DOI:10.14075/j.jgg.2024.09.433

文章编号:1671-5942(2025)10-1093-08

基于机器学习的矿震与爆破信号分类

梁潇南[1]　王建军[1]　尹欣欣[2]

1　中国地震局兰州地震研究所,兰州市东岗西路 450 号,730000

2　甘肃省地震局,兰州市东岗西路 450 号,730000

摘　要:针对甘肃某矿矿震与爆破信号的分类问题,分析了支持向量机、*K*-means 聚类、主成分分析等常用无监督分类方法在特征选择不足、分类精度较低和样本不平衡等方面存在的显著挑战。为尝试解决这些问题,本文使用一种轻量级协同学习方法(LCL-SSS),该方法结合了 MiniRocket 特征提取与改进的 *K*-means 聚类,旨在提升分类的准确性与效率。通过时频分析发现,爆破事件的 P 波初动频率主要集中在 80～200 Hz,而矿震事件的 P 波频率则分布在 20～120 Hz。经过 30 次训练实验,LCL-SSS 方法的分类准确率达到了 95.07%,有效捕捉到矿震波形中的关键特征。

关键词:矿震;时频分析;无监督学习;地震信号分类

中图分类号:P315　　**文献标识码**:A

矿震是采矿活动引发的非天然地震现象,伴随弹性能量迅速释放,可能导致地下工程或地面建筑物损坏,甚至造成人员伤亡[1-2]。随着采矿深度的增加、规模的扩大和方式的革新,矿震灾害日益复杂[3-4]。矿震的发生与地质构造、应力状态及开采方式密切相关,准确识别震动事件类型,深入研究矿震发生机理、破坏特征及其与采矿活动的关系,对保障矿区安全生产、预防和控制矿震灾害具有重要意义。

在矿震与爆破事件的识别领域,研究方法已经从传统判据向人工智能技术转变。传统判据主要基于地球物理特征,如 P/S 震幅比、震源深度、P 波初至等[5-6]。随着研究的深入,新的判据和方法不断涌现[7-13],目前大多数研究集中在天然地震和人工爆炸事件上,针对矿震识别的研究相对较少。由于矿震和爆破事件的复杂时频特征,传统方法在识别效果上存在局限性[14],尽管多层卷积神经网络在分类精度上表现出色,但其训练过程复杂,计算效率较低[15]。为解决上述问题,本文专注于矿震与爆破事件的识别,采用一种轻量级协同学习方法(LCL-SSS)[16],该方法融合了无监督学习和监督学习的优势,通过一维卷积神经网络实现了高效分类。与传统监督分类方法相比,LCL-SSS 方法减少了对大量标记数据的依赖,提高了计算效率,降低了过拟合的风险。本文旨在准确识别矿震与爆破事件,为矿震灾害的预防提供科学依据。

1　数据与方法

1.1　矿震数据与台站布设情况

选取 2024-01-01—04-06 甘肃某矿矿震事件,研究区范围为 102.88°～102.92°E、36.35°～36.38°N,分析震级大于 M_L－0.56 的矿震和爆破事件,共选取矿震事件 46 个,爆破事件 73 个。矿震和爆破的能量分布相似,集中在 M_L－0.56～0.12 之间,其中矿震震级为 M_L－0.49～0.68,爆破震级为 M_L－0.56～0.72。研究数据来自于由 11 个地表 ALLSEIS-4C 三分量地震监测台站和 20 个井下 SOS 台站组成的井地一体监测台网(图 1)。

1.2　时频分析对比

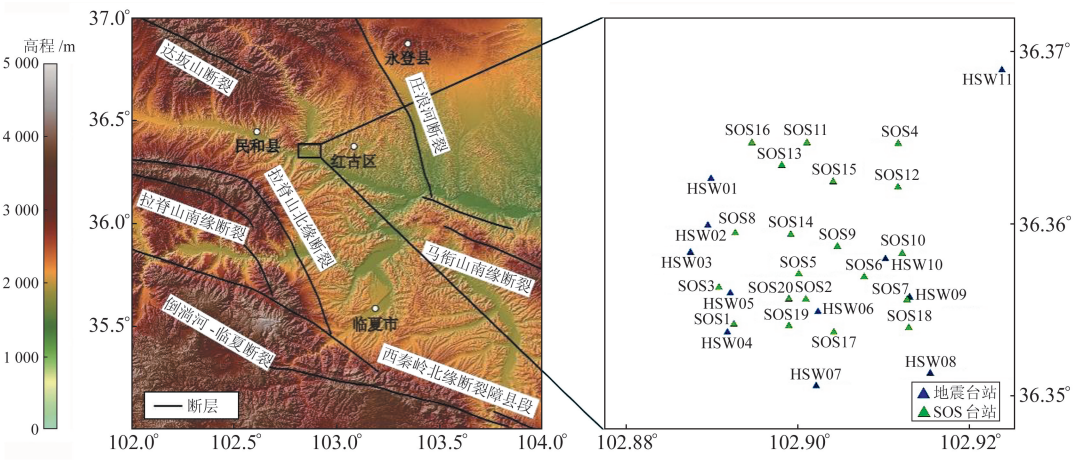
本文采用连续小波变换(CWT)进行时频分析。小波变换是一种时间尺度平面分析方法,能够对高频和低频信号分别使用窄时窗和宽时窗,在时域和频域中都可表现信号的局部特征,其中高频部分具有高时间分辨率和低频率分辨率,低频部分具有高频率分辨率和低时间分辨率。小波变换的窗口面积恒定,形状可变,时间窗和频率窗可灵活调整[17]。

收稿日期:2024-09-19

项目来源:中国地震局地震预测研究所基本科研业务费(2023IESLZ01);甘肃省科技计划(23YFFA0015)。

第一作者简介:梁潇南,硕士生,主要研究方向为地震学,E-mail:liangxiaonan22@mails.uca s.ac.cn。

通讯作者:尹欣欣,博士生,高级工程师,主要研究方向为地震台网监测和诱发地震,E-mail:yxx@gsdzj.gov.cn。



(a) 研究区域构造 (b) 台站分布

图 1 区域构造及台站分布

Fig. 1 Regional structure and distribution of stations

对基本小波母函数 $\psi(t)$ 进行伸缩和平移变换，得到一系列与母函数波形相似但波形宽度不同的新函数 $\psi_{a,b}(t)$：

$$\psi_{a,b}(t) = |a|^{-\frac{1}{2}}\psi\left(\frac{t-b}{a}\right), b \in R, a \in R-\{0\} \tag{1}$$

函数 $f(t)\in L^2$ 的小波变换定义为：

$$W_f(a,b) = |a|^{-\frac{1}{2}}\int f(t)\psi\left(\frac{t-b}{a}\right)\mathrm{d}t \tag{2}$$

相应反变换公式为：

$$f(t) = C_\varphi^{-\frac{1}{2}}\iint W_f(a,b)\psi_{a,b}(t)\frac{\mathrm{d}a\,\mathrm{d}b}{a^2} \tag{3}$$

由 $\psi(t)$ 生成的函数族 $\{\Psi_{a,b}(t)\}$ 称为连续小波。式(1)中，b 为定位参数，a 为尺度参数，$\psi_{a,b}(t)$ 随参数 a、b 改变而变化。当 $a>1$ 时，函数 $\psi_{a,b}(t)$ 表现为伸展；当 $a<1$ 时，函数 $\psi_{a,b}(t)$ 表现为压缩。随着 a 的减小，$\psi_{a,b}(t)$ 支撑区变窄，频谱 $\hat{\psi}_{a,b}(\omega)$ 向高频扩展；当 a 增大时，$\psi_{a,b}(t)$ 支撑区变宽，频谱 $\hat{\psi}_{a,b}(\omega)$ 移向低频，这使得窗口大小呈自适应特性。当信号在高频段时，时窗宽度减小，时间分辨率提高，频率分辨率降低。

1.3 基于机器学习的地震信号分类方法

采用 LCL-SSS 地震信号分类方法，结合监督学习的特征提取和无监督学习的聚类灵活性，通过两步协同学习框架提高地震事件分类的准确性和效率。

1)第 1 步，LCL-SSS 使用 MiniRocket 方法[18]提取地震波形特征。MiniRocket 是一种高效时间序列特征提取技术，使用固定长度为 9 的卷积核进行数据变换，权重为 $\alpha=-1$ 和 $\beta=2$，应用膨胀卷积，膨胀率范围为 $[[2^0],[2^{2^{\cdot\max/m}}],\cdots,[2^{m\cdot\max/m}]]$，其中 m 为最大膨胀数，限制为 32。MiniRocket 通过计算概率峰值(PPV)进行特征提取，利用预计算和组合操作提高计算效率，其卷积操作公式为：

$$X * W_d = \sum_{j=0}^{m-1} x_i - \left(\left|\frac{m}{2}\right| d\right) + (j\cdot d)w_j,$$
$$\forall i \in \{0,1\cdots,n-1\} \tag{4}$$

式中，x_i 为输入地震波形数据；W 为卷积核权重；d 为膨胀率。这种操作可有效处理长时间序列数据，计算复杂度低。

2)第 2 步，LCL-SSS 使用改进 K-means 算法对提取特征进行无监督聚类分析，将 SCAN 损失函数集成到聚类方法中，提高聚类分布的均匀性。利用欧几里得距离(Euclidean distance)找到每个样本的 k 个最近邻点，通过神经网络学习聚类函数 softmax 函数进行软分配，得到类别概率分布。SCAN 损失包括一致性损失和熵损失，其中一致性损失确保样本及其邻居预测一致，熵损失避免聚类集中于单一类别。这种设计可有效解决传统 K-means 算法可能出现的聚类退化问题，即单个聚类主导预测趋势或聚类消失。

为评估 LCL-SSS 方法的性能，本文还对比了 3 种常用分类方法：K-means、主成分分析(PCA)和支持向量机(SVM)。K-means 是一种经典的无监督学习算法，通过迭代将数据划分为 K 个簇，最小化每个数据点到簇中心的距离平方和[19]；PCA 是一种降维技术，通过线性变换将高维数据投影到低维空间，保留数据主要变异性，用于提取波形特征和减少数据维度[20]；SVM 是一种有监督学习算法，通过在高维特征空间中构建超平面，最大化不同类别数据点之间的间隔[21]。

1.4 评估方法

采用标准神经网络评估指标计算召回率、准

确率和 F_1 分数。TP 表示正确预测为正样本，FP 表示错误预测为正样本，TN 表示正确预测为负样本，FN 表示错误预测为负样本，则准确率 A 为模型整体的预测正确性：

$$A = (\mathrm{TP} + \mathrm{TN})/(\mathrm{TP} + \mathrm{TN} + \mathrm{FP} + \mathrm{FN}) \quad (5)$$

召回率 R 为实际正样本中被预测为正样本的比例：

$$R = \mathrm{TP}/(\mathrm{TP} + \mathrm{FN}) \quad (6)$$

精确率 P 表示正确预测为正样本的比例。F_1 分数为精确率和召回率调和平均值，用于综合衡量分类性能，计算公式为：

$$P = \mathrm{TP}/(\mathrm{TP} + \mathrm{FP}) \quad (7)$$

$$F_1 = 2\mathrm{TP}/(2\mathrm{TP} + \mathrm{FP} + \mathrm{FN}) \quad (8)$$

由于数据量较小，本文采用留一交叉验证方法(leave-one-out cross-validation)来验证方法的准确性和稳定性。每次测试保留 1 个事件，完成所有子测试后给出整体识别率。此方法只能计算最终识别率，无法计算平均、最高和最低识别率。为应对类别不平衡问题，输出参数时使用加权计算，每个类别的权重根据其在真实标签中的比例确定。

2　结果分析

2.1　波形与时频分析对比结果

为分析矿震和爆破事件的波形特征，采用连续小波变换对两类事件进行时频分析。两类事件的采样频率为 500 Hz，奈奎斯特频率(Nyquist frequency)为 250 Hz。图 2 为 6 组矿震和爆破事件的频谱分析结果。

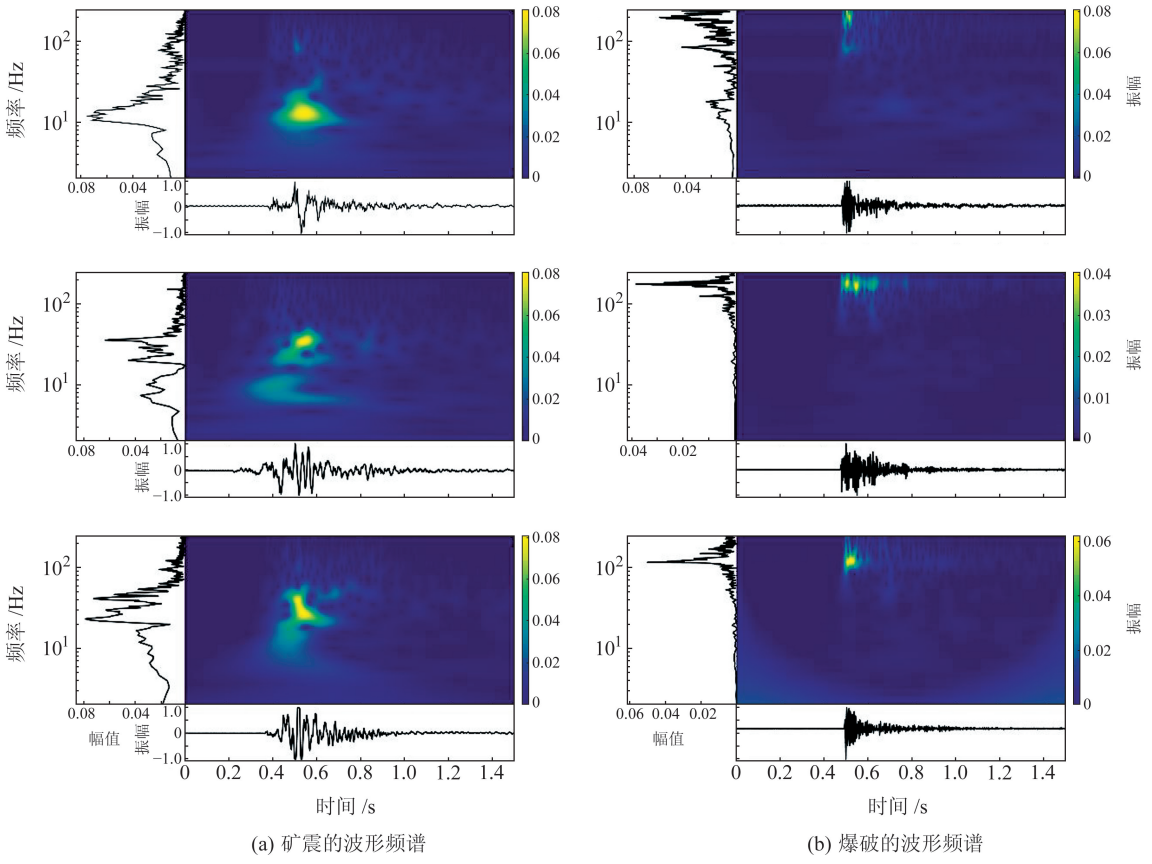


图 2　矿震和爆破的波形频谱

Fig. 2　Waveform spectrum diagram of mining earthquakes and blastings

图 2 显示，爆破和矿震波形差异显著。爆破波形表现为 P 波能量强，初动多为向上，初始阶段震动明显、振幅大、衰减快，尾部能量减弱迅速；相比之下，矿震波形特点为 P 波能量大，初动方向多为向下，能量分布均匀，波形持续时间长、衰减慢，尾部仍有明显震动。时频分析显示，矿震和爆破信号在频率特征上既有差异又存在重叠。矿震信号频率分布相对集中，主要在 20～120 Hz；爆破信号频率复杂，主要集中在 80～200 Hz。在 80～120 Hz 范围内，矿震和爆破信号都有明显的频率成分，形成重叠区域，这种频率特征的部分重叠和复杂性使得仅依靠频率阈值难以准确区分两类事件。

尽管时频分析揭示矿震和爆破事件在波形和频率特征上存在显著差异，但在实际应用中仍面临挑战。部分事件可能呈现出介于典型矿震和爆破之间的特征，这种模糊性使得仅依靠时频特征进行准确分类变得困难。此外，矿区环境复杂，可

能存在干扰信号或非典型事件，这些因素会影响基于时频特征的识别效果。鉴于以上局限性，有必要引入更先进的机器学习方法以提高分类的准确性和效率。

2.2 基于机器学习的地震信号分类

本文采用 *K*-means、PCA、SVM 和 LCL-SSS 四种方法对 46 个矿震事件和 73 个爆破事件进行分类，并进行 30 次训练实验，结果如图 3 和表 1 所示。在分类过程中，提取每个事件的时域和频域特征，如振幅和峰值频率等。*K*-means 通过特征聚类进行分类；PCA 利用降维来识别主要特征；SVM 通过标记数据进行训练，学习分类边界；LCL-SSS 结合时频分析和多层次特征进行学习，优化分类结果并减少误判。

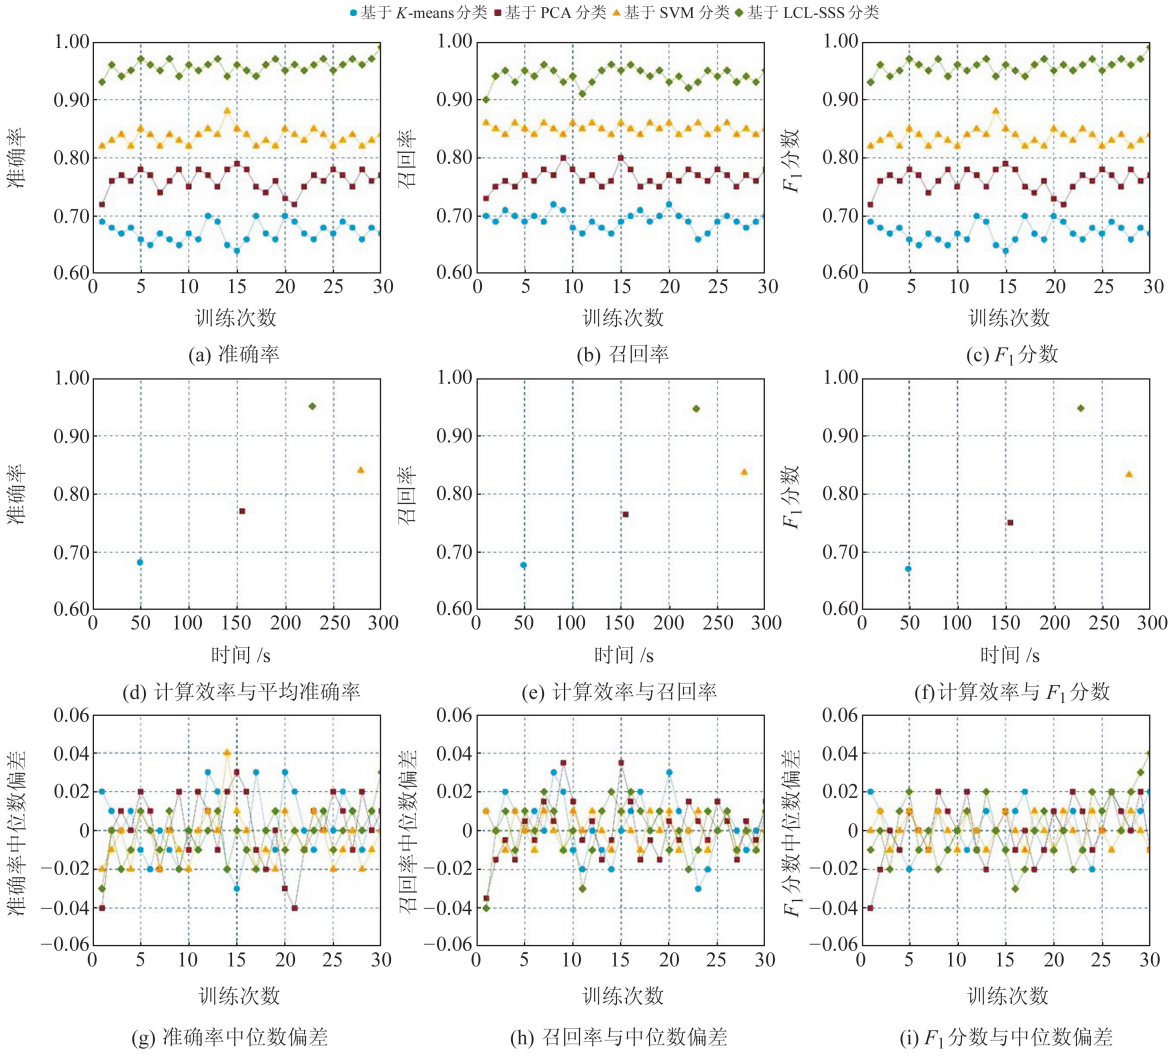


图 3 分类方法训练 30 次的准确率、召回率和 F_1 分数及与中位数的偏差

Fig. 3 Accuracy, recall, F_1 score, and deviation from median of classification method trained 30 times

表 1 不同分类方法结果

Tab. 1 Results of different classification methods

方法	类别	类型	准确率 /%	召回率 /%	F_1 分数 /%
基于 *K*-means 分类	无监督学习	矿震	60.02	65.76	61.34
		爆破	76.44	69.76	73.03
基于 PCA 分类	无监督学习	矿震	71.89	74.09	71.19
		爆破	82.13	78.83	80.88
基于 SVM 分类	监督学习	矿震	80.47	82.07	79.75
		爆破	87.59	85.25	86.81
基于 LCL-SSS 分类	协同学习	矿震	93.75	93.03	93.45
		爆破	96.39	96.23	95.96

由表 1 可见，LCL-SSS 结果最佳，准确率达 95.07%，在矿震和爆破事件的分类中均表现出色；SVM 和 PCA 次之，准确率分别为 84.03% 和 77.01%，两者都在爆破事件的识别上优于矿震；*K*-means 的准确率最低，为 68.23%，在识别矿震事件上存在较大困难。总体而言，所有分类方法在爆破事件的识别上均优于矿震，这可能是因为爆破事件的特征更加一致，便于识别。

图 3 显示，4 种分类方法的性能显著不同。其中，LCL-SSS 表现最佳，其准确率、召回率和 F_1 分数均较高且波动最小，展现出优异的分类性能和稳定性；SVM 次之，表现相对稳定，但训练过程中有波动；PCA 表现一般，波动较大，反映出特征

提取和分类的不稳定性;*K*-means 表现最差,波动最大,显示分类能力较弱。通过计算训练准确率、召回率和 F_1 分数与中位数的偏差,并结合 4 种方法的标准差来评估结果的稳定性,标准差越小结果越稳定。由表 2 可以看出,LCL-SSS 在准确率上最稳定,大部分集中在 0 附近,且多在 0 线上方,表明其性能普遍高于中位数;SVM 在准确率和 F_1 分数上较为稳定,但召回率波动较大;PCA 和 *K*-means 则显示出较大波动,尤其是 *K*-means,结果不稳定。

表 2　不同分类方法准确率、召回率、F_1 分数的标准差

Tab. 2　Standard deviation of accuracy, recall, and F_1 score for different classification methods

方法	类别	准确率标准差/%	召回率标准差/%	F_1 分数标准差/%
基于 *K*-means 分类	无监督学习	1.62	1.47	1.15
基于 PCA 分类	无监督学习	1.86	1.49	1.44
基于 SVM 分类	监督学习	1.44	1.82	0.78
基于 LCL-SSS 分类	协同学习	1.33	1.50	1.68

为直观比较各分类方法的效果,对矿震和爆破事件进行分类分析,并将结果可视化。由图 4 可见,*K*-means 在区分矿震和爆破事件时困难较大,尤其在交界区域,错误分类现象明显;PCA 有所改善,但仍存在错误分类;SVM 显著提高了准确性,错误点减少,分类能力良好;LCL-SSS 表现最佳,错误点最少,几乎实现完全正确分类。整体趋势显示,随着方法的进步,分类效果不断提升,错误率逐渐降低,LCL-SSS 在处理这类地震数据时展现出最佳性能。

3　讨　论

本文采用 *K*-means、PCA、SVM 和 LCL-SSS 四种方法对矿震与爆破事件进行分类识别,旨在评估不同算法在地震事件分类中的性能。结果显示,LCL-SSS 分类效果最佳,总体准确率达 95.07%,显著优于其他方法。LCL-SSS 结合高效的 Mini-Rocket 特征提取,能迅速捕捉地震波形关键特征;改进的 *K*-means 聚类算法增强了对非线性数据的处理能力;轻量化设计在确保高准确度的同时降低了计算复杂度,适合大规模实时数据的处理。此外,LCL-SSS 通过协同学习策略,结合无监督的特征提取和有监督的分类过程,减少了对大量标记数据的依赖,提高了模型的泛化能力。特别是在频率特征的识别上,LCL-SSS 能有效区分矿震(20～120 Hz)与爆破事件(80～200 Hz),在复杂频谱特征分类中表现出色。30 轮训练测试结果显示,LCL-SSS 方法高度稳定,保证了其在实际应用中的可靠性。

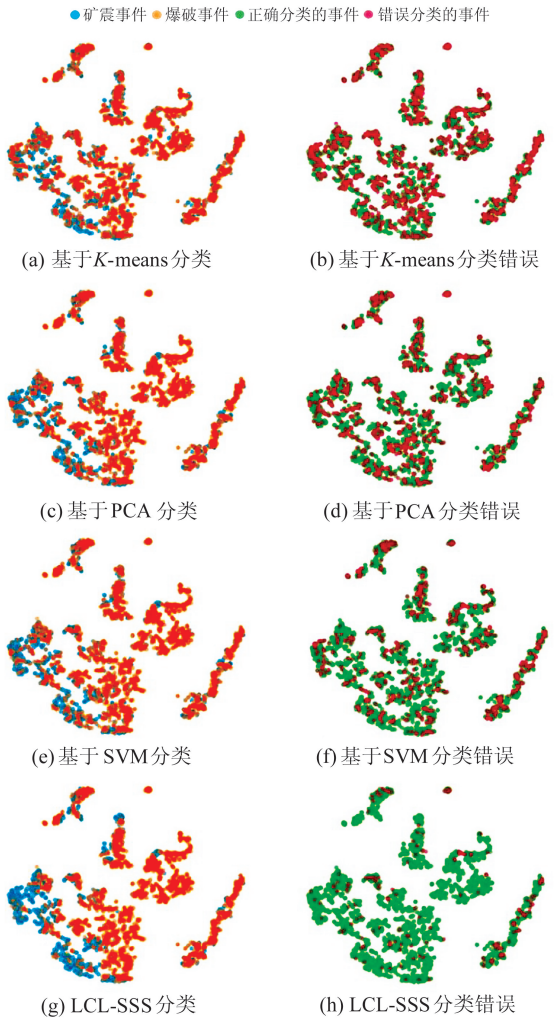


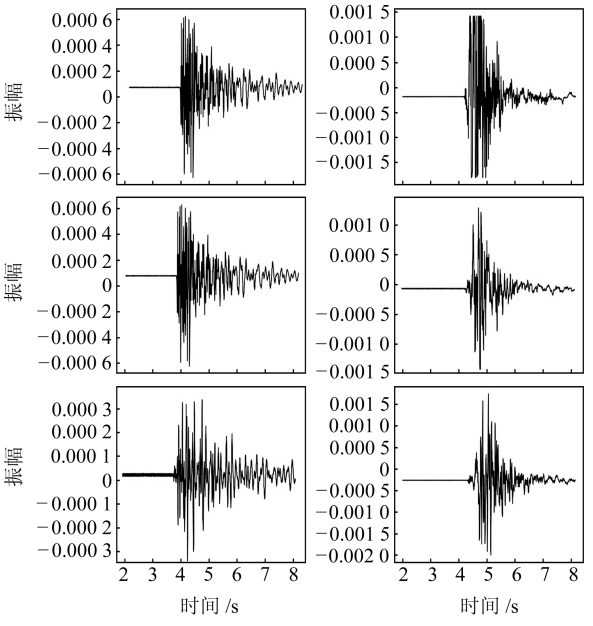
图 4　矿震与爆破信号 4 种分类模型的特征提取可视化

Fig. 4　Visualization of feature extraction for four classification models of mining seismic and blasting signals

相比之下,其他方法的分类能力与 LCL-SSS 相比存在明显差距。SVM 的准确率为 84.03%,表明监督分类方法在利用标记数据学习特征表示方面有优势,但其性能依赖于对手工特征的提取和选择,其表现受到特征质量的限制,无法全面捕捉地震信号的信息[21]。PCA 的准确率为 77.01%,作为一种线性降维方法,对地震信号的非线性特征提取能力有限[20],虽然低于监督学习,但仍表明无监督学习方法在处理地震信号时有潜力。*K*-means 的准确率最低,为 68.23%,表明其在处理信号特征方面的能力不足,难以有效区分矿震和爆破事件[19]。所有方法在识别爆破事件时的表现均优于矿震事件,可能因为爆破事件的波形和频谱特征更加一致和明显。

本文采用的地震事件数据包括地面台站和井下台站记录,比较两者的差异有助于理解矿震与

爆破信号的分类(图5和表3)。地面台站记录具有较大的震动幅度和广泛的频率范围,适合识别强震或爆破事件,但由于环境噪声干扰,面波较为发育,且高频成分较少,地面台站数量少,数据量不足,限制了特征提取,可能影响分类准确性。相比之下,井下台站记录因受矿井结构保护,噪声较少,高频成分丰富且衰减快,能提供更清晰的震动信号,有利于捕捉矿震特征并减少干扰,LCL-SSS方法在井下记录中的分类效果优于地面记录。



(a) 地面台站的波形 (b) 井下台站的波形

图5 地面台站与井下台站波形

Fig. 5 Waveforms of ground stations and underground stations

表3 不同分类方法在地面与井下台站上的分类结果

Tab. 3 Classification results of different classification methods on surface and underground stations

方法	类别	类型	准确率/%	召回率/%	F_1 分数/%
基于K-means分类	无监督学习	地面台站	64.12	66.45	62.10
		井下台站	72.34	70.56	72.22
基于PCA分类	无监督学习	地面台站	74.04	72.88	70.00
		井下台站	79.98	79.01	80.50
基于SVM分类	监督学习	地面台站	80.50	81.94	79.80
		井下台站	87.56	84.50	85.90
基于LCL-SSS分类	协同学习	地面台站	94.02	92.15	93.08
		井下台站	96.12	95.00	95.50

矿震本质上可视为一种特殊的构造地震,其发生机制与天然地震相似,均涉及岩体内应力的积累和释放,主要区别在于矿震通常发生在采矿活动影响区域,震源深度较浅,震中分布相对集中。在波形特征上,天然地震的波形在频谱和P/S比特征上介于典型爆破和矿震之间。通过对比各分类方法的效果发现,LCL-SSS在识别典型事件时表现出较高的准确性,而其他方法的分类结果存在较大误差,说明LCL-SSS在处理复杂信号时具有优势。

无监督学习方法具有独特优势,特别是在处理大规模数据集或面对未知事件时不需要人工标记。在实际应用中,获取大量准确标记的地震数据耗时且昂贵,因此无监督方法可作为初步分析工具。建立无监督方法在实践中应用相对简单,与有监督方法相比,不需要制作标签,计算成本低[16]。监督分类任务优化目标函数是 $E_{(x,y)\sim D}[\ln p_\theta(y\mid x)]$,从标记数据中提取与标签相关的信息;而无监督任务主要用于最大似然估计 $E_{x\sim D}[\ln p_\theta(x)]$。由于缺乏类别信息,无监督方法难以正确估计基于类别的分布,因此在基于全波形识别的地震类型研究中,较少使用无监督方法[23]。

LCL-SSS结合MiniRocket特征提取和改进的K-means聚类,能更好地捕捉地震信号的复杂非线性特征,尽管不直接使用标签信息,该方法通过特征提取和聚类算法发现数据中与不同类型地震事件相关的内在结构。与传统的无监督聚类方法(如K-means和PCA)相比,LCL-SSS能更准确地识别事件区分特征,表现更佳。这表明,创新的无监督学习技术有潜力克服传统无监督方法的限制,为地震数据分析提供新的可能。

4 结 语

本文对矿震与爆破事件进行时频分析和多种分类方法比较,得出以下结论:

1)矿震与爆破事件在时频特征上存在差异。时频分析表明,爆破事件波形P波能量强,初动多为向上,频率较高且分散,集中在80~200 Hz;相比之下,矿震事件波形更复杂,P波初动多为向下,衰减缓慢,频率主要分布在20~120 Hz。这些差异反映了两类事件的不同形成机制,也为自动化分类提供了重要特征,有助于矿山安全生产和矿震预警。

2)LCL-SSS在矿震信号分类中表现出色。LCL-SSS总体准确率达95.07%,显著优于SVM(84.03%)、PCA(77.01%)和K-means(68.23%),所有方法在识别爆破事件时的表现优于矿震事件,可能是因为爆破特征更为一致。尽管SVM等监督学习方法通常优于无监督方法,但LCL-SSS展示了无监督学习在矿震信号分类中的巨大潜力,特别适用于标记数据不足的情况。

3)LCL-SSS在矿震信号分类中展现出独特优势。在技术层面,LCL-SSS集成了高效的

MiniRocket特征提取和改进的 K-means 聚类算法,增强了对复杂非线性数据的处理能力,其轻量级设计保证了高准确度,同时降低了计算复杂度,适合实时处理大规模数据,在多轮训练测试中表现出优异的稳定性,能够识别复杂频谱特征。此外,LCL-SSS 无需手动制作标签,减少了前期工作量,计算成本低,适合处理缺乏先验信息的大规模地震数据。

尽管 LCL-SSS 表现优异,但由于矿震事件样本较少,存在过拟合问题。未来需不断收集不同区域的非天然地震事件样本,以提高方法的泛化能力。此外,随着机器学习方法的改进,分类准确率和计算效率仍有提升空间,未来将致力于实现更快速、精确的矿震事件分类研究。

致谢:本文图件使用 GMT 软件绘制,在此深表感谢。

参考文献

[1] Slawomir J G,Andrzej K. 矿山地震学引论[M]. 北京:地震出版社, 1998(Slawomir J G, Andrzej, K. Introduction to Mine Seismology[M]. Beijing: Seismological Press, 1998)

[2] 朱建波, 马斌文, 谢和平, 等. 煤矿矿震与冲击地压的区别与联系及矿震扰动诱冲初探[J]. 煤炭学报, 2022, 47(9): 3396-3409(Zhu Jianbo, Ma Binwen, Xie Heping, et al. Differences and Connections between Mining Seismicity and Coal Bursts in Coal Mines and Preliminary Study on Coal Bursts Induced by Mining Seismicity[J]. Journal of China Coal Society, 2022, 47(9): 3396-3409)

[3] Cai M F, Brown E T. Challenges in the Mining and Utilization of Deep Mineral Resources[J]. Engineering, 2017, 3(4): 9-12

[4] 袁亮, 姜耀东, 何学秋, 等. 煤矿典型动力灾害风险精准判识及监控预警关键技术研究进展[J]. 煤炭学报, 2018, 43(2): 306-318(Yuan Liang, Jiang Yaodong, He Xueqiu, et al. Research Progress of Precise Risk Accurate Identification and Monitoring Early Warning on Typical Dynamic Disasters in Coal Mine[J]. Journal of China Coal Society, 2018, 43(2): 306-318)

[5] 黄汉明, 边银菊, 卢世军, 等. v-SVC 算法在地震与爆破识别及窗长度选取中的应用[J]. 地震地磁观测与研究, 2010, 31(3): 24-31(Huang Hanming, Bian Yinju, Lu Shijun, et al. v—SVC Algorithm Applied in Earthquake and Explosion Recognition and the Choice of Window Length [J]. Seismological and Geomagnetic Observation and Research, 2010, 31(3): 24-31)

[6] Ghaffarzadeh H. A Classification Method for Pulse-Like Ground Motions Based on S-Transform[J]. Natural Hazards, 2016, 84(1): 335-350

[7] 韩绍卿, 李夕海. 基于离散 Gabor 变换的特征提取及其在核爆地震识别中的应用[C]. 第四届国家安全地球物理学术研讨会, 青岛, 2008(Han Shaoqing, Li Xihai. Feature Extraction Based on Discrete Gabor Transform and Its Application in Nuclear Explosion Earthquake Identification [C]. The 4th National Security Geophysics Academic Symposium, Qingdao, 2008)

[8] 黄汉明, 边银菊, 卢世军, 等. 天然地震与人工爆破的波形小波特征研究[J]. 地震学报, 2010, 32(3): 270-276(Huang Hanming, Bian Yinju, Lu Shijun, et al. A Wavelet Feature Research on Seismic Waveforms of Earthquakes and Explosions [J]. Acta Seismologica Sinica, 2010, 32(3): 270-276)

[9] Kuyuk H S, Yildirim E, Dogan E, et al. Application of k-Means and Gaussian Mixture Model for Classification of Seismic Activities in Istanbul[J]. Nonlinear Processes in Geophysics, 2012, 19(4): 411-419

[10] 赵明, 陈石, Yuen D. 基于深度学习卷积神经网络的地震波形自动分类与识别[J]. 地球物理学报, 2019, 62(1): 374-382(Zhao Ming, Chen Shi, Yuen D. Waveform Classification and Seismic Recognition by Convolution Neural Network[J]. Chinese Journal of Geophysics, 2019, 62(1): 374-382)

[11] Linville L, Pankow K, Draelos T. Deep Learning Models Augment Analyst Decisions for Event DiscriminationJ]. Geophysical Research Letters, 2019, 46(7): 3643-3651

[12] Zhou Y H, Chen W C. Recurrent Autoencoder Model for Unsupervised Seismic Facies Analysis[J]. Interpretation, 2022, 10(3): 451-460

[13] Puzyrev V, Elders C. Unsupervised Seismic Facies Classification Using Deep Convolutional Autoencoder[J]. Geophysics, 2022, 87(4): 125-132

[14] Dong L J, Li X B, Xie G N. Nonlinear Methodologies for Identifying Seismic Event and Nuclear Explosion Using Random Forest, Support Vector Machine, and Naive Bayes Classification[J]. Abstract and Applied Analysis, 2014(1)

[15] Mousavi S M, Beroza G C. A Machine-Learning Approach for Earthquake Magnitude Estimation[J]. Geophysical Research Letters, 2020, 47(1)

[16] Yin X X, Liu F, Cai R, et al. Research on Seismic Signal Analysis Based on Machine Learning[J]. Applied Sciences, 2022, 12(16)

[17] 徐增光. 地震信号的时频分析方法研究及实际应用[D]. 北京: 中国石油大学(北京), 2019(Xu Zengguang. Research and Practical Application of Time-Frequency Analysis Method of Seismic Signal[D]. Beijing: China University of Petroleum(Beijing), 2019)

[18] Dempster A, Schmidt D F, Webb G I. MiniRocket: A very Fast (almost) Deterministic Transform for Time Series Classification[C]. Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, Singapore, 2021

[19] MacQueen J. Some Methods for Classification and Analysis of Multivariate Observations[C]. Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability, Berkeley, 1967

[20] Jolliffe I T. Principal Component Analysis for Special Types of Data[M]. New York: Springer, 2002

[21] Cortes C, Vapnik V. Support-Vector Networks[J]. Machine Learning, 1995, 20(3): 273-297

Classification of Mining Seismic and Blasting Signals Based on Machine Learning

LIANG Xiaonan[1] *WANG Jianjun*[1] *YIN Xinxin*[2]

1 Lanzhou Institute of Seismology, CEA, 450 West-Donggang Road, Lanzhou 730000, China

2 Gansu Earthquake Agency, 450 West-Donggang Road, Lanzhou 730000, China

Abstract: This study focuses on the classification problem of mining seismic and blasting signals in a mine in Gansu province. Common unsupervised classification methods such as support vector machine, *K*-means clustering, and principal component analysis were analyzed. These methods face significant challenges in terms of insufficient feature selection, low classification accuracy, and imbalanced samples. To attempt to address these issues, this paper employs a lightweight collaborative learning method (LCL-SSS) that combines MiniRocket feature extraction with improved *K*-means clustering, aiming to enhance the accuracy and efficiency of classification. Through time-frequency analysis, it was found that the initial P-wave frequency of blasting events is mainly concentrated between 80 to 200 Hz, while the P-wave frequency of mining seismic events is distributed between 20 to 120 Hz. After 30 training experiments, the classification accuracy of the LCL-SSS method reached 95.07%, effectively capturing key features in mining seismic waveforms.

Key words: mining earthquake; time frequency analysis; unsupervised learning; classification of seismic signals

Foundation support: Fundamental Research Funds of the Institute of Earthquake Prediction, CEA, No. 2023IESLZ01; Science and Technology Program of Gansu Province, No. 23YFFA0015.

About the first author: LIANG Xiaonan, postgraduate, majors in seismology, E-mail: liangxiaonan22@mails.ucas.ac.cn.

Corresponding author: YIN Xinxin, PhD candidate, senior engineer, majors in seismic network monitoring and induced earthquakes, E-mail: yxx@gsdzj.gov.cn.

(上接第 1032 页)

Prediction Method of Sea Level Change in the South China Sea Based on NTFT-WSE

SUN Haozhe[1,2] *LIU Lintao*[2] *SUN Xuepeng*[2] *LIU Ziping*[1,2]

YE Zhourun[3] *LIANG Xinghui*[2] *SHEN Cong*[1,2] *WANG Guocheng*[2]

1 Innovation Academy for Precision Measurement Science and Technology, CAS, 340 Xudong Street, Wuhan 430077, China

2 University of Chinese Academy of Sciences, A19 Yuquan Road, Beijing 100049, China

3 College of Civil Engineering, Hefei University of Technology, 193 Tunxi Road, Hefei 230009, China

Abstract: A wideband signal extraction method based on normal time-frequency transform (NTFT-WSE) is proposed based on standard time-frequency theory. First, the standard time-frequency transform is used to extract and model the periodic signals of sea level. Then, the NTFT-WSE method is employed to extract, model, and predict the components at different time scales, achieving accurate prediction of the periodic low-frequency signals of sea level changes. Compared with the standard Morlet wavelet transform, the NTFT-WSE method reduces the root mean square error (RMSE) and mean absolute error (MAE) in periodic signal extraction by 26.03% and 22.24%, respectively, significantly improving the extraction accuracy of mid- and low-frequency signals. Finally, based on satellite altimetry sea level anomaly data from June 1993 to May 2008, the NTFT-WSE method was used to predict the sea level changes in the south China sea from June 2008 to May 2023. The prediction results are consistent with the overall trend of actual observations.

Key words: sea level anomaly; Morlet wavelet transform; sea level change; prediction; normal time-frequency transform; south China sea

Foundation support: National Natural Science Foundation of China, No. 42074011.

About the first author: SUN Haozhe, postgraduate, majors in geoscience signal processing, E-mail: sunhaozhe22@mails.ucas.ac.cn.

Corresponding author: LIU Lintao, researcher, majors in normal time-frequency transform, E-mail: llt@asch.whigg.ac.cn.