

激光参数对 DP780 双相钢/PA66 碳纤维界面宽度的影响及其预测模型

贺赵国¹, 周惦武¹, 邓乔², 杨佳豪¹, 王新宇¹

(1. 湖南大学, 整车先进设计制造技术全国重点实验室, 长沙, 410082; 2. 深圳阿尔比斯科技有限公司, 深圳, 518000)

摘要: 钢/碳纤维激光直接连接界面的粘接效果与碳纤维的熔融宽度密切相关, 而激光热输入是影响其熔融宽度的主要因素. 文中进行了 DP780 钢/PA66 碳纤维激光直接连接试验, 基于多层感知机和支持向量机探索了碳纤维熔化宽度的 BP 神经网络预测模型, 并利用 AOA 算法优化了 BP 神经网络. 同时研究了激光参数中光束扫描速率、离焦量和激光功率对熔化宽度的影响, 并计算了激光的能量密度. 结果表明, 通过 AOA 算法优化的 BP 神经网络, 其训练集、测试集和验证集的相关系数 R 分别为 0.962 96, 0.970 09 和 0.988 28, 表明 AOA-BP 预测模型具有良好的预测精度和泛化能力. 此外, 响应曲面的分析结果指出, 激光参数对碳纤维熔融宽度的影响权重从大到小依次为光束扫描速率、离焦量和激光功率. 离焦量正向的增大可以使激光能量分布更加平缓, 扩大光束能量的覆盖范围.

创新点: (1) 采用优化神经网络 AOA-BP 预测了激光焊接钢/碳纤维的界面宽度.

(2) 分析了离焦量、激光功率、光束扫描速率对钢/碳纤维界面宽度成型的影响权重.

(3) 获得良好钢/碳纤维界面的最佳热输入组合为光束扫描速率 20 mm/s、离焦量 0 mm 和激光功率 1 000 W.

关键词: 钢/碳纤维连接; 优化神经网络; 激光能量密度

中图分类号: TG 460 文献标识码: A doi: 10.12073/j.hjxb.20240901002

Influence of laser parameters on the steel/CFRP interface width and its predictive modeling

HE Zhaoguo¹, ZHOU Dianwu¹, DENG Qiao², YANG Jiahao¹, WANG Xinyu¹

(1. State Key Laboratory of Advanced Design and Manufacturing Technology for Vehicle, Hunan University, Changsha, 410082, China; 2. Shenzhen Rapid Parts Solutions Company, Shenzhen, 518000, China)

Abstract: The steel/CFRP interface bonding is determined by the melting width of CFRP in the direct steel/CFRP laser joining, while laser heat input is the major factor affecting the melting width. In this paper, the experiment of steel/CFRP direct laser joining was conducted and a BP neural network prediction model of the CFRP melting width was explored based on MLP and SVM, and the BP neural network was optimized by the AOA algorithm. Meanwhile, based on the RSM analysis, the weights of beam scanning rate, defocusing and laser power on the melting width were studied, and laser energy density distribution was calculated. The results indicate that the related coefficients R in the training, test and validation set of AOA-BP neural network are 0.962 96, 0.970 09, 0.988 28, respectively, which means that the established AOA-BP prediction model exhibits well prediction accuracy and generalization capability. Furthermore, the results of RSM reveal that the descending order of the weights of laser parameters influencing the melting width is as follows: beam scanning rate, defocusing, and laser power. The increase in defocusing serves to flatten the laser energy density distribution, expanding the coverage area of beam energy.

Highlights: (1) Optimized neural network AOA-BP was used for predicting the interfacial width of laser-welded steel/CFRP.

(2) The weights of influence of defocusing, laser power, and beam scanning rate on the width forming of steel/CFRP interface were analyzed.

(3) The optimal combination of laser parameters for obtaining desirable steel/CFRP interface is 20 mm/s beam scanning rate, 0 mm defocusing distance, and 1 000 W laser power.

Key words: steel/CFRP joining; optimized neural network; laser energy density distribution

0 序言

碳纤维增强热塑性复合材料(carbon fiber reinforced plastic, CFRP)在轨道交通、先进能源等领域具有广泛应用前景^[1-3],然而其生产成本低,难以实现单一碳纤维结构件的应用。为实现低成本和轻量化制造,越来越多采用碳纤维与金属材料的异质混合结构件,这样必涉及碳纤维与高强钢等轻质材料之间的连接^[4]。

由于热塑性碳纤维树脂基体可以重熔,因此碳纤维与钢的连接可通过焊接实现^[5],其中激光焊^[6]是近年来发展迅速的连接技术,它利用高能量光束迅速熔化材料,使其快速凝固成形;由于其热输入小,焊后变形小,且焊接时间短,效率高,可获得柔性接头,十分适合钢/碳纤维异种材料之间的焊接。在金属/碳纤维激光连接时^[7],上层的钢吸收光束能量后,能量通过热传导的方式使碳纤维树脂发生熔化,形成接头。Xia 等人^[8]研究发现,激光功率较低时,碳纤维的熔化宽度不足,连接界面处存在间隙,无法形成有效接头;Su 等人^[9]指出,热输入在改变碳纤维熔化宽度的同时,改变了接头的断裂形式;Hao 等人^[10]进一步认为,过度的热输入致使碳纤维在发生过量熔化的同时,使其受到了一定程度上的损伤。因此,在激光焊中,如何进行碳纤维熔化宽度的识别与预测,从而有效控制碳纤维的熔化宽度,一直是自动化焊接研究的重点与难点。

目前,由于激光参量组合繁多,所以需要通过人力进行大量的重复性试验,以获取相应参数下的碳纤维熔化宽度。因此,需要通过建立某种数学模型预测激光参量对于碳纤维熔化宽度的影响,其中由于激光复杂的光电物理现象以及材料的热物理性质差异,激光参量与碳纤维熔化宽度的关系往往不是简单的线性关系,而是一种较为复杂的多元非线性回归问题^[11]。此时,利用反向传播及梯度优化算法的人工神经网络^[12]为解决复杂的多元非线性回归问题提供了思路。邹丽等人^[13]开发了一种粗糙集与径向基函数神经网络集成的焊接疲劳寿命预测模型;邱广宇等人^[14]利用最小二乘法,提出了

一种预测焊接接头疲劳寿命的卷积神经网络;Hamidinejad 等人^[15]使用人工神经网络(artificial neural network, ANN)回归模型成功预测了搅拌摩擦焊中优化参数对于接头最终强度的影响;Campbell 等人^[16]建立了一种神经网络模型,用于预测在交替保护气体频率下接头的有效喉道长度;Nagesh 等人^[17]利用 ANN 的反向传播原理,成功的预测了熔池的几何尺寸与焊缝表面形貌的关系。

文中探索了一种基于多层感知机(multi-layer perceptron, MLP)和支持向量机(support vector machine, SVM)的神经网络为研究对象的碳纤维熔化宽度预测模型,并使用基于元启发式新型智能优化算法(angle of arrival, AOA)对神经网络初始权重进行优化,并用于指导激光热源的光路搭建及模型设计,从而更好的确立合格的实际工业过程中的钢/CFRP 激光焊工艺。

1 试验与神经网络建模

1.1 试验方法

试验所用材料为含 30% 短纤维丝的聚己二酰己二胺 66 (Polyadiohexylenediamine-66, PA66) 树脂碳纤维和双相钢 780 (Dual Phase Steel-780, DP780), 尺寸分别为 75 mm × 30 mm × 2.0 mm 和 75 mm × 30 mm × 1.6 mm。

试验前,用砂纸去除待连接工件表面氧化层,并用丙酮清洗。如图 1 所示,双相钢搭接在碳纤维上,搭接宽度 30 mm,并使用夹具固定。激光器型号为 YLS-4000-CL,最大输出功率为 4.0 kW,光束波长 1 064 nm,光斑直径 0.3 mm,光束发散角 $\alpha < 0.15$ rad,同时,使用氩气保护焊缝,使用压缩空气保护激光头。Zhang 等人^[18]研究发现,沿着钢/CFRP 宽度方向上的温度场会影响界面气泡的形成,从而对接头的力学性能产生影响;Tan 等人^[19]研究了光束扫描速率对钛/CFRP 界面的影响,发现界面宽度方向上,树脂的粘接比例会影响界面的力学性能;Hussein 等人^[20]研究了 304 不锈钢/聚甲基丙烯酸甲酯界面的温度场模型,阐明了界面处树脂熔融温度宽度区间与力学性能之间的关系;Arkhurst 等

人^[21]使用激光连接了镁合金/CFRP, 结果发现沿着宽度方向上的异质界面特性会对接头界面的力学性能造成最为重要的影响; 此外, 之前的工作中发现^[7], 在接头的形成过程中, 熔融的碳纤维树脂裹挟着碳纤维丝沿着宽度方向在钢表面铺展, 并在一定温度的作用下形成钢/碳纤维界面的化学连接, 而在接头的失效过程中, 外力作用导致裂纹产生在钢/CFRP 的接触界面, 也就是宽度方向. 随着外力的进一步作用, 裂纹沿着钢/CFRP 界面不断拓展, 直至接头完全失效. 可见, 对于金属/CFRP 连接界面, 其沿着界面宽度方向上的相关特性会对接头的力学性能产生重要影响. 因此, 试验后使用金相显微镜测量双相钢/碳纤维界面宽度, 如图 2 所示. 优化焊接工艺参数见表 1, 并且文中所采用的离焦量为非负值.




图 1 钢/碳纤维激光焊示意图

Fig. 1 Schematic of steel/CFRP laser welding




图 2 钢/碳纤维界面测量

Fig. 2 Measurement of steel/CFRP interface

表 1 焊接工艺参数
Table 1 Welding parameters

激光功率 P/kW	离焦量 L/mm	焊接速率 $v/(\text{mm}\cdot\text{s}^{-1})$
0.8, 0.85, 0.9, 0.95, 1.0	0, 4, 8	20, 25, 30, 35, 40

1.2 神经网络建模及其优化

多层感知机^[22]是一种基于生物神经元、细胞、触点等提出的, 以监督式学习为主的多层非线性映射系统, 包含输入层、隐含层以及输出层. 将试验得到的特征输入及输出置于其中, 利用正向、反向传

播和梯度下降, 不断的对多层非线性映射系统内部层与层之间的权重及偏差进行更新修正. 正向传播过程为

$$y_i = f_1(\sum_{i=1}^p \omega_{ij}x_i + b_i) \quad (1)$$

隐含层的输出将会作为输出层的输入, 继续进行前向传播, 即

$$y_k = f_2(\sum_{k=1}^s \omega_{jk}y_i + b_k) \quad (2)$$

式中: x 是输入层输入; y 是隐含层输出; f 是隐含层神经元的激活函数; p 和 s 分别是输入和输出层的神经元个数; ω 和 b 分别是输入层与隐含层之间的权重与偏差; i 是隐含层的第 i 个节点; j 和 k 指隐含层与输入层第 j 个与第 k 个神经元.

通过神经网络的正向传播, 由实际得到的特征输入, 得到了输出值, 即预测值. 再利用预测值与实际得到的特征输出, 计算均方误差值 (mean squared error, MSE), 即

$$M_{\text{MSE}} = \frac{\sum_i^m (y_{ki} - y_{li})^2}{m} \quad (3)$$

式中: y_k 指输出特征值; y_l 指实际特征值; y_{ki} 指输出的第 i 个特征值; y_{li} 指实际得到的第 i 个特征值.

基于均方误差值, 利用梯度下降法^[23], 不断修正反向传播神经网络 (back propagation, BP) 层与层之间的权重及偏差, 对网络进行训练.

采用的感知机网络有三层, 分别为输入层、隐含层及输出层, 层与层之间的连接方式为全连接. 其中, 输入层包含 3 个神经元, 分别对应离焦量、激光功率、光束扫描速率, 隐含层包含 5 个神经元; 输出层的单神经元对应 PA66 碳纤维的界面宽度. 最后, 由于传统 BP 神经网络对初始权重较为敏感^[23], 初始随机的权重和偏差会导致在网络局部最优收敛, 每次的求解结果差异性较大. 所以, 需要引入额外的算法优化神经网络的初始权重和偏差, 提高模型的预测精度和泛化能力^[24-25].

Abualigah 等人^[26]提出了一种基于元启发式新型智能优化算法 AOA, 其利用基本的乘除加减运算实现算法的寻优过程. 整个 AOA 优化算法可以被分为以下 3 个过程: 初始化阶段、探索阶段和开发阶段. 在初始化阶段中, 参数范围内随机设置初始解 X , 每次迭代的最佳候选解被确定为当前的最优解, X 为 $N \times n$ 的矩阵, 即

$$X = \begin{pmatrix} x_{11} & \cdots & x_{1n} \\ \vdots & \ddots & \vdots \\ x_{N1} & \cdots & x_{Nn} \end{pmatrix} \quad (4)$$

AOA 算法的初始化阶段,在 $[0,1]$ 中取随机数 r ,并将 r 与数学优化器加速函数 MOA 进行比较.若 r 大于等于 MOA ,则选择探索阶段,进行参数的迭代寻优.反之,若 r 小于 MOA ,则选择开发阶段,即

$$MOA(I) = M_{\min} + I \times \frac{M_{\max} - M_{\min}}{M_I} \quad (5)$$

式中: I 为当前迭代次数; M_I 为最大迭代次数; M_{\max}/M_{\min} 为加速函数的最大/最小值.

探索阶段主要利用除法机制和乘法机制两个搜索机制作为搜索策略,参考式 (6). 在 $[0,1]$ 中任取一个随机数 r_0 . 若 $r_0 > 0.5$, 选择最外层除法策略,反之选择乘法策略.

$$f_{\text{MOP}}(t) = 1 - \frac{\frac{1}{C_I^a(t)}}{\frac{1}{M_I^a(t)}} \quad (6)$$

式中: $f_{\text{MOP}}(t)$ 为 t 次迭代时的函数值; a 为敏感参数.

利用 AOA 算法求解由 BP 神经网络中权重及偏差所构成的高维参数空间,寻找目标神经网络中初始权重及偏差最优解,从而实现对 BP 神经网络的优化,得到 AOA-BP 优化神经网络,如图 3 所示.

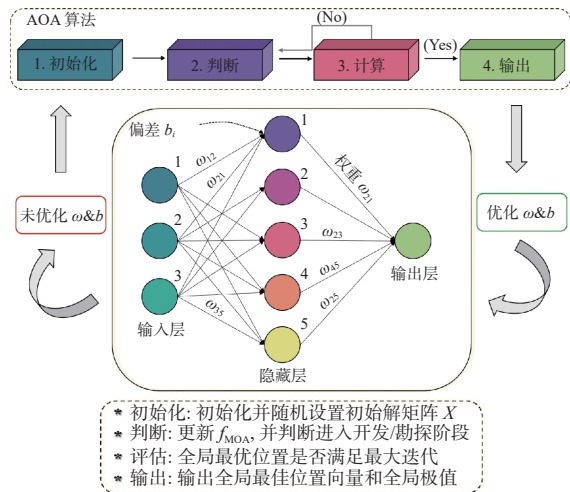


图 3 AOA 算法优化 BP 神经网络

Fig. 3 Flowchart of AOA algorithm to optimize BP neural network

2 结果与分析

图 4 展示了 AOA 算法对神经网络初始权重及偏差的优化迭代过程. 在迭代初期 (0~23 代), 算法迭代曲线的函数值下降较慢, 基本保持在 0.042 5 不再变化; 当迭代达到第 25 轮时, 摆脱了局部最优的束缚, 算法迭代曲线的函数值骤然下降, 降低至

0.033, 进一步探索全局的最优解; 最后, 在经过 30 轮的迭代, 算法迭代曲线的函数值降到最低 0.032, 表明 AOA 寻找到了 BP 神经网络最优的初始权重及偏差. 随后, 将优化的权重及偏差输入 BP 神经网络中, 为后续的回归训练过程建立网络基础结构.




图 4 AOA 算法优化迭代过程

Fig. 4 AOA algorithm optimization the iterative process

当 BP 神经网络获取经过 AOA 算法优化后的权重及偏差后, 根据图 3 的训练流程图, 开展神经网络模型的建立. 在训练过程中, 为了使得神经网络可以给出较为精确的拟合结果, 相应的目标的 MSE 误差被设定为 1×10^{-3} . 同时, 为了对比 AOA 对 BP 神经网络的优化效果, 图 5 分别展示了 BP 及 AOA-BP 优化神经网络训练、验证及测试时的损失函数变化曲线. 由图 5(a) 可知, 未经 AOA 优化的 BP 神经网络, 在训练集中, 神经网络不断学习数据的特征, 其 MSE 值不断下降, 在网络训练第 2 代时低于设定的目标误差值 1×10^{-3} . 相反, 神经网络在验证集与测试集中, 第一代误差函数的拐点, 当迭代次数大于 1 时, MSE 值不断增大, 上述现象表明, 此时的 BP 神经网络发生了过拟合现象, 即数据集在训练集中的误差极小, 但在测试与验证集中的误差较大; 如图 5(b) 所示, 经过 AOA 优化的 BP 神经网络 (AOA-BP), 在训练过程中, 当训练过程迭代 27 代后, MSE 误差函数值在不断减小, 训练集的误差大于测试集与验证集, MSE 的最小值为 0.028 4, 表明 AOA-BP 优化神经网络在整个的训练过程中避免了过拟合的产生.

经过训练, 图 6 展示了上述两种神经网络的预测值与试验值的对比结果, 同时, 使用标准差 (standard deviation, STD) 及平均百分误差 (mean absolute percentage error, MAPE)^[27] 分别表征预测




图 5 神经网络损失函数曲线

Fig. 5 Neural network loss function curve. (a) loss function curve of BP neural network; (b) loss function curve of AOA-BP neural network

结果误差的稳定性及预测模型的精度, STD 和 MAPE 的值越小, 表明所建立模型的预测结果精度和稳定性越高.

图 6 给出了未优化 BP 神经网络训练集的预测结果, 并列举了训练集的 STD 及 MAPE 的计算结果, 见表 2 和表 3. 由表可知, 在 BP 神经网络中, 相比训练集, 其验证集的 STD 值较大, 说明在训练过程中, 训练集中的预测精度较高, 但是在训练结束后, 模型在验证集中的预测误差较为不稳定. 同时, 从图 6 可以看出 BP 神经网络在验证集的预测值与试验值有较大的差异, 这是因为, BP 神经网络在预测过程中发生了过拟合现象. 换言之, BP 神经网络在训练集中搜寻到了误差函数的全局较优值, 而在测试集中仅收敛在误差函数曲面的局部最优处, 表明模型的泛化能力较差, 不能够建立起稳定及准确的预测模型.

图 7 展示了优化神经网络 AOA-BP 预测值与试验值的对比结果, 相应的 STD 及 MAPE 也被列举在表 4 和表 5 中. 由表可知, AOA-BP 神经网络在训练集与测试集中的 STD 值和 MAPE 均较低, 且显著低于原始的 BP 神经网络, 表明 AOA-BP 神

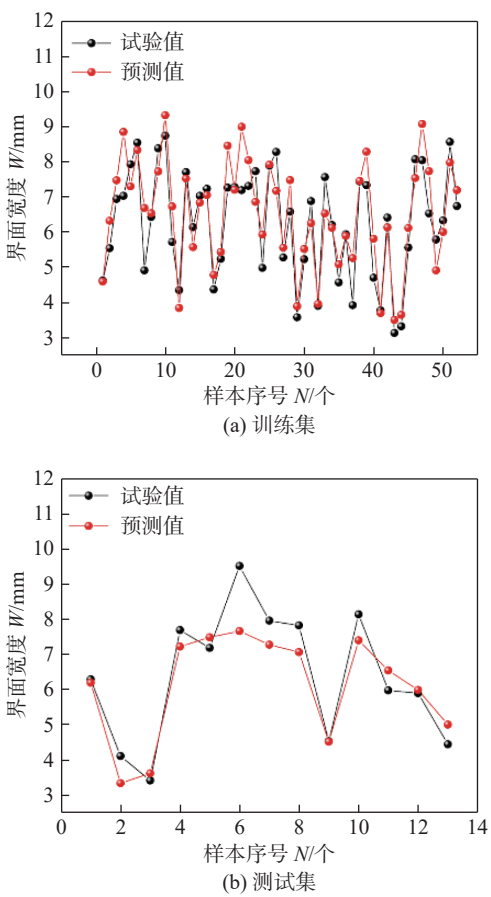


图 6 BP 神经网络训练/测试结果对比

Fig. 6 Comparison of BP neural network results. (a) training; (b) testing


表 2 BP 神经网络训练集对比
Table 2 Training set of BP neural network

序号	试验数据 W_1/mm	预测数据 W_2/mm	标准差 S_{STD}	平均误差 M_{MAPE}
1	6.13	5.561	0.32	0.09
2	7.02	6.827	0.03	0.03
3	7.25	8.442	1.42	0.08
4	6.57	7.461	0.79	0.07
5	3.57	3.879	0.09	0.04


表 3 BP 神经网络测试集对比
Table 3 Validation set of BP neural network

序号	试验数据 W_1/mm	预测数据 W_2/mm	标准差 S_{STD}	平均误差 M_{MAPE}
1	8.54	7.879	0.43	0.04
2	8.14	7.721	0.17	0.03
3	9.77	8.117	2.73	0.08
4	6.61	7.116	0.25	0.04
5	5.24	5.743	0.25	0.05

经网络所建立的预测模型具有良好的预测精度及泛化能力.



(a) 训练集



(b) 测试集

图7 AOA-BP神经网络结果对比

Fig. 7 Comparison of BP neural network. (a) training; (b) testing results

表4 AOA-BP神经网络训练集对比

Table 4 Training set of AOA-BP neural network

序号	试验数据 W_1/mm	预测数据 W_2/mm	标准差 $S_{\text{STD}} (10^{-3})$	平均误差 $M_{\text{MAPE}} (10^{-3})$
1	7.89	7.857	1.09	2.09
2	7.69	7.720	0.90	3.90
3	7.43	7.500	4.9	4.71
4	6.19	6.219	0.729	2.34
5	8.38	8.388	0.064	0.477

表5 AOA-BP神经网络测试集对比

Table 5 Validation set of AOA-BP neural network

序号	试验数据 W_1/mm	预测数据 W_2/mm	标准差 $S_{\text{STD}} (10^{-3})$	平均误差 $M_{\text{MAPE}} (10^{-3})$
1	7.02	7.044	1.09	1.71
2	3.57	3.597	0.729	3.78
3	5.62	5.317	5.93	7.35
4	8.03	8.038	0.064	4.98
5	6.73	6.728	0.004	0.149

图8展示了神经网络预测模型的多元非线性回归结果。多元非线性回归结果中的相关系数 R 值,表明了模型的精度,其值越大,模型精度越





(a) 训练集 $R = 0.977\ 47$ (b) 验证集 $R = 0.919\ 18$ (c) 测试集 $R = 0.943\ 71$ (d) 全集 $R = 0.977\ 47$

图8 BP神经网络的多元回归结果

Fig. 8 Multiple regression results for BP neural networks. (a) training set; (b) validation set; (c) test set; (d) universal set


高^[26], 即

$$R = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 \sum (y - \bar{y})^2}} \quad (7)$$


式中: x, \bar{x}, y, \bar{y} 分别表示两个变量及其平均值. 而不同集合中的 R 值则可以反应所建立模型的泛化能力^[26]. 其中未经优化 BP 神经网络的回归结果参考图 8. BP 神经网络在训练集中的相关系数 R 为 0.977 47, 表明此时的拟合结果良好, 模型精度良好. 然而, 在验证集与测试集中的相关系数 R 却分别为 0.919 18 与 0.943 71, 均低于训练集, 说明模型陷入了过拟合, 所建立模型的泛化能力较差.

图 9 为 AOA-BP 神经网络的多元非线性回归结果, 其中训练集的相关系数 R 为 0.962 96, 在验证集与测试集中分别为 0.970 09 和 0.988 28, 整体的相关系数 R 为 0.961 03, 表明 AOA 算法对 BP 神经网络权重优化是有效的, 模型在训练集以外的集合也表现出良好的预测精度, 此时模型的泛化能力良好.


在所建立的 AOA-BP 神经网络预测模型的基础上, 采用曲面响应法^[27] 分析了激光功率、光束扫描速率与离焦量 3 个激光参量对碳纤维熔化宽度的影响权重, 如图 10 所示. 图 10(a) 中碳纤维熔化宽度的极值出现在二维映射图的右下角, 说明随着激光功率的提升, 以及较低的光束扫描速率, 可以促进碳纤维熔化宽度的增大. 同时, 当激光功率或光束扫描速率值固定时, 可以看到碳纤维熔化宽度变化的较大梯度出现在靠近光束扫描速率的一侧, 表明相比激光功率, 碳纤维熔化宽度受光束扫描速率的变化影响较大; 图 10(b) 中碳纤维熔化宽度的极值出现在二维映射图的右上角, 说明随着离焦量的增大, 以及激光功率的增大, 碳纤维熔化宽度不断增大, 同时碳纤维熔化宽度变化梯度的较大值在靠近离焦量的一侧, 说明相比激光功率, 离焦量是影响碳纤维熔化宽度的主要参量; 图 10(c) 中碳纤维熔化宽度的极值出现在右下角, 说明随着离焦量的增大以及光束扫描速率的降低, 碳纤维熔化宽度不断上升, 其中碳纤维熔化宽度变化梯度的较大值在靠近光束扫描速率的一侧, 这说明在这两个特征参量中, 光束扫描速率为影响碳纤维熔化宽度变化的主要参量. 总而言之, 激光功率、离焦量以及光束扫描速率 3 个特征参量, 对碳纤维熔化宽度影响程度从大到小排序依次为光束扫描速率、离焦量、激光功率.




(a) 训练集 $R = 0.962\ 96$



(b) 验证集 $R = 0.970\ 09$



(c) 测试集 $R = 0.988\ 28$



(d) 全集 $R = 0.961\ 03$

图 9 AOA-BP 优化神经网络的多元回归结果

Fig. 9 Multiple regression results for AOA-BP neural networks. (a) training set; (b) validation set; (c) test set; (d) universal set

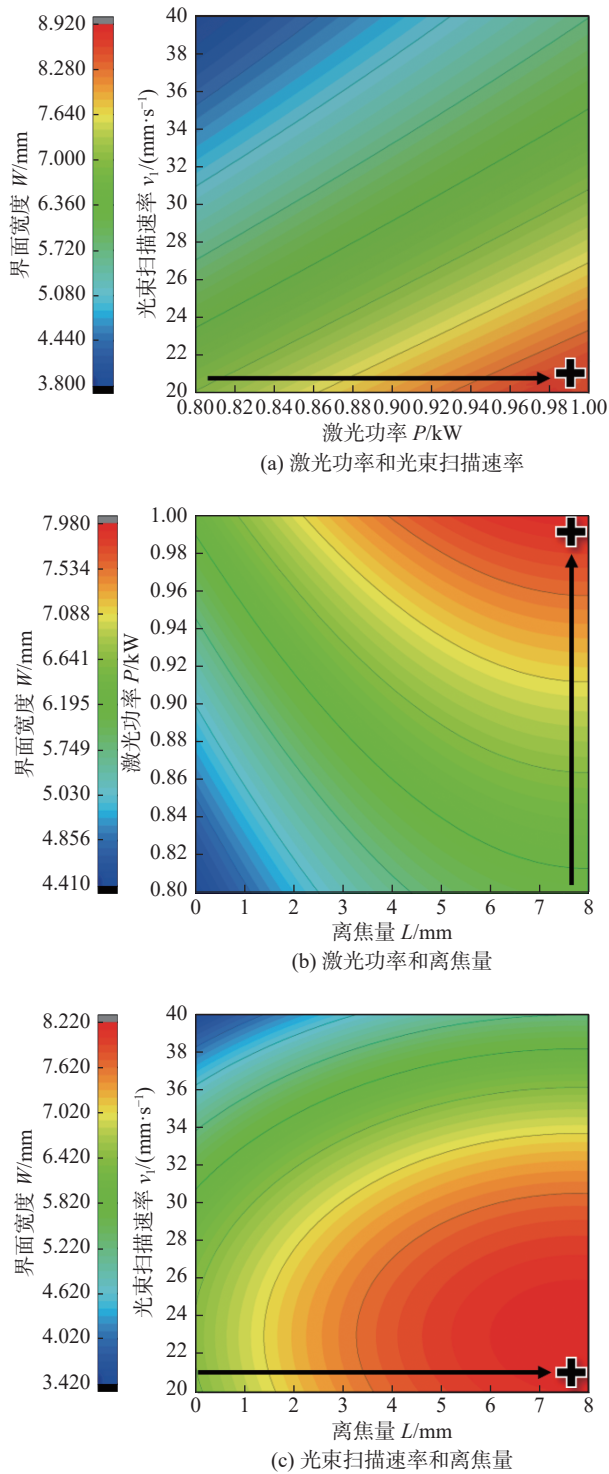


图 10 激光工艺参数与碳纤维界面宽度的响应曲面分析
Fig. 10 Response surface analysis of laser process parameters and carbon fiber interfacial widths. (a) laser power and beam scanning speed; (b) laser power and defocus distance; (c) beam scanning speed and defocus distance

文中所采用的激光器,其波长为 1 064 nm,最小光斑直径为 0.3 mm. 在试验过程中,随着离焦量逐渐向正向增大,光斑直径也逐渐增大,致使激光的辐射面积增加. 然而,光斑直径增大后,会导致激光在光斑直径范围内的能量密度值降低. 所以,当

离焦量正向扩大时,如果需要保证整体热输入的的稳定,可以通过增大激光功率提高光斑直径范围内的能量密度,也可以通过降低光束扫描速率,以提升线性热输入,确保整体热输入的的稳定. 同时,整体热输入也会对钢/CFRP 界面的宽度产生影响. 在试验中发现,当光束扫描速率越低,且激光功率和离焦量越大时,所获得的钢/CFRP 界面宽度较大. 然而,当观察表 3 中 9.77 mm 的界面时,发现界面存在大量的工艺性气孔,反而恶化了接头性能. 因此,针对 DP780 钢/PA66 CFRP 的连接界面,基于上述整体热输入量调整思路,当把表 1 中的激光参数先后控制在光束扫描速率 20 mm/s、离焦量 0 mm、激光功率 1 000 W 时^[7],可以获得界面宽度为 5.62 mm (表 5) 且无气孔、间隙,连接性能较好的钢/CFRP 界面.

为了进一步解释光束扫描速率、离焦量及激光功率 3 个输入特征对钢—碳纤维界面宽度的影响机理,计算了不同条件下的激光能量密度. 高斯分布通常用来描述激光能量的分布,其表达式为^[28]

$$I = \frac{2\eta P}{\pi r_0^2} e^{-\frac{2(x^2+y^2)}{r_0^2}} \quad (8)$$

式中: I 表示激光能量强度; η 表示材料的激光吸收率; P 表示激光功率; r_0 表示光斑半径; r 表示到光斑中心的距离; x 和 y 分别表示光斑沿 x 方向和 y 方向的位置.

由图 10 可知,激光功率、离焦量与界面宽度呈正相关关系,光束扫描速率与界面宽度呈负相关,其中由于不同特征参数的量纲不同,因此所有特征参数的变化比例被控制在 25%,以计算不同条件下的激光能量分布. 如图 11 所示,仅当光束扫描速率变化时,激光峰值能量从 160 J/mm² 提升至 200 J/mm²,增加了 25%;仅当激光功率提升时,激光峰值能量的提升较低,仅有 14.2%,其中激光功率与光束扫描速率分别变化时,激光辐射宽度并没有发生变化,仅有激光的峰值能量上升;仅当离焦量增加时,激光能量辐射宽度增大,这有利于光束能量向垂直于光束通道的两侧扩散,但是相应的激光峰值能量下降. 综上所述,3 个激光参量发生相同比例的变化时,光束扫描速率所引起的激光峰值能量变化幅度 (25%) 大于激光功率 (14.2%). 在这个过程中,激光能量的辐射宽度并未发生改变,与此同时,离焦量的变化使得激光能量辐射宽度增大,促进了能量在光束通道法向方向的传递,光束能量在

钢表面的覆盖区域增大. 上层钢吸收激光能量后, 通过热传导的方式将能量传递至下层的碳纤维, 使其发生熔化, 形成钢/碳纤维连接界面. 因此, 钢—碳纤维界面的宽度, 取决于界面处所吸收的能量大小. 其中上层较大的激光峰值能量有利于能量向下层界面处的传递, 增大界面处所获得的能量大小^[11]. 而较大的光束覆盖面积, 配合适当的激光功率, 在保证界面处获得足够熔融能量的同时, 可以促进能量向两侧的扩散, 增大界面处的熔化面积.

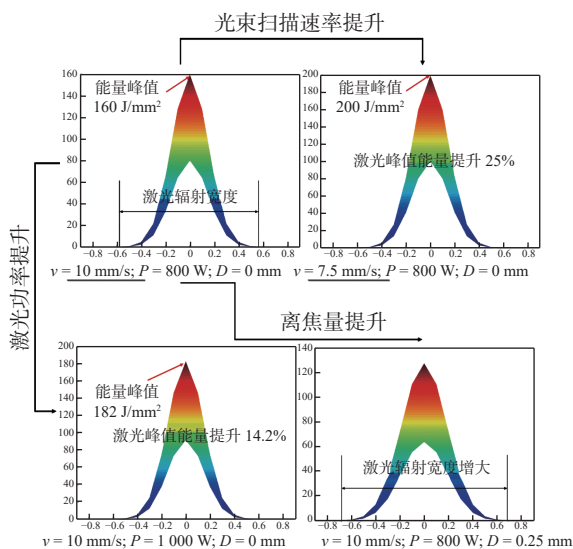


图 11 不同参数下的激光能量分布

Fig. 11 Laser energy density distribution with various parameters

综上所述, 通过响应曲面法以及不同条件下激光能量的计算, 发现影响钢—碳纤维界面宽度的激光参量权重从大至小依次为光束扫描速率、离焦量、激光功率.

根据报道^[10], 在金属和碳纤维的连接中, 界面处过高的热输入会导致碳纤维树脂发生热分解, 损坏其连接界面, 而较低的热输入会导致界面热量不足, 碳纤维融化量有限, 无法形成有效的接头. 所以, 为了实现对钢—碳纤维界面处热输入的精确控制, 以获得良好的接头界面, 光束扫描速率是首要的目标控制变量, 可以使用机器人手臂的水平线性位移速率控制器调整; 其次, 根据图 11, 正离焦量的增大, 扩大了激光能量的覆盖范围, 峰值能量下降且促进了光束能量向两侧的传递, 激光能量呈现为扁平状分布. 同时, 根据激光器的工作原理^[28], 光子在谐振腔及增益介质内部大量形成后, 形成激光束, 通过光纤传输到激光器镜头的光学模组中 (包含振镜、场镜及准直、保护镜片), 最终作用在工件

的表面. 所以, 通过调整激光器镜头光学模组中的场镜尺寸与准直之比^[29], 可以获得不同程度上扁平状分布的激光能量. 此外, 同样的激光器, 使用不同尺寸的光纤芯径时, 其激光能量密度数值是不同的, 相应的激光能量分布形式也会发生变化^[30-33], 但是其较高的成本需要额外考虑; 最后, 在光束扫描速率和离焦量的数值确定后, 改变激光器的输出功率, 进一步对激光的热输入量进行控制, 最终实现对钢—碳纤维界面热量的精确调控, 以获得性能良好的钢/碳纤维接头界面.

3 结论

(1) 基于 AOA-BP 优化神经网络, 建立了激光功率、离焦量、光束扫描速率与钢/碳纤维界面宽度的预测模型. 训练集的 MSE 函数值小于验证集和测试集, 经过 27 次迭代, 达到最小值 0.028 4. AOA-BP 优化神经网络在训练集、验证集和测试集中的 R 值分别为 0.962 96, 0.970 09, 0.988 28, 表明所建立预测模型良好的预测精度及泛化能力.

(2) 响应曲面模型分析结果表明, 钢/碳纤维界面宽度与激光功率、离焦量成正比, 与光束扫描速率成反比. 影响钢/碳纤维界面宽度的激光参量权重排序从大到小依次为光束扫描速率、离焦量和激光功率. 获得良好钢/碳纤维界面的最佳热输入组合为光束扫描速率 20 mm/s、离焦量 0 mm 和激光功率 1 000 W.

参考文献

- [1] Wang K, Shriver D, Li Y, *et al.* Characterization of weld attributes in ultrasonic welding of short carbon fiber reinforced thermoplastic composites[J]. *Journal of Manufacturing Processes*, 2017, 29: 124 – 132.
- [2] Kashaev N, Ventzke V, Riekehr S, *et al.* Assessment of alternative joining techniques for Ti-6Al-4V/CFRP hybrid joints regarding tensile and fatigue strength[J]. *Material Design*, 2015, 81: 73 – 81.
- [3] Li J, Zhang K, Li Y, *et al.* Influence of interference-fit size on bearing fatigue response of single-lap carbon fiber reinforced polymer/Ti alloy bolted joints[J]. *Tribology International*, 2016, 93: 151 – 162.
- [4] Sairajan K, Aglietti G, Mani K. A review of multifunctional structure technology for aerospace applications[J]. *Acta Astronaut*, 2016, 120: 30 – 42.
- [5] Pramanik A, Basak A K, Dong Y, *et al.* Joining of carbon fiber re-

- inforced polymer (CFRP) composites and aluminium alloys -a review[J]. *Composite, Part A: Applied Science and Manufacturing*, 2017, 101: 1 – 29.
- [6] Pan X, Wang X, Tian Z, *et al.* Effect of dynamic recrystallization on texture orientation and grain refinement of Ti6Al4V titanium alloy subjected to laser shock peening[J]. *Journal of Alloy Compounds*, 2021, 850: 156672.
- [7] He Z, Zhou D, Zhou S, *et al.* Effect of linear heat input on the interface and mechanical properties of steel/CFRP laser welding joint[J]. *Composite Structures*, 2024, 324: 117652.
- [8] Xia H, Ma Y, Chen C, *et al.* Influence of laser welding power on steel/CFRP lap joint fracture behaviors[J]. *Composite Structures*, 2022, 285: 115247.
- [9] Su J, Tan C, Wu Z, *et al.* Influence of defocus distance on laser joining of CFRP to titanium alloy[J]. *Optics and Laser Technology*, 2020, 124: 106006.
- [10] Hao K, Liao W, Zhang T, *et al.* Interface formation and bonding mechanisms of laser transmission welded composite structure of PET on austenitic steel via beam oscillation[J]. *Composite Structures*, 2022, 235: 111752.
- [11] Ai Y, Lei C, Cheng J, *et al.* Prediction of weld area based on image recognition and machine learning in laser oscillation welding of aluminum alloy[J]. *Optics and Lasers in Engineering*, 2023, 160: 107258.
- [12] Li Y, Lee T, Wang C, *et al.* An artificial neural network model for predicting joint performance in ultrasonic welding of composites[J]. *Procedia CIRP*, 2018, 76: 85 – 88.
- [13] 邹丽, 杨鑫华, 孙屹博, 等. 基于RS-RBFNN的钛合金焊接接头疲劳寿命预测[J]. *焊接学报*, 2015, 36(4): 25 – 29.
- Zou Li, Yang Xinhua, Sun Yibo, *et al.* Fatigue life prediction of titanium alloy welded joints based on RS-RBFNN[J]. *Transactions of the China Welding Institution*, 2015, 36(4): 25 – 29.
- [14] 邱广宇, 耿健, 史少聪, 等. 基于卷积神经网络的焊接接头疲劳寿命预测[J]. *现代制造技术与装备*, 2024(60): 8.
- Qiu Guangyu, Geng Jian, Shi Shaocong, *et al.* Fatigue life prediction of welded joints based on convolutional neural network[J]. *Modern Manufacturing Technology and Equipment*, 2024(60): 8.
- [15] Hamidinejad S M, Kolahan F, Kokabi A H. The modeling and process analysis of resistance spot welding on galvanized steel sheets used in car body manufacturing[J]. *Material Design*, 2012, 34: 759 – 767.
- [16] Campbell S W, Galloway A M, McPherson N A. Artificial neural network prediction of weld geometry performed using GMAW with alternating shielding gases[J]. *Welding Journal*, 2012, 91(6): 174s – 181s.
- [17] Nagesh D S, Datta G L. Prediction of weld bead geometry and prediction in shielded metal-arc welding using neural networks[J]. *Journal of Material Process Technology*, 2002(79): 1 – 10.
- [18] Zhang Z, Tan X, Zhang J, *et al.* Suppression of shrinkage porosity in laser-joining of CFRP and steel using a laser surface modification process “Surfi-Sculpt”[J]. *International Journal of Adhesion and Adhesives*, 2018(85): 184 – 192.
- [19] Tan C, Su J, Zhu B, *et al.* Effect of scanning speed on laser joining of carbon fiber reinforced PEEK to titanium alloy[J]. *Optics and Laser Technology*, 2020(129): 106273.
- [20] Hussein F, Salloomi K, E. Akman, *et al.* Finite element thermal analysis for PMMA/st.st.304 laser joining[J]. *Optics and Laser Technology*, 2017(87): 64 – 71.
- [21] Arkhurst B, Seol J, Lee Y, *et al.* Interfacial structure and bonding mechanism of AZ31/carbon-fiber-reinforced plastic composites fabricated by thermal laser joining[J]. *Composite Part B*, 2019, 167: 71 – 82.
- [22] Nagesh D S, Datta G L. Prediction of weld bead geometry and prediction in shielded metal-arc welding using neural networks[J]. *Journal of Materials Processing Technology*, 2002, 79: 1 – 10.
- [23] Cherkassky V, Ma Y. Practical selection of SVM parameters and noise estimation for SVM regression[J]. *Neural Network*, 2004, 17(1): 113 – 26.
- [24] Vapnik C C V. Support-vector networks[J]. *Machine Learning*, 1995, 20: 273 – 97.
- [25] Zhang J, Yue X, Qiu J. A unified ensemble of surrogates with global and local measures for global metamodelling[J]. *Engineering Optimization*, 2020, 53(3): 474 – 495.
- [26] Abualigah L, Diabata A, Mirjalili S, *et al.* The arithmetic optimization algorithm[J]. *Computer Methods in Applied Mechanics and Engineering*, 2021, 376(1): 113609.
- [27] Box G E P. The exploration and exploitation of response surfaces: some general considerations and examples[J]. *Biometrics*, 1954, 10(1): 16 – 60.
- [28] Farshad M, Sadeh J. A novel fault-location method for HVDC transmission lines based on similarity measure of voltage signals[J]. *IEEE Transactions on Power Delivery*, 2013, 28(4): 2483 – 2490.
- [29] Rai R, Kelly S, Martukanitz R, *et al.* A convective heat-transfer model for partial and full penetration keyhole mode laser welding of a structural[J]. *Metallurgical and Materials Transactions A-Physical Metallurgy and Materials Science*, 2008, 1(39A): 98 – 112.
- [30] Schweier M, Heins J, Haubold M, *et al.* Spatter formation in laser welding with beam oscillation[C]//7th International WLT Conference on Lasers in Manufacturing, 2013: 20 – 30.
- [31] Siegman A, Townsend S. Output beam propagation and beam quality from a multimode stable-cavity laser[J]. *IEEE Journal of Quantum Electronics*, 1993, 29(4): 1212 – 1217.
- [32] Shao K, Zhou Q, Chen Q, *et al.* Research progress of water-laser compound machining technology[J]. *Coatings*, 2022, 12(12): 1887.
- [33] Baldeck L, Raccach, Alfano R. Observation of self-focusing in optical fibers with picosecond pulses[J]. *Optics Letter*, 1987, 12(8): 588 – 589.

第一作者:贺赵国,博士研究生;主要研究方向为钢/碳纤维异种材料连接;Email: hezhaoguohzg@163.com.

通信作者:周怿武,博士,教授;Email: ZDWe_mail@hnu.edu.cn.