

[研究·设计]

DOI:10.3969/j.issn.1005-2895.2019.06.009

基于进化神经网络的304不锈钢车削加工 表面粗糙度预测

马 猛,王明红

(上海工程技术大学 机械与汽车工程学院, 上海 201620)

摘 要:表面粗糙度是衡量加工零件质量的重要指标之一,对表面粗糙度进行提前预测有利于提高加工质量。课题组采用正交试验方法进行了YG8硬质合金刀具干式车削304不锈钢棒料的实验,得到不同切削条件下的表面粗糙度。由于BP神经网络的算法预测精度不高而且容易陷入局部极小值,利用遗传算法的全局搜索能力优化BP神经网络的结构和初值,建立基于进化神经网络的表面粗糙度预测模型。结果表明:进化的BP神经网络模型有效地克服了BP神经网络容易陷入局部极小值的缺陷,实现了表面粗糙度的精确预测。

关 键 词:金属切削;表面粗糙度预测;正交试验;进化神经网络

中图分类号: TG51; TH161 文献标志码: A 文章编号: 1005-2895(2019)06-0044-04

Prediction of Surface Roughness for 304 Stainless Steel Turning Based on Evolutionary Neural Network

MA Meng, WANG Minghong

(School of Mechanical and Automotive Engineering, Shanghai University of Engineering Science, Shanghai 201620, China)

Abstract: The surface roughness is one of the important indicators for the quality of machined surface. It is helpful for improving machining quality to predict surface roughness in advance. Dry turning 304 stainless steel with YG8 carbide tool was carried out by orthogonal test method, the surface roughness was obtained under different cutting conditions. Due to the prediction accuracy of BP neural network algorithm not high and easy to get into the local minimum value, the structure and initial value of BP neural network were optimized by the global search ability of genetic algorithm, and the surface roughness prediction model based on evolutionary neural network was established. The results show that evolutionary neural network model overcomes the defect of BP neural network easily falling into local minimum point, and realizes the accurate prediction of surface roughness.

Keywords: metal cutting; surface roughness prediction; orthogonal test; evolutionary neural network

表面粗糙度会影响机械加工零件的疲劳强度、耐腐蚀性等,是评价加工表面质量的重要参数之一^[1],对304不锈钢切削加工表面粗糙度进行提前预测有利于提高加工质量,降低废品率。

X. J. Cai等^[2]提出了一种平均误差为5.46%的神经网络预测表面粗糙度的最佳预测模型。Rajora M等^[3]采用性能更为优良的GA-LM混合神经网络用于车削加工过程中表面粗糙度的预测。高世龙等^[4]把正交试验和BP人工神经网络结合,应用人工智能神

经网络方法建立了加工表面粗糙度预测模型。莫蓉等^[5]提出了一种BP+GA表面粗糙度预测模型,预测精度较高。

课题组利用遗传算法的全局搜索能力优化BP神经网络的结构和初始参数,提出了一种进化神经网络的表面粗糙度预测模型。切削速度、进给量、背吃刀量和刀尖圆弧半径对304不锈钢车削加工表面粗糙度的影响显著^[6]。为高效、经济地进行实验,课题组采用正交试验法,以切削速度、进给量、背吃刀量和刀尖圆弧半

收稿日期:2019-04-13;修回日期:2019-08-16

第一作者简介:马猛(1992),男,山东聊城人,硕士研究生,主要研究方向为金属切削加工及其仿真模拟。E-mail: m18321188089@126.com

径为变量,得到不同切削条件下的表面粗糙度。

1 实验条件

1.1 实验设备和材料

车削实验采用沈阳机床厂生产的 CA6140 车床,刀具选用 YG8 硬质合金刀具,车刀前角 15°,后角 8°。304 不锈钢的化学成分及质量分数如表 1 所示,工件的尺寸为 $\Phi 60 \text{ mm} \times 300 \text{ mm}$ 。车削实验采用干式切削,车削加工现场如图 1 所示。

表 1 工件材料化学成分

Table 1 Chemical composition of workpiece materials %

C	Si	S	P	Mn
0.061 61	0.351 18	0.024 46	0.021 41	1.765 96
Ni	Cr	Mo	Cu	Fe
8.249 58	18.260 23	0.073 76	0.238 61	70.956 20




图 1 车削加工现场

Figure 1 Turning site

1.2 正交实验

实验变量为切削速度、进给量、背吃刀量和刀尖圆弧半径,采用 L9(3⁴) 正交表进行实验,各实验变量的水平见表 2。利用 OU1300 便携式表面粗糙度测量仪得到加工工件的表面粗糙度,对每组实验变量下对应的样本测量 3 次并取其平均值作为最终的实验结果。

表 2 实验参数及结果

Table 2 Test parameters and results

序号	切削速度/ ($\text{m} \cdot \text{min}^{-1}$)	进给量/ ($\text{mm} \cdot \text{r}^{-1}$)	背吃刀 量/mm	刀尖圆弧 半径/mm	表面粗 糙度/ μm
1	60	0.20	0.5	0.4	3.646
2	60	0.15	0.3	0.6	1.618
3	60	0.10	0.1	0.8	1.466
4	100	0.15	0.5	0.8	1.668
5	100	0.10	0.3	0.4	1.528
6	100	0.20	0.1	0.6	2.525
7	140	0.10	0.5	0.6	1.423
8	140	0.20	0.3	0.8	2.088
9	140	0.15	0.1	0.4	2.231

2 基于进化神经网络的表面粗糙度预测模型构建

2.1 BP 神经网络模型

切削加工表面粗糙度与切削条件之间为高度非线性关系。根据 Kolmogorov 理论,单隐层的 BP 神经网络可逼近任意的连续非线性函数^[7],BP 网络拓扑结构如图 2 所示。




图 2 3 层 BP 神经网络模型

Figure 2 Three-layer BP neural network model

设 BP 神经网络有 m 个输入 1 个输出,输出为 A_k (表面粗糙度 R_a),隐含层有 n 个神经元。设 $k = 1, 2, \dots, K$ (其中 K 为样本总数)则 BP 神经网络的输入向量为 $X^{(k)} = (x_{k1}, x_{k2}, \dots, x_{km})$,隐含层向量为 $H^{(k)} = (h_{k1}, h_{k2}, \dots, h_{kn})$,输入层到隐含层的权值为 W_{ij} ($i = 1, 2, \dots, m; j = 1, 2, \dots, n$),隐含层到输出层的权值为 V_j ,对于样本 k ,隐含层神经元节点 j 的输出为

$$h_{kj} = f\left(\sum_{i=1}^m W_{ij}x_{ki}\right) \quad (1)$$

输出层神经元节点的理论输出为

$$A_k = f\left(\sum_{j=1}^n V_jx_{kj}\right) \quad (2)$$

隐含层激励函数选择为对数 Sigmoid 函数

$$f(x) = (1 + e^{-x})^{-1} \quad (3)$$

BP 神经网络的误差函数为

$$E = \frac{1}{2} \sum_{k=1}^K (A_k - A_{ko})^2 \quad (4)$$

式中: A_{ko} 为对应于样本 k 的输出层神经元节点的实际输出预测值。

BP 算法的目标是通过反复迭代来保证 E 接近最小值。根据梯度下降法,连接权值的迭代公式为

$$\left. \begin{aligned} V_j(N+1) &= V_j(N) - \eta \frac{\partial E}{\partial V_j}; \\ W_{ij}(N+1) &= W_{ij}(N) - \eta \frac{\partial E}{\partial W_{ij}} \end{aligned} \right\} \quad (5)$$

式中： N 为迭代步数； η 为学习速率。

在每次迭代中，连接权值从隐含层到输出层的变化情况如下：

$$\left. \begin{aligned} \Delta V_j(N+1) &= \eta \sum_{k=1}^K \delta_k h_{kj} + \lambda \Delta V_j(N); \\ \delta_k &= A_k(1 - A_k)(A_{ko} - A_k). \end{aligned} \right\} \quad (6)$$

式中： λ 是调整系数； δ_k 是神经元节点输出的误差。

连接权值从输入层到隐含层的变化量为

$$\left. \begin{aligned} \Delta W(N+1) &= \eta \sum_{k=1}^K D_{kj} x_{kj} + \lambda \Delta W_{ij}(N); \\ D_{kj} &= A_k(1 - A_k) \delta_k V_j. \end{aligned} \right\} \quad (7)$$

式中 D_{kj} 为隐含层神经元节点的误差。

利用 BP 算法可以解决非线性问题^[8]，但由于采用连接权值的梯度下降法，往往导致均方差落入局部极小值。

2.2 进化神经网络模型

课题组建立的进化神经网络模型如图 3 所示^[9-13]。当 BP 算法在学习过程中陷入局部极小值时，则利用遗传算法生成其子代，从父代和子代中选择一个最优个体作为学习过程的新起点，经过交叉和变异后生成新的连接权值。进化神经网络算法步骤如下：

1) 初始化连接权值及其阈值，并在 $[-1, 1]$ 中随机选值。

2) 依次选择一个样本，输入到如图 2 所示的网络中。

3) 利用式(1)、式(2)、式(6)和式(7)分别计算出 h_{kj}, A_k, δ_k 和 D_{kj} 。

4) 返回到步骤 2)，直到所有的样本被完全训练。

5) 根据式(5)、式(6)和式(7)对各层连接权值进行校正。

6) 利用式(4)计算均方差 $E(N)$ 。如果 $E(N) \leq \varepsilon$ ($\varepsilon > 0$ ，是给定的小数)则终止迭代过程，否则返回步骤 3)。

7) BP 神经网络误差梯度的计算公式为

$$\Delta E = [E(N) - E(N - \tau)] / \tau. \quad (8)$$

式中： τ 是误差梯度的窗口大小。

如果 ΔE 小于设定梯度阈值 T_H 且 $E(N) > \varepsilon$ ，此时利用遗传算法来优化 BP 网络的结构和初始参数，避免 BP 算法在学习过程中陷入局部极小值，优化过程如图 3 所示。

8) 编码染色体，随机生成初始种群

$$P = (X_1, X_2, \dots, X_p) \quad (9)$$

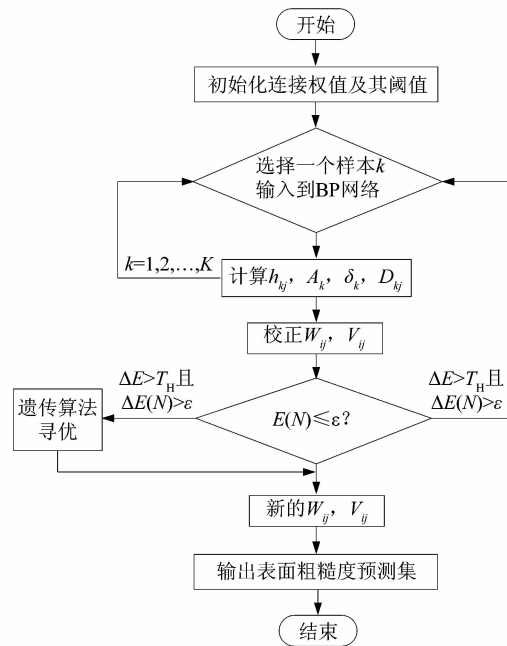


图 3 进化神经网络模型

Figure 3 Evolutionary neural network model

$X_i = (u_1, u_2, \dots, u_c), u_j (j = 1, 2, \dots, q)$ 为两个神经元节点之间的连接权值。在 $[-1, 1]$ 中给 u_j 一个随机数。

9) 适应度函数取均方差 E ，与步骤 6) 的判断标准相同。

10) 根据 $f(X_i) = \beta(1 - \beta)^{i-1}, 0 < \beta < 1$ 。(10) 计算染色体的概率，得到其总的概率

$$F_i = \sum_{i=1}^i f(X_i). \quad (11)$$

在 $[0, F_p]$ 生成一个随机数 γ ，如果

$$F_{i-1} \leq \gamma \leq F_i, \quad (12)$$

将 X_i 作为最优秀的个体。

11) 父代染色体选择交叉概率高的个体，并标记为 (X'_i, X'_j) 。再经过交叉运算，得到相应的子代为

$$\left. \begin{aligned} x &= \xi \times X'_i + (2 - \xi) \times X'_j; \\ y &= (2 - \xi) \times X'_i + \xi \times X'_j. \end{aligned} \right\} \quad (13)$$

式中 ξ 取 $(0, 1)$ 内的任意数。

12) 选择染色体 $X_i = (u_1, u_2, \dots, u_c)$ ，通过在 $[-1, 1]$ 内随机地选取一个数 u'_j 来替代 u_j ，则子代染色体变异后为 $X'_i = (u_1, u_2, \dots, u'_j, u_q)$ ，并评估变异结果，如果变异后的染色体更优良，停止变异，反之继续变异，直到找到符合条件的子代染色体。

13) 经过步骤 8) ~ 12) 操作后，如果新的权值满足步骤 6) 的条件，则停止迭代，输出进化结果。否则，回到步骤 8) 进行新一轮的进化。

3 预测结果分析

课题组采用 BP 网络模型的拓扑结构如图 2 所示。输入层神经元为切削速度、进给量、背吃刀量和刀尖圆弧半径,隐含层有 15 个神经元,输出层神经元为表面粗糙度,学习速率 η 为 0.5,调整系数 λ 为 0.8。

分别采用 BP 神经网络和进化的神经网络模型对表面粗糙度进行预测,采用均方差 M_{SE} 来评价两种模型的预测精度。

$$M_{SE} = \frac{1}{K} \sum_{k=1}^K (A_{ko} - A'_{ko})^2 \quad (14)$$

式中: A_{ko} 为第 k 个样本的表面粗糙度预测值; A'_{ko} 为对应条件下的第 k 个样本表面粗糙度实验值。

采用 MATLAB 软件进行仿真,经计算采用进化的神经网络预测时,均方差 $M_{SE} = 0.107$,采用 BP 网络预测时,均方差 $M_{SE} = 0.198$,两种模型的预测结果如图 4 所示。从图 4 中可以看出进化神经网络表面粗糙度预测值与相对应的实验值几乎有相同的趋势,验证了预测模型的准确性;表明进化的神经网络预测模型预测精度更高,从侧面反映了预测模型能有效地避免陷入局部极小值。

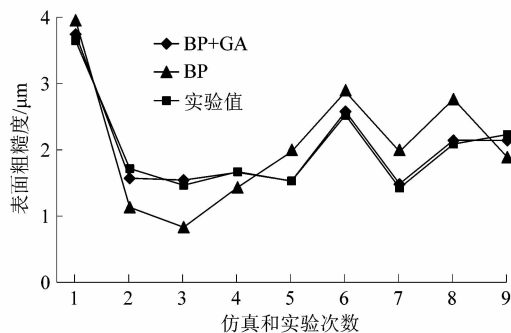


图 4 表面粗糙度预测值与实验值的比较

Figure 4 Comparison of surface roughness between predicted value and experimental value

将得到的正交实验值与 BP + GA 算法预测的表面粗糙度进行对比,结果如表 3 所示。从表 3 中得到实验值和预测值之间总的平均相对误差为 2.76%,说明模型有较高的预测精度。

4 结论

课题组利用遗传算法的全局搜索能力来优化 BP 神经网络的结构和初始参数,结合正交试验法得到的实验数据,建立了一种进化神经网络表面粗糙度预测模型。结果表明:进化的神经网络表面粗糙度预测模型预测精度较高,其平均相对误差为 2.76%,有效地克

表 3 实验结果和预测结果对比

Table 3 Comparison of experimental results and prediction results

序号	表面粗糙度/ μm		相对误差/%
	实验值	BP + GA 预测值	
1	3.646	3.744	2.7
2	1.618	1.571	3.1
3	1.466	1.545	5.4
4	1.668	1.660	0.0
5	1.528	1.530	0.1
6	2.525	2.578	2.1
7	1.423	1.486	4.4
8	2.088	2.146	2.8
9	2.231	2.141	4.2

服了 BP 算法学习过程中容易陷入局部极小值的缺陷,获得较满意的结果。课题组的研究实现了对 304 不锈钢加工表面粗糙度的精确预测。

参考文献:

- [1] 刘国孝,刘国忠,刘斌恒,等. 不锈钢切削加工研究进展[J]. 兵器材料科学与工程,2016,39(6):128.
- [2] CAI X J, LIU Z Q, WANG Q C, et al. Surface roughness prediction in turning of free machining steel 1215 by artificial neural network[J]. Advanced Materials Research, 2011, 188:7.
- [3] RAJORA M, SHIH A H, ZOU Pan, et al. A hybrid neural network for prediction of surface roughness in machining[J]. Applied Mechanics and Materials, 2014, 633/634:579-582.
- [4] 高世龙,安立宝. 基于神经网络的车削加工表面粗糙度智能预测[J]. 机械设计与研究,2016(1):96.
- [5] 莫蓉,田国良,孙惠斌. 基于遗传算法优化的 BP 神经网络在粗糙度预测上的应用[J]. 机械科学与技术,2015,34(5):729-732.
- [6] 伊海洋. 不锈钢材料车削加工的实验研究与有限元仿真[D]. 成都:西南石油大学,2015:49-52.
- [7] 高腾,苗鸿宾,江敏. 基于进化神经网络 BTA 钻削表面粗糙度的在线预测[J]. 组合机床与自动化加工技术,2014(1):26-28.
- [8] 任谢楠. 基于遗传算法的 BP 神经网络的优化研究及 MATLAB 仿真[D]. 天津:天津师范大学,2014:20-35.
- [9] 万俊盛,陈小虎,毋文峰. 基于遗传神经网络的液压齿轮泵特征层融合诊断[J]. 机床与液压,2013,41(13):65.
- [10] 王国凡,薛二剑,唐学峰. 基于进化神经网络的无监督的指标重要度判定方法在体育计量中的应用[J]. 体育科学,2011,31(2):90-95.
- [11] 刘鹏飞,付波. 基于遗传算法优化 BP 神经网络的短期热负荷预测方法研究[J]. 区域供热,2019(1):43-48.
- [12] 谢橙晔. 小世界网络模型的优化及应用研究[D]. 镇江:江苏大学,2018:35-47.
- [13] 余鹏,唐权,张文涛,等. 基于高斯模糊信息粒化和改进小波神经网络的短期负荷区间预测[J]. 机电工程,2017,34(2):167-172.