

文章编号:1671-251X(2022)01-0091-07

DOI:10.13272/j.issn.1671-251x.2021070062

基于 GRU 和 XGBoost 的矿压显现规律预测

柴敬^{1,2}, 刘义龙³, 王安义³, 屈世甲⁴, 欧阳一博¹

(1. 西安科技大学 能源学院, 陕西 西安 710054; 2. 西安科技大学 西部矿井开采及灾害防治教育部重点实验室, 陕西 西安 710054; 3. 西安科技大学 通信与信息工程学院, 陕西 西安 710054; 4. 天地(常州)自动化股份有限公司, 江苏 常州 213015)

摘要:采用光纤传感器监测的光纤频移值对矿压显现规律进行表征的过程中,传感器采集的数据存在缺失现象,无法准确预测矿压显现规律。针对该问题,以千秋煤矿为工程背景,在假设光纤下半部分数据丢失的前提下,引入 GRU(门控循环单元)和 LSTM(长短期记忆网络)2 种预测模型,对缺失的光纤频移值进行对比预测,得出 GRU 模型的收敛速度优于 LSTM 模型的收敛速度,说明基于 GRU 模型的缺失值处理方法较优。将原始完整的光纤频移值转换为可表征矿压显现位置的光纤平均频移变化度,引入 XGBoost(极端梯度提升)模型和 BP 神经网络模型进行对比预测,XGBoost 模型能准确预测出测试集中所有出现“尖峰”的位置,而 BP 神经网络模型只预测出 2 处“尖峰”位置,说明 XGBoost 模型的预测效果优于 BP 神经网络模型的预测效果。将预测出的光纤频移缺失值替换至缺失位置,形成“完整”光纤频移值数据,将该数据转换为光纤平均频移变化度后,采用 XGBoost 模型进行预测。验证结果表明:LSTM 模型及 GRU 模型均可准确预测出光纤下半部分的数据,且 GRU 模型准确性较 LSTM 模型准确性高;使用 XGBoost 可准确预测出测试集中出现的周期来压;通过 GRU 模型预测出的缺失数据经整合至缺失位置后,使用 XGBoost 模型仍可进行有效的矿压预测。

关键词:矿压显现规律;极端梯度提升算法;XGBoost;GRU;光纤频移值;光纤平均频移变化度
中图分类号:TD323 **文献标志码:**A

Prediction of strata behaviors law based on GRU and XGBoost

CHAI Jing^{1,2}, LIU Yilong³, WANG Anyi³, QU Shijia⁴, OUYANG Yibo¹

(1. College of Energy Engineering, Xi'an University of Science and Technology, Xi'an 710054, China; 2. Key Laboratory of Western Mine Exploitation and Hazard Prevention, Ministry of Education, Xi'an University of Science and Technology, Xi'an 710054, China; 3. College of Communication and Information Engineering, Xi'an University of Science and Technology, Xi'an 710054, China; 4. Tiandi(Changzhou) Automation Co., Ltd., Changzhou 213015, China)

Abstract:In the process of using optical fiber frequency shift value monitored by optical fiber sensor to characterize the strata behaviors law, the data collected by the sensor is missing, and the strata behaviors law can not be accurately predicted. In order to solve this problem, taking Qianqiu Coal Mine as the engineering background, under the premise of partial data loss of the lower half of the optical fiber, two prediction models, GRU (Gated Recurrent Unit) and LSTM (Long Short-Term Memory), are introduced to compare and predict the missing optical fiber frequency shift value. The convergence speed of the GRU model is better than that of the LSTM model, which shows that the missing value processing method based

收稿日期:2021-07-20;**修回日期:**2022-01-06;**责任编辑:**王晖,郑海霞。
基金项目:国家重点研发计划项目(2018YFC0808301);国家自然科学基金资助项目(51804244)。
作者简介:柴敬(1964—),男,宁夏平罗人,教授,博士研究生导师,主要从事采矿工程、实验岩石力学及光纤传感方面的研究工作,E-mail:chaij@xust.edu.cn。
引用格式:柴敬,刘义龙,王安义,等.基于 GRU 和 XGBoost 的矿压显现规律预测[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]. 扫码移动阅读 Industry and Mine Automation,2022,48(1):91-97.



on the GRU model is better. The original and complete optical fiber frequency shift value is converted into the average optical fiber frequency shift change which can characterize the strata behaviors position, and the XGBoost (eXtreme Gradient Boosting) model and the BP neural network model are introduced for comparative prediction. The XGBoost model can predict all the ‘peak’ positions in the test set accurately. However, the BP neural network model can only predict two ‘peak’ positions, which shows that the prediction effect of the XGBoost model is better than that of the BP neural network model. The predicted optical fiber frequency shift missing value is replaced to the missing position to form ‘complete’ optical fiber frequency shift value data. The data is converted into the average optical fiber frequency shift change and then the XGBoost model is used for prediction. The results show that both the LSTM model and the GRU model can predict the data of the lower half of the optical fiber accurately, and the GRU model has higher accuracy than the LSTM model. The XGBoost model can predict the periodic pressure in the test set accurately. After the missing data predicted by the GRU model is integrated into the missing position, the XGBoost model can still predict the strata behaviors effectively.

Key words: strata behaviors law; extreme gradient boosting algorithm; XGBoost; GRU; optical fiber frequency shift value; optical fiber average frequency shift change

0 引言

煤炭开采过程破坏了岩层间原始的应力平衡状态,在重力影响下,岩体会产生新的应力场,通常称为矿压显现。剧烈的矿压会诱发巷道变形失稳、瓦斯突出、冲击地压等地质灾害,为煤矿生产带来巨大的损失^[1-2]。因此,为减少地质灾害的发生,掌握矿压显现的规律并对矿压进行有效预测和控制是煤矿安全生产的重要课题之一。

近年来,分布式光纤传感技术^[3-5]的兴起有效解决了矿压难以监测的问题。但是,由于采动过程中岩层变形具有随机性、非线性特点,导致矿压规律难以预测。为解决该问题,许多学者采用光纤传感器监测的光纤频移值对矿压显现规律进行表征。王润沛^[6]基于光纤平均频移变化度表征矿压的原理,结合机器学习算法对矿压进行预测。巩师鑫等^[7]基于液压支架工作阻力数据表征矿压的原理,采用 MRDA FLPEM(流形正则域适应函数链接预测误差)集成算法预测了综采工作面矿压。赵毅鑫等^[8]利用液压支架阻力数据分析了大采高工作面的矿压显现规律并采用深度学习算法预测了矿压。常峰^[9]基于工作面顶板矿压数据,采用遗传算法优化后的 BP 神经网络模型预测了综采工作面顶板的来压规律。李泽萌^[10]采用 LSTM(Long Short-Term Memory,长短期记忆网络)模型对支架阻力数据表征的矿压进行预测。赵铭生等^[11]基于工作面综采条件下的矿压破坏深度实测数据,采用遗传算法优化后的 BP 神经网络模型对矿压破坏深度进行预测。上述研究在数据完整情况下对矿压显现规律进行了有效预测,但矿井环境恶劣,传感器采集的数据

存在缺失现象,导致无法准确预测矿压显现规律。因此,本文以义马煤业(集团)有限责任公司千秋煤矿为工程背景,搭建三维相似物理模型,在假设光纤下半部分数据丢失的前提下,引入 GRU(Gated Recurrent Unit,门控循环单元)和 LSTM 预测模型,对缺失的光纤频移值进行对比预测,使用预测效果较优的缺失值填补光纤频移值数据缺失位置。将填补后的光纤频移值数据转换为能表征矿压规律的光纤平均频移变化度数据,引入极端梯度提升(eXtreme Gradient Boosting, XGBoost)^[12]模型和 BP 神经网络模型进行对比预测,得到较适合的矿压预测模型。

1 相似物理模型及光纤数据监测系统搭建

1.1 相似物理模型搭建

根据千秋煤矿的地质特征及构造(表 1)搭建三维相似物理模型,如图 1 所示。模型几何相似比为 1:400,容重相似比为 1:1.6,尺寸为 3 600 mm×2 000 mm×2 000 mm(长×宽×高)。模型中上覆岩层厚度为 174 mm,模拟煤层厚度为 60 mm,底板厚度为 200 mm。在模型上方均匀放置载荷共计 3.4 kPa 的沙袋。自开切眼位置从左至右进行掘进,工作面推进步距为 40 mm,推进总长为 2 400 mm。

1.2 光纤数据监测系统搭建

在相似物理模型中埋设分布式光纤传感器,建立光纤数据监测系统,如图 2 所示。该系统由光纤传感器、NBX-6055 应力分析仪及计算机组成。在模型中部等间距布设 3 条垂直光纤 Fv1, Fv2, Fv3, 光纤数据采样间隔为 10 mm,有效长度为 1 740 mm。

表 1 覆岩结构及物理力学参数

Table 1 Rock structure and physical and mechanical parameters						
序号	名称	岩层厚度/m	抗压强度/MPa	抗拉强度/MPa	弹性模量/ 10 ³ MPa	岩层容重/ (t·m ⁻³)
15	黏土	15.0	15.0	1.5	5.0	1.6
14	泥灰岩	5.0	15.0	1.5	5.0	1.6
13	砾岩	65.0	35.0	5.5	32.0	1.8
12	细砂岩	85.0	30.0	4.0	28.0	1.6
11	砾岩	250.0	75.0	5.5	32.0	1.7
10	破碎带	1.0	40.0	4.0	28.0	1.7
9	砾岩	160.0	75.0	5.5	32.0	1.8
8	泥岩	50.0	50.0	1.2	5.0	1.9
7	细砂岩	40.0	40.0	9.0	35.0	1.6
6	粉砂岩	70.0	45.0	4.0	28.0	1.7
5	细砂岩	25.0	40.0	9.0	31.0	1.6
4	泥岩	25.0	50.0	1.2	5.0	1.9
3	2 号煤	15.0	16.0	0.6	3.5	0.9
2	砾岩	8.0	65.0	5.5	32.0	1.8
1	泥岩	72.0	50.0	1.2	5.0	1.9



图 1 三维相似物理模型

Fig.1 3D similar physical model

在模拟工作面掘进时,光纤受到岩层内部变形力的作用发生频移,通过 NBX-6055 应力分析仪将光信号转换为电信号后,传输到计算机,最后使用计算机软件实现对光纤数据的解析和存储,采集到的数据以 .bat 格式存放。为了便于处理,将数据迁移至 excel 表格中,数据结构为 174×60 的矩阵形式,行代表整条光纤各个位置的数据,列代表工作面的推进距离。

2 相关原理

2.1 光纤频移数据表征矿压原理

根据光纤传感原理可知,在消除温度因素影响




图 2 光纤监测系统

Fig.2 Optical fiber monitoring system

后,布里渊频移值与应变存在线性关系。布里渊频移值的变化是传感光纤对岩体变形破裂过程中信息变化的反映。岩层产生的变形越明显,光纤所受应力越大,光纤监测系统测得的布里渊频移值变化也越大;当岩层产生的变形不明显时,光纤监测系统测得的布里渊频移值变化小。基于上述岩层变形引起的光纤频移值变化规律,文献[13-16]提出了一种利用光纤平均频移变化度表征矿压的方法,即将光纤平均频移变化度曲线中的“尖峰”位置作为上覆岩层矿压显现的判断指标。光纤平均频移变化度公式为

$$D_l = \frac{1}{N} \left[\sum_{n=1}^N (|S_l^n| - |S_{l-1}^n|) \right] \tag{1}$$

式中: D_l 为工作面第 l 次掘进时的光纤平均频移变化度; N 为光纤采样点个数; S_l^n 为第 l 次掘进时光纤传感器第 n 个采样点的频移值。

2.2 GRU 预测原理

GRU 模型是基于 RNN (Recurrent Neural Network,循环神经网络)预测模型和 LSTM 预测模型的改进模型,既解决了 RNN 模型中由于共享系数矩阵导致的梯度弥散和梯度爆炸的问题,也解决了 LSTM 中内部单元结构冗余的问题。这使得 GRU 模型在运算速度上优于 LSTM 模型,且对小样本数据集的预测精度更高。

GRU 模型内部单元主要由重置门和更新门组成,如图 3 所示。重置门可以令当前神经元的隐藏状态遗忘与预测不相关的信息。更新门用于更新当前时刻该神经单元记忆有效信息的程度,更新门的值越大说明记忆的有效信息越多。

GRU 模型内部各部分运算表达式为

$$r = \sigma(W_r x_t + B_r h_{t-1}) \tag{2}$$

$$z = \sigma(W_z x_t + B_z h_{t-1}) \tag{3}$$

$$g = \tanh(W_g x_t + B_g r h_{t-1}) \tag{4}$$

$$h_t = (1 - z) h_{t-1} + z g \tag{5}$$




图 3 GRU 网络结构

Fig. 3 GRU network topology

式中： r 为重置门； σ 为 sigmoid 激活函数，表示神经元的激活率； $W_r, B_r, W_z, B_z, W_g, B_g$ 分别为重置门、更新门和候选隐藏状态的上一时刻输出及当前时刻输入所对应的权重矩阵； x_t 为 t 时刻的输入； h_{t-1} 为 $t-1$ 时刻的输出； z 为更新门； g 为候选隐藏状态； h_t 为 t 时刻的输出。

2.3 XGBoost 预测原理

XGBoost 是在上一次模型预测的基础上加入一颗新树，然后去拟合前面树的预测结果与真实值之间的残差从而形成新模型，并将新模型作为下次模型学习的基础，以此提升模型的预测精度。其函数为

$$\bar{y}_c = \sum_{k=1}^K f_k(u_c), f_k \in F \tag{6}$$

式中： $\bar{y}_c$ 为模型的第 c 个预测值； $f_k(u_c)$ 为输入特征 u_c 对应的第 k 棵决策树模型； K 为决策树总数； F 为所有决策树模型元素的集合。

XGBoost 使用的目标函数为

$$Y^{(m)} = q(y_c, \bar{y}_c^{(m)}) + \Omega \tag{7}$$

$$\Omega = \gamma T + \frac{1}{2} \lambda \|\omega\|^2 \tag{8}$$

式中： $Y^{(m)}$ 为迭代至第 m 轮的目标函数； $q(y_c, \bar{y}_c^{(m)})$ 为真实值 y_c 与第 m 轮迭代预测值 $\bar{y}_c$ 的误差函数，误差函数通过不断学习，逐渐使预测结果不断逼近真实值； Ω 为惩罚项； γ, λ 分别为叶子数量和叶子节点分数的系数矩阵； T 为每棵树的叶子数量； ω 为每棵树的叶子节点分数组成的集合。

2.4 评估指标

采用平均绝对误差 M_R 和平均相对误差 M_A 作为模型预测效果的评价指标。

$$M_R = \frac{1}{C} \sum_{c=1}^C \frac{|y_c - \bar{y}_c|}{\frac{1}{C} \sum_{c=1}^C y_c} \times 100\% \tag{9}$$

$$M_A = \frac{1}{C} \sum_{c=1}^C |(y_c - \bar{y}_c)| \tag{10}$$

式中 C 为参与评估的样本数。

3 基于 GRU 模型的缺失值处理

3.1 参数设置

为选取较优模型进行缺失值处理，对 LSTM 和 GRU 模型的预测效果进行对比。采用掘进至 2 320 mm 的光纤频移值数据作为 GRU 和 LSTM 模型的数据集，将数据集按照 7:3 的比例划分为训练集和测试集。设预测步长为 1，将均方误差函数作为损失函数，批尺寸为 3，迭代次数为 20。

3.2 实验结果分析

LSTM 和 GRU 模型的损失函数分别如图 4、图 5 所示。可看出在迭代过程中，LSTM 模型在 7 次迭代后收敛过程平稳，GRU 模型在 5 次迭代后收敛过程平稳，训练集损失函数和测试集损失函数均达到平稳状态，说明 GRU 模型的收敛速度比 LSTM 模型的收敛速度快。




图 4 LSTM 模型损失函数

Fig. 4 LSTM model loss function




图 5 GRU 模型损失函数

Fig. 5 GRU model loss function

LSTM 和 GRU 模型对 Fv1 光纤下半部分数据反归一化后的预测结果如图 6 所示。可看出 2 种预测模型都能准确预测出光纤下半部分频移数据。为衡量模型的表现能力，计算真实值和预测值的误差可得：LSTM 模型的平均相对误差为 15.63%，平均绝对误差为 17.43 MHz，GRU 模型的平均相对误差为 10.84%，平均绝对误差为 9.78 MHz。说明 GRU 模型的精度比 LSTM 模型的精度高。因此，使用 GRU 模型对缺失值进行回归预测可得到更优效果。

3.3 GRU 模型泛化能力评估

为了评估 GRU 模型的泛化能力，假设工作面




图 6 LSTM 和 GRU 模型的预测结果

Fig. 6 The prediction results of LSTM and GRU models
掘进至 1 320 mm 时出现缺失现象,导致在后续监测过程中,光纤监测的下半部分光纤频移值数据均缺失,采用 GRU 模型进行多次预测,将预测结果填补至缺失位置,如图 7 所示。与光纤原始频移数据(图 8)对比可知,使用 GRU 模型预测的光纤数据与原始光纤频移数据曲线基本一致,说明 GRU 模型具有良好的泛化能力。




图 7 光纤预测数据整合

Fig. 7 The optical fiber prediction data integration




图 8 光纤原始频移数据

Fig. 8 The optical fiber raw frequency shift data

4 基于 XGBoost 模型的矿压预测

4.1 数据预处理

为了验证 XGBoost 模型在预测矿压规律上的优越性,采用传统的 BP 神经网络模型与 XGBoost

模型对矿压进行对比预测。将完整的光纤频移值转换为能表征矿压现象的光纤平均频移变化度曲线,如图 9 所示。根据光纤平均频移变化度“尖峰”可以表征矿压的原理,对“尖峰”进行标注,在工作面掘进过程中,共出现 14 次来压现象。




图 9 Fv1 光纤平均频移变化度曲线

Fig. 9 The average frequency shift curve of Fv1 optical fiber

4.2 数据集构建

基于混沌理论^[17]对光纤平均频移变化度数据进行相空间重构,通过自相关法得到最佳延迟时间 τ 和嵌入维数 v 。经实验得到当 $v=3, \tau=1$ 时,模型达到最优状态。设 P 为根据嵌入维数 v 建立的输入数据集, Q 为根据延迟时间 τ 建立的输出数据集,数据集形式为

$$P = \begin{bmatrix} p_1 & p_2 & \cdots & p_v \\ p_2 & p_3 & \cdots & p_{v+1} \\ \vdots & \vdots & & \vdots \\ p_{n-v} & p_{n-v+1} & \cdots & p_{n-1} \end{bmatrix}, Q = \begin{bmatrix} p_{v+1} \\ p_{v+2} \\ \vdots \\ p_n \end{bmatrix} \quad (11)$$

式中 p 为数据集中的数据。

将经过相空间重构的数据集按照 4:1 的比例划分为训练集和测试集,将训练集代入模型进行学习,测试集用来评估模型预测效果。

4.3 矿压预测

采用网格搜索算法对 XGBoost 模型中树的深度和数量等超参数进行最优化,当树的深度为 6、树的数量为 60 时,可使模型性能达到最优。XGBoost 模型和 BP 神经网络模型的预测结果如图 10 所示。可看出 XGBoost 模型能准确预测出测试集中所有出现“尖峰”的位置,而 BP 神经网络模型只预测出 2 处“尖峰”的位置,说明 XGBoost 模型的预测效果优于 BP 神经网络模型的预测效果。

计算可得 BP 神经网络模型的平均绝对误差为 34.42 MHz,平均相对误差为 23.01%,XGBoost 模型的平均绝对误差为 13.60 MHz,平均相对误差为 9.45%,XGBoost 模型误差小于 BP 神经网络模型,




图 10 XGBoost 模型和 BP 神经网络模型的预测结果

Fig. 10 Prediction results of XGBoost model and BP neural network model

说明 XGBoost 模型预测矿压的准确率优于 BP 神经网络模型。

5 实验验证

为验证使用 GRU 模型预测缺失值的有效性和采用 XGBoost 模型预测矿压的泛化性,将预测出来的缺失数据填补到缺失位置,形成“完整”的光纤频移值数据,将其转换为光纤频移变化度数据后,再使用 XGBoost 模型进行预测,实验结果如图 11 所示。可看出经缺失值填补后,采用 XGBoost 模型依然可以准确预测出“尖峰”位置。对 XGBoost 模型预测出来的数据与真实数据间的误差进行统计,可得平均绝对误差为 13.74 MHz,平均相对误差为 9.48%。与使用 XGBoost 模型预测完整光纤的效果相差不大。综上所述,使用 GRU 模型可对缺失的光纤数据进行有效预测,且 XGBoost 模型在其他数据集中的表现良好。




图 11 替换数据预测

Fig. 11 Replacement data prediction

6 结论

(1) 通过 LSTM 和 GRU 模型对光纤下半部分数据进行预测。结果表明,2 种模型均可准确预测出光纤下半部分的数据,且 GRU 模型准确性较

LSTM 模型准确性高。

(2) 基于表征矿压规律的相似物理模型实验测得的光纤频移数据,使用 XGBoost 模型对模拟工作面推进下的矿压进行预测,可准确预测出测试集中所有出现“尖峰”的位置,其平均绝对误差为 13.60 MHz,平均相对误差为 9.45%。

(3) 通过多次采用 GRU 模型预测其他掘进次数的光纤下半部分数据,用预测结果替换原始监测结果,重新计算光纤平均频移变化度,经归一化、相空间重构后代入 XGBoost 模型进行预测。结果表明,替换后的数据能准确预测出周期来压,与原始结果基本吻合,其平均绝对误差为 13.74 MHz,平均相对误差为 9.48%。

参考文献 (References):

[1] 何满潮,马新根,王炯,等.中厚煤层复合顶板切顶卸压自动成巷工作面矿显现特征分析[J].岩石力学与工程学报,2018,37(11):2425-2434.
HE Manchao, MA Xingen, WANG Jiong, et al. Feature analysis of working face strata pressure with roof cutting pressure releasing in medium-thick seam and compound roof condition[J]. Chinese Journal of Rock Mechanics and Engineering, 2018, 37 (11): 2425-2434.

[2] 高瑞.远场坚硬岩层破断失稳的矿压作用机理及地面压裂控制研究[D].徐州:中国矿业大学,2018.
GAO Rui. The mechanism of ground pressure induced by the breakage of far-field hard strata and the control technology of ground fracturing[D]. Xuzhou: China University of Mining and Technology, 2018.

[3] 张朔滕.基于光纤传感的矿压在线监测系统在阳煤五矿的应用研究[D].徐州:中国矿业大学,2019.
ZHANG Shuoteng. Application of on-line monitoring system of mine pressure based on optical fiber sensing in Yangquan No. 5 Coal Mine [D]. Xuzhou: China University of Mining and Technology, 2019.

[4] 袁应吉,刘洪洋,吴文飞.光纤光栅传感技术在煤矿安全监测中的应用[J].科学技术创新,2019(36):159-160.
YUAN Yingji, LIU Hongyang, WU Wenfei. Application of fiber grating sensing technology in coal mine safety monitoring [J]. Scientific and Technological Innovation, 2019(36): 159-160.

[5] 杜文刚.基于光纤感测的采动覆岩变形演化特征试验研究[D].西安:西安科技大学,2020.
DU Wengang. Experimental study on deformation evolution characteristics of mining rock based on optical fiber sensing [D]. Xi'an: Xi'an University of Science and Technology, 2020.

[6] 王润沛. 基于机器学习的分布式光纤监测覆岩变形矿压预测研究[D]. 西安:西安科技大学,2020.

WANG Runpei. Study on the prediction of deformation and rock pressure of overburden monitored by distributed optical fiber based on machine learning [D]. Xi'an: Xi'an University of Science and Technology,2020.

[7] 巩师鑫,任怀伟,杜毅博,等. 基于MRDA-FLPEM集成算法的综采工作面矿压迁移预测[J]. 煤炭学报,2021,46(增刊1):529-538.

GONG Shixin, REN Huaiwei, DU Yibo, et al. Transfer prediction of underground pressure for fully mechanized mining face based on MRDA-FLPEM integrated algorithm [J]. Journal of China Coal Society,2021,46(S1):529-538.

[8] 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.

[9] 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 the prediction model for the coal working face roof pressure based on GA-BP neural networks [D]. Xuzhou: China University of Mining and Technology,2019.

[10] 李泽萌. 基于LSTM的采煤工作面矿压预测方法研究[D]. 西安:西安科技大学,2020.

LI Zemeng. Research on prediction method of mining pressure in coal face based on LSTM[D]. Xi'an:Xi'an University of Science and Technology,2020.

[11] 赵铭生,刘守强,纪润清,等. 基于遗传算法优化BP神经网络的华北型煤田矿压破坏带深度预测[J]. 矿业研究与开发,2020,40(6):89-93.

ZHAO Mingsheng, LIU Shouqiang, JI Runqing, et al. Depth prediction of mining pressure failure zone in North China coalfield based on BP neural network optimized by genetic algorithm[J]. Mining Research and Development,2020,40(6):89-93.

[12] LUO Junling, ZHANG Zhongliang, FU Yao, et al. Time series prediction of COVID-19 transmission in America using LSTM and XGBoost algorithms[J]. Results in Physics,2021,27(3):104462-104471.

[13] 袁强. 采动覆岩变形的分布式光纤检测与表征模拟试验研究[D]. 西安:西安科技大学,2017.

YUAN Qiang. Experimental study on distributed and representation of mining-induced overburden deformation with distributed optical fiber sensing [D]. Xi'an: Xi'an University of Science and Technology,2017.

[14] 柴敬,魏世明. 相似材料中光纤传感检测特性分析[J]. 中国矿业大学学报,2007,36(4):458-462.

CHAI Jing, WEI Shiming. Transmission character analysis of fiber optical sensing in similar material of simulation experiments[J]. Journal of China University of Mining & Technology,2007,36(4):458-462.

[15] 柴敬,霍晓斌,钱云云,等. 采场覆岩变形和来压判别的分布式光纤监测模型试验[J]. 煤炭学报,2018,43(增刊1):36-43.

CHAI Jing, HUO Xiaobin, QIAN Yunyun, et al. Model test for evaluating deformation and weighting of overlying strata by distributed optical fiber sensing [J]. Journal of China Coal Society, 2018, 43 (S1): 36-43.

[16] 朱磊. 基于光纤频移变化度的采动覆岩变形表征试验研究[D]. 西安:西安科技大学,2018.

ZHU Lei. Experimental research on overburden deformation characterized by fiber frequency shift variation degree[D]. Xi'an:Xi'an University of Science and Technology,2018.

[17] TAKENS F. On the numerical determination of the dimension of an attractor[J]. Dynamical Systems and Bifrucations,1985,898:99-106.