

基于特征选择的矿山微震信号自动识别

郑培晓¹, 蒲成志¹, 谢国森², 罗勇¹, 李广悦¹

(1. 南华大学 资源环境与安全工程学院, 湖南 衡阳 421001; 2. 核工业北京化工冶金研究院, 北京 101149)

摘要: 微震信号的自动识别是微震监测技术中亟需解决的一个重要问题, 决定了预警的准确性与时效性。基于机器学习的方法虽在微震信号识别中得到了广泛应用, 但其在处理低信噪比的原始信号时效果欠佳。该方法中, 特征集和算法模型二者共同决定了信号的识别率, 但特征集构建尚缺乏统一的标准。为解决该问题, 基于改进的多准则融合特征选择算法, 开展了某金属矿山微震信号的自动识别研究。首先构建开放式信号特征库, 库内分3类收录了多种被证实可用于信号识别的特征, 随后运用改进的多准则融合特征选择算法对库内特征进行量化评分, 选出最优子集, 最后将该子集作为粒子群优化支持向量机 (particle swarm optimization - support vector machine, 简称 PSO-SVM) 识别算法的输入, 开展信号自动识别试验。结果表明: 使用改进后的多准则融合特征选择算法构建的最优子集包含 32 个特征, 相较于传统方法构建的特征集包含特征类别更为丰富, 将其作为信号输入, 在使用少量训练数据的情况下, 训练集与测试集的信号识别率分别为 100.00% 和 99.23%, 满足工程需要。不同类别特征对信号识别贡献不同, 时频域特征相较于时域和频域特征具有更好的表现。该研究为微震信号的自动识别提供了新的有效途径, 对推动微震监测技术在工程中的广泛应用具有重要意义。

关键词: 微震信号识别; 特征选择; PSO-SVM 算法; 特征库; 原始信号

中图分类号: TD853; TD868

文献标识码: A

文章编号: 1000-7598 (2025) 07-2199-12

Automatic identification of mine microseismic signals based on feature selection

ZHENG Pei-xiao¹, PU Cheng-zhi¹, XIE Guo-sen², LUO Yong¹, LI Guang-yue¹

(1. School of Resources, Environment and Safety Engineering, University of South China, Hengyang, Hunan 421001, China;

2. Beijing Research Institute of Chemical Engineering and Metallurgy, China National Nuclear Corporation, Beijing 101149, China)

Abstract: The automatic identification of microseismic signals is an urgent issue to be addressed in microseismic monitoring technology, and its performance determines the accuracy and timeliness of early warning. Although machine learning methods have been extensively utilized in the identification of microseismic signals, they exhibit notable limitations in identifying original signals with low signal - to - noise ratios. Both feature sets and algorithmic models jointly determine signal recognition accuracy in machine learning approaches. However, the construction of feature sets is yet to be standardized uniformly. To address this issue, the automatic identification of microseismic signals in a metal mine was investigated based on the improved multi - criterion fusion feature selection algorithm. Firstly, a dynamic signal feature library was established, which categorizes validated recognition features into three domains. Subsequently, an improved multi - criterion fusion feature selection algorithm was applied to quantitatively score the features, through which an optimal feature subset was selected. Finally, this subset was utilized as input parameters for the particle swarm optimization-support vector machine (PSO - SVM) recognition algorithm to identify signals automatically. The results indicate that the optimal subset constructed using the improved multi - criterion fusion feature selection algorithm includes 32 features. Compared to the feature sets constructed by using traditional methods, the optimal subset contains a richer variety of feature categories. When used as signal input with few training samples, the recognition accuracy of the training and test sets is 100% and 99.23%, respectively. Feature contribution analysis revealed that time - frequency domain features have a better performance compared to time - domain and frequency - domain features. This study establishes a new paradigm for the identification of microseismic signals. It holds substantial significance in propelling the extensive utilization of microseismic monitoring techniques in engineering applications.

Keywords: microseismic signals identification; feature selection; PSO-SVM algorithm; feature library; original signal

收稿日期: 2024-09-25

录用日期: 2025-02-11

基金项目: 国家自然科学基金面上项目 (No.52474133)。

This work was supported by the General Project of National Nature Science Foundation of China(52474133).

第一作者简介: 郑培晓, 男, 1999 年生, 硕士研究生, 主要从事矿山动力灾害监测研究。E-mail: 599687173@qq.com

通讯作者: 李广悦, 男, 1970 年生, 博士, 教授, 主要从事铀矿开采理论与技术研究。E-mail: lgy673@163.com

1 引言

当前正处于矿产资源开采不断向地球深处推进的进程^[1-2],在这一进程中,为实现深部矿产资源的安全高效开采,采矿业亟须由传统采矿模式向智能化采矿模式转变^[3]。微震监测系统通过采集地下岩石破裂释放的微小信号,可为评估深部矿体开采过程中的地应力活动规律、进行地下开采安全监测预警以及采矿参数优化等研究提供可靠的数据支撑^[4-6]。目前,微震监测技术已经成为保障深部矿山安全开采的有效工具之一,在实践应用中展现出巨大的实用价值^[7]。石峰等^[8]针对某金属矿山,提出了使用微震时间分异速率指标进行岩体破坏前期预警的方法,实践表明该方法可实现提前 10 d 预警。Yang 等^[9]针对某无底柱分段崩落法矿山,以微震事件簇作为上盘整体破坏边界指标,通过上盘巷道顶板垮落边界调查证实了该指标具有实用效果。Feng^[10]、Liu^[11]等基于李夕兵等^[12]提出的“利用高应力所具有的破裂诱变特性能动的优化采矿参数”的思想,利用微震数据计算等效应力,对两个采区的爆破参数进行定性优化,该举措降低了炸药单耗和爆炸震动,有效减少了岩体的过破和欠破。

虽然微震技术在过去的 20 年中逐渐成为深部矿山安全监测和管理的重要手段,但为使该技术在未来的矿山中得到更广泛的应用,一些关键的技术问题仍有待解决^[5],其中信号的自动识别与分类问题决定了微震监测预警的准确性与时效性^[4],是亟待解决的一个技术难题。由于深部矿山生产方式的复杂性,微震监测系统采集到的岩体破裂信号中往往夹杂着机械振动、电气设备运行和爆破作业等生产活动产生的各种噪声。传统识别主要依赖研究者根据经验进行手动识别,随着采集到的数据量越来越大,人工信号识别越来越难以满足实践需求。为解决该问题,统计分析、频谱分析和机器学习的方法被用来实现信号的自动识别^[3-4]。洪勇等^[13]对香炉山钨矿爆破、岩体破裂等几种类型震源信号的特征参数进行了统计分析,获得了信号部分特征参数统计库,为该矿山日常监测中信号的辨识提供了重要参考。樊鑫等^[14]通过提取信号的小波散射系数构建特征集,使用支持向量机(support vector machine,简称 SVM)识别算法对微震事件与噪声事件进行识别,识别率分别为 96.30%和 98.15%。Zhang 等^[15]使用变分模态分解(variational mode decomposition,简称 VMD)研究信号各模态能量分布和能量聚焦系数,提取能量聚焦系数构建特征集,使用决策树

算法对岩石破裂信号与爆破信号进行识别,结果表明该方法对岩石破裂信号的识别率达到 98%,对爆破信号的识别率达到 97%。

机器学习的方法由于识别速率快、准确率高而得到广泛应用,但其在面对低信噪比的原始信号时效果欠佳。使用该方法需提前构建特征集并搭建算法模型,此二者共同决定了信号的识别率,其中特征集是机器学习的基础^[16],决定了系统识别能力的潜在最大值,算法模型则实现对识别能力上限的最大化逼近。然而,如何构建特征集目前并没有统一的标准,传统的构建方式大都依赖研究者的主观性,通过统计特性来定性化的判定某项特征是否有利于信号识别。同时,研究者们出于对模型过拟合风险和计算复杂度的担忧,构建的特征集往往规模较小。随着越来越多的特征被证明可用于信号的识别,这种主观化的特征集构建方式极易使得研究者在面对海量特征时陷入选择困境,进而限制微震监测技术的应用与推广。

为突破这一困境,实现原始信号的高精度识别,规范化特征集构建流程至关重要。特征选择方法是一种有效的数据降维方法,可帮助研究者在海量数据中快速筛选出最优子集,其能力在文本分类、故障检测和数据挖掘等领域已得到证实^[17-18],使用此方法,将为特征集构建提供新的理论指导,使得特征集构建更加规范化。与传统方法相比,特征选择方法构建的特征集可以涵盖更多的特征数目与更丰富的特征种类,这不仅能提升信号识别的上限,更有助于实现对原始信号的直接识别。

基于此,本文依托某金属矿山建立的 16 通道微震监测系统,对其爆破事件与岩石破裂事件产生的原始信号进行识别研究。首先构建一个信号特征库,库内收录被证实可用于信号识别的特征,继而运用特征选择方法在库内选出最优子集作为特征集,借助粒子群优化支持向量机(particle swarm optimization-support vector machine,简称 PSO-SVM)识别算法开展原始信号的自动识别研究,旨在为微震信号的自动识别提供高效、准确的解决方案。

2 工程背景及微震事件分类

2.1 工程背景

某金属矿处于扬子准地台和华夏古陆之间的加里东褶皱带上诸广岩体的南部中心部位,由碎裂花岗岩、糜棱岩化花岗岩、糜棱岩及微晶石英岩组成。目前开采的二期工程为地下开采,采用平硐-竖井联合开拓,地表标高为+450 m,地下开采标高为

-200 m, 开采深度达 650 m。针对该金属矿山开采情况, 确定重点监测范围后, 布设 16 通道微震监测系统, 该系统可完整记录监测区域的微震信号波形。

2.2 微震事件分类

矿山微震监测的目的是对开采扰动引发的地压显现规律与岩爆倾向性进行科学评估, 通过分析监测数据, 确定合理的地压显现和岩爆倾向性预警阈值, 以实现岩体稳定性监测预警。地下矿山开采作业中, 爆破扰动是岩石灾害的主要诱因, 是需要重点关注的研究对象。然而, 爆破信号的波形特征与岩石破裂信号存在一定的相似性, 极易被误判为岩石破裂信号, 这将对岩体稳定性监测预警产生严重的干扰, 从而阻碍微震监测技术发挥其应有的价值。因此, 精准识别深部矿山开采过程中的爆破信号与

岩石破裂信号具有重要意义。

为精准确定信号标签, 在监测前期, 对爆破信号震源进行测试, 记录其波形图, 观察波形特征, 同时与前人的研究进行对比, 确定爆破信号特点。岩石破裂事件标签的确定则是基于对非生产活动期间采集到的信号经过人工排查分析来确定。此外, 信号采集过程中发现, 岩石破裂信号在波形上呈现出两类不同的表现, 分别记为 I 类岩石破裂信号和 II 类岩石破裂信号。为探究在信号识别研究中, 是否存在对岩石破裂信号再分类的必要性, 随机选取两类信号各 100 例, 对它们的 11 种特征参数进行了统计分析, 结果如图 1 所示。图中, 3.0~3.7 节点为小波包 3 层分解后第 0 节点~小波包 3 层分解后第 7 节点。




图 1 两类岩石破裂信号特征参数

Fig.1 Characteristic parameters of rock fracture signals

由图 1 可知, 两类岩石破裂信号在峰峰值、总功率、小波包 3.0 节点能量占比以及小波包后 5 个节点的能量占比方面存在显著的差异性。同时, 对图 1(a)中上升时间的统计结果进行细致观察可知, II 类信号相较于 I 类信号具有更长的上升时间。此外, 两类信号的出现频率也具有显著差异性, I 类信号出现频率更为均匀, II 类信号出现频率则具有明显聚集现象。综合上述两类信号的统计规律可知, I 类和

II 类岩石破裂信号在多种特征参数上存在显著差别, 因而有必要对岩石破裂事件进行细分。

本文分别取上述两类岩石破裂信号 477 例、407 例与爆破信号 598 例组成信号数据集, 进行自动识别研究。3 类信号的典型波形图如图 2 所示。由图 2 可知, I 类岩石破裂信号振幅大, 持续时间短, 无明显上升与下降阶段; II 类岩石破裂信号振幅小, 上升阶段与下降阶段明显, 尾波发育, 持续时间为 I

类岩石破裂信号的 3~5 倍。爆破信号振幅相对较大,持续时间最长,一般在 1 000 个采样点以上,尾波衰减波动大。




图 2 3 类信号时域波形

Fig.2 Time-domain waveforms of three signals

3 信号特征库构建与特征参数提取

目前,许多特征被发现可用于微震信号的识别,其主要可概括为 3 个类别:基于统计分析的时域特征、基于傅里叶变换的频域特征和基于小波分析等的时频域特征。本文参考现有研究^[19-27],按照上述分类标准,结合本项目中信号的具体情况,选取了 61 种已被证实可用于信号识别的特征,组建信号特征库,其中时域特征 17 种,频域特征 9 种,时频域特征 35 种,详见表 1。特征参数提取基于 Matlab

2019b 平台进行,使用配置 Inter i5 CPU、8G 内存的计算机。

其中,时域特征参数提取需提前确定信号的起止时间,本文以信号瞬时能量占据峰值能量的比值为依据设定信号起止时间阈值^[25]。对采集到的信号,经试验测试发现:以信号瞬时能量初次达到 5% 峰值能量时记为信号起始时间,信号能量最后一次衰减至 1%峰值能量时记为信号结束时间,对信号起止点拾取效果较好,因此选用该组阈值作为信号起止时间的判定标准。同时,信号进行快速傅里叶变换后的频率谱中易出现能量散射现象,故而本文基于信号功率谱提取信号频域特征参数。时频域特征参数提取中,信号下降时间段累计能量衰减率^[24]提取时考虑到 I 类岩石破裂信号较短,故而将峰后下降段分为 11 段,库内收录前 9 段。信号本征模态函数(intrinsic mode function,简称 IMF)提取采用经验模态分解(empirical mode decomposition,简称 EMD),得到数个从高频到低频的 IMF 分量,计算各分量与原信号的相关系数和方差贡献率,结果如图 3 所示。这两个指标值越大,对应分量越重要,由图 3 可知:3 类信号前 6 个 IMF 分量的相关系数和方差贡献率较大,当超过 IMF6 时,相关系数和方差贡献率最大值仅为 0.013 5 和 0.536 6,可认为这些分量在原始信号中所占比重较小,予以剔除,故而将信号分解为 6 层。

表 1 特征库组成

Table 1 Composition of feature library

时域		频域		时频域	
编号	名称	编号	名称	编号	名称
1	持续时间	18	主频	27~35	信号下降时段第 k 段能量衰减率
2	峰值	19	均方频率	36~41	第 k 个 IMF 边际谱能量
3	波形指标	20	中值功率	42~47	第 k 个 IMF 分量偏度
4	方根	21	重心频率	48~53	第 k 个 IMF 分量峭度
5	峰峰值	22	最大频谱值	54~61	3 层小波树第 k 个节点能量占比
6	平均幅值	23	频率标准差		
7	方差	24	平均频率		
8	脉冲指标	25	总功率		
9	峭度指标	26	平均功率		
10	标准差				
11	均方根值				
12	偏度指标				
13	裕度指标				
14	上升时间				
15	下降时间				
16	方根幅值				
17	峰值指标				

虽然本文中构建的信号特征库仅收录特征 61 种,但其构建了一个开放性的框架,可以不断吸收新的特征从而保证信号特征库的技术适应

性。此外,微震信号具有一致性,但同时也存在特异性。本文特征选择算法可以针对具体工程场景对特征量化评分进行具体分析,因此,库内收

录特征时应同时考虑特征的有效性和普适性。




图3 IMF分量相关系数和方差贡献率

Fig.3 IMF's component correlation coefficients and variance contribution rates

4 基于特征选择方法的特征集构建与信号识别

4.1 基于特征选择方法的特征集构建

特征选择是直接从一组特征中挑选出一些最有效特征以降低特征空间维数的方法，它要求这个特征集可以为后续的学习方法提供较多的有用信息且相互之间信息冗余尽量小^[28]。特征选择包含4个基本过程：子集生成、子集评价、停止准则和结果验证。子集评价是特征选择的核心，其评价准则可划分为4类：距离度量、信息度量、依赖性度量和一致性度量。

距离度量直观方便，受到广大研究者的青睐，基于此准则，Liu等^[29]提出了一种基于核空间的多准则融合特征选择算法。该算法使用类分离度作为评价指标用于进行分类算法的特征选择，它由建立在度量类间样本和类内样本相似度基础上的类间分离度 B^Φ 和类内分离度 W^Φ 两部分构成，此外，为适用于非线性数据，该算法首先将特征映射到核空间后又进行评价。

然而，该方法在衡量类分离度时仅以均值作为评价指标，这种单一指标的选择易使结果受到异常点的干扰，且无法反映数据分布的差异。此外，在考量类内分离度时，该方法未剔除因自身与自身相似度所产生的计算值增量，该增量会导致计算值大于真实值，且呈现出一种特性：对真实值小的部分该增量更大，对真实值大的部分该增量则较小，这些因素削弱了算法的可靠性。

基于上述考量，本文在此方法的基础上进行改进，一方面，综合考量均值和方差共同定义类分离度，另一方面，在计算类内分离度时摒弃对自身与自身相似度的考量，算法具体流程如图4

所示，为便于叙述，后面称本文算法为多准则融合特征选择算法。




图4 多准则融合特征选择算法流程

Fig.4 Procedure of multi-criterion fusion feature selection algorithm

4.1.1 算法原理

考虑到微震信号各特征间并不都线性可分，而将向量投影到高维空间后可以极大程度地改善这种情况，所以首先利用核函数将原始数据投影到高斯径向基核空间中，利用余弦相似度对两事件进行相似度衡量，如下式所示：

$$\cos(\theta) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle \quad (1)$$

式中： $\mathbf{x}_i$ 、 $\mathbf{x}_j$ 分别为 i 、 j 事件的特征参数向量，为61维向量，每一维代表一个特征； θ 为两个事件样本向量之间的夹角； $\Phi(\mathbf{x})$ 为将 $\mathbf{x}$ 事件样本从原特征空间映射到核空间后得到的特征向量。

以余弦相似度作为样本相似度进行度量，则对任意两个同类样本，其余弦相似度应该较大，即类内分离度 W^Φ 应该尽量大；对任意的两个不同类样本，其余弦相似度应该较小，即类间分离度 B^Φ 应该尽量小。同时，为了更全面地考虑特征间的统计特征，定义 B^Φ 与 W^Φ 由余弦相似度的均值与标准差共同影响， B^Φ 为所有不同类事件余弦相似度均值与标准差相减后的均值， W^Φ 为所有同类事件余弦相似度均值与标准差相减后的均值，其中同类间余弦相似度均值计算中不考虑自身与自身余弦相似度，具体表达式为

$$W_\Phi = \left\{ \sum_{n=1}^N \sum_{m=1, m \neq n}^N \left[\sum_{i=1}^L \sum_{j=1, j \neq i}^L (\mu^{ij} - s^{ij}) \right] \right\} \times \frac{2}{L(L-1)} \quad (2)$$

$$B_{\Phi} = \left\{ \sum_{n=1}^N \sum_{m=1}^N \left[\sum_{i=1}^L \sum_{j=1}^K (\mu^{ij} - s^{ij}) \right] \right\} \times \frac{1}{LK} \quad (3)$$

式中: μ^{ij} 为 i 事件与 j 事件余弦相似度的均值; s^{ij} 为 i 事件与 j 事件余弦相似度的标准差; L 和 K 为某两类事件样本的数量; N 为事件类型的数量; m 、 n 为特征种类。

记类分离度为类内分离度与类间分离度之差, 则其为带宽参数 σ 的函数, 根据合理分类原则, 好的带宽参数应使类分离度最大, 则带宽参数 σ 的选择问题为一个一维优化问题, 表示为

$$\sigma = \arg \max J(\sigma) \quad (4)$$

式中: J 为类分离度, 其中 $J(\sigma) = W^{\Phi}(\sigma) - B^{\Phi}(\sigma)$, 为全部特征的类分离度。

为考核某一特征对类分离度的贡献量, 即某特征的有效得分, 以类分离度的变化量作为有效得分^[30], 具体表示式为

$$E_k^J = J(\sigma) - J_k(\sigma) \quad (5)$$

式中: E_k^J 为某特征有效性得分; $J_k(\sigma)$ 为去掉特征 k 后的类分离度。

上述算法将各特征对信号分类的有效性进行量化, 但特征间的相关性未被考量, 因此以皮尔逊相关系数来对相关系数进行考量, 表达式为

$$\rho(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y} \quad (6)$$

式中: $\rho(X, Y)$ 为向量 X 与向量 Y 的皮尔逊相关系数; $\text{Cov}(X, Y)$ 为二者协方差; σ_X 与 σ_Y 分别为两向量标准差。向量 X 与 Y 与前文向量 x 与 y 不同, 为所有信号的某个特征组成的特征向量, 每一维代表一个微震信号的某项特征。

综合考量特征的有效性和相关性, 每个特征的最终得分表示为

$$i_{\ell} = \begin{cases} \arg \max (E_{\ell}^J), \ell = 1 \\ \arg \max \left\{ E_{\ell}^J - \frac{1}{\ell - 1} \sum_{i=1}^{\ell-1} |\rho_{\min}| \right\}, \ell \geq 2 \end{cases} \quad (7)$$

式中: ℓ 为特征得分排序号; E_{ℓ}^J 为特征 m 有效性得分。

4.1.2 特征排序

该算法首先需要根据式 (4) 对带宽参数 σ 的取值进行确定, 采用试验来选定最适宜的值。设定 σ 的范围并使其离散化, 最小为 0.1, 最大为

3.0, 设置步长为 0.1, 求取类分离度, 与最大类分离度对应的即为最优 σ 。类分离度曲线如图 5 所示, 当带宽参数取值为 2.0 时, 最大类分离度为 0.974 1。选定 σ 值为 2.0。根据算法得分, 信号特征的排序结果如表 2 所示。




图 5 类分离度曲线

Fig.5 Curve of class separability

4.1.3 特征集构建

排序后特征按序号每次递增一个组成特征子集, 依次组成 61 个特征子集, 分别记为子集 1 至子集 61。使用 PSO-SVM 算法进行识别任务, 信号总量的 70% 划分为训练集, 30% 划分为测试集, 通过内置随机参数因子的方式保证每一次训练集与测试集使用的信号相同。以参与分类的特征个数和识别率作为评价指标, 选出最优特征子集。使用特征个数与识别率之间的关系, 如图 6 所示。

由图 6 可知, 识别率随着参与特征个数的增加总体呈现出先上升后保持平稳的趋势, 在特征个数增加的前期, 识别率迅速上升, 当使用特征个数为 4 个时, 训练集与测试集识别率均达到 95% 以上, 说明经过多准则融合特征选择算法量




图 6 特征个数与识别率对应关系

Fig.6 Relationships between the number of features and recognition rates

表 2 特征得分排序

Table 2 Feature ranking based on scores of multi-criterion fusion feature selection algorithm

排名	名称	排名	名称	排名	名称
1	峰值	22	3.5 节点能量占比	43	3.1 节点能量占比
2	裕度指标	23	峰后 5 段能量衰减率	44	IMF2 边际谱能量
3	峰后 6 段能量衰减率	24	3.4 节点能量占比	45	方差
4	平均幅值	25	峰后 8 段能量衰减率	46	峰后 1 段能量衰减率
5	IMF1 分量峭度	26	IMF3 边际谱能量	47	IMF1 分量偏度
6	IMF6 分量峭度	27	IMF4 边际谱能量	48	IMF4 分量峭度
7	3.0 节点能量占比	28	IMF5 分量峭度	49	均方根值
8	峰后 2 段能量衰减率	29	平均频率	50	IMF1 边际谱能量
9	峰后 3 段能量衰减率	30	IMF3 分量偏度	51	IMF3 分量峭度
10	IMF2 分量峭度	31	脉冲指标	52	标准差
11	主频	32	中值功率	53	偏度指标
12	下降时间	33	峰后 9 段能量衰减率	54	3.3 节点能量占比
13	IMF5 分量偏度	34	波形指标	55	峰峰值
14	峰后 7 段能量衰减率	35	峰值指标	56	总功率
15	IMF5 边际谱能量	36	IMF4 分量偏度	57	最大频谱值
16	IMF6 边际谱能量	37	频率标准差	58	均方频率
17	3.6 节点能量占比	38	峭度指标	59	方根
18	峰后 4 段能量衰减率	39	IMF6 分量偏度	60	方根幅值
19	3.2 节点能量占比	40	重心频率	61	平均功率
20	上升时间	41	IMF2 分量偏度	—	—
21	持续时间	42	7 节点能量占比	—	—

化评分后,对信号识别具有良好贡献的特征被筛选出来,促使识别率前期快速上升。此后,随着特征个数的增加,模型识别率开始缓慢波动上升,同时测试集识别率与训练集识别率逐渐接近,当使用特征个数达到 32 个时,训练集与测试集识别率均达到 99%以上,且随着使用特征个数的增加识别率得到良好的保持,这说明此时训练出的模型较为稳定。由此确定子集 32 为最优子集,选取该子集为识别算法的特征集进行信号识别。

4.2 信号识别

构造 PSO-SVM 联合算法进行信号识别。支持向量机的基本思想是创建一个定义在特征空间上间隔最大的线性分类器^[31],以此来实现分类任务,该算法目前被证实在解决小样本、非线性和高维的分类问题方面有较大优势,已被广泛应用于信号识别、文本分类等领域。但其分类准确性受到误差惩罚参数 C 与核函数形式及其参数的影响较大^[32]。PSO 是一种基于鸟群捕食原理研究的随机搜索启发式算法,通过模拟群体粒子的随机运动,寻找全局最优解,具有收敛快速、操作简单等优点^[33],被广泛用来优化算法。参考奉国和^[32]的研究,本文 SVM 中核函数选用高斯核函数,之后使用 PSO 对 SVM 的误差惩罚参数 C 与高斯核函数 σ' 进行优化构建 PSO-SVM 联合算法实现分类任务。算法的具体运

行流程如图 7 所示,试验使用台湾大学林智仁等开发的开源工具包 LIBSVM 在 Matlab 2019b 平台进行。




图 7 PSO-SVM 算法流程

Fig.7 Procedure of PSO-SVM algorithm

使用 4.1.3 节选出的特征集作为 PSO-SVM 算法的输入向量开展信号识别试验,其中信号数据集内全部信号的 30%划分为训练集,70%划分为测试集,对模型进行参数调整优化后,训练集与测试集的信号识别率分别为 100.00%与 99.23%,具体识别结果

如图 8、9 所示。由试验结果可知,本文方法可在使用较少训练量的基础上实现对原始信号的精确识别,这一成果具有重要意义,它表明本文方法在数据有限的情况下仍能高效、准确地完成信号识别任务,有助于提升信号处理的效率。考虑到信号特征库具有技术适应性,当库内收录更多特征时,原始信号将具有更稳定的识别效果。




图 8 原始信号训练集预测结果
Fig.8 Prediction results of training set for original signals




图 9 原始信号测试集预测结果
Fig.9 Prediction results of test set for original signals

4.3 现场应用

微震监测的目的是为了揭示矿山地压显现规律,对地下岩体稳定性做出判断,为安全生产提供可靠的保障^[34]。为进一步说明本文方法的实用意义,下面选取 2023 年 8 月 2—15 日两周内采集的微震信号并结合现场生产情况进行说明。

2023 年 8 月在 2、5、6、7 和 9 号进行了爆破作业。通过实时连续监测,微震监测系统累计采集上述 3 类信号共计 100 例,其中爆破信号 61 例、I 类岩石破裂信号 5 例以及 II 类岩石破裂信号 34 例。需要强调的是,这 100 例信号并未纳入前面训练使用的信号数据集中。将其输入训练好的 PSO-SVM 分类模型中,信号识别率为 100%,说明本文方法

对信号的自动识别具有较强的工程价值。

各类事件累计数量随时间分布情况如图 10 所示。由图 10 可知,在爆破作业阶段,I 类岩石破裂事件数量有较高增长,随着爆破作业停止,该类信号也随之停止,这说明岩石破裂事件与爆破事件密切相关,爆破事件越多,岩石破裂活动越剧烈^[35]。II 类岩石破裂事件集中出现在爆破活动停止后的 2 d 内,这是由于爆破等开采扰动使得原有的应力平衡被打破,深部岩体进入动态调整阶段,同时由于生产作业停止,岩体内累计的弹性应变能无法以短促、剧烈的形式释放,而是当累积到一定能量密度后,以局部岩体微破裂的形式释放,具有一定的时滞性。




图 10 微震事件累计数量
Fig.10 Cumulative numbers of microseismic events

5 讨论

5.1 规范化特征集构建流程的必要性

为阐明规范化特征集构建流程的必要性,下面将本文方法构建的特征集与基于统计分析方法构建的特征集进行对比。试验组特征集构建方式如下:4.1.3 节中构建的子集 32 为组 1,子集 5、子集 6 与子集 7 依次组成试验组 2、组 3 和组 4。对照组特征集构建方式如下:对库内特征实施 5 次有放回随机取样,每次随机选取 10 个特征构成 1 组,共计 5 组。随后,运用统计分析方法对组内特征参数进行研究,筛选对信号分类无效的特征后,组成 5 组特征集,依次编号为组 5~9。信号数据库中全部信号的 30%划分为训练集,70%划分为测试集,为保证变量唯一,所有组均采用相同的数据划分方式和识别算法进行信号识别研究,识别效果见图 11。

由图 11 可知,当特征集内特征数量相同时,即对比组 2 和组 8,组 3 和组 5、6、9,组 4 和组 7 的结果表明,本文方法构建的特征集具有更高的信号识别率。对比组 2 和组 5 至组 9 可知,本文方法构建的特征集在使用更少特征时,信号识别率已经达到甚至超越传统定性化方式构建的特征集,这对




图 11 不同特征集的认识率

Fig.11 Recognition accuracy of different feature sets

于提升计算效率、节省计算资源极为有利，更有助于微震监测技术在工程中的应用与推广。此外，对比组 1 和组 5 至组 9 可知，由于特征选择方法能够对信号特征进行量化评分，这为研究者提供了理论依据，使得特征集规模得以突破传统方式构建的特征集的规模限制，更加全面地利用了信号信息，有

助于信号的更高水平识别。这些结果表明，规范化特征集构建流程极其必要。

5.2 不同类别特征对信号识别的贡献

信号特征库具有技术适应性，明确库内应优先收录的特征类别，以及在收录新特征时更应注重哪些类别是后续需要关注的问题。故而本文探究了不同类别特征对信号识别贡献的研究。同时考虑到以往研究大都基于降噪信号，为与前人的研究建立联系并更为全面的说明问题，本节对降噪信号与原始信号进行了识别效果对比。

采用小波阈值降噪^[36-37]方法对信号进行降噪处理，选用参数为 bior3.7 小波基、3 层分解，rigrsure 阈值规则搭配软阈值处理方法，去噪使用的小波函数，参考文献[36]。选取一例信噪比较低的信号说明降噪效果，对比如图 12 所示。由图 12 可知，降噪后信号保留了原始信号的整体波形，同时去除了信号的高频“毛刺”突起，降噪效果良好。




图 12 信号降噪效果

Fig.12 Noise reduction effect

降噪后信号使用特征个数与识别率对应关系如图 13 所示。对比图 13 和图 6 可知，原始信号与降噪信号二者在特征个数与识别率对应关系上具有一致性，随着特征个数的增加，信号识别率均表现出先升高后平稳的趋势，且在特征个数扩充的前期，信号识别率增长较快。对于降噪信号，当使用特征个数达到 8 个时，训练集与测试集识别率均达到 98.5% 以上，并随着特征个数的增加，识别率得到良好的维持。对比稳定后的两种信号的识别率可知，使用本文方法，不需要进行降噪处理即可实现信号的高精度识别。

对原始信号与降噪信号排序前 10 位和前 30 位特征中各类别的占比进行研究，类别占比计算如下式所示：

$$P_k = \frac{M_k}{A_k} \times 100\% \quad (8)$$

式中： P_k 为 k 类特征的占比； M_k 为 k 类特征排序在前 10 或前 30 的个数； A_k 为 k 类特征的总个数。

各类别特征占比见图 14 所示。由图 14 可知，信号经降噪处理，时域特征占比有明显提升，这说明对含噪音较少的信号，时域特征具有良好识别效果，但同时也反映了时域特征极易受到噪声干扰的特点。频域特征对信号识别效果较差，这是由于频域特征的提取需要基于傅里叶变换，该方法对平稳信号处理具有较好的效果，对微震这类非平稳信号处理效果较差。无论信号降噪与否，时频域特征对信号识别均具有较好的贡献，这既表明其对信号识别具有良好效果，又体现了其抵御噪声干扰的能力。综合来看，时频域特征相较于时域和频域特征具有更好识别效果，这与目前研究中的认知相一致。在实际中采集到的微震信号往往夹杂噪音，故而后对特征库进行补充时应更多考量时频域特征。






图 13 降噪信号特征个数与识别率对应关系

Fig.13 Relationships curves between the number of features and recognition rate for noise reduction signals



(a) 前 10 位排序占比



(b) 前 30 位排序占比

图 14 各特征域占比

Fig.14 Percentage of the different feature domains

传统机器学习方法进行信号识别的思路是先进信号降噪,后构建特征集输入算法模型以实现信号识别;本文为先构建特征集,对特征集进行筛选后直接输入算法模型以实现信号识别。结果表明,本文方法能够实现对原始信号的直接识别,无需预先降噪处理,且在信号识别率上与传统降噪后再识别的效果相当。这意味着本文方法可以在不影响信号识别率的前提下,简化信号处理流程,减少因降噪环节可能导致的信号特征丢失的风险。

另一方面,本文方法具有良好的实用性,即其可根据具体工程场景对信号的特征评分进行具体分

析,且该过程无需复杂的人为操作步骤,这使得本文方法能够在不同类型的信号环境以及多样化的工程场景中,快速有效地筛选出合适的特征集,以实现信号的准确识别。

6 结 论

(1) 参考现有研究成果,综合考虑特征的有效性和普适性,构建开放式信号特征库,库内收录 61 种信号特征。

(2) 使用改进后的多准则融合特征选择算法对库内特征进行量化评分,构建了最优特征集,将其作为 PSO-SVM 算法模型的输入,在使用少量训练数据的情况下,训练集和测试集信号识别率分别达到 100%与 99.23%,实现了对原始信号的精确识别。

(3) 不同类别特征对信号识别的贡献不同,时域和时频域特征均对信号识别具有较好的贡献,但时域特征易受到噪声干扰,时频域特征则具有较强的抵御噪声干扰的能力。故而后特征库内收录新特征时应更多考量时频域特征。

(4) 特征选择算法通过对信号特征进行量化评分,优化了特征集结构,相较于传统的先降噪后识别,本文方法为信号精准识别提供了一种新的高效解决方案。

致谢:感谢“矿山微震监测”项目对本论文的资助,感谢所有现场工作人员对本论文研究提供的帮助。

参 考 文 献

- [1] LI P, CAI M F. Challenges and new insights for exploitation of deep underground metal mineral resources[J]. *Transactions of Nonferrous Metals Society of China*, 2021, 31(11): 3478-3505.
- [2] 袁亮. 煤矿典型动力灾害风险辨识及监控预警技术研究进展[J]. *煤炭学报*, 2020, 45(5): 1557-1566.
YUAN Liang. Research progress on risk identification, assessment, monitoring and early warning technologies of typical dynamic hazards in coal mines[J]. *Journal of China Coal Society*, 2020, 45(5): 1557-1566.
- [3] SHU H M, AHMAD Y D. Microseismic monitoring signal waveform recognition and classification: review of contemporary techniques[J]. *Applied Sciences*, 2023, 13: 12739.
- [4] DONG L J, TANG Z, LI X B, et al. Discrimination of mining microseismic events and blasts using convolutional neural networks and original waveform[J]. *Journal of Central South University*, 2020, 27(10): 3078-3089.

- [5] LIU J P, SI Y T, WEI D C, et al. Developments and prospects of microseismic monitoring technology in underground metal mines in China[J]. **Journal of Central South University**, 2021, 28(10): 3074-3098.
- [6] 陈炳瑞, 吴昊, 池秀文, 等. 基于 STA/LTA 岩体破裂微震信号实时识别算法及工程应用[J]. 岩土力学, 2019, 40(9): 3689-3696.
- CHEN Bing-rui, WU Hao, CHI Xiu-wen, et al. Real-time recognition algorithm for microseismic signals of rock failure based on STA/LTA and its engineering application[J]. **Rock and Soil Mechanics**, 2019, 40(9): 3689-3696.
- [7] 肖晓春, 丁振, 丁鑫, 等. 基于 P 波到时拾取的分析法与遗传算法联合定位方法与应用[J]. 岩土力学, 2024, 45(7): 2195-2207.
- XIAO Xiao-chun, DING Zhen, DING Xin, et al. Joint positioning method of P-wave arrival time picking based analysis-geneticalgorithm and its application[J]. **Rock and Soil Mechanics**, 2024, 45(7): 2195-2207.
- [8] 石峰, 张达, 王平, 等. 矿山岩体破坏微震分异速率特征及预警[J]. 有色金属工程, 2024, 14(3): 139-145.
- SHI Feng, ZHANG Da, WANG Ping. et al. Characteristics and early warning of microseismic differentiation rate of rock mass failure in mines[J]. **Nonferrous Metals Engineering**, 2024, 14(3): 139-145.
- [9] YANG K Y, CHEN C X, XIA K Z, et al. Stability analysis and failure mechanism of the hanging wall in a sublevel caving mine based on microseismic monitoring[J]. **Bulletin of Engineering Geology and the Environment**, 2024, 83: 259.
- [10] FENG X T, LIU J P, CHEN B R, et al. Monitoring, warning, and control of rockburst in deep metal mines[J]. **Engineering**, 2017, 3: 538-545.
- [11] LIU J P, LIU Y H, XU S D, et al. Relationship between microseismic activities and mining parameters during deep mining process[J]. **Journal of Applied Geophysics**, 2018, 159: 814-823.
- [12] 李夕兵, 姚金蕊, 宫凤强. 硬岩金属矿山深部开采中的动力学问题[J]. 中国有色金属学报, 2011, 21(10): 2551-2563.
- LI Xi-bing, YAO Jin-rui, GONG Feng-qiang. Dynamic problems in deep exploitation of hard rock metal mines[J]. **The Chinese Journal of Nonferrous Metals**. 2011, 21(10): 2551-2563.
- [13] 洪勇, 李庶林, 高真平, 等. 工程微震监测信号参数统计分析[J]. 矿业研究与开发, 2020, 40(1): 148-154.
- HONG Yong, LI Shu-lin, GAO Zhen-ping, et al. Microseismic monitoring signals of mine engineering[J]. **Mining Research and Development**, 2020, 40(1): 148-154.
- [14] 樊鑫, 程建远, 王云宏, 等. 基于小波散射分解变换的煤矿微震信号智能识别[J]. 煤炭学报, 2022, 47(7): 2722-2731.
- FAN Xin, CHENG Jian-yuan, WANG Yun-hong, et al. Intelligent recognition of coal mine microseismic signal based on wavelet scattering decomposition transform[J]. **Journal of China Coal Society**, 2022, 47(7): 2722-2731.
- [15] ZHANG X L, JIA R S, LU X M, et al. Identification of blasting vibration and coal-rock fracturing microseismic signals[J]. **Applied Geophysics**, 2018, 15(2): 280-289.
- [16] 王律己, 黄晨宇, 单伽程, 等. 基于多元特征驱动的既有建筑地震损伤机器学习预测方法[J]. 建筑结构学报, 2024, 45(7): 1-12.
- WANG lü-ji, HUANG Chen-yu, SHAN Jia-cheng, et al. Multi-feature-driven prediction of seismic damage for existing buildings using machine learning[J]. **Journal of Building Structures**, 2024, 45(7): 1-12.
- [17] 薛生, 郑晓亮, 袁亮, 等. 基于机器学习的煤与瓦斯突出预测研究进展及展望[J]. 煤炭学报, 2024, 49(2): 664-694.
- XUE Sheng, ZHENG Xiao-liang, YUAN Liang, et al. A review on coal and gas outburst prediction based on machine learning[J]. **Journal of China Coal Society**, 2024, 49(2): 664-694.
- [18] 许华杰, 刘冠霆, 张品, 等. 采用动态相关度权重的特征选择算法[J]. 计算机工程与应用, 2024, 60(4): 89-98.
- XU Hua-jie, LIU Guan-ting, ZHANG Pin, et al. Feature selection algorithm using dynamic relevance weight[J]. **Computer Engineering and Applications**, 2024, 60(4): 89-98.
- [19] 谷雪斌, 张呈国, 郭伟耀, 等. 冲击地压矿井典型微震信号特征及其判识研究[J]. 煤炭学报, 2024, 49(增刊 2): 694-713.
- GU Xue-bin, ZHANG Cheng-guo, GUO Wei-yao, et al. Characteristics and recognition of typical microseismic signals in rock burst mines[J]. **Journal of China Coal Society**, 2024, 49(Suppl.2): 694-713.
- [20] 胡静云, 张茹, 任利, 等. 矿山微震波形特征自动模式识别算法研究[J]. 岩石力学与工程学报, 2022, 41(2): 346-361.
- HU Jing-yun, ZHANG Ru, REN Li, et al. Research on automatic pattern recognition algorithm of micro-seismic waveform characteristics in mines[J]. **Chinese Journal of Rock Mechanics and Engineering**, 2022, 41(2): 346-361.
- [21] 李金雨, 雷文杰, 赵洪宝, 等. 重复爆破采动下煤岩冲击破坏的微震响应特征[J]. 中国矿业大学学报, 2019, 48(5): 966-974.
- LI Jin-yu, LEI Wen-jie, ZHAO Hong-bao, et al. Micro-seismic characteristics during impact failure of

- coal and rock under repetitive blast mining[J]. **Journal of China University of Mining & Technology**, 2019, 48(5): 966-974.
- [22] DONG L J, WESSELOO J, POTVIN Y, et al. Discrimination of mine seismic events and blasts using the fisher classifier, naive Bayesian classifier and logistic regression[J]. **Rock Mechanics and Rock Engineering**, 2015, 49(1): 183-211.
- [23] 阳铨权. 矿山微震信号智能识别技术研究与应用[D]. 济南: 齐鲁工业大学, 2023.
- YANG Cheng-quan. Research and application of intelligent identification technology of mine microseismic signal[D]. Jinan: Qilu University of Technology, 2023.
- [24] 熊璐伟, 钟晓阳, 李庶林, 等. 基于改进的 HHT-SVM 微震信号特征提取及分类识别研究[J]. 中国安全生产科学技术, 2023, 19(10): 13-20.
- XIONG Lu-wei, ZHONG Xiao-yang, LI Shu-lin, et al. Research on feature extraction and classification and identification of microseismic signals based on improved HHT-SVM[J]. **Journal of Safety Science and Technology**, 2023, 19(10): 13-20.
- [25] 王英乐, 左宇军, 陈 斌, 等. 基于改进 HHT 的矿山微震信号多尺度特征提取及分类研究[J]. 矿冶工程, 2022, 42(6): 7-12.
- WANG Ying-le, ZUO Yu-jun, CHEN Bin, et al. Multi-scale feature extraction and classification of micro-seismic signals based on improved HHT[J]. **Mining and Metallurgical Engineering**, 2022, 42(6): 7-12.
- [26] 朱权洁, 姜福兴, 于正兴, 等. 爆破震动与岩石破裂微震信号能量分布特征研究[J]. 岩石力学与工程学报, 2012, 31(4): 723-730.
- ZHU Quan-jie, JIANG Fu-xing, YU Zheng-xing, et al. Study on energy distribution characters about blasting vibration and rock fracture microseismic signal[J]. **Chinese Journal of Rock Mechanics and Engineering**, 2012, 31(4): 723-730.
- [27] 洪勇. 矿山微震监测信号去噪处理与统计辨识研究[D]. 厦门: 厦门大学, 2020.
- HONG Yong. Study on denoising and statistical identification of microseismic monitoring signal of mine[D]. Xiamen: Xiamen University, 2020.
- [28] 李郅琴, 杜建强, 聂 斌, 等. 特征选择方法综述[J]. 计算机工程与应用, 2019, 55(24): 10-19.
- LI Zhi-qin, DU Jian-qiang, NIE Bin, et al. Summary of feature selection methods[J]. **Computer Engineering and Applications**, 2019, 55(24): 10-19.
- [29] LIU Z L, ZUO M J, XU H B. Fault diagnosis for planetary gearboxes using multi-criterion fusion feature selection framework[J]. **Journal of Mechanical Engineering Science**, 2012, 227(9): 2064-2076.
- [30] GUYON I, WESTON J, BARNHILLI S, et al. Gene selection for cancer classification using support vector machines[J]. **Machine Learning**, 2002, 46(1-3): 389-422.
- [31] 李航. 统计学习方法[M]. 北京: 清华大学出版社, 2012.
- LI Hang. Statistical learning methods[M]. Beijing: Tsinghua University Press, 2012.
- [32] 奉国和. SVM 分类核函数及参数选择比较[J]. 计算机工程与应用, 2011, 47(3): 123-128.
- FENG Guo-he. Parameter optimizing for support vector machines classification[J]. **Computer Engineering and Applications**, 2011, 47(3): 123-128.
- [33] 王如锴, 练继建, 苑希民, 等. 基于 PSO-SVM 的鹤盛流域山洪风险评价[J]. 水资源保护, 2024, 40(2): 46-54.
- WANG Ru-kai, LIAN Ji-jian, YUAN Xi-min, et al. Risk assessment of torrential floods in the Heshengxi watershed based on PSO-SVM[J]. **Water Resources Protection**, 2024, 40(2): 46-54.
- [34] 吴爱祥, 武力聪, 刘晓辉, 等. 矿山微地震活动时空分布[J]. 北京科技大学学报, 2012, 34(6): 609-613.
- WU Ai-xiang, WU Li-cong, LIU Xiao-hui, et al. Space-time distribution of microseismic activities in mines[J]. **Journal of University of Science and Technology Beijing**, 2012, 34(6): 609-613.
- [35] 赵金帅, 冯夏庭, 王鹏飞, 等. 爆破开挖诱发的地下交叉洞室微震特性及破裂机制分析[J]. 岩土力学, 2018, 39(7): 2563-2573.
- ZHAO Jin-shuai, FENG Xia-ting, WANG Peng-fei, et al. Analysis of microseismic characteristics and fracture mechanism of underground caverns induced by blasting excavation[J]. **Rock and Soil Mechanics**, 2018, 39(7): 2563-2573.
- [36] 胡昌华, 张军波, 夏军, 等. 基于 MATLAB 的系统分析与设计——小波分析[M]. 西安: 西安电子科技大学出版社, 1999.
- HU Chang-hua, ZHANG Jun-bo, XIA Jun, et al. System analysis and design based on MATLAB: wavelet analysis[M]. Xi'an: Xidian University Press, 1999.
- [37] 唐佩, 李青锋, 朱川曲, 等. 基于小波变换的微震阈值去噪方法[J]. 湖南科技大学学报(自然科学版), 2021, 36(4): 1-7.
- TANG Pei, LI Qing-feng, ZHU Chuan-qu, et al. Microseism threshold denoising method based on wavelet transform[J]. **Journal of Hunan University of Science and Technology (Natural Science Edition)**, 2021, 36(4): 1-7.