



# 数据驱动的深井超长工作面支架载荷区域特征分析与分区预测

巩师鑫

## 引用本文:

巩师鑫. 数据驱动的深井超长工作面支架载荷区域特征分析与分区预测[J]. 煤炭科学技术, 2024, 52(S1): 1–12.  
GONG Shixin. Data-driven regional characteristic analysis and partition prediction of support load in deep well and ultra-long working face[J]. Coal Science and Technology, 2024, 52(S1): 1–12.

在线阅读 View online: <https://doi.org/10.12438/est.2023-0607>

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 超长工作面支架工作阻力分布及分区增阻特性研究

Study on working resistance distribution of support and resistance increasing characteristics of support partition in longwall face with ultra-large length  
煤炭科学技术. 2023, 51(4): 11–20 <https://doi.org/10.13199/j.cnki.cst.2022-1431>

#### 深埋超长综采工作面矿压规律及支架适应性研究

Sturdy on ground pressure law and support adaptability of deep-buried and ultra-long fully-mechanized longwall mining face  
煤炭科学技术. 2021, 49(3): 43–48 <https://doi.org/10.13199/j.cnki.cst.2021.03.004>

#### 超长综采工作面撤架期间煤自燃预测及防控技术研究

Study on coal spontaneous combustion prediction and control technology during withdrawal period of super long fully-mechanized mining face  
煤炭科学技术. 2020, 48(1) <http://www.mtkxjs.com.cn/article/id/e211443f-6c1c-439e-ab04-f4854fa8dd7f>

#### 大采高智能化工作面液压支架自动跟机控制技术研究

Research on automatic follow-up control technology of hydraulic support in intelligent working face with large mining height  
煤炭科学技术. 2019(7) <http://www.mtkxjs.com.cn/article/id/1bb414b1-2823-4d7e-bfbe-81d991936233>

#### 大倾角工作面液压支架撤除技术研究

Research on hydraulic support removal technology in large inclined working face  
煤炭科学技术. 2020, 48(3) <http://www.mtkxjs.com.cn/article/id/f98e5707-0166-4560-949e-d8b2a69dbcc9>

#### 综采工作面液压支架自主调斜调偏技术研究

Study on autonomic tilting and offsetting technology of hydraulic support in fully-mechanized working face  
煤炭科学技术. 2019(10) <http://www.mtkxjs.com.cn/article/id/f1265c90-e924-4eea-b71f-c0875b252191>



关注微信公众号，获得更多资讯信息

## 采矿科学与工程



巩师鑫. 数据驱动的深井超长工作面支架载荷区域特征分析与分区预测[J]. 煤炭科学技术, 2024, 52(S1): 1-12.  
GONG Shixin. Data-driven regional characteristic analysis and partition prediction of support load in deep well and ultra-long working face[J]. Coal Science and Technology, 2024, 52(S1): 1-12.

移动扫码阅读

# 数据驱动的深井超长工作面支架载荷区域特征分析与分区预测

巩 师 鑫<sup>1,2</sup>

(1. 中煤科工开采研究院有限公司 智能开采装备分院, 北京 100013; 2. 天地科技股份有限公司 开采设计事业部, 北京 100013)

**摘要:** 实现液压支架载荷预测分析对于及时改善支架适应性和实现安全支护具有重要作用, 需要高质量、大数量的支架载荷时序数据和有效的预测方法作为支撑。然而, 深部超长工作面上覆岩层应力环境和垮落步距的非同质同步引发工作面不同区域支架载荷差异化。因此, 针对深井超长工作面顶板覆岩长期循环动载作用和分区破断造成工作面不同区域载荷差异明显以及无法实现动态区域更新下的液压支架载荷预测的问题, 提出了一种数据驱动的深井超长工作面支架载荷区域特征分析与分区预测方法。首先, 在获取工作面液压支架载荷数据的基础上, 利用 MeanShift 聚类算法实现工作面区域动态划分, 并分析深井超长工作面不同区域的支架载荷变化特征; 然后, 提出一种考虑多维时序数据特征和注意力机制 LSTM 预测方法, 构建支架载荷一次性多输入多输出预测框架, 实现了预测算法精度和输入输出特征结构的协同设计; 最后, 基于前述工作面区域划分结果, 建立工作面区域化液压支架群组载荷预测模型, 实现了综采工作面液压支架群组载荷时序数据循环训练和高精度预测。该方法通过考虑工作面载荷区域分布特征, 建立多输入多输出特征工程, 可实现基于工作面区域动态更新的液压支架群组载荷预测, 能够为后续分析工作面矿压显现规律, 超前适应采场环境变化和指导工作面正常回采提供依据。

**关键词:** 工作面; 液压支架; 载荷预测; 时间序列数据; 区域划分

中图分类号: TD323 文献标志码: A 文章编号: 0253-2336(2024)S1-0001-12

## Data-driven regional characteristic analysis and partition prediction of support load in deep well and ultra-long working face

GONG Shixin<sup>1,2</sup>

(1. Intelligent Mining Equipment Branch, CCTEG Coal Mining Research Institute Co., Ltd., Beijing 100013, China; 2. Mining Design Division, CCTEG Tiandi Science & Technology Co., Ltd., Beijing 100013, China)

**Abstract:** Accurate prediction of hydraulic support load plays an important role in improving the adaptability of support and the stability of surrounding rock control, where high-quality and large-scale time series data and effective prediction methods are needed. However, the cyclic training and modeling of intercepting hundreds of sets of load data in the same time period consumes a lot of computing resources and takes a long time to train. And the heterogeneity of the stress environment of the overlying strata on the working face and the asynchronous caving step distance lead to different support loads in different areas of the working face. In view of the obvious different load in different areas of the working face caused by the long-term cyclic dynamic load and partition failure of the roof overlying rock of the fully mechanized mining face, and the problem that the load prediction of hydraulic support group under dynamic area cannot be realized, a novel predicting scheme of hydraulic support group load in working face with respect to regional characteristics is proposed. Specifically,

收稿日期: 2023-04-25 责任编辑: 朱恩光 DOI: 10.12438/cst.2023-0607

基金项目: 国家自然科学基金资助项目(52104161, 52274154); 中煤科工开采研究院有限公司科技创新基金资助项目(KCYJY-2024-MS-13)

作者简介: 巩师鑫(1990—), 男, 辽宁大连人, 副研究员, 博士。E-mail: gongshixin1990@163.com

meanshift adaptive clustering algorithm is used to realize the region division of fully mechanized mining face firstly then the regional characteristics of the working face are analyzed. Secondly, an attention-based LSTM algorithm combined with the production technology is proposed. Taking the regional support load as the input, a one-time multi-input and multi-output prediction model of regional support load is established, which verifies the prediction effectiveness of the proposed input-output feature engineering. Finally, based on the division results of the working face area, regionalized hydraulic support group load prediction models are established based on the proposed attention-based LSTM algorithm to achieve high-precision prediction of the hydraulic support load of the fully mechanized mining face. By considering the regional distribution characteristics of the working face and proposing a multi-input and multiple-output feature engineering, the hydraulic support group load prediction based on the dynamic update of the working face area can be realized, which can be used for the follow-up predicting analysis of the strata behaviors provides a basis for guiding the safe and efficient mining.

**Key words:** working face; hydraulic support; load forecasting; time series data; region division

## 0 引言

综采工作面在推进过程中上覆岩层不断破断垮落,工作面矿压显现规律随之产生周期性变化<sup>[1]</sup>。随着工作面长度和埋深增加,高地压和长度效应导致其覆岩破坏与运动规律发生质变,呈现分区破断特征和大小周期来压现象<sup>[2]</sup>。因此,深井超长工作面不同区域的围岩安全稳定支护需求存在差异,支架应该根据外部条件采取合适参数以满足差异化安全支护需要。

液压支架载荷实时监测和预测分析是确保支架支护效果的重要前提,以此分析工作面顶板来压步距、顶板断裂时的压力状态等矿压显现参数,从而提高支架适应性,实现围岩稳定控制<sup>[2]</sup>。随着智能化开采的不断深入发展,我国大部分采煤工作面已经实现了液压支架载荷的在线监测,而进一步开展全工作面矿压预测分析需要高质量的支架载荷时序数据和有效的液压支架载荷预测方法作为支撑。然而,地下采场环境变化复杂,覆岩特性、采高、埋深及工作面长度等多因素均对液压支架载荷产生影响,机理分析、预测难度较大<sup>[3]</sup>,因此,基于液压支架工作阻力监测数据,采用数据驱动建模方法建立综采工作面矿压时间序列预测模型引起了广泛关注。相关学者通过提出基于反向传播神经网络<sup>[4]</sup>、引入广义开尔文模型<sup>[5]</sup>、采用深度学习方法<sup>[6-7]</sup>的矿压预测模型,初步实现了高效、易于使用的工作面周期来压预测分析。然而,作为单维时间序列的液压支架载荷数据预测难度较大,输入特征少、可用信息不足、方法适应性低,因此,相关学者针对上述难题,通过分解数据<sup>[8]</sup>、改善数据分布形态<sup>[9]</sup>、利用组合预测方式<sup>[10-11]</sup>等手段,提高液压支架载荷预测精度。此外,引入关联性较强的特征分量<sup>[12-13]</sup>和分级分类思想<sup>[14-15]</sup>也可有效提升液压支架载荷预测分析效果。

上述研究通过分解数据、改善其分布形态、利用

组合预测等方式增强了单维时间序列数据预测效果,通过增加关联性强的特征改善了输入特征少、可用信息不足、方法适应性低等问题,为数据驱动建模应用于工作面液压支架载荷分析、实现支架载荷预测奠定了良好的基础。然而,无论是通过分解数据、改善数据分布形态的数据预处理,还是利用组合算法,或增加关联性较强的特征等方式,针对某单个液压支架的载荷建立预测分析模型的本质没有改变,而对于多达上百台液压支架的综采工作面,截取相同时间段内的上百组载荷数据循环训练建模不可避免,消耗计算资源大、训练时间久;而且,长期研究也发现长工作面液压支架并非等强支护,工作面中部支架和两端部的支架状态明显不同,虽然部分学者开展了基于工作面区域特征的液压支架载荷预测分析,但是区域仅划分为中部和两端部,且划分依据不明确,更无法体现区域动态变化特征。综采工作面推进过程是一个立体动态过程,沿工作面方向顶板垮落步距难以同步,会出现分区破断和某个区域首先破断然后向两侧迁移的现象,工作面上覆岩层应力环境和垮落步距的差异变化必然引起工作面不同区域的支架承受顶板压力的变化和区域支护需求的动态改变<sup>[16-17]</sup>,如果工作面所有支架参数相同将导致支架受力不均,工作面支护效果难以达到最佳。

因此,针对工作面顶板覆岩长期循环动载作用和分区破断造成工作面不同区域载荷差异明显,以及无法实现动态区域更新下的液压支架载荷预测的问题,提出一种数据驱动的深井超长工作面支架载荷区域特征分析与分区预测方法。首先,在获取工作面液压支架载荷数据的基础上,利用 MeanShift 聚类算法实现工作面区域动态划分,并分析深井超长工作面不同区域的支架载荷变化特征;然后,提出一种考虑多维时序数据特征和注意力机制 LSTM 预测方法,构建支架载荷一次性多输入多输出预测框架,实现预测算法精度和输入输出特征结构的协同

设计；最后，基于前述工作面区域划分结果，建立工作面区域化液压支架群组载荷预测模型，实现综采工作面液压支架群组载荷时序数据循环训练和高精度预测。

## 1 工作面载荷区域动态辨识与特征分析

综采工作面开挖后，采场上覆岩层会在自身重力的作用下发生弯曲破坏，而且相同条件下随着远离端部巷帮，支撑条件变弱，岩层弯曲程度变大<sup>[18]</sup>。而工作面长度增加后，沿工作面方向顶板垮落更难以同步，会出现分区破断或者某个区域首先破断然后向两侧迁移的现象。因此，工作面不同位置或区域下，液压支架群组支护应力开始由单峰值向多峰值转化，当工作面长度达到300 m后，液压支架群组支护应力逐渐呈马鞍形三峰值“M”型<sup>[19]</sup>。为满足深井超长工作面的差异化支护需求，需要开展更为精细化的工作面区域载荷特征分析，建立区域化的支架载荷预测分析模型，从而采取更为针对性的支护措施。

### 1.1 工作面基本情况

中煤新集口孜东煤矿140502超长工作面开采5号煤，位于-967 m水平的1405采区，为该采区的首采工作面。工作面采用倾斜长壁布置，风巷倾向长911.0 m，可采倾向长826.7 m，运输巷倾向长1185.5 m，可采倾向长813.7 m。工作面顶、底板以泥岩为主，少数为细砂岩、粉砂岩及砂质泥岩，煤层结构较简单，顶、底板岩性较软。因此，该工作面是典型的“三软”复杂煤层工作面，其地层综合柱状图如图1a所示。同时，口孜东矿140502工作面所在采区北高南低，倾角5°~18°，平均倾角约14°。工作面煤层全层厚度5.45~7.09 m，平均厚度约为6.53 m，普氏系数 $f$ 为1.6，从上述基本信息可以看出整个煤层具有明显起伏，工作面运输巷和风巷并不在同一水平位置，纵高度相差近20 m，如图1b所示，整个工作面剖面呈现类似“锅盖”形状。

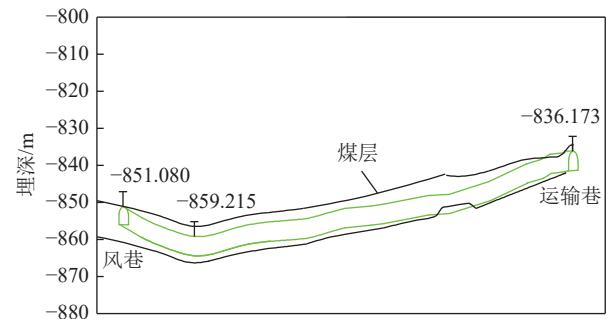
### 1.2 工作面载荷区域动态辨识

工作面上覆岩层应力环境和垮落步距的差异变化必然引起工作面不同区域的支架承受顶板压力的变化和区域支护需求的动态改变，为实现更为精细化的支架载荷预测和分析，充分反映数据自身的类别属性，提出了基于MeanShift聚类的工作面区域动态辨识方法。

MeanShift算法是建立在核密度估计的基础之上的数据聚类算法。假设有数据集 $X_i \in \mathbb{R}^d$

岩性 柱状	层	厚	累厚/m	岩性描述
	最小 — 最大 /m	平均/m		
	2.35 — 9.90	8.65	14.78	细砂岩 (基本顶)
	0.98 — 6.38	3.81	6.13	砂质泥岩 (直接顶)
	0 — 1.33	0.89	2.32	煤线 (直接顶)
	0 — 4.5	1.43	1.43	泥岩 (直接顶)
	4.0 — 8.0	6.61	6.61	5煤
	1.67 — 6.30	3.13	3.13	砂质泥岩 (直接底)
	1.88 — 7.83	3.93	7.06	细砂岩 (基本底)

(a) 140502工作面地层综合柱状图(1: 200)



(b) 140502工作面剖面图(1: 1 000)

图1 工作面基本情况

Fig.1 Basic information of the working face

( $i = 1, 2, \dots, n$ )，其密度梯度 $\nabla\rho$ 可通过以带宽为 $r$ 的核函数 $k(X)$ 的梯度函数估计获得：

$$\nabla\rho_{r,k(X)} = \frac{2c_{k,d}}{nl^{d+2}} \left[ \sum_{i=1}^n g\left(\left\|\frac{X-X_i}{r}\right\|^2\right) \right] m_{r,G(X)} \quad (1)$$

式中： $X$ 为 $d$ 维随机变量； $c_{k,d}$ 为使 $k(X)$ 积分为1且 $g(X) = -k'(X)$ 的正归一化常数； $n$ 为样本个数； $l$ 为梯度半径； $m_{r,G(X)}$ 为均值偏移向量，可通过式(2)计算得到。

$$\mathbf{m}_{r,G(X)} = \frac{\sum_{i=1}^n X_i g(\|X - X_i, r\|^2)}{\sum_{i=1}^n g(\|X - X_i, r\|^2)} - X \quad (2)$$

式中:  $G(X)$ 为权重核函数。

上述过程可以通过递归迭代实现,该过程通过计算均值偏移向量,不断修正内核,以保证均值偏移过程的鲁棒性和收敛性<sup>[20]</sup>。虽然经典 K-means 聚类算法能够实现高效快速聚类,但最终聚类效果受初始聚类中心的影响,同时,随机初始化可能会生成不同的聚类效果,结果可重复性较差。MeanShift 聚类算法虽然也是基于中心的聚类算法,但其不需要事先制定类别数,可通过定义核函数使偏移值对偏移向量的贡献随样本与被偏移点的距离的不同而不同,增加权重系数赋予不同样本不同的权重,最终实现数据集自适应聚类。同时,MeanShift 聚类算法具有稳定性好、谱聚类效果好、层次聚类速度快等特点,对于大型数据集具有高效性和可扩展性<sup>[21]</sup>,可实现自适应的类内紧缩性和类间独立性。由此,可利用 MeanShift 聚类算法动态识别超长工作面因上覆岩层应力环境和垮落步距的变化引起的差异化区域。

因此,本文基于工作面液压支架前后立柱压力数据监测情况,以 MeanShift 聚类算法自主划分样本集密度,根据液压支架所承受载荷和所处位置的差异从而实现工作面区域区分。中煤新集口孜东煤矿 140502 工作面液压支架立柱压力监测点以等距分布在整個工作面,分别监测了第 6 号、14 号、22 号、30 号、38 号、46 号、54 号、62 号、70 号、78 号、86 号、94 号、102 号、110 号、118 号、126 号、134 号、142 号、150 号液压支架的前、后立柱压力数据。根据该工作面支架立柱压力实际监测点情况,以前、后立柱压力和支架号作为 MeanShift 聚类算法的输入参数,同时,为保证工作面区域划分的连续性,以上述编号液压支架为中心架,认为该中心架前 3 个和后 4 个液支架与中心架为同一区域,以此原则划分整个工作面的区域。基于 MeanShift 聚类的工作面区域动态识别及更新策略如下:

Step 1: 将该工作面所监测的液压支架前立柱压力、后立柱压力和支架号作为 MeanShift 聚类算法的输入参数。

Step 2: 利用网格搜索法最终确定聚类搜索半径为 30,进行数据集聚类分析。

Step 3: 在聚类结果基础上,根据所得的各聚类中心,初步划分该工作面的支护区域。

Step 4: 对于部分液压支架支护区域聚类结果存在区域跳变现象,根据支架所处某一区域的概率高低最终决定其所属支护区域。

Step 5: 对于新采集的数据,求取其与各类别中心的欧式距离,距离越小,该数据属于某一类别的概率越大,从而得出新数据所属区域。

根据上述基于 MeanShift 聚类算法的工作面区域划分流程,利用采集的口孜东矿 140502 工作面 19 个液压支架的前、后立柱压力数据对工作面区域划分,结果如图 2 所示。

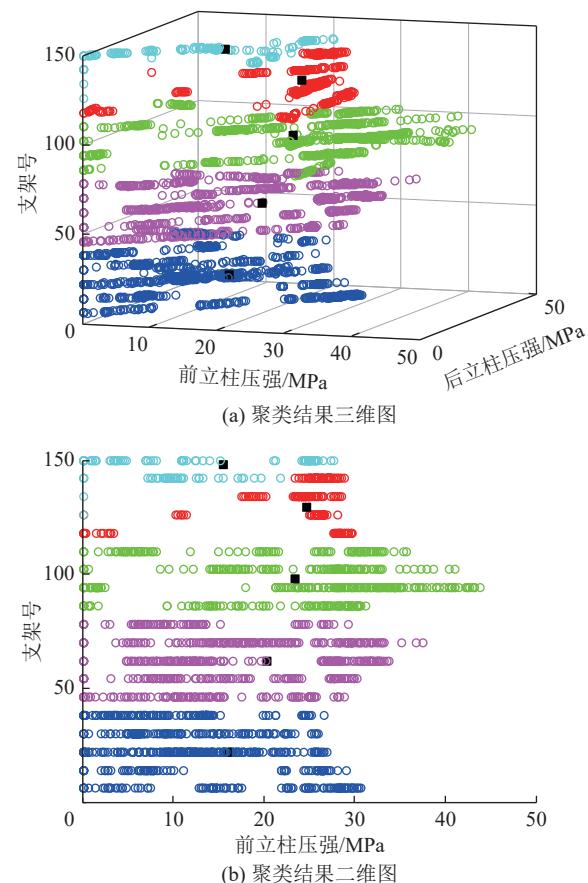


图 2 工作面区域聚类划分

Fig.2 Partition map of working face load area

图 2 中, Z 轴为支架号,分别为第 6、14、22、30、38、46、54、62、70、78、86、94、102、110、118、126、134、142 和 150 号。由图 2 可以看出,以前立柱压力、后立柱压力和支架号 3 个变量作为聚类算法的输入参数,可将工作面液压支架群组分为 5 个区域(根据颜色不同,从下向上依次记为区域 1—区域 5),且工作面各区域边界划分较为明显。但是从图 2b 也可以观察出,同一个支架的区域存在动态变化情况,即部分液压支架在某一时刻后从某一区域变为另一区域,如 142 号支架前期属于区域 4(图 2b 红色

区域),后期由于前、后立柱受力变化迁移至区域5(图2b浅蓝色区域),对于此类情况,可根据该支架所处某一区域的概率高低决定支护区域。最终,140502工作面区域划分结果见表1。

表1 工作面区域聚类结果

Table 1 Division clustering result of working face

区域	聚类中心	所包含支架
1	(22, 15.96, 16.64)	1~42
2	(62, 20.36, 18.36)	43~82
3	(98, 23.77, 23.46)	83~114
4	(129.2, 27.76, 22.78)	115~146
5	(148.1, 15.58, 16.2)	147~156

### 1.3 工作面区域特征分析

根据MeanShift聚类算法基于中心的数据划分特点,数据(支架号、支架前立柱压力和支架后立柱压力)通过均值漂移迭代,在整个数据集中寻找被低密度区域分离的高密度区域,分离出的高密度区域即为一个独立的类别,从而达到自适应聚类,因此,聚类中心所在位置为数据点密集的区域。从工作面划分区域的区域中心(图2中黑色点)可以直观地看出,各区域中心的支架载荷总体呈现工作面中部大、两端小的分布特征,且整个支架载荷分布重心偏向工作面中部至机尾。

综采工作面两端部巷帮支撑条件对工作面支护应力分布形式影响明显,随着在工作面倾向方向远离两巷位置,两端巷帮对工作面中部的上覆岩层支撑作用逐渐减小,在相同支护条件下,工作面中部的

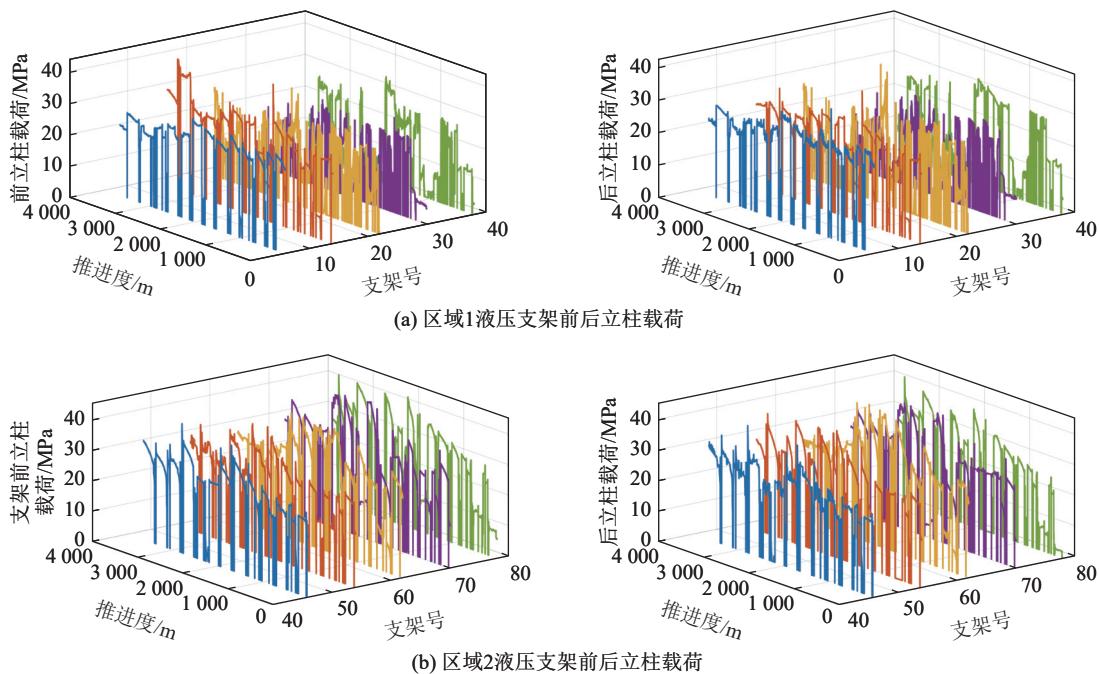
上覆岩层下沉量逐渐加大,因此,更多的液压支架位于高应力区,支架载荷呈现增大趋势。而对于口孜东矿140502工作面,其整个煤层具有明显起伏,相对于工作面机巷,工作面风巷及附近位置埋深更深,承受的矿山压力更明显,支架载荷变化与其他区域将会不同。

根据图2和表1所示工作面区域划分结果,进一步分析各区域的支架载荷变化特征及规律。各区域的支架立柱载荷监测情况如图3所示。

通过图3所示的各区域液压支架前、后立柱载荷变化情况可以看出,液压支架前、后立柱压力具有差异性,后立柱受力相对前立柱较小;工作面两端液压支架立柱载荷明显小于工作面中部液压支架载荷。根据深部采场覆岩破断失稳过程分析<sup>[15]</sup>,在推进过程中,工作面中部上覆围岩在采场高地压的作用下首先发生破断,促使直接顶离层,顶板岩层应力释放,作用于支架的载荷增大;而在工作面两端部,由于受巷帮煤柱支撑作用影响,端头区域的顶板岩层未发生明显断裂失稳,顶板岩层之间始终具有较好的传力条件,其支架载荷变化范围明显小于工作面中部。支架载荷的上述分布特征同理论分析结果吻合,表明口孜东矿140502工作面基本顶存在分区破断现象,不同区域支架载荷强度不同,各区域中心的支架载荷总体呈现工作面中部大、两端小的分布特征。

## 2 多维时序注意力机制LSTM预测方法

工业生产数据变化复杂、具有极强的非线性特



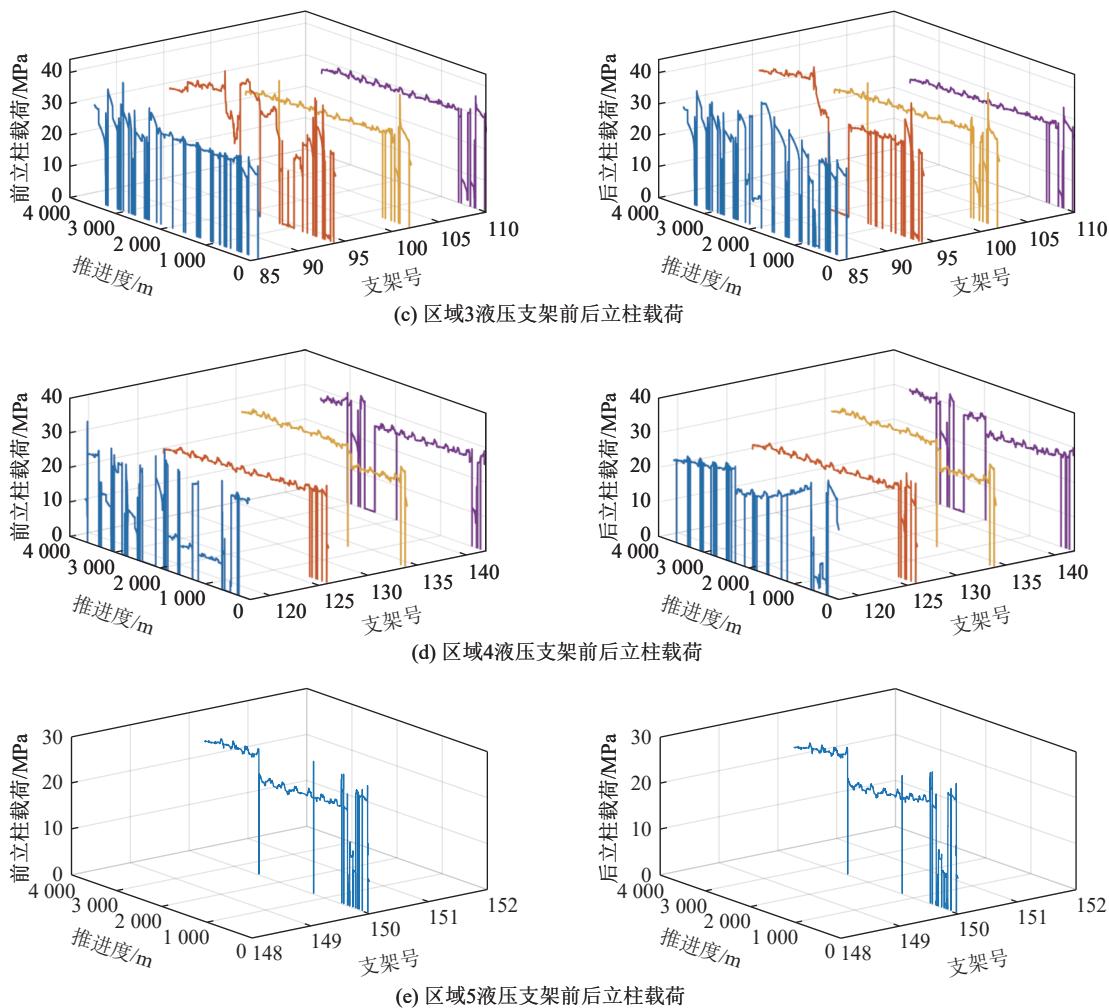


图3 各区域的支架前后立柱载荷监测情况

Fig.3 Pressure monitoring of support column in each area

征,传统自回归线性模型结构相对简单,具有局限性,工业数据的预测适应性较低<sup>[22]</sup>。基于人工神经网络的建模方法在拟合非线性变化的数据中具有较好的表现,因此,采用循环神经网络(Recurrent Neural Network, RNN)、长短期记忆(Long Short Term Memory, LSTM)网络预测工业生产时间序列数据是一种有效的方法<sup>[23]</sup>。然而,传统的神经网络仅支持独立处理每个输入,即前后输入之间完全没有任何关系,整个网络中没有任何信息交互,因此,很难利用之前信息预测未来的事件,不利于处理时间序列预测问题。

综采工作面液压支架载荷数据是典型的时间序列数据,即在不同时间点采集到的数据,反映了支架立柱压力随时间变化状态和程度,由于工作面上覆岩层在推进过程中的不断垮落,支架载荷时序数据总体呈现一种比较缓慢而长期的持续上升的群组同性质变动趋向,并在特定时间点数据值发生突降,但变动幅度不等,随着工作面推进始终重复上述过程,即综采工作面液压支架载荷时序数据具有趋势性、

周期性、随机性和综合性变化特点。因此,为实现支架载荷时序数据区域化一次性建模,需要充分考虑综采工作面液压支架载荷时序数据变化特点和LSTM模型网络结构对特殊数据结构的适应性。对于工作面支架载荷时间序列预测而言,通常会采用增加输入指标时间维度的方式丰富输入指标特征,从而提高模型的预测精度,即选用 $q-k, \dots, q-1, q$ 时刻的数据作为输入, $q+1$ 时刻的数据作为输出。然而,输入指标维度并未有明确参考依据,现主要以试凑法得到符合预测精度的模型即可<sup>[24]</sup>。

时序数据预测需要考虑不同时间维度间的非线性相互依赖,LSTM模型网络结构能够充分考虑数据时序关联关系。传统时间序列数据预测方法是基于历史时序趋势预测未来变化趋势,通过在时间维度上构建合适的模型拟合历史数据,并根据数据随时间趋势变化规律,合理地预测未来数据。根据开采工艺,工作面倾向方向多个液压支架联合支护,多组支架载荷数据在空间位置上存在协同变化的特征;

同时随着工作面推进，顶板上覆岩层不断破断垮落，支架载荷数据在时间维度上存在周期性变化特征。因此，充分考虑LSTM网络结构对多输入多输出较强的适应性，给出了如图4所示的综采工作面液压支架载荷预测模型的具有多维时序数据特征的多输入多输出特征工程。

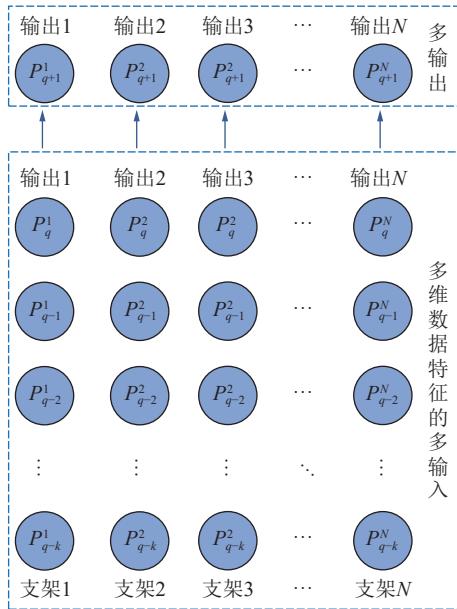


图4 具有多维时序数据特征的多输入多输出特征工程  
Fig.4 Multi-input and multi-output feature engineering with multi-dimensional time series data features

如图4所示，以工作面某一区域所有支架的前几时刻的载荷 $P$ 为输入，以该区域所有支架的下一时刻的载荷 $P$ 为输出，并随着时间从序列头部到后部不断移动，由此，构造出时间维度+空间维度的多维时序数据特征的多输入多输出特征工程，实现支架载荷时序数据区域化一次性建模。

虽然传统LSTM网络的局部连接、权重共享以及池化等优化操作可以让神经网络变得相对简单，有效缓解模型复杂度和表达能力之间的矛盾，但是，LSTM网络具有循环神经网络中的长距离依赖问题，信息“记忆”能力并不高，而当要记住更多“信息”，模型就会变得更复杂，考虑到综采工作面液压支架的“降架、移架、升架”循环动作，通过引入注意力机制，从大量信息中有选择地筛选出少量重要信息并聚焦，以权重系数的形式反映对应数据的重要程度。利用注意力机制可进一步缓解多维输入而导致的模型计算复杂度，即通过注意力机制考虑输入信息对输出信息在时间上的记忆衰减，使模型对输入序列的不同时刻特征赋予差异化的权重<sup>[25]</sup>，对输出有较大影响的数据所赋予的权重较大，反之重要程度低的数据所赋予的权重较低。因此，对于考虑多维时序数据特征的LSTM预测方法，注意力机制使模型对输入序列的不同时刻隐向量赋予了相对应的权重，按重要程度将隐向量合并为新的隐向量并输入到全连接层。引入注意力机制的LSTM网络传播过程如下：

将LSTM网络的隐藏状态与所有的输入状态进行对比，计算得到输入层中隐向量的注意力权重 $\alpha$ ：

$$\alpha_i = \frac{\exp(s_{ti})}{\sum_{i=1}^T \exp(s_{ti})} \quad (3)$$

式中： $s_{ti}$ 为不同节点间的注意力分值，计算公式如式(4)； $T$ 为LSTM网络输入层节点个数。

$$s_{ti} = v \tanh(Wx_t + Ux_i + b) \quad (4)$$

式中： $v$ 为待学习参数； $W$ 、 $U$ 和 $b$ 分别为网络权重和偏移量。 $x_i$ 为输入层第*i*个隐向量； $x_t$ 为输入层第*t*个隐向量。

由此，LSTM网络输出层节点状态向量为

$$C = \sum_{i=1}^T \alpha_i h_i \quad (5)$$

最后的特征向量，即最后节点的隐藏向量为

$$h_{t0} = f(C, h_t, x_t) \quad (6)$$

式中： $h_i$ 为隐含层第*i*个节点向量； $h_t$ 为隐含层第*t*个节点向量； $f$ 为神经网络激活函数，如图5中的 $\sigma$ 和tanh函数， $f_t$ 为LSTM网络遗忘门输出； $o_t$ 为LSTM网络输出门输出； $I_t$ 和 $\bar{C}_t$ 为LSTM网络输入门中间计算值； $S_t$ 为LSTM网络输入。

针对支架载荷时序数据区域化一次性建模，模型的输入为多个液压支架的载荷数据，每个支架载荷数据又是多时刻的，并将每个支架载荷数据维度确定为支架工作循环时间的长度，利用考虑多维时序数据特征和注意力机制相结合的LSTM预测方法，在时间维度上更侧重临近时刻的影响，在空间维度上全面考虑多支架的协同变化，兼顾支架载荷时序数据周期特征和邻近影响原则，因此，为实现预测算法和输入输出特征结构的协同设计，进一步有效提升液压支架载荷预测效果，提出一种考虑多维时序数据特征和注意力机制相结合的LSTM时序数据预测方法(MALSTM)，整体网络架构如图5所示。通过确定具有多维时序数据特征的多输入多输出特征工程，利用注意力机制对输入序列(一个支架循环工作周期)的不同时刻特征赋予差异化的权重，从而考虑时序影响实现更高精度的预测。

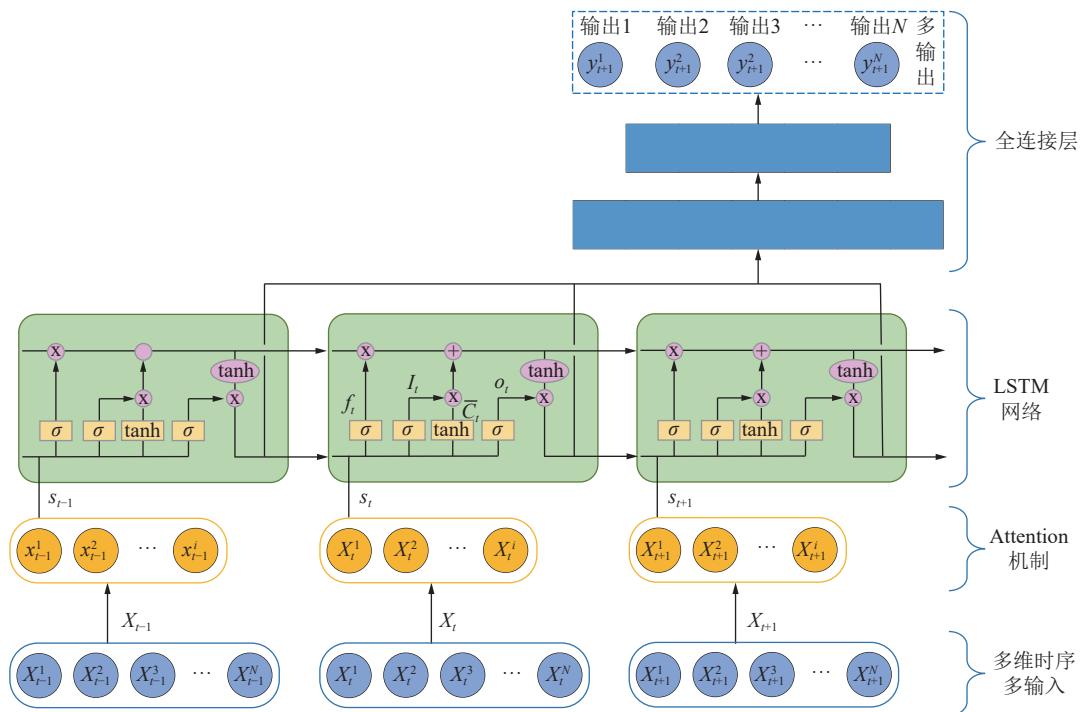


图 5 MALSTM 网络

Fig.5 MALSTM network

### 3 基于工作面区域特征的液压支架载荷预测

基于支架载荷数据和 MeanShift 聚类算法实现了综采工作面倾向方向上的区域划分,为后续实现精细化的载荷预测和针对性的支护奠定了基础。根据图 2 工作面区域划分结果,针对工作面每个区域利用所提 MALSTM 网络建立支架载荷区域预测模型。

#### 3.1 数据预处理

采集的综采工作面液压支架原始监测数据可能存在采集时间间隔和时间点不一致、重复采样、噪声影响等问题,数据驱动依赖高质量数据,因此,在进行基于区域特征的液压支架载荷预测分析之前需对原始数据进行预处理,包括根据阈值和相邻点位变化量剔除异常、坏点数值,采用滑动均值滤波噪声数据,统一时间戳,进行数据插值补齐缺失时间点的数据等操作。

选择合适长度的历史数据对实现高精度的时间序列预测至关重要。根据之前研究工作<sup>[9]</sup>,由于口孜东矿 140502 工作面液压支架立柱压力数据采样时间为 5 min,而采煤机连续运行单向截割一刀的时间大约为 1 h,即工作面该液压支架在采煤机第  $k$  刀煤过程中能够监测到的工作阻力数据约为 12 个,因此对于支架时序载荷预测模型而言,确定利用  $k-11, \dots, k-2, k-1, k$  的数据预测  $k+1$  刀煤的

支架载荷。根据口孜东矿 140502 工作面液压支架立柱压力数据实际监测情况,共采集 3 932 组时序数据,根据上述历史数据长度,共计得到 3 908 组预测模型数据集,其中训练数据集 3 126 组和测试数据集 782 组。

#### 3.2 评价指标

为验证所提结合生产工艺的基于 MALSTM 算法预测方法和制定的多输入输出指标特征工程的有效性,以均方根误差 (Root Mean Square Error, RMSE) 以及平均绝对误差 (Mean Absolute Error, MAE) 作为评价指标对基于所提算法所建立模型的预测精度进行评价,公式如式(7)、式(8)所示。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (7)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (8)$$

式中:  $y_i$  为实际值;  $\hat{y}_i$  为预测值;  $n$  为数据个数。

#### 3.3 区域支架载荷预测模型及结果

根据图 2 工作面区域划分结果,利用传统 LSTM 算法和所提 MALSTM 算法分别建立工作面各区域的支架载荷一次性预测模型,各区域支架载荷预测模型建立情况见表 2。

由表 2 可知,不同区域的支架载荷预测模型需要重新建模和训练。如针对某一区域,通过选取该

区域的所有支架前 12 个时刻的载荷数据为输入, 该区域所有支架下一时刻的载荷数据为输出, 利用图 5 所示的 MALSTM 网络, 建立工作面某个区域的支架载荷一次性预测模型, 从而实现整个工作面的支架载荷预测。

表 2 各区域载荷预测模型建立情况

Table 2 Establishment of load prediction model in each region

区域编号	所预测支架号
1	6、14、22、30、38
2	46、54、62、70、78
3	86、94、102、110
4	118、126、134、142
5	150

模型训练环境为 python 3.9.7, 使用 keras 2.8.0 深度学习框架对数据集进行建模。模型学习率为 0.000 01, 批训练大小为 147, Epoch 为 1 000, 损失函数为均方误差, 优化器采用 Adamax 优化器, 神经网络为双隐含层结构, 隐含层神经单元个数为 200, 采用 Relu 激活函数。图 6 给出了基于传统 LSTM 算法的区域 1 各个支架载荷模型训练结果。

根据图 6 基于传统 LSTM 算法的区域 1 支架载荷模型训练结果可以看出, 所确定的输入输出特征工程基本能够实现支架载荷动态变化的预测, 但从图 6 可以直观看出大多数情况下预测曲线的趋势变化与实际相差较大。

因此, 为进一步提高工作面支架载荷区域化预测的精度, 基于 MALSTM 算法, 以支架工作循环时间的长度作为输入变量的维度, 建立区域支架载荷预测模型。图 7 给出了以区域 1 为示例的各个支架载荷模型训练结果, 图 8 给出了基于 MALSTM 算法和 LSTM 算法的模型训练误差收敛曲线。

如图 7 和图 8 所示, 基于 MALSTM 所训练的模型能够较好地拟合实际压力变化情况, 且精度较高, 同时 MALSTM 模型的误差收敛曲线能够较快地收敛, 且误差更小。

图 9 分别给出了以区域 1 为示例的传统 LSTM 支架载荷预测结果和所提 MALSTM 支架载荷预测结果。

从图 9 的预测结果中可以直观地看出, 所提结合生产工艺的 MALSTM 算法能够很好的实现支架载荷分区预测, 预测值与实际值的动态变化趋势基本保持一致, 误差也在可接受范围内, 尤其是在支架载荷并未发生较大范围波动的情况下, 预测结果能

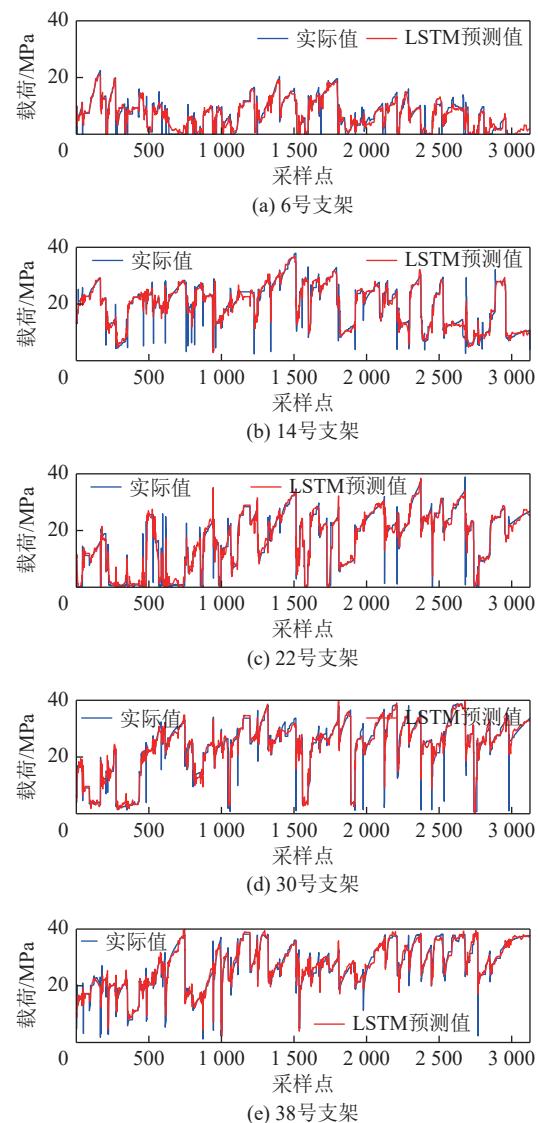


图 6 基于传统 LSTM 算法的区域 1 模型训练结果  
Fig.6 Train results of region 1 based on traditional LSTM algorithm

够更好地拟合实际情况。因此, 所提方法的预测结果能够实现不同区域的支架载荷较高精度的动态预测。

表 3 对比了上述 2 种方法的区域 1 支架载荷预测误差。根据模型预测误差对比(表 3)可知, 所提 MALSTM 算法的预测误差远低于传统 LSTM 算法, 即所提方法的预测精度更高, 能够实现工作面区域支架载荷的高精度预测。

## 4 结 论

1) 为解决深部超长工作面顶板长期循环动载作用和分区破断造成工作面不同区域载荷差异明显以及无法实现动态区域更新下的液压支架群组载荷预测的问题, 提出了一种数据驱动的工作面支架

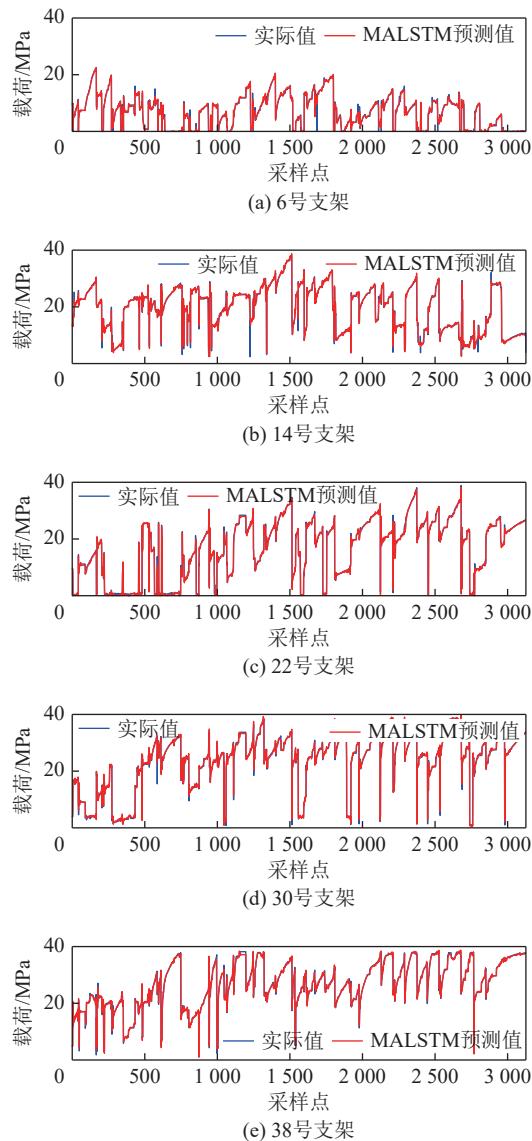


图7 基于 MALSTM 算法的区域 1 模型训练结果  
Fig.7 Train results of region 1 based on MALSTM algorithm

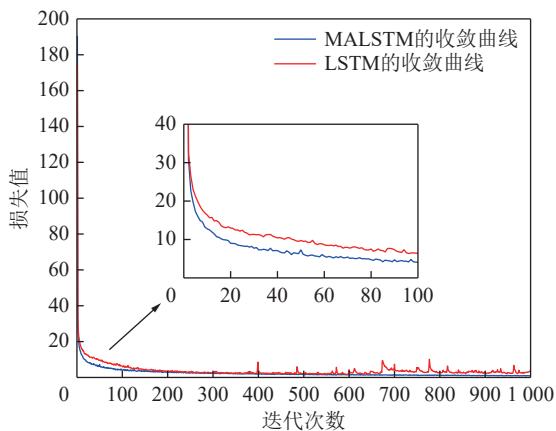


图8 模型训练误差收敛曲线  
Fig.8 Model training error convergence curve

载荷区域特征分析与分区预测方法。

2) 提出了基于 MeanShift 聚类算法的工作面倾

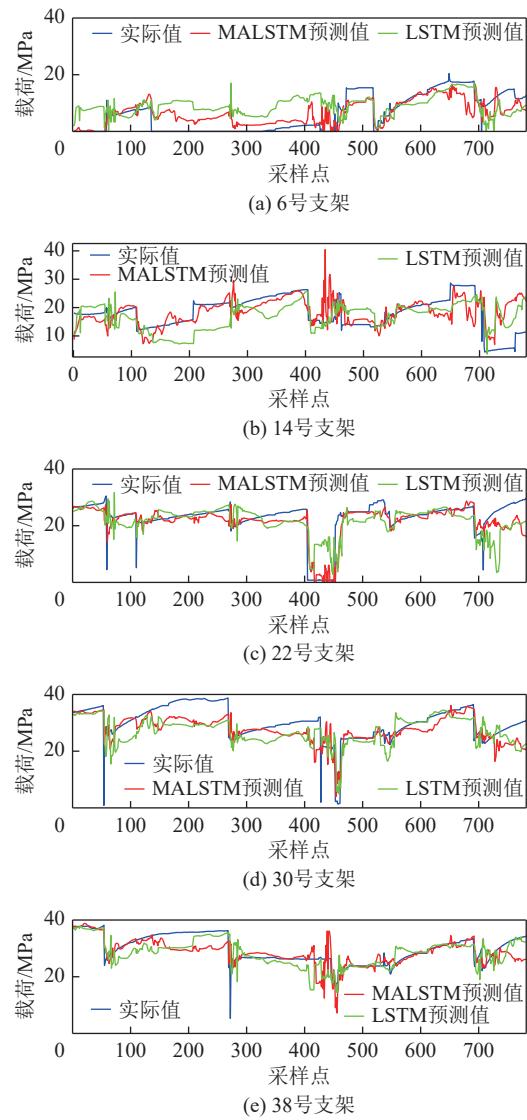


图9 区域 1 支架载荷预测结果对比  
Fig.9 Prediction results of region 1

表3 区域 1 支架载荷预测误差对比

Table 3 Comparison of prediction errors for support load in zone 1

算法	支架号	RMSE	MAE
LSTM	6	156.305 2	8.872 4
	14	188.592 0	11.213 5
	22	32.847 4	4.401 2
	30	41.276 0	5.121 0
	38	19.080 2	3.813 4
MALSTM	6	3.712 8	1.006 7
	14	3.399 4	0.868 6
	22	9.498 8	2.208 1
	30	0.016 9	0.108 2
	38	1.325 4	0.731 1

向方向区域划分方法，并结合实际工作面煤层条件分析了区域支架载荷分布变化特征：口孜东 140502

大采高超长工作面中部支架载荷呈现增大趋势,两端部支架载荷呈现降低趋势,且由于工作面风巷附近位置埋深更深,支架载荷变化更明显。

3)构建了工作面支架载荷预测多输入多输出指标特征工程,开展了基于MALSTM算法的支架载荷区域化一次性预测研究,实现了工作面支架载荷区域化高精度预测。

#### 参考文献(References):

- [1] 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.
- [2] 张可斌,钱鸣高,郑朋强,等.采场支架围岩关系研究及支架合理额定工作阻力确定[J].采矿与安全工程学报,2020,37(2): 215–223.  
ZHANG Kebin, QIAN Minggao, ZHENG Pengqiang, et al. Relationship between support and surrounding rocks and determination of reasonable rated working resistance against support[J]. Journal of Mining & Safety Engineering, 2020, 37(2): 215–223.
- [3] 王云广,郭文兵,白二虎,等.高强度开采覆岩运移特征与机理研究[J].煤炭学报,2018,43(S1): 28–35.  
WANG Yunguang, GUO Wenbing, BAI Erhu, et al. Characteristics and mechanism of overlying strata movement due to high-intensity mining[J]. Journal of China Coal Society, 2018, 43 (S1): 28–35.
- [4] 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 working face cycle pressure based on BP neural network[J]. Journal of Anhui University of Science and Technology (Natural Science Edition), 2012, 32(1): 59–63.
- [5] 徐刚,张春会,张振金.综放工作面顶板缓慢活动支架增阻预测模型[J].煤炭学报,2020,45(11): 3678–3687.  
XU Gang, ZHANG Chunhui, ZHANG Zhenjin. Prediction model for increasing resistance of hydraulic support due to slow motion of the roof in mechanized mining working face[J]. Journal of China Coal Society, 2020, 45(11): 3678–3687.
- [6] 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.
- [7] 柴敬,刘义龙,王安义,等.基于GRU和XGBoost的矿压显规律预测[J].工矿自动化,2022,48(1): 91–97.  
CHAI Jing, LIU Yilong, WANG Anyi, et al. Prediction of strata behaviors law based on GRU and XGBoost[J]. Industrial and Mining Automation, 2022, 48(1): 91–97.
- [8] 张洋,马云东,崔铁军.基于小波和混沌优化LSSVM的周期来压预测[J].安全与环境学报,2014,14(4): 63–66.  
ZHANG Yang, MA Yundong, CUI Tiejun. Periodic compression prediction based on wavelet and chaos optimization LSSVM[J]. Journal of Safety and Environment, 2014, 14(4): 63–66.
- [9] 巩师鑫,任怀伟,杜毅博,等.基于MRDA-FLPE集成算法的综采工作面矿压迁移预测[J].煤炭学报,2021,46(S1): 529–538.  
GONG Shixin, REN Huawei, DU Yibo, et al. Transfer prediction of underground pressure for fully mechanized mining[J]. Journal of China Coal Society, 2021, 46(S1): 529–538.
- [10] 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.
- [11] 尹希文,徐刚,刘前进,等.基于支架载荷的矿压双周期分析预测方法[J].煤炭学报,2021,46(10): 3116–3126.  
YIN Xiwen, XU Gang, LIU Qianjin, et al. Method of double-cycle analysis and prediction for rock pressure based on the support load[J]. Journal of China Coal Society, 2021, 46 (10) : 3116–3126.
- [12] 常峰.基于GA-BP神经网络的工作面顶板矿压预测模型应用研究[D].徐州:中国矿业大学,2019.  
CHANG Feng. Application research of mining pressure prediction model for working face roof based on GA-BP neural network[D]. Xuzhou: China University of Mining and Technology, 2019.
- [13] 屈世甲,李鹏.基于支架工作阻力大数据的工作面顶板矿压预测技术研究[J].矿业安全与环保,2019,46(2): 92–97.  
QU Shijia, LI Peng. Research on roof pressure prediction technology of working face based on big data of support working resistance[J]. Mining Safety and Environmental Protection, 2019, 46(2): 92–97.
- [14] 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研究[J].煤炭学报,2021,46(S1): 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.
- [15] 庞义辉,巩师鑫,刘庆波,等.深部采场覆岩断裂失稳过程及支架载荷预测分析[J].采矿与安全工程学报,2021,38(2): 304–316.  
PANG Yihui, GONG Shixin, LIU Qingbo, et al. Overlying strata fracture and instability process and support loading prediction in deep working face[J]. Journal of Mining & Safety Engineering, 2021, 38(2): 304–316.
- [16] 徐亚军,王国法.液压支架群组支护原理与承载特性[J].岩石力学与工程学报,2017,36(1): 3367–3373.  
XU Yajun, WANG Guofa. Supporting principle and bearing characteristics of hydraulic powered roof support groups[J]. Chinese Journal of Rock Mechanics and Engineering, 2017, 36( 1 ) : 3367–3373.

- [ 17 ] 刘杰, 王恩元, 赵恩来, 等. 深部工作面采动应力场分布变化规律实测研究[J]. 采矿与安全工程学报, 2014, 31(1): 30–65.  
LUI Jie, WANG Enyuan, ZHAO Enlai, et al. Distribution and variation of mining-induced stress field in deep workface[J]. Journal of Mining & Safety Engineering, 2014, 31(1): 30–65.
- [ 18 ] 王国法, 张金虎, 徐亚军, 等. 深井厚煤层长工作面支护应力特性及分区协同控制技术[J]. 煤炭学报, 2021, 46(3): 763–773.  
WANG Guofa, ZHANG Jinghu, XU Yajun, et al. Supporting stress characteristics and zonal cooperative control technology of long working face in deep thick coal seam[J]. Journal of China Coal Society, 2021, 46(3): 763–773.
- [ 19 ] 王家臣, 杨胜利, 杨宝贵, 等. 深井超长工作面基本顶分区破断模型与支架阻力分布特征[J]. 煤炭学报, 2019, 44(1): 54–63.  
WANG Jiachen, YANG Shengli, YANG Baogui, et al. Roof sub-regional fracturing and support resistance distribution in deep longwall face with ultra-large length[J]. Journal of China Coal Society, 2019, 44(1): 54–63.
- [ 20 ] CUI Zhen, ZHOU Yanlai, GUO Shenglian, et al. Effective improvement of multi-step-ahead flood forecasting accuracy through encoder-decoder with an exogenous input structure[J]. Journal of Hydrology, 2022, 609: 127764.
- [ 21 ] ZHANG Leilei, WANG Guoxin, SUN Weijian. Automatic extraction of building geometries based on centroid clustering and contour analysis on oblique images taken by unmanned aerial vehicles[J]. International Journal of Geographical Information Science, 2022, 36(3): 453–475.
- [ 22 ] MARTÍNEZ F, CHARTE F, FRÍAS P M, et al. Strategies for time series forecasting with generalized regression neural networks[J]. Neurocomputing, 2022, 491: 509–521.
- [ 23 ] SHEN Zhipeng, FAN Xuechun, ZHANG Liangyu, et al. Wind speed prediction of unmanned sailboat based on CNN and LSTM hybrid neural network[J]. Ocean Engineering, 2022, 254: 111352.
- [ 24 ] CHENG Yongwei, WANG Chao, FAN Tijun. Forecast of the time lag effect of carbon emissions based on a temporal input-output approach[J]. Journal of Cleaner Production, 2021, 293: 126131.
- [ 25 ] REN Juan, YU Zhongping, GAO Guiqiang, et al. A CNN-LSTM-LightGBM based short-term wind power prediction method based on attention mechanism[J]. Energy Reports, 2022, 8( S5 ) : 437–443.