

基于多特征信息融合的砂岩破裂状态识别方法*

杨丽荣, 江川, 刘吉顺, 戴聪聪, 程铁栋

(江西理工大学机电工程学院 赣州, 341000)

摘要 针对岩体在受外界应力时内部破裂状态靠经验难以准确判断的问题,提出了一种多特征信息融合和最小二乘支持向量机(least square support vector machine,简称LSSVM)的岩石破裂状态识别方法。首先,利用改进集合经验模态分解(ensemble empirical mode decomposition,简称EEMD)对砂岩声发射信号进行分解,得到一组有效的平稳本征模函数(intrinsic mode function,简称IMF)分量,对各IMF分量进行自回归(auto regressive,简称AR)建模,提取AR模型系数作为时域特征向量;其次,通过对双谱矩阵进行奇异值分解,分析了砂岩各破碎状态声发射信号的频域特征;最后,利用局部线性嵌入(locally linear embedding,简称LLE)进行特征约简,并将融合特征向量进行归一化处理作为LSSVM的输入,砂岩破裂状态作为输出,采用粒子群算法(particle swarm optimization,简称PSO)对参数自动寻优,实现对岩石破裂状态的诊断识别。结果表明:融合特征具有较强的鲁棒性,且相对单一时域特征识别率提高了6%。

关键词 砂岩破裂;多特征融合;局部线性嵌入;最小二乘支持向量机;模式识别

中图分类号 TH39

引言

由于岩石内部细微间隙的存在,外力的作用使内部间隙发生闭合、拓展和贯通,并以弹性波的方式来释放部分能量,这个过程称为声发射。由于传播介质特性对弹性波的传播会造成干扰,且受传感器响应频率特性和环境噪声的影响,采集的声发射信号是一种复杂的非平稳信号。因此,有效的特征提取方法是声发射研究的关键难题^[1-2],对岩石失稳监测、揭示岩石破裂过程具有重要意义。

张艳博等^[3]利用希尔伯特-黄变换(Hilbert-Huang transform,简称HHT)研究岩石破裂声发射特性,将岩石破裂分为3个阶段,确定了声发射信号的有效频率是20 kHz~120 kHz。鲜晓东等^[4]利用中值滤波-奇异值分解及AR模型相结合的方法,在避免计算模型阶次的同时,实现了岩石声发射信号到达时间的自动识别。凌同华等^[5]采用经验模态分解(empirical mode decomposition,简称EMD)分析了冲击载荷作用下的岩石声发射信号,结果表明EMD有较好的适应性。Jia等^[6]提出了一种基于EEMD和灰色理论的振动信号去噪新方法,结果表明能有效地去除噪声。以

上研究是通过单一时域、频域或能量特征来分析岩石内部状态变化,采用多特征融合识别技术涉及很少。

笔者采用改进EEMD-AR和双谱奇异值分解相结合的方法,提取构造表征砂岩破裂各状态的多维特征向量。采用LLE进行可视化特征约简,将融合特征向量进行归一化处理作为LSSVM的输入,砂岩破裂状态作为输出,采用PSO对参数自动寻优,实现对岩石破裂状态的诊断识别。

1 基于改进EEMD-AR的时域特征提取

时间序列的AR模型参数包含了岩体内部破裂状态的重要信息,但由于时间序列模型仅对平稳过程具有较好的分析效果^[7],因此对于非平稳过程的声发射信号,须将其分解成有效的平稳分量,再进行AR模型特征提取。戴聪聪等^[8]提出了改进的EEMD方法,通过引入云模型理论克服了EEMD根据经验选取有效IMF分量的缺陷。

笔者采用改进的EEMD与AR模型相结合的方法进行时域特征提取,改进的EEMD-AR时域特征

* 国家自然科学基金资助项目(51464017);江西省教育厅科技资助项目(GJJ190452)

收稿日期:2020-06-29;修回日期:2020-09-06

提取步骤如下:

1) 原始声发射信号 $y(t)$ 的云向量 $\bar{v} = (Ex, En, He)$ 。其中: Ex 表示期望值 (expected value); En 表示特征熵 (entropy); He 表示超熵 (hyper entropy)。

2) 通过 EEMD 分解原始声发射信号 $y(t)$, 得到 $IMF_k (k = 1, 2, \dots, n)$ 。

3) 计算各个 IMF 分量的云模型数字特征 $Ex_{imf}, En_{imf}, He_{imf}$ 组成的云向量 $\bar{v}_{IMF_k} = (Ex_{IMF_k}, En_{IMF_k}, He_{IMF_k})$ 。

4) 为得到原始信号与各个 IMF 分量云相似值, 需要先计算出 2 个云向量夹角的余弦, 即 $\cos(\bar{V}, \bar{u}_j) = \frac{\bar{V} \cdot \bar{V}_{IMF_k}}{\|\bar{V}\| \cdot \|\bar{V}_{IMF_k}\|}$, 其中, j 时间序列云向量 $\bar{u}_j = (Ex_j, En_j, He_j)$ 。

5) 通过分析多组信号来决定阈值大小, 去除小于阈值的 IMF 分量, 得到有效 IMF 分量。

6) 利用有效 IMF 分量建立 AR 模型, 得到 AR 模型回归参数构成的特征向量。

2 基于双谱奇异值分解的频域特征提取

双谱为三阶累积量的二维傅里叶变换, 双谱分析法能很好地消除高斯噪声^[9]。将砂岩不同破裂阶段下的信号进行双谱分析, 并对双谱高阶矩阵进行奇异值分解, 将提取的多个奇异谱值作为砂岩声发射信号频域特征向量。

设 $x(n)$ 为均值为 0 的 k 阶平稳随机信号, 其三阶累积量求解公式为

$$r(\tau_1, \tau_2) = E\{(n)x(n + \tau_1)x(n + \tau_2)\} \quad (1)$$

其中: τ 为信号延时变量。

三阶累积量的二维傅里叶变换公式为

$$B_x(\omega_1, \omega_2) = \sum_{\tau_1=-\infty}^{\infty} \sum_{\tau_2=-\infty}^{\infty} c_{3x}(\tau_1, \tau_2) e^{-j(\omega_1\tau_1 + \omega_2\tau_2)} \quad (2)$$

其中: ω 为信号的傅里叶变换。

奇异值分解是将包含原始信号信息的吸引子轨迹矩阵分解到一系列奇异值和奇异值矢量对应的时频子空间。矩阵奇异值属于矩阵的固有特征, 其大小表示了矩阵中对应噪声成分的大小, 由此定义奇异谱为

$$p_i = \lambda_i / \sum_{i=1}^r \lambda_i \quad (i = 1, 2, \dots, r) \quad (3)$$

其中: $(\sum_{k=1}^s \lambda_k / \sum_{k=1}^r \lambda_k) > 85\%$ 为矩阵的奇异值; r 为矩阵的秩; p_i 为整个系统中各个状态变量与所占能量的相对关系, 也称为由矩阵经奇异值分解得到的奇异谱。

为了使损失信息不太多, 又能达到减少变量的目的, 通常筛选前 s 个奇异谱累计贡献率大于 85% 的分量作为特征向量并降维, 即

$$(\sum_{k=1}^s \lambda_k / \sum_{k=1}^r \lambda_k) > 85\% \quad (4)$$

3 基于 PSO-LSSVM 的砂岩破裂状态分类方法

针对主元分析忽略原始信号的局部信息问题, 提出了一种无监督的 LLE 算法, 通过对局部线性处理实现数据的降维和可视化^[10]。利用多特征信息融合和 PSO-LSSVM 对砂岩破裂状态进行识别。图 1 为砂岩破裂状态识别方法流程图。

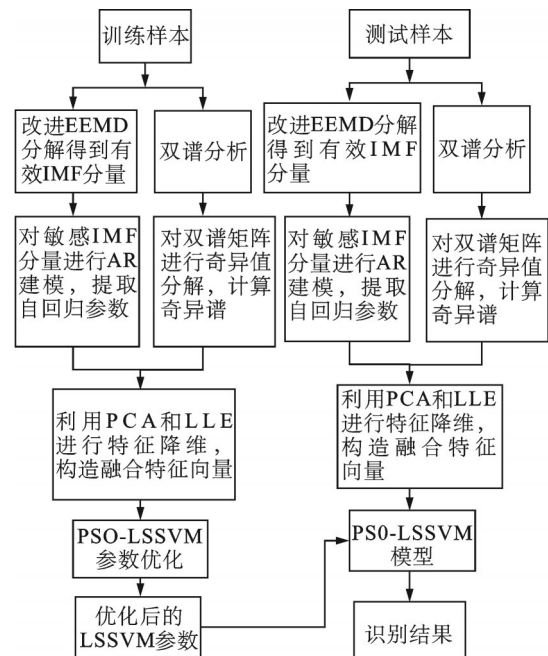


图 1 砂岩破裂状态识别方法流程图

Fig.1 Flow chart of identification method for sandstone fracture state

4 实验分析

4.1 岩石单轴加载实验

为了保证实验的普遍性和多样性, 实验选用不

同矿山的红砂岩。将岩体经钻孔取样机取出柱状岩芯,采用双端面磨石机打磨得到标准岩样。各岩样参数如表 1 所示。

表 1 实验岩样参数

Tab.1 Specifications of test rock samples mm		
试样编号	直径×高度	端面不平度
H1	49.96×99.96	—
H7	50.02×99.98	—
G15	49.98×100.04	<0.05
R10	50.01×100.02	—

实验采用位移加载控制模式,速率为 0.002 mm/s,声发射传感器为 SR15 型,其共振频率为 150 kHz;放大器增益为 40 dB,采样频率为 0.5 MHz,采样点数为 12 000。为了降低环境噪声的干扰,在探头的表面涂抹植物油,再将胶带缠绕在样品表面中间位置,加载实验装置如图 2 所示。

通过对红砂岩样品进行单轴压缩实验,得到不




图 2 加载实验装置图

Fig.2 Loading test device diagram

同规格红砂岩样品的应力-应变曲线,如图 3 所示。由图 3 可知,不同红砂岩失稳破坏的峰值应力不同,但单轴破坏过程都表现为 4 个阶段(0A 为压密阶段、AB 为弹性变形阶段、BC 为塑性变形阶段、CD 为失稳破坏阶段),4 个阶段比较明显的区别是应力应变曲线的斜率不同。

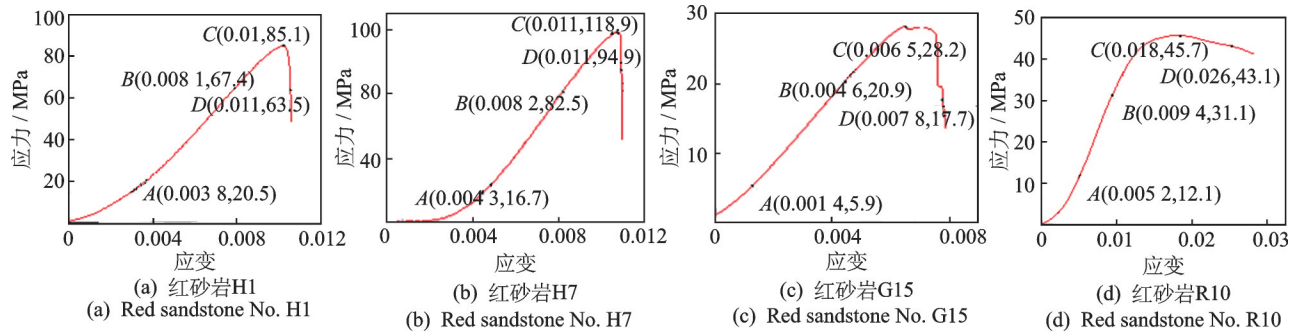


图 3 单轴压缩下不同规格红砂岩样品的应力-应变曲线

Fig.3 Stress-strain curves of different red sandstones under uniaxial compression

4.2 敏感 IMF 分量选择及时域特征提取

采集岩石破碎整个过程的声发射信号,根据时间顺序,4 个阶段各选取 100 组信号。选取应力为 9.83 MPa 的连续声发射信号进行分析,通过改进的 EEMD 算法对声发射时域波形进行分解,分解结果取前 8 个 IMF 波形,如图 4 所示。由图 4 可知,时间尺度较长、频率较低的分量分别为 IMF₅, IMF₆, IMF₇和 IMF₈,代表信号中的低频成分。

计算 IMF₁~IMF₈与原始信号的云相似值

$$\text{sim}(i, j) = \cos(\bar{\nu}_i, \bar{\mathbf{u}}_j) = \frac{\bar{\nu}_i \cdot \bar{\mathbf{u}}_j}{\|\bar{\nu}_i\| \cdot \|\bar{\mathbf{u}}_j\|} \quad (5)$$

其中: $\bar{\nu}_i = (Ex_i, En_i, He_i)$; $\bar{\mathbf{u}}_j = (Ex_j, En_j, He_j)$ 分别为 i, j 时间序列云向量。

IMF₁~IMF₈与原始信号的云相似值如表 2 所示。其中: $\text{sim}_q (q = 1, 2, \dots, 8)$ 为 IMF_n ($n = 1, 2, \dots, 8$) 与原信号的云相似值。可见,前 6 个 IMF 分量的相似值相对较大。

任意选择 10 组信号利用 EEMD 算法进行分解,将每个 IMF 分量的云相似值进行曲线拟合。图 5 为所有样本的云相似值拟合曲线。从图 5 可知, IMF₁, IMF₂, IMF₃ 的云相似值较大,包含更多原始信号的信息量,可以较好地表示原始信号特征。根据多次实验统计分析,选择阈值为 0.655,将 IMF₁, IMF₂, IMF₃ 确定为有效分量。

为了消除其他因素对模型的影响,对选取的前 3 个 IMF 分量进行能量归一化处理。

$$\hat{c}_i(t) = c_i(t) / \sqrt{\sum_{i=1}^N c_i^2(t)} \quad (6)$$

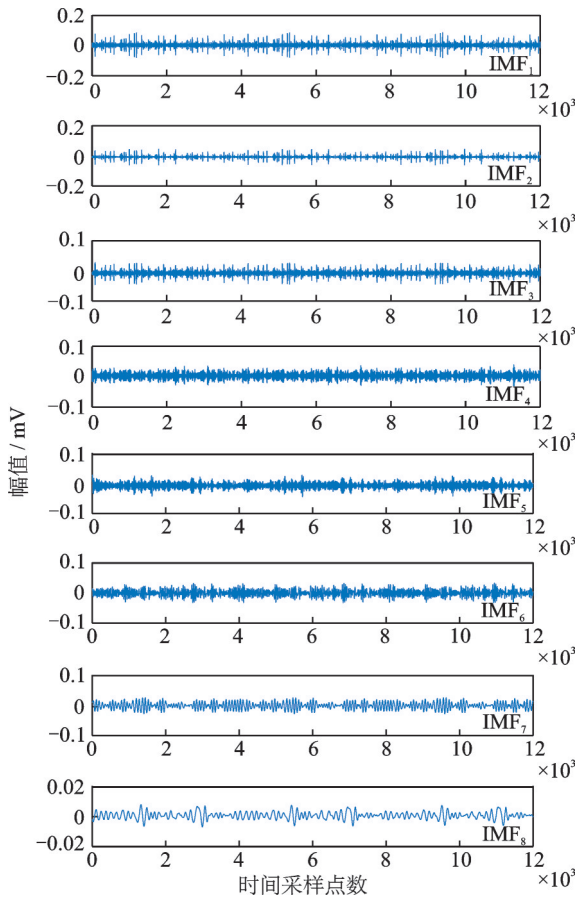


图 4 岩石声发射信号的前 8 个 IMF 波形

Fig.4 The first 8 IMF waveforms of rock acoustic emission signals

其中: $c_i(t)$ 为改进 EEMD 处理后得到的前 3 个 IMF 分量 ($i=1\sim 3$); $\hat{c}_i(t)$ 为能量归一化后的 IMF 分量。通过改进的 EEMD 算法,对砂岩同一阶段不

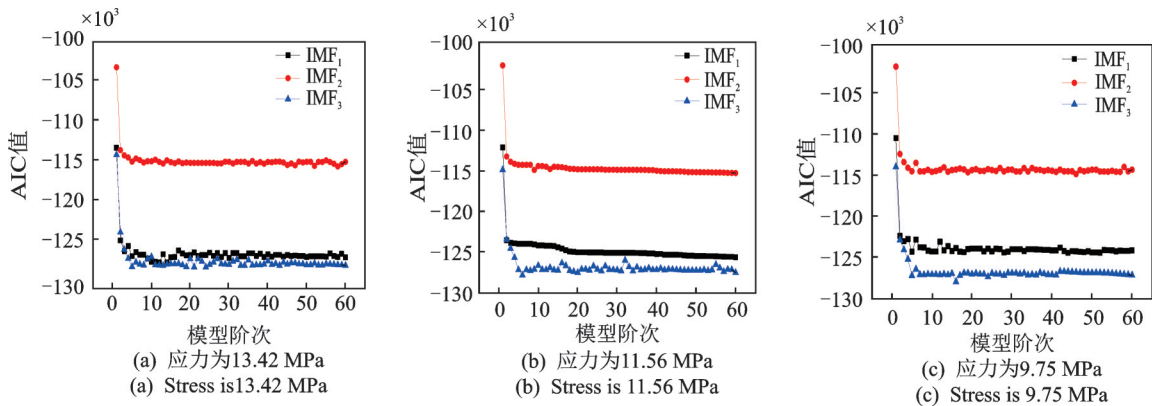


图 6 同一破裂阶段不同应力下 AIC 值随模型阶次变化

Fig.6 Changes of AIC values of different stresses with model order at the same fracture stage

任意选取多组信号建立 AR 模型,对分解的 3 个 IMF 分量进行预测来检验模型的准确度。限于篇幅,取第 1 破裂阶段下应力为 11.29 MPa

表 2 IMF₁~IMF₈与原始信号的云相似度
Tab.2 Similarity values of cloud between IMF₁~IMF₈ and original signal

sim ₁	sim ₂	sim ₃	sim ₄	sim ₅	sim ₆	sim ₇	sim ₈
0.943	0.912	0.663	0.317	0.339	0.127	0.093	0.037

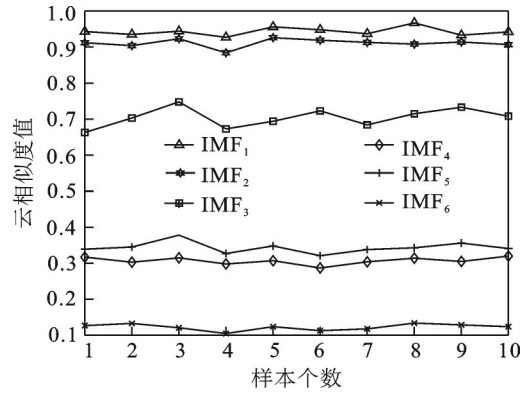


图 5 所有样本的云相似度拟合曲线图

Fig.5 Fitting curves of cloud similarity values for all samples

同应力和不同阶段某个应力作用下的有效 IMF 分量建立 AR 模型。由于 AR 模型预测的准确性与模型的阶次有关,模型定阶方法常用最佳准则函数法,笔者选用赤池信息准则 (Akaike information criterion, 简称 AIC)。图 6 为同一破裂阶段不同应力下 AIC 值随模型阶次变化。图 7 为不同阶段 AIC 值随模型阶次变化。结合图 6,7 可知,各 IMF 分量模型阶数大于 5 时,AIC 值波动相对来说很小。因此,提取各个 IMF 分量在 5 阶 AR 模型下的模型系数作为岩石不同破裂阶段的特征向量。

的信号进行验证。IMF 分量预测误差如图 8 所示。

由图 8 可知,AR 模型阶次为 5 时,IMF 分量预

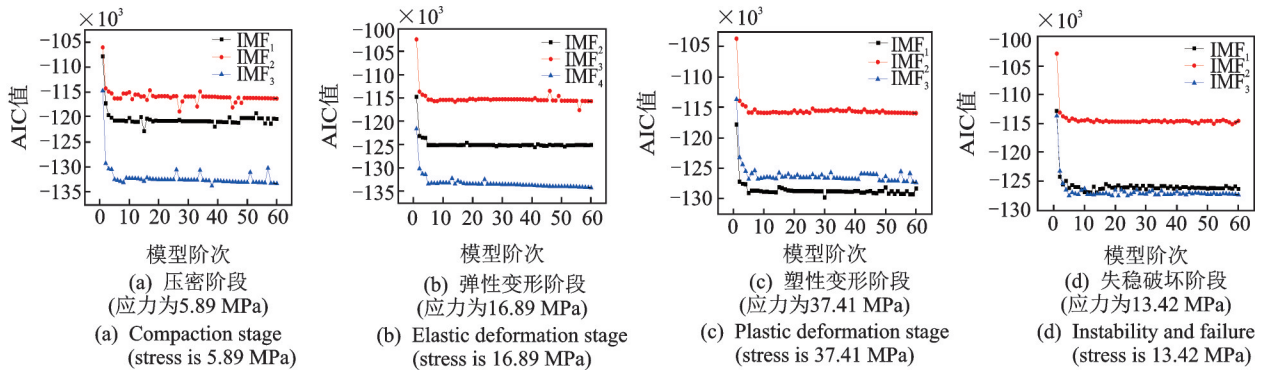


图7 不同阶段 AIC 值随模型阶次变化图

Fig.7 Variation of AIC values with model order at different stage




图8 IMF 分量预测误差图

Fig.8 IMF component prediction error diagram

测误差很小。同时,对该组信号进行 3 阶、4 阶和 6 阶 AR 建模,分别计算其预测误差值。通过对比分析,得到 5 阶 AR 模型下的各 IMF 分量预测值与原始信号最接近,能更好地反映原始信号特征。提取各 IMF 分量的 5 阶 AR 模型系数,构造 15 维特征向量作为时域特征向量

$$T_{ar} = [\varphi_{11}, \varphi_{12}, \dots, \varphi_{15}, \dots, \varphi_{31}, \dots, \varphi_{35}] \quad (7)$$

其中: $\varphi_{m,n}$ 为信号经改进 EEMD 分解后第 m 个 IMF 分量的第 n 阶模型系数。

4.3 频域特征提取

为了消除其他条件变化对采样信号的影响,在应用双谱分析之前,先对原始信号进行去均值及归一化处理,即

$$y(i) = [x(i) - \bar{x}] / s \quad (8)$$

其中: $\bar{x} = \sum_{i=1}^n x_i / n$; $s = \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 / n}$; n 为数据采样点数。

分别对同一破裂阶段不同应力下的声发射信号进行双谱分析,图 9 为各阶段不同应力的声发射信号双谱图。由图 9 可知,同一阶段不同应力的声

发射信号双谱图虽然有区别,但双谱图的形状差异较小,且体现出相同的特征。不同阶段的双谱图表现出明显的形状差异和特征差异,表明砂岩声发射信号的双谱特征可以较好地地区分岩石不同破裂阶段。

对双谱分析得到二维初始双谱特征矩阵的每一个元素取模,构成一个实矩阵。对实矩阵进行奇异值分解,得到多个奇异值。根据式(3)计算各个信号的奇异谱特征值,再根据式(4)提取累积贡献率大于 85% 的奇异谱分量作为砂岩破裂各阶段的特征。经过大量的数据处理发现:累计贡献率大于 85% 的奇异谱数量在岩石破裂不同阶段是不一样的,一般在 4~10 区间之内。因此,为了使构造的特征向量维数一致,统一选取前 10 个奇异谱构成频域特征向量 $T_{ho} \in R^{1 \times 10}$ 。

4.4 融合特征提取对比实验验证

选取 300 组样本,将时域特征向量 T_{ar} 与频域特征向量 T_{ho} 组成联合多特征向量,构成一个 300×25 的特征矩阵 M ,矩阵的每一行代表每个样本的联合多特征。

4.4.1 采用主元分析法进行特征降维

计算各主元的贡献率及累积贡献率,根据式(4)累积贡献率超过 85% 的准则,选择前 7 个累积贡献率大于 88% 的主元。

对于一个新的样本,按照联合特征向量的方法,构造出 25 维联合特征向量。向新的主元投影,得到降维后的特征向量 $T_{new} \in R^{1 \times 7}$ 。 T_{new} 中不同主元的二维和三维分布如图 10 所示。可见,采用 PCA 降维后,4 种状态的三维特征分布较分散,各状态有交叉混叠,且在第 1 阶段数据样本出现较多错判及漏判。

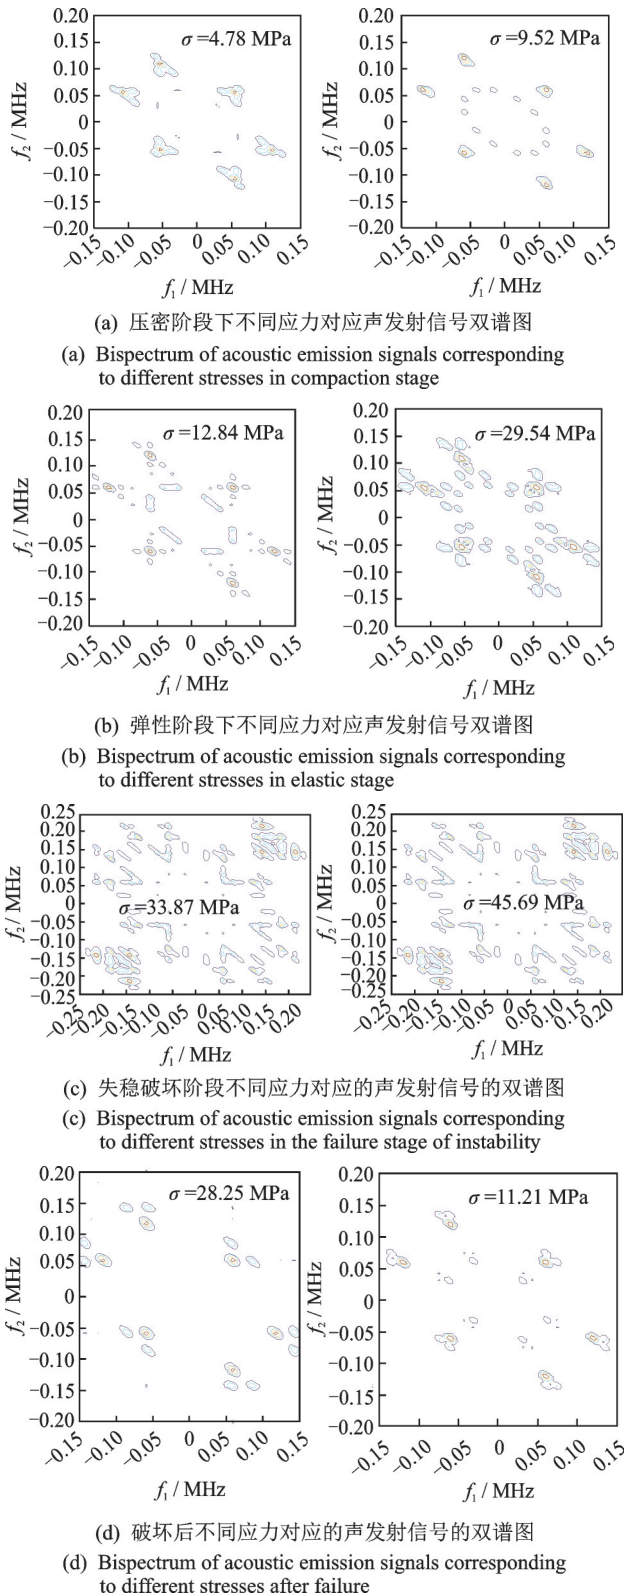


图 9 各阶段不同应力的声发射信号双谱图

Fig.9 Bispectrum of acoustic emission signals of different stresses at different stage

4.4.2 采用 LLE 算法进行特征降维

由于 LLE 算法受低维子空间维数 d 和近邻参数 k 选取的影响,采用极大似然估计法,确定砂

岩破裂各阶段声发射信号特征数据集的低维子空间维数 $d=4$;固定低维子空间维数 $d=4$,改变近邻参数 k 的取值,利用支持向量机(support vector machine,简称 SVM)对融合特征向量进行识别,分析比较不同 k 值时的识别率。分析结果表明, $k=5$ 时识别率最高,因此确定近邻参数 $k=5$ 。

利用 LLE 算法对样本数据降维,得到 4 维的融合特征向量 T'_{new} 的聚类效果如图 11 所示。可以看出,采用 LLE 降维后的聚类效果比 PCA 降维的聚类效果更集中,各阶段交叉混叠数目也明显减少,且样本漏判和错判率明显降低。

4.5 砂岩破裂状态识别分类

选取每种破裂状态训练样本 75 组,共计 300 组。测试样本各 25 组,共计 100 组。将 4 种不同破裂状态声发射信号提取的融合特征向量进行归一化处理,通过 PSO-LSSVM 算法建立砂岩破裂状态识别模型。对于局部搜索能力 c_1 和全局搜索能力 c_2 ,遵循 c_1 先大后小, c_2 先小后大的思想,经过多次实验分析,最终设定 $c_1=0.5, c_2=1.7$,种群数量为 50,迭代次数为 200。在时域特征集下搜索到的最佳惩罚因子 $\gamma=0.1, \sigma=187.267$;在频域特征集下为 $\gamma=0.1, \sigma=105.438$;在融合特征集下为 $\gamma=3.672, \sigma=55.924$ 。

用训练好的 PSO-LSSVM 多模式分类器对测试样本特征集进行分类预测,分别对时域特征向量集、频域特征向量集和 LLE 降维后的融合特征向量集采用 PSO-LSSVM 优化算法进行分类验证。不同特征的识别率比较如表 3 所示。

从表 3 可知,将信号的联合特征通过 LLE 提取融合特征用于岩石破裂状态分类,可以提高系统的识别率,采用融合特征后的识别率最高为 90%,相对于单一的时域特征识别提高了 6%。

为了进一步研究最小二乘支持向量机在分类方面的性能及 LLE 降维融合特征的性能,采用相同的样本类别分布,分别以 BP 神经网络、SVM 和 LSSVM 作为分类器对 LLE 降维融合特征进行识别。不同识别方法的识别率比较如表 4 所示。可以看出,采用不同的识别方法,4 个阶段的识别率相近。因此,LLE 降维的融合特征具有较强的鲁棒性;从总识别率上看,对于小样本的识别,LSSVM 优于 SVM 和 BP 神经网络。




图 10 不同主元的二维和三维分布

Fig.10 Two-dimensional and three-dimensional distributions of different principal components

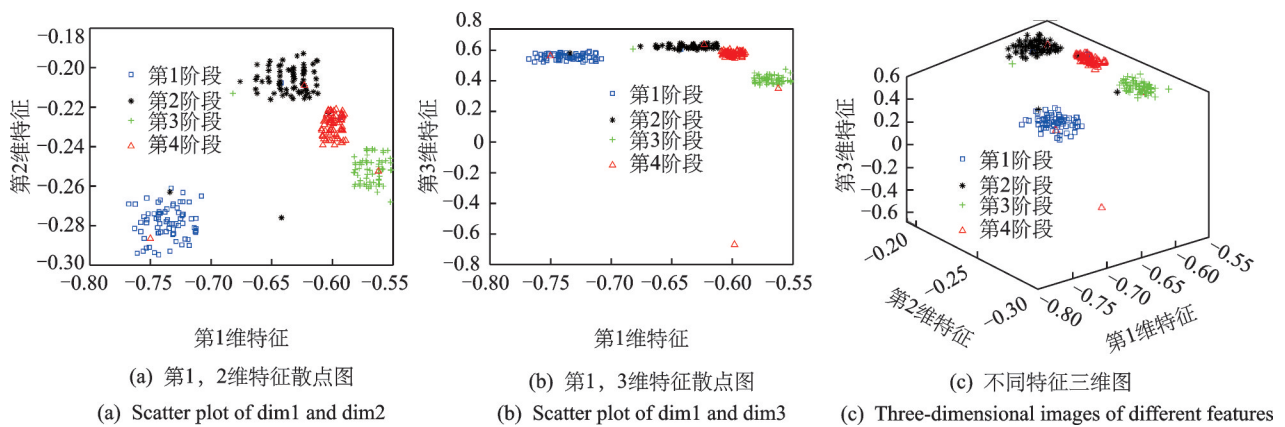


图 11 LLE算法降维后的融合特征的聚类效果

Fig.11 Clustering effect of fusion features after dimensionality reduction of LLE algorithm

表 3 不同特征的识别率比较

Tab.3 Comparison of recognition rates of different features

特征类型	第 1 阶段	第 2 阶段	第 3 阶段	第 4 阶段	总识别率
时域特征	0.84	0.84	0.88	0.80	0.840
频域特征	0.88	0.84	0.90	0.84	0.865
融合特征	0.92	0.88	0.92	0.88	0.900

表 4 不同识别方法的识别率比较

Tab.4 Comparison of recognition rates of different recognition methods

识别方法	第 1 阶段	第 2 阶段	第 3 阶段	第 4 阶段	总识别率
BP	0.80	0.84	0.88	0.76	0.82
SVM	0.84	0.88	0.84	0.80	0.84
LSSVM	0.88	0.84	0.88	0.80	0.85

5 结论

1) 提出了改进的 EEMD-AR 算法,即通过云相似度筛选有效 IMF 分量,利用有效 IMF 分量建

立 AR 模型,通过对比分析得到 5 阶 AR 模型效果最好,能够准确反映信号特征,同时验证了模型的准确性。提取各个 IMF 分量在 5 阶 AR 模型下的模型系数,作为岩石不同破裂阶段的时域特征向量。

2) 针对传统功率谱提取频域特征存在的缺陷,利用双谱分析了砂岩各破裂状态信号的双谱图。结果表明,不同状态的双谱图形状差异较大,易于区分。采用奇异值对双谱矩阵进行分解,根据累计贡献率原则,选取前 10 个奇异谱作为频域特征向量。

3) 利用 PCA 和 LLE 分别对由时域、频域特征向量构成的联合特征向量进行降维,验证了 LLE 降维后的融合特征向量的聚类效果更好。

4) 通过构建的 PSO-LSSVM 识别模型,分析验证了融合特征下的分类识别率最高,相对于单一时域特征识别率提高了 6%。验证了融合特征向量具有较强的鲁棒性,在对声发射源进行定位和失稳预测方面具有指导意义。

参 考 文 献

- [1] 彭冠英,许明,谢强,等.基于岩石声发射信号的指数衰减型小波基构造[J].岩土力学,2016,37(7):1868-1876.
PENG Guanying, XU Ming, XIE Qiang, et al. Exponentially decaying wavelet base structure based on rock acoustic emission signal[J]. Rock and Soil Mechanics, 2016, 37(7): 1868-1876. (in Chinese)
- [2] 许中林,李国禄,董天顺,等.声发射信号分析与处理方法研究进展[J].材料导报,2014,28(9):56-60.
XU Zhonglin, LI Guolu, DONG Tianshun, et al. Research progress of acoustic emission signal analysis and processing methods [J]. Materials Guide, 2014, 28(9): 56-60. (in Chinese)
- [3] 张艳博,梁鹏,孙林,等.基于HHT的粉砂岩破裂声发射信号频率特性研究[J].采矿与安全工程学报,2016,33(1):179-184.
ZHANG Yanbo, LIANG Peng, SUN Lin, et al. Study on frequency characteristics of acoustic emission signal of siltstone fracture [J]. HHT Mining and Safety Engineering Journal, 2016, 33(1):179-184. (in Chinese)
- [4] 鲜晓东,袁双,纪松林.基于消噪处理岩石声发射信号到达时间的识别方法[J].煤炭学报,2015,40(S1):100-106.
XIAN Xiaodong, YUAN Shuang, JI Songlin. Identification method for the arrival time of acoustic emission signals based on noise elimination [J]. Journal of Coal, 2015,40(S1):100-106. (in Chinese)
- [5] 凌同华,张胜,易志强,等.岩石声发射信号能量分布特征的EMD分析[J].振动与冲击,2012,31(11):26-31.
LING Tonghua, ZHANG Sheng, YI Zhiqiang, et al. EMD analysis of energy distribution characteristics of rock acoustic emission signals [J]. Vibration and Impact, 2012, 31(11):26-31. (in Chinese)
- [6] JIA Y C, LI G L, DONG X, et al. A novel denoising method for vibration signal of hob spindle based on EEMD and grey theory [J]. Measurement, 2020, 169(9):108490.
- [7] 戴文舒,鲍凯凯,陈新华,等.基于AR模型的时变水声信道统计分析方法[J].振动与冲击,2019,38(13):231-235.
DAI Wenshu, BAO Kaikai, CHEN Xinhua, et al. Time-varying underwater acoustic channel statistical analysis method based on AR model[J]. Vibration and Shock, 2019, 38(13): 231-235. (in Chinese)
- [8] 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. Spectrum characteristics of red sandstone acoustic emission signals based on improved EEMD [J]. Vibration and Shock, 2018,37(16): 118-123. (in Chinese)
- [9] 程静,王维庆,樊小朝,等.基于二值双谱和模糊聚类的风电轴承故障诊断[J].振动、测试与诊断,2018,38(4):765-771.
CHENG Jing, WANG Weiqing, FAN Xiaochao, et al. Wind turbine bearing fault diagnosis based on binary bispectrum and fuzzy clustering [J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(4): 765-771. (in Chinese)
- [10] LI X G, JIA G H, LI J F, et al. A face hallucination algorithm via an LLE coefficients prior model [J]. Chinese Journal of Electronics, 2018, 27(6): 1234-1240.



第一作者简介:杨丽荣,女,1979年11月生,硕士、副教授。主要研究方向为复杂信号处理分析及系统建模与模式识别。
E-mail:18978844@qq.com