



## 基于LSTM的液压支架尾梁倾角预测方法

姚钰鹏 张境麟 熊武

### 引用本文:

姚钰鹏, 张境麟, 熊武. 基于LSTM的液压支架尾梁倾角预测方法[J]. 煤炭科学技术, 2025, 53(5): 362–371.

YAO Yupeng, ZHANG Jinglin, XIONG Wu. Method of tail beam posture prediction of top coal caving hydraulic support based on LSTM[J]. Coal Science and Technology, 2025, 53(5): 362–371.

在线阅读 View online: <https://doi.org/10.12438/cst.2024-0211>

### 您可能感兴趣的其他文章

#### Articles you may be interested in

#### 基于Prophet+LSTM模型的煤矿井下工作面矿压预测研究

Research on prediction of underground coal mining face pressure based on Prophet+LSTM model

煤炭科学技术. 2021, 49(7): 16–23 <http://www.mtkxjs.com.cn/article/id/5a8ce5fc-b7c0-4929-9c3c-3f8f38c11b4c>

#### 液压支架放煤机构安全过煤临界准则及放煤口精准控制方法研究

Safe passing critical criterion for drawn top-coal on rear conveyor and accurate control approach for drawing opening dimension

煤炭科学技术. 2023, 51(9): 251–260 <https://doi.org/10.13199/j.cnki.cst.2022-1010>

#### 基于数字孪生的煤矿两柱式支架载荷预测方法

SSARF: A novel prediction method for two-column supports in coal mines based on digital twins

煤炭科学技术. 2025, 53(1): 312–325 <https://doi.org/10.12438/cst.2024-0131>

#### 基于CNN-LSTM模型的TBM隧道掘进参数及岩爆等级预测

Prediction of TBM tunneling parameters and rockburst grade based on CNN-LSTM model

煤炭科学技术. 2024, 52(S2): 21–37 <https://doi.org/10.12438/cst.2023-0777>

#### 基于神经网络补偿的液压支架群推移系统直线度控制方法

Straightness control method of hydraulic support group pushing system based on neural network compensation

煤炭科学技术. 2024, 52(11): 174–185 <https://doi.org/10.12438/cst.2024-0951>

#### 基于BP神经网络的覆岩“两带”高度预测研究

Research on height prediction of “two zones” of overburden based on BP neural network in Wuyang Mine

煤炭科学技术. 2021, 49(8): 53–59 <http://www.mtkxjs.com.cn/article/id/25b4e31b-0c95-40e7-8cec-5a393c55ac7a>



关注微信公众号, 获得更多资讯信息



移动扫码阅读

姚钰鹏, 张境麟, 熊 武. 基于 LSTM 的液压支架尾梁倾角预测方法[J]. 煤炭科学技术, 2025, 53(5): 362-371.  
YAO Yupeng, ZHANG Jinglin, XIONG Wu. Method of tail beam posture prediction of top coal caving hydraulic support based on LSTM[J]. Coal Science and Technology, 2025, 53(5): 362-371.

## 基于 LSTM 的液压支架尾梁倾角预测方法

姚钰鹏, 张境麟, 熊 武

(北京天玛智控科技股份有限公司, 北京 101399)

**摘要:**综放开采是我国特厚煤层主要的开采方式, 放煤执行机构控制精度很大程度上依赖于尾梁姿态的数据反馈。为了提高放煤执行机构的控制精度, 提出了一种基于长短期记忆神经网络(LSTM)的支架尾梁倾角预测方法。将与尾梁放煤动作相关的支架底板绝对坐标、尾梁倾角、尾梁相对高度、移架速率和立柱压力作为 RNN 卷积网络和 LSTM 神经网络的输入变量, 使用某煤矿综放工作面放煤历史数据对支架尾梁姿态预测模型进行训练和验证, 建立支架尾梁姿态预测模型, 对尾梁倾角进行连续 16 h 预测, 结果预测的尾梁倾角曲线与实际尾梁倾角曲线的拟合程度达 98.7%。在综采放顶煤工作面开展了 3~4 个生产班的液压支架尾梁倾角预测试验, 经过对比分析预测的尾梁倾角曲线与实际尾梁倾角曲线, 当置信区间为 (0.98,1.02) 时, 连续生产 16 h 预测准确率为 98.40%。基于 LSTM 的支架尾梁倾角姿态预测方法解决了电液控系统自适应放煤作业尾梁倾角控制问题, 为综放工作面无人放煤奠定了基础。

**关键词:** 支架尾梁姿态; 倾角预测; 长短期神经网络; 时序处理; 放煤工艺

**中图分类号:** TP391 **文献标志码:** A **文章编号:** 0253-2336(2025)05-0362-10

### Method of tail beam posture prediction of top coal caving hydraulic support based on LSTM

YAO Yupeng, ZHANG Jinglin, XIONG Wu

(Beijing Tianma Intelligent Control Technology Co., Ltd., Beijing 101399, China)

**Abstract:** Fully mechanized caving is the main mining method for extra-thick coal seams in my country. The control accuracy of the caving actuator depends largely on the data feedback of the tail beam posture. In order to improve the control accuracy of the caving actuator, a method for predicting the inclination of the support tail beam based on the long short-term memory neural network (LSTM) was proposed. The absolute coordinates of the support bottom plate, the inclination of the tail beam, the relative height of the tail beam, the frame shifting rate and the column pressure related to the tail beam caving action were used as the input variables of the RNN convolutional network and the LSTM neural network. The historical data of coal caving in a fully mechanized caving working face of a coal mine were used to train and verify the support tail beam posture prediction model, and the support tail beam posture prediction model was established. The tail beam inclination was predicted for 16 consecutive hours. The fitting degree of the predicted tail beam inclination curve and the actual tail beam inclination curve reached 98.7%. In the fully mechanized top coal caving face, 3~4 production shifts of hydraulic support tail beam inclination prediction tests were carried out. After comparing and analyzing the predicted tail beam inclination curve with the actual tail beam inclination curve, when the confidence interval was (0.98, 1.02), the prediction accuracy for 16 hours of continuous production was 98.40%. The LSTM-based support tail beam inclination posture prediction method solved the problem of tail beam inclination control in the electro-hydraulic control system's adaptive coal caving operation, laying the foundation for unmanned coal caving in the fully mechanized top coal caving face.

**Key words:** tail beam posture of hydraulic support; tail beam angle predict; LSTM neural network; chronological processing; top coal caving process

收稿日期: 2024-02-20 策划编辑: 常 琛 责任编辑: 王晓珍 DOI: 10.12438/cst.2024-0211

基金项目: 国家重点研发计划资助项目(2023YFC2907504)

作者简介: 姚钰鹏(1989—), 男, 河北定州人。E-mail: yaoyupeng@tdmarco.com

## 0 引 言

放顶煤开采通过控制液压支架尾梁的倾斜角度实现后部放煤作业。受限于生产环境和机械结构,操作人员难以直接观察到放煤时煤矸落入后部刮板输送机,需要依赖声音和时间来判断放煤情况<sup>[1-3]</sup>。在远程或自动放煤操作中,仅依靠尾梁上的倾角传感器来采集尾梁姿态数据,但当传感器损坏时,由于安全规程限制,工人无法进行及时更换,造成支架放煤闭环控制缺失关键反馈数据,无法准确获取设备执行情况,导致放煤控制无法及时调整,从而出现丢煤、落矸等问题<sup>[4]</sup>。

为了提高放煤执行机构的控制精度,必须准确获取尾梁倾角。当前,尾梁倾角的获取方法有:通过尾梁倾角传感器获取、通过预测模型获取等<sup>[5-6]</sup>。受煤矿井下环境复杂,电磁扰动、振动和噪声规律不明显等因素影响,尾梁倾角传感器测量的稳定性不高。为了准确获取尾梁倾角,提出一种基于长短期记忆神经网络 LSTM 算法的尾梁姿态预测模型。根据支架空间坐标、执行机构实时状态、设备健康状态等相关因子与尾梁倾角的非线性相关关系,将相关因子作为时序上的输入量输入深度卷积神经网络(RNN)和长短期神经网络(LSTM),尾梁倾角作为输出量,生成并训练数据相关性模型,构建相关因子与尾梁倾角映射关系,形成基于 LSTM 的尾梁姿态预测模型。

## 1 放煤机构运动分析

### 1.1 支架机械结构与支护姿态

放煤支架如图 1 所示,主要包括顶梁、掩护梁、尾梁、立柱。放煤工艺主要由支架掩护梁、尾梁和后部刮板输送机协同实现。放煤时,尾梁插板收回,放煤口打开,尾梁上方区域煤层由于失去支撑力,在矿山压力作用下逐渐塌方,并落入后部刮板输送机。




图 1 ZFY10800/22/42D 型放煤液压支架

Fig.1 ZFY10800/22/42D type coal caving hydraulic support

放煤过程由尾梁摆动和插板伸收控制,并避免矸石落入后部刮板机。后部刮板机通过连杆控制与液压支架的水平距离,准确的接收后部落煤并将其运输至带式输送机<sup>[7]</sup>。因此,尾梁姿态角度是实现精准放煤的关键因素之一。

支架支护姿态可以分为绝对姿态和相对姿态。绝对姿态指支架相对于地面(绝对坐标系)的空间角度。相对姿态指液压支架各梁与底板的角关系。建立支架结构模型,如图 2 所示,支架各梁上的刚性连接处用红色节点标记,支架销轴连接处用蓝色节点表示,支架底座上的刚性连接处用黑色节点表示,油缸连接用绿色虚线表示<sup>[8-10]</sup>。支架支护姿态受油缸伸收影响,并非完全刚性运动,采用运动学求解需要大量支护结构状态信息。一般情况下,在支架底座、顶梁和尾梁上安装倾角传感器来采集机构的绝对坐标,而立柱、掩护梁油缸和尾梁油缸上较少安装倾角传感器<sup>[11]</sup>。




图 2 液压支架结构模型

Fig.2 Hydraulic support structure model

### 1.2 尾梁倾角影响因素

尾梁的相对姿态是指尾梁相对于支架的姿态,通过尾梁相对姿态和支架绝对姿态,可以获取尾梁在三维空间的静态姿态。

设尾梁相对支架的旋转矩阵为

$$R_{rel} = \begin{pmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{pmatrix} \quad (1)$$

设尾梁相对支架的位置向量为

$$t_{rel} = \begin{pmatrix} x_{rel} \\ y_{rel} \\ z_{rel} \end{pmatrix} \quad (2)$$

设支架在全局坐标系中的旋转矩阵为

$$\mathbf{R}_{\text{abs}} = \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix} \quad (3)$$

设支架在全局坐标系中的位置向量为

$$\mathbf{t}_{\text{abs}} = \begin{pmatrix} x_{\text{abs}} \\ y_{\text{abs}} \\ z_{\text{abs}} \end{pmatrix} \quad (4)$$

尾梁的绝对旋转矩阵  $\mathbf{R}_{\text{tail}}$  是支架的绝对旋转矩阵  $\mathbf{R}_{\text{abs}}$  与尾梁相对支架的旋转矩阵  $\mathbf{R}_{\text{rel}}$  的乘积:

$$\mathbf{R}_{\text{tail}} = \mathbf{R}_{\text{abs}} \mathbf{R}_{\text{rel}} \quad (5)$$

尾梁的绝对位置向量  $\mathbf{t}_{\text{tail}}$  是支架的绝对位置向量  $\mathbf{t}_{\text{abs}}$  加上支架的旋转矩阵  $\mathbf{R}_{\text{abs}}$  作用于尾梁相对支架的位置向量  $\mathbf{t}_{\text{rel}}$  之后的结果:

$$\mathbf{t}_{\text{tail}} = \mathbf{t}_{\text{abs}} + \mathbf{R}_{\text{abs}} \mathbf{t}_{\text{rel}} \quad (6)$$

通过上述计算,可以得到尾梁在全局坐标系中的静态姿态,包括其旋转矩阵  $\mathbf{R}_{\text{tail}}$  和位置向量  $\mathbf{t}_{\text{tail}}$ 。完成从支架姿态和尾梁相对姿态到尾梁绝对姿态的解算过程。

尾梁倾角为尾梁与底板之间的夹角。当液压油流入尾梁油缸时,油缸伸长,尾梁倾角增大;当液压油流出油缸时,油缸缩短,尾梁倾角减小<sup>[12]</sup>。因此,油缸供液状态直接影响了尾梁倾角的变化速率,供液状态受管路压力、供液距离、设备泄压情况、同时供液设备数量的影响,且乳化液压力和流量传感器往往安装在泵站出口和回液口,无法提供某个具体支架的供液情况,因此只能通过立柱支撑压力、移架速率来反映动力油压的情况<sup>[13]</sup>。

综上,尾梁倾角影响因素  $P_{\text{tail}}$  描述为

$$P_{\text{tail}} = \left\{ \vec{R}, \theta, H_{\text{tail}}, v_{\text{push}}, N_{\text{column}} \right\} \quad (7)$$

其中,  $\vec{R}$  为支架底座空间角度;  $\theta$  为尾梁倾角传感器采集的角度;  $H_{\text{tail}}$  为图 2 所示的支架尾梁刚体 Z 点相对底板垂直距离;  $v_{\text{push}}$  为移架速率;  $N_{\text{column}}$  为支架立柱支撑压力。

将尾梁倾角影响因素  $P_{\text{tail}}$  输入 RNN 卷积网络和 LSTM 神经网络实现尾梁倾角  $P_{\text{tail}}$  的预测输出。

## 2 基于 LSTM 的尾梁倾角预测模型

### 2.1 基于 LSTM 的尾梁倾角预测模型

使用 LSTM 神经网络方法进行支架尾梁倾角预测,具体流程如图 3 所示。

对尾梁倾角传感器采集到的数据  $A$  进行初步筛选,数据  $A$  为某矿综放工作面放顶煤支架尾梁连续 16 h 生产班的运行数据,计算尾梁最快运动时相邻

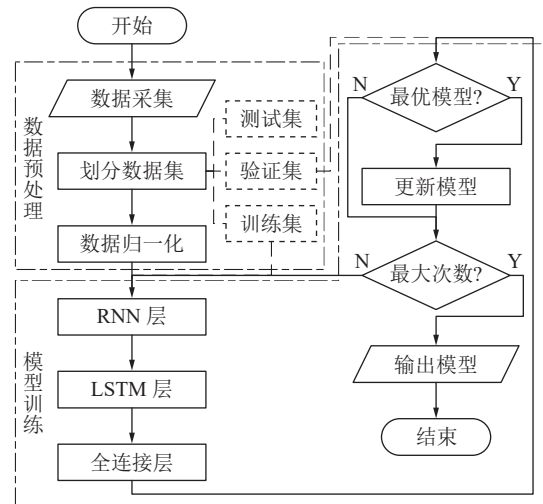


图 3 支架尾梁倾角预测流程

Fig.3 Prediction process of tail beam inclination angle of hydraulic support

时刻倾角变化速率,该速率乘以 1.5 倍安全系数,作为支架尾梁正常运动时角速度阈值 GRAD,当采集的相邻倾角数据变化速率大于梯度阈值时,数据作为异常数据剔除。数据集  $A$  预处理后得到数据集  $B$ ,公式为

$$B = \left\{ A \mid a \in A, \frac{|a_i - a_{i-1}|}{\Delta t} \leq \text{GRAD} \right\} \quad (8)$$

式中,  $\Delta t$  为相邻采集数据的时间间隔,由传感器采样频率决定。

将数据集  $B$  的数据按照训练集、验证集、测试集 7 : 1 : 2 的比例划分,并采用经典的数据归一化方法,将数据缩放到 [0,1] 区间。在 RNN 层,将式(8)归一处理的时序训练集输入卷积网络,提取支架尾梁倾角的时序特征,得到 Process Data 1。

在 LSTM 层,输入 Process Data 1,经 LSTM 的隐藏状态进行时序数据处理,得到 Process Data 2。

Process Data 2 经过全连接层输出为时序列向量  $C$ ,该组数据为一次 LSTM 训练的预测结果。

将预测结果与验证集进行对比,取得验证集的方差  $e_{\text{var}}$ ,比较前次训练后的方差数据和本次训练的方差,当本次方差更小时,更新训练模型。达到训练次数后,输出并保存训练模型。

### 2.2 基于 LSTM 的尾梁倾角预测

使用某矿综放工作面放顶煤支架尾梁的运行数据。随机选取 5 个支架,每个支架选取 5 d 的运行数据,共计 25 组数据样本。倾角传感器采集频率 10 Hz,数据采集、延时、刷新和上报损失按 5% 计算,单个数据样本约 54.72 万条数据向量,任选一个支架尾梁倾角数据样本,如 72 号支架连续 16 h 的倾角数




图 4 含放煤动作及漂移误差的尾梁倾角原始数据

Fig.4 Original data of tail beam inclination including coal discharge action and drift error

在自动放煤工艺中，支架尾梁倾角变化率为 5 ~ 6(°)/s，考虑工况条件和供液稳定性综合影响，尾梁倾角变化率不会大于 10(°)/s，考虑倾角传感器采集

频率为 10 Hz，因此 2 个采样之间的尾梁倾角变化不会大于 30'。基于滤波算法剔除角度漂移和变化异常数据后，得到支架尾梁倾角数据样本，如图 5 所示。




图 5 剔除异常采集的尾梁倾角数据

Fig.5 Tilt angle data after eliminating the abnormal data collected by sensors

剔除异常数据后，尾梁倾角影响因子数据见表 1，一条数据包含时间戳、支架底板空间角度、支架尾梁

刚体 Z 点相对底板垂直高度、移架速率、支架立柱压力。

表 1 模型训练原始数据  
Table 1 Original data for model training

时间	影响因子				
	$\vec{R}$	$\theta$	$H_{tail}$	$v_{push}$	$N_{column}$
2023-10-14 16:00:00:053	(4.5,6.7,2.4)	70.6	1.45	0	26.7
2023-10-14 16:00:00:154	(4.5,6.7,2.4)	70.6	1.45	0	26.7
2023-10-14 16:00:00:256	(4.5,6.7,2.4)	70.4	1.45	0	26.6
2023-10-14 16:00:00:357	(4.5,6.7,2.5)	70.5	1.45	0	26.6
2023-10-14 16:00:00:460	(4.5,6.7,2.5)	70.5	1.45	0	26.6
⋮	⋮	⋮	⋮	⋮	⋮
2023-10-15 07:59:59:943	(1.4,8.9, -1.4)	68.9	1.37	0	27.2

设置 LSTM 神经网络模型的输入时间步长为  $l_s=20$ ，输出时间步长  $l_p=1$ ，使用 2 个隐藏层，隐藏层节

点分别设置为 256 个、64 个，层间 dropout 参数设置为 0.2，模型最大迭代次数 150 次，学习率为 0.005，

当训练 40 次误差未见明显降低时终止训练, 使用 Adam 优化器计算梯度下降<sup>[14]</sup>, 迭代训练效果如图 6 所示。当进行 50 次迭代后, 误差损失值接近 0.05 以下, 模型训练结果基本满足预测需求。

选取 25 个连续样本, 输入训练好的支架倾角预测模型, 得到 2 个生产班连续 16 h 的支架尾梁倾角预测曲线, 如图 7 所示, 对比相应时段实际采集的支架尾梁倾角曲线, LSTM 模型预测结果与真实值无明显误差。




图 6 迭代训练效果

Fig.6 Iterative training effect




图 7 预测结果对比

Fig.7 Comparison of prediction results

### 2.3 模型准确率

选用平均绝对误差 MAE、均方根误差 RMSE 和线性回归相关系数  $R^2$  作为模型预测回归评价指标<sup>[15]</sup>。MAE 评价模型整体预测的误差, 该值越小回归效果越好; RMSE 评价模型预测值与测试集的偏离度, 该值越小回归效果越好;  $R^2$  评价模型预测值对真实值的拟合效果, 值越接近 1 越回归效果越好。

为了更直观评价模型的拟合度, 设计模型拟合程度指标作为模型评价指标, 首先, 定义数据集中真实值为  $y_i$ , 预测值为  $\hat{y}_i$ , 其中  $i=1,2,\dots,N,N$  为数据集中的样本数量, 误差百分比 (Percentage Error) 可以计算如下:

$$PE = \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (9)$$

定义指示函数  $I_i$ , 表示第  $i$  个样本是否满足百分比小于阈值的条件:

$$I_i = \begin{cases} 0 & \text{if } \left| \frac{y_i - \hat{y}_i}{y_i} \right| \leq \text{threshold} \\ 1 & \text{otherwise} \end{cases} \quad (10)$$

其中, threshold 定义为相对误差阈值, 不同任务对差异容忍度不同, 可以设定不同值, 倾角预测对误差要求较高, 因此设置 threshold 为 0.03, 接着定义拟合程度  $F$  为满足条件的样本数量  $n$  与总样本数  $N$  的比值:

$$F = \frac{\sum I_i}{N} \quad (11)$$

评估 LSTM 模型在预测支架尾梁倾角方面的性能, 得出以下评估结果: MAE=1.778 4, RMSE=2.364 1,  $R^2=0.997 04$ 。结果表明, 支架尾梁倾角预测模型具有极高的拟合度和预测精度。

代入式(9)、(10)、(11), 计算得到模型的拟合度为 98.7%, 表明 LSTM 模型在处理支架尾梁倾角预测问题上表现出色, 能够有效捕捉数据的复杂非线性关系, 实现高精度预测。

## 3 应用情况

### 3.1 井下试验

为了测试支架尾梁姿态预测模型在综放工作面的预测精度, 将预测模型部署在集控系统井下巷道监控中心主机上, 控制器与主机通过工业以太网连接, 进行实时数据通信。综放工作面液压支架尾梁倾角预测流程如图 8 所示, 随机选取 5 个支架, 电液控系统实时采集 16 h 尾梁倾角数据, 录入历史数据库, 作为对照组数据; 同时采集支架姿态、供液压力和移架速率等相关因子数据, 经时序编组后, 作为预测样本输入预测模型。试验过程中, 对比当前时刻采集到的尾梁倾角数据和上一时刻预测模型计算得出的预测数据来评价预测的准确性。

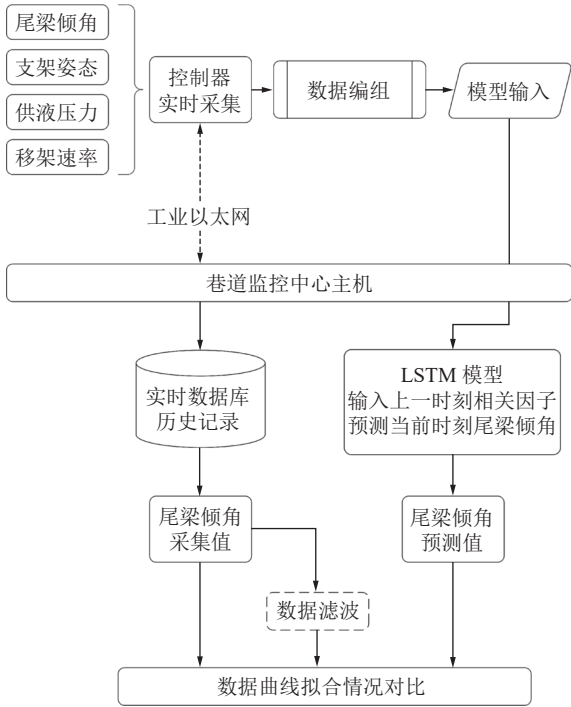


图 8 综放工作面液压支架尾梁倾角预测流程

Fig.8 Prediction process for tail beam inclination angle of hydraulic supports in fully mechanized top-coal caving face

试验要求工作面环境和设备符合一般生产条件, 随机选用状态良好的支架, 生产过程按照该矿综放工作面作业规程要求, 以自动跟机放煤为主, 工人对放煤情况进行人工干预, 尾梁倾角传感器数据上报频率为 10 Hz。24 h 内有 1 个检修班和 2 个生产班, 每天生产班工作 16 h, 开采 8 刀煤。16 h 的数据预测和采集结果如图 9 所示。

支架的尾梁姿态预测曲线和传感采集曲线拟合程度好, 预测数据准确反馈出生产情况。与传感采集曲线相比, 拟合曲线没有产生角度数据突变, 符合液压支架运动学规律; 传感器采集曲存在数据漂移孤点, 拟合曲线没有数据漂移情况, 可以有效的避免采集数据漂移的问题。

进一步验证采集结果的准确性, 按式(8)将异常数据进行剔除, 得到各个支架的有效采集数据。设置置信区间为 (0.98,1.02), 对预测数据的准确率  $\eta$  进行统计, 公式为

$$\eta = \left( 1 - \frac{\sum_{i=1}^N [1_{y_{i,pre} \in (0.98y_{i,col}, 1.02y_{i,col})}] }{N} \right) \quad (12)$$

其中,  $N$  为有效数据数量;  $y_{i,pre}$  为第  $i$  个模型预测输出值;  $y_{i,col}$  为第  $i$  个传感器采集数据。各个传感器的预测数据准确率见表 2。

基于 5 个试验支架准确率数据, 得到最低准确

率为 97.6%, 支架平均准确率为, 加权准确率为 98.40%。通过实验表明, 在 16 h 内持续使用预测值输入, 预测误差在  $\pm 2\%$  内的平均概率为 98.40%, 最小概率为 97.6%, 模型准确性和稳定性较高。

### 3.2 极限性能测试

继续选用上述 5 个支架, 持续进行预测, 测试模型的性能极限, 测试的置信区间为  $((1-\lambda)y_{col}, (1+\lambda)y_{col})$ ,  $\lambda$  表示误差因子。记录首次触发区间边界、10 次触发区间边界和连续 5 次触发区间边界的时间 (连续 5 次触发边界认为模型失效)。误差因子  $\lambda$  取值分别为 0.02、0.05 和 0.10, 触发阈值的分布情况如图 10 所示, 统计结果见表 3。

该煤矿 XX202 综放工作面采用三班制, 每天 0—8 时为生产班、8—16 时为检修班、16—24 时为生产班, 每个生产班开采 8 刀煤, 支架放煤 8 次, 检修班对放煤作业动作随机操作。实验从 0 时刻开始, 生产班和检修班交替作业。从触发误差计时的时间来看, 除 68 号支架 10 次触发  $\lambda=0.10$  属于检修班, 其他触发误差计时的时间均属于生产班, 符合实际概率情况。

从测试结果可知, 当  $\lambda=0.02$  时, 平均首次触发在 4.9 h, 平均 10 次触发在 18.2 h, 平均连续 5 次触发在 32.1 h; 当  $\lambda=0.05$  时, 平均首次触发在 11.6 h, 平均十次触发在 23.3 h, 平均连续 5 次触发在 51.1 h; 当  $\lambda=0.10$  时, 平均首次触发在 21.0 h, 平均 10 次触发在 31.1 h, 平均连续 5 次触发在 85.9 h。由此可知, 在  $\lambda=0.02$  时, 模型在第 1 个生产班会出现触发边界的误差, 模型失效在第 3~4 个生产班; 在  $\lambda=0.05$  时, 模型在第 1~2 个生产班会出现触发边界的误差, 模型失效在第 5 个生产班; 在  $\lambda=0.10$  时, 模型在第 2 个生产班会出现触发边界的误差, 模型失效在第 7~9 个生产班, 该结果符合累加误差一般规律。

结合表 2 中单个支架的误差准确率可知, 支架的阈值触发与时间与 16 h 预测准确率呈相关关系, 支架准确率与极限误差触发时间之间的分布关系如图 11 所示, 可知支架模型预测准确率越高, 模型极限性能越好, 推测模型预测的准确率与支架的健康状态存在相关性。

### 3.3 生产应用情况

当误差因子  $\lambda \leq 0.02$  时, 对放煤作业具有较强的指导意义。在性能极限测试时, 首次触发  $\lambda=0.02$  在 3.8 h, 适当增加安全系数, 在不考虑支架健康状态的情况下, 以 3 h 为周期进行偏差校正, 理论准确率  $\eta=100\%$ 。



## 1)应用模型处理传感采集漂移。

倾角传感器采集数据漂移是常见问题,当GRAD(A)超出置信区间时,使用模型计算 $\Delta t$ 时刻的尾梁倾角数据,进行插值,补偿数据滤波造成的倾角数据丢失。将补偿数据插入采集数据,拟合出尾梁倾角曲线,如图12所示,可知其曲线平滑程度符合液压机构运动



学规律。该应用有利于更准确的反馈支架尾梁状态,为放煤控制提供数据支撑。

## 2)应用模型处理传感数据丢失。


当支架无法采集倾角传感器数据时(传感器损坏等情况),可以通过目标支架左右邻架数据作取平均值作为输入,来实时输出目标支架尾梁倾角数据。




(a) 26号支架16h和放煤局部曲线



(b) 43号支架16h和放煤局部曲线



(c) 68 号支架 16 h 和放煤局部曲线



(d) 74 号支架 16 h 和放煤局部曲线

图 9 井下生产 16 h 预测试验

Fig.9 16-hour underground production prediction experiment

煤层的情况在前进方向一个支架步距内、水平方向邻架宽度之间往往不存在突变,因此左右邻架作为数据源一般情况下可以较好的反映目标支架情况。

从历史数据中选取 1 000 个周期为 3 h 的数据组,以目标支架左右邻架作为数据源,将左右邻架的

数据取平均值,与采集本架数据进行对比,全部数据最大误差范围小于 1.5%,平均误差约为 0.4%,将平均值作为模型输入,经过模型计算得到尾梁倾角,与采集尾梁倾角进行对比,模型输出准确率达 99.8%。

将支架尾梁姿态预测模型应用于倾角传感器滤

表 2 16 h 模型预测准确率

Table 2 Accuracy of the 16-hour model prediction

支架编号	剔除异常后数据样本N	准确率 $\eta/\%$
26	831 830	98.3
43	821 065	97.6
68	832 634	98.6
74	828 657	99.1
91	827 554	98.4

表 3 阈值触发情况

Table 3 Threshold triggered results

架号	$\lambda$	首次触发时间/h	10次触发时间/h	连续触发时间/h
26	0.02	5.3	17.4	30.1
	0.05	8.2	21.6	45.2
	0.10	20.6	26.3	89.2
43	0.02	3.8	16.4	28.9
	0.05	6.5	19.2	41.2
	0.10	18.5	22.6	65.6
68	0.02	4.9	19.4	28.6
	0.05	17.1	29.6	50.1
	0.10	20.9	34.5	94.2
74	0.02	5.4	20.7	42.1
	0.05	17.8	27.6	67.8
	0.10	26.3	42.1	101.7
91	0.02	5.1	17.2	30.7
	0.05	8.2	18.7	51.3
	0.10	18.7	30.2	78.9




图 10 5 个支架在不同置信区间的阈值触发时间

Fig.10 Threshold triggering time of 5 scaffolds in different confidence intervals

波数据插值和邻架反馈基础上的持续预测, 测试效果良好。

### 4 结 论

1)为了提高放煤执行机构的控制精度, 提出了一种基于长短期记忆神经网络(LSTM)的支架尾梁倾角预测方法。

2)将与尾梁放煤动作相关的支架底板绝对坐标、尾梁倾角、尾梁相对高度、移梁速率和立柱压力作为 RNN 卷积网络和 LSTM 神经网络的输入变量, 建




图 11 模型失效时间-预测准确率关系

Fig.11 Relationship between model failure time and prediction accuracy

立支架尾梁姿态预测模型。

3)使用某煤矿综放工作面放煤历史数据对支架

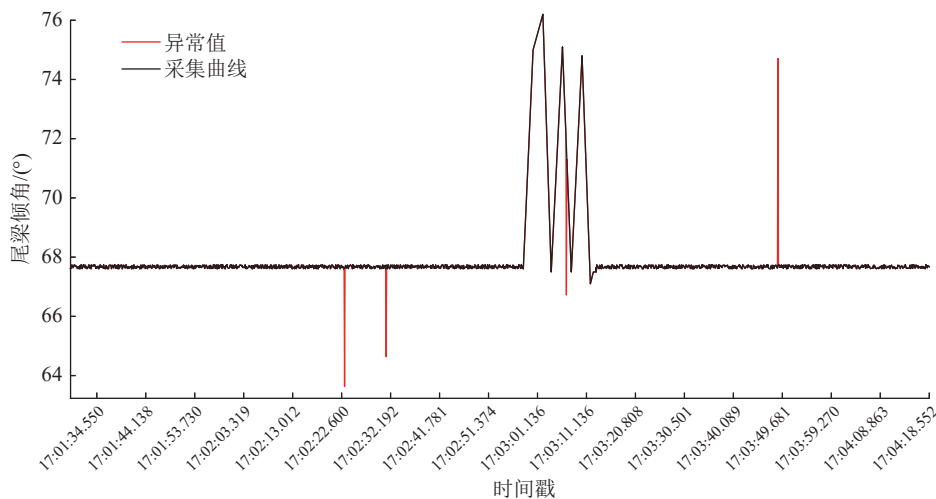


图 12 尾梁倾角采集和预测修正曲线

Fig.12 Using models for interpolation of abnormal data

尾梁姿态预测模型进行训练和验证,建立了一种基于 LSTM 的支架尾梁倾角姿态预测模型,并对尾梁倾角进行连续 16 h 预测,结果预测的尾梁倾角曲线与实际尾梁倾角曲线的拟合程度达 98.7%。

4)在综采放顶煤工作面开展了 3~4 个生产班的液压支架尾梁倾角预测试验,经过对比分析预测的尾梁倾角曲线与实际尾梁倾角曲线,当误差因子  $\lambda=0.02$  时,16 h 连续预测的准确率为 98.40%,模型在连续预测 3~4 个生产班后失效;以 3 h 为预测偏差校正周期,理论准确率达 100%;以左右邻架作为数据输入源,模型预测的准确率达 99.8%。

#### 参考文献(References):

- [1] 王国法,徐亚军,张金虎,等.煤矿智能化开采新进展[J].煤炭科学技术,2021,49(1):1-10.  
WANG Guofa, XU Yajun, ZHANG Jinhu, et al. New development of intelligent mining in coal mines[J]. Coal Science and Technology, 2021, 49(1): 1-10.
- [2] 王家臣.我国综放开采 40 年及展望[J].煤炭学报,2023,48(1):83-99.  
WANG Jiachen. 40 years development and prospect of longwall top coal caving in China[J]. Journal of China Coal Society, 2023, 48(1): 83-99.
- [3] 张守祥,张学亮,刘帅,等.智能化放顶煤开采的精确放煤控制技术[J].煤炭学报,2020,45(6):2008-2020.  
ZHANG Shouxang, ZHANG Xueliang, LIU Shuai, et al. Intelligent precise control technology of fully mechanized top coal caving face[J]. Journal of China Coal Society, 2020, 45(6): 2008-2020.
- [4] 王祖洸.特厚煤层群组放煤理论及智能放煤控制方法研究[D].焦作:河南理工大学,2022.  
WANG Zuguang. Study on the theory of coal release in extremely thick coal seam groups and intelligent coal release control methods [D]. Jiaozuo:Henan Polytechnic University, 2022.
- [5] 马长青,李旭阳,李峰,等.基于多传感器融合的液压支架位姿精确感知方法[J].工矿自动化,2025,51(4):114-119.  
MA Changqing, LI Xuyang, LI Feng, et al. Precise perception method for hydraulic support pose based on multi-sensor fusion[J]. Industry and Mine Automation, 2025, 51(4): 114-119.
- [6] 姚钰鹏,熊武.基于行为分析的工作面移架决策模型[J].煤矿机电,2025,46(1):1-7.  
YAO Yupeng, XIONG Wu. Working face frame-moving decision model based on behavior analysis[J]. Coal Mine Machinery, 2025, 46(1): 1-7.
- [7] 李首滨,李森,张守祥,等.综采工作面智能感知与智能控制关键技术与应用[J].煤炭科学技术,2021,49(4):28-39.  
LI Shoubin, LI Sen, ZHANG Shouxian, et al. Key Technologies and applications of intelligent perception and intelligent control in fully mechanized mining face[J]. Coal Science and Technology, 2021, 49(4): 28-39.
- [8] 庞义辉,刘新华,王泓博,等.基于千斤顶行程驱动的液压支架支护姿态与高度解析方法[J].采矿与安全工程学报,2023,40(6):1231-1242.  
PANG Yihui, LIU Xinhua, WANG Hongbo, et al. Support attitude and height analysis method of hydraulic support based on jack stroke drive[J]. Journal of Mining & Safety Engineering, 2023, 40(6): 1231-1242.
- [9] 王忠乐.综采液压支架姿态监测及控制技术[J].工矿自动化,2022,48(S2):116-118.  
WANG Zhongle. Attitude monitoring and control technology of fully mechanized mining hydraulic support[J]. Industry and Mine Automation, 2022, 48(S2): 116-118.
- [10] 徐亚军,王国法,刘业献.两柱掩护式液压支架承载特性及其适应性研究[J].煤炭学报,2016,41(8):2113-2120.  
XU Yajun, WANG Guofa, LIU Yexian. Supporting property and adaptability of 2-leg powered support[J]. Journal of China Coal Society, 2016, 41(8): 2113-2120.
- [11] 伍永平,杜玉乾,解盘石,等.大倾角煤层俯仰斜工作面平行四边形液压支架结构与运动响应[J].煤炭科学技术,2024,52(4):314-325.  
WU Yongping, DU Yuqian, XIE Panshi, et al. Structural design and motion response of parallelogram hydraulic support for pseudo-inclined working face in steeply inclined coal seam[J]. Coal Science and Technology, 2024, 52(4): 314-325.
- [12] 李建.曹家滩超大采高工作面压力一位姿数据融合分析及应用[D].北京:煤炭科学研究总院,2024.  
LI Jian. Pressure-pose data fusion analysis and application in caojiatan ultra-large mining height working face [D]. Beijing:China Coal Research Institute, 2024.
- [13] 王文苗.松软厚煤层大采高综采面支架-围岩系统状态感知与稳定性评价研究[D].徐州:中国矿业大学,2024.  
WANG Wenmiao. Research on state perception and stability evaluation of support-surrounding rock system in soft thick coal seam with large mining height comprehensive mining face [D]. Xuzhou:China University of Mining and Technology, 2024.
- [14] 李博,郭星燃,李娟莉,等.基于 LSTM-Adam 的刮板输送机链传动系统故障预警方法[J].工矿自动化,2023,49(9):140-146.  
LI Bo, GUO Xingran, LI Juanli, et al. A fault warning method for scraper conveyor chain transmission system based on LSTM-Adam[J]. Industry and Mine Automation, 2023, 49(9): 140-146.
- [15] 杨进.基于 RF 算法与 LSTM 神经网络对矿工呼吸流量的长短期预测[D].徐州:中国矿业大学,2023.  
YANG Jin. Short- and long-term prediction of miners' respiratory flow based on rf algorithm and LSTM Neural Network [D]. Xuzhou:China University of Mining and Technology, 2023.