



地震学报

ACTA SEISMOLOGICA SINICA



ISSN 0253-3782 CN 11-2021/P

## 基于时频特征和机器学习的小震级地震事件类型识别

李雪颜 边银菊 侯晓琳 王婷婷 张艺潇

### Recognition of small magnitude seismic event type based on time-frequency features and machine learning

Li Xueyan, Bian Yinju, Hou Xiaolin, Wang Tingting, Zhang Yixiao

引用本文:

李雪颜, 边银菊, 侯晓琳, 王婷婷, 张艺潇. 2025. 基于时频特征和机器学习的小震级地震事件类型识别. *地震学报*[J], 47(4): 594–609. DOI: 10.11939/jass.20240012

Li X Y, Bian Y J, Hou X L, Wang T T, Zhang Y X. 2025. Recognition of small magnitude seismic event type based on time–frequency features and machine learning. *Acta Seismologica Sinica*[J], 47(4): 594–609. DOI: 10.11939/jass.20240012

在线阅读 View online: <https://doi.org/10.11939/jass.20240012>

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 基于短时傅里叶变换和卷积神经网络的地震事件分类

Classification of seismic events based on short–time Fourier transform and convolutional neural network  
地震学报. 2021, 43(4): 463–473 <https://doi.org/10.11939/jass.20200128>

#### 基于格拉姆角场和多尺度残差神经网络的地震事件分类方法

Seismic events classification based on Gram’s angle field and multi–scale residual neural network  
地震学报. 2024, 46(1): 69–80 <https://doi.org/10.11939/jass.20220144>

#### 不同地区人工爆炸与天然地震记录特征及识别研究

Research on seismic characteristics and identification of artificial explosion in different areas and natural earthquake  
地震学报. 2021, 43(4): 427–440 <https://doi.org/10.11939/jass.20210169>

#### 基于机器学习的长宁地震三维断层几何特征建模

Geometry features modeling of three–dimensional fault plane of Changning earthquake based on machine learning  
地震学报. 2023, 45(6): 1040–1054 <https://doi.org/10.11939/jass.20220079>

#### 基于深度学习的地震震级分类

Earthquake magnitude classification based on deep learning  
地震学报. 2022, 44(4): 656–664 <https://doi.org/10.11939/jass.20210046>

#### 天山中段地区重复地震时空特征研究

Spatio–temporal characteristics of repeating seismic events in the middle of Tianshan orogenic belt  
地震学报. 2021, 43(5): 551–568 <https://doi.org/10.11939/jass.20200192>

李雪颜, 边银菊, 侯晓琳, 王婷婷, 张艺潇. 2025. 基于时频特征和机器学习的小震级地震事件类型识别. 地震学报, 47(4): 594–609. doi: 10.11939/jass.20240012.  
Li X Y, Bian Y J, Hou X L, Wang T T, Zhang Y X. 2025. Recognition of small magnitude seismic event type based on time-frequency features and machine learning. *Acta Seismologica Sinica*, 47(4): 594–609. doi: 10.11939/jass.20240012.

# 基于时频特征和机器学习的小震级 地震事件类型识别\*

李雪颜 边银菊\* 侯晓琳 王婷婷 张艺潇

(中国北京 100081 中国地震局地球物理研究所)

**摘要** 针对华北地区小震级( $M_L \leq 3.0$ )地震事件, 利用  $K$ -近邻算法(KNN)、自适应提升算法(AdaBoost)和轻量级梯度提升机算法(LGBM)对天然地震、人工爆破以及矿震塌陷事件进行类型识别. 首先对地震事件波形记录和时频谱进行分析, 提取时间、P 波与 S 波振幅比、频率、过零率、峰值振幅、峰值加速度、能量、信号、角度及其它比值等 10 个类别的 62 个特征, 并将这些特征作为分类的基础; 然后采用三种分类算法分别对二分类任务和三分类任务进行模型训练; 最后对测试数据的类型进行识别. 结果显示: 所有分类模型的识别准确率均达 90.0% 以上, 其中 LGBM 的综合性能最强, AdaBoost 次之; 不同分类任务中天然地震与矿震的分类模型表现最佳.

**关键词** 天然地震 非天然地震事件 特征提取 地震事件分类

doi: 10.11939/jass.20240012 中图分类号: P315.61 文献标识码: A

## Recognition of small magnitude seismic event type based on time-frequency features and machine learning

Li Xueyan Bian Yinju\* Hou Xiaolin Wang Tingting Zhang Yixiao

(Institute of Geophysics, China Earthquake Administration, Beijing 100081, China)

**Abstract:** The recognition and classification of seismic events hold significant importance in seismic monitoring and earthquake disaster mitigation. This research primarily focuses on 1935 seismic event data with low magnitude ( $M_L \leq 3.0$ ) in the North China region, encompassing three distinct types of events: natural earthquakes, artificial explosions, and mining collapses. Preliminary analysis of the earthquake catalog involved the geographical distribution examination, annual trends, and magnitude distribution of these events. Preprocessing of raw seismic data included amplitude normalization, detrending, mean removal, and band-pass filtering (0.5–20 Hz). Additionally, short-time Fourier transform analysis was utilized to visualize waveform and spectrogram characteristics, facilitating the observation and analysis of both time and frequency domain features. Based on the analysis results, 62 features across 10 categories,

\* 基金项目 北京市自然科学基金(8234066)和中国地震局地球物理研究所  
自主立项项目(0722001)联合资助.

收稿日期 2024-01-23 收到初稿, 2024-05-25 决定采用修改稿.

作者简介 李雪颜, 在读硕士研究生, 主要从事地震监测研究, e-mail:  
lixueyan21@mails.ucas.ac.cn; \* 通信作者: 边银菊, 博士, 研  
究员, 主要从事地震核查研究, e-mail: bianyinju@cea-igp.ac.cn



including time, P/S amplitude ratio, frequency, zero-crossing rate, peak amplitude, peak ground acceleration, energy, signal characteristics, angle, and other ratios, were extracted as the foundation for classification.

This research employed *K*-Nearest Neighbors (KNN), Adaptive Boosting (AdaBoost), and Light Gradient Boosting Machine (LGBM) algorithms to classify the seismic events. The models were trained on the extracted 62 features for binary and ternary classification tasks of natural earthquakes, artificial explosions, and mining collapses. The basic principles of KNN, AdaBoost, and LGBM algorithms were initially introduced, followed by a description of the training process for the classification models. To ensure balanced sample distribution for each event type, data were selected based on uniform distribution of time and geographical location. Ultimately, 545 events for each event type, totaling 1635 seismic events, were chosen as the sample data for building the classification models. The dataset was divided into training and testing sets using a holdout method, with 75% of the data used for model construction and validation, and 25% for evaluating model performance. The training data covered the main geographical range of the North China region (109.3°E–123.5°E, 34.1°N–43.7°N), ensuring the models could capture the region's diversity and complexity. The testing data covered a slightly different geographical range (110.8°E–124.1°E, 34.9°N–42.7°N).

The 62 features were used to train classification models by KNN, AdaBoost, and LGBM algorithms. Models were trained with number 0 representing natural earthquakes, number 1 representing artificial explosions, and number 2 representing mining collapses. Various classification models were evaluated using KNN, AdaBoost, and LGBM, with each model trained and tested 100 times for 0–1, 0–2, 1–2, and 0–1–2 classification tasks. AdaBoost and LGBM demonstrated superior performance compared to KNN across all classification tasks, especially in 0–1 and 0–1–2 classification tasks. LGBM consistently exhibited the best overall performance, maintaining an accuracy of over 95% and showing high stability. In different classification tasks, 0–2 classification yielded the most outstanding results, followed by 1–2 classification.

Following the training of classification models, the focus shifted to comprehensive evaluation of these models using testing data. Each model was used to identify the event types in the testing data, yielding performance results for each model across different classification tasks. Confusion matrices were generated based on identification results, demonstrating excellent performance for each classification task, particularly in the 0–2 classification using three different classification algorithms.

Based on confusion matrices, performance evaluation metrics, including accuracy, precision, recall, and  $F_1$  score, were calculated. In the 0–1 classification task, AdaBoost performed the best, achieving an accuracy of 96.69%. In the 0–2 classification task, all three algorithms performed well, with evaluation metrics exceeding 99.26%. In the 1–2 and 0–1–2 classifications, LGBM exhibited the best performance. Overall, each classification model demonstrated excellent performance, with accuracy, precision, recall, and  $F_1$  score all exceeding 89.71%.

LGBM exhibited superior overall performance, maintaining an accuracy of over 96.32% and demonstrating high stability. KNN still has significant room for improvement, possibly due to its sensitivity to data, resulting in relatively weaker performance compared to AdaBoost and LGBM. AdaBoost's overall performance lies between LGBM and KNN.

Finally, ROC curves were plotted to visualize the recognition of the testing dataset using three different classification algorithms (KNN, AdaBoost, LGBM). While KNN algorithm performance for 0-1 and 1-2 classifications requires optimization, all other models performed exceptionally well in the ternary classification scenario. Confusion matrices and evaluation metrics indicate that the constructed classification models perform well on testing data, with ROC curve analysis further confirming the excellent performance of the classification models in various tasks, revealing the applicability of different algorithms in their respective tasks, and providing strong support for the practical application of the models.

**Key words:** natural earthquake; non-natural seismic events; feature extraction; classification of seismic events

## 引言

随着科技的迅速发展和全球地缘政治局势的持续紧张,非天然地震活动的监测与识别成为维护国家安全的关键一环。地下核爆的有效监测有助于国际社会更好地履行《全面禁止核试验条约》等国际公约,从而维护全球核安全。非天然地震识别技术对地下核爆和区域性非天然地震事件监测、国家军事响应能力和国家安全保障尤为重要(Chiang *et al.*, 2018; Gaebler *et al.*, 2019; Wang *et al.*, 2022)。一方面,天然地震目录中往往混杂着非天然地震,不利于构造地震的研究;另一方面,地震事件数量随震级的降低呈指数级增长,淹没在小震级地震事件中的特殊地震事件更加难以检测和识别。因此,对小震级地震事件进行分析、识别和验证将成为推动监测与识别非天然地震技术发展的重要方向。

非天然地震事件涵盖工业爆破、矿震塌陷、核爆破、滑坡等。早期对地震事件类型的识别研究主要聚焦于区分天然地震与核爆破,国内外学者已将发震位置、P波初动方向、 $m_b/M_s$ 、震相幅值比等特征作为识别核爆的重要判据(Pomeroy *et al.*, 1982; Taylor *et al.*, 1989; 边银菊, 2005; Selby *et al.*, 2005; Chiang *et al.*, 2014)。随着研究的逐步深入,地震事件类型识别的量化特征得以提取与验证。例如:王婷婷和边银菊(2011)提出P波初动振幅与S波峰值振幅之比、P波峰值振幅与S波峰值振幅之比可作为首都圈小震级天然地震与爆破事件的判定依据;靳玉贞等(2015, 2019)发现优势频率可用于识别山西地区的非天然地震事件;杨千里等(2020)根据地震与爆破在时频谱中频带范围和能量团分布的差异性引入谱图二阶矩,将其作为新的识别判据;Voyles等(2020)和Koper等(2021)均指出 $M_L-M_C$ 是区分爆破与天然地震的有效度量;Sanina等(2021)将P波与Lg波振幅谱比值的对数与频率的关系曲线斜率作为新判据,以区分短时群爆破与地震;Zhang等(2021)的研究结果表明P波与S波振幅比、持续时间、谱图二阶矩、拐角频率等32个特征对地震、爆破和矿震三类事件具有良好的分类性能。

近年来人工智能方法及其联合其它方法在非天然地震事件分类方面的应用也有重大进展。陈润航等(2018)采用卷积神经网络与梅尔频率倒谱系数对首都圈及其周边地区的天然地震与人工爆破事件进行分类识别,正确识别率高达97.1%。Tibi等(2019)对美国犹他州地区的地震事件采用振幅比和机器学习方法进行对比研究,结果显示振幅比联合多元二次判别函数得到的准确率为80%—90%,训练卷积神经网络模型所得的准确率为90%—100%,最佳方案是结合振幅比和机器学习方法各自的长处。Jia等(2022)参考卷积神经网络结构VGGnet, ResNet和Inception设计了三种地震事件分类器,利用三通道地震全波形时间序列数据和频谱

数据对设计的分类器进行了测试和比较,结果显示地震、爆破和矿山坍塌的快速分类可以在事件发生后约 1 分钟内完成. Ren 等(2022)使用 AlexNet 卷积神经网络模型对宁夏及周边地区地震事件的波形记录进行了识别,其结果显示对天然地震的识别准确率可达 100%,而对爆破和塌陷的准确率为 85% 左右. Kong 等(2022)提出将深度学习与物理特征相结合的地震事件识别方法,对天然地震与爆破事件进行有效区分,该组合方法具有更强的泛化能力. Yue 等(2023)构建了一个包含 7 层卷积神经网络的模型,通过地震波形图像和时频谱信息对自然地震、爆破和塌陷地震事件进行分类,试验结果表明模型识别性能良好,平均准确率达 96.13%. Barama 等(2023)使用 P 波地震记录和卷积神经网络训练得到了一个地震源分类器,通过该分类器对天然地震的 P 波、地下核爆破的 P 波以及噪声进行识别、验证,准确率超过 95%. 隗永刚等(2019)提出了基于深度学习残差网络模型的爆破识别方法,并使用该方法对河北三河采石场的爆破和周边地震事件进行识别研究,结果表明该模型的识别率达 97.3% 且效果稳定. 任涛等(2019)采用 Bagging 机器学习算法对 80—200 km 震中距范围内的地震事件进行识别,准确率达 85% 以上. Wang 等(2022)利用五种人工智能方法构建了中国中东部地区地震、爆破和矿震的两分类与三分类模型,其中,地震与矿震分类器和地震与爆破分类器的平均准确率分别为 97.4%—98.4% 和 96.5%—97.6%. Mousavi 等(2016)利用人工神经网络模型和逻辑回归模型将震源深度小于 250 m 的事件从震源深度为 1—2 km 的事件中区分出来,准确率为 88%—90.7%. Shang 等(2017)使用主成分分析(principal components analysis, 缩写为 PCA)和人工神经网络(artificial neural network, 缩写为 ANN)对微震事件与采石场爆破的判别进行了研究,PCA 的准确率达到 89%,这表明 PCA-ANN 分类器在微震事件分类中最为可靠且具有潜力. Lindenbaum 等(2020)通过训练神经网络和树分类器来判断可疑事件的性质,并将此方法应用于在以色列和约旦收集的 1609 个事件中,取得了良好的效果. Tan 等(2021)将线性判别函数(linear discriminant function, 缩写为 LDF)和 ANN 方法应用于土耳其埃迪尔内(Edirne)地区及其附近的地震事件,以区分地震与采石场爆破,结果显示 LDF 和 ANN 方法的准确率分别为 95% 和 99%. 范晓易等(2020)利用小波变换从山东地区的天然地震、爆破和塌陷事件中提取出香农熵特征,采用支持向量机方法(a library of support vector machine, 缩写为 LIBSVM)进行分类识别,并分析了影响分类效果的因素. 蔡杏辉等(2021)结合 P 波与 S 波振幅比、小波包对数能量熵、小波能量比、波形能量分布的特征组合和支持向量机对福建地区的天然地震和人工爆破事件进行事件类型判别,识别准确率达到 94.5%. 梁皓等(2023)使用支持向量机方法对中国东北地区的天然地震、爆破和塌陷事件进行了分类识别,结果显示,该方法在三分类识别中的准确率高达 99.2%,证明了支持向量机在小样本量地震事件分类中的潜在应用前景. 这些研究表明人工智能方法在地震事件类型识别方面表现优异,有必要深入研究.

为此,本文将聚焦于华北地区  $M_L 3.0$  以下的天然地震、人工爆破和矿震塌陷三种不同类型的地震事件,对地震波形、频率及能量进行分析,提取并量化时域、频域和能量特征,建立相应的特征训练集和测试集,结合三种不同的机器学习方法对三类事件进行分类,对分类效果进行评估分析,对比不同分类器的性能,旨在建立高精度的地震事件分类模型,实现对天然地震、人工爆破和矿震塌陷的可靠判别.

1 地震数据预处理

1.1 地震数据收集、整理与分析

从北京遥测数字地震台网和国家测震台网数据备份中心获取了华北地区(108.4°E—124.1°E, 34.1°N—43.7°N)在2008年8月至2016年12月期间天然地震、人工爆破和矿震塌陷三类事件的目录及相应的地震波形记录. 在对三类事件的波形、发震时间和发震地点逐一进行检视后, 筛选出天然地震741次、人工爆破608次, 矿震塌陷586次, 总计事件1935个. 为确保每类事件的样本数量均衡, 按照发震时间和地理位置的分布均匀性进行了筛选, 最终确定每类事件545个, 将总共1635个事件作为样本数据. 在本研究中, 我们采用留出法将样本数据划分为训练数据和测试数据两部分, 其中: 训练数据占总样本的75%, 用于构建与验证分类模型; 测试数据占总样本的25%, 用于评估分类模型的性能. 训练数据的覆盖范围为(109.3°E—123.5°E, 34.1°N—43.7°N)(图1a), 该范围包含了华北地区的核心区域, 可确保模型在训练阶段能够涵盖地区的多样性和复杂性. 测试数据的范围为(110.8°E—124.1°E, 34.9°N—42.7°N)(图1b). 从数据分布图中可以看出, 天然地震呈随机分布的特点, 相比之下, 人工爆破呈相对聚集的状态, 矿震塌陷则最为集中.

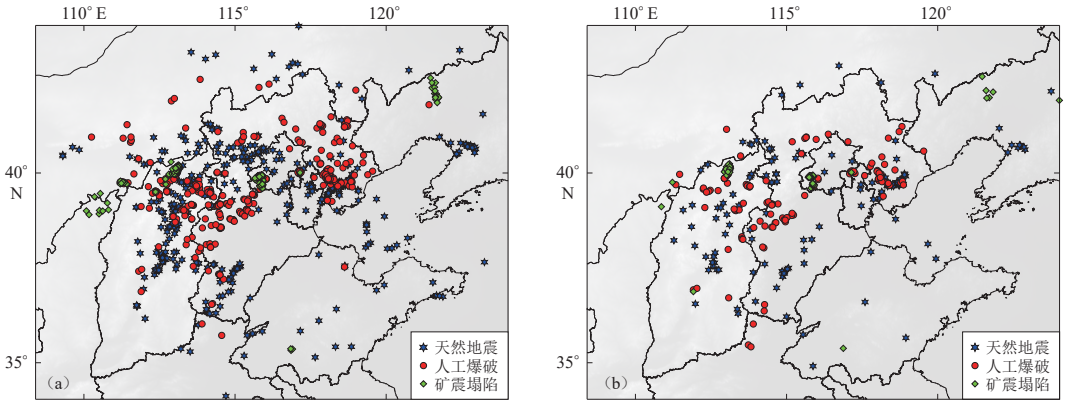


图1 华北地区训练数据(a)和测试数据(b)的地震事件分布图

Fig. 1 Distribution of train data (a) and test data (b) of seismic events in North China

图2为2008年到2016年间华北地区天然地震、人工爆破和矿震塌陷数量的年度分布直方图, 从中可以更直观地观察到地震事件数量的年度变化趋势. 由于数据从2008年8月开始统计, 所以2008年的地震事件数量相较于其它年份偏少. 天然地震的数量分布整体呈现随机性, 反映了构造地震在不同年份的多样性和复杂性; 人工爆破的数量在2010年达到峰值, 2013年后骤减, 可能与首都圈城市、公路工程等处于建设高峰期有关; 矿震塌陷的数量在2013年明显增大, 而后逐年减小. 通过分析这些地震事件数量的年度变化趋势, 能够更好地揭示人类活动对地震事件的影响.

三类事件的震级均为 $M_L 3.0$ 以下, 主要集中在 $M_L 1.5—2.5$ 范围内, 其中, 天然地震的震级主要分布在 $M_L 1.5—2.0$ 之间, 而人工爆破和矿震塌陷的震级主要分布在 $M_L 1.5—2.5$ . 地震事件的训练数据和测试数据样本的震级分布统计直方图如图3所示, 可见训练数据和测试数据的震级分布之间的差异微小, 两者保持了高度的一致性.

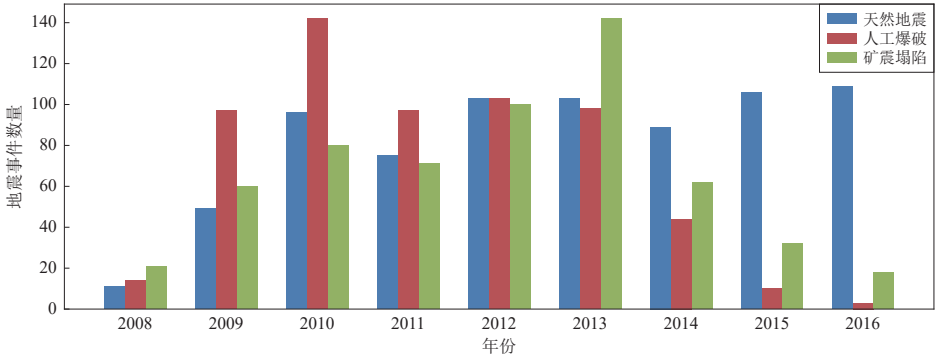


图 2 2008—2016 年华北地区三类地震事件年度分布

Fig. 2 Annual distribution of three types of seismic events of North China during 2008–2016

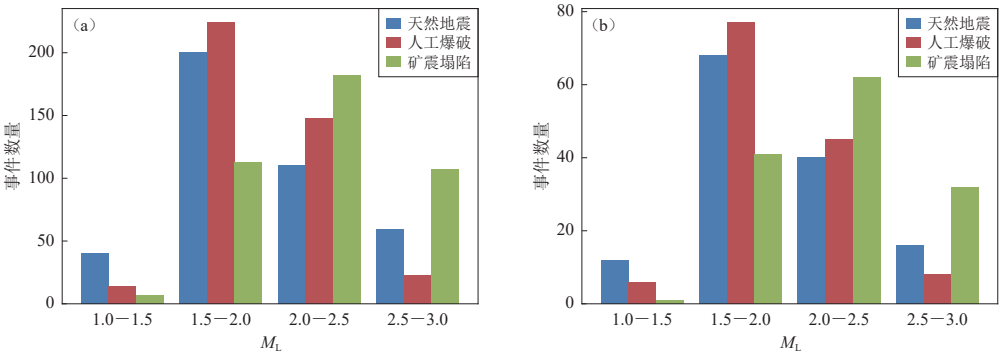


图 3 训练数据(a)和测试数据(b)地震事件震级分布统计

Fig. 3 Statistics on magnitude distribution of train data (a) and test data (b) of seismic events

本研究涉及的地震事件类型主要分为三类：天然地震、人工爆破和矿震塌陷。天然地震释放的能量较大且持续时间较长，地震波的成分复杂，衰减速度较慢，所记录到的波形数据通常较为连续、平滑。人工爆破主要指由工业活动引起的爆破事件，一般发生在近地表，传播介质较为疏松，相较于天然地震，人工爆破产生的地震波波形特征更简单，衰减速度更快。矿震塌陷主要指采矿活动引起的震动和地下空间塌陷所导致的地震事件，其震源深度较浅，由于矿山地质条件的复杂性和采矿活动的影响，此类地震波的传播路径也相对不稳定，会受到地形地貌的影响，从而导致地震波在传播过程中可能失真或迅速衰减(赵永等, 1995; Zhang et al, 2021)。本研究首先对原始地震数据进行预处理，包括振幅归一化、去趋势、去均值和带通滤波(0.5—20 Hz)，之后进行短时傅里叶变换，最终筛选出震中距 300 km 以内的地震波形；然后绘制三类地震事件的波形记录和时频图，藉此更详细地观察地震事件在时域和频域上的特征，从中挑选较具代表性的三类事件的单台记录(图 4)，更直观地比较三类记录在时频域上的差异。

由图 4 可见：天然地震的波形(图 4a)频带较宽，在 0—20 Hz 均有能量分布，且主要集中在 3—12 Hz，S 波振幅和能量明显大于 P 波；人工爆破的波形(图 4b)中 P 波十分尖锐，持续时间较短，衰减迅速，能量瞬间释放，集中在 5—15 Hz，符合爆破源的瞬时特性，S 波能量和振幅低于 P 波，频率低于 10 Hz；矿震塌陷的波形(图 4c)衰减缓慢，持续时间较长，以低频成

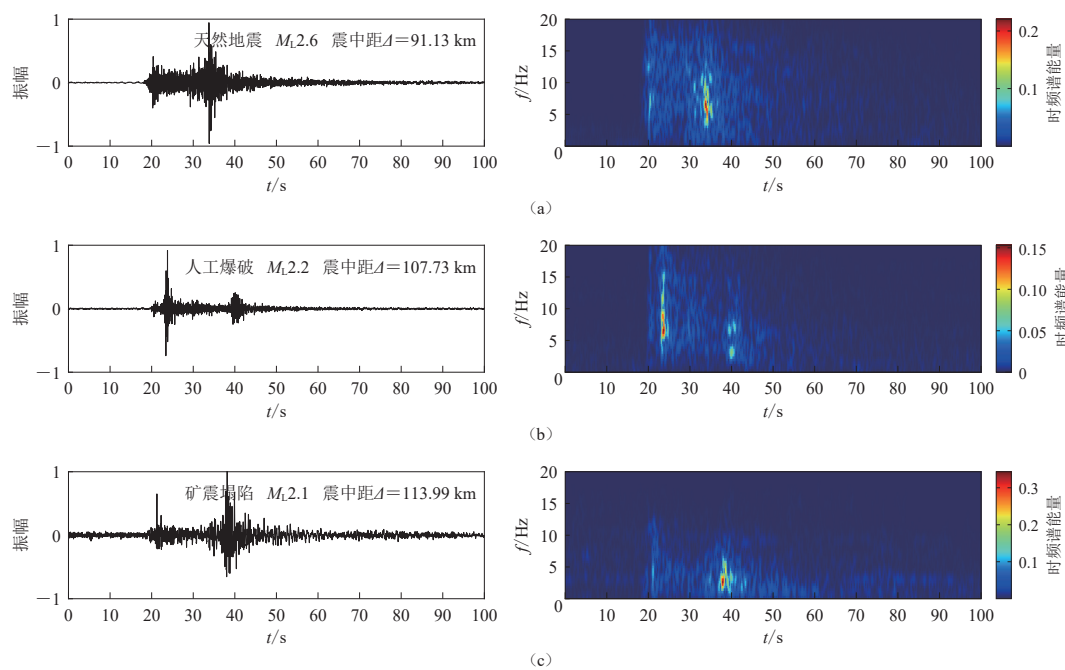


图 4 天然地震(a)、人工爆破(b)、矿震塌陷(c)的波形记录(左)和时频谱图(右)

Fig. 4 Waveform records (left panels) and time-frequency spectrograms (right panels) of natural earthquake (a), artificial explosion (b) and mining collapse (c), respectively

表 1 地震事件类型识别所提取的特征表

Table 1 Table of extracted features used for event type recognition

特征	物理意义	数量
时间	地震波形从起始点到达波峰所需的时间;从波峰到达结束点所需的时间;从起始点到结束点所经历的总时间;地震波形超过设定阈值的持续时间;地震波形在超过设定阈值后到达波峰所需的时间;地震波形在超过设定阈值后从波峰到结束点所需的时间;地震波形在超过设定阈值前波形的上升、下降时间;两个相邻的波峰或波谷之间的时间间隔,即两个相邻波峰或波谷之间的周期(Kim <i>et al.</i> , 2021; 薛思敏等, 2022)	9
P波与S波振幅比	P波与S波峰值振幅之比(Yildirim <i>et al.</i> , 2011);对P波、S波进行傅里叶变换,滤波波段为1—20 Hz时P波与S波振幅比(Wang <i>et al.</i> , 2021)	21
频率	地震信号中波形每秒振动的次数,为周期的倒数(Levshin, Ritzwoller, 1995),其中:中心频率为地震信号在频率域中的中心位置;主频率为地震信号中最大振幅对应的频率;平均频率为地震信号频谱的加权平均频率;地震波形在上升或下降阶段的平均频率;波形上升、下降时,地震信号在超过设定阈值情况下的平均频率;地震信号复倒频谱的实部(魏富胜,黎明, 2003)	9
过零率	地震波形从正值变为负值,或从负值变为正值的次数,具体指地震信号在超过设定阈值情况下的过零率、峰值振幅前后的过零率、地震信号在超过设定阈值情况下的最大振幅前后的过零率(Dargahi-Noubary, 1998)	6
峰值振幅	地震波形中振幅达到的最大值(Horasan <i>et al.</i> , 2009; Badawy <i>et al.</i> , 2019)	1
峰值加速度	地震信号中垂直于水平面的最大加速度值(Goforth <i>et al.</i> , 2006)	1
能量	地震信号总能量,峰值振幅前的吸收能量,峰值振幅后的衰减能量(刘莎等, 2012)	3
信号	地震信号强度,信号均方根(Laasri <i>et al.</i> , 2015; Saad <i>et al.</i> , 2019)	2
其它比值	地震波形的上升时间与峰值振幅之比RA,地震波形的下降时间与峰值振幅之比DA,阈值之上的上升、下降时间与振幅的比值;RA与地震波形的平均频率AF之比RA/AF,DA与地震波形的平均频率AF之比DA/AF(吴顺川等, 2020)	6
角度	地震波形的上升、下降角度,为RA与DA的反正切函数(Ma <i>et al.</i> , 2015);地震信号在超过设定阈值情况下的上升、下降角度	4

分(1—6 Hz)为主.

1.2 特征选择与提取

根据上述对天然地震、人工爆破、矿震塌陷三类地震事件的波形记录和时频谱图的综合分析, 对三类事件垂直分量的地震记录进行特征提取. 结合相关特征在地学领域的物理意义和应用背景, 编写了相应的计算函数, 准确提取出每类特征的具体数值, 并对多个台站的计算结果进行平均. 从这些原始地震数据中共提取了 62 个特征, 这些特征分为时间、P 波与 S 波振幅比、频率、过零率、峰值振幅、峰值加速度、能量、信号、角度、其它比值等 10 个类别, 其具体描述列于表 1.

在上述特征的提取过程中, 不仅关注地震学领域中常用的事件类型识别判据, 还引入了岩石力学领域的一些常用分类特征, 例如地震波形上升时间与峰值振幅之比 RA, RA 与地震

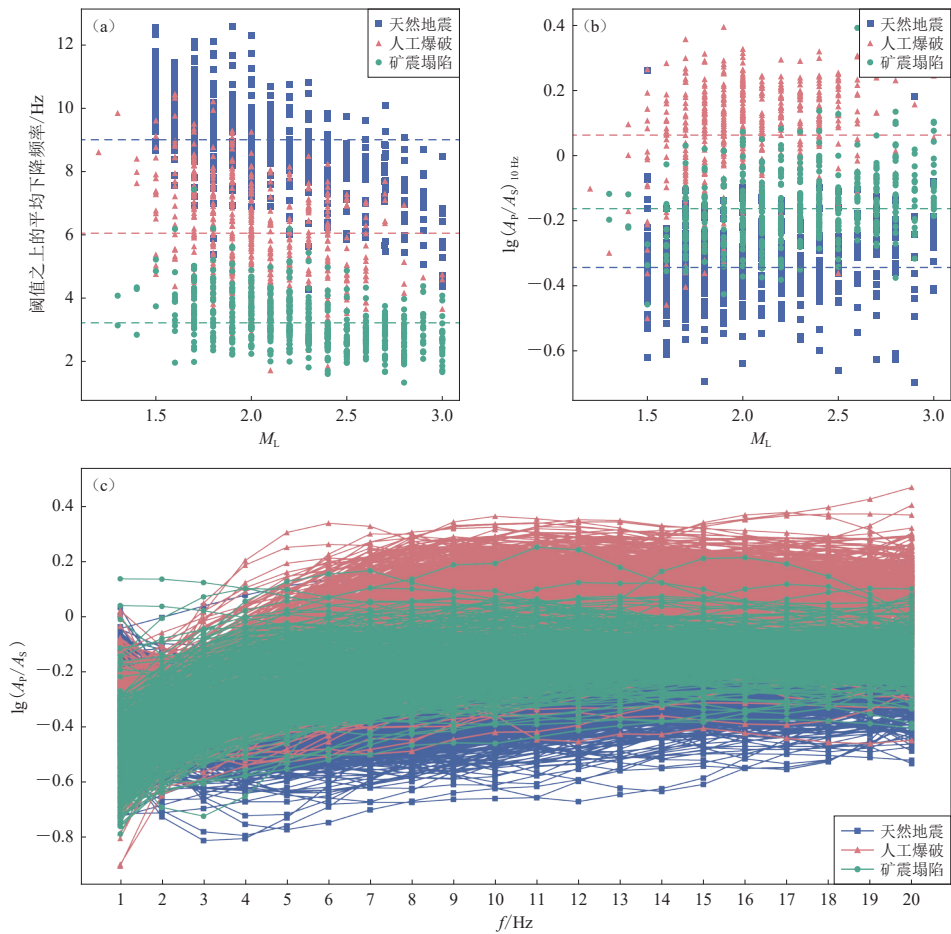


图 5 三类事件部分特征分布图

(a) 阈值之上的平均下降频率特征分布; (b) 滤波波段为 9.5—10.5 Hz 的 P 波与 S 波振幅比  $A_P/A_S$  特征分布;  
(c) 1—20 Hz 频带的 P 波与 S 波振幅比  $A_P/A_S$  特征分布

Fig. 5 Distribution of partial features for three types of events

(a) Distribution of features of the average frequency decay above the threshold; (b) Distribution of P/S amplitude ratio  $A_P/A_S$  at the filter band 9.5–10.5 Hz; (c) Distribution of P/S amplitude ratio  $A_P/A_S$  at the frequency band from 1 to 20 Hz

波形的平均频率  $AF$  之比  $RA/AF$ , 地震波形下降时间与峰值振幅之比  $DA$  和  $DA/AF$  等(吴顺川等, 2020)。这种综合的特征选择和提取方法能够更全面、更准确地揭示不同类型地震事件的特性, 为后续分析和分类模型的搭建奠定基础。

图 5 展示了所提取的 62 个特征中部分特征的分布情况。图 5a 和 5b 分别为阈值之上的平均下降频率和 P 波与 S 波振幅比(滤波波段为 9.5—10.5 Hz)的特征分布图, 三类事件中这两个特征集中在不同数值分布范围。可以观察到: 图 5a 中天然地震的均值最大, 而矿震塌陷的均值最小; 图 5b 中天然地震的均值最小, 人工爆破的均值最大; 图 5c 为 1—20 Hz 频带的 P 波与 S 波振幅比数值分布图, 可见 5 Hz 以后人工爆破的 P 波与 S 波振幅比趋于最大, 天然地震的振幅比趋于最小。

## 2 分类模型原理

### 2.1 $K$ -近邻算法

$K$ -近邻算法( $K$ -Nearest Neighbor, 缩写为 KNN)是一种基本分类和回归方法, 本研究仅涉及 KNN 的分类问题。在 KNN 的分类过程中, 首先, 给定一个训练数据集, 该数据集包含已知类别的样本。对于新的输入实例, 算法会在训练数据集中找到与该实例最邻近的  $K$  个实例, 通常通过计算距离来确定其邻近性; 其次, KNN 算法将统计这  $K$  个邻近实例中各个类别出现的频率; 最后, 将输入实例分类到其中出现频率最高的类别, 成为该实例的预测分类。这种基于近邻性的分类方法, 能够在不依赖先验概率分布的情况下, 通过对数据集的直接学习进行预测, 具有较好的适用性和灵活性。在实际应用中, KNN 算法曾用于火山构造地震的分类与识别、微震事件和爆破事件的分类问题(Peng *et al.*, 2021; Pérez *et al.*, 2022), 为解决相应分类问题提供了简单而有效的途径。

### 2.2 自适应提升算法

自适应提升算法(Adaptive Boosting, 缩写为 AdaBoost)是一种集成学习技术, 其核心思想在于通过组合多个相对较弱的学习器, 构建一个性能强大的分类器。该算法由 Freund 和 Schapire (1997) 提出。

AdaBoost 的训练过程可以简要概括为以下步骤: 首先假设  $N$  个样本, 每个样本最初都被赋予相同的权值, 通常为  $1/N$ 。在具体训练过程中, 若某个样本点被弱分类器正确分类, 其权值将减小; 相反, 若被错误分类, 其权值将增加, 使用权值更新后的样本集训练下一个弱分类器, 此过程将迭代进行, 直至全部样本都被正确分类。弱分类器训练完成后, 根据其分类错误率对各个弱分类器的权重进行调整。错误率低的弱分类器在最终分类器中占据较大的权重, 因而增强其在整体模型中的影响。AdaBoost 算法在实践中常用于分类问题, 特别是对于决策树等弱分类器的集成, 在地学领域曾用于强震和微震分类(Peng *et al.*, 2021; 吴涛等, 2022), 其优点在于能够有效处理复杂的数据集, 提高模型的泛化能力。

### 2.3 轻量级梯度提升机算法

轻量级梯度提升机算法(Light Gradient Boosting Machine, 缩写为 LGBM)是一种高效的梯度提升机(Gradient Boosting Machine, 缩写为 GBM)算法, 专为应对大规模数据和高效训练而设计。该算法基于梯度提升技术, 通过迭代的方式逐步提高模型的预测能力。它采用基于树的模型作为弱学习器, 其中树的构建过程采用一种称为叶子结点分裂(leaf-wise)的高效特征分裂策略。相较于传统的层级分裂(level-wise), 这种策略在每次分裂时选择对当前样本集贡

献最大的特征和阈值,从而减少树的深度,提高训练速度. LGBM 以其高效的性能、低的内存消耗、显著优越的准确率为解决实际分类问题提供了强有力的支持.

3 地震事件类型识别实验与结果分析

3.1 分类模型训练

将本研究中训练数据的 62 个特征采用 KNN, AdaBoost, LGBM 三种分类算法进行分类模型训练. 模型训练中, 0 表示天然地震, 1 表示人工爆破, 2 表示矿震塌陷, 0-1 代表天然地震与人工爆破的分类模型, 0-2 代表天然地震与矿震塌陷的分类模型, 1-2 代表人工爆破与矿震塌陷的分类模型, 0-1-2 代表天然地震与人工爆破、矿震塌陷的分类模型. 对 0-1, 0-2, 1-2, 0-1-2 使用 KNN, AdaBoost, LGBM 分别训练 100 次, 每次试验从训练数据中随机抽取 75% 用于训练, 其余 25% 用于测试该分类模型的准确率. 不同分类模型的准确率如图 6 所示, 计算得到的每个分类模型准确率的平均值、最大值、最小值列于表 2.

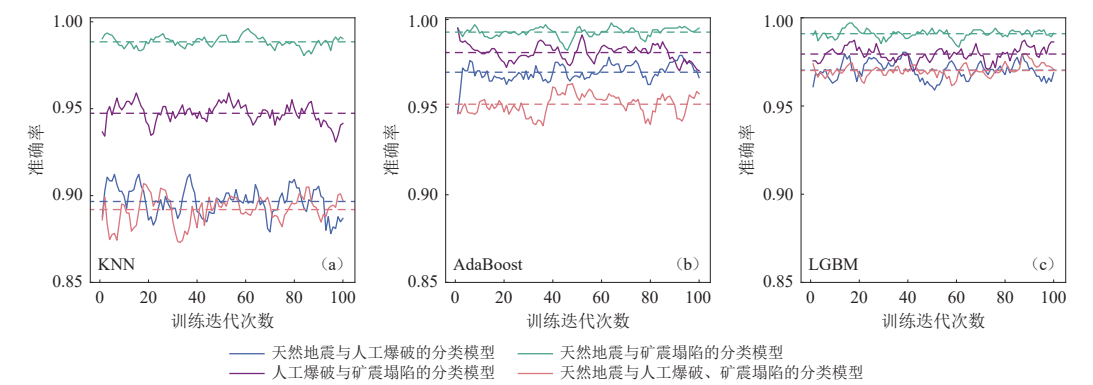


图 6 采用 KNN (a), AdaBoost (b), LGBM (c) 对分类模型训练 100 次所得的准确率

Fig. 6 The accuracy of classification models after 100 times training using KNN (a), AdaBoost (b) and LGBM (c), respectively

表 2 不同分类模型的准确率平均值、最大值、最小值

Table 2 Average, maximum and minimum of accuracy for different classification model												
分类方法	天然地震与人工爆破分类模型的准确率			天然地震与矿震塌陷分类模型的准确率			人工爆破与矿震塌陷分类模型的准确率			天然地震与人工爆破、矿震塌陷分类模型的准确率		
	平均值	最大值	最小值	平均值	最大值	最小值	平均值	最大值	最小值	平均值	最大值	最小值
KNN	89.66%	91.22%	87.80%	98.84%	99.61%	98.05%	94.73%	95.90%	93.07%	89.19%	90.68%	87.30%
AdaBoost	96.99%	97.95%	94.63%	99.28%	99.80%	98.24%	98.12%	99.51%	97.07%	95.17%	96.35%	93.94%
LGBM	97.03%	98.05%	95.90%	99.10%	99.71%	98.34%	97.95%	98.73%	96.98%	97.01%	97.98%	96.16%

从图 6 中可以明显观察到, 相对于 KNN 算法, AdaBoost 和 LGBM 在各种分类模型中的性能更优, 尤其在 0-1 和 0-1-2 方面表现更为显著. 在不同的分类算法中, LGBM 的整体表现最为出色, 其准确率保持在 95% 以上, 具有较高的稳定性. 在不同分类任务中, 0-2 分类效果最为突出, 1-2 次之.

表 2 包含了使用不同分类算法(KNN, AdaBoost, LGBM)分别对 0-1, 0-2, 1-2, 0-1-2 训练 100 次的结果. 可见: 0-1 分类中, LGBM 表现最佳; 0-2 分类中, 三种算法的准确率均值

均达到 98.05% 以上；1-2 分类中，AdaBoost 和 LGBM 的分类效果更佳；0-1-2 分类中，LGBM 同样表现最佳。值得注意的是，LGBM 模型在所有分类任务上都表现出色，不仅准确率较高，还呈现出较强的鲁棒性。

3.2 测试结果与性能评估

在完成分类模型的训练后，接下来聚焦于测试数据，对这些模型进行全面的评估。使用每个模型对测试数据的事件类型进行识别，得到各模型关于不同分类任务上的识别结果，并基于此生成混淆矩阵，如图 7 所示。可以看出，每个分类任务都完成得较为出色，特别是对于 0-2 分类，三种不同的分类算法均表现最佳。

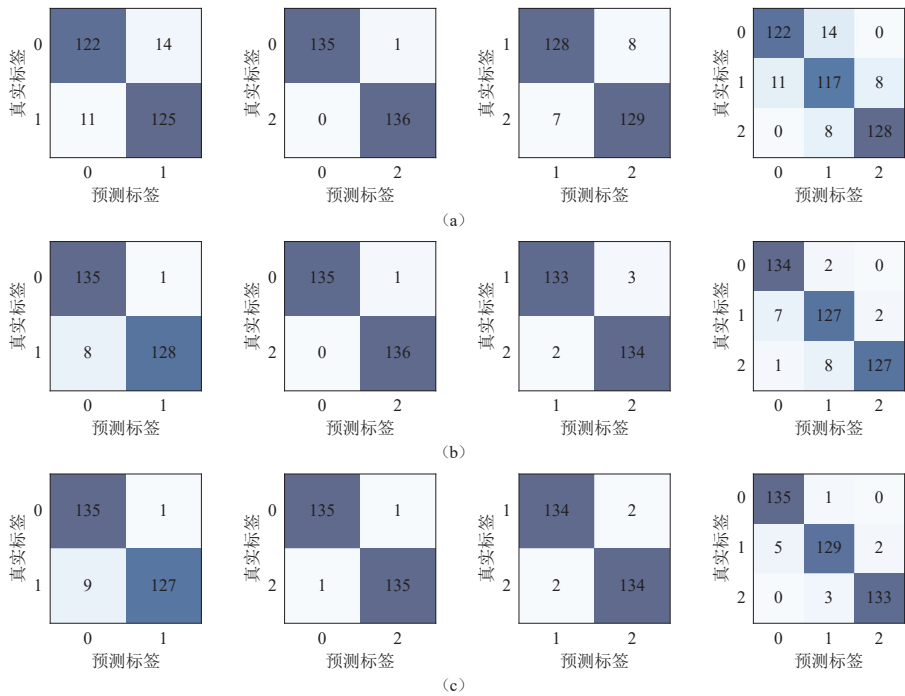


图 7 由三种分类算法对测试数据的识别结果生成的混淆矩阵

坐标轴上的数值 0 代表天然地震，1 代表人工爆破，2 代表矿震塌陷

Fig. 7 Confusion matrices resulted from identification results of test data by three classification algorithms

The value 0 on the coordinate axes stands for natural earthquake, 1 for artificial explosion, and 2 for mining collapse,

(a) KNN; (b) AdaBoost; (c) LGBM

基于混淆矩阵，我们计算了模型性能评估指标，包括准确率、精确率、召回率和  $F_1$  分数，结果详列于表 3。通过表 3 可以观察到：0-1 分类中，AdaBoost 的表现最佳，准确率可达 96.69%；0-2 分类中，三类算法表现都很好，评价指标均达 99.26% 以上，其中 KNN 和 AdaBoost 略高于 LGBM，所有的矿震塌陷都被正确分类，因此精确率达 100.00%；1-2 和 0-1-2 分类中，LGBM 的分类效果最好。总之，以上每个分类模型的表现都很好，准确率、精确率、召回率、 $F_1$  分数均达到 89.71% 及以上。值得指出的是，Wang 等(2022)对 1-2 的分类准确率在 90.00% 左右，本研究中将准确率提升至 94.49% 以上，取得了明显的改进。

最后绘制采用三种分类算法(KNN, AdaBoost, LGBM)识别测试集的受试者工作特征(receiver operating characteristic, 缩写为 ROC)曲线. ROC 曲线是一种用于评估分类模型性能的重要工具, 其斜率越大, 说明模型在提高真正例率的同时, 更少地将负例误分类为正例, 因此曲线下面积(area under curve, 缩写为 AUC)越大, 模型性能越卓越. 图 8a 展示了在不同的二分类任务(0-1, 0-2, 1-2)中三种分类算法的 ROC 曲线, 可以看出 KNN 算法对 0-1 和 1-2 的识别仍待优化. 由于 ROC 曲线是为二分类问题所设计, 所以图 8b 呈现了 0-1-2 分类中 0, 1, 2 每个类别的 ROC 曲线, 进一步展示了模型的综合性能, 其中 KNN 对 0 和 1、AdaBoost 对 1 的识别还有改进空间, 其它模型都展现出稳健的识别能力.

表 3 不同分类模型对不同分类任务的评价指标

Table 3 Evaluation metrics of different classification models for different classification task

分类模型	分类任务	准确率	精确率	召回率	$F_1$ 分数
KNN	0-1	90.81%	91.73%	89.71%	90.71%
	0-2	99.63%	100.00%	99.26%	99.63%
	1-2	94.49%	94.81%	94.12%	94.47%
	0-1-2	91.75%	93.15%	93.03%	93.03%
AdaBoost	0-1	96.69%	94.41%	99.26%	96.75%
	0-2	99.63%	100.00%	99.26%	99.63%
	1-2	98.16%	98.52%	97.79%	98.15%
	0-1-2	95.10%	96.11%	98.99%	97.52%
LGBM	0-1	96.32%	93.75%	99.26%	96.44%
	0-2	99.26%	99.26%	99.26%	99.26%
	1-2	98.53%	98.53%	98.53%	98.53%
	0-1-2	97.30%	97.31%	97.30%	97.30%

注: 0-1代表天然地震与人工爆破的分类模型, 0-2代表天然地震与矿震塌陷的分类模型, 1-2代表人工爆破与矿震塌陷的分类模型, 0-1-2代表天然地震与人工爆破、矿震塌陷的分类模型.

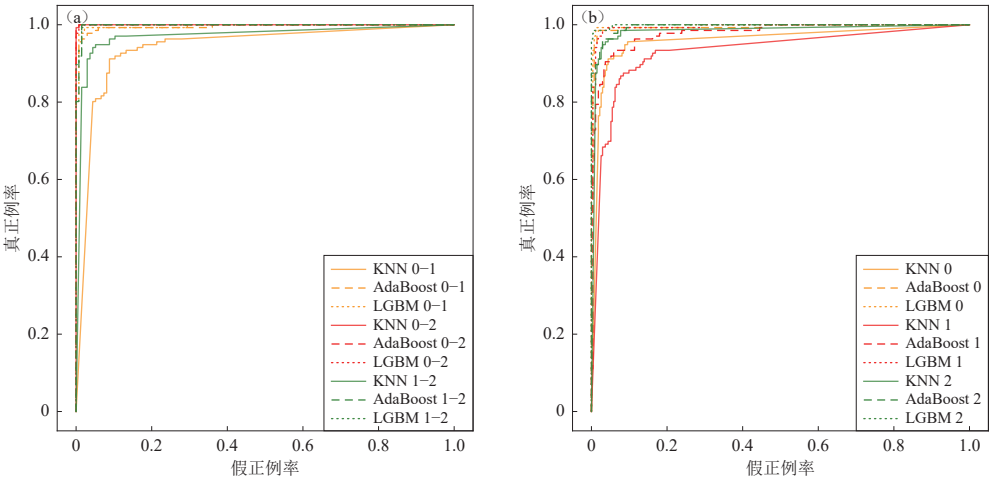


图 8 不同分类模型的 ROC 曲线

图例中, 0 代表天然地震, 1 代表人工爆破, 2 代表矿震塌陷

(a) 0-1, 0-2, 1-2 分类模型; (b) 0-1-2 分类模型

Fig. 8 ROC curves of different classification models

In the legends, 0 stands for natural earthquake, 1 for artificial explosion, and 2 for mining collapse

(a) 0-1, 0-2, 1-2 classification models; (b) 0-1-2 classification model

4 讨论与结论

本文将华北地区  $M_L3.0$  以下天然地震、人工爆破、矿震塌陷这三类地震事件中的 75% 和 25% 分别划分为训练数据和测试数据, 根据地震波形记录和时频谱提取了 10 类 62 个

特征,分别采用 KNN, AdaBoost, LGBM 分类算法对不同分类任务(0-1, 0-2, 1-2, 0-1-2)进行训练,构建了相应的分类模型并对参数进行优化,并将训练完成的分类模型对测试数据进行识别,得到相应的混淆矩阵和评价指标.主要结论如下:

1) 结合三类事件的时频特征,量化提取了时间、P 波与 S 波振幅比、频率、过零率、峰值振幅、峰值加速度、能量、信号、角度和其它比值等 10 类 62 个特征,作为不同分类模型训练、测试并进行识别的基础.

2) 通过训练和测试结果,发现 0-1, 0-2, 1-2, 0-1-2 均取得了较好的分类效果,准确率在 90.81% 以上.特别是在 0-2 分类中,三种算法均取得最佳效果,1-2 的分类准确率次之.此外,虽然 0-1 和 0-1-2 的分类效果也较好,但仍存在一些优化的空间.

3) LGBM 整体表现最为优秀,其准确率保持在 96.32% 以上,并且具有较高的稳定性.KNN 仍有很大改进空间,可能由于其对数据较为敏感,在处理不同数据时性能相对弱于 AdaBoost 和 LGBM. AdaBoost 的综合性能介于 LGBM 与 KNN 之间.

4) 混淆矩阵和评价指标均表明上述构建的分类模型对测试数据分类效果良好,ROC 曲线的分析进一步印证了分类模型在不同任务中的卓越性能,不同算法的 ROC 曲线特点揭示了在各自任务中的适用性,为模型的实际应用提供了有力支持.

本研究仅针对华北地区的地震事件进行了探究,可以进一步将该分类方法应用于其它地区的地震事件分类,以验证和扩展在其它地区的应用.所提取的 62 个特征在本研究中效果良好,可以将更多的地震特征引入到分类中.在以后的研究中,将更多地关注多种分类算法的联合使用,以提高综合识别能力.

## 参 考 文 献

- 边银菊. 2005. Fisher 方法在震级比  $m_b/M_s$  判据识别爆炸中的应用研究[J]. *地震学报*, 27(4): 414-422.
- Bian Y J. 2005. Application of Fisher method to discriminating earthquakes and explosions using criterion  $m_b/M_s$  [J]. *Acta Seismologica Sinica*, 27(4): 414-422 (in Chinese).
- 蔡杏辉, 廖诗荣, 张燕明, 陈惠芳, 林彬华. 2021. 基于支持向量机的地震事件类型自动识别及应用[J]. *华南地震*, 41(2): 27-35.
- Cai X H, Liao S R, Zhang Y M, Chen H F, Lin B H. 2021. Automatic identification of earthquake event types based on support vector machine and its application[J]. *South China Journal of Seismology*, 41(2): 27-35 (in Chinese).
- 陈润航, 黄汉明, 柴慧敏. 2018. 地震和爆破事件源波形信号的卷积神经网络分类研究[J]. *地球物理学进展*, 33(4): 1331-1338.
- Chen R H, Huang H M, Chai H M. 2018. Study on the discrimination of seismic waveform signals between earthquake and explosion events by convolutional neural network[J]. *Progress in Geophysics*, 33(4): 1331-1338 (in Chinese).
- 范晓易, 曲均浩, 刘方斌, 周少辉. 2020. 使用支持向量机识别地震类型的影响因素分析[J]. *大地测量与地球动力学*, 40(10): 1034-1038.
- Fan X Y, Qu J H, Liu F B, Zhou S H. 2020. Analysis of influencing factors in use of support vector machine method to identify earthquake types[J]. *Journal of Geodesy and Geodynamics*, 40(10): 1034-1038 (in Chinese).
- 靳玉贞, 林木金, 范晓瑜, 刘晓萍, 何佳, 杨世英, 孟彩菊. 2015. 山西地区爆破、塌陷(矿震)特殊地震动特征识别[J]. *地震地磁观测与研究*, 36(3): 63-66.
- Jin Y Z, Lin M J, Fan X Y, Liu X P, He J, Yang S Y, Meng C J. 2015. Feature recognition of explosion, collapse (mine earthquake) to specific ground motion in Shanxi region[J]. *Seismological and Geomagnetic Observation and Research*, 36(3): 63-66 (in Chinese).
- 靳玉贞, 刘炜, 何佳, 杨世英, 孟彩菊, 刘晓萍. 2019. 太原基准地震台核爆震相识别[J]. *地震地磁观测与研究*, 40(4):

59–64.

- Jin Y Z, Liu W, He J, Yang S Y, Meng C J, Liu X P. 2019. Identification of nuclear explosion waveform recorded by Taiyuan fundamental seismic station[J]. *Seismological and Geomagnetic Observation and Research*, **40**(4): 59–64 (in Chinese).
- 梁皓, 孙丽, 陈姝莽, 支明. 2023. 基于支持向量机算法的地震事件分类研究: 以东北地区为例[J]. *地球物理学报*, **66**(12): 5030–5040.
- Liang H, Sun L, Chen S Q, Zhi M. 2023. Research on seismic event classification based on SVM algorithm: An application in Northeast China[J]. *Chinese Journal of Geophysics*, **66**(12): 5030–5040 (in Chinese).
- 刘莎, 杨建星, 田宝峰, 郑钰, 姜旭东, 徐志强. 2012. 首都圈地区爆破、矿塌和天然地震的识别研究[J]. *地震学报*, **34**(2): 202–214.
- Liu S, Yang J S, Tian B F, Zheng Y, Jiang X D, Xu Z Q. 2012. Discrimination between explosions, mine collapses and earthquakes in capital region of China[J]. *Acta Seismologica Sinica*, **34**(2): 202–214 (in Chinese).
- 任涛, 林梦楠, 陈宏峰, 王冉冉, 李松威, 刘晓雨, 刘杰. 2019. 基于 Bagging 集成学习算法的地震事件性质识别分类[J]. *地球物理学报*, **62**(1): 383–392.
- Ren T, Lin M N, Chen H F, Wang R R, Li S W, Liu X Y, Liu J. 2019. Seismic event classification based on Bagging ensemble learning algorithm[J]. *Chinese Journal of Geophysics*, **62**(1): 383–392 (in Chinese).
- 王婷婷, 边银菊. 2011. 识别天然地震和人工爆破的判据选择[J]. *地震地磁观测与研究*, **32**(6): 62–67.
- Wang T T, Bian Y J. 2011. Criterion selection of earthquake and explosion recognition[J]. *Seismological and Geomagnetic Observation and Research*, **32**(6): 62–67 (in Chinese).
- 魏富胜, 黎明. 2003. 震源性质的倒谱分析[J]. *地震学报*, **25**(1): 47–54.
- Wei F S, Li M. 2003. Cepstrum analysis of source character[J]. *Acta Seismologica Sinica*, **25**(1): 47–54 (in Chinese).
- 魏永刚, 杨千里, 王婷婷, 蒋长胜, 边银菊. 2019. 基于深度学习残差网络模型的地震和爆破识别[J]. *地震学报*, **41**(5): 646–657.
- Wei Y G, Yang Q L, Wang T T, Jiang C S, Bian Y J. 2019. Earthquake and explosion identification based on Deep Learning residual network model[J]. *Acta Seismologica Sinica*, **41**(5): 646–657 (in Chinese).
- 吴顺川, 甘一雄, 任义, 郑立夫. 2020. 基于 RA 与 AF 值的声发射指标在隧道监测中的可行性[J]. *工程科学学报*, **42**(6): 723–730.
- Wu S C, Gan Y X, Ren Y, Zheng L F. 2020. Feasibility research of AE monitoring index in tunnel based on RA and AF[J]. *Chinese Journal of Engineering*, **42**(6): 723–730 (in Chinese).
- 吴涛, 庞聪, 江勇, 丁炜, 廖成旺. 2022. 基于随机子空间和 AdaBoost 集成学习的地震事件性质辨识研究[J]. *地球物理学进展*, **37**(3): 981–988.
- Wu T, Pang C, Jiang Y, Ding W, Liao C W. 2022. Identification and classification of earthquake types based on Cov-SSI and AdaBoost ensemble learning algorithm[J]. *Progress in Geophysics*, **37**(3): 981–988 (in Chinese).
- 薛思敏, 黄汉明, 施佳鹏, 袁雪梅, 黎炳君. 2022. 基于 EMD 的 IMF 时域统计特征提取及其应用于震动事件源类型识别研究[J]. *地震工程学报*, **44**(1): 100–107.
- Xue S M, Huang H M, Shi J P, Yuan X M, Li B J. 2022. Extraction of IMF time-domain features based on EMD and its application to recognition of vibration event source type[J]. *China Earthquake Engineering Journal*, **44**(1): 100–107 (in Chinese).
- 杨千里, 王婷婷, 边银菊. 2020. 基于广义 S 变换的地震与爆炸识别[J]. *地震学报*, **42**(5): 613–628.
- Yang Q L, Wang T T, Bian Y J. 2020. Recognition of earthquakes and explosions based on generalized S transform[J]. *Acta Seismologica Sinica*, **42**(5): 613–628 (in Chinese).
- 赵永, 刘卫红, 高艳玲. 1995. 北京地区地震、爆破和矿震的记录图识别[J]. *地震地磁观测与研究*, **16**(4): 48–54.
- Zhao Y, Liu W H, Gao Y L. 1995. Distinguishing earthquake, explosion and mine earthquake in Beijing area[J]. *Seismological and Geomagnetic Observation and Research*, **16**(4): 48–54 (in Chinese).
- Badawy A, Gamal M, Farid W, Soliman M S. 2019. Decontamination of earthquake catalog from quarry blast events in northern Egypt[J]. *J Seismol*, **23**(6): 1357–1372.
- Barama L, Williams J, Newman A V, Peng Z G. 2023. Global nuclear explosion discrimination using a convolutional neural network[J]. *Geophys Res Lett*, **50**(17): e2022GL101528.

- Chiang A, Dreger D S, Ford S R, Walter W R. 2014. Source characterization of underground explosions from combined regional moment tensor and first-motion analysis[J]. *Bull Seismol Soc Am*, **104**(4): 1587–1600.
- Chiang A, Ichinose G A, Dreger D S, Ford S R, Matzel E M, Myers S C, Walter W R. 2018. Moment tensor source-type analysis for the Democratic People's Republic of Korea-declared nuclear explosions (2006–2017) and 3 September 2017 collapse event[J]. *Seismol Res Lett*, **89**(6): 2152–2165.
- Dargahi-Noubary G R. 1998. Statistical estimation of corner frequency and its application to seismic event-identification[J]. *Soil Dyn Earthq Eng*, **17**(5): 297–309.
- Freund Y, Schapire R E. 1997. A decision-theoretic generalization of on-line learning and an application to boosting[J]. *J Comput Syst Sci*, **55**(1): 119–139.
- Gaebler P, Ceranna L, Nooshiri N, Barth A, Cesca S, Frei M, Grünberg I, Hartmann G, Koch K, Pilger C, Ross J O, Dahm T. 2019. A multi-technology analysis of the 2017 North Korean nuclear test[J]. *Solid Earth*, **10**(1): 59–78.
- Goforth T T, Hetzer C H, Stump B W. 2006. Characteristics of regional seismograms produced by delay-fired explosions at the Minntac iron mine, Minnesota[J]. *Bull Seismol Soc Am*, **96**(1): 272–287.
- Horasan G, Güney A B, Küsmez A, Bekler F, Ögütçü Z, Musaoğlu N. 2009. Contamination of seismicity catalogs by quarry blasts: An example from İstanbul and its vicinity, northwestern Turkey[J]. *J Asian Earth Sci*, **34**(1): 90–99.
- Jia L Z, Chen H F, Xing K. 2022. Rapid classification of local seismic events using machine learning[J]. *J Seismol*, **26**(5): 897–912.
- Kim G, Ku B, Ko H. 2021. Multifeature fusion-based earthquake event classification using transfer learning[J]. *IEEE Geosci Remote Sens Lett*, **18**(6): 974–978.
- Kong Q K, Wang R J, Walter W R, Pyle M, Koper K, Schmandt B. 2022. Combining deep learning with physics based features in explosion-earthquake discrimination[J]. *Geophys Res Lett*, **49**(13): e2022GL098645.
- Koper K D, Holt M M, Voyles J R, Burlacu R, Pyle M L, Wang R J, Schmandt B. 2021. Discrimination of small earthquakes and buried single-fired chemical explosions at local distances ( $<150$  km) in the western United States from comparison of local magnitude ( $M_L$ ) and coda duration magnitude ( $M_c$ ) [J]. *Bull Seismol Soc Am*, **111**(1): 558–570.
- Laasri E H A, Akhouayri E S, Agliz D, Zonta D, Atmani A. 2015. A fuzzy expert system for automatic seismic signal classification[J]. *Expert Syst Appl*, **42**(3): 1013–1027.
- Levshin A L, Ritzwoller M H. 1995. Characteristics of surface waves generated by events on and near the Chinese nuclear test site[J]. *Geophys J Int*, **123**(1): 131–148.
- Lindenbaum O, Rabin N, Bregman Y, Averbuch A. 2020. Seismic event discrimination using deep CCA[J]. *IEEE Geosci Remote Sens Lett*, **17**(11): 1856–1860.
- Ma J, Zhao G Y, Dong L J, Chen G H, Zhang C X. 2015. A comparison of mine seismic discriminators based on features of source parameters to waveform characteristics[J]. *Shock Vib*, **2015**(1): 919143.
- Mousavi S M, Horton S P, Langston C A, Samei B. 2016. Seismic features and automatic discrimination of deep and shallow induced-microearthquakes using neural network and logistic regression[J]. *Geophys J Int*, **207**(1): 29–46.
- Peng K, Tang Z, Dong L J, Sun D Y. 2021. Machine learning based identification of microseismic signals using characteristic parameters[J]. *Sensors*, **21**(21): 6967.
- Pérez N, Venegas P, Benitez D, Grijalva F, Lara R, Ruiz M. 2022. Benchmarking seismic-based feature groups to classify the Cotopaxi volcanic activity[J]. *IEEE Geosci Remote Sens Lett*, **19**: 7500505.
- Pomeroy P W, Best W J, McEvilly T V. 1982. Test ban treaty verification with regional data: A review[J]. *Bull Seismol Soc Am*, **72**(6B): S89–S129.
- Ren J Q, Zhou S H, Wang J Y, Yang S, Liu C. 2022. Research on identification of natural and unnatural earthquake events based on AlexNet convolutional neural network[J]. *Wire Commun Mob Comput*, (1): 6782094.
- Saad O M, Shalaby A, Sayed M S. 2019. Automatic discrimination of earthquakes and quarry blasts using wavelet filter bank and support vector machine[J]. *J Seismol*, **23**(2): 357–371.
- Sanina I A, Nesterkina M A, Konstantinovskaya N L, Gabsatarova I P. 2021. Identification of the nature of seismic events that occurred in the East European platform as recorded by the Mikhnevo small-aperture seismic array at regional distances[J].

- Seism Instr*, **57**(1): 38–54.
- Selby N D, Bowers D, Douglas A, Heyburn R, Porter D. 2005. Seismic discrimination in southern Xinjiang: The 13 March 2003 Lop Nor earthquake[J]. *Bull Seismol Soc Am*, **95**(1): 197–211.
- Shang X Y, Li X B, Morales-Esteban A, Chen G H. 2017. Improving microseismic event and quarry blast classification using artificial neural networks based on Principal Component Analysis[J]. *Soil Dyn Earthq Eng*, **99**: 142–149.
- Tan A, Horasan G, Kalafat D, Gülbağ A. 2021. Discrimination of earthquakes and quarries in the Edirne district (Turkey) and its vicinity by using a linear discriminate function method and artificial neural networks[J]. *Acta Geophys*, **69**(1): 17–27.
- Taylor S R, Denny M D, Vergino E S, Glaser R E. 1989. Regional discrimination between NTS explosions and western U.S. earthquakes[J]. *Bull Seismol Soc Am*, **79**(4): 1142–1176.
- Tibi R, Linville L, Young C, Brogan R. 2019. Classification of local seismic events in the Utah region: A comparison of amplitude ratio methods with a spectrogram-based machine learning approach[J]. *Bull Seismol Soc Am*, **109**(6): 2532–2544.
- Voyles J R, Holt M M, Hale J M, Koper K D, Burlacu R, Chambers D J A. 2020. A new catalog of explosion source parameters in the Utah region with application to  $M_L$ - $M_C$ -based depth discrimination at local distances[J]. *Seismol Res Lett*, **91**(1): 222–236.
- Wang T T, Bian Y J, Yang Q L, Ren M Y. 2021. Correction of P/S amplitude ratios for low-magnitude seismic events based on Bayesian Kriging method[J]. *Bull Seismol Soc Am*, **111**(5): 2799–2813.
- Wang T T, Bian Y J, Zhang Y X, Hou X L. 2022. Using artificial intelligence methods to classify different seismic events[J]. *Seismol Res Lett*, **94**(1): 1–16.
- Yıldırım E, Gülbağ A, Horasan G, Doğan E. 2011. Discrimination of quarry blasts and earthquakes in the vicinity of Istanbul using soft computing techniques[J]. *Comput Geosci*, **37**(9): 1209–1217.
- Yue L, Qu J H, Zhou S H, Qu B A, Zhang Y W, Xu Q F. 2023. Seismic event classification based on a two-step convolutional neural network[J]. *J Seismol*, **27**(3): 527–535.
- Zhang Y X, Wang T T, Bian Y J, Yang Q L. 2021. Features of different types of seismic events in China's Capital Region[J]. *Earthquake Science*, **34**(6): 489–506.