

激光与光电子学进展

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

杨思瑞¹, 白海清^{1,2*}, 鲍骏¹, 任礼¹, 李超凡¹

¹陕西理工大学机械工程学院, 陕西 汉中 723001;

²陕西省工业自动化重点实验室, 陕西 汉中 723001

摘要 针对激光熔覆过程中熔覆层形貌难以控制的问题,以 45 钢和 Fe45 分别作为基材和熔覆粉末,设计 3 因素 5 水平的试验方案,并测量熔覆层的宏观尺寸。首先,利用遗传算法(GA)对反向传播(BP)神经网络的初值进行优化,建立了 GA-BP 神经网络模型,以激光工艺参数为输入、熔覆层形貌为输出进行了训练和测试,分析其预测精度。然后,分别以回归分析、BP 神经网络和 GA-BP 神经网络三种方法建立预测模型,并与实际得到的熔覆层形貌进行比较。结果表明,通过遗传算法优化的 GA-BP 神经网络模型与实际的误差约为 3%,BP 神经网络模型与实际误差为 7.38%,而回归分析预测模型预测误差最大可达到 15.5%。经比较可知,GA-BP 神经网络预测模型的结果与实际最为接近。故 GA-BP 神经网络预测模型对提高熔覆层质量具有一定的指导价值。

关键词 激光技术; 激光熔覆; 遗传算法-反向传播神经网络; 回归分析; 形貌预测

中图分类号 TG174.4

文献标志码 A

DOI: 10.3788/LOP202259.2114002

Prediction of Cladding Layer Morphology Based on BP Neural Network Optimized by Regression Analysis and Genetic Algorithm

Yang Sirui¹, Bai Haiqing^{1,2*}, Bao Jun¹, Ren Li¹, Li Chaofan¹

¹School of Mechanical Engineering, Shaanxi University of Technology, Hanzhong 723001, Shaanxi, China;

²Shaanxi Key Laboratory of Industrial Automation, Hanzhong 723001, Shaanxi, China

Abstract The experiment employs 45 steel and Fe45 as the base material and cladding powder, respectively, to develop three factors and five levels of the test scheme, and evaluate the cladding layer's macroscopic size, to solve the challenge that the cladding layer morphology is difficult to control in a laser cladding process. First, the backpropagation (BP) neural network's initial value was optimized using a genetic algorithm (GA), and GA-BP neural network model was developed. The laser process parameters were taken as input and cladding layer morphology as output to train and test, and the prediction accuracy was examined. Second, the prediction model was developed using regression analysis, BP neural network, and GA-BP neural network, and compared with the actual cladding layer morphology. The findings demonstrate that the GA-BP neural network model's error optimized by the genetic algorithm was about 3%, the maximum error of the BP neural network prediction model was 7.38%, and the maximum error of the regression analysis prediction model is 15.5%. It can be seen from the comparison that the results of the GA-BP neural network prediction model are the closest to the actual. Thus, the GA-BP neural network prediction model has a certain regulating value for enhancing the quality of the cladding layer.

Key words laser technique; laser cladding; genetic algorithm backpropagation neural network; regression analysis; morphology prediction

1 引言

激光熔覆是在金属表面利用激光热源快速融化金

属粉末的一种工艺,形成一种与基材表面具有良好冶金结合的熔覆涂层,有效提高金属表面的抗氧化、耐磨、耐蚀性以及基材硬度^[1-2]。激光熔覆在零件的修复

收稿日期: 2021-10-12; 修回日期: 2021-11-04; 录用日期: 2021-11-05

基金项目: 陕西理工大学研究生创新基金项目(SLG YCX2124)、陕西省技术创新引导项目(2021QFY05-03)

通信作者: *bretmail@snut.edu.cn

中应用较多,对于激光熔覆而言,激光功率、扫描速度和送粉量是对熔覆层质量影响较大的激光工艺参数^[3]。激光熔覆技术在零件修复领域被广泛应用,但激光熔覆过程是一个多因素耦合的过程,其熔覆层形貌也对熔覆层质量具有十分重要的影响。

熔覆层高度和宽度是影响熔覆层形貌的重要因素,宽度、高度的变化会导致熔覆层表面不平整,甚至影响成形零件的内部组织性能和力学性能。在激光熔覆成形过程中,单道熔覆层形貌受多个工艺参数的影响且各参数之间具有复杂的耦合关系,并且激光工艺参数对熔覆高度、宽度的影响呈非线性变化,很难用统一的数学表达式进行描述^[4]。在熔覆层表面形貌方面:梁旭东等^[5]采用随机森林(RF)算法构建了激光熔覆工艺参数(激光功率、扫描速度、送粉速率)到单道熔覆层尺寸的回归模型,并将模型用于特定熔覆参数组下单道尺寸的预测,最终发现预测模型的预测误差小于4%;倪立斌等^[6]运用神经网络建立熔覆带特征(熔覆带高度、熔覆带宽度)与熔覆工艺参数之间的预测模型,采用反向传播(BP)神经网络和粒子群算法相结合的方法对激光熔覆过程的工艺参数进行优化;王鹏飞等^[7]采用试验与仿真相结合的方法研究了工艺参数及基体倾斜角度对激光熔覆熔池流场及轮廓的影响,结果发现,在倾斜基体激光熔覆时,基体倾斜导致的激光能量密度及粉末浓度的降低对熔覆高度有显著影响。在熔覆层形貌预测方面:陈书翔等^[8]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;范鹏飞等^[9]分别运用多元线性回归分析和神经网络方法,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;梁万旭等^[10]通过设计全因子试验,基于响

应曲面分析方法构建涂层形貌与工艺参数之间的数学模型,并将预测结果与试验数据进行比对,结果发现,熔覆层平均高度、基体平均熔深、平均稀释率、表面平均高度差的平均相对误差较低,具有较高的预测精度。

综上所述,目前对于激光熔覆层表面形貌的分析主要以单一神经网络方法和数据拟合分析法居多,神经网络在非线性系统问题上的应用逐渐被重视,神经网络技术逐渐在实际工程中越发重要^[11-12]。本文选择遗传算法(GA)来优化BP神经网络,建立GA-BP神经网络预测模型,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。设计3因素5水平的试验并测量熔覆层高度和宽度,以熔覆工艺参数为输入,分别以熔覆层高度和宽度为输出,通过GA-BP神经网络算法建立熔覆工艺参数和熔覆层宏观形貌之间的数学模型^[13],并与回归分析和单一神经网络所建立的数学模型进行熔覆层形貌的预测对比分析,对实现制备优形貌高质量的熔覆层具有一定的指导意义。

2 试验设备与方法

2.1 试验设备与材料

激光熔覆试验选用3 kW 光纤同轴送粉激光熔覆机如图1所示,其系统主要包括软件系统、激光器、数控系统、粉末输送系统、保护气体输送装置及工作台。基材尺寸为100 mm×100 mm×10 mm的45钢试件,熔覆前利用磨砂纸细磨抛光以提高工件平整度,使用无水乙醇擦拭以去除表面油污。试样观测设备采用超深显微镜如图2所示,将待测量的试件置于显微镜平台上,将镜头对准试件进行聚焦,选择放大倍数为1000倍,待可以清晰显示出熔覆层截面后,对截面进行拍照再对照片进行测量得到所需的几何参数。熔覆材料为Fe45粉末,对粉末进行密封烘干处理,确保试验粉末的干燥性。试验材料的化学成分如表1所示。




图1 3 kW 光纤激光熔覆机

Fig. 1 3 kW fiber laser cladding machine



图2 超景深显微镜

Fig. 2 Ultra depth of field microscope

表1 试验材料化学成分

Table 1 Chemical composition of test materials

Item	Mass fraction / %					
	C	Si	Mn	Ni	Cr	Fe
45 steel	0.45	0.27	0.65	0.25	0.12	Bal.
Fe45 powder	0.75	3.00	3.00	13.00	16.00	Bal.

为了选择更贴合实际情况的试验数据,减少试验结果各类误差因素的影响,根据前期试验研究,调整喷头到工作台表面的距离为 15 mm,初始预热温度设置为 22 °C,在熔覆过程中采用氩气(Ar)作为保护气,保护气流量为 6~10 L/min,设计 3 因素 5 水平的试验如表 2 所示。

表2 试验因素水平表

Table 2 Test factor level table

Process parameter	Level 1	Level 2	Level 3	Level 4	Level 5
	Laser power / kW	1.80	1.95	2.10	2.25
Scanning speed / (mm·s ⁻¹)	4	6	8	10	12
Powder feed speed / (r·min ⁻¹)	1.8	2.0	2.2	2.4	2.6

2.2 试验结果

根据试验因素的水平表设计 25 组试验,每次单道

熔覆结束后待基板冷却至室温,再进行下一组试验,确保各单道熔覆层之间不会产生相互影响,25 组单道熔覆层如图 3 所示。为了测量熔覆层的宽度和高度,采用线切割的方式对单道熔覆层沿垂直与熔覆层的方向进行切割,为了防止出现同一熔覆层的不同位置的随机性而无法代表该熔覆层的形貌,通过前期大量实际试验数据发现,虽然熔覆层两端的高度和宽度值与熔覆层中段数值差距较大,但熔覆层中段形貌相差较小,故在后期进行数据测量时,选择测量靠近中间段熔覆层的高度和宽度,如图 4 所示,并且在同一熔覆层中选择三个且相邻间隔均为 1 mm 位置进行测量并取平均值,在切割后对截面进行打磨抛光处理,采用超深显微镜对 25 组截面进行观察,最后取值得到熔覆层的高度和宽度值如表 3 所示。在 25 组样本数据的基础上,利用线性回归和神经网络分析法,建立了熔覆工艺参数和熔覆层形貌的预测模型。




图3 不同工艺参数的熔覆层外观形貌

Fig. 3 Surface morphology of cladding layer with different process parameters




图4 熔覆层宽度和高度测量位置

Fig. 4 Measurement position of cladding layer width and height

表3 试验方案及结果

Table 3 Test scheme and results

Number	Laser power / kW	Scanning speed / (mm·s ⁻¹)	Powder feed speed / (r·min ⁻¹)	Height / mm	Width / mm	Number	Laser power / kW	Scanning speed / (mm·s ⁻¹)	Powder feed speed / (r·min ⁻¹)	Height / mm	Width / mm
1	1.80	4	1.8	0.663	2.163	14	2.10	10	1.8	0.378	2.173
2	1.80	6	2.0	0.537	2.228	15	2.10	12	2.0	0.310	2.124
3	1.80	8	2.2	0.430	1.975	16	2.25	4	2.4	1.258	2.460
4	1.80	10	2.4	0.381	2.170	17	2.25	6	2.6	1.032	2.425
5	1.80	12	2.6	0.483	2.032	18	2.25	8	1.8	0.465	2.338
6	1.95	4	2.0	0.840	2.264	19	2.25	10	2.0	0.428	2.120
7	1.95	6	2.2	0.710	2.244	20	2.25	12	2.2	0.510	2.157
8	1.95	8	2.4	0.632	2.180	21	2.40	4	2.6	1.512	2.622
9	1.95	10	2.6	0.560	2.080	22	2.40	6	1.8	0.804	2.440
10	1.95	12	1.8	0.358	2.123	23	2.40	8	2.0	0.590	2.487
11	2.10	4	2.2	1.050	2.570	24	2.40	10	2.2	0.493	2.324
12	2.10	6	2.4	0.663	2.335	25	2.40	12	2.4	0.403	2.390
13	2.10	8	2.6	0.650	2.254						

3 线性回归分析

回归分析法可以通过一个数学表达式来表征熔覆层形貌和工艺参数之间的联系。设有一个因变量 Y 与 n 个自变量 X_1, X_2, \dots, X_n , 则因变量和自变量之间的关系可以表示为

$$Y = a_0 + a_1 \cdot X_1 + a_2 \cdot X_2 + \dots + a_n \cdot X_n + \epsilon, \quad (1)$$

式中: $a_0, a_1, a_2, \dots, a_n$ 为回归系数, 且均为常数; ϵ 为误差系数^[14]。本文中因变量 Y_1, Y_2 分别代表熔覆层宽度 W 和高度 H , 而自变变量 X_1, X_2, X_3 则分别为激光功率 P 、扫描速度 S 、送粉速率 F 。

利用表 3 的试验数据, 通过 SPSS Statistics 分析软件, 分别以熔覆层宽度和高度为因变量、各工艺参数为自变量建立对应的回归方程, 表示为

$$Y_1 = 0.53P - 0.033S + 0.07F + 1.260, \quad (2)$$

$$Y_2 = 0.428P - 0.079S + 0.369F - 0.441. \quad (3)$$

使用 F 检验法对回归方程进行显著性检验, 表示为 $Y_{1,0.05}(23, 1) = 29.552, Y_{2,0.05}(23, 1) = 33.281$ 。远大于临界值 $Y_{0.05}(23, 1) = 4.28$, 故回归方程显著, 可以使用。

4 GA-BP 神经网络分析

4.1 GA-BP 神经网络原理

神经网络算法具有快速寻找最佳解的优点, 但由于其初始值选择范围较大, 求解时易求得小范围最佳解, 而遗传算法具有较高的全局搜索能力, 因此将遗传算法与 BP 神经网络结合后, 先采用遗传算法对 BP 神经网络所有初始值选择最佳值, 再利用 BP 网络进行精确求解^[15]。不同的权值和阈值会对训练速度、网络的收敛性以及最终的寻优结果造成极大的误差, 为了减小神经网络的计算误差, 必须要选择最优的初始值, 而引入遗传算法就是为了优化神经网络的初始权值和阈值^[16]。遗传算法优化 BP 神经网络算法流程如图 5 所示。

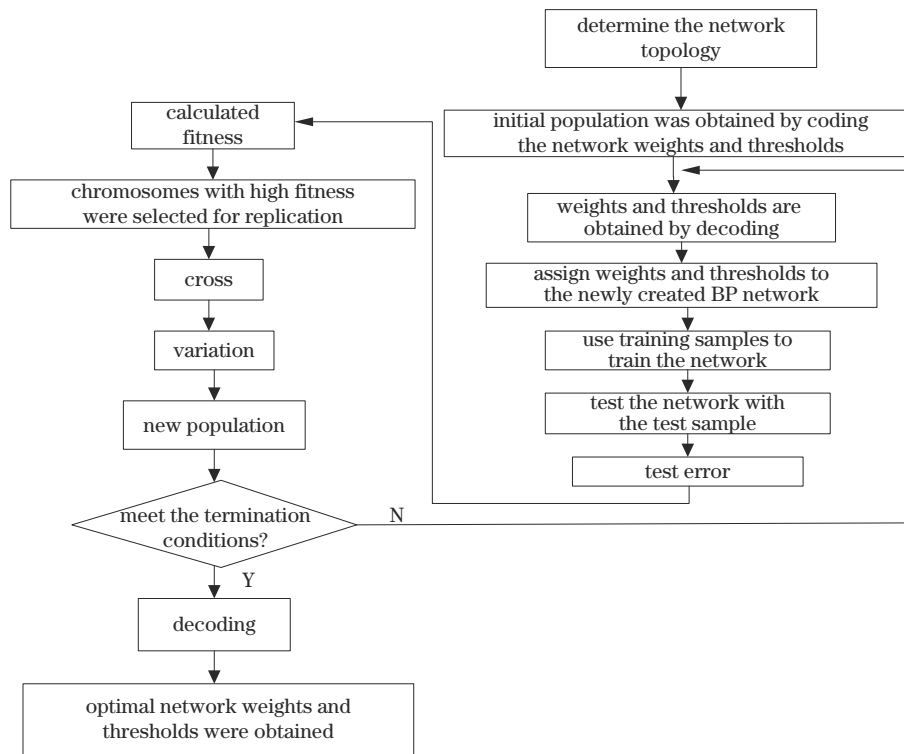


图 5 GA-BP 神经网络算法流程图

Fig. 5 Algorithm flow chart of GA-BP neural network

因为本文试验得到的数据较少, 故选择三层 BP 神经网络足以解决问题, 在三层网络中, 隐含层神经网络个数 n_2 和输入层个数 n_1 之间有近似关系^[17], 表示为

$$n_2 = 2 \times n_1 + 1. \quad (4)$$

由式(4)确定本文输入层个数为 3, 隐含层个数为 7, 故确定本次神经网络结构为 $3 \times 7 \times 1$, GA-BP 神经网络只有一个输出, 所建立的 BP 神经网络结构如图 6 所示。

遗传算法是一种进化算法^[18], 从全局优化搜索的

角度而言, 遗传算法经过一代一代地繁衍、变异及优化, 最终找到最优解^[19]。针对神经网络中初始的权值及阈值, 根据神经网络结构可以确定网络的初始权值和阈值分别为 28 和 8, 因此遗传算法的优化参数的个数为 36, 其他具体参数如表 4 所示。

4.2 GA-BP 神经网络训练及测试仿真试验

由于试验得到的数据不是统一的量纲, 各参数之间相差较大无法进行统一处理, 故需要进行归一化处理, 将所有数据转换为 $[0, 1]$ 之间^[20]。




图 6 BP神经网络结构图

Fig. 6 BP neural network structure diagram

表 4 GA-BP 预测算法参数

Table 4 Parameters of GA-BP prediction algorithm

Parameter settings	Parameter value	Parameter settings	Parameter value
Population size	40	Variables get binary bits	10
Maximum number of iterations	80	Number of training	1000
Crossover probability	0.71	Training goal	0.01
Mutation probability	0.01	Learning rate	0.1

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}}, \quad (5)$$

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

将试验得到的 25 组样本数据分成两组，选择第 1、7、13、19、25 组作为测试数据，其余 20 组数据作为训练数据。将试验得到的数据分别作为输入和输出加载到 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，

再利用剩下的 5 组测试数据集对神经网络进行测试。分别得到测试值和预测值的熔覆层宽度、高度对比曲线，如图 7 所示。

把遗传算法得到的最优初始权值和阈值赋值给 BP 神经网络，经过 BP 神经网络学习和训练之后，当算法迭代到第 4 代时，最佳训练性能达到 1.248×10^{-5} 。输出分别为宽度和高度时，遗传算法优化 BP 神经网络初始值的迭代过程如图 8 所示。

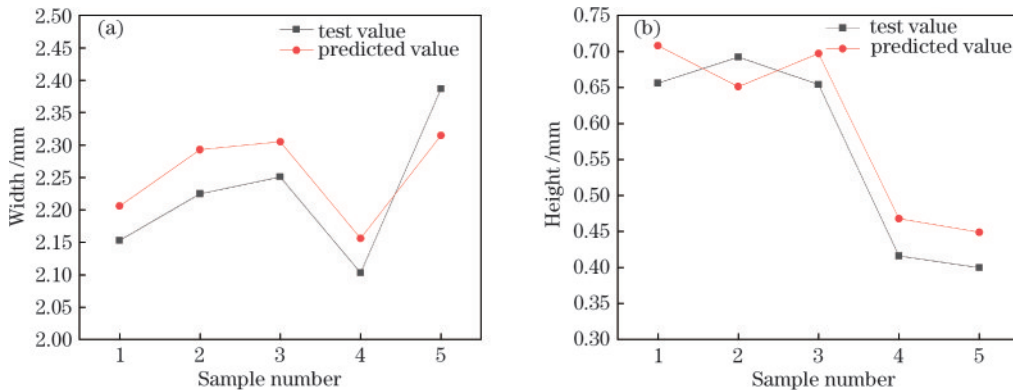


图 7 测试值和预测值对比关系。(a)宽度；(b)高度

Fig. 7 Comparison between test values and predicted values. (a) Width; (b) height

计算出测试集样本的预测值和期望值之间的相关系数，表示为

$$R = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X)} + \sqrt{\text{Var}(Y)}}, \quad (6)$$

式中： X 和 Y 分别为熔覆层形貌的期望输出和预测输出； $\text{Cov}(X, Y)$ 是期望输出和预测输出的协方差；

$\sqrt{\text{Var}(X)}$ 和 $\sqrt{\text{Var}(Y)}$ 是期望输出和预测输出的方差^[21]。 R 值越接近 1，表明二者之间相关性越强。

测试时，BP 神经网络预测值和相关系数如图 9 所示。图 9(a)、(b) 中熔覆层宽度、高度的相关系数分别为 0.9926、0.9903。相关系数接近 1，表明 GA-BP 神经网络模型预测精度较高。

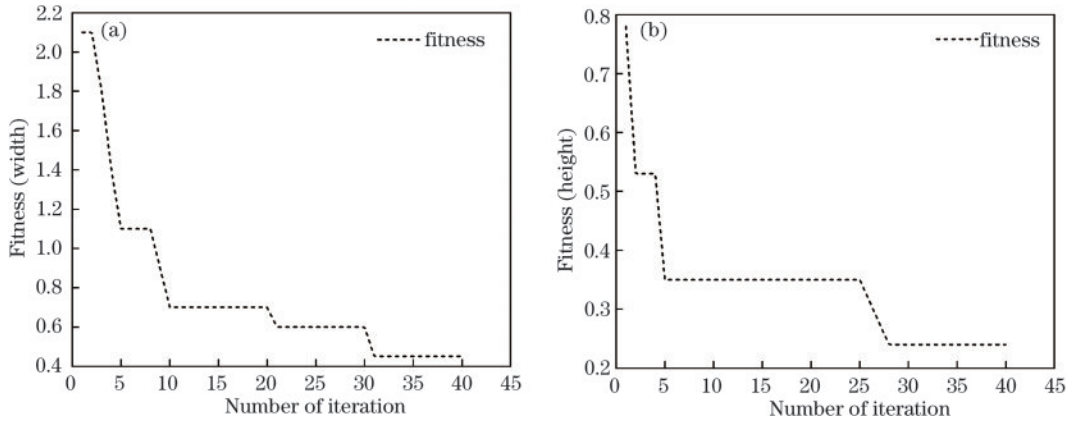


图 8 适应度函数迭代曲线。(a)宽度;(b)高度

Fig. 8 Iteration curves of fitness function. (a) Width; (b) height

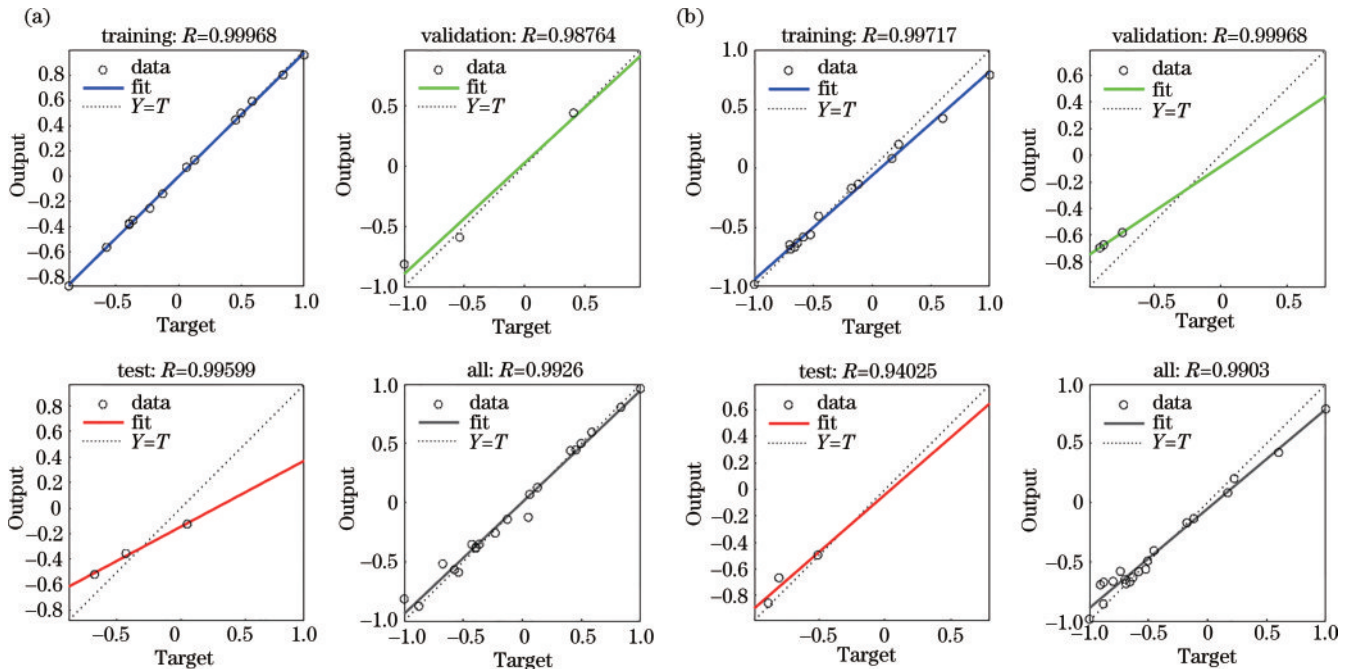


图 9 熔覆层形貌预测与期望值拟合图。(a)宽度;(b)高度

Fig. 9 Fitting diagrams of cladding layer morphology predicted and expected value. (a) Width; (b) height

基于上述已建立的 GA-BP 神经网络模型,在已有样本中随机选择 5 组测试样本与该预测模型得到的预测值进行对比分析,其结果如表 5 所示。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较小,相对误差分别在 4.46% 和 4.91% 之内,通过该数据验证了 GA-BP 神经网络预测模型已经具备很高的预测精度。出现误差的原因主要有:1) 样本在试验过程和数据采集过程中,测量值与原始值之间存在一定的测量误差,这会影响神经网络训练的精度;2) 本文采用的 GA-BP 神经网络本身存在一定的缺陷,该网络仅仅是针对非线性数据的一种近似趋近的方法,并不能很准确地反映熔覆工艺参数和熔覆层形貌之间的关系;3) 本次样本采集的数据太少,导致网络训练的精度无法达到很高的要求。

5 预测模型的对比分析

为了验证在 GA-BP 预测模型中引入遗传算法是否对神经网络的寻优能力有所提升,建立一个未进行优化且与之前具有相同网络结构($3 \times 7 \times 1$)的 BP 神经网络,并对比两个神经网络预测模型在相同情况下对熔覆层形貌的预测误差。与此同时,为了对比神经网络与回归分析在预测熔覆层形貌方面的精度,本文对比了三种模型对熔覆层形貌的预测精度,并且都与试验得到的实际熔覆层形貌进行比较。为了验证三种预测模型对熔覆层形貌预测精度,同时为节约成本,故选择熔覆层宽度为指标进行验证,并且对比不同方式建立的预测模型对熔覆层形貌预测的误差。重新选择 5 组参数进行试验,利用超深显微镜测量得到熔覆层宽度值如表 6 所

表 5 熔覆层形貌测试值与预测值误差分析

Table 5 Error analysis of the test value and predicted value of cladding layer morphology

Number	Width			Height		
	Test value /mm	Predicted value /mm	Error /%	Test value /mm	Predicted value /mm	Error /%
3	1.975	2.05	3.59	0.430	0.44	3.50
9	2.080	2.17	4.46	0.560	0.54	-2.32
11	2.570	2.59	1.11	1.050	1.07	2.69
18	2.338	2.28	-2.39	0.465	0.45	-3.44
24	2.324	2.47	3.22	0.493	0.51	4.91

示,对比 GA-BP 神经网络、BP 神经网络和回归分析所建立的预测模型,分析不同预测模型对熔覆层宽度的预

测误差,从而选出一种最优预测模型,图 10 为重新选择的 5 组试验得到的熔覆层宏观形貌图。

表 6 熔覆层宽度试验值与预测值对比

Table 6 Comparison between test value and predicted value of width of cladding layer

No.	Laser power /kW	Scanning speed /($\text{mm}\cdot\text{s}^{-1}$)	Powder feed speed /($\text{r}\cdot\text{min}^{-1}$)	Test result /mm	GA-BP /mm	BP /mm	Regression analysis /mm
1	1.80	8	1.8	2.463	2.558	2.643	2.082
2	1.80	12	2.0	2.182	2.240	2.064	1.963
3	1.95	8	2.0	2.384	2.421	2.482	2.174
4	1.95	12	2.2	2.280	2.233	2.138	2.050
5	2.10	8	2.2	2.413	2.460	2.491	2.265

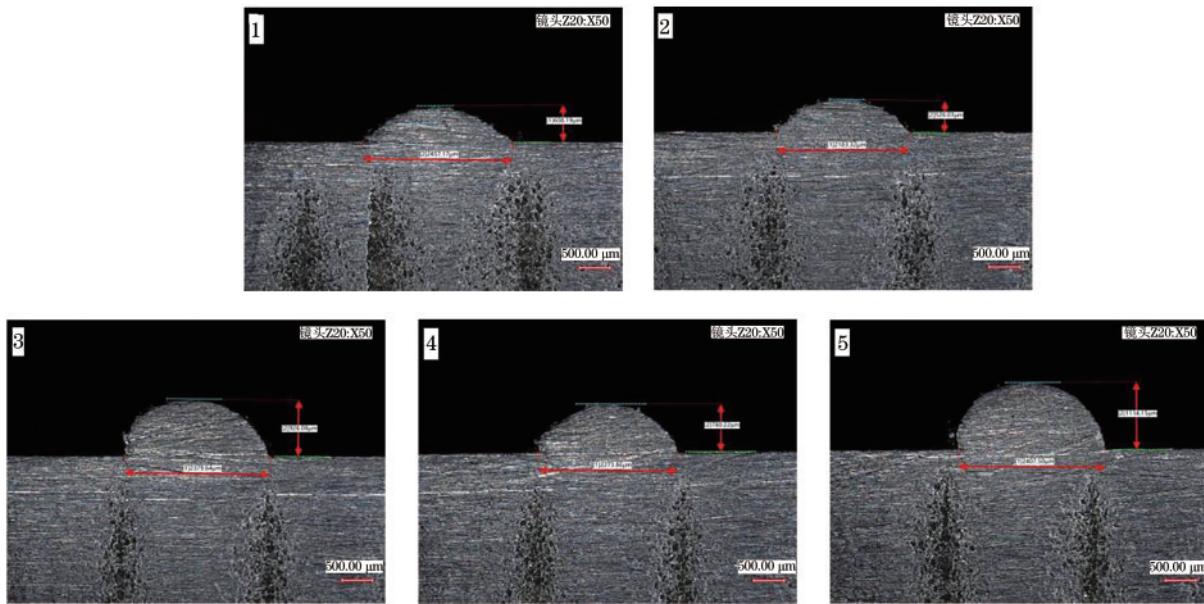


图 10 5 组试验熔覆层形貌图

Fig. 10 Morphology of 5 groups of test cladding layers

从图 11 可以看出,GA-BP 神经网络模型预测值与试验值极为接近,证明了 GA-BP 模型对熔覆层宏观尺寸预测的可行性。未优化的 BP 神经网络对熔覆层宽度的预测结果略高于试验值,分析认为:1)未优化的 BP 神经网络的初始值不是最优解,其本身存在一定的误差;2)通过试验得到的样本数据太少,BP 神经网络没有大量的数据进行训练,故 BP 神经网络预测误差偏高。采用回归分析得到的预测值与实际值之间误差最大,分析认为:试验得到的样本数据在进行拟合回归

方程时存在一定的误差,使得回归方程拟合精度不高,以及测量熔覆层形貌时也存在误差,导致后续的预测值与实际值之间误差较大。由图 12 可知,第 1 组试验数据中由回归分析模型预测熔覆层宽度值时,得到的误差最高达到 15.5%,而采用 GA-BP 神经网络预测第 1 组熔覆层宽度值时误差降低至 3.89%。在 5 组预测结果中:采用回归分析预测熔覆层宽度时,预测误差在 -15.5%~-5.98% 之间;未优化的 BP 神经网络预测误差在 -6.45%~7.38% 之间;而采用遗传算法

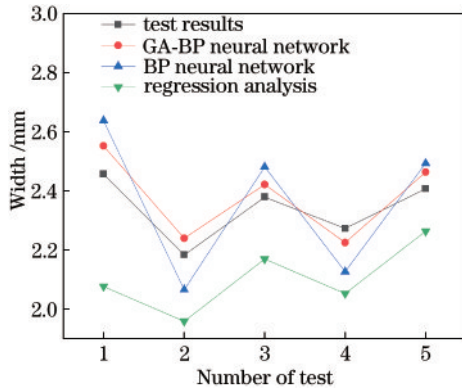


图 11 熔覆层宽度试验值与预测值的对比

Fig. 11 Comparison between test value and predicted value of cladding layer width

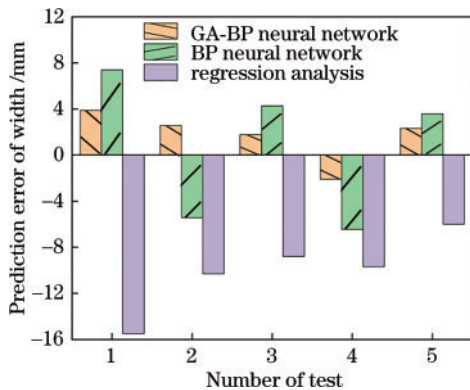


图 12 不同预测模型的熔覆层宽度预测误差对比

Fig. 12 Comparison of prediction errors of cladding width with different prediction models

优化的 GA-BP 神经网络的预测误差在 -2.09% ~ 3.89% 之间, 远远小于回归分析和 BP 神经网络预测模型误差。由此可以得出, GA-BP 神经网络对熔覆层形貌的预测精度最高。

6 结 论

本文利用遗传算法优化 BP 神经网络的初始值, 建立工艺参数和熔覆层宏观尺寸之间的 GA-BP 神经网络预测模型, 并且通过 20 组数据训练和 5 组数据测试后, 得到测试值和预测值之间相关系数接近 1, 而且对于熔覆层宽度、高度预测值和测试值之间的相对误差分别在 4.46% 和 4.91% 之内, 说明了 GA-BP 神经网络模型具有较高的预测精度。然后, 比较了 GA-BP 神经网络、BP 神经网络以及回归分析三种预测模型对于熔覆层宽度的预测值与试验得到的宽度值的误差, 结果表明: GA-BP 神经网络预测模型的误差范围为 -2.09% ~ 3.89% ; BP 神经网络预测模型的误差范围为 -6.45% ~ 7.38% ; 回归分析预测模型的误差范围为 -15.5% ~ -5.98% 。通过比较三种模型的预测精度可知, GA-BP 神经网络模型对熔覆层形貌的预测精度高于其他两种预测模型。

参 考 文 献

- [1] 战金明, 梁志刚, 黄进钰, 等. TC4 钛合金表面单道激光熔覆工艺研究[J]. 应用激光, 2020, 40(6): 955-961.
Zhan J M, Liang Z G, Huang J Y, et al. Study on the single laser cladding process on TC4 titanium alloy surface[J]. Applied Laser, 2020, 40(6): 955-961.
- [2] 靳鸣, 贺定勇, 吴旭, 等. 激光熔覆 TiC 增强不锈钢涂层的组织及性能[J]. 材料热处理学报, 2019, 40(9): 129-134.
Jin M, He D Y, Wu X, et al. Microstructure and properties of laser cladding TiC reinforced stainless steel coatings[J]. Transactions of Materials and Heat Treatment, 2019, 40(9): 129-134.
- [3] 吴军, 朱冬冬, 杨日初, 等. 45 钢轴面激光熔覆 Ni60AA 涂层工艺参数优化及摩擦磨损性能研究[J]. 激光与光电子学进展, 2021, 58(11): 1114008.
Wu J, Zhu D D, Yang R C, et al. Parameters optimization and friction and wear properties for laser cladding Ni60AA coating on 45 steel shaft surface[J]. Laser & Optoelectronics Progress, 2021, 58(11): 1114008.
- [4] 蒋伟伟, 傅戈雁, 张吉平, 等. 三分光束光内同轴送丝熔覆层几何形貌预测[J]. 红外与激光工程, 2020, 49(3): 0305005.
Jiang W W, Fu G Y, Zhang J P, et al. Prediction of geometrical shape of coaxial wire feeding cladding in three-beam[J]. Infrared and Laser Engineering, 2020, 49(3): 0305005.
- [5] 梁旭东, 王炜, 赵凯, 等. 随机森林回归分析在激光熔覆形貌预测中的应用[J]. 中国有色金属学报, 2020, 30(7): 1644-1652.
Liang X D, Wang W, Zhao K, et al. Application of random forest regression analysis in trace geometry prediction of laser cladding[J]. The Chinese Journal of Nonferrous Metals, 2020, 30(7): 1644-1652.
- [6] 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.
- [7] 王鹏飞, 杨坤, 陈明智, 等. 倾斜基板激光熔覆 GH3536 熔池形貌的仿真与实验研究[J]. 中国激光, 2021, 48(10): 1002121.
Wang P F, Yang K, Chen M Z, et al. Simulation and experimental research on the GH3536 molten pool laser cladding on inclined substrate[J]. Chinese Journal of Lasers, 2021, 48(10): 1002121.
- [8] 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.
- [9] 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.
- [10] 梁万旭, 杨勇, 金康, 等. 基于响应面法的同轴送粉多道激光熔覆层形貌预测[J]. 激光与光电子学进展, 2022, 59(1): 0114012.
- Liang W X, Yang Y, Jin K, et al. Morphology prediction of coaxial powder feeding multichannel laser cladding layer based on response surface[J]. Laser & Optoelectronics Progress, 2022, 59(1): 0114012.
- [11] Brinksmeier E, Meyer D, Huesmann-Cordes A G, et al. Metalworking fluids: mechanisms and performance[J]. CIRP Annals, 2015, 64(2): 605-628.
- [12] 董长虹. 神经网络与应用[M]. 北京: 国防工业出版社, 2005.
- Dong C H. MATLAB neural network and application [M]. Beijing: National Defense Industry Press, 2005.
- [13] Alimardani M, Toyserkani E. Prediction of laser solid freeform fabrication using neuro-fuzzy method[J]. Applied Soft Computing, 2008, 8(1): 316-323.
- [14] Porzio G C. Regression analysis by example[J]. Journal of Applied Statistics, 2013, 40(12): 2776-2777.
- [15] 谢书明, 张词秀, 丁惜瀛. 基于模糊神经网络 UC 轧机中间辊弯辊控制[J]. 沈阳工业大学学报, 2009, 31(1): 98-102.
- Xie S M, Zhang C X, Ding X Y. Control for intermediate bending roll of UC rolling mill based on fuzzy neural network[J]. Journal of Shenyang University of Technology, 2009, 31(1): 98-102.
- [16] 刘干成, 黄博. 基于 GA-BP 神经网络的镍基合金熔覆涂层形貌预测[J]. 应用激光, 2018, 38(4): 527-535.
- Liu G C, Huang B. Prediction of Ni-based alloy cladding coatings topography based on GA-BP neural network[J]. Applied Laser, 2018, 38(4): 527-535.
- [17] 郁磊, 史峰, 王辉, 等. MATLAB 智能算法 30 个案例分析[M]. 2 版. 北京: 北京航空航天大学出版社, 2015.
- Yu L, Shi F, Wang H, et al. Analysis of 30 cases of MATLAB intelligent algorithm[M]. 2nd ed. Beijing: Beijing University of Aeronautics & Astronautics Press, 2015.
- [18] 张斌, 常森, 王桔, 等. 基于遗传算法的激光视觉焊缝特征点提取[J]. 中国激光, 2019, 46(1): 0102001.
- Zhang B, Chang S, Wang J, et al. Feature points extraction of laser vision weld seam based on genetic algorithm[J]. Chinese Journal of Lasers, 2019, 46(1): 0102001.
- [19] 陈春燕, 彭阳, 许环梓, 等. 蚁群和遗传算法在旅行路线规划中的研究[J]. 高师理科学刊, 2020, 40(7): 33-36.
- Chen C Y, Peng Y, Xu H Z, et al. Study on ant colony and genetic algorithm in traveling route planning[J]. Journal of Science of Teachers' College and University, 2020, 40(7): 33-36.
- [20] 孟庆栋. 基于机器学习的激光熔覆形貌预测与监测研究[D]. 徐州: 中国矿业大学, 2020.
- Meng Q D. Research on prediction and monitoring of laser cladding morphology based on machine learning[D]. Xuzhou: China University of Mining and Technology, 2020.
- [21] 罗椿旺. 基于 BP 神经网络的激光选区熔化成形件表面粗糙度优化研究[D]. 厦门: 厦门理工学院, 2021.
- Luo C W. Research on optimization of surface roughness of laser selective melting forming part based on BP neural network[D]. Xiamen: Xiamen University of Technology, 2021.