

改进 VMD 去噪与多特征融合的声发射信号识别方法

程铁栋¹,王运来²,张志钊²,易其文¹,尹宝勇²,袁海平³

(1.江西理工大学 电气工程与自动化学院,江西 赣州 341000;

2.江西理工大学 理学院,江西 赣州 341000;

3.合肥工业大学 土木与水利工程学院,安徽 合肥 230009)

摘要:针对岩石破裂过程中声发射信号难以识别的问题,提出一种改进变分模态分解(VMD)去噪与多特征融合的声发射信号识别方法。首先,根据奇异值理论确定 VMD 分解模态数 K ,实现信号的自适应分解。然后,利用排列熵筛选出最优本征模态分量(IMF)并重构,进而提取重构信号的多个特征向量并融合。最后,将融合特征向量输入到多元宇宙算法优化的支持向量机(MVO-SVM)模型实现声发射信号的识别。实验结果表明,相比同种特征提取方法,基于改进 VMD 去噪的识别效果优于 EEMD 去噪和小波阈值去噪;相比单一特征向量,声发射信号的融合特征向量可以取得更高的识别准确率。

关键词:声发射;变分模态分解;排列熵;多特征融合;支持向量机;模式识别

中图分类号:TP183;TD76

文献标志码:A

Acoustic emission signal recognition method based on improved VMD denoising and multi-feature fusion

CHENG Tiedong¹,WANG Yunlai²,ZHANG Zhizhao²,YI Qiwen¹,YIN Baoyong²,YUAN Haiping³

(1. School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou,

Jiangxi 341000, China;2. School of Science, Jiangxi University of Science and Technology, Ganzhou, Jiangxi 341000, China;

3. College of Civil Engineering, Hefei University of Technology, Hefei, Anhui 230009, China)

Abstract: To handle the problem of acoustic emission signal recognition in the process of rock fracture, an acoustic emission signal recognition method based on improved variational modal decomposition (VMD) denoising and multi-feature fusion is proposed in this paper. Firstly, the VMD decomposition mode number K was determined according to the singular value theory to realize the adaptive decomposition of the signal. Then, the optimal intrinsic mode function (IMF) was selected by permutation entropy, and the multi-feature vector are extracted from the reconstructed signal and fused for further recognition. Finally, the fusion feature vector was input into the support vector machine model optimized by multi-verse optimizer (MVO-SVM) to realize the recognition of acoustic emission signals. The experimental results show that, comparing with the same feature extraction method, the recognition effect of the improved VMD denoising is better than those of EEMD denoising and wavelet threshold denoising. Compared with the single feature vector, the fused feature vector of acoustic emission signal can achieve higher recognition accuracy.

Key words: acoustic emission; variational mode decomposition; permutation entropy; multi-feature fusion; support vector machine; pattern recognition

收稿日期:2021-03-16

基金项目:国家自然科学基金项目(51874112);江西省科技厅重点研发项目(20192BBEL50042);江西省教育厅科技计划重点项目(202101400673)

作者简介:程铁栋(1975—),男,江西宜春人,副教授,博士,主要从事矿山灾害预警研究。

王运来(1997—),男,江苏徐州人,硕士研究生,主要从事信号识别研究,本文通信作者.E-mail:416464773@qq.com

岩石声发射(acoustic emission, AE)是指岩石在受到外部载荷或内力作用下,其内部含有的大量微孔洞、裂隙发生了聚合、扩展及相互贯穿,储存的能量以弹性波形式释放的过程^[1]。声发射技术作为一种动态检测方法,被广泛应用于岩石力学工程领域的灾害监测、预警方面^[2]。通过对声发射传感器采集的岩石声发射信号进行分析,可以获取岩石破坏的时间、地点、机制等信息。由于背景噪声、机械噪声等因素的干扰,传感器所采集的声发射信号波形极为复杂,导致声发射信号的识别异常困难。因此,岩石声发射信号的准确识别对岩体失稳灾变的预警研究具有重要意义。

随着声发射技术在各个领域的广泛应用,对信号去噪能力的要求逐渐提高。刘东瀛等^[3]提出一种基于相关系数原理的经验模态分解(empirical mode decomposition, EMD)去噪方法;戴聪聪等^[4]提出一种将总体经验模态分解法(ensemble empirical mode decomposition, EEMD)与云相似度理论相结合的去噪方法;姜长泓等^[5]通过对小波阈值法的改进,提出基于平移不变小波的声发射信号去噪方法。上述去噪方法虽然取得了不错的效果,但也存在不足之处。例如,EMD 在分解信号的过程中易出现模态混叠及端点效应等问题^[6],EEMD 在分解信号的过程中会存在残余的白噪声^[7],小波阈值去噪在分解层数的确定和阈值的选择等方面存在困难^[8]。

特征提取是声发射信号识别的关键,常用的声发射信号特征提取方法主要包括基于参数的分析方法和基于波形的分析方法^[9]。参数分析法通过对信号的统计特征参数进行分析,是目前声发射信号领域应用最广泛的方法。姚旭龙等^[10]利用能量贡献率构建了岩石破裂关键事件声发射信号的优选方法;司莉等^[11]通过对声发射信号的递归定量分析,提出基于递归定量分析与支持向量机相结合的声发射信号识别方法。这些方法为声发射信号的识别提供了多个途径并取得不错的效果,但也存在一些不足:能量贡献率作为单一特征,提供的声发射源信息有限;递归定量分析存在计算量大的问题。

变分模态分解(variational mode decomposition, VMD)是 Dragomiretskiy 等^[12]提出的一种新的非递归式模态分解算法,该方法可有效避免 EEMD 在分解信号过程中产生残余的白噪声。然而,VMD 对信号进行分解时,需要提前设置本征模态分量(intrinsic mode function, IMF)的个数 K ,且 K 的取值影响算法的分解效果^[13]。目前时频域特征参数已被广泛应用于故障诊断领域,但多个特征融合参数在声发射领域应用较少。

鉴于此,本研究利用改进的 VMD 算法对岩石声发射信号进行分解,结合排列熵筛选出最优 IMF 分量并进行重构,然后提取重构信号的多个特征参数,将多个特征参数融合并输入到多元宇宙优化算法(multi-verse optimizer, MVO)优化的支持向量机(support vector machine, SVM),对岩石声发射信号进行识别。

1 改进的 VMD 算法

1.1 VMD 算法

VMD 算法的实质是通过构建并求解约束变分模型,得到多个具有特定稀疏性的 IMF 分量。VMD 算法构建的约束变分模型为:

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

式中: u_k 为 VMD 分解得到的各个 IMF 分量; ω_k 为各个 IMF 分量对应的中心频率; $\delta(t)$ 为单位脉冲函数; j 为虚数单位; $f(t)$ 为原始信号。

为了求解该约束变分模型,通过引入二次惩罚因子和拉格朗日乘子项将有约束变分问题转换为如下无约束变分问题:

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

式中: α 为二次惩罚因子, λ 为拉格朗日乘子。这里, α 也称为分解完备性的平衡参数,其取值会影响 VMD

方法的分解效果。 $\|f(t) - \sum_k u_k(t)\|_2^2$ 表示原始信号与各模态分量之差中各元素的平方和, $\langle \lambda(t), f(t) - \sum_k u_k(t) \rangle$ 表示拉格朗日乘子 $\lambda(t)$ 与 $f(t) - \sum_k u_k(t)$ 的内积, 利用乘法算子交替方向法可以解决以上无约束变分问题。当迭代求解变分模型时, 不断更新 u_k^{n+1} 、 ω_k^{n+1} 和 λ^{n+1} , 直至满足迭代停止条件, 最终完成式 (2) 中无约束变分问题的求解。

1.2 VMD 算法的改进

VMD 算法需要提前设置 IMF 分量个数, 且通过主观经验难以合理设置该参数。本研究利用奇异值最佳有效秩阶次自动获得 VMD 分解的最优 K 值。排列熵是一种检测动力学突变和时间序列随机性的方法^[14], 其大小反映时间序列的随机程度, 可以根据排列熵值评定 IMF 分量的含噪程度^[15]。改进 VMD 去噪算法的主要步骤如下。

1) 信号的奇异值分解

假设信号序列为 $X = \{x_1, x_2, \dots, x_N\}$, 将 X 构造为 $p \times q$ 阶 Hankel 矩阵:

$$H = \begin{bmatrix} x_1 & x_2 & \cdots & x_q \\ x_2 & x_3 & \cdots & x_{q+1} \\ \vdots & \vdots & \vdots & \vdots \\ x_p & x_{p+1} & \cdots & x_N \end{bmatrix} \quad (3)$$

对 Hankel 矩阵 H 进行奇异值分解, 得到:

$$H = U \Sigma V^T = \sum_{i=1}^r \sigma_i H_i \quad (4)$$

式中: $U \in \mathbf{R}^{p \times p}$ 称为左奇异矩阵, $V \in \mathbf{R}^{q \times q}$ 称为右奇异矩阵, 且均为正交矩阵; $\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r)$, 为对角矩阵。对角矩阵 Σ 中的元素 $\sigma_i (i=1, 2, \dots, r)$ 称作 H 的奇异值, 且奇异值为降序排列, 即 $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r \geq 0, r = \min(p, q)$ 为矩阵的 H 秩。

2) 求相邻两个奇异值之间的差值

若 k 阶奇异值与 $k-1$ 阶奇异值之差最大, 且与 $k+1$ 阶奇异值之差最小, 即 $\max(\sigma_k - \sigma_{k-1}), \min(\sigma_k - \sigma_{k+1})$ 时, 则将此时的 k 值确定为奇异值最佳有效秩阶次。

3) 信号的 VMD 分解

将 k 设定为 VMD 分解的最优 K 值并对信号进行分解, 得到 K 个 IMF 分量。

4) 计算 K 个 IMF 分量的排列熵值, 对一个长度为 N 的 IMF 分量进行相空间重构, 得到矩阵

$$Y = \begin{bmatrix} u(1) & u(1+t) & \cdots & u(1+(m-1)t) \\ u(2) & u(2+t) & \cdots & u(2+(m-1)t) \\ u(j) & u(j+t) & \cdots & u(j+(m-1)t) \\ \vdots & \vdots & \vdots & \vdots \\ u(M) & u(M+t) & \cdots & u(M+(m-1)t) \end{bmatrix} \quad (5)$$

式中: m 为嵌入维数, t 为延迟时间, $M = N - (m-1)t$ 。

将矩阵 Y 中的每行按升序重新排列, 得到向量中各元素位置的列索引构成的一组符号序列:

$$S(l) = \{j_1, j_2, \dots, j_m\}, l = 1, 2, \dots, d \quad (6)$$

式中: m 维相空间映射不同的符号序列总共有 $m!$ 种, $d \leq m!$ 。

每一种符号序列出现的次数 t 与 $m!$ 种符号序列的总次数 M 的比值作为该符号序列出现的概率, 即:

$$P_j = \frac{t}{M}, j = 1, 2, \dots, d \quad (7)$$

进而得到排列熵的计算式为:

$$H_{pe} = - \sum_{j=1}^d P_j \ln(P_j) \quad (8)$$

将排列熵值进行归一化处理,即:

$$0 \leq H'_{pe} = \frac{H_{pe}}{\ln(m!)} \leq 1. \quad (9)$$

对每一个 IMF 分量都进行排列熵的计算,可以得到 K 个 IMF 分量的排列熵值。

5) 信号重构

排列熵值的大小表示时间序列的随机程度,熵值越小,说明时间序列越简单、规则;反之,熵值越大,则时间序列越复杂、随机。因此,将归一化后的排列熵值大于 0.8 的 IMF 分量剔除,对剩余 K' 个 IMF 分量进行重构,即可得到去噪后的信号 \hat{X} ,信号重构的计算式为:

$$\hat{X} = \sum_{i=1}^{K'} u_i. \quad (10)$$

2 多特征融合提取方法

2.1 梅尔频率倒谱系数

梅尔频率倒谱系数(Mel frequency cepstral coefficients, MFCC)是一种广泛应用于音频场景和语音识别的特征参数,其计算简单、区分能力较为突出^[16]。MFCC 提取信号特征的过程如下。

1) 语音信号一般需要经过预加重、分帧以及加窗处理,变成单帧的短时信号,而本研究的声发射信号在进行特征提取之前已经是单帧的信号,可将每一帧信号视为一组信号进行处理。

2) 对声发射信号作快速傅里叶变换,得到频域数据

$$X(h) = \sum_{n=0}^{N-1} x(n) e^{-\frac{j2\pi hn}{N}}, 0 \leq h \leq N. \quad (11)$$

3) 对频域数据取模后再平方,得到信号的功率谱

$$E(h) = |X(h)|^2. \quad (12)$$

4) 将信号的功率谱通过 Q 个 Mel 滤波器组进行计算,得到:

$$S(i) = \sum_{h=0}^{N-1} E(h) H_i(h), 0 \leq i \leq Q. \quad (13)$$

式中, $H_i(h)$ 为第 i 个滤波器的传递函数,其计算式为:

$$H_i(h) = \begin{cases} 0, & h < f(i-1); \\ \frac{h-f(i-1)}{f(i)-f(i-1)}, & f(i-1) \leq h \leq f(i); \\ \frac{f(i+1)-h}{f(i+1)-f(i)}, & f(i) \leq h \leq f(i+1); \\ 0, & h > f(i+1). \end{cases} \quad (14)$$

式中, $f(i)$ 为中心频率。

5) 将 $S(i)$ 取对数并进行离散余弦变换,可以得到:

$$MFCC(a) = \sum_{i=0}^Q S(i) \cos \frac{\pi a(i-0.5)}{Q}. \quad (15)$$

式中, a 为 Mel 频率倒谱系数的个数,即特征向量的维数。 a 的取值范围通常为 12~16,增大该值会使得计算量相应增加^[17],因而本研究中 MFCC 作为特征向量时的维数确定为 12 维。

2.2 短时能量

短时能量(short-time energy, SE)是对声音信号在时域上的分析。由于声发射信号是一种非线性、非平稳信号,能量会随时间变化,因此引入短时能量作为声发射信号在时域方面的特征。短时能量的计算式为:

$$SE_n = \sum_{m=0}^{N-1} x_n^2(m). \quad (16)$$

式中: $x_n(m)$ 为输入的第 n 帧信号; N 为一帧信号的长度; SE_n 为第 n 帧信号的能量,即短时能量。

2.3 谱质心

谱质心(spectral centroid, SC)是描述音色属性的重要物理参数之一,是频率成分的重心^[18]。对信号在一定频率范围内的能量进行加权平均,便可得到该信号的谱质心,计算式为:

$$SC = \frac{\sum_{i=1}^n f_i \cdot E(f_i)}{\sum_{i=1}^n E(f_i)} \tag{17}$$

式中: f_i 为信号的频率, $E(f_i)$ 为信号的能量谱, SC 为信号做离散傅里叶变换的谱质心。

2.4 特征融合

将上述 3 个特征向量以列向量的形式进行组合,最终得到一个融合的特征向量

$$\mathbf{F} = [F_1, F_2, \dots, F_{13}, F_{14}] \tag{18}$$

式中: F_1, F_2, \dots, F_{12} 为 MFCC,表征信号的频域特征; F_{13} 为 SE,表征信号的时域特征,与 MFCC 在时频域起互补作用; F_{14} 为 SC,反映信号的频率分布和能量分布情况。

3 建立 MVO-SVM 模型

SVM 是 Vapnik^[19]在统计学习理论和结构风险最小化的基础上提出的一种通用学习方法,该方法适合解决小样本和非线性问题。MVO 是 Mirjalili 等^[20]提出的一种基于物理机理的启发式优化算法,具有待调节的参数少、搜索效率高及优化能力强等优点,已经被成功应用于许多工程问题中。SVM 在应用过程中,需要提前设置合适的惩罚参数 γ 。本研究利用 MVO 对 SVM 的参数进行寻优,可以避免因人工选取参数不合适导致模型分类精度降低问题。利用训练集样本作为 SVM 的输入数据,并引入 MVO 算法优化 SVM,从而建立 MVO-SVM 模型。如图 1 所示,MVO-SVM 模型的建立过程包括 5 个步骤。

1) MVO 通过随机初始化产生宇宙 X_i^j ,将惩罚参数 C 和核函数参数 γ 作为宇宙的分量,设定惩罚参数 C 和核函数参数 γ 的取值区间为 $[0.1, 20]$,即宇宙分量的上下界。

2) 定义 SVM 对训练数据的分类误差作为 MVO 优化 SVM 的适应度函数,当适应度函数达到最小值时,对应的宇宙分量作为当前最优分量。

3) 依据式(20)更新宇宙。

$$x_i^j = \begin{cases} X_j + TDR \times ((ub_j - lb_j) \times r_4 + lb_j), & r_2 < WEP, r_3 < 0.5; \\ X_j - TDR \times ((ub_j - lb_j) \times r_4 + lb_j), & r_2 < WEP, r_3 \geq 0.5; \\ x_i^j, & r_2 \geq WEP. \end{cases} \tag{20}$$

式中: x_i^j 和 X_j 分别为第 i 个宇宙和当前最优宇宙的第 j 维参数; ub_j, lb_j 分别为第 j 维宇宙分量的上、下界; r_2, r_3, r_4 为 $[0, 1]$ 内的随机数; TDR 和 WEP 为 MVO 算法的两个控制参数。

4) 当算法运行达到最大迭代次数时,停止更新宇宙,此时输出的全局最优宇宙即为惩罚参数 C 和核函数参数 γ 的最优值。

5) 以惩罚参数 C 和核函数参数 γ 的最优值重构 SVM 模型。

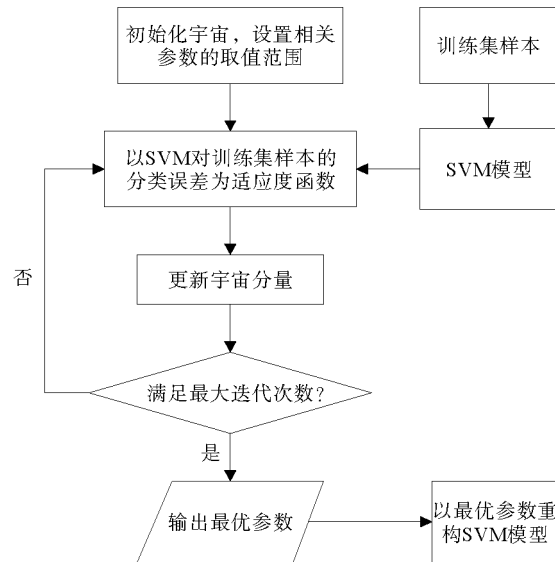


图 1 MVO-SVM 模型的建立过程

Fig. 1 Establishment proceeding of MVO-SVM model

4 实验分析

4.1 实验方案

实验室模拟岩石声发射信号,声发射信号采集设备的工作原理如图 2 所示。




图 2 声发射信号采集设备的工作原理

Fig. 2 Working principle of acoustic emission signal acquisition equipment

声发射信号的采集使用江西理工大学自主研发的 PIE-3-L 型传感器如图 3 所示,传感器的采样频率为 145 kHz,声发射信号的采样点数为 4 000。实验时,在传感器与岩石的接触面之间涂抹少量黄油,然后将传感器放置于岩石的固定位置。

在距离声发射传感器 20 cm 处进行 4 种不同信号的采集测试:①爆破信号。将鞭炮置于岩石底下,用鞭炮爆炸产生的信号模拟矿山现场岩石爆破产生的信号;②断铅信号。按国际无损检测界规定,选择 0.5 mmHB 铅笔芯进行断铅实验,以模拟岩石破断声发射信号;③电钻信号。利用电钻对岩石进行钻孔,模拟矿山现场的工况声源;④敲击信号。用金属棒保持一定的力度敲击岩石,模拟矿山现场的另一工况声源。实验分别采集不同类型的信号各 105 组,总计采集到数据 420 组。



图 3 声发射信号采集装置

Fig. 3 Acquisition device of acoustic emission signal

4.2 改进的 VMD 去噪

从采集的声发射信号中取一帧长度为 4 000 点的信号,通过计算信号的奇异值最佳有效秩阶次,得到 VMD 分解预设的分量个数 $K=3$,再用 VMD 算法对信号进行分解得到 IMF_1 、 IMF_2 、 IMF_3 ,进而计算 3 个 IMF 分量的排列熵值分别为 0.442 1、0.504 1、0.845 5,最后确定 IMF_1 和 IMF_2 为最优分量并重构,重构后的信号如图 4 所示。由图 4 可见,改进的 VMD 去噪后声发射信号波形较为光滑,在剔除大部分噪声的同时保留了声发射信号的主要特征。对采集的多组声发射信号分别运用该方法去噪,均能达到较好的效果。




图 4 改进的 VMD 去噪结果

Fig. 4 Denoising results of improved VMD

原始信号分别经 EEMD、小波阈值和改进的 VMD 去噪处理后的频谱如图 5 所示。图 5(a)为原始声发射信号的频谱,信号包含了部分高频噪声,频谱分布范围宽广。图 5(b)为 EEMD 去噪后的信号频谱,可以

看出 EEMD 去噪效果一般,无法抑制大部分噪声。图 5(c)为小波阈值去噪后的信号频谱图,表明小波阈值去噪能抑制高频噪声,对低频噪声也能起到较好的抑制作用,但该方法需要人为设定阈值,在信号重构时会丢失部分有用信息。图 5(d)为改进的 VMD 去噪频谱图,可以看出,该方法对低频和低频噪声均能达到良好的抑制作用,且去噪后的频谱集中分布于某一频率,与 EEMD 去噪和小波阈值去噪算法相比,改进的 VMD 去噪算法效果更好。




图 5 原始声发射信号及各方法去噪后的频谱

Fig. 5 Spectrum of original signal and denoising by various methods

为定量评价改进的 VMD 去噪算法的性能,用信噪比(signal-to-noise ratio, SNR)对 3 种算法的去噪效果进行比较,结果见表 1。

由表 1 可见,相比于 EEMD、小波阈值去噪,改进的 VMD 去噪算法的 SNR 值分别提高了 5.23、0.84 dB,说明改进的 VMD 降噪方法相对较好。

4.3 融合特征向量提取

利用融合的特征向量对采集的爆破、断铅、电钻和敲击信号进行特征提取,再对所有信号样本的特征值进行归一化处理。为展示不同类别信号样本的差异,表 2 列出了每一类信号中 4 个样本的 14 维特征值。其中, $F_1 \sim F_{12}$ 为 MFCC 的 12 维特征参数, F_{13} 为 SE 的一维特征参数, F_{14} 为 SC 的一维特征参数。由表 2 可见,不同类别信号的特征参数存在较大差异。

表 1 3 种去噪算法参数对比

Tab. 2 Parameters comparison of three denoising algorithm

指标	EEMD	小波阈值	改进的 VMD
SNR/dB	7.84	12.23	13.07

表 2 4 类信号的特征参数对比

Tab. 2 Comparison of characteristic parameters of four types of signals

类别	F_1	F_2	F_3	F_4	F_5	F_6	F_7	F_8	F_9	F_{10}	F_{11}	F_{12}	F_{13}	F_{14}
1	-9.3	0.6	-4.2	3.5	-7.1	3.4	-1.3	3.8	-0.1	3.6	1.3	0.6	3780.9	2 618.7
1	5.6	-15.1	-0.7	-4.9	-7.4	-1.3	1.5	-1.3	-0.2	2.4	3.2	0.1	139.8	1 725.4
1	-6.3	-7.3	-3.3	-5.1	-9.1	-0.9	2.0	0.9	-1.1	1.7	1.0	0	1674.8	2 241.4
1	-10.6	1.7	-4.6	2.1	-9.7	4.2	1.2	7.7	3.4	6.3	2.3	0.7	3637.3	2 145.7
2	7.2	1.6	7.1	-3.2	-4.0	4.0	7.3	5.2	3.3	3.1	1.1	-0.3	97.4	880.8
2	12.2	-0.5	2.4	-6.2	-4.4	-0.6	-2.1	-3.0	1.2	0.9	-0.1	-0.4	335.1	819.5
2	7.3	2.0	8.0	-5.4	-2.2	4.2	6.7	4.2	4.1	2.4	1.6	0	194.6	770.6
2	8.5	4.5	7.4	0	0.8	7.6	6.8	2.1	0.3	0.7	0.3	-0.4	63.5	562.7
3	-17.2	10.5	-12.2	11.1	-4.8	10.8	-2.0	9.8	2.6	7.1	1.2	0.9	7 028.8	3 540.9
3	-10.1	10.4	-6.5	7.0	-4.2	7.6	0.3	10.4	4.0	6.1	1.2	0.9	7 236.4	1 824.7
3	-13.6	10.8	-9.1	11.1	-3.9	10.0	-0.1	9.5	2.0	5.8	0.8	0.7	6 749.7	2 632.9
3	-14.6	10.8	-9.4	10.8	-3.4	11.5	-1.0	8.6	3.5	7.5	1.4	1.0	6 813.5	2 921.7
4	-8.1	-7.6	-3.1	8.3	2.1	3.9	-1.2	1.6	0.9	3.0	1.3	0.7	1 405.3	3 593.7
4	-3.5	-12.4	-4.0	4.0	6.5	8.1	2.6	0.5	4.6	6.4	1.1	-0.5	752.2	3 261.3
4	-5.4	-4.6	-8.3	3.3	0.9	7.7	1.2	4.7	5.4	7.4	1.9	0.4	2 497.6	2 380.7
4	3.3	-13.1	-7.8	-1.7	2.2	-0.8	-0.6	4.0	5.2	2.8	0.7	0.4	642.7	2 163.9

4.4 声发射信号识别

1) 信号预处理。利用改进的 VMD 方法对采集的 4 类信号共计 420 组数据进行去噪处理。

2) 构建融合特征向量,将多个特征参数融合作为分类识别的特征向量。划分训练数据和测试数据,从已有的 4 类信号共 420 组数据中,按照训练数据与测试数据为 4 : 1 的划分方式对信号进行随机分层采样,以保证训练数据和测试数据中的类别数目均衡。设定爆破信号的标识类别为 1,断铅信号的标识类别为 2,电钻信号的标识类别为 3,敲击信号的标识类别为 4。

3) 将训练集和测试集分别作归一化处理。目的是将所有的特征值大小限定在 $[0,1]$,防止某个特征值过大或者过小。

4) 建立 MVO-SVM 模型。把 MVO 算法寻优得到的模型参数作为惩罚参数、核函数参数。采用 RBF 核函数训练 SVM 模型,利用训练好的 SVM 模型对测试集分类,结果如图 6 所示。

图 6 中,测试集样本数量为 84 个,类别标签为 1、2、3、4,样本实际标签与样本预测标签重合表示该样本被正确识别。由图 6 可见,类别 1 样本中有 1 个样本被误识别为类别 3、类别 2 样本中有 1 个样本被误识别为类别 4,类别 3 样本中有 1 个样本被误识别为类别 2,类别 4 样本中有 1 个样本被误识别为类别 1。综上,MVO-SVM 对爆破、断铅、电钻及敲击信号的识别准确率为 95.24%。




图 6 MVO-SVM 分类识别结果

Fig. 6 Classification and recognition results of MVO-SVM

为了测试去噪方法的有效性,采用改进的VMD去噪、EEMD去噪、小波阈值去噪等方法,对比不同特征提取方法在MVO-SVM模型上的识别准确率,如表3所示。

由表3可知:①在不同的去噪方法下,采用融合特征向量提取声发射信号的特征,可以获得较高的识别准确率,而单一的特征向量则无法获得较好的效果,且仅SE和SC作为特征向量时,声发射信号的识别准确率均较低;②在不同的特征提取方法下,利用改进的VMD去噪后识别效果整体上优于EEMD和小波阈值去噪方法;③在EEMD和小波阈值去噪方法上,单一特征向量的识别准确率相同,而融合特征向量的识别准确率显著提高,且在两种去噪方法上的识别效果存在差异。因此,基于改进的VMD与融合特征向量构建的声发射信号识别方法准确率高,对4种不同类别信号均能进行有效识别。

5 结论

1) 提出一种改进的VMD算法,利用奇异值最佳有效秩阶次确定VMD分解的IMF分量个数 K ,并利用排列熵筛选出最优IMF分量并重构。将改进的VMD算法应用于声发射信号去噪,提高了信号的信噪比。

2) 利用MFCC、SE和SC等3种特征构建融合特征向量 F ,以此计算信号的特征值,使各类信号样本的特征值差异更加明显,为MVO-SVM模型识别声发射信号提供了新的方法。

3) 构建融合特征向量的特征提取方法,在EEMD去噪和小波阈值去噪的基础上均可以取得较好的识别效果,而改进VMD去噪的融合特征向量的识别准确率最高,可以达到95.24%。表明基于改进的VMD去噪与融合特征向量构建的岩石声发射信号识别方法是可行的,能有效识别出声发射信号。

本研究提出的基于改进VMD去噪与多特征融合的声发射信号识别方法对室内模拟岩石声发射信号可以达到较高的识别准确率,但对于实际矿山岩石声发射信号的识别还需进一步验证,后续将针对现场岩石声发射信号进行研究,建立泛化性能更好的分类模型,以期得到较好的识别效果,为实际工程应用提供参考。

参考文献:

[1]付斌,周宗红,王海泉,等.大理岩单轴循环加卸载破坏声发射先兆信息研究[J].煤炭学报,2016,41(8):1946-1953.
FU Bin,ZHOU Zonghong,WANG Haiquan,et al.Precursor information study on acoustic emission characteristics of marble under uniaxial cyclic loading-unloading[J].Journal of China Coal Society,2016,41(8):1946-1953.

[2]孙强,薛晓辉,朱术云.岩石脆性破坏临界信息综合识别[J].固体力学学报,2013,34(3):311-319.
SUN Qiang,XUE Xiaohui,ZHU Shuyun.The identification method of critical information for rock brittle failure[J].Chinese Journal of Solid Mechanics,2013,34(3):311-319.

[3]刘东瀛,邓艾东,刘振元,等.基于EMD与相关系数原理的故障声发射信号降噪研究[J].振动与冲击,2017,36(19):71-77.
LIU Dongying,DENG Aidong,LIU Zhenyuan,et al.Denoising method for fault acoustic emission signals based on the EMD and correlation coefficient[J].Journal of Vibration and Shock,2017,36(19):71-77.

[4]戴聪聪,程铁栋,宗路,等.基于改进EEMD的红砂岩声发射信号的频谱特性研究[J].振动与冲击,2018,37(16):118-123.
DAI Congcong,CHENG Tiedong,ZONG Lu,et al.A study on spectrum characteristics of red sandstone acoustic emission signals based on improved EEMD[J].Journal of Vibration and Shock,2018,37(16):118-123.

[5]姜长泓,王龙山,尤文,等.基于平移不变小波的声发射信号去噪研究[J].仪器仪表学报,2006,27(6):607-610.

表3 不同去噪方法下各种特征提取方法的识别准确率
Tab.3 Recognition accuracy of various machine learning methods under different noise reduction methods

去噪方法	特征向量	识别准确率/%
改进的 VMD	MFCC	91.67
	SE	85.71
	SC	82.14
	融合特征向量	95.24
EEMD	MFCC	86.90
	SE	82.14
	SC	80.95
	融合特征向量	91.67
小波阈值	MFCC	88.09
	SE	82.14
	SC	80.95
	融合特征向量	94.05

- JIANG Changhong, WANG Longshan, YOU Wen, et al. Research on acoustic emission signal denoising based on translation invariant wavelet[J]. Chinese Journal of Scientific Instrument, 2006, 27(6): 607-610.
- [6] LIU H H, HAN M H. A fault diagnosis method based on local mean decomposition and multi-scale entropy for roller bearings[J]. Mechanism and Machine Theory, 2014, 75: 67-78.
- [7] JIANG F, ZHU Z C, LI W, et al. Robust condition monitoring and fault diagnosis of rolling element bearings using improved EEMD and statistical features[J]. Measurement Science & Technology, 2014, 25(2): 1-14.
- [8] 李红延, 周云龙, 田峰, 等. 一种新的小波自适应阈值函数振动信号去噪算法[J]. 仪器仪表学报, 2015, 36(10): 2200-2206.
LI Hongyan, ZHOU Yunlong, TIAN Feng, et al. Wavelet-based vibration signal de-noising algorithm with a new adaptive threshold function[J]. Chinese Journal of Scientific Instrument, 2015, 36(10): 2200-2206.
- [9] 施克仁. 无损检测新技术[M]. 北京: 清华大学出版社, 2007: 53-106.
SHI Keren. New technology of nondestructive testing[M]. Beijing: Tsinghua University Press, 2007: 53-106.
- [10] 姚旭龙, 张艳博, 刘祥鑫, 等. 岩石破裂声发射关键特征信号优选方法[J]. 岩土力学, 2018, 39(1): 375-384.
YAO Xulong, ZHANG Yanbo, LIU Xiangxin, et al. Optimization method for key characteristic signal of acoustic emission in rock fracture[J]. Rock and Soil Mechanics, 2018, 39(1): 375-384.
- [11] 司莉, 毕贵红, 魏永刚, 等. 基于 RQA 与 SVM 的声发射信号检测识别方法[J]. 振动与冲击, 2016, 35(2): 97-103.
SI Li, BI Guihong, WEI Yonggang, et al. Detection and identification of acoustic emission signals based on recurrence quantification analysis and support vector machines[J]. Journal of Vibration and Shock, 2016, 35(2): 97-103.
- [12] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [13] 唐贵基, 王晓龙. 参数优化变分模态分解方法在滚动轴承早期故障诊断中的应用[J]. 西安交通大学学报, 2015, 49(5): 73-81.
TANG Guiji, WANG Xiaolong. Parameter optimized variational mode decomposition method with application to incipient fault diagnosis of rolling bearing[J]. Journal of Xi'an Jiaotong University, 2015, 49(5): 73-81.
- [14] BANDT C, POMPE B. Permutation entropy: A natural complexity measure for time series[J/OL]. Physical Review Letters, 2002, 88(17). DOI: 10.1103/PhysRevLett.88.174102.
- [15] 赵昕海, 张术臣, 李志深, 等. 基于 VMD 的故障特征信号提取方法[J]. 振动、测试与诊断, 2018, 38(1): 11-19.
ZHAO Xinhai, ZHANG Shuchen, LI Zhishen, et al. Application of new denoising method based on VMD in fault feature extraction[J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(1): 11-19.
- [16] 李虹, 徐小力, 吴国新, 等. 基于 MFCC 的语音情感特征提取研究[J]. 电子测量与仪器学报, 2017, 31(3): 448-453.
LI Hong, XU Xiaoli, WU Guoxin, et al. Research on speech emotion feature extraction based on MFCC[J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(3): 448-453.
- [17] 张文克. 融合 LPCC 和 MFCC 特征参数的语音识别技术的研究[D]. 湘潭: 湘潭大学, 2016.
ZHANG Wenke. The research of fusion LPCC and MFCC feature parameters in speech recognition technology[D]. Xiangtan: Xiangtan University, 2016.
- [18] 沈飞, 陈超, 徐佳文, 等. 谱质心迁移在变工况轴承故障诊断的应用[J]. 仪器仪表学报, 2019, 40(5): 99-108.
SHEN Fei, CHEN Chao, XU Jiawen, et al. Application of spectral centroid transfer in bearing fault diagnosis under varying working conditions[J]. Chinese Journal of Scientific Instrument, 2019, 40(5): 99-108.
- [19] VAPNIK V. The nature of statistical learning theory[M]. Berlin: Springer, 1995.
- [20] MIRJALILI S, MIRJALILI S M, HATAMLOU A. Multi-verse optimizer: A nature-inspired algorithm for global optimization[J]. Neural Computing and Applications, 2016, 27(2): 495-513.

(责任编辑: 齐敏华)