时空融合与多模态驱动的冲击地压预测研究

付天予[1],杨小彬[1],胡慢谷[1],张骁俊[1],宋义敏[2],张　锐[1,3],李春永[4]
(1. 中国矿业大学(北京)应急管理与安全工程学院,北京 100083; 2. 北方工业大学 土木工程学院,北京 100144;
3. 内蒙古科技大学 安全与应急管理学院,内蒙古 包头 014010; 4. 准格尔旗云飞矿业有限责任公司 串草圪旦煤矿,
内蒙古 鄂尔多斯 010400)

摘要: 冲击地压是制约煤矿深部开采的重大动力灾害,现有冲击地压预测方法多依赖单一模态特征,面临信息利用不充分问题. 本文提出时空特征融合与多模态驱动的冲击地压危险预测方法(MDL-RBP). 首先,对微震信号进行短时傅里叶变换(STFT)、希尔伯特-黄变换(HHT)、连续小波变换(CWT)时频分析,并提取b值、a值、震频、能量极值等11个地球物理统计学指标,构建涵盖空间、时频和物理统计指标域的互补信息数据集;其次,针对冲击类别不平衡问题,从数据-算法-评估3个维度设计综合处理策略,提升模型对冲击危险样本的识别能力;最后,通过Transformer及MLP捕获时空特征协同关系,并引入双向交叉注意力实现时空特征耦合,设计自适应门控融合模型,通过可学习门控向量动态调整各贡献权重,增强模型的泛化能力. 结果表明:多模态融合模型准确率达90.9%,较最优单模态提升15个百分点,强冲击危险(Ⅳ级)召回率达100%,实现零漏报;在3~30 d多时间窗口预测中,短期(3~7 d)Ⅳ级召回率均为100%,30 d窗口仍保持86%以上准确率. 该方法突破了传统单一模态预警方法的局限性,为煤矿冲击地压精准预测提供了理论支撑和技术方案.

关键词: 冲击地压;多模态融合;深度学习;微震监测;时频分析;类别不平衡
中图分类号: TP 391　　**文献标志码:** A　　**文章编号:** 1000-1964(2026)03-0877-20

Spatiotemporal fusion and multimodal-driven rockburst hazard warning

FU Tianyu[1], YANG Xiaobin[1], HU Mangu[1], ZHANG Xiaojun[1], SONG Yimin[2],
ZHANG Rui[1,3], LI Chunyong[4]
(1. School of Emergency Management and Safety Engineering, China University of Mining and Technology-Beijing, Beijing 100083, China; 2. School of Civil Engineering, North China University of Technology, Beijing 100144, China; 3. School of Safety and Emergency Management, Inner Mongolia University of Science and Technology, Baotou, Inner Mongolia, 014010, China; 4. Chuancaogedan Coal Mine, Yunfei Mining Co., Ltd. of Jungar Banner, Ordos, Inner Mongolia, 010400, China)

Abstract: Rockburst is a severe dynamic hazard that poses a critical threat to safe and efficient deep coal mining. Conventional rockburst prediction approaches commonly depend on single-source information, resulting in incomplete characterization of the spatiotemporal evolution of precursory signals. In this study, a spatiotemporal feature fusion and multimodal-driven framework, termed MDL-RBP, was developed for rockburst hazard prediction. Specifically, microseismic waveforms were transformed into time-frequency representations using the Short-Time Fourier Transform (STFT), Hilbert-Huang Transform (HHT), and Continuous Wavelet Transform (CWT),

收稿日期: 2025-12-30　　**修回日期:** 2026-03-18　　**DOI:** 10.13247/j.cnki.jcumt.20250622
基金项目: 国家自然科学基金项目(51774015)
第一作者: 付天予(2000—),男,河北省唐山市人,博士研究生.E-mail:futianyu0109@163.com
通信作者: 杨小彬(1976—),男,重庆市人,教授,博士生导师.E-mail:yangxiaobin@cumtb.edu.cn
引用格式: 付天予,杨小彬,胡慢谷,等.时空融合与多模态驱动的冲击地压预测研究[J].中国矿业大学学报,2026,55(3):877-896.
FU Tianyu, YANG Xiaobin, HU Mangu, et al. Spatiotemporal fusion and multimodal-driven rockburst hazard warning[J]. Journal of China University of Mining & Technology, 2026, 55(3): 877-896.

while eleven geophysical-statistical indicators (e. g., b-value, a-value, event frequency, and energy extrema) were extracted to establish a complementary dataset integrating spatial, time-frequency, and physical-statistical information. To mitigate pronounced class imbalance, a unified scheme was implemented across data-, algorithm-, and evaluation-level settings to enhance recognition of hazardous categories. Furthermore, a transformer coupled with a multilayer perceptron (MLP) was employed to model spatiotemporal dependencies, and bidirectional cross-attention was introduced to facilitate deep coupling among heterogeneous feature sources. An adaptive gating fusion module was finally incorporated to learn modality contributions in a data-driven manner, thereby improving generalization. Experimental results show that MDL-RBP achieves an accuracy of 90.9% outperforming the best single-modal baseline by 15 percentage points, and attains 100% recall for the most hazardous class (Level Ⅳ), eliminating missed alarms. Across multi-horizon forecasts from 3 to 30 days, Level Ⅳ recall remains 100% for short-term horizons (3—7 days), and the 30-day horizon maintains an accuracy exceeding 86%. The proposed method advances multimodal spatiotemporal modeling for rockburst prediction and offers a practical technical solution for accurate hazard forecasting in deep coal mines.

Key words: rockburst; multimodal fusion; deep learning; microseismic monitoring; time-frequency analysis; class imbalance

随着浅部煤层资源的日益枯竭,开采深度逐渐增加,冲击地压危险程度显著提升[1],已成为制约煤矿安全高效生产的主要灾害.与冲击地压诱发机理研究侧重于力学本质分析不同,冲击地压预测更注重从时频、空间与物理指标多个维度全方位捕获冲击前兆信息,实现对未来可能发生危险的有效判识.然而,冲击地压发生过程复杂且瞬时性强,尤其在多因素交织条件下,如何提高预警准确性和时效性成为亟待解决的关键问题[2].

现有冲击地压预警以现场监测为主[4],微震监测受限于定位精度、响应时效及自动识别能力[5],钻屑法则存在点测量局限、人工误差大及作业安全风险等问题[6],同时现行冲击地压危险性评价体系,难以实时捕捉微震活动的时频演化特征,对短期前兆信息的动态识别能力有限[8].为克服传统方法局限性,基于统计学及机器学习的冲击地压预测方法应运而生.文献[8]提出"最大能量+7日偏差高值数"预警法,有效提升了微震冲击危险预警能力.文献[10-11]提出基于CatBoost的可解释冲击地压预测模型,并将SHAP值分析应用于特征重要性解释.但传统机器学习方法普遍依赖特征工程,面对多源监测数据的非线性耦合与时空演化规律时,往往难以实现更深层次的有效表征与泛化建模.

近年来深度学习模型为冲击地压时序预测提供了新思路[12-13].针对工况演化导致的非平稳性,文献[14]结合ADF检验构建分成因数据集,并融合1D-CNN与BiLSTM实现能量与频次的稳定预测;文献[15]将CNN思想用于空间扫描与综合指标构建,实现危险区域动态圈定与分级预测;文献[16]提出FDNet融合专家知识指标与深度特征以提升预测性能.尽管深度学习方法取得显著进展,但大多数模型仅使用单一类型数据,难以全面刻画冲击地压复杂的多因素耦合特性;时频分析方法虽有应用,但与深度学习的深度集成不足,长期、中期、短期预测指标缺乏有效整合.

多模态通过融合多源异构数据为突破上述局限提供了新思路.文献[17]提出了面向地下采矿地质灾害预测的多模态数据融合框架,显著提升了稀疏分布多维数据的预测精度.文献[18]构建了基于自适应阈值的钻进参数多模态融合模型(ATRDF),综合利用转速、钻速等异构数据,实现了岩体的高精度分类.然而,目前针对冲击地压的多模态深度学习研究仍处于起步阶段,主要局限在于:现有多模态方法多为简单拼接或加权融合,缺乏对不同模态间语义关联的深度挖掘;时频域、空间域和物理指标域信息的协同建模机制尚未建立;跨模态注意力机制在冲击地压预测中的应用研究几乎空白.

鉴于此,提出基于多模态深度学习的冲击危险性判识方法.首先,结合微震监测信号进行STFT,HHT,CWT时频分析,以及a,b值等物理指标,构建涵盖空间、时频和物理指标域的多模态数据集.其次,针对样本不平衡问题设计"数据+算法+评估"三位一体的综合处理策略,以缓解类别不平衡问题.再次,设计多模态深度学习网络

(MDL-RBP)，分别提取时频特征和空间结构特征，利用 Transformer 及 MLP 实现时空融合，通过自适应门控机制动态调整不同特征权重．本研究旨在突破现有方法的单一模态局限，实现多源信息深度融合，为煤矿冲击地压精准预测提供理论支撑和技术方案．

1　工程背景与多模态特征构建

1.1　工程背景及冲击危险性分级

以吉林省龙家堡煤矿为研究对象，该矿为典型千米深部冲击地压矿井，矿区构造条件复杂，正断层发育，该矿区主要断层包括 DF7，DF21，DF22，DF27，DF39，DF40 等，其中部分断层落差可达 6 m，对区域应力分布具有显著影响．三维地震勘探结果表明，上述断层在空间上存在约 10 m 的摆动特征，其邻近区域局部应力集中明显，并伴随发育一定规模的小幅褶曲构造，在采掘扰动条件下可能诱发局部应力释放与微震活动．

进一步以 615 工作面为具体研究对象，其位于矿井六采区北翼，开采Ⅱ、Ⅲ号合采煤层，煤层间夹矸厚度约为 0.5～2.0 m，煤体层理发育、结构较为复杂．东翼为 513 工作面；北翼为-1010 车场及转载皮带道；南翼 DF39 断层；西翼为 617 工作面．巷道围岩条件表现为顶板以泥岩、凝灰岩及砾岩为主，底板以粉砂岩和泥岩为主．615 工作面冲击危险性主要由断层、覆岩结构、采深、采动应力及影响来决定，鉴定为强冲击危险区，冲击风险较高，运输顺槽、开眼、回风顺槽为强冲击危险区域，615 工作面布置示意如图 1 所示．

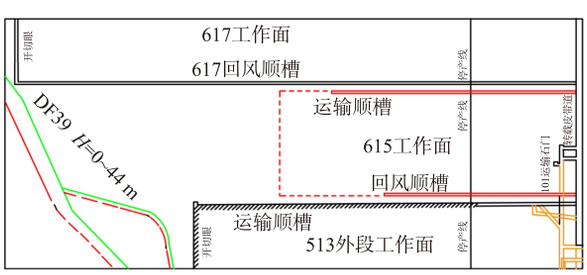

注：H 为断层落差．

图 1　615 工作面布置示意

Fig. 1　Layout of panel 615

615 工作面采用 ARAMIS M/E 微震监测系统，可监测频率为 0～150 Hz、能量为 102 J 以上的微震活动，2 台传感器布置在运输石门附近，剩余 4 台分别布置在运输顺槽和回风顺槽附近，相邻传感器之间间隔 300～600 m 左右随着巷道掘进，动态调整传感器位置，最大程度覆盖到监测区域．

图 2 展示了 2023 年 615 工作面微震活动的日尺度统计特征，图 2a 为每日总能量柱状图，统计了 7 d 移动均值用于表征整体变化趋势，统计结果显示最大日能量为 157.748 kJ，平均日能量为 37.588 kJ，监测总天数为 296 d．图 2b 为每日事件数变化及其均值参考线，平均为 20.0 次/d，最大日事件数为 71，最小日事件数为 1，总事件数为 5 908．图 2 揭示了监测期内微震活动呈现明显的阶段性增强-衰减演化特征：3—5 月微震能量与事件频次同步升高，反映围岩破裂活动增强、能量释放加剧，存在冲击地压危险性特征；而 7—10 月活动水平整体较低，系统处于相对稳定阶段．移动平均曲线进一步表明，微震活动强度的变化具有一定持续性和趋势性，为后续基于滑动窗口的危险性识别与预测建模提供了依据．

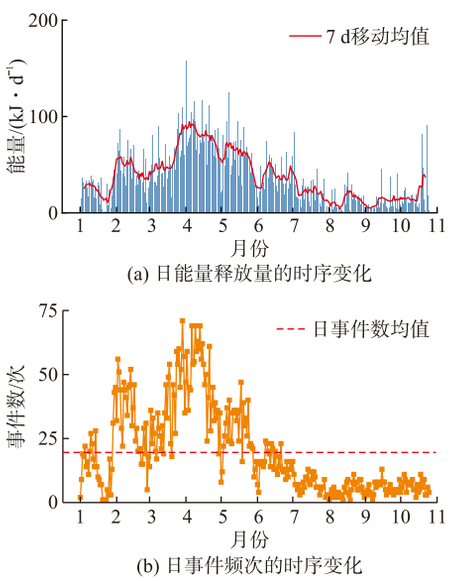

(a) 日能量释放量的时序变化

(b) 日事件频次的时序变化

图 2　微震日总能量与日事件数时序演化特征

Fig. 2　Temporal evolution characteristics of daily total microseismic energy and daily event count

为确定冲击地压危险等级的能量阈值并实现分级预测，需为每个滑动时间窗口赋予冲击地压风险等级标签．现有研究多采用固定能量阈值对风险进行分级，但不同矿区地质条件与采掘扰动差异较大，采用固定能量阈值往往难以准确反映现场微震能级结构．巷道掘进过程中，冲击孕育阶段常伴随局部应力集中，受扰动影响后，局部区域内特定能级事件可能出现突增或骤减，导致能级比例异常[19]，该异常通常表现为能量-频度曲线在某些能级附近发生转折或偏移，据此可识别能级分界点并用于危险等级划分，根据该矿 615 巷掘进期间统计的全部微震事件，绘制出能量-频度曲线并进行线性拟合，得到的能量-频度曲线结果如图 3，并据此确定 4 个危险等级的单次能量区间如表 1 所示．

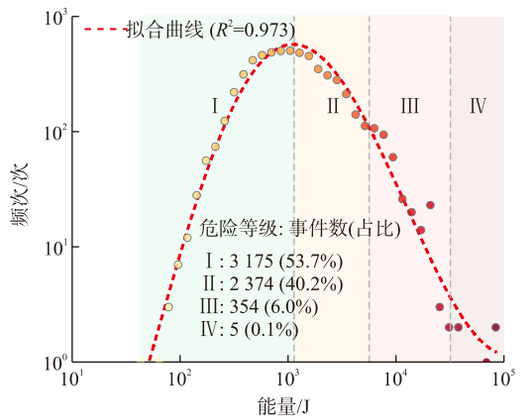

图 3 615 巷掘进期间微震能量-频度曲线

Fig. 3 Microseismic energy-frequency curve during excavation of roadway 615

表 1 基于能量-频度拐点的冲击地压危险分级标准

Table 1 Rockburst hazard classification criteria based on energy-frequency inflection point

危险等级	能量 E/J	频度特征
Ⅰ级(低危险)	<1 103	频度快速上升段
Ⅱ级(中危险)	1 103～<5 649	高频主体区(近峰值)
Ⅲ级(较高危险)	5 649～31 892	频度下降段
Ⅳ级(高危险)	>31 892	高频稀有、能量极高

1.2 前兆特征提取

为系统刻画冲击地压孕育过程中微震活动前兆信息,以固定滑动时间窗为基本单元,对微震事件序列开展多层次特征构建:首先从提取地球物理与统计学指标,表征微震活动的宏观演化;其次从波形时频结构与震源空间组织入手构建时频与空间图像特征,以捕捉非平稳频谱特征及空间聚集-迁移规律.

1.2.1 基于地球物理指标的微震指标选取

为兼顾冲击地压孕育过程中能量释放水平、事件规模分布及序列复杂性关键信息,在固定滑动窗口内选取 7 项地球物理统计指标及 4 项统计学指标构成物理特征向量,用于表征微震活动的宏观演化状态,见表 2. 数据处理与特征构建的总体流程如图 4 所示. 表 2 所列的公式中:N 为震频;M 为震级;a_{GR} 和 b_{GR} 为古登堡-里克特关系中的常数;m 为震级分档总数;N_i 为第 i 个微震事件的频次;E_i 为第 i 个微震事件的能量;e 为自然对数的底数;M_0 为参考震级;$\bar{M}$ 为平均震级;m_i 为第 i 个微震事件的震级;n 为微震事件总数.

表 2 冲击地压预测地球物理及统计学指标统计

Table 2 Summary of geophysical and statistical indicators for rockburst warning

指标		公式	物理意义
地球物理指标	b[20]	$\lg N(\geqslant M)=a_{GR}-b_{GR}M$	矿震活动强度的高低
	a[21]	$a=\frac{1}{m}\sum_{i=1}^{m}\lg N_i+\frac{b_{GR}}{m}\sum_{i=1}^{m}\lg E_i$	矿震活动水平的高低
	$A(b)$[22]	$A(b)=\frac{1}{b_{GR}}\lg\sum_{i=1}^{N}10^{b_{GR}m_i}$	微震事件中能量较大的一部分微震事件
	B[23]	$B=\frac{\lg e}{\bar{M}-M_0},\bar{M}=\sum_{i=1}^{n}\frac{m_i}{n}$	缺失震级的现象
	$P(b)$[24]	$P(b)=\frac{N}{b_{GR}}\left(\lg\sum_{i=1}^{N}10^{b_{GR}m_i}-\lg N\right)$	小震级微震事件活动度
	S[25]	$S=0.117\lg(N+1)+0.029\times\lg\frac{1}{N}\sum_{i=1}^{N}10^{1.5m_i}+0.015M$	微震活动的强弱程度
	AC[25],简写为 C_A	$C_A=\frac{\ln n}{n\times\ln M}$	矿震演化的时序过程的混沌特性
统计学指标	震频 N		特定时间窗下发生微震次数
	能量极值 E_{max}	$E_{max}=\mathrm{Max}(E_1,E_2,\cdots,E_N)$	特定时间窗下发生微震的最大能量
	能量均值 E_{mean}	$E_{mean}=\frac{\sum_{i=1}^{N}E_i}{N}$	特定时间窗下发生微震的平均能量
	各级能量占比 r_i	$r_i=\frac{M_i}{N}$	特定时间窗下各级微震能量占比

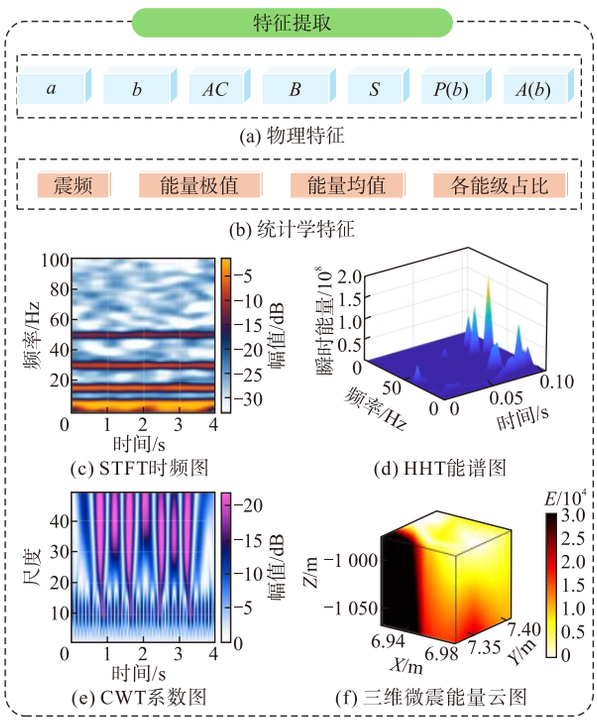

图 4　微震数据处理与特征构建流程

Fig. 4　Flowchart of microseismic data processing and feature construction

同时绘制基于 3D 滑动窗口计算得到的各指标时序演化趋势如图 5 所示. 图 5 展示了 1—11 月期间矿井微震监测系统获取的多维地球物理指标时序演化特征及其与大能量冲击事件(红色五角星标记)的对应关系.

图 5a 中,b 值整体围绕 1.0 波动,在部分大能级事件前后出现局部低值响应,AC 值在 3—6 月间较低,表明该时段地震序列时间相关性极弱,6 月后随大能级事件陆续发生显著回升. 图 1b 中,S 与 $A(b)$ 在大事件活跃期(3—7 月)协同维持高位,分别约为 0.35～0.40 与 5～6,反映该阶段地震活动离散度大、b 值波动剧烈;7 月后二者同步下降. 图 1c 中,缺震 B 呈现全时段最为显著的单调下降趋势,自年初约 0.60～0.85 持续降至年末约 0.25,与大能级事件的累积能量释放过程高度吻合,具有显著的中长期前兆特征;a 值整体波动较大,与大能级事件的时间对应性相对较弱. 图 1d 中,大能级事件多在 $P(b)$ 突然变化时发生,具备一定参考价值. 综合来看,单一指标在一定程度上可对大能级事件进行预警,但受制微震的复杂性与非线性特征,其预测结果仍具有极大不确定性,因此开展多参数联合分析、从多维度综合判断异常信号极为重要.

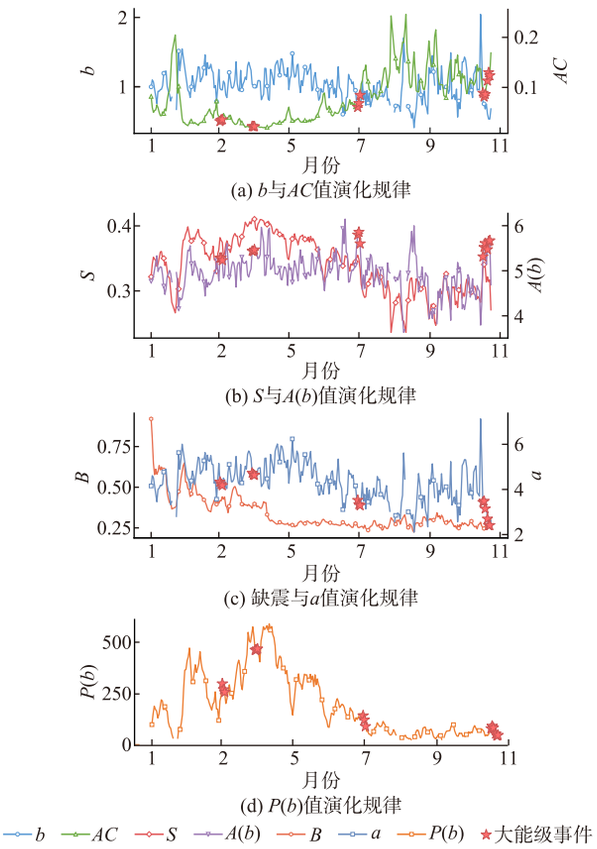

图 5　冲击地压前兆指标时序演化

Fig. 5　Temporal evolution of rockburst precursor indicators

1.2.2　考虑时频及空间特性的微震信息提取

地球物理统计指标主要反映微震活动的宏观水平与分布特征,但对波形的非平稳时频演化以及震源空间聚集信息表征不足. 因此,进一步根据微震信息提取时频-空间特征,分为:时频表征(STFT 谱图、HHT 能量谱、CWT 系数图)与空间表征(三维微震能量云图),分别从频带演化、多尺度瞬态与空间聚集迁移 3 个维度刻画时间窗内的微震活动特征,为后续多模态融合预测模型提供多模态表征. 表 3 给出所选取的 4 类图像数据及其主要物理指示意义.

表 3　冲击地压预测时空图像特征选取及物理意义

Table 3　Selection and physical significance of spatiotemporal image features for rockburst warning

特征类型	符号表示	主要刻画信息	机理解释
STFT 时频谱图	I_{STFT}	固定窗下频带能量随时间演化	捕捉主频漂移、频带扩展、能量迁移等渐变型前兆
HHT 瞬时能量谱	I_{HHT}	非线性非平稳瞬时频率与能量突变	对突发性能量释放、频率跳变更敏感
CWT 系数图	I_{CWT}	多尺度局部能量与纹理结构	反映不同破裂尺度协同演化(微裂隙→宏观破裂)
三维微震能量云图	I_{3D}	震源聚集、迁移、空间热点	定位应力集中区与破裂带扩展

1) STFT 时频谱图

微震波形信号为典型非平稳过程，其频谱结构随时间演化与岩体破裂机制变化密切相关[26]. 采用短时傅里叶变换(STFT)构建窗口级时频谱图：

$$\mathrm{STFT}(t,f)=\int_{-\infty}^{+\infty}s(\tau)\cdot w(\tau-t)\cdot \mathrm{e}^{-\mathrm{j}2\pi f\tau}\mathrm{d}\tau, \quad (1)$$

式中：$s(\tau)$为微震波形；$w(\cdot)$为窗函数；t为时间；τ为时间平移量；e为自然对数的底数；j为虚数单位；f为频率. 为获得稳定的图像输入，对功率谱进行对数压缩并归一化. STFT 可用于表征主频漂移、频带能量增强与频带迁移等特征，适于捕捉冲击孕育的中前期“渐变型”时频异常，STFT 时频谱如图 4c 所示.

2) HHT 瞬时频率-能量谱

冲击孕育后期常表现为较强的非线性与非平稳特征，微震信号可能出现瞬态增强、频率突变等现象[27]. 为此，采用 Hilbert-Huang 变换(HHT)获取瞬时频率与能量分布. 通过 EMD 将信号分解为若干本征模态函数(IMF)：

$$s(t)=\sum_{m=1}^{K}\mathrm{IMF}m(t)+r(t), \quad (2)$$

式中：$s(t)$为原始信号；K为 IMF 分量总数；$m(t)$为第 k 个本征模态函数；$r(t)$为残余分量. 对各 IMF 进行 Hilbert 变换，构建 Hilbert 能量谱 $H(F,T)$，并进行对数尺度映射得到 I_{HHT}. 与 STFT 相比，HHT 不依赖固定基函数，能够自适应刻画瞬时频率变化，对冲击发生前的“突发型”前兆更敏感，HHT 能谱如图 4d 所示.

3) CWT 多尺度系数图

为刻画不同破裂尺度对应的频率成分变化，采用连续小波变换(CWT)获得多尺度时频局部化表征：

$$W(s,\tau)=\frac{1}{\sqrt{|s|}}\int s(t)\psi^{*}\left(\frac{t-\tau}{s}\right)\mathrm{d}t, \quad (3)$$

式中：s为尺度；ψ^{*}为母小波 ψ 的复共轭. 将 $|W(a,b)|$ 映射为尺度-时间二维图像 I_{CWT}. 小尺度对应高频成分(微裂隙活动)，大尺度对应低频成分(宏观破裂过程). 当多尺度能量同时异常增强或呈协同演化趋势时，破裂机制由微观向宏观转化，具有较强的冲击危险指导意义[28]，CWT 系数如图 4e 所示.

4)三维微震能量云图

冲击地压具有显著空间局部性，应力集中区的形成与扩展常表现为震源点在空间上的聚集、迁移[29]. 利用震源定位结果构建窗口内点云：

$$I_{3\mathrm{D}}=(x_i,y_i,z_i,E_i), \quad (4)$$

式中：(x_i,y_i,z_i)为震源坐标. 以能量作为点的颜色或大小映射生成三维微震能量云图 $I_{3\mathrm{D}}$，用于表征微震空间位置、聚集程度及潜在破裂带形态. 该空间表征可为预测提供“危险区域可定位”的工程意义，并与时频表征形成互补三维微震能量云图如 4f 所示.

2 多模态数据融合的冲击危险性预测模型

2.1 不平衡问题处理

2.1.1 类别不平衡概述

在构建冲击地压危险性预测模型的过程中，类别不平衡是制约模型性能的关键[30]. 图 6 对比展示了理想情况与实际情况的差异：在理想的类别平衡场景下(图 6a)，各危险等级样本均匀分布，决策边界清晰稳定；而实际数据中(图 6b)，高危样本(Ⅳ级)严重稀缺，导致模型决策边界向多数类严重偏移，丧失对关键高危事件的预测能力.

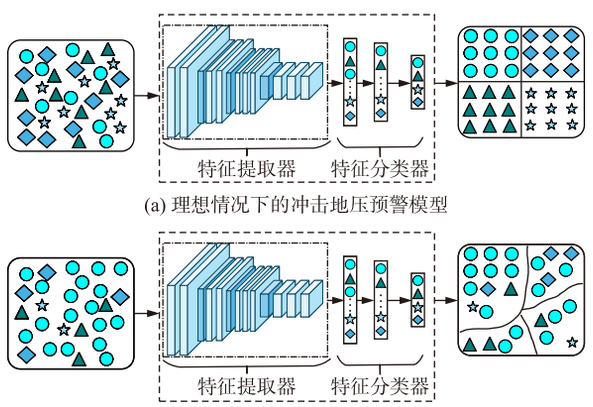

(a) 理想情况下的冲击地压预警模型

(b) 样本不平衡情况下的冲击地压预警模型

● Ⅰ级 (低危险) ◆ Ⅱ级 (中危险) ▲ Ⅲ级 (较高危险) ☆ Ⅳ级 (高危险)

图 6 冲击地压类别不平衡示意

Fig. 6 Schematic diagram of rockburst class imbalance

针对上述问题，提出了“数据层面＋算法层面＋评估层面”三位一体的综合处理策略.

2.1.2 数据层

从数据层面，通过类别平衡批次采样与 SMOTE 过采样的协同策略增强少数类样本.

1) 类别平衡批次采样

为缓解高危样本极少导致梯度更新被多数类主导的问题，本文在严格遵循“基于历史信息预测未来”的时序建模原则下，按时间顺序将滑动窗口样本划分为训练、验证和测试三段连续且互不重叠的时间区间. 在此基础上，仅在训练集内部采用

类别平衡批次采样策略，在每个批次中按预设比例抽取各风险等级样本，以缓解类别极度不平衡对训练稳定性的影响．该策略仅作用于训练阶段的样本抽样概率，不引入未来时间段信息；验证集与测试集保持原始时间顺序与真实类别分布，因此不会造成信息泄露，也不影响模型在真实分布下的泛化评估．

2) SMOTE过采样

原始数据空间的线性插值难以保证合成样本的物理合理性，而特征空间中的样本分布更具语义连续性．因此，本文对训练集在编码器提取的特征空间进行SMOTE过采样．

步骤1：特征提取．

使用预训练编码器，将Ⅳ级样本映射到特征空间．

步骤2：K近邻查找．

对于每个少数类样本h_i，在同类样本中查找$K=5$个最近邻h_j.

步骤3：线性插值合成．

$$h_{\mathrm{syn}}=h_i+\lambda\left(h_j-h_i\right),\lambda\sim U(0,1),\tag{5}$$

式中：$\lambda\sim U(0,1)$为服从[0,1]均匀分布的随机数；h_j为h_i的一个随机近邻．合成样本在特征空间中位于原样本和其近邻之间，保持了类内的局部分布结构．

步骤4：标签继承．

合成样本继承h_i的类别标签，将少数样本扩充至较高的倍数，使得训练过程中高危样本有足够的训练权重．

2.1.3　算法层

标准交叉熵损失中所有类别权重相等，容易被较高数量类别影响，因此，提出损失函数(Focal Loss)，通过引入调制因子，降低易分样本的损失权重，强制模型关注困难样本：

$$L_{\mathrm{cls}}=-\frac{1}{N'}\sum_i\sum_c\alpha_c\left(1-\hat{y}_{ic}\right)^{\gamma}\cdot y_{ic}\log\left(\hat{y}_{ic}\right),\tag{6}$$

式中：L_{cls}为损失函数；N'为样本数量；a_c为类别权重；γ为聚焦参数，取值为2；$(1-\hat{y}_{ic})^{\gamma}$为调制因子，当模型对某样本预测置信度高($\hat{y}_{ic}\to1$)时，调制因子趋近于0，该样本损失贡献降低，当预测置信度低($\hat{y}_{ic}\to0$)时，调制因子趋近于1；使得模型在训练后期，当多数类样本已被正确分类后，能够将优化重心转移到少数类和边界样本上，有效缓解决策边界偏向多数类的问题．

2.1.4　评估层

针对类别不平衡问题，采用宏平均精确率(P_{M})、宏平均召回率(R_{M})、宏平均F_1($F_{1\mathrm{M}}$)和加权F_1($F_{1\mathrm{W}}$)作为核心评估指标：

1) 召回率(R)

$$R=\frac{T_{\mathrm{P}}}{T_{\mathrm{P}}+F_{\mathrm{N}}},\tag{7}$$

式中：T_{P}为真正例数；F_{N}为假负例数．召回率反映了模型“不漏报”的能力．对于高危类别，召回率低意味着大量危险事件被错误预测为低危，在工程应用中是不可接受的，故求Ⅲ级召回率≥70%，Ⅳ级召回率≥100%．

2) 精确率(P)

$$P=\frac{T_{\mathrm{P}}}{T_{\mathrm{P}}+F_{\mathrm{P}}},\tag{8}$$

式中　F_{P}为模型错误预测为正类的实际负类样本数．

精确率反映了模型预测为某类别的样本中真正属于该类别的比例，体现了模型的“不误报”能力．

3) 宏平均精确率与召回率

$$P_{\mathrm{M}}=\frac{1}{C}\sum_{i=1}^{C}P_i,\tag{9}$$

$$R_{\mathrm{M}}=\frac{1}{C}\sum_{i=1}^{C}R_i,\tag{10}$$

式中：P_i为第i类的精确率；R_i为第i类的召回率；C为类别总数，取值为4．宏平均指标对每个类别赋予相等权重，即使样本数量极少的高危类别也能获得与低危类别同等的重要性，有效避免了多数类主导评估结果的问题．

4) F_1分数及其宏平均与加权平均

F_1分数综合考虑精确率与召回率的调和平均：

$$F_1=\frac{2\cdot P\cdot R}{P+R},\tag{11}$$

$$F_{1\mathrm{M}}=\frac{1}{C}\sum_{i=1}^{C}F_{1i},\tag{12}$$

$$F_{1\mathrm{W}}=\sum_{i=1}^{C}\frac{N_i}{N_{\mathrm{t}}}\cdot F_{1i},\tag{13}$$

式中：N_i为第i类样本数量；N_{t}为总样本数；F_{1i}为第i个样本的F_1分数；$F_{1\mathrm{M}}$对所有类别平等对待，确保少数类性能得到充分关注；$F_{1\mathrm{W}}$则根据各类别样本比例加权，兼顾整体性能与类别平衡．

三层面的处理策略相互配合，形成协同效应：数据层面的平衡采样和SMOTE过采样直接增加

了高危样本的训练权重，确保每个批次都有足够的高危样本，避免参数更新被多数类垄断；算法层引入损失函数聚集困难样本，即使批次中高危样本数量有限，其损失权重也能得到有效提升；评估层面的多维度指标体系（P_{M}，R_{M}，$F_{1\mathrm{M}}$，$F_{1\mathrm{W}}$）避免了总体准确率的“虚假繁荣”，确保模型选择和超参数调优聚焦于真正重要的高危预测性能.

2.2　多模态深度学习模型结构

2.2.1　总体架构概述

本文提出的多模态深度学习预测模型（MDL-RBP）采用“并行特征提取＋时空融合＋多任务学习”的端到端框架. 模型总体架构如图 7 所示，主要包括以下核心模块：

1）模态编码器：5 个并行的深度神经网络分别处理各模态数据，将异构输入映射为统一维度的嵌入向量 $h\in\boldsymbol{R}_d$，d 为嵌入向量（$\boldsymbol{R}$）的维度. 每个编码器针对其输入数据的特性进行专门设计.

2）时空融合：将 5 个模态分为“时序”和“空间”2 个子网络，分别建模时频演化和空间分布特征，然后通过交叉注意力实现互补融合. 时序流使用变换器编码器（Transformer Encoder）处理 STFT，HHT，CWT 这 3 个时频模态；空间流通过 MLP 融合点云特征和物理指标中的空间组成分.

3）自适应门控融合：在融合后的特征上引入可学习的门控机制，动态调整各模态的贡献权重，提升对噪声模态和模态缺失的鲁棒性. STFT，HHT，CWT 将微震波形映射到时频平面，三维微震能量云图刻画微震空间位置及潜在破裂活动，同时地球物理与统计学指标从宏观层面反映能量释放与事件规模分布. 由于各模态基于不同的物理机制且对不同信息敏感，各模态具有互补性：STFT 适于刻画渐变型频率结构，HHT 对非线性瞬态突变更敏感，CWT 保留多尺度能量分布，三维云图表征震源聚集与迁移，而 a 值、b 值、缺震、活动度及震频与能量统计量等指标可稳定刻画活动水平与能级结构变化. 基于上述差异与互补关系，采用领域知识引导的差异化编码器设计，如表 4 所示.

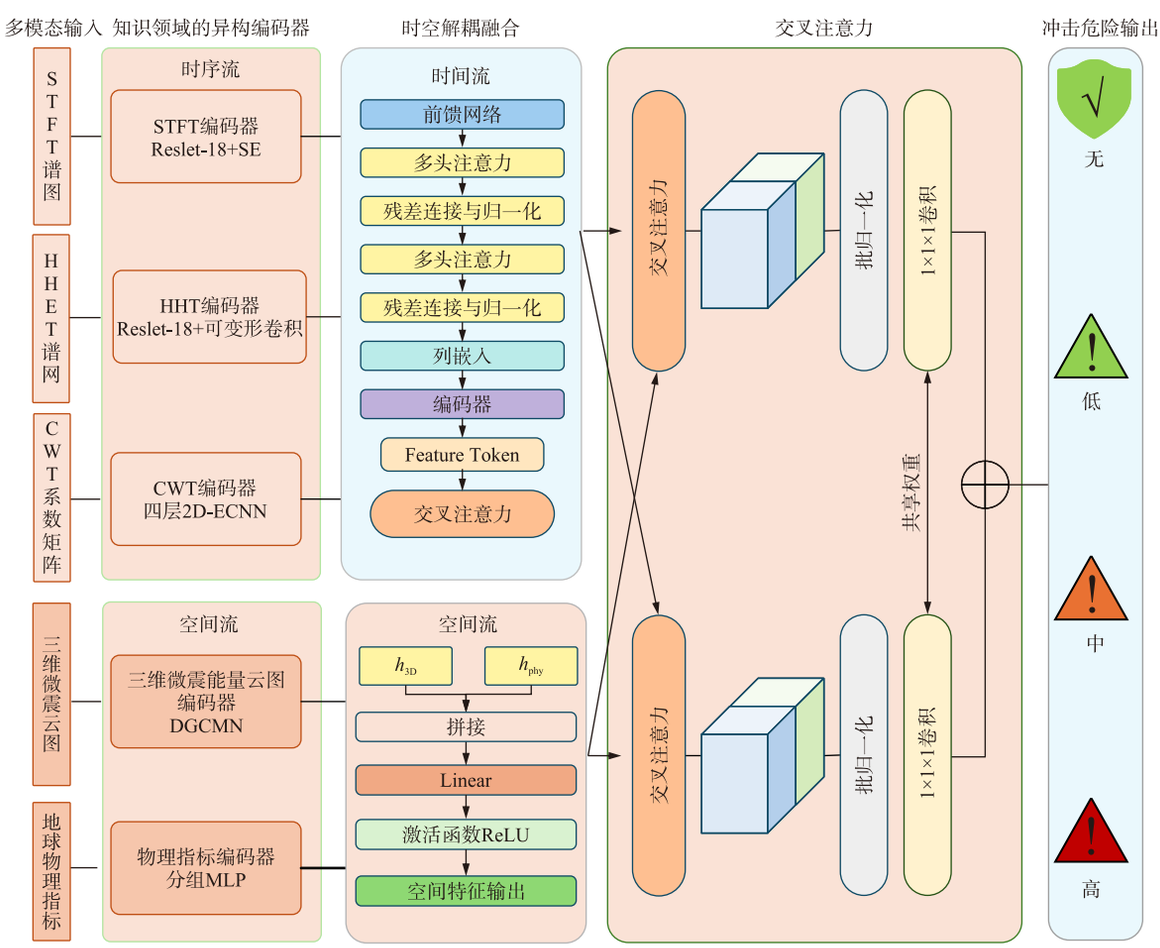

注：h_{3D} 为 I_{3D} 经三维微震能量云图编码器输出的空间嵌入特征；h_{phy} 为 x_{phy} 经物理与统计学指标编码器输出的嵌入特征.

图 7　MDL-RBP 模型整体架构

Fig. 7　Overall architecture of MDL-RBP model

表 4　5 类模态数据的形式化表示与物理意义

Table 4　Formal representation and physical significance of five modal data types

模态	符号表示	物理含义	编码器
物理与统计学指标	x_{phy}	宏观统计演化规律	分组 MLP
STFT 谱图	I_{STFT}	时频能量分布	CNN＋FSA
HHT 谱图	I_{HHT}	非平稳瞬态特征	CNN＋可变形卷积
CWT 系数	I_{CWT}	多尺度破裂机制	2D-CNN
三维微震能量云图	I_{3D}	空间聚集与迁移	DGCNN

注：MLP 为多层感知机；CNN 为卷积神经网络；FSA 为频率自注意力；DGCNN 为动态图卷积网络.

2.2.2　地球物理指标数值特征编码器

考虑冲击地压孕育的“应力积累—能量集聚—失稳破坏”演化机理，且不同指标对不同阶段的敏感性存在差异，将上述数值特征按物理含义进行分组编码，以增强网络学习的结构化先验，分为 3 组：

1）规模-应力表征组（反映事件规模分布与应力状态变化）：

$$\boldsymbol{x}_{\mathrm{s}}=[b,\ B,\ P(b),\ A(b)]\in\boldsymbol{R}^{4},\tag{14}$$

式中　$\boldsymbol{R}$为规模-应力特征向量.

2）活动强度-能量水平组（反映能量释放水平与活动强弱）：

$$\boldsymbol{x}_{\mathrm{e}}=[a,\ S,\ N,\ E_{\max},\ E_{\mathrm{mean}},\ \boldsymbol{r}_i]\in\boldsymbol{R}^{(5+K)},\tag{15}$$

式中　K为能级数量，本文取 4.

3）时序复杂性组（反映序列演化的非线性特征）：

$$\boldsymbol{x}_{\mathrm{c}}=[C_{\mathrm{A}}]\in\boldsymbol{R}^{1}.\tag{16}$$

针对上述 3 组输入，分别采用独立的两层全连接网络（MLP）进行编码：

$$\begin{aligned}\boldsymbol{h}_{\mathrm{s}}&=\mathrm{MLP}_{s}(\boldsymbol{x}_{s})\in\boldsymbol{R}^{d_{\mathrm{s}}},\\ \boldsymbol{h}_{\mathrm{e}}&=\mathrm{MLP}_{e}(\boldsymbol{x}_{e})\in\boldsymbol{R}^{d_{\mathrm{e}}},\\ \boldsymbol{h}_{\mathrm{c}}&=\mathrm{MLP}_{c}(\boldsymbol{x}_{c})\in\boldsymbol{R}^{d_{\mathrm{c}}},\end{aligned}\tag{17}$$

式中：$\boldsymbol{h}_{\mathrm{s}},\boldsymbol{h}_{\mathrm{e}},\boldsymbol{h}_{\mathrm{c}}$分别为规模-应力组、活动强度-能量组、时序复杂性组的嵌入向量；$d_{\mathrm{s}},d_{\mathrm{e}},d_{\mathrm{c}}$分别为 3 组嵌入向量的维度；MLP(•)由“全连接＋非线性激活（ReLU）＋归一化＋Dropout”组成，以提升训练稳定性并抑制过拟合. 最终将 3 组嵌入拼接得到物理指标的统一表征：

$$\boldsymbol{z}_{\mathrm{phy}}=\mathrm{Concat}(\boldsymbol{h}_{\mathrm{s}},\boldsymbol{h}_{\mathrm{e}},\boldsymbol{h}_{\mathrm{c}})\in\boldsymbol{R}^{d_{\mathrm{phy}}},\tag{18}$$

$$d_{\mathrm{phy}}=d_{\mathrm{s}}+d_{\mathrm{e}}+d_{\mathrm{c}},\tag{19}$$

式中　Concat(·)为拼接操作. 采用分组编码具有三方面优势：其一，相比将全部数值特征直接输入单一全连接网络，分组结构更易学习组内指标的内在耦合关系，符合冲击孕育的物理过程；其二，可在指标维度不高的情况下有效控制参数规模与过拟合风险；其三，分组输出可与后续注意力与门控模块联动，实现对“规模-应力”“能量-强度”“复杂性”3 类信息的自适应加权融合. 本文物理指标分组与编码流程如图 8 所示.

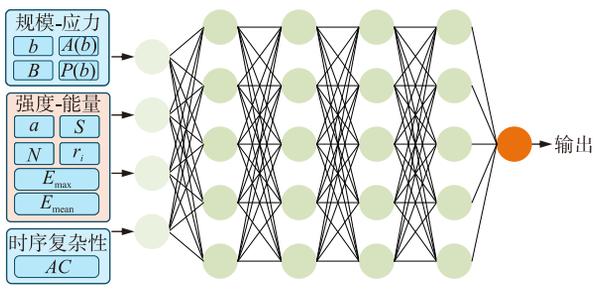

图 8　物理指标分组编码架构

Fig. 8　Grouped encoding architecture for physical indicators

2.2.3　时频及空间特征编码

1）STFT 频谱编码器

STFT 频谱图属于规则网格的时频能量分布图像，既包含较稳定的频带结构，又存在随孕育过程逐步演化的能量迁移特征，因此采用轻量化的 ResNet-18[31] 作为骨干，在此基础上，于 ResBlock-2 后引入 SE（Squeeze-and-Excitation）注意力模块[32]，对通道维进行自适应重标定，使网络能够从微震时序数据中学习“哪些频段更关键”，STFT 频谱编码器如图 9 所示.

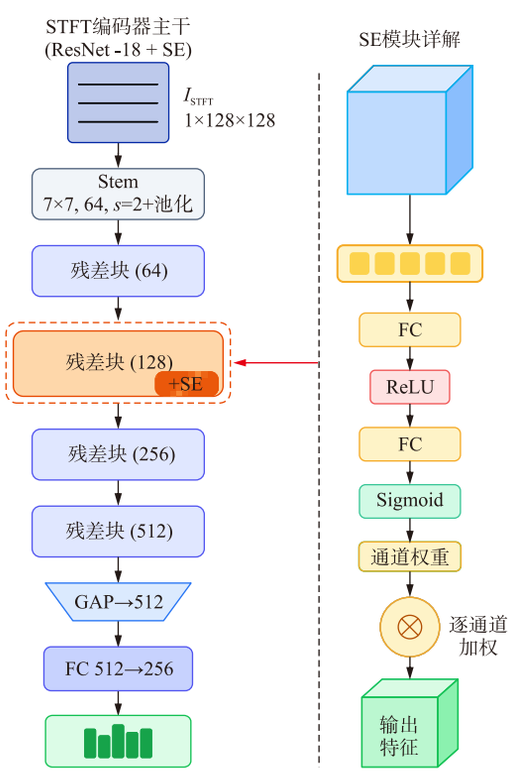

注：s为尺度；GAP 为全局平均池化；FC 为全连接层；ReLU 为修正线性单元激活函数.

图 9　STFT 编码器架构

Fig. 9　Architecture of STFT encoder

该设计与冲击地压孕育阶段的频域响应规律相一致：在应力集中与破裂加速阶段，谱图中常出现特定频带能量异常增强及频带迁移现象，SE模块可将这类频域选择性差异映射为通道权重提升，增强模型对关键时频结构的敏感性，进而提高对冲击危险的识别能力.

2) CWT编码器：2D-CNN

CWT矩阵包含多尺度破裂信息. 由于CWT已经在尺度维度进行了分解，无需过深的网络来提取层次化特征，采用较浅的4层2D-CNN即可有效编码如图10所示.

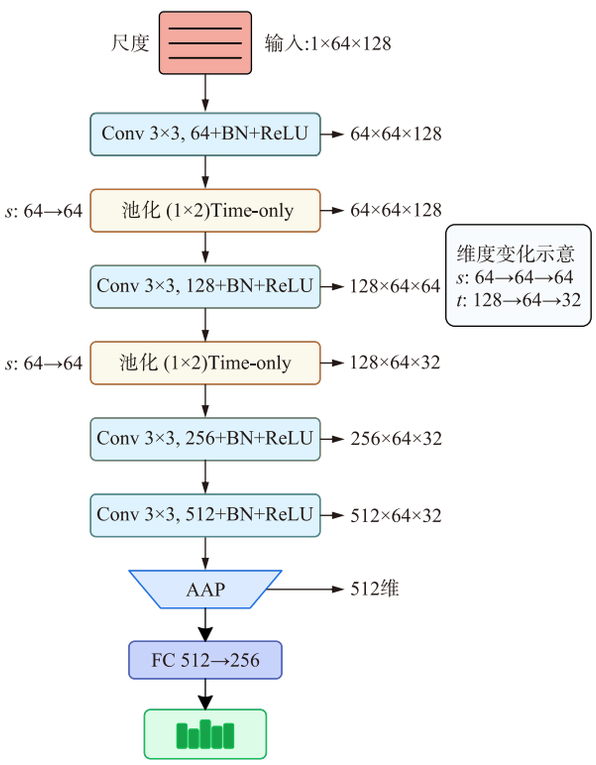

注：Conv为卷积层；BN为批归一化；AAP为自适应平均池化.

图10 CWT编码器架构

Fig. 10 Architecture of CWT encoder

3) HHT编码器

在冲击地压孕育过程中，岩体内部能量快速释放往往导致波形瞬时特性发生突变，其在HHT谱图上通常表现为瞬时频率曲线的急剧跳变、弯折及不规则纹理结构增强. 此类结构既非规则又具有显著的局部几何变形，采用常规卷积在固定采样网格上提取特征时，容易出现对齐误差与响应被“平滑化”的问题. 为增强对上述非规则时频结构的适配能力，在HHT谱图编码器中引入可变形卷积[33]：通过学习卷积核采样位置的偏移量$\Delta\rho$，使卷积能够在特征空间中自适应调整采样点，从而更好地对齐瞬时频率轨迹、突变边界与局部能量团簇等关键形态，实现对非平稳前兆的精细捕捉. 网络结构上，HHT分支与STFT分支保持一致的ResNet-18骨干以保证模型轻量与训练稳定性，并在更高层语义特征聚合阶段(ResBlock-3)嵌入可变形卷积层，使其在较大感受野下学习复杂的非线性时频结构与突变模式，进而提升对冲击前兆“突发型”特征的敏感性与危险识别能力，HHT编码器架构如图11所示.

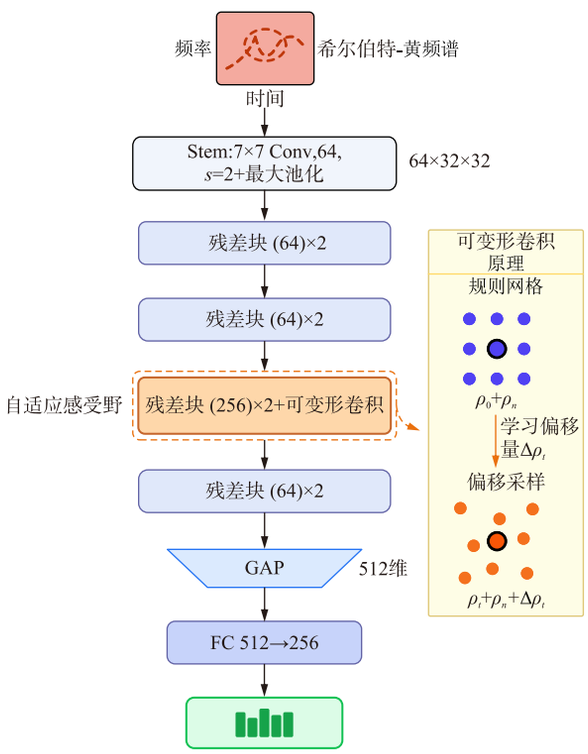

注：ρ_0为卷积核中心点位置；ρ_n为规则网格中第n个采样点相对于中心的固定偏移量.

图11 HHT编码器架构

Fig. 11 Architecture of HHT encoder

4) 三维微震能量云图编码器

微震云图属于无序点集数据，区别于时频图像的规则网格结构，其关键在于网络对点的输入顺序不敏感，即满足排列不变性. 为此，采用动态图卷积网络(DGCNN)[34]对三维微震能量云图进行编码：该方法在特征空间中动态构建K近邻图，并基于边卷积(EdgeConv)聚合邻域差分特征，从而在保持排列不变的同时刻画云图的局部几何结构. 云图的局部聚集与相对空间关系间接反映应力集中区与破裂活动组织形态；DGCNN通过K近邻动态图可识别聚集团簇、破裂走向等结构性特征. 随着多层EdgeConv的逐级堆叠，网络感受野由局部邻域扩展到更大范围，实现从局部聚集模式到全局空间格局的层次化表征，最终通过对称的池化算子获得窗口级点云的全局嵌入向量，用于

后续与时频模态及物理指标的融合预测，DGCNN 点云编码流程如图 12 所示.

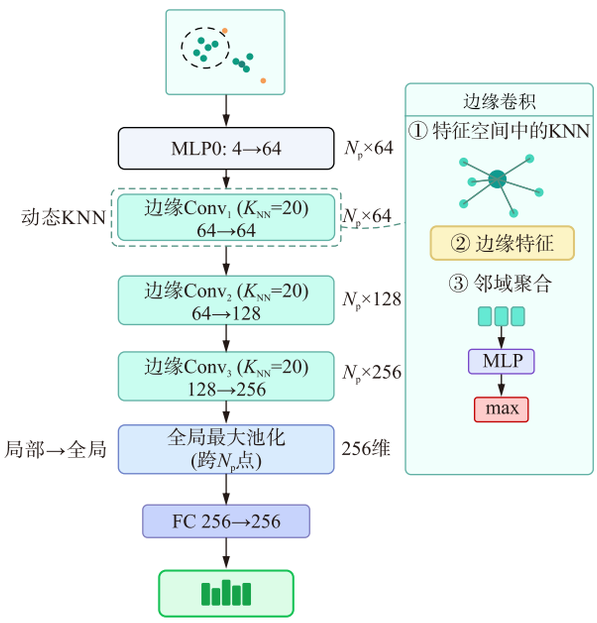

注：N_p为输入点云中的点数（即单个样本中参与编码的微震事件点数量）；K_{NN}为动态 KNN 构图时选取的近邻数.

图 12　DGCNN 点云编码流程

Fig. 12　Flowchart of DGCNN point cloud encoding

2.2.4　时空跨模态融合机制

不同于简单的特征拼接或早期融合，通过设计时空融合架构，将 5 个模态特征按照物理属性分为“时序”和“空间”，分别建模时间演化和空间分布，再通过交叉注意力实现互补融合.

1）时序流

时序流处理 3 个时频模态：STFT，HHT，CWT. 这 3 个模态都刻画了微震信号在时间-频率维度的演化，但侧重点不同（STFT 擅长平稳结构、HHT 擅长瞬态变化、CWT 擅长多尺度特征）. 时序流的目标是学习这 3 个模态之间的协同关系和互补模式.

将 3 个时频嵌入向量作为序列输入：

$$\boldsymbol{H}_{\text{temporal}}=[\boldsymbol{h}_{\text{STFT}};\boldsymbol{h}_{\text{HHT}};\boldsymbol{h}_{\text{CWT}}]\in\boldsymbol{R}^{(3\times d)},\tag{20}$$

式中：$\boldsymbol{H}_{\text{temporal}}$为时序模态嵌入矩阵；$\boldsymbol{h}_{\text{STFT}}$，$\boldsymbol{h}_{\text{HHT}}$，$\boldsymbol{h}_{\text{CWT}}$分别为 STFT，HHT，CWT 模态的嵌入向量；d为嵌入向量的维度.

使用 Transformer Encoder 建模序列内的自注意力，表达式为

$$\boldsymbol{H}'_{\text{temporal}}=\text{TransformerEncoder}(\boldsymbol{H}_{\text{temporal}})\in\boldsymbol{R}^{(3\in d)},\tag{21}$$

式中：$\boldsymbol{H}'_{\text{temporal}}$为经 Transformer 编码后的时序特征矩阵.

Transformer 的自注意力机制计算序列中每对模态之间的关联度：

$$\text{Attention}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V})=\text{softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\text{T}}}{\sqrt{d_K}}\right)\cdot\boldsymbol{V},\tag{22}$$

式中：$\boldsymbol{Q}$，$\boldsymbol{K}$，$\boldsymbol{V}$分别为查询、键、值矩阵；d_K为键的维度；softmax(·)为归一化指数函数；T 为矩阵转置操作. 自注意力能够捕捉模态间的长程依赖，例如 HHT 捕捉到的瞬态突变可能与 STFT 某个频段的能量变化相关联.

对序列输出进行平均池化（MeanPooling），得到时序流的融合特征：

$$\boldsymbol{h}_{\text{temporal}}=\text{MeanPooling}(\boldsymbol{H}'_{\text{temporal}})\in\boldsymbol{R}^{d}.\tag{23}$$

2）空间流

空间流融合三维微震能量云图 h_{3D} 和物理统计学指标. 三维微震能量云图直观规律，两者结合能够更全面地刻画空间特征.

通过 MLP 融合 2 类空间特征：

$$\boldsymbol{h}_{\text{spatial}}=\text{ReLU}(\boldsymbol{W}_s[h_{3D};h_{\text{phy}}]+\boldsymbol{b}_s)\in\boldsymbol{R}^{d},\tag{24}$$

式中：$\boldsymbol{h}_{\text{spatial}}$为融合 2 类空间特征向量；ReLU(·)为修正线性单元激活函数；$\boldsymbol{W}_s$为可学习的权重矩阵；$\boldsymbol{b}_s$为偏置向量.

3）跨流交叉注意力

时序流和空间流分别编码了时频演化和空间分布，但冲击地压的孕育过程是时空耦合的，某个空间区域的震源聚集可能对应该区域的时频异常. 为了建模这种跨流关联，引入双向交叉注意力.

从时序到空间的交叉注意力，表达式为

$$\boldsymbol{h}'_{\text{spatial}}=\boldsymbol{h}_{\text{spatial}}+\text{CrossAttn}(\boldsymbol{Q}=\boldsymbol{h}_{\text{spatial}},\boldsymbol{K}=\boldsymbol{h}_{\text{temporal}},\boldsymbol{V}=\boldsymbol{h}_{\text{temporal}}),\tag{25}$$

式中：$\boldsymbol{h}'_{\text{spatial}}$为经交叉注意力增强后的空间特征向量；CrossAttn 为交叉注意力函数；$\boldsymbol{h}_{\text{temporal}}$为时序流融合特征向量.

空间特征作为查询（$\boldsymbol{Q}$），时序特征作为键值（$\boldsymbol{K}$，$\boldsymbol{V}$），计算空间对时序的注意力权重. 从空间到时序的交叉注意力，表达式为

$$\boldsymbol{h}'_{\text{temporal}}=\boldsymbol{h}_{\text{temporal}}+\text{CrossAttn}(\boldsymbol{Q}=h_{\text{temporal}},\boldsymbol{K}=\boldsymbol{h}_{\text{spatial}},\boldsymbol{V}=\boldsymbol{h}_{\text{spatial}}).\tag{26}$$

交叉注意力的物理意义：如果某个空间区域的震源密度高 $\boldsymbol{h}_{\text{spatial}}$，且该区域对应的时频信号有异常 $\boldsymbol{h}_{\text{temporal}}$，则交叉注意力权重会升高，增强融合特征的判别能力. 这种机制实现了“时频异常与空间位置的关联”，符合冲击地压的物理规律.

4）自适应门控融合

将时序流和空间流输出拼接后，通过门控机制动态调整各部分的贡献权重：

$$\boldsymbol{u}=[\boldsymbol{h}_{\text{phy}};\ \boldsymbol{h}'_{\text{temporal}};\ \boldsymbol{h}'_{\text{spatial}}]\in\boldsymbol{R}^{3d},\tag{27}$$

$$\boldsymbol{g}=\text{Sigmoid}(\boldsymbol{W}_g\cdot\boldsymbol{u}+\boldsymbol{b}_g)\in(0,1)^{3d},\tag{28}$$

$$\boldsymbol{h}_{\text{fused}}=\boldsymbol{g}\odot\boldsymbol{u}\in\boldsymbol{R}^{3d},\tag{29}$$

式中：$\boldsymbol{u}$为物理指标、时序流与空间流特征拼接后的联合向量；$\boldsymbol{g}$为门控向量；Sigmoid(·)为Sigmoid激活函数；$\boldsymbol{W}_g$为门控层的可学习权重矩阵；$\boldsymbol{b}_g$为门控层的偏置向量；$\boldsymbol{h}_{\text{fused}}$为经门控加权后的最终融合特征向量；$\odot$为逐元素乘法(Hadmard积)．$\boldsymbol{g}$对每个特征维度进行加权，相当于“软性模态选择”．训练过程中，模型会自动学习哪些模态对当前样本更重要．例如，对于高危样本，能量相关特征可能获得更高权重；对于空间异常主导的样本，空间流权重会升高．这种自适应性提升了模型对不同冲击类型的泛化能力，同时增强了对噪声模态和模态缺失的鲁棒性．

3 工程试验

3.1 数据集建立及预处理

本研究以吉林省龙家堡典型冲击地压矿井615工作面掘进期间采集的微震监测数据为基础，构建冲击危险性预测数据集．

本研究监测周期为296 d，共采集微震事件5 908条．采用3 d固定窗口、1 d步长的滑动方式，共生成293个时间窗口样本，每个样本包含对应窗口内的全部微震事件及其衍生特征．根据前文所述的能级-频度拐点划分标准，对293个样本进行危险等级标注．标注依据为窗口内最高能级事件所属区间：Ⅰ级8个样本，Ⅱ级95个样本，Ⅲ级185个样本，Ⅳ级5个样本．样本分布呈现典型的长尾特征，高危样本占比较低，为预测模型训练带来严重的类别不平衡挑战．

数据预处理包括以下3个步骤：

1) 多模态特征提取与标准化

对每个时间窗口，分别提取5类模态特征．物理统计指标经Z-score标准化处理，消除量纲影响；STFT谱图通过短时傅里叶变换生成128×128分辨率的时频图像；HHT谱图经EMD分解获得5层IMF后进行Hilbert变换，输出128×128能量谱；CWT系数图采用Morlet小波在32个尺度上展开，得到32×128的多尺度表征；三维震源点云保留原始XYZ坐标及能量强度．所有图像特征归一化至[0,1]区间，以加速网络收敛．

2) 数据集划分

按时间顺序将293个滑动窗口样本划分为训练集、验证集和测试集3段连续且互不重叠的时间区间，其样本数量比例约为7.0∶1.5∶1.5(训练集205个样本、验证集44个样本、测试集44个样本)．考虑到滑动窗口之间存在重叠(窗口长度3 d、预测步长1 d)，为避免训练集与验证集、验证集与测试集在边界处共享原始微震事件而造成信息泄露，在两处集合边界分别设置embargo=2 d(即窗口长度−1)，并剔除跨边界重叠窗口，有效保证不同数据集在原始事件层面的相互独立性，从而确保评估过程严格符合“基于过去信息预测未来风险”的时序预警原则．

3) 类别不平衡处理

针对训练集的类别不平衡问题，采用2.1节所述的三层面综合策略．数据层面，对Ⅰ级和Ⅳ级样本在特征空间进行SMOTE过采样，扩增至Ⅱ级样本数量的80%，同时每个批次采用类别平衡采样，确保高危样本在每轮训练中的充分曝光；算法层面，引入Focal Loss($\gamma=2$)并设置类别权重为[4.0,1.5,3.0,5.0]，强化对困难样本的关注；评估层面，重点监控Ⅲ级和Ⅳ级的召回率，要求分别≥70%和≥100%，确保预测的准确性．

3.2 模型训练

3.2.1 训练过程

所提出的模型在配置了一个NVIDIA GTX 4090 GPU的桌面上执行．计算软件环境采用TensorFlow框架配置．物数融合及多模态驱动下的冲击地压前兆预测模型在不同训练迭代次数下训练集与测试集的损失值如图13所示．

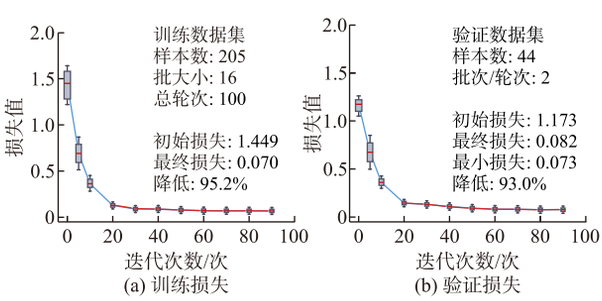

图13 MDL-RBP训练损失函数收敛曲线

Fig. 13 Training loss convergence curve of MDL-RBP

图13中给出了模型在训练集与验证集上的损失随迭代轮数(Epoch)的收敛过程．训练集共205个样本、批大小(batch size)为16、总迭代100轮，训练损失由初始的1.449快速下降，在前20轮内完成主要收敛，最终降至0.070，整体下降幅度为95.2%．验证集共44个样本，验证损失在前期迅速降低，由1.173降至0.082，最低达到0.073，整体下降幅度为93.0%；在约20轮后验证曲线进入平

台期并维持在较低水平，仅存在小幅波动．训练与验证损失的下降趋势一致、最终数值接近，未出现明显的“训练持续下降而验证显著回升”的发散现象，说明模型优化过程稳定，具备较好的泛化表现．基于上述过程训练得到模型验证集的预测结果如图 14 所示．

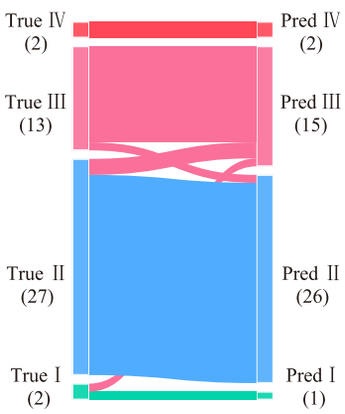

图 14　冲击危险等级预测结果桑基图

Fig. 14　Sankey diagram of rockburst hazard level prediction results

图 14 为冲击危险等级预测结果桑基图，左侧代表真实危险等级，右侧代表模型预测等级，括号中的数字代表样本数，连接两侧的流带宽度正比于样本数量，流带颜色与等级对应，交叉流带表示误分类．模型输出的等级分布与真实样本分布总体一致，主要流量集中在对角线方向（即同级流带），说明多数样本能够给出与真实等级匹配的判别．其中对于Ⅳ级危险而言，未出现Ⅳ级被降判为更低等级的情况，说明在最关键的高危识别上实现了零漏报，对应Ⅳ级的召回率为 100%．这体现了冲击地压危险预测中“本质安全”的原则，宁可适度提高警惕，也不允许高危状态被低估．

3.2.2　计算复杂度与推理效率分析

为评估模型在实际预警流程中的部署可行性，本文在相同软硬件环境下统计 MDL-RBP 的模型复杂度与推理速度，结果见表 5．由表 5 可以看出，多模态编码与跨模态融合带来一定额外计算开销，但该耗时统计的对象为“全验证集一次推理”，其量级远小于冲击地压预警系统按班/按日更新的业务周期，因而不会造成预警更新延迟或影响现场正常使用．与仅图像基线相比，MDL-RBP 在计算开销增加的同时获得了多源信息的联合表征能力，从而提升了整体预测性能，尤其在高危等级识别上具有更稳定的收益．

表 5　MDL-RBP 与基线模型的复杂度与推理效率对比

Table 5 Comparison of model complexity and inference efficiency between MDL-RBP and baseline models

模型	参数量/10^6	浮点运算量/10^9	网络推理耗时/s
MDL-RBP	27.77	33.07	242.4
仅图像 CNN	11.47	14.59	105.6

3.3　结果对比分析

3.3.1　模型分析结果

为验证多模态融合策略的有效性，对比了 5 类单模态、4 类组合模态及完整多模态模型．所有模型采用相同训练配置（学习率 5e-4，batch size 为 16，Adam 优化器），试验结果如表 6 所示：

表 6　单模态/多模态对比试验

Table 6　Single-modal/multi-modal comparative tests

对比项	P_M	R_M	F_{1M}	F_{1W}
多模态结果	0.941	0.847	0.869	0.909
STFT＋HHT＋CWT＋空间点云	0.829	0.828	0.786	0.890
单物理统计指标	0.749	0.800	0.763	0.855
HHT＋CWT＋空间点云	0.749	0.684	0.687	0.825
STFT＋HHT＋CWT	0.568	0.635	0.589	0.771
STFT＋HHT	0.664	0.897	0.725	0.807
单 STFT	0.654	0.782	0.687	0.778
单 HHT	0.745	0.647	0.669	0.754
单 CWT	0.597	0.647	0.612	0.759
三维微震能量云图	0.582	0.743	0.625	0.738

由表 6 可知，完整多模态模型在所有评估指标上均取得最优表现，准确率为 0.909，F_{1M} 为 0.869，相比最佳单模态（单 STFT，0.778）准确率提升 0.131．单模态性能方面，时频域模态（STFT 0.778、HHT0.754）优于空间域（三维微震能量云图 0.738），表明微震波形时频特征具有更强判别能力；单物理统计指标准确率为 0.855，说明地球物理与统计指标蕴含有效宏观信息．组合模态性能随模态信息融合总体提升：STFT＋HHT＋CWT 为 0.771，HHT＋CWT＋空间点云为 0.825，STFT＋HHT＋CWT＋空间点云为 0.890．完整多模态进一步融合时频域、空间域和物理统计指标 3 类信息，提升至 0.909，验证了多源异构信息深度融合的有效性．

图 15 为不同模态对比试验混淆矩阵（行代表真实标签，列代表预测标签，对角线数字代表预测正确的样本数，非对角数字代表预测错误的样本数）．Ⅰ，Ⅱ，Ⅲ，Ⅳ级对应表 1 中的危险分级．由

图 15 可知，完整多模态模型（图 15a）对角线值最大，高危Ⅳ级实现 100% 召回率（2/2），无漏报．对比分析表明：时频域与空间点云组合（图 15b）出现Ⅳ级漏报（1/2 误判为Ⅲ级）；纯时频域组合（图 15c）Ⅲ级识别下降（11/13），存在向Ⅰ级与Ⅱ级的混淆；空间点云单模态（图 15i）Ⅳ级同样存在漏报（1/2），且Ⅲ级有 1 个样本误判为Ⅳ级．物理统计学指标单模态（图 15j）对Ⅳ级保持 100% 召回（2/2），但Ⅲ级混淆较明显（8/13），主要误判为Ⅱ级．完整多模态通过动态整合各模态优势，召回率从单模态的 72.7% 提升至 90.9%，Ⅲ，Ⅳ级保持 100% 无漏报，充分证明了多模态深度学习的优越性．

	Ⅰ	Ⅱ	Ⅲ	Ⅳ
Ⅰ	1	0	1	0
Ⅱ	0	24	3	0
Ⅲ	0	0	13	0
Ⅳ	0	0	0	2

(a) 多模态

	Ⅰ	Ⅱ	Ⅲ	Ⅳ
Ⅰ	2	0	0	0
Ⅱ	2	24	1	0
Ⅲ	0	1	12	0
Ⅳ	0	0	1	1

(b) STFT+HHT+CWT+3D

	Ⅰ	Ⅱ	Ⅲ	Ⅳ
Ⅰ	1	0	1	0
Ⅱ	2	23	2	0
Ⅲ	1	1	11	0
Ⅳ	0	0	0	2

(c)STFT+HHT+CWT

	Ⅰ	Ⅱ	Ⅲ	Ⅳ
Ⅰ	1	0	1	0
Ⅱ	2	22	3	0
Ⅲ	0	1	12	0
Ⅳ	0	0	1	1

(d) STFT+HHT

	Ⅰ	Ⅱ	Ⅲ	Ⅳ
Ⅰ	2	0	0	0
Ⅱ	3	20	2	2
Ⅲ	0	2	11	0
Ⅳ	0	0	0	2

(e) HHT+CWT+3D

	Ⅰ	Ⅱ	Ⅲ	Ⅳ
Ⅰ	2	0	0	0
Ⅱ	2	19	5	1
Ⅲ	0	1	12	0
Ⅳ	0	0	1	1

(f) STFT

	Ⅰ	Ⅱ	Ⅲ	Ⅳ
Ⅰ	1	1	0	0
Ⅱ	2	19	3	3
Ⅲ	0	3	10	2
Ⅳ	0	0	0	2

(g) HHT

	Ⅰ	Ⅱ	Ⅲ	Ⅳ
Ⅰ	1	1	0	0
Ⅱ	0	20	6	1
Ⅲ	0	2	11	0
Ⅳ	0	0	1	1

(h) CWT

	Ⅰ	Ⅱ	Ⅲ	Ⅳ
Ⅰ	1	1	0	0
Ⅱ	1	20	5	1
Ⅲ	0	1	11	1
Ⅳ	0	0	1	1

(i) 3D

	Ⅰ	Ⅱ	Ⅲ	Ⅳ
Ⅰ	0	2	0	0
Ⅱ	0	25	2	0
Ⅲ	0	4	8	1
Ⅳ	0	0	0	2

(j) 物理统计学指标

图 15 不同模态对比试验混淆矩阵

Fig. 15 Confusion matrices for different modality comparison experiments

3.3.2 不同组分消融试验

为验证模型各关键模块的有效性，设计了消融试验，逐一移除核心组件并观察性能变化．试验结果如表 7 所示．混淆矩阵（行代表真实标签，列代表预测标签）如图 16 所示．

表 7 数据表明，各模块对模型性能均有贡献．完整多模态模型准确率为 0.909，F_{1M} 为 0.869．移除物理分组统计指标后，准确率降至 0.841，F_{1M} 降至 0.810，说明物理分组与统计指标为模型提供了有效的宏观约束信息并提升了整体判别性能．HHT 谱图编码器去除可变形卷积后，准确率为 0.864，F_{1M} 为 0.823；STFT 特征去除 SE 注意力模块后，准确率同为 0.864，但 F_{1M} 显著降至 0.693，表明 SE 注意力对提升 STFT 频带能量特征的判别性更为关键，而可变形卷积有助于捕获 HHT 瞬时频率的局部形变特征．去除时空融合模块后，准确率降至 0.841，F_{1M} 为 0.817，验证了时空融合机制对跨模态信息协同建模的必要性．将三维震源点编码器由 DGCNN 替换为普通 CNN 后，准确率降至 0.841，F_{1M} 降至 0.755，说明点云拓扑关系建模对提取震源空间聚集模式具有明显优势．模型性能提升源于多层次协同：时频域编码器（SE 注意力＋可变形卷积）精细提取局部特征，物理统计指标提供宏观约束，DGCNN 捕获空间拓扑，时空融合模块整合多源信息．各模块缺失均导致性能下降，验证了 MDL-RBP 架构设计的合理性．

表 7 不同组分消融对比试验

Table 7 Component ablation experiments

模型配置	准确率	P_M	R_M	F_{1M}	F_{1W}
多模态结果	0.909	0.941	0.847	0.869	0.909
移除物理分组统计指标	0.841	0.760	0.895	0.810	0.840
HHT 谱图编码器去除可变形卷积	0.864	0.782	0.905	0.823	0.862
STFT 特征去除 SE 注意力模块	0.864	0.695	0.693	0.693	0.853
去除时空融合	0.841	0.763	0.905	0.817	0.842
三维震源点采用正常 CNN	0.841	0.721	0.809	0.755	0.842

	I	II	III	IV
I	1	0	1	0
II	0	24	3	0
III	0	0	13	0
IV	0	0	0	2

(a) 多模态

	I	II	III	IV
I	2	0	0	0
II	1	24	2	0
III	0	3	9	1
IV	0	0	0	2

(b) 移除物理分组统计指标

	I	II	III	IV
I	2	0	0	0
II	1	23	2	1
III	0	3	10	0
IV	0	0	0	2

(c) STFT去除SE注意力

	I	II	III	IV
I	1	1	0	0
II	1	22	3	1
III	0	1	12	0
IV	0	0	0	2

(d) HHT去除可变形卷积

	I	II	III	IV
I	0	2	0	0
II	1	25	1	0
III	0	2	11	0
IV	0	0	0	2

(e) 3D点云采用正常CNN

	I	II	III	IV
I	2	0	0	0
II	1	23	3	0
III	0	1	12	0
IV	0	0	0	2

(f) 去除时空融合

图 16　消融试验混淆矩阵

Fig. 16　Confusion matrices for component ablation experiments

3.3.3　特征冗余性分析

为验证所构建指标体系中是否存在冗余特征，本文对11项数值特征进行共线性检验（其中各级能量占比 r_i 包括 r_1，r_2，r_3，r_4，为避免多重共线性去除 r_4，因此共计13个数值特征）. 考虑到各组特征分别输入独立的MLP子网络进行编码，组间不存在交叉运算，多重共线性问题仅在组内有意义. 因此，本文采用方差膨胀因子（*VIF*）对各组指标分别进行诊断，检验结果如图17所示.

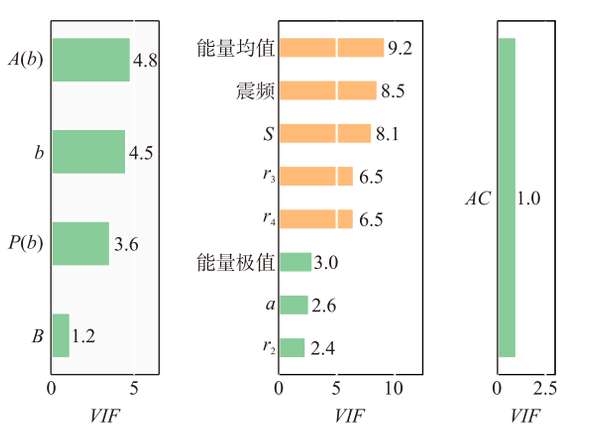

(a) 规模-应力　(b) 活动强度-能量　(c) 时序复杂性

图 17　组内 *VIF* 多重共线性诊断结果

Fig. 17　Intra-group *VIF* multicollinearity diagnosis results

图17展示了3个组别的组内 *VIF* 值诊断结果. 规模-应力组中，各指标 *VIF* 值均低于5，其中 $A(b)$ 最高为4.8，B 最低为1.2，表明该组内各指标间不存在显著多重共线性问题. 活动强度-能量组中，能量均值（9.2）、震频（8.5）及 S（8.1）的 *VIF* 值相对较高，r_3 与 r_4 均为6.5，但所有指标的 *VIF* 值均未超过10的阈值，属于较低程度共线性，在可接受范围之内；a（2.6）、能量极值（3.0）及 r_2（2.4）的 *VIF* 值较低. 时序复杂性组仅含 AC 值一项指标，*VIF* 值固定为1.0，不存在共线性问题.

综上，3个组别内所有指标的 *VIF* 值均低于10，未出现多重共线性. 分组MLP编码策略通过独立子网络对各组特征进行非线性映射，能够最大程度上消除部分复杂特征对结果的消极影响. 同时为验证不同特征的重要性，分别采用随机森林、SHAP这2种方式对特征权重进行分析，结果如图18所示.

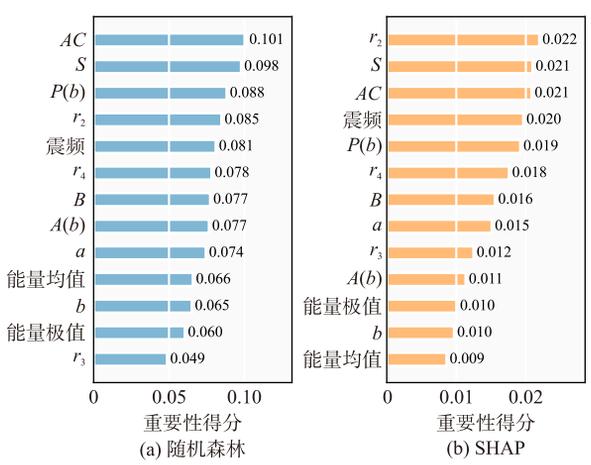

(a) 随机森林　(b) SHAP

图 18　基于随机森林与SHAP的特征重要性评估

Fig. 18　Feature importance evaluation based on random forest and SHAP

由图18可知，随机森林和SHAP这2种方法所得特征重要性排序整体一致. 其中，随机森林及SHAP特征重要性中能量均值、b 值、能量极值、r_3 权重相对较低，为验证上述低权重指标对模型性能的实际影响，本文将上述4项指标设定为冗余特征.

为进一步验证训练中各指标有效性，本文在保持模型结构与训练策略不变的条件下补充开展了指标有效性对比试验. 以MDL-RBP作为基准，在保持网络结构、训练策略与数据划分不变的前提下，分别移除“全部数值指标”、“地球物理7项”、“统计学4项”、“冗余特征”对测试集上的准确率、宏平均精确率（P_M）、宏平均召回率（R_M）、宏平均

F_1(F_{1M})和加权 F_1(F_{1W})进行评估,如表 8 所示.

表 8 特征冗余性机组试验设计与结果汇总

Table 8 Feature redundancy group experiment design and results summary

输入特征	准确率	P_M	R_M	F_{1M}	F_{1W}
多模态	0.909	0.941	0.847	0.869	0.909
移除物理分组	0.886	0.807	0.914	0.837	0.884
移除统计指标	0.864	0.844	0.905	0.865	0.861
移除物理分组及统计指标	0.841	0.762	0.895	0.811	0.842
去除冗余指标	0.886	0.816	0.838	0.822	0.889

由表 8 可知,完整多模态输入下模型准确率为 0.909,F_{1M} 为 0.869,各项指标均为最优. 移除物理分组统计指标后准确率下降至 0.886,F_{1M} 降至 0.837;移除统计指标后准确率降至 0.864,F_{1M} 为 0.865;同时移除 2 类指标后性能下降最为显著,准确率仅为 0.841,F_{1M} 降至 0.811. 仅去除冗余特征(能量均值、b 值、能量极值、r_3)后,模型准确率同样下降至 0.886,F_{1M} 降至 0.822,低于完整输入方案,一方面,各指标贡献相对均衡,低权重特征与高权重特征之间的重要性得分并未呈现数量级差异;另一方面,权重相对较低的指标在强非线性映射过程中可能与其他特征形成隐性交互关系,其对模型预测精度的潜在贡献难以通过线性重要性度量方式充分体现,贸然剔除此类指标存在损失有效信息的风险.

3.3.4 类别不平衡处理必要性验证试验

为验证所提出“数据层-算法层-评估层”三位一体不平衡处理策略的有效性,设计对比试验逐层添加处理模块. 试验结果如表 9 所示,混淆矩阵(行代表真实标签,列代表预测标签)如图 19 所示.

表 9 类别不平衡处理对比试验

Table 9 Class imbalance handling comparison experiments

策略	准确率	P_M	R_M	F_{1M}	F_{1W}
多模态	0.909	0.941	0.847	0.869	0.909
评估+算法	0.864	0.916	0.703	0.764	0.863
评估+数据	0.864	0.916	0.703	0.764	0.863
评估(基线)	0.818	0.891	0.790	0.816	0.822

表 9 表明,数据层与算法层策略均会显著影响类别不平衡条件下的识别表现. 基线模型(仅采用评估层策略,图 19a)准确率为 0.818,F_{1M} 为 0.816. 加入数据层或算法层处理后(评估+数据、评估+算法),模型准确率均提升至 0.864,且Ⅳ级召回率为 50%(1/2),说明单一层面的不平衡处理在提高总体准确率的同时,可能引入高危类别的漏报风险. 数据层与算法层联合应用的完整多模态模型(图 19d)性能进一步提升:准确率达到 0.909,同时Ⅳ级实现 100% 召回(2/2),表明“数据层-算法层-评估层”协同策略能够兼顾总体精度与高危漏报控制.

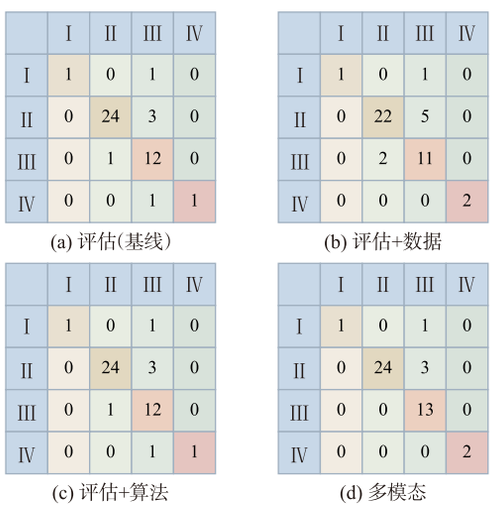

图 19 类别不平衡处理对比试验混淆矩阵

Fig. 19 Confusion matrices for class imbalance handling experiments

3.3.5 不同时间窗口预测效果分析

为验证本文所提模型在不同预测时间尺度下的泛化能力,本节设计了多时间窗口预测试验. 试验选取未来 3,7,15,30 d 这 4 个时间窗口,分别训练并评估模型的预测性能. 不同时间窗口对应的预测任务具有不同的难度特征:短期预测(3~7 d)由于时间跨度相对较小,地震活动的前兆特征与目标事件之间的关联性较强;而中长期预测(15~30 d)则面临更大的不确定性,需要模型具备捕捉长程依赖关系的能力.

表 10 详细列出了不同预测时间窗口的分类性能指标. 试验结果表明,模型在未来 3 d 预测任务中取得最优性能,准确率为 0.91,F_{1M} 为 0.93. 随着预测时间窗口延长,准确率整体呈下降趋势,7,15,30 d 窗口准确率分别为 0.91,0.89,0.86;F_{1M} 在 7 和 15 d 窗口分别为 0.84 和 0.70,并在 30 d 窗口回升至 0.90. 总体而言,即使在最长的 30 d 预测窗口下,模型仍保持 0.86 以上的准确率,体现出一定的时序泛化能力.

表 10　不同时间窗口预测性能对比

Table 10　Prediction performance comparison across different time windows

时间窗/d	准确率	P_M	R_M	F_{1M}	样本数/个			
					Ⅰ	Ⅱ	Ⅲ	Ⅳ
3	0.91	0.921	0.938	0.927	2	12	24	6
7	0.91	0.795	0.967	0.836	2	1	30	11
15	0.89	0.691	0.701	0.696	2	1	22	19
30	0.86	0.885	0.956	0.901	2	1	7	34

图 20 展示了模型在 4 个时间窗口下的混淆矩阵(行代表真实标签,列代表预测标签). 从图 20 可以看到,随着预测时间窗口的增加,各危险等级的样本分布呈现明显变化趋势:Ⅰ级和Ⅱ级(低危)样本数量显著减少,而Ⅲ级和Ⅳ级(高危)样本比例逐渐上升. 这种变化符合地震活动的累积效应规律,即在更长的时间窗口内,发生较高等级地震事件的概率增加. 在未来 3 和 7 d 的预测任务中,模型对Ⅳ级高危事件的识别准确率均达到 100%,表明本文方法对短期高危事件具有优异的检测能力.

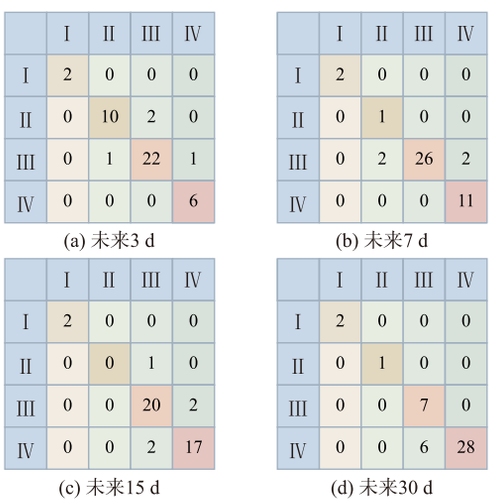

图 20　不同时间窗口预测混淆矩阵

Fig. 20　Confusion matrices for different time window predictions

从各等级样本的分类情况来看,模型对主导类别(Ⅲ级)的识别能力较为稳定. 于高危等级(Ⅳ级),模型表现出优异的检测能力:在 3 和 7 d 窗口下,Ⅳ级召回率均达到 100%;在 15 和 30 d 窗口下,尽管Ⅳ级样本数量显著增加(分别为 19 和 34 个),但模型仍能保持较高的召回率.

综上所述,本文提出的多模态融合模型在不同时间窗口预测任务中均展现出稳健的性能表现. 短期预测(3～7 d)不仅精度高,而且对高危事件的检测准确率达到 100%,适用于紧急场景;中长期预测(15～30 d)虽然面临更大挑战,但仍能维持可接受的准确率水平,可为中长期风险评估提供参考依据. 这种多尺度预测能力使得该模型能够满足不同应用场景的需求,具有较强的实用价值.

3.4　讨　论

3.4.1　不同滑动窗口长度对预测结果的影响

冲击地压前兆信息的时间尺度具有多尺度特征,从秒级的能量突增到日-周尺度的活动性演化均可能与危险性相关. 本文在 3.1 节采用长度为 3 d、步长为 1 d 的滑动窗口进行特征构建,一方面,掘进阶段微震事件具有间歇性与随机性,若窗口过短(如 1 d),将导致窗口内有效事件数偏少,进而使最大能量、频度统计及 b 值等统计量估计不稳定、方差增大,模型对偶然扰动更敏感;另一方面,若窗口过长(如 7 d),时序特征将被过度平滑,短期异常被稀释,同时标签划分中“窗口内最大能量”对风险等级的主导效应会使长窗口更容易混入高能事件,增加类别混淆并降低对近期风险的定位能力. 基于上述考虑,3 d 窗口在“统计稳定性”和“前兆敏感性”之间提供了折中.

为验证窗口长度对预测效果的影响,本文在保持模型结构、训练策略、预测任务(如未来 7 d 危险等级)与训练/验证/测试划分不变的前提下,仅改变滑动窗口长度 $L\in\{1\,\mathrm{d},\,3\,\mathrm{d},7\,\mathrm{d}\}$ 进行对比试验如表 11 所示

表 11　不同滑动窗口长度对预测性能的影响

Table 11　Effects of different sliding window lengths on prediction performance

窗口长度/d	准确率	P_M	R_M	F_{1M}	F_{1W}
3	0.909	0.941	0.847	0.869	0.909
7	0.864	0.921	0.829	0.844	0.867
1	0.773	0.560	0.636	0.589	0.762

由表 11 可知,3 d 窗口整体性能最优,1 和 7 d 窗口均出现不同程度下降:1 d 窗口由于特征统计不稳定导致 F_{1M} 下降且高危类别召回率波动更大;7 d 窗口则因信息稀释与类别混加剧,使 F_{1M} 与高危识别能力下降. 上述结果说明,在本文掘进阶段监测数据条件下,3 d 窗口能够更有效地刻画冲击前兆特征,从而获得更稳定且更具工程意义的预测效果.

3.4.2 不同工作面泛化性验证

为验证所建立模型的泛化性能，本文引入吉林省龙家堡矿 513 回采工作面数据，构造跨工作面检验场景，以验证模型对未知矿井及工作面的泛化能力．首先按照 1.1 节所述能量-频度拐点法，基于 513 工作面微震事件统计结果重新确定冲击地压危险分级，结果如图 21 所示．

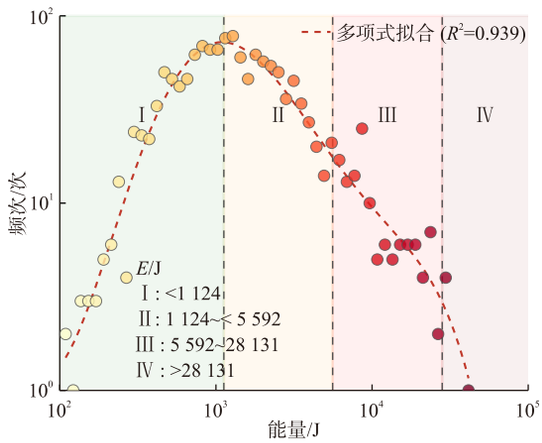

图 21 513 工作面微震能量-频度曲线

Fig. 21 Microseismic energy-frequency curve of the 513 working face

确定 513 工作面击地压危险分级标准后，计算其测试集性能如表 12 所示．工作面测试集混淆矩阵（行代表真实标签，列代表预测标签）如图 22 所示．

表 12 跨工作面泛化测试结果

Table 12 Cross-working-face generalization test results

工作面	准确率	P_M	R_M	F_{1M}	F_{1W}
513	0.935	0.897	0.96	0.92	0.938

	Ⅰ	Ⅱ	Ⅲ	Ⅳ
Ⅰ	4	0	0	0
Ⅱ	0	11	1	0
Ⅲ	0	0	12	1
Ⅳ	0	0	0	2

图 22 513 工作面测试集混淆矩阵

Fig. 22 Confusion matrix of the test set for the 513 working face

结果表明，模型在准实时回放与跨工作面测试中仍能保持较高的整体性能，并能在多数情况下维持对高危类别的有效识别，说明所提出的多模态融合与时空建模策略具有一定跨时间、跨空间的泛化能力，可满足冲击地压前兆风险预警的应用需求．

4 结 论

1）构建了融合空间域、时频域和物理指标域的多模态冲击危险性数据集．通过 STFT，HHT，CWT 这 3 种时频分析方法提取微震监测信号的多尺度时频特征，结合物理指标，实现了对冲击前兆信息从时频演化到空间分布的全方位信息捕获，为多模态深度学习提供了数据基础．

2）设计了“数据层-算法层-评估层”三位一体的类别不平衡处理策略．数据层采用特征空间 SMOTE 过采样与类别平衡批次采样协同增强少数类样本；算法层引入 Focal Loss 聚焦困难样本；评估层以宏平均 F_1 为核心指标确保少数类性能．3 层策略协同使Ⅳ级召回率提升至 100%，消除高危漏报．

3）提出了多模态时空融合架构 MDL-RBP，实现了多模态特征的深度交互．将 5 个模态按物理属性分为“时序流”（STFT，HHT，CWT）和“空间流”（微震分布、物理指标），时序流通过 Transformer 自注意力机制学习 3 种时频表征的协同互补关系，空间流融合震源分布与宏观指标；引入双向交叉注意力建模时空耦合关联，使时频异常与空间位置有效关联．消融试验表明，移除时空融合模块后准确率下降 6 个百分点，验证了该机制对跨模态信息整合的关键作用．

4）现场应用验证了模型的有效性和实用性．MDL-RBP 模型在吉林省龙家堡煤矿 615 工作面的冲击危险性判识准确率达 90.9%，较最优单模态（STFT，77.8%）提升 13.1%；强冲击危险（Ⅳ级）预测成功率达 100%，实现零漏报；在 3～30 d 多时间窗口预测中准确率均保持在 86% 以上，同时在未知工作面取得了较高的精度，具备多尺度预测能力，为煤矿冲击地压防治提供了技术支撑．

参考文献：

[1] 程香港，乔 伟，窦林名，等．宁正-彬长煤矿区地应力场分布规律及其复杂性评价方法[J]．中国矿业大学学报，2026，55(2)：499-513.
CHENG Xianggang，QIAO Wei，DOU Linming，et al. Distribution characteristics and complexity evaluation method of in-situ stress field in the Ningzheng-Binchang coal mining area distribution law of in-situ

stress field and complexity evaluation method in Ningzheng-Binchang coal mining area[J]. Journal of China University of Mining & Technology, 2026, 55(2): 499-513.

[2] 曹安业,梁颖欣,杨　旭,等.人工智能赋能下的冲击地压监测预警方法研究进展[J/OL].中国矿业大学学报, 1-22[2026-03-16]. https://link.cnki.net/urlid/32.1152.td.20260313.1620.003.
CAO Anye, LIANG Yingxin, YANG Xu, et al. Research progress on microseismic early warning methods of rockburst in coal mines empowered by artificial intelligence[J/OL]. Journal of China University of Mining & Technology, 1-22[2026-03-16]. https://link.cnki.net/urlid/32.1152.td.20260313.1620.003.

[3] 潘一山,宋义敏,刘　军.我国煤矿冲击地压防治的格局、变局和新局[J].岩石力学与工程学报,2023,42(9):2081-2095.
PAN Yishan, SONG Yimin, LIU Jun. Pattern, change and new situation of coal mine rockburst prevention and control in China[J]. Chinese Journal of Rock Mechanics and Engineering, 2023, 42(9): 2081-2095.

[4] 崔　峰,何仕凤,罗　钟,等.基于贝叶斯优化算法与机器学习相融合的冲击地压多元指标预警研究[J].煤炭学报,2025,50(增1):297-313.
CUI Feng, HE Shifeng, LUO Zhong, et al. Research on multi-index early warning of rock burst based on bayesian optimization algorithm and machine learning[J]. Journal of China Coal Society, 2025, 50(Sup 1): 297-313.

[5] 曹安业,王常彬,杨　旭,等.微震定位精度影响下采场裂隙表征与冲击地压预警[J].煤炭科学技术,2024,52(2):1-9.
CAO Anye, WANG Changbin, YANG Xu, et al. Fractures characterization in mining field considering seismic location accuracy and its application on prewarning coal burst hazards[J]. Coal Science and Technology, 2024, 52(2): 1-9.

[6] 朱广安,王　铱,徐自豪.基于声发射信号处理的含水煤体当量钻屑量反演试验研究[J].岩石力学与工程学报, 2025, 44(8): 2040-2054.
ZHU Guang'an, WANG Yi, XU Zihao, et al. Inversion of equivalent drill cuttings volume of water-bearing coal mass basedon acoustic emission signal processing in mining engineering[J]. Chinese Journal of Rock Mechanics and Engineering, 2025, 44(8): 2040-2054.

[7] CHENG X G, QIAO W, HE H. Study on deep learning methods for coal burst risk prediction based on mining-induced seismicity quantification[J]. Geomechanics and Geophysics for Geo-Energy and Geo-Resources, 2023, 9(1): 145.

[8] 朱斯陶,姜福兴,刘金海,等.复合厚煤层巷道掘进冲击地压机制及监测预警技术[J].煤炭学报, 2020, 45(5):1659-1670
ZHU Sitao, JIANG Fuxing, LIU Jinhai, et al. Mechanism and monitoring and early warning technology of rock burst inthe heading face of compound thick coal seam[J]. Journal of China Coal Society, 2020, 45(5): 1659-1670.

[9] BASNET P M S, MAHTAB S, JIN A B, et al. A comprehensive review of intelligent machine learning based predicting methods in long-term and short-term rock burst prediction[J]. Tunnelling and Underground Space Technology, 2023, 142: 105434.

[10] QIU Y G, ZHOU J. Short-term rockburst prediction in underground project: Insights from an explainable and interpretable ensemble learning model[J]. Acta Geotechnica, 2023, 18(12): 6655-6685.

[11] QIU Y G, ZHOU J. Novel rockburst prediction criterion with enhanced explainability employing CatBoost and nature-inspired metaheuristic technique[J]. Underground Space, 2024, 19: 101-118.

[12] LIU H M, XU F Y, LIU B J, et al. Time-series prediction method for risk level of rockburst disaster based on CNN-LSTM[J]. Journal of Central South University (Science and Technology), 2021, 52(3): 659-670.

[13] ZHANG S C, MU C M, FENG X H, et al. Intelligent dynamic warning method of rockburst risk and level based on recurrent neural network[J]. Rock Mechanics and Rock Engineering, 2024, 57(5): 3509-3529.

[14] 王绍琛,王　超,李士栋,等.基于自适应集成学习的煤矿微震时序预测模型[J].采矿与岩层控制工程学报, 2025, 7(4): 247-262.
WANG Shaochen, WANG Chao, LI Shidong, et al. Time series prediction model of microseismicity in coal mine based on adaptive ensemble learning[J]. Journal of Mining and Strata Control Engineering, 2025, 7(4): 247-262.

[15] 王爱文,李　超,潘一山,等.冲击危险区域多元地球物理指标动态辨识方法及其应用[J].煤炭学报, 2024, 49(6): 2573-2588.
WANG Aiwen, LI Chao, PAN Yishan, et al. Dynamic identification method for rockburst hazard areas based on multivariate geophysical indicators and its application[J]. Journal of China Coal Society,

2024, 49(6): 2573-2588.

[16] CAO A Y, LIU Y Q, YANG X, et al. FDNet: Knowledge and data fusion-driven deep neural network for coal burst prediction[J]. Sensors, 2022, 22(8): 3088.

[17] LIANG R Y, ZHANG C G, HUANG C R, et al. Multimodal data fusion for geo-hazard prediction in underground mining operation[J]. Computers & Industrial Engineering, 2024, 193: 110268.

[18] BAI J, WANG S, XU Q, et al. Adaptive threshold multimodal fusion for rock prediction in complex geological environments while drilling[J]. Bulletin of Engineering Geology and the Environment, 2025, 84(4): 178.

[19] 崔 峰,宗 程,来兴平,等.急倾斜巨厚煤层掘进巷道冲击危险时序及等级智能预测[J].煤炭学报, 2025, 50(2): 845-861.
CUI Feng, ZONG Cheng, LAI Xingping, et al. Intelligent prediction of time series and grade of rock burst in steeply inclined ultra-thick coal seam excavation roadway[J]. Journal of China Coal Society, 2025, 50(2): 845-861.

[20] 王书文.矿井微震信号b值计算样本及参数选取研究[J].煤炭科学技术, 2016, 44(12): 51-56.
WANG Shuwen. Study on calculation sample and parameter selection of mine microseism signal b value[J]. Coal Science and Technology, 2016, 44(12): 51-56

[21] GUTENBERG B, RICHER C F. Frequency of earthquakes in California[J]. Bulletin of the Seismological Society of America, 1944, 34(4): 185-188.

[22] 吴佳翼,曹学锋.地震活动性的定量化问题[J].地震, 1983(6): 13-16.
WU Jiayi, CAO Xuefeng. On the quantification of seismicity[J]. Earthquake, 1983(6): 13-16.

[23] 卫鹏飞.华北缺震曲线[J].地震研究, 1980(4): 144-148.
WEI Pengfei. Seismic gap curve in North China[J]. Journal of Seismological Research, 1980(4): 144-148.

[24] 崔 峰,张随林,来兴平,等.急倾斜巨厚煤层矿震诱冲机制及时-空特征[J].煤炭学报, 2023, 48(增2): 449-463.
CUI Feng, ZHANG Suilin, LAI Xingping, et al. Mechanism of rock burst induced by mine earthquake and the time-space characteristics of in steep and extremely thick coal seam[J]. Journal of China Coal Society, 2023, 48(Sup 2): 449-463.

[25] 谷继成,魏富胜.论地震活动性的定量化地震活动度[J].中国地震, 1987, 3(增1):14-24.
GU Jicheng, WEI Fusheng. On the quantification of seismicity: Seismic activity[J]. Earthquake Research in China, 1987, 3(Sup 1): 14-24.

[26] CHEN S H, ZHANG B H, PENG C B, et al. Double dominant frequency of microseismic signal and micro-fracture mechanism of granite rockmass[J]. Geomechanics and Geophysics for Geo-Energy and Geo-Resources, 2025, 11(1): 115.

[27] LIANG Z Z, XUE R X, XU N W, et al. Characterizing rockbursts and analysis on frequency-spectrum evolutionary law of rockburst precursor based on microseismic monitoring[J]. Tunnelling and Underground Space Technology, 2020, 105: 103564.

[28] MA T H, TANG C A, TANG S B, et al. Rockburst mechanism and prediction based on microseismic monitoring[J]. International Journal of Rock Mechanics and Mining Sciences, 2018, 110: 177-188.

[29] XU H C, LAI X P, ZHANG S, et al. Precursor information recognition of rockburst in the coal-rock mass of meizoseismal area based on multiplex microseismic information fusion and its application: A case study of Wudong coal mine[J]. Lithosphere, 2022, 2022(11): 7349759.

[30] ZHOU J, LI X B, MITRI H S. Strength of stacking technique of ensemble learning in rockburst prediction with imbalanced data: Comparison of eight single and ensemble models[J]. Natural Resources Research, 2021, 30(2): 1795-1815.

[31] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016: 770-778.

[32] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2018: 7132-7141.

[33] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks[C]//Proceedings of the IEEE International Conference on Computer Vision. IEEE, 2017: 764-773.

[34] WANG Y, SUN Y B, LIU Z W, et al. Dynamic graph CNN for learning on point clouds[J]. ACM Transactions on Graphics, 2019, 38(5): 146.

(责任编辑 沈 菊 宋 爽)