



DOI:10.12404/j.issn.1671-1815.2403169

引用格式:史慧楠,王大勇,于光宁,等.内圆切入磨削不同砂轮磨削性能在线监测方法[J].科学技术与工程,2025,25(9):3687-3697.

Shi Huinan, Wang Dayong, Yu Guangning, et al. Online monitoring method of grinding performance of different grinding wheels in internal circular plunge grinding[J]. Science Technology and Engineering, 2025, 25(9): 3687-3697.

内圆切入磨削不同砂轮磨削性能在线监测方法

史慧楠¹,王大勇¹,于光宁^{1*},迟玉伦²

(1. 中国航发哈尔滨轴承有限公司, 哈尔滨 150027; 2. 上海理工大学机械工程学院, 上海 200093)

摘要 针对不同砂轮磨削性能对内圆切入磨削加工质量具有重要影响,为了实现在线监测内圆磨削加工过程中不同砂轮在相同实验参数条件下进行磨削时的磨削性能,提出了一种基于粒子群优化-反向传播(particle swarm optimization-back propagation, PSO-BP)神经网络的不同砂轮磨削性能监测方法。首先,对采集的声发射信号、功率信号、振动信号、位移信号以及电流信号的特征参数进行特征提取;然后,根据各传感器的特征值数据样本及 PSO-BP 神经网络的全局寻优功能,采用初始权值和阈值,建立了 PSO-BP 在线监测模型对不同砂轮磨削性能进行精准监测;最后,结合实验数据将 BP 神经网络模型与 PSO-BP 模型进行了对比分析。结果表明 PSO-BP 监测模型比 BP 神经网络模型监测精度更高,平均正确率高达 97.6%,并通过大量试验验证了 PSO-BP 神经网络模型的有效性,能够有效监测不同砂轮的磨削性能状态。

关键词 砂轮;磨削性能;多传感器;PSO-BP

中图分类号 TH161; **文献标志码** A

Online Monitoring Method of Grinding Performance of Different Grinding Wheels in Internal Circular Plunge Grinding

SHI Hui-nan¹, WANG Da-yong¹, YU Guang-ning^{1*}, CHI Yu-lun²

(1. AECC Harbin Bearing Co., Ltd., Harbin 150027, China; 2. School of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

[Abstract] The quality of internal plunge grinding process is affected by the grinding performance of different grinding wheels. In order to online monitor the grinding performance of different grinding wheels under the same experimental parameters during the internal grinding process. A particle swarm optimization-back propagation (PSO-BP) neural network-based grinding performance monitoring method for different grinding wheels was proposed. Firstly, the feature parameters of acoustic emission signal, power signal, vibration signal, displacement signal and current signal were extracted. Then, according to the eigenvalue data samples of each sensor and the global optimization function of BP neural network by particle swarm optimization algorithm, the PSO-BP online monitoring model was established by using PSO algorithm to optimize the initial weights and thresholds of BP neural network to accurately monitor the grinding performance of different grinding wheels. Finally, the BP neural network model and the PSO-BP model were analyzed and compared with the experimental data. The results show that the PSO-BP monitoring model has higher monitoring accuracy than the BP neural network model, with an average correct rate as high as 97.6%, and the validity of PSO-BP is verified through a large number of experiments, which is able to effectively monitor the grinding performance status of different grinding wheels.

[Keywords] grinding wheel; grinding performance; multisensor; PSO-BP

由于不同砂轮其磨料、结合剂材料和制造工艺等不同,使得不同砂轮的磨削性能也各不相同,在磨削加工过程中会产生不同程度的弹性变形。因此,在内圆磨削加工中,当砂轮选择不合适时也会直接影响加工精度、工件表面粗糙度以及磨削效率^[1]。然而,在实际的磨削加工过程中,磨削加工

的砂轮型号是根据磨削条件、工件材料以及加工要求等进行选取的,缺少严谨的理论支撑,使得以往根据经验来选取的砂轮其准确性和合理性都不高^[2-3]。因此,需要对不同砂轮的磨削性能在线监测方法进行深入研究,从而能够选择到适合的磨削砂轮,进而获得理想的磨削效率和磨削效果。

收稿日期:2024-04-28 修订日期:2024-12-20

基金项目:国家科技重大专项(J2019-IV-0004-0071)

第一作者:史慧楠(1989—),女,汉族,黑龙江哈尔滨人,硕士,工程师。研究方向:航空轴承加工制造技术。E-mail:shihuinan0930@163.com。

* 通信作者:于光宁(1996—),男,回族,黑龙江齐齐哈尔人,硕士,助理工程师。研究方向:航空轴承加工制造技术。E-mail:583859731@qq.com。

最近几年,许多国内外学者对不同砂轮磨削性能监测方法进行了研究,并取得了一定的成果。梁桂强等^[4]使用电镀金刚砂轮、钎焊金刚砂轮、陶瓷结合剂烧结金刚砂轮和树脂结合剂烧结金刚砂轮来超声振动辅助磨削铝基碳化硅,通过将砂轮磨损、材料去除、磨削表面形貌进行对比分析,给出了磨削砂轮的选择方法。丁宁等^[5]建立了一种基于声发射信号的砂轮磨损监测模型,采用小波分解系数均方值特征提取与反向传播(back propagation, BP)神经网络相结合的方法实现了对砂轮磨损的监测。Leng^[6]针对砂轮磨料选择问题提出一种模糊灰色关系分析方法,该方法影响用三角形模糊数表示的因子(评价属性)值,采用变异系数法来确定评估属性的权重,通过算例分析了所提出方法的有效性和可行性。然而,目前不同砂轮磨削性能监测方法大多数是通过分析砂轮特性参数或者通过检测工件表面粗糙度等来选择合适的砂轮进行加工,仍未有一套智能有效的监测系统来监测不同砂轮的磨削性能。

现主要基于多种传感器信号,提出基于粒子群优化-反向传播(particle swarm optimization-back propagation, PSO-BP)神经网络的不同砂轮磨削性能在线监测方法,通过对位移信号、声发射(acoustic emission, AE)信号和功率信号、电流信号以及振动信号进行特征值提取,构建 PSO-BP 神经网络模型进行学习和训练,实现内圆磨削过程中不同型号砂轮磨削性能在线实时监测,从而为砂轮选型提供准确依据。

1 不同砂轮磨削监测信号的特征提取

为了能够获得不同砂轮在磨削加工过程中较为全面的磨削状态信息,实现在线监测内圆磨削加工过程中不同砂轮在相同实验参数条件下进行磨削时的磨削性能,需要从采集到的传感器信号中找到与砂轮磨削性能相关性较强的特征信息,并对传感器信号进行特征提取,以便为不同砂轮磨削性能监测模型提供准确有效的数据样本。分析砂轮磨削性能与时间常数的关系,介绍多种传感器信号特征和时间常数,并提出了一种基于多传感器信号的不同砂轮磨削性能评估方法。

1.1 内圆磨削砂轮性能与时间常数

内圆磨削采用的砂轮直径较小,砂轮主轴为较细的悬臂梁结构,这就使得其在磨削加工过程中容易发生变形,如图 1(a)所示。内圆磨削系统产生的弹性变形极大地制约了砂轮磨削的进给速度,使得砂轮更易堵塞和钝化,影响磨削工件表面质量。此外,由于砂轮的磨料、结合剂材料以及砂轮的制造工




图 1 内圆切入磨削系统

Fig. 1 Internal plunge grinding system

艺不同,不同砂轮具有不同的切削性能,在磨削加工时产生的弹性变形也各不相同,同样会影响工件的加工精度和表面粗糙度及内圆磨削效率。为了分析磨削过程中弹性变形对磨削工件质量和磨削效率的影响,对内圆切入磨削模型及磨削过程中弹性变形的产生和影响进行深入分析。内圆切入磨削加工的简化模型如图 1(b)所示,可以简化为由砂轮刚度 k_s 、工件刚度 k_w 以及砂轮与工件接触刚度 k_a 共 3 个弹簧系统组成,其中 v_w 为砂轮转速, v_s 为工件转速, \dot{u} 为机床程序设定进给速度^[7-8], a 为进给深度, F_n 为法向磨削力, F_t 为切向磨削力。

该内圆切入磨削模型的系统等效刚度 k_e 可以表示为

$$\frac{1}{k_e} = \frac{1}{k_s} + \frac{1}{k_w} + \frac{1}{k_a} \quad (1)$$


由 Chen 等^[9]的研究结果可知,时间常数 τ 是衡量系统等效刚度 k_e 和磨削力系数 k_c 之间的关系的一个参数。时间常数 τ 表示为

$$\tau = \frac{k_c}{k_e n_w} \quad (2)$$

式(2)表明,时间常数 τ 与系统等效刚度 k_e 、磨削力系数 k_c 以及工件转速 n_w 有关^[10]。如图 2 所示,在 iu 曲线上,弹性变形 iu 达到最大值时的那一点的切线与时间 t 坐标轴有一个交点 M ,该点所对应的时间就是时间常数 τ 。同样,时间常数 τ 也可看作是在 $F_n(t)$ 曲线上, $t=0$ 处的切线与达到稳定状态时的最大值 F_{nmax} 线的交点处的时间,时间常数 τ 是磨削材料去除率模型的一个重要参数。

由式(2)可知,时间常数 τ 与系统等效刚度 k_e 和磨削力系数 k_c 有关。当 k_e 增大时,时间常数 τ 变小;砂轮变钝时,时间常数 τ 增大;进给速度 \dot{u} 增大时,时间常数 τ 减小^[7]。

通过上述对内圆切入磨削模型以及磨削系统弹性变形的产生和影响进行深入分析可知,系统时间常数 τ 的大小与磨削系统刚度、磨削砂轮钝化及磨削表面质量等有很大关系,是磨削工艺参数优化和实现高精度磨削加工的一个关键参数。同时,时间常数 τ 会随着砂轮磨削性能的变化而变化,即时间常数 τ 是表征砂轮的磨削性能状态一个重要参数。因此,可以利用不同传感器信号的时间常数 τ 的变化来研究不同砂轮在磨削加工过程中的磨削性能。



\dot{u} 为实际磨削进给速度; δ 为弹性变形量; f_r 为数控指令进给量

图 2 磨削过程系统模型

Fig. 2 System model of grinding process

1.2 传感器信号特征与时间常数

为了研究不同砂轮在内圆磨削加工过程中的磨削性能,将通过计算内圆磨削加工过程中声发射信号、功率信号、振动信号、电流信号以及位移信号中能够表征砂轮磨削状态的特征参数来分析不同

砂轮在磨削加工中的磨削性能。

1.2.1 声发射信号时间常数

砂轮在磨削加工过程中,磨粒的塑性变形、破碎以及断裂等都会产生声发射信号,能够作为判别砂轮磨削状态的依据。姜晨等^[11]假设 AE 信号与法向磨削力之间呈线性关系,表达式为

$$V_{AE}(t) = k_{ae} F_n(t) \quad (3)$$

式(3)中: $V_{AE}(t)$ 为实时测量磨削 AE 信号 RMS 值; k_{ae} 为实时 AE 信号 RMS 与磨削力 $F_n(t)$ 的比例系数; t 为磨削加工时间。时间常数 τ ^[12] 可以表示为

$$\begin{cases} \tau_{AE} = \frac{V_{AE}}{\dot{V}_{AE}} \left(1 - \frac{\dot{u}_{n-1}}{\dot{u}_n} \right) e^{-1} \\ t - t_{n-1} = \tau, t - t_{n-2} \gg \tau \end{cases} \quad (4)$$

式(4)中: \dot{V}_{AE} 为 AE 信号变化率。

1.2.2 功率信号时间常数

砂轮在磨削加工过程中,电主轴受磨削力影响,会导致功率信号变化,Hecker 等^[13]研究表明功率信号和砂轮磨削切向力之间有很好的线性关系。

1.2.3 振动信号均方差(RMS)

振动信号能够反映磨削加工过程中砂轮磨削工件时的振动频率和振幅,可用于监测磨削加工过程中的振动信息。提取振动信号的 RMS 特征值可用于监测不同砂轮在磨削加工过程中的磨削性能。

1.2.4 位移信号标准差

位移传感器可用于监测砂轮磨削加工过程中工件进给各阶段稳定状态,能够准确区分粗磨、半精磨以及精磨各阶段对应的 AE 信号和功率信号。因此,将提取位移传感器的标准差作为监测不同砂轮在磨削加工过程中的磨削性能的特征参数之一。

1.2.5 电流信号平均值

电流传感器输出的电流信号可用于监测磨削加工过程中的电流变化信息。将提取电流传感器的平均值作为监测不同砂轮在磨削加工过程中的磨削性能的特征参数之一。

上述各传感器信号的特征参数,可以作为不同砂轮磨削性能在线监测模型的输入数据集来对模型进行训练,通过训练好的模型从而能够在线监测不同砂轮在相同磨削工艺参数条件下的磨削性能。

1.3 基于 PSO 优化 BP 神经网络算法的不同砂轮磨削性能评估方法

由于实际内圆磨削加工过程中磨削砂轮和工件都处于高速旋转状态,传统的磨削力传感器无法安装到有效位置,因此很难直接测量磨削加工过程中的磨削力。然而,如声发射传感器、振动传感器等比磨削力传感器方便安装,且还能靠近磨削加工区域足够的距离,同时其信号与砂轮磨削切向力之间有着很好

的线性关系。因此,利用内圆磨削加工中声发射信号、功率信号、振动信号、电流信号以及位移信号来分析不同砂轮在磨削加工中的磨削性能。同时,由于粒子群算法的整体寻优能力和 BP 神经网络的局部寻优能力相结合达到优化 BP 神经网络的目的,从而能够更好地评估不同砂轮在磨削过程中的加工性能。因此,提出了一种基于多传感器信号与粒子群优化 BP 神经网络算法相结合的不同砂轮磨削性能在线监测方法,其具体评估流程如图 3 所示。

由图 3 可知,内圆磨削不同砂轮加工性能在线监测方法主要由传感器信号采集、信号特征提取、模型预测以及预测分类结果 4 个部分组成。首先,利用不同传感器在线监测不同砂轮在内圆磨削加工过程的功率信号、声发射信号、振动信号、电流信号和位移信号,通过数据采集卡将传感器信号进行模数转换后传输到计算机上,利用通过 LabView 软件自行编写的数据采集软件对不同监测信号进行和保存。然后,计算不同砂轮其位移信号的标准差、AE 和功率信号的时间常数、电流信号的平均值以及振动信号的均方根(RMS),将这些特征值数据样本作为 PSO-BP 智能监测模型的输入样本。最后结合实验数据,通过将 BP 神经网络模型与 PSO-BP 模型进行分析对比,表明了 PSO-BP 监测模型比 BP 神经网络模型监测精度更高,实现了对不同砂轮的磨削性能进行在线监测。

2 PSO 优化 BP 神经网络算法模型

为了能够在线实时监测不同砂轮在进行内圆磨削时的磨削性能,保证磨削加工过程中工件磨削质量。利用 PSO-BP 神经网络算法,将上述传感器信号的特征值作为 PSO-BP 模型的输入样本对其进行训练,然后通过训练好的模型来对不同砂轮在磨削加工过程中的磨削性能进行在线监测。

2.1 BP 神经网络算法

采用的不同砂轮磨削性能状态监测网络结构如图 4 所示。用三层 BP 神经网络来对不同砂轮磨削性能进行监测,输入层神经元数一般取 m ,与嵌入维数相同,隐层神经元数多为靠经验选取,这里记为 p ,输出层神经元数为 3。BP 神经网络传递函数采用 Sigmoid 函数,输出为线性单元。

隐层节点的输入为

$$S_j = \sum_{i=1}^m w_{ij} - \theta_j, j = 1, 2, \dots, p \quad (5)$$

式(5)中: w_{ij} 为输入层到隐层的连接权值; θ_j 为隐层节点的阈值。

隐层节点的输出为

$$b_j = \frac{1}{1 + \exp\left(-\sum_{i=1}^m w_{ij}x_i + \theta_j\right)}, j = 1, 2, \dots, p \quad (6)$$




图 3 不同砂轮磨削性能评估方法流程

Fig. 3 Flow chart of different grinding wheel grinding performance evaluation methods

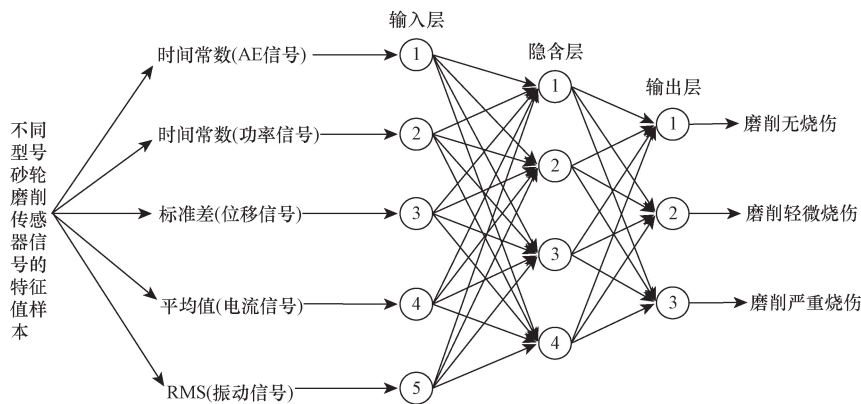


图 4 不同砂轮磨削性能状态监测网络结构

Fig. 4 Network structure of condition monitoring of grinding performance of different grinding wheels

输出层节点的输入为

$$L = \sum_{j=1}^p v_j b_j - \gamma \quad (7)$$

式(7)中: v_j 为隐层到输出层的连接权值; γ 为输出层的阈值。

输出层节点的输出为

$$x_{i+1} = \frac{1}{1 + \exp\left(-\sum_{j=1}^p v_j b_i + \gamma\right)} \quad (8)$$

输入不同砂轮磨削传感器信号的特征值样本训练 BP 神经网络,得到训练好的网络,然后对不同砂轮磨削性能进行监测。但这种 BP 神经网络往往出现收敛速度慢、精度低、预测值与期望值的误差比较大等问题。原因在于 BP 神经网络在不同砂轮的特征值数据样本训练过程中,初始权值和阈值是随机选取的,容易出现局部收敛极小点,从而降低拟合效果。

2.2 PSO 算法

采用 PSO 算法对 BP 神经网络的初始权值和阈值进行优化,优化后的初始权值和阈值能使 BP 神经网络具有更好的收敛速度和更高的预测精度。将粒子群算法的整体寻优能力和 BP 神经网络的局部寻优能力相结合达到优化 BP 神经网络的目的,从而能够更好地监测不同砂轮型号在磨削过程中的性能。

在一个 D 维的搜索空间中,有 n 个粒子组成的种群 $\mathbf{X} = (\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n)$, 其中第 i 个粒子表示为一个 D 维的向量 $\mathbf{X}_i = [x_{i1}, x_{i2}, \dots, x_{iD}]^T$, 代表第 i 个粒子在 D 维搜索空间中的位置,也代表问题的一个潜在解。根据目标函数即可计算出每个粒子位置 \mathbf{X}_i 对应的适应度值。第 i 个粒子的速度为 $\mathbf{V}_i = [V_{i1}, V_{i2}, \dots, V_{iD}]^T$, 其个体极值为 $\mathbf{P}_i = [P_{i1}, P_{i2}, \dots, P_{iD}]^T$, 种群的全局极值为 $\mathbf{P}_g = [P_{g1}, P_{g2}, \dots, P_{gD}]^T$ 。

在每一次迭代过程中,粒子通过个体极值和全局极值更新自身的速度和位置,更新公式如下。

$$\mathbf{V}_{id}^{k+1} = w\mathbf{V}_{id}^k + c_1 r_1 (\mathbf{P}_{id}^k - \mathbf{X}_{id}^k) + c_2 r_2 (\mathbf{P}_{gd}^k - \mathbf{X}_{id}^k) \quad (9)$$

$$w(k) = w_{\text{start}} - (w_{\text{start}} - w_{\text{end}}) \left(\frac{k}{T_{\text{max}}}\right)^2 \quad (10)$$

$$\mathbf{X}_{id}^{k+1} = \mathbf{X}_{id}^k + \mathbf{V}_{id}^{k+1} \quad (11)$$

式中: w 为惯性权重, $d = 1, 2, \dots, D$; $i = 1, 2, \dots, n$; k 为当前迭代次数; \mathbf{V}_{id} 为粒子的速度; w_{start} 和 w_{end} 为惯性权重值; T_{max} 为最大迭代数; c_1 和 c_2 为非负的常数,称为加速度因子; r_1 和 r_2 为分布于 $[0, 1]$ 的随机数。为防止粒子的盲目搜索,一般将其位置和速度限制在一定的区间 $[-\mathbf{X}_{\text{max}}, \mathbf{X}_{\text{max}}]$ 、 $[-\mathbf{V}_{\text{max}}, \mathbf{V}_{\text{max}}]$ 。

通过上述提出的粒子群优化算法来优化 BP 神

经网络。首先对 BP 神经网络和粒子群的参数进行初始化,根据神经网络的结构来确定粒子种群规模的大小。然后将 BP 神经网络的预测误差作为粒子群的适应度函数,计算并比较粒子的适应度值,找到粒子的最优位置。最后通过粒子群算法得到的最优解来优化 BP 神经网络的权值,利用优化后的 BP 神经网络来对不同砂轮磨削性能进行预测。PSO 算法优化 BP 神经网络的流程图如图 5 所示。

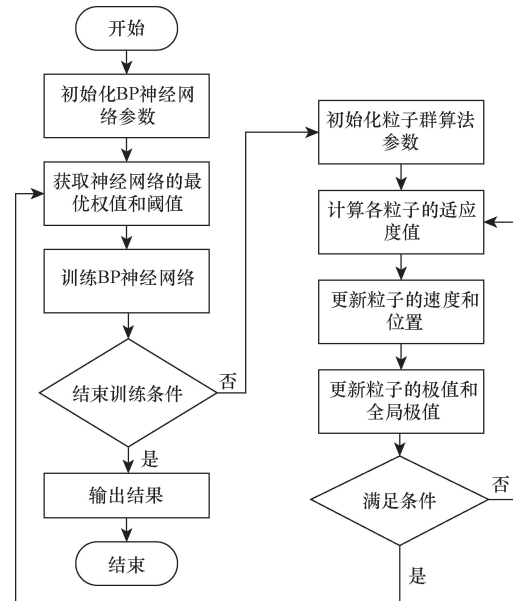


图 5 PSO 优化 BP 流程图

Fig. 5 PSO optimization BP flow chart

3 实验研究

3.1 实验设置

为了验证上述提出的粒子群算法优化 BP 神经网络对不同砂轮在相同磨削工艺参数下的磨削性能评估的可靠准确性,采用机床型号为 M215AMD215A 的内圆磨床,利用电磁无心夹具装夹工件,工件为滚动球轴承外圈,其型号为 91106, 其外直径为 75.2 mm,宽度为 12.5 mm,内直径为 68.5 mm,工件转速为 1 889 mm/s,并采用切入式磨削方法磨削工件,如图 6 所示。选用型号为 3MQS100J、3MQS100K 和 SH/SK100K 的 3 种砂轮在相同实验条件下分别进行磨削加工,3 种型号砂轮的尺寸都为 86 mm × 14 mm × 20 mm,采用金刚滚轮修整,当磨削加工 3 个工件后修整一次砂轮。

实验采用声发射传感器、功率传感器、电流传感器、振动传感器和电涡流位移传感器来监测不同砂轮磨削时的磨削性能,其中功率传感器安装在机床电器柜中用来监测磨削加工中砂轮电主轴功率变化情况,如图 7(a)所示为功率传感器,其型号为





图6 磨削加工现场图
Fig. 6 Grinding site map



(a)功率传感器



(b)电流传感器



(c)AE和振动传感器



(d)电涡流位移传感器

图7 传感器安装图

Fig. 7 Sensor installation diagram

GPW201-V3-A2-F1-P2-03,量程为 50 kW。电流传感器与机床电源相接,安装在机床电器柜位置,其型号为 MIK-DJI,如图 7(b)所示为电流传感器。声发射传感器和振动传感器安装在靠近工件夹具处,采集磨削过程中的声发射信号和振动信号,安装位置如图 7(c)所示,其中声发射传感器的型号以及测量频率范围分别为 AE104S 和 50 ~ 200 kHz,振动传感器型号为 SE920。电涡流位移传感器安装在机床砂轮架进给位置,其型号为 DT3005-S2-M-C1,安装位置如图 7(d)所示。同时,实验采用的数据采集硬件为 NI 公司的采集卡,并结合 WinDaq 软件来采集不同砂轮磨削加工过程中的功率信号、声发射信号、电流信号、振动信号以及位移信号。

基于上述所提出的砂轮性能评估方法和表 1 磨削加工参数,在相同的试验条件下分别采用不同砂轮进行磨削加工。在磨削加工过程中,采用不同砂轮进行磨削加工时,由于不同砂轮的硬度和粒度等都不相同,因此在磨削加工过程中其切削能力不同。而切削能力的大小,会使得磨削加工过程中产生的功率大小不尽相同,从而会导致工件表面产生不同程度的烧伤,此时功率传感器、电流传感器、位移传感器以及声发射传感器监测到不同砂轮磨削加工时所产生的各信号均会发生变化,如图 8 所示。

表 1 磨削加工参数表


Table 1 Grinding parameters table

工序	进给量/mm	进给速度/(mm·s ⁻¹)	加工时间/s
快进	9.84	12 000	0.4
快趋	0.30	0.28	1.0
黑皮磨	0.25	0.07	3.57
粗磨	0.2	0.06	3.33
精磨	0.02	0.01	2.0
光磨	0.01	0.005	2
光延时	0	0	0.5
修整	0.03	0.03	4.8
总计	—	—	19.6


通过信号的变化可以反映加工工件在不同砂轮进行磨削加工时产生的烧伤程度。因此,可以通过上述提出的粒子群算法优化 BP 神经网络模型对不同砂轮磨削过程中的声发射信号、功率信号、电流信号以及位移信号进行分析。

3.2 传感器信号特征参数提取分析


由上述对时间常数 τ 分析可知,时间常数能够间接监测不同砂轮在相同工艺参数条件下的磨削性能。如图 9 和图 10 所示,分别计算了一组型号为 3MQS100J、3MQS100K 和 SH/SK100K 砂轮的功率信号和声发射信号的时间常数 τ ,其中砂轮型号 3MQS100J 的功率信号和声发射信号的时间常数 τ




(a) 3MQS100J 砂轮(磨削无烧伤)



(b) 3MQS100K 砂轮(磨削轻微烧伤)




(c) SH/SK100K 砂轮(磨削严重烧伤)




(d) 最终选取砂轮型号为 3MQS100J

图 8 不同砂轮信号图


Fig. 8 Signal diagram of different grinding wheels



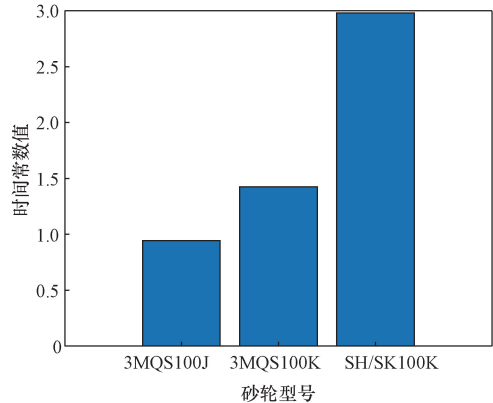
(a) 砂轮型号 3MQS100J 时间常数



(b) 砂轮型号 3MQS100K 时间常数



(c) 砂轮型号 SH/SK100K 时间常数



(d) 不同型号砂轮时间常数值

图 9 不同砂轮型号功率信号时间常数

Fig. 9 Time constant of power signal for different grinding wheel models




图10 不同砂轮型号声发射信号时间常数
Fig. 10 Time constant of acoustic emission signal for different grinding wheel models

分别为0.945 5和0.951 9,砂轮型号3MQS100K的功率信号和声发射信号的时间常数 τ 分别为1.425 3和0.583 3,砂轮型号SH/SK100K的功率信号和声发射信号的时间常数 τ 分别为2.981 5和1.003 2。由此得知,不同砂轮磨削时其磨削性能的变化,使得与之对应的时间常数 τ 的大小也会发生变化。因此,功率信号和声发射信号的时间常数 τ 可以作为粒子群优化BP神经网络模型监测不同砂轮磨削性能的输入训练样本。

为了监测不同砂轮磨削时的磨削性能,需要对不同砂轮在相同磨削工艺参数下进行磨削加工时采集到的声发射信号、功率信号、电流信号、振动信号以及电涡流位移信号进行特征值提取。将型号为3MQS100J、3MQS100K和SH/SK100K的砂轮在磨削加工过程中工件表面产生的不同程度烧伤依次定为磨削无烧伤、磨削轻微烧伤和磨削严重烧伤,且不同的磨削烧伤程度分别赋值为1、2、3,与3种状态一一对应。分别将上述3种砂轮磨削时的声发射信号、功率信号、电流信号、振动信号以及电涡流位移信号进行特征提取,并将各信号特征值作为样本数据。由于不同砂轮磨削时,工件表面产生不同程度烧伤的各传感器信号值有明显的不同,因此选取声发射信号的时间常数、功率信号的时间常数、位移信号的标准差、振动信号的RMS以及电流信号的平均值作为特征值。通过计算得到的特征值如表2~表4和图11所示。

由图11可以看出,各传感器信号的特征参数值在不同砂轮磨削时会呈现一定的变化规律。因此,

表2 3MQS100J型号砂轮的各信号特征参数
Table 2 Signal characteristic parameters of 3MQS100J model grinding wheel

信号 信号	声发射 信号时 间常数	功率信 号时 间常数	位移信号 标准差	电流信号 平均值	振动 信号 RMS
1	0.927 8	0.861 3	1.034 2	2.124 3	1.137 6
2	0.860 3	0.868 7	1.009 5	2.146 1	1.138 0
3	0.724 1	0.964 6	1.050 4	2.147 8	1.137 3
4	0.985 7	0.875 7	1.034 1	2.139 4	1.137 0
5	0.804 6	0.981 5	1.037 4	2.131 6	1.137 4
6	0.726 7	0.968 9	1.052 8	2.134 0	1.137 3
7	0.719 8	0.894 3	1.030 5	2.180 8	1.137 7
8	0.781 4	0.836 1	1.052 7	2.160 6	1.137 3
9	0.939 7	0.953 1	1.037 5	2.120 0	1.137 6
10	0.756 0	0.887 5	1.056 1	2.133 4	1.137 3
11	0.795 2	0.882 5	1.049 1	2.178 5	1.137 5
12	0.980 4	0.963 1	1.049 4	2.152 2	1.137 2
13	0.893 9	0.794 1	1.058 9	2.137 2	1.137 4
14	0.700 9	0.813 8	1.066 4	2.149 6	1.137 5
15	0.951 9	0.945 5	1.050 7	2.116 5	1.137 2

表 3 3MQS100K 型号砂轮的各信号特征参数

Table 3 Signal characteristic parameters of 3MQS100K model grinding wheel

信号	声发射 信号时 间常数	功率信 号时间 常数	位移信号 标准差	电流信号 平均值	振动 信号 RMS
1	0.510 4	1.164 4	1.003 8	2.262 9	1.137 3
2	0.597 4	1.198 8	1.019 4	2.225 7	1.137 4
3	0.574 0	1.276 7	1.016 5	2.213 9	1.137 4
4	0.521 2	1.465 8	1.002 1	2.188 2	1.136 9
5	0.643 4	1.233 8	1.006 9	2.217 9	1.137 5
6	0.660 4	1.339 9	1.002 4	2.205 3	1.137 0
7	0.556 7	1.394 5	1.004 7	2.220 9	1.137 5
8	0.578 1	1.307 4	1.026 9	2.171 3	1.137 3
9	0.574 0	1.436 4	1.027 0	2.217 3	1.137 4
10	0.543 0	1.487 4	1.006 0	2.247 9	1.137 3
11	0.645 2	1.523 5	1.025 3	2.179 4	1.137 6
12	0.645 0	1.497 7	1.019 5	2.200 4	1.137 3
13	0.605 6	1.571 3	1.005 5	2.217 0	1.137 5
14	0.612 7	1.313 4	1.028 2	2.134 3	1.137 6
15	0.583 3	1.425 3	1.030 2	2.200 4	1.137 7

表 4 SH/SK100K 型号砂轮的各信号特征参数

Table 4 Signal characteristic parameters of SH/SK100K model grinding wheel

信号	声发射 信号时 间常数	功率信号 时间常数	位移信号 标准差	电流信号 平均值	振动 信号 RMS
1	0.784 4	1.929 8	0.901 4	2.354 0	1.139 3
2	0.904 3	2.749 5	0.898 2	2.450 1	1.137 6
3	1.125 7	3.296 0	0.926 4	2.441 0	1.137 2
4	1.127 0	3.378 4	0.922 3	2.553 6	1.136 9
5	1.266 8	3.277 6	0.920 1	2.478 7	1.137 0
6	1.247 2	4.271 7	0.943 1	2.612 9	1.138 9
7	1.282 1	3.499 0	0.992 0	2.468 2	1.137 2
8	1.582 8	4.065 0	0.934 8	2.523 2	1.141 9
9	1.128 3	3.610 1	0.944 1	2.552 4	1.140 4
10	1.077 9	3.174 6	0.958 5	2.563 7	1.139 6
11	1.147 1	3.508 8	0.961 8	2.536 7	1.138 5
12	1.172 1	3.048 8	0.963 4	2.508 3	1.138 8
13	1.274 0	3.241 5	0.963 8	2.418 3	1.137 7
14	1.068 9	3.202 0	0.962 8	2.508 9	1.136 9
15	1.003 2	2.981 5	0.961 2	2.410 3	1.141 0

可以将上述计算得到的各传感器信号特征参数值作为 PSO-BP 神经网络模型的输入训练样本,以实现对不同砂轮磨削性能在线监测。

4 模型识别结果分析

通过对砂轮型号为 3MQS100J、3MQS100K 和 SH/SK100K 的各信号进行特征提取后,分别使用 PSO-BP 神经网络模型和 BP 神经网络对不同砂轮进行磨削时工件表面产生的烧伤程度进行预测。将

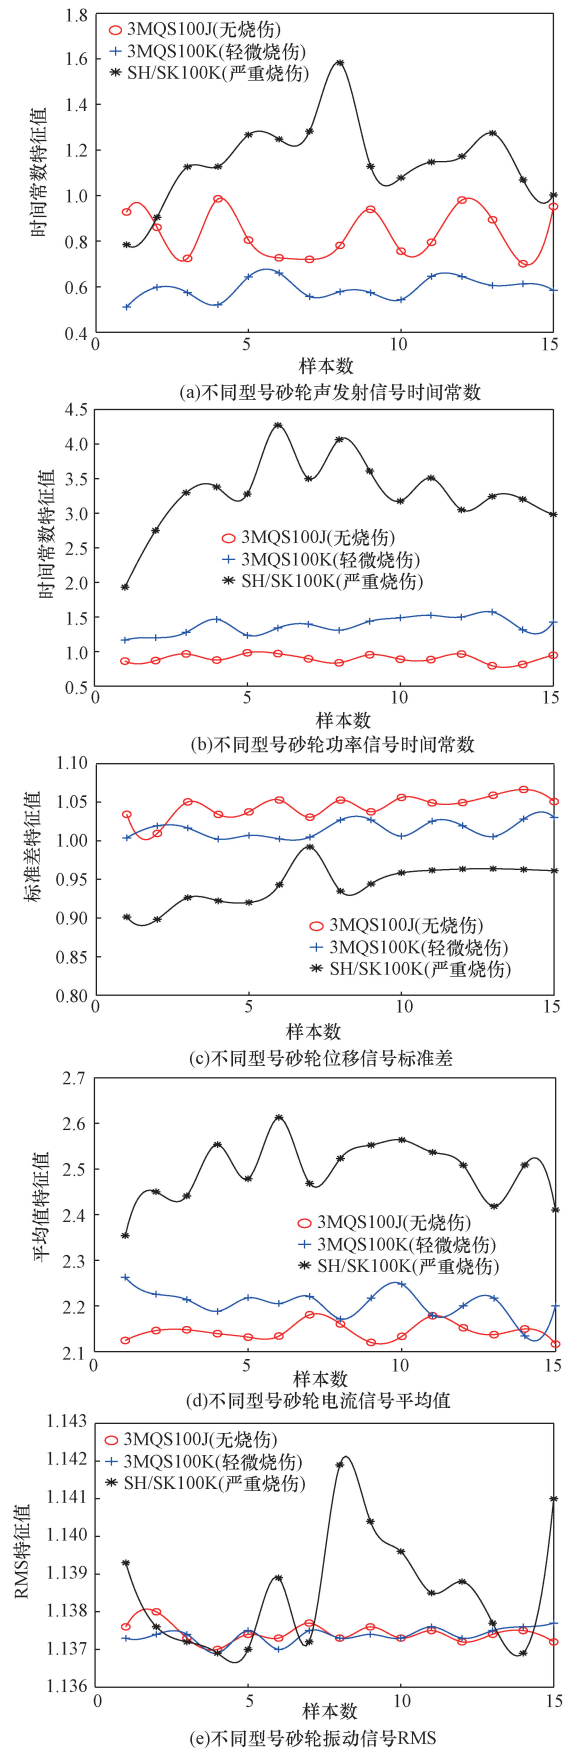


图 11 不同砂轮信号特征值

Fig. 11 Eigenvalues of different grinding wheel signals

上述提取到的 45 组不同砂轮的信号特征值作为训练样本进行学习训练,在样本中,前 15 组是砂轮型号为 3MQS100J 的各信号特征值,即磨削工件为无烧伤状态。中间 15 组是砂轮型号为 3MQS100K 的各信号特征值,即磨削工件为轻微烧伤状态,后 15 组是砂轮型号为 SH/SK100K 的各信号特征值,即磨削工件为严重烧伤状态。将 45 组样本数据作为训练和测试数据代入 PSO-BP 神经网络模型进行分类监测,得到的模型分类结果如图 12(a) 所示。随机选取 45 组特征样本数据中的 30 组作为训练样本,15 组为测试样本,代入到 BP 神经网络模型中学习训练,得到的模型分类结果如图 12(b) 所示。

从图 12 中可知,PSO-BP 神经网络模型和 BP 神经网络模型对不同砂轮磨削时产生的烧伤程度的识别平均准确率分别约为 97.8% 和 86.7%。因此,从实验结果分析上看,PSO-BP 神经网络的识别准确率相比 BP 神经网络来说更高,可以将 PSO-BP 模型的识别结果与实际的不同砂轮磨削时产生的烧伤程度视为相同。但是,为了防止模型单次训练测试结果出现的偶然性,分别对 BP 神经网络模型和 PSO-BP 神经网络模型连续运行 10 次,并计算每次模型监测的准确率,得到结果图 13 所示。





图 12 模型预测结果

Fig. 12 Model prediction results





图 13 模型评估准确率

Fig. 13 Model evaluation accuracy

由图 13 结果可知,PSO-BP 模型监测不同砂轮的磨削性能的平均准确率为 97.6%,而 BP 神经网络模型监测不同砂轮的磨削性能的平均准确率为 86.5%。由此可知,通过粒子群优化算法,能够改善 BP 神经网络在不同砂轮的特征值数据样本训练过程中,初始权值和阈值的随机选取以及容易出现局部收敛极小点的缺陷,从而能够在监测不同砂轮在磨削过程中的性能时准确率更高。因此,可以通过 PSO-BP 神经网络模型实现对不同砂轮的磨削性能进行在线监测,选择出合适的砂轮进行磨削加工,以避免工件表面出现烧伤等问题,从而保证工件表面质量和磨削加工效率。

5 结论

主要研究了内圆磨削加工中不同砂轮磨削性能在线监测方法,基于对多传感器信号的特征参数分析,提出了 PSO-BP 算法模型对内圆磨削加工中在相同实验参数条件下不同砂轮的磨削性能进行在线实时监测,并通过不同砂轮磨削加工实验进行了验证,得到了如下结论。

(1) 基于理论和实验对内圆磨削不同砂轮在相同实验条件下进行磨削时的磨削性能进行研究,通过采集分析声发射信号、功率信号、振动信号、位移信号以及电流信号的特征参数实现对不同砂轮磨削性能的在线监测,从而保证磨削加工工件表面质量达到加工指标。

(2) 根据声发射信号、功率信号、振动信号、位移信号以及电流信号的特点,计算了不同砂轮的位移信号的标准差、AE 和功率信号的时间常数、电流信号的平均值以及振动信号的均方根 (RMS) 来作为监测模型的输入数据样本。

(3) 根据各传感器的特征值数据样本及粒子群优化算法对 BP 神经网络的全局寻优功能,建立了 PSO-BP 在线监测模型对不同砂轮磨削性能进行精准监测。

(4) 通过各传感器信号对不同砂轮磨削性能的研究,并将传感器信号特征值样本代入 BP 神经网络进行监测对比,验证了 PSO-BP 的有效性,其平均监测准确率能高达 97.6%。

参 考 文 献

- [1] 周康康, 曹毅, 徐刚强. 通机凸轮轴凸轮表面磨削振纹分析[J]. 机电信息, 2019(26): 96-97.
Zhou Kangkang, Cao Yi, Xu Gangqiang. Analysis of grinding vibration pattern on cam surface of camshaft of through machine[J]. Mechanical and Electrical Information, 2019(26): 96-97.
- [2] 王奔, 王德林, 郑英晓, 等. 磨削工艺参数对硬质合金刀具磨制损伤的影响[J]. 工具技术, 2024, 58(4): 25-30.
Wang Ben, Wang Delin, Zheng Yingxiao, et al. Influence of grinding process parameter on grinding damage of cemented carbide tools[J]. Tool Engineering, 2024, 58(4): 25-30.
- [3] 黄新春, 史恺宁. GH4169DA 磨削表面完整性控制工艺域优选方法[J]. 科学技术与工程, 2022, 22(25): 10939-10944.
Huang Xinchun, Shi Kaining. Optimization methods of surface integrity control technology region in grinding superalloy GH4169DA[J]. Science Technology and Engineering, 2022, 22(25): 10939-10944.
- [4] 梁桂强, 周晓勤, 赵菲菲, 等. SiC_p/Al 超声振动辅助磨削砂轮选择方法研究[J]. 功能材料, 2016, 47(1): 1255-1258, 1262.
Liang Guiqiang, Zhou Xiaolin, Zhao Feifei, et al. Choosing proper grinding wheel for ultrasonic vibration-assisted grinding SiC_p/Al[J]. Journal of Functional Materials, 2016, 47(1): 1255-1258, 1262.
- [5] 丁宁, 段景淞, 石建, 等. 基于声发射砂轮磨损监测系统的研究[J]. 南京航空航天大学学报, 2020, 52(1): 48-52.
Ding Ning, Duan Jingsong, Shi Jian, et al. Research on grinding wheel wear monitoring system based on acoustic emission[J]. Journal of Nanjing University of Aeronautics and Astronautics, 2020, 52(1): 48-52.
- [6] Leng J H. Grinding wheel abrasive in material selection using fuzzy grey relation analysis method[J]. Advanced Materials Research, 2014, 1022: 18-21.
- [7] 迟玉伦. 基于功率信号的切入式磨削工艺优化关键技术研究[D]. 上海: 上海理工大学, 2016.
Chi Yulun. Study on the key technology of plunge grinding optimization based on power signal[D]. Shanghai: University of Shanghai for Science and Technology, 2016.
- [8] 任敬心, 华定安. 磨削原理[M]. 北京: 电子工业出版社, 2011.
Ren Jingxin, Hua Ding'an. Grinding principle[M]. Beijing: Publishing House of Electronics Industry, 2011.
- [9] Chen X, Rowe W B, Mills B, et al. Analysis and simulation of the grinding process. Part III: Comparison with experiment[J]. International Journal of Machine Tools and Manufacture, 1996, 36(8): 897-906.
- [10] 刘涛, 邓朝晖, 罗程耀, 等. 基于动态磨削深度的非圆轮廓高速磨削稳定性建模与分析[J]. 机械工程学报, 2021, 57(15): 264-274.
Liu Tao, Deng Zhaohui, Luo Chengyao, et al. Stability modeling and analysis of non-circular high-speed grinding with consideration of dynamic grinding depth[J]. Journal of Mechanical Engineering, 2021, 57(15): 264-274.
- [11] 姜晨, 李郝林. 基于声发射信号的精密外圆切入磨削时间评估算法及试验研究[J]. 机械工程学报, 2014, 50(5): 194-200.
Jiang Chen, Li Haolin. Algorithm and experiment of estimation of time of precision cylindrical plunge grinding based on acoustic emission signal[J]. Journal of Mechanical Engineering, 2014, 50(5): 194-200.
- [12] Chi Y L, Gu J J, Li H L. Grinding wheel wear monitoring based on the time constant and support vector machine[J]. Journal of the Chinese Society of Mechanical Engineers, 2019, 40(4): 341-353.
- [13] Hecker R L, Liang S Y, Wu X J, et al. Grinding force and power modeling based on chip thickness analysis[J]. The International Journal of Advanced Manufacturing Technology, 2007, 33(5/6): 449-459.