

文章编号: 1001-3806(2007)05-0511-04

基于进化神经网络的激光熔覆层质量预测

徐大鹏, 周建忠*, 郭华锋, 季霞

(江苏大学 机械工程学院, 镇江 212013)

摘要: 为了有效地控制激光熔覆层质量, 采用反向传播 (BP) 算法建立了激光熔覆层质量 (熔覆层宽度、熔覆层深度和稀释率) 随激光功率、光斑直径和扫描速度变化的进化神经网络预测模型。针对 BP 算法存在收敛速度慢、容易陷入局部极小值及全局搜索能力弱等缺陷, 采用遗传算法训练 BP 神经网络, 取代了一些传统的学习算法, 设计了基于进化神经网络的学习算法。经过理论分析和实验验证, 在神经网络的输出端得到期望的线性输出, 并在训练样本之外, 选取了 5 组工艺参数检验神经网络模型的可靠性, 预测结果与相应的实验结果的最大相对误差为 2.14%。结果表明, 运用该模型可以方便、准确地选择激光工艺参数, 提高激光熔覆层的加工质量。

关键词: 激光技术; 激光熔覆成形; 熔覆层质量; 人工神经网络; 遗传算法

中图分类号: TG156.9; TP183 文献标识码: A

Quality prediction of laser cladding layer based on improved neural network

XU Da-peng, ZHOU Jian-zhong, GUO Hua-feng, JI Xia

(School of Mechanical Engineering, Jiangsu University, Zhenjiang 212013, China)

Abstract Artificial neural networks were introduced in the area of laser cladding forming. The prediction model of surface quality in laser cladding parts, including the width, depth of cladding layer and dilution, was proposed based on the improved learned arithmetic. The model combined the global optimization searching performance of the genetic algorithm and the localization of the back propagation (BP) neural networks. Five technical parameters were selected to test the reliability of the model. The simulation and experimental results show that the evolutionary neural network based on genetic algorithm can effectively overcome the problem of falling into local minimum point. This method can get higher accuracy of prediction. It improves the measurement precision with the maximum relative error 2.14% between the predicted content and the real value.

Key words laser technique; laser cladding forming; quality of cladding layer; artificial neural networks; genetic algorithm

引 言

激光熔覆成形技术是在快速原型制造技术和激光熔覆表面强化技术的基础上发展起来的一项新的先进的制造技术, 它既保留了快速原型制造技术中能够快速制造任意形状复杂零件的特点, 又具有成形零件性能优良、组织结构致密的优点, 能实现高性能致密金属零件的快速无模近终形制造, 是快速成形技术的一个重要发展方向。但激光熔覆层质量的影响因素较多^[1-5], 且在加工过程中还存在着许多不确定或难以确定的因素, 这些因素有送粉系统的稳定性、激光喷嘴的聚焦性、激光功率、光斑直径、扫描速度等, 因此, 要想获得最佳的熔覆层质量, 必须要积累大量的加工经验, 因这种方法试验成本高、工作量大, 往往造成一定程度的浪费。

正是由于以上所提到的激光熔覆成形工艺的特点及复杂性, 激光熔覆成形技术工艺条件的优化面临着许多问题和困难, 而反向传播 (back propagation, BP) 神经网络 (artificial neural networks, ANN) 具有强大的自适应、自组织、自学习及联想记忆能力, 对复杂的非线性过程高效、精度地建立模型。通过熔覆层宽度、熔覆层深度和稀释率来评价熔覆层质量, 利用人工神经网络高度的非线性处理能力对实验数据进行分析, 找出工艺参数与激光熔覆层质量之间普遍规律, 以实现激光熔覆层质量的预测。运用该方法可以激光加工过程智能控制及加工质量的预报, 降低对操作人员的技术要求以及提高加工效率有着重要的意义, 并为实际应用提供依据。

1 神经网络的结构

影响激光熔覆层质量的因素很多, 主要有激光功率 P (W)、光斑直径 D (mm)、扫描速度 v ($\text{mm} \cdot \text{min}^{-1}$)。由于这 3 个工艺参数与激光熔覆层质量之间存在复杂的非线性关系, 通过建立 3 层 BP 神经网络

作者简介: 徐大鹏 (1979-), 男, 硕士研究生, 主要从事基于激光熔覆的金属零件快速制造技术的研究。

* 通讯联系人。E-mail: zhoujz@ujs.edu.cn

收稿日期: 2006-07-26 收到修改稿日期: 2006-09-06




Fig 1 BP neural networks structure

模型来进行研究。其 BP 模型结构如图 1 所示。图中输入层有 3 个输入神经元 (X_1, X_2, X_3), 即激光功率、光斑直径和扫描速度; 输出层有 3 个输出神经元 (Y_1, Y_2, Y_3), 即熔覆层质量的 3 个评价指标, 熔覆层宽度 w 、熔覆层高度 H 和稀释率 η 。隐层有 m 个神经元, 其单元数依据输入样本的个数确定。

该 3 层 BP 神经网络的学习过程如下: 对于第 k ($k = 1, 2, \dots, K$) 个输入模式, 第 m ($m = 1, 2, \dots, M$) 个隐层神经元的输出 h_{km} , V_m 为输出层神经元与第 m 个隐层神经元之间的连接权值, W_{mn} 为第 m 个隐层神经元与第 n ($n = 1, 2, 3$) 个输入层的输入神经元的之间的连接权值。对于第 k 个输入模式, 第 n 个输入神经元的输入为 X_{kn} , 所期望的输出为 A_{ko} 。根据对神经元的定义, 第 m 个隐层神经元的输出 $h_{km} = f(\sum_{n=1}^3 W_{mn} \times X_{kn})$, 其中 $f(x) = (1 + e^{-x})^{-1}$, 同样第 k 个输入模式, 输出层为 $A_k = \sum_{m=1}^M V_m \times h_{km}$, 为此, 系统的总能量定义为 $E = \frac{1}{2} \sum_{k=1}^K (A_{ko} - A_k)^2$, BP 算法的过程就是反复迭代改变 W_{mn}, V_m 权值, 以保证系统能量函数的值最小。根据梯度下降算法, 可得到每一层的权值递迭公式^[6]:

$$V_m(N+1) = V_m(N) - \delta(\partial E / \partial V) \quad (1)$$

$$W_{mn}(N+1) = W_{mn}(N) - \delta(\partial E / \partial W) \quad (2)$$

每一次递迭过程中隐含层至输出层、输入层至隐含层权值的变化分别表示为^[6]:

$$\Delta V_m(N+1) = \delta \sum_{k=1}^K \theta_k h_{km} + \alpha \Delta V_m(N) \quad (3)$$

$$\Delta W_{mn}(N+1) = \delta \sum_{k=1}^K D_{kn} X_{kn} + \alpha \Delta W_{mn}(N) \quad (4)$$

式中, $\theta_k = A_k(1 - A_k)(A_{ko} - A_k)$, $D_{kn} = A_k(1 - A_k)\theta_k V_m$, δ 为学习效率, α 为调整系数, N 为递迭次数。

2 基于遗传算法的神经网络优化

因 BP 神经网络易陷入局部最小值, 使用遗传算法能够有效地优化神经网络权值和阈值。过程如下^[7]。

(1) 对神经网络的权值和阈值使用二进制代码 ($0, 1$) 进行编码, 编码的位数和求解的精度有关, 一个解的实际值 P 和它的二进制位串表示值 Q 的关系如下:

$$Z = Z_{\min} + \frac{Q}{2^L - 1} (Z_{\max} - Z_{\min} + 1) \quad (5)$$

式中, L 为二进制编码长度, Z_{\max} 和 Z_{\min} 分别为 Z 取值范围的最大值和最小值。

(2) 产生适应度值的评价函数, 该函数以神经网络的最后输出值作为目标, 适应度函数有下式计算:

$$f = \frac{1}{1 + E} \quad E = \frac{1}{2} \sum_{i=1}^k (\bar{y}_i - y_i)^2 \quad (6)$$

式中, y_i 为导师信号, 即熔覆层质量的实验值; \bar{y}_i 为网络输出值, k 为样本集的个数。

(3) 选择若干适应度最大的个体, 直接继承给下一代。采用适应度比例方法进行选择操作。在该方法中, 各个个体的选择概率和其适应度值成比例。在当前父代和子代中, 为了不使适应度最大的个体被淘汰, 采用父代适应度最大的个体替代遗传操作后产生的个体中适应度最差的个体。

(4) 交叉和变异, 产生新个体。

(5) 计算新一代的种群的评价函数的适应度; 如果不满足要求, 则重新进行选择、交叉和变异等过程, 直到适应值不再有效地增加为止。流程图如图 2 所示。网络模型使用的参数为: 初始组群 50, 交叉概率 0.3, 变异概率 0.01, 误差精度 0.01。



Fig 2 Flow chart of ANN-genetic algorithm combined optimization structure

3 实验与仿真

3.1 激光熔覆实验

试验采用的是中国有色金属研究院生产的 N45 合金粉末, 粒度为 200 目, 基体为 A3 钢。实验设备为 NEL-2.5kW 快轴流 CO₂ 激光器, 激光模式为 TEM₀₀, 数控系统为西门子 840D。分别在基体上进行了单道和多道熔覆实验。用线切割机将熔覆后的试样纵向剖开, 经过抛光机抛光和金相砂纸研磨, 用王水腐蚀截面, 在 Nikon-TV 金相显微镜下观察显微组织, 图 3 为熔覆层纵截面的金相显微镜照片。从上至下依次为熔化区、热影响区和基体, 基体与熔覆层交界线是向基体凹陷的圆弧形, 圆弧有起伏。




Fig 3 Metallographical images of laser cladding layer in longitudinal section

3 2 熔覆层质量影响因素及与工艺参数之间的关系

3 2 1 影响熔覆层宽度的因素

影响熔覆层宽度的主要因素为光斑直径, 其次是扫描速度, 最后是激光功率。熔覆层宽度和扫描速度 v 、激光在熔覆表面上光斑直径 D 之间的关系^[8]: $w = D(1 - av)$ (7)

式中, a 为经验常数, 与粉末及基体材料、激光功率等有关。从图 4a 中可以看出, 当激光功率一定时, 熔覆

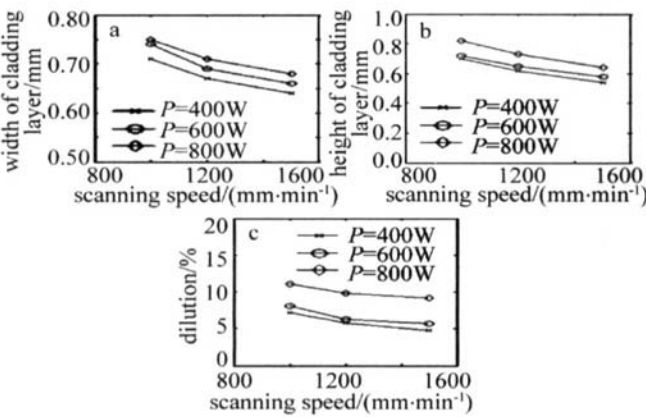


Fig 4 Related curve between surface quality of cladding layer with technology parameter

层宽度会随着扫描速度的增加而减小; 当扫描速度一定时, 熔覆层宽度随着激光功率的增加而增加。当激光功率、扫描速度和铺粉厚度合适的情况下, 熔覆层宽度几乎等于激光光斑直径。

3 2 2 影响熔覆层深度的因素

对熔覆层厚度影响最显著的是扫描速度, 其次是激光功率。从图 4b 中可以看出, 熔覆层厚度随着扫描速度的增加而减小, 随着激光功率的增加而增加, 只是熔覆层厚度随着激光功率发生改变的程度相对较小。

3 2 3 影响熔覆层稀释率的因素 稀释率是描述熔覆层成分由于熔化的基体材料混入而引起成分变化的程度, 由于激光光斑直径一定时, 熔覆层宽度随工艺参数的变化不大^[9], 因此, 截面积 A_1 与 A_2 变化主要体现在熔覆层高度 H 与基材熔深 h , 稀释率可由下式计算^[10]:

$$\eta = h / (H + h) \quad (8)$$

从图 4c 中可知, 当铺粉厚度一定时, 稀释率会随着扫描速度的增加而减小。激光功率和光斑直径一定时, 随着激光功率的增加, 稀释率增加。激光功率对熔覆层深度影响较小, 因此激光功率对稀释率影响并不显著。

实验结果表明, 扫描速度对激光熔覆层质量的影响比较显著, 激光功率的影响并不明显; 当扫描速度较小时随着扫描速度的增加, 熔覆层宽度、熔覆层深度和稀释率变化得比较明显, 当扫描速度达到一定数值时, 熔覆层宽度、熔覆层深度和稀释率变化比较小。从实验中还看到, 虽然激光功率对熔覆层质量的影响并不显著, 但是随着激光功率的增加, 熔覆层表面气孔减小, 表面光洁度提高。

3 3 神经网络的训练及其数据的检验

首先, 考虑到训练样本较多且取值范围相差较大, 为了提高输出目标的精度, 需要对训练样本进行数据的预处理, 预处理公式为: $X = (x - \bar{x}) / S$ (9)

式中, X 为网络输入值, x 为样本值, \bar{x} 为样本平均值, S 为样本标准差。

其次, 网络的输入层含有 3 个神经元, 输出层含有 3 个神经元, 隐含层单元个数为 7 个。在实验数据中选取 14 组作为神经网络的训练样本, 构造输入输出模式, 在 $[-0.5, 0.5]$ 中随机产生初始化权值矢量, 在 $[-0.25, 0.25]$ 中随机产生初始化阈值矢量, 网络训练结束后得到预测值如表 1 所示。表中 Y_1, Y_2 和 Y_3 分别为熔覆层宽度、厚度和稀释率的实验值; Y_1', Y_2' 和 Y_3' 为进化神经网络预测模拟结果; Δ 为预测相对误差。由表 1 实验结果可知, 进化神经网络的预测结果是非常精确的, 相对误差在 1.7% 之内。

Table 1 Contrasting trained network output value with experiential expert value

k	X_1	X_2	X_3	Y_1	Y_1'	Δ	Y_2	Y_2'	Δ	Y_3	Y_3'	Δ
1	400	0.8	1200	0.6	0.6012	0.2%	0.62	0.6204	0.6%	0.058	0.0587	1.19%
2	600	0.8	1200	0.62	0.6288	1.4%	0.65	0.6512	0.18%	0.063	0.0638	1.25%
3	800	0.8	1200	0.63	0.6312	0.19%	0.73	0.7311	0.15%	0.098	0.0991	1.11%
4	400	0.6	1500	0.5	0.5104	0.46%	0.48	0.4831	0.64%	0.062	0.0628	1.27%
5	600	0.6	1500	0.52	0.5208	0.15%	0.51	0.5117	0.33%	0.073	0.0734	0.54%
6	800	0.6	1500	0.56	0.5696	1.69%	0.56	0.5622	0.39%	0.168	0.1688	0.47%
7	400	0.4	1500	0.25	0.2633	1.3%	0.15	0.1526	1.7%	0.075	0.0762	1.57%
8	600	0.4	1500	0.3	0.3100	0.5%	0.34	0.3403	0.09%	0.183	0.1836	0.33%

continue

k	X_1	X_2	X_3	Y_1	Y_1'	Δ	Y_2	Y_2'	Δ	Y_3	Y_3'	Δ
9	800	0.4	1500	0.32	0.3298	1.48%	0.46	0.4628	0.61%	0.254	0.2557	0.66%
10	400	0.4	1200	0.31	0.3105	0.16%	0.1	0.1014	1.38%	0.111	0.1110	0
11	600	0.4	1200	0.34	0.3422	0.64%	0.25	0.2534	1.34%	0.192	0.1927	0.36%
12	800	0.4	1200	0.35	0.3524	0.68%	0.3	0.3	0	0.325	0.3266	0.49%
13	400	0.8	1000	0.71	0.7112	0.17%	0.7	0.7052	0.74%	0.072	0.0726	0.83%
14	600	0.8	1000	0.74	0.7433	0.64%	0.72	0.7204	0.06%	0.081	0.0821	1.34%

最后,神经网络的训练结束后,对网络的检验也非常重要,需要的是神经网络可以对训练样本之外的数据进行准确的预测。为了检验得到的神经网络是否准

确可靠,选取了5组数据来检验神经网络,表2为用于检验的5组工艺参数实验结果与预测结果对照及误差分析。

Table 2 Contrast of testing data evaluating network

k	X_1	X_2	X_3	Y_1	Y_1'	Δ	Y_2	Y_2'	Δ	Y_3	Y_3'	Δ
1	500	0.8	1200	0.61	0.6203	1.66%	0.76	0.7701	1.31%	0.075	0.0757	0.92%
2	500	0.8	1500	0.59	0.2919	0.32%	0.52	0.5233	0.63%	0.055	0.0058	2.14%
3	500	0.4	1500	0.26	0.2603	0.12%	0.17	0.1727	1.56%	0.124	0.1304	1.04%
4	700	0.4	1500	0.31	0.3187	2.73%	0.41	0.4139	0.94%	0.176	0.1772	0.68%
5	700	0.8	1200	0.68	0.6852	0.76%	1.0	1.0	0	0.078	0.0792	1.52%

从表2中可以看出,5组检验样本的预测值与实验数值非常接近,相对误差在2.14%以内,能够反映出实际值的变化,因此神经网络可靠。这说明网络用自学习方法学得的熔覆层质量与其各个输入参量之间的关系可以作为预测新的样本熔覆层质量的知识。并且,网络利用这个知识进行推理,进而预测出了未经网络学习过的样本的熔覆层质量。

4 结论

(1)通过熔覆层宽度、熔覆层深度和稀释率来评价激光熔覆层质量,分析了激光功率、扫描速度和熔覆层质量之间的关系,其中扫描速度对熔覆层质量的影响最为显著,其次是激光功率,光斑直径主要影响熔覆层宽度。(2)BP神经网络善于处理非线性问题,且有很强的泛化能力,利用神经网络建立了激光功率、扫描速度和光斑直径与熔覆层质量(熔覆层宽度、熔覆层深度和稀释率)之间非线性映射关系。(3)利用基因遗传算法优化了神经网络的权值和阈值,并建立了合适的数据预处理公式,从而提高了神经网络的学习效率和求解的精确性,5组检验样本的预测值与对应的实验结果之间的相对误差在2.14%以内。(4)借助于神经网络,通过合理地选择工艺参数,可以使激光熔覆制件的质量得以有效地控制,这在实际工程应用中有着积极的意义。

参 考 文 献

- [1] LIU XM, GUAN ZZ. The relationship between the process parameter of laser cladding by powder feeding method and the laser layer parameters [J]. Transactions of Metallurgical Treatment, 1998, A26(5): 29~34
- [2] van ACKER K, VANHOYE WEGHEN D, PERSOONS R *et al*. Influence of tungsten carbide particle size and distribution on the wear resistance of laser clad WC/Ni coatings [J]. Wear, 2005, 258(1~4): 194~202
- [3] SONG J L, DENG Q L, CHEN Ch Y *et al*. Rebuilding of metal components with laser cladding forming [J]. Applied Surface Science, 2006, 252(22): 7934~7940.
- [4] WU X W, ZHU B D, ZENG X Y *et al*. Critical state of laser cladding with power auto-feeding [J]. Surface and Coatings Technology, 1996, 79(1~3): 200~204.
- [5] JIS Q, LI P, ZENG X Y. Microstructure and mechanical property analyses of metal parts directly fabricated by laser cladding [J]. Laser Technology, 2006, 30(2): 130~133 (in Chinese).
- [6] YAN P F, ZHANG C S. Artificial neural network and simulated evolutionary computing [M]. Beijing: Tsinghua University Press, 2000, 15~22 (in Chinese).
- [7] LEI Y J, ZHANG S W, LI X W *et al*. MATLAB genetic algorithm toolbox and application [M]. Xi'an University of Electronic Science and Technology of China Press, 2005, 15~33 (in Chinese).
- [8] STEEN W M, WEERASINGHE V M, MONSON P. Some aspects of the formation of laser clad tracks [J]. SPIE, 1996, 650: 226~234.
- [9] LIU J C, LIU L J. Experimental study on fabrication of thick wall metallic features by laser cladding [J]. Chinese Journal of Mechanical Engineering, 2004, 40(10): 185~188 (in Chinese).
- [10] ZHU B D, ZENG X Y, TAO C Y *et al*. Effect of laser processing parameters on dilution of the clad coating [J]. Chinese Journal of Materials Research, 1994, 8(4): 315~319 (in Chinese).