



煤炭学报
Journal of China Coal Society
ISSN 0253-9993, CN 11-2190/TD

《煤炭学报》网络首发论文

题目: 物理指标与数据特征融合驱动的冲击地压时序预测方法
作者: 曹安业, 刘耀琪, 杨旭, 李森, 王常彬, 白贤栖, 刘亚鹏
DOI: 10.13225/j.cnki.jccs.2022.0680
网络首发日期: 2022-07-10
引用格式: 曹安业, 刘耀琪, 杨旭, 李森, 王常彬, 白贤栖, 刘亚鹏. 物理指标与数据特征融合驱动的冲击地压时序预测方法[J/OL]. 煤炭学报.
<https://doi.org/10.13225/j.cnki.jccs.2022.0680>



网络首发: 在编辑部工作流程中, 稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定, 且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式(包括网络呈现版式)排版后的稿件, 可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定; 学术研究成果具有创新性、科学性和先进性, 符合编辑部对刊文的录用要求, 不存在学术不端行为及其他侵权行为; 稿件内容应基本符合国家有关书刊编辑、出版的技术标准, 正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性, 录用定稿一经发布, 不得修改论文题目、作者、机构名称和学术内容, 只可基于编辑规范进行少量文字的修改。

出版确认: 纸质期刊编辑部通过与《中国学术期刊(光盘版)》电子杂志社有限公司签约, 在《中国学术期刊(网络版)》出版传播平台上创办与纸质期刊内容一致的网络版, 以单篇或整期出版形式, 在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊(网络版)》是国家新闻出版广电总局批准的网络连续型出版物(ISSN 2096-4188, CN 11-6037/Z), 所以签约期刊的网络版上网络首发论文视为正式出版。

doi:10.13225/j.cnki.jccs.2022.0680

物理指标与数据特征融合驱动的冲击地压时序预测方法

曹安业^{1,2,3}, 刘耀琪¹, 杨旭⁴, 李森⁴, 王常彬¹, 白贤栖¹, 刘亚鹏⁴

(1.中国矿业大学 矿业工程学院, 江苏 徐州 221116; 2.中国矿业大学 江苏省矿山地震监测工程实验室, 江苏 徐州 221116; 3.徐州物硕信息技术有限公司, 江苏 徐州 221116; 4.中国矿业大学 计算机科学与技术学院, 江苏 徐州 221116)

摘要: 煤矿智能化建设的大背景下, 如何高效的从冲击地压海量监测数据提取有效信息与提高预测预警准确率是未来的研究重点与难点。为解决目前基于物理指标冲击地压预测方法泛化能力较差、对海量数据特征挖掘不充分的困境, 结合深度学习技术, 初步尝试建立了物理指标与数据特征融合驱动的冲击地压时序预测方法。本文以陕西彬长矿区某强冲击危险工作面为背景, 分析了多次大能量事件发生前物理指标的变化特征, 并统计剖析了仅使用物理指标驱动的冲击地压危险预测指标的短板与不足; 提出采用物理指标与数据特征融合驱动的冲击地压时序预测方法, 预测模型包括数据预处理、特征提取以及预警模型构建三个模块, 数据预处理将原有微震监测数据处理为具有特定时间窗的前兆模式序列, 特征提取主要包括基于物理指标的显式特征以及基于卷积神经网络的数据隐式特征提取, 提出基于注意力机制的显式特征和隐式特征的深度融合方法, 并通过全连接网络实现预测模型分类, 实现对不同冲击危险等级的大能量事件进行预测。模型测试结果表明: 预测时长为未来 1 天、未来 2 天以及未来 3 天时预测 F1 值分别可达 0.956, 0.950 以及 0.854, 现场可根据需求选用预测时长; 工程应用时模型可对大能量事件准确预测, 误差分析结果表明模型预测准确率较高, 可满足现场需求。研究成果可为冲击地压的实时精准预警提供参考与借鉴。

关键词: 冲击地压; 时序预测; 物理指标; 数据特征; 融合驱动; 机器学习

中图分类号: TD313

文献标识码: A

Physical index and Data Fusion-Driven method for coal burst prediction in time sequence

CAO Anye^{1,2,3}, LIU Yaoqi¹, YANG Xu⁴, LI Sen⁴, WANG Changbin¹, BAI Xianxi¹, LIU Yapeng⁴

(1. School of Mines, China University of Mining & Technology, Xuzhou 221116, China; 2. Jiangsu Engineering Laboratory of Mine Earthquake Monitoring and Prevention, China University of Mining & Technology, Xuzhou 221116, China; 3. Xuzhou Wushuo Information Co., Ltd, Xuzhou 221116, China. 4. School of Computer Science & Technology, China University of Mining & Technology, Xuzhou 221116, China)

Abstract: Under the background of coal mine intelligent construction, how to efficiently extract adequate information from the massive monitoring data of coal burst and improve the accuracy of prediction and warning is the focus and difficulty of future research. Aiming to solve the challenges of the poor generalization ability of current physical model-based coal burst prediction methods and insufficient feature mining of massive data, combined with deep learning technology, a time series coal burst prediction method driven by the fusion of physical model and data feature was initially established. In this paper, taking a strong coal burst risk longwall face in Binchang Mining area, Shaanxi Province as the background, the variation characteristics of physical indicators before several large energy events are analyzed, and the shortcomings of coal burst risk prediction

¹基金项目: 国家自然科学基金项目(51734009, U21A20110); 山东省重大科技创新工程项目(2019SDZY02); 江苏省研究生科研与实践创新计划项目(KYCX22_2609); 中国矿业大学未来科学家计划项目(2022WLKXJ003)

作者简介: 曹安业(1982-), 男, 江苏省盐城市人, 教授, 博士生导师。E-mail: caoanye@163.com
通讯作者: 杨旭(1995-), 男, 江苏省徐州市人, 讲师, 博士。E-mail: yang_xu@cumt.edu.cn

indicators driven only by physical models are statistically analyzed. The coal burst time domain prediction method driven by the fusion of physical model and data feature is proposed. The prediction model includes three modules: data preprocessing, feature extraction, and early warning model construction—the data preprocessing processes the original microseismic monitoring data into precursor pattern sequence within a specific time window. Feature extraction based on a physical model mainly includes the characteristics of explicit and implicit data feature extraction based on convolution neural network. The explicit and implicit characteristics of the depth of the fusion method was put forward based on attention mechanism, and through the whole connection network forecast model classification, the impact of different risk levels of large energy events. The model test results show that the prediction F-1 score can reach 0.956, 0.950, and 0.854, respectively, when the prediction time is one day, two days, and three days in the future. The site can choose the prediction time according to the demand. In engineering application, the model can accurately predict large energy events, and the error analysis results show that the prediction accuracy of the model is high, which can meet the needs of the site. The research results can provide a reference for real-time and accurate warnings of coal burst.

Key words: coal burst; time domain prediction; physical index; data characteristics; fusion drive; machine learning

冲击地压灾害由采掘空间煤岩体集聚弹性能的瞬间释放所引起,具有突发、急剧以及猛烈的特点,易造成巷道严重损毁和人员重大伤亡^[1-2]。究其根源,冲击地压的诱发机理不清、冲击灾变信息判识不明以及监测技术精度不足是主要原因^[3]。

相较于冲击地压诱发机理研究的突破可有效指导针对性制定防控措施,冲击地压的监测预警更注重冲击灾变信息的全方位捕捉与灾变前兆信息的有效辨识。冲击灾变信息的捕捉方法主要可分为:①岩石力学方法,主要包括钻屑法^[4-5]、煤岩体变形观测法、煤岩体应力测量法^[6-7]、煤炮及矿震统计法、顶板来压预测法、工作面“见方”预测法等;②地球物理方法,主要包括微震法^[8-10]、电磁辐射法^[11]、声发射(地音)法^[12-14]、电荷感应法^[15]等,通过连续记录煤岩体内出现的动力现象,实时监测冲击危险状态。其中,微震监测方法是目前煤矿开采过程中监测范围最大、信息量最多的方法,我国冲击地压矿井几乎都安装了该类监测系统,已成为煤矿冲击地压区域性监测预警的最主要手段。齐庆新等^[16-17]较早开展了冲击地压的微震监测理论及应用研究,姜福兴等^[9]研发并在国内多个矿井建立了矿山微震监测系统,潘一山等^[18]研制了矿震监测定位系统并进行了现场应用,窦林名等^[19]在冲击地压微震监测和防治方面进行了大量研究,取得了显著成果。此外,冯夏庭、唐春安等采用微震监测技术对金属矿山的岩爆进行监测,取得了较好的效果^[20-22]。

冲击地压危险的预测具体可分为冲击危险性的时序预测与冲击危险区域的空间预测,两者各有侧重,均具有广阔的研究前景。就冲击危险时

序预测而言,诸多学者基于微震监测数据提出基于物理指标的时序预测方法,该方法的特点是致力于寻找冲击地压发生的前兆信息。如田向辉等^[23]提出了一种基于微震能量、频次的定量-趋势冲击危险预警方法,李宏艳等^[24]初步建立了以响应能量异常系数和无响应时间异常系数为指标的冲击危险性微震评价方法。同时,已有学者发现单一物理指标仅代表冲击孕育过程中某些物理特征的变化趋势,导致使用单一物理指标预警准确率难以进一步提升,据此提出采用多参量综合预警的思路,在现场应用获得较好效果^[25-26]。然而,面对日益复杂的采掘工程环境,如“三高一扰动”等复杂环境下的冲击地压机理模型有待进一步完善,而基于物理指标的预测方法往往基于一定的物理假设与力学模型,导致其预测模型的适用性可能大打折扣。此外,在煤矿智能化建设的大背景下,如何高效利用海量的监测数据,充分挖掘其内在的灾变信息特征,以及预警模型的快速更新迭代是制约煤矿冲击地压智能化预警的新的瓶颈。

面对此困境,已有学者展开积极探索。国家重点研发计划“煤矿典型动力灾害风险判识及监控预警技术研究”已布局开展基于人工智能的冲击地压多源多场智能监测预警的阶段性研究^[27],魏立科等^[28]提出了冲击地压灾害风险监察智能分析系统关键技术架构,陈结等^[29]提出了冲击地压“双驱动”智能预警架构与方法。此外,由于岩爆与冲击地压均为矿山典型动力灾害,具有一定的相似性,在监测预警理念与方法上可相互借鉴。就机器学习算法在岩爆预测的研究方面,已有学者结合神经网络、支持向量机、随机森林、

深度学习等人工智能方法对岩爆灾害预测开展初步研究。如孙臣生等^[30]以非线性科学理论为指导,结合BP神经网络对隧道岩爆预测模型进行改进,葛启发、冯夏庭^[31]结合集成学习算法和BP神经网络算法进行了岩爆等级预测模型研究,张航^[32]开展了基于深度学习的隧道微震信号处理及岩爆智能预警研究,李明亮等^[33]结合相关系数与支持向量机算法开展了岩爆烈度等级预测研究,田睿等^[34]开展了基于深度残差神经网络的岩爆预测方法研究,DONG等^[35]结合随机森林算法进行了岩爆等级预测方法研究。岩爆预测领域的相关研究进展可为煤矿冲击地压智能预警研究提供一定借鉴。然而,基于机器学习所构建的模型具有数据集构建成本高、可解释性差、稳定性低等弊端。物理指标驱动和基于数据驱动的预警方法各具优势,如何将两者优势互补,做到物理指标与数据驱动的有效融合,是未来冲击地压预测预警的主要发展方向。

本文以陕西彬长矿区某强冲击危险工作面为背景,统计分析了多次大能量事件发生前物理指标的变化特征并剖析了仅使用物理指标驱动的冲击地压危险预测方法的短板与不足,在此基础上提出采用物理指标与数据特征融合驱动的冲击地压时序预测方法。该预测模型包括数据预处理、特征提取以及预警模型构建三个模块,数据预处理将原有微震监测数据处理为具有特定时间窗的前兆模式序列;特征提取主要包括基于物理指标的显式特征以及基于卷积神经网络的数据隐式特征提取;以此,提出基于注意力机制的显式特征和隐式特征的深度融合方法,并通过全连接网络实现预测模型分类,实现对不同冲击危险等级的大能量事件进行预测,并进行了方法应用及实践。

1 工程背景

彬长矿区某矿主采4煤层,平均厚度9.43m,埋深介于800m~1000m,直接顶为厚度1m~4m的泥岩,基本顶为厚度约10m的细粒砂岩,上覆多层厚度不等的粗粒砂岩。4煤层经鉴定具有强冲击倾向性,其顶、底板分别具有弱冲击倾向性。

该矿生产期间大能量事件频发,并诱发过多起冲击地压显现。如2021年9月29日监测到一起 $1.6 \times 10^5 \text{J}$ 的微震事件,事件发生时地面有明显震感,井下冒顶范围可达55m,冒顶高度约2m,顶板锚杆索脱落、崩断,顶板钢带破断;底板与巷道两帮无明显变形。现场典型显现场景如图1所示。



图1 彬长某矿典型冲击地压显现场景

Fig.1 Typical coal burst scene of a coal mine in Binchang mine area

本文研究对象302工作面为该矿三盘区首采工作面,平均埋深约980m,顶板上方存在多层坚硬砂岩顶板。工作面区域煤层起伏较大,其中部与停采线附近分布有较大幅度的向斜,构造应力水平较高。仅2020年11月至2021年2月回采期间就发生大能量事件(能量大于 10^5J)19起,大能量震源分布及工作面布置如图2所示,综合柱状图如图3所示。

302工作面自2020年6月至2021年5月回采期间监测到多次微震事件,各能级微震事件频次与能量占比见图4。工作面回采过程中能量大于 $5 \times 10^4 \text{J}$ 的事件频次占比仅为3.81%,而能量占比却可达32.67%,可见工作面开采应力调整剧烈,大能量事件对工作面的冲击危险性起到重要影响。同时,工作面监测到的大量微震信息可为本文后续研究提供数据基础。




图2 302工作面布置图

Fig.2 The layout of longwall 302

厚度/m	岩性柱状	岩性名称
10.40		粉砂岩
3.63		中砂岩
3.02		泥岩
3.21		中砂岩
3.00		泥岩
4.50		细砂岩
1.40		泥岩
1.50		中砂岩
17.24		砂质泥岩
1.50		粗砂岩
9.80		砂质泥岩
1.00		粗砂岩
1.00		泥岩
20.08		粗砂岩
13.03		中砂岩
10.79		细砂岩
1.25		泥岩
13.70		4煤
14.67		泥岩

图3 302工作面综合柱状图

Fig.3 Synthesis column around lonwall 302




图4 302工作面回采过程中微震事件频次及能量占比

Fig.4 Microseismic event frequency and energy ratio during the longwall 302 mining

302 工作面回采前采用综合指数法及多因素耦合法对冲击危险进行了预评估。冲击危险综合指数为 0.86，具有强冲击危险性；受大采深（采深接近千米）、断层以及褶曲等地质构造影响，工作面以中等危险区域为主，并多处具有强冲击危险性。为实时掌握工作面冲击危险程度，指导现

场卸压解危工作，有必要进一步开展工作面危险预警方法研究，尤其应提高大能量事件的预警准确率。


2 物理指标驱动的冲击危险预警实例分析

为实现对大能量事件的精准预警，本节首先分析工作面大能量事件发生前常见物理预警指标，如矿震时间信息熵 Q_t 值、矿震活动度 S 值、 a 值、 b 值、 $A(b)$ 值、 Z -map 值、矿震活动标度 ΔF 值、缺震、以及断层总面积 $A(t)$ 值等指标^[25]的变化规律，进而对物理指标驱动的冲击危险预警的有效性进行分析。


如图 5 所示，选取 2020 年 11 月至 2021 年 2 月期间的微震数据进行分析，分别计算了该时间段 19 次大能量事件发生前上述 9 个指标的变化情况（计算时间窗口与滑移步长为 1 天，大能量震源分布见图 2）。

利用物理指标变化特征通常从两方面进行预警（此处分析的时间窗为 3 天，滑移步长为 1 天）：一是趋势预警，如图 5 中各指标存在急剧上升（3 天内指标值连续上升）、急剧下降（3 天内指标值连续下降）、先升后降（3 天内指标值先升后降）、先降后升（3 天内指标值先降后升）等情况；实际应用过程中根据大能量事件发生前各指标“异常变化趋势”开展分析预警。二是阈值预警，通过大能量事件发生前各指标所达到的阈值进行预警，如图 5 中各指标存在局部极值的情况，实际应用过程中可通过各指标值的“局部极值”是否超过阈值进行预警。


通过及时总结各物理指标的变化规律，可有效改善冲击地压预警的准确率。但是仅凭人工进行庞大监测数据统计，难免工程量巨大。此外，基于人工经验对变化趋势、阈值进行标定时，难免由于个人经验等因素产生非必要的误差，例如对指标变化趋势中“上升”还是“下降”的判断，若选择不同的统计窗口可能会得出完全相反的结果；此外，冲击危险程度不同，大能量事件发生前各指标的变化速率也显著不同，凭人工进行判断势必会产生误差，而通过统计方法计算时不同的时间窗口也会产生差异。对采用“阈值”进行预警而言，同样存在采用统计方法与统计窗口的不同，可产生误差甚至导致预警失败。



(a) 大能量事件发生前后 b 值、 Z -map 值、 $A(t)$ 值变化



(b) 大能量事件发生前后 S 值、 $A(b)$ 值、 Q_t 值变化



(c) 大能量事件发生前后 a 值、 ΔF 值、缺震变化

图 5 大能量事件发生前后各物理指标时序变化特征

Fig.5 Temporal variation characteristics of physical indexes before and after the occurrence of high-energy events

为进一步分析采用“趋势”法进行大能量事件预警的有效性。对图 5 中 19 次大能量事件发生前各物理指标的变化率、当日预警值、前 3 天最大值以及变化趋势进行了统计（缺震只包含 1 和 0 两种结果，此处不做统计），各指标变化趋势的统计分布如图 6 右轴与上轴所示。


如图 6 所示，各物理指标的四类变化特征在大能量事件发生之前存在明显的规律性。以图 6(a) 为例，大能量事件发生前 Z -map 值的四类指标变化特征的概率分布存在较为明显的集中分布特征，如当日预警值与变化率的概率峰值集中在 0.3 与 0.4 左右，前 3 天最大值与变化趋势的概率峰值均集中在 0.4 附近；通过统计其它 7 类指标(图

6(b)~图 6(h))也均可获得类似的统计特征。

理论上，通过统计各类指标的变化特征可对大能量事件进行预警。但其实不然，主要原因有：(1)各指标变化特征的概率分布虽具有明显的集中分布特征，但是集中度并不十分突出，如图 6(c) 中 S 值的当日预警值与变化率概率分布曲线较为平缓，在实际判断过程中可能难以得出准确的预警值；(2)由于各物理指标往往基于一定的物理含义，不同地质与采掘环境下指标的敏感性可能存在差异，而井下采掘过程中条件复杂，孕灾环境多变，这会导致物理指标预警的敏感性显著不同，以本文 302 工作面各物理指标统计特征为例(图 6(a)~图 6(h))，在本工作面开采背景下各指标的指

标统计特征存在明显的概率分布差异可证明这一点；(3)井下采掘过程中微震数据时刻产生，积累了大量的数据，如何自动、高效的获取物理指标的前兆信息也面临挑战。

因此，本文后续尝试结合大数据与机器学习方法对预警指标的前兆信息特征进行提取，并提出一种可大规模处理与实时分析的冲击地压时序预测方法。






图 6 大能量事件发生前后各物理指标变化统计特征

Fig.6 Statistical characteristics of physical index changes before and after high-energy events




图 7 物理指标与数据融合驱动的冲击地压预测模型架构

Fig. 7 Coal burst prediction model driven by combined physical index and data characteristics

3 物理指标与数据特征融合驱动的预测方法

3.1 预测模型架构

如图 7 所示，本文提出的预测方法主要包括三个部分：数据预处理、特征提取以及预测模型。数据预处理将微震原始数据包括发生时间、

能量以及震源坐标等转化为用于模型输入的前兆模式序列数据。具体过程为首先将原始数据进行统计分析，计算得到每日的最大能量值和平均能量值，生成以日为最小单位的时间序列数据。指定前兆模式序列长度，生成多前兆模式序列及其标签。

特征提取包括知识驱动的显式特征提取和数据驱动的隐式特征提取。显式特征是指利用物理

指标所计算的相关指标，并基于子集搜索方法确定最优的显式特征指标组合。隐式特征是指利用深度学习从海量数据中所挖掘的隐藏规律信息，本文利用卷积神经网络实现隐式特征提取。

预测模型包括特征融合和分类网络。在特征融合部分，提出了基于注意力机制的显式特征和隐式特征的深度融合方法。在分类网络部分，通过全连接网络拟合实现分类，进而构建冲击地压大能量事件预测模型。

3.2 数据预处理过程

如图 8 所示，为使数据适用于模型的训练和预测，对微震原始数据包括时间、能量以及震源坐标等进行预处理。



图 8 数据预处理过程

Fig.8 The process of data preprocessing

首先，以固定时间窗统计数据，构建时间序列数据集。假设第 i 个时间窗计算得到的数据记录为 m_i ，其可以表示为：

$$m_i = (id, e_{\max}, e_{\text{mean}}, f) \quad (1)$$

其中， id 为时间窗编号， e_{\max} 为时间窗内微

震最大能量， e_{mean} 为时间窗内的微震平均能量， f 为时间窗内微震频次。当数据被划分为 n 个时间窗并对数据进行遍历可得时间数据序列数据集 $M = (m_0, m_1, m_2, \dots, m_{n-1})$ ，进一步根据时间序列数据集 M 构建前兆模式序列，假设其第 i 个前兆模式序列为 s_i ，可表示为：

$$s_i = (m_{ixj}, m_{ixj+1}, m_{ixj+2}, \dots, m_{ixj+p-1}) \quad (2)$$

其中 p 为前兆模式序列长度， j 为采样步长。因此，在 n 个时间窗口且 $n \gg p$ 的前提下，生成的前兆模式序列集可表示为：

$$S = (s_0, s_1, s_2, \dots, s_{D-1}) \quad (3)$$

其中 D 表示前兆模式序列样本在预测时间范围为 N 小时情况下的前兆模式序列数量。

本文的目的是预测大能量事件发生的概率，在利用深度学习模型训练之前，需对不同冲击危险等级的微震能量进行定义及标记，具体对应关系如表 1 所示。此外，便于后续模型训练，需建立前兆模式序列集合对应的标签集合 T 表示为：

$$T = (t_0, t_1, t_2, \dots, t_{D-1}) \quad (4)$$

其中， t_i 为前兆模式序列 s_i 的标签， e_i 为前兆模式序列 s_i 未来 N 小时内最大能量值，取值范围如下：

表 1 标记的微震能量及其与冲击危险的对应关系

Table 1 Labeled microseismic energy and its relation to coal burst risk

t_i	e_i 的取值范围	对应冲击危险等级
0	$e_i \leq 1 \times 10^4 \text{J}$	无
1	$1 \times 10^4 \text{J} \leq e_i < 5 \times 10^4 \text{J}$	弱
2	$5 \times 10^4 \text{J} \leq e_i < 1 \times 10^5 \text{J}$	中等
3	$e_i \geq 1 \times 10^5 \text{J}$	强

3.3 特征提取方法

3.3.1 物理指标的显式特征提取

显式特征是基于物理指标提取的特征指标，本文将第 2 节所述 9 个指标作为候选集，采用反馈式选择方法进行最优指标筛选，其主要思想是动态添加指标，具体利用已有微震数据计算不同指标添加后的模型精度，根据精度判断该指标集合是否最优，步骤如下：给定微震指标集合 $\{a_1, a_2, \dots, a_m\}$ ，将每个指标看作一个候选子集，对 m 个候选指标子集分别进行评价，假定第一轮最优候选集是 $\{a_2\}$ ，则将其作为第一轮选定集；后续在该选定集中加入一个指标，构成了包含两个指标的候选子集，假定这 $m-1$ 个候选子集中 $\{a_2, a_5\}$ 最

优, 则将其作为第二轮选定集; 直到 $r+1$ 轮, 最优候选子集精度低于上一轮, 则将第 r 轮指标集合做为最终的特征选择结果。在本研究中, 一个特征子集优劣的评价标准是特征子集在不同数据

集和不同采样方法上的模型平均准确率。反馈式微震指标选择机制解决了微震指标选择问题, 一定程度上提高了模型预测准确率。

表 2 不同物理指标组合预测的预测 F1 值

Table 2 The F1 values predicted by different physical indicator couples

指标组合	F1 值 (预测未来 3 天)	指标组合	F1 值 (预测未来 3 天)	指标组合	F1 值 (预测未来 3 天)
b 值	0.769	b 值、 $A(b)$ 值	0.753	b 值、 a 值、 Q_t 值	0.786
a 值	0.731	b 值、缺震	0.759	b 值、 a 值、 S 值	0.799
$A(b)$ 值	0.754	b 值、 ΔF 值	0.756	b 值、 a 值、 $A(b)$ 值、 ΔF 值	0.837
缺震	0.749	b 值、 Q_t 值	0.759	b 值、 a 值、 $A(b)$ 值、 Q_t 值	0.826
ΔF 值	0.737	b 值、 S 值	0.769	b 值、 a 值、 $A(b)$ 值、 S 值	0.836
Q_t 值	0.736	b 值、 a 值、 $A(b)$ 值	0.822	b 值、 a 值、 $A(b)$ 值、缺震	0.854
S 值	0.737	b 值、 a 值、缺震	0.793		
b 值、 a 值	0.781	b 值、 a 值、 ΔF 值	0.802		

依据“反馈式选择”的思路, 笔者选择预测时长为 3 天, 选用样本训练集和测试集样本数量比为 1919:822, 选用模型参数见表 5, 依次对不同物理指标组合预测的 F1 值 (计算公式见式 (9), 试验结果见表 2) 进行了比较, 笔者发现使用 b 值、 a 值、 $A(b)$ 值、缺震组成的指标组合预警准确率较高 ($F1=0.854$), 若在此基础上再增添指标预警准确率上升有限, 却会大幅增加运算时间, 对实现该方法的实时预警不利, 因此本文将上述 4 个指标作为优选的显式特征指标, 其物理含义及计算方法如表 3 所示。

3.3.2 数据驱动的隐式特征提取

本文提出基于深度学习的隐式特征提取方法, 该方法利用深度学习中的卷积神经网络实现隐式特征提取。卷积神经网络其隐含层内的卷积核参数共享和层间连接的稀疏性使得卷积神经网络能够以较小的计算量实现隐式特征提取。本文采用的卷积神经网络为 3 层卷积, 总共包含 112 个卷积核, 卷积核大小均为 3×3 , 步长为 1, 填充为 1。经过 3 层卷积后进行扁平化操作, 再通过一个线性层, 即可输出 1000 维度的隐式特征向量, 该向量即为本文所要提取的隐式特征。

表 3 优选的物理指标及其含义

Table 3 Physical indicators and their meanings

指标	计算公式	指标含义
b 值	$b = \frac{\sum_{i=1}^m \lg E_i \sum_{i=1}^m \lg N_i - m \sum_{i=1}^m \lg E_i \lg N_i}{m \sum_{i=1}^m \lg^2 E_i - (\sum_{i=1}^m \lg E_i)^2} \quad [36]$	式中 m 为能级分档总数, $\lg E_i$ 表示第 i 档表示的能级, N_i 表示第 i 档能级的 w 微震总数, a 、 b 值可通过最小二乘法等拟合获得。 a 值可代表某一时段内微震活动水平的高低, a 值越大说明微震发生的频次越高; b 值代表微震活动强度的强弱, b 值越小发生大能量事件的可能性越大。
a 值	$a = \frac{1}{m} \sum_{i=1}^m \lg N_i + b \frac{1}{m} \sum_{i=1}^m \lg E_i \quad [36]$	
$A(b)$ 值	$A(b) = \frac{1}{b} \log \sum_{i=1}^N 10^{bM_i} \quad [37]$	式中 b 表示统计区域内的 b 值, M_i 表示微震事件能级。 $A(b)$ 值综合考虑了某时段内微震事件的频次、能量以及活性等因素, 可直观定量的对微震活性进行评价。
缺震	$B = \frac{\lg e}{\bar{M} - M_0}, \bar{M} = \sum_{i=1}^n \frac{m_i}{n} \quad [38]$	式中 B 为宇津德治公式计算得到的 b 值, \bar{M} 为统计时段内的平均能级, M_0 为初始能级, n 为统计时段内的微震事件

总数。缺震意味着某时段内平均能级 M 比长时间段内平均能级 \bar{M} 偏小，则该区域极有可能发生大能量事件来补充缺少的这部分能级。




图9 预测模型网络架构

Fig.9 Network architecture for prediction model

3.4 预测模型构建

基于 3.2 节创建的训练数据集，可建立目标函数，利用反向传播算法进行网络权重的更新，使得目标函数损失最小化，从而生成预测模型。训练完的模型用于大能量事件预测，即输入前兆模式序列，用于预测未来一段时间内发生大能量事件的等级。本文任务属于时间序列分类任务，其输入是前 N 天的矿震数据，输出为 $N+1$ 天的冲击地压等级。模型整体网络架构如图 9 所示，包括特征提取、特征融合、分类网络三部分。

3.4.1 特征融合

在预测模型中，需将显式特征和隐式特征进行深度融合。由于显示特征和隐式特征的复杂性和异构性，导致简单的加权特征融合方法并不适用，因此本文利用深度学习中的注意力机制法实现特征融合，并实现显式特征和隐式特征内每个维度的加权。

如图 10 所示，首先，将显式特征 F^e 和隐式特征 F^i 进行合并，从而得到初始特征向量 F^s 。

$$F^s = [F^e, F^i] \quad (5)$$

其中，显式特征向量和隐式特征向量 $F^e \in R^{d_1}$ $F^i \in R^{d_2}$ 的维度分别为 d_1 和 d_2 ，融合特征向量 $F^s \in R^{(d_1+d_2)}$ 的维度为 d_1+d_2 。在注意力机制中，隐式特征和显式特征的权重向量记为 $V^e \in R^{d_1}$ ， $V^i \in R^{d_2}$ ，其计算方法如下：

$$\begin{cases} V^e = H(F^s \cdot M^e) \\ V^i = H(F^s \cdot M^i) \end{cases} \quad (6)$$

其中， $M^e \in R^{(d_1+d_2) \times d_2}$ ， $M^i \in R^{(d_1+d_2) \times d_1}$ 是两个可学习参数矩阵， $H(x)$ 为激活函数 $\frac{1}{1+e^{-x}}$ 。权重向量 V^e 和 V^i 的每一个维度对应 F^e 和 F^i 每一个特征维度的权重。最后，计算最终的融合特征向量 F^f 可表示为：

$$F^f = [F^e \odot V^e, F^i \odot V^i] \quad (7)$$

其中， \odot 表示哈达玛积，融合后的特征用于后续分类网络输入。




图 10 预测模型中显式与隐式特征融合示意图

Fig.10 Schematic of explicit and implicit feature fusion in

3.4.2 分类网络

预测模型中的分类网络包括一个全连接层和一个激活函数，在深度学习中，全连接层起到分类器的作用，其可以将学到的分布式特征表示映射到样本标记空间中，本模型中全连接层由 2000 个神经元组成。然后，利用激活函数进行归一化处理，得到每个类别的概率，概率最大的类别即为输出类别，即发生该能量区间（能量区间划分见表 1）的大能量事件的概率最大。

3.4.3 模型训练

考虑到实际数据中大能量事件发生的次数较少，导致标签为小能量事件的数据远多于大能量事件的数据，进一步导致训练数据集样本不平衡。若使用传统的深度学习模型训练方法，则会导致模型在分类时偏向学习样本较多的一类的问题。针对该问题，本文采用“再放缩”的思想，在训练过程中，模型根据批样本和总体样本的分布情况，动态调整各类别在计算损失的权重。在网络训练中，使用加权交叉熵损失函数计算模型的损失值，进而不断更新神经网络模型中的参数，使得模型在训练数据集上的损失最小化。此外，在冲击地压预测过程中，本文在损失函数中添加了各类别的学习权重 z_c 和 z_1 ，通过调整大能量事件的学习权重，使得该模型可以更偏向大能量样本的预测，以降低大能量事件的漏报率。本文的加权交叉熵损失 L 可表示为：

$$\left\{ \begin{array}{l} L = \frac{1}{N} \sum_{i=1}^N L_i \\ L_i = \frac{1}{W} \sum_c -z_c \cdot w_c \cdot y_{ic} \cdot \ln(p_{ic}) \\ W = \sum_c w_c \end{array} \right. \quad (8)$$

其中， L_i 表示第 i 个前兆模式序列的损失值， N 表示前兆模式序列数量， M 表示能量等级类别数量， z_c 表示类别 c 的学习权重， w_c 表示类别 c 的样本分布权重，若第 i 个前兆模式序列的标签为 c ，则 $y_{ic}=1$ ，否则 $y_{ic}=0$ ； p_{ic} 为观测样本 i 为类别 c 的预测概率。上述方法有效改善了微震数据不平衡的问题，加快了模型收敛速度，并提高了模型预测准确率。此外，我们通过深度学习中常用的“dropout”方法来避免模型过拟合问题。

4 模型训练及预测实验

4.1 评价指标

本实验利用混淆矩阵记录模型预测结果（见

表 4）。对于每个类别，若实际情况为真，且预测为真，则记作 TP（True Positive）；若实际情况为真，且预测为假，则记为 FN（False Negative）。若实际情况为假，且预测为假，则记 TN（True Negative）；若实际情况为假，且预测为真，则记为 FP（False Positive）。

在模型评估中，本文使用 F1 值作为评估指标。F1 值能综合考虑查准率（Precision）和召回率（Recall），计算公式如下：

$$F1 = 2 \frac{P \times R}{P + R} \quad (9)$$

其中， P 和 R 分别表示查准率和召回率，计算方法为：

$$P = \frac{TP}{TP + FP} \quad (10)$$

$$R = \frac{TP}{TP + FN} \quad (11)$$

表 4 记录预测结果的混淆矩阵

Table 4 The confusion matrix of the predicted results

		实际情况	
		真	假
预测情况	真	“真-真”（TP）	“真-假”（FP）
	假	“假-真”（FN）	“假-假”（TN）

4.2 模型训练及预测

图 11 为 302 工作面 2020-11-1 至 2021-3-1 回采期间微震日最大能量分布情况，受复杂采掘环境等因素影响，工作面多数情况下处于中等冲击危险状态，甚至局部时间段频繁发生 10^5J 以上的大能量事件。一方面说明在 302 工作面实施大能量事件预测的必要性，另一方面丰富的数据可满足预警模型训练的需要。本节以该时间段共 131 天的微震数据为样本进行训练和测试，具体将数据以 7: 3 的比例进行随机划分，生成训练集和测试集。在预测未来 1 天、2 天、3 天情况下，生成的训练集和测试集样本数量比分别为 1952:836，1936:829，1919:822。后续在预警效能分析时采用训练集数据完成模型训练后，使用预警模型对测试集中的大能量事件进行预测以检验预测模型的有效性。数据预处理参数设置如表 5 所示。设置模型训练时的批大小为 16，最大训练轮次为 130，学习率为 0.0001。不同预测实验中训练集与测试集的目标函数损失值变化见图 12，实验过程中当目标函数损失值连续 20 轮不降低或者 F1 值连续 20 轮不上升即停止训练。





图 11 302 工作面 2020-11-1 至 2021-3-1 回采期间日最大能量分布

Fig.11 Maximum daily energy distribution during longwall 302 retreat from 2020-11-1 to 2021-3-1


表 5 数据预处理参数取值

Table 5 The parameter value of warning model


参数	参数含义	取值
I	计算时间序列数据所用的时间窗 (单位: 小时)	1
p	前兆模式序列长度 (即前兆模式序列所含时间序列的个数)	336
s	前兆模式序列采样步长	1
N	预测未来的时长 (单位: 小时)	24/48/72



(a) 预测未来 1 天



(b) 预测未来 2 天



(c) 预测未来 3 天

图 12 不同预测实验中目标损失函数损失值变化

Fig. 12 The loss value of target loss function changes in different prediction experiments

冲击地压危险实时预测有助于保障人员及时撤出, 灾情及时处理及指导卸压防控措施等。因此, 预测冲击地压或大能量事件何时、何地以及能级大小便是关键所在。针对预测冲击地压危险“何时”发生, 为验证本文提出的融合驱动的冲击地压预测方法的预测效能, 采用训练完成的预测模型对未来一定时间内 (预测 1 天、2 天及 3 天) 的大能量事件进行预测, 并采用混淆矩阵分析其 F1 值, 预测结果的混淆矩阵以及 F1 值如表 6~表 8 所示。

表 6 预测未来 1 天的预测结果混淆矩阵

Table 6 The predicted results in the future one day

预测 1 天		真实情况			
		无	弱	中	强
预测情况	无	65	3	0	0
	弱	0	202	7	0
	中	0	12	370	3

况	强	0	4	10	160
F1=0.956					

表 7 预测未来 2 天的预测结果混淆矩阵

Table 7 The predicted results in the future two day

预测 2 天		真实情况			
		无	弱	中	强
预测情况	无	50	3	0	0
	弱	0	95	6	0
	中	0	5	381	5
	强	0	4	15	265
F1=0.950					

表 8 预测未来 3 天的预测结果混淆矩阵

Table 8 The predicted results in the future three day

预测 3 天		真实情况			
		无	弱	中	强
预测情况	无	34	7	1	0
	弱	0	29	0	0
	中	0	8	344	2
	强	0	19	24	354
F1=0.854					

由表 6~表 8 可知，预测实验 F1 值最高可达 0.956，最低为 0.854，可见本模型对冲击危险的预测效果较好。因此，现场选用本模型进行预测时，可根据现场危险情况（采用综合指数法等可提前预估采掘工作面整体冲击危险等级）确定预测时长：若提前预测采掘工作面冲击危险等级较高，例如本文实验的 302 工作面，大能量事件频发（见图 11），冲击危险性较高，需实施大量的卸压工程，需耗费大量时间，因此需尽量提前预测危险，此时选用预测时长 3 天为宜；若预测现场预估的整体冲击危险等级较低或者预估的冲击危险等级较高同时需采取的卸压工程量较小时，选用预测时长 1 天为宜。

通过本实验不难发现，在工作面采掘过程中可保证微震数据正常采集情况下，使用本模型可有效预测冲击地压危险；未来在此基础上，笔者将进一步开展实验，以探求本模型在预测时长更短时能否精准预测危险的可能性。在此过程中，需保证模型在微震数据不足的情况下获得较好的训练结果，拟解决的途径主要有：（1）试验本模型在小样本情况下的适应性，适时调整参数，以期获得较好的训练结果；（2）通过云平台等建立冲击地压事件数据库，采用大批量的模型调整模型参数，使预测模型具有更强的泛化能力；（3）研究基于迁移学习的模型泛化方法，使模型具有较强的自适应及调整能力，实现模型参数的及时

更新迭代与调整。

4.3 工程应用性能测试

为进一步评估模型总体性能，本节进行工程应用测试。实验设计思路如下：① 利用 302 工作面前 110 天的数据训练初始模型，然后预测第 111 到 113 天内发生各能量等级事件的概率；② 模拟时间推移 1 天，对模型进行训练并更新，具体采用前 111 天的数据重新训练，预测第 112 到 114 天内发生各能量等级事件的概率；③ 再模拟时间推移 1 天，对模型再进行更新，利用前 112 天的数据重新训练，预测第 113 到 115 天内的冲击危险性；以此类推，共进行了 50 次模拟预测。如表 9 所示，在 2021-2-27 至 2021-4-17 这 50 天内，302 共发生 6 起 10^5J 以上的大能量事件。对比实际与预测危险等级不难发现，本模型通过每日训练更新迭代后准确预测了 6 起大能量事件中的 5 起，将另外 1 起具有强冲击危险性的大能量事件预测为中等冲击危险。为进一步对模型的工程应用效果进行分析，统计了 50 天模拟预测结果中误差分布如图 13 所示，不难发现 50 次预测中 26 次预测结果准确，20 次预测结果为误差 1 级（例如实际危险等级为弱而预测等级为中等，两者相差 1 级），仅有 4 次预测结果误差等级可达 2 级。工程应用结果表明本融合驱动预测模型可对强冲击危险尤其是大能量事件提前预测，进而为针对性防控措施制定提供重要参考。

表 9 工程应用中实际与预测危险等级对比

Table 9 The comparison of actual and predicted risk levels in engineering applications

日期	当日最大能量/J	实际危险等级	预测危险等级
2021/3/16	331771.9375	强	中等
2021/3/23	101247.9219	强	强
2021/4/8	144103.6094	强	强
2021/4/15	446221.3124	强	强
2021/4/16	160679.7355	强	强
2021/4/18	163858.8447	强	强




图 13 工程应用中预测结果误差分布

Fig.13 The error distribution of prediction results in engineering applications

5 结论及展望

(1) 通过实例分析了物理指标驱动用于冲击地压危险预测的不足与短板。结果表明物理指标主要利用冲击危险来临前各物理指标的异常变化进行预警,如典型的“趋势法”与“阈值法”,而二者的概率分布特征分析表明难以得出明显的统计特征;各物理指标往往仅适用于特定采掘条件,模型泛化与跨场景预测效率较差;物理指标往往通过特定统计数据得出,难以结合大数据分析技术进行模型更新及实时分析。

(2) 提出物理指标与数据特征融合驱动的预测模型。预测模型包括数据预处理、特征提取以及预测模型融合。数据预处理将原有微震监测数据处理为具有特定时间窗的前兆模式序列;特征提取主要包括基于物理指标的显式特征以及基于卷积神经网络的数据隐式特征提取;提出基于注意力机制的显式特征和隐式特征的深度融合方法,并通过全连接网络实现预测模型分类,实现对不同冲击危险等级的大能量事件进行预测。

(3) 采用混淆矩阵对预测结果进行分析,预测实验结果表明预测时长为未来1天、未来2天以及未来3天时预测F1值分别可达0.956,0.950,0.854,现场可根据需求选用预测时长;工程应用结果表明融合驱动模型可对大能量事件准确预测,误差分析结果表明模型预测准确率较高,可满足现场需求。

煤岩动力灾害的智能化预测是煤矿智能化建设的重要组成部分,而机器学习与大数据技术是实现智能化预测与提高预测准确率的关键所在。本文提出的基于物理指标与数据特征融合驱动的预测方法仅是将机器学习技术用于冲击地压危险预测的初步尝试,经笔者粗略总结,未来仍有面向不同煤矿预测模型迁移、小样本数据情况下的机器学习模型构建以及多源异构数据融合等关键技术问题需进行攻关。

参考文献 (References):

[1] 窦林名,田鑫元,曹安业,等. 我国煤矿冲击地压防治现状与难题[J]. 煤炭学报,2022,47(1):152-171.
DOU Linming, TIAN Xinyuan, CAO Anye, et al. Present situation and problems of coal mine rock burst prevention and control in China[J]. Journal of China Coal Society,2022,47(1):152-171.
[2] 袁亮. 煤矿典型动力灾害风险判识及监控预警技术研究进展[J]. 煤炭学报,2020,45(5):1557-1566.
YUAN Liang. Research progress on risk identification, assessment, monitoring and early warning technologies of typical dynamic hazards in

coal mines[J]. Journal of China Coal Society,2020,45(4):1557-1566.

[3] 袁亮,姜耀东,何学秋,等. 煤矿典型动力灾害风险精准判识及监控预警关键技术研究进展[J]. 煤炭学报,2018,43(2):306-318.

YUAN Liang, JIANG Yaodong, HE Xueqiu, et al. Research progress of precise risk accurate identification and monitoring early warning on typical dynamic disasters in coal mine[J]. Journal of China Coal Society,2018,43(2):306-318.

[4] GU Shitan, WANG Chunqiu, Jiang Bangyou, et al. Field test of rock burst danger based on drilling pulverized coal parameters[J]. Disaster Advances,2012,5.

[5] 国家市场监督管理总局,中国国家标准化管理委员会. 冲击地压测定、监测与防治方法 第6部分: 钻屑监测方法. [S], 2019.

[6] 王健达,秦凯,邓志刚,等. 基于光纤光栅采动应力测试的冲击地压预警技术研究[J]. 煤炭科学技术,2019,47(6):126-132.

WANG Jianda, QIN Kai, DENG Zhigang, et al. Study on early warning technology of rock burst based on mining stress monitoring by fiber-grating[J]. Coal Science and Technology,2019,47(6):126-132.

[7] 国家市场监督管理总局,中国国家标准化管理委员会. 冲击地压测定、监测与防治方法 第7部分: 采动应力监测方法. [S],2019.

[8] 蔡武,窦林名,李振雷,等. 微震多维信息识别与冲击矿压时空预测——以河南义马跃进煤矿为例[J]. 地球物理学报,2014,57(8):2687-2700.

CAI Wu, DOU Linming, LI Zhenlei, et al. Microseismic multidimensional information identification and spatio-temporal forecasting of rock burst: A case study of Yima Yuejin coal mine, Henan, China[J]. Chinese Journal of Geophysics,2014,57(8):2687-2700.

[9] 姜福兴,杨淑华,陈云海,等. 煤矿冲击地压的微地震监测研究[J]. 地球物理学报,2006(5):1511-1516.

JIANG Fuxing, YANG Shuhua, CHENG Yunhai, et al. A study on microseismic monitoring of rock burst in coal mine[J]. Chinese Journal of Geophysics,2006(5):1511-1516.

[10] 国家市场监督管理总局,中国国家标准化管理委员会. 冲击地压测定、监测与防治方法 第4部分: 微震监测方法. [S],2019.

[11] 国家市场监督管理总局,中国国家标准化管理委员会. 冲击地压测定、监测与防治方法 第8部分: 电磁辐射监测方法. [S],2021.

[12] 王常彬,曹安业,井广成,等. 单轴受载下岩体破裂演化特征的声发射CT成像[J]. 岩石力学与工程学报,2016,35(10):2044-2053.

WANG Changbin, CAO Anye, JING Guangcheng, et al. Evolution characteristics of rock under uniaxial by combining acoustic emission and CT image[J]. Chinese Journal of Rock Mechanics and Engineering,2016,35(10):2044-2053.

[13] 贺虎,窦林名,巩思园,等. 冲击矿压的声发射监测技术研究[J]. 岩土力学,2011,32(4):1262-1268.

HE Hu, DOU Linming, GONG Siyuan, et al. Study of acoustic emission monitoring technology of rockburst[J]. Rock and Soil Mechanics,2011,32(4):1262-1268.

- [14] 国家市场监督管理总局,中国国家标准化管理委员会. 冲击地压测定、监测与防治方法 第5部分:地音监测方法. [S],2019.
- [15] 潘一山,唐治,李忠华,等. 不同加载速率下煤岩单轴压缩电荷载应规律研究[J]. 地球物理学报,2013,56(3):1043-1048.
- PAN Yishan, TANG Zhi, LI Zhonghua, et al. Research on the change inducing regularity of coal rock at different loading rate in uniaxial compression tests[J]. Chinese Journal of Geophysics,2013,56(3):1043-1048.
- [16] 夏永学,康立军,齐庆新,等. 基于微震监测的5个指标及其在冲击地压预测中的应用[J].煤炭学报,2010,35(12):2011-2016.
- XIA Yongxue, KANG Lijun, QI Qingxin, et al. Five indexes of microseismic and their application in rock burst forecastion[J]. Journal of China Coal Society,2010,35(12):2011-2016.
- [17] 齐庆新,欧阳振华,赵善坤,等. 我国冲击地压矿井类型及防治方法研究[J]. 煤炭科学技术,2014,42(10):1-5.
- QI Qingxin, OUYANG Zhenhua, ZHAO Shankun, et al. Study on types of rock burst mine and prevention methods in China[J]. Coal Science and Technology,2014,42(10):1-5.
- [18] 潘一山,赵扬锋,官福海,等. 矿震监测定位系统的研究及应用[J]. 岩石力学与工程学报,2007(5):1002-1011.
- PAN Yishan, ZHAO Yangfeng, GUAN Fuhai, et al. Study on rockburst monitoring and orientation system and its application.[J]. Chinese Journal of Rock Mechanics and Engineering,2007(5):1002-1011.
- [19] 窦林名,牟宗龙,陆菜平,等. 采矿地球物理理论与技术[M]. 北京: 科学出版社,2014.
- [20] 徐奴文,唐春安,沙椿,等. 锦屏一级水电站左岸边坡微震监测系统及其工程应用[J]. 岩石力学与工程学报,2010,29(5):915-925.
- XU Nuwen, TANG Chunan, SHA Chun, et al. Microseismic monitoring system establishment and its engineering applications to left bank slope of Jinping I hydropower station.[J]. Chinese Journal of Rock Mechanics and Engineering,2010,29(5):915-925.
- [21] 陈炳瑞,冯夏庭,曾雄辉,等. 深埋隧洞 TBM 掘进微震实时监测与特征分析[J]. 岩石力学与工程学报,2011,30(2):275-283.
- CHEN Bingrui, FENG Xiating, ZENG Xionghui, et al. Real-time microseismic monitoring and its characteristic analysis during TBM tunneling in deep-buried tunnel[J].Chinese Journal of Rock Mechanics and Engineering,2011,30(2):275-283.
- [22] 刘建坡,石长岩,李元辉,等. 红透山铜矿微震监测系统的建立及应用研究[J]. 采矿与安全工程学报,2012,29(1):72-77.
- LIU Jianpo, SHI Changyan, LI Yuanhui, et al. Studies on establishment and application of microseismic monitoring system in Hongtoushan copper mine[J]. Journal of Mining and Safety Engineering,2012,29(1):72-77.
- [23] 田向辉,李振雷,宋大钊,等. 某冲击地压频发工作面微震冲击前兆信息特征及预警方法研究 [J]. 岩石力学与工程学报,2020,39(12):2471-2482.
- TIAN Xianghui, LI Zhenlei, SONG Dazhao, et al. Study on microseismic precursors and early warning methods of rockbursts in a working face[J]. Chinese Journal of Rock Mechanics and Engineering,2020,39(12):2471-2482.
- [24] 李宏艳,莫云龙,孙中学,等.基于响应能量和无响应时间的冲击危险性动态评价技术[J]. 煤炭学报,2019,44(9):2673-2681.
- [25] CAI Wu, DOU Linming, ZHANG Min, et al. A fuzzy comprehensive evaluation methodology for rock burst forecasting using microseismic monitoring[J]. Tunnelling and Underground Space Technology,2018,80:232-245
- [26] 窦林名,周坤友,宋士康,等. 煤矿冲击矿压机理、监测预警及防控技术研究[J]. 工程地质学报,2021,29(4):917-932.
- DOU Linming, ZHOU Kunyou, SONG Shikang, et al. Occurrence mechanism, monitoring and prevention technology of rockburst in coal mines[J]. Journal of Engineering Geology,2021,29(4):917-932.
- [27] 袁亮. 煤矿典型动力灾害风险判识及监控预警技术“十三五”研究进展[J]. 矿业科学学报,2021,6(1):1-8.
- YUAN Liang. Risk identification, monitoring and early warning of typical coal mine dynamic disasters during the 13th Five-Year Plan period[J]. Journal of Mining Science and Technology,2021,6(1):1-8.
- [28] 魏立科,姜德义,王翀,等. 煤矿冲击地压灾害风险监控智能分析系统关键技术架构研究[J]. 煤炭学报: 1-12.
- WEI Like, JIANG Deyi, WANG Chong, et al. Key technological architecture of the intelligent monitoring-analysis system for coal mine rockburst risk supervision[J]. Journal of China Coal Society: 1-12.
- [29] 陈结,杜俊生,蒲源源,等. 冲击地压“双驱动”智能预警架构与工程应用[J]. 煤炭学报, 2022, 47(2): 3397-3407.
- CHEN Jie, DU Junsheng, PU Yuanyuan, et al. “Dual-driven” intelligent pre-warning framework of the coal burst disaster in coal mine and its engineering application[J]. Journal of Mining Science and Technology, 2022, 47(2): 3397-3407.
- [30] 孙臣生. 基于改进 MATLAB-BP 神经网络算法的隧道岩爆预测模型[J]. 重庆交通大学学报(自然科学版),2019,38(10):41-49.
- SUN Chensheng. A prediction model of rock burst in tunnel based on the improved MATLAB-BP neural network[J]. Journal of Chongqing Jiaotong University(Natural Science),2019,38(10):41-49.
- [31] 葛启发,冯夏庭. 基于 AdaBoost 组合学习方法的岩爆分类预测研究[J]. 岩土力学,2008(4):943-948.
- GE Qifa, FENG Xiating. Classification and prediction of rockburst using AdaBoost combination learning method[J]. Rock and soil Mechanics,2008(4):943-948.
- [32] 张航. 基于深度学习的隧道微震信号处理及岩爆智能预警研究[D]. 成都理工大学,2020.
- ZHANG Hang. Research on microseismic signal LI Hongyan, MO Yunlong, SUN Zhongxue, et al. Dynamic evaluation technology of rock burst based on response energy and non-response time[J]. Journal of

China Coal Society, 2019, 44(09): 2673-2681.

[33] 李明亮,李克钢,秦庆词,等. 岩爆烈度等级预测的机器学习算法模型探讨及选择[J]. 岩石力学与工程学报,2021,40(S1):2806-2816.

LI Mingliang, LI Kegang, QIN Qingci, et al. Discussion and selection of machine learning algorithm model for rockburst intensity grade prediction[J]. Chinese Journal of Rock Mechanics and Engineering,2021,40(S1):2806-2816.

[34] 田睿,孟海东,陈世江,等. 基于深度神经网络的岩爆烈度分级预测[J]. 煤炭学报,2020,45(S1):191-201.

TIAN Rui, MENG Haidong, CHEN Shijiang, et al. Prediction of intensity classification of rockburst based on deep neural network[J].Journal of China Coal Society,2020,45(S1):191-201.

[35] DONG Longjun, LI Xibing, PENG Kang. Prediction of Rockburst Classification Using Random Forest[J]. Transaction of Nonferrous Metals Society of China,2013,23(2):472-477.

[36] Gutenberg B,Richer CF. Frequency of Earthquakes in California*[J]. Bulletin of the Seismological Society of America,1944,34(4):185-188.

[37] 吴佳翼,曹学锋. 地震活动性的定量化问题[J]. 地震,1983(6):13-16,22.

WU Jiayi, CAO Xuefeng. Quantification of seismicity[J]. Earthquake, 1983(6):13-16,22.

[38] 卫鹏飞. 华北缺震曲线[J]. 地震研究,1980(4):144-148.

WEI Pengfei. North China seismic curve[J]. Journal of Seismological Research,1980(4):144-148.