



您可能感兴趣的文章、专题：

“煤矿智能化综述及关键技术”专题

“我国煤矿瓦斯防治理论技术研究进展”专题

“煤地质与煤结构”专题

“煤矿安全+智能化”专题

“深部煤层瓦斯精准抽采”专题

“中国煤科首席科学家”专题

“矿井冲击地压灾害防治技术及工程实践”专题

2020 年度《煤炭科学技术》“领跑者 5000”论文

2021《煤炭科学技术》封面文章

煤炭行业青年科学家论坛(2021 年)

采矿科学与工程



移动扫码阅读

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. doi:10.13199/j.cnki.cst.2021.07.002

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. doi: 10.13199/j.cnki.cst.2021.07.002

基于 Prophet+LSTM 模型的煤矿井下工作面矿压预测研究

曾庆田^{1,2},吕珍珍²,石永奎³,田广宇²,林泽东²,李超¹

(1.山东科技大学 电子信息工程学院,山东 青岛 266590;2.山东科技大学 计算机科学与工程学院,山东 青岛 266590;

3.山东科技大学 能源与矿业工程学院,山东 青岛 266590)

摘要:为了高效地对工作面矿压变化趋势进行有效预测,减少顶板突发事故和引导煤矿井下安全生产,提出了融合相邻多个支架影响的矿压数据预测模型 Prophet+LSTM。该模型首先基于数字信号处理技术,将原始矿压数据经过算术平均值滤波和小波去噪方法减少噪声和随机误差;其次在深入分析 Prophet 模型和 LSTM 模型特性基础上,通过添加额外回归变量方法融合相邻多支架矿压数据;最后为充分利用 Prophet 模型和 LSTM 模型的优势,构建了一种 Prophet+LSTM 组合模型对工作面矿压进行预测,通过线性加权组合方法获取最有权重系数使模型预测结果误差逐步减少。以均方根误差(RMSE)和平均绝对误差(MAE)来评估 Prophet+LSTM 模型对矿压时间序列的预测效果。预测模型在某矿工作面支架矿压时序数据的应用结果表明:经过数字信号处理后的支架矿压预测结果 RMSE 和 MAE 分别下降了约 20% 和 16%,Prophet 模型和 LSTM 模型的预测结果优于传统的 BP 神经网络和 ARIMA 模型,且 Prophet+LSTM 模型预测方法较其单项模型具有更强的稳定性和更高的准确性,实现了对工作面在推进过程中矿压变化的有效预测。该预测方法对煤矿井下工作面矿压预测提供了研究思路。

关键词:矿压预测;时间序列预测;Prophet 模型;LSTM 神经网络

中图分类号:TP391;TD323

文献标志码:A

文章编号:0253-2336(2021)07-0016-08

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

ZENG Qingtian^{1,2}, LYU Zhenzhen², SHI Yongkui³, TIAN Guangyu², LIN Zedong¹, LI Chao¹

(1. College of Electronic Information Engineering, Shandong University of Science and Technology, Qingdao 266590, China; 2. College of Computer Science and Engineering, Shandong University of Science and Technology, Qingdao 266590, China; 3. College of Energy and Mining Engineering, Shandong University of Science and Technology, Qingdao 266590, China)

Abstract: This paper tries to effectively predict the change trend of mining pressure in the working face, thereby reducing roof accidents and guiding coal mine safety production, a mining pressure data prediction model Prophet+LSTM is proposed that integrates the influence of multiple adjacent supports. The model is first based on digital signal processing technology, the original mine pressure data is filtered through arithmetic mean filtering and wavelet denoising methods to reduce noise and random errors; secondly, based on the in-depth analysis of the characteristics of the Prophet model and the LSTM model, the method of adding additional regression variables is used to combine the rock pressure data affected by multiple adjacent supports; finally, in order to make full use of the advantages of the Prophet model and the LSTM model, a Prophet+LSTM combined model is constructed to predict the rock pressure of the working face, and the most weighted weight is obtained through the linear weighted combination method. The coefficients gradually reduce the error of the model's prediction results. The root mean square error(RMSE) and mean absolute error(MAE) are used to evaluate the prediction effect of the Proph-

收稿日期:2020-12-25;责任编辑:朱恩光

基金项目:山东省科技计划资助项目(重大关键技术)(2016ZDJS02A11);山东省高等学校工业物联网工程技术研发中心开放课题(KF2019003)

作者简介:曾庆田(1976—),男,山东高密人,教授,博士生导师,现任山东科技大学副校长。Tel:0532-86058076, E-mail:qtzeng@163.com

通讯作者:李超(1984—),男,河北唐山人,副教授,博士生导师,博士。Tel:0532-86057524, E-mail:lichao@sdust.edu.cn

et+LSTM model on the mine pressure time series. The results of the application of the prediction model on the time series data of the support rock pressure in a certain mine show that the RMSE and MAE values of the support rock pressure prediction results after digital signal processing have decreased by about 20% and 16%, respectively. The prediction results of the Prophet model and the LSTM model. It is better than the traditional BP neural network and ARIMA model, and the prediction method of the Prophet+LSTM model has stronger stability and higher accuracy than its single model, which can effectively predict the changes in the mine pressure during the advancing process of the working face. This prediction method provides a research idea for the prediction of underground pressure in coal mines.

Key words: underground pressure prediction; time series prediction; Prophet model; LSTM neural network

0 引言

煤矿生产过程中矿压异常导致的生产事故,直接影响到煤矿生产的经济性、安全性、可靠性以及工作人员的安全状况等^[1-3]。据统计,顶板事故占煤矿伤亡事故的 40%~50%,高频率顶板事故的发生给国家带来巨大的经济损失^[4-5]。随着物联网技术在煤矿开采过程中的深度应用,工作面物理环境数据得到了大量的积累,对这些数据进行深入分析与挖掘,以预测煤矿安全突发事故成为当前研究的重要方向之一^[6]。国内外在矿压显现规律预测领域已经有了相当深入的研究,工作面矿压数据预测预报方法可以分为 3 类:①基于统计学与模糊数学等非确定性数学方法;文献[7-8]分别应用统计分析法及模糊数学理论对工作面来压进行预测和矿压显现特征分析研究。②基于矿压理论确定顶板结构,并发掘其物理力学规律的确定性方法;文献[9]采用震动波 CT 探测技术进行了区域应力场反演,对冲击危险区域进行了预测。③基于大量监测数据,以利用计算机分析预测为目的的系统科学或智能技术方法。文献[10]利用支持向量机对小样本预测具有良好的泛化能力和自适应多模态算法的自适应特性,提出了煤矿顶板压力实时预报的智能模式识别方法。文献[11]基于支架工作阻力大数据的矿压分析技术能够对工作面矿压规律进行精准分析。文献[12]以神东哈拉沟煤矿 02212 综采工作面为工程背景,进行基于 PSO-BP 神经网络模型的矿压预测实践研究,得出该工作面的矿压显现规律并确定影响因素。文献[13]采用灰色关联度分析法分析各影响因素与矿压的关联度,建立基于 GA-BP 神经网络的工作面顶板矿压预测模型。文献[14]采用深度学习方法预测了红庆河大采高工作面矿山压力,预测结果表明 LSTM 方法较 BP 神经网络预测更具准确性。虽然工作面矿压预测取得了较好成绩,但单一模型预测结果误差仍较大。总体来看,上述研究基于机器学习方法在矿压预测中取得了较好成绩,但是采用传统机器学习与深度学习方法组合

和融合相邻多个支架的影响因素的研究较少。在实际应用中,时间序列预测问题通常包含线性和非线性成分,单一的预测方法不能很好地捕捉时间序列的复合特征。因此,通过深入分析时间序列数据特性,应用不同时间序列分析方法融合的组合模型进行预测分析是未来解决时间序列预测问题的趋势。目前,基于自回归移动平均模型(ARIMA)与支持向量回归模型和改进粒子群算法等方法与 BP 神经网络组合的预测及综合分析模型已经在采矿工程领域的预测工作中取得了较好的效果^[15-16]。从上述研究中发现组合模型可以更好地捕捉时间序列数据的复杂特征。作者以鄂尔多斯盆地呼和乌素矿某工作面支架矿压时序数据为例,采用算术平均值滤波和小波去噪方法进行数据预处理,分离出所期望的信息。考虑融合相邻多个支架影响因素,利用主流的机器学习算法提出一种基于 Prophet+LSTM 模型预测方法对工作面矿压变化趋势进行预测,为引导煤矿安全生产部门预判顶板危机和及时制定矿井调控政策提供理论数据支撑。

1 煤矿工作面矿压预测模型

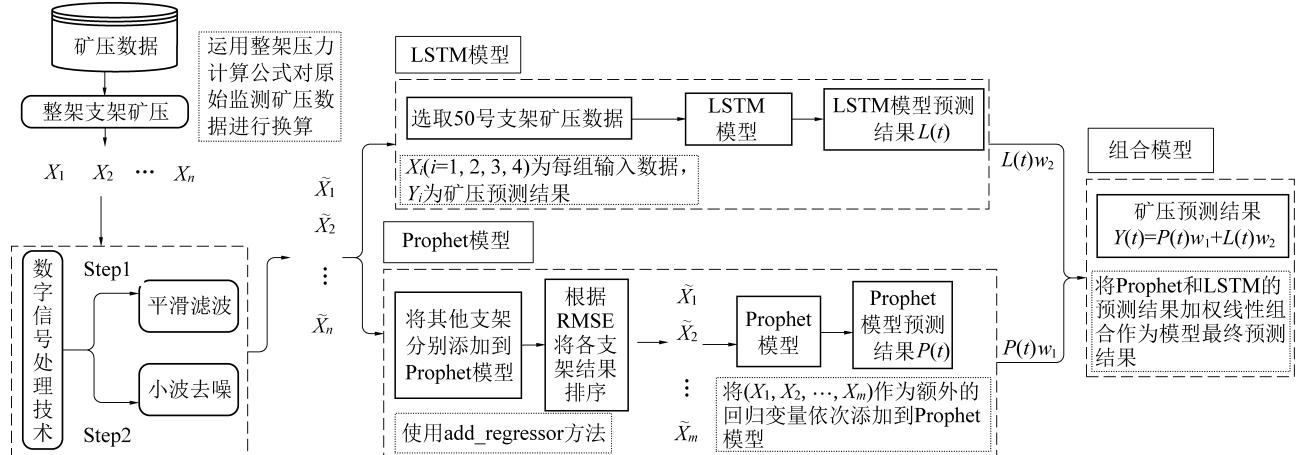
以工作面支架矿压显现规律为研究对象,结合数字信号处理技术,运用 Prophet 和 LSTM 深度学习方法分别对支架矿压时序数据进行预测,然后将 2 个单项模型预测结果线性加权叠加得到最终的 Prophet+LSTM 组合模型的预测结果。工作面矿压预测模型如图 1 所示,主要包括 3 个部分。

1) 矿压时间序列数据处理:首先从矿压原始数据表中获取支架矿压原始数据;然后运用数字信号处理技术对矿压原始数据进行滤波和消噪,得到数字信号处理后的矿压序列;最后根据各支架矿压的标准偏差选择矿压波动较小的支架。

2) 矿压预测单项模型:使用添加回归项方法将相邻多个支架矿压数据分别添加到 Prophet 模型中,然后拟合模型计算各自的 RMSE 值并将误差结果排序,将排序后的各支架矿压数据作为附加的回归变量依次添加到 Prophet 模型。使用数字信号处

理后的50号支架矿压数据训练LSTM神经网络模型,数据以 (X, Y) 形式表示。使2层LSTM神经网络,训练时每一组数据 $X = \{x_1, x_2, x_3, x_4\}$ 为4个, x_1, x_2, x_3, x_4 为时间顺序上连续4个时间段的矿压数据, Y 为4个时间段后预测矿压结果。

3) 基于Prophet+LSTM组合模型的矿压预测:



X_1, X_2, \dots, X_n —从矿压原始数据表中获取的原始矿压序列; $\tilde{X}_1, \tilde{X}_2, \dots, \tilde{X}_n$ —数字信号处理后的矿压序列; $\tilde{X}_1, \tilde{X}_2, \dots, \tilde{X}_m$ —相邻多个支架矿压时序数据

图1 煤矿工作面矿压预测模型

Fig.1 Prediction model of underground pressure in coal mining face

2 工作面矿压时间序列数据处理

由于煤矿物联网架构下的井下工作面传感器受到干扰比较多,测得的数据存在较大的噪声和随机误差,这对支架矿压预测提出了挑战。利用算术平均值滤波法来降低随机误差,采用小波去噪压缩信号,实现信号中噪声消除。

算术平均值滤波对抑制周期性干扰和随机干扰有良好效果。主要用于对压力、流量等周期脉动参数的采样值进行平滑加工,是数字滤波方法中最简单和最常用的一种,该方法是在某时刻对信号进行连续多次采样,对样本数据进行算术平均,作为该时刻的信号值。根据算术平均值滤波算法,按输入的 N 个工作面矿压时序数据,获取 y_t ,使其与各矿压采样值之间的偏差的平方和最小值 E ,即

$$E = \min \left[\sum_{i=1}^N (y_t - x_t)^2 \right] \quad (1)$$

$$y_t = \frac{1}{N} \sum_{i=1}^N x_t \quad (2)$$

其中: N 为样本数量; x_t 为时刻 t 的矿压采样值; y_t 为采样值的算术平均值。由式(2)可见,算数平均值滤波实质是将 N 个采样值相加求平均作为时刻 t 的值。

在对工作面支架矿压时序数据进行滤波后,采

对经过数字信号处理后的矿压时间序列数据,分别构建预测精度较高的融合相邻多个支架影响的Prophet和LSTM神经网络单项模型,通过调整Prophet和LSTM模型对应的权重线性加权叠加2个模型的预测结果,得到最终Prophet+LSTM组合模型的预测结果。

用小波阈值去噪方法压缩信号,提取出噪声信号中有用的支架矿压数据。小波去噪是通过短波实现噪音消除,将信号细节特征提取与低通滤波融合起来的去噪方法^[17]。近年来,小波去噪理论得到了非常迅速的发展,由于其具备良好的时频特性,因而实际应用非常广泛且获得了非常好的效果。小波去噪原理如图2所示。

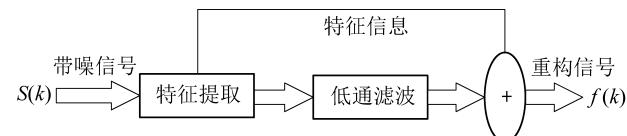


图2 小波去噪原理

Fig.2 Principle of wavelet denoising

$$S(k) = f(k) + \varepsilon e(k), k = 0, 1, \dots, n-1 \quad (3)$$

其中: $S(k)$ 为含噪声信号; k 为 n 个采样点; $f(k)$ 为有用信号; $e(k)$ 为噪声系数函数; ε 为噪声系数的标准偏差。根据式(3),提取出噪声信号中有用的支架矿压数据 $f(k)$ 。

经过数字信号处理之后的矿压数据的标准偏差对比结果,如图3所示。根据误差上下波动的幅度大小选取预测模型的训练数据,50号支架矿压的标准偏差最小,因此选取50号支架数据用于预测模型训练。

考虑到数字信号处理技术对结果的重要影响,对各支架矿压序列数据在应用数字信号处理前后进行了对比分析,如图4(2019年数据)所示。选取3

个支架查看数字信号处理后矿压的变化情况,可以明显看到数据趋势更加平滑,噪声减少明显。

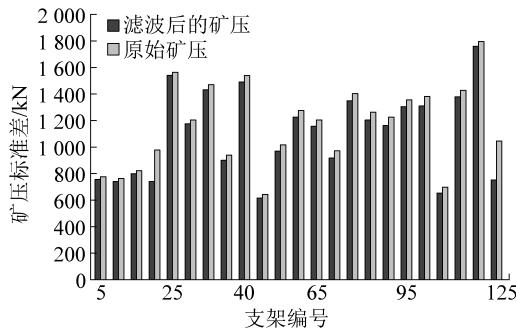


图 3 数字信号处理后各支架标准差对比

Fig.3 Comparison of standard deviation of each bracket after digital signal processing

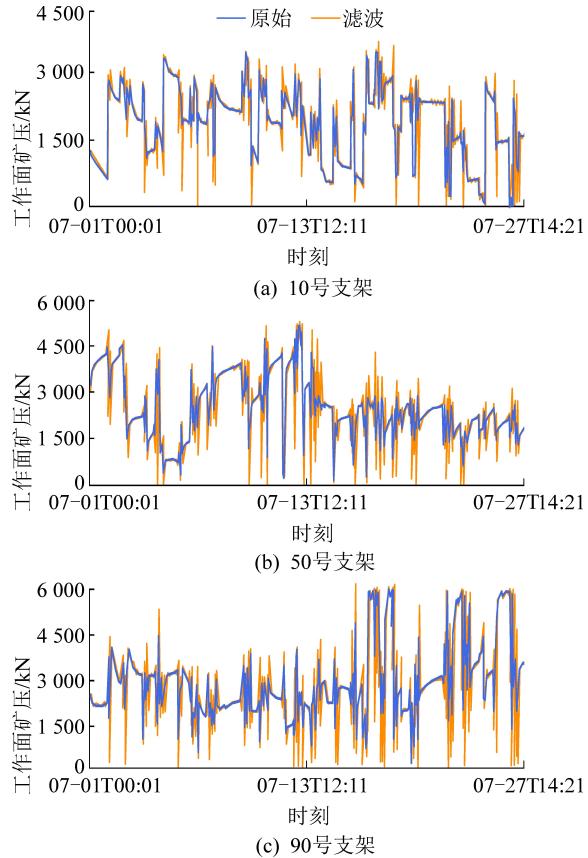


图 4 各支架数字信号处理效果对比

Fig.4 Comparison of digital signal processing effects of each bracket

3 基于 Prophet+LSTM 的矿压预测模型

为有效预测工作面矿压,考虑不同支架的影响因素。使用添加回归项方法将相邻多个支架的矿压时间序列数据作为额外的回归变量添加到 Prophet 模型,然后提出一种基于线性加权组合的 Prophet+LSTM 模型方法预测工作面支架矿压。

3.1 融合相邻多个支架影响因素的 Prophet 模型

Prophet 是 Facebook 开源的一套时间序列预测

模型工具^[18],已经在预测工作中得到了广泛应用并取得了较好效果^[19-20]。Prophet 在实质上采用广义加法模型来拟合和预测函数,将时间序列建模分为非线性趋势、周期性成分和节假日或特殊事件的总和,并允许融合额外的回归变量。Prophet 模型还擅长处理具有异常值和趋势变化的周期数据,而工作面矿压数据具有很强的突变性。因此,将具有成分分解能力的 Prophet 模型用于工作面支架矿压预测。Prophet 模型将时间序列按下式进行分解:

$$P(t) = g(t) + s(t) + h(t) + \varepsilon(t) \quad (4)$$

其中: $P(t)$ 为 Prophet 模型预测结果; $g(t)$ 为趋势项; $s(t)$ 为周期项; $h(t)$ 为节日项; $\varepsilon(t)$ 为误差项。Prophet 算法是通过拟合这几项,最后将其累加起来作为时间序列的预测值。其中, $g(t)$ 是整个模型的核心组件,包含不同程度的假设和调节光滑度的参数,用于拟合时间序列中的非周期性变化,从数据中选择变化点(changepoint)检测趋势走向。基本趋势项使用的是分段线性函数:

$$g(t) = [m + \alpha(t)\delta]t + [b + \alpha(t)^T\gamma] \quad (5)$$

式中: m 为增长率; $\alpha(t)$ 为指数函数; δ 为增长率的变化量; b 为偏移量; γ 为突变点边界。

将相邻多个支架矿压数据作为额外的回归变量使用 add_regressor 方法添加到趋势项 $g(t)$ 中,提高 Prophet 模型的预测效果。首先将相邻多个支架矿压时间序列数据分别添加到 Prophet 模型进行预测,然后根据各自的 RMSE 和 MAE 大小排序。排序结果代表支架矿压数据对 50 号支架矿压数据的影响程度。因此,可以将排序后的相邻多个支架矿压数据作为额外的回归变量依次添加到 Prophet 模型以提高预测精度。Prophet 的预测过程为:①构建数据格式,生成时间序列的时间戳和取值分别为 ds 和 y ,建立时间序列模型;②使用 add_regressor 方法添加额外的回归变量,拟合模型;③预测和评估模型,根据 RMSE 和 MAE 调整模型参数;④以可视化的方式反馈整个预测结果。

3.2 基于 Prophet+LSTM 的矿压预测组合模型

为了提高工作面矿压预测的准确度,且充分利用 Prophet 模型和 LSTM 神经网络模型的优势,提出一种基于线性加权的 Prophet+LSTM 组合模型用于工作面矿压预测。

首先对矿压时间序列数据构建预测精度较高的 Prophet 和 LSTM 神经网络单项模型,设定 Prophet 模型在 t 时刻的预测值为 $P(t)$,LSTM 神经网络模型的预测值为 $L(t)$, $t = 1, 2, \dots, n$,并设定 2 个模型的权重系数分别为 w_1 和 w_2 。则,Prophet+LSTM

线性加权叠加模型预测结果公式如下。

$$Y(t) = w_{1i}P(t) + w_{2i}L(t), w_{1i} + w_{2i} = 1 \quad (6)$$

$$i = 1, 2, \dots, N; t = 1, 2, \dots, n$$

其中:设定 N 为 11,由于 $w_{1i} + w_{2i} = 1$,设定权重系数 w_{1i} 为 $[1, 0]$ 递减的 11 个数值,则 w_{2i} 为 $[0, 1]$ 递增的 11 数值。首先将这 11 组权重系数 w_{1i} 和 w_{2i} 分别与 Prophet 和 LSTM 神经网络模型在 t 时刻下的矿压预测结果相乘,然后将相同时刻两个模型带有权重系数的预测结果相加,最终得到组合模型的预测结果。最优权重系数获取方法如图 5 所示。

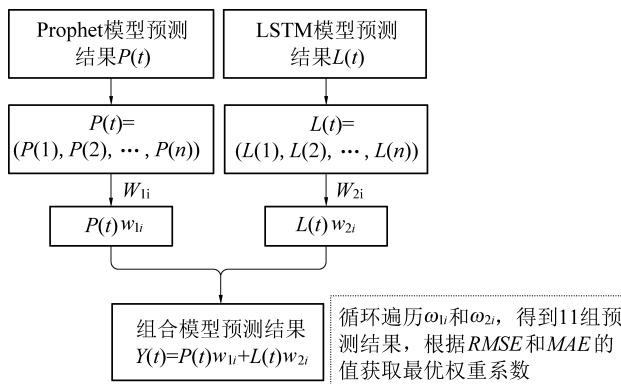


图 5 获取最优权重系数

Fig.5 Get optimal weight coefficient

4 试验结果分析

为有效评估上述方法预测工作面支架矿压的实际效果,首先构建预测精度较高的 Prophet 和 LSTM 神经网络单项模型,然后基于线性加权的 Prophet+LSTM 组合模型建模。最后,与 2 种经典的时间序列预测模型预测效果进行比较,验证所提出的方法具有更好的准确性和预测能力。

4.1 数据集介绍

将某矿工作面支架矿压时序数据经过数字信号处理后作为矿压预测的数据集,该数据集共 702 415 组数据,数据时间频率是每隔 5 min 记录 1 次,数据集示例见表 1。

表 1 原始数据集示例

Table 1 Example of original data set

时间	5号支架	50号支架	...	125号支架
	矿压/kN	矿压/kN	...	矿压/kN
2019-06-01T00:01:00	1 437.711	3 274.927	...	2 786.244
2019-06-01T00:11:00	1 444.069	3 370.176	...	2 954.168
⋮	⋮	⋮	⋮	⋮
2019-07-31T19:11:00	3 384.013	3 766.172	...	1 507.896

4.2 评估指标

选用均方根误差 (RMSE)、平均绝对误差 (MAE) 作为评估各组权重系数对应的 Prophet+LSTM 模型效果的标准,计算公式如下

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x - \tilde{x})^2} \quad (7)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x - \tilde{x}| \quad (8)$$

其中, $x = (x_1, x_2, \dots, x_N), x_i \in R^N$ 为 t 时刻工作面支架矿压真实值; $\tilde{x} = (\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_n), \tilde{x}_i \in R^n$ 为 t 时刻工作面支架矿压的预测值; n 为样本点个数。RMSE 和 MAE 的值越小说明模型预测能力越好。

4.3 融合滤波技术和相邻多个支架的影响因素的预测结果分析

为了有效地预测工作面矿压,考虑到不同滤波情况对预测模型的影响因素,设计 3 种不同的数据处理方法(表 2),通过试验对比 3 种数据处理方法对预测模型预测准确性的影响。方法 1,用于预测的 50 号支架和其他相邻多个支架矿压数据均使用原始矿压数据;方法 2,仅将用于预测的 50 号支架矿压数据进行数字信号处理方法处理,而其他相邻多个支架矿压数据使用原始矿压数据;方法 3,用于预测的 50 号支架和其他相邻多个支架矿压数据都进行数字信号处理方法处理。

表 2 3 种数据处理方法

Table 2 Three data processing methods

方法	用于预测的支架数据	其他相邻多个支架矿压数据
1	☆	☆
2	★	☆
3	★	★

注:★为对数据进行数字信号预处理;☆为原始数据,不做数字信号处理。

使用 RMSE 和 MAE 对各个方法进行比较,试验结果如图 6 所示。

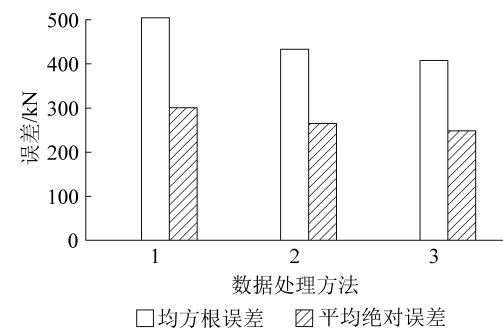


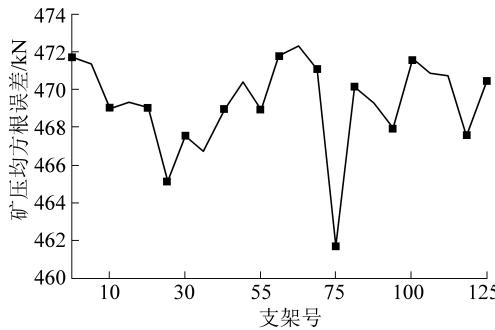
图 6 随着滤波情况变化的预测结果对比

Fig.6 Comparison of prediction results with changes in filtering conditions

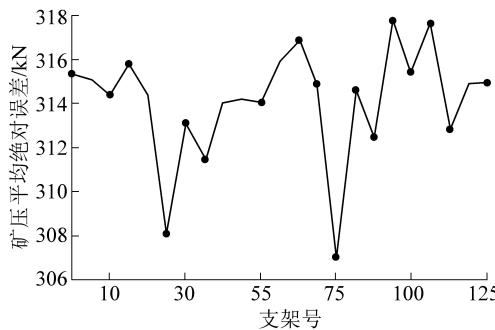
由图 6 知,方法 3 预测结果的 RMSE 和 MAE 最小。试验结果表明,经过数字信号处理之后的矿压时间序列数据在预测模型中具有更高的准确性。

将融合额外回归变量的 Prophet 模型预测结果

根据式(7)和式(8)与真实矿压数据进行比较,然后根据加入不同支架数后的误差值,验证所提出的融

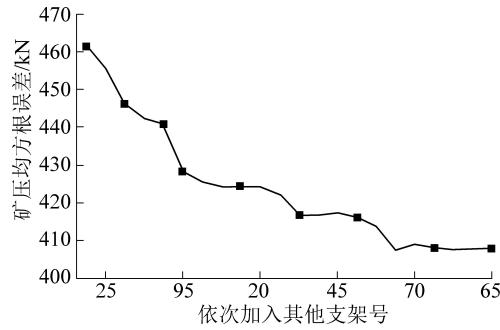


(a) 融合单个支架均方根误差

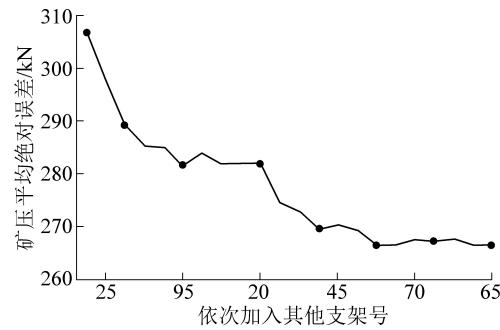


(c) 融合单个支架平均绝对误差

合相邻多个支架影响的 Prophet 模型的预测性能,结果如图 7 所示。



(b) 融合多个支架均方根误差



(d) 融合多个支架平均绝对误差

图 7 融合不同支架数量的误差对比

Fig.7 Error comparison of fusion of different stent numbers

图 7a 是将单个支架作为额外的回归变量添加到 Prophet 模型进行预测的 RMSE 和 MAE, 可以明显看到 25 和 75 号支架对 50 号支架的影响力度较大; 图 7b 是根据图 7a 中的结果排序后依次融合到 Prophet 模型的结果, 随着支架数量的增加, RMSE 和 MAE 逐渐减少, 当融合到 105 号支架时 RMSE 减少了 64.307 kN (13.6%), MAE 减少了 48.766 kN (15.5%), 之后误差基本不再变化。结果表明: 融合相邻多个支架矿压数据作为附加的回归变量添加到 Prophet 模型的线性部分, 可以提高 Prophet 模型的预测精度。

表 3 为不同训练集占比的试验结果, 根据表 3, 将融合相邻多个支架的矿压时间序列数据按 9:1 划分为训练集和测试集, 使用训练集训练模型, 测试集进行测试。图 8(2019 年数据)是 Prophet 模型的最终拟合效果及预测结果, 由图 8 可知, 只有少量数据不在置信区间内, 说明该区间内的支架矿压变化趋势与历史数据变化趋势的相关性较大。

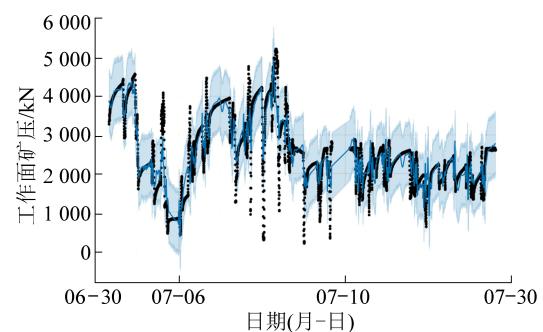
4.4 不同模型预测性能试验对比

表 4 是融合相邻多个支架影响的 Prophet + LSTM 组合模型不同权重系数的预测结果。在表 4 中, 当权重系数 $w_1 = 0.2, w_2 = 0.8$ 时, 预测结果 MAE 最小; 当权重系数 $w_1 = 0.3, w_2 = 0.7$ 时, 预测结果

表 3 不同训练集占比的试验结果

Table 3 Experimental results of different training set proportions

训练集 占比/%	矿压均方根 误差/kN	矿压平均绝 对误差/kN
50	510.232	342.661
60	426.101	288.966
70	410.453	277.374
80	409.680	271.266
90	407.708	266.560



·—实际值; ——预测值; ■—置信区间;
不存在黑色圆点的数据区间表示对矿压趋势的预测区间

图 8 Prophet 模型预测结果

Fig.8 Prophet model prediction results

RMSE 最小; 当权重系数 $w_1 = 0.2, w_2 = 0.8$ 时, RMSE 与 MAE 的和最小。结果显示, 相对于 Prophet 和

LSTM模型,Prophet+LSTM模型的预测效果明显提高,其预测效果总体上优于其单项预测模型。

表4 不同权重对应组合模型的RMSE和MAE

Table 4 RMSE and MAE values of combined model corresponding to different weights

权重系数		均方根	平均绝对	误差
w_1	w_2	误差/kN	误差/kN	和/kN
1.0	0	407.708	266.560	674.268
0.9	0.1	367.574	237.751	605.325
0.8	0.2	330.957	213.933	544.890
0.7	0.3	297.181	191.721	488.902
0.6	0.4	267.327	171.596	438.923
0.5	0.5	242.844	153.862	396.706
0.4	0.6	225.491	139.317	364.808
0.3	0.7	216.982	128.325	345.307
0.2	0.8	218.356	121.335	339.691
0.1	0.9	229.436	130.105	359.541
0	1.0	248.927	139.196	388.123

为进一步验证 Prophet+LSTM 组合模型的应用性能,选取 ARIMA 模型、BP 神经网络模型、Prophet 模型、LSTM、Prophet+LSTM 组合模型作为对比模型。对工作面支架矿压数据进行建模预测,各模型评估结果见表 5。表 5 得 Prophet+LSTM 组合预测模型、Prophet 和 LSTM 单项模型的预测性能明显优于 ARIMA 和 BP 神经网络经典时间序列模型。且 Prophet+LSTM 模型预测结果误差值最小,预测效果最佳,可作为一种有效的工作面矿压预测模型。

表5 不同模型的性能对比

Table 5 Performance comparison of different models

模型	均方根误差/kN	平均绝对误差/kN
ARIMA	574.446	459.077
BP	449.736	356.254
Prophet	407.708	266.560
LSTM	248.927	139.196
Prophet+LSTM ($w_1=0.2, w_2=0.8$)	218.356	121.335

5 结 论

1) 将算术平均值滤波和小波去噪方法运用到矿压预测模型中,设计 3 种不同的数据处理方法处理支架矿压数据。分析表明传感器测得的数据经过数字信号处理可以减少噪声和随机误差,提高了矿压预测模型精度。

2) 在 Prophet 模型中添加相邻多个支架矿压数

据可以提高其预测精度,对比未考虑融合相邻多个支架影响的预测结果, RMSE 和 MAE 误差分别减少约 14% 和 15%。将深度学习方法引入到矿压预测中,解决了传统浅层神经网络加深遇到的问题,对比 BP 神经网络模型预测结果, LSTM 模型 RMSE 和 MAE 误差值分别减少约 45% 和 61%,表明 LSTM 在捕捉时序特性上有更强的能力。

3) 将 Prophet+LSTM 组合模型的预测方法应用到工作面支架矿压预测中,解决了单项模型预测方法不能很好地捕捉时间序列的复合特征问题,提高了支架矿压预测模型的精度。对比 LSTM 模型预测结果, Prophet+LSTM 模型 RMSE 和 MAE 误差分别减少约 12% 和 13%,结果表明 Prophet+LSTM 组合模型的预测效果明显提高,预测效果总体上优于单项模型。

参考文献(References):

- [1] 齐庆新,李一哲,赵善坤,等.我国煤矿冲击地压发展 70 年:理论与技术体系的建立与思考[J].煤炭科学技术,2019,47(9):1-40.
QI Qingxin, LI Yizhe, ZHAO Shankun, et al. The development of rock burst in coal mines in my country for 70 years: the establishment and thinking of theory and technology system[J]. Coal Science and Technology, 2019, 47(9):1-40.
- [2] 牛超,施龙青,肖乐乐,等.2001-2013 年煤矿生产事故分类研究[J].煤矿安全,2015,46(3):208-211.
NIU Chao, SHI Longqing, XIAO Lele, et al. Study on the classification of coal mine production accidents from 2001 to 2013[J]. Safety in Coal Mines, 2015, 46(3):208-211.
- [3] 孙继平.煤矿安全生产理念研究[J].煤炭学报,2011,36(2):313-316.
SUN Jiping. Study on the concept of coal mine safety production [J]. Journal of China Coal Society, 2011, 36(2):313-316.
- [4] 王家臣,刘峰,王蕾.煤炭科学开采与开采科学[J].煤炭学报,2016,41(11):2651-2660.
WANG Jiachen, LIU Feng, WANG Lei. Coal mining and mining science[J]. Journal of China Coal Society, 2016, 41 (11): 2651-2660.
- [5] 钱鸣高,许家林,王家臣.再论煤炭的科学开采[J].煤炭学报,2018,43(1):1-13.
QIAN Minggao, XU Jialin, WANG Jiachen. Discussion on the scientific mining of coal again[J]. Journal of China Coal Society, 2018, 43(1):1-13.
- [6] 姜耀东,宋红华,马振乾,等.基于地应力反演的构造应力区沿空巷道窄煤柱宽度优化研究[J].煤炭学报,2018,43(2):319-326.
JIANG Yaodong, SONG Honghua, MA Zhenqian, et al. Research on optimization of narrow coal pillar width along goaf in tectonic stress zone based on in-situ stress inversion[J]. Journal of China Coal Society, 2018, 43(2):319-326.

[7] 庞军林. 基于统计分析法的工作面来压预测研究[J]. 煤矿开采, 2012, 17(4): 93-95.
PANG Junlin. Research on prediction of working face pressure based on statistical analysis method [J]. Coal Mining Technology, 2012, 17(4): 93-95.

[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): 1828-1835.
HUO Bingjie, JING Xuedong, YU Bin, et al. Research on classification prediction method of stope compressive strength of thick coal seam with hard roof [J]. Chinese Journal of Rock Mechanics and Engineering, 2019, 38(9): 1828-1835.

[9] 李静, 巩思园, 李慧, 等. 基于震动波 CT 探测技术的冲击危险预测[J]. 煤矿安全, 2016, 47(7): 69-72.
LI Jing, GONG Siyuan, LI Hui, et al. Shock hazard prediction based on seismic wave CT detection technology [J]. Safety in Coal Mines, 2016, 47(7): 69-72.

[10] 周宣赤, 白春华, 林大超, 等. 顶板压力预报机制研究[J]. 煤炭学报, 2011, 36(S2): 299-303.
ZHOU Xuanchi, BAI Chunhua, LIN Dachao, et al. Study on the roof pressure prediction mechanism [J]. Journal of China Coal Society, 2011, 36(S2): 299-303.

[11] 左凌云. 基于支架工作阻力大数据的工作面区域矿压分析研究[J]. 煤炭工程, 2019, 51(11): 60-64.
ZUO Lingyun. Analysis of mine pressure based on big data of support working resistance [J]. Coal Engineering, 2019, 51(11): 60-64.

[12] 杨硕. 基于 PSO-BP 神经网络的浅埋煤层工作面顶板矿压预测研究[D]. 西安: 西安科技大学, 2010.

[13] 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.

[14] 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. Analysis and model generalization of mine pressure prediction based on deep learning in large mining height face [J]. Journal of China Coal Society, 2020, 45(1): 54-65.

[15] 王菲, 杨雪, 李文生, 等. 基于信息熵-模糊神经网络的煤矿安全评价研究[J]. 煤矿安全, 2014, 45(3): 213-216.
WANG Fei, YANG Xue, LI Wensheng, et al. Research on coal mine safety evaluation based on information entropy-fuzzy neural network [J]. Safety in Coal Mines, 2014, 45(3): 213-216.

[16] 靳甜甜. 基于小波分析与 ARMA 组合模型的矿压显现预报研究[D]. 西安: 西安科技大学, 2015.

[17] 杨永杰, 王德超, 陈绍杰, 等. 基于离散小波分析的灰岩压缩破坏声发射预测研究[J]. 煤炭学报, 2010, 35(2): 213-217.
YANG Yongjie, WANG Dechao, CHEN Shaojie, et al. Acoustic emission prediction of limestone compression failure based on discrete wavelet analysis [J]. Journal of China Coal Society, 2010, 35(2): 213-217.

[18] TAYLOR S J, LETHAM B, et al. Forecasting at scale [J]. The American Statistician, 2018, 72(1): 37-45.

[19] 李丽萍, 段桂华, 王建新. 基于 Prophet 框架的银行网点备付金预测方法[J]. 中南大学学报(自然科学版), 2019, 50(1): 75-82.
LI Liping, DUAN Guihua, WANG Jianxin. Prediction method of bank branch reserve payment based on Prophet framework [J]. Journal of Central South University (Science and Technology), 2019, 50(1): 75-82.

[20] 葛娜, 孙连英, 石晓达, 等. Prophet-LSTM 组合模型的销售量预测研究[J]. 计算机科学, 2019, 46(S1): 446-451.
GE Na, SUN Lianying, SHI Xiaoda, et al. Study on sales forecast of Prophet-LSTM combination model [J]. Computer Science, 2019, 46(S1): 446-451.