

基于 BP 和 RBF 神经网络的表面质量预测研究

彭彬彬, 闫献国, 杜娟

(太原科技大学 机械工程学院, 太原 030051)

摘要: **目的** 研究 RBF 和 BP 神经网络在铣削加工中的作用, 实现对铣削加工质量的预测, 改善铣削性能。**方法** 对环形铣刀与常用的球形铣刀进行对比, 然后基于 MATLAB 平台, 建立以铣削速度、进给量和铣削深度为输入参数, 表面粗糙度为输出参数的 RBF 神经网络模型。通过大量的试验数据对 RBF 神经网络模型进行训练, 然后再用训练好的 RBF 神经网络模型预测表面粗糙度, 将预测值与实测值进行比较, 验证 RBF 神经网络的预测性能。将训练好的 BP 神经网络模型与 RBF 神经网络所建模型的预测结果进行比较。**结果** 发现用 RBF 方法预测的表面粗糙度相对误差的绝对值不超过 6%, 最大误差为 0.056 098, 平均误差为 0.022 277, 而 BP 方法的最大误差为 0.074 947, 平均误差为 0.036 578。**结论** 环形铣刀加工质量更好。RBF 神经网络的预测精度较高, 具有比 BP 神经网络更优的预测能力, 且拥有建模时间短、收敛速度高、训练过程稳定以及学习速度快等优点, 能有效进行铣削质量预测。

关键词: 铣削加工; 表面粗糙度; RBF 神经网络; 质量预测; BP 神经网络

中图分类号: TG54; TP183 **文献标识码:** A **文章编号:** 1001-3660(2020)10-0324-05

DOI: 10.16490/j.cnki.issn.1001-3660.2020.10.038

Surface Quality Prediction Based on BP and RBF Neural Networks

PENG Bin-bin, YAN Xian-guo, DU Juan

(School of Mechanical Engineering, Taiyuan University of Science and Technology, Taiyuan 030051, China)

ABSTRACT: The work aims to study the role of RBF and BP neural networks in milling, so as to realize the prediction of milling quality and improve the milling performance. Firstly, the circular milling cutter was compared with the commonly used spherical milling cutter, and then based on the MATLAB platform, an RBF neural network model was established with the milling speed, feed and milling depth as input parameters and surface roughness as output parameters. The RBF neural network model was trained through a large amount of experimental data, and then the trained RBF neural network model was used to predict the surface roughness, and the predicted value was compared with the measured value to verify the prediction performance of the RBF neural network. After the BP neural network model was trained in the same way, the prediction results of the model established with the RBF neural network were compared. The absolute value of the surface roughness relative error

收稿日期: 2019-08-30; 修订日期: 2020-02-24

Received: 2019-08-30; Revised: 2020-02-24

基金项目: 国家自然科学基金项目 (51475317)

Fund: Supported by the National Natural Science Foundation of China (51475317)

作者简介: 彭彬彬 (1969—), 男, 博士, 副教授, 主要研究方向为精密切削技术。

Biography: PENG Bin-bin (1969—), Male, Doctor, Associate professor, Research focus: Precision cutting technology.

通讯作者: 杜娟 (1973—), 女, 博士, 教授, 主要研究方向: CAD/CAM 及智能制造技术。邮箱: lgzjdj1999@163.com

Corresponding author: DU Juan (1973—), Female, Doctor, Professor, Research focus: CAD/CAM and intelligent manufacturing technology. E-mail: lgzjdj1999@163.com

引文格式: 彭彬彬, 闫献国, 杜娟. 基于 BP 和 RBF 神经网络的表面质量预测研究[J]. 表面技术, 2020, 49(10): 324-328.

PENG Bin-bin, YAN Xian-guo, DU Juan. Surface quality prediction based on BP and RBF neural networks[J]. Surface technology, 2020, 49(10): 324-328.

by the RBF method did not exceed 6%, the maximum error was 0.056 098, the average error was 0.022 277, while the maximum error of the BP method was 0.074 947, and the average error was 0.036 578. The processing quality of circular milling cutter is better. RBF neural network model has better prediction ability than BP neural network, and has shorter modeling time, higher convergence speed, stable training process and faster learning speed, and can effectively predict the milling quality.

KEY WORDS: milling; surface roughness; RBF neural network; quality prediction; BP neural network

在智能制造飞速发展的今天，小到日用品，大到国家科研项目，都与高端制造技术有关。产品越精细，其结构越复杂，涉及到复杂曲面的加工时，对加工精度、加工质量的要求也越高。普通机床难以实现精细加工，而五轴联动数控加工机床的使用让工件的装夹变得容易，可减小切削力，提高刀具使用寿命，降低成本^[1]，实现了对具有复杂结构工件的精细加工。在加工复杂曲面类产品时，常用的刀具是球头铣刀，但球头铣刀存在明显的缺陷，如端铣能力差，使得刀具磨损严重，铣削速度会受到限制，加工效率低等^[2]。相比之下，环形铣刀（如图 1）的优点突出，受到了行业内国内外专家和学者的关注。刘献礼等^[3]对汽车覆盖件的铣削加工进行了球面铣刀和环形铣刀的对比研究；岳彩旭等^[4]对环形铣刀刃线进行分析，发现它能够显著提高加工精度；Wagner 等^[5]研究了环形铣刀加工情况下的刀具磨损情况；Serafettin 等^[6]对环形铣刀铣削加工的稳定性、加工后表面粗糙度以及三维表面光洁度等进行了研究，发现环形铣刀可以制得残留高度和表面粗糙度都小的产品。

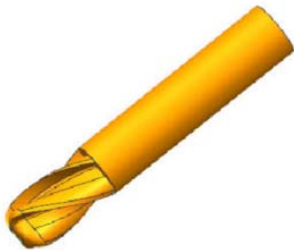


图 1 环形铣刀
Fig.1 Circular milling cutter

在铣削过程中，由于很多工艺参数及其交互作用对加工质量都具有一定的影响。传统的数学统计分析和线性预测存在一定的缺陷，并且很难建立出能准确表达加工质量与工艺参数之间的复杂数学模型关系式，预测精度较低^[7]。人工神经网络是近年来迅速发展起来的人工智能的一个重要部分，经过系统训练和学习，能够快速找出输入参数和输出参数之间的函数关系，适合工艺参数与加工质量之间的非线性预测。目前，主要的人工神经网络有 BP 和 RBF 神经网络等。倪立斌等^[8]利用神经网络遗传算法优化参数；张臣等^[9]利用 BP 神经网络对铣削工艺进行优化设计；宋江腾等^[10]利用 RBF 神经网络模型对合金磨用量进行预测。本文创新性地把 BP 和 RBF 神经网络

进行对比研究，选出预测精度更高与预测效果更好的方法。

1 实验

1.1 实验材料与方法

本次实验选用的工件材料为 7050-T7451 航空铝合金，其力学性能如表 1 所示。实验机床型号为 VDL-1000E 高速铣削加工中心，刀具材料为硬质合金钢 YG8，其力学性能如表 2 所示。以表面粗糙度（*Ra*）为性能评价指标，采用便携式表面粗糙度测试仪(Mitutoyo SJ-210)进行测量，观测表面粗糙度的变化，并对所得数据进行分析研究。

表 1 工件材料的力学性能
Tab.1 Mechanical properties of workpiece materials

Density/(kg·m ⁻³)	Elastic modulus/GPa	Poisson's ratio
2820	71.7	0.33

表 2 刀具材料的力学性能
Tab.2 Mechanical properties of cutter materials

Density/(kg·m ⁻³)	Elastic modulus/GPa	Poisson's ratio	Specific heat capacity/(J·kg ⁻¹ ·K ⁻¹)
14 800	640	0.22	220

1.2 实验方案与结果

为了使进行实验的次数最少且充分考察铣削速度（*A*）、进给量（*B*）和铣削深度（*C*）对表面粗糙度的影响，将评价加工质量的表面粗糙度（*Ra*）作为响应性能指标，*Ra*1、*Ra*2 分别为球头铣刀和环形铣刀加工的工件表面粗糙度。以铣削速度（*A*）、进给量（*B*）和铣削深度（*C*）为影响因子，采用正交实验法设计得到实验方案，选取的三因素四水平编码如表 3 所示。

表 3 工艺参数因素编码水平表
Tab.3 Process parameter factor coding level

Factor level	1	2	3	4
<i>A</i> /(r·min ⁻¹)	60	90	120	150
<i>B</i> /(mm·r ⁻¹)	0.1	0.2	0.3	0.4
<i>C</i> /mm	0.2	0.4	0.6	0.8

按照正交实验法设计实验,采用不同编码组合进行实验。使用表面粗糙度测试仪(Mitutoyo SJ-210),对每组实验进行三次测量,取三次的平均值作为最终表面粗糙度值。实验方案如表4所示。

表4 实验方案
Tab.4 Experimental scheme

Experimental coding	A $/(r \cdot \min^{-1})$	B $/(mm \cdot r^{-1})$	C/mm	Ra1/ μm	Ra2/ μm
1	60	0.1	0.4	0.582	0.542
2	60	0.1	0.2	0.633	0.560
3	60	0.2	0.4	0.715	0.615
4	60	0.3	0.6	0.625	0.505
5	60	0.4	0.8	0.698	0.570
6	90	0.1	0.4	0.665	0.545
7	90	0.2	0.2	0.702	0.576
8	90	0.2	0.6	0.657	0.522
9	90	0.3	0.8	0.732	0.551
10	90	0.4	0.6	0.719	0.536
11	120	0.1	0.6	0.611	0.499
12	120	0.2	0.8	0.699	0.533
13	120	0.3	0.2	0.654	0.561
14	120	0.3	0.4	0.617	0.568
15	120	0.4	0.4	0.684	0.557
16	150	0.1	0.8	0.743	0.571
17	150	0.2	0.6	0.641	0.571
18	150	0.2	0.2	0.747	0.583
19	150	0.3	0.4	0.651	0.571
20	150	0.4	0.2	0.714	0.589
21	120	0.4	0.6	0.683	0.565
22	60	0.3	0.2	0.658	0.561
23	90	0.1	0.2	0.667	0.556
24	90	0.3	0.4	0.711	0.560
25	120	0.1	0.2	0.682	0.511
26	120	0.2	0.6	0.603	0.514
27	150	0.1	0.8	0.641	0.571
28	150	0.4	0.2	0.618	0.589
29	60	0.4	0.2	0.697	0.562
30	90	0.1	0.6	0.559	0.502
31	60	0.1	0.4	0.616	0.542
32	60	0.1	0.8	0.599	0.530
33	90	0.2	0.4	0.717	0.556
34	60	0.1	0.4	0.649	0.542
35	90	0.3	0.2	0.682	0.571

从表4的Ra1和Ra2数据对比可知,在同样的加工条件下,采用环形铣刀比采用球形铣刀更能有效地降低工件的表面粗糙度值,提高加工质量。

2 BP神经网络和RBF神经网络的基本原理与建立

2.1 BP神经网络的基本原理

BP神经网络是一种误差反向传播神经网络,它由输入层、隐含层和输出层构成,每一层都由一定数量的神经元构成,它的网络结构如图2所示。它的基本原理是,把期望输出与实际输出的均方误差向输入层反射传播,分配给各连接节点并计算出参考误差,从而调节连接权值,使得均方误差达到最小^[11]。

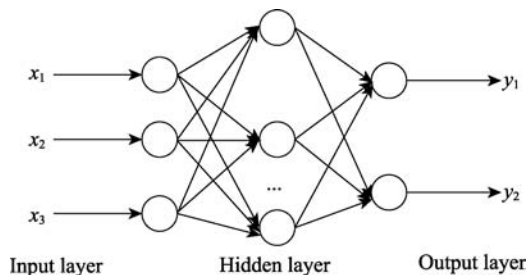


图2 BP网络结构图
Fig.2 BP network structure diagram

2.2 RBF神经网络的基本原理

RBF神经网络是一种具有单隐含层的前向网络,它不仅可以用来进行函数逼近,还能进行预测,从理论来讲,它可以逼近任何非线性函数^[12]。它由输入层、隐含的径向基层和输出线性层构成,它的网络结构如图3所示。径向基函数是径向对称的,常用的是高斯函数:

$$R_i(x) = \exp\left(-\frac{\|x - c_i\|^2}{2\sigma_i^2}\right), i = 1, 2, \dots, p$$

其中, x 是 m 维输入向量; c_i 是第 i 个基函数的中心; σ_i 是第 i 个基函数的方差; p 是感知单元的个数。

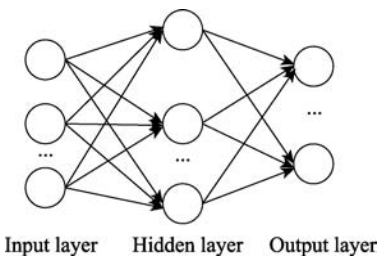


图3 RBF网络结构图
Fig.3 RBF network structure diagram

RBF网络的输入层实现从 $x \rightarrow R_i(x)$ 的非线性映射,输出层实现从 $R_i(x) \rightarrow y_R$ 的线性映射,即:

$$y_R = \sum_{i=1}^p w_{ki} R_i(x), k = 1, 2, \dots, q$$

其中, q 是输出节点数, w_{ki} 为第 k 个输出层与第 i 个隐含层神经之间的调节权重。

2.3 RBF 神经网络的构建

用 RBF 神经网络对 20 组数据进行分析,步骤如下。

(1) 确定输入层节点。在环形铣削加工工艺过程中,多种工艺参数影响加工质量,选取铣削速度、进给量和铣削深度这几个主要工艺参数作为神经网络的输入节点。

(2) 确定输出层节点。根据影响加工质量的因素指标,确定在此网络中以表面粗糙度为加工量的评价指标。

(3) 确定隐含层节点。在 RBF 神经网络中,隐含层起着关键的作用,隐含层层数影响模型精度、误差和运行速度的快慢,所以要结合实际情况进行试探性选择,再逐步进行优化^[13]。

(4) 规范化处理。由于各参数的取值范围和量纲有很大不同,不能在同一标准下确定各参数对表面粗糙度的影响,为了使得神经网络在进行训练过程中收敛速度更快,泛化能力更好,要先对样本数据进行规范化处理,把数据都转化为[0,1]之间的数。本文采取的规范化方法为最大最小值归一法^[14]。函数形式为:

$$x_k = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

式中: x_k 为标准化之后的数据; x_{\min} 为数据中最小的数; x_{\max} 为数据中最大的数。

(5) 网络模型的训练。将前 15 组数据作为训练样本,以 16—20 组数据作为测试数据。用 MATLAB 自带的神经网络工具箱中的 newrbe 函数创建 RBF 神经网络。在 RBF 神经网络中,输入层节点数为 3,输出层节点为 4,隐含层节点数采用 newrbe 函数的自动设置。spread 为径向基函数的扩展系数^[15], spread 过大或者过小都不利于实现神经网络的预测。如果 spread 太小,输入向量可能无法覆盖住区域,则需要的神经元会增加;如果太大,会导致神经元之间产生重叠区域,从而引起过度拟合^[14],增加数值计算上的困难。所以采用试凑法确定 spread 的值,分别取 15、19、20、21 和 25 进行预测,经过对比分析,确定 spread 为 20。

2.4 BP 神经网络的构建

用 BP 神经网络对 20 组数据进行分析。输入层节点、输出层节点与 RBF 神经网络选取相同,隐含层采用 tansig 函数,输出层采用 logsig 函数,训练函数采用 traingd 函数,再进行与 RBF 神经网络同样的规范化处理和网络模型训练。

3 神经网络预测结果与分析

3.1 RBF 神经网络的构建与预测

通过建立好的 RBF 神经网络模型对表面粗糙度

进行预测,将 26—35 组测试数据输入到神经网络模型中,得到输出结果。对实测值和预测值进行对比,得出相对误差,如表 5 所示。表面粗糙度相对误差的绝对值不超过 6%,最大误差为 0.056 098,平均误差为 0.022 277,说明 RBF 神经网络的预测精度较高。实测值与预测值的对比折线图如图 4 所示,从图中可以看出,实测值与预测值的趋势基本吻合。

表 5 RBF 神经网络表面粗糙度实测值与预测值对比表
Tab.5 Comparison of measured surface roughness by RBF neural network and predicted value

Experimental coding	Measured value/ μm	Predictive value/ μm	Relative error
26	0.514	0.5294	-0.029 920
27	0.571	0.5642	0.011 983
28	0.589	0.6021	-0.022 232
29	0.562	0.5883	-0.046 840
30	0.502	0.5302	-0.056 098
31	0.542	0.5507	-0.016 004
32	0.530	0.5308	-0.001 533
33	0.556	0.5455	0.018 910
34	0.542	0.5507	-0.016 004
35	0.571	0.5691	0.003 244

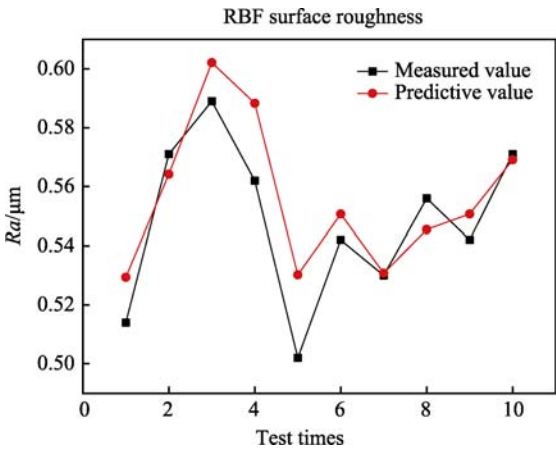


图 4 RBF 实测值与预测值的对比折线图
Fig.4 Contrast line graph between measured value by RBF and predicted value

3.2 BP 神经网络的构建与预测

用同样的表 4 的前 25 组数据对所建立的 BP 神经网络进行训练,26—35 组数据用来测试,将实测值与预测值进行对比,如表 6 所示,最大误差为 0.074 947,平均误差为 0.036 578,实测值与预测值的对比折线图如图 5 所示。通过对比说明,同等条件下建立的 RBF 神经网络有更高的预测精度,且训练时间和收敛速度都比 BP 神经网络好。

表 6 BP 神经网络表面粗糙度实测值与预测值对比表
Tab.6 Comparison of measured surface roughness by BP neural network and predicted value

Experimental coding	Measured value/ μm	Predictive value/ μm	Relative error
26	0.514	0.5278	-0.026 930
27	0.571	0.5573	0.024 005
28	0.589	0.5719	0.029 062
29	0.562	0.5199	0.074 947
30	0.502	0.5281	-0.052 028
31	0.542	0.5572	-0.028 050
32	0.530	0.5092	0.039 294
33	0.556	0.5789	-0.041 271
34	0.542	0.5572	-0.028 050
35	0.571	0.5836	-0.022 139

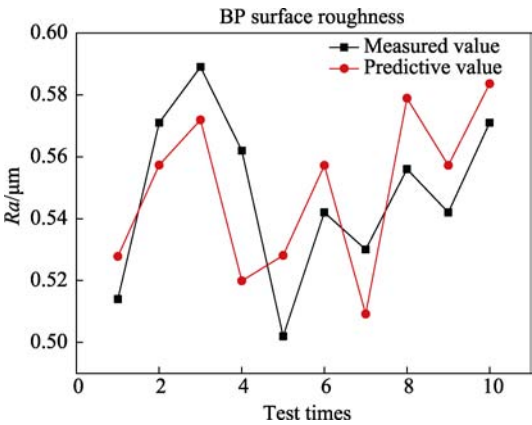


图 5 BP 实测值与预测值的对比折线图

Fig.5 Contrast line graph between measured value by BP and predicted value

4 结 论

1) 同等条件下, 环形铣刀比球形铣刀性能更好, 能更好地降低表面粗糙度, 提高铣削加工质量。

2) RBF 神经网络模型的表面粗糙度预测值与实测值的平均误差为 0.022 277, 而 BP 神经网络模型的平均误差为 0.036 578, 可见 RBF 预测精度较高, 可以应用于铣削工艺表面粗糙度的预测。

3) 将 RBF 神经网络模型和同等情况下建立的 BP 神经网络模型进行对比发现: RBF 神经网络的预测精度更高, 训练速度更快, 训练稳定性更高, 所以对于表面粗糙度预测来说, RBF 神经网络更优。

参考文献:

[1] SHOKRANI A, DHOKIA V, NEWMAN S T. Environmentally conscious machining of difficult to machine materials with regard to cutting fluids[J]. International journal of machine tools and manufacture, 2012, 57(2): 83-101.

[2] CETIN H M, OZCELIK B, KURAM E, et al. Evaluation

of vegetable based cutting fluids with extreme pressure and cutting parameters in turning of AISI 304L by Taguchi method[J]. Journal of cleaner production, 2011, 19 (17): 2049-2056.

[3] 刘献礼, 姜彦翠, 吴石, 等. 汽车覆盖件用淬硬钢模具铣削加工的研究进展[J]. 机械工程学报, 2016, 52(17): 35-49.

LIU Xian-li, JIANG Yan-cui, WU Shi, et al. Research progress in milling of hardened steel moulds for automobile panels[J]. Chinese journal of mechanical engineering, 2016, 52(17): 35-49.

[4] 岳彩旭, 李录彬, 计伟, 等. 基于磨制精度的环形铣刀刃线几何模型[J]. 南京航空航天大学学报, 2016, 48(1): 93-97.

YUE Cai-xu, LI Lu-bin, JI Wei, et al. Geometry model of edge milling edge line based on grinding accuracy[J]. Journal of Nanjing University of Aeronautics and Astronautics, 2016, 48(1): 93-97.

[5] WAGNER V, DUC E. Study of Ti-1023 milling with toroidal tool[J]. The international journal of advanced manufacturing technology, 2014, 75(9-12): 1473-1491.

[6] ENGIN S, ALTINTAS Y. Mechanics and dynamics of general milling cutters. Part I: Helical end mills[J]. International journal of machine tools and manufacture, 2001, 41(15): 2195-2212.

[7] 张婕, 曹西京, 杨玮, 等. 基于模糊神经网络的安全生产方案决策[J]. 工业工程, 2010, 13(6): 105-108.

ZHANG Jie, CAO Xi-jing, YANG Wei, et al. Decision making of safe production scheme based on fuzzy neural network[J]. Industrial engineering, 2010, 13(6): 105-108.

[8] 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. Laser cladding process optimization based on neural network and particle swarm optimization algorithm[J]. China laser, 2011, 38(2): 99-104.

[9] 张臣, 周儒荣, 庄海军, 等. 基于 BP 神经网络的球头铣刀铣削力建模与仿真[J]. 中国机械工程, 2005, 16 (20): 1791-1794.

ZHANG Chen, ZHOU Ru-rong, ZHUANG Hai-jun, et al. Modeling and simulation of milling force of ball-end milling cutter based on BP neural network[J]. China mechanical engineering, 2005, 16(20): 1791-1794.

[10] 宋江腾, 曾攀, 赵加清, 等. 基于 RBF 神经网络模型的司太立合金磨损量预测[J]. 润滑与密封, 2011, 36(3): 30-32.

SONG Jiang-teng, ZENG Pan, ZHAO Jia-qing, et al. Prediction of wear content of stellite alloy based on RBF neural network model[J]. Lubrication engineering, 2011, 36(3): 30-32.

[11] 张浩, 刘玉德, 石文天, 等. 微细切削加工表面质量的研究综述[J]. 表面技术, 2017, 46(7): 219-232.

ZHANG Hao, LIU Yu-de, SHI Wen-tian, et al. Review of research on surface quality of micro-cutting[J]. Surface technology, 2017, 46(7): 219-232.