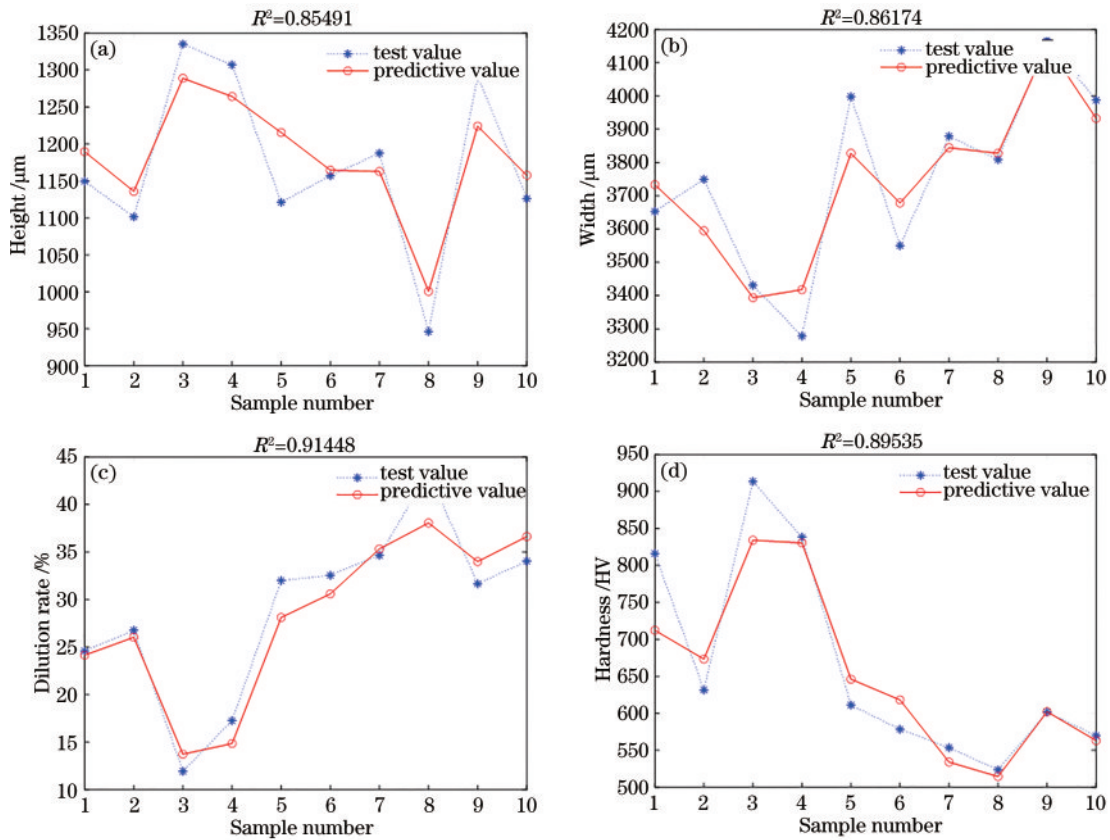


图 10 响应量测试值和预测值的对比曲线与决定系数 R^2 。(a)高度;(b)宽度;(c)稀释率;(d)硬度

Fig. 10 Comparison curves of response volume test and predicted values with coefficient of determination R^2 . (a) Height; (b) width; (c) dilution rate; (d) hardness

从图 10 中可以得出,GA-BP 神经网络预测模型得到的输出值与样本试验值的偏差都较小,宽度、高度、稀释率和硬度的决定系数 R^2 分别为 0.85、0.86、0.91 和 0.89,说明 GA-BP 神经网络预测模型已经具备很高的预测精度。

可以看出,图 11(a)宽度和图 11(c)稀释率的预测值和期望值效果最好,相关系数 R 达到 0.9 左右,图 11(d)中的宽度拟合效果也非常好,相关系数 R 也在 0.8 左右。而图 11(b)中,高度的预测值和期望值的拟合效果相对差一些,总体 R 值在 0.7 左右。一般认为,训练模型过程中出现相关系数 R 值稍低的情况,原因主要有以下三个方面:1)样本在试验过程和数

据集中,测量值与真实值之间存在一定的测量误差,而神经网络模型的精度非常依赖样本,若训练数据存在噪声,则神经网络模型很难达到预期的性能;2) GA-BP 神经网络模型存在一定程度的不足,神经网络的结构、神经网络设置的相关参数等都会影响模型的训练过程以及精度;3)本次样本采集的数据较少,导致对于网络训练的精度无法达到很高的要求。

3.3 灰关联度分析

3.3.1 灰关联度分析原理

灰关联分析是一种以灰关联度数值大小为标准,判断各因素间关系强弱次序的分析方法,其基本思想是:以因素的数据列为依据,用数学方法研究因素间的




图 11 响应量预测与期望值拟合图。(a)宽度;(b)高度;(c)稀释率;(d)硬度

Fig. 11 Plot of predicted and expected value fit of response volume. (a) Width; (b) height; (c) dilution rate; (d) hardness

几何对应关系。采用灰关联度衡量多目标的完成情况,换句话说,灰关联分析是对实际试验中所存在的多项工艺指标的优化问题,以灰关联度为标准,转化为单项灰关联度优化问题,实现对多项工艺指标的优化,同时可得到经优化的最优参数组合方案。

本文追求得到一定参数范围内的最佳综合性能所对应的参数组。在本试验中,在激光功率、扫描速度、保护气流量这三个参数范围内,以稀释率、显微硬度、熔覆层宽度和熔覆层高度四个指标的灰关联度得到的最优参数组合,将更能真实有效地反映出各工艺参数对加工过程的影响程度。

3.3.2 灰关联度分析方法

灰关联度分析法共有三个步骤,分别为归一化处

理、灰关联系数计算、灰关联度计算。

第一步需对 4 个性能检测数据进行统一量纲化处理,统一量纲化处理分为望大望小和望目,望大(LTB)表示越大越好,望小(STB)表示越小越好,望目(NTB)表示越接近目标值越好,具体计算公式为

$$X_i(k) = \begin{cases} \frac{Y_i(k) - \min Y_i(k)}{\max Y_i(k) - \min Y_i(k)}, & \text{LTB} \\ \frac{\max Y_i(k) - Y_i(k)}{\max Y_i(k) - \min Y_i(k)}, & \text{STB} \\ \frac{\max |Y_i(k) - a(k)| - |Y_i(k) - a(k)|}{\max |Y_i(k) - a(k)| - \min |Y_i(k) - a(k)|}, & \text{NTB} \end{cases}, (9)$$

式中： $X_i(k)$ 为第 k 个组织特征的第 i 组试验数据的归一化值； $Y_i(k)$ 为第 k 个组织特征的第 i 组试验数据值； $\max Y_i(k)$ 和 $\min Y_i(k)$ 分别代表第 k 个组织特征的最大值和最小值。本试验中，熔覆层宽度响应量选择望大，熔覆层高度选择望小，稀释率选择望目 30%，硬度选择望大。

第二步，按式(9)分别计算不同响应量的灰关联系数，灰关联系数表示上述归一化数据与理想值之间的关系，响应量的灰关联系数值越高，代表其值越符合期望。

$$C_{\text{GRC}_i}(k) = \frac{\min_i |x_i^0 - x_i(k)| + \xi \max_i |x_i^0 - x_i(k)|}{|x_i^0 - x_i(k)| + \xi \max_i |x_i^0 - x_i(k)|}, \quad (10)$$

式中： $C_{\text{GRC}_i}(k)$ 为第 k 个组织特征的第 i 组试验的灰关联系数值； x_i^0 为试验的理想值，在本研究中 $x_i^0 = 1$ ； ξ 为分辨系数，其取值范围为 0~1，本研究中 $\xi = 0.5$ 。

最后，按式(10)计算灰关联度，用于综合评价熔覆层的性能，灰关联度越大，表明熔覆层的综合性能越好。

$$C_{\text{GRC}_i} = \frac{1}{n} C_{\text{GRC}_i}(k), \quad (11)$$

式中： C_{GRC_i} 为第 i 组试验的灰关联度值； n 为响应量的数量，本研究中 $n = 4$ 。

将 4 个响应量数据作为分析的原始数据，利用灰关联分析方法可以得到 125 组灰关联度，其结果如表 8 所示。

从表 8 可以看出，125 组样品的灰关联度范围 0.3947~0.6250，其中样品 106 的灰关联度最高为 0.6250，说明当激光功率为 1800 W，扫描速度为 $4 \text{ mm}\cdot\text{s}^{-1}$ 和保护气流量为 $6 \text{ L}\cdot\text{min}^{-1}$ 时，其综合性能最好。

本文在此基础上，研究寻找更优的综合性能参数。本试验在激光功率、扫描速度和保护气流量三种激光参数上设置更小的上升梯度，得到参数分布更密集的样品组。具体参数水平设计如表 9 所示。

由此方法设计全因子参数组，共可得到 29889 组参数，表中未知的性能数据，采取用上述 4 种 GA-BP 神经网络模型的预测值并代入其中，由此得到的参数数据和性能数据，将所有参数组的性能数据按照式(7)~(9)计算得出灰关联度，最终得到细化的工艺参数对应的灰关联度，部分工艺参数与其灰关联度的相互关系如图 12 所示。

图 12 为部分工艺参数与灰关联度的三维阵点图，每个阵点方块的颜色深浅变化代表灰关联度的变化。可以看出，灰关联度变化最小有小于 0.43，最大有大于 0.67，说明细化工艺参数，灰关联度的最大值得到了明显的提升。图中 0.52~0.58 之间的阵点颜色占比最大，说明参数范围内的大部分灰关联度都在中等

表 8 部分样品的灰关联度
Table 8 Gray correlation degree of some samples

No.	LP /W	SS / ($\text{mm}\cdot\text{s}^{-1}$)	FG / ($\text{L}\cdot\text{min}^{-1}$)	GRC
1	1000	4	6	0.5455
2	1000	4	7	0.4814
3	1000	4	8	0.5468
4	1000	4	9	0.5495
5	1000	4	10	0.5891
6	1000	5	6	0.5075
7	1000	5	7	0.4698
8	1000	5	8	0.5105
9	1000	5	9	0.5254
10	1000	5	10	0.5506
11	1000	6	6	0.4564
12	1000	6	7	0.4691
13	1000	6	8	0.4647
14	1000	6	9	0.5239
15	1000	6	10	0.5242
⋮	⋮	⋮	⋮	⋮
25	1000	8	10	0.3947
⋮	⋮	⋮	⋮	⋮
106	1800	4	6	0.6250
⋮	⋮	⋮	⋮	⋮
116	1800	7	6	0.5705
117	1800	7	7	0.5704
118	1800	7	8	0.5028
119	1800	7	8	0.5482
120	1800	7	10	0.5502
121	1800	8	6	0.5344
122	1800	8	7	0.5060
123	1800	8	8	0.5505
124	1800	8	9	0.4607
125	1800	8	10	0.6033

表 9 参数水平设计
Table 9 Parameter level design

Process parameter	Parameter range	Upward gradient	Number of levels
LP /W	1000–1800	10	81
SS /($\text{mm}\cdot\text{s}^{-1}$)	4–8	0.1	41
FG /($\text{L}\cdot\text{min}^{-1}$)	6–10	0.5	9

程度内，综合性能一般。有趣的是，图中阵点颜色比较深的集中在最顶部，并且最高灰关联度的黑色阵点方块位于阵点 $M(1080 \text{ W}, 4.8 \text{ mm}\cdot\text{s}^{-1}, 10 \text{ L}\cdot\text{min}^{-1})$ 和阵点 $N(1060 \text{ W}, 4.6 \text{ mm}\cdot\text{s}^{-1}, 10 \text{ L}\cdot\text{min}^{-1})$ 也都在顶部，说明保护气流量对灰关联度有明显的正向作用。另一方面，阵点颜色较深的区域位于阵点图的左上角和右上角，也侧面表明激光功率和扫描速度对灰关联度的




图 12 细化的工艺参数与灰关联度的关系

Fig. 12 Relationship between the refined process parameters and gray correlation degree

耦合影响。

灰关联度的范围为 0.3946~0.6834, 和最初的 125 组灰关联度相比, 灰关联度范围有一定程度的扩大, 扩大幅度为 25.36%。其中, 最大灰关联度为 0.6834, 说明参数组为 1090 W、4.4 mm·s⁻¹、10 L·min⁻¹ 时, 其综合性能最佳, 与最初的 125 组试验组对比, 灰关联度的最大值有小幅提升, 提升幅度为 9.34%, 由此说明, 这种方法对提升灰关联度的上限具有很好的潜力。

3.4 GA-BP 神经网络模型与灰关联度的验证

为了验证上述 GA-BP 神经网络模型的预测准确性, 以及通过灰关联度寻找最佳综合性能的合理性, 故对上述 4 种 GA-BP 神经网络模型和灰关联度的最佳参数组的准确性进行验证。本试验在上述参数范围内随机选取了 5 组参数组, 作为 GA-BP 神经网络模型验证试验的样品, 样本序号分别记为 T₁、T₂、T₃、T₄ 和 T₅, 选取综合灰关联度最高的参数组作为灰关联度验证试验的样品, 重复制备三次, 样品记为 H₁、H₂ 和 H₃, 验证试验的参数组合如表 10 所示。

表 10 验证样品的参数

Table 10 Sample parameters for validation

Sample number	LP /W	SS / (mm·s ⁻¹)	FG / (L·min ⁻¹)
T ₁	1370	5.0	7.5
T ₂	1410	6.5	8.0
T ₃	1060	6.2	6.0
T ₄	1700	7.5	9.0
T ₅	1500	4.0	7.0
H ₁	1090	4.4	10.0
H ₂	1090	4.4	10.0
H ₃	1090	4.4	10.0

将表 10 中所有样品进行激光熔覆制备和测量后, 最终得到的 GA-BP 神经网络样品性能数据的测试值和预测值的对比情况如表 11 所示。表中 T₁'、T₂'、T₃'、T₄' 和 T₅' 均为各样品对应的预测值。

表 11 神经网络验证样品的测试值与预测值

Table 11 Test and predicted values of the validated samples by neural networks

Sample	W /μm	H /μm	η /%	DH /HV
T ₁	3882.1	1287.5	24.069	715.30
T ₁ '	3993.5	1234.3	30.000	602.05
T ₂	3885.3	1301.9	21.143	754.24
T ₂ '	3723.9	1198.0	25.800	707.74
T ₃	3405.7	1299.4	12.671	772.44
T ₃ '	3504.1	1277.9	12.732	905.74
T ₄	3907.8	1259.2	27.893	660.16
T ₄ '	3771.5	1200.0	32.221	610.27
T ₅	4129.7	1191.8	32.907	529.98
T ₅ '	4225.3	1209.1	38.730	535.17

可以看出, 神经网络模型预测值与测试值存在微小的差距, 这些差距在试验允许的范围之内。其中有小部分的预测值和测试值差距稍大。为了直观地预测值与测试值之间的差距, 本文采用相对误差 δ 来表示, 计算公式为

$$\delta_i = \frac{|x_i - X_i|}{X_i} \times 100\%, \quad (11)$$

式中: x_i 为样品 T_i 各性能数据的预测值; X_i 为接近 T_i 各性能数据的真实值; δ_i 为各样品的相对误差百分比, 其中 i=1, 2, 3, 4, 5。将每个样品所有性能数据的相对百分比误差进行比较。

图 13 为神经网络验证样品的各性能数据相对误差直方图, 可以看出相对误差最大是样品 T₁ 的稀释率, 接近 25%, 相对误差最小的是样品 T₃ 的稀释率, 接近 0.5%, 说明关于稀释率响应量的神经网络模型的预测效果不稳定, 预测波动性较大。相对地, 除了样品 T₂ 的高度相对误差在 8% 左右, 其余所有样品的宽度和高度的相对误差, 均在 5% 以下, 说明宽度和高度的神经网络预测模型预测精度较高, 稳定性也非常好。而关于硬度的相对误差, 从图中可以看出 T₁ 和 T₃ 在 10% 以上, 其余三个样品在 10% 以下, 说明硬度的神经网络模型预测总体效果较好, 但是稳定性一般。综上所述, 从验证样品检测数据的相对误差来看, 稀释率的神经网络模型预测效果一般, 宽度、高度和硬度的神经网络模型总体上预测效果较好, 具有较好的可靠性和稳定性。

样品 H₁、H₂ 和 H₃ 性能数据及灰关联度的测试值和预测值的对比情况如表 12 所示。其中 H' 表示该参数组对应的预测值。可以看出, 三个样品四种性能检测数据的存在较小的差别, 其中 H₂ 与其余两组样品各项




图 13 神经网络验证样品性能数据的相对误差

Fig. 13 Relative error of validation sample performance data for neural networks

表 12 神经网络验证样品的测试值与预测值

Table 12 Test and predicted values of the validated samples by neural networks

Sample	W / μm	H / μm	η / %	DH / HV	GRC
H ₁	3715.3	1112.5	32.564	518.72	0.5448
H ₂	3459.6	925.1	41.638	530.90	0.5668
H ₃	3666.2	1030.9	35.639	525.47	0.5403
H'	3714.2	967.4	29.972	611.42	0.6797

数据差别较大,因此最后得到的灰关联度也与其余两组差别较大。由此说明,即使是相同工艺参数下的激光熔覆样品,也会存在误差,这种误差的来源有很多种,比如激光器的光源不是一直稳定,比如由于试验者操作过程中存在失误,铺粉高度没有达到严格统一标准等。

三个样品的平均灰关联度为 0.5506,与该工艺参数下的理想预测值 0.6797 存在差距,相对误差百分比为 19%,相对误差偏大,说明灰关联度的预测值与实际工艺参数下的测试值存在不小的误差。这些误差产生的原因主要是以下几个方面:1)制备激光熔覆样品过程中存在操作不稳定的因素和激光光源不稳定的可能性;2)样品检测的过程中,存在一些数据测量误差;3)BP 神经网络模型自身存在的不足而导致的误差,因为其学习方法最速下降法本身就有容易陷入局部最优点的缺点,以及其隐含层结构难以确定,一定程度限制神经网络的预测精度^[24];4)神经网络预测模型存在预测误差,这是由于神经网络训练完成的预测模型是对真实值的近似逼近,预测值终究不能完全代替真实值,因此神经网络并不能完全反映工艺参数与熔覆层形貌、硬度等之间的关系;5)验证样品的制备和性能数据的测量也不可避免存在误差。由此可见,出现综合灰关联度误差较大的原因,也是上述原因介绍中误差叠加的结果。

4 结 论

本文采用激光熔覆技术在 304 不锈钢表面成功制备了 TiC 颗粒增强 Fe 基复合涂层,研究了工艺参数对熔覆层几何特征、硬度性能特征的影响,并通过 GA-BP 神经网络和灰关联合的方法寻得了最佳综合性能的参数组,对工艺参数进行优化。所得结论如下:

1)对工艺参数和性能数据进行多元非线性回归分析,随激光功率对增加,稀释率先增加后降低,硬度先降低后增加,宽度明显增加,高度无明显变化。随扫描速度增加,稀释率降低,硬度先增加后降低,宽度降低,高度变化不明显。随保护气流量增加,稀释率增加,硬度降低,宽度无明显变化,高度降低。

2)基于遗传算法优化 BP 神经网络,建立工艺参数与熔覆层性能数据之间的预测模型,四种 GA-BP 神经网络模型的拟合优度 R^2 分别达到 0.85、0.86、0.91 和 0.89,与非线性回归模型相比 R^2 明显提升,预测精度良好。

3)利用灰关联度对综合性能进行表征,寻优得到最佳综合性能的样本参数为 1800 W,扫描速度 $4 \text{ mm} \cdot \text{s}^{-1}$ 和保护气流量为 $6 \text{ L} \cdot \text{min}^{-1}$ 。降低参数水平梯度后,利用综合灰关联度寻得最佳综合性能为 1090 W, $4.4 \text{ mm} \cdot \text{s}^{-1}$, $10 \text{ L} \cdot \text{min}^{-1}$,最佳的综合性能能提高 9.34%。

4)对四种 GA-BP 神经网络模型和灰关联度优化结果进行验证,结果表明,除稀释率预测效果一般,宽度、高度和硬度的神经网络模型总体上预测效果较好,具有较好的可靠性和稳定性。灰关联度的验证结果比较一般,相对误差百分比为 19%,最终误差属于整个试验过程中误差叠加的结果。

参 考 文 献

- [1] 张瑞珠, 李林杰, 唐明奇, 等. 激光熔覆技术的研究进展[J]. 热处理技术与装备, 2017, 38(3): 7-11.
Zhang R Z, Li L J, Tang M Q, et al. Research progress of laser cladding technology[J]. Heat Treatment Technology and Equipment, 2017, 38(3): 7-11.
- [2] 胡登文, 刘艳, 陈辉, 等. Q960E 钢激光熔覆 Ni 基 WC 涂层组织及性能[J]. 中国激光, 2021, 48(6): 0602120.
Hu D W, Liu Y, Chen H, et al. Microstructure and properties of laser cladding Ni-based WC coating on Q960E steel[J]. Chinese Journal of Lasers, 2021, 48(6): 0602120.
- [3] 花超. 浅述激光熔覆技术的应用[J]. 科技风, 2019 (21): 146.
Hua C. Application of laser cladding technology[J]. Science and Technology Wind, 2019(21): 146.
- [4] 丰玉强, 杜泽旭, 胡正飞. 镍含量对激光熔覆镍钛合金涂层组织与性能的影响[J]. 中国激光, 2022, 49(8): 0802022.
Feng Y Q, Du Z X, Hu Z F. Influence of Ni content on microstructure and properties of NiTi alloy coatings

- fabricated by laser cladding[J]. Chinese Journal of Lasers, 2022, 49(8): 0802022.
- [5] 聂金浩. 304 不锈钢表面激光熔覆 FeCrAlNbNi 涂层的组织与高温性能研究[D]. 太原: 中北大学, 2021.
Nie J H. Study on the microstructure and high temperature properties of FeCrAlNbNi coating on 304 stainless steel surface by laser cladding[D]. Taiyuan: North University of China, 2021.
- [6] 方振兴, 祁文军, 李志勤. 304 不锈钢激光熔覆搭接率对 CoCrW 涂层组织与耐磨及耐腐蚀性能的影响[J]. 材料导报, 2021, 35(12): 12123-12129.
Fang Z X, Qi W J, Li Z Q. Effect of laser cladding lap ratio of 304 stainless steel on microstructure, wear resistance and corrosion resistance of CoCrW coating[J]. Materials Reports, 2021, 35(12): 12123-12129.
- [7] 欧阳春生, 刘秀波, 罗迎社, 等. 304 不锈钢表面激光制备 Ti₃SiC₂-Ni 基自润滑复合涂层的高温摩擦学性能[J]. 表面技术, 2020, 49(8): 161-171.
Ouyang C S, Liu X B, Luo Y S, et al. High-temperature tribological properties of Ti₃SiC₂-Ni based self-lubricating composite coatings prepared on 304 stainless steel by laser cladding[J]. Surface Technology, 2020, 49(8): 161-171.
- [8] Vasantharaja P, Vasudevan M. Optimization of A-TIG welding process parameters for RAFM steel using response surface methodology[J]. Proceedings of the Institution of Mechanical Engineers, Part L: Journal of Materials: Design and Applications, 2018, 232(2): 121-136.
- [9] 李巨光. 送粉式单道激光熔覆层横截面形貌几何模型研究[D]. 秦皇岛: 燕山大学, 2014.
Li C G. Reserch on the geometrical model of cross-section morphology of single laser cladding by powder injection[D]. Qinhuangdao: Yanshan University, 2014.
- [10] Gao J L, Wang C, Hao Y B, et al. Prediction of TC11 single-track geometry in laser metal deposition based on back propagation neural network and random forest[J]. Journal of Mechanical Science and Technology, 2022, 36(3): 1417-1425.
- [11] 温海骏, 孟小玲, 许向川, 等. 基于神经网络和遗传算法的激光熔覆工艺参数多目标优化[J]. 应用激光, 2019, 39(5): 734-740.
Wen H J, Meng X L, Xu X C, et al. Multi-objective optimization of laser cladding process parameters based on neural network and genetic algorithm[J]. Applied Laser, 2019, 39(5): 734-740.
- [12] 杨贤群. 送粉式激光熔覆质量预测与熔覆过程数值模拟[D]. 哈尔滨: 哈尔滨工业大学, 2008.
Yang X Q. Predicting the quality of clad in laser cladding by powder and numerical simulation of cladding process[D]. Harbin: Harbin Institute of Technology, 2008.
- [13] 王燕燕, 李家豪, 舒林森, 等. 基于 RSM 与 NSGA-II 算法的激光熔覆参数多目标优化[J]. 激光与光电子学进展, 2022, 59(7): 0714004.
Wang Y Y, Li J H, Shu L S, et al. Multi-objective optimization of laser cladding parameters based on RSM and NSGA-II algorithm[J]. Laser & Optoelectronics Progress, 2022, 59(7): 0714004.
- [14] 杨思瑞, 白海清, 鲍骏, 等. 基于回归分析和遗传算法优化的 BP 神经网络熔覆层形貌预测[J]. 激光与光电子学进展, 2022, 59(21): 2114002.
Yang S R, Bai H Q, Bao J, et al. Prediction of cladding layer morphology based on bp neural network optimized by regression analysis and genetic algorithm[J]. Laser & Optoelectronics Progress, 2022, 59(21): 2114002.
- [15] 李琦, 李涛, 吴祖鹏, 等. 基于神经网络的激光熔覆层面积及气孔率预测[J]. 应用激光, 2020, 40(1): 29-34.
Li Q, Li T, Wu Z P, et al. Prediction of laser cladding layer area and porosity based on neural network[J]. Applied Laser, 2020, 40(1): 29-34.
- [16] 陈书翔, 李洪玉, 陈辉. 激光熔覆镍基熔覆层截面形貌预测[J]. 焊接, 2021(2): 9-13, 62.
Chen S X, Li H Y, Chen H. Prediction of cross section morphology of Ni based cladding layer by laser cladding[J]. Welding & Joining, 2021(2): 9-13, 62.
- [17] Wang Q T, Zeng X B, Chen C R, et al. An integrated method for multi-objective optimization of multi-pass Fe50/TiC laser cladding on AISI 1045 steel based on grey relational analysis and principal component analysis[J]. Coatings, 2020, 10(2): 151.
- [18] 范鹏飞, 张冠. 基于线性回归和神经网络的金属陶瓷激光熔覆层形貌预测[J]. 表面技术, 2019, 48(12): 353-359, 368.
Fan P F, Zhang G. Prediction on geometrical characteristics of cermet laser cladding based on linear regression and neural network[J]. Surface Technology, 2019, 48(12): 353-359, 368.
- [19] Bax B, Rajput R, Kellet R, et al. Systematic evaluation of process parameter maps for laser cladding and directed energy deposition[J]. Additive Manufacturing, 2018, 21: 487-494.
- [20] Lian G F, Xiao S H, Zhang Y, et al. Multi-objective optimization of coating properties and cladding efficiency in 316L/WC composite laser cladding based on grey relational analysis[J]. The International Journal of Advanced Manufacturing Technology, 2021, 112(5): 1449-1459.
- [21] 倪立斌, 刘继常, 伍耀庭, 等. 基于神经网络和粒子群算法的激光熔覆工艺优化[J]. 中国激光, 2011, 38(2): 0203003.
Ni L B, Liu J C, Wu Y T, et al. Optimization of laser cladding process variables based on neural network and particle swarm optimization algorithms[J]. Chinese Journal of Lasers, 2011, 38(2): 0203003.
- [22] Alizadeh-Sh M, Marashi S P H, Ranjbarodeh E, et al. Laser cladding of Inconel 718 powder on a non-weldable substrate: clad bead geometry-solidification cracking relationship[J]. Journal of Manufacturing Processes, 2020, 56: 54-62.
- [23] Liu J C, Ni L B. Prediction of laser clad parameters based on neural network[J]. Materials Technology, 2012, 27(1): 11-14.
- [24] 李友坤. BP 神经网络的研究分析及改进应用[D]. 淮南: 安徽理工大学, 2012.
Li Y K. Research, analysis and improvement application of BP neural network[D]. Huainan: Anhui University of Science & Technology, 2012.