

急倾斜巨厚煤层掘进巷道冲击危险时序及等级智能预测

崔 峰^{1,2,3}, 宗 程^{1,2}, 来兴平^{1,2}, 何仕凤^{1,2}, 张随林^{1,2}, 贾 冲^{1,2}

(1. 西安科技大学 能源学院, 陕西 西安 710054; 2. 西安科技大学 教育部西部矿井开采及灾害防治重点实验室, 陕西 西安 710054;

3. 自然资源部煤炭资源勘查与综合利用重点实验室, 陕西 西安 710021)

摘 要: 实现煤矿冲击地压智能预警对于保障矿井安全作业具有重要意义。以新疆某矿急倾斜巨厚煤层的掘进巷道冲击地压发生时序智能分级预测作为背景, 分析了急倾斜巨厚煤层巷道掘进期间各微震信息指标的时空演化规律, 利用遗传算法 (Genetic Algorithm, GA) 优化的随机森林 (Random Forest, RF) 对预测冲击发展趋势性能较高的多项指标进行了优选, 基于相空间重构技术 (Phase Space Reconstruction, PSR) 将数据映射至高维空间进行重构, 结合长短期记忆神经网络 (Long Short-Term Memory, LSTM) 训练学习高维度数据特征, 构建了基于深度学习与多元混沌时序的急倾斜巨厚煤层冲击地压预测模型 (PSR-LSTM), 依据现场实际对模型的预测性能进行了评价。结果表明: 急倾斜巨厚煤层巷道掘进下各微震信息指标对冲击预警的敏感性较强, 彼此之间具有显著的相关性; 优选出了预测冲击发展趋势性能较高的 6 项微震信息指标; 多项指标的时间序列具有混沌特性, 经过相空间重构后再进行 LSTM 学习训练, 可有效增强模型的数据利用率与预测精度, 所构建的 PSR-LSTM 模型在指定预测时长为 1 d 的情况下, 预测准确率可达 0.913 5、 F_1 值可达 0.911 6, 均优于未经重构的 LSTM 模型。模型较好地预测了急倾斜巨厚煤层掘进巷道发生冲击危险的时序趋势及危险等级, 研究方法可为急倾斜巨厚煤层掘进巷道冲击地压发生的智能预测预警提供借鉴与参考。

关键词: 急倾斜巨厚煤层; 掘进巷道; 冲击地压; 多元混沌时序; 相空间重构; 深度学习

中图分类号: TP18; TD324 **文献标志码:** A **文章编号:** 0253-9993(2025)02-0845-17

Intelligent prediction of time series and grade of rock burst in steeply inclined ultra-thick coal seam excavation roadway

CUI Feng^{1,2,3}, ZONG Cheng^{1,2}, LAI Xingping^{1,2}, HE Shifeng^{1,2}, ZHANG Suilin^{1,2}, JIA Chong^{1,2}

(1. College of Energy Engineering, Xi'an University of Science and Technology, Xi'an 710054, China; 2. Key Laboratory of Western Mines and Hazard Prevention of China Ministry of Education, Xi'an University of Science and Technology, Xi'an 710054, China; 3. Key Laboratory of Coal Resources Exploration and Comprehensive Utilization, Ministry of Natural Resources, Xi'an 710021, China)

Abstract: Realizing the intelligent warning of rock burst in coal mine is of great significance to ensure the safety of mine operation. Based on the intelligent classification prediction of rock burst occurrence time series in roadway of steeply inclined ultra-thick coal seam in a mine in Xinjiang, the spatio-temporal evolution of each microseismic information index during roadway excavation was analyzed. The Random Forest optimized by Genetic Algorithm (GA) was used. RF se-

收稿日期: 2023-12-28 策划编辑: 郭晓炜 责任编辑: 宫在芹 DOI: 10.13225/j.cnki.jccs.2023.1762

基金项目: 国家自然科学基金资助项目 (51874231); 陕西省创新能力支撑计划资助项目 (2020KJXX-006); 陕煤联合基金资助项目 (2019JLZ-04)

作者简介: 崔 峰 (1986—), 男, 河南新乡人, 教授, 博士。E-mail: cuifeng9418@163.com

引用格式: 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.



移动阅读

lects a number of indicators with high performance in predicting the development trend of impact. Based on the Phase Space Reconstruction (PSR) technology, the data is mapped to the high-dimensional space for reconstruction. LSTM is trained to learn the characteristics of high dimensional data, and a prediction model of steeply inclined ultra-thick coal seam rock burst (PSR-LSTM) based on deep learning and multiple chaotic time series is constructed. The results show that each microseismic information index is sensitive to shock warning and has significant correlation with each other. Six microseismic information indexes with high performance in predicting the development trend of shock are selected. The time series of multiple indicators has chaotic characteristics. After phase space reconstruction, LSTM learning and training can effectively enhance the data utilization rate and prediction accuracy of the model. When the prediction time of the constructed PSR-LSTM model is specified as 1 day, the prediction accuracy can reach 0.913 5, and the F_1 value can reach 0.911 6. All of them are better than the unreconstructed LSTM model. The model can well predict the time series trend and danger level of the rock burst in the excavation roadway of steeply inclined ultra-thick coal seam. The research method can provide reference for the intelligent prediction and early warning of rock burst in the excavation roadway of steeply inclined ultra-thick coal seam.

Key words: steeply inclined ultra-thick coal seam; excavation roadway; rock burst; multivariate chaotic time series; phase space reconstruction; deep learning

0 引 言

近年来,随着我国煤炭资源的开采重心逐渐由浅部开采向深部开采方向转移,受限于深部矿井复杂的地质环境、原岩应力高以及冲击地压防控经验不足等因素,当工作面前方煤岩受频繁的高强度开采扰动影响,极易诱发冲击地压等动力灾害^[1],为有效防治冲击地压造成的破坏性灾害,实现有效的预警是当前的工作重点^[2]。

冲击地压具有高度不确定性和不可预知性,因此对于易发生冲击地压的矿井,厘清时空特征、全方位获取灾变的前兆信息对于冲击地压的防治具有极其重要的意义^[3]。目前,冲击地压监测预警领域,已有学者做了大量的研究,主流的预警手段有微震法、地音法、钻屑法等。其中,微震法能够实现煤岩体破裂的连续监测而被广泛应用^[4],齐庆新等^[5]将微震监测理论应用到冲击地压监测防治中;窦林名等^[6]应用微震监测法构建了冲击危险性动态预测评价的震动波 CT 探测技术并给出了各指标判别准则;姜福兴等^[7]通过对厚煤层冲击地压灾害的研究,构建了复合型厚煤层“震-冲”型动力灾害力学模型;田向辉等^[8]提出了一种定量-趋势冲击危险预警方法;丛利等^[9]提出了一种基于动静载冲击地压危险叠加的综合预警方法;崔峰等^[10]研究指出加卸载响应比指标有着较好预警效能。可以看出众学者针对微震监测法,进行了大量实践并取得了显著的效果。随着采掘环境日益复杂,结合煤矿智能化建设的需求,将深度学习等人工智能方法引入采矿及岩土工程动力灾害研究领域,融合智能模型提取动力灾害特征信息,建立多元数据驱动的预警模

型来解决冲击地压的复杂性和非线性问题,可以更好地把握深井冲击地压动态。

就人工智能与岩石力学交叉领域方面,大量学者进行了积极的探索。赵洪波等^[11]将冲击地压看做一时间序列过程,提出冲击地压预测的 PSO-SVM 模型,建立了冲击地压序列之间的非线性关系;谭云亮等^[12]基于冲击地压 AE 时间序列,建立了小波神经网络预测模型;AHMAD 等^[13]发现随机树法预测冲击地压分类等级上可以达到较高的准确率;田睿等^[14]开展了基于深度残差神经网络的岩爆预测方法研究;DONG 等^[15]结合随机森林算法进行了岩爆等级预测方法研究;考虑到冲击地压发生过程具有混沌特征,陶慧等^[16]提出基于多变量时间序列相空间重构 GRNN 模型,使用多状态量重构后的相空间作为输入,完成了冲击地压预测实验;崔峰等^[17]开展了基于相空间重构与深度学习的冲击地压 b 值序列趋势研究,为冲击地压 b 值在时间上的演化特征提供了借鉴;刘慧敏等^[18]进一步使用 CNN-LSTM 集成学习方法得到了岩爆未来状态的预测值。

上述学者从能量、频次、 b 值等多参量响应规律和特征入手,基本厘清了冲击地压发生的时空演化规律,并深入研究了基于数据驱动的预警方法,研究成果对于冲击地压智能化监测预警具有重要意义。然而,受限于冲击地压等地质灾害事件的复杂性和多样性,现有的深度学习算法存在特征提取困难、模型解释性差、泛化能力弱等弊端。模型在未知数据上易出现过拟合或欠拟合的情况,从而难以确定预测结果的可信度和掌握冲击地压机理。并且大多学者都是以近水平或缓倾斜煤层为研究对象,针对急倾斜巨厚煤

层这种煤岩赋存环境极其复杂的地质条件,对于其冲击地压前兆特征挖掘和发生时序智能分级预测的研究较少。如何从急倾斜巨厚煤层冲击地压的监测数据中高效提取出有效信息,增强预警模型泛化能力和预测准确率是当前亟待解决的重点问题。

对于急倾斜巨厚煤层的冲击地压智能预警,笔者以新疆某矿急倾斜巨厚煤层掘进巷道为背景,提出了一种深度学习与多元混沌时序的数据融合驱动预测方法。统计分析了急倾斜巨厚煤层掘进巷道的冲击地压前兆微震信息指标的演化规律;引入相空间重构技术(PSR)将优选的指标时序数据映射到高维空间进行重构;考虑到冲击地压时空演化的动态性和非线性,选用 LSTM 模型学习各指标时间序列特征,实现对未来冲击危险等级的预测分类。构建的模型可弥补微震信息指标的不足,提取出冲击地压多指标下隐含数据特征,最终达到提高预警准确率的目的。

1 工程背景

新疆某矿为急倾斜 $45^{\circ}\sim 87^{\circ}$ 巨厚煤层开采的典型煤矿,在山脉等地质构造与断层长期影响作用下,该矿急倾斜煤层呈现出独特的大角度褶曲与扭转的构造特征,地质环境极其复杂,其急倾斜煤岩赋存特征如图 1 所示。

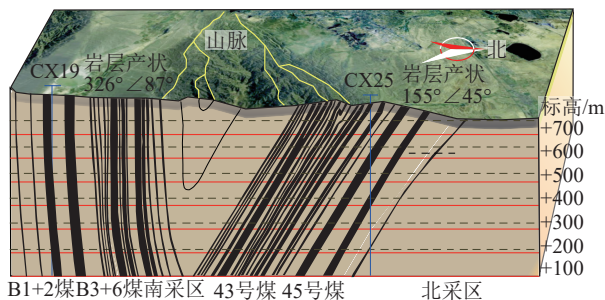


图1 某矿急倾斜煤岩赋存特征

Fig.1 Occurrence characteristics of steeply inclined coal and rock in a mine

该矿现主采 B1+2 煤层与 B3+6 煤层, B1+2 煤层平均厚度 37 m, B3+6 煤层平均厚度 49 m, 据现场应力结果显示:该矿应力场以水平构造为主,为垂直应力的 1.74~1.90 倍。现场采用水平分段综采放顶煤采煤法,现阶段的分段高度为 25 m,割煤高度为 3 m,放煤高度约 22 m。煤层回采结束后,在采空区内充填矸石与黄土。

随着该矿掘进进入+400 水平,巷道受地应力影响逐步加大,结合冲击危险区域划分情况来看, B3 和 B6 巷道都已经进入冲击危险高发区,危险性较高。2023 年 8 月 12 日,该矿+400 水平 B3 巷道与 B6 巷道

同时掘进时,在 B3 巷道的 810 m 处发生 1 次大能量事件,能量值达 33 000 J。工作面出现较大煤炮声,工作面有轻微扬尘, B3 巷北帮煤体侧 786~816 m 出现底鼓,平均 40 cm。统计到 8 月 6 日至 8 月 12 日共发生 7 次超 1 000 J 以上能量事件,其微震能量事件分布及震源位置如图 2 所示。

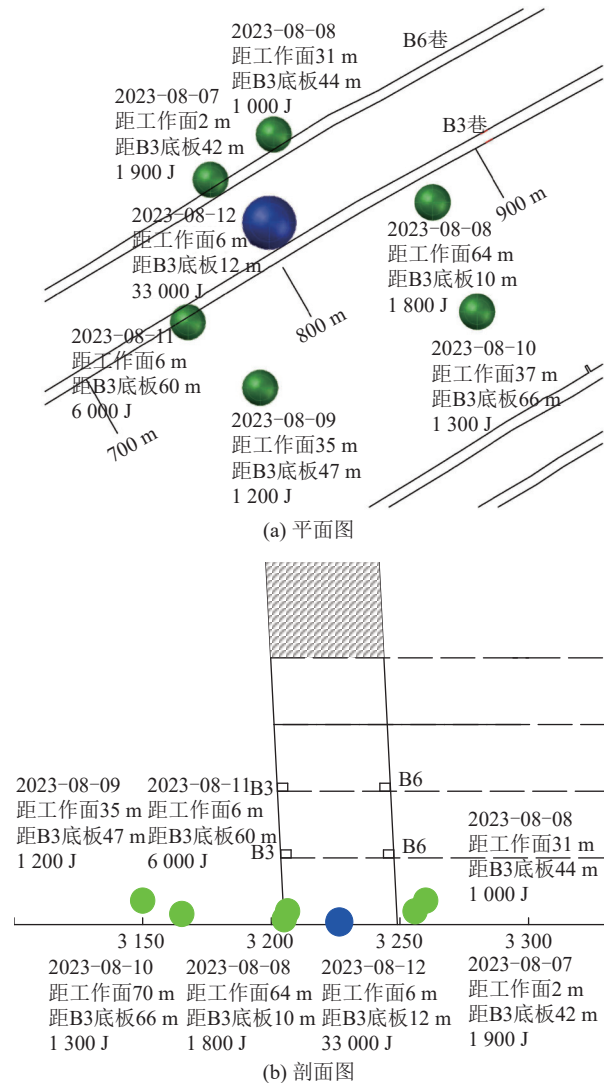


图2 “8·12”大能量事件及前一周微震事件空间分布

Fig.2 Spatial distribution of large energy events of “8·12” and microseismic events in previous week

+400 水平 B3 巷道“8·12”事件发生前一个月监测到多次微震事件,各能级微震事件频次与能量占比如图 3 所示。

由图 3 可知,该矿+400 水平 B3 掘进面 2023 年 7 月 12 日至 8 月 12 日的微震事件整体上可划分为 B3 单巷掘进、B3 和 B6 双巷同时掘进 2 个时期。B3 与 B6 两巷掘进工作面平均距离为 191 m, 8 月 1 日前为 B3 单巷掘进, 8 月 1 日后为 B3 和 B6 双巷同时掘进期。单巷掘进时期 B3 巷能量频次整体较为平稳,





图3 “8·12”事件前一月微震事件特征

Fig.3 Microseismic event characteristics in the month before “8·12” event

进入双巷掘进后,微震能量呈“升高—降低—再升高—再降低”周期性变化趋势,此时期微震能量变化幅度较单巷掘进时期明显增大。表明 B6 巷掘进面与 B3 巷掘进面出现采动应力叠加现象,受 B6 巷掘进影响, B3 掘进面煤岩应力调整不稳定,活动较为剧烈。该时期 B3 掘进面冲击危险性较高,为实时掌握 B3 巷冲击危险程度,需进一步挖掘“8·12”事件之前的历史微震数据潜在规律和隐含的前兆信息,形成多元微震信息指标融合驱动的综合预警,旨在实时判别危险等级,指导现场解危工作。

2 冲击地压多元预警指标确定

2.1 微震信息指标的选取

大能量事件以及冲击地压的发生的过程中,除可以直接辨识的震动、声浪现象外,还伴随着能量等微震前兆信息的改变。国内外学者在地震学领域的相关研究基础上,提出了许多关于冲击地压的微震预警指标并赋予了表征意义。冲击地压矿井的种类不同,不同的微震信息指标的预警能力表现具有差异,同时单一指标的预警能力具有一定的局限性,多指标融合可以更好的实现冲击危险的智能特征识别。因此,面向实际情况需要进一步细化指标这一需求,结合急倾

斜巨厚煤层的地质和开采条件,根据经验和统计分析,综合考虑了关于时间、空间、强度的共计 9 个微震信息指标,对预测急倾斜巨厚煤层掘进巷道发生冲击危险的敏感性较高,各指标含义简介如下:

1) b 值。1941 年,古登堡和里克特针对地震活动特征研究,提出了著名的地震-频度关系 (G-R^[19]关系),即:

$$\lg N(\geq M) = a - bM \quad (1)$$

其中, M 为震级; N 为 $\geq M$ 的累计次数; a 、 b 为微震活动的相关经验常数;研究表明,可以将微震数据的能量频次关系转化为 G-R 关系的震级频次关系^[20],具体计算方法如下:

$$\lg E = 4.8 + 1.5M \quad (2)$$

式中: E 为震源释放能量, J。

当前计算 b 值最主要的方法有最大似然法和最小二乘法^[21]。其中最大似然法采用空间扫描步求取平均震级从而得到 b 值,易受小震级事件影响,而本文研究对象为矿井掘进面,小震级事件偏多,因此采取最小线性二乘法进行时间步扫描得到 b 值的时序规律特征。计算方法如下:

$$b = \frac{\sum_{i=1}^m M_i \sum_{i=1}^m \lg N_i - m \sum_{i=1}^m M_i \lg N_i}{m \sum_{i=1}^m M_i^2 - \left(\sum_{i=1}^m M_i \right)^2} \quad (3)$$

式中: m 为震级分档总数; M_i 为第 i 档震级; N_i 为第 i 档震级的实际事件数。

2) $A(b)$ 值。在冲击地压前兆信息的研究中,虽然将 G-R 关系中的 a 值和 b 值作为某一时间段内微震活动趋势和能量占比指标,但它并不能严格表征微震活动平静或增强,例如小能量的事件可能导致 a 值增大但活动强度并未增加, b 值可以表示能量事件大小比例而不能表示总体释放的能量。基于此,为准确描述微震活动的增强或平静特征,引入 $A(b)$ 值^[22]综合考虑特定时间与特定地点内微震能量和频次等因素,它主要代表了工作面采动范围内全部微震事件中能量较大的一部分微震事件,可作为微震的时间、强度预警指标。 $A(b)$ 值定义如下:

$$A(b) = \frac{1}{b} \lg \sum_{i=1}^n 10^{bM} \quad (4)$$

式中: n 为微震频次。 $A(b)$ 值与 b 值的大小成反比,即 b 值越小则 $A(b)$ 值越大。

3) 微震活动 $P(b)$ 值。 $P(b)$ 值代表了小震级微震

事件^[23]。在特定的时间范围内,小震级的增多可以表征矿震的孕育过程,大能量事件发生时,小震级事件有着活动强度低而数量增多的特征,该特点可以作为预警的参考,小震级微震事件集合 $P(b)$ 值定义如下:

$$P(b) = \frac{n}{b} \left(\lg \sum_{i=1}^n 10^{bM} - \lg n \right) \quad (5)$$

4) 矿震活动度 S 值。矿震活动度 S 值考虑微震活动的时、空、强因素,包含微震的频次、能量、震源分布集中度及强度的记忆特征等多个指标,可以很好的定量描述微震活动的强弱程度^[24]。矿震活动度 S 值定义如下:

$$S = 0.117 \lg(n+1) + 0.029 \lg \frac{1}{n} \sum_{i=1}^n 10^{1.5M} + 0.015 M_{\max} \quad (6)$$

式中: M_{\max} 为最大震级。强矿震事件发生时,在时间、空间、强度的增加都将会导致矿震活动度 S 值的上升。

5) 缺震。“缺震”表示为缺失震级的现象,当某区域长期的平均能级较小时,那么这一区域将极有可能发生较大的能量事件作为对该区域大能级缺失的弥补。缺震可作为强度预警指标,计算公式^[25]如下:

$$b_L = \frac{0.4343}{\bar{M} - M_0} \quad (7)$$

式中: b_L 为缺震值; \bar{M} 和 M_0 分别为该区域的时间段内微震事件的平均能级和起始能级。

6) 矿震活动标度 ΔF 值。罗兰格结合苏联地震学,得到地震断裂层面上所受的总应力 F_0 与震级相对应^[26],强矿震事件发生时矿震活动标度 ΔF 出现高值异常,该值定义如下:

$$\Delta F = \lg \left(\frac{\sum F_0}{T} \right) \quad (8)$$

$$F_0 = 10^{6.11+1.09M} \quad (9)$$

式中: T 为天数; F_0 为地震破裂断层面上所受的总应力。

7) 算法复杂性 AC 值。算法复杂性 AC 值可以表征矿震演化的时序过程^[27],有一定的混沌特性,适用于矿震的时间序列分析, AC 值定义如下:

$$AC = \frac{\ln x}{x \ln y} \quad (10)$$

式中: x 为某一特定时间段内震级变化次数; $y = M_{\max} - M_{\min} + 1$, M_{\max} 为最大震级, M_{\min} 为最小震级。

8) Z -map 值。 Z -map 值是通过分析某一时间段内

微震事件的平均震级的变化,进而获得该区域特定时间段内微震活动性的强弱^[28]。 Z -map 值大致服从正态分布的规律,定义如下:

$$\bar{m}_j = \frac{1}{k} \sum_{i=1}^k m_i \quad (11)$$

$$z = \frac{\bar{M} - \bar{m}}{\sqrt{\frac{(\sigma_M)^2}{N} + \frac{(\sigma_m)^2}{n}}} \quad (12)$$

式中: \bar{m}_j 为统计范围内全部微震事件平均震级; \bar{M} 和 \bar{m} 为全部范围与统计范围 2 种情况下 m_j 的均值; σ_M 和 σ_m 为 2 样本的标准差。

9) 等效能级参数 EEM 。等效能级参数 EEM 反映区域内微震事件平均能级的情况,它将微震事件能级进行归一化,反映对正常水平偏离程度,矿震发生时高值异常情况^[28],该指标定义如下:

$$\sigma(m^*) = \frac{m^* - \bar{M}^*}{\sqrt{\bar{M}^*}} \quad (13)$$

式中: $\sigma(m^*)$ 为等效能级参数 EEM ; m^* 为归一化能级; \bar{M}^* 为 m^* 的平均归一化能级。

2.2 冲击地压微震信息指标实例分析

以该矿+400 水平 B3 巷掘进工作面 2023 年 6 月—2023 年 9 月期间的微震数据作为源数据计算各指标值。由于 B3 单巷掘进期间每日的微震数量较少,每天事件数相差较大,为减少各指标数据误差,增强数据表现能力,因此按照事件数划分计算窗口和滑移步长。研究发现当事件窗口过大容易受早期数据的影响、窗口过小则各指标值的波动变大。经调试,以计算窗口为 100,滑移步长为 10,计算出的各指标演化趋势以及 2 次较大能量事件显现的标注如图 4 所示。

计算得到了各个指标的平均值:平均 b 值为 0.696、平均 $A(b)$ 值 3.153、平均 $P(b)$ 值-354.896、平均矿震活动度 S 值 0.385、平均缺震值 0.387、平均矿震活动标度 ΔF 值 3.46、平均 Z -map 值-0.226、平均算法复杂度 AC 值 0.04、平均等效能级参数 EEM 值 0.024。

当“8·12”大能量事件发生时,其 b 值较小,为 0.531,小于平均值且前多日的数据整体呈现明显的降幅, $A(b)$ 值为 5.5,远大于平均值。 $P(b)$ 相较平均值较高。 S 值与缺震值较高,显著高于平均值,相较于前几日趋势陡增,且幅度较大。矿震活动标度 ΔF 值为 3.434,为统计范围内最小值,且单巷和双巷掘进期间均发生过一次幅度较大的降低趋势。 Z -map 值为

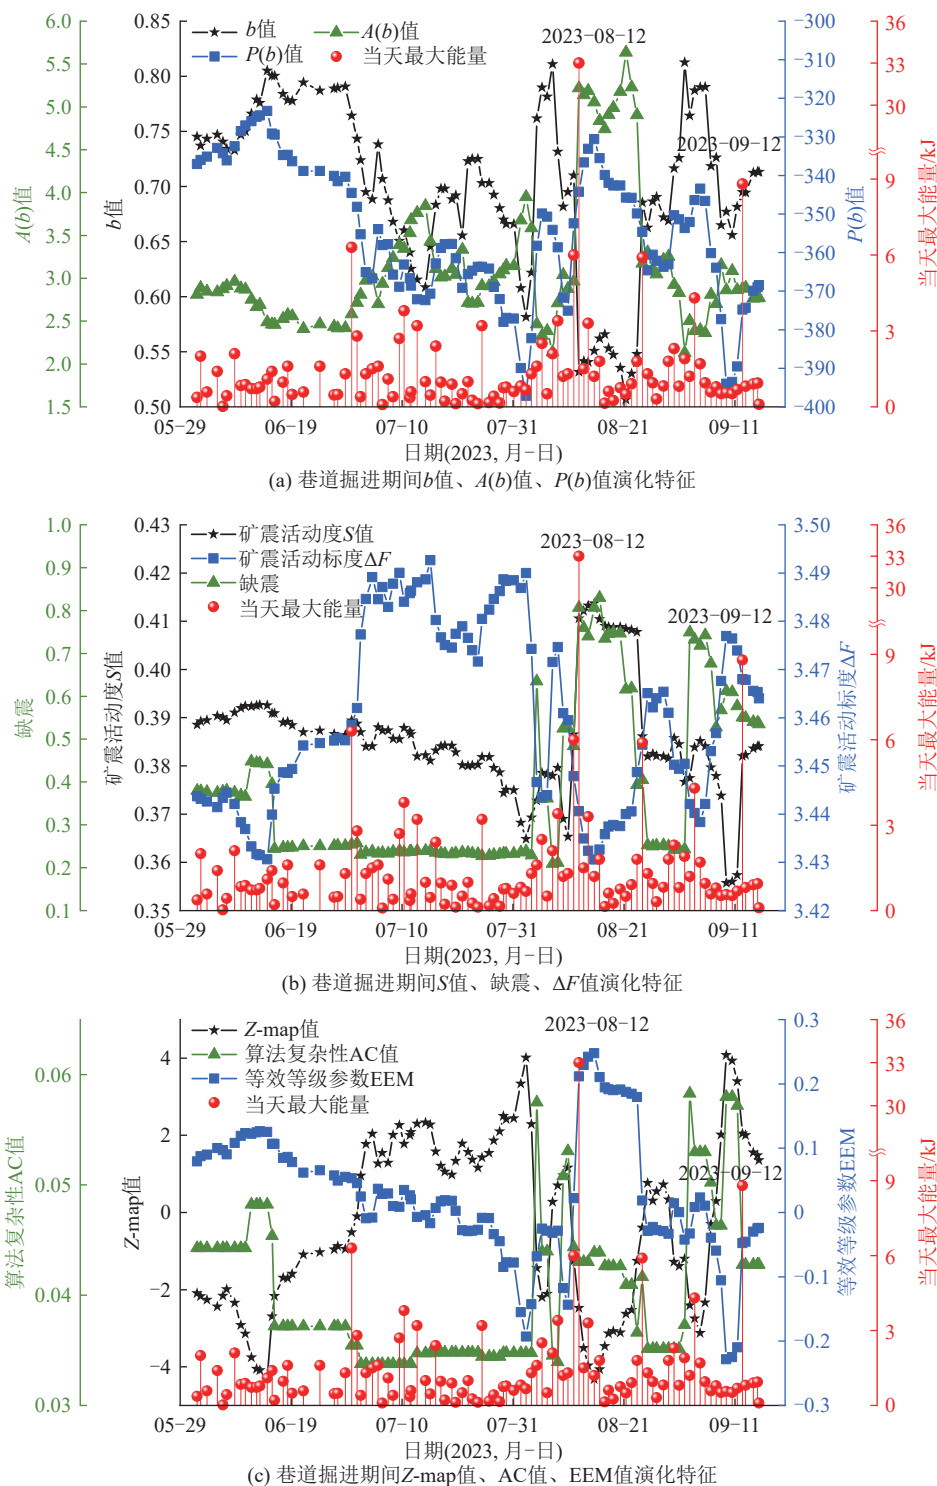


图4 巷道掘进期间各指标变化特征

Fig.4 Variation characteristics of each index during roadway excavation

-2.476, 低于平均值, 处于统计范围内最小值附近, 等效能级参数 EEM 值相对较高, 为 0.211, 算法复杂性 AC 值为 0.043, 相对于平均值较高, 双巷掘进期间变化趋势相较于单巷掘进期间幅度明显增大。

大能量事件的发生代表着煤岩较大的破裂, 在此之前能量不断积聚, 微震活动不断趋于活跃, 各微震信息指标均有相应的短期或中长期前兆特征。通过

统计分析可知: b 值、 $P(b)$ 值、 ΔF 值、算法复杂性 AC 值的演化曲线处于一定范围内的极小值或极小值附近亦或处于快速下降状态; $A(b)$ 值、缺震值、微震活动度 S 、等效能级参数 EEM 大部分处于一定范围的极大值或极大值附近亦或处于上升状态; 对于 Z -map 这一指标而言, 当其绝对值超过 2 时危险性较高, 大能量事件显现时其绝对值均高于预警值。

由上述分析可知,各指标在大能量事件发生前存在异常特征,所达到的阈值存在着超标的情况,往往在特定的时间窗口内存在着局部极值或处于极值范围附近。例如煤岩迅速破裂释放能量导致低 b 值异常、矿震活动强烈导致高 $A(b)$ 值异常、高 S 值异常等,同时各指标往往还伴随着急剧的上升或下降等情况,变化幅度与变化趋势均存在着差异性。基于对各指标阈值或趋势的预警有效性识别,可以相对直观的判断出当前危险程度,但也存在着局限性和不足之处。首先,统计的方式方法不同、基于人为经验产生的决断措施不同等因素影响下,将产生非必要的误差,甚至

可能因为标准的不统一而导致与结果完全相悖的结论。其次,统计各类指标的变化特征能达到的预警效果有限,因为各指标的计算是基于一定物理含义的,不同矿井的地质条件、赋存情况不同,则各指标对于预警结果的敏感性权重也存在差异^[29]。基于以上分析和探讨,笔者尝试引入深度学习方法,旨在对预警指标的信息特征进行深度挖掘,实现冲击地压的精确预测。

2.3 预测模型架构

本文提出的预测模型架构如图5所示,主要包括3部分:数据预处理、特征指标优选、预测模型。

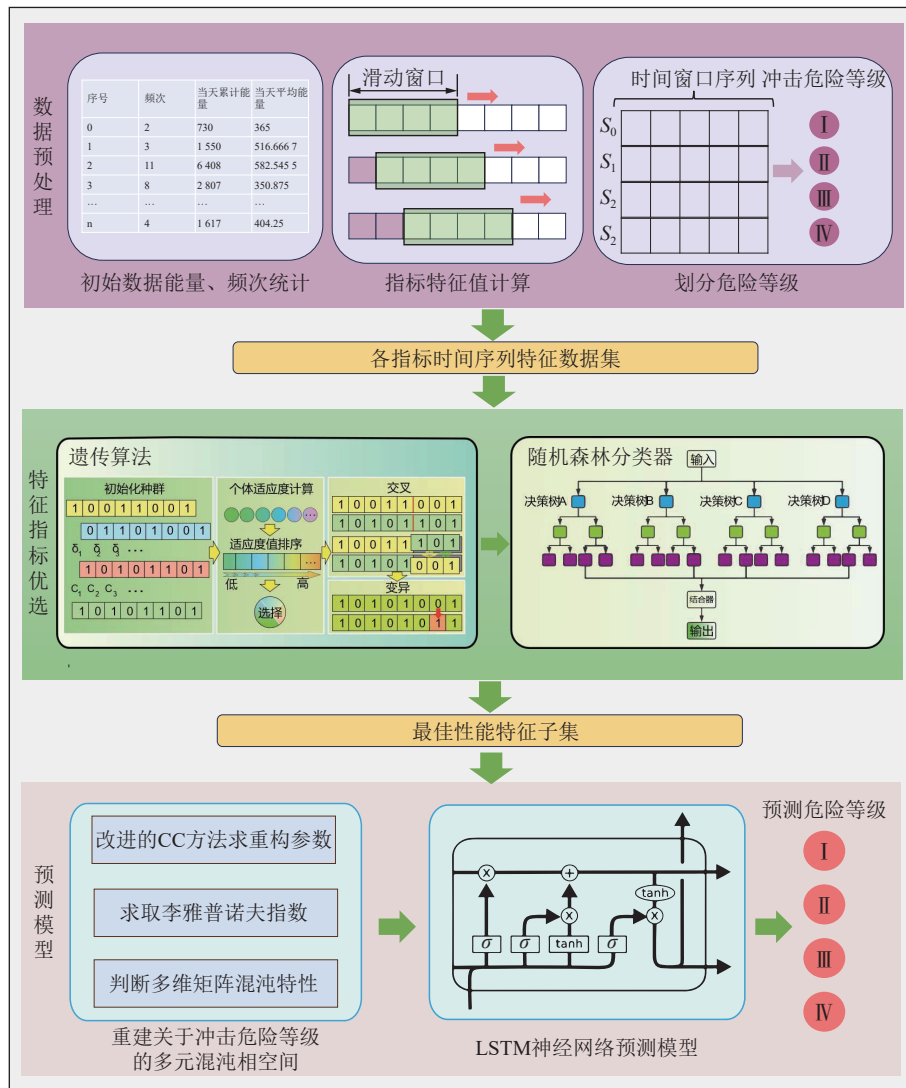


图5 冲击地压预测模型架构

Fig.5 Structure of rock burst prediction model

数据预处理首先将原始微震数据的坐标能量等信息根据给定时间窗口进行统计和分析,通过指定计算窗口与滑移步长,计算得到各指标的时序数据;再根据微震历史数据分布特征及能级-频度曲线,找到能量拐点并确定分类阈值;最后,生成多指标特征的

时间窗口序列及其标签,最终得到用于训练的模式序列集合。

特征指标优选主要是根据预处理部分得到的序列及标签,采用一种集成的机器学习算法,得到最优模型的指标组合,提高运算效率。

预测模型首先构建了关于冲击危险的多元混沌相空间, 然后将其结果输入至预测网络中, 最后实现冲击危险等级的预测分类。

2.4 数据预处理

数据预处理的整体过程如图 6 所示。首先需要构建各指标的时序数据集。具体是通过滑动计算窗口, 得到每一指标的窗口值并记录。

假设第 i 个滑动窗口计算得到的数据记录为 w_i , 其可以表示为

$$w_i = (\text{id}, \text{date}, e_1, e_2, \dots, e_9) \quad (14)$$

式中: id 为窗口编号, date 为日期时间, $e_1 \sim e_9$ 为选取的微震信息指标。由此可以得到被划分为 n 个窗口的时间序列数据:

$$\text{Window} = (w_0, w_1, w_2, \dots, w_{n-1}) \quad (15)$$

再根据滑动窗口数据集 Window 构建各指标的

时间前兆序列, 对于每一个数据记录 w_i 来说, 设其前兆序列为 p_i , 则其可以表示为

$$p_i = (w_{i \times j - 1}, w_{i \times j - 2}, \dots, w_{i \times j - s}) \quad (16)$$

其中, s 为指定滑动窗口的长度, 此处设定为 100, j 为采样步长, 此处设定为 1。即第 i 个记录数据其前兆序列为前 s 个记录数据的集合。得到 n 个时间窗口的前兆模式序列集 P 可表示为

$$P = (p_1, p_2, \dots, p_n) \quad (17)$$

最后, 建立每个前兆模式序列集相对应的冲击危险指数 G 的标签集合, 具体可表示为

$$G = (t_0, t_1, t_2, \dots, t_D) \quad (18)$$

其中, D 为总体统计天数的数量, t_i 为时间窗口序列中某一天的冲击危险等级标签, 分类标签具体计算过程如下文。



图 6 数据预处理过程

Fig.6 Data preprocessing process

为细化监测预警结果, 在集成学习模型训练之前, 需要对每个时间窗口的微震能量数据集给定分类标签。通过观察巷道掘进期间的历史微震数据, 在大能量事件发生前, 存在某应力集中区域。应力受采掘扰动导致冲击显现后, 该区域或附近位置的震级档内的事件出现突增或骤减, 导致微震事件比例异常。因此, 可由能量-频度曲线的分析找到能级的偏移点, 从而确定微震单次能量所对应的冲击危险等级。

根据该矿+400水平B3巷掘进期间统计的全部微震事件, 选取 $1.8 \leq \lg E \leq 4.0$ 区间的微震监测数据绘制出能量-频度曲线并进行线性拟合, 得到的能级-频度曲线结果如图 7 所示。

得到了拟合曲线方程为

$$\lg N = (-7.331\ 69 \pm 6.942\ 7) \times 10^{-4} \times \exp\{-\lg E / [(-0.493\ 12 \pm 0.058\ 54) \times 10^{-4}]\} + 2.001\ 17 \pm 0.068\ 21 \quad (19)$$

式中: $\lg N$ 为频度, $\lg E$ 为能级, R^2 为回归方程的拟合度。

由图 7 可知, 拟合度 R^2 为 0.914 37, 具有较好的

拟合效果, 说明 $\lg E$ 的选取区间较合理, 可以作为“G-R”关系中 b 值的能量区间。另一方面, 全部微震事件的能级-频度曲线呈现出先升后降的抛物线形式, 初期的高频次、低能级段呈现为指数分布, 随着能级的

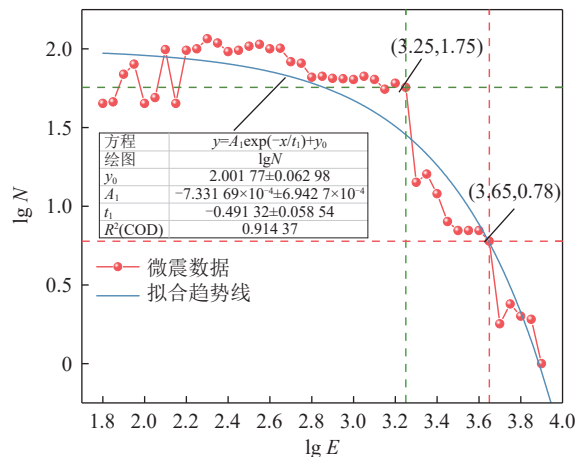


图 7 +400 水平 B3 巷掘进期间微震能级-频度曲线

Fig.7 Microseismic energy-frequency curve during tunneling of B3 lane at +400 level

增加,曲线呈现出线性分布特征。可以观测到曲线具有斜率的突然下降现象,说明此时发生了能级偏移,震级档内的微震事件比例异常,冲击危险性增加,将偏移点的能量值作为临界值具有较好的预警潜力。

从图7中可以明显看出能量-频次曲线中的2个偏移点,分别为(3.25,1.75)、(3.65,0.78),于是可将大能量事件发生的临界值作为冲击危险的临界点,从而计算得到冲击危险等级。划定弱冲击危险的能量临界值 $E_r=10^{3.25}=1\ 778\text{ J}$ 、中等冲击危险的能量临界值 $E_z=10^{3.65}=3\ 981\text{ J}$ 。依据现场实际,在巷道掘进期间,除“8·12”事件能量有较大幅度显现,其余整体微震事件能量值均位于10 000 J以下,且并无能量显现情况发生。由图7得到的能级-频度曲线也可看出,能级大于4.0的情况下并无频度分布,因此对强冲击危险临界值进行单独划分,选择 $E_q=10\ 000\text{ J}$ 作为强冲击危险的能量临界值。同样对单次微震能量数据进行处理,具体处理方法为以当日发生的最高能量微震事件值作为冲击地压监测预警的等级,根据微震能量等级划分的区间,将对应的单次能量数据进行标准化处理。 E' 为能量标准化结果, E_{\max} 为历史期间最大能量事件。该矿B3掘进工作面单次能量危险等级细分见表1。

表1 单次能量危险等级细分

Table 1 Breakdown of single energy hazard level

能量区间/J	能量标准化结果 E'	危险等级判别 I_i
0~1 778	$\frac{0.25E}{E_r}$	I(无冲击危险)
>1 778~3 981	$0.25 + \frac{0.25(E - E_r)}{E_z - E_r}$	II(弱冲击危险)
>3 981~10 000	$0.50 + \frac{0.25(E - E_z)}{E_q - E_z}$	III(中等冲击危险)
>10 000	$0.75 + \frac{0.25(E - E_q)}{E_{\max} - E_q}$	IV(强冲击危险)

2.5 基于GA-RF指标优选

对于不同种类的冲击地压矿井,各预警指标作为对前兆信息的表征作用的敏感性并不相同,即指标的预警能力存在着差异。因此优选出预警能力较高的前兆信息指标可以达到提高预警准确率的目的。本文采用前述的9个指标作为候选集,采用一种反馈迭

代式思路优选特征指标。通过GA-RF算法创建和维护一个特征子集的种群,并使用遗传操作(交叉和变异)来生成新的特征子集;通过多次迭代和反复训练模型并剔除最不重要的特征,评估出最优特征指标集合作为最终的特征选择结果。具体步骤如下:

1) 加载给定的微震数据集 $\{a_1, a_2, \dots, a_m, \text{label}\}$, 将每个指标看做一个候选子集, 对应 a_1-a_m , label 是将当天的危险等级作为分类标签并编码为数字。然后, 将数据集划分为特征和标签, 并将其分割为训练集和测试集。选用样本训练集和测试集样本数量比为8:2。

2) 定义适应度函数, 该函数使用随机森林分类器对选择的特征进行训练和预测, 最后返回分类器的 F_1 值作为适应度评分。 F_1 值是精确率(Precision)和召回率(Recall)的调和平均, 可用来判别分类器的优劣。计算公式如下:

$$F_1 = 2 \frac{PR}{P+R} \quad (20)$$

式中: P 为精确率, 代表所有被模型预测为正例中真正例的比率; R 为召回率, 代表所有真正例中预测结果也为正例的比率。

3) 定义遗传算法的相关参数, 然后初始化种群, 并在主循环中进行遗传算法的操作: 在每一代循环中, 我们计算每个个体的适应度评分(即当前候选指标子集的 F_1 值), 然后选择父代个体进行交叉操作, 生成子代个体; 接着, 对子代个体进行变异操作, 以增加种群的多样性; 最后, 更新种群并打乱个体顺序; 在每一代的循环中, 记录当前代最佳个体的选择特征和适应度评分。

4) 在循环结束后, 找到具有最高适应度评分的个体, 并输出其对应的选择特征, 这些特征就是通过遗传算法选择出的最佳特征子集。

对于算法的超参数选取, 根据经验和多次试验测试进行了参数调优, 最终确定随机森林分类器的决策树数量为100, 控制随机性的种子值设置为30, 遗传算法中, 设定种群大小为100、迭代次数为50、特征数量为9、变异率为0.02。由上述指标优选思想, 取得试验结果见表2。

表2 不同微震信息指标组合预测的适应度评分值

Table 2 Fitness scores predicted by different combinations of physical indicators

指标组合	F_1 值	指标组合	F_1 值
b值、A(b)值、缺震、AC值、EEM值、S值	0.761	b值、A(b)值、缺震、S值	0.746
A(b)值、AC值、EEM值	0.758	b值、A(b)值、缺震、AC值、EEM值、S值、Z-map值	0.744
A(b)值、缺震、Z-map值、S值	0.756	b值、A(b)值、缺震、AC值、EEM值、S值、 ΔF 值	0.729
b值、A(b)值、缺震、AC值、S值	0.749	b值、A(b)值、缺震、AC值、EEM值、S值、P(b)值	0.727
b值、缺震、S值	0.747	b值、A(b)值、缺震、Z-map值、 ΔF 值、AC值、S值	0.714

对各指标组合的 F_1 值进行比较,发现 b 值、 $A(b)$ 值、缺震、算法复杂度 AC 值、等效能级参数 EEM 值、矿震活动度 S 值的 6 个指标组合为最优结果,预警准确率较高 ($F_1=0.761$)。在此最优组合基础增加其他指标并不会提高准确率,且会增加后续模型的学习训练时间,因此指标优选后一定程度上提高了数据处理的效率。

图 8 为随机森林算法对优选出的 6 个特征的重要程度分布情况,其重要性的数值越偏离 0,表示该特征对于目标变量的影响越大,重要程度越高。可以看出,针对该矿的急倾斜巨厚煤层掘进巷道而言,对冲击危险等级敏感性最强的是缺震值和矿震活动度 S 值,其次按照特征重要性排序依次是等效能级参数 EEM 值、 b 值、 $A(b)$ 值以及算法复杂性 AC 值。结合指标组合的适应度评分可知以上 6 个微震信息指标对于冲击危险等级的敏感性较高,后续研究可根据该特征的重要性排序动态调整学习权重和参数选择,优化学习效率,提升预测准确率。




图 8 随机森林特征重要性排序

Fig.8 Importance ranking of random forest features

3 多元时间序列的相空间重构

3.1 相空间重构理论

混沌现象是自然界中普遍存在的由确定的非线性动力系统产生复杂行为的不规则运动,它能够还原出随机无序现象中的规律,更好的刻画事物的本质特征以及动力态性。一个系统变化往往受到多种物理因素的共同影响,当某个因素产生变化时,背后往往包含着系统中其他因素相应的动态信息。研究表明在任何混沌系统当中,可以用一个一维混沌时间序列来重构出与原动力系统在拓扑意义下等价的相空间^[30],从而直观描述出混沌系统的状态特征。

由上述的混沌理论可知,混沌系统中的变量运动轨迹会呈现出特定的规律,由此可以根据给定的冲击地压时间序列轨迹构建相应的相空间。通过计算获得时间延迟、嵌入维数等相关参数,将原有的时间序

列拓展至更高维度的空间中,于是相空间中的每一维数均相互等价且能互相表征。总之,相空间的重构就是在混沌理论的基础上从分量时间序列出发创建一个保持原来多个分量的等价多维状态空间^[31]。

在急倾斜巨厚煤层掘进巷道冲击地压多元微震信息指标的预测研究中,其影响因素具有动态变化性和多样性。通过量化数据可知,挖掘数据中隐含的规律,需要长时间且频率较高的数据。该矿+400 水平 B3 巷道相关微震信息指标自开掘后长期变化趋势相对一致,因此可结合上文 GA-RF 特征提取方法,利用实验优选的 6 个影响因素共同构建多元混沌相空间。

3.2 延迟时间和嵌入维数的确定

重构相空间是混沌时间序列分析的基础,D.KU-GIUMTZIS^[32]提出了嵌入窗法,指出延迟 τ 和维数 m 相关,且依靠嵌入窗 $\tau_w = (m-1)\tau$ 相互关联。H.S.KIM 等^[33]进一步提出了 C-C 算法,该算法弥补了自相关函数法只适用于线性系统、非线性系统易出现误导而导致重构相空间失败等缺点,该算法抗噪声能力较强且能够同时计算出 τ 和 m 。对于 C-C 方法简介如下:

考虑混沌时间序列 $x=\{x_i|i=1,2,\dots,N\}$,先定义关联积分 $C(m,N,r,t)$,再由 2 个关联积分之差构造统计量 S_1 :

$$S_1(m,N,r,t) = C(m,N,r,t) - C^m(1,N,r,t) \quad (21)$$

式中: m 为嵌入维, r 为空间距离, t 为时延,关联积分 C 表示相空间中任意两点之间距离小于 r 的概率。

随后将时间序列 x 分解为 t 个互不重叠的子序列,并依据统计量 S_1 采用分块平均策略,构造出每个子序列的统计量 S_2 :

$$S_2(m,N,r,t) = \frac{1}{t} \sum_{s=1}^t \left[C_s\left(m, \frac{N}{t}, r, t\right) - C_s^m\left(1, \frac{N}{t}, r, t\right) \right] \quad (22)$$

当 N 趋近于无穷时,有:

$$S_2(m,r,t) = \frac{1}{t} \sum_{s=1}^t [C_s(m,r,t) - C_s^m(1,r,t)] \quad (23)$$

根据自相关法原理,最优时延可取 S_2 的第 1 个零点,或者 S_2 对所有半径 r 相互差别最小的时间点,选择最大半径和最小半径定义差量:

$$\Delta S_2(m,t) = \max \{S_2(m,r_j,t)\} - \min \{S_2(m,r_j,t)\} \quad (24)$$

最后依据 BDS 统计结论可确定统计量 N 、 m 、 r 参数的估计取值,有如下公式:

$$\begin{cases} \bar{S}(t) = \frac{1}{16} \sum_{j=2}^4 \sum_{m=2}^5 S_2(m, r_j, t) \\ \Delta \bar{S}(t) = \frac{1}{4} \sum_{m=2}^5 \Delta S_2(m, t) \\ S_{\text{cor}}(t) = \Delta \bar{S}(t) + |\bar{S}(t)| \end{cases} \quad (25)$$

式中:最优时延取 $\bar{S}(t)$ 的第1个零点或 $\Delta \bar{S}(t)$ 第1个局部极小点,嵌入窗口取 $S_{\text{cor}}(t)$ 的全局最小点。

本文采用文献[34]提出的改进的C-C方法实现相空间重构参数的计算。冲击地压相关微震信息指标的时序数据中即存在着确定性因素也含有随机因素,即有噪声也有混沌特性。采取改进的C-C法思想选取相关参数,可以一定程度上弥补噪声带来的不良影响,根据该法可求得各时间序列的嵌入维数 m 和时间延迟 τ 。现以 b 值为例说明参数计算过程,图9为根据改进的C-C法求取的时间序列 b 值时延和嵌入维数的计算结果。




图9 改进的C-C方法求取 b 值结果

Fig.9 Results by the improved C-C method for b values

由图9可知,所求 b 值时间序列的时间延迟 $\tau=48$,嵌入窗 $\tau_w=33$,根据公式推导可知 $m=\tau_w/\tau+1$,对 τ_w/τ 运算值进行向下取整得0,求得 b 值的嵌入维数 $m=1$,同理可计算其余6个指标的时延和嵌入维数,结果见表3。

表3 重构相空间中各影响因素延迟时间和时间窗

Table 3 Delay time and time window of each influencing factor in reconstructed phase space

相空间参数	b 值	$A(b)$ 值	S 值	缺震值	AC值	EEM值
时间延迟 τ	48	4	11	23	11	11
嵌入维数 m	1	13	8	3	7	7

3.3 基于Wolf法最大Lyapunov指数的混沌性检验

混沌系统对初始值敏感性较强,为此引入描述混沌系统敏感性的指标Lyapunov指数。在实际应用中,建立多元混沌时间序列需要检验其是否具有混沌特性,若选取的时间序列不具有混沌特性则无法成功找到混沌吸引子,最终导致预测失败。Lyapunov指数法可以较为简单判断系统的混沌程度,该法应用较为普遍且得到广泛认可。

Wolf于1985年首次提出了轨道追踪法[35],这种方法需要使用较长的数据量,它是一种通过相平面、相体积、相轨迹等等演化来估计Lyapunov指数的一种方法。各指标数据量相对较大,因此本文采用wolf法估计Lyapunov指数,检验重构后的时间序列是否具有混沌秩序性,wolf法简介如下:

假设重构相空间 Y ,其初始点为 $Y(t_0)$,设其与最近邻点 $Y_0(t_0)$ 的距离为 L_0 ,观察直到 t_1 时刻两点时间演化轨迹,对于两点之间的距离若满足式(26),则保留 $Y(t_1)$ 。

$$\varepsilon > 0, L'_0 = |X(t_1) - X_0(t_1)| > \varepsilon \quad (26)$$

随后,在 $Y(t_1)$ 邻近另外找一个点 $Y_1(t_1)$,使得 $L_1 = |Y(t_1) - Y_1(t_1)| < \pi$,并且与之夹角尽可能小,对上述方法进行迭代,直至 $Y(t)$ 到达时间序列终点,最大Lyapunov指数 λ_i 计算公式为

$$\lambda = \frac{1}{t_M - t_0} \sum_{i=0}^M \ln \frac{L'_i}{L_i} \quad (27)$$

经过上述计算步骤可得, b 值、 $A(b)$ 值、缺震、等效能级参数4个时间序列的最大Lyapunov指数分别为0.6487、0.0315、0.1176、0.0230,结果均大于0,说明以上4个分量均具有混沌特性。矿震活动度 S 值与AC值Lyapunov指数小于0,不参与相空间重构,但其与冲击地压等级的相关性较高,仍保留其作为一维时序数据使用。

3.4 重建关于能量等级的多元混沌相空间

相较于单元相空间重构,多元相空间重构还原程度更高,更加贴切于实际使用环境。多元相空间建立的基本步骤[36]如下:

设有 Q 个变量时间序列 X_1, X_2, \dots, X_Q ,且 $X_q = \{X_{q,1}, X_{q,2}, \dots, X_{q,N}\}$, $q=1,2,\dots,Q$, N 为观测分量时间序列长度,对应变量的时间延迟为 $\tau_1, \tau_2, \dots, \tau_Q$,嵌入维数为 m_1, m_2, \dots, m_Q ,此时多元相空间产生的相点数:

$$L = N - \max [(m_q - 1) \tau_q] \quad (28)$$

相空间的 P 时间状态的坐标 V_p 如式(29)所示,多变量时间序列重构的相空间矩阵 V 如式(30)所示。

$$V_P = [x_{1,p}, x_{1,p-\tau_1}, \dots, x_{1,p-(m_1-1)\tau_1}; x_{2,p}, x_{2,p-\tau_2}, \dots, x_{2,p-(m_2-1)\tau_2}; \dots; x_{Q,p}, x_{Q,p-\tau_Q}, \dots, x_{Q,p-(m_Q-1)\tau_Q}] \quad (29)$$

$$V = \begin{bmatrix} V_{N_0} \\ V_{N_0+1} \\ \vdots \\ V_P \end{bmatrix} = \begin{bmatrix} x_{1,N_0} & x_{1,N_0-\tau_1} & \dots & x_{1,N_0-(m_1-1)\tau_1} & \dots & x_{Q,N_0} & x_{Q,N_0-\tau_Q} & \dots & x_{Q,N_0-(m_Q-1)\tau_Q} \\ x_{1,N_0+1} & x_{1,N_0+1-\tau_1} & \dots & x_{1,N_0+1-(m_1-1)\tau_1} & \dots & x_{Q,N_0+1} & x_{Q,N_0+1-\tau_Q} & \dots & x_{Q,N_0+1-(m_Q-1)\tau_Q} \\ \vdots & \vdots & \dots & \vdots & \dots & \vdots & \vdots & \dots & \vdots \\ x_{1,P} & x_{1,P-\tau_1} & \dots & x_{1,P-(m_1-1)\tau_1} & \dots & x_{Q,P} & x_{Q,P-\tau_Q} & \dots & x_{Q,P-(m_Q-1)\tau_Q} \end{bmatrix} \quad (30)$$

$$P = N_0, N_0 + 1, \dots, N \quad (31)$$

式中: $N_0 = \max_{1 \leq q \leq Q} \{(m_q - 1)\tau_q + 1\}$, 相空间总维数 $M = m_1 + m_2 + \dots + m_Q$ 。

根据 2023-03-10—2023-09-15 的各指标时序数据建立相空间, 对数据集进行归一化处理, 从而降低最终预测误差。根据表 3 给出的 m 和 τ 两个参数及式 (31) 进行相空间重构, 计算可知 $N_0=78$, 相空间总

维数为 24, 再将 S 值与 AC 值去除其前 78 个事件的数据, 然后作为额外的二维时序数据使用, 最终得到了一个大小为 $26 \times 1\,421$ 的神经网络向量矩阵, 如图 10 所示。矩阵中, x_1 、 x_2 、 x_3 、 x_4 、 x_5 、 x_6 分别对应的是 b 值、 $A(b)$ 值、缺震、EEM 值、 S 值、 AC 值的时间序列。预测时, 将每一个状态点作为上一神经网络训练集样本输出和下一神经网络训练集样本的输入。




图 10 关于冲击危险等级的多元相空间矩阵

Fig.10 Multivariate phase space matrix for impact risk levels

4 基于 LSTM 模型的冲击危险预测

4.1 预测模型构建

长短期记忆神经网络 (LSTM), 是循环神经网络 (RNN) 的一种特殊类型, LSTM 通过刻意设计来避免长期依赖问题, 利用记忆单元来实现节点的不断更新, 从而解决了传统径向基神经网络中对于远距离数据的依赖特性, 使其能够更好地捕捉时间序列数据中的长期依赖关系, 并且在处理长序列数据时不易出现梯度消失或梯度爆炸问题, 在时间序列的预测方面具有一定优势。冲击地压的发生是一个孕育演化的动态过程, 也是一个非线性的动力学过程, 从能量的积聚至突然释放, 均伴随着物理信息等时间序列的转变, 为了更好的刻画这种转变特点, 可以引入 LSTM 预测冲击危险等级, 其网络架构如图 11 所示。

LSTM 网络具有 3 个门控单元, 包括输入门、遗忘门和输出门, 其中 x_t 为当前状态的数据输入, h_{t-1} 和 h_t 分别为上一个时间点和本时刻的隐藏层输出值, c_{t-1} 和 c_t 分别为上一时刻和本时刻的细胞状态, f_t 为遗忘门输出值, i_t 和 \tilde{c}_t 分别为激活函数 σ 与激活函数 \tanh 输出值, o_t 为当前时刻输出门的输出结果。 ω_{xf} 、 ω_{xi} 、

ω_{xo} 为输入 x_t 到各个门的权重矩阵。 ω_{hf} 、 ω_{hi} 、 ω_{ho} 、 ω_{hc} 为隐藏状态 h_{t-1} 到各个门的权重矩阵。 ω_{cf} 、 ω_{ci} 、 ω_{co} 为细胞状态 c_{t-1} 到各个门的权重矩阵。 b_f 、 b_i 、 b_o 、 b_c 为各个门的偏置项。

$$\begin{aligned} f_t &= \sigma(\omega_{xf}x_t + \omega_{hf}h_{t-1} + \omega_{cf}c_{t-1} + b_f) \\ i_t &= \sigma(\omega_{xi}x_t + \omega_{hi}h_{t-1} + \omega_{ci}c_{t-1} + b_i) \\ o_t &= \sigma(\omega_{xo}x_t + \omega_{ho}h_{t-1} + \omega_{co}c_{t-1} + b_o) \\ \tilde{c}_t &= \tanh(\omega_{xc}x_t + \omega_{hc}h_{t-1} + b_c) \\ c_t &= f_t c_{t-1} + i_t \tanh(\omega_{xc}x_t + \omega_{hc}h_{t-1} + b_c) \\ h_t &= o_t \tanh(c_t) \end{aligned} \quad (32)$$

以多元混沌相空间的状态坐标作为多变量输入数据集, 将每天的冲击地压危险等级作为目标值。指定 LSTM 隐含层层数及其神经元个数等参数, 再通过网格搜索系统地遍历多种参数组合, 使用交叉验证来寻找最佳的模型参数, 对学习率、批处理大小、优化器类型 3 个超参数进行寻优, 从而生成 LSTM 预测模型。根据前 N 个事件的微震数据, 预测间隔时间为 t 所对应的第 $N+1$ 个事件的冲击地压危险等级。由此迭代预测各个时间段的危险等级, PSR-LSTM 预测模型架构如图 12 所示。




图 11 LSTM 网络架构

Fig.11 LSTM network architecture

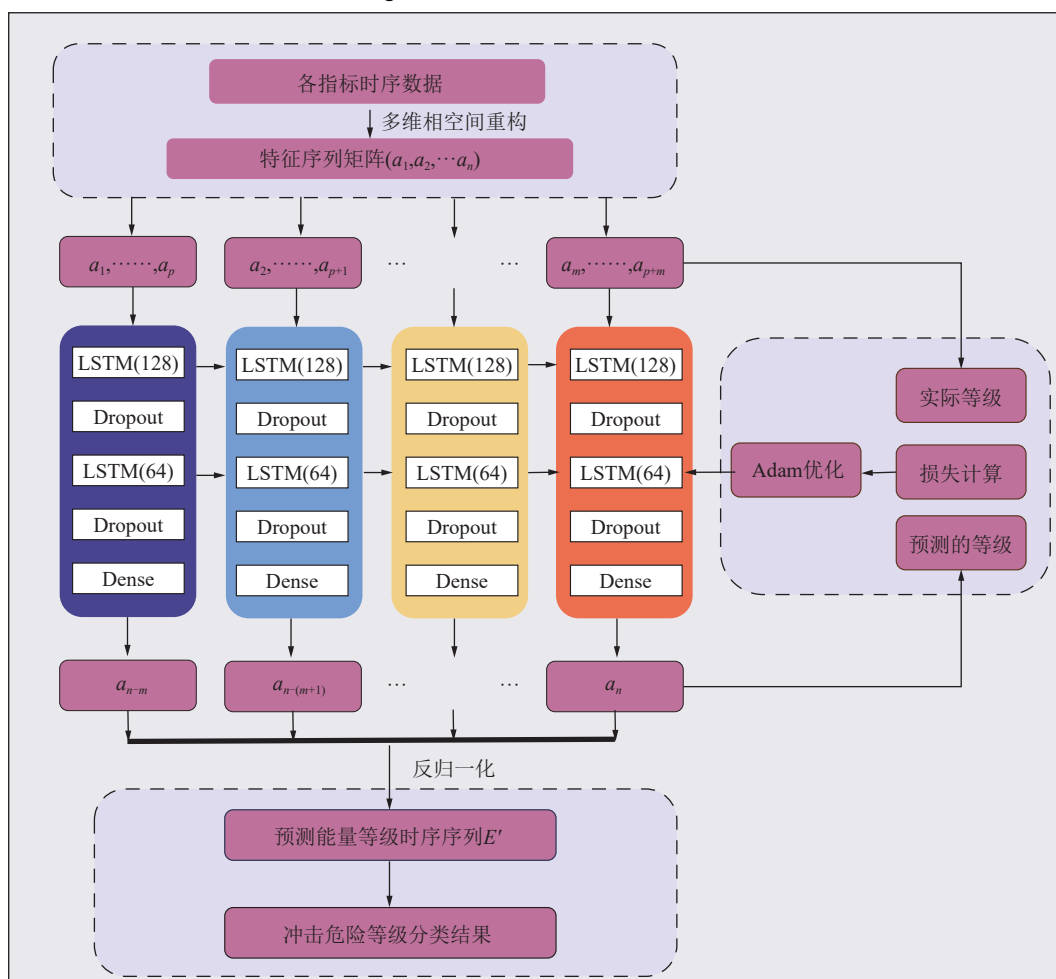


图 12 PSR-LSTM 预测模型架构

Fig.12 PSR-LSTM prediction model architecture

4.2 预测模型训练

图 13 为该矿+400 水平 B3 巷道 2023-03-10—2023-09-15 当天最大能量值标准化后的分布特征,根据重构的相空间训练集矩阵,按照 8 : 2 的比例对统计范围内所有天的数据进行划分,最终得到的训练集和测试集的样本比为 1 125 : 281。




图 13 日最大能量值分布特征

Fig.13 Daily maximum energy value distribution

采用隐含层为 2 层,每层神经元数均为 50, Dense 层神经元数量为 1 的 PSR-LSTM 模型。经过网格搜索超参数寻优后,确定 PSR-LSTM 模型的训练批次大小为 20,总的训练轮次为 120,采用 Adam 的随机梯度下降做优化,使用 2 折交叉验证策略,确定随机失活比例 Dropout 为 20%,指定输入层数据特征为 26,模式序列所含时间序列个数为 100,利用平均绝对误差 (mean absolute error, MAE) 做损失函数,根据实时训练损失情况动态调整学习率,预测间隔时间为 1 d,模型参数设置见表 4。

表 4 模型参数设置

Table 4 Model parameter Settings

参数	参数含义	数值
LSTM	隐含层层数	2
	隐含层神经元数	50
Dense	连接层层数	1
	连接层神经元数	1
batch_size	训练批次	[16, 20]
epochs	训练轮数	[100, 120]
optimizer	优化器	['adam','Adadelata']
cv	交叉验证策略	2
Dropout	随机失活比例	0.2
Input_shape	数据特征形状	(100, 26)

为对比 LSTM 与 PSR-LSTM 两种方案下预测效

果,对 2 种方案进行同样的参数设置后分别进行训练,得到 LSTM 的最佳训练轮次为 100。LSTM 和 PSR-LSTM 预测实验的目标函数训练集损失值变化如图 14 所示。




图 14 不同方案中目标函数损失值的变化情况

Fig.14 Changes of loss value of objective function in different schemes

由图 14 可知,当 0 迭代至 20 次时,2 个模型下降较快,迭代至 20 次以后,2 个模型损失下降幅度变得平稳并逐渐达到最低。其中,LSTM 的损失值稳定在 2.26×10^{-2} ,PSR-LSTM 的损失值稳定在 1.59×10^{-2} 。通过损失函数的情况来看,PSR-LSTM 模型优于 LSTM。

4.3 冲击危险等级评价指标

为有效评价急倾斜巨厚煤层掘进巷道冲击地压危险等级的预测分类效果,采用混淆矩阵对结果进行记录,在混淆矩阵中,真正例记作为 TP,含义为实际情况为真且预测正确;真反例记作 TN,含义为实际情况为假且预测情况为假;假正例记作 FP,即实际情况为真而预测为假;假反例记作 FN,即实际情况为假而预测为假。总的来说,真正例和真反例表示被正确预测的数据,假正例和假反例表示被错误预测的数据,并且样本总数为 TP、TN、FP、FN 之和,混淆矩阵见表 5。

表 5 分类结果混淆矩阵

Table 5 Confusion matrix of classification results

冲击危险等级类别	实际情况(正例)	实际情况(反例)
预测情况(正例)	真正例(TP)	假反例(FN)
预测情况(反例)	假正例(FP)	真反例(TN)

分类模型中,常用的评价指标有 Accuracy 以及上文提到的查准率 P 、召回率 R 和 F_1 值。其中,Accuracy 是最直观的衡量模型好坏的指标,其反映了冲击地压危险预测模型的分类准确性。本文通过以上 4

个指标的分析对混淆矩阵记录的冲击危险等级分类结果进行评估。 F_1 值计算公式见式(20),其余各指标计算公式如下:

$$\text{Accuracy} = \frac{\text{TN} + \text{TP}}{\text{TN} + \text{TP} + \text{FN} + \text{FP}} \quad (33)$$

$$P = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (34)$$

$$R = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (35)$$

4.4 模型预测结果

预测冲击危险的等级大小和发展趋势对于及时的解危措施有重要的参考意义,针对该矿双巷掘进的事件背景,结合本文的试验方法,分别利用 LSTM 和 PSR-LSTM 网络模型对所有历史数据进行预测,设定预测时长为 1 d,最终得到的混淆矩阵结果分别如图 15、16 所示。根据每个类别的样本数量采用加权




图 15 LSTM 混淆矩阵预测结果

Fig.15 Prediction results of LSTM confusion matrix




图 16 PSR-LSTM 混淆矩阵预测结果

Fig.16 Prediction results of PSR-LSTM confusion matrix

平均的方式对混淆矩阵的各评估指标进行计算,结果如图 17 所示。

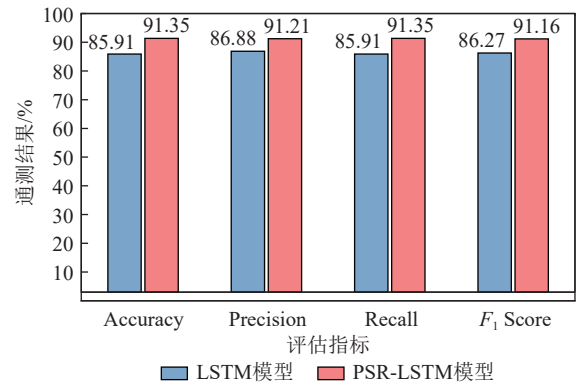


图 17 各评估指标预测结果

Fig.17 Prediction results of each evaluation index

由图 17 可知, LSTM 模型预测的准确率为 85.91%, F_1 值为 86.27%; PSR-LSTM 模型预测的准确率为 91.35%, F_1 值为 91.16%, 由此可见, 选用 PSR-LSTM 预测效果较好。基于 PSR-LSTM 对统计范围内标准化能量时序等级 E' 的真实值和预测值对比如图 18 所示。




图 18 能量时序等级真实值与预测值对比

Fig.18 Comparison of real and predicted values of energy time series

由图 18 中对于真实值和预测值的对比可知, 整体预测趋势与实际基本吻合。该矿 400B3 巷掘进期间共发生了 2 次较大能量的动力显现事件, 分别为能量值为 33 000 J 的“8·12”事件与能量值为 8 800 J 的“9·12”事件。通过测试结果不难发现, 模型成功预测到了这 2 次事件, 其中, 对“8·12”事件预测的标准化能量值 E' 为 0.81, 分类级别为 IV, 对于“9·12”事件预测的标准化能量值 E' 为 0.70, 分类级别为 III, 分类结果正确。测试结果表明模型的预测性能较好, 可实现对大能量事件提前预测, 进而为现场防冲预警提供参考。

5 结 论

1) 通过实例分析,掌握了急倾斜巨厚煤层巷道掘进过程中冲击地压 9 项前兆微震信息指标的时空演化规律,发现各微震信息指标对于预测大能量事件发生的敏感性存在差异。为提升预测准确率,基于 GARF 算法优选了 b 值、 $A(b)$ 值、缺震、EEM 值、 S 值、AC 值等 6 项指标,各指标之间具有显著的相关性,对预测冲击危险等级的敏感性较强。所用方法可结合大数据技术实现灾变信息实时分析和模型的迭代更新。

2) 构建了深度学习与多元混沌时序的急倾斜巨厚煤层掘进巷道的冲击危险等级预测模型,将优选的指标时序数据集基于改进的 C-C 法求得各指标的嵌入维数与时间延迟,对具有混沌特性的指标进行多元相空间重构。重构后的矩阵由 LSTM 神经网络训练测试,预测出目标为未来一天的冲击危险发展趋势,实现了不同冲击危险等级的预测划分,结果可作为急倾斜煤岩发生冲击显现的重要预警指标。

3) 运用混淆矩阵、Accuracy、 F_1 值等评价指标对预测模型进行了综合分析,测试结果表明模型的预测准确率达到 0.913 5, F_1 值达到了 0.911 6。实际应用中,模型成功预测到了历史掘进期间发生的 2 起大能量事件,表明模型可实现急倾斜煤层掘进巷道大能量事件的精确预测,能较好的满足现场需求。所提出的基于深度学习与多元混沌时序的微震信息指标数据融合驱动预测方法,可为急倾斜巨厚煤层掘进巷道的防冲预警提供参考与借鉴。

参考文献(References):

- [1] 潘一山,李忠华,章梦涛.我国冲击地压分布、类型、机理及防治研究[J]. *岩石力学与工程学报*, 2003, 22(11): 1844-1851.
PAN Yishan, LI Zhonghua, ZHANG Mengtao. Distribution, type, mechanism and prevention of rockburst in China[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2003, 22(11): 1844-1851.
- [2] 姜耀东,赵毅鑫.我国煤矿冲击地压的研究现状:机制、预警与控制[J]. *岩石力学与工程学报*, 2015, 34(11): 2188-2204.
JIANG Yaodong, ZHAO Yixin. State of the art: Investigation on mechanism, forecast and control of coal bumps in China[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2015, 34(11): 2188-2204.
- [3] 曹安业,陈凡,刘耀琪,等.冲击地压频发区矿震破裂机制与震源参量响应规律[J]. *煤炭学报*, 2022, 47(2): 722-733.
CAO Anye, CHEN Fan, LIU Yaoqi, et al. Response characteristics of rupture mechanism and source parameters of mining tremors in frequent coal burst area[J]. *Journal of China Coal Society*, 2022, 47(2): 722-733.
- [4] 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.
- [5] 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.
- [6] 窦林名,蔡武,巩思园,等.冲击危险性动态预测的震动波 CT 技术研究[J]. *煤炭学报*, 2014, 39(2): 238-244.
DOU Linming, CAI Wu, GONG Siyuan, et al. Dynamic risk assessment of rock burst based on the technology of seismic computed tomography detection[J]. *Journal of China Coal Society*, 2014, 39(2): 238-244.
- [7] 姜福兴,王平,冯增强,等.复合型厚煤层“震-冲”型动力灾害机理、预测与控制[J]. *煤炭学报*, 2009, 34(12): 1605-1609.
JIANG Fuxing, WANG Ping, FENG Zengqiang, et al. Mechanism, prediction and control of “rock burst induced by shock bump” kind dynamic accident in composite thickness coal[J]. *Journal of China Coal Society*, 2009, 34(12): 1605-1609.
- [8] 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.
- [9] 丛利,曹安业,周远宏,等.基于动静载冲击地压危险叠加的综合预警方法[J]. *采矿与安全工程学报*, 2020, 37(4): 767-776.
CONG Li, CAO Anye, ZHOU Yuanhong et al. The comprehensive pre-warning method of rock burst hazard based on theory of dynamic and static combined loading[J]. *Journal of Mining & Safety Engineering*, 2020, 37(4): 767-776.
- [10] 崔峰,贾冲,来兴平,等.基于加卸载响应比的冲击地压矿井急倾斜巨厚煤层推进速度研究[J]. *煤炭学报*, 2022, 47(2): 745-761.
CUI Feng, JIA Chong, LAI Xingping, et al. Study on advancing rate of steeply inclined extra-thick coal seam in rock burst mine based on loading-unloading response ratio[J]. *Journal of China Coal Society*, 2022, 47(2): 745-761.
- [11] 赵洪波,茹忠亮.冲击地压预测的 PSO-SVM 模型[J]. *岩石力学与工程学报*, 2007, 26(S1): 3479-3483.
ZHAO Hongbo, RU Zhongliang. PSO-SVM model for rock burst prediction[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2007, 26(S1): 3479-3483.
- [12] 谭云亮,孙中辉,杜学东.冲击地压 AE 时间序列小波神经网络预测模型[J]. *岩石力学与工程学报*, 2000, 19(S1): 1034-1036.
TAN Yunliang, SUN Zhonghui, DU Xuedong. Wavelet neural network prediction model of AE time series of rockburst[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2000, 19(S1): 1034-1036.
- [13] AHMAD M, HU J L, HADZIMA-NYARKO M, et al. Rockburst hazard prediction in underground projects using two intelligent classification techniques: A comparative study[J]. *Symmetry*, 2021, 13(4): 632.

- [14] 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]. Chinese Journal of Coal Science, 2019, 45(S1): 191–201.
- [15] DONG L J, LI X B, PENG K. Prediction of rockburst classification using random forest[J]. *Transactions of Nonferrous Metals Society of China*, 2013, 23(2): 472–477.
- [16] 陶慧, 马小平, 乔美英. 基于多变量混沌时间序列的冲击地压预测[J]. 煤炭学报, 2012, 37(10): 1624–1629.
TAO Hui, MA Xiaoping, QIAO Meiyang. Rock burst prediction on multivariate chaotic time series[J]. Journal of China Coal Society, 2012, 37(10): 1624–1629.
- [17] 崔峰, 何仕凤, 来兴平, 等. 基于相空间重构与深度学习的冲击地压矿井时间序列 b 值趋势[J]. 煤炭学报, 2023, 48(5): 2022–2034.
CUI Feng, HE Shifeng, LAI Xingping, et al. Trend of time sequence b value of rock burst mine based on phase space reconstruction and deep learning[J]. Journal of China Coal Society, 2023, 48(5): 2022–2034.
- [18] 刘慧敏, 徐方远, 刘宝举, 等. 基于 CNN-LSTM 的岩爆危险等级时序预测方法[J]. 中南大学学报(自然科学版), 2021, 52(3): 659–670.
LIU Huimin, XU Fangyuan, LIU Baoju, 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.
- [19] 徐伟进, 高孟潭. 根据截断的 G-R 模型计算东北地震区震级上限[J]. 地球物理学报, 2012, 55(5): 1710–1717.
XU Weijin, GAO Mengtan. Calculation of upper limit earthquake magnitude for Northeast seismic region of China based on truncated G-R model[J]. *Chinese Journal of Geophysics*, 2012, 55(5): 1710–1717.
- [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] SANDRI L, MARZOCCHI W. A technical note on the bias in the estimation of the b -value and its uncertainty through the Least Squares technique[J]. *Annals of Geophysics*, 2007, 50(3): 329–339.
- [22] 吴佳翼, 曹学锋. 全球地震活动性的定量研究(二): 1964 至 1983 年全球 6 级以上地震活动的分析[J]. 地震学报, 1987, 9(3): 225–238.
WU Jiayi, CAO Xuefeng. Quantitative studies of global seismicity (2): Discussion on global earthquakes ($m \geq 6$) from 1964 to 1983[J]. *Acta Seismologica Sinica*, 1987, 9(3): 225–238.
- [23] 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(S2): 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(S2): 449–463.
- [24] 谷继成, 魏富胜. 论地震活动性的量化地震活动度[J]. 中国地震, 1987, 3(S1): 14–24.
GU Jicheng, WEI Fusheng. On the quantification of seismic activity: Seismic activity[J]. *Seismology in China*, 1987, 3(S1): 14–24.
- [25] 卫鹏飞. 华北缺震曲线[J]. 地震研究, 1980, 3(4): 144–148.
WEI Pengfei. North China lack of earthquake curve[J]. *Journal of Seismological Research*, 1980, 3(4): 144–148.
- [26] 罗兰格, 侯建明. 地震活动性的标度[J]. 地震, 1987, 7(6): 40–45.
LUO Lange, HOU Jianming. Seismicity scale[J]. *Earthquake*, 1987, 7(6): 40–45.
- [27] 吕悦军, 陆远忠. 用算法复杂性分析时间序列[J]. 中国地震, 1993, 9(3): 39–44.
LU Yuejun, LU Yuanzhong. Characterization of time sequence by algorithmic complexity[J]. *Earthquake Research in China*, 1993, 9(3): 39–44.
- [28] 韩泽鹏. 煤矿冲击矿压前兆信息识别及预警模型研究[D]. 徐州: 中国矿业大学, 2020: 16–18.
HAN Zepeng. Study on identification of precursor information and early warning model of rock burst in coal mine[D]. Xuzhou: China University of Mining and Technology, 2020: 16–18.
- [29] 曹安业, 刘耀琪, 杨旭, 等. 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]. 煤炭学报, 2023, 48(10): 3659–3673.
CAO Anye, LIU Yaoqi, YANG Xu, et al. Physical index and data fusion-driven method for coal burst prediction in time sequence[J]. *Journal of China Coal Society*, 2023, 48(10): 3659–3673.
- [30] 陈铿, 韩伯棠. 混沌时间序列分析中的相空间重构技术综述[J]. 计算机科学, 2005, 32(4): 67–70.
CHEN Keng, HAN Botang. A survey of state space reconstruction of chaotic time series analysis[J]. *Computer Science*, 2005, 32(4): 67–70.
- [31] 娄天泷. 基于多元混沌序列环境重金属 LSTM 预测改进[D]. 兰州: 西北师范大学, 2020.
LOU Tianlong. Improvement of environmental heavy metal LSTM prediction based on multivariate chaotic sequence[D]. Lanzhou: Northwest Normal University, 2020.
- [32] KUGIUMTZIS D. State space reconstruction parameters in the analysis of chaotic time series: The role of the time window length[J]. *Physica D: Nonlinear Phenomena*, 1996, 95(1): 13–28.
- [33] KIM H S, EYKHOLT R, SALAS J D. Nonlinear dynamics, delay times, and embedding windows[J]. *Physica D: Nonlinear Phenomena*, 1999, 127(1-2): 48–60.
- [34] 陆振波, 蔡志明, 姜可宇. 基于改进的 C-C 方法的相空间重构参数选择[J]. 系统仿真学报, 2007, 19(11): 2527–2529, 2538.
LU Zhenbo, CAI Zhiming, JIANG Keyu. Determination of embedding parameters for phase space reconstruction based on improved C-C method[J]. *Journal of System Simulation*, 2007, 19(11): 2527–2529, 2538.
- [35] 张海龙, 闵富红, 王恩荣. 关于 Lyapunov 指数计算方法的比较[J]. 南京师范大学学报(工程技术版), 2012, 12(1): 5–9.
ZHANG Hailong, MIN Fuhong, WANG Enrong. The comparison for Lyapunov exponents calculation methods[J]. *Journal of Nanjing Normal University (Engineering and Technology Edition)*, 2012, 12(1): 5–9.
- [36] 王圣伟, 李萍, 娄天泷, 等. 基于多元混沌时间序列 PS-LSTM 污染物预测模型[J]. 传感器与微系统, 2022, 41(4): 117–120.
WANG Shengwei, LI Ping, LOU Tianlong, et al. Time-series PS-LSTM contaminant prediction model based on multivariate chaotic[J]. *Transducer and Microsystem Technologies*, 2022, 41(4): 117–120.