

邓勤. 基于多元时间序列的煤矿粉尘浓度预测方法[J]. 矿业安全与环保,2024,51(6):35-41. DENG Qin. Coal mine dust concentration prediction method based on multivariate time series [J]. Mining Safety &

Environmental Protection, 2024, 51(6):35-41.

DOI: 10. 19835/j. issn. 1008–4495. 20240775

基于多元时间序列的煤矿粉尘浓度预测方法

邓 勤1,2

(1. 煤矿灾害防控全国重点实验室,重庆 400037; 2. 中煤科工集团重庆研究院有限公司,重庆 400037)

摘要:为了提高矿井粉尘浓度预测精度,针对煤矿粉尘浓度数据的时序特征,提出了一种基于多元 时间序列分析的煤矿粉尘浓度预测方法。采用变分模态分解(VMD)将粉尘浓度时序信号分解为趋 势、周期和随机波动3个维度;分别利用灰色模型(CM(1,1))、霍尔特-温特斯(Holt-Winters)三次指 数平滑法及自回归移动平均(ARMA(p,q))模型对各维度进行预测,并将预测结果进行融合生成最终 预测值。利用现有矿井监测数据对提出的粉尘浓度预测方法进行了验证。实验结果表明,基于多元时 间序列的煤矿粉尘浓度预测方法的平均绝对误差(MAE)为0.0094,均方误差(MSE)为0.0001,均方 根误差(RMSE)为0.0104,最大相对误差为0.48%。将基于多元时间序列的煤矿粉尘浓度预测方法 与经典单一或复合方法进行比较,其在 MSE、RMSE 及最大相对误差等关键指标方面均优于经典方法, 验证了该方法的有效性。

关键词:粉尘浓度预测;时序数据;变分模态分解;灰色模型;霍尔特-温特斯三次指数平滑法;自回 归移动平均模型

中图分类号:TD714

文献标志码:A 文章编号:1008-4495(2024)06-0035-07

Coal mine dust concentration prediction method based on multivariate time series

DENG $Qin^{1,2}$

(1. State Key Laboratory of Coal Mine Disaster Prevention and Control, Chongqing 400037, China;
 2. CCTEG Chongqing Research Institute, Chongqing 400037, China)

Abstract: To enhance the accuracy of dust concentration prediction in coal mines, a prediction method of coal mine dust concentration based on multivariate time series analysis was proposed according to the time series characteristics of coal mine dust concentration data. The method began by employing variational mode decomposition (VMD) to decompose the dust concentration time series signal into three components: trend, periodic, and random fluctuations. Subsequently, each component was predicted using different models: the grey prediction model (GM(1,1)), the Holt–Winters triple exponential smoothing method, and the autoregressive moving average (ARMA(p,q)) model. The prediction results from these models were then combined to produce the final forecast value. The proposed method of dust concentration prediction was verified by using the existing mine monitoring data. Experimental results indicate that the method based on multivariate time series achieves an average absolute error (MAE) of 0.009 4, a mean square error (MSE) of 0.000 1, a root mean square error (RMSE) of 0.010 4, and a maximum relative error of 0.48%. Compared with the classical single and fused method, the dust concentration prediction method based on multivariate time series is superior to the classical method in MSE, RMSE and maximum relative error, which verifies the effectiveness of the method.

收稿日期:2024-08-23;2024-09-25修订

基金项目:重庆市自然科学基金项目(CSTB2023NSCQ-MSX0736);国家重点研发计划项目(2023YFC2509305);中煤 科工集团重庆研究院自立重点专项项目(2023ZDZX01)

作者简介:邓 勤(1987—),女,重庆人,硕士,助理研究员,主要从事煤矿粉尘监测方面的研究工作。E-mail: shard1025@126.com。

Keywords: dust concentration prediction; time series data; variational mode decomposition; gray prediction model; Holt-Winters triple exponential smoothing method; autoregressive moving average model

随着工业化进程的加速推进,煤矿井下环境中 的粉尘浓度不断升高。矿井粉尘不仅会影响设备的 正常运行,还会对矿工的健康构成严重威胁^[1],甚至 可能引发爆炸等严重的安全事故^[2-7]。通过预测矿 井粉尘浓度,可以对潜在风险及安全隐患进行预判, 从而确保生产工作的顺利开展^[8]。因此,开发高效、 准确的粉尘浓度预测技术已成为矿业安全生产的一 项重要任务。

近年来,相关学者在粉尘浓度预测领域进行了 大量研究。基于各类优化方法的 BP 神经网络预测 模型虽提高了预测精确度,但其算法收敛速度慢且 对初值敏感,容易陷入局部最优^[9-10]:基于熵权法径 向基神经网络的预测方法虽然具有能够准确逼近任 意非线性函数且快速收敛的特性,但对神经网络结 构和参数过于敏感,不当的参数配置可能导致预测性 能显著下降^[11];外因输入非线性自回归模型(NARX) 通过整合时间序列与神经网络技术,在一定程度上 可避免传统预测模型因变量多和数据采集困难导致 的问题,提高了预测的精确度,然而其计算复杂度及 成本较高,实用性受到限制^[12];差分自回归移动平 均模型(ARIMA)通过差分方法实现粉尘浓度时序 数据的平稳化,虽有良好的预测效果,但模型建立过 程繁琐,参数的选择和诊断过程复杂^[13];基于机器 学习与深度学习的集成模型整合了多种算法的优 势,提高了整体预测性能,但其对计算资源和维护的 需求较高[14-15]。上述方法虽然各具优势,但普遍缺 乏对粉尘浓度时序数据的物理特性分析,导致模型 的可解释性和稳定性有所欠缺。

鉴于粉尘浓度与矿井作业状态密切相关,其变 化往往受到矿井通风系统运行状况、降尘及除尘措 施效果、设备运转情况、人员进出、班次交替,以及操 作中的偶发事件等多种因素的影响,这些因素会引 发粉尘浓度的趋势性、周期性或随机波动变化。因 此,笔者采用变分模态分解(VMD)方法,将粉尘浓 度时序信号分解为趋势、周期和随机波动3个维度; 对每个维度分别应用灰色模型(GM(1,1))、霍尔 特-温特斯(Holt-Winters)三次指数平滑法和自回归 移动平均(ARMA(*p*,*q*))模型进行独立预测;最后, 通过整合各分解维度的预测结果,构建出一个综合 的粉尘浓度预测方法,以增强预测的精确度和可 靠性。

1 模型理论基础

· 36 ·

1.1 变分模态分解(VMD)

VMD 是由 Konstantin Dragomiretskiy 与 Dominique Zosso 于 2014 年提出的一种多尺度频率 分解方法^[16],该方法利用迭代搜索和求解变分模型 最优解来将原始复杂信号f分解为k个具有特定中 心频率和有限带宽的本征模态信号(IMF),IMF 表 示如下:

$$u_k(t) = A_k(t) \cos(\varphi_k(t))$$
(1)

式中: $A_k(t)$ 为模态函数包络线; $\varphi_k(t)$ 为相位函数。

为保证分解序列为具有中心频率的有限带宽模态分量,同时各个模态估计带宽之和最小,约束条件为所有模态之和与原始信号相等,则 VMD 约束变分模型如下:

$$\min_{\substack{\|u_k\| \neq \omega_k\}}} \left\{ \sum_{k=1}^{3} \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) e^{-j\omega_k t} \right] \right\|_2^2 \right\},$$
s. t.
$$\sum_{k=1}^{3} u_k(t) = f(t)$$
(2)

为求解此约束最优化问题,可利用二次惩罚项 和拉格朗日乘子法优势,通过引入增广 Lagrangian 函数将其转化为非约束变分问题求解:

$$L(\left\{u_{k}\right\},\left\{\omega_{k}\right\},\lambda) = \alpha \sum_{k=1}^{3} \left\|\partial_{t}\left[\left(\delta(t)+\frac{j}{\pi t}\right)*u_{k}(t)\right]\right]$$
$$e^{-j\omega_{k}t}\left\|\int_{2}^{2} \left\|f(t)-\sum_{k=1}^{3}u(t)\right\|_{2}^{2} \left|\left\langle\lambda(t),f(t)-\sum_{k=1}^{3}u_{k}(t)\right\rangle\right|$$
(3)

式中:α为二次惩罚因子;λ为拉格朗日乘子。

利用交替方向乘子法(ADMM))即可求解该非 约束变分问题^[16]。

1.2 灰色模型(GM(1,1))

GM(1,1)模型,作为基于灰色系统理论的预测 工具,因其具有所需样本量小和建模过程简单的特 点,在经济、能源和环境领域的趋势预测中得到了广 泛应用^[17-18]。

设原始数据序列为 $X = [x(0), x(1), ..., x(n)], X^{(1)}$ 为 X 的累加序列, $z^{(1)}(t)$ 为 $X^{(1)}$ 的均值 生成序列, 定义如下:

$$z^{(1)}(t) = \frac{1}{2} [x^{(1)}(t) + x^{(1)}(t-1)], t = 1, 2, \cdots, n$$
(4)

利用 *z*⁽¹⁾(*k*) 与 *X*⁽¹⁾ 可构建 GM(1,1) 模型的微分方程:

$$x(t) + \theta z^{(1)}(t) = \chi, t = 1, 2, \dots, n$$
 (5)
式中: θ 为发展灰数; χ 为内生控制灰数。

构建参数矩阵向量B与向量P:

$$\boldsymbol{B} = \begin{bmatrix} -z^{(1)}(1) & 1 \\ -z^{(1)}(2) & 1 \\ \vdots & \vdots \\ -z^{(1)}(n) & 1 \end{bmatrix}$$
(6)
$$\boldsymbol{P} = \begin{bmatrix} x(1) \\ x(2) \\ \vdots \\ x(n) \end{bmatrix}$$
(7)

利用最小二乘法对 θ 与 χ 的值进行求解:

$$\left[\hat{\theta}, \hat{\chi}\right]^{\mathrm{T}} = (\boldsymbol{B}^{\mathrm{T}}\boldsymbol{B})^{-1}\boldsymbol{B}^{\mathrm{T}}\boldsymbol{P}^{\mathrm{T}}$$
(8)

预测数据序列为 $Y = [y(0), y(1), \dots, y(n)],$ $Y^{(1)}$ 为 Y 的累加序列,则所构建的 GM(1,1) 预测模 型公式如下:

$$y^{(1)}(t) = \left(x(0) - \frac{\chi}{\theta}\right) e^{-\theta(t-1)} + \frac{\chi}{\theta}$$
(9)

对 $y^{(1)}(t)$ 进行逆生还原可求得第 t 个时刻的预 测值 y(t):

 $y(t) = y^{(1)}(t) - y^{(1)}(t-1)$ (10)

1.3 Holt-Winters 三次指数平滑法

Holt-Winters 三次指数平滑法通常用于处理具有 季节性模式的数据。这种方法可以有效预测短期内的 未来值,尤其适用于具有趋势和季节性波动的数据。

设原始数据序列为 *X* = [*x*(0),*x*(1),…,*x*(*n*)], 预测数据序列为 *Y* = [*y*(0),*y*(1),…,*y*(*n*)],则 *t*+*m* 时刻的预测值 *y*(*t*+*m*)为:

$$y(t+m) = A(t) + mB(t) + S \{t+m-T[\text{floor}((m-1)/T)+1]\}$$
(11)

式中:*A*(*t*)为一次平滑值;*B*(*t*)为二次平滑值;*S*(*t*) 为三次平滑值;*T* 为变化周期。

A(t)、B(t)、S(t)的计算公式如下: $A(t) = \alpha [x(t) - S(t-T)] + (1-\alpha) [A(t-1) + \alpha]$

$$B(t-1)]$$
(12)
$$B(t) = B[A(t) - A(t-1)] + (1-B)B(t-1)$$
(13)

$$S(t) = \gamma [x(t) - A(t)] + (1 - \gamma)S(t - T)$$
(14)

式中 α , β , γ 为平滑系数,可利用 K 折交叉验证法以 RMSE 最小化准则求得。

1.4 自回归移动平均(ARMA)模型

ARMA 模型(自回归移动平均模型)是自回归模型(AR)与移动平均模型(MA)的结合,适用于具有平稳性特征的时间序列数据。该模型假定时间序列数据的未来值可以通过分析和利用其历史数据之间的相关性进行预测,从而达到较高的预测精度^[19]。预测过程如下:

同样设原始数据序列为 *X*=[*x*(0),*x*(1),…,*x*(*n*)], 预测数据序列为 *Y*=[*y*(0),*y*(1),…,*y*(*n*)],则建 立的预测模型公式如下:

$$x(t) = \mu + \sum_{i=1}^{p} a_i x(t-i) + \varepsilon(t) + \sum_{i=1}^{q} b_i \varepsilon(t-i)$$
(15)

式中: μ 为常数;p 为模型采用时序数据本身的滞后数,也称为AR项; a_i 为x(t)序列i 阶AR系数;x(t-i)为x(t)滞后i 阶序列; $\varepsilon(t)$ 为均值为0的独立同分布白噪声;q 为模型采用预测误差的滞后阶数,也称为 MA项; b_i 为序列 $\varepsilon(t)i$ 阶 MA 系数; $\varepsilon(t-i)$ 为 $\varepsilon(t)$ 滞后i 阶序列。

确定 $p \neq q$ 值是构建 ARMA 模型的关键步骤, 通常基于以下几个方面的依据^[20]:

1) 自相关函数(ACF) 与偏自相关函数(PACF) 分析: 通过绘制并观察时间序列的 ACF 和 PACF 图 的滞后特性, 可初步判断 *p* 和 *q* 的取值。

2)信息准则:常用的信息准则包括赤池信息准则(AIC)、贝叶斯信息准则(BIC)、汉南-奎因信息准则(HQIC),通常选择使信息准则值最小的 *p* 和 *q* 值作为模型阶数。

3)交叉验证:为了确保模型的泛化能力和预测 性能,可使用交叉验证方法将数据划分为训练集和 验证集,在不同的数据集上反复验证模型的准确性, 调整 *p* 和 *q* 以获得稳定、可靠的预测模型。

2 基于多元时间序列的煤矿粉尘浓度预测 方法

基于多元时间序列的煤矿粉尘浓度预测流程如 图 1 所示。





该方法首先采用 VMD 对原始粉尘浓度时序信 号进行维度分解,分别得到趋势维度、周期维度及随 机波动维度的多元粉尘浓度时序数据;然后,结合不 同维度粉尘数据特征与现有典型预测模型特征,选取 GM(1,1)模型对趋势维度进行预测、Holt-Winters 三 次指数平滑法对周期维度进行预测、ARMA(*p*,*q*)对 随机波动维度进行预测;最后,整合各维度预测值, 形成一个综合的粉尘浓度预测结果。

3 预测与分析

基于提出的多元时间序列煤矿粉尘浓度预测方法,选取实际煤矿工作面粉尘浓度测量数据进行分析。将粉尘浓度数据划分为训练集与预测验证集, 训练集用于预测方法的构建,预测验证集用于评估 Mining Safety & Environmental Protection

方法的有效性和可靠性。

3.1 数据准备与预测

3.1.1 数据准备

以2023年4月8日察哈素煤矿31321工作面粉 尘浓度监测数据为基础,选择8:00—12:00期间采 集的48组数据,其中前40组数据作为训练数据集, 后8组数据作为预测验证数据集。原始粉尘浓度时 序数据见表1。

	表1 原始粉尘浓度时序数据
Table 1	Original dust concentration time series data

时刻	粉尘质量浓度/(g·cm ⁻³)	时刻	粉尘质量浓度/(g·cm ⁻³)
8:00	3. 245	10:00	3. 214
8:05	3. 194	10:05	3. 191
8:10	3. 186	10:10	3. 174
8:15	3.180	10:15	3. 215
8:20	3. 182	10:20	3. 189
8:25	3. 199	10:25	3. 202
8:30	3.259	10:30	3.204
8:35	3. 185	10:35	3. 169
8:40	3. 171	10:40	3. 177
8:45	3. 201	10:45	3. 189
8:50	3.208	10:50	3. 208
8:55	3. 181	10:55	3. 181
9:00	3.253	11:00	3. 202
9:05	3. 182	11:05	3. 171
9:10	3.176	11:10	3. 195
9:15	3.215	11:15	3. 205
9:20	3.209	11:20	3. 184
9:25	3. 194	11:25	3. 198
9:30	3.227	11:30	3. 197
9:35	3. 198	11:35	3. 156
9:40	3. 187	11:40	3. 182
9:45	3. 221	11:45	3. 192
9:50	3. 196	11:50	3.200
9:55	3. 197	11:55	3. 191

原始粉尘浓度时序数据的时序图如图 2 所示。



3.1.2 预测过程与结果

提取前40组时序数据用于预测方法构建。首 先利用VMD对数据进行维度分解,分别得到3个维 度时序数据,如图3所示。



3.1.2.1 趋势维度预测

v

针对趋势维度信号,采用 GM(1,1) 对其进行预测。根据 1.2 节中介绍的理论基础,通过构建参数 矩阵 *B* 和向量 *P*,并结合最小二乘法,可求得发展灰数 $\theta = 1.015 8 \times 10^{-4}$,内生控制灰数 X = 3.2041,故预测模型为:

$$\gamma^{(1)}(t) = -3.154 \ 0 \times 10^{-4} e^{-1.015 \ 8 \times 10^{-4}(t-1)} +$$

$$3.1543 \times 10^4$$
 (16)

$$(t) = y^{(1)}(t) - y^{(1)}(t-1)$$
(17)

式中:y(t)为t时刻预测值; $y^{(1)}(t)$ 为预测值累加序 列值。

由模型可得趋势维度后 8 组数据预测值,具体数据见表 2。

表 2 趋势维度粉尘浓度预测数据 Table 2 predicted data in trend dimension

	<u> </u>
序号	预测粉尘质量浓度/(g·cm ⁻³)
1	3. 191 1
2	3. 190 8
3	3. 190 5

Mining Safety & Environmental Prote	ection
-------------------------------------	--------

表2(续)				
序号	预测粉尘质量浓度/(g·cm ⁻³)			
4	3. 190 2			
5	3. 189 8			
6	3. 189 5			
7	3. 189 2			
8	3. 188 9			

3.1.2.2 周期维度预测

采用累加形式的 Holt-Winters 三次指数平滑法 对周期维度信号进行预测。根据 1.3 节中介绍的理 论基础,以 RMSE 最小化为判断准则,利用 K 折交叉 验证法求得方法系数取值: $\alpha = 0.10$ 、 $\beta = 0.10$ 、 $\gamma = 0.22$,故预测公式如下:

$$y(t+m) = A(t) + mB(t) + S \{t+m-6[floor((m-1)/6)+1]\}$$
(18)
$$A(t) = 0.1[x(t) - S(t-6)] + 0.9[A(t-1) + B(t-1)]$$
(19)

$$B(t) = 0.1[A(t) - A(t-1)] + 0.9B(t-1)$$
(20)

S(t) = 0.22[x(t) - A(t)] + 0.78S(t-6)(21)

式中:*y*(*t*+*m*)为*t*+*m*时刻预测值;*x*(*t*)为原始数据 在*t*时刻取值。

周期维度后8组数据预测值见表3。

表 3 周期维度粉尘浓度预测数据 Table 3 Predicted data in periodic dimension

序号	预测粉尘质量浓度/(g·cm ⁻³)
1	0.012 5
2	0.007 5
3	-0.005 3
4	-0.012 0
5	-0.006 0
6	0.004 9
7	0.012 6
8	0

3.1.2.3 随机波动维度预测

针对随机波动维度信号,采用 ARMA(p,q)进行 预测。根据 1.4 节中介绍的理论基础可知, ARMA 模型建立的关键在于确定模型阶数 p,q 的取值。因 此,首先需要通过绘制时序数据的 PACF 和 ACF 分 析图,初步判断p,q 的取值范围;然后,利用 AIC 等信息 准则对模型进行定阶,从而确定最优的p,q 值。

随机波动维度时序数据 ACF 及 PACF 分析图如 图 4 所示。



图 4 随机波动维度时序数据 ACF 和 PACF 分析图 Fig. 4 ACF and PACF analysis of time series data for random fluctuations dimension

由图 4 可以看出, PACF 与 ACF 均在第 5 个取 值后呈现不显著非零状态, 故 p 取值范围为[1,5], q 取值范围为[1,5]。

在取值范围内遍历所有可能的 $p \setminus q$ 值组合,为 每个组合建立 ARMA 模型,并计算其对应的 AIC、 BIC 及 HQIC 值。将所有模型的 AIC、BIC 和 HQIC 值相加,得到一个总准则值,选择总准则值最小的模 型对应的 $p \setminus q$ 值作为最优阶数。计算可得到最优模 型阶数为 $p=4 \setminus q=3$,故预测模型为 ARMA(4,3)。

随机波动维度后8组数据预测值见表4。

	表 4 随机波切维度树生浓度顶测数据
Table 4	Predicted data in random fluctuations dimension

_		
	序号	预测粉尘质量浓度/(g·cm ⁻³)
	1	-0.006 7
	2	0.003 8
	3	0.005 7
	4	-0.007 0
	5	0.003 2
	6	0.010 4
	7	-0.002 6
	8	-0.008 5

3.1.2.4 预测结果

将3个维度的预测结果进行整合,得到基于多

元时间序列的综合粉尘预测结果。将最终预测结果 与预测验证数据集中8组实测粉尘浓度数据进行比 较,数据对比见表5,对比图如图5所示。

表 5 综合预测值与实测值对比 Table 5 Comparison of comprehensive predicted values and measured values

序号	实测粉尘质量浓度/(g·cm ⁻³)	预测粉尘质量浓度/(g·cm ⁻³)
1	3. 18	3. 20
2	3. 20	3. 20
3	3. 20	3. 19
4	3.16	3. 17
5	3. 18	3. 19
6	3. 19	3.20
7	3.20	3.20
8	3. 19	3. 18



values and measured values

3.2 结果分析与方法评价

为确定预测方法的有效性与泛化能力,将预测 结果与预测验证集中的 8 组实测数据进行对比分 析。采用的评价指标包括平均绝对误差(MAE)、均 方误差(MSE)、均方根误差(RMSE)及最大相对误 差,这些指标分别从不同维度准确衡量了模型的预 测性能及误差特征,各项评价指标值见表 6。

表 6 预测方法在预测数据集上的误差值 Table 6 Error values of proposed prediction method on the prediction dataset

误差类型	误差值
平均绝对误差 (MAE) /(g·cm ⁻³)	0.009 4
均方误差 (MSE) /(g·cm ⁻³)	0.000 1
均方根误差 (RMSE) /(g·cm ⁻³)	0.0104
最大相对误差/%	0. 48

由表 6 可以看出,该方法在预测数据集上具有 · 40 ·

较好的表现,显示出较高的预测精度和稳定性。低 MAE、MSE、RMSE 和极小的最大相对误差表明模型 在整体上能够准确预测,并在处理新数据时具有较 强的泛化能力和鲁棒性,适用于实际应用。

为全面评估提出的多元时间序列预测方法的有效性及泛化能力,将其与经典时序预测模型(GM(1,1)和ARIMA(*p*,*n*,*q*))、经典机器学习预测方法(XGBoost)及复合预测方法(小波分解-神经网络)进行比较。5种不同预测方法所得结果与原始数据对比如图 6 所示。



同样采用 MAE、MSE、RMSE 和最大相对误差对预测方法进行评价分析,5种方法各类误差值见表7。

表 7 不同预测方法在预测数据集上的误差值 Table 7 Error values of different prediction methods on the prediction dataset

	各预测方法误差值				
误差类型	基于多元 时间序列的 预测方法	GM (1,1)	ARIMA (2,1,2)	XGBoost	小波分 解-神 经网络
平均绝对误 差(MAE)/	0.009 4	0.009 3	0.009 1	0. 010 9	0. 020 0
(g·cm) 均方误差 (MSE)/ (g·cm ⁻³)	0.000 1	0.000 2	0.000 2	0.000 2	0. 000 8
均方根误差 (RMSE)/ (g·cm ⁻³)	0.010 4	0.014 3	0.015 0	0.015 0	0. 029 0
最大相对 误差/%	0. 48	1.16	1.10	1.10	1.96

通过对各项误差指标进行综合比较,发现提出的基于多元时间序列的预测方法表现出较小的误差,特别是在均方误差(MSE)、均方根误差(RMSE)

和最大相对误差方面均优于其他方法,这可能是因 为该方法能够从趋势、周期和随机波动3个维度更 全面、准确地捕捉到粉尘浓度的变化特征;相比之 下,GM(1,1)和 ARIMA(p,n,q)模型的误差指标相 对接近,但略逊于多元时间序列方法,这可能是因为 这2种模型能够识别时间序列中的某些规律性,但 在处理数据波动性方面存在一定的局限性;XGBoost 和小波分解-神经网络模型的误差值相对较高,这可 能是由于这2种模型在特征选择和数据预处理过程 中未充分考虑粉尘浓度变化的时间序列特征,导致 在捕捉趋势性或周期性变化时出现偏差。此外,小 波分解-神经网络模型由于复杂度较高,可能存在过 拟合风险。

分析结果表明,基于多元时间序列的预测方法 在捕捉和拟合数据集的变化方面表现更为出色,能 够更准确地反映粉尘浓度的实际波动情况。

4 结束语

第51卷 第6期

2024年12月

1)针对煤矿井下粉尘浓度时序变化特征,提出 了基于多元时间序列的粉尘浓度预测方法。该方法 首先通过 VMD 将粉尘浓度信号分解为趋势、周期和 随机波动 3 个部分;然后,采用 GM(1,1)、Holt-Winters 三次指数平滑法和 ARMA(*p*,*q*)模型分别对 不同维度信号进行有针对性的预测;最后,将各分解 维度的预测结果整合在一起,形成了综合粉尘浓度 预测结果。

2)以矿井实际粉尘浓度监测数据为背景,将实 际测量数据划分为训练集与预测验证集,利用训练 集建立综合预测方法,利用预测验证集对预测方法 进行性能及泛化能力检验,结果表明,预测结果具有 较好的可靠性和准确度。

3)提出的预测方法仅依赖于粉尘浓度的历史时 序数据,能够适应不同类型的矿井尘源,同时也可对 呼吸性粉尘进行有效预测。通过预测矿井环境中粉 尘浓度动态变化情况,可帮助矿山管理者合理调整 通风系统参数,优化部署喷雾除尘措施,从而提高粉 尘防治效率,降低粉尘对工人健康和设备运转的危害。

4) 提出的预测方法在预测过程中未能充分考虑 井下环境参数(如温度、湿度、通风条件等) 对粉尘浓 度变化的影响,后续研究将集成多源数据和环境变 量,构建更为精确和稳健的粉尘浓度预测模型,以提 高预测方法在长期预测粉尘浓度中的有效性。

参考文献(References):

[1] 毛翎,彭莉君,王焕强. 尘肺病治疗中国专家共识(2018 年版)[J]. 环

境与职业医学,2018,35(8):677-689.

MAO Ling, PENG Lijun, WANG Huanqiang. Consensus of Chinese experts on pneumoconiosis treatment (2018) [J]. Journal of Environmental and Occupational Medicine, 2018, 35(8): 677-689.

- [2] 李德文,赵政,郭胜均,等."十三五"煤矿粉尘职业危害防治技术及发展方向[J].矿业安全与环保,2022,49(4):51-58.
 LI Dewen, ZHAO Zheng, GUO Shengjun, et al. "13th Five Year Plan" coal mine dust occupational hazard prevention and control technology and development direction [J]. Mining Safety & Environmental Protection, 2022, 49(4):51-58.
- [3] 苗彦平,桂长庚,郑旭鹤,等.大采高综采面粉尘分布规律及防治 技术研究[J].煤炭技术,2023,42(1):124-128.
 MIAO Yanping,GUI Changgeng,ZHENG Xuhe, et al. Study on dust distribution characteristics and its pollution prevention of coal workface with large mining height[J]. Coal Technology, 2023, 42(1): 124-128.
- [4] 张晓蕾,邓斌,杨松立,等. 粉尘爆炸事故的模糊综合评估分析与预防 策略研究[J]. 中国安全生产科学技术,2024,20(3):83-89.
 ZHANG Xiaolei, DENG Bin, YANG Songli, et al. Study on fuzzy comprehensive evaluation analysis and prevention strategies of dust explosion incidents[J]. Journal of Safety Science and Technology, 2024,20(3):83-89.
- [5] 李刚,周哲,胡锦华.基于知识图谱的我国矿井粉尘防治技术研究进展与展望[J].金属矿山,2023(7):28-39.
 LI Gang, ZHOU Zhe, HU Jinhua. Study progress and prospect analysis of mine dust control technology based on knowledge graph in China[J]. Metal Mine,2023(7):28-39.
- [6] 周福宝,袁亮,程卫民,等. 矿井粉尘职业健康防护技术 2013—2023 年研究进展[J]. 中国安全生产科学技术,2023,19(12):5-15.
 ZHOU Fubao, YUAN Liang, CHENG Weimin, et al. Research progress on occupational health protection technology of mine dust from 2013 to 2023[J]. Journal of Safety Science and Technology, 2023,19(12):5-15.
- [7] 李刚,李胜,张伟军,等. 我国金属矿山采—装—运过程中粉尘职业危害防控技术进展与展望[J]. 金属矿山,2024(5):41-54.
 LI Gang,LI Sheng,ZHANG Weijun, et al. Advancements and future prospects of dust control technology for occupational hazards in metal mining, loading and transportation in China[J]. Metal Mine, 2024(5): 41-54.
- [8] 王杰,郑林江.煤矿粉尘职业危害监测技术及其发展趋势[J].煤炭科学技术,2017,45(11):119-125.
 WANG Jie,ZHENG Linjiang. Development tendency and monitoring technology of dust occupational hazard in coal mine[J]. Coal Science and Technology,2017,45(11):119-125.
 [0] 水庄三 卫票 整式整体比价化 pp 抽搐网络协约小油麻莱测[L] 测
- [9] 赵广元,马霏. 粒子群算法优化 BP 神经网络的粉尘浓度预测[J]. 测 控技术,2018,37(6):20-23. ZHAO Guangyuan, MA Fei. Prediction of dust concentration based on particle swarm optimization BP neural network[J]. Measurement & Control Technology,2018,37(6):20-23.
- [10] 徐景果,张宇轩,王飞,等. 基于猎人猎物优化算法的粉尘浓度 BP 神经网络预测模型[J].陕西煤炭,2024,43(8):52-56.
 XU Jingguo,ZHANG Yuxuan,WANG Fei, et al. BP neural network prediction model of dust concentration based on Hunter - Prey optimization algorithm[J]. Shaanxi Coal,2024,43(8):52-56.
- [11] 李德根,刘晓亮,宋胜伟,等. 熵权法径向基神经网络的截割粉 尘浓度模型与预测[J]. 煤炭技术,2018,37(6):177-179.
 LI Degen, LIU Xiaoliang, SONG Shengwei, et al. Prediction and model of cutting dust concentration of radial basis neural network with entropy weight[J]. Coal Technology,2018,37(6):177-179.
 (下转第 53 页)

alucia in accident increasing [1] Fact 2022

material evidence analysis in accident investigation [J]. Fuel, 2022, 315:123209.

- [84] QI Y Q,GAN X Y,LI Z,et al. Variation and prediction methods of the explosion characteristic parameters of coal dust/gas mixtures [J]. Energies, 2021, 14(2):264.
- [85] AJRASH M J, ZANGANEH J, MOGHTADERI B. Methane coal dust hybrid fuel explosion properties in a large scale cylindrical explosion chamber [J]. Journal of Loss Prevention in the Process Industries, 2016, 40:317-328.
- [86] GUO C W, SHAO H, JIANG S G, et al. Effect of low-concentration coal dust on gas explosion propagation law[J]. Powder Technology, 2020,367:243-252.
- [87] SONG S X, CHENG Y F, MENG X R, et al. Hybrid CH₄/coal dust explosions in a 20 - L spherical vessel [J]. Process Safety and Environmental Protection, 2019, 122:281–287.
- [89] AMYOTTE P R, MINTZ K J, PEGG M J, et al. The ignitability of coal dust-air and methane-coal dust-air mixtures [J]. Fuel, 1993, 72(5):671-679.
- [90] MA D, QIN B T, GAO Y, et al. Study on the explosion characteristics of methane-air with coal dust originating from lowtemperature oxidation of coal [J]. Fuel, 2020, 260; 116304.
- [91] 景国勋,邵泓源,吴昱楼,等. 不同煤种对瓦斯煤尘爆炸影响的 实验研究[J].煤矿安全,2020,51(5):1-5. JING Guoxun, SHAO Hongyuan, WU Yulou, et al. Experimental study on the influence of different coal species on gas and coal dust explosion[J]. Safety in Coal Mines,2020,51(5):1-5.

- $\label{eq:generalized} \begin{array}{l} \mbox{[92] ZHANG L, WANG H Y, CHEN C, et al. Experimental study to} \\ \mbox{assess the explosion hazard of CH_4/coal dust mixtures induced by} \\ \mbox{high temperature source surface [J]. Process Safety and} \\ \mbox{Environmental Protection, 2021, 154:60-71.} \end{array}$
- [93] LI Y,XU H L, WANG X S. Experimental study on the influence of initial pressure on explosion of methane-coal dust mixtures [J]. Procedia Engineering, 2013, 62:980-984.
- [94] KUNDU S K, ZANGANEH J, ESCHEBACH D, et al. Explosion severity of methane-coal dust hybrid mixtures in a ducted spherical vessel[J]. Powder Technology, 2018, 323:95-102.
- [95] 王晓彬. 点火延迟时间对甲烷煤尘爆炸特性的影响[J]. 煤矿安全,2020,51(3):23-27.
 WANG Xiaobin. Effect of Ignition delay time on explosion characteristics of methane and coal dust hybrid mixtures[J]. Safety in Coal Mines,2020,51(3):23-27.
- [96] NIU Y H,ZHANG L L, SHI B M, et al. Methane-coal dust mixed explosion in transversal pipe networks[J]. Combustion Science and Technology, 2021, 193(10):1734-1746.
- [97] DONG C J, BI M S, ZHOU Y H. Effects of obstacles and deposited coal dust on characteristics of premixed methane-air explosions in a long closed pipe[J]. Safety Science, 2012, 50(9):1786-1791.
- [98] ZHANG J L, LI C, LI G, et al. Effect of large particle mixing on cloud ignition and explosion of fine rice husk [J]. Process Safety and Environmental Protection, 2024, 191:304-314.
- [99] JIANG H P, BI M S, HUANG L, et al. Suppression mechanism of ultrafine water mist containing phosphorus compounds in methane/ coal dust explosions[J]. Energy, 2022, 239:121987.

(责任编辑:林桂玲)

(上接第41页)

 [12] 周旭,王艺博,朱毅,等.基于非线性自回归模型的矿井粉尘浓度预测[J].华北理工大学学报(自然科学版),2021,43(4): 127-133.

ZHOU Xu, WANG Yibo, ZHU Yi, et al. Mine dust concentration prediction based on nonlinear autoregressive model [J]. Journal of North China University of Science and Technology (Natural Science Edition), 2021, 43(4): 127-133.

- [13] 王月红,高萌,赵帅博.矿井粉尘浓度预测模型的建立及应用研究[J].中国矿业,2021,30(1):178-181.
 WANG Yuehong, GAO Meng, ZHAO Shuaibo. Establishment and application of mine dust concentration prediction model[J]. China Mining Magazine,2021,30(1):178-181.
- [14] 王和堂,谭江龙,杨天龙,等. 基于集成学习的综掘面粉尘浓度 预测模型[J/OL]. 金属矿山. https://link. cnki. net/urlid/ 34.1055. TD. 20230815.1444.002.
 WANG Hetang, TAN Jianglong, YANG Tianlong, et al. Excavation

WANG Hetang, TAN Jiangtong, TANG Tiantong, et al. Excavation face dust concentration prediction model based on Ensemble Learning [J/OL]. Metal Mine. https://link. cnki. net/urlid/ 34. 1055. TD. 20230815. 1444. 002.

[15] 王布川.基于神经网络的煤巷综掘工作面粉尘浓度预测研究[J].
 矿业研究与开发,2017,37(6):22-25.
 WANG Buchuan. Research on dust concentration forecast of fully

mechanized driving face in coal roadway based on neural network[J]. Mining Research and Development,2017,37(6):22-25.

- [16] DRAGOMIRETSKIY K,ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing,2014,62(3):531-544.
- [17] 刘思峰,党耀国,方志耕,等.灰色系统理论及其应用[M].5版. 北京:科学出版社,2010.
- [18] 陈日辉. 矿井粉尘浓度的灰色预测法[J]. 工业安全与防尘,
 2000,26(12):5-7.
 CHEN Pitch Communication of and any and the provided in [1].

CHEN Rihui. Grey prediction of underground dust concentration [J]. Industrial Safety and Environmental Protection,2000,26(12):5-7.

- [19] 韩敏,许美玲. 一种基于误差补偿的多元混沌时间序列混合预 测模型[J]. 物理学报,2013,62(12):120510.
 HAN Min, XU Meiling. A hybrid prediction model of multivariate chaotic time series based on error correction [J]. Acta Physica Sinica,2013,62(12):120510.
- [20]汤筠筠,郭忠印.基于自回归求和移动平均的冬季路温短临预测[J].同济大学学报(自然科学版),2017,45(12):1824-1829.
 - TANG Junjun, GUO Zhongyin. Pavement temperature short impending prediction based on ARIMA in winter [J]. Journal of Tongji University (Natural Science), 2017, 45(12):1824-1829. (责任编辑:樊淑兰)