马莉，赵明，任雪，郭攀，2026. 基于深度学习震相拾取与多算法定位的大强矿区微震目录构建及误差分析. 地震学报，**48**(6)：1−16. doi：10.11939/jass.20260097.
Ma L，Zhao M，Ren X，Guo P，2026. Construction and Error Analysis of Microseismic Catalog in Daqiang Mining Area Using Deep-Learning-Based Phase Picking and Multi-Algorithm Localization. *Acta Seismologica Sinica*，**48**(6)：1−16. doi：10.11939/jass.20260097.

基于深度学习震相拾取与多算法定位的大强矿区微震目录构建及误差分析*

马 莉[1,2)] 赵 明[1,2),†] 任 雪[1,2)] 郭 攀[1,2)]

1）中国沈阳 110034 辽宁省地震局
2）中国北京 100081 中国地震局地球物理研究所

摘要 矿区微震监测是提高采矿生产安全性和及时发出灾害预警的重要技术手段之一. 随着采矿区地震监测数据规模不断增加，传统人工震相识别与目录编制方法已难以满足高时效、高精度和连续化监测需求. 为提高矿区微震目录构建效率与定位可靠性，基于辽宁大强矿区 2023 年 7 月 10 日至 8 月 11 日 64 套短周期密集台阵连续记录，采用 DiTingPicker 深度学习模型进行 P 波和 S 波震相自动拾取，并结合 REAL 震相关联、HypoInverse 绝对定位和 HypoDD 双差相对定位构建微震目录. 结果表明，该流程共识别并定位 255 个微震事件；目录完备性震级约为 M_L1.0，b 值约为 0.90. 微震事件集中分布于矿区开采工作面及已知断层附近，与浅部采掘扰动层位对应良好. S 波拾取质量和短周期地震仪授时误差均会造成震源深度系统性偏移，是制约浅源微震定位精度的重要因素. 研究证实，深度学习能够显著提升矿区微震目录构建的自动化水平和处理效率，实际应用中应重视短周期仪器授时校验，进一步提高矿区微震定位质量.

关键词 深度学习 矿区微震 地震目录 双差定位
doi：10.11939/jass.20260097 **中图分类号**：P315 **文献标识码**：A

Construction and Error Analysis of Microseismic Catalog in Daqiang Mining Area Using Deep-Learning-Based Phase Picking and Multi-Algorithm Localization

Ma Li[1,2)] Zhao Ming[1,2),†] Ren Xue[1,2)] Guo Pan[1,2)]

1) *Liaoning Earthquake Agency*, *Shenyang* 110034, *China*
2) *Institute of Geophysics*, *China Earthquake Administration*, *Beijing* 100081, *China*

Abstract: Microseismic monitoring in mining areas is one of the key technical approaches to enhance mining safety and issue timely hazard early warnings. With the rapid growth of the seismic monitoring data from mining areas, the traditional manual seismic phase identification

* **基金项目** 国家自然科学基金-联合基金项目（U2239205）和国家重点研发计划（2024YFC3012800）共同资助. .
收稿日期 2026-06-24 收到初稿，2026-08-20 决定采用修改稿.
作者简介 马莉，硕士，高级工程师，主要从事地震监测工作，e-mail：rongcuoxue@163.com；†通信作者：赵明，博士，副研究员，主要从事人工智能地震数据处理工作，e-mail：mzhao@cea-igp.ac.cn

and catalog compilation methods can barely meet the demands of time-sensitive, high-precision and continuous monitoring. Our study area is the Daqiang Coal Mine, which sits in Zhangqiang Town, Kangping County, Shenyang, Liaoning. Since 2022, Liaoning Earthquake Agency and the mine's company have been working together on building a dedicated seismic network, tweaking the station layout, and doing detailed analyses of microseismic activity. To speed up catalog construction and get more reliable locations, we used continuous recordings from 64 sets of short-period dense array deployed at the Daqiang Mining Area in Liaoning Province as the research dataset, covering the period from July 10 to August 11, 2023. We ran these data through an automated workflow that uses AI for phase picking and location, and then we looked at the locations, waveform features, and station residuals together. For phase picking, we used the DiTingPicker deep learning model to pick P-wave and S-wave seismic phases automatically, and we combined REAL for association, HypoInverse for absolute locations, and HypoDD for double-difference relative relocation to build our catalog. For most stations, the P-wave arrivals on the vertical component are fairly clear, and the P-wave picks are generally consistent, which suggests that the deep learning model has good detection capability for this type of microseismic event. The S-wave amplitudes, however, are weak and the onsets are not obvious, so the S-wave picks come with higher uncertainty than the P picks.

The results show that the workflow picked out and located 255 microseismic events. The processing time dropped from about a month with manual work to roughly two days, which is about 15 times more efficient. The catalog's completeness magnitude is around $M_{\mathrm{L}}1.0$, and the b-value is about 0.90. In terms of space, the events are mostly clustered around the mining face and near known faults, which matches pretty well with the shallow disturbance from mining. More detailed examination reveals that both S-wave picking quality and timing errors from the short-period instruments can affect the locations of shallow events, sometimes shifting the depths systematically. A few stations showed systematic mismatches between the theoretical arrival times and the real waveform features, suggesting possible overall timing offsets. But these anomalies are not necessarily caused by the phase-picking model itself; they could also be related to station timing errors, channel delays, time calibration issues in the data headers, or the operating status of the instruments. In this study, we tested how well deep learning works for detecting microseismic events and picking phases in a mining setting, built a catalog for the Daqiang mining area, and looked at its spatial temporal distribution and magnitude-frequency patterns. We also discuss how S-wave arrival quality, phase weighting choices, and timing errors affect the location results for shallow events. Our findings should be useful for automated monitoring, catalog quality control, and identifying dynamic hazard risks in mines. Looking at the locations overall, the events tend to cluster on the map mainly within and around the mining area, showing pretty clear spatial clustering that seems to relate to both mining disturbances and local structures. Events are mostly located near the mine boundaries and within the array coverage, suggesting that the dense array has good monitoring capability for microseismicity in this area. In terms of magnitude distribution, small events dominate, while relatively few larger ones occur – this matches the general pattern of mining-induced microseismicity. AI-based methods have significantly improved the efficiency of event detection and phase picking, providing important technical support for rapid catalog construction. However, in the complex observational environment of a mine, automated results still need to be combined with waveform verification, station residual analysis, and location sensitivity testing. Especially for shal-

low microseismic events, weak S-wave development and station timing errors can have a notable effect on the estimated focal depths.

In summary, AI-based methods can significantly enhance the automation and efficiency of microseismic catalog construction in mining areas. In practice, however, particular attention should be paid to the timing accuracy of short-period instruments. DiTingPicker demonstrates good applicability to the Daqiang dataset, performing well on the dense array data. The observed spatial clustering, together with the magnitude-frequency characteristics (M_L 1.0, b≈0.90), suggests that microseismicity is associated with both mining disturbances and local structural conditions. Shallow events tend to be scattered, likely related to near-surface activities, while deeper events exhibit linear trends that may reflect buried faults or stress concentration boundaries. Timing errors and unstable S-wave picking are identified as two key factors affecting the reliability of shallow event locations in this study.

Key words: deep learning; mining microseism; earthquake catalog; double-difference location

引言

矿区微震活动可以反映采掘活动、围岩破裂与采矿区应力调整过程，其时空分布特征对识别潜在动力灾害风险、评价采场稳定性和优化矿山安全生产具有重要意义. 随着矿区密集台阵和连续波形观测的广泛应用，微震监测数据量迅速增加，传统依赖人工浏览波形和手动拾取震相的处理方式已难以满足高时效、高一致性和精细化的监测需求. 机器学习已成为固体地球科学中处理大规模观测资料、提取信号特征和辅助认识物理过程的重要研究工具（Bergen *et al*, 2019）. 将深度学习与物理过程认识相结合，也是地球系统科学中开展数据分析和解释的重要方向（Reichstein *et al*, 2019）. 除事件检测与震相拾取外，机器学习还被用于地震震级估计，拓展了波形自动化分析的应用范围（Mousavi, Beroza, 2020）. 基于Transformer的模型进一步探索了利用实时地震波形估计震级和震源位置的可能性（Münchmeyer *et al*, 2021）. 人工智能方法，特别是深度学习震相拾取与自动化目录构建技术，为矿区微震活动性分析提供了新的技术途径. 结合卷积神经网络与循环神经网络的混合模型也被用于事件检测和震相拾取，为联合提取局部波形特征与时间序列信息提供了另一种实现方式（Zhou *et al*, 2019）. 一方面，深度学习模型能够从连续波形中自动识别弱小事件并拾取P波、S波到时，显著提高事件检出效率；另一方面，自动化流程能够减少人工判断差异，提高目录构建的一致性，为后续震源定位、震级统计、活动性分析和灾害风险判识提供更加稳定的数据基础.

大强煤矿位于辽宁省沈阳市康平县张强镇境内，距康平县城东约25 km，设计生产能力150×10^4 t/a，采用立井开拓方式. 矿区地貌以辽河冲洪积平原为主，北部为略有起伏的沙丘地貌，南部为波状平原，整体表现为南北两侧相对较高、中部相对平坦. 区域构造上，矿区处于新华夏系第二沉降带与天山—阴山纬向构造带的交接部位，盆地基底由太古界变质岩系组成. 张强盆地受北部辽阳窝堡断隆、南部卧牛石隆起、东部八虎山背斜和西部后新丘背斜共同控制，整体呈南北向狭长展布、东缓西陡的向斜盆地格局. 区内EW、NW和NE向断裂及其次级断裂发育，构造组合复杂；大部分区域被第四系覆盖，局部零星出露白垩系地层. 上述地质构造背景和采掘扰动共同影响矿区微震活动的发生、迁移和空间聚集特征（郭

宝建，2015）.

矿区微震监测可为采掘扰动响应、围岩稳定性评价和动力灾害风险判识提供直接观测依据. 与天然地震监测相比，矿区微震通常具有震级小、震源浅等特点，部分事件具有明显爆破源特征. 爆破事件通常以压缩体积变化或近似各向同性源过程为主，剪切辐射成分相对较弱，因而S波不如天然剪切破裂型微震事件发育，使S波初至难以稳定识别. S波到时质量不足不仅会增加人工复核难度，也会直接影响震源深度约束和微震目录质量. 地震台阵观测也已用于识别人为爆炸及相关活动，说明连续地震记录可为人工震源的探测与分析提供独立观测信息（Dando *et al*，2023）.

近年来，机器学习和深度学习方法已广泛应用于地震检测、震相拾取、震相关联、地震—爆破判别和自动化目录构建等研究. 早期研究表明，卷积神经网络可直接从波形中学习地震事件识别特征，并用于事件检测和定位（Perol *et al*，2018）. 随后，PhaseNet、EQTransformer等深度学习模型在P波和S波自动拾取中表现出较高精度和较强泛化能力（Zhu，Beroza，2019；Mousavi *et al*，2020）. 面向台阵观测，Siamese Earthquake Transformer采用成对波形输入开展事件检测和震相拾取，为利用台阵波形间的信息联系提供了方法参考（Xiao *et al*，2021）. Ross等（2019a）利用模板匹配方法在南加州连续波形中识别出大量常规目录遗漏的地震，表明波形相似性分析能够有效补充弱小地震目录. 针对中国地震台网资料，Wang等（2019）开展了深度学习震相到时拾取研究；Yu等（2023）进一步比较了多种神经网络拾取模型的精度和效率. 在汶川地震余震区，深度学习方法也被用于震相检测与拾取，提供了国内复杂地震序列资料的应用实例（Zhu L J *et al*，2019）. 针对意大利Mugello地震序列，Cianetti等（2021）比较了不同深度学习方法的自动处理结果与人工分析结果，为具体台网条件下的模型评估提供了实例. 针对漾濞和玛多地震，Jiang等（2021）比较了PhaseNet与EQTransformer的事件检测能力，为国内地震资料的模型选择提供了参考.

除震相拾取外，自动化地震目录构建还需震相关联、初始定位、精定位等多环节协同完成. PhaseLink、PALM、QuakeFlow等工作将震相拾取、震相关联与定位模块整合为一体化自动处理流程，为连续波形中弱微事件检测及高精度地震目录编制提供了可行思路（Ross *et al*，2019b；Zhou *et al*，2022；Zhu *et al*，2023）. FastLink结合机器学习与GPU计算开展快速震相关联，并应用于漾濞地震余震序列处理（Yu，Wang，2022）. 除深度学习关联方法外，基于贝叶斯高斯混合模型的震相关联方法也为多事件到时数据的自动分组提供了途径（Zhu W Q *et al*，2022）. LOC-FLOW进一步整合了机器学习震相拾取与多阶段定位处理，形成从连续波形到高精度地震位置的自动化工作流程（Zhang M *et al*，2022）. Liu等（2020）将机器学习震相拾取用于2019年Ridgecrest地震序列，实现了从原始地震记录到序列活动特征的快速分析. 面向局地地震检测构建的全球三分量波形基准数据集，为不同算法的训练与性能比较提供了统一的数据基础（Magrini *et al*，2020）. 在诱发地震研究中，机器学习震相拾取与密集台阵观测的结合也被用于揭示Raton盆地复杂断层带上的地震活动（Wang *et al*，2020）. INSTANCE等公开地震数据集进一步丰富了可用于机器学习的波形与标注资源，为模型训练和跨区域评估提供了支持（Michelini *et al*，2021）. 国内学者构建了‘谛听’人工智能地震学数据集，为面向

中国地震观测资料的模型训练提供了数据基础(赵明等, 2022; Zhao *et al*, 2023a). 基于DiTing 等大规模标注波形训练的DiTingPicker 已用于泸定地震序列的自动化处理与发震构造分析(Zhao *et al*, 2023c). 随后发布的'谛听'数据集2.0 进一步扩展了中国地震台网人工智能训练数据资源, 为多任务地震波形分析提供了数据基础(赵明等, 2023). 国内发布的CSNCD 数据集也为面向中国地震台网资料的算法开发和评估提供了数据资源(An, 2024). 该模型依托大规模人工标注地震波形开展训练, 可高效实现 P、S 波震相自动识别, 现已应用于区域地震序列的精细解析工作(Zhao *et al*, 2023c). 上述研究表明, 深度学习技术在提升震相拾取效能的同时, 可与传统地震定位算法有机融合, 搭建具备良好扩展性的自动化地震目录生成体系.

然而, 深度学习拾取结果并不能直接等同于高质量地震目录. 不同震相拾取模型在不同数据集和应用条件下的表现并不一致, 因此模型选择需要结合目标台网资料开展独立评估(Münchmeyer *et al*, 2022). 对于矿区微震而言, 地震目录的可靠性仍受速度模型、台站几何、震相关联策略、S 波到时质量、震相权重设置和仪器授时状态等因素共同制约. 特别是在浅源、近距离和强噪声条件下, S 波拾取误差可能显著影响震源深度; 地震仪授时不准则可能在不同台站之间引入系统性到时偏差, 进而导致震中位置偏移、震源深度异常或事件空间聚集形态发生改变. 因此, 在将深度学习方法用于矿区微震监测时, 有必要将自动化震相拾取与定位质量控制相结合, 对关键定位参数和仪器状态进行系统检验.

在此背景下, 辽宁省地震局联合铁法煤业集团大强煤矿有限责任公司, 自 2022 年起围绕矿区专用地震监测台网建设、台阵布局优化以及微震活动精细解析开展联合研究. 本文选取大强煤矿 2023 年 7 月 10 日—8 月 11 日 64 套短周期密集台阵连续观测波形作为研究数据, 首先利用 DiTingPicker 模型实现 P、S 波震相自动拾取; 然后通过 REAL 算法完成震相关联与初始事件构建, 借助 HypoInverse 开展绝对定位, 再采用 HypoDD 双差定位压制共同路径带来的定位误差(Waldhauser, 2001). 基于上述技术流程, 本文拟开展三方面工作: 评估深度学习算法用于矿区微震检测与震相拾取的实际适用性; 构建大强矿区微震目录, 剖析微震活动的时空分布与震级-频度特征; 探讨 S 波拾取质量、震相权重、仪器授时误差等因素对浅源微震定位效果的制约作用. 相关研究成果, 可为矿区微震自动化处理、目录质量管控及矿山动力灾害风险研判提供技术参考. 下文将对数据资料、处理流程与分析结果展开详细阐述.

1 研究数据介绍

2023 年 7 月 10 日—2023 年 8 月 11 日, 辽宁省地震局科创中心选取了 64 套 CDS-E20 一体化三分量数字地震仪, 在铁法煤业集团大强煤矿有限责任公司矿区内布设短周期台阵, 用于采集矿区微震数据. 矿区位置及具体仪器布设见图 1. 从图可以看出此次布设的台阵已将矿区的位置包围, 监测能力得到有力保障.

地震监测在岩石结构常规检测和岩体稳定性评估方面起着至关重要的作用. 在岩石力学工程背景下, 实时检测与精确定位是开展有效地震监测的必要条件. 传统震源定位方法依赖人工挑选地震波数据获取震相到时, 定位效果受震相到时精度制约. 台阵波形记录中存在

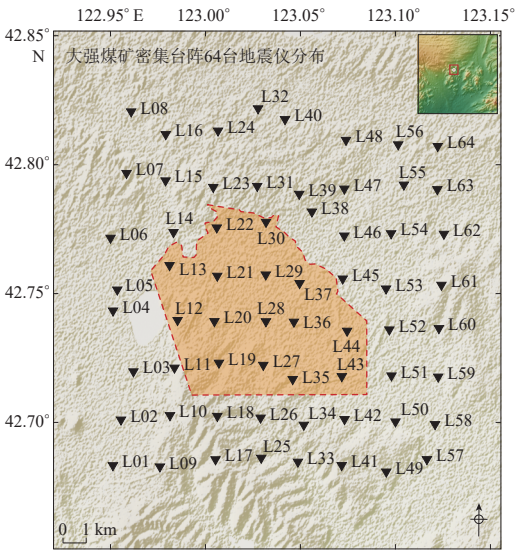

图 1 短周期密集台阵仪器分布图

Fig. 1 Distribution diagram of short-period dense array instruments

较强背景噪声以及人为活动产生的干扰事件，使得台阵数据人工处理的准确性易受信号波形质量影响. 地下采矿环境复杂，大规模采矿活动带来的扰动也会对数据质量产生较大影响.

为实现及时、精确的矿区微震检测，对数据使用 DiTingPicker 进行微震检测工作，共检测出微震事件 255 个，其中满足精定位条件的 77 个. 在处理效率方面，传统人工流完成相近规模数据中全部事件的识别通常需要约一个月；采用 DiTingPicker 进行自动化处理后，相关工作约在两天内完成，整体效率提高约 15 倍，为人工分析提供快速、稳定的初步检测结果. 该方法适用于需要快速响应或处理大规模连续波形数据的矿区微震监测场景，有助于提升监测人员的事件筛查、参数复核和综合研判效率.

2 深度学习方法对大强矿区地震序列检测计算

2.1 连续地震波形处理流程

本文采用深度学习震相拾取与经典地震定位相结合的综合处理流程，从连续地震波形中自动提取震相、关联事件并构建微震目录. 该流程的基本思路是：首先利用深度学习模型提高连续波形中弱小微震事件的检出效率和震相拾取一致性；随后基于多台站 P 波和 S 波到时约束进行震相关联和初始定位；最后通过绝对定位和双差相对定位逐步优化震源参数，削弱速度模型误差、台站几何不均衡和共同传播路径误差对定位结果的影响. 考虑到矿区微震具有震源浅、震中距短、背景噪声强以及爆破事件混入等特点，本文在自动化处理过程中同步开展震相质量控制、台站残差检查和定位结果对比分析，以提高微震目录的稳定性和可靠性. 具体流程如下.

1）震相自动拾取. 利用 DiTingPicker 对原始连续三分量波形进行扫描，自动识别微震信号并拾取 P 波和 S 波初至到时，其中 P、S 震相拾取概率阈值为 0.3，地震事件检测概率阈值为 0.5. DiTingPicker 基于大规模人工标注地震波形训练，能够在连续波形中输出震相类型、到时位置及相应置信度. 对于矿区台阵资料，P 波通常初至较清晰，而 S 波在爆破或爆炸源事件中往往不发育，且易受 P 波尾波、散射波和机械噪声干扰，因此需要对自动拾取结果进行质量控制. 本文根据拾取置信度、同一事件内不同台站到时的一致性、P 波与 S 波的物理传播关系以及异常走时残差，对置信度较低、明显受噪声污染或不符合传播规律的拾取结果进行剔除或降权.

2）震相关联与初始定位. 将自动拾取的 P、S 震相到时输入 REAL 系统进行震相关联，形成候选微震事件（Zhang *et al*, 2019）. REAL 根据区域速度模型、台站位置和震相到时，在给定时空搜索范围内寻找能够被多个台站共同解释的震相组合，从而完成事件关联和初始

震源参数估计. 为减少孤立误拾取和噪声触发对目录的影响, 本文在关联过程中综合考虑参与定位的台站数量、P波和S波震相数、震相空间覆盖范围以及走时残差大小. 仅当候选事件具有足够数量的有效震相约束, 并且初始定位结果与台站记录之间具有合理走时关系时, 才进入后续定位流程.

3) 绝对定位. 以REAL获得的初始定位结果为输入, 采用HypoInverse程序基于P波和S波震相到时进行迭代反演, 得到事件发震时刻、震中位置、震源深度及定位残差等绝对定位参数. 绝对定位能够在给定速度模型和台站几何条件下确定事件的整体空间位置, 是后续相对定位和时空分布分析的基础. 考虑到矿区事件震源浅、台站间距小, 定位结果对S波到时误差和近台残差较为敏感, 本文重点检查定位残差、参与定位台站数、方位覆盖和深度分布是否合理, 并对残差异常或深度明显偏离采掘层位的事件进行复核.

4) 双差相对定位. 在绝对定位结果的基础上, 采用HypoDD双差定位方法进一步优化事件相对位置. 双差定位利用相邻事件在同一台站上的到时差, 构建事件对之间的相对走时约束. 对于空间距离较近、传播路径相似的事件, 速度模型误差和路径效应在走时差中可被部分抵消, 因此该方法能够提高事件相对位置的稳定性和空间分辨率(Waldhauser, 2001). 本文利用HypoDD对微震事件进行相对重定位, 重点分析事件空间丛集、线性展布和深度分布特征是否在重定位后更加清晰, 以此判断目录是否能够反映矿区采掘扰动和断裂构造控制下的微震活动格局.

5) 质量控制与台站残差检查. 为保证自动化目录的可靠性, 本文对每一事件的震相残差、参与定位台站数、P/S震相比例、定位均方根残差以及各台站平均残差进行统计分析. 若某一台站在多个事件中持续出现同号、相近幅度的走时残差, 说明该台站可能存在授时误差、通道延迟、仪器响应异常或元数据时间标定不准确等问题. 对于浅源矿区微震而言, 即使较小的台站授时偏差, 也可能在短震中距条件下引起明显的震源位置偏移, 尤其会影响震源深度和事件空间聚集形态. 因此, 在发现系统性台站残差后, 应进一步检查该台站的授时状态、数据头段时间信息、通道延迟参数和仪器运行记录; 必要时对该台站到时进行校正、降权或剔除, 并对比校正前后的定位结果. 通过上述质量控制, 可降低异常台站和低质量震

表 1　震相关联与定位中使用的具体参数

Table 1　Parameters used in earthquake association and location

方法	参数设置
REAL	搜索网格的参数R=0.5, 50, 0.03, 5, 0.01 走时表参数G=0.5, 100, 0.01, 5 速度参数V=6.3, 3.4, 2.0, 1.5, 1 为P波S波拾取参数S=5, 3, 8, 3, 5.0, 0.5, 5.0, 5.0
HypoInverse	残差加权参数为RMS=3, 0.3, 1, 3; 初始距离加权参数DI1=1, 50, 1, 2; 主距离加权参数DIS=3, 20, 1, 3; 震相质量权重WET=1, 1.0, 0.9, 0.1; 水平定位误差ERH＜20 km; 垂直定位误差ERZ＜20 km
HypoDD	MINWGHT=0; MAXDIST=200 km; MAXSEP=30 km; MAXNGH=20; MINLNK=2; MINOBS=2; MAXOBS=30; IDAT=2; IPHA=3; DIST=200 km; ISTART=2; ISOLV=2(LSQR); NSET=1; NITER=8; WTCTP=1.0; WTCTS=0.1; WRCT=999 s; WDCT=30 km; DAMP=120

注: 表中MINWGHT为震相拾取权重下限; MAXDIST为事件对与台站的最大距离; MAXSEP为配对事件的最大震源间距; MAXNGH为每个事件的最大邻近事件数; MINLNK为确定邻近事件所需的最少连接数; MINOBS为每个事件对保存的最少观测数; MAXOBS为每个事件对保存的最多观测数; IDAT为输入数据类型; IPHA: 使用的震相类型; DIST为事件簇中心与台站的最大距离; ISTART为初始震源位置选取方式; ISOLV为最小二乘求解方法; NSET为迭代参数组数; NITER为当前参数组的迭代次数; WTCTP为目录P波数据权重; WTCTS为目录S波数据权重; WRCT为目录数据残差截断参数(0＜WRCT＜1时单位为s; WRCT≥1时为标准差倍数); WDCT为目录数据重加权的最大事件间距; DAMP为LSQR求解的阻尼系数.

表 2 定位使用的速度模型

Table 2 Velocity model used for earthquake location

层号	层顶深度/km	v_P/(km·s^{-1})	v_S/(km·s^{-1})	v_P/v_S
1	0	2.936	1.695	1.732
2	0.8	2.936	1.695	1.732
3	1.8	2.506	1.447	1.732
4	3	4.500	2.598	1.732
5	5.5	6.000	3.464	1.732
6	15	6.200	3.580	1.732
7	22	6.400	3.695	1.732
8	33	6.400	3.695	1.732

相对微震目录的影响，提高后续时空分布分析和风险判识的可信度.

所使用的不同模块的具体参数设置见表 1. 所使用的速度模型见表 2. 如图 2 所示，最终获得的定位结果中 P 震相走时残差均值 0.06 s，标准差 0.191 s. S 震相走时残差均值−0.07 s，标准差 0.530 s；HypoDD 定位结果 RMS 中位数为 0.31 s.

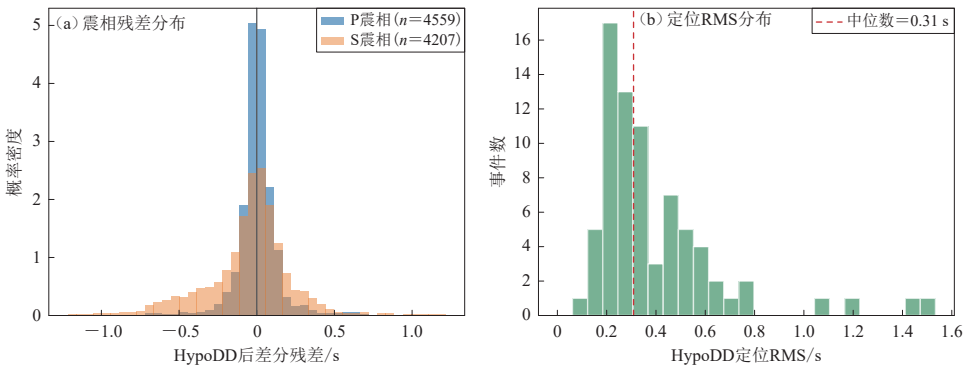

图 2 定位后震相的走时残差分布图(a)和定位误差分布图(b)

Fig. 2 Distribution of travel-time residual (a)and location residuals (b)

2.2 结果分析

针对大强矿区短周期密集台阵连续波形资料，本文采用人工智能震相拾取与自动化定位流程识别微震事件，并对定位结果、波形特征和台站残差进行综合分析. 结果表明，DiTingPicker 能够在矿区较强背景噪声条件下较稳定地识别 P 波初至，并显著提高连续波形处理效率. 图 3 给出了 2023 年 7 月 12 日 22:05:59.740 UTC、M_L2.0 事件的三分量波形记录. 可以看出，多数台站在垂直分量上具有相对清晰的 P 波到时，P 波拾取结果整体连续性较好，说明深度学习模型对该类微震事件具有较好的检出能力. 然而，水平分量上的 S 波到时相对分散，部分台站 S 波初至不清晰，甚至难以与 P 波尾波和后续散射波区分. 这一现象与矿区事件中爆破或爆炸源成分较强有关. 相较于天然剪切破裂事件，爆破事件通常以体积变化和压缩性辐射为主，剪切波能量不发育，因此 S 波振幅较弱、初至不明显，导致 S 波拾取结果具有更高不确定性.

从图 3 还可以看出，个别台站的理论到时与实际波形特征存在系统性偏离. 例如，L45 台站附近的 P 波和 S 波拾取位置与相邻台站的走时变化趋势不完全一致，表现出疑似整体时间偏移特征. 这类异常并不一定源于震相识别模型本身，也可能与台站授时误差、通道延迟、数据头段时间标定或仪器运行状态有关. 由于本研究对象为浅源、近距离矿区微震，台站间距和震中距均较小，毫秒至百毫秒量级的授时偏差都可能在定位反演中被错误解释为震源位置或深度变化.

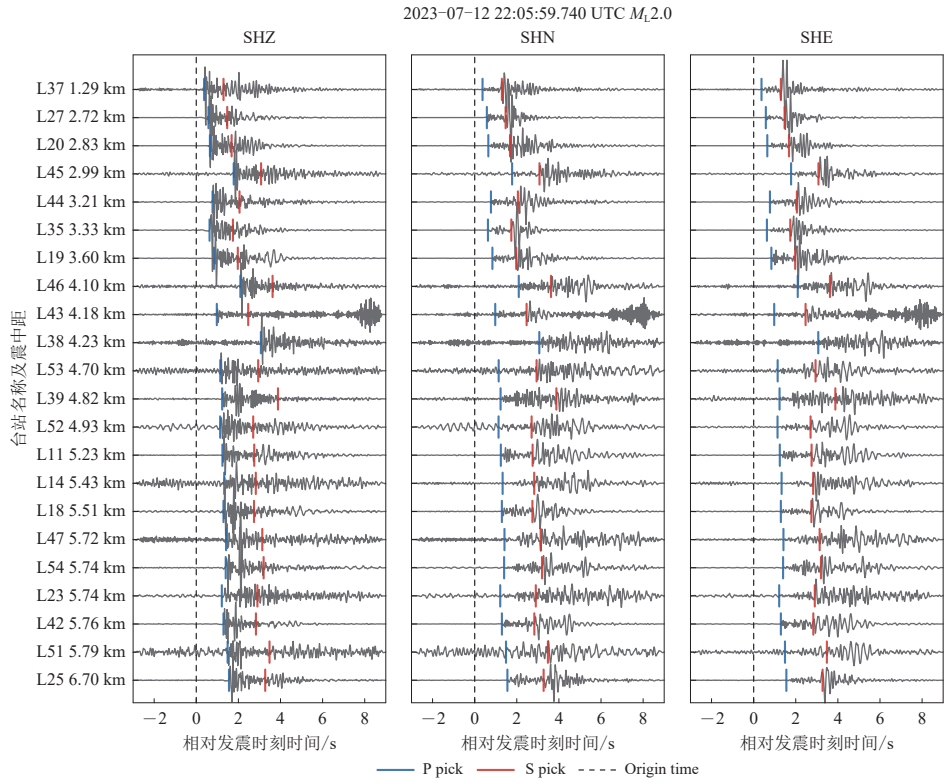

图 3　关联后地震事件波形示例

Fig. 3　An example of correlated seismic event waveforms

2.2.1　空间分布特征

图 4 展示了微震事件的三维空间分布及其平面投影和剖面投影结果. 总体上, 事件在平面上主要集中于矿区开采范围及其周边区域, 显示出较明显的空间丛集性, 与采掘扰动和局部构造控制具有一定对应关系. 事件主要分布在矿区边界附近和台阵覆盖范围内, 说明密集台阵对研究区微震活动具有较好的监测能力. 从震级分布看, 小震级事件占主体, 较大震级事件相对较少, 符合矿区微震活动的一般特征. 其它地区的研究表明, 精细地震定位能够揭示地震丛集与三维断层几何之间的关系, 为认识地震活动的空间组织提供约束(Ross *et al*, 2020). 本文局部线性展布是否对应断层结构, 仍需结合定位不确定性和独立地质资料检验.

需要注意的是, 当前定位结果在深度方向上呈现明显的分层现象: 一部分事件集中于接近 0 m 深度, 另一部分事件集中于约 30 m 深度附近. 对于浅源微震而言, 震源深度通常是最不稳定的定位参数之一, 容易受到速度模型、台站几何、S 波到时质量和台站授时状态的共同影响. 当部分台站存在授时偏差时, 不同台站之间的相对到时关系会发生系统性改变, 定位程序会通过调整震源深度来吸收这类走时残差, 从而造成深度集中于边界值或特定深度层位的现象. 与此同时, 若事件 S 波不发育, S-P 到时差约束不足, 震源深度将主要依赖 P 波到时和台站几何控制, 进一步加重深度反演的不确定性. 接近 0 m 的事件多为小震级事件, 可能与浅部爆破、卸压、机械振动或采场近地表扰动有关; 接近 30 m 的事件震级相对较大, 可能反映采掘工作面附近围岩应力调整, 或与矿区边界和隐伏构造附近的局部应力释放有

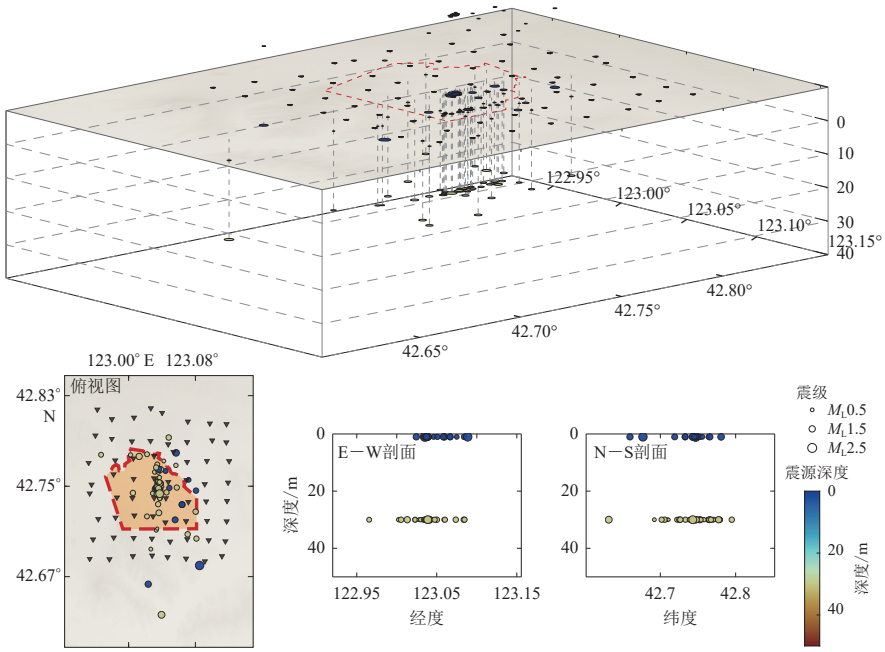

图 4 微震事件三维空间分布

Fig. 4 Three-dimensional spatial distribution of microseismic events

关. 但考虑到图 3 中存在疑似台站授时不准现象，且 S 波到时识别稳定性不足，当前深度分布仍需通过进一步质量控制加以验证. 人工智能方法显著提高了矿区微震事件识别和震相拾取效率，为快速构建微震目录提供了重要技术支撑. 但在矿区复杂观测环境下，自动化结果仍需与波形复核、台站残差检查和定位敏感性分析结合使用. 特别是对于浅源微震定位，S 波不发育和台站授时误差可能显著影响震源深度.

2.2.2 时间与震级分布特征

7 月微震活动相对活跃，共记录 64 个重定位事件，7 月 9—31 日期间日均约 2.8 个，按有事件记录的日期统计日均约 3.2 个. 较高活动日主要出现在 7 月 16—18 日和 7 月 21 日前后，其中 7 月 17 日记录 7 个事件，7 月 21 日记录 6 个事件. 8 月上旬事件数减少，共记录 13 个重定位事件，8 月 1—10 日期间日均约 1.3 个. 该变化可能与采掘强度、爆破安排、局部应力调整或台网运行状态变化有关，仍需结合生产日志和台站运行记录进行约束. 从一天内分布来看，事件在全天均有发生，未表现出稳定的昼夜周期性；0—6 时共记录 22 个事件，8—12 时共记录 19 个事件，相对略集中，可能与矿区作业节奏、爆破时间安排或背景噪声水平变化有关. 由于矿区人为活动具有明显的时段性，后续可结合生产记录、爆破记录和噪声谱特征进一步区分采掘相关事件与天然微震. 震级统计显示，7 月目录中 M_L＜1.0 事件占 43.8%，M_L 1.0—2.0 事件占 53.1%，M_L>2.0 事件占 3.1%，总体仍以小震级事件为主. 最大事件为 M_L 2.5（7 月 18 日），其次为 M_L 2.3（7 月 26 日）和 M_L 2.0（7 月 12 日）. 8 月事件震级范围为 M_L 0.3—2.1，最大事件为 M_LL 2.1（8 月 10 日）. 重定位事件主要集中在 42.75°N，123.04°E 附近，事件整体分布范围为 42.603 0°—42.815 2°N，122.945 7°—123.118 0°E. 少数外围离散事件需结合波形、到时残差和生产记录判断其是否为构造活动、远距离爆破或定位不确定性较大的事件.

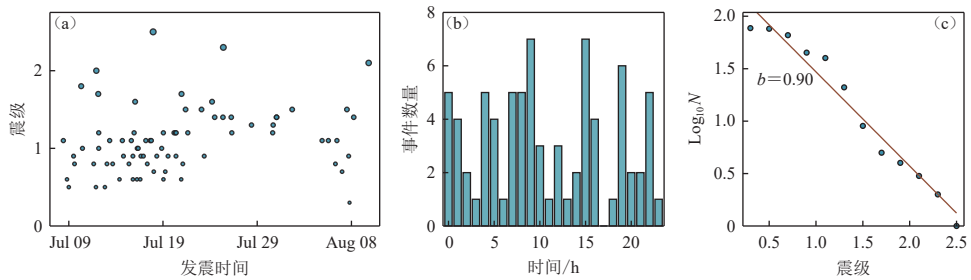

图 5　所有地震事件的时间与震级分布

(a) 震级随发震时间的分布；(b) 按小时统计的地震事件数；(c) 震级—累积频次分布及其拟合结果

Fig. 5　Temporal and magnitude distributions of all earthquake events

(a) Earthquake magnitudes versus origin time; (b) Hourly distribution of earthquake counts;

(c) cumulative frequency–magnitude distribution and its fit

3 讨论

3.1　矿区地震风险性分析

基于高精度地震目录，我们对研究区的地震活动特征进行了系统分析. 从时空分布来看，微震事件呈现明显的丛集性，主要沿矿区开采工作面和已知断层分布，反映出采掘活动对围岩应力的扰动作用及构造活化的空间关联. 开展微震活动性和震级—频度分析前，需要评估台网监测能力及地震目录的完整性，明确统计结果所对应的有效震级范围(冯建刚等，2012). 震级-频度分析显示，目录的完备性震级(M_C)采用最大曲率法(Wiemer，Wyss，2000)估计约为 M_L1.0. 完备性震级本身存在估计不确定性，后续应结合目录质量评估和重采样分析，检验完备性震级及相关统计结果的稳定性(Woessner，Wiemer，2005). 不同完备性震级估计方法对目录特征和样本条件的响应存在差异，有必要通过多种方法对比检验估计结果的稳定性(黄亦磊等，2016). 后续还可采用基于检测概率的完备性震级评估方法，进一步分析台网监测能力的空间差异(李智超，黄清华，2014). 研究采用最大似然法(Aki，1965)，计算 b 值，得到 b 值约为 0.90. 受观测时段较短、地震样本数量有限的制约，仅依靠该结果尚不足以判定矿区应力集中程度，也无法排除冲击地压发生风险，样本量不足是影响本次 b 值计算结果的重要因素. 尽管如此，b 值研究仍具备重要科学意义：低 b 值区域往往与高应力集中区高度吻合，可作为识别潜在突水、冲击地压风险区的指标. 后续可引入 PolarCAP 等 P 波初动极性自动判别方法，对高质量 P 波初动数据开展辅助分类，为震源机制解分析提供观测约束(Chakraborty *et al*，2022). DiTingMotion 也可用于 P 波初动极性自动判别，并为后续震源机制反演提供辅助信息(Zhao *et al*，2023b). 如果我们能进一步结合震源机制解反演，发现破裂类型以剪切破裂为主，兼有少量张拉破裂，主压应力方向与区域构造应力场基本一致，表明微震活动既受采矿扰动控制，也受背景构造应力制约. 综合而言，精细的地震目录分析为矿区动力灾害的动态预警与防控提供了关键数据支撑.

3.2　地震定位的不足与未来改进方向

本文旨在利用深度学习震相拾取与自动化定位流程构建大强矿区微震目录. 总体来看，该流程能够显著提高连续波形处理效率，并获得较为完整的微震事件目录. 但从定位结果和波形检查来看，当前目录仍存在一定不确定性，主要体现在台站授时误差和 S 波拾取不稳定

两个方面. 这两个因素都会直接影响震相到时约束, 进而影响震源位置, 尤其是震源深度的可靠性.

首先, 台站授时误差可能是影响浅源微震定位的重要因素. 矿区微震通常震源浅、震中距短, 定位结果对不同台站之间的相对到时非常敏感. 如果个别台站存在GPS授时异常、通道延迟或数据头段时间标定不准确, 其记录的P波和S波到时会整体提前或滞后. 定位程序在反演过程中可能将这种系统性时间偏差误解释为震源位置变化, 从而造成震中偏移、震源深度异常或事件空间分布形态失真. 本文在波形检查中发现, 个别台站的到时与相邻台站的走时变化趋势不完全一致, 提示其可能存在授时或通道延迟问题. 因此, 后续应重点开展台站残差统计, 识别是否存在长期同号、相近幅度的异常残差; 对于疑似异常台站, 应进一步核查授时记录、仪器运行状态和元数据时间信息, 并通过时间校正、降权或剔除试验比较定位结果的变化.

其次, S波拾取不稳定也是影响定位精度的重要原因. 与P波相比, 矿区事件中的S波往往更难识别. 一方面, 矿区目录中可能包含较多爆破或爆炸源事件. 在人工爆炸事件识别方面, 已有研究利用卷积神经网络开展地下核爆炸与地震信号判别, 为基于波形特征的事件分类提供了方法参考(Barama *et al*, 2023). 该文的对象是地下核爆炸, 不能直接作为模型适用于矿山爆破的验证依据. 对贝鲁特化学爆炸的研究也开展了事件判别与当量估计, 为人工爆炸源的地震学分析提供了实例(Zhang L *et al*, 2022). 这类事件通常以体积变化和压缩性辐射为主, 剪切波能量不发育, 因而S波初至较弱甚至不清晰; 另一方面, 矿区事件震中距短, P波尾波、散射波和面波容易与S波到时重叠, 强背景噪声也会进一步降低S波拾取稳定性. 由于S-P到时差是约束震源深度和震中距的重要信息, S波到时误差会显著影响浅源微震定位结果, 可能造成震源深度偏移或深度分布异常. 针对地下核爆炸, Yang等(2021)通过联合Pn和Pg差分走时开展了位置与埋深估计, 说明不同震相约束的组合可为深度确定提供补充信息. 该研究的观测尺度和可用震相与矿区近距离台阵不同, 相关方法在本区的适用性仍需单独评估. 因此, 后续定位中应对S波到时进行专门质量控制, 对S波不清晰或不发育的事件降低S波权重, 并开展不同P/S权重方案下的定位敏感性测试, 以评估S波拾取误差对震源深度和空间分布的影响.

未来改进方向主要包括两个方面. 一是加强台站授时质量控制, 在常规定位前增加台站级残差诊断和时间一致性检查, 对存在系统性残差的台站进行授时记录核查、时间校正、降权或剔除, 并比较不同处理方案下定位结果的稳定性. 二是完善S波质量控制和权重设置, 对S波不发育、初至不清晰或受P波尾波干扰明显的事件进行分类处理, 通过人工复核、S波降权和P/S权重敏感性测试, 减少低质量S波到时对震源深度的影响. 通过上述改进, 可进一步提升矿区微震目录的定位可靠性, 为后续采掘扰动分析和动力灾害风险判识提供更稳定的数据基础. 后续可借助SeisBench提供的统一数据与模型接口, 在一致的预处理和评估条件下比较不同拾取模型的表现(Woollam *et al*, 2022). 后续还可评估SeisCLIP等预训练模型提取的波形特征是否有助于矿区事件分类, 并利用人工核验样本检验其适用性(Si *et al*, 2024).

4 结论

本文以辽宁大强矿区2023年7月10日至8月11日短周期密集台阵连续记录为研究对

象，采用 DiTingPicker 深度学习模型进行震相自动拾取，并结合 REAL 震相关联、HypoInverse 绝对定位和 HypoDD 双差相对定位，构建了大强矿区微震事件目录．研究表明，人工智能方法能够显著提高矿区连续波形处理效率和微震目录构建的自动化水平，为采掘扰动识别、围岩稳定性评价和动力灾害风险判识提供了重要技术支撑．同时，矿区微震定位结果受仪器授时误差、S 波到时质量等因素影响．主要认识如下：

1）DiTingPicker 在大强矿区短周期密集台阵资料处理中具有较好的适用性．该方法能够在较强背景噪声条件下自动识别微震事件并拾取 P 波和 S 波到时，为人工分析提供快速、稳定的初步检测结果．该方法适用于需要快速响应或处理大规模连续波形数据的矿区微震监测场景，有助于提升监测人员的事件筛查、参数复核和综合研判效率．

2）本研究共识别并定位 255 个微震事件．事件在平面分布上呈现明显丛集性，主要集中于 122.95°—123.15°E、42.65°—42.90°N 范围内的开采工作面及断层附近，表明微震活动与采掘扰动和局部构造条件具有一定空间对应关系．事件相对深度主要分布在 0—30 m 范围内，总体与浅部采掘扰动层位较为一致，但局部深度集中现象仍需结合定位误差来源进一步检验．

3）震级—频度分析显示，目录完备性震级约为 M_L1.0，b 值约为 0.90，未表现出明显异常低值．考虑到本研究观测时段较短、样本数量有限，单独依据 b 值判断冲击地压风险仍存在不确定性．后续应结合采掘进度、震源机制、能量释放率、事件迁移特征和现场应力监测资料，对矿区动力灾害风险进行综合评估．

4）从空间分布看，浅部事件多呈离散分布，可能与爆破、卸压、机械扰动或近地表采掘活动有关；相对深部事件局部呈线性展布，可能受隐伏断层、采动裂隙带或应力集中边界控制．但由于矿区事件中可能混有爆破或爆炸源事件，且部分事件 S 波不发育，对不同深度层位和空间展布特征的物理解释仍需结合波形特征、事件类型判别和定位质量控制进一步验证．

5）台站授时误差和 S 波拾取不稳定是影响本文浅源微震定位可靠性的两个重要因素．若个别台站存在授时偏差或通道延迟，定位程序可能将系统性到时误差误解释为震源位置或深度变化；同时，爆破或爆炸源事件中 S 波往往不发育，S 波初至容易受 P 波尾波、散射波和噪声干扰，进而削弱震源深度约束．未来目录构建应重点加强台站残差统计、授时状态检查、可疑台站校正或剔除试验，并开展 S 波质量控制和 P/S 权重敏感性测试，以进一步提高矿区微震定位结果的稳定性和解释可信度．

感谢肖卓伟老师（中国科学院地质与地球物理研究所）在深度学习震相识别方法上的指导与支持，感谢中国地震局地球物理研究所提供 DiTingPicker 软件及“谛听”数据集．

参　考　文　献

冯建刚，蒋长胜，韩立波，陈继锋，2012. 甘肃测震台网监测能力及地震目录完整性分析 [J]. 地震学报，**34**(5)：646–658.

Feng J G，Jiang C S，Han L B，Chen J F，2012. Analysis on the monitoring capability of seismic networks and completeness of earthquake catalogues in Gansu region[J]. *Acta Seismologica Sinica*，**34**(5)：646–658 (in Chinese).

郭宝建，2015. 康北煤田大强井田煤层特征及煤层对比 [J]. 陕西煤炭，**34**(1)：63–65.

Guo B J，2015. Comparison on coal seams and seams characteristics of Daqiang mine in Kangbei coalfield[J]. *Shaanxi Coal*，**34**(1)：63–65 (in Chinese).

黄亦磊，周仕勇，庄建仓，2016. 基于地震目录估计完备震级方法的数值实验 [J]. 地球物理学报，**59**(4)：1350–1358.

Huang Y L，Zhou S Y，Zhuang J C，2016. Numerical tests on catalog-based methods to estimate magnitude of completeness[J].

Chinese Journal of Geophysics, **59**(4): 1350–1358 (in Chinese).

李智超, 黄清华, 2014. 基于概率完备震级评估首都圈地震台网检测能力[J]. 地球物理学报, **57**(8): 2584–2593.

Li Z C, Huang Q H, 2014. Assessment of detectability of the Capital-circle Seismic Network by using the probability-based magnitude of completeness (PMC) method[J]. *Chinese Journal of Geophysics*, **57**(8): 2584–2593 (in Chinese).

Tan Y P, Cao J Q, Chen J F, Deng L, Li H, 2015. Temporal decay characteristics of the aftershock sequence of the 2013 Minxian-Zhangxian, Gansu, M_s6.6 earthquake[J]. *Chinese Journal of Geophysics*, **58**(9): 3222–3231 (in Chinese).

赵明, 肖卓伟, 陈石, 房立华, 2022. "谛听"人工智能地震学训练数据集[DS/OL]. 国家地震科学数据中心. [2026-05-25]. https://data.earthquake.cn/datashare/report.shtml?PAGEID=datasourcelist&dt=ff8080827e3317f4017e331e7ce00002.

Zhao M, Xiao Z W, Chen S, Fang L H, 2022. "DiTing" benchmark Chinese data set for artificial intelligence in seismology[DS/OL]. National Earthquake Data Center. [2026-05-25]. https://data.earthquake.cn/datashare/report.shtml?PAGEID=datasourcelist&dt=ff8080827e3317f4017e331e7ce00002 (in Chinese).

赵明, 肖卓伟, 陈石, 张博, 汪小厉, 唐淋, 郭凯, 马莉, 杨红艳, 张怀, 2023. 谛听数据集2.0-中国地震台网多功能大型人工智能训练数据集[DS/OL]. [2026-05-25]. https://data.earthquake.cn/datashare/report.shtml?PAGEID=datasourcelist&dt=ff8080828b238a7a018b40eac2790006.

Zhao M, Xiao Z W, Chen S, Zhang B, Wang X L, Tang L, Guo K, Ma L, Yang H Y, Zhang H, 2023. Diting dataset 2.0 - multi-functional large-scale artificial intelligence training data set from Chinese Seismic Network[DS/OL]. [2026-05-25]. https://data.earthquake.cn/datashare/report.shtml?PAGEID=datasourcelist&dt=ff8080828b238a7a018b40eac2790006 (in Chinese).

Aki K, 1965. Maximum likelihood estimate of b in the formula logN=a-bM and its confidence limits[J]. *Bull Earthq Res Inst*, **43**(2): 237–239.

An Y R, 2024. Introduction to a recently released dataset entitled CSNCD: A comprehensive dataset of Chinese seismic network[J]. *Earthq Res Adv*, **4**(1): 100255.

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.

Bergen K J, Johnson P A, De Hoop M V, Beroza G C, 2019. Machine learning for data-driven discovery in solid earth geoscience[J] *Science*, **363**(6433): aau0323.

Chakraborty M, Cartaya C Q, Li W, Faber J, Rümpker G, Stoecker H, Srivastava N, 2022. PolarCAP–A deep learning approach for first motion polarity classification of earthquake waveforms[J]. *Artif Intell Geosci*, **3**: 46–52.

Cianetti S, Bruni R, Gaviano S, Keir D, Piccinini D, Saccorotti G, Giunchi C, 2021. Comparison of deep learning techniques for the investigation of a seismic sequence: An application to the 2019, M_W 4.5 Mugello (Italy) earthquake[J]. *J Geophys Res: Solid Earth*, **126**(12): e2021JB023405.

Dando B D E, Goertz-Allmann B P, Brissaud Q, Köhler A, Schweitzer J, Kvaerna T, Liashchuk A, 2023. Identifying attacks in the Russia-Ukraine conflict using seismic array data[J]. *Nature*, **621**(7980): 767–772.

Jiang C, Fang L H, Fan L P, Li B R, 2021. Comparison of the earthquake detection abilities of PhaseNet and EQTransformer with the Yangbi and Maduo earthquakes[J]. *Earthq Sci*, **34**(5): 425–435.

Kuang W H, Yuan C C, Zhang J, 2021. Real-time determination of earthquake focal mechanism via deep learning[J]. *Nat Commun*, **12**(1): 1432.

Liu M, Zhang M, Zhu W Q, Ellsworth W L, Li H Y, 2020. Rapid characterization of the July 2019 Ridgecrest, California, earthquake sequence from raw seismic data using machine-learning phase picker[J]. *Geophys Res Lett*, **47**(4): e2019GL086189.

Magrini F, Jozinović D, Cammarano F, Michelini A, Boschi L, 2020. Local earthquakes detection: A benchmark dataset of 3-component seismograms built on a global scale[J]. *Artif Intell Geosci*, **1**: 1–10.

Michelini A, Cianetti S, Gaviano S, Giunchi C, Jozinović D, Lauciani V, 2021. INSTANCE–the Italian seismic dataset for machine learning[J]. *Earth Syst Sci Data*, **13**(12): 5509–5544.

Mousavi S M, Beroza G C, 2020. A machine-learning approach for earthquake magnitude estimation[J]. *Geophys Res Lett*, **47**(1): e2019GL085976.

Mousavi S M, Ellsworth W L, Zhu W Q, Chuang L Y, Beroza G C, 2020. Earthquake transformer-an attentive deep-learning model for simultaneous earthquake detection and phase picking[J]. *Nat Commun*, **11**(1): 3952.

Münchmeyer J, Bindi D, Leser U, Tilmann F, 2021. Earthquake magnitude and location estimation from real time seismic waveforms with a transformer network[J]. *Geophys J Int*, **226**(2): 1086–1104.

Münchmeyer J, Woollam J, Rietbrock A, Tilmann F, Lange D, Bornstein T, Diehl T, Giunchi C, Haslinger F, Jozinović D, Michelini A, Saul J, Soto H, 2022. Which picker fits my data? A quantitative evaluation of deep learning based seismic pickers[J]. *J Geophys Res: Solid Earth*, **127**(1): e2021JB023499.

Perol T, Gharbi M, Denolle M, 2018. Convolutional neural network for earthquake detection and location[J]. *Sci Adv*, **4**(2): e1700578.

Reichstein M, Camps-Valls G, Stevens B, Jung M, Denzler J, Carvalhais N, Prabhat, 2019. Deep learning and process understanding for data-driven Earth system science[J]. *Nature*, **566**(7743): 195–204.

Ross Z E, Meier M A, Hauksson E, 2018. *P* wave arrival picking and first-motion polarity determination with deep learning[J]. *J Geophys Res: Solid Earth*, **123**(6): 5120–5129.

Ross Z E, Trugman D T, Hauksson E, Shearer P. 2019a. Searching for hidden earthquakes in Southern California[J]. *Science*, **364**(6442): 767-771.

Ross Z E, Cochran E S, Trugman D T, Smith J D, 2020. 3D fault architecture controls the dynamism of earthquake swarms[J]. *Science*, **368**(6497): 1357–1361.

Ross Z E, Yue Y S, Meier M A, Hauksson E, Thomas H H. 2019b. PhaseLink: A deep learning approach to seismic phase association[J]. *J Geophys Res: Solid Earth*, **124**(1): 856-869.

Si X, Wu X M, Sheng H L, Zhu J, Li Z F, 2024. SeisCLIP: A seismology foundation model pre-trained by multimodal data for multipurpose seismic feature extraction[J]. *IEEE Trans Geosci Remote Sens*, **62**: 5903713.

Waldhauser F, 2001. HypoDD—a program to compute double-difference hypocenter locations[R]. U. S. Geological Survey.

Wang J, Xiao Z W, Liu C, Zhao D P, Yao Z X, 2019. Deep learning for picking seismic arrival times[J]. *J Geophys Res: Solid Earth*, **124**(7): 6612–6624.

Wang R J, Schmandt B, Zhang M, Glasgow M, Kiser E, Rysanek S, Stairs R, 2020. Injection-induced earthquakes on complex fault zones of the Raton Basin illuminated by machine-learning phase picker and dense nodal array[J]. *Geophys Res Lett*, **47**(14): e2020GL088168.

Wiemer S, Wyss M, 2000. Minimum magnitude of completeness in earthquake catalogs: Examples from Alaska, the western United States, and Japan[J]. *Bull Seismol Soc Am*, **90**(4): 859–869.

Woessner J, Wiemer S, 2005. Assessing the quality of earthquake catalogues: Estimating the magnitude of completeness and its uncertainty[J]. *Bull Seismol Soc Am*, **95**(2): 684–698.

Woollam J, Münchmeyer J, Tilmann F, Rietbrock A, Lange D, Bornstein T, Diehl T, Giunchi C, Haslinger F, Jozinović D, Michelini A, Saul J, Soto H, 2022. SeisBench—A toolbox for machine learning in seismology[J]. *Seismol Res Lett*, **93**(3): 1695–1709.

Xiao Z W, Wang J, Liu C, Li J, Zhao L, Yao Z X, 2021. Siamese earthquake transformer: A pair-input deep-learning model for earthquake detection and phase picking on a seismic array[J]. *J Geophys Res: Solid Earth*, **126**(5): e2020JB021444.

Yang G, Zhao L F, Xie X B, Zhang L, Yao Z X, 2021. High-precision relocation with the burial depths of the North Korean underground nuclear explosions by combining Pn and Pg differential traveltimes[J]. *J Geophys Res: Solid Earth*, **126**(6): e2020JB020745.

Yu Z Y, Wang W T, 2022. FastLink: A machine learning and GPU-based fast phase association method and its application to Yangbi M_S 6.4 aftershock sequences[J]. *Geophys J Int*, **230**(1): 673–683.

Yu Z Y, Wang W T, Chen Y N, 2023. Benchmark on the accuracy and efficiency of several neural network based phase pickers using datasets from China Seismic Network[J]. *Earthq Sci*, **36**(2): 113–131.

Zhang L, Zhao L F, Xie X B, H X, Yao Z X, 2022. Yield estimation and event discrimination of the 4 August 2020 Beirut chemical explosion[J]. *Seismol Res Lett*, **93**(4): 2004–2014.

Zhang M, Liu M, Feng T, Wang R J, Zhu W Q, 2022. LOC-FLOW: An end-to-end machine learning-based high-precision

earthquake location workflow[J]. *Seismol Res Lett*, **93**(5): 2426–2438.

Zhao M, Xiao Z W, Chen S, Fang L H, 2023a. DiTing: A large-scale Chinese seismic benchmark dataset for artificial intelligence in seismology[J]. *Earthq Sci*, **36**(2): 84–94.

Zhao M, Xiao Z W, Zhang M, Yang Y, Tang L, Chen S, 2023b. DiTingMotion: A deep-learning first-motion-polarity classifier and its application to focal mechanism inversion[J]. *Front Earth Sci*, **11**: 1103914.

Zhao X, Xiao Z W, Wang W, Li J, Zhao M, Chen S, Tang L. 2023c. Fine seismogenic fault structures and complex rupture characteristics of the 2022 *M*6.8 luding, Sichuan earthquake sequence revealed by deep learning and waveform modeling[J]. *Geophys Res Lett*, **50**(18): e2023GL102976.

Zhou Y J, Yue H, Zhou S K, Kong Q Y, 2019. Hybrid event detection and phase-picking algorithm using convolutional and recurrent neural networks[J]. *Seismol Res Lett*, **90**(3): 1079–1087.

Zhou Y J, Yue H, Fang L H, Zhou S Y, Zhao L, Ghosh A, 2022. An earthquake detection and location architecture for continuous seismograms: Phase picking, association, location, and matched filter (PALM)[J]. *Seismol Res Lett*, **93**(1): 413–425.

Zhu J, Li Z F, Fang L H, 2023. USTC-Pickers: A unified set of seismic phase pickers transfer learned for China[J]. *Earthq Sci*, **36**(2): 95–112.

Zhu L J, Peng Z G, McClellan J, Li C Y, Yao D D, Li Z F, Fang L H, 2019. Deep learning for seismic phase detection and picking in the aftershock zone of 2008 M_W7.9 Wenchuan Earthquake[J]. *Phys Earth Planet Inter*, **293**: 106261.

Zhang M, Ellsworth W L, Beroza G C, 2019. Rapid Earthquake Association and Location[J]. *Seismological Research Letters*, **90**(6): 2276–2284.

Zhu W Q, Beroza G C, 2019. PhaseNet: A deep-neural-network-based seismic arrival-time picking method[J]. *Geophys J Int*, **216**(1): 261–273.

Zhu W Q, McBrearty I W, Mousavi S M, Ellsworth W L, Beroza G C, 2022. Earthquake phase association using a Bayesian Gaussian mixture model[J]. *J Geophys Res: Solid Earth*, **127**(5): e2021JB023249.

Zhu W Q, Hou A B, Yang R, Datta A, Mousavi S M, Ellsworth W L, Beroza G C, 2023. QuakeFlow: A scalable machine-learning-based earthquake monitoring workflow with cloud computing[J]. *Geophys J Int*, **232**(1): 684–693.