

引用格式: 龚子维, 刘希强, 张仲宁, 等. 基于 VMD-PNN 的砂轮钝化声发射检测[J]. 声学技术, 2021, 40(2): 260-268. [GONG Ziwei, LIU Xiqiang, ZHANG Zhongning, et al. Acoustic emission detection of blunting states of grinding wheel based on VMD-PNN[J]. Technical Acoustics, 2021, 40(2): 260-268.] DOI: 10.16300/j.cnki.1000-3630.2021.02.018

基于 VMD-PNN 的砂轮钝化声发射检测

龚子维^{1,2}, 刘希强^{1,2}, 张仲宁^{1,2}, 杨京^{1,2}, 程建春^{1,2}, 刘翔雄³

(1. 南京大学声学研究所, 江苏南京 210093; 2. 人工微结构科学与技术协同创新中心, 江苏南京 210093;

3. 华辰精密装备(昆山)股份有限公司, 江苏昆山 215337)

摘要: 在磨削加工过程中, 加工刀具即砂轮会发生钝化现象, 砂轮表面磨损影响加工精度和工件质量, 需要及时检测并修整。磨粒的塑性变形、破碎、断裂等会产生声发射信号, 能够作为精确识别砂轮钝化状态的依据, 且不易被噪声干扰, 因此提出一种基于变分模态分解(Variational Mode Decomposition, VMD)和概率神经网络(Probabilistic Neural Network, PNN)的砂轮钝化声发射检测方法。VMD 可以将原始信号分解为多个本征模态函数(Intrinsic Mode Function, IMF)分量, 筛选其中峭度较大的分量重构即得到声发射信号。声发射检测的关键是特征参数的选取, 在相关研究基础上本文提出了声发射包络能量占比作为一个重要的特征参数, 并选取了共 5 种特征参数, 构建出 5 维特征向量数据集, 输入到 PNN 中进行训练, 经过测试识别准确度达到 94.5%。该方法建立了声发射信号特征参数与砂轮不同钝化状态的关系, 能够对砂轮严重钝化状态给出准确预警, 具有实际应用价值。文章比较了声发射信号不同特征参数用于识别砂轮钝化状态的准确度, 对特征参数的选用具有参考意义。

关键词: 砂轮钝化; 声发射; 变分模态分解(VMD); 概率神经网络(PNN)

中图分类号: O426.9

文献标志码: A

文章编号: 1000-3630(2021)-02-0260-09

Acoustic emission detection of blunting states of grinding wheel based on VMD-PNN

GONG Ziwei^{1,2}, LIU Xiqiang^{1,2}, ZHANG Zhongning^{1,2}, YANG Jing^{1,2},
CHENG Jianchun^{1,2}, LIU Xiangxiong³

(1. Institute of Acoustic, Nanjing University, Nanjing 210093, Jiangsu, China; 2. Collaborative Innovation Center of Advanced Microstructures, Nanjing 210093, Jiangsu, China; 3. Huachen Precision Equipment (Kunshan) Co., Ltd., Kunshan 215337, Jiangsu, China)

Abstract: During the grinding process, the blunting phenomenon occurs on the processing tool, i.e. the grinding wheel. The wear of the grinding wheel surface affects the machining accuracy and the quality of the workpiece, and it needs to be detected and repaired in time. The plastic deformation, fragmentation, and fracture of the abrasive particles will generate acoustic emission (AE) signals, which can be used as a basis identifying the blunting states of the grinding wheel, and it is not easy to be disturbed by noise. Therefore, an AE detection method of grinding wheel blunting states based on variational mode decomposition (VMD) and probabilistic neural network (PNN) is proposed. VMD can decompose the original signal into multiple intrinsic mode function (IMF) components, and filter out the components with larger kurtosis to reconstruct AE signal. The key to AE detection is the selection of characteristic parameters. Based on the related researches, the proportion of envelope energy is presented as an important characteristic parameter, and a total of 5 characteristic parameters are selected to construct a five-dimensional characteristic vector dataset and input to PNN for training. After testing, the recognition accuracy reaches 94.5%. This method establishes the relationship between the characteristic parameters of AE signal and the different blunting states of grinding wheel, which can accurately predict the severe blunting state of grinding wheel and has practical application value. Moreover, the accuracies using different characteristic parameters of AE signals to identify the blunting states of grinding wheel are compared in this paper, which has reference significance for the selection of characteristic parameters.

Key words: grinding wheel blunting; acoustic emission; variational mode decomposition (VMD); probabilistic neural network (PNN)

收稿日期: 2020-03-09; 修回日期: 2020-03-26

基金项目: 国家自然科学基金项目(11374157)。

作者简介: 龚子维(1995—), 男, 安徽芜湖人, 硕士研究生, 研究方向为声发射检测信号处理。

通信作者: 杨京, E-mail: yangj@nju.edu.cn

0 引 言

声发射(Acoustic Emission, AE)是指材料受到外力或者内力作用, 发生塑性变形或断裂, 以瞬态

弹性波的形式释放应变能的现象^[1-2]。利用声发射检测磨削加工过程中砂轮的钝化状态, 相比于其他间接检测方法具有环境噪声易分离、可选特征参数较多, 灵敏度高、响应速度快等特点^[3], 近年来声发射检测在刀具钝化状态检测中得到广泛应用。文献[4]研究了单磨粒模型中磨粒磨损过程及声发射产生机理; 文献[5]建立了砂轮磨削的简化理论模型, 推导出塑性功率与剪切力、接触面积以及切入深度等加工参数的关系, 声发射能量大小与砂轮钝化存在相关性。

与其他刀具类似, 砂轮钝化程度随磨削时间推移而增加, 文献[6-7]分别用加工材料单位去除量所需时间或能量来表示砂轮钝化程度, 加工过程中砂轮从修整结束到下一次修整之前可以分为初期钝化、中期钝化和严重钝化三个钝化阶段。初期钝化阶段砂轮刚经过修整, 磨粒较为锋利, 发生的变化以磨粒破碎为主, 这种钝化会产生新的切削刃, 即“自锐现象”, 对磨削能力影响较小; 在中期钝化阶段, 磨粒发生塑性变形, 表面逐渐磨平, 与加工材料接触面积增大, 砂轮钝化程度平稳上升; 到了严重钝化阶段, 更多磨粒开始出现断裂、脱落, 砂轮加速钝化, 需要及时修整^[6]。图1为磨削过程中砂轮钝化程度变化曲线。




图1 砂轮磨削钝化曲线
Fig.1 Grinding wheel blunting curve

利用声发射信号来检测砂轮的钝化状态, 首先需要对采集到的原始信号进行去噪处理, 声发射信号的频率主要分布在 100~500 kHz, 其他为低频的摩擦噪声和较高频的电气噪声。目前主要采用的信号处理方法包括小波变换(Wavelet Transform, WT)、经验模态分解(Empirical Mode Decomposition, EMD)等。WT 方法利用窗函数平移将原信号分解成若干小波分量, 这种方法需根据信号特点选定小波基, 易产生异常谐波。EMD 方法属于递归分解, 根据信号本身的特点将一段信号分解成一组本征模态函数(Intrinsic Mode Function, IMF), 适用于非线性、非平稳信号。针对 EMD 方法易产生包络线

误差累积、模态混淆及端点效应等问题, Dragomiretskiy 等^[8]提出变分模态分解(Variational Mode Decomposition, VMD), 该方法具有完备的数学理论基础, 克服了小波分解需定义小波基的问题, 通过求解约束变分模型将信号分解为指定数量的本征模态分量, 能够避免端点效应、抑制模态混叠, 且分解较为彻底。

对分解后的分量进行筛选并重构得到声发射信号后, 还需要提取声发射信号中能够表征砂轮钝化状态的特征参数。为探究砂轮钝化程度和声发射信号特征参数的关系, 文献[9]通过实验将声发射的振铃计数和均方根值(Root Mean Square, RMS)两个特征参数与砂轮钝化状态联系起来; 文献[10]提取声发射 RMS 信号, 利用声发射频域信号频谱矩心特征参数来表征砂轮钝化状态; 文献[11]证明 RMS 和能量计数两个统计数据含有砂轮表面状态的重要信息; 文献[12]将功率比(Ratio of Power, RoP)引入砂轮磨损评估中; 文献[13]提取了声发射信号的幅度、振铃计数、能量计数等八个特征参数构建训练集对砂轮钝化状态进行识别。以上方法基本实现了对砂轮钝化状态的识别, 但均未对不同特征参数的作用进行量化比较, 没有系统性衡量声发射信号多种特征参数对砂轮钝化状态的识别效果。

特征参数与砂轮钝化状态的具体对应关系数学模型目前较难建立, 国内外相关研究通过训练神经网络来识别砂轮钝化状态, 而声发射信号本身存在一定的波动, 会影响识别的准确性。概率神经网络(Probabilistic Neural Network, PNN)利用密度函数估计方法输出识别结果, 对于非线性数据也能保持较高精度, 适用于处理非线性、非平稳的磨削声发射信号。

综合以上因素, 本文提出一种基于 VMD-PNN 进行声发射信号处理和砂轮钝化状态识别的方法。利用 VMD 快速精确地得到声发射信号, 选取典型特征参数构建多维特征向量数据集, 通过 PNN 网络建立磨削声发射信号与砂轮钝化状态的关系。经过测试, 该方法可以较为准确识别砂轮钝化状态, 并能横向对比不同特征参数的检测效果。

1 方法理论

1.1 变分模态分解(VMD)

VMD 算法基于维纳(Wiener)滤波和希尔伯特(Hilbert)变换方法, 能够将信号自适应分解为 k 个稀疏的本征模态函数(IMF), 第 k 个本征模态函数表

示为

$$u_k(t) = A_k(t) \cos \omega_k(t) \quad (1)$$

式中: $u_k(t)$ 为具有假设的中心频率 $\omega_k(t)$ 和有限带宽的调频调幅信号, $A_k(t)$ 为包络, $\varphi_k(t)$ 的时间导数 $\varphi'_k(t) = d\varphi_k(t)/dt$ 为瞬时频率, 需要构建目标函数求解第 1 到 k 个模态函数 $\{u_k(t)\} = \{u_1(t), u_2(t), \dots, u_k(t)\}$ 和中心频率 $\{\omega_k(t)\} = \{\omega_1(t), \omega_2(t), \dots, \omega_k(t)\}$ 。

首先对模态函数 $u_k(t)$ 进行 Hilbert 变换, 计算与每个模态相关的解析信号, 得到 $u_k(t)$ 的单边频谱 s_k :

$$s_k = \left[\delta(t) + \frac{j}{\pi t} \right] * u_k(t) \quad (2)$$

式中: $\delta(t)$ 为冲激函数, $*$ 为卷积运算。修正各自估计的中心频率, 将每一个模态的频谱调制到其相应的基频上, 获得 $u_k(t)$ 转换到基带的单边频谱 s'_k :

$$s'_k = \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \quad (3)$$

接着估计各模态分量的带宽, 计算梯度的平方 L2 范数, 得到约束变分模型:

$$\begin{aligned} \min_{\{u_k\}, \{\omega_k\}} & \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\}, \\ \text{s.t.} & \sum_{k=1}^K u_k = f \end{aligned} \quad (4)$$

限制条件为所有模态之和为原信号 f 。求解式(4)的约束变分问题, 引入惩罚因子 α 和拉格朗日 (Lagrange) 乘法算子 λ 。

增广 Lagrange 函数为

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \\ & + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \end{aligned} \quad (5)$$

K 为分解层数, 然后利用交替方向乘法算子算法 (Alternate Direction Method of Multipliers, ADMM) 求解式(5)的最优解, 在频域内迭代更新 u_k 、 ω_k 和 λ 。

u_k 和 ω_k 和 λ 的迭代公式分别为

$$u_k^{n+1}(\omega) = \frac{f(\omega) - \sum_{i=1, i \neq k}^K u_i(\omega) + \frac{\lambda(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (6)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |u_k(\omega)|^2 d\omega}{\int_0^\infty |u_k(\omega)|^2 d\omega} \quad (7)$$

$$\lambda^{n+1}(\omega) = \lambda^n(\omega) + \tau \left[f(\omega) - \sum_{k=1}^K u_k^{n+1}(\omega) \right] \quad (8)$$

最后重复式(6)~(8), 直到满足式(9)中的终止条件, 并输出最后结果。

$$\sum_{k=1}^K \left(\frac{\|u_k^{n+1} - u_k^n\|_2^2}{\|u_k^n\|_2^2} \right) < \varepsilon \quad (9)$$

式中: ε 为设定的终止参数。

1.2 声发射特征参数选取

声发射信号是有许多声发射事件 (AE Hit) 组成的, 从波形首次越过门限值开始, 直到落回门限值以下并且一段时间内 (该时间设置为撞击定义时间) 不再升到门限值以上, 定义为一次 AE Hit。一个典型的 AE Hit 波形如图 2 所示。




图 2 典型声发射信号波形图

Fig.2 Waveform of typical acoustic emission signal

对于每次 AE Hit, 有多种常用特征参数来进行描述。幅度 (Amplitude) 指 AE Hit 达到的最大振幅; 持续时间 (Duration) 指一次 AE Hit 从开始到结束的间隔; 振铃计数 (ring-down counts, 记为 C), 表示一次 AE hit 越过门限的震荡次数; 能量计数 (S_E), 表示一个 AE hit 的波形包络面积; 均方根值 (RMS), 指的是 AE hit 信号幅度的均方根值, 表达式为

$$R_{MS} = \sqrt{\frac{1}{t_2 - t_1} \int_{t_1}^{t_2} u^2(t) dt} \quad (10)$$

式中: $u(t)$ 为信号幅度, 以上特征参数都应用于描述单次 AE Hit, 在一段声发射信号中, 需计算所有 AE Hit 对应特征参数并求均值作为该段声发射信号的特征参数, 因此这些特征参数不能衡量 AE Hit 的密度和声发射信号整体状况。

文献[14]提出一种通过功率比来评价声发射信号的特征量, 声发射功率比:

$$R_p = \frac{\sum_{k=N_1}^{N_2} |X_k|^2}{\sum_{k=0}^{N-1} |X_k|^2} = \frac{\sum_n x_{AE}^2(t)}{\sum_n x^2(t)} \quad (11)$$

式(11)是 R_p 频域和时域两种表示方法, N_1 和 N_2 为声发射的频率范围, 在本文中 R_p 含义为声发射信号功率与原始信号功率之比。 R_p 可以排除信号随时间变化引起的功率值整体波动影响, 适用于衡量声发射信号在时域的变化规律。

参考能量计数的定义原理, 用希尔伯特变换对

信号求包络, 在一段信号中, 声发射分量包络能量和原始信号包络能量的比值定义为声发射包络能量比 R_{EE} :

$$R_{EE} = \frac{\sum_{n=1}^{n_2} H[x(t)]}{\sum_{k=0}^{N-1} H[x(t)]} = \frac{\sum_n H[x_{AE}(t)]}{\sum_n H[x(t)]} \quad (12)$$

式中: $x_{AE}(t)$ 是信号 $x(t)$ 经过分解后的声发射分量, $H[x(t)]$ 是信号的希尔伯特变换。

$$H[x(t)] = -\frac{1}{\pi} \int_{-\infty}^{\infty} \frac{x(\tau)}{t-\tau} d\tau \quad (13)$$

R_{EE} 含义为声发射信号能量占比, 这里的声发射能量是一种结合声发射信号特征定义的包络能量, 含义为信号检波包络线下的面积, 量纲为 $mV \cdot ms$, 与物理意义上的能量不同。

特征参数选取是声发射检测的重要环节, 以上声发射特征参数可以分为两类, 一类是对单次 AE hit 进行评价, 分别从信号电平、时间和包络能量(电平 $\times$ 时间)三个维度进行衡量, 在计算时需对一段信号所有 AE hit 分别计算并求平均值; 另一类为声发射信号与原始信号的功率或包络能量比值, 是对声发射信号进行整体衡量, 上文所提到的声发射特征参数分类如表 1 所示。其中幅度和持续时间易受异常声发射事件影响, 波动较大, 结合此前相关研究基础, 本文选取 C 、 S_E 、 R_{MS} 、 R_p 和 R_{EE} 作为砂轮钝化状态识别参考特征参数。

表 1 声发射特征参数分类

Table 1 Classification of AE characteristic parameters

评价维度	特征参数	评价维度	特征参数
AE hit 电平	幅度 R_{MS}	AE hit 能量	能量计数 S_E
AE hit 时间	持续时间 C	声发射信号整体	R_p 、 R_{EE}

1.3 概率神经网络(PNN)

概率神经网络是一种建立在径向基(Radial Basis Function, RBF)网络的基础上, 基于贝叶斯决策理论, 结合密度函数估计方法的神经网络^[15]。概率神经网络的结构如图 3 所示。

结构共分为四层, 第一层为输入层, 接收训练数据集的值, 神经元个数与输入向量长度相等, 并




图3 PNN神经网络结构

Fig.3 PNN neural network structure

传递给第二层。第二层是隐含层, 该层接收输入层的数据, 并计算输入向量与中心的距离, 输出一个标量, 第 i 类模式的第 j 神经元的输入输出关系为

$$\phi_{ij}(x) = \frac{1}{(2\pi)^{\frac{1}{2}} \delta^n} \exp \left[-\frac{(x-x_{ij})(x-x_{ij})^T}{2\delta^2} \right] \quad (14)$$

式中: $(x-x_{ij})^T$ 为 $(x-x_{ij})$ 的转置, δ 为平滑因子, 可以调节样本分类的精确度, 一般设定在 0~1 之间。第三层是求和层, 把隐含层已经分到不同类别神经元连接起来, 累加结果输入到输出层。最后一层为输出层, 具有判决功能, 输出离散值, 代表各种模式的类别。概率神经网络相比传统 BP 神经网络不会产生反向误差传递, 容错性强, 学习过程收敛速度快。

2 实验与结果分析

2.1 实验系统搭建

搭建声发射检测及砂轮钝化状态识别实验系统, 包括三个组成模块, 如图 4 所示。




图4 声发射检测实验系统

Fig.4 Experimental system for acoustic emission detection

砂轮选用 36 粒绿色碳化硅砂轮, 线速度为 $42 m \cdot s^{-1}$, 进刀量为 $0.03 mm$; 加工工件为合金铸钢; 传感器为全接触式 AE 传感器, 固介灵敏度较高, 固定在磨床砂轮外壳上, 响应范围为 $0 \sim 3 MHz$; AE 传感器接收到的信号由安捷伦 u2331 数据采集设备采集, 存储为二进制文件, 再通过计算机进行信号分析处理。

2.2 VMD 参数设定

信号处理的关键是利用 VMD 方法对原始信号进行分解得到声发射信号, VMD 有两个重要参数 α 和 K , α 是惩罚因子, 决定分解出每个分量的带宽限制, 通常取默认值 2000; 分解层数 K 的确定方法有多种, 这里采取峭度判别法。相比于噪声信号, 声发射信号波形陡峭, 峭度值较大。逐步增大 K , 观察每个分量的波形和峭度, 直到出现峭度值较小的非声发射分量为止, 此时分解层数为适宜的 K 值,

取其中峭度较大的分量重构，即得到声发射信号。
VMD 各模态的中心频率及峭度分布如表 2、3 所示。
VMD 5 层分解的 IMF 波形及频谱图如图 5 所示。

从表 2、表 3 及图 5 观察到，随着分解层数 K 的增大，各分量的中心频率基本保持不变，在分解层数达到 5 时出现中心频率大于 1 000 kHz 而峭度较低的电气噪声分量，故分解层数 K 定为 5，并判

表 2 VMD 分解各模态中心频率分布表


Table 2 Modal center frequencies of VMD decomposition

K	中心频率/kHz				
	IMF 1	IMF 2	IMF 3	IMF 4	IMF 5
2	3.669	143.3	—	—	—
3	3.667	141.5	322.3	—	—
4	3.666	141.3	316.4	484.1	—
5	3.666	141.3	316.3	484.0	1 436


表 3 VMD 分解各模态峭度分布表

Table 3 Modal kurtosis distribution of VMD decomposition


K	峭度				
	IMF 1	IMF 2	IMF 3	IMF 4	IMF 5
2	2.709	437.2	—	—	—
3	2.709	423.5	534.7	—	—
4	2.709	422.3	498.2	538.7	—
5	2.709	422.2	498.1	538.4	34.70




(a) IMF1 波形




(b) IMF2 波形




(c) IMF3 波形




(d) IMF4 波形




(e) IMF5 波形




(f) IMF1 的频谱




(g) IMF2 的频谱



(h) IMF3 的频谱



(i) IMF4 的频谱



(j) IMF5 的频谱


图 5 VMD 5 层分解 IMF 波形图及频谱图

Fig.5 IMF waveforms and spectrums of 5 layer VMD decomposition

断 IMF2、IMF3 和 IMF4 是声发射信号分量，将这三个分量重构即得到所需的声发射信号。

读取三段已标记砂轮钝化状态的信号数据波形文件并进行 5 层 VMD 分解，取 IMF2、IMF3 和 IMF4 进行重构，观察不同砂轮钝化状态下原始信号和声发射信号波形。图 6~8 分别为初期钝化、中期钝化、严重钝化三个阶段的原始信号和 VMD 分解后重构的声发射信号波形图及对应频谱。

可以看出，磨削加工过程中砂轮处于初期钝化阶段时，声发射事件强度较弱，分布稀疏，20 kHz



(a) 原始信号波形




图6 初期钝化原始信号与声发射信号波形及频谱图
Fig.6 The waveforms and spectrums of the original and the VMD reconstructed AE signals in initial blunting state




图7 中期钝化原始信号与声发射信号波形及频谱图
Fig.7 The waveforms and spectrums of the original and the VMD reconstructed AE signals in intermediate blunting state




图8 严重钝化原始信号与声发射信号波形及频谱图
Fig.8 The waveforms and spectrums of the original and the VMD reconstructed AE signals in severe blunting state

以上频段幅值较小;砂轮进入中期钝化阶段以及严重钝化阶段,单次声发射事件强度增大,声发射信号频谱幅值增大,故单位时间内声发射信号与原始信号的能量比也大幅增加。

2.3 数据集训练与识别结果分析

信号处理模块的全过程如图 9 所示,取磨削过程中已明确砂轮钝化状态的初期钝化信号 40 s,中期钝化信号 40 s,严重钝化信号 20 s。对信号分别进行分帧处理,以 0.1 s 为一帧,对每帧信号进行 VMD 分解、重构,得到 1 000 帧声发射信号。设定门限值为 300 mV,计算每帧声发射信号所有正常声发射事件的 C 、 S_E 、 R_{MS} ,并在一帧内求平均值得到平均 C 、平均 S_E 、平均 R_{MS} 、对每帧声发射信号进行整体计算得到 R_p 和 R_{EE} ,共五个特征参数,构建一组多维特征向量数据集作为训练集,将训练集作归一化处理输入 PNN 网络中训练。图 9 中将 C 、 S_E 、 R_{MS} 、 R_p 、 R_{EE} 5 个特征参数分别标注为①,②,③,④,⑤。




图 9 多维特征向量数据集的构建过程
Fig.9 Construction process of multi-dimensional characteristic vector dataset

改变信号分帧的起始位置,将训练集每帧信号后移 0.05 s,帧长依然为 0.1 s,得到的数据集与训练集是同一段信号因不同分帧方法所得,因此被认为是独立同分布的。将该数据集作为测试集,随机取三种状态各 80、80、40 帧,共 200 帧进行测试。


测试结果用混淆矩阵表达,如图 10 所示,初期钝化状态、中期钝化状态和严重钝化状态分别被标记为类别 1、2 和 3。同时利用五种特征进行训练和测试,整体识别准确率为 94.5%,多次重复测试集取样过程,平均准确率维持在 94%以上,且严重钝化状态对应的数据均能被正确判定为严重钝化。可以认为该神经网络经过训练后能够根据特征参数对砂轮钝化状态进行识别,并对严重钝化状态作出准确预警。

为评估该神经网络的泛用性,取另一段加工材料为合金锻钢支承辊的 400 s 连续磨削加工信号,


输出类	1	78 97.5%	4 5.0%	0 0.0%
	2	2 2.5%	71 88.8%	0 0.0%
	3	0 0.0%	5 6.2%	40 100.0%
		1	2	3
		目标类		

图 10 混淆矩阵,砂轮钝化识别结果
Fig.10 Confusion matrix and the identification result of grinding wheel blunting state


设定帧长为 0.1 s,帧移为 1 s,即用每 1 s 信号中间 0.1 s 的特征参数来表征这 1 s 的砂轮状态。得到该段连续磨削加工信号的数据集作为连续信号数据集,图 11 为该数据集的五维特征参数变化图。对连续信号数据集作归一化处理并输入已通过此前训练集训练好的 PNN 网络,得到识别结果如图 12 所示。连续信号数据集被清晰分成了三种钝化状态,不同颜色代表不同钝化状态,且随时间推移存在阶段性变化。在两个钝化状态之间存在短暂的过渡态,根据加工要求和材料特点,当连续若干帧信号有一定帧数信号被识别为严重钝化信号,可认为砂轮已经进入严重钝化状态,此时需要对砂轮进行修整。本文方法应用在其他加工工件上依然能够对砂轮钝化状态进行有效识别。



(a) 振铃计数



(b) 能量计数



(c) 均方根值




图 11 连续磨削加工信号的 5 维特征参数数据集随时间变化图
Fig.11 Variations of the 5D characteristic parameter dataset of continuous grinding signal with time




图 12 砂轮钝化状态判别结果
Fig.12 Identifying results of grinding wheel blunting states

2.4 不同特征参数识别准确率比较

探究不同特征参数对于识别准确性的影响，对特征参数进行分组，分组采用部分特征参数进行训练。5 种特征参数分别标注为①，②，③，④，⑤，按表 4 分为 15 种组合方式。

对不同特征参数组合的训练集和数据集分别进行训练与测试，结果如图 13 和表 5 所示。其中，

表 4 特征参数分组表
Table 4 Grouping table for characteristic parameters

组合编号	特征参数编号	组合编号	特征参数编号	组合编号	特征参数编号
1	①	6	②	11	③④
2	①②	7	②③	12	③④⑤
3	①②③	8	②③④	13	④
4	②③④	9	②③④⑤	14	④⑤
5	①②③④⑤	10	③	15	⑤




图 13 特征参数组合测试正确率对比
Fig.13 Comparison of correct rates between different characteristic parameter combination tests

表 5 特征参数单独训练测试结果表
Table 5 Test results of individual characteristic parameter training

组合编号	特征参数名称	正确率/%
1	C	79.0
6	S_E	83.0
10	R_{MS}	91.0
13	R_p	85.5
15	R_{EE}	88.0

组合 5 因为同时用到了五种特征参数准确率最高。单个特征参数的识别准确率中，组合 10(R_{MS})的准确度最高，达到 91.0%；其次是组合 15(R_{EE})和组合 13(R_p)，单个特征参数的准确度达到 88.0%和 85.5%。

由此可得，不同声发射特征参数对砂轮钝化状态识别效果存在差异，使用多个特征参数的测试准确率高于使用其中部分特征参数， R_{MS} 、 R_{EE} 等典型特征参数与砂轮钝化状态相关性较强。

进一步探究两类声发射特征参数在不同钝化阶段的识别准确率差异，对比组合 3 和组合 14，结果如表 6。

表 6 两组特征参数在不同钝化阶段的识别准确率
Table 6 Identification accuracy of two groups of characteristic parameters in different blunting stages

组合编号	特征参数	准确率/%			综合准确率/%
		初期钝化	中期钝化	严重钝化	
3	C 、 S_E 、 R_{MS}	86.3	92.5	100	91.5
14	R_p 、 R_{EE}	88.8	85.0	100	89.5

组合 3 特征参数(C 、 S_E 和 R_{MS})衡量单次 AE Hit 强度变化，组合 14 特征参数(R_p 和 R_{EE})整体衡量声发射信号能量大小。从砂轮钝化原因来看，初期钝化主要是磨粒的破碎，AE hit 密度增加而单次 AE hit 强度变化较小；中期钝化以磨粒磨损和塑性变形为主，磨削力和接触面积增大，AE hit 强度有明显

增加,使得第一类特征参数(组合 1)在中期钝化阶段识别准确率高于初期钝化阶段;严重钝化阶段 AE hit 强度和 AE hit 密度都大幅增加导致区分明显,两组识别准确率都很高。由此可知,声发射特征参数变化与砂轮钝化原因存在对应关系,通过针对性选取典型特征参数可以较准确地识别砂轮在特定阶段的钝化情况。

3 结 论

本文利用 VMD 方法,将磨削加工过程中产生的声发射信号分离出来,保留了声发射信号的主要特征并避免了噪声干扰。声发射特征参数变化存在一定的波动性,PNN 能够较为准确地将特征参数对应到砂轮的不同钝化状态,测试准确率较高(94.5%),且经过泛用性评估,实现了对砂轮钝化状态的识别和严重钝化状态预警。

声发射信号特征参数的选取是影响识别准确率的关键,本文在声发射检测相关研究基础上对特征参数进行归类,参考声发射能量的定义提出声发射包络能量比(R_{EE}),共选取 5 个典型特征参数,通过分组训练并比较测试准确率的方式,证实了所选特征参数对砂轮钝化状态有较高的识别准确率,并验证了典型特征参数变化与砂轮不同钝化原因存在相关性,可为实际声发射检测特征参数的选取提供参考。

参 考 文 献

- [1] LI X L. A brief review: acoustic emission method for tool wear monitoring during turning[J]. International Journal of Machine Tools and Manufacture, 2002, 42(2): 157-165.
- [2] DIMLA Snr D E. Sensor signals for tool-wear monitoring in metal cutting operations—a review of methods[J]. International Journal of Machine Tools and Manufacture, 2000, 40(8): 1073-1098.
- [3] 朱建辉,师超钰,冯克明,等.磨削加工过程声发射检测技术发展现状[J].工具技术,2017,51(9): 6-11.
ZHU Jianhui, SHI Chaoyu, FENG Keming, et al. Application situation and trend of acoustic emission technology in grinding process[J]. Tool Engineering, 2017, 51(9): 6-11.
- [4] 梅益铭.单磨粒磨削中的磨粒磨损过程及磨损状态监测方法研究[D].杭州:浙江大学,2017.
- MEI Yiming. Research on grit wear process and monitoring technique of grain wear in single-grit grinding[D]. Hangzhou: Zhejiang University, 2017.
- [5] 刘希强,杨京,程建春,等.磨削加工过程的声发射机理研究[C]//中国声学学会青年学术会议,2015.
- [6] 吴志远,闫峻,时小军,等.工程陶瓷恒力磨削金刚石砂轮钝化规律研究[J].现代制造工程,2011(6): 97-99,137.
WU Zhiyuan, YAN Jun, SHI Xiaojun, et al. The dullness model of diamond wheels in condition of invariable grinding force[J]. Modern Manufacturing Engineering, 2011(6): 97-99,137.
- [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 & Technology, 2016.
- [8] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [9] 柏航州,王隆太.基于声发射技术的磨削监控系统开发与试验研究[J].现代制造工程,2008(5): 121-125.
BAI Hangzhou, WANG Longtai. The development and experiment research of monitoring and control system for grinding based on AE technology[J]. Modern Manufacturing Engineering, 2008(5): 121-125.
- [10] MOIA D F G, THOMAZELLA I H, AGUIAR P R, et al. Tool condition monitoring of aluminum oxide grinding wheel in dressing operation using acoustic emission and neural networks[J]. Journal of the Brazilian Society of Mechanical Sciences and Engineering, 2015, 37(2): 627-640.
- [11] MIRANDA H I, ROCHA C A, Jr OLIVEIRA P, et al. Monitoring single-point dressers using fuzzy models[J]. Procedia CIRP, 2015, 33: 281-286.
- [12] 王洪雨,姚振强,许胜.基于声发射技术的砂轮磨损实验研究[J].组合机床与自动化加工技术,2018(8): 33-37.
WANG Hongyu, YAO Zhenqiang, XU Sheng. Experimental study of grinding wheel wear process based on acoustic emission technology[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2018(8): 33-37.
- [13] 钟利民,李丽娟,杨京,等. HDP-HSMM 的磨削声发射砂轮钝化状态识别[J].应用声学,2019,38(2): 151-158.
ZHONG Limin, LI Lijuan, YANG Jing, et al. The blunt state identification of acoustic emission for grinding wheel based on HDP-HSMM[J]. Journal of Applied Acoustics, 2019, 38(2): 151-158.
- [14] WANG Z, WILLETT P, DEAGUIAR P R, et al. Neural network detection of grinding burn from acoustic emission[J]. International Journal of Machine Tools and Manufacture, 2001, 41(2): 283-309.
- [15] LIU J X, WEN X B, YUAN L M, et al. A robust approach of watermarking in contourlet domain based on probabilistic neural network[J]. Multimedia Tools and Applications, 2017, 76(22): 24009-24026.