

中文引用格式:张杰,杨科,范超尘. 基于 MTAM-LSTM 的采煤工作面支架载荷预测方法[J]. 中国安全科学学报,2026,36(3):144-152.
英文引用格式:ZHANG Jie,YANG Ke,FAN Chaochen. Prediction method of support load in coal mining face based on MTAM-LSTM [J].
China Safety Science Journal,2026,36(3):144-152.

基于 MTAM-LSTM 的采煤工作面支架载荷预测方法^{*}

张杰^{1,2},杨科^{1,2}教授,范超尘^{1,2}

(1 安徽理工大学 深部煤炭安全开采与环境保护全国重点实验室,安徽 淮南 232001;

2 安徽理工大学 矿业工程学院,安徽 淮南 232001)

中图分类号:X936;TD 323

文献标志码:A

DOI: 10.16265/j.cnki.issn1003-3033.2026.03.1821

基金项目:国家自然科学基金区域创新发展联合基金资助(U21A20110)。

【摘要】 为有效预测液压支架载荷、评估支架运行状态,提出一种基于多尺度卷积时间注意力模块(MTAM)-长短时记忆(LSTM)神经网络的液压支架载荷预测模型。首先,采用自适应噪声完备集合经验模态分解(CEEMDAN)算法分解支架载荷数据获取本征模态分量,基于 K-L 散度准则剔除本征模态分量中的冗余分量形成支架载荷预测输入序列;其次,建立 MTAM 捕捉支架载荷变化特征,静态注意力生成数据特征信息的注意力权重,动态注意力优化不同序列特征的关注度,并引入残差学习保持特征信号的完整性;然后,利用 LSTM 构建特征信息与支架载荷之间的深层依赖关系,实现支架载荷数据的超前预测;最后,选取陕西某冲击地压矿井 402102 工作面液压支架载荷数据进行实证分析,对比不同模型均方根误差、决定系数和平均绝对误差 3 种评价指标,结果表明:MTAM-LSTM 模型的均方根误差(RMSE)和平均绝对误差(MAE)均明显小于对比模型,RMSE 整体降低 0.16~0.45,MAE 降低 0.16~0.45,不同场景下决定系数 R^2 达到 0.91,验证了 MTAM-LSTM 的预测准确率和模型泛化能力。

【关键词】 多尺度卷积时间注意力模块(MTAM); 长短时记忆神经网络(LSTM); 采煤工作面; 载荷预测; 液压支架; 泛化能力

Prediction method of support load in coal mining face based on MTAM-LSTM

ZHANG Jie^{1,2}, YANG Ke^{1,2}, FAN Chaochen^{1,2}

(1 State Key Laboratory for Safe Mining of Deep Coal Resources and Environment Protection,
Anhui University of Science and Technology, Huainan Anhui 232001, China; 2 School of Mining
Engineering, Anhui University of Science and Technology, Huainan Anhui 232001, China)

Abstract: In order to effectively predict hydraulic support loads and evaluate the operational status of supports, a hydraulic support load prediction model based on MTAM-LSTM was proposed. The CEEMDAN algorithm was employed to decompose the load data of supports and extract intrinsic mode functions. Redundant components in the intrinsic mode functions were eliminated according to K-L divergence criterion, thereby forming the input sequence for load prediction. An MTAM was constructed to capture the variation characteristics of hydraulic support loads. Static attention generated attention weights for feature

information of data, while dynamic attention optimized the focus on different sequence features. Residual learning was introduced to maintain the integrity of feature signals. LSTM networks were then utilized to establish deep dependencies between feature information and hydraulic support loads, enabling advanced prediction of support load data. Field data from the 402102 working face of a rockburst-prone coal mine in Shaanxi were used for empirical validation. RMSE, R^2 , and MAE were used as evaluation metrics for comparison among different models. The results show that the RMSE and MAE of the MTAM-LSTM model are significantly lower than those of the comparison models, with RMSE reduced by 0.16–0.45 and MAE reduced by 0.16–0.45, while the coefficient of determination R^2 reaches 0.91 under different scenarios, thereby validating the prediction accuracy and generalization capability of MTAM-LSTM model.

Keywords: multi-convolution temporal attention module (MTAM); long short-term memory (LSTM); mining working face; load prediction; hydraulic support; generalization ability

0 引言

液压支架载荷作为顶板岩层应力状态变化的重要指标,能够反映矿井内部地质结构稳定性^[1-2]。随着开采深度的增加,地质条件变得更加复杂,采煤工作面顶板管理难度大,避免液压支架长期处于高负荷状态下工作,造成因支架故障导致的生产停滞^[3]。因此,准确预测液压支架载荷对于确保矿井安全和提高生产效率具有重要意义。

采煤工作面液压支架载荷反映了煤层开采过程中岩体的变形和破坏程度^[4-5],分析和预测液压支架载荷数据能够评估工作面围岩状态。传统支架载荷预测方法主要包含经验判断及物理力学模型^[6-7],霍丙杰等^[8]利用模糊数学理论,基于不同影响指标建立不同矿压强度的预测模型,利用现场数据全面分析了模型有效性。徐刚等^[9]提出基于综放顶板分区支承的力学模型,分析了工作面推进过程中顶板矿压变化,探讨了支架工作阻力演化特征。随着监测技术的发展,基于数据驱动方法被广泛应用于液压支架载荷预测,贺超峰等^[10]设计了一种基于反向传播(Back Propagation, BP)神经网络的矿压预测方法,通过分析采深、倾角等关键影响因素,实现对来压步距和强度的准确预测。XIAO Yigai 等^[11]提出基于卷积神经网络(Convolutional Neural Network, CNN)的矿山地压监测预警系统,通过岩石力学分析和微震监测技术实现冲击地压风险的实时分级预警,在实际应用中验证了其有效性。DONG Jianjun 等^[12]提出基于液压支架监测数据集的多元线性回归模型,验证了限制性多元线性回归模型预测矿压的显著效果。赵毅鑫等^[13]利用深度学习算法建立了一种基于长短时记忆(Long Short-Term Memory, LSTM)网络的矿压预测方法,通过不同矿

压数据验证模型的准确率和泛化能力。综上,现有模型在特征提取方面多依赖单一尺度或单一结构,未能充分挖掘液压支架载荷信号中多尺度、多因素耦合特征。

工作面液压支架在矿压周期显现、煤岩结构扰动、采掘活动干扰等多重因素影响下,其载荷信号表现出明显的非平稳性与非线性特征。因此,笔者拟提出基于多尺度卷积时间注意力模块(Multi-convolution Temporal Attention Module, MTAM)–LSTM 的采煤工作面支架载荷预测方法,通过多尺度卷积捕捉局部特征、动态–静态注意力机制增强关键特征,利用 LSTM 预测支架载荷变化,并基于陕西某矿液压支架载荷数据开展预测研究,以期为液压支架载荷的超前预测提供技术支撑。

1 液压支架载荷预测框架和数据预处理

1.1 数据获取和预测框架

预测分析陕西咸阳某矿 402102 采煤工作面 2019 年 8 月 14 日—2020 年 1 月 14 日液压支架载荷数据,其主采 4 号煤层平均开采深度 680 m,平均倾角小于 5°,平均煤厚 23 m,煤层有强冲击倾向性。工作面“煤炮”频繁,引发巷道动力显现强烈。

支架载荷呈现出高度的非线性和动态变化特征,导致数据具有复杂的空间分布和时序特征^[14]。为有效监测液压支架状态,提出基于深度学习的支架载荷预测方法,预测框架如图 1 所示。

1.2 支架载荷数据处理

为捕捉支架载荷的时变特性,利用自适应噪声完备集合经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise,




图1 液压支架载荷预测框架

Fig.1 Load prediction framework of hydraulic support

CEEMDAN)分解载荷数据为不同频率的本征模态分量。CEEMDAN 能够避免经验模态分解(Ensemble Empirical Mode Decomposition,EEMD)存在模态混合等问题,实现较低的重构误差,降低白噪声对分解信号的干扰^[15],形成支架载荷预测模型的关键数据特征,CEEMDAN 算法分解分量如图2所示。

利用 K-L 散度识别 CEEMDAN 分解后本征模态分量中存在的冗余分量,具体步骤如下:

1) CEEMDAN 分解原始信号 $X=(x_1, x_2, \cdots, x_n)$, 得到信号的证模态分量 (Intrinsic Mode Function, IMF)。

2) 计算原始信号和单个 IMF 分量 $E=(e_1, e_2, \cdots, e_n)$ 的概率分布 $p(x)$ 和 $q(x)$, 得到 E 相对于 X 的 K-L 散度 δ 为:

$$\delta(p,q)=\sum_{x\in n}p(x)\lg\frac{p(x)}{q(x)}\tag{1}$$

计算 K-L 散度值 $D(p,q)$:

$$D(p,q)=\delta(p,q)+\delta(q,p)\tag{2}$$

在实际应用中,不同数据下散度值存在差异,需结合具体情况进行调整^[16]。表1中,K-L 散度值归一化后 IMF1-IMF6 的散度值均小于 0.08,而 IMF7-IMF11 的散度值显著升高,呈现明显的数量级差异,表明后者与原信号的相关性较弱。基于该特性将阈值设置为 0.1,用于剔除冗余分量提升输入特征的有效性。图2中 IMF7 的平均频率相较于 IMF6 出现显著偏离,表现出平均频率变化的不连续性,表明该分量存在弱相关成分或由模态混叠引起的异常模态^[17]。因此,选取 IMF1-IMF6 为 MTAM-LSTM 训练的特征样本。




图2 CEEMDAN 分解的 IMF 分量

Fig.2 IMF components decomposed by CEEMDAN

表1 原始数据与 IMF 之间的 K-L 散度归一化值

Table 1 Normalised value of K-L scatter between the original data and IMF

IMF 分量	K-L 值	IMF 分量	K-L 值
IMF 1	0.018	IMF 7	0.269
IMF 2	0.028	IMF 8	0.312
IMF 3	0.009	IMF 9	0.459
IMF 4	0	IMF 10	1
IMF 5	0.030	IMF 11	0.758
IMF 6	0.071	—	—

2 基于 MTAM-LSTM 的采煤工作面 液压支架载荷预测方法

2.1 采煤工作面液压支架载荷预测模型

采煤工作面液压支架载荷预测流程如图3所示,具体包含数据预处理、特征提取和信息反馈3个部分。归一化原始支架载荷数据并划分数据集,通过动态注意力模块学习更新静态注意力权重,获得关键特征激励权重,提高 MTAM 的特征提取能力,利用 LSTM 映射输出结果。

MTAM-LSTM 模型以 $x_{l-k}, \cdots, x_{l-1}, x_l$ 支架载荷 IMF 分量作为输入数据,输出未来不同时间点支架载荷变化,模型网络参数设置见表2。为捕捉液压支架载荷短期依赖信息、长时间依赖和周期性趋势,将卷积核分别设置为 1、3 和 5。采用 TCN 对液压支架载荷序列进行建模,提取多尺度时间依赖特征。TCN 的扩张因子设置为 $d=2^k$,其中, $k \in \{0,1,2,3\}$,能够保持模型计算效率的同时扩大感受野,覆盖更长时间依赖信息^[18]。




图 3 MTAM-LSTM 液压支架载荷预测流程

Fig. 3 MTAM-LSTM hydraulic support load prediction flow chart

表 2 MTAM-LSTM 网络参数设置

Table 2 MTAM-LSTM network parameter settings

类型	输入形状	卷积核	通道数	输出形状
Input Layer	(None, 12, 6)	—	12	(None, 12, 6)
Conv1D	(None, 12, 6)	1	16	(None, 12, 16)
Conv1D	(None, 12, 6)	3	16	(None, 12, 16)
Conv1D	(None, 12, 6)	5	16	(None, 12, 16)
Concatenate	(None, 12, 6)	—	48	(None, 12, 48)
TCN+TAM	(None, 12, 48)	3	48	(None, 12, 24)
BatchNormalization	(None, 12, 24)	—	48	(None, 12, 24)
TCN+TAM	(None, 12, 24)	3	48	(None, 12, 12)
LSTM	(None, 12, 12)	—	32	(None, 32)
Dense	(None, 32)	—	5	(None, 5)

为解决支架载荷数据特征提取过程中特征关注度低的问题,设计 TAM 获取各通道激励权重,挖掘各通道特征数据间的相互依赖关系,自适应增强时序信号相关特征^[19]。通过静态注意力捕捉长期稳定的特征权重,动态注意力根据输入特征的时间步动态调整权重分布。利用加权融合的方式进行集成,以兼顾全局与局部信息。输入特征信号 $\mathbf{Y} = [y_1, y_2, \dots, y_c]$, $\mathbf{W}$ 为融合后的注意力权重。

$$\mathbf{D} = G(S(\delta(P(\mathbf{Y}^T)))) \tag{3}$$

$$\mathbf{S} = \text{Conv}(\text{TCN}(\mathbf{Y})) \tag{4}$$

$$\mathbf{W} = \mathbf{S} \odot \mathbf{D} \tag{5}$$

式中: $P(\cdot)$ 、 $S(\cdot)$ 和 $G(\cdot)$ 分别为通道数为 1 的

一维卷积、标准化操作和全局平均池化; $\mathbf{D}$ 和 $\mathbf{S}$ 分别为动态和静态注意力的输出。

注意力权重充分考虑了全局信息的引导,可有效突出关键特征信息。然而,随着网络层数加深,特征信息会出现表达能力弱化的问题。因此,引入残差连接保留原始信息的同时增强对关键信号的识别能力^[20]。残差连接的输出 $\mathbf{Y}'$ 表示为:

$$\mathbf{Y}' = \mathbf{W} \times \mathbf{Y} \oplus \mathbf{Y} \tag{6}$$

作为处理时序数据的可扩展性模型,LSTM 解决了循环神经网络(Recurrent Neural Network,RNN)梯度爆炸和梯度消失问题,保留了 RNN 对时间序列数据出色预测能力^[21]。LSTM 基本结构如图 4 所




图 4 LSTM 基本结构
Fig. 4 LSTM basic structure

示,LSTM 通过输入门、遗忘门和输出门控制特征信息的输入输出,消除冗余信息,提取和选择关键特征信息^[22],其中激活函数为双曲正切函数(Hyperbolic Tangent, TanH)。

2.2 数据预处理

时间窗数据采集如图 5 所示,液压支架载荷样本数据以时间窗大小为 n 、滑动步长为 m 进行采样,旨在捕捉历史液压支架载荷随时间变化的动态演变,构建时间序列数据的输入表示。




图 5 时间窗数据采集
Fig. 5 Time window data acquisition

采用数据归一化方法确保模型训练时输入数据的尺度一致,优化算法模型使其更快地收敛,提高模型的泛化能力。数据归一化过程:

$$X = \begin{cases} \frac{x - x_{\min}}{x_{\max} - x_{\min}}, & \text{if } x_{\max} \neq x_{\min} \\ 0, & \text{if } x_{\max} = x_{\min} \end{cases} \quad (7)$$

式中: x 为输入载荷数据; $x_{\max}$ 和 $x_{\min}$ 分别为 x 的最大值和最小值。

2.3 MTAM-LSTM 模型评价指标

MTAM-LSTM 模型采用均方根误差(Root Mean Square Error, RMSE)、决定系数 R^2 和平均绝对误差(Mean Absolute Error, MAE)评价指标进行性能评估。RMSE 通过比较支架载荷预测值和实际值之间的偏差来衡量准确性, R^2 表示非线性回归模型的拟

合优度,MAE 通过计算平均绝对误差占比来评价模型有效性,模型训练过程中优化器采用 Adam,损失函数为 MSE。

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{k=1}^N (y_k - y'_k)^2} \quad (8)$$

$$R^2 = 1 - \frac{\sum_{k=1}^N (y_k - y'_k)^2}{\sum_{k=1}^N (y_k - \bar{y})^2} \quad (9)$$

$$\text{MAE} = \frac{1}{N} \sum_{k=1}^N |y_k - y'_k| \quad (10)$$

式中: N 为样本个数; y_k 和 y'_k 为第 k 个实际值和预测值; $\bar{y}$ 为实际样本的平均值。

3 液压支架载荷预测对比分析

3.1 试验验证

基于 402102 工作面开展预测模型对比试验,将原始时序数据以 2 : 1 划分为训练集和测试集,旨在保证训练集数据充分,以便模型学习足够的数据特征,并利用测试集验证模型的预测性能。

为验证 LSTM 模型隐藏神经元数对性能的敏感性,以 4 号液压支架载荷数据,设置 4 组对比试验,见表 3。从表 3 可以看出,模型在隐藏单元数为 32 的设置下取得最佳预测性能,模型预测时间为 0.44 s,说明该参数设置能够较好地平衡模型表达能力与训练稳定性,以及矿井实时预测的要求。

表 3 参数组合对比结果

Table 3 Comparison results of parameter combinations					
试验	隐藏神经元数	RMSE	R^2	MAE	T/s
A	16	3.28	0.76	2.46	0.41
B	32	2.48	0.86	1.77	0.44
C	64	2.66	0.84	2.05	0.46
D	128	2.94	0.81	2.03	0.49

通过自相关函数^[23],确定支架载荷的滞后阶数为 12(时间窗大小 n)。MTAM-LSTM 模型分别进行 8 次不同预测步数下的支架载荷预测如图 6 所示。预测步数从 1 增加到 5 时,模型性能基本保持平衡,表明所提模型能有效预测未来 5 h 内的载荷变化。随着预测步数进一步增加,导致模型因计算复杂度增加而出现模型稳定性和准确率降低。因此,将液压支架载荷预测模型的预测步数设定为 5(滑动步长 m)。

为分析 MTAM-LSTM 模型预测性能,选取 402102 工作面 4 号液压支架载荷数据,开展不同模型对比试验,如图 7 所示。从图 7a 中可以看出,




图 6 不同预测步数对应的评价指标

Fig. 6 Evaluation metrics for different prediction steps

MTAM-LSTM 模型的预测数据与实测数据最为接近,能准确地预测支架载荷突变的位置。图 7b 和图 7c 中,LSTM 和 BP 神经网络仅对 4 号支架载荷数据展现较好的预测效果,在 60、100 号液压支架上预测值与真实值存在较大的偏差,表明 MTAM-LSTM 模型具有更好的稳定性。

5 种预测模型误差对比结果见表 4, MTAM-LSTM 对比无 CEEMDAN 模块的 MTAM-LSTM 以及 VMD-MTAM-LSTM 验证了 CEEMDAN 模块有效降低模态混叠的影响,显著提升了预测精度与稳定性。相较于 VMD,CEEMDAN 能更有效地应对非平稳载荷数据的冗余分量。MTAM-LSTM 模型的预测效果优于其他 2 种算法,且在不同支架下的 MAE 比






图 7 402102 工作面 4 号液压支架预测曲线

Fig. 7 Prediction curve of hydraulic support in 402102 working face

LSTM 模型分别降低 0.31、1.29 和 0.33;比 BP 模型分别降低 0.13、1.83 和 0.96;同时,具有更高的 R^2 值,表明所提方法具有更优越的模型稳定性。

表 4 402102 工作面不同支架数据下的预测误差对比

Table 4 Comparison of prediction errors under different support data in 402102 working face

方法	4 号液压支架			60 号液压支架			100 号液压支架		
	RMSE	R^2	MAE	RMSE	R^2	MAE	RMSE	R^2	MAE
MTAM-LSTM	4.32	0.79	3.14	5.37	0.79	4.01	4.38	0.75	3.36
无 CEEMDAN	4.53	0.73	3.34	6.08	0.71	4.59	4.62	0.72	3.42
VMD-MTAM-LSTM	4.50	0.71	3.05	6.1	0.74	4.2	4.87	0.70	3.49
LSTM ^[13]	4.87	0.73	3.45	7.11	0.64	5.30	4.92	0.69	3.69
BP ^[10]	4.48	0.77	3.27	7.50	0.60	5.84	5.56	0.60	4.32

通过 3 折交叉验证模型稳定性,结果如图 8 所示。从 RMSE、 R^2 和 MAE 可以看出,所提模型相比

LSTM 和 BP 具有更低的预测误差;且所提模型的误差棒波动最小,进一步说明 MTAM-LSTM 在预测






图 8 402102 工作面液压支架交叉验证性能

Fig. 8 402102 Working face hydraulic support cross validation performance

4 号、60 号和 100 号液压支架载荷数据时的精度和稳定性均优于其他 2 种方法。

3.2 模型消融试验

设计模型消融试验验证多尺度卷积(Multi-scale Convolutional Neural Network, MCNN)、TAM 和 LSTM 对预测性能的贡献。基于 402102 工作面 4 号液压支架数据开展 MCNN-LSTM、Model_1、Model_2 和 LSTM 对比试验,见表 5。MCNN-LSTM 模型的 MAE 比 LSTM 模型降低 0.14, Model_2 模型的 MAE 相比 Model_1 降低 0.30, Model_1、LSTM 的 R^2 分别为 0.67、0.73,验证了 MCNN 增强模型数据特征提取的能力,TAM、LSTM 模块提升了支架载荷预测的精度。

表 5 模型消融对比结果

Table 5 Model Ablation Comparison Results				
模型	关键模块	RMSE	R^2	MAE
MCNN-LSTM	MCNN、LSTM	4.75	0.75	3.31
Model_1	TAM	5.41	0.67	3.94
Model_2	MTAM	4.84	0.74	3.64
LSTM	LSTM	4.87	0.73	3.45

3.3 跨矿井验证

为研究 MTAM-LSTM 模型在不同矿井支架载荷数据下的泛化性能,利用安徽某矿 11513 工作面支架载荷数据进行模型验证。11513 工作面煤层平均煤厚 4.52 m,在工作面开采、顶板破碎、隧道开挖等先后影响下,煤体承载力大幅降低,容易引发失稳灾害。数据集为 2018 年 11 月 1 日—19 日采集的液压支架载荷数据,样本时间跨度 19 天,能够覆盖周期来压间隔。将数据集划分为训练集(前 296 个样本点)和测试集(后 148 个样本点),不同支架数据下的预测误差对比见表 6,可以看出,MTAM-LSTM 在不同矿井液压支架载荷预测中依旧具有较好的预测性能,进一步体现了 MTAM-LSTM 模型更高的稳定性和泛化能力。

表 6 11513 工作面不同支架数据下的预测误差对比
Table 6 Comparison of prediction errors under different support data in 11513 working surface

方法	3 号液压支架			10 号液压支架		
	RMSE	R^2	MAE	RMSE	R^2	MAE
MTAM-LSTM	1.32	0.87	0.50	2.27	0.91	1.17
LSTM ^[13]	2.00	0.70	0.79	3.14	0.82	1.42
BP ^[10]	2.12	0.65	0.94	3.56	0.67	1.91

基于 MTAM-LSTM 的采煤工作面支架载荷预测模型在实际应用中仍可能面临以下问题:①不同矿井监测系统的数据采样频率不统一,导致输入数据分布存在差异,影响模型的泛化性能;②部分矿井传感器布设条件受限,造成关键输入特征缺失,降低模型的预测准确性;③模型无法完全预测支架载荷突变情况。根据以上可能存在的问题,后续将探索在线学习机制动态更新模型参数以适应井下实时变化的地质条件。

4 结 论

1) 通过 K-L 散度有效识别 CEEMDAN 分解后模态分量的弱相关分量,确定 IMF1—IMF6 为 MTAM-LSTM 训练的特征样本,有助于增强模型预测性能。

2) 基于 402102 采煤工作面 4 号、60 号和 100 号液压支架载荷数据进行模型训练,得到模型的 RMSE、 R^2 和 MAE 分别为 4.32、0.79 和 3.14,5.37、0.79 和 4.01,4.38、0.75 和 3.36,验证了 MTAM-LSTM 的预测准确率和稳定性。

3) 4 种模型的消融对比结果证明,MCNN、TAM、LSTM 这 3 个模块对提升工作面液压支架载荷数据的特征提取和预测性能具有重要作用。MTAM-LSTM 在 11513 工作面支架载荷数据的 R^2 为 0.91,验证了 MTAM-LSTM 模型的泛化能力和跨矿井应用效果。

参 考 文 献

[1] 庞义辉,王国法,任怀伟. 大采高工作面煤壁片帮的多因素敏感性分析[J]. 采矿与安全工程学报, 2019, 36(4): 736-745.
PANG Yihui, WANG Guofa, REN Huaiwei. Multiple influence factor sensitivity analysis on coal wall spalling of workface with large mining height[J]. Journal of Mining & Safety Engineering, 2019, 36(4): 736-745.

[2] 王慧,赵国超,宋宇宁,等. 基于改进的威布尔分布的液压支架可靠性评估方法[J]. 中国安全科学学报, 2018, 28(5): 99-104.
WANG Hui, ZHAO Guochao, SONG Yuning, et al. Reliability evaluation method of hydraulic support based on improved

- Weibull distribution[J]. China Safety Science Journal, 2018, 28(5): 99–104.
- [3] 魏文艳. 综采工作面智能化开采技术发展现状及展望[J]. 煤炭科学技术, 2022, 50(增2): 244–253.
WEI Wenyan. Development status and prospect of intelligent mining technology of longwall mining[J]. Coal Science and Technology, 2022, 50(S2): 244–253.
- [4] 杨科, 刘千贺, 李志华. 厚松散层上提工作面覆岩运移与支架-围岩关系研究[J]. 煤炭科学技术, 2015, 43(10): 12–17.
YANG Ke, LIU Qianhe, LI Zhihua. Study on relationship between overburden strata migration in thick loose strata with extending upper extraction limit coal mining face and support-surrounding rock[J]. Coal Science and Technology, 2015, 43(10): 12–17.
- [5] 刘畅, 刘正和, 张俊文, 等. 工作面长度对覆岩空间结构演化及大采高采场矿压规律的影响[J]. 岩土力学, 2018, 39(2): 691–698.
LIU Chang, LIU Zhenghe, ZHANG Junwen, et al. Effect of mining face length on the evolution of spatial structure of overlying strata and the law of underground pressure in large mining height face[J]. Rock and Soil Mechanics, 2018, 39(2): 691–698.
- [6] 李云鹏, 赵善坤, 李杨, 等. 复杂坚硬岩层条件下特厚煤层综放开采矿压分级预测[J]. 煤炭学报, 2021, 46(增1): 38–48.
LI Yunpeng, ZHAO Shankun, LI Yang, et al. Prediction on weighting classification of fully-mechanized caving mining under extremely thick coal seam[J]. Journal of China Coal Society, 2021, 46(S1): 38–48.
- [7] 曾庆田, 吕珍珍, 石永奎, 等. 基于 Prophet+LSTM 模型的煤矿井下工作面矿压预测研究[J]. 煤炭科学技术, 2021, 49(7): 16–23.
ZENG Qingtian, LYU Zhenzhen, SHI Yongkui, et al. Research on prediction of underground coal mining face pressure based on Prophet+LSTM model[J]. Coal Science and Technology, 2021, 49(7): 16–23.
- [8] 霍丙杰, 荆雪冬, 于斌, 等. 坚硬顶板厚煤层采场来压强度分级预测方法研究[J]. 岩石力学与工程学报, 2019, 38(9): 1 828–1 835.
HUO Bingjie, JING Xuedong, YU Bin, et al. A classification forecasting method for the weighting intensity of stopes of thick coal seams with hard roofs[J]. Chinese Journal of Rock Mechanics and Engineering, 2019, 38(9): 1 828–1 835.
- [9] 徐刚, 张春会, 蔺星宇, 等. 基于分区支承力学模型的综放工作面顶板矿压演化与压架预测[J]. 煤炭学报, 2022, 47(10): 3 622–3 633.
XU Gang, ZHANG Chunhui, LIN Xingyu, et al. Predicting ground pressure evolution and support crushing of fully mechanized top coal caving face based on zoning support mechanical model[J]. Journal of China Coal Society, 2022, 47(10): 3 622–3 633.
- [10] 贺超峰, 华心祝, 杨科, 等. 基于 BP 神经网络的工作面周期来压预测[J]. 安徽理工大学学报:自然科学版, 2012, 32(1): 59–63.
HE Chaofeng, HUA Xinzhu, YANG Ke, et al. Forecast of periodic weighting in working face based on back-propagation neural network[J]. Journal of Anhui University of Science and Technology: Natural Science, 2012, 32(1): 59–63.
- [11] XIAO Yigai, DENG Hongwei, XIE Zhimou, et al. Mine ground pressure monitoring and early warning based on deep learning data analysis[J]. Mobile Information Systems, 2022, 2022(1): DOI: 10.1155/2022/6255119.
- [12] DONG Jianjun, XIE Zhengquan, JIANG Hao, et al. Multiple regression method for working face mining pressure prediction based on hydraulic support monitoring dataset[J]. Frontiers in Earth Science, 2023, 11: DOI: 10.3389/feart.2023.1114033.
- [13] 赵毅鑫, 杨志良, 马斌杰, 等. 基于深度学习的大采高工作面矿压预测分析及模型泛化[J]. 煤炭学报, 2020, 45(1): 54–65.
ZHAO Yixin, YANG Zhiliang, MA Binjie, et al. Deep learning prediction and model generalization of ground pressure for deep longwall face with large mining height[J]. Journal of China Coal Society, 2020, 45(1): 54–65.
- [14] 钱鸣高, 许家林. 煤炭开采与岩层运动[J]. 煤炭学报, 2019, 44(4): 973–984.
QIAN Minggao, XU Jialin. Behaviors of strata movement in coal mining[J]. Journal of China Coal Society, 2019, 44(4): 973–984.
- [15] 秦长坤, 赵武胜, 贾海宾, 等. 基于模态分解和深度学习的煤矿微震时序预测方法[J]. 煤炭学报, 2024, 49(9):

3 781–3 797.

QIN Changkun, ZHAO Wusheng, JIA Haibin, et al. A method for predicting the time series of microseismic events in coal mines based on modal decomposition and deep learning[J]. Journal of China Coal Society, 2024, 49(9): 3 781–3 797.

- [16] 韩中合, 朱霄珣, 李文华. 基于 K-L 散度的 EMD 虚假分量识别方法研究[J]. 中国电机工程学报, 2012, 32(11): 112–117, 154.

HAN Zhonghe, ZHU Xiaoxun, LI Wenhua. A false component identification method of EMD based on kullback-leibler divergence[J]. Proceedings of the CSEE, 2012, 32(11): 112–117, 154.

- [17] 赵润. 智能环境中基于 RFID 的无源感知关键技术研究[D]. 上海: 上海交通大学, 2019.
ZHAO Run. Boosting RFID based passive sensing in smart environment[D]. Shanghai: Shanghai Jiaotong University, 2019.

- [18] GAO Tianyu, LI Zhanli, LI Hongan. A prediction network for hydraulic support pressure based on multitimescale feature extraction[J]. Mathematical Problems in Engineering, 2022, 2022(1): DOI: 10.1155/2022/8526744.

- [19] GAO Yifei, ZHANG Xiaohang, LI Zhengren, et al. An attention-based spatio-temporal model for methane concentration forecasting in coal mine[J]. Neural Processing Letters, 2023, 55(4): 4 777–4 798.

- [20] HAN Shuzhen, SUN Shengke, ZHAO Zhanshan, et al. Deep residual multiscale convolutional neural network with attention mechanism for bearing fault diagnosis under strong noise environment[J]. IEEE Sensors Journal, 2024, 24(6): 9 073–9 081.

- [21] 王红伟, 伍永平, 解盘石, 等. 大倾角变角度综放工作面顶板运移与支架稳定性分析[J]. 中国矿业大学学报, 2017, 46(3): 507–513.

WANG Hongwei, WU Yongping, XIE Panshi, et al. Research on strata movement and support stability of fully mechanized sublevel caving workface with variable angle in steeply dipping seam[J]. Journal of China University of Mining & Technology, 2017, 46(3): 507–513.

- [22] YU Yong, SI Xiaosheng, HU Changhua, et al. A review of recurrent neural networks: LSTM cells and network architectures[J]. Neural Computation, 2019, 31(7): 1 235–1 270.

- [23] 康帅, 李治甫, 王自法, 等. 基于相关函数和卷积神经网络的结构损伤识别[J]. 地震工程与工程振动, 2024, 44(2): 50–60.

KANG Shuai, LI Zhifu, WANG Zifa, et al. Structural damage identification based on correlation function and CNN[J]. Earthquake Engineering and Engineering Dynamics, 2024, 44(2): 50–60.

作者简介: 张杰 (1995—),男,安徽六安人,博士研究生,主要研究方向为煤岩动力灾害预测预警。
E-mail:jiezhang617@163.com。