

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

范鹏飞¹, 张冠^{1,2}

(1.新疆大学, 乌鲁木齐 830047; 2.新疆大学工程训练中心, 乌鲁木齐 830047)

摘 要: **目的** 研究激光熔覆关键工艺参数(激光功率、扫描速度、送粉速率)与单道熔覆层宏观形貌(宽度、高度、熔池深度)之间的数量关系, 以实现 WC-Co50 复合熔覆层形貌的预测, 从而为牙轮钻头的修复提供参考。**方法** 设计不同的实验参数, 利用 4 kW 光纤激光器在牙轮钻头钢 15MnNi4Mo 表面熔覆单道 WC-Co50 复合涂层。采用工业显微镜观察单道熔覆层的横截面宏观形貌, 并测量其三维尺寸。在上述形貌参数的基础上, 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, 并将实验结果与模型预测结果进行对比。**结果** 总体来讲, 神经网络对熔覆层形貌的预测结果更为精确, 平均相对误差为 5.3187%; 多元线性回归分析预测的平均相对误差为 6.0028%。分析表明, 对熔覆层宽度的预测结果最精确, 两种方法的平均相对误差仅为 1.2999%; 对高度及熔池深度的预测结果稍差, 平均相对误差分别为 8.0586% 和 7.6237%。**结论** 两种预测方法都具有较高的精度, 但神经网络法函数关系不明确, 运算过程复杂, 需要通过进一步的算法优化来提高预测精度。

关键词: 牙轮钻头; 激光熔覆; 金属陶瓷; 多元线性回归分析; 人工神经网络; 形貌预测

中图分类号: TG174.4 **文献标识码:** A **文章编号:** 1001-3660(2019)12-0353-07

DOI: 10.16490/j.cnki.issn.1001-3660.2019.12.043

Prediction on Geometrical Characteristics of Cermet Laser Cladding Based on Linear Regression and Neural Network

FAN Peng-fei¹, ZHANG Guan^{1,2}

(1.Xinjiang University, Urumqi 830047, China; 2.Engineering Training Center of Xinjiang University, Urumqi 830047, China)

ABSTRACT: The work aims to study the quantitative relationship among the key technological parameters (laser power, scanning speed, powder feeding rate) and the geometrical characteristics (width, height, bath depth) of single-track cladding layer, so as to predict the geometrical size of WC-Co50 composite coating and provide a reference for the repair of cone bit. Different experiments were designed and single-track WC-Co50 composite coatings were deposited on the surface of cone bit 15MnNi4Mo steel by 4 kW fiber laser. Meanwhile, the cross-sectional macrostructure of the single-track coating was observed and its three-dimensional size was measured by industrial microscopy. Based on the above data, multiple linear regression analysis and artificial neural network were used to establish the mathematical models between the key process parameters and

收稿日期: 2019-08-31; 修订日期: 2019-11-20

Received: 2019-08-31; Revised: 2019-11-20

基金项目: 新疆维吾尔自治区自然科学基金 (2017D01C062)

Fund: Natural Science Foundation of Xinjiang Uygur Autonomous Region (2017D01C062)

作者简介: 范鹏飞 (1992—), 男, 硕士, 主要研究方向为激光熔覆表面强化。

Biography: FAN Peng-fei (1992—), Male, Master, Research focus: laser cladding surface strengthening.

通讯作者: 张冠 (1989—), 男, 博士研究生, 实验师, 主要研究方向为激光熔覆表面强化与非晶涂层制备。邮箱: 1203040588@qq.com

Corresponding author: ZHANG Guan (1989—), Male, Doctoral candidate, Experimenter, Research focus: laser cladding surface strengthening, amorphous coating preparation. E-mail: 1203040588@qq.com

the geometrical characteristics of the cladding layer. Then, the experimental results were compared with those predicted by the models. The neural network model was more accurate in predicting the cladding layer characteristics, with an average relative error of 5.3187%, while the mean relative error of multiple linear regression analysis model was 6.0028%. The analysis indicated that the prediction result of the coating width was the most accurate, and the average relative error of the two methods was only 1.2999%. Meanwhile, the prediction results of the height and molten pool depth were slightly worse, with average relative errors of 8.0586% and 7.6237% respectively. The both prediction methods have high accuracy, but the function of the neural network is vague, and the calculation process is complex. The both prediction methods have high accuracy. However, the function relationship of neural network is not clear and the operation process is complex, so further algorithm optimization is needed to improve the prediction accuracy.

KEY WORDS: cone bit; laser cladding; cermet; multiple linear regression analysis; artificial neural network; prediction of geometrical characteristics

激光熔覆技术是一种先进的表面改性技术,常用于磨损零部件的再制造。激光熔覆具有快速加热、冷却的特点,在激光束作用下,可迅速将基体表面加热到 10^5 K 以上,同时冷却速度高达 $10^6 \sim 10^7$ K/s,因此制备的涂层晶粒细小,组织致密,且熔覆层与基体可形成冶金结合,整体性能较优^[1-6]。

熔覆层的形貌对最终的成形质量有较大影响,由于影响熔覆层形貌的因素较多,且熔覆过程中存在较多的不可控因素,因此对熔覆层的形貌控制往往依靠大量的实验数据积累^[7]。但这种方法成本较高,常常造成资源浪费,所以对熔覆层的形貌预测成为该领域的热点研究方向。神经网络具有高度非线性拟合能力,可以在未知函数关系的情况下建立输入与输出的关系,得到了广泛的应用。黄安国等^[8]以 MATLAB 为开发平台,利用人工神经网络技术建立了激光熔覆工艺参数与铝合金熔覆层形貌及性能之间的关系模型,具有较高的预测精度。杨东辉等^[9]以扫描速度和折线角度为输入量,通过神经网络技术,建立了激光立体成形件的表面质量预测模型,结果表明,预测值和实验值的均方差小于 0.01。倪立斌等^[10]利用反向传播神经网络建立了铁基合金熔覆层形貌与工艺参数之间的预测模型,并在此基础上,通过粒子群优化算法对工艺参数进行寻优。结果表明,利用优化后的参数制备的熔覆层与预期结果误差较小。刘立君等^[11]利用 BP 神经网络,反求 DIEVAR 模具钢激光熔凝参数,结果表明,利用反求的参数进行激光熔凝处理,

模型具有较高的精度,与期望值误差仅为 1.33%,且抗热疲劳性能大幅提高。

目前激光熔覆层宏观形貌的预测方法主要是神经网络法^[12-14],但该方法函数关系不明确,且运算复杂,具有一定的局限性。利用多元线性回归分析可以建立工艺参数与熔覆层形貌之间的定量函数关系,且操作简单,但该方法在形貌预测中的应用鲜见报道,同时关于金属陶瓷复合涂层的形貌预测也未见报道。本文利用激光熔覆技术在牙轮钻头钢 15MnNi4Mo 表面制备 WC-Co50 金属陶瓷复合涂层,分别运用神经网络和回归分析两种方法,建立工艺参数与宏观形貌之间的模型,并对熔覆层宽度、高度和熔池深度进行了预测,为牙轮钻头的修复提供参考。

1 实验

1.1 实验材料及方法

实验选用的基体材料为牙轮钻头常用钢 15MnNi4Mo (尺寸为 100 mm×80 mm×13 mm)。实验前用金相砂纸打磨基体,除去表面锈迹和氧化物,并用无水乙醇清洗,烘干待用。实验所用粉末材料为 Co50 自熔性合金粉末与球形 WC 陶瓷粉末,粉末形貌如图 1 所示,实验前采用辊筒球磨机将 40% 的 WC 粉末与 60% 的 Co50 粉末混合均匀待用。基体材料与 Co50 粉末材料的化学成分如表 1 所示。

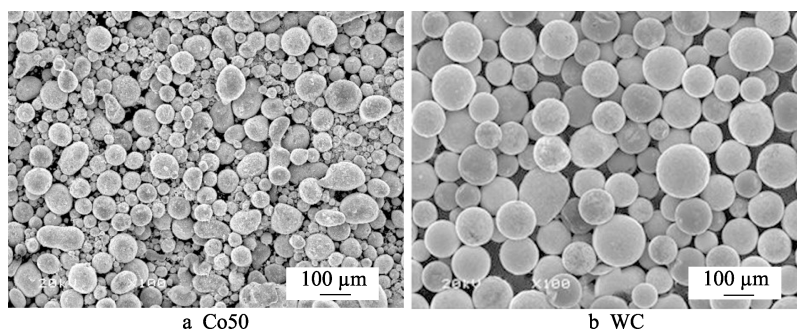


图 1 粉末微观形貌

Fig.1 Micro morphology of cladding powders

表 1 基体材料和 Co50 粉末化学成分
Tab.1 Chemical compositions of substrate and Co50 powder

Element	C	Cr	Ni	Mo	Si	Mn	Fe	B	Co
15MnNi4Mo	0.13~0.17	0.1~0.2	3.25~3.75	0.3~0.4	0.15~0.35	0.7~0.95	Bal.	—	—
Co50	0.3~0.7	18~20	26~30	4~6	3.5~4.0	—	≤12	2.0~3.5	Bal.

该实验采用同步侧向送粉方式,实验设备主要包括德国 IPG-YLS-4000 光纤激光器、KUKA-KR30HA 机械臂、新松双料仓负压式送粉器以及冷却器等,设备实物如图 2 所示。本文主要研究激光功率 P (kW)、扫描速度 V_s (mm/s) 以及送粉速率 V_f (g/s) 与单道熔覆层宽度 W (mm)、高度 H (mm) 和熔池深度 D (mm) 之间的关系,控制光斑直径为 4 mm,单道熔覆层长度为 40 mm,熔池采用氩气保护,保护气流量为 10 L/min。激光熔覆示意图如图 3 所示。

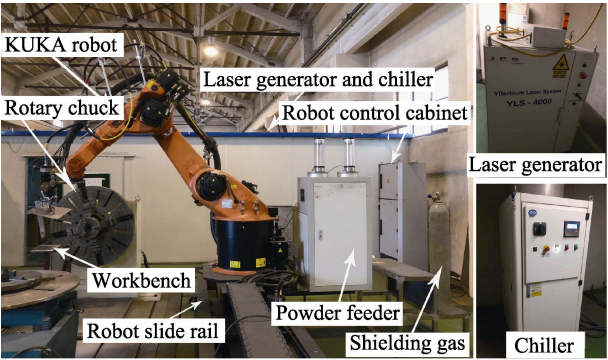


图 2 激光熔覆设备
Fig.2 Equipment for laser cladding

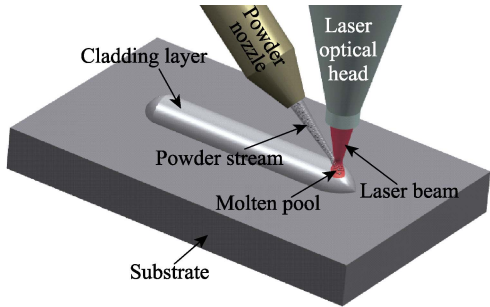
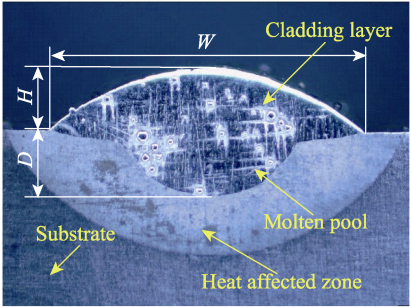


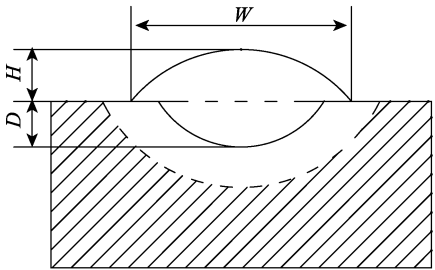
图 3 激光熔覆示意图
Fig.3 Schematic illustration of laser cladding

熔覆后,在单道熔覆层中部沿垂直于激光扫描方向线切割 10 mm×10 mm 大小的试样,用金相砂纸研磨并机械抛光后,制备熔覆层横截面的金相样品。用王水对试样截面腐蚀 10~15 s,利用 XJ-3DHD16 型工业显微镜观察熔覆层形貌并测量其三维尺寸,熔覆层宏观形貌如图 4 所示。

本文设计了 19 组实验,熔覆后分别制备金相样品并测量其三维形貌尺寸,数据保留 2 位小数,实验结果如表 2 所示。在这 19 组实验数据的基础上,利用多元线性回归分析法和神经网络法,建立了熔覆层工艺参数与其形貌尺寸之间的关系,并分别对熔覆层宽度、高度和熔池深度进行了预测。



a 熔覆层横截面



b 熔覆层横截面示意图

图 4 熔覆层宏观形貌

Fig.4 Macroscopic structure of cladding layer: a) cross section of the cladding layer; b) schematic illustration of the cross section of the cladding layer

表 2 熔覆层宏观形貌尺寸
Tab.2 Macrostructure size of the cladding layer

No.	Laser power P/kW	Scanning speed $V_s/(\text{mm}\cdot\text{s}^{-1})$	Feeding rate $V_f/(\text{g}\cdot\text{s}^{-1})$	Width W/mm	Height H/mm	Depth D/mm
1	2.2	6	0.375	3.29	0.55	0.51
2	2.2	7	0.5	3.11	0.65	0.32
3	2.2	8	0.625	3.05	0.52	0.36
4	2.4	7	0.625	3.11	0.89	0.3
5	2.4	8	0.375	3.25	0.51	0.41
6	2.4	6	0.5	3.36	0.86	0.5
7	2.6	8	0.5	3.4	0.67	0.52
8	2.6	6	0.625	3.51	0.85	0.57
9	2.6	7	0.375	3.45	0.7	0.64
10	2	7	0.5	3.02	0.65	0.14
11	2.4	7	0.5	3.25	0.7	0.47
12	2.8	7	0.5	3.4	0.67	0.6
13	3.2	7	0.5	3.57	0.72	0.75
14	2.4	5	0.5	3.32	0.96	0.59
15	2.4	9	0.5	3.15	0.29	0.5
16	2.4	11	0.5	2.98	0.38	0.23
17	2.4	7	0.25	3.33	0.51	0.5
18	2.4	7	0.75	2.91	1.01	0.26
19	2.4	7	1	2.84	1.29	0.11

1.2 多元线性回归分析法

多元线性回归分析可以建立因变量和多个自变量之间的函数关系。设有一个响应变量 Y 与 n 个预测变量 X_1, X_2, \dots, X_n , 则响应变量和预测变量之间的关系可以用如下线性关系式(式(1))表示^[15]:

$$Y = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \dots + \beta_n \cdot X_n + \varepsilon \quad (1)$$

式中, $\beta_0, \beta_1, \beta_2, \dots, \beta_n$ 均为常数, 被称为偏回归系数, ε 为误差项。本文中响应变量 Y_1, Y_2, Y_3 分别代表熔覆层宽度 W 、高度 H 及熔池深度 D , 而预测变量 X_1, X_2, X_3 则分别为激光功率 P 、扫描速度 V_s 以及送粉速率 V_f 。

利用表2实验数据, 通过 SPSS 统计分析软件分别建立了工艺参数与单道熔覆层宏观形貌之间的关系, 如式(2)~(4)所示:

$$W = 0.5P - 0.061V_s - 0.7332V_f + 2.831 \quad (2)$$

$$H = 0.1069P - 0.1053V_s + 1.0351V_f + 0.6575 \quad (3)$$

$$D = 0.4493P - 0.0438V_s - 0.5691V_f - 0.046 \quad (4)$$

1.3 神经网络预测法

选择误差反向传播神经网络模型对熔覆层形貌进行预测, 该模型具有较强的非线性逼近能力, 且算法简单、运算量小, 因此得到了广泛应用^[16]。BP 神经网络算法的学习流程如图5所示。

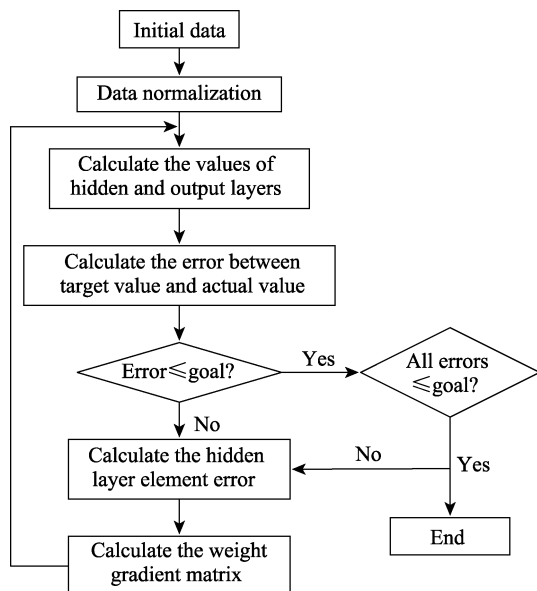


图5 BP网络学习流程图

Fig.5 Chart of BP network learning process

人工神经网络模型主要包括输入层、隐含层与输出层三部分, 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^[17]。由于本文样本数量为19组, 且复杂程度一般, 所以选择只有一个隐含层的三层神经网络模型。本文主要研究工艺参数与熔覆层形貌之间

的关系, 因此输入层包含激光功率、扫描速度及送粉速率3个神经元。为了使线性回归法与神经网络法的预测对比更具有普遍性和普适性, 针对熔覆层的宽度、高度和熔池深度, 分别建立BP神经网络模型, 并随机选择不同的组别进行预测。宽度预测选择第5组、第9组和第15组; 高度预测选择第6组、第17组及第18组; 熔池深度预测选择第11组、第12组及第18组。因此该神经网络的输出端只包含一个神经元, 分别为熔覆层宽度、高度以及熔池深度, 所建立的BP神经网络结构如图6所示。

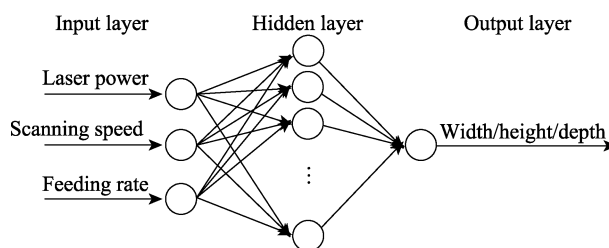


图6 熔覆层形貌尺寸BP网络模型

Fig.6 BP model for macrostructure size of the cladding coating

隐含层的神经元数目对整个模型的容错能力具有重要影响, 其个数 m 可由经验公式(5)得出^[18]:

$$m = \sqrt{A + B} + C \quad (5)$$

式中, A 为输出端神经元数量, B 为输入端神经元数量, C 为[1,10]之间的常数。利用试凑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9时, 其输出误差最小。因此该模型的隐含层神经元数量选定为9个, 即该神经网络结构为 $3 \times 9 \times 1$ 。

确定了BP神经网络的拓扑结构后, 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0.0001, 学习效率设定为0.01。将上述实验数据分为两组, 其中16组作为神经网络的训练样本, 其他3组数据用作测试样本。由于实验样本中各数据的单位不统一, 且输入量与输出量之间差异较大, 为了保证训练的可靠性和样本数据的可比性, 需要将数据归一化, 即带入式(6)中转化为[0,1]之间的数据:

$$x' = \frac{(x - x_{\min})}{(x_{\max} - x_{\min})} \quad (6)$$

式中, x' 为归一化处理后的数据, x 为单个样本值, x_{\min} 为样本数据最小值, x_{\max} 为样本数据最大值。将归一化后的数据加载到上述神经网络模型进行训练, 直到满足设定精度或达到最大迭代次数为止, 用训练后的模型即可对3组测试样本进行形貌预测。

2 熔覆层形貌预测结果对比

2.1 熔覆层宽度预测结果

为了检验多元线性回归分析和BP神经网络对熔

覆层宽度的预测精度，选择第 5 组、第 9 组和第 15 组实验样本分别进行预测，预测结果如表 3 所示。表中 W 为熔覆层宽度的测量值， W' 为多元线性回归分析

析的预测值， Δ' 为测量值与线性回归预测值的相对误差， W'' 为神经网络的预测值， Δ'' 为测量值与神经网络预测值的相对误差。

表 3 熔覆层宽度预测结果对比
Tab.3 Comparison of prediction results of the cladding coating width

No.	P/kW	$V_s/(\text{mm}\cdot\text{s}^{-1})$	$V_f/(\text{g}\cdot\text{s}^{-1})$	W/mm	W'/mm	$\Delta'/\%$	W''/mm	$\Delta''/\%$
5	2.4	8	0.375	3.25	3.2678	0.5477	3.2547	0.1446
9	2.6	7	0.375	3.45	3.4288	0.6145	3.5223	2.0957
15	2.4	9	0.500	3.15	3.1151	1.1079	3.2536	3.2889
Average	—	—	—	—	—	0.7567	—	1.8431

图 7 为熔覆层宽度实验值和预测值的对比结果。结合表 3 和图 7 可以发现，对熔覆层宽度的预测具有较高的精度，两种方法的平均相对误差仅为 1.2999%。其中多元线性回归分析的最小相对误差仅为 0.5477%，平均相对误差为 0.7576%；BP 神经网络预测的最小相对误差仅 0.1446%，平均相对误差为 1.8431%。整体而言，线性回归法对宽度的预测精度更高，但神经网络模型具有更高的局部精度。

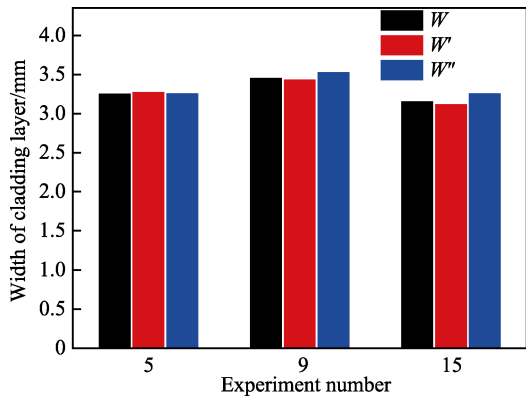


图 7 熔覆层宽度对比
Fig.7 Comparison of the cladding coating width

图 8 为两种预测模型的相对误差变化趋势。可以看出，两种模型的最大相对误差仅有 3.2889%，表明实验值与预测值并没有较大的差异，说明用这两种模型来预测熔覆层宽度均是可行的。此外，由图 8 还可以看出，线性回归法的相对误差整体波动较小，而神经网络法则波动较大，表明线性回归法对熔覆层宽度的预测稳定性更高。

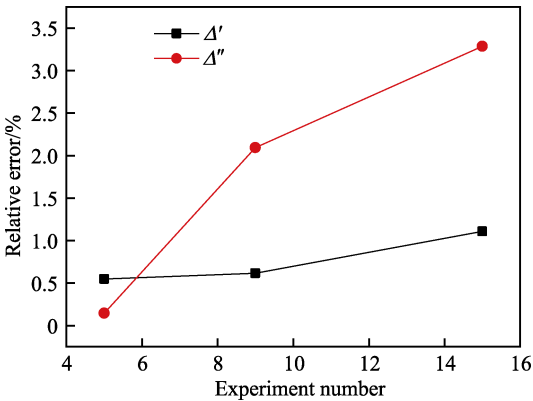


图 8 两种预测方法宽度相对误差
Fig.8 Relative error of width predicted by two methods

2.2 熔覆层高度预测结果

对熔覆层高度的预测分别选择第 6 组、第 17 组及第 18 组，结果如表 4 所示。表中 H 为熔覆层高度的测量值， H' 为多元线性回归分析的预测值， Δ' 为测量值与线性回归预测值的相对误差， H'' 为神经网络的高度预测值， Δ'' 为测量值与神经网络预测值的相对误差。

图 9 为熔覆层高度实验值和预测值对比结果，发现不同实验编号对应的熔覆层高度差异较大，结合表 4 工艺参数可知，这主要是由送粉速率引起的，送粉速率越大，则高度也越大。由表 4 和图 9 可以看出，对熔覆层高度的预测结果虽然不如宽度准确，但精度也在可控范围内，两种预测方法的平均相对误差仅为 8.0586%。多元线性回归分析预测的最小相对误差为 5.6139%，平均相对误差为 9.0608%；神经网络预测的最小相对误差为 4.686%，平均相对误差为

表 4 熔覆层高度预测结果对比
Tab.4 Comparison of prediction results of the cladding coating height

No.	P/kW	$V_s/(\text{mm}\cdot\text{s}^{-1})$	$V_f/(\text{g}\cdot\text{s}^{-1})$	H/mm	H'/mm	$\Delta'/\%$	H''/mm	$\Delta''/\%$
6	2.4	6	0.50	0.86	0.7998	7	0.8197	4.6860
17	2.4	7	0.25	0.51	0.4357	14.5686	0.5468	7.2157
18	2.4	7	0.75	1.04	0.9533	5.6139	0.9164	9.2673
Average	—	—	—	—	—	9.0608	—	7.0563

7.0563%。可见对于熔覆层高度的预测,神经网络法具有更高的预测精度。这些误差产生的原因主要有三个方面:一是在数据测量过程中,测量值只能精确到小数点后两位数字,导致与真实值之间存在不可避免的误差;二是所建立的预测模型只是对真实值的近似逼近,并不能完全反映工艺参数与熔覆层形貌之间的关系;三是样本数据量限制,导致模型精度有限。

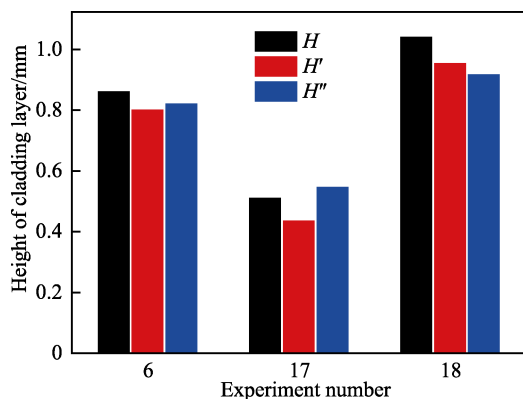


图 9 熔覆层高度对比

Fig.9 Comparison of the cladding coating height

图 10 为线性回归法和神经网络法高度预测结果的相对误差变化趋势,可以看出,两种方法的最大相对误差(14.5686%)出现在线性回归分析模型的第 17 组数据,考虑到该模型平均相对误差较小,其结果可以接受。由图可见,线性回归法的高度预测相对

误差整体波动较大,而神经网络法的变化趋势则较为平缓,表明对熔覆层高度的预测,神经网络法具有较高的预测稳定性。

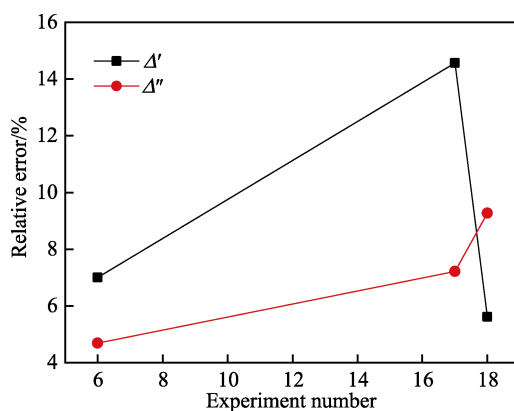


图 10 两种预测方法高度相对误差

Fig.10 Relative error of height predicted by two methods

2.3 熔池深度预测结果

针对熔池深度的预测,选择第 11 组、第 12 组及第 18 组,结果如表 5 所示。表中 D 为熔池深度的测量值, D' 为多元线性回归分析的预测值, Δ' 为测量值与线性回归预测值的相对误差, D'' 为神经网络的熔池深度预测值, Δ'' 为测量值与神经网络预测值的相对误差。

表 5 熔池深度预测结果对比

Tab.5 Comparison of prediction results of the molten pool depth

No.	P/kW	$V_s/(\text{mm}\cdot\text{s}^{-1})$	$V_f/(\text{g}\cdot\text{s}^{-1})$	D/mm	D'/mm	$\Delta'/\%$	D''/mm	$\Delta''/\%$
11	2.4	7	0.50	0.47	0.4412	6.1277	0.4362	7.1915
12	2.8	7	0.50	0.60	0.6209	3.4833	0.5579	7.0167
18	2.4	7	0.75	0.26	0.2989	14.9615	0.2419	6.9615
Average	—	—	—	—	—	8.1908	—	7.0566

图 11 为熔池深度的实验值和预测值对比结果,发现三组实验熔池深度差别较大,由表 5 可知这主要是由激光功率和送粉速率造成的。激光功率影响热量的输入,而送粉速率则影响到达基体的热量的多少,基体吸收的热量越多,则熔池深度越大。由表 5 和图 11 可知,两种算法对熔池深度的预测精度较高,平均相对误差仅为 7.6237%。线性回归分析预测的最小相对误差为 3.4833%,平均相对误差达到 8.1908%;神经网络模型预测的最小相对误差为 6.9615%,平均相对误差则为 7.0566%。因此对于熔池深度的预测,神经网络模型具有更高的精度。

图 12 为两种模型对熔池深度预测结果的相对误差变化趋势,可以看出,两种模型预测的最大相对误差(14.9615%)出现在线性回归的第 18 组数据。由图可见,线性回归模型的相对误差整体波动较大,而

神经网络模型则基本保持不变,具有良好的稳定性。表明对于熔池深度的预测,神经网络模型的预测结果

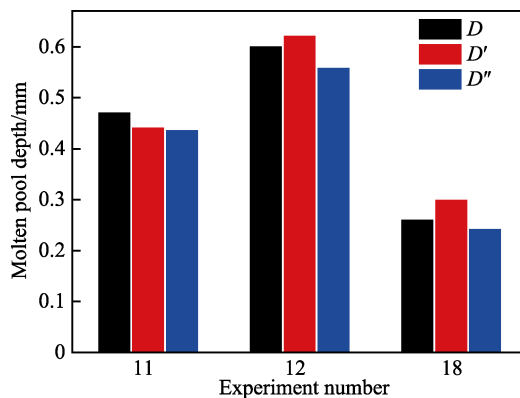


图 11 熔池深度对比

Fig.11 Comparison of the molten pool depth

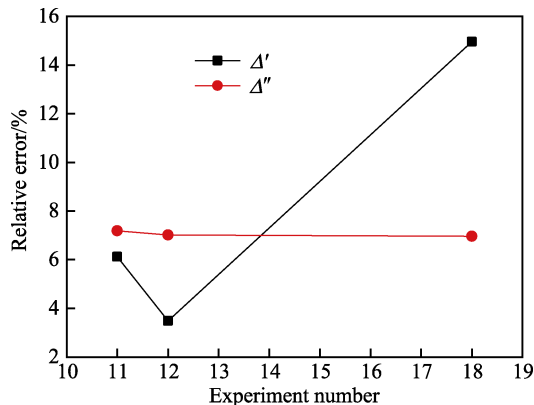


图 12 两种预测方法深度相对误差

Fig.12 Relative error of the depth predicted by two methods

具有较好的稳定性和可靠性。

综合上述三种形貌的预测分析结果,多元线性回归分析的综合平均相对误差为 6.0028%,神经网络的综合平均相对误差为 5.3187%,表明神经网络法具有更高的预测精度。对于熔覆层宽度的预测,两种方法的平均相对误差仅为 1.2999%,而对于熔覆层高度和熔池深度的预测,两种方法的平均相对误差分别达到 8.0586%和 7.6237%,表明熔覆层宽度具有最佳的预测效果。这主要是在激光熔覆过程中,激光束直径保持不变,其宽度作用范围基本不变,因此工艺参数对熔覆层宽度的影响相对较小;而熔覆层高度和熔池深度则受工艺参数影响较大,整体波动也较大。

3 结论

1) 对于熔覆层宽度的预测,多元线性回归分析具有更高的精度以及预测稳定性,线性回归的平均相对误差仅为 0.7576%;而对于熔覆层高度和熔池深度的预测,神经网络具有更好的预测精度及稳定性,神经网络对高度和深度预测的平均相对误差分别为 7.0563%和 7.0566%。

2) 预测精度最高的参数为熔覆层宽度,两种预测方法的平均相对误差仅为 1.2999%;而对于熔覆层高度和熔池深度的预测,两种方法的平均相对误差分别为 8.0586%和 7.6237%。

3) 两种模型对熔覆层形貌的预测均具有较高的精度,多元线性回归分析对熔覆层形貌预测的平均相对误差为 6.0028%,而神经网络预测的平均相对误差仅为 5.3187%,但神经网络运算复杂,函数关系模糊,需要通过进一步的算法优化来提高预测精度。因此在精度要求不高的情况下,可以采用多元线性回归分析进行预测。

参考文献:

[1] 任维彬,董世运,徐滨士,等. 压缩机叶片激光再制造

成形闭环控制设计与实现[J]. 焊接学报, 2018, 39(3): 11-15.

REN Wei-bin, DONG Shi-yun, XU Bin-shi, et al. Design and implementation of laser refabrication forming closed-loop controlling for compressor blade[J]. Transactions of the China welding institution, 2018, 39(3): 11-15.

[2] BOBBIO L D, OTIS R A, BORGONIA J P, et al. Additive manufacturing of a functionally graded material from Ti-6Al-4V to invar: Experimental characterization and thermodynamic calculations[J]. Acta materialia, 2017, 127: 133-142.

[3] 叶四友,刘建永,杨伟. 激光熔覆 316L 不锈钢涂层组织和性能的研究[J]. 表面技术, 2018, 47(3): 48-53.

YE Si-you, LIU Jian-yong, YANG Wei. Microstructure and properties of laser clad 316L stainless steel layer[J]. Surface technology, 2018, 47(3): 48-53.

[4] ZHANG S, WU C L, ZHANG C H, et al. Laser surface alloying of FeCoCrAlNi high-entropy alloy on 304 stainless steel to enhance corrosion and cavitation erosion resistance[J]. Optics & laser technology, 2016, 84: 23-31.

[5] 龚玉兵,王善林,黄勇,等. 脉冲频率对激光熔覆 FeCoCrMoCBY 涂层组织与性能的影响[J]. 稀有金属, 2017, 41(10): 1117-1124.

GONG Yu-bing, WANG Shan-lin, HUANG Yong, et al. Microstructure and properties of laser cladding FeCo-CrMoCBY coating with different pulse frequencies[J]. Chinese journal of rare metals, 2017, 41(10): 1117-1124.

[6] SHAH K, HAG I, KHAN A, et al. Parametric study of development of Inconel-steel functionally graded materials by laser direct metal deposition[J]. Materials & design, 2014, 54: 531-538.

[7] 赵洪运,杨贤群,舒凤远,等. 激光熔覆层形貌预测对比分析[J]. 焊接学报, 2009, 30(1): 51-54.

ZHAO Hong-yun, YANG Xian-qun, SHU Feng-yuan, et al. Comparative analysis on predictions of the geometric form of laser cladding[J]. Transactions of the China welding institution, 2009, 30(1): 51-54.

[8] 黄安国,李刚,汪永阳,等. 基于人工神经网络的铝合金激光熔覆层特征与性能的预测[J]. 中国激光, 2008 (10): 1632-1636.

HUANG An-guo, LI Gang, WANG Yong-yang, et al. Prediction of characteristic and performance of laser cladding for Al alloy based on artificial neural network[J]. Chinese journal of lasers, 2008(10): 1632-1636.

[9] 杨东辉,马良,黄卫东. 基于人工神经网络的激光立体成形件成形表面质量预测[J]. 中国激光, 2011, 38(8): 88-93.

YANG Dong-hui, MA Liang, HUANG Wei-dong. Component's surface quality predictions by laser rapid forming based on artificial neural networks[J]. Chinese journal of lasers, 2011, 38(8): 88-93.

(下转第 368 页)

- PANG Jing-zhu. Research and application on grinding heat and its monitoring methods in precision high-speed cylindrical grinding[D]. Shanghai: Donghua University, 2015: 62-63.
- [16] BRINKSMEIER E, MEYER D, HUESMANN-CORDES A G, et al. Metalworking fluids-mechanisms and performance[J]. CIRP Annals-manufacturing technology, 2015, 64(2): 605-628.
- [17] 吴玉厚, 王浩, 孙健, 等. 氮化硅陶瓷干湿磨削温度与表面质量研究[J]. 组合机床与自动化加工技术, 2019(4): 124-128.
- WU Yu-hou, WANG Hao, SUN Jian, et al. Study on temperature characteristics and surface quality of Si_3N_4 ceramics under dry and wet grinding[J]. Modular machine tool & automatic manufacturing technique, 2019(4): 124-128.
- [18] HULSE C O, COPLEY S M, PASK J A. Effect of crystal orientation on plastic deformation of magnesium oxide[J]. Journal of the American Ceramic Society, 1963, 46(7): 317-323.
- [19] SUN J, WU Y H, ZHOU P, et al. The effect of grinding parameters on grinding performance and cracks extending mechanism of Si_3N_4 ceramic based on diamond grains[J]. Revista romana de materiale-romanian journal of materials, 2018, 48(2): 198-203.
- [20] 马廉洁, 巩亚东, 顾立晨, 等. 可加工微晶玻璃陶瓷磨削表面成形机制[J]. 机械工程学报, 2017, 53(15): 201-207.
- MA Lian-jie, GONG Ya-dong, GU Li-chen, et al. Mechanism of surface forming in grinding machinable glass ceramics[J]. Journal of mechanical engineering, 2017, 53(15): 201-207.
- [21] 郭国强, 安庆龙, 林立芳, 等. 成形磨削温度的理论与试验分析[J]. 机械工程学报, 2018, 54(3): 203-215.
- GUO Guo-qiang, AN Qing-long, LIN Li-fang, et al. Analytical and experimental investigation of temperature in form grinding[J]. Journal of mechanical engineering, 2018, 54(3): 203-215.

(上接第 359 页)

- [10] 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): 99-104.
- NI Li-bin, LIU Ji-chang, WU Yao-ting, 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): 99-104.
- [11] 刘立君, 姜亚青, 王晓鹏, 等. 激光熔凝参数 BP 神经网络的反求[J]. 哈尔滨理工大学学报, 2017, 22(3): 112-116.
- LIU Li-jun, JIANG Ya-qing, WANG Xiao-peng, et al. Inverse solution of BP neural network for laser remelting parameters[J]. Journal of Harbin University of Science and Technology, 2017, 22(3): 112-116.
- [12] 雷凯云, 秦训鹏, 刘华明, 等. 基于神经网络的宽带激光熔覆熔池特征参数预测[J]. 光电子·激光, 2018, 29(11): 1212-1220.
- LEI Kai-yun, QIN Xun-peng, LIU Hua-ming, et al. Prediction on characteristics of molten pool in wide-band laser cladding based on neural network[J]. Journal of optoelectronics-laser, 2018, 29(11): 1212-1220.
- [13] 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 Gan-cheng, HUANG Bo. Prediction of Ni-based alloy cladding coatings topography based on GA-BP neural network[J]. Applied laser, 2018, 38(4): 527-535.
- [14] 姜淑娟, 刘伟军, 南亮亮. 基于神经网络的激光熔覆高度预测[J]. 机械工程学报, 2009, 45(3): 269-274.
- JIANG Shu-juan, LIU Wei-jun, NAN Liang-liang. Laser cladding height prediction based on neural network[J]. Journal of mechanical engineering, 2009, 45(3): 269-274.
- [15] SAMPRIT C, ALI S H. Regression analysis by example [M]. America: Wiley-Interscience, 2006.
- [16] 陈子琴, 高向东, 王煜, 等. 大功率激光焊背面焊缝宽度神经网络预测[J]. 焊接学报, 2018, 39(11): 48-52.
- CHEN Zi-qin, GAO Xiang-dong, WANG Yu, et al. Weldment back of weld width prediction based on neural network during high-power laser welding[J]. Transactions of the China welding institution, 2018, 39(11): 48-52.
- [17] 张永帅, 杨国威, 王琦琦, 等. 基于全卷积神经网络的焊缝特征提取[J]. 中国激光, 2019, 46(3): 36-43.
- ZHANG Yong-shuai, YANG Guo-wei, WANG Qi-qi, et al. Weld feature extraction based on fully convolutional networks[J]. Chinese journal of lasers, 2019, 46(3): 36-43.
- [18] MATLAB 中文论坛. MATLAB 神经网络 30 个案例分析 [M]. 北京: 北京航空航天大学出版社, 2010.
- MATLAB Chinese forum. MATLAB neural network 30 case studies[M]. Beijing: Beijing University of Aeronautics and Astronautics Press, 2010.