

多工序组合气囊抛光策略智能优化

邱家军

上海理工大学, 机械工程学院, 上海

收稿日期: 2023年2月14日; 录用日期: 2023年3月16日; 发布日期: 2023年3月23日

摘要

针对进一步提高多工序气囊抛光效率和质量的技术需要, 开展基于智能算法的多工序组合气囊抛光策略优化研究。以黄铜H62轴套为实验样件进行气囊粗抛与精抛实验, 分析总结样件表面粗糙度变化规律; 构建BP神经网络(Back propagation neural network, BP)模型, 利用实验数据训练获得不同抛光工艺参数下表面粗糙度及抛光时间的映射关系; 以获得最优表面粗糙度和抛光时间为目标, 采用NSGA-II(Non-dominated sorting genetic algorithm-II, NSGA-II)多目标优化的方法优化多工序组合抛光中各工序的工艺参数, 预测获得最佳转换工序的时间节点及最优多工序组合抛光参数。实验结果表明, 当采用优化的多工序组合抛光策略进行抛光时, 相比于优化后的单工序精抛所需总时长缩短了25%的时间, 由16分钟下降至12分钟, 而表面粗糙度Ra相比于优化后的单工序粗抛下降了0.317 μm 。该研究针对多工序组合气囊抛光工艺优化需要, 设计了基于NSGA-II多目标优化算法的多工序工艺参数优化策略, 可以实现轴套零件多工序气囊抛光加工效率和质量的同步提升。

关键词

气囊抛光, 多工序组合抛光, 黄铜H62, BP神经网络, NSGA-II

Intelligent Optimization of Multi Process Combination Bonnet Polishing Strategy

Jiajun Qiu

School of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Feb. 14th, 2023; accepted: Mar. 16th, 2023; published: Mar. 23rd, 2023

Abstract

In order to further improve the efficiency and quality of multi-process bonnet polishing, the optimization research of multi-process combination airbag polishing strategy based on intelligent al-

gorithm is carried out. The brass H62 shaft sleeve was used as the experimental sample to carry out the air bag rough polishing and fine polishing experiments, and the change rules of the surface roughness of the sample were analyzed and summarized; The Back propagation neural network (BP) model is constructed, and the mapping relationship between surface roughness and polishing time under different polishing process parameters is obtained by training the experimental data; In order to obtain the optimal surface roughness and polishing time, the Non-dominated sorting genetic algorithm-II (NSGA-II) multi-objective optimization method is used to optimize the process parameters of each process in multi-process combination polishing, and predict the time node of the optimal conversion process and the optimal multi-process combination polishing parameters. Results: The experimental results show that when the optimized multi-process combination polishing strategy is used for polishing, the total time required for the optimized single-process polishing is reduced by 25%, from 16 minutes to 12 minutes, and the surface roughness Ra is reduced by 0.317 μm compared with the optimized single-process polishing. Aiming at the needs of multi-process combination airbag polishing process optimization, this study designed a multi-process process parameter optimization strategy based on NSGA-II multi-objective optimization algorithm, which can achieve the synchronous improvement of multi-process airbag polishing efficiency and quality of shaft sleeve parts.

Keywords

Bonnet Polishing, Multi Process Combination Polishing, Brass H62, BP Neural Network, NSGA-II

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

气囊抛光由英国伦敦大学光学科学实验室和 Zeeko 有限公司联合提出, 是一种精度高、去除效率高且适用于平面、球面、非球面甚至任意曲面的抛光方式[1]-[6]。针对轴套类零件的抛光研究, 实验室采用自制的气囊抛光设备进行了抛光实验。实验发现所选用的工艺参数优劣将直接影响零件的表面粗糙度和抛光时间。为了得到合适的加工参数, 实验人员需要花费大量时间进行调整和试错, 这种方式依赖于实验人员的主观经验, 很难在不同的实验人员之间相互学习和传授。因此, 提出一种有效且能够相互借鉴的气囊抛光策略优化方法不仅可以提高气囊抛光的加工效率和质量, 还可以大大减少实验人员的工作量[7] [8] [9]。

为了得到行之有效的抛光策略优化方法, 国内外众多学者进行了大量的工作和实验[10] [11] [12] [13]。一部分学者采用正交实验法进行加工策略的优化, 通过控制改变工艺参数中的单一变量, 观察零件表面粗糙度或去除率的变化来寻找合适的加工参数。这种方式通过逐一确定较优的工艺参数实现抛光效率和质量的提升, 但对实验人员的经验要求较高, 花费精力较大[14]; 随着神经网络算法的快速发展和广泛运用, 有学者开始注意到其在抛光策略优化研究中的价值并进行了探索[15]。如潘杰[16]等基于 SPSO-BP 神经网络, 实现抛光工艺参数自适应匹配, 从而能够在零件表面产生缺陷前进行调整, 减少零件的报废率。郭继通等[17]基于遗传算法和神经网络构建了软脆工件研磨加工工艺智能决策系统, 能够为研磨工件时提供最优决策。赵传营等[18]通过智能算法对 TC4 材料研磨进行了工艺参数优化, 有效降低 TC4 材料加工的表面粗糙度。区别于正交实验法、神经网络算法等以优化工艺参数为主要手段, 颜晓强[19]等利用了小球头接触式抛光和磁流变抛光组合加工的方法, 解决了加工效率与加工质量相矛盾的问题, 充分将

两种抛光方式的优点结合。

纵观国内外相关研究,多数学者以表面粗糙度或去除率为评价指标进行抛光的策略优化,并达到了提升抛光质量和效率的效果,但还存在以下待完善之处:优化方法单一,仅进行单工序工艺参数优化或多工序结合的抛光策略优化,缺乏将二者结合研究;难以应用于气囊抛光的策略优化,缺乏针对气囊抛光的策略优化方法。因此,本文将单工序工艺参数优化和多工序组合抛光结合,提出一种多工序组合气囊抛光策略智能优化方法,达到提高气囊抛光的效率和质量的的目的。

2. 抛光实验与数据收集

2.1. 抛光原理

实验室自制的轴套类零件气囊抛光设备的抛光原理如图 1 所示,抛光头有一个由抛光垫包裹气腔组成的封闭空间,空间内部充满可控的气体压力 ρ 。当气囊头接触工件未压缩时如 a) 所示,当压缩量为 σ 时如 b) 所示,此时由于两者发生挤压,抛光垫与工件发生弹性形变,磨粒分布变得密集。当气囊头以角速度 ω 转动,带动磨粒与工件表面发生相对运动实现抛光。工件以线速度 v 在箭头方向往复运动可以实现轴向抛光。




Figure 1. Principle of bonnet polishing
图 1. 气囊抛光原理

2.2. 抛光实验

气囊抛光设备如图 2 所示,设备具有四轴驱动控制,由卧式车床改装而来。实验采用的工件为黄铜 H62 轴套零件,其实物图如图 3 所示。实验进行时长为 20 分钟的粗抛和精抛单工序抛光,实验前在内圆随机选择三个点测量表面粗糙度取其平均值作为工件的初始表面粗糙度。经过实验,得到表面粗糙度随时间变化曲线如图 4 所示。

表面粗糙度随时间变化曲线表明,零件在抛光时表面粗糙度下降的速率会不断减少直至趋于平稳,而单工序粗抛组达到平稳的所需时间为 4 min,其抛光后的表面粗糙度在 $0.503 \mu\text{m}$ 小范围波动;单工序精抛组所需的时间为 12 min,其抛光后的表面粗糙度在 $0.155 \mu\text{m}$ 左右小范围波动。为了提高抛光效率,可以将抛光过程中达到表面粗糙度平稳的时间点定为在该工艺参数下抛光所需的时间,从曲线变化规律可以看出粗抛的抛光时间短而表面粗糙度大,精抛的抛光时间长,表面粗糙度小。

2.3. 数据收集

以抛光参数为输入,以抛光后的表面粗糙度和抛光时间为输出的预测模型,需要在规定抛光参数范围(如表 1 所示)内进行大量实验,所得到的部分实验数据如表 2 所示。




Figure 2. Bonnet polishing equipment for shaft sleeve parts
图 2. 轴套类零件气囊抛光设备




Figure 3. H62 Brass shaft sleeve
图 3. H62 黄铜轴套

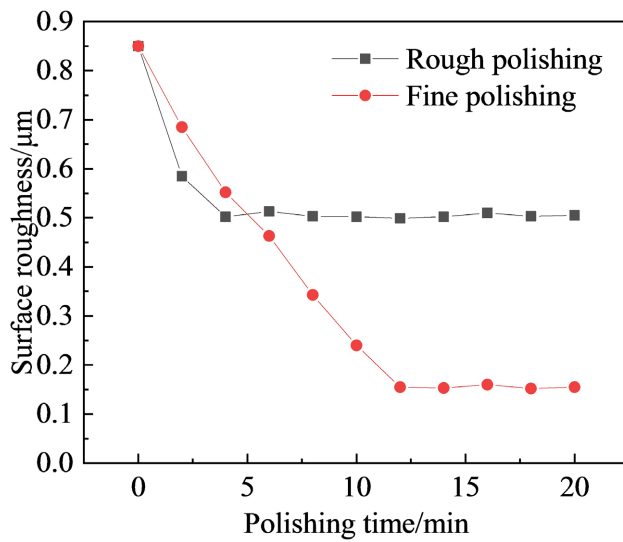


Figure 4. Time varying curve of roughness of single process polishing experiment
图 4. 单工序抛光实验表面粗糙度随时间变化曲线

Table 1. Range of polishing parameters
表 1. 抛光参数范围

	转速/(r·min ⁻¹)	压缩量/(mm)	充气压力/(MPa)	往复速度/(mm·s ⁻¹)	磨粒粒径/(μm)
粗抛范围	1000~1500	0.2~0.3	0.2~0.3	3~4	2.5; 5; 10
精抛范围	100~500	0.05~0.15	0.05~0.15	1~2	0.1; 1

Table 2. Polishing data of some single process
表 2. 单工序抛光数据

实验序号	转速/(r·min ⁻¹)	压缩量/(mm)	充气压力/(MPa)	往复速度/(mm·s ⁻¹)	磨粒粒径/(μm)	初始表面粗糙度/(μm)	抛光时长/(min)	最终表面粗糙度/(μm)
1	1000	0.25	0.25	3	5	0.882	4	0.475
2	1125	0.25	0.3	3	2.5	0.884	4	0.402
3	1200	0.2	0.25	4	10	0.894	6	0.372
4	1500	0.25	0.3	3	10	0.88	2	0.592
5	1200	0.3	0.2	4	5	0.835	2	0.542
6	200	0.05	0.05	1	0.1	0.881	18	0.095
7	200	0.05	0.1	1	0.1	0.856	16	0.128
8	400	0.1	0.1	2	0.1	0.862	14	0.155
9	400	0.1	0.15	2	0.1	0.893	14	0.198
10	500	0.15	0.15	2	1	0.846	12	0.251

3. 表面粗糙度和抛光时间的预测模型构建

3.1. 基于 BP 神经网络的表面粗糙度及抛光时间的预测模型

BP 神经网络(Back Propagation, neural network, BP)由于其具有精度高、样本少、计算快等特点是最为经典的一种神经网络结构。考虑到研究的气囊抛光案例中实验提供数据样本比较困难, BP 神经网络可以克服此类困难完成对表面粗糙度及抛光时间的预测模型构建[20] [21] [22]。利用 BP 神经网络构建表面粗糙度及抛光时间的预测模型,需要对算法进行了解和相关过程计算。从结构来看(如图 5),其分为输入层、隐藏层和输出层,其中隐藏层可以含有多个层。BP 神经网络的构建是由数据驱动,因此数据信息需要由输入层进入,经过层层计算最终由输出层输出新的数据信息。整个数据处理过程按传播方向可以分为正向传播和反向传播。正向传播时让数据信息依次从输入层、隐藏层最后到输出层得出结果的过程[23]。每一层的输入均为上一层的输出,依次计算。




Figure 5. BP neural network structure
图 5. BP 神经网络结构

正向传播的计算过程一般表示为:

$$net_i = \sum_{j=0}^n X_j W_j + \theta_i \quad (1)$$

式中: net_i 为第 i 层, n 代表第 i 层全部节点数, X_j 代表输入, W_j 代表权重, θ_i 代表阈值。一般地, 由于初始的权重和阈值是随机的, 每一层的第一次正向传播计算的结果与真实值会有一个很大的差距, 因此需要反向传播计算来调整权重与阈值。

反向传播的基本思路是通过计算输出与层与真实值之间的误差来计算权重与阈值变化梯度, 从而调整权重与阈值, 最终使误差减小。故有:

$$J_i = \frac{1}{2} \sum_{j=1}^p (net_i - net_i^*)^2 \quad (2)$$

式中: J_i 为第 i 层计算误差, net_i^* 为第 i 层真实值数据。

从而得到权重变化梯度为:

$$\frac{\partial J_i}{\partial W_i} = \frac{\partial}{\partial W_i} \left(\frac{1}{2} \sum_{j=1}^p (net_i - net_i^*)^2 \right) \quad (3)$$

阈值变化梯度为:

$$\frac{\partial J_i}{\partial \theta_i} = \frac{\partial}{\partial \theta_i} \left(\frac{1}{2} \sum_{j=1}^p (net_i - net_i^*)^2 \right) \quad (4)$$

通过正向传播与反向传播重复计算迭代, 直到收敛或误差小于规定范围, 则整个 BP 神经网络模型构建完成[24]。

3.2. 模型评价

图 6 为基于 MATLAB 构建 BP 神经网络的精度变化曲线, 从图中可以看出当模型迭代步数在 12 步时, 均方根误差精度可以达到 7.1384×10^{-6} 。图 7 中训练样本的跟踪能力、确认样本跟踪能力、验证样本跟踪能力以及总样本跟踪能力都逼近于 1, 说明模型对样本的跟踪和泛化能力较强。




Figure 6. Accuracy change curve
图 6. 精度变化曲线

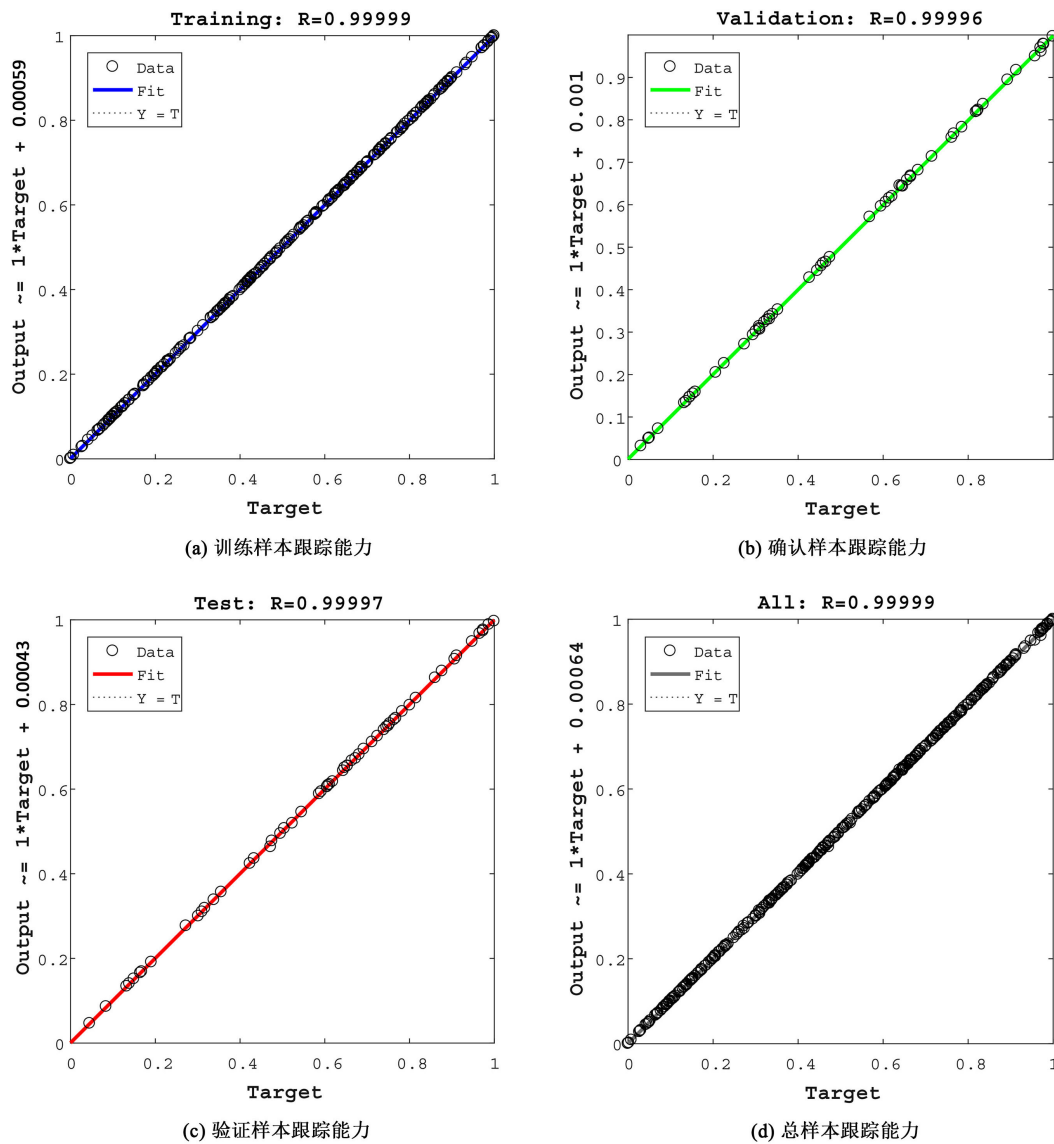


Figure 7. Sample tracking ability of BP neural network model
 图 7. BP 神经网络模型样本跟踪能力

4. 多目标优化算寻优

4.1. NSGA-II 算法

在诸多抛光参数中找到最优的抛光参数，可以在多工序组合中每一工序抛光后的表面粗糙度和所需的抛光时间均为最小，多目标优化就是解决此类问题的重要思想。其中 NSGA-II (non-dominated sorting genetic algorithm-II, NSGA-II) 是一种流行的多目标遗传算法之一，它降低了非劣排序遗传算法的复杂性，具有运行速度快，解集的收敛性好的优点[25]。

多目标优化模型通常包括三个方面：参数变量、约束条件以及目标函数。结合实际抛光效果及工艺参数要求，可以建立如下多目标优化模型：

- 1) 抛光参数变量：气囊头转速 $n/(r \cdot \min^{-1})$ ；压缩量 $\sigma/(mm)$ 充气压力 $\rho/(MPa)$ ；往复速度 $v/(mm \cdot s^{-1})$ ；磨粒粒径 $D/(mm)$ 。

2) 约束条件(抛光参数范围):

粗抛:

$$s.t. \begin{cases} 1000 \leq n \leq 1500 \\ 0.2 \leq \sigma \leq 0.3 \\ 0.2 \leq \rho \leq 0.3 \\ 3 \leq v \leq 4 \\ D \in \{2.5; 5; 10\} \end{cases} \quad (5)$$

精抛:

$$s.t. \begin{cases} 100 \leq n \leq 500 \\ 0.05 \leq \sigma \leq 0.15 \\ 0.05 \leq \rho \leq 0.15 \\ 1 \leq v \leq 2 \\ D \in \{0.1; 1\} \end{cases} \quad (6)$$

3) 目标函数

令基于 BP 神经网络对表面粗糙度及抛光时间的预测模型表达式为:

$$\begin{cases} Ra = f_i(n; \sigma; \rho; v; D) \\ t = g_i(n; \sigma; \rho; v; D) \end{cases} \quad (7)$$

其中: $i = 1, 2$, 分别指粗抛或精抛。

根据多目标优化流程中目标函数的建立准则, 可以使:

$$goal. \begin{cases} \min(f_i(n; \sigma; \rho; v; D)) \\ \min(t = g_i(n; \sigma; \rho; v; D)) \end{cases} \quad (8)$$

4.2. 优化

在求解多目标优化问题时, 由于两个目标相互冲突, 很难使得两个目标同时达到最优。因此 NSGA-II 提出 Pareto 最优解集的概念, 通过定义解的等级得到一系列相对最优解集。同时, NSGA-II 提出非支配排序算法和精英策略, 使算法能够快速准确地寻找到最优个体, 将算法所收集到的各个最优个体集合起来所组成的分布图则为多目标优化的 Pareto 前沿。图 8 为利用 NSGA-II 多目标优化求解最优解的算法流程图, 得到的粗抛多目标优化 Pareto 解前沿如图 9、图 10 所示[26] [27] [28], 图示中的各点均代表一组最优抛光工艺参数组, 通过 pareto 前沿可以分析得到粗抛和精抛的合适参数。

抛光参数优化后得到的 Pareto 解前沿表明粗抛后表面粗糙度数值最低可以达到 $0.23 \mu\text{m}$ 左右, 需要的抛光时长提升至 8 min 左右。因此取最优解集中间部分的解, 使得零件的表面粗糙度和抛光时间都处于中位。基于粗抛优化后的结果进行精抛多目标优化, 可以得到图 10 的精抛多目标寻优 Pareto 前沿。最终得到算法优化后的多工序组合抛光工艺参数如表 3 所示。

4.3. 优化结果

基于所计算出的抛光参数, 所得出的实验结果如图 11~13 所示。从图 11 中看出利用优化后的抛光参数进行抛光, 单工序粗抛或精抛的结果都优于图 4 中的数据结果。同时, 利用预测出的时间作为转换工序的节点而整合出的多工序抛光得到的表面粗糙度低于采用粗抛参数所能达到的表面粗糙度, 而抛光时长低于精抛所需的时长。表面粗糙度由单工序中粗抛后的表面粗糙度 $0.408 \mu\text{m}$, 下降至 $0.081 \mu\text{m}$, 而整

个时长由 16 分钟下降至 12 分钟，缩短的时间占整个时长的 25%。算法结果表明抛光总耗时 12 分钟，12 分钟后表面粗糙度将不会有大的变化，而从曲线图中也得到了证实。

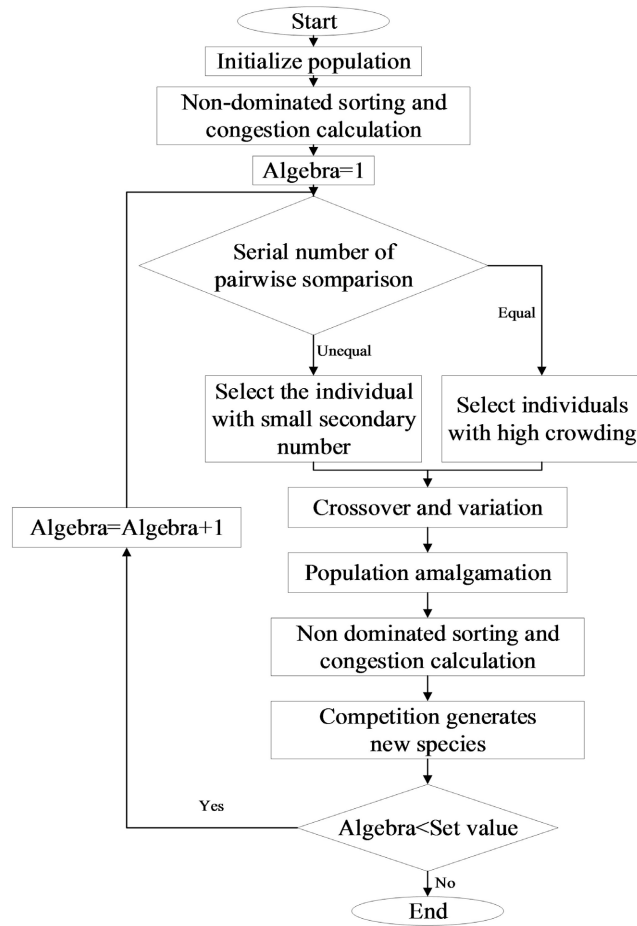


Figure 8. NSGA-II multi objective optimization flow chart
图 8. NSGA-II 多目标优化流程图

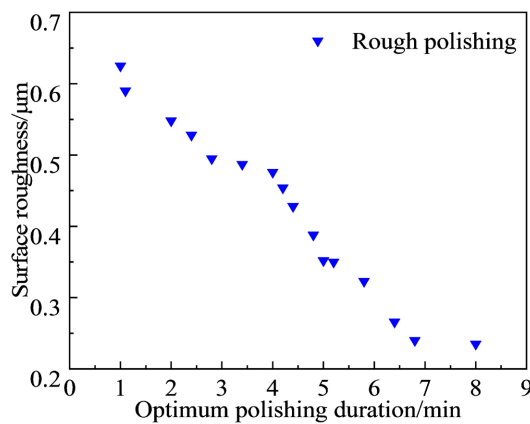


Figure 9. Pareto frontier of rough polishing multi objective optimization
图 9. 粗抛多目标优化 Pareto 解前沿

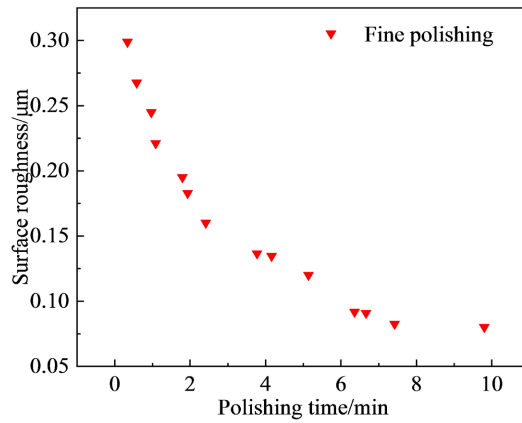


Figure 10. Pareto of frontier of fine polishing multi objective optimization

图 10. 精抛多目标优化 Pareto 前沿

Table 3. Process parameters of multi process combination polishing
表 3. 多工序组合抛光工艺参数表

工序	转速/ ($r \cdot \text{min}^{-1}$)	压缩量/ (mm)	充气压力/ (MPa)	往复速度/ ($\text{mm} \cdot \text{s}^{-1}$)	磨粒粒径/ (μm)	抛光时间/ (min)	表面粗糙度/ (μm)
粗抛	1150	0.2	0.2	3	10	4	0.408
精抛	300	0.1	0.05	1.5	1	8	0.081

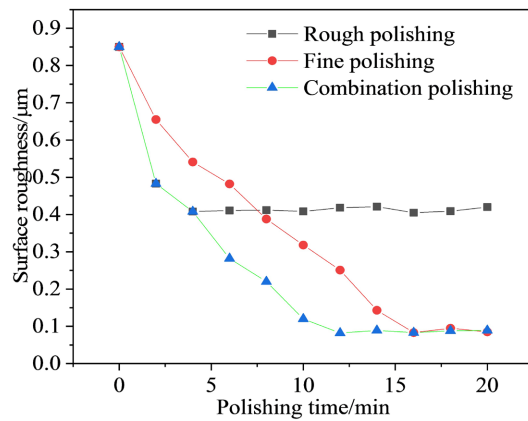


Figure 11. Time varying curve of multi process polishing roughness

图 11. 多工序抛光表面粗糙度随时间变化曲线




Figure 12. Surface roughness curve before and after polishing

图 12. 抛光前后表面粗糙度曲线




Figure 13. Comparison of surface morphology before and after polishing

图 13. 抛光前后表面形貌对比

5. 结论

本文针对进一步提高多工序气囊抛光效率和质量的技术需要,开展了基于智能算法的多工序组合气囊抛光策略优化为目的的研究,得到的结论如下:

1) 通过分析样件在粗抛和精抛的条件下表面粗糙度变化,发现气囊抛光在不同工序下存在加工质量与效率存在矛盾,粗抛的抛光时间较短而得到的粗糙度较大,精抛的结果则与之相反。

2) 通过实验数据训练得出的 BP 神经网络对不同工艺参数下表面粗糙度与抛光时间的预测模型对样本的跟踪和泛化能力较强,且模型的均方根误差在 7.1384×10^{-6} 左右。

3) 通过多目标优化算法优化得出的气囊抛光工艺参数,抛光的结果和效率均优于利用未优化的工艺参数所进行的气囊抛光结果。

4) 通过将优化后的工艺参数整合成的多工序组合抛光,实验结果相比于优化后的单工序精抛所需抛光时间缩短了 25% 的时间,而表面粗糙度相比于优化后的单工序粗抛下降了 $0.314 \mu\text{m}$ 。

5) 利用智能优化方法可以避免通过构建去除函数数学模型优化工艺参数的繁琐,同时能够适应不同的抛光环境和方式所产生的不利影响。该方法相比其他方法,更能适用于各种场合。

参考文献

- [1] 贾平. 中国部分精密仪器与装备发展现状及展望[J]. 科技导报, 2017, 35(11): 39-46.
- [2] 姜晨, 刘剑, 魏久祥, 等. h 形磁性复合流体抛光工具设计及工艺试验[J]. 光学精密工程, 2022, 30(12): 1452-1461.
- [3] 袁巨龙, 张飞虎, 戴一帆, 等. 超精密加工领域科学技术发展研究[J]. 机械工程学报, 2010, 46(15): 161-177.
- [4] 高宏刚, 曹健林, 朱镛, 等. 超光滑表面及其制造技术的发展[J]. 物理, 2000(10): 610-614.
- [5] 高宏刚, 陈斌, 曹健林. 超光滑光学表面加工技术[J]. 光学精密工程, 1995(4): 7-14.
- [6] Liu, D., Shi, Y.Y., Lin, X.J., et al. (2020) Polishing Surface Integrity of TC17 Aeroengine Blades. *Journal of Mechanical Science and Technology*, **34**, 689-699. <https://doi.org/10.1007/s12206-020-0114-7>
- [7] 王瑞芳, 徐方. 机器人研磨抛光工艺研究与实现[J]. 新技术新工艺, 2008(9): 19-22+2.
- [8] 袁巨龙, 王志伟, 文东辉, 吕冰海, 等. 超精密加工现状综述[J]. 机械工程学报, 2007(1): 35-48.
- [9] 周旭升. 大中型非球面计算机控制研抛工艺方法研究[D]: [博士学位论文]. 长沙: 国防科学技术大学, 2007.
- [10] 宋剑锋. 曲面光学零件气囊抛光工艺参数优化及其相关技术研究[D]: [博士学位论文]. 哈尔滨: 哈尔滨工业大学, 2009.
- [11] Hou, Y., Zhao, N. and Dang, L.X. (2022) Solving Multi-Objective School Bus Routing Problem Using an Improved NSGA-II Algorithm. *Engineering Letters*, **30**, 788-796.
- [12] Kruchinin, D., Paramonova, O. and Farafontova, E. (2019) Change of a State of the Optical Parts Surfaces Made of k8 Glass after Polishing Completion. In: *Materials Science Forum*, Trans Tech Publications Ltd., Bäch, 315-319. <https://doi.org/10.4028/www.scientific.net/MSF.946.315>

- [13] Sato, U. and Kawakubo, H. (2021) Influence of Na_2SO_4 -Electrolytic Oxidizing Water on Polishing Surface of Oxygen Free Copper. *Journal of the Japan Society for Precision Engineering*, **87**, 772-778. <https://doi.org/10.2493/jjspe.87.772>
- [14] Peng, Y.F., Shen, B.Y., Wang, Z.Z., et al. (2021) Review on Polishing Technology of Small-Scale Aspheric Optics. *International Journal of Advanced Manufacturing Technology*, **115**, 965-987. <https://doi.org/10.1007/s00170-021-07202-3>
- [15] Wang, P., Gao, R. and Yan, R.Q. (2017) A Deep Learning-Based Approach to Material Removal Rate Prediction in Polishing. *CIRP Annals*, **66**, 429-432. <https://doi.org/10.1016/j.cirp.2017.04.013>
- [16] 潘杰, 陈凡, 杨炜, 等. 基于 SPSO-BP 神经网络的自适应抛光工艺参数匹配[J]. 表面技术, 2022, 51(8): 387-399.
- [17] 郭继通, 郑方志, 徐成宇, 等. 基于遗传算法和神经网络的软脆工件研磨加工工艺智能决策系统[J]. 表面技术, 2020, 49(4): 23-29+46.
- [18] 赵传营, 赵玉刚, 刘宁, 等. 基于神经网络遗传算法的磁粒研磨 TC4 材料工艺参数优化[J]. 表面技术, 2020, 49(2): 316-321.
- [19] 颜晓强, 王晗, 张嘉荣, 等. 小口径非球面小球头接触式抛光及磁流变抛光组合加工[J]. 表面技术, 2022, 51(7): 274-287+323.
- [20] 戚德虎, 康继昌. BP 神经网络的设计[J]. 计算机工程与设计, 1998(2): 47-49.
- [21] 孙志军, 薛磊, 许阳明, 王正. 深度学习研究综述[J]. 计算机应用研究, 2012, 29(8): 2806-2810.
- [22] Schneckenburger, M., Hofler, S., Garcia, L., et al. (2022) Material Removal Predictions in the Robot Glass Polishing Process Using Machine Learning. *SN Applied Sciences*, **4**, Article No. 33. <https://doi.org/10.1007/s42452-021-04916-7>
- [23] 刘彩红. BP 神经网络学习算法的研究[D]: [硕士学位论文]. 重庆: 重庆师范大学, 2008.
- [24] Xiao, G.J., Zhu, B., Zhang, Y.D., et al. (2023) FCSNet: A Quantitative Explanation Method for Surface Scratch Defects during Belt Grinding Based on Deep Learning. *Computers in Industry*, **144**, Article ID: 103793. <https://doi.org/10.1016/j.compind.2022.103793>
- [25] Uday, A.B., Naik, N., Madhu, G.M., et al. (2022) Implementation and Validation of NSGA-II Algorithm for Constrained and Unconstrained Multi-Objective Optimization Problem. 2022 *IEEE IAS Global Conference on Emerging Technologies (GlobConET)*, Arad, 20-22 May 2022, 539-544. <https://doi.org/10.1109/GlobConET53749.2022.9872465>
- [26] Deb, K., Agrawal, S., Pratap, A., et al. (2000) A Fast Elitist Non-Dominated Sorting Genetic Algorithm for Multi-Objective Optimization: NSGA-II. In: Schoenauer, M., et al., Eds., *Parallel Problem Solving from Nature PPSN VI*, Springer, Berlin, 849-858. https://doi.org/10.1007/3-540-45356-3_83
- [27] Deb, K., Pratap, A. and Moitra, S. (2000) Mechanical Component Design for Multiple Objectives Using Elitist Non-Dominated Sorting GA. In: Schoenauer, M., et al., Eds., *Parallel Problem Solving from Nature PPSN VI*, Springer, Berlin, 859-868. https://doi.org/10.1007/3-540-45356-3_84
- [28] 陈小庆, 侯中喜, 郭良民, 等. 基于 NSGA-II 的改进多目标遗传算法[J]. 计算机应用, 2006(10): 2453-2456.