

文章编号: 1671-251X(2025)03-0156-09

DOI: 10.13272/j.issn.1671-251x.2024080043

# 基于微震信号深度特征学习的岩石破裂类型识别

李典泽<sup>1,2</sup>, 许华杰<sup>1,3</sup>, 张勃<sup>1</sup>

(1. 广西大学 计算机与电子信息学院, 广西 南宁 530004;

2. 广西电网有限责任公司桂林供电局, 广西 桂林 541002;

3. 广西大学 广西多媒体通信与网络技术重点实验室, 广西 南宁 530004)

**摘要:** 岩石破裂类型识别是实现煤矿冲击地压灾害预测和预警的重要前提。微震是岩石破裂监测的有效手段之一,但常规的微震信号机器学习方法存在特征提取能力有限,以及受噪声影响导致的准确率不高且泛化性较差等问题。针对上述问题,提出了一种基于微震信号深度特征学习的岩石破裂类型识别方法。首先,通过巴西圆盘劈裂试验和直剪试验分别获取张拉型破裂微震信号和剪切型破裂微震信号,并将其时频谱图、Log-Mel 频谱图和梅尔频率倒谱系数合并构造微震信号聚合(MSA)声谱图;然后,通过加入多特征并行密集连接块(MP-DenseBlock)和压缩与激发过渡层(SE-TransLayer)的改进 DenseNet(SE-MPDenseNet)对 MSA 声谱图进行深度特征提取;最后,将提取的特征向量输入至添加 Hinge Loss 损失函数的改进 LightGBM(HBL-LightGBM)进行分类,识别岩石破裂类型。通过真三轴加载试验模拟接近地下工程实际环境中的冲击地压灾害,结果表明,所提方法对于岩石破裂类型识别的准确率达 92.12%,且具有较强的特征提取能力和泛化能力。

**关键词:** 岩石破裂类型; 微震监测; 深度学习; 机器学习; 声谱图

中图分类号: TD315/324

文献标志码: A

Rock fracture type recognition based on deep feature learning of microseismic signals

LI Dianze<sup>1,2</sup>, XU Huajie<sup>1,3</sup>, ZHANG Bo<sup>1</sup>

(1. School of Computer, Electronics and Information, Guangxi University, Nanning 530004, China; 2. Guilin Power Supply Bureau of Guangxi Power Grid Co., Ltd., Guilin 541002, China; 3. Guangxi Key Laboratory of Multimedia Communications and Network Technology, Guangxi University, Nanning 530004, China)

**Abstract:** Accurate identification of rock fracture types is crucial for the prediction and early warning of coal mine rockburst hazards. Microseismic monitoring has been widely used for detecting rock fractures. However, conventional machine learning methods for microseismic signal analysis exhibited limited feature extraction capabilities and were highly susceptible to noise, leading to reduced classification accuracy and poor generalization performance. To address these limitations, this study proposed a novel rock fracture type recognition method based on deep feature learning of microseismic signals. In this study, microseismic signals corresponding to tensile and shear fractures were collected through Brazilian disc splitting and direct shear tests, respectively. These signals were then processed to construct a microseismic signal aggregation (MSA) spectrogram, which integrated time-frequency spectrograms, log-Mel spectrograms, and Mel-frequency cepstral coefficients. To enhance feature extraction efficiency, an improved DenseNet model (SE-MPDenseNet) was developed by incorporating multi-feature parallel dense blocks (MP-DenseBlock) and squeeze-and-excitation

收稿日期: 2024-08-15; 修回日期: 2025-03-23; 责任编辑: 盛男。

基金项目: 国家自然科学基金项目(52169021); 广西自然科学基金项目(2024JJA170106)。

作者简介: 李典泽(2000—), 男, 广西陆川人, 硕士研究生, 研究方向为人工智能、神经网络, E-mail: dianze@163.com。通信作者: 许华杰(1974—), 男, 广西南宁人, 副教授, 博士, 研究方向为人工智能、自动化技术在矿业工程中的应用, E-mail: hjxu2009@163.com。

引用格式: 李典泽, 许华杰, 张勃. 基于微震信号深度特征学习的岩石破裂类型识别[J]. 工矿自动化, 2025, 51(3): 156-164.

LI Dianze, XU Huajie, ZHANG Bo. Rock fracture type recognition based on deep feature learning of microseismic signals[J]. Journal of Mine Automation, 2025, 51(3): 156-164.



扫码移动阅读

transition layers (SE-TransLayer). The extracted deep feature vectors were subsequently fed into an optimized LightGBM classifier (HBL-LightGBM), which was modified with a Hinge Loss function to improve classification performance. To evaluate the effectiveness of the proposed method, a true triaxial loading test was conducted to simulate rockburst hazards under realistic underground engineering conditions. Experimental results demonstrated that the proposed approach achieved a rock fracture type recognition accuracy of 92.12%, significantly outperforming conventional methods in both feature extraction capability and generalization ability. The findings indicate that the proposed method provides a robust and effective framework for microseismic-based rock fracture classification. It offers valuable insights for rockburst hazard monitoring and mitigation in mining and geotechnical engineering.

**Key words:** rock fracture classification; microseismic monitoring; deep learning; machine learning; spectrogram analysis

## 0 引言

随着我国煤矿由浅部开采逐步过渡到深部开采,在矿山地下工程建设过程中经常会发生冲击地压灾害,突发性强、破坏性大,甚至会严重威胁施工人员的人身安全,造成巨大经济损失<sup>[1]</sup>。岩石破裂是一种从微破裂不断累积,最终导致宏观破碎的过程。按照破裂原因划分,这些微破裂可分为张拉型破裂和剪切型破裂<sup>[2]</sup>。已有研究表明,岩石破裂的过程是一个从以张拉型破裂为主逐渐转换到以剪切型破裂为主的过程<sup>[3-4]</sup>,岩石破裂类型的识别是实现冲击地压灾害预测和预警的重要前提。

在工程实践中,可通过分析岩石宏观破裂过程中电阻率变化规律实现破裂类型的识别<sup>[5-6]</sup>,或通过分析岩石破裂过程宏观力学特性与岩石电磁辐射信号特征的对应关系对破裂类型进行识别<sup>[7-8]</sup>。此外,当岩石承受外力时,内部的局部微破裂源会以弹性波的形式迅速释放能量,并产生声发射、微震等声学信号,因此声发射、微震技术是岩石破裂监测和识别的有效手段<sup>[9-10]</sup>。其中,声发射信号频率相对较高,能够较好地表征岩石微小尺度(毫米或厘米级)破裂现象,多用于岩石破裂过程监测和识别室内试验。如通过分析声发射信号相关参数对岩石损伤进行定量化表征,实现岩石破裂类型识别及损伤演化特征分析<sup>[11-12]</sup>;通过分析岩石宏观损伤破裂过程中的声发射信号变化规律,研究岩石微破裂产生类型和发展趋势<sup>[13-14]</sup>;结合声发射 RA-AF(Risetime/Amplitude-Average Frequency)值演化特征及宏观破裂形貌识别不同岩爆倾向灰岩的破裂特征<sup>[15]</sup>;通过不同非均质性岩石的声发射特征与应力状态和能量水平之间的关系对岩石破裂类型进行识别<sup>[16]</sup>等。而微震信号频率相对较低,主要通过速度或加速度传感器获取,在大尺度的岩体破坏监测和识别方面具有优势<sup>[5,17]</sup>,相

关方法有微震信号 P 波与 S 波的能量比值法<sup>[5]</sup>等,但这类人工特征分析方法步骤冗长、容易受主观因素影响。近年来,人工智能领域的机器学习方法在岩石破裂类型识别方面得到了应用,如将支持向量机(Support Vector Machine, SVM)用于岩石破裂类型识别<sup>[4]</sup>,通过高斯过程及岩石破裂声谱图特征实现岩石拉剪破裂类型识别<sup>[18]</sup>等,但这类常规机器学习方法存在特征提取能力有限,以及因噪声影响导致的准确率不高且泛化性较差等问题。

深度学习方法的特征提取能力强,但其有效性需要靠大量的熟练数据来保证,而在煤矿深部开采工程的实际应用中,通常难以获取到足够数量的微震数据。因此,本文结合深度卷积神经网络和浅层机器学习方法,提出一种基于微震信号深度特征学习的岩石破裂类型识别方法。该方法通过构造微震信号聚合(Microseismic Signal Aggregation, MSA)声谱图,对深度特征提取网络和浅层分类网络进行训练,得到岩石破裂类型识别模型,可充分发挥深度学习特征提取能力强、端到端学习和浅层机器学习方法所需训练数据少的优点,提升岩石破裂类型识别的准确率。

## 1 基于微震信号深度特征学习的岩石破裂类型识别方法

### 1.1 方法架构

基于微震信号深度特征学习的岩石破裂类型识别方法架构如图 1 所示。

1) 数据获取和声谱图转换。为实现岩石拉剪破裂类型的准确识别,分别通过巴西圆盘劈裂试验和直剪试验获取单纯的张拉型破裂微震信号和剪切型破裂微震信号,将这 2 种微震信号作为原始样本。在语音识别领域,常用的声信号特征表达方法有时频谱图、Log-Mel 频谱图、梅尔频率倒谱系数(Mel-

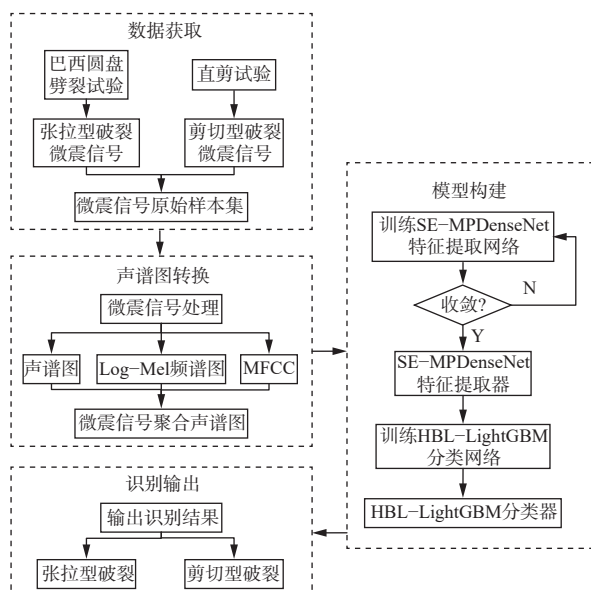


图 1 基于微震信号深度特征学习的岩石破裂类型识别方法架构

Fig. 1 Schematic of rock fracture type recognition method based on deep feature learning of microseismic signals

Frequency Cepstral Coefficients, MFCC)等。其中, 时频谱图由声音信号经过短时傅里叶变换(Short-Time Fourier Transform, STFT)得到, 体现频率随时间的变化规律; Log-Mel 频谱图用于描述声音的频率分布特征; MFCC 反映声信号的频谱特征, 对不同的声信号具有较好的鲁棒性。已有研究<sup>[19]</sup>指出: 对于声信号识别模型, 聚合特征比单一特征具有更高的分类准确率, 且基于频域的变换方法更适合离散信号。微震信号是一种连续信号, 但在实际应用中, 为了对微震信号进行分析和处理, 通常对微震信号进行离散化处理。因此, 对微震信号原始样本提取时频谱图、Log-Mel 频谱图和 MFCC, 并且合并为 MSA 声谱图, 作为特征提取器的输入。

2) 模型构建。深度卷积神经网络通过多层卷积和池化操作自动提取数据中的高维特征, 避免了人工特征的主观性和不确定性。因此, 提出一种基于 DenseNet<sup>[20]</sup>的改进深度特征提取网络(Squeeze-and-Excitation Multi-feature Parallel DenseNet, SE-MPDenseNet), 从 2 个方面改进: ① 对 DenseNet 模型中的 Dense 块进行改进, 提出多特征并行密集连接块(Multi-feature Parallel DenseBlock, MP-DenseBlock), 利用多个不同大小的并行卷积核提取特征图, 再使用密集连接机制将每个特征图在通道维度上连接起来, 以更好地传递信息和梯度, 提高网络的表达能力和性能。② 对 DenseNet 模型中的 Transition 层进行改进, 受 SENet<sup>[21]</sup>启发, 提出压缩与激发过渡层(Squeeze-and-Excitation Transition Layer, SE-TransLayer), 通过学习权重因子, 对每个通道的信息

进行重新加权, 使得网络更加关注重要的通道, 提升网络性能。对 SE-MPDenseNet 进行训练, 模型收敛后用作特征提取器。

受室内开展岩石破裂试验的条件限制, 收集到的岩石破裂微震信号数据集规模通常较小。浅层机器学习方法的优点在于使用小数据集也能训练出具有良好泛化性的模型。LightGBM<sup>[22]</sup>是一种基于决策树算法的高效可扩展梯度提升框架, 在许多任务上都取得了极高的准确率, 但通常情况下识别岩石破裂类型需要对微震信号进行离散化处理, 导致信号的边界较难识别。Hinge Loss 是一种常用于分类任务的损失函数, 其优点是对样本中异常值具有较强的鲁棒性<sup>[23]</sup>。因此, 通过添加 Hinge Loss 损失函数对 LightGBM 进行改进, 提出一种改进的分类网络(Hinge BinaryLogLoss-LightGBM, HBL-LightGBM)。使用 SE-MPDenseNet 从微震信号对应的 MSA 声谱图中提取的特征向量对 HBL-LightGBM 进行训练, 得到 HBL-LightGBM 分类器, 最终获得结合特征提取器和分类器的岩石破裂类型识别模型。

3) 识别输出。使用训练得到的岩石破裂类型识别模型对输入的岩石破裂微震信号进行识别, 并输出识别结果。

## 1.2 岩石破裂微震信号获取和声谱图转换

为获取岩石张拉破裂和剪切破裂所产生的微震信号, 采用团队自主研发的高压伺服动真三轴试验机开展花岗岩的巴西圆盘劈裂试验和直剪试验, 试验平台如图 2 所示。真三轴试验机在 3 个相互垂直的方向上具有 3 个独立伺服加载系统, 竖直方向最大试验力为 5 000 kN, 两水平方向最大试验力为 3 000 kN, 试验机配置有单面摆杆卸载装置, 具有三向六面压缩条件下单面快速卸载、施加扰动荷载等特殊功能, 可开展单轴、双轴、常规三轴、真三轴、巴西圆盘、直剪等岩石力学试验。采用中国科学院武汉岩土力学研究所研发的中科微震(SinoSeiSm)监测系统分别采集单纯的张拉型破裂微震信号和剪切型破裂微震信号, 使用的微震传感器型号为 AU(T) 1000, 灵敏度为 1 V/g( $g$  为重力加速度), 分辨率为 0.1 mg, 测量范围为  $\pm 5g$ , 可实现 32 位 AD 转换, 采样频率为 4 kHz, 动态范围不低于 120 dB。

巴西圆盘劈裂试验和直剪试验中岩样严格按照国际岩石力学学会标准加工: 巴西圆盘劈裂试验岩样为圆柱体, 底面直径为 100 mm, 厚度为 40 mm; 直剪试验岩样为正方体, 边长为 100 mm。试验加载方案: ① 巴西圆盘劈裂试验用于产生张拉型破裂微震信号, 加载方式如图 3(a)所示。先在竖直方向加载






图 2 试验平台

Fig. 2 Experimental platform setup

至预压 3 MPa, 之后在竖直方向以 0.1 MPa/s 的加载速率施加荷载, 直至岩样发生断裂破坏。② 直剪试验用于产生剪切型破裂微震信号, 加载方式如图 3(b) 所示。先在竖直方向加载至预压 1 MPa, 之后在水平方向以 0.1 MPa/s 的加载速率施加荷载, 直至岩样发生断裂破坏。





图 3 试验加载方式

Fig. 3 Loading configuration in experimental setup


获取的张拉型破裂微震信号和剪切型破裂微震信号的时频谱如图 4 所示。

通过以上试验采集的数据集共包含微震信号样本 121 个, 其中张拉型破裂微震信号样本 69 个, 剪切型破裂微震信号样本 52 个。针对微震信号的特点, 结合时频谱图、Log-Mel 频谱图和 MFCC 构建 MSA 声谱图, 过程如图 5 所示。使用 Librosa 语音处理库对微震信号原始样本进行处理, 岩石破裂微震信号原始样本长度为 1 536。设置快速傅里叶变换 (Fast Fourier Transform, FFT) 点数为 384, 窗口长度为 192, 帧移为 8, 得到大小为  $193 \times 193$  的时频谱图; 设置 FFT 点数为 384, 帧移为 8, Mel 滤波器个数为 128, 得到大小为  $128 \times 193$  的 Log-Mel 频谱图; 设置 MFCC 数量为 40, FFT 点数为 384, 帧移为 8, 得到大小为  $40 \times 193$  的 MFCC。将得到的时频谱图、Log-Mel 频谱图和 MFCC 拉伸到大小为  $224 \times 224$ , 并按照

顺序在通道维度上堆叠, 最终得到大小为  $3 \times 224 \times 224$  的 MSA 声谱图。



(a) 张拉型破裂微震信号时频谱



(b) 剪切型破裂微震信号时频谱

图 4 张拉型及剪切型破裂微震信号时频谱

Fig. 4 Time-frequency spectrograms of microseismic signals from tensile and shear fractures




图 5 MSA 声谱图构建

Fig. 5 Construction of Microseismic Signal Aggregation spectrogram

### 1.3 SE-MPDenseNet

SE-MPDenseNet 结构如图 6 所示, 其中主要包括 2 个方面的改进。




图 6 SE-MPDenseNet 结构

Fig. 6 Structure of SE-MPDenseNet

1) MP-DenseBlock。DenseNet 中的 DenseBlock 由多个 DenseLayer 组成, 每个 DenseLayer 包含 2 个



卷积层(Conv), 卷积核大小分别为  $1 \times 1$  和  $3 \times 3$ 。对于卷积神经网络来说, 不同大小的卷积核感受野不同, 能提取到的特征也不相同, 卷积核越大, 每一次卷积操作覆盖的区域就越大, 从而能够捕获更广阔的空间信息, 有助于增强网络的全局理解能力。因此, 从增强网络特征提取能力出发, 提出 MP-DenseBlock, 其结构如图 7 所示, 其中  $\oplus$  表示通道维度连接。多个 MP-DenseLayer 连接组成 MP-DenseBlock, 每个改进的 MP-DenseLayer 分别采用卷积核大小为  $1 \times 1$ ,  $3 \times 3$ ,  $5 \times 5$  的卷积层获得不同尺度的特征, MP-DenseLayer 之间依然采用密集连接, 将每一层 MP-DenseLayer 输出的特征相连。然而增加卷积核的尺寸会增加网络宽度, 导致计算量增加, 因此,  $5 \times 5$  卷积核实际上通过 2 个  $3 \times 3$  的卷积核来实现, 以获得与  $5 \times 5$  卷积核相同的感受野, 同时通道间的信息交互也可以提高网络的表达能力。

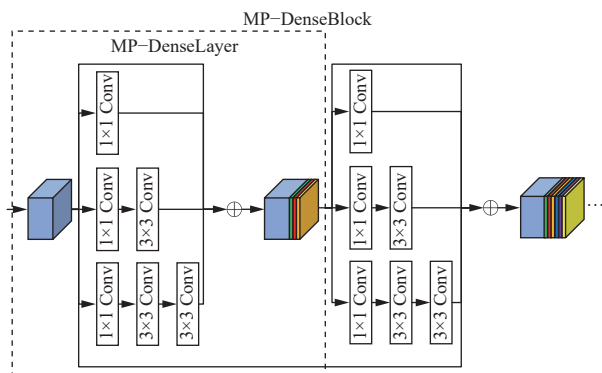


图 7 MP-DenseBlock 结构

Fig. 7 Structure of MP-DenseBlock

2) SE-TransLayer。在 DenseNet 中, DenseBlock 之间采用 TransitionLayer 连接, 以降低特征图的通道数和空间大小, 这种做法虽然有助于增加网络的感受野, 但可能会丢失一些特征信息, 影响网络性能。因此, 从提升网络的特征表达能力出发, 提出 SE-TransLayer, 其结构如图 8 所示, 其中  $r$  为压缩比例,  $C, H, W$  分别为特征图的通道数、高度、宽度。通过 2 次卷积操作降低通道数和特征图大小: 第 1 次卷积操作采用的卷积核尺寸为  $1 \times 1$ , 之后经过全局平均池化和 2 个全连接层(第 1 个全连接层将通道数量压缩到  $C/2r$ , 第 2 个全连接层将通道数量还原到  $C/2$ ); 第 2 次卷积操作采用的卷积核尺寸为  $3 \times 3$ 。之后计算每个通道的权重, 再通过矩阵相乘为每个通道赋予权重信息, 使网络更关注对正确分类有用的特征信息, 增强网络对有用信息的感知能力。

使用岩石张拉破裂和剪切破裂对应的 MSA 声谱图数据对 SE-MPDenseNet 进行训练, 直到模型收敛。使用 SE-MPDenseNet 对岩石破裂微震信号进行




图 8 SE-TransLayer 结构

Fig. 8 Structure of SE-TransLayer

特征提取, 再将获得的特征向量输入浅层机器学习方法进行分类, 而特征向量对于分类性能的影响很大, 因此, 选择 SE-MPDenseNet 网络哪一层的输出作为特征向量成为关键问题。有研究<sup>[24]</sup>指出, 网络较深的层输出的特征表达能力更强, 所包含的语义信息更抽象, 比浅层特征更有优势, 但网络末端的全连接层作用是将前层计算得到的特征空间映射到样本标记空间, 其输出一般不作为特征向量使用。因此, 本文选择 SE-MPDenseNet 中最深的全局平均池化层输出的 1 024 维特征向量作为特征提取器的输出。

#### 1.4 HBL-LightGBM

LightGBM 是一种对高维数据具有良好处理能力的浅层机器学习方法, 可用于处理高维特征向量。但 LightGBM 在解决分类问题上可能存在问题: 一方面, 其使用的二元对数损失函数 BinaryLogLoss 通常对噪声比较敏感, 如果训练数据中同时存在噪声和异常值, 影响可能更大, 训练得到的最终模型的性能可能会受到一定影响; 另一方面, 对于输出分数接近于极值的样本, BinaryLogLoss 计算得到的梯度会变得很小, 导致模型难以持续优化。

Hinge Loss 可以降低噪声数据的影响, 使得模型更具健壮性; 同时, 通过对超出边界的误差进行惩罚使得模型对样本中异常值的鲁棒性得到提升。因此, 提出一种结合 Hinge Loss 和 BinaryLogLoss 的损失函数 HBLLoss, 替换 LightGBM 中原来使用的 BinaryLogLoss, 从而得到 HBL-LightGBM。

$$L_{\text{HBLLoss}} = L_{\text{HingeLoss}} + L_{\text{BinaryLogLoss}} \quad (1)$$

$$L_{\text{HingeLoss}} = \sum_{i=1}^N \max(0, 1 - (2y_i - 1)(2p_i - 1)) \quad (2)$$

$$L_{\text{BinaryLogLoss}} = \sum_{i=1}^N [y_i \lg(p_i) + (1 - y_i) \lg(1 - p_i)] \quad (3)$$

式中:  $L_{\text{HBLLoss}}$ ,  $L_{\text{HingeLoss}}$ ,  $L_{\text{BinaryLogLoss}}$  分别为 HBLLoss, Hinge Loss 和 BinaryLogLoss 损失函数;  $N$  为样本总数;  $y_i$  为样本的真实标签,  $y_i \in \{0, 1\}$ ;  $p_i$  为样本的预测标签,  $p_i \in \{0, 1\}$ 。

由于 Hinge Loss 损失函数的计算使用的是  $\{-1, 1\}$  标签, 而 HBL-LightGBM 的输出标签为  $\{0, 1\}$ , 为保证 HingeLoss 可在 HBL-LightGBM 中使用, 在式(2)中, 采用  $(2y_i-1)$  和  $(2p_i-1)$  将样本的真实标签  $y_i$  和预测标签  $p_i$  映射到  $[-1, 1]$  区间, 再用于计算 Hinge Loss 损失函数。

2 试验结果与分析

2.1 试验数据及试验环境

采用留出法以 7:3 的比例划分训练集和测试集, 训练集共包含 84 张 MSA 声谱图, 测试集共包含 37 张 MSA 声谱图。采用添加噪声、随机平移、时域增强和频域增强等数据增强方法将训练集扩充为原来的 5 倍, 共得到 420 个样本, 以解决数据量不足的问题。采用所提 SE-MPDenseNet 作为特征提取器, HBL-LightGBM 作为分类器, 使用深度学习框架 PyTorch 实现基于微震信号深度特征学习的岩石破裂类型识别方法。HBL-LightGBM 相关超参数设置: 采用梯度提升树算法, 迭代次数为 300, 树最大深度为 4, 学习率为 0.03, 叶子节点数量为 16, 其他超参数均采取默认参数值。计算平台环境: Windows11 64 位操作系统, 8 核 AMD Ryzen7 3700X CPU (3.6 GHz), NVIDIA GeForce RTX2070 Super 显卡 (GPU), 32 GiB 内存。

2.2 岩石破裂类型识别试验

使用高压伺服动真三轴试验机进行真三轴加载试验, 可以较好地模拟冲击地压灾害的发生过程, 采用所提方法对真三轴加载下的岩石破裂类型进行识别, 以测试该方法在工程模拟环境中的性能。

试验采用的岩样为花岗岩, 尺寸为 100 mm×100 mm×200 mm(长×宽×高)。试验加载方式: 分别从轴向、径向和切向 3 个方向以 0.5 MPa/s 的速率同步加载, 轴向和径向方向分别施加压力至 30 MPa 和 5 MPa 后保持不变, 切向继续以 0.5 MPa/s 的速率施加压力直至岩样破坏。

使用 SE-MPDenseNet 对所有微震信号的 MSA 声谱图进行特征提取, 得到对应的特征向量; 然后将这些特征向量输入 HBL-LightGBM 分类网络, 得到每个微震信号的类别。由于巴西圆盘劈裂试验和直剪试验分别进行了多次, 获取的岩石破裂微震信号来自不同的试验, 单次测试的结果可能缺乏稳定性和可靠性。所以, 进行 100 次随机划分数据集试验, 每次随机划分的训练集与测试集互斥, 划分完数据集后重新进行模型训练, 通过测试集测试模型性能, 最终对 100 次试验获取的模型各项性能指标计算均值和标准差, 结果见表 1。

表 1 岩石破裂类型识别结果  
Table 1 Recognition results for different rock fracture types %

类别	准确率	召回率	$F_1$ 分数	总体准确率
剪切	90.34	87.82	88.87	92.12
张拉	93.90	92.51	91.06	

从岩石破裂类型识别的准确率、召回率、 $F_1$  分数和总体准确率对试验结果进行评估, 其中准确率表示模型预测为某一类时正确的概率, 召回率表示模型找出真正某一类样本的能力,  $F_1$  分数是准确率和召回率的综合评价指标, 是准确率和召回率的调和平均。从表 1 可看出: 所提方法的总体准确率达 92.12%, 说明训练得到的岩石破裂类型识别模型在所需训练数据少且多次随机划分数数据集时仍能获得较高的准确率; 总体标准差为 4.50%, 说明即使在多次随机划分数数据集的情况下, 所提方法的准确率变化幅度也较小, 具有较高的稳定性和鲁棒性; 对 2 类样本的识别准确率均达 90% 以上,  $F_1$  分数达 88% 以上, 说明所提方法对于每个类别都具有良好的分辨能力; 在训练集上训练得到的模型在测试集上也能有很好的表现, 说明所提方法具有很强的泛化能力。

真三轴加载试验获得的微震信号波形如图 9(a) 所示, 根据试验中的应变-应力曲线(图 9(b)), 将整个试验过程划分为初始压密阶段(A)、线弹性阶段(B)、弹塑性阶段(C)和塑性阶段(D)。

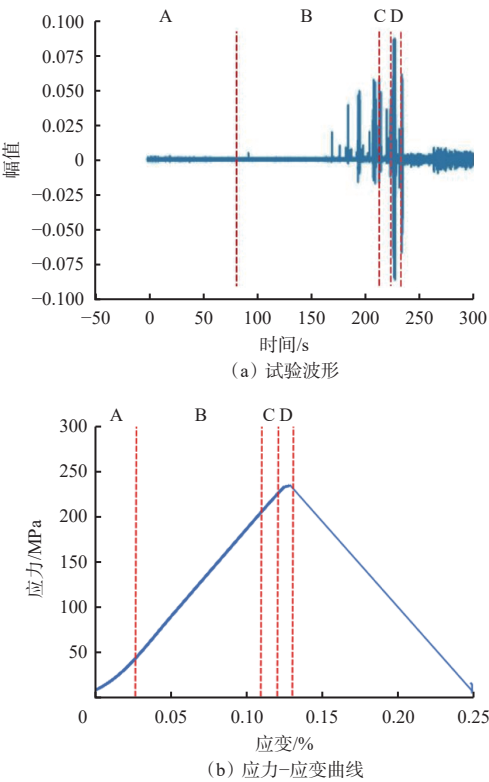


图 9 真三轴加载试验波形及阶段划分

Fig. 9 Waveform and stage division of true-triaxial loading test

在初始压密阶段,岩石之间的天然孔隙逐渐闭合,尚未发生破裂事件,因此对加载过程中的初始压密阶段不做分析,仅对线弹性阶段、弹塑性阶段和塑性阶段做分析。在获得微震信号后将其转换为 MSA 声谱图,共提取到 43 个待测样本,分别处于试验的线弹性阶段、弹塑性阶段和塑性阶段。使用训练好的 SE-MPDenseNet 模型从 MSA 声谱图中提取特征向量,然后再将这些特征向量输入到训练好的 HBL-LightGBM 模型,对待测微震信号样本进行识别,得出真三轴加载试验过程中的张拉型破裂和剪切型破裂情况,结果如图 10 所示,对应的试样实际破裂形态如图 11 所示。

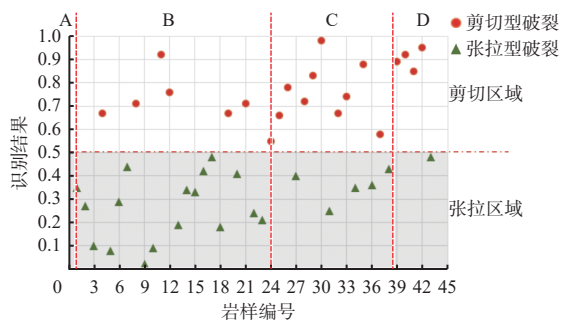


图 10 真三轴加载试验拉剪破裂识别结果

Fig. 10 Recognition results for tensile and shear fractures of true-triaxial loading test




图 11 真三轴加载试验后岩样破坏情况

Fig. 11 Post-test failure morphology of rock samples from true-triaxial loading test

从图 10 可看出:在线弹性阶段,剪切型破裂微震信号占比约为 26%;在弹塑性阶段,剪切型破裂微震信号占比约为 67%;在塑性阶段,剪切型破裂微震信号占比增加到 80%。试验结果表明:在冲击地压孕育的初期,主要发生一些微小的张拉型破裂;随着岩石应力不断增大,岩石内部积聚的能量越来越大,因此发生破裂时所释放的能量也较大,形成一些较大的剪切型破裂;试验后期,岩石内部受力达到极限,此时,岩石内部积聚的能量释放,一部分能量转换为剪切型破裂消耗,剩余能量转换为临空面的颗粒弹射动能,岩石发生大尺度破坏,即发生冲击地压。利用所提方法得到的冲击地压过程中拉剪破裂演化的结论与传统工程力学试验研究结果<sup>[3-4]</sup>保持一致,验证了该方法的有效性和可行性。

为直观展示 SE-MPDenseNet 的特征提取能力,通过 SE-MPDenseNet 对微震信号的 MSA 声谱图数据进行特征提取,得到特征向量,使用 t-SNE(t-Distributed Stochastic Neighbor Embedding)算法对这些特征向量进行降维,映射到二维空间中,可视化结果如图 12 所示。可看出,除去少量的离群点,张拉型破裂样本主要集中在上半部分区域,剪切型破裂样本主要集中在下半部分区域,这说明经过 SE-MPDenseNet 提取的特征向量具有良好的可分性,方法展现出较强的特征提取能力。




图 12 特征向量的 t-SNE 可视化

Fig. 12 t-SNE visualization of extracted feature vectors

### 2.3 消融实验

为验证对 DenseNet 和 LightGBM 所作改进的有效性,开展消融实验,结果见表 2。可看出与 DenseNet 相比,使用了 MP-DenseBlock 和 SE-TransLayer 后的 DenseNet 在准确率上分别提升了 1.14% 和 0.33%;相较于 LightGBM,添加了 Hinge Loss 的 HBL-LightGBM 准确率提升了 0.92%。

表 2 不同改进策略对识别准确率的影响

Table 2 Effect of different model enhancement strategies on recognition accuracy

特征提取器	分类器	准确率/%
DenseNet	HBL-LightGBM	90.64
DenseNet+MP-DenseBlock	HBL-LightGBM	91.78
DenseNet+SE-TransLayer	HBL-LightGBM	90.97
SE-MPDenseNet	LightGBM	91.20
SE-MPDenseNet	HBL-LightGBM	92.12

### 3 结论

1) 在特征提取网络方面,对 DenseNet 进行改进,加入多特征并行密集连接块 MP-DenseBlock 和压缩与激发过渡层 SE-TransLayer,得到深度特征提取网络 SE-MPDenseNet。

2) 在分类网络方面,对 LightGBM 进行改进,在其 BinaryLogLoss 损失函数中加入 Hinge Loss 损失函数,得到浅层分类网络 HBL-LightGBM。

3) 将岩石破裂微震信号对应的 MSA 声谱图输



入 SE-MPDenseNet, 提取的特征向量经过 HBL-LightGBM 分类识别岩石破裂类型, 充分发挥了深度学习特征提取能力强和浅层机器学习方法所需训练数据少的优点。

4) 将所提方法用于与现场工程环境近似的真三轴加载试验(模拟冲击地压灾害)下的岩石破裂类型识别中, 结果表明该方法的识别准确率达 92.12%, 且岩石拉剪破裂演化规律与传统工程力学试验研究结果一致, 验证了所提方法的有效性和可行性。

#### 参考文献(References):

- [1] FENG Xiating, CHEN Bingrui, LI Shaojun, et al. Studies on the evolution process of rockbursts in deep tunnels[J]. *Journal of Rock Mechanics and Geotechnical Engineering*, 2012, 4(4): 289-295.
- [2] SU Guoshao, JIANG Jianqing, ZHAI Shaobin, et al. Influence of tunnel axis stress on strainburst: an experimental study[J]. *Rock Mechanics and Rock Engineering*, 2017, 50(6): 1551-1567.
- [3] SU Guoshao, SHI Yanjiong, FENG Xiating, et al. True-triaxial experimental study of the evolutionary features of the acoustic emissions and sounds of rockburst processes[J]. *Rock Mechanics and Rock Engineering*, 2018, 51(2): 375-389.
- [4] 赵国富, 苏国韶, 胡诗红, 等. 一种基于微震试验的硬岩破裂模式识别方法[J]. *实验力学*, 2022, 37(1): 107-117.  
ZHAO Guofu, SU Guoshao, HU Shihong, et al. A recognition method of cracking types for hard rock based on microseisms tests[J]. *Journal of Experimental Mechanics*, 2022, 37(1): 107-117.
- [5] 李德春, 葛宝堂, 舒继森. 岩体破坏过程中的电阻率变化试验[J]. *中国矿业大学学报*, 1999, 28(5): 80-82.  
LI Dechun, GE Baotang, SHU Jisen. Experiment of resistivity variation of rocks in failure process[J]. *Journal of China University of Mining & Technology*, 1999, 28(5): 80-82.
- [6] 李术才, 许新骥, 刘征宇, 等. 单轴压缩条件下砂岩破坏全过程电阻率与声发射响应特征及损伤演化[J]. *岩石力学与工程学报*, 2014, 33(1): 14-23.  
LI Shucan, XU Xinji, LIU Zhengyu, et al. Electrical resistivity and acoustic emission response characteristics and damage evolution of sandstone during whole process of uniaxial compression[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2014, 33(1): 14-23.
- [7] 李忠辉, 王恩元, 何学秋, 等. 含水量对煤岩电磁辐射特征的影响[J]. *中国矿业大学学报*, 2006, 35(3): 362-366.  
LI Zhonghui, WANG Enyuan, HE Xueqiu, et al. Effect of moisture content on electromagnetic radiation characteristic of coal or rock[J]. *Journal of China University of Mining & Technology*, 2006, 35(3): 362-366.
- [8] 李夕兵, 万国香, 周子龙. 岩石破裂电磁辐射频率与岩石属性参数的关系[J]. *地球物理学报*, 2009, 52(1): 253-259.  
LI Xibing, WAN Guoxiang, ZHOU Zilong. The relation between the frequency of electromagnetic radiation (EMR) induced by rock fracture and attribute parameters of rock masses[J]. *Chinese Journal of Geophysics*, 2009, 52(1): 253-259.
- [9] 高煜, 胡宾鑫, 朱峰, 等. 微震初至波到时自动拾取研究[J]. *工矿自动化*, 2020, 46(12): 106-110.  
GAO Yu, HU Binxin, ZHU Feng, et al. Research on automatic picking of microseismic first arrival[J]. *Industry and Mine Automation*, 2020, 46(12): 106-110.
- [10] 何凤贞, 李桂臣, 阚甲广, 等. 岩石多尺度损伤研究进展[J]. *煤炭科学技术*, 2024, 52(10): 33-53.  
HE Fengzhen, LI Guichen, KAN Jianguang, et al. Research progress on multi-scale damage of rock[J]. *Coal Science and Technology*, 2024, 52(10): 33-53.
- [11] 张凯, 张东晓, 赵勇强, 等. 损伤岩石声发射演化特征及响应机制试验研究[J]. *煤田地质与勘探*, 2024, 52(3): 96-106.  
ZHANG Kai, ZHANG Dongxiao, ZHAO Yongqiang, et al. Experimental study on acoustic emission evolution characteristics and response mechanism of damaged rocks[J]. *Coal Geology & Exploration*, 2024, 52(3): 96-106.
- [12] 张泽坤, 宋战平, 程昀, 等. 加载速率影响下类硬岩声发射及破裂响应特征[J]. *煤田地质与勘探*, 2022, 50(2): 115-124.  
ZHANG Zekun, SONG Zhanping, CHENG Yun, et al. Acoustic emission characteristics and fracture response behavior of hard rock-like material under influence of loading rate[J]. *Coal Geology & Exploration*, 2022, 50(2): 115-124.
- [13] 朱权洁, 张尔辉, 李青松, 等. 岩石破坏失稳的声发射响应与损伤定量表征研究[J]. *中国安全生产科学技术*, 2020, 16(1): 92-98.  
ZHU Quanjie, ZHANG Erhui, LI Qingsong, et al. Study on acoustic emission response and damage quantitative characterization of rock destruction and instability[J]. *Journal of Safety Science and Technology*, 2020, 16(1): 92-98.
- [14] 李炜强, 许沁舒, 成功, 等. 单轴压缩下砂岩微破裂演化力学行为研究[J]. *煤炭科学技术*, 2020, 48(11): 60-67.  
LI Weiqiang, XU Qinshu, CHENG Gong, et al. Study on mechanical behavior of sandstone micro-fracture evolution under uniaxial compression test[J]. *Coal Science and Technology*, 2020, 48(11): 60-67.
- [15] 刘健, 王晓军, 徐莎莎, 等. 基于声发射 RA-AF 值识别不同岩爆倾向性灰岩破裂特征[J]. *金属矿山*, 2022(10): 16-23.  
LIU Jian, WANG Xiaojun, XU Shasha, et al. Identification of limestone fracture characteristics with different rockburst propensities based on acoustic

- emission RA-AF values[J]. *Metal Mine*, 2022(10): 16-23.
- [16] 纪洪广, 张春瑞, 张月征, 等. 岩石材料破裂过程中声发射信号的应力状态及能量演化研究[J]. *中国矿业大学学报*, 2024, 53(2): 211-223.
- JI Hongguang, ZHANG Chunrui, ZHANG Yuezheng, et al. Research on stress state and energy evolution of acoustic emission signal during rock materials fracture process[J]. *Journal of China University of Mining & Technology*, 2024, 53(2): 211-223.
- [17] 陈炳瑞, 冯夏庭, 符启卿, 等. 综合集成高精度智能微震监测技术及其在深部岩石工程中的应用[J]. *岩土力学*, 2020, 41(7): 2422-2431.
- CHEN Bingrui, FENG Xiating, FU Qiqing, et al. Integration and high precision intelligence microseismic monitoring technology and its application in deep rock engineering[J]. *Rock and Soil Mechanics*, 2020, 41(7): 2422-2431.
- [18] 黄杰, 苏国韶, 王拯扶, 等. 基于声谱图特征的硬岩破裂类型识别方法[J]. *人民长江*, 2021, 52(8): 198-203.
- HUANG Jie, SU Guoshao, WANG Zhengfu, et al. Recognition method of hard rock cracking types based on spectrograms characteristics[J]. *Yangtze River*, 2021, 52(8): 198-203.
- [19] CHANG Zhenghao, HE R, YU Yongsheng, et al. A two-stream convolution architecture for ESC based on audio feature distanglement[C]. *Asian Conference on Machine Learning*, New York, 2023: 153-168.
- [20] HUANG Gao, LIU Zhuang, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]. *IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 2017: 2261-2269.
- [21] HU Jie, SHEN Li, SUN Gang. Squeeze-and-excitation networks[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 2018: 7132-7141.
- [22] YANG Huazhong, CHEN Zhongju, YANG Huajian, et al. Predicting coronary heart disease using an improved LightGBM model: performance analysis and comparison[J]. *IEEE Access*, 2023, 11: 23366-23380.
- [23] WANG Huajun, LI Genghui, WANG Zhenkun. Fast SVM classifier for large-scale classification problems[J]. *Information Sciences*, 2023, 642. DOI: [10.1016/j.ins.2023.119136](https://doi.org/10.1016/j.ins.2023.119136).
- [24] WU Di, FAN Zheyi, YI Shuhan. Crowd counting based on multi-level multi-scale feature[J]. *Applied Intelligence*, 2023, 53(19): 21891-21901.
- ~~~~~
- (上接第 112 页)
- [17] 王文娟. 瓦斯传感器的封装改进与检测方法研究[D]. 徐州: 中国矿业大学, 2015.
- WANG Wenjuan. Research on package improvement and detection method of gas sensor[D]. Xuzhou: China University of Mining and Technology, 2015.
- [18] 王昊, 李杰, 郑闯凯, 等. 煤矿采场顶板灾害预警技术研究进展及展望[J]. *矿业安全与环保*, 2024, 51(2): 46-52.
- WANG Hao, LI Jie, ZHENG Chuangkai, et al. Research progress and prospect of early warning technology of coal mine stope roof disaster[J]. *Mining Safety & Environmental Protection*, 2024, 51(2): 46-52.
- [19] 肖双双, 马亚洁, 李卫炎, 等. 我国露天矿粉尘防治理论技术近 20 a 研究进展与展望[J]. *金属矿山*, 2023(7): 40-56.
- XIAO Shuangshuang, MA Yajie, LI Weiyan, et al. Study progress and prospect on theory and technology for dust prevention and control in open-pit mine of China in the past 20 years[J]. *Metal Mine*, 2023(7): 40-56.
- [20] 丁雨生. 可调谐激光光谱吸收式瓦斯预警系统研究[D]. 淮南: 安徽理工大学, 2017.
- DING Yusheng. Study on tunable laser spectrum absorption gas early warning system[D]. Huainan: Anhui University of Science & Technology, 2017.
- [21] 陈强强. 基于 TDLAS 煤矿瓦斯浓度监测系统的研究[D]. 西安: 西安科技大学, 2010.
- CHEN Qiangqiang. Research on coal mine gas concentration monitoring system based on TDLAS[D]. Xi'an: Xi'an University of Science and Technology, 2010.
- [22] 史经灿. 粉尘浓度测量仪检定装置的粉尘均匀性控制研究[D]. 徐州: 中国矿业大学, 2022.
- SHI Jingcan. Study on dust uniformity control of dust concentration measuring instrument calibration device[D]. Xuzhou: China University of Mining and Technology, 2022.
- [23] ZHANG Hao, NIE Wen, LIANG Yu, et al. Development and performance detection of higher precision optical sensor for coal dust concentration measurement based on Mie scattering theory[J]. *Optics and Lasers in Engineering*, 2021, 1442. DOI: [10.1016/J.OPTLASENG.2021.106642](https://doi.org/10.1016/J.OPTLASENG.2021.106642).
- [24] 范培全, 魏爱玲, 张冬晨, 等. 700 MHz 频段 5G 网络性能分析与建设方案建议[J]. *电信科学*, 2022, 38(5): 158-164.
- FAN Peiquan, WEI Ailing, ZHANG Dongchen, et al. Performance analysis and construction scheme proposal of 5G network at 700 MHz band[J]. *Telecommunications Science*, 2022, 38(5): 158-164.