

DOI:10.16356/j.1005-2615.2023.03.004

基于相关性分析与 CNN-BiLSTM 神经网络的 PSZ 陶瓷 磨削表面粗糙度智能预测

郭力, 郑良瑞, 冯浪

(湖南大学机械与运载工程学院/国家高效磨削工程技术研究中心, 长沙 410082)

摘要: 部分稳定氧化锆 (Partially stabilized zirconia, PSZ) 陶瓷因其优越的性能在航空航天工业等领域有广泛的应用。表面粗糙度是评价 PSZ 陶瓷磨削加工水平的关键指标, 为了降低磨削表面粗糙度的预测误差, 提出了一种基于相关性分析与卷积-双向长短期记忆神经网络 (Convolution-bidirectional long short term memory neural network, CNN-BiLSTM) 的 PSZ 陶瓷磨削表面粗糙度声发射预测模型。通过分析磨削声发射信号特征值与磨削表面粗糙度值之间相关性, 筛选出磨削声发射信号与磨削表面粗糙度之间的最相关频段和特征矩阵, 作为 CNN-BiLSTM 神经网络的输入参数以降低磨削表面粗糙度声发射预测的误差。研究表明, 基于相关性分析与 CNN-BiLSTM 神经网络的 PSZ 陶瓷磨削表面粗糙度的平均预测误差低于 3.92%。

关键词: 部分稳定氧化锆; 磨削声发射; 相关性分析; 卷积-双向长短期记忆神经网络; 表面粗糙度预测

中图分类号: TG58

文献标志码: A

文章编号: 1005-2615(2023)03-0401-09

Intelligent Prediction of PSZ Ceramic Grinding Surface Roughness Based on Correlation Analysis and CNN-BiLSTM Neural Network

GUO Li, ZHENG Liangrui, FENG Lang

(College of Mechanical and Vehicle Engineering/National Engineering Research Center for High Efficiency Grinding,
Hunan University, Changsha 410082, China)

Abstract: Partially stabilized zirconia (PSZ) is widely used in the aerospace industry and other fields due to its superior properties. Surface roughness is a key index to evaluate the grinding level of PSZ ceramics. In order to reduce the prediction error of grinding surface roughness, an acoustic emission (AE) prediction of grinding surface roughness of PSZ ceramics based on correlation analysis and convolution-bidirectional long short term memory (CNN-BiLSTM) neural network is proposed. The correlation between the eigenvalues and the grinding surface roughness values in different frequency bands in the grinding AE signals are analyzed, and the optimal sensitive frequency band and the feature matrix of the grinding AE signals are selected as the input parameters of the CNN-BiLSTM neural network to reduce the prediction error of acoustic emission of grinding surface roughness. The results show that the average prediction errors based on correlation analysis and CNN-BiLSTM neural network PSZ grinding surface roughness AE prediction is under 3.92%.

Key words: partially stabilized zirconia; grinding acoustic emission; correlation analysis; convolution-bidirectional long short term memory (CNN-BiLSTM); surface roughness prediction

基金项目: 湖南省自然科学基金科教联合项目 (2021JJ60032)。

收稿日期: 2023-03-09; 修订日期: 2023-05-06

通信作者: 郭力, 男, 教授, 博士生导师, E-mail: guolihnu8@163.com。

引用格式: 郭力, 郑良瑞, 冯浪. 基于相关性分析与 CNN-BiLSTM 神经网络的 PSZ 陶瓷磨削表面粗糙度智能预测 [J]. 南京航空航天大学学报, 2023, 55(3): 401-409. GUO Li, ZHENG Liangrui, FENG Lang. Intelligent prediction of PSZ ceramic grinding surface roughness based on correlation analysis and CNN-BiLSTM neural network [J]. Journal of Nanjing University of Aeronautics & Astronautics, 2023, 55(3): 401-409.

部分稳定氧化锆 (Partially stabilized zirconia, PSZ) 陶瓷作为工程陶瓷的一种, 因其具有耐高温、抗烧蚀、抗氧化以及耐磨损等优越性能在电子信息、新能源、生物医药、航空航天、节能环保以及海洋生物工程等领域具有重要应用前景^[1,2]。PSZ 陶瓷的主要加工方式为磨削, 因其低韧性、高硬度的特点, 使其在磨削过程中易出现表面加工缺陷问题从而严重影响加工质量^[3]。而表面粗糙度是加工表面的微观几何形状误差, 主要用于评价磨削加工质量, 因此对 PSZ 陶瓷磨削表面粗糙度的进行预测具有重要意义。

PSZ 陶瓷在磨削时会发出包含了陶瓷工件表面质量相关信息的大量声发射 (Acoustic emission, AE) 信号, 因此选择磨削 AE 信号来预测 PSZ 陶瓷磨削表面的粗糙度。近年来, 基于声发射信号的表面粗糙度预测研究取得了的进展。文献[4]以磨削 AE 信号基于附加动量法和自适应调整学习法建立 3 层 BP 神经网络对磨削表面进行粗糙度, 相对误差可控制在 8.66% 以内。文献[5]研究了树脂金刚石砂轮磨削氧化铝工件过程中 AE 信号有效值与表面粗糙度之间的相关性, 发现 74~79 kHz 和 103~108 kHz 两个频带范围内的 AE 信号有效值能够较好的拟合粗糙度值。研究表明, 先进的加工方法和人工智能方法使得表面粗糙度的分析和预测更加可靠和准确。文献[6]针对这基本问题提出了一种基于最小冗余和最大相关性的特征筛选方法, 以找出预测磨削表面粗糙度的最优特征组合。文献[7]基于 AE 信号建立卷积神经网络 (Convolutional neural network, CNN) 粗糙度预测模型, 实验显示未经处理的原始信号基于深度学习神经网络亦可对粗糙度进行识别, 但识别结果较差。文献[8]证实了对深度神经网络实行 Dropout 与批标准化操作可以有效提高网络的泛化性能。文献[9]提出一种一维卷积-长短期记忆 (One-dimensional convolution-long and short term memory, 1DCNN-LSTM) 深度神经网络的 Ti-48Al-2Cr-2Nb 微铣削表面粗糙度预测模型, 解决了批量序列数据处理和小样本数据的表面粗糙度预测精确问题。

若要降低磨削表面粗糙度声发射预测误差, 必须保证高质量的输入参数和预测模型网络结构。但目前以 AE 信号为输入信号的磨削表面粗糙度的预测研究仍存在不足之处: (1) 利用整个频带范围内的声发射信号特征值作为神经网络的输入时, 由于存在大量噪声信号和冗余信息的干扰, 误差较大导致预测精度不高。(2) 长短期记忆网络 (Long short term memory, LSTM) 优化了传统循环神经网络在训练时容易遇到的梯度消失问题, 但是对于

序列数据处理的能力不强、样本关键特征的学习效率和能力较差, 导致网络预测性能较差。

因此, 本文采用小波包分析对磨削声发射信号进行分解与重构, 去除大部分噪声信号和冗余信息; 分析磨削 AE 信号各个频段的特征值与磨削表面粗糙度值两者的相关性, 去除冗余信息筛选 AE 信号最佳敏感频段的特征矩阵, 提高模型输入参数的质量。同时建立基于相关性分析与卷积-双向长短期记忆神经网络 (Convolution-bidirectional long short term memory neural network, CNN-BiLSTM) 的 PSZ 陶瓷磨削表面粗糙度声发射预测模型, 以解决序列数据处理以及样本关键特征提取效率和性能问题, 最终降低磨削表面粗糙度预测误差。

1 磨削表面粗糙度预测模型

1.1 CNN-BiLSTM 网络模型构建

双向长短期记忆网络 (Bidirectional long short term memory network, BiLSTM) 是在 LSTM 基础上的改进, 它由一个前向 LSTM 和一个后向 LSTM 构成^[10]。2 个 LSTM 神经网络分别以正序和逆序对输入序列进行特征提取, 能够双向学习特征数据, 因此该网络的特征提取效率和性能都优于单个 LSTM。

t 时刻 BiLSTM 的隐藏状态输出 y_t 为

$$y_t = \vec{h}_t \oplus \overleftarrow{h}_t \quad (1)$$

式中: \vec{h}_t 、 \overleftarrow{h}_t 分别表示 t 时刻前向和后向 LSTM 的隐藏状态输出; “ \oplus ” 表示特征向量的拼接。

基于 CNN 对数据的处理能力和 BiLSTM 的双向特征学习能力, 建立了 CNN-BiLSTM 磨削表面粗糙度预测模型, 包括输入层、CNN 层、BiLSTM 层、丢弃层、全连接层、回归层和输出层。结构如图 1 所示。

CNN 层由 4 个卷积块组成, 其中每个卷积块又由卷积层、归一化层、激活层 3 个部分组成, 由于池化操作会使得到的特征信息丢失, 所以此处不进行池化操作。首先将磨削声发射信号经过相关性分析得到的最佳敏感频段的特征矩阵作为 CNN-BiLSTM 预测模型的输入参数, 经过 4 个 CNN 层对数据进行特征提取, 得到高质量特征序列。其次将高质量特征序列作为 BiLSTM 的输入参数, 对数据进行双向特征学习, 经全连接层进行数据特征处理, 再由回归层实现对表面粗糙度的回归预测。其中, 丢弃层主要是采用 dropout 操作, 使 BiLSTM 的部分神经元失活, 提高模型的泛化能力。

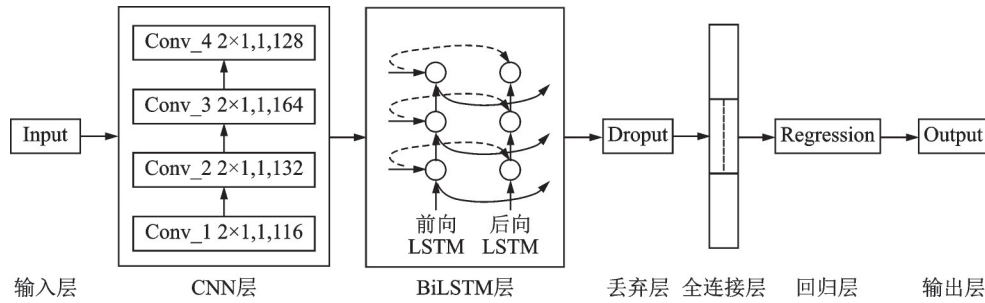


图 1 CNN-BiLSTM 结构

Fig.1 Structure of CNN-BiLSTM

1.2 基于相关性分析与 CNN-BiLSTM 磨削表面粗糙度预测模型

首先,对 AE 原始信号进行小波包分析提取主要特征频段,以相关性分析见式(2)筛选最佳敏感频段和特征矩阵,获取高质量输入参数。另外,由 AE 信号提取得到的特征序列作为输入参数时,模型应具有较强的序列数据处理能力和样本关键特征的学习能力,采用 CNN-BiLSTM 可以有效解决该问题。

$$r(X, Y) = \frac{C(X, Y)}{\sqrt{D(X)D(Y)}} \quad (2)$$

式中: X 为特征值; Y 为磨削表面粗糙度值; $C(X, Y)$ 表示 X, Y 协方差; $D(X), D(Y)$ 分别表示 X, Y 的方差。

基于相关性分析与 CNN-BiLSTM 磨削表面粗糙度预测模型的构建步骤如下,流程图见图 2。

- (1)采集 AE 信号和 PSZ 陶瓷磨削表面粗糙度。
- (2)小波包分析选择确定主要特征频段并去除冗余信息。
- (3)相关性分析选择最佳敏感频段和特征矩阵。

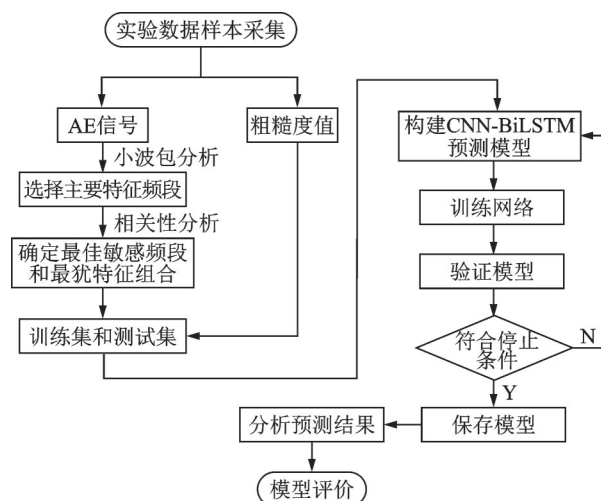


图 2 基于相关性分析和 CNN-BiLSTM 的磨削表面粗糙度预测模型构建与评价流程

Fig.2 Construction and evaluation process of grinding surface roughness prediction model based on correlation analysis and CNN-BiLSTM neural network

(4)利用 CNN-BiLSTM 模型预测 PSZ 陶瓷磨削表面粗糙度。

模型参数确定如下:

- (1)输入层:AE 信号经小波包、相关性分析后确定的特征矩阵作为输入参数。
- (2)输出层:磨削表面粗糙度值作为输出参数。
- (3)CNN 层:包含 4 个卷积块,其中卷积核尺寸为 2×1 ,步长为 1,通道数分别为 16、32、64、128。
- (4)BiLSTM 层:该层隐含层节点数为 200。
- (5)丢弃层:dropout 参数设为 0.2,使 20% 的神经元失活。
- (6)其他参数设置:使用 Adam 梯度下降算法,最大迭代次数 600 次,初始学习率为 0.01,学习率下降因子 0.5。

2 试验验证

2.1 氧化锆陶瓷磨削声发射实验

实验在 MGK7120x6/F 平面磨床上进行,磨削试件为 PSZ 陶瓷,其材料力学性能如表 1 所示,尺寸为 $35 \text{ mm} \times 13 \text{ mm} \times 13 \text{ mm}$,磨削表面 $35 \text{ mm} \times 13 \text{ mm}$ 。陶瓷试件装在夹具中。试验装置示意图如图 3 所示,声发射传感器用夹具安装在靠近 PSZ 工件的磨床工作台上。采用美国物理声学公司 PAC 的 R6a 声发射传感器对磨削 PSZ 陶瓷时产生的 AE 信号进行监测,同时对 AE 传感器输出的 AE 信号以 40 dB 的放大增益进行前置放大,并用 PCI-2 声发射 AE 信号采集卡进行信号采集。最后,利用 MATLAB 软件对采集到的磨削 AE 信号进行分析处理。

本实验旨在采集 PSZ 陶瓷在不同磨削参数下的 AE 信号和磨削表面粗糙度。设计 PSZ 陶瓷磨削试验如表 2 所示,其中“数量”为每组实验参数下磨削陶瓷试件个数,最终获得 32 组试验数据。实验结束后利用 DR160 表面粗糙度测量仪测量试件的进刀位置、中间位置、退刀位置 3 处的表面粗糙度取平均值如表 3 所示。

表1 PSZ材料力学性能

Table 1 Mechanical properties of PSZ materials

工件材料	晶粒尺寸/ μm	密度/ $(\text{g}\cdot\text{cm}^{-3})$	抗弯强度/MPa	微观硬度/GPa	断裂韧性/ $(\text{MPa}\cdot\text{m}^{1/2})$	弹性模量/GPa
PSZ	≤ 1	6	946	11.8	8.1	205

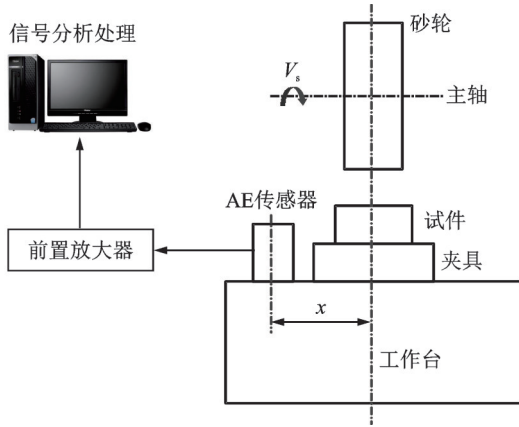


图3 试验装置示意图

Fig.3 Schematic diagram of the test setup

表2 PSZ陶瓷磨削正交试验

Table 2 Orthogonal test of PSZ grinding

砂轮转速 $V_s/$ ($\text{m}\cdot\text{s}^{-1}$)	工作台速度 $V_w/$ ($\text{m}\cdot\text{min}^{-1}$)	磨削深度 $a_p/$ μm	数量
17.6	4	10	4
26.4	6	20	4

表3 PSZ陶瓷磨削表面粗糙度

Table 3 Surface roughness of grinding PSZ ceramics

序号	$Ra/\mu\text{m}$	序号	$Ra/\mu\text{m}$	序号	$Ra/\mu\text{m}$	序号	$Ra/\mu\text{m}$
1	0.690	9	0.739	17	0.605	25	0.635
2	0.733	10	0.512	18	0.489	26	0.580
3	0.606	11	0.610	19	0.483	27	0.741
4	0.536	12	0.536	20	0.558	28	0.581
5	0.433	13	0.474	21	0.476	29	0.631
6	0.532	14	0.521	22	0.644	30	0.441
7	0.719	15	0.588	23	0.485	31	0.556
8	0.607	16	0.560	24	0.744	32	0.645

2.2 小波包分析确定AE信号主要特征频段

由声发射采集系统采集到的磨削AE原始信号及其傅里叶变换后的频谱图如图4(a,b)所示。小波包分析是一种非常有效的信号频谱分析方法,通过自动选择适当频带来匹配被分析信号的特性,以保证信号分析的准确性和实时性,提高特征提取的可靠性^[11-12]。小波包分解与重构原始AE信号,设置小波包层数为4层,小波基dmev。4层小波包分解后得到16个频段,每个频带宽度为62.5 kHz。在该16个频带内进行能量统计,得到小波包系数 $\{x_i(g), g=1, 2, 3, \dots, M-1, M\}$ 。计算各频段上的能量占比,该值可以表征磨削AE信号的能量分布特点,计算公式为^[13]

$$P_{j,i} = \frac{\sum_{g=1}^M |x_i(g)|^2}{E} \quad (3)$$

式中: i 表示AE信号的不同频段; M 为小波包分解(Wavelet packet decomposition, WPD)后各频段信号长度; E 为各频段能量总和; $\sum_{g=1}^M |x_i(g)|^2$ 表示各个子频段上的能量。

声发射信号作为一种将应变能以弹性波形式传递出来的方式,其能量的强弱可以反应声发射信号的强弱^[14]。由图5可知,0~62.5 kHz频段内的平均能量占比为96.83%,62.5~125 kHz频段内的平均能量占比为2.86%,其他14个频段的平均能量占比总和仅为0.31%。所以在其他14个频段上的AE信号极其微弱,则其所包含特征信息对磨削表面粗糙度的影响也极其微弱,可不作考虑。由于AE信号的能量主要集中于0~62.5 kHz和62.5~125 kHz两个频段,所以该频段内信号包含了丰富的与磨削表面粗糙度相关的特征信息。0~62.5 kHz和62.5~125 kHz两个频段内的AE信号进行重构信号如图4(c~f)所示。

2.3 确定AE信号最佳敏感频段和特征矩阵

2.3.1 确定AE信号最佳敏感频段

研究表明利用整个频带范围内的声发射信号特征值作为神经网络的输入来预测磨削表面粗糙度,由于冗余信息较多,误差较大预测精度不高^[4]。所以根据工况条件等将信号整个频带分成不同的频段,找出冗余信息最少的最佳AE信号频带,以提高预测精度。选择0~62.5 kHz和62.5~125 kHz两个频带的重构信号,以5 kHz作为频率间隔,将两个频带划分为0~5、5~10、...、55~62.5 kHz和62.5~70、70~75、...、120~125 kHz共24个频段,依次对应1、2、3、...、23、24序号。

进给量一定时,当磨削深度增加,材料单位时间去除体积增大,磨削AE信号的有效值增大;同时由于材料去除不充分,磨削表面粗糙度也增大。则磨削表面粗糙度与有效值之间存在一定的相关性。建立不同试验条件下的 Ra 值拟合曲线(Ra 值随着磨削参数的改变而变化情况)和24个频段内AE信号有效值拟合曲线(有效值随着磨削参数的改变而变化情况),图6仅展示部分。分析有效值与粗糙度值之间的拟合曲线,判断不

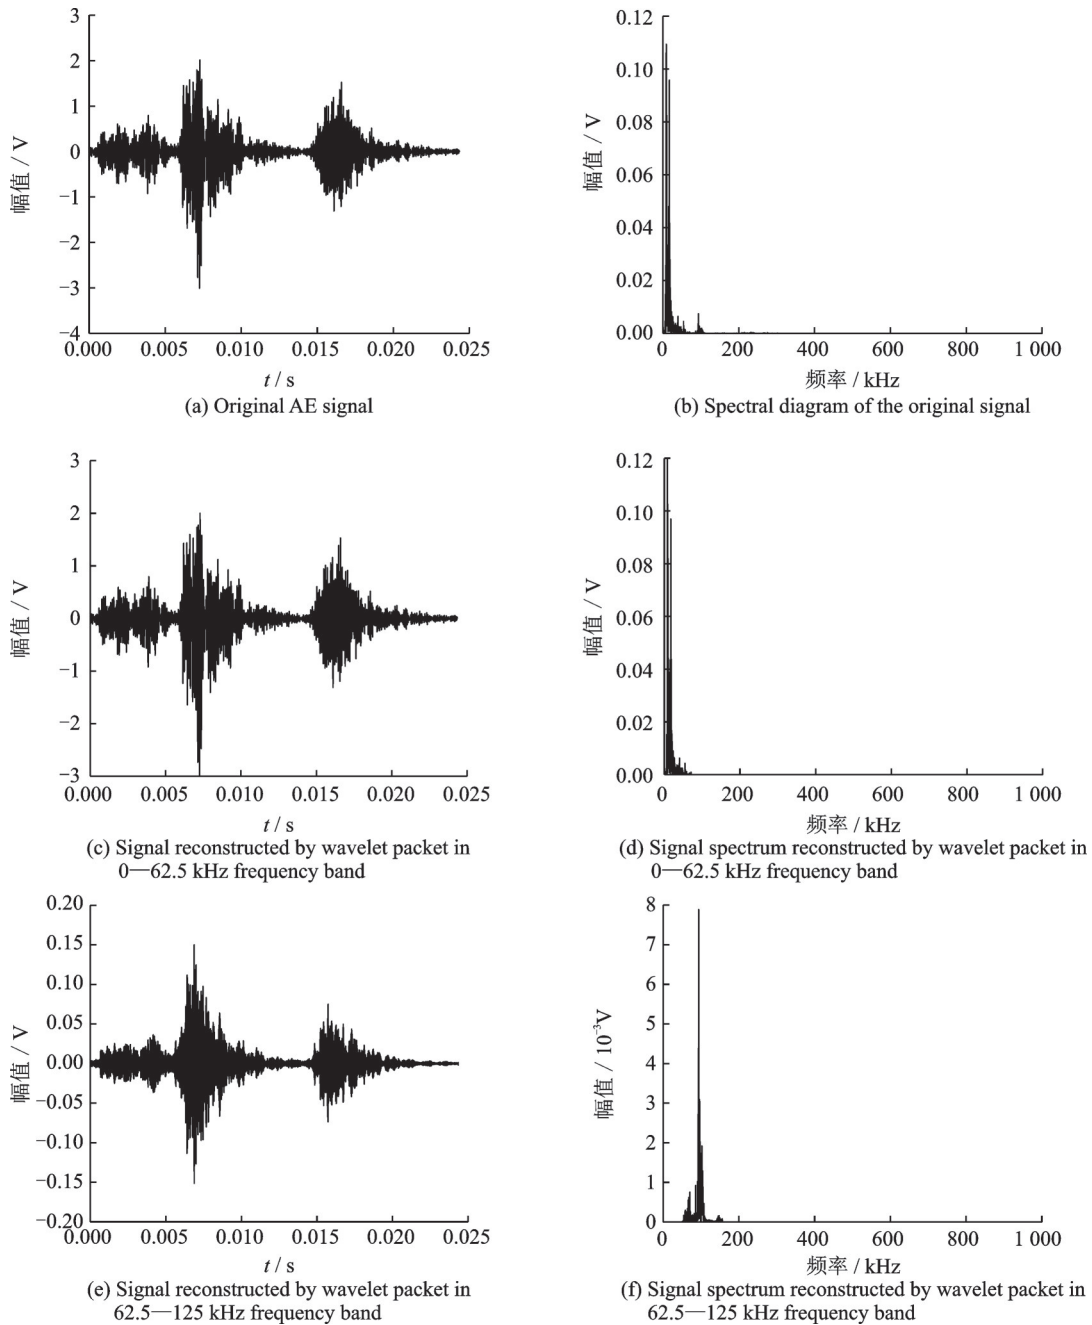


图 4 AE 信号小波包分析前后对比图

Fig.4 Comparison of AE signal before and after wavelet packet analysis




图 5 不同频段能量占比

Fig.5 Energy ratio of different frequency bands

同频段有效值对 Ra 值的拟合程度,即有效值拟合曲线与 Ra 值拟合曲线的相似程度;若相似程度越大,则拟合程度越好相关性越高;反之则拟合程度越差相关性越低。通过分析 AE 信号有效值对磨削表面粗糙度值的拟合程度,初步筛选出拟合程度较好的频段,再结合有效值与粗糙度值之间的相关系数大小,确定最佳敏感频段。对比分析可知,AE 信号有效值对 Ra 值的拟合程度较好的频段有 25~30、62.5~70、70~75、75~80、80~85、85~90 kHz,对应频段序号为 6、13、14、15、16、17。

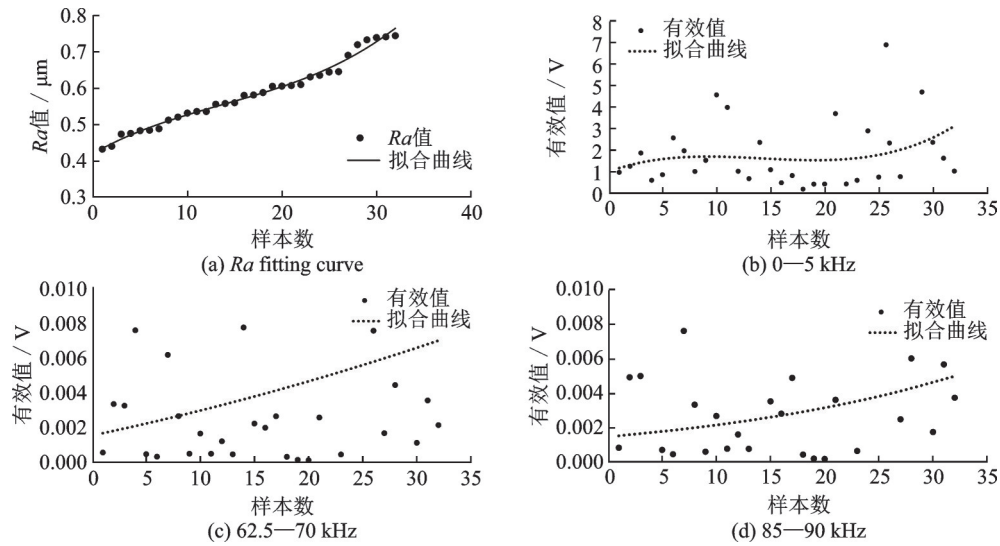


图6 不同磨削参数下Ra值拟合曲线和部分频段有效值拟合曲线

Fig.6 Fitting curves of Ra values and effective values in some frequency bands under different grinding parameters

分析上述6个频段的有效值与粗糙度值之间相关系数,确定最佳敏感频段。一般来说,相关系数小于0.1的为弱相关,大于0.1而小于0.5的为实相关,大于等于0.5的为强相关^[15]。由图7可知,在筛选出的6个频段内,6、15、16频段其拟合程度与17频段拟合曲线相似,但是相关系数均为0.37,而17频段的相关系数为0.40,所以17频段敏感程度

要高于6、15、16频段。另外,14频段与17频段的相关系数均为0.40,但是14比17频段的拟合曲线拟合程度要高。所以14频段敏感程度要高于17频段。而14与13频段的相关系数大,所以13频段敏感程度要高于14频段。则13频段(即62.5~70 kHz)的敏感程度最高。




图7 24个频段内AE信号有效值与Ra值的相关系数

Fig.7 Correlation coefficient between Ra and AE signal RMS in 24 frequency bands

平均相关系数(Average correlation coefficient, ARC)由式(4)所示,不同频段内各个特征值与粗糙度值的平均相关系数^[16]。

$$ARC = \frac{\sum_{i=1}^L R_{\text{coef}}(\{X_1^i, X_2^i, \dots, X_n^i\}^T, Y)}{L} \quad (4)$$

式中: $\sum_{i=1}^L R_{\text{coef}}(\{X_1^i, X_2^i, \dots, X_n^i\}^T, Y)$ 为不同各个特征值与粗糙度值之间的相关系数之和; n 为特征值个数, L 为频段总数。

ARC越高,表示该频段内各个特征值与粗糙度值的相关程度越高。由图8可知,在24个频段中62.5~70 kHz(序号13)内的PSZ陶瓷各个特征

值的ARC最大,其值为0.29,所以该频段内的各个特征值与粗糙度值的总体相关程度最大。通过有效值与Ra值拟合曲线之间的相似性判断有效值对Ra值的拟合程度进行初步筛选,再结合有效值与Ra值之间的相关系数最终确定的最佳敏感频段与最大平均相关系数确定的为同一频段,所以该方法行之有效的。

2.3.2 确定特征矩阵

在62.5~70 kHz频段内提取特征值,分别有最大值等16个特征值,分析各个特征值与PSZ陶瓷磨削表面粗糙度值之间的相关性,选择相关系数大于0.2的特征值组成新的特征矩阵作为CNN-BiLSTM神经网络的输入。由表4可知,




图 8 24 个频段内 AE 信号各个特征值的 ARC

Fig.8 ARC of each characteristic value of AE signal in 24 frequency bands

表 4 62.5~70 kHz 频段内 16 个特征值与磨削表面粗糙度值之间的相关系数 r

Table 4 Correlation coefficient r between the 16 eigenvalues and the grinding surface roughness values in the frequency range of 62.5—70 kHz

特征值	最大值	最小值	峰-峰值	平均值	标准差	方差	有效值	偏度
r	0.383 3	0.430 3	0.156 4	0.412 3	0.125 8	0.079 4	0.408 9	-0.087 4
特征值	峭度	峰值因子	脉冲因子	波形因子	裕度因子	能量	峰值频率	功率谱峰值
r	0.333 3	-0.329 6	-0.291 5	-0.181 8	-0.291 9	0.390 8	-0.310 5	0.361 4

PSZ 陶瓷经小波包分解与重构后的磨削 AE 信号在 62.5~70 kHz 频段内的 16 个特征值与表面粗糙度值之间相关系数绝对值大于 0.2 的有最大值等 11 个特征值,选择该 11 个特征值构成的特征矩阵作为 CNN-BiLSTM 神经网络的输入,磨削表面粗糙度值作为输出。

2.4 CNN-BiLSTM 网络模型预测与结果分析

共有 32 组实验数据,对数据进行归一化,85% 用于训练(即 1~27 组),15% 用于预测(即 28~32 组)。将 PSZ 陶瓷磨削声发射信号的最佳敏感频段的特征矩阵 32×11 作为 CNN-BiLSTM 神经网络的输入数据集,磨削表面粗糙度值作为输出数据集。CNN-BiLSTM 模型训练过程如图 9 所示。当训练次数达到 100 次的时候,训练误差达到 0.05 左右,模型训练过程开始趋于稳定,满足 PSZ 陶瓷磨削表面粗糙度预测要求。

为验证 CNN-BiLSTM 表面粗糙度预测模型的精确度,将输入数据集 32×11 的矩阵归一化后




图 9 CNN-BiLSTM 表面粗糙度预测模型训练过程

Fig.9 CNN-BiLSTM surface roughness prediction model training process

分别输入到 CNN、LSTM、CNN-LSTM 和 CNN-BiLSTM 神经网络当中,得到如表 5 不同模型的预测结果。为了比较不同模型的预测精度,将平均相对误差(Mean relative error, MRE)和均方根误差(Root mean squared error, RMSE)同时用于模型的评价。为了使预测结果更加准确,总共预测 20 次求取平均值进行对比。

由表 5 可知,对 PSZ 陶瓷磨削表面粗糙度进行声发射预测,对比相同网络模型不同信号类型下的预测误差发现,在反向传播(Back propagation, BP)网络中已处理 AE 信号比未处理 AE 信号的 MRE 和 RMSE 分别减少了 7.92% 和 4.17%;在 CNN-BiLSTM 模型中已处理 AE 信号比未处理 AE 信号的 MRE 和 RMSE 分别减少了 1.95% 和 1.64%。所以经过小波包以及相关性分析确定最佳敏感频段的方法可以有效提高输入参数质量,从而降低 PSZ 陶瓷磨削表面粗糙度预测误差。对比相同信号类型不同网络模型下的预测误差发现,在未处理 AE 信号类型下 CNN-BiLSTM 模型比 BP 网络的 MRE 和 RMSE 分别减少了 16.06% 和 9.22%;在已处理 AE 信号类型下 CNN-BiLSTM 模型比 BP、LSTM、CNN、CNN-LSTM 网络模型的 RMSE 分别减少了 6.69%、6.25%、3.83%、1.72%。所以 CNN-BiLSTM 模型的预测效果要好于 BP、LSTM、CNN、CNN-LSTM 模型。结果表明,高质量的输入参数与模型网络结构能够明显提高磨削表面粗糙度声发射预测精度。

表5 不同模型PSZ磨削表面粗糙度预测结果

Table 5 Surface roughness prediction results of PSZ grinding with different models

信号类型	神经网络类型	评价指标/%	预测组数							平均误差
			1	2	3	...	18	19	20	
未处理AE信号	BP	MRE	16.13	24.22	17.36	...	19.33	40.87	22.94	22.72
		RMSE	11.85	14.01	10.80	...	14.43	24.94	14.32	14.78
	CNN-BiLSM	MRE	3.23	0.82	9.71	...	13.50	10.03	5.98	6.66
		RMSE	1.93	0.53	7.43	...	11.02	7.77	8.17	5.56
已处理AE信号	BP	MRE	17.75	16.91	15.86	...	16.54	13.78	12.10	14.80
		RMSE	14.36	9.65	13.26	...	15.59	9.41	7.09	10.61
	LSTM	MRE	18.21	11.24	9.77	...	17.50	11.24	8.74	13.84
		RMSE	13.99	7.26	7.26	...	16.00	8.07	5.25	10.17
	CNN	MRE	7.72	1.54	18.53	...	5.36	9.37	3.95	9.47
		RMSE	6.23	1.12	10.72	...	4.45	7.61	3.14	7.75
	CNN-LSTM	MRE	11.14	2.04	8.84	...	5.91	4.31	17.26	7.56
		RMSE	7.93	1.31	6.49	...	3.76	4.25	10.43	5.64
	CNN-BiLSTM	MRE	1.12	1.24	0.91	...	1.28	5.92	6.66	4.71
		RMSE	1.00	0.72	0.59	...	0.79	5.64	5.49	3.92

3 结 论

(1)通过对PSZ陶瓷磨削AE信号的特征值与磨削表面粗糙度值之间的相关性分析,确定了AE信号的最佳敏感频段为62.5~70 kHz及其特征输入矩阵。该方法能有效地减少磨削AE信号中的冗余信息,提高输入参数质量。

(2)提出了一种基于相关性分析的CNN-BiLSTM深度神经网络磨削表面粗糙度声发射预测模型。经相关性分析得到的高质量输入参数,由CNN层自适应网络有效提取出高质量特征序列后,输入到BiLSTM网络对样本关键特征进行双向学习,实现了对小样本数据的精准预测。

(3)基于相关性分析与CNN-BiLSTM神经网络磨削表面粗糙度声发射预测模型,对PSZ陶瓷磨削表面粗糙度进行声发射预测平均预测误差在3.92%以下。在预测精度上有大幅度提升,对于高精度预测具有较好的工程意义,有利于磨削表面质量的在线监控和调整。

参考文献:

- [1] 肖汉宁,刘井雄,郭文明.工程陶瓷的技术创新与产业发展[C]//中国硅酸盐学会陶瓷分会2015学术年会论文集.淄博:中国硅酸盐学会,2015:165-172.
XIAO Hanning, LIU Jinxiang, GUO Wenming. Technical innovation and industrial development of engineering ceramics[C]//Proceedings of 2015 Academic annual meeting of Ceramics Society of China Silicate Society. Zibo, China: China Society of Ceramics, 2015:165-172.
- [2] 郭力,邓喻,霍可可.氧化铝陶瓷磨削金刚石砂轮磨削的声发射监测[J].湖南大学学报,2018,45(4):

34-40.

GUO Li, DENG Yu, HUO Keke. Acoustic emission monitoring of diamond grinding wheel wear with grinding alumina ceramic grinding [J]. Journal of Hunan University, 2018, 45(4): 34-40.

- [3] 丁宁,段景淞,石建,等.基于声发射砂轮磨损监测系统研究[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.

- [4] 胡仲翔,滕家绪,钱耀川,等.用声发射信号和改进的BP神经网络预测磨削表面粗糙度[J].装甲兵工程学院学报,2009,23(6):76-79.

HU Zhongxiang, TENG Jiayu, QIAN Yaochuan, et al. Prediction of grinding surface roughness with acoustic emission signal and modified BP neural network [J]. Journal of Academy of Armored Force Engineering, 2009, 23(6): 76-79.

- [5] AULESTIA V M A, ALEXANDRE F A, AGUIAR P R, et al. Correlation between surface roughness and AE signals in ceramic grinding based on spectral analysis[J]. MATEC Web of Conferences, 2018, 249: 3003.

- [6] GUO Weicheng, WU Chongjun, DING Zishan, et al. Prediction of surface roughness based on a hybrid feature selection method and long short-term memory network in grinding [J]. The International Journal of Advanced Manufacturing Technology, 2021, 112(9/10): 2853-2871.

- [7] IBARRA-ZARATE D, ALONSO-VALERDI L M, CHUYA-SUMBA J, et al. Prediction of Inconel 718

- roughness with acoustic emission using convolutional neural network based regression[J]. The International Journal of Advanced Manufacturing Technology, 2019,2019:1-13.
- [8] PAN Y N, KANG R K, DONG Z G, et al. On-line prediction of ultrasonic elliptical vibration cutting surface roughness of tungsten heavy alloy based on deep learning [J]. Journal of Intelligent Manufacturing, 2020, 33(3):675-685.
- [9] 王志勇, 马轩, 杜金金. 基于1DCNN-LSTM神经网络的Ti-48Al-2Cr-2Nb微铣削表面粗糙度预测[J]. 制造技术与机床, 2022(5): 128-133.
WANG Zhiyong, MA Xuan, DU Jinjin. Surface roughness prediction for Ti-48Al-2Cr-2Nb micro-milling based on 1DCNN-LSTM neural network[J]. Manufacturing Technology & Machine Tool, 2022(5): 128-133.
- [10] LUO Senlin, HAO Jingwei, PAN Limin. An automatic sleep staging method based on CNN-BiLSTM[J]. Transactions of Beijing Institute of Technology, 2020, 40(7): 746-752.
- [11] 敖银辉, 汪宝生. 基于小波包与概率神经网络的液压泵故障模式识别[J]. 机床与液压, 2014, 42(13): 168-170.
AO Yinhui, WANG Baosheng. Fault model recognition of hydraulic pump based on wavelet packet and probabilistic neural network[J]. Machine Tool & Hydraulics, 2014, 42(13): 168-170.
- [12] 谢成俊. 小波分析理论与工程应用[M]. 长春: 东北师范大学出版社, 2015.
XIE Chengjun. Wavelet analysis theory and engineering application [M]. Changchun: Northeast Normal University Press, 2015.
- [13] 叶赵伟, 朱永成, 左敦稳, 等. 基于声发射技术的搅拌摩擦焊接工具磨损监测[J]. 南京航空航天大学学报, 2018, 50(3):404-410.
YE Zhaowei, ZHU Yongcheng, ZUO Dunwen, et al. Wear monitoring of friction stir welding tools based on acoustic emission technology[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2018, 50(3):404-410.
- [14] 胡陈林, 毕果, 林桂丹, 等. 基于声发射信号检测的光学元件表面加工质量监控研究[J]. 制造技术与机床, 2014(6): 78-81.
HU Chenlin, BI Guo, LIN Guidan, et al. Research on optical surface quality based on the monitoring of acoustic emission signals[J]. Manufacturing Technology & Machine Tool, 2014(6): 78-81.
- [15] 王新峰, 邱静, 刘冠军. 基于特征相关性和冗余性分析的机械故障特征选择研究[J]. 中国机械工程, 2006,17(4): 379-382.
WANG Xinfeng, QIU Jing, LIU Guanjun. Mechanical fault feature selection based on feature correlation and redundancy analysis [J]. China Mechanical Engineering, 2006,17(4): 379-382.
- [16] 孙正, 戈洪宇. 基于情景匹配的战时备件分配模型[J]. 兵工自动化, 2019, 38(9): 205-211.
SUN Zheng, GE Hongyu. Wartime spare parts allocation model based on situation matching [J]. Ordnance Industry Automation, 2019, 38(9): 205-211.

(编辑:张蓓)