

基于卡尔曼滤波、分形和 LSTM 的大坝变形趋势分析方法

邓思源¹, 周兰庭¹, 柳志坤^{2,3}

(1. 河海大学水利水电学院, 江苏 南京 210098;
2. 青岛市发展和改革委员会动能转换推进处, 山东 青岛 266000; 3. 青岛市经济发展研究院, 山东 青岛 266000)

摘要: 为了实现对大坝变形趋势的合理分析, 提出了一种融合卡尔曼滤波、分形理论和长短时记忆神经网络(LSTM)的大坝变形趋势综合分析方法。该方法利用卡尔曼滤波对原始观测数据进行降噪处理, 采用分形理论中的 R/S 方法对大坝未来变形趋势进行定性判断和解析, 通过对滤波后数据建立 LSTM 定量预测模型, 结合定性和定量的分析结果, 实现大坝变形趋势的综合评判。实例分析结果表明, 该方法能够较好地分析大坝变形趋势, 对大坝监测数据的随机性和非平稳性具有较好的适用性, 趋势分析和预测符合工程实际情况, 为大坝的变形综合分析提供了一种新方法。

关键词: 大坝; 卡尔曼滤波; 分形; LSTM 模型; 变形预测; 趋势判断

中图分类号: TV698 **文献标志码:** A **文章编号:** 1006-7647(2022)05-0121-06

Analysis method of dam deformation trend based on Kalman filter, fractal and LSTM//DENG Siyuan¹, ZHOU Lanting¹, LIU Zhikun^{2,3} (1. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China; 2. Kinetic Energy Conversion Promotion Office, Qingdao Development and Reform Commission, Qingdao 266000, China; 3. Qingdao Economic Development Research Institute, Qingdao 266000, China)

Abstract: In order to realize reasonable analysis of dam deformation trend, a comprehensive analysis method integrated with Kalman filter, fractal and long short-term memory neural network (LSTM) was proposed. In the method, Kalman filter was used to denoise the original observation data, the R/S method of fractal was used to qualitatively judge and analyze the future deformation trend of the dam, and a LSTM quantitative prediction model was established for the filtered data. Combining with the qualitative and quantitative analysis results, comprehensive evaluation of dam deformation trend was realized. The example analysis results show that the proposed method can analyze the dam deformation trend well, and has good applicability to the randomness and nonstationary of dam monitoring data. The trend analysis and prediction are in line with the actual situation of the project, which provides a new method for the comprehensive analysis of dam deformation.

Key words: dam; Kalman filter; fractal; LSTM model; deformation prediction; trend judgment

随着水利资源的深入开发, 坝址的地质条件越来越复杂, 大坝的规模也向高、大方向发展^[1,2]。为了保障大坝运行的安全性, 高效可靠的大坝变形监测及趋势预报变得愈发重要。然而, 在大坝变形监测过程中, 变形监测数据易受噪声污染, 增加了监测过程及趋势分析的难度, 同时, 大坝变形呈现显著的非线性特征, 给预报的准确性带来考验, 使得大坝变形趋势更加难以预估。

针对上述问题, 许多学者进行了探讨和研究, 构

建出一系列较为可靠、适用的大坝变形趋势分析预测模型或理论。如李子阳等^[3]综合考虑去噪与时变功能, 基于 Kalman 滤波方程组, 结合统计模型和 ARMA 等方法, 提出了一种能反映大坝性态变化和变形发展趋势的时变 Kalman 预测模型; 刘亮亮等^[4]针对混凝土坝变形呈现显著的非线性特征, 引入分形插值理论, 提出了一种可行有效的混凝土坝趋势分析方法; 郝永河等^[5]基于变形信息分解, 将 R/S 分析法同优化极限学习机及混沌理论结合, 融

基金项目: 国家自然科学基金(51209078, 51739003)

作者简介: 邓思源(1997—), 男, 硕士研究生, 主要从事大坝安全监控研究。E-mail: 625019563@qq.com

通信作者: 周兰庭(1975—), 女, 副教授, 博士, 主要从事大坝安全监控和水利水电建设管理研究。E-mail: ltzhou@hhu.edu.cn

合定性分析和定量预测结果,实现了较为可靠的大坝变形趋势预报;牛景太^[6]提出了基于奇异谱分析与粒子群算法优化支持向量机的混凝土坝变形监控模型。这些模型虽均具有一定的有效性和适用性,却囿于对大坝变形趋势某单一方面的分析研究,缺乏对该类问题多方面的综合考虑,故而在未充分考虑干扰和噪声、未充分挖掘变形监测数据的时间依赖性、模型参数难以确定、构建数学模型过程复杂、长期预报能力不足等问题,导致模型存在一定的局限性。因此,亟待从多方面着手,引入先进的理论方法,并充分融合各自优势,进而提升大坝变形趋势分析的综合性 and 可靠性。

鉴于此,考虑到卡尔曼滤波^[7-8]在削减干扰和噪声方面的优势、分形理论^[9-10]在解析判断呈现较强非线性和时间相关性特征的数据方面的适用性以及长短时记忆神经(long short-term memory neural network, LSTM)模型^[11-12]在分析处理具有典型动态特性的时间序列时优秀的应用表现,本文将三者进行优势融合,提出了一种基于卡尔曼滤波、分形和 LSTM 模型的大坝变形趋势综合分析方法,可实现从定性和定量的层面对大坝未来变形趋势进行综合分析评价,从而更为可靠掌握大坝未来变形的发展趋势。

1 基本理论

1.1 卡尔曼滤波

卡尔曼滤波是从与被提取信号有关的观测量中通过算法估计出所需信号的一种滤波算法,特别适用于数据量大且具有显著非平稳性的大坝变形监测数据^[8]。依据文献^[13]推导,可得其状态方程和观测方程分别为

$$\boldsymbol{X}_k = \boldsymbol{C}_{k|k-1} \boldsymbol{X}_{k-1} + \boldsymbol{W}_{k-1} \quad (k = 1, 2, \cdots) \quad (1)$$

$$\boldsymbol{Y}_k = \boldsymbol{M}_k \boldsymbol{X}_k + \boldsymbol{V}_k \quad (k = 1, 2, \cdots) \quad (2)$$

式中: $\boldsymbol{X}_k$ 、 $\boldsymbol{Y}_k$ 分别为 t_k 时刻的状态矢量和观测矢量; $\boldsymbol{C}_{k|k-1}$ 为从 t_{k-1} 时刻到 t_k 时刻的系统一步状态转移矩阵; $\boldsymbol{M}_k$ 为观测矩阵; $\boldsymbol{W}_{k-1}$ 、 $\boldsymbol{V}_k$ 分别为系统噪声矢量和观测噪声矢量。

对于系统噪声和观测噪声两序列的统计特性,可作以下假定:

$$\begin{cases} E(\boldsymbol{W}_k) = 0 \\ E(\boldsymbol{V}_k) = 0 \\ C_{ov}(\boldsymbol{W}_k, \boldsymbol{W}_j) = \boldsymbol{Q}_k \delta_{kj} \\ C_{ov}(\boldsymbol{V}_k, \boldsymbol{V}_j) = \boldsymbol{R}_k \delta_{kj} \\ C_{ov}(\boldsymbol{W}_k, \boldsymbol{V}_j) = 0 \end{cases} \quad (3)$$

式中: $\boldsymbol{Q}_k$ 、 $\boldsymbol{R}_k$ 分别为系统噪声矢量和观测噪声矢量的方差矩阵; δ_{kj} 为狄拉克(Dirac)函数,当 $k = j$ 时,

$\delta_{kj} = 1$, 否则 $\delta_{kj} = 0$; E 为数学期望; C_{ov} 为协方差。

如果给定 t_k 时刻的观测量 $\boldsymbol{Y}_k$, 可根据随机离散线性系统的卡尔曼滤波基本公式对 $\boldsymbol{X}_k$ 的最优估计值 $\hat{\boldsymbol{X}}_k$ 进行递推计算:

$$\hat{\boldsymbol{X}}_k = \hat{\boldsymbol{X}}_{k|k-1} + \boldsymbol{K}_k (\boldsymbol{Y}_k - \boldsymbol{M}_k \hat{\boldsymbol{X}}_{k|k-1}) \quad (4)$$

其中

$$\hat{\boldsymbol{X}}_{k|k-1} = \boldsymbol{C}_{k|k-1} \hat{\boldsymbol{X}}_{k-1}$$

$$\boldsymbol{K}_k = \boldsymbol{P}_{k|k-1} \boldsymbol{M}_k^T (\boldsymbol{M}_k \boldsymbol{P}_{k|k-1} \boldsymbol{M}_k + \boldsymbol{R}_k)^{-1}$$

$$\boldsymbol{P}_{k|k-1} = \boldsymbol{C}_{k|k-1} \boldsymbol{P}_{k-1} \boldsymbol{C}_{k|k-1}^T + \boldsymbol{Q}_{k-1}$$

$$\boldsymbol{P}_k = (\boldsymbol{I} - \boldsymbol{K}_k \boldsymbol{M}_k) \boldsymbol{P}_{k|k-1}$$

式中: $\hat{\boldsymbol{X}}_{k|k-1}$ 为 t_{k-1} 时刻到 t_k 时刻的一步估计值; $\boldsymbol{K}_k$ 为 t_k 时刻的卡尔曼滤波增益矩阵; $\boldsymbol{P}_k$ 为 t_k 时刻的状态估计误差协方差矩阵; $\boldsymbol{P}_{k|k-1}$ 为 t_{k-1} 时刻到 t_k 时刻的一步估计误差协方差矩阵。

根据以上方程,拟定 $k = 1$ 时 $\boldsymbol{X}_{k-1}$ 和 $\boldsymbol{P}_{k-1}$ 的初始值 $\boldsymbol{X}_0$ 和 $\boldsymbol{P}_0$, 通过 t_k 时刻的观测值 $\boldsymbol{Y}_k$ 即可对 t_k 时刻的状态估计 $\hat{\boldsymbol{X}}_k$ 进行递推求解。综上所述,卡尔曼滤波过程就是一种递推计算过程,同时在计算过程中进行持续地预测和修正,如此往复以获得观测时刻的最优估计,以达到削减观测数据中随机干扰噪声的效果。

1.2 分形理论

分形理论是研究事物分形性质及其应用的科学理论,其中 R/S 分析法是分形理论中的一种分析方法。 R/S 分析法又称为重标极差分析法,是由 Hurst^[14] 在探讨尼罗河水库水位波动的规律时首先提出的。

将时间序列 $\{X_1, X_2, \cdots, X_N\}$ 划分为 m 个时间长度为 n 的子序列,其中 $m = N/n$, 子序列记为 $T_i (i = 1, 2, \cdots, m)$, T_i 的元素为 $T_{j,i} (j = 1, 2, \cdots, n; i = 1, 2, \cdots, m)$, 则每个子序列 T_i 的均值 $\bar{T}_i$ 和标准差 S_i 分别为

$$\bar{T}_i = \frac{1}{n} \sum_{j=1}^n T_{j,i} \quad (5)$$

$$S_i = \sqrt{\frac{1}{n} \sum_{j=1}^n (T_{j,i} - \bar{T}_i)^2} \quad (6)$$

每个子序列 T_i 的累积偏差为

$$L_{j,i} = \sum_{j=1}^n (T_{j,i} - \bar{T}_i) \quad (7)$$

累积偏差的极差阈值为

$$R_i = \max L_{j,i} - \min L_{j,i} \quad (8)$$

结合式(6)和(8)得到子序列的重标极差 R_i/S_i , 即

$$R_i/S_i = \frac{\max L_{j,i} - \min L_{j,i}}{\sqrt{\frac{1}{n} \sum_{j=1}^n (T_{j,i} - \bar{T}_i)^2}} \quad (9)$$

对各子序列 R_i/S_i 求均值即可得到相应尺度下

的 $(R/S)_n$,即

$$(R/S)_n = \frac{1}{m} \sum_{i=1}^m (R_i/S_i) \tag{10}$$

改变 n 的取值,重复上述步骤,求取不同尺度下对应的 $(R/S)_n$ 值,再经过统计分析,即可获得 $(R/S)_n$ 值同Hurst指数 H 之间具有如下关系:

$$(R/S)_n = Cn^H \tag{11}$$

式中 C 为拟合参数。

根据式(11)可得到Hurst指数。Hurst指数又称为分形指数,常用于时间序列的趋势性评价,具有较强的预报功能。通过随机试验总结发现,Hurst指数存在如下性质:当 $0<H<0.5$ 时,说明时间序列存在反持续性特征,且 H 值越靠近0,反持续性越强;当 $H=0.5$ 时,说明时间序列无规律性特征明显,呈随机游走态;当 $0.5<H<1$ 时,说明时间序列存在持续性特征,且 H 值越靠近1,持续性越强。值得说明的是, H 的取值总是在0和1之间,若存在 $H>1$ 的情况,则表明时间序列中存在确定性误差,不具备分析价值。

进一步可得 R/S 分析法的统计量 V_n 计算公式如下:

$$V_n = (R/S)_n / \sqrt{n} \tag{12}$$

根据文献[15],Hurst指数和豪斯道夫维数 D 存在下述关系:

$$D = 2 - H \tag{13}$$

1.3 LSTM

LSTM由Hochreiter等提出^[16],由于其能够学习长期顺序依存关系,具有从经验中学习的能力,目前被广泛应用于时间序列的预测。LSTM通常由输入门、忘记门、输出门3个门组成^[17]。

忘记门的作用是控制细胞状态中信息的取舍:

$$f_t = \sigma(W_{hf}h_{t-1} + W_{xf}x_t + b_f) \tag{14}$$

输入门的作用是更新细胞状态中的信息:

$$i_t = \sigma(W_{hi}h_{t-1} + W_{xi}x_t + b_i) \tag{15}$$

$$\tilde{C}_t = \tanh(W_{hc}h_{t-1} + W_{xc}x_t + b_c) \tag{16}$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \tag{17}$$

输出门控制着需要输出的信息:

$$o_t = \sigma(W_{ho}h_{t-1} + W_{xo}x_t + b_o) \tag{18}$$

$$h_t = o_t \tanh(C_t) \tag{19}$$

式中: f_t 、 i_t 、 o_t 分别为忘记门、输入门和输出门; C_t 为 t 时刻隐藏层的单元状态向量; $\tilde{C}_t$ 为单元状态的当前输入; h_t 和 h_{t-1} 分别为隐藏层当前和前一时刻的输出; x_t 为输入向量; W_{hf} 、 W_{xf} 、 W_{hi} 、 W_{xi} 、 W_{hc} 、 W_{xc} 、 W_{ho} 、 W_{xo} 分别为忘记门、输入门、输出门中不同输入和输出对应的权重矩阵; b_f 、 b_i 、 b_c 、 b_o 分别为忘记门、输入门、当前输入的单元状态、输出门中的偏置向量; σ 为标准sigmoid激活函数。

2 变形趋势综合分析方法

结合各方法的优势,构建一种融合卡尔曼滤波、分形理论和LSTM模型的大坝变形趋势综合分析方法,其流程如下:

步骤1 利用卡尔曼滤波削减原始观测数据中的干扰和噪声,即滤波处理。

步骤2 基于滤波处理后的数据,通过 R/S 分析法,分析判断大坝变形序列的发展趋势,对大坝未来变形进行初步的定性判断。

步骤3 基于滤波处理后的数据构建LSTM模型,进一步对大坝未来变形进行定量分析判断;同时,引入其他神经网络预测模型,以验证LSTM模型的有效性和优越性。

步骤4 将LSTM模型的预测结果同 R/S 分析法的分析判断结果进行对比分析,通过 R/S 分析方法和LSTM二者的结合,在定性的基础上加入定量元素,共同评价大坝未来的变形情况。

3 实例分析

以某混凝土重力坝为例,对该坝某测点处未来变形趋势进行分析评价。大坝共布置了12个引张线测点,以实现对坝顶水平位移情况的监测。本文选取位于10号坝段的引张线测点EX8从2013年8月10日至2014年12月22日的位移观测值用于分析,共计500个数据,其过程线见图1中黑色曲线。




图1 位移过程线

3.1 卡尔曼滤波处理

首先采用卡尔曼滤波算法对大坝原始监测数据进行降噪处理。依据文献[8,13]的滤波初值拟定方法,根据前两次观测值的动态平差结果,取初始值

$X_0 = (-4.15, 0.02)^T$, $P_0 = \begin{bmatrix} 0.04 & 0 \\ 0 & 0.04 \end{bmatrix}$;系统一步

状态转移矩阵 $C_{k|k-1} = \begin{bmatrix} 1 & \Delta T_k \\ 0 & 1 \end{bmatrix}$,将观测值的采样

间隔 ΔT_k 取为1,则 $C_{k|k-1} = \begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix}$;观测矩阵 $M_k =$

(1 0);由观测方法,将观测噪声矢量 V_k 的方差矩阵的初始值 R_0 取为 0.04 mm^2 ;根据前两次观测值的动态平差结果结合方差传播定律,将系统噪声矢量 W_{k-1} 的方差矩阵的初始值 Q_0 取为 $\begin{bmatrix} 0.04 & 0.08 \\ 0.08 & 0.16 \end{bmatrix}$ 。基于式(4)进行不断地递推计算和预测修正,通过持续寻优,最终达到卡尔曼滤波的期望效果。处理结果见图1中红色曲线。

由图1可见,滤波值所呈现的位移变化规律同实际测得的位移值变化规律基本一致,且滤波后位移过程线一定程度上剔除了原位移过程线中由干扰和噪声产生的起伏和扰动,更加平滑,降低了粗糙程度,增强了位移监测数据的趋势性特征,更加趋于真实。滤波值和原始位移值之间的残差大部分在 $\pm 0.1 \text{ mm}$ 以内,说明卡尔曼滤波处理有一定的数据平滑效果,在削减噪声影响方面效果明显^[18]。

3.2 大坝变形 R/S 分析

在卡尔曼滤波处理的基础上,为初步定性分析大坝变形序列的发展趋势,基于2014年10月1日之前的417个大坝变形数据,根据R/S分析法对大坝变形趋势进行分析评价。具体操作流程如下:将时间序列划分为 m 组互不重叠的子序列,分别计算求得每组子序列的R/S统计量,再求其均值,进而得到对应不同长度 n 的平均 $(R/S)_n$ 值,分别对 n 值和 $(R/S)_n$ 值求对数,之后以 $\lg n$ 作为横坐标、 $\lg(R/S)_n$ 为纵坐标绘制 $\lg(R/S)_n - \lg n$ 双对数坐标散点图,再通过最小二乘法对散点进行线性拟合,得到的直线斜率即是Hurst指数 H ;类似地,可绘制 $\lg V_n - \lg n$ 双对数坐标散点图进行辅助分析。R/S分析结果如图2所示。




图2 大坝变形 R/S 分析结果

由图2(a)可见, $\lg(R/S)_n - \lg n$ 双对数坐标散点图除局部存在小幅波动以外总体上呈线性趋势,说明此变形序列存在部分随机性的同时趋势性较为明显。通过线性拟合得到的均方根误差 R_{MSE} 为 0.383 mm , 相关系数为 0.992 , 均方根误差较小, 拟合度较高, 表明分形分析结果具有较高的可信度和不错的参考价值, 同时求得此大坝变形序列的Hurst指数 H 为 0.954 , 大于 0.5 , 表明该测点处的大坝变形趋势呈现正向持续增长性, 且 H 较为靠近 1 , 加之 $\lg V_n - \lg n$ 双对数坐标散点图总体呈上升趋势, 说明大坝该测点处变形监测序列存在显著的长程相关性, 具有较强的规律性和代表性, 持续性强且趋势增强明显。根据 H 可得分形维数 D 为 1.046 , 略大于 1 , 可知大坝该测点处变形以线弹性为主, 兼具部分非线性特征。结合上述分析, 可初步推断大坝该测点处变形较为稳定。

综上所述, 可初步判断出未来一段时间内大坝该测点处变形存在较强的持续增长性特征, 变形值会随着前期的增大而继续增大, 且变形变化较为稳定。

3.3 LSTM 建模预测

将经过卡尔曼滤波处理过后的500个数据中2014年10月1日之前的417个数据用于LSTM建模, 后83个数据用于模型预测验证, 利用MATLAB进行LSTM模型的构建。参数寻优采用Adam算法, 训练时点数设置为40, 隐含层节点数设置为20, 窗口长度设置为20, 其余参数则采用默认值。

为验证LSTM神经网络在大坝变形预测中的优越性, 在同样数据的基础上建立BP神经网络模型和ELMAN神经网络模型, 对未来变形值进行分析预测。由于模型预测精度与网络隐含层节点数之间关系密切, 本文采用试算法拟定隐含层节点数, 最终确定BP神经网络和ELMAN神经网络的隐含层节点数分别为12和3。各模型预测过程线如图3所示。




图3 各神经网络模型的预测过程线

由图3可以看出, LSTM模型、BP模型和ELMAN模型的预测过程线与实测值过程线均较为贴合, 均方根误差均较低, 分别为 0.0367 mm 、 0.0899 mm 和 0.0695 mm , 预测结果较为理想, 综合

3.1 节的论述,分析其原因不难得出:本文在原始数据的基础上加入了卡尔曼滤波进行降噪处理,一定程度上削弱了干扰和噪声的影响,平滑或剔除了不合理的波动,使数据的趋势性特征得以保留和强化,信息表达的真实性和稳定性增加,进而使得模型的学习拟合过程更加趋于简单化和高效化,降低了模型预测结果的不确定性,保证了预测精度,一定程度上验证了对原始数据进行卡尔曼滤波降噪的可行性和必要性。

对比 3 种模型的预测效果,相较于 BP 模型和 ELMAN 模型,LSTM 模型的预测过程线同实测过程线更为吻合,其预测值的变化规律与实测值更加趋同;LSTM 模型预测结果的均方根误差最小,预测精度更高。因此相较于其他神经网络模型,LSTM 神经网络模型预测效果更为理想,能更为稳定地反映大坝变形的趋势和规律,在大坝变形预测中更为适用。

由图 3 的预测结果可见,大坝该测点处变形在约 90 d 内始终保持一种稳定的正向增长的态势,呈现出较强的持续增长性特征。

3.4 变形趋势综合分析

将 LSTM 模型的定量预测结果同 R/S 分析法的定性分析结果进行对比,实现对彼此预测判断结果准确性的相互检验,可见二者均判断得到该测点处的大坝变形存在正向持续增长的趋势,综合分析结果与工程实际情况相符。这既在一定程度上说明了 R/S 分析法的定性分析评定结果的有效性,又验证了 LSTM 模型定量分析判断结果的可靠性,同时也证明了本文将 R/S 分析法用于大坝变形趋势定性层面的分析,再将 LSTM 模型用于大坝变形趋势定量层面的评判,层层深入、互为佐证的大坝变形趋势综合分析方法思路的可行性和有效性。

4 结 语

本文融合卡尔曼滤波、分形理论和 LSTM 模型三者的优势,提出了一种大坝变形趋势综合分析方法。实例分析结果表明,卡尔曼滤波能一定程度地削减大坝变形监测数据中的干扰和噪声,提升大坝变形趋势分析的合理性和可靠性;基于卡尔曼滤波的降噪处理,分形理论和 LSTM 模型均能较为准确地对大坝变形趋势分别进行定性分析评价和定量预测判断,有效克服了大坝变形监测数据普遍存在的随机性和非平稳性等问题;融合分形理论和 LSTM 模型的定性和定量分析结果,可实现大坝变形趋势的综合评判,相较于单方面的定性或定量预报,可靠度得到了更好的保障。可见,本文提出的大坝变形趋势综合分析方法具有一定的适用性和推广价值。

参考文献:

[1] 吴中如. 水工建筑物安全监控理论及应用[M]. 南京: 河海大学出版社,2003.

[2] 庞琼,王士军,倪小荣,等. 世界已建高坝大库统计分析[J]. 水利水电科技进展,2012,32(6): 34-37. (PANG Qiong, WANG Shijun, NI Xiaorong, et al. Statistical analysis of world existed high dams and large reservoir [J]. Advances in Science and Technology of Water Resources , 2012, 32(6): 34-37. (in Chinese))

[3] 李子阳,郭丽,顾冲时. 大坝监测资料的时变 Kalman 预测模型[J]. 武汉大学学报(信息科学版), 2010, 35 (8): 991-995. (LI Ziyang, GUO Li, GU Chongshi. A time-varying Kalman model for dam monitoring data prediction [J]. Geomatics and Information Science of Wuhan University, 2010, 35 (8): 991-995. (in Chinese))

[4] 刘亮亮,陈旭东. 基于分形插值的混凝土坝变形趋势分析[J]. 人民黄河, 2020, 42 (8): 146-149. (LIU Liangliang, CHEN Xudong. Analysis of deformation trend of concrete dam based on fractal interpolation[J]. Yellow River, 2020, 42(8): 146-149. (in Chinese))

[5] 郝永河,郝永艳,唐承忠,等. 基于变形信息分解的大坝变形趋势判断及预测研究[J]. 大地测量与地球动力学, 2021, 41 (8): 841-845. (HAO Yonghe, HAO Yongyan, TANG Chengzhong, et al. Research on dam deformation trend judgment and prediction based on deformation information decomposition [J]. Journal of Geodesy and Geodynamics, 2021, 41(8): 841-845. (in Chinese))

[6] 牛景太. 基于奇异谱分析与 PSO 优化 SVM 的混凝土坝变形监控模型[J]. 水利水电科技进展,2020,40(6): 60-65. (NIU Jingtai. Dam deformation monitoring model based on singular spectrum analysis and SVM optimized by PSO [J]. Advances in Science and Technology of Water Resources,2020,40(6): 60-65. (in Chinese))

[7] 彭丁聪. 卡尔曼滤波的基本原理及应用[J]. 软件导刊, 2009, 8(11): 32-34. (PENG Dingcong. Basic principle and application of Kalman filter [J]. Software Guide, 2009, 8(11): 32-34. (in Chinese))

[8] 王利,李亚红,刘万林. 卡尔曼滤波在大坝动态变形监测数据处理中的应用[J]. 西安科技大学学报,2006,26 (3): 353-357. (WANG Li, LI Yahong, LIU Wanlin. Application of Kalman filter in data processing of dam dynamic deformation monitoring [J]. Journal of Xi'an University of Science and Technology, 2006,26(3): 353-357. (in Chinese))

[9] 赖道平,吴中如,周红. 分形学在大坝安全监测资料分析中的应用[J]. 水利学报,2004,49(1): 100-104. (LAI Daoping, WU Zhongru, ZHOU Hong. Application of

- fractal theory to analyze dam safety monitoring data [J]. Journal of Hydraulic Engineering, 2004, 49 (1): 100-104. (in Chinese))
- [10] 周兰庭,柳志坤. 大坝变形实测数据的多重分形特征解析方法[J]. 水利水电科技进展, 2021, 41 (6): 18-24. (ZHOU Lanting, LIU Zhikun. Multifractal feature analysis method for measured data of dam deformation [J]. Advances in Science and Technology of Water Resources, 2021, 41(6): 18-24. (in Chinese))
- [11] 欧斌,吴邦彬,袁杰,等. 基于 LSTM 的混凝土坝变形预测模型[J]. 水利水电科技进展, 2022, 42 (1): 21-26. (OU Bin, WU Bangbin, YUAN Jie, et al. LSTM-based deformation prediction model of concrete dams [J]. Advances in Science and Technology of Water Resources, 2022, 42(1): 21-26. (in Chinese))
- [12] 刘亚新,樊启祥,尚毅梓,等. 基于 LSTM 神经网络的水电站短期水位预测方法[J]. 水利水电科技进展, 2019, 39(2): 56-60. (LIU Yaxin, FAN Qixiang, SHANG Yizi, et al. Short-term water level prediction method for hydropower station based on LSTM neural network [J]. Advances in Science and Technology of Water Resources, 2019, 39(2): 56-60. (in Chinese))
- [13] 余学祥,张华海,吕伟才,等. Kalman 滤波在 GPS 监测网中的应用[J]. 工程勘察, 2000, 28 (4): 33-35. (YU Xuexiang, ZHANG Huahai, LU Weicai, et al. Application of Kalman filter in GPS monitoring network [J]. Geotechnical Investigation and Surveying, 2000, 28 (4): 33-35. (in Chinese))
- [14] HURST H E. Long-term storage capacity of reservoirs: an experimental study[J]. Transactions of American Society of Civil Engineers, 1951, 116: 770-808.
- [15] 陈霖霞. 基于分形及混沌理论的中国股票市场分析与预测[D]. 南京:南京财经大学, 2008.
- [16] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9 (8): 1735-1780.
- [17] 郭张军,黄华东,屈旭东. 基于深度学习的大坝变形预测模型[J]. 水电能源科学, 2020, 38(3): 83-86. (GUO Zhangjun, HUANG Huadong, QU Xudong. Dam deformation prediction model based on deep learning [J]. Water Resources and Power, 2020, 38(3): 83-86. (in Chinese))
- [18] 王井利,张春哲. 自适应卡尔曼滤波在地铁监测中的应用[J]. 沈阳建筑大学学报(自然科学版), 2014, 30 (2): 263-268. (WANG Jingli, ZHANG Chunzhe. Application of the adaptive Kalman filter in metro monitoring data processing [J]. Journal of Shenyang Jianzhu University (Natural Science), 2014, 30 (2): 263-268. (in Chinese))

(收稿日期:2021-09-12 编辑:雷燕)

(上接第 114 页)

- [17] 李永明,张恺韬,郭哲良,等. 基于 CATIA 软件的楔形盾构隧道管片参数化建模与排版[J]. 隧道建设, 2019, 39 (3): 391-397. (LI Yongming, ZHANG Kaitao, GUO Zheliang, et al. Parametric modeling and segment layout of wedge shield tunnel based on software catia [J]. Tunnel Construction, 2019, 39(3): 391-397. (in Chinese))
- [18] 车冠宇,毛伟栋. Revit+Dynamo 参数化隧道模型构建体系探析[J]. 公路交通科技(应用技术版), 2018, 14 (4): 246-248. (CHE Guanyu, MAO Weidong. Analysis of Revit + Dynamo parametric tunnel model construction system [J]. Highway Traffic Technology, 2018, 14 (4): 246-248. (in Chinese))
- [19] 仇朝珍,贺波,葛胜锦. Dynamo 在桥梁 BIM 建模中的应用[J]. 中外公路, 2019, 39 (5): 179-182. (QIU Chaozhen, HE Bo, GE Shengjin. Application of Dynamo in bridge BIM modeling [J]. Journal of China & Foreign Highway, 2019, 39(5): 179-182. (in Chinese))
- [20] 邹明强. 水电站压力钢管直径与分段优化设计探讨[J]. 水利水电技术, 1996, 27 (2): 28-32. (ZHOU Mingqiang. Discussion on diameter and sectional optimal design of penstock in hydropower station [J]. Water Resources and Hydropower Engineering, 1996, 27(2): 28-32. (in Chinese))
- [21] 刘志宏,喻晓旭. 基于遗传算法的两阶段切割问题的研究[J]. 电子技术与软件工程, 2018(24): 155-156. (LIU Zhihong, YU Xiaoxu. Research on two-stage cutting problem based on genetic algorithm [J]. Electronic Technology & Software Engineering, 2018(24): 155-156. (in Chinese))
- [22] 朱俊辉. 大口径长距离输水钢管整体吊装沉管施工关键技术及实证研究[D]. 广州:华南理工大学, 2020.
- [23] 冯飞鸿. 输水用大直径钢管卷制工艺参数研究[J]. 科学技术创新, 2021 (10): 124-125. (FENG Feihong. Research on coiling process parameters of large diameter steel pipe for water conveyance [J]. Scientific and Technological Innovation, 2021 (10): 124-125. (in Chinese))

(收稿日期:2021-09-19 编辑:骆超)