

基于BP神经网络的面偏斜度和峰度预测建模

胡敬文

(佛山广播电视大学, 广东 佛山 528000)

摘要: 目的 当前实际生产中对表面形貌的表征主要利用表面算术平均偏差 S_a , 而通过不同加工方式获得的表面有时尽管具有相同的 S_a 值, 而其表面纹理结构、表面轮廓幅度值的对称程度及凸峰尖锐程度往往存在较大的差异, 所以此时引入表面偏斜度 S_{sk} 和表面峰度 S_{ku} 来共同表征表面形貌更为精确可信。方法 利用正交试验和极差分析的方法研究各磨削参数如何影响表面偏斜度和表面峰度的变化。将BP神经网络引入到对表面偏斜度和表面峰度的预测建模中, 利用其自学习的特性, 有效克服了表面粗糙度建模的多输入、非线性复杂问题。结果 获得了磨削参数对表面偏斜度和表面峰度的影响规律, 当 $v_s=20$ m/s, $v_f=27$ m/min, $f=5$ mm/min, $a_p=0.005$ mm 时 S_{sk} 最小, 当 $v_s=29$ m/s, $v_f=23$ m/min, $f=25$ mm/min, $a_p=0.002$ mm 时 S_{ku} 最小; 分别建立了磨削参数对 S_{sk} 和 S_{ku} 的精确神经网络预测模型。结论 v_f 和 f 对 S_{sk} 影响较大, 而 f 和 v_s 对 S_{ku} 的影响最大。为获得凹谷较多、尖锐凸峰较少的表面, 必须选择合适的磨削工艺参数。建立的预测模型可以对磨削工艺优化起到有效的指导作用。

关键词: 表面偏斜度; 表面峰度; 磨削参数; 神经网络; 预测建模

中图分类号: TH161+.14 **文献标识码:** A **文章编号:** 1001-3660(2017)02-0235-05

DOI: 10.16490/j.cnki.issn.1001-3660.2017.02.040

Predictive Modeling of Surface Skewness and Kurtosis Based on BP Neural Network

HU Jing-wen

(Foshan Radio & TV University, Foshan 528000, China)

ABSTRACT: The work aims to introduce surface skewness S_{sk} and surface kurtosis S_{ku} to jointly characterize surface topography in a more precise and reliable manner when the symmetric degree and profile peak sharpness of surface texture structures and surface profile amplitude values tend to be subject to large difference, even though the surfaces obtained through various processing methods sometimes have the same S_a value regarding the situation that the surface topography is characterized mainly with the surface arithmetic average deviation S_a in the actual production. Orthogonal experiment and range analysis were applied to study the influence of grinding parameters on the change in S_{sk} and S_{ku} . On this basis, BP neural network was introduced in the predictive modeling of S_{sk} and S_{ku} . The complex problem of multi-input and nonlinearity for surface roughness modeling was effectively solved due to the property of self-learning. The effect laws of grinding parameters on S_{sk} and S_{ku} were achieved. S_{sk} would reach the minimum when $v_s=20$ m/s, $v_f=27$ m/min, $f=5$ mm/min and $a_p=0.005$ mm, and S_{ku} was the minimum when $v_s=29$ m/s, $v_f=23$ m/min, $f=25$ mm/min and $a_p=0.002$ mm. And then, the accurate neural network prediction models for S_{sk} and S_{ku} based on grinding parameters were built respectively. v_f and f have a significant impact on S_{sk} . Similarly, f and v_s impact S_{ku} .

收稿日期: 2016-08-14; 修订日期: 2016-11-31

Received: 2016-08-14; Revised: 2016-11-31

作者简介: 胡敬文(1981—), 男, 硕士, 讲师, 主要从事于计算机仿真、大数据、云计算、地理信息系统的研究。

Biography: HU Jing-wen (1981—), Male, Master, Lecturer, Research focus: computer simulation, big data, cloud computing, GIS (geographic information system).

the most. It is necessary to select suitable grinding parameters to obtain the surface with more valleys and less acute profile peaks. Moreover, the prediction models built can guide the optimization of grinding process effectively.

KEY WORDS: surface skewness; surface kurtosis; grinding parameters; neural network; predictive modeling

衡量机械零件加工质量的好坏,除了加工精度外,表面质量也是一个极其重要的方面^[1]。随着现代科学技术的发展,对机械产品性能、使用寿命和可靠性要求越来越高,从而对零件表面粗糙度也有了越来越高的要求。表面粗糙度的好坏,直接影响机械零件的摩擦学性能、承载能力、耐腐蚀性、耐疲劳性等多种表面特性,从而对机械产品的寿命和可靠性保证产生不可忽视的影响^[2-3]。如何用有效的表面形貌评价参数来表征表面形貌结构,从而准确地规划切削工艺,一直是科学研究的一个重点^[4-5]。

在传统的表面粗糙度评价体系中,算术平均偏差 S_a 一直是使用最广泛、应用最成熟的一个表面形貌评价参数^[6-7]。在生产实际中,通常认为具有相同 S_a 值的表面具有相同或相近的表面精度和表面性。然而,采用不同的加工方法获得的表面,由于受切削参数、运动轨迹等的影响,表面微结构往往存在较大的差异,例如磨削和研磨加工产生的表面往往关于基线呈负的不对称性,且其尖峰较多;而车削或者电火花加工产生的表面常关于基线呈正的不对称性^[8],所以引入相关的表征表面轮廓偏斜程度和尖锐程度的表面形貌参数是非常有必要的。表面偏斜度 S_{sk} 和表面峰度 S_{ku} 是属于表面功能参数集中幅度参数的 2 个评价指标,其分别表征表面轮廓幅度值的不对称性和轮廓幅度曲线的尖锐程度^[9]。研究表明这 2 个表面形貌参数对表面耐磨损性能和耐腐蚀性能具有非常显著的影响^[10],所以,研究各切削参数变化对表面偏斜度和表面峰度的影响规律,并建立对这 2 个参数的相关预测模型,对于获得具有优秀摩擦学性能的表面并优化加工工艺,具有现实意义。

人工神经网络具有信息的分布存储、并行处理自学习以及特有的非线性适应性信息处理能力的优点,克服了传统人工智能方法对系统模型的依赖。神经网络的自学习功能更为解决表面粗糙度预测这种多输入、多输出的非线性复杂问题提供了新思路。目前, BP 神经网络和其他算法的人工神经网络算法已被广泛应用于对表面形貌的预测建模中^[11-13]。它只要事先通过样本训练确定神经网络内部各单元之间的连接权值和阈值,就可以准确地预测出相应的表面粗糙度值^[14]。

文中利用正交试验的方法研究磨削加工时,4 个主要的磨削参数对表面偏斜度和表面峰度的影响规律,并针对其特性提出磨削工艺的优化思路;然后利用 BP 神经网络建立对表面偏斜度和表面峰度较为精确的预测

模型,为磨削工艺的优化提供理论支持。

1 表面偏斜度和表面峰度

轮廓偏斜度 S_{sk} 为取样长度 l 内 n 个轮廓偏距的三次方的平均值,如式(1)所示^[9,15]。它是衡量轮廓幅度分布曲线不对称性的一种评定参数。研究证明:如果偏斜度为 0,则表示幅度分布对称均匀,如高斯曲线;如果偏斜度小于 0,它可能是具有较多深谷的表面;如果偏斜度大于 0,则该表面可能具有较多尖峰。所以,一个好的加工表面,其偏斜度应为负值,如图 1 所示。

$$S_{sk} = \frac{1}{MNS_q^3} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} [z(x_i, y_j) - \mu]^3 \quad (1)$$




图 1 表面轮廓偏斜度
Fig.1 Surface profile skewness

表面峰度 S_{ku} 是纵坐标值概率密度函数锐度的测定,其定义如式(2)所示。它表征轮廓幅度分布曲线变化的尖锐程度。当轮廓偏距服从高斯分布时,峰度值约为 3。以高斯分布曲线形状为基准,峰度值大于 3 时,幅度分布曲线形状较为陡峭,称为尖峰态曲线;峰度值小于 3 时,幅度分布曲线较宽、较平坦,称为低峰态曲线,如图 2 所示。研究表明:表面的峰




图 2 表面峰度曲线
Fig.2 Surface kurtosis curves

度越小，轮廓幅度分布越平坦；表面尖峰数量越少，表面耐磨损性能越好。

$$S_{ku} = \frac{1}{MNS_q^4} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} [z(x_i, y_j) - \mu]^4 \tag{2}$$

2 实验

2.1 实验设计

正交实验的优点在于可以凭借尽可能少的实验次数，表达较为丰富的信息量，通过极差分析，可以找出各个磨削参数的最优水平，进而对切削参数进行优化。实验选用砂轮速度 v_s 、工件速度 v_f 、轴向进给量 f 、磨削深度 a_p 4 个参数作为实验因素，每个实验因素设定 5 个水平值，分别用 1、2、3、4、5 表示，如表 1 所示。根据正交实验设计原则，构造如表 1 所示的 $L_{25}(5^4)$ 形式的正交实验表，共开展 25 组正交实验。

2.2 加工条件

实验采用的工件材料为经表面淬火后的灰铸铁 HT250。机床采用用 M7130 平面磨床，磨削实验完成后，利用光学轮廓仪扫面工件表面三维形貌，并计算表面粗糙度等参数。测量结果如表 1 所示。

表 1 $L_{25}(5^4)$ 正交实验表
Tab.1 $L_{25}(5^4)$ orthogonal array and experimental results

实验号	因素				S_{sk}	S_{ku}	数据形式
	$v_s / (\text{m} \cdot \text{s}^{-1})$	$v_f / (\text{m} \cdot \text{s}^{-1})$	f / mm	a_p / mm			
1	17	15	5	0.002	0.11	3.538	Training
2	17	19	10	0.005	-0.18	3.328	Training
3	17	23	15	0.008	-0.23	3.508	Testing
4	17	27	20	0.011	-0.324	3.65	Training
...
10	20	31	5	0.005	-0.758	4.07	Training
11	23	15	15	0.014	0.26	3.55	Testing
12	23	19	20	0.002	-0.314	3.442	Training
...
15	23	31	10	0.011	-0.147	2.85	Training
16	26	15	20	0.005	0.4	2.61	Testing
17	26	19	25	0.008	0.433	3.22	Training
18	26	23	5	0.011	-0.097	3.61	Training
19	26	27	10	0.014	-0.35	3.81	Training
20	26	31	15	0.002	0.094	3.32	Testing
21	29	15	25	0.011	-0.1	2.8	Training
22	29	19	5	0.014	-0.332	3.388	Training
23	29	23	10	0.002	-0.227	2.8	Testing
24	29	27	15	0.005	-0.258	2.735	Training
25	29	31	20	0.008	0.43	2.504	Training

2.3 结果的统计分析

为了评价不同磨削参数对表面偏斜度和表面峰度的影响规律，对实验数据进行极差分析，如图 3 所示。图 3a 是 4 个磨削参数对表面偏斜度的影响规律。从图可以看出，工件速度 v_f 、轴向进给量 f 和砂轮转速 v_s 对 S_{sk} 的影响都较为显著。随着工件速度的增大， S_{sk} 呈下降的趋势，但是当工件速度过大时， S_{sk} 的值又略有增大；相反，随着 v_s 和 f 的逐渐增大， S_{sk} 也随之逐渐增大。而磨削深度 a_p 对 S_{sk} 的影响较小，且随着 a_p 的增大， S_{sk} 有增大的趋势。所以为了获得较小的 S_{sk} 值，且尽量为负值，则应适当增大工件速度，同时减小 v_s 、 f 和 a_p 。4 个参数对 S_{sk} 的影响大小顺序为： $v_f > f > v_s > a_p$ 。

图 3b 为磨削参数对表面峰度的影响规律。轴向进给量 f 和砂轮转速 v_s 对表面峰度的影响最大，工件速度 v_f 和磨削深度 a_p 对其影响较小。随着 f 、 v_s 、 v_f 的增大， S_{ku} 都有下降的趋势。而随着 a_p 的增大， S_{ku} 逐渐增大。从图 3 分析可以看出，为了获得尖锐凸峰较少的表面，则 S_{ku} 应尽量小一些，所以选择磨削参数时可适当增大 f 、 v_s 、 v_f ，同时适当减小 a_p 。




图 3 磨削参数对表面粗糙度的影响
Fig.3 Influence of grinding parameters on surface roughness

3 BP 神经网络预测建模

在磨削加工过程中，影响表面形貌的因素很多，

各因素与表面偏斜度和表面峰度之间是一种非线性的关系,故使用传统方法(如回归分析)进行表述时精度较低,且关系复杂。而人工神经网络技术善于处理非线性映射逼近问题,可以建立考虑多因素的表面偏斜度和表面峰度模型^[16]。所以文中利用已有的实验数据,通过反复尝试,分别建立了能够较为准确地预测表面偏斜度和表面峰度的神经网络模型,并对模型进行了准确性验证。

3.1 BP神经网络预测原理

BP神经网络的基本模型包括输入层、隐含层和输出层3层结构,其输入输出的关系可以用式(3)表示。其中 $x_i (i=1, 2, 3, \dots, R)$ 为输入值, $w_i (i=1, 2, 3, \dots, R)$ 为神经元间的连接权值, b 为阈值(偏置值), f 为传递函数, y 为输出值^[17]。

$$y = f\left(\sum_{i=1}^R x_i w_i + b\right) \quad (3)$$

3.2 神经网络结构设计

3.2.1 输入/输出设计及训练样本选择

输入层确定为 v_s 、 v_f 、 f 、 a_p 4个输入量;输出层为表面偏斜度或者表面峰度1个输出量。故输入层有4个节点,输出层1个节点,分别针对 S_{sk} 和 S_{ku} 建立2个神经网络预测模型。

训练样本的合理选择同样会对模型预测精度产生大的影响。针对已有的实验数据,随机选取表1中除第3、11、16、20、23组之外的实验数据作为训练样本,第3、11、16、20、23组实验数据为测试样本。

3.2.2 隐含层设计

隐含层层数及其节点数的选择,往往需要设计者反复多次的尝试才能确定。具体隐含层节点数的确定可以根据式(4)进行设计:

$$l = \sqrt{n+m} + a \quad (4)$$

式中: l 为隐含层节点数; n 为输入层节点数; m 为输出层节点数; a 为1~10之间的常数。

经过反复训练尝试,最终,对于表面偏斜度 S_{sk} 的预测模型选择1个隐含层,切其节点数为10;对于表面峰度 S_{ku} 的预测模型选择2个隐含层,隐含层节点数分别为7和8。最终确定的BP神经网络结构如图4所示。

3.3 网络训练与学习

神经网络中常用的传递函数有3个:tansig, logsig, purelin;常用的训练函数很多,例如trainlm、traingd、trainbfg等。通过不同排列组合的反复尝试,训练函数最终选择收敛速度最快的Levenberg-Marquardt反向传播算法训练函数trainlm,传递函数对于 S_{sk} 和 S_{ku} 2个神经网络预测模型分别选择logsig、purelin函数和

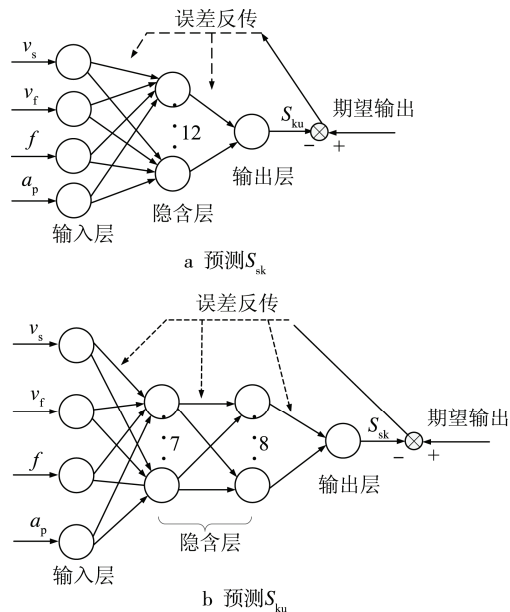


图4 神经网络结构

Fig.4 Neural network structure (a) predicting S_{sk} , (b) predicting S_{ku}

logsig、logsig、purelin函数。网络的学习率设为0.05,动量因子为0.95,最小均方误差设为0.0001,最大训练次数设为5000次。依次最终分别建立了针对 S_{sk} 和 S_{ku} 的BP神经网络预测模型。

3.4 预测结果分析与对比

在MATLAB软件下进行神经网络的训练测试,分别经过47和126次训练达到了要求的目标误差0.001。图5为2个模型的预测结果与真实值的对比。




图5 神经网络预测结果与真实值对比

Fig.5 Comparison between predicting results of neural network model and actual values

表 2 为二者的相对误差显示。从图 5 可以看出，2 个模型的预测值与真实值拟合程度非常高，且其变化趋势基本一致；而从表 2 中的相对误差可以看出，最大误差分别为 9.71%和 15.77%，其值较小，且在工程实际中在可以接受的范围内，说明本预测模型对 S_{sk} 和 S_{ku} 的预测较为准确，可以较好地指导将来的磨削工艺优化及其他研究。

表 2 神经网络预测模型相对误差比较
Tab. 2 Comparison of relative errors of neural network prediction model

测试 样本	S_{sk}			S_{ku}		
	预测值	真实值	相对误差/%	预测值	真实值	相对误差/%
1	3.477	3.508	0.88	-0.252	-0.23	9.57
2	3.365	3.55	5.21	0.301	0.26	15.77
3	2.548	2.61	2.38	0.352	0.4	0.12
4	3.041	3.32	8.40	0.0839	0.094	11.09
5	3.072	2.8	9.71	-0.246	-0.227	8.37

4 结论

首先利用正交试验的方法，研究了磨削参数对表面偏斜度 S_{sk} 和表面峰度 S_{ku} 的影响规律，获得了对这 2 个表面形貌幅度参数影响最大的因素分别是 v_f 和 f ，并据此提出了获得凹谷较多、尖锐凸峰较少的表面的合适的磨削工艺参数。然后将 BP 神经网络应用于对 S_{sk} 和 S_{ku} 的预测建模中，并建立了较为精确的磨削参数对 S_{sk} 和 S_{ku} 的预测模型。该模型对于磨削工艺的优化和质量控制具有一定的参考和应用价值。

参考文献

[1] 张慧萍, 张校雷, 张洪霞, 等. 300M 超高强钢车削加工表面质量[J]. 表面技术, 2016, 45(2): 181—187.
ZHANG Hui-ping, ZHANG Xiao-lei, ZHANG Hong-xia, et al. Surface Quality of High-speed Turning 300M Ultra-high Strength Steel[J]. Surface Technology, 2016, 45(2): 181—187.

[2] YAO C F, JIN Q C, HUANG X C, et al. Research on Surface Integrity of Grinding Inconel718[J]. International Journal of Advanced Manufacturing Technology, 2013, 65(65): 1019—1030.

[3] 黄建龙, 吴建宏, 党兴武. 表面粗糙度对 GCr15/35CrMo 摩擦副摩擦磨损特性的影响[J]. 表面技术, 2013, 42(4): 62—64.
HUANG Jian-long, WU Jian-hong, DANG Xing-wu. Influence of Surface Roughness on Friction and Wear Characteristics of GCr15/35CrMo Friction Pair[J]. Surface Technology, 2013, 42(4): 62—64.

[4] 胥超, 樊文欣, 赵俊生, 等. 连杆衬套表面粗糙度评定方法对比分析[J]. 表面技术, 2013, 42(6): 109—112.

XU Chao, FAN Wen-xin, ZHAO Jun-sheng, et al. Comparative Analysis of Evaluation Methods for the Surface Roughness of Connecting Rod Bushings[J]. Surface Technology, 2013, 42(6): 109—112.

[5] 方新燕. 三维表面形貌的表征及润滑特性的研究[D]. 合肥: 合肥工业大学, 2006.
FANG Xin-yan. Characterization and Lubrication Analysis of Three-dimensional Surface Topography[D]. Hefei: Hefei University of Technology, 2006.

[6] HECKER R L, LIANG S Y. Predictive Modeling of Surface Roughness in Grinding[J]. International Journal of Machine Tools & Manufacture, 2003, 43(8): 755—761.

[7] JIANG J, GE P, HONG J. Study on Micro-interacting Mechanism Modeling in Grinding Process and Ground Surface Roughness Prediction[J]. International Journal of Advanced Manufacturing Technology, 2013, 67(5/8): 1035—1052.

[8] TAYEBI N, POLYCARPOU A A. Modeling the Effect of Skewness and Kurtosis on the Static Friction Coefficient of Rough Surfaces[J]. Tribology International, 2004, 37(6): 491—505.

[9] STOUT K J. Development of Methods for the Characterisation of Roughness in Three Dimensions[J]. Journal of the Brazilian Society of Mechanical Sciences, 2002, 24(4): 312—317.

[10] 李伯奎. 三维表面偏斜度与陡度的规律研究[J]. 计量技术, 2008(10): 3—6.
LI Bo-kui. Research of Law between 3D Surface Skewness and Kurtosis[J]. Measurement Technique, 2008(10): 3—6.

[11] 张永顺, 孙华, 丁伟, 等. 基于 BP 神经网络的切削表面粗糙度预测方法[J]. 机械管理开发, 2011(5): 71—72.
ZHANG Yong-shun, SUN Hua, DING Wei, et al. Prediction Method of Machining Surface Roughness Based BP Neural Network[J]. Mechanical Management and Development, 2011(5): 71—72.

[12] 崔伯第, 郭建亮. 基于模糊神经网络的表面粗糙度建模研究[J]. 机床与液压, 2012, 40(9): 132—134.
CUI Bo-di, GUO Jian-liang. Research on Modeling of Surface Roughness Based on Fuzzy Neural Networks[J]. Machine Tool & Hydraulics, 2012, 40(9): 132—134.

[13] ASILTÜRK İ, ÇUNKAS M. Modeling and Prediction of Surface Roughness in Turning Operations Using Artificial Neural Network and Multiple Regression Method[J]. Expert Systems with Applications, 2011, 38(5): 5826—5832.

[14] BOSCHETTO A, GIORDANO V, VENIALI F. Surface Roughness Prediction in Fused Deposition Modelling by Neural Networks[J]. International Journal of Advanced Manufacturing Technology, 2013, 67(9/12): 2727—2742.

[15] 李志强. 表面微观形貌的测量及其表征[D]. 重庆: 重庆大学, 2006.
LI Zhi-qiang. The Survey and Token of Micro-scale Surface[D]. Chongqing: Chongqing University, 2006.

[16] VRABEL M, MANKOVA I, BENO J, et al. Surface Roughness Prediction Using Artificial Neural Networks when Drilling Udimet 720[J]. Procedia Engineering, 2012, 48(1): 693—700.

[17] 陈明. MATLAB 神经网络原理与实例精解[M]. 北京: 清华大学出版社, 2013.
CHEN Ming. MATLAB Neural Network Principle and Essence of Instance[M]. Beijing: Tsinghua University Press, 2003.