

表面质量控制及检测

基于 BP 神经网络的确切性剪切增稠
抛光材料去除率模型宋志龙¹, 吕冰海¹, 柯明峰¹, 杨易彬¹, 邵琦¹, 袁巨龙¹, Duc-nam Nguyen²

(1. 浙江工业大学 特种装备制造与先进加工技术教育部重点实验室, 杭州 310014;

2. 胡志明工业大学 机械工程学院, 越南 胡志明市 727010)

摘要: **目的** 通过训练不同实验参数条件下的确切性剪切增稠抛光的实验数据, 建立基于 BP 神经网络的确切性剪切增稠抛光材料去除率模型, 为实现抛光点材料的确定去除控制提供基础。**方法** 以 BK7 平面玻璃为抛光对象展开确切性剪切增稠抛光正交实验, 根据正交实验分析结果, 比较抛光头转速、抛光头与工件之间的间隙以及抛光液浓度三个因素, 对抛光点材料去除率影响的权重, 确定 BP 神经网络的输入参量。根据经验公式初步确定网络隐含层节点个数, 并综合比较不同隐含层节点数目的模型性能来确定整体网络结构, 使用训练集实验数据训练网络模型, 建立抛光点的材料去除率模型。**结果** 模型预测结果与实验结果对比表明, 所建立的峰值去除率 BP 神经网络预测模型输出结果与实验结果之间的相对误差在 6.8% 以内, 验证了所建立材料去除率模型的准确性。**结论** 传统理论模型难以精确描述确切性剪切增稠抛光的工艺参数与抛光区域材料峰值去除率之间复杂的非线性映射关系, 而 BP 神经网络的自学习自适应能力能够克服这种问题, 为确切性剪切增稠抛光去除率模型的建立提供新的思路。

关键词: 剪切增稠抛光 (STP); BP 神经网络; 确切性抛光; 去除率; 去除率模型**中图分类号:** TG175 **文献标识码:** A **文章编号:** 1001-3660(2020)11-0320-06**DOI:** 10.16490/j.cnki.issn.1001-3660.2020.11.037Removal Rate Model of Deterministic Shear Thickening
Polishing Material Based on BP Neural NetworkSONG Zhi-long¹, LYU Bing-hai¹, KE Ming-feng¹, YANG Yi-bin¹,
SHAO Qi¹, YUAN Ju-long¹, Duc-nam Nguyen²

(1. Key Laboratory of Special Equipment Manufacturing and Advanced Processing Technology of the Ministry of Education, Zhejiang University of Technology, Hangzhou 310014, China; 2. Faculty of Mechanical Engineering, Industrial University of Ho Chi Minh City, Ho Chi Minh City 727010, Vietnam)

收稿日期: 2020-01-07; 修订日期: 2020-04-15

Received: 2020-01-07; Revised: 2020-04-15

基金项目: 浙江省自然科学基金项目 (LR17E050002); 国家自然科学基金 (51805485, 51805484, 51775508)

Fund: Supported by the Natural Science Foundation of Zhejiang Province (LR17E050002), National Natural Science Foundation of China (51805485, 51805484, 51775508)

作者简介: 宋志龙 (1995—), 男, 硕士研究生, 主要研究方向为超精密加工技术。

Biography: SONG Zhi-long (1995—), Male, Master, Research focus: ultra-precision machining technology.

通讯作者: 吕冰海 (1978—), 男, 博士, 研究员, 主要研究方向为超精密加工技术。邮箱: icewater7812@126.com

Corresponding author: LYU Bing-hai (1978—), Male, Doctor, Researcher, Research focus: ultra-precision machining technology. E-mail: icewater7812@126.com**引文格式:** 宋志龙, 吕冰海, 柯明峰, 等. 基于 BP 神经网络的确切性剪切增稠抛光材料去除率模型[J]. 表面技术, 2020, 49(11): 320-325.
SONG Zhi-long, LYU Bing-hai, KE Ming-feng, et al. Removal rate model of deterministic shear thickening polishing material based on BP neural network[J]. Surface technology, 2020, 49(11): 320-325.

ABSTRACT: The work aims to establish the removal rate model of deterministic shear thickening polishing (DSTP) based on BP neural network by training the data of DSTP under different conditions, to provide basis for the deterministic removal control of material at polishing point. DSTP orthogonal experiment was conducted on BK7 flat glass, and the results were analyzed to compare the weight of each factor's (polishing head speed, polishing gap, concentration of polishing slurry) impact on material removal rate of polishing point, to determine the input parameters of BP neural network. The number of hidden layer nodes was determined by experimental equation initially, and then the whole structure of network model was constructed by comparing the performance of the model under different hidden layer nodes. The final material removal rate model was established based on the experimental data designed network trained by the model. The comparison between the model prediction results and the experimental results showed that the relative error was less than 6.8% between the output of the established BP neural network prediction model and the measured results, proving the accuracy of the prediction model. The traditional theoretical model is difficult to accurately describe the complicated nonlinear mapping relationship between the process parameters of DSTP and the peak removal rate. The self-learning and adaptive ability of BP neural network can overcome this problem and provide a novel strategy for building the removal rate model of the deterministic shear thickening polishing process.

KEY WORDS: shear thickening polishing; BP neural networks; deterministic polishing; removal rate; removal rate model

确定性抛光通过精确控制抛光头抛光区域材料去除量、抛光路径以及抛光驻留时间,可对工件表面轮廓误差进行修正^[1],在保证工件表面质量的同时,获得高面型精度。近年来出现的典型确定性抛光方法包括:磁流变抛光^[2]、电射流抛光^[3]、磁射流抛光^[4]、气囊抛光^[5]等。在确定性抛光中,工件表面的材料去除量是去除函数和驻留时间的卷积。因此,材料去除模型对于工件表面修型起着至关重要的作用^[6-8]。尹韶辉等^[9]分析了磁流变抛光中的流体动压力和磁化压力,得出了适用于小口径非球面斜轴磁流变抛光材料去除率模型。YANG 等^[10]进行了不同磨粒浓度对去除机理的影响分析,得到了磁射流材料去除模型。Kim 等^[11]研究了射流抛光中的材料去除特性,得到射流抛光材料去除模型。

吕冰海等提出了一种基于非牛顿流体剪切增稠效应的剪切增稠抛光 (Shear Thickening Polishing, STP),分析了抛光过程的材料去除机理^[12],并建立了表面粗糙度演变模型^[13]。利用 STP 方法抛光硬质合金刀片复杂切削刃 15 min 后,其表面粗糙度从 121.8 nm 减小至 7.1 nm^[14]。轴承套圈经过 STP 方法抛光后,得到了 4.55 nm 的表面粗糙度和 0.82 μm 的表面轮廓误差^[15]。确定性剪切增稠抛光 (Deterministic Shear Thickening Polishing, DSTP) 是将 STP 方法应用于确定性抛光工艺中,其先决条件是确定抛光点的材料去除模型。然而,影响确定性剪切增稠抛光材料去除率的参数诸多,主要有抛光头转速、抛光头与工件之间的间隙高度以及抛光液的浓度等,且参数之间存在交互作用及高度非线性关系,采用传统数学方法建立抛光去除模型存在局限性。

近来,神经网络 (NN) 由于具有自学习、自适应以及显著的非线性函数逼近等特点,被广泛用来解决复杂工艺参数的控制问题。樊世燕等^[16]对比了响应

曲面法 (RSM) 和人工神经网络 (NN) 在铜 CMP 工艺参数控制中的应用,研究发现 NN 比 RSM 具有更好的拟合度和预测精度。李婕等^[17]在优化航空发动机叶片砂带抛光工艺参数时,采用 BP 神经网络建立了表面粗糙度与工艺参数之间的预测模型,确定了最佳工艺参数。鄢烈忠等^[18]建立了磨料水射流抛光工艺参数 BP 神经网络预测模型,以磨料浓度、靶距、横移速度与表面粗糙度作为输入参数,输出入射角度和射流压力,并在模型输出的入射角度和射流压力下,进行实验,测得实际值与模型预测值的相对误差在 0.29%~2.89% 之间。此外,NN 方法亦被应用于超声无磨料外圆抛光工件表面粗糙度的预测、滚子轴承电化学抛光、硅和铜等材料 CMP 工艺理论模型的构建^[19-22]。

本文旨在基于 BP 神经网络建立确定性剪切增稠抛光点材料峰值去除率模型。在不同实验条件下进行正交实验,并将实验数据分为训练集和测试集样本。将训练集样本用于 BP 神经网络的训练,采用经验公式确定 BP 神经网络隐含层节点的数量范围,综合比较不同隐含层节点数目时网络的性能,确定网络的整体结构,最后使用测试集样本验证所建立的材料去除率模型的准确性。

1 确定性剪切增稠抛光原理

DSTP 加工平面玻璃原理示意图如图 1 所示。以剪切增稠流体作为基液配制抛光液,将抛光用的磨粒分散在剪切增稠流体中。通过抛光头旋转带动抛光液的流动,抛光头与工件之间抛光液受到的剪切速率超过一定的阈值时会产生剪切增稠效应,抛光液中分散的胶态固体粒子聚集成大量粒子簇,并将磨粒包裹在其中。接触区域抛光液的黏度急剧增大,瞬间呈现固

体特性,增强了对磨粒的把持力,在抛光区域形成一个柔性“固着磨具”。对工件表面材料进行微切削,结合抛光头的路径和抛光驻留时间的控制,可实现对工件表面轮廓误差的修正。抛光头转速、抛光间隙和抛光液浓度等是抛光区域的材料去除函数的主要工艺参数。




图1 剪切增稠确定性抛光原理示意图

Fig.1 Schematic illustration of shear thickening deterministic polishing

2 确定性剪切增稠抛光实验

2.1 实验过程与实验条件

为了探究确定性剪切增稠抛光中抛光头转速、抛光间隙和抛光液浓度三个影响参数对峰值去除率的影响权重,以确定网络模型的输入参量,本文将运用3因素4水平的正交实验对三个参数进行分析,并将抛光点材料峰值去除率(抛光点去除函数呈高斯分布)作为评价指标。本次实验采用3000# Al_2O_3 剪切增稠抛光液^[23],其流变曲线如图2所示(采用流变仪测量)。随着剪切速率的增加,抛光液黏度的变化呈现三个阶段:区域I为剪切变稀阶段,黏度随剪切速率的增加而降低;区域II为剪切增稠阶段,黏度随剪切速率的增加急速上升,这也是STP所运用的区域;区域III又呈现为剪切变稀阶段。抛光实验条件如表1所示,抛光实验平台如图3所示,平面工件(BK7光学玻璃)浸没在抛光液中,具有楔形结构的抛光头靠近工件表面,通过主动旋转带动抛光液流动从而产生剪切作用,实现工件表面确定点的材料去除。






图2 剪切增稠抛光液黏度曲线

Fig.2 Viscosity curve of shear thickening polishing slurry



a 示意图



b 实物图

图3 确定性抛光实验平台

Fig.3 Deterministic polishing experimental device: a) schematic diagram; b) Picture

表1 确定性抛光实验条件

Tab.1 Deterministic polishing experimental conditions

Experimental conditions	Parameters
Workpiece diameter (inch)	1.5
Abrasive	Al_2O_3
Abrasive particle size	3000#
Abrasive particle concentration/wt%	3, 5, 7, 9
Polishing head size/mm	$\phi 75 \times 30$
Wedge grooves number of polishing head	12
Rotating speed/($\text{r} \cdot \text{s}^{-1}$)	4, 8, 12, 16
Gap/mm	0.6, 0.8, 1, 1.2
Polishing time/h	1

2.2 抛光点峰值去除率测量方法

实验中为得到工件的材料去除率,首先使用激光干涉平面度仪 GPI XP/D 对抛光之前的玻璃表面进行测量,得到表面的平面度如图4a所示;抛光头在玻璃表面中心并作为驻留点,定点抛光1h后,再次用平面度仪测量抛光后玻璃表面的平面度,如图4b所示;将抛光后面形与初始面形相减得到抛光过程的材料去除量分布,如图5a所示。提取X轴中心截面轮廓数据,并取最高点作为峰值去除量,如图5b所示。

2.3 实验结果及分析

按表1所示的实验条件进行3因素4水平的正交实验,并采用2.2所述方法测量去除率,得到各参数各水平值下的材料去除率,如表2所示。对实验结果进行方差分析,抛光头转速、抛光间隙和抛光液浓度

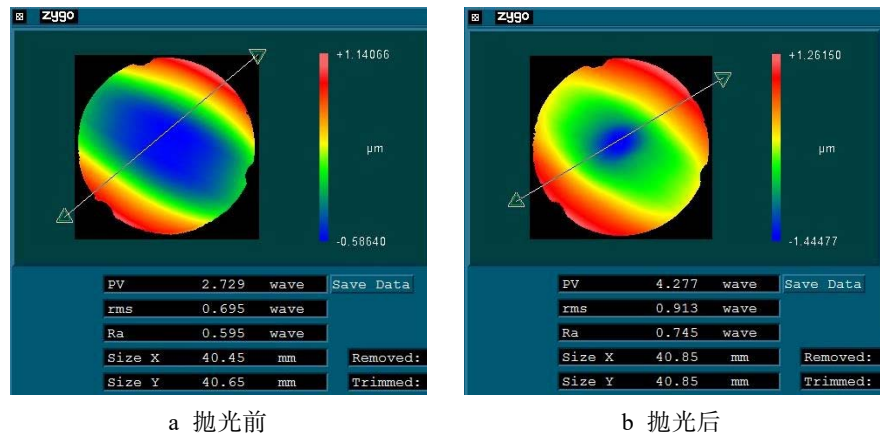


图 4 玻璃面型图
Fig.4 Surface pattern of glass: a) before polishing; b) after polishing

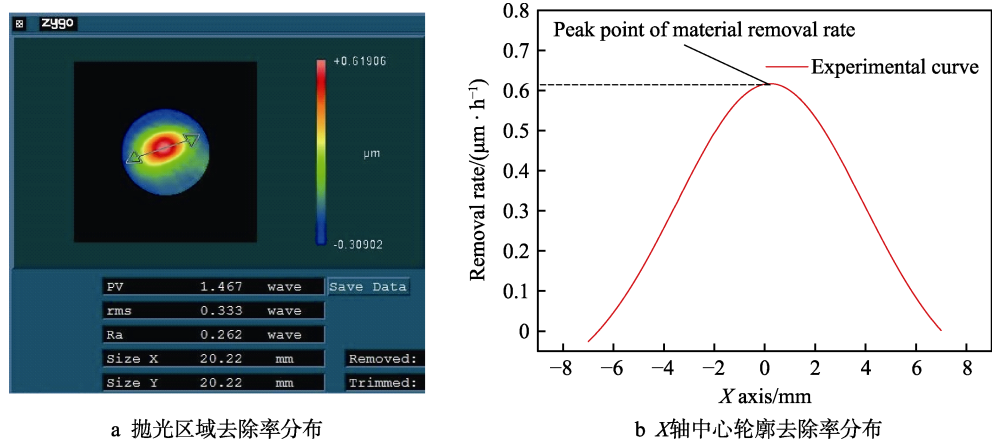


图 5 去除率分布
Fig.5 Removal rate distribution: a) polishing zone; b) X-axis center contour

表 2 实验结果
Tab.2 Experiment result

Serial number	Rotating speed $\omega/(\text{r}\cdot\text{s}^{-1})$	Gap h/mm	Concentration $c/\text{wt}\%$	MRR/ $(\mu\text{m}\cdot\text{h}^{-1})$
1	4	0.6	3	0.027
2	4	0.8	5	0.056
3	4	1	7	0.118
4	4	1.2	9	0.093
5	8	0.6	5	0.049
6	8	0.8	3	0.248
7	8	1	9	2.530
8	8	1.2	7	0.389
9	12	0.6	7	0.066
10	12	0.8	9	0.413
11	12	1	3	0.436
12	12	1.2	5	0.161
13	16	0.6	9	0.081
14	16	0.8	7	0.065
15	16	1	5	0.050
16	16	1.2	3	0.027

对材料去除率的影响权重分别为 34.38%、33.45%和 32.17%，可见三个因素对材料去除率都有着重要的影响，因此将这三个因素均作为确定性剪切增稠抛光材料去除模型的输入参量。

3 确定性剪切增稠抛光峰值去除率材料去除模型的建立

3.1 BP 神经网络结构设计

BP 神经网络具有自学习、自适应和很强的非线性映射的能力，可以逼近任意连续函数，且只需要数据样本而无需建立数学模型，就可以建立起输入与输出之间的非线性映射关系。在不限隐层节点数的情况下，一个三层 BP 神经网络可以实现任意 n 维到 m 维的映射^[24]，因此本文选用单隐层的 BP 神经网络建立材料去除模型。

根据第 2.3 节正交实验分析结果，网络的输入层节点数为 3，分别为抛光头转速 ω 、抛光间隙 h 和抛光液浓度 c 。网络的输出层节点数为 1，即抛光点的

峰值去除率。中间隐含层的节点数目在很大程度上决定了网络的预测性能。过少的隐层节点数目会导致网络对复杂函数的拟合能力不足,而过多的隐层节点数目则会导致网络出现过拟合现象,网络的泛化能力差。这里隐含层节点数目考虑根据经验公式(1)^[25]确定。

$$n_1 = \sqrt{n+m} + \alpha \quad (1)$$

式中: n_1 为隐含层节点数, n 为输入层节点数, m 为输出层节点数, α 为 1~10 之间的常数。由于输入层节点数为 3, 输出层节点数为 1, 因此隐含层节点数范围是 3~12。综合比较各隐含层节点数下网络模型的性能, 最终确定隐含层节点数目为 11。得到整个 BP 神经网络的结构为 3×11×1, 如图 6 所示。

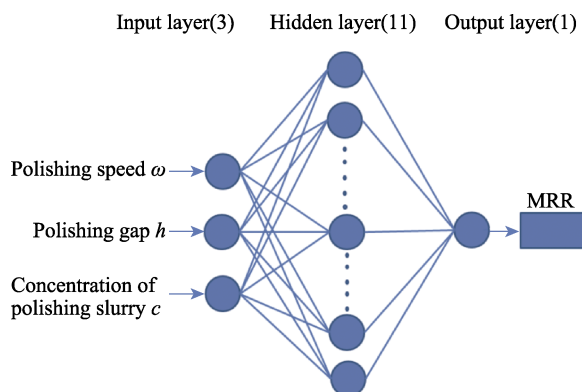


图 6 确定性剪切增稠抛光 BP 神经网络模型
Fig.6 BP neural network model for DSTP

3.2 BP 神经网络训练

根据图 6 所示的网络结构训练模型, 网络中间层的神经元传递函数使用 S 型正切函数 $\tanh()$, 网络的训练函数为 Adam()。训练次数设置为 3000, 初始学习率设为 0.01。在训练的后期, 模型输出值与实验值之间的误差越来越小, 使得每次权重更新的变化量很小, 因此采用周期性学习率衰减的方式, 每隔 1000 次迭代学习率衰减 10 倍。训练目标为网络输出值与真实数据值之间的均方误差小于 1×10^{-5} 。随机选取表 1 中的第 4、5、9、13 组实验数据作为测试样本, 用来测试网络模型, 其余样本数据用来训练模型。训练期间, BP 神经网络通过其自主学习能力, 不断修正各节点之间的权值, 以使模型输出结果不断逼近样本数据, 直至达到训练目标或者达到训练次数时停止。图 7 为随着训练的进行, 网络输出值与实验值之间的均方误差的变化情况。可以看到, 在训练的起始阶段, 两者均方误差值大幅下降, 在约第 300~1000 次迭代期间出现震荡, 这是由于此时的模型准确度已经较高, 0.01 的学习率无法使模型向更精确的结果逼近。而学习率周期性衰减的策略会随着训练的进行周期性降低学习率, 因此在 1000 次迭代之后, 均方误差值进一步下降并趋于稳定, 在第 2814 次迭代时达到了预设目标误差。




图 7 BP 神经网络训练过程中的误差变化
Fig.7 Error variation during BP neural network training

3.3 BP 神经网络测试

为了测试训练的网络模型的性能, 将测试集工艺参数输入神经网络, 然后比较网络输出值与实验值之间的误差是否满足要求。图 8 为 BP 神经网络预测值与实验值的对比, 可以看到实验值与神经网络预测值比较接近, 四组测试数据的相对误差分别为 3.9%、4.1%、6.8%和 5.2%, 表明所建立的 BP 神经网络预测模型是准确可靠的, 可以有效地对确定性剪切增稠抛光区域的峰值去除率做出预测。




图 8 BP 神经网络预测值与测试样本值的对比曲线
Fig.8 Comparison of predicted values of BP neural network and test sample values

所建立的 BP 神经网络模型并不是一个明确的函数关系式, 而是一个网络结构, 利用该网络结构训练出的确定性剪切增稠峰值去除率预测模型, 克服了传统理论模型难以精确描述工艺参数与实验目标之间复杂的非线性映射关系的问题, 为优化抛光工艺提供了新的思路。但是根据实验结果可以看出, 该模型的预测结果与实验结果依然存在一定的误差, 其主要原因为: 1) 实验中存在随机误差以及测量误差; 2) 实验样本数据量小, 数据的多样性不足, 也会对模型的准确性造成影响。

4 结论

1) 通过分析不同实验参数下的确定性剪切增稠抛光正交实验结果, 得出抛光头转速、抛光头间隙和抛光液三个参数对抛光区域峰值去除率的影响权重分别为 34.38%、33.45%、32.17%, 进而确定了 BP 神经网络模型的输入参量。

2) 根据正交实验分析结果确定了 BP 神经网络模型输入节点数为 3, 根据经验公式并综合比较不同隐含层节点数目下网络的性能, 确定了网络模型隐含层节点数量为 11, 从而确定了最终网络结构为 $3 \times 11 \times 1$ 。

3) 采用建立的 BP 神经网络模型对正交实验数据进行训练, 所训练的模型在测试样本数据上的预测值与实验值的相对误差在 6.8% 以内, 验证了所建立的模型的准确性。

参考文献:

- [1] 计时鸣, 杜学山, 陈国达, 等. 确定性抛光综述[J]. 航空精密制造技术, 2010, 46(6): 1-5.
JI Shi-ming, DU Xue-shan, CHEN Guo-da, et al. Review on deterministic polishing[J]. Aviation precision manufacturing technology, 2010, 46(6): 1-5.
- [2] KORDONSKI W, GOLINI D. Progress update in magnetorheological finishing[J]. International journal of modern physics B, 1999, 13(14): 2205-2212.
- [3] KURIYAGAWA T, SAEKI M, SYOJI K. Electrorheological fluid-assisted ultra-precision polishing for small three-dimensional parts[J]. Precision engineering, 2002, 26(4): 370-380.
- [4] 陈逢军, 唐宇, 苗想亮, 等. 磨料射流表面抛光研究综述[J]. 表面技术, 2015, 44(11): 119-127.
CHEN Feng-jun, TAGN Yu, MIAO Xiang-liang, et al. Review on the abrasive jet surface polishing (AJP) technology[J]. Surface technology, 2015, 44(11): 119-127.
- [5] 计时鸣, 张利, 金明生, 等. 气囊抛光技术及其研究现状[J]. 机电工程, 2010, 27(5): 1-12.
JI Shi-ming, ZHANG Li, JIN Ming-sheng, et al. Status and outlook of gasbag polishing technique[J]. Journal of mechanical & electrical engineering, 2010, 27(5): 1-12.
- [6] ALAM Z, JHA S. Modeling of surface roughness in ball end magnetorheological finishing (BEMRF) process[J]. Wear, 2017, 374: 54-62.
- [7] ZHANG Ya-jun, CAO Cong, SUN Ming, et al. Modeling of material removal in dynamic deterministic polishing[J]. International journal of advanced manufacturing technology, 2015, 81(9-12): 1631-1642.
- [8] WANG Chun-jin, WANG Zhen-zhong, PAN Ri, et al. Research on the residual error evaluation method for deterministic polishing of aspheric optics[J]. Journal of mechanical engineering. 2014, 50(9): 169-175.
- [9] YIN Shao-hui, XU Zhi-qiang, CHEN Feng-jun, et al. Inclined axis magnetorheological finishing technology for small aspherical surface[J]. Journal of mechanical engineering, 2013, 49(17): 33-38.
- [10] WANG Tan, CHENG Hao-bo, DONG Zhi-chao, et al. Removal character of vertical jet polishing with eccentric rotation motion using magnetorheological fluid[J]. Journal of materials processing tech, 2013, 213(9): 1532-1537.
- [11] KIM W B, NAM Eunseok, MIN B K, et al. Material removal of glass by magnetorheological fluid jet[J]. International journal of precision engineering & manufacturing, 2015, 16(4): 629-637.
- [12] LI Min, LYU Bing-hai, YUAN Ju-long, et al. Shear-thickening polishing method[J]. International journal of machine tools & manufacture, 2015, 94(1): 88-99.
- [13] LI Min, LYU Bing-hai, YUAN Ju-long, et al. Evolution and equivalent control law of surface roughness in shear-thickening polishing[J]. International journal of machine tools & manufacture, 2016, 108: 113-126.
- [14] LYU Bing-hai, HE Qian-kun, CHEN Shi-hao, et al. Experimental study on shear thickening polishing of cemented carbide insert with complex shape[J]. The international journal of advanced manufacturing technology, 2019, 103(1-4): 585-595.
- [15] LI Min, HUANG Zhen-rong, DONG Ting, et al. Surface integrity of bearing steel element with a new high-efficiency shear thickening polishing technique[J]. Procedia CIRP, 2018, 71: 313-316.
- [16] 樊世燕, 刘玉玲, 林凯, 等. 优化 CMP 碱性铜抛光液配比的新方法[J]. 半导体制造技术, 2015, 40(3): 211-216.
FAN Shi-yan, LIU Yu-ling, LIN Kai, et al. A novel method of optimizing the alkaline polishing slurry composition for Cu CMP[J]. Semiconductor technology, 2015, 40(3): 211-216.
- [17] 李捷, 史耀耀, 何晓东. 航空发动机叶片砂带抛光工艺参数优化[J]. 航空制造技术, 2016(8): 60-65.
LI Jie, SHI Yao-yao, HE Xiao-dong. Optimization of process parameters in abrasive belt polishing of aeroengine blade[J]. Aeronautical manufacturing technology, 2016(8): 60-65.
- [18] 鄢烈忠, 雷玉勇, 唐炼, 等. 基于 BP 神经网络的磨料水射流抛光质量研究[J]. 煤矿机械, 2017, 38(12): 133-135.
YAN Lie-zhong, LEI Yu-yong, TANG Lian, et al. Research on polishing quality of abrasive water jet based on BP neural network[J]. Coal mine machinery, 2017, 38(12): 133-135.
- [19] 周苗, 蔡红霞, 王文斌, 等. 基于神经网络的针阀体挤压研磨工艺模型[J]. 机械设计与制造, 2012, 10(10): 245-247.
ZHOU Miao, CAI Hong-xia, WANG Wen-bin, et al. Modeling for extrusion grinding of inject valve based on neural network[J]. Machinery design & manufacture, 2012, 10(10): 245-247.