

基于蠕滑趋势影响和特征优化算法的阶跃型滑坡位移预测模型

冯 谕^{1,2}, 曾怀恩^{1,2,3}, 邓华锋^{1,2}, 涂鹏飞^{1,2}

(1. 三峡大学 土木与建筑学院, 湖北 宜昌 443002; 2. 三峡大学 湖北省水电工程施工与管理重点实验室, 湖北 宜昌 443002;

3. 湖北长江三峡滑坡国家野外科学观测研究站, 湖北 宜昌 443002)

摘要: 在滑坡位移预测模型构建过程中, 为了清晰地分离出各类特征影响的滑坡位移部分, 增强位移预测模型的力学可解释性与泛化能力, 提出一种基于蠕滑趋势影响和特征优化算法的阶跃型滑坡位移预测模型。该预测模型首先运用粒子群算法优化变分模态分解(PSO-VMD)方法将训练数据分解为具有西原蠕变特征的趋势项位移及其他数据曲线; 然后, 综合选取滑坡位移的外界影响特征, 对其他数据曲线运用遗传特征优化算法(GA)分离重构得到具有傅里叶波动特征的波动项位移及最大化与外界影响特征间相关性的影响项位移; 分别运用西原蠕变泰勒展开多项式模型, 傅里叶波动模型及卷积神经网络-挤压激励注意力模块-门控循环单元模型(CNN-SE-GRU)对趋势项位移, 波动项位移及影响项位移进行预测; 令各项位移训练时的误差为随机项位移, 运用核密度区间估计约束下灰狼算法优化极限学习机(KDE-GWO-ELM)模型对该位移进行预测; 最终, 各项位移预测值叠加后实现对阶跃型滑坡位移的预测。以阶跃型滑坡——白水河滑坡为例, 选取 ZG118 与 ZG93 监测点 2005 年 11 月~2009 年 10 月累积水平位移数据为训练数据, 2009 年 11 月~2010 年 7 月累积水平位移数据为预测数据进行研究。结果表明, 预测模型下 ZG118 与 ZG93 监测点的均方根误差 RMSE 分别为 5.85 与 10.61 mm, 平均绝对百分比误差 MAPE 分别为 0.27% 与 0.43%, 与 CNN-SE-GRU/LSTM 模型、GWO-ELM 模型、VMD-GWO-ELM 模型及 EEMD-CNN-GRU 模型相比, 该模型不仅预测精度有所提升, 且清晰地解释了时间特征、外界影响特征及误差特征对预测模型的影响, 具有较好的可解释性与泛化能力。

关键词: 边坡工程; 阶跃型滑坡; 蠕滑趋势; PSO-VMD 模型; 傅里叶波动函数; GA 特征优化算法; CNN-SE-GRU 模型; KDE-GWO-ELM 模型

中图分类号: P 642

文献标识码: A

文章编号: 1000-6915(2025)03-0705-16

A step-type landslide displacement prediction model based on creep trend influence and feature optimization algorithm

FENG Yu^{1,2}, ZENG Huaien^{1,2,3}, DENG Huafeng^{1,2}, TU Pengfei^{1,2}

(1. College of Civil Engineering and Architecture, China Three Gorges University, Yichang, Hubei 443002, China; 2. Hubei Key Laboratory of Construction and Management in Hydropower Engineering, China Three Gorges University, Yichang, Hubei 443002, China; 3. National Field Observation and Research Station of Landslides in the Three Gorges Reservoir Area of Yangtze River, Yichang, Hubei 443002, China)

Abstract: In the construction process of the landslide displacement prediction model, in order to clearly separate the landslide displacement parts affected by various features to enhance the mechanical interpretability and

收稿日期: 2024-07-15; **修订日期:** 2024-09-01

基金项目: 国家自然科学基金资助项目(42074005); 三峡大学湖北省水电工程施工与管理重点实验室开放基金项目(2023KSD11)

Supported by the National Natural Science Foundation of China(Grant No. 42074005) and Open Foundation of Hubei Key Laboratory of Construction and Management in Hydropower Engineering, China Three Gorges University(Grant No. 2023KSD11)

作者简介: 冯 谕(1998-), 男, 2021年毕业于绍兴文理学院工程管理专业, 现为硕士研究生, 主要从事滑坡监测数据处理方面的研究工作。E-mail: 2044207612@qq.com。通讯作者: 曾怀恩(1979-), 男, 博士, 现任教授。E-mail: zenghuaien_2003@163.com

DOI: 10.3724/1000-6915.jrme.2024.0554

generalization ability of the displacement prediction model, a step-type landslide displacement prediction model based on the influence of creep trend and feature optimization algorithm is proposed. Firstly, the Particle Swarm Optimization-Based Variational Modality Decomposition(PSO-VMD) Method is used to decompose the training data into other data curves and trend displacement with influence of Nishihara creep model. Secondly, the external influence features of landslide displacement are comprehensively selected, other data curves are separated and reconstructed with the genetic feature optimization algorithm(GA) to obtain the fluctuation displacement with Fourier characteristics and the influence displacement that maximizes the correlation with external influence features. The Nishihara creep Taylor expansion polynomial model, Fourier function model and Convolutional Neural Network-Squeeze Excitation Attention Module-Gated Recurrent Unit Model(CNN-SE-GRU) are used to respectively fit and predict the trend displacement, fluctuation displacement and influence displacement. The errors of each displacement model training fit are defined as the random displacement; it is predicted by the Gray Wolf Optimization-Based Extreme Learning Machines model under the constraint of kernel density estimation(KDE-GWO-ELM). Finally, the prediction of step-type landslide displacement is accomplished by superimposing all displacement prediction model results. Taking the step-type landslide- namely Baishuihe landslide as an example, the cumulative horizontal displacement data of monitoring points ZG118 and ZG93 from November 2005 to October 2009 are selected as training data, and the data from November 2009 to July 2010 are selected as prediction data for research. The prediction results show that the root mean square error(RMSE) of monitoring points ZG118 and ZG93 under the prediction model 5.85 mm and 10.61mm respectively, the mean absolute percentage error(MAPE) are 0.27% and 0.43% respectively. Compared with the CNN-SE-GRU/LSTM model, GWO-ELM model, VMD-GWO-ELM model and EEMD-CNN-GRU model, the novel prediction model not only improves the prediction accuracy, but also shows clearly the influence of time features, external influence features and error features for prediction model. Thus, it has excellent interpretability and generalization ability.

Key words: slope engineering; step-type landslide; creep trend; PSO-VMD model; Fourier fluctuation function; GA feature optimization algorithm; CNN-SE-GRU model; KDE-GWO-ELM model

1 引 言

自 2003 年 6 月三峡库区蓄水以来,许多新滑坡相继产生,对人民生活造成了巨大威胁,为了解决新滑坡带来的安全问题,建立滑坡早期预警系统^[1]。滑坡位移预测方法因成本低、预测及时等特点成为滑坡早期预警系统的重要组成部分,对降低滑坡灾害风险具有重要意义^[2]。

滑坡累积位移曲线在形态特征上表现为阶跃型的滑坡为阶跃型滑坡^[3-4],考虑到阶跃型滑坡具有发育时间短、危害性较大的特征,对于该类型滑坡位移的预测研究非常必要。目前,阶跃型滑坡位移预测模型主要是时序分解模型,可视化拟合预测模型及机器学习预测模型组合的综合性预测模型^[4]。

将滑坡位移时序分解为简易位移分量的分解方法主要有:移动平均分解^[5];指数平滑分解^[6];经验模态分解(empirical mode decomposition, EMD)^[7];集合经验模态分解(ensemble empirical mode decomposition,

EEMD)^[8];自适应噪声完全集合经验模态分解(complete EEMD with adaptive noise, CEEMDAN)^[9];变分模态分解(varational mode decomposition, VMD)^[10-11]等方法。

滑坡位移经时序分解后的简易位移分量被学者划分为趋势项位移,波动项位移及随机项位移。对于趋势项位移与波动项位移,常用多项式拟合模型与三角函数拟合模型对其进行预测^[12-13];受外界因素影响的随机项位移,常用的机器学习预测模型有:支持向量机预测模型^[8, 14](support vector machines regression, SVR);极限学习机预测模型^[10, 15](extreme learning machines, ELM);长短期记忆神经网络预测模型^[7, 12](long short-term memory, LSTM);门控神经网络预测模型^[5](gated recurrent unit, GRU);各类组合型预测模型如 BA(bat algorithm)-SVR-Adaboost(adaptive boosting)模型^[9], GWO(grey wolf optimizer)-MIC(the maximal information coefficient)-SVR 模型^[11], WA(wavelet analysis)-GWO-BP(error back propagation)模型^[13], PSO(particle swarm optimization)-SVR 模

型^[16]等预测模型。

对于三峡库区阶跃型滑坡, 这些预测模型的预测效果较好, 预测精度较高, 但这些模型在构建与预测时存在如下问题: (1) 趋势项位移在分解与预测时不具有力学可解释性。(2) 直接将分解后的其他曲线作为或叠加作为波动项位移与随机项位移, 并不合理。(3) 波动项位移与随机项位移预测时将误差特征因子与外界影响特征因子混合作为模型输入, 泛化能力不强。因此, 为了解决上述问题, 文中模型在分解与预测趋势项位移时引入西原蠕变模型, 增强趋势项位移力学可解释性。运用 GA 特征优化算法分离重构后得到具有傅里叶波动特征的波动项位移及最大化与外界影响特征间相关性的影响项位移, 以模型训练时各项位移的拟合误差为随机项位移, 通过分离各类特征影响的滑坡位移部分, 增强模型的可解释性与泛化能力。

新模型在现有的机器学习预测模型中引入西原蠕变模型, 分析预测具有力学可解释性。新模型分离出了蠕变力学特征, 时间波动特征, 外界影响特征及误差特征造成的滑坡位移部分, 具有良好的可解释性与泛化能力。

新模型为滑坡预测方法提供了一种新的思路, 也增强了滑坡位移分解方法的可解释性。

2 白水河滑坡概况

2.1 滑坡工程地质概况

白水河滑坡地处长江右岸, 位于三峡库区秭归县沙镇溪镇白水河村, 距三峡大坝坝址 56 km^[17]。

滑坡后缘高程约 410 m, 前缘抵长江 135 m 水位以下, 东西两侧以基岩山脊为界。滑坡体南北向长 780 m, 东西宽 700 m, 平均厚度约 30 m, 坡度范围为 30°~35°, 总体积约 1.26×10⁷ m³, 下伏基岩岩层产状为 15°∠36°^[18]。

据白水河滑坡工程地质剖面图, 如图 1 所示, 滑坡体具有土质与碎裂岩质两层滑带^[19]。相关勘探数据表明, 白水河滑坡变形主要集中在浅层滑带, 该滑带埋深较浅, 可通过分析地表监测点水平位移变化情况来看滑带的滑动情况。

2.2 滑坡变形情况

白水河滑坡属特大型松散顺层古滑坡。2003 年 6 月三峡水库蓄水及强降雨综合作用下, 白水河滑坡开始复活, 预警区域内出现明显变形且具有不断增长的趋势, 诱发了一系列新型滑坡灾害^[20-21]。




图1 白水河滑坡工程地质剖面图

Fig.1 Geological section of Baishuihe landslide

考虑到新型滑坡灾害破坏情况, 2003 年 6 月起, 对白水河滑坡进行变形监测, 并于 2004 年 7 月划定滑坡预警区, 如图 2 所示。




图2 白水河滑坡监测点平面布置图

Fig.2 Monitoring arrangement of displacement in Baishuihe landslide

预警区域内监测点 2005 年 11 月~2010 年 7 月监测数据较为完整, 变形程度较大, 变形曲线类似。其中, ZG93 与 ZG118 监测点位于滑坡中部, 变形程度大, 阶跃特征明显, 分析预测可以很好的把控滑坡变形情况。因此, 选取 ZG118 与 ZG93 监测点 2005 年 11 月~2010 年 7 月滑坡累计水平位移监测数据进行研究。

除时间因素外, 影响滑坡位移的外界因素主要为降雨及库水位变动。因此, 选取 2005 年 11 月~

2010 年 7 月秭归气象观测站的大气降雨日值及库水位月均变动值作为白水河滑坡位移预测的特征输入基本数据。2005 年 11 月~2010 年 7 月滑坡累计位移、降雨量、库水位监测曲线如图 3 所示。




图 3 2005 年 11 月~2010 年 7 月滑坡累计位移、降雨量、库水位监测曲线

Fig.3 Curves of monitored cumulative displacement of landslide, rainfall, and reservoir water level from November 2005 to July 2010

3 滑坡位移分解

3.1 滑坡位移分解模型

为了简化计算,常用统计理论中的时间序列分解模型对阶跃型滑坡位移曲线进行分解处理。目前,阶跃型滑坡位移时间序列分解模型主要由趋势项位移,波动项位移以及随机项位移组成,即

$$F = c + w + \partial \quad (1)$$

式中: F 为滑坡总位移, c 为趋势项位移, w 为波动项位移, ∂ 为随机项位移。

为了增强预测模型的可解释性与泛化能力,创建 3 类特征:时间特征,外界影响特征及误差特征。考虑到各类特征的影响,在式(1)基础上,提出新型分解模型:

$$F = c(t) + w(t) + e(r_i, w_i) + \partial(\mu) \quad (2)$$

式中: $c(t)$, $w(t)$ 分别为以时间特征为变量的趋势项位移与波动项位移; $e(r_i, w_i)$ 为以降雨影响特征 r_i 及库水位影响特征 w_i 为变量的影响项位移; $\partial(\mu)$ 为以误差特征 μ 为变量的随机项位移。

3.2 西原蠕变模型

前述学者研究分解出的趋势项位移曲线形状不统一且不具有力学可解释性。据张倬元等^[22]研究,对于处于蠕变阶段的滑坡,滑坡位移具有的发展趋势应为蠕滑趋势,因此,滑坡趋势项位移应受蠕变影响,即滑坡位移发展趋势与蠕变模型有关。为此,引入蠕变模型。

分析时间段内,白水河滑坡仍处于初始蠕变阶段,但受外界水动力影响产生了多次阶跃状振荡变

化。根据冯 谕等^[23-26]研究成果中的模型实验,滑坡位移历时曲线及滑动阶跃识别分解方法,选取西原蠕变模型作为趋势项位移 $c(t)$ 的拟合近似模型。

据何云明等^[27-28]研究中西原蠕变模型的元件组合模式,求解得到西原蠕变方程:

$$\varepsilon = \begin{cases} \left[\frac{\sigma}{E_0} + \frac{\sigma}{E_1} \left(1 - e^{-\left(\frac{E_1}{\eta_1} t \right)} \right) \right] & (\sigma < \sigma_s) \\ \left[\frac{\sigma}{E_0} + \frac{\sigma}{E_1} \left(1 - e^{-\left(\frac{E_1}{\eta_1} t \right)} \right) \right] + \frac{\sigma - \sigma_s}{\eta_2} t & (\sigma \geq \sigma_s) \end{cases} \quad (3)$$

式中: E_0 为弹性模量; E_1 为黏弹性模量; η_1 , η_2 为黏滞系数; σ 为总应力; σ_s 为坡体屈服应力; ε 为应变。

据式(3),得到 2 种应力情况下的蠕变曲线,如图 4 所示。




图 4 2 种应力情况下的蠕变曲线

Fig.4 Creep curves under two stress conditions

据图 3, ZG93 与 ZG118 监测点累计水平位移平缓期间的增长幅度较大。考虑到图 4 中曲线①后续变形较为平缓,曲线②由于线性多项的影响,后续变形增长幅度较大,因此,选取趋势项位移近似拟合模型表达曲线为曲线②,表达式为

$$\hat{c}(t) = a_1(1 - e^{-b_1 t}) + c_1 t + D \quad (4)$$

式中: a_1 , b_1 , c_1 , D 为拟合求解参数。

3.3 PSO-VMD 分解模型

目前,变分模态分解方法(VMD)^[29]已广泛应用于阶跃型滑坡位移预测。对于该分解方法原理,众多学者已进行了多次解释说明,文中不做赘述。

相较于人为设定参数的常规 VMD 分解,以时间序列熵值为优化条件,经算法优化模态个数 k 与惩罚因子 α 下的 VMD 分解更加合理。因此,本文为了考虑蠕滑及时间序列熵特征影响,以分解后序列模糊熵与趋势项位移拟合优度 R^2 组合为目标函

数, 采用粒子群算法(PSO)^[30]优化 VMD 分解过程中的模态个数 k 与惩罚因子 α , 得到最优情况下的 VMD 分解模型。模糊熵(Fuzzy Entropy, FE)的计算过程见 W. T. Chen 等^[31]研究, 文中不做赘述。详细的 PSO-VMD 模型构建方式如下:

滑坡位移曲线经 VMD 分解后的各固有模态(intrinsic mode function, IMF)曲线模糊熵越小, 复杂度越小且第一条本征模态(IMF1)曲线的平滑性最好。因此, 设定待优化目标分别为: IMF1 曲线经式(4)拟合下的拟合优度 R^2 及分解后的 IMF 时间序列最小模糊熵 FE, 即

$$\left. \begin{aligned} R^2 &= 1 - \frac{\sum_{i=0}^{n-1} (\hat{c}_i - c_i)^2}{\sum_{i=0}^{n-1} (c_i - \bar{c}_i)^2} \\ FE &= \min(\text{FuzzyEn}(\text{IMF}_j)) \quad (j=1, 2, \dots, k) \end{aligned} \right\} \quad (5)$$

式中: $\hat{c}_i$ 为 IMF1 曲线趋势项位移拟合值, $\bar{c}_i$ 为 IMF1 曲线均值, c_i 为 IMF1 曲线原值, k 为模态个数, $\text{FuzzyEn}(\text{IMF}_j)$ 为模糊熵计算函数。

考虑到 R^2 为正向影响因子, FE 为逆向影响因子, 且相较于 R^2 , FE 较小, 优化过程中 FE 的影响并不明显。因此, 为了提高 FE 的影响程度, 将 FE 放大至 $[0, 1]$ 范围内, 设定目标函数表达为

$$\text{Fitness} = R^2 - \beta \cdot FE \quad (6)$$

式中: β 为缩放因子, 经计算设定 β 值为 10。

为了保证拟合后的曲线形态与西原蠕变曲线形态一致, 设定待优化拟合参数的取值范围; 同时, 经验上, 设定模态个数 k 与惩罚因子 α 的取值范围, 综合设定的待优化参数的取值范围如下:

$$\begin{bmatrix} a_1 \\ b_1 \\ c_1 \\ D \\ k \\ \alpha \end{bmatrix} = \begin{bmatrix} [-50\ 000, 50\ 000] \\ [0, 1000] \\ [-50\ 000, 50\ 000] \\ [-50\ 000, 50\ 000] \\ [3, 11] \\ [50, 5000] \end{bmatrix} \quad (7)$$

综上所述, 根据 PSO 算法的迭代优化方式, 有 PSO-VMD 模型优化流程如图 5 所示。

3.4 分解结果

设定训练数据与预测数据比例为 $\{0.85, 0.15\}$, 即训练数据集为 2005 年 11 月~2009 年 10 月累积水平位移 48 组数据, 预测数据集为 ZG118 与 ZG93 监测点 2009 年 11 月~2010 年 7 月累计水平位移 9 组数据。运用 PSO-VMD 算法对该训练数据集进行分解。




图 5 PSO-VMD 模型计算流程

Fig.5 Flow chart of PSO-VMD model

经验上, 设定算法种群个数 $N = 30$, 迭代次数 $M_1 = 200$, 粒子群参数 $P1$ 与 $P2$ 为 1.5。同时, 据刘慧等^[32]研究成果, 时间序列模糊熵计算时, 取窗口元素个数 m 为 2, 边界梯度 t 为 2, 边界宽度 r 为

$$r = \text{std}(\text{IMF}) \quad (8)$$

式中: $\text{std}(\cdot)$ 为标准差计算函数。

将图 3 中 ZG118 与 ZG93 监测点训练数据及各设置参数代入 PSO-VMD 分解模型中, 经优化, 得到 PSO-VMD 模型优化迭代曲线如图 6 所示。




图 6 PSO-VMD 模型迭代曲线

Fig.6 Iteration curves of PSO-VMD model

据 PSO-VMD 模型优化结果, 得到 ZG118 与 ZG93 监测点 PSO 算法优化下的最优模态层数 k 为 3, 最优惩罚因子 α 分别为 730 与 697, 最大适应度 $Fitness$ 分别为 0.5513 与 0.5172, 据此, 得到 ZG118 与 ZG93 监测点 2005 年 11 月~2009 年 10 月原始数据优化分解模态曲线, 如图 7 所示。




图 7 ZG118 与 ZG93 监测点 2005 年 11 月~2009 年 10 月原始数据优化分解模态曲线

Fig.7 Optimized decomposition mode curves of ZG118 and ZG93 data from November 2005 to October 2009

4 滑坡位移重构

前述学者将分解后的其他曲线作为或叠加作为波动项位移与随机项位移, 这样设定虽简易, 但每条曲线内部应同时具有受时间波动与外界因素影响的位移曲线, 这样设定并不合理。因此, 据式(2), 针对波动项位移与影响项位移, 对 $IMF2$ 曲线与 $IMF3$ 曲线进行重构, 如下:

4.1 选取外界影响特征

(1) 降雨型影响特征

滑坡位移变化与前期降雨及关键性降雨有较大关系^[33]。据图 3, 分析时间段内, 有 2 次典型阶跃变形: ① 2007 年 5~8 月期间, 月降雨量达到 400 mm 以上, ZG118 与 ZG93 监测点产生了大幅度阶跃变形; ② 2008 年 7~9 月期间, 月降雨量达到了 350 mm 以上, ZG118 与 ZG93 监测点产生了阶跃变形。同时, 据郭璐等^[34-35]分析结果, 降雨是白水河滑坡变形的重要影响因素, 可以认为, 白水河滑坡的部分位移与强降雨及前期降雨之间具有较强的相关关系。因此, 选取降雨型影响特征: 当月降雨量 R_t , 上月降雨量 R_{t-1} , 上月日折减降雨最值 $r_{\max(i-1)}$ 。

其中, 上月日折减降雨最值 $r_{\max}$ 的计算方式为

$$r_{\max(i-1)} = R_{\max(i-1)} \eta_{i-1} \tag{9}$$

式中: $R_{\max(i-1)}$ 为上月日降雨最值, η_{i-1} 为上月日降雨最值距本月的天数。

(2) 库水位型影响特征

高晨曦等^[36]研究认为, 滑坡位移与库水位变动有较大关系, 且由于地下水渗出缓于库水位的原因, 库水位变动对于滑坡位移的影响具有滞后效应。据肖捷夫^[37]研究成果, 库水位上涨对滑坡位移影响无法确定, 但库水位下降时, 产生的渗透压会对滑坡位移产生较大影响。据图 3, 2007 年 5 月至 8 月及 2008 年 7~9 月前期, 库水位产生了较大变动, 白水河滑坡产生了阶跃变形。同时, 据郭璐等^[34-35]分析结果, 库水位变动也是白水河滑坡变形的重要影响因素, 且库水位下降对滑坡变形的影响程度较大, 可以认为, 白水河滑坡的部分位移与前期库水位变动尤其是库水位下降之间具有较强的相关关系。因此, 选取库水位型影响特征: 上月均库水位变动 V_{i-1} , 前 2 个月均库水位变动 V_{i-2} , 前 3 个月均库水位变动 V_{i-3} , 上月折减库水位 h_{i-1} 。其中, 月均库水位变动 V_i 表达如下:

$$V_i = \frac{1}{2}[(H_{i+1} - H_i) + (H_i - H_{i-1})] \tag{10}$$

式中: H_{i+1} 为次月平均库水位值, H_i 为当月平均库水位值, H_{i-1} 为上月平均库水位值。

上月折减库水位 h_{i-1} 计算方式如下:

$$h_{i-1} = \lambda_{i-1} H_{i-1} \tag{11}$$

式中: λ_{i-1} 为上月出现库水位降低的总天数。

综上所述, 得到选取的外界影响特征如表 1 所示。

表 1 经选取的外界影响特征表				
Table 1 Selected external influence characteristics table				
影响特征属性	经选取的外界影响特征			
降雨型	当月降雨量 R_t	上月降雨量 R_{t-1}	上月日折减降雨最值 $r_{\max(i-1)}$	
库水位型	上月均库水位变动 V_{i-1}	前两个月均库水位变动 V_{i-2}	前三个月均库水位变动 V_{i-3}	上月折减库水位 h_{i-1}

4.2 GA 特征优化模型

如表 1 所示, 设定外界影响特征后, 计算外界影响特征与 $IMF2$, $IMF3$ 曲线的初始相关关系。

选择 Pearson 相关性系数^[38]绝对值 r_p 作为外界影响特征与 $IMF2$, $IMF3$ 之间相关性的评价标准, r_p 的表达如下:

$$r_p = |R_p^2| = \frac{\sum_{i=0}^{n-1} (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=0}^{n-1} (x_i - \bar{x})^2 \sum_{i=0}^{n-1} (y_i - \bar{y})^2}} \quad (12)$$

式中: x_i 为外界影响特征; $\bar{x}$ 为外界影响特征均值, y_i 为 $IMF2$, $IMF3$ 原始数据; $\bar{y}$ 为 $IMF2$, $IMF3$ 数据均值; R_p^2 为 Pearson 相关性系数。

将表 1 中外界影响特征及图 7 中 $IMF2$, $IMF3$ 数据代入式(12)。得到外界影响特征与 $IMF2$, $IMF3$ 初始相关性热图, 如图 8 所示。




图 8 外界影响特征与 $IMF2$, $IMF3$ 间初始相关性热图

Fig.8 Correlation heatmap between $IMF2$, $IMF3$ and external influence characteristics

据高华喜和殷坤龙^[39]研究中 Pearson 系数相关性评价标准:

$$r_p \in \begin{cases} [0, 0.3) & (x, y\text{-间相关性极弱}) \\ [0.3, 0.5) & (x, y\text{-间低度相关}) \\ [0.5, 0.8) & (x, y\text{-间中度相关}) \\ [0.8, 1] & (x, y\text{-间高度相关}) \end{cases} \quad (13)$$

图 8 中的外界影响特征与 $IMF2$, $IMF3$ 之间相关性变动区间为 $[0.02, 0.33]$, 据式(13), 可得 2 个变量之间的相关性较差。

因此, $IMF2$ 与 $IMF3$ 位移量不完全由外界影响特征引起, 内部还存在与时间波动特征有关的波动项位移, 需对该位移进行提取, 设置提取方式为傅里叶函数提取, 计算表达如下:

常用傅里叶波动函数的计算表达为

$$\left. \begin{aligned} w_j(t) &= U_0 + \sum_{i=1}^N U_a^i \sin(U_b^i t + U_c^i) + U_p^i \cos(U_q^i t + U_z^i) \\ w(t) &= w_2(t) + w_3(t) \end{aligned} \right\} \quad (j=2, 3) \quad (14)$$

式中: t 为时间变量; U_0 , U_a^i , U_b^i , U_c^i , U_p^i , U_q^i , U_z^i 为傅里叶函数待提取参数, N 为信号波动函数个数; $w_2(t)$, $w_3(t)$ 分别为 $IMF2$, $IMF3$ 内部存在的波

动项位移。

正弦函数与余弦函数之间可相互转换, 因此, 考虑到求解难度问题, 对式(14)做简化处理, 处理后的表达为

$$\left. \begin{aligned} w_j(t) &= U_0 + \sum_{i=1}^n U_n \quad (j=2, 3) \\ U_i &= A_i \sin(B_i t + C_i) \\ w(t) &= w_2(t) + w_3(t) \end{aligned} \right\} \quad (15)$$

式中: A_i , B_i , C_i 为傅里叶函数简化后的待求解参数, U 表征分解后的波动频谱, n 表征简化后的正弦函数个数。

据式(2), 定义影响项位移 $e(r_i, w_i)$ 表达为

$$\left. \begin{aligned} e(r_i, w_i) &= \text{sum}(e_j(r_i, w_i)) \\ e_j(r_i, w_i) &= IMFj - w_j(t) \quad (j=2, 3) \end{aligned} \right\} \quad (16)$$

为了确定最大化与外界影响特征间相关性的影响项位移, 设定遗传特征优化(Genetic Algorithm, GA)模型, 如下:

遗传算法于 1975 年由 Holland 教授提出, 该优化算法的计算原理已由众多学者介绍, 文中不做赘述。

据前述理论, 设定适应度函数 FIT 为

$$FIT = \text{sum}(r(x_i, e_j(r_i, w_i))) \quad (17)$$

式中: $r(x_i, e_j(r_i, w_i))$ 为各项外界影响特征与影响项位移之间的相关性系数矩阵。

由于该问题寻优较为简单, 因此, 设定遗传算法各阶段计算模型如表 2 所示。

表 2 遗传算法各阶段计算模型

Table 2 The calculation model of each stage of Genetic Algorithm

遗传算法阶段	拟选择模型
选择阶段	轮盘赌选择模型
交叉阶段	单点交叉模型
变异阶段	单点变异模型
重组阶段	-

综上, 有 GA 优化模型的计算流程如图 9 所示。

4.3 重构结果

据 GA 特征优化模型原理, 经验上, 设定种群数量 $NP=30$, 交叉算子 $q_1=0.8$, 变异算子 $q_2=0.1$, 迭代次数 $M_2=500$, 取 $IMF2$ 与 $IMF3$ 正弦波动函数个数 $n=3$ 。

滑坡波动项位移计算时, 一般以年为计算波动周期, 因此, 取正弦波动函数周期基准值 T 为 12 个月, 设置波动项位移实际周期变换系数为 b_i , 初始相位系数为 c_i , 有




图9 GA 优化模型计算流程

Fig.9 Flow chart of GA optimization model

$$\left. \begin{aligned} T &= 12 \\ B_i &= b_i \frac{2\pi}{T} \\ C_i &= c_i T \end{aligned} \right\} \quad (18)$$

经验上, 取 b_i 与 c_i 参数的计算范围为

$$\begin{bmatrix} b_i \\ c_i \end{bmatrix} = \begin{bmatrix} [0.8, 1.2] \\ [0, 1] \end{bmatrix} \quad (19)$$

综上, 设定待优化参数取值范围如下:

(1) 当待求解曲线为 $IMF2$ 曲线时, 根据 $IMF2$ 曲线的数值范围, 确定常数项 U_0 与振幅 A_i 的取值范围; 同时, 据前述周期的设定, 确定 B_i 与 C_i 的取值范围。综合设定的待优化参数取值范围为

$$\begin{bmatrix} U_0 \\ A_i \\ B_i \\ C_i \end{bmatrix} = \begin{bmatrix} [-20, 20] \\ [-50, 50] \\ [\frac{2\pi}{15}, \frac{\pi}{5}] \\ [0, 12] \end{bmatrix} \quad (i=1, 2, 3) \quad (20)$$



(2) 当待求解曲线为 $IMF3$ 曲线时, 根据 $IMF3$ 曲线的数值范围, 确定常数项 U_0 与振幅 A_i 的取值范

围; 同时, 据前述周期的设定, 确定 B_i 与 C_i 的取值范围。综合设定的待优化参数取值范围为

$$\begin{bmatrix} U_0 \\ A_i \\ B_i \\ C_i \end{bmatrix} = \begin{bmatrix} [-15, 15] \\ [-30, 30] \\ [\frac{2\pi}{15}, \frac{\pi}{5}] \\ [0, 12] \end{bmatrix} \quad (i=1, 2, 3) \quad (21)$$

综上, 将设置好的各参数及 $IMF2$, $IMF3$ 数据代入 GA 特征优化模型进行迭代计算, 得到如下结果:

以适应度 FIT 出现较大变化时的点作为一次进化点, 得到 GA 特征优化模型下各进化点 (E_i , $i=1, 2, \dots, n$) 外界影响特征与 $IMF2$, $IMF3$ 曲线之间的相关性热图, 如图 10, 11 所示。

图10 ZG118 监测点 $IMF2$ 与 $IMF3$ 曲线各进化点相关性热图Fig.10 Correlation heatmap of $IMF2$ and $IMF3$ curves at various evolutionary points of ZG118图11 ZG93 监测点 $IMF2$ 与 $IMF3$ 曲线各进化点相关性热图Fig.11 Correlation heatmap of $IMF2$ and $IMF3$ curves at various evolutionary points of ZG93

据图 10 与 11，得到 ZG118 监测点与 ZG93 监测点 $IMF2$ ， $IMF3$ 曲线经优化后的最优适应度分别为 $\{3.220\ 2, 3.253\ 5\}$ ； $\{3.170\ 9, 3.450\ 0\}$ 。

计算得到优化后的 ZG118 与 ZG93 监测点 $IMF2$ ， $IMF3$ 曲线的内部波动频谱分布如图 12 与 13 所示。

据图 12 与 13，得到 ZG118 与 ZG93 监测点 $IMF2$ ， $IMF3$ 曲线内部存在的波动项位移情况如表 3 所示。

据式(15)与表 3，得到监测点内部存在的波动项位移函数 $w(t)$ 表达分别为

$$w(t)_{ZG118} = w_2(t)_{ZG118} + w_3(t)_{ZG118} =$$
$$\sum_{i=0}^3 U_{n_ZG118_IMF2} + \sum_{i=0}^3 U_{n_ZG118_IMF3} \quad (22)$$

$$w(t)_{ZG93} = w_2(t)_{ZG93} + w_3(t)_{ZG93} =$$
$$\sum_{i=0}^3 U_{n_ZG93_IMF2} + \sum_{i=0}^3 U_{n_ZG93_IMF3} \quad (23)$$




图 12 ZG118 监测点 $IMF2$ 与 $IMF3$ 曲线内部波动频谱图
Fig.12 Fluctuation spectrums of $IMF2$ and $IMF3$ curves at ZG118




图 13 ZG93 监测点 $IMF2$ 与 $IMF3$ 曲线内部波动频谱图
Fig.13 Fluctuation spectrums of $IMF2$ and $IMF3$ curves at ZG93

据式(16)，得到经分解重构后的影响项位移 $e(r_i, w_i)$ 计算表达分别为

$$e(r_i, w_i)_{ZG118} = e_2(r_i, w_i)_{ZG118} + e_3(r_i, w_i)_{ZG118} =$$
$$IMF2_{ZG118} + IMF3_{ZG118} - w(t)_{ZG118} \quad (24)$$

$$e(r_i, w_i)_{ZG93} = e_2(r_i, w_i)_{ZG93} + e_3(r_i, w_i)_{ZG93} =$$
$$IMF2_{ZG93} + IMF3_{ZG93} - w(t)_{ZG93} \quad (25)$$

根据线性相关原理，影响项位移分项经线性组合后的影响项位移与外界影响特征间仍具有较好的相关性。根据计算，得到外界影响特征与影响项位移间相关性热图，如图 14 所示，该图也进一步证明了重构后的影响项位移与外界影响特征间具有较好的相关性。

经 GA 算法重构所得波动项位移与影响项位移的模糊熵 FE 值较 $IMF2$ 曲线与 $IMF3$ 曲线较小，重构后的位移并未提高序列的复杂程度。

综上所述，得到 ZG118 与 ZG93 监测点波动项位移曲线与影响项位移曲线如图 15 所示。

表 3 ZG118 与 ZG93 监测点 $IMF2$ ， $IMF3$ 曲线内部波动项位移情况表

Table 3 Table of internal fluctuation displacement of $IMF2$ and $IMF3$ curves at ZG118 and ZG93

监测点编号	曲线类型	内部波动项位移情况			
		U_0	U_1	U_2	U_3
ZG118	$IMF2$	-3.281 6	-49.941 9sin(0.527 5t+1.411 6)	-49.996 1sin(0.487 9t+10.056 0)	-49.942 2sin(0.576 0t+4.771 7)
	$IMF3$	-13.260 4	-29.988 6sin(0.576 4t+10.899 8)	-29.997 1sin(0.513 7t+2.072 7)	-29.997 0sin(0.493 5t+3.191 0)
ZG93	$IMF2$	-3.055 5	-49.997 8sin(0.523 4t+1.557 7)	49.981 9sin(0.485 1t+0.825 1)	-49.994 8sin(0.523 6t+1.494 1)
	$IMF3$	10.433 0	30.000 0sin(0.526 7t+4.471 4)	29.994 8sin(0.514 1t+5.206 2)	29.988 5sin(0.527 3t+4.438 1)




图 14 外界影响特征与影响项位移间相关性热图

Fig.14 Correlation heatmap between external influence characteristics and influence displacement




图 15 ZG118 与 ZG93 监测点波动项位移与影响项位移曲线

Fig.15 Fluctuation displacement and influence displacement curves at ZG118 and ZG93

5 滑坡位移预测

5.1 趋势项与波动项位移预测

据图 4 与 7, PSO-VMD 模型分解后的 IMF1 曲线具有一定的蠕滑特征,但由于 VMD 分解方法特性,IMF1 曲线在域内的二阶微分变化情况与西原蠕变曲线有差异,直接采用西原蠕变模型拟合预测 IMF1 曲线的效果较差。

因此,为了顾及趋势项位移的蠕滑特征及拟合预测效果,对式(4)进行泰勒展开,忽略高阶影响,得到新型西原蠕变模型泰勒展开拟合式为

$$\hat{c}(t) = a_2 t^3 + b_2 t^2 + c_2 t + d \quad (26)$$

若使得式(26)的二阶微分恒小于 0,则下式需成立:

$$b_2 < -3a_2 t \quad (27)$$

据式(27),变换 b_2 会影响拟合曲线的单调性,因此,为了保证拟合预测效果,以训练区段与预测区段内拟合曲线单调递增为条件,在充分考虑蠕滑曲线形态影响的情况下,设定参数 b_2 的拟合上限值。

经计算,取 ZG118 与 ZG93 监测点趋势项位移拟合参数 b_2 的拟合上限值分别为 1.1 和 1。

综上,分别运用式(26)对 ZG118 与 ZG93 监测点的趋势项位移训练数据进行拟合,得到表达式如下:

当分析监测点为 ZG118 点时,最小二乘拟合求解得到如下式:

$$\hat{c}(t) = -0.008\,068t^3 + 1.1t^2 - 11.48t - 39.56 \quad (28)$$

当分析监测点为 ZG93 点时,最小二乘拟合求解得到如下式:

$$\hat{c}(t) = -0.007\,691t^3 + t^2 - 1.883t - 279.3 \quad (29)$$

据式(28)与(29),得到 ZG118 与 ZG93 监测点趋势项位移拟合预测图如图 16 所示。




图 16 ZG118 与 ZG93 监测点趋势项位移拟合预测图

Fig.16 Prediction of trend displacement at ZG118 and ZG93

同时,据表 3,式(22)及(23)波动项位移表达,得到 ZG118 与 ZG93 监测点的波动项位移预测结果如图 17 所示。

5.2 影响项与随机项位移预测

(1) CNN-SE-GRU 预测模型

据图 14,对于影响项位移,提出一种多变量时间序列预测模型:CNN-SE-GRU 模型,建立方式如下:

卷积神经网络(convolutional neural network, CNN)在多变量时间序列预测中用于提取变量的深




图 17 ZG118 与 ZG93 监测点波动项位移拟合预测图

Fig.17 Prediction of fluctuation displacement at ZG118 and ZG93

层次特征^[40], 考虑到数据特征及复杂度, 以 CNN 模型中较为经典的残差神经网络^[41](ResNet)作为本文的特征提取卷积神经网络模型, ResNet 网络原理见 K. M. He 等^[41]研究, 文中不做赘述。为了促进梯度的反向传播, 更好地提取重要特征, 为 ResNet 网络添加 SE(squeeze and excitation blocks)注意力机制^[42]。

相较于 LSTM(long short-term memory)神经网络, 门控循环神经网络^[43](gate recurrent unit, GRU)的运算速度更快, 效率更高^[44]。因此, 本文选用 GRU 模型作为预测模型的主要回归预测模型, GRU 模型计算原理与结构见 J. Chung 等^[43]研究, 文中不再进行赘述。

综上, 建立 CNN-SE-GRU 模型, 计算结构如图 18 所示。

(2) 影响项位移预测结果

据图 14, 选取优化后相关性较好的外界影响特征(V_{i-2} , V_{i-3} , R_i , R_{i-1})作为多维特征输入, 同时, 为了统一量纲, 设置输入的多维影响特征 $\{X_i, i = 1, 2, \dots, N\}$ 的归一化方式为

$$x_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (30)$$




图 18 CNN-SE-GRU 模型计算结构

Fig.18 Calculation Structure of CNN-SE-GRU Model

据图 18, 设置 CNN 网络参数: 卷积 1 层核长 $N_1=2$, 通道数 $C_1=32$, 卷积 2 层核长 $N_2=3$, 通道数 $C_2=64$, SE 注意力机制下的重新校正通道数 $C_3=0.25C_2$; 设置 GRU 网络超参数: 迭代次数为 500, 初始学习率为 0.01, 300 次迭代后学习率变为 0.001, 隐藏单元个数为 6。

以影响项位移训练区段均方误差 MSE 为损失函数进行模型训练, MSE 计算表达为

$$MSE = \frac{1}{n} \sum_{i=1}^n (e_i - \hat{e}_i)^2 \quad (31)$$

式中: e 为影响项位移真实值, $\hat{e}$ 为影响项位移模型训练值。

训练区段外界影响特征经 CNN-SE 模块运算后输入 GRU 中迭代 500 次会得到收敛结果, 但在预测区段, 该特征组合可能并不是最优结果, 随机性较大, 为此, 重复运行 CNN-SE-GRU 模型 10 次, 取均值作为本文的影响项位移预测结果, 增强预测模型的稳定性。得到 ZG118 与 ZG93 监测点的影响项位移预测结果如图 19 所示。

(3) KDE 区间估计与随机项位移预测结果

训练区段内, 趋势项位移、波动项位移及影响项位移预测叠加后的位移与总位移之间仍有拟合误差, 该误差对预测结果有较大影响, 因此, 定义该拟合误差为随机项位移, 表达如下:

$$\hat{e}(\mu) = c(t) - \hat{c}(t) + e(r_i, w_i) - \hat{e}(r_i, w_i) \quad (32)$$

式中: $\hat{e}(r_i, w_i)$ 为训练区段内影响项位移预测模型训练结果。

随机项位移是一种拟合误差, 误差具有随机性与传递性, 因此, 首先运用 KDE^[45-46](kernel density estimation)区间估计方法, 通过训练区段内随机项位移的变化范围, 估计预测区段随机项位移的置信变化范围, 对预测区段内随机项位移加以约束。KDE





图 19 ZG118 与 ZG93 监测点影响项位移预测结果


Fig.19 Prediction results of influence displacement at ZG118 and ZG93

区间估计原理见郭田丽等^[47]研究, 文中不做赘述, 核函数带宽拟合计算时采用最小二乘法。

综上, 计算得到核函数密度估计结果如图 20 所示。最小二乘拟合得到的带宽分别为 38.502 7 与 40.941 5。得到 ZG118 与 ZG93 监测点总位移预测区段区间估计结果如图 21 所示。




(a) ZG118




(b) ZG93

图 20 ZG118 与 ZG93 监测点核密度概率函数估计结果

Fig.20 Estimation results of kernel density probability function for ZG118 and ZG93



(a) ZG118




(b) ZG93

图 21 ZG118 与 ZG93 监测点总位移预测区段区间估计结果

Fig.21 Interval estimation results of total displacement prediction section for ZG118 and ZG93

为了解决误差预测随机问题, 提高预测模型稳定性, 据图 21, 在区间估计范围内, 运用 GWO-ELM 模型^[18]对随机项位移进行预测, GWO-ELM 模型原理见廖 康等^[18]研究成果, 文中不做赘述。

经验上, 设定 GWO 算法种群数量为 20, 迭代次数为 100, ELM 算法隐藏层神经元个数为 40。同时, 取区间估计内的 10 次模型训练后的预测结果均值作为最终预测结果, 以前一年的拟合误差作为变量进行输入, 得到 ZG118 与 ZG93 监测点随机项位移预测结果如图 22 所示。



(a) ZG118




图 22 ZG118 与 ZG93 监测点随机项位移预测结果
Fig.22 Random displacement prediction results of ZG118 and ZG93

5.3 预测结果分析

综上，据式(2)，将趋势项位移、波动项位移、影响项位移、随机项位移预测结果相加后，得到 ZG118 与 ZG93 的整体预测结果如图 23 所示。




图 23 ZG118 与 ZG93 监测点水平位移预测结果
Fig.23 Prediction results of horizontal displacement at ZG118 and ZG93

以均方根误差 $RMSE$ 与平均绝对百分比误差 $MAPE$ 作为模型评价指标，得到 ZG118 与 ZG93 监测点预测模型的 $RMSE$ 分别为 5.847 5 与 10.616 4 mm， $MAPE$ 分别为 0.27%与 0.43%，模型预测效果良好。

为对比文中预测模型与其他模型的预测效果，以外界因素特征，时间特征及滑坡位移历史数据混合作为特征输入，得到 CNN-SE-LSTM/GRU 模型，GWO-ELM 模型，VMD-GWO-ELM 模型，EEMD-CNN-GRU 模型预测结果如表 4 所示。

表 4 不同预测模型性能对比

Table 4 Performance comparison of different prediction models

模型名称	$RMSE/mm$		$MAPE/\%$	
	ZG118	ZG93	ZG118	ZG93
CNN-SE-LSTM/GRU	154.76/109.22	142.37/84.34	8.80/7.29	7.94/6.31
GWO-ELM	18.85	24.67	1.43	2.90
VMD-GWO-ELM	12.41	10.83	0.58	0.44
EEMD-CNN-GRU	38.95	30.13	1.86	1.41
文中预测模型	5.85	10.62	0.27	0.43

据本文的模型预测结果与表 4 模型预测结果，以 $RMSE$ 为预测性能评价指标，对于 ZG118 监测点，本文提出的预测模型较 CNN-SE-LSTM/GRU 模型：GWO-ELM 模型、VMD-GWO-ELM 模型及 EEMD-CNN-GRU 模型分别降低了 96.22%/94.64%，68.97%，52.86%及 84.98%；对于 ZG93 监测点，本文提出的预测模型较 CNN-SE-LSTM/GRU 模型、GWO-ELM 模型、VMD-GWO-ELM 模型及 EEMD-CNN-GRU 模型分别降低了 92.54%/87.41%，69.37%，1.94%及 64.75%，预测精度有所提升。同时，预测模型还清晰地分离出了各类特征影响的滑坡位移部分，增强了模型的可解释性与泛化能力。

6 结 论

(1) 基于西原蠕变理论建立的 PSO-VMD 模型及趋势项位移拟合预测模型具有较好的力学可解释性。

(2) GA 特征优化算法对其他模态曲线进行分离重构后得到具有傅里叶波动特征的波动项位移及最大化与外界影响特征间相关性的影响项位移，同时将训练区段的拟合误差作为随机项位移，清晰地分离出了各类特征影响的滑坡位移部分，增强了模型的可解释性与泛化能力。

(3) 以均方根误差 $RMSE$ 与平均绝对百分比误差 $MAPE$ 作为预测模型的评价指标，本文提出的预测模型整体预测效果：ZG118 与 ZG93 监测点水平位移预测模型的 $RMSE$ 分别为 5.847 5 与 10.616 4 mm， $MAPE$ 分别为 0.27%与 0.43%，模型预测效果良好，且与以往预测模型相比，预测精度有所提升。

同时，本文研究仍存在不足之处：(1) 对于人类活动或地震等偶然强应力产生的滑坡位移，预测效果不准确；(2) 西原蠕变模型无法拟合加速蠕变阶段及临滑阶段的滑坡趋势项位移。如何有效解决这些问题，还需做进一步研究与探讨。

参考文献(References):

[1] 段梦凡. 基于 GRU 的边坡位移预测研究[硕士学位论文][D]. 石家庄: 石家庄铁道大学, 2022.(DUAN Mengfan. Study on slope displacement prediction based on GRU[M. S. Thesis][D]. Shijiazhuang: Shijiazhuang Tiedao University, 2022.(in Chinese))

[2] 李振洪, 宋 闯, 余 琛, 等. 卫星雷达遥感在滑坡灾害探测和监测中的应用: 挑战与对策[J]. 武汉大学学报: 信息科学版, 2019,

- 44(7): 967 – 979.(LI Zhenhong, SONG Chuang, YU Chen, et al. Application of satellite radar remote sensing to landslide detection and monitoring: Challenges and solutions[J]. Geomatics and Information Science of Wuhan University, 2019, 44(7): 967 – 979.(in Chinese))
- [3] 许强, 汤明高, 徐开祥, 等. 滑坡时空演化规律及预警预报研究[J]. 岩石力学与工程学报, 2008, 27(6): 1 104 – 1 112.(XU Qiang, TANG Minggao, XU Kaixiang, et al. Research on space-time evolution laws and early warning-prediction of landslides[J]. Chinese Journal of Rock Mechanics and Engineering, 2008, 27(6): 1 104 – 1 112.(in Chinese))
- [4] 冯谔, 涂鹏飞, 曾怀恩. 降雨及库水位共同作用下滑坡阶跃位移临界面的识别方法[J]. 岩石力学与工程学报, 2023, 42(11): 2 788 – 2 805.(FENG Yu, TU Pengfei, ZENG Huaen. A method for identifying critical displacement threshold of landslide step under combined effects of rainfall and reservoir water level[J]. Chinese Journal of Rock Mechanics and Engineering, 2023, 42(11): 2 788 – 2 805.(in Chinese))
- [5] ZHANG Y G, TANG J, HE Z Y, et al. A novel displacement prediction method using gated recurrent unit model with time series analysis in the Erdaohe landslide[J]. Natural Hazards, 2021, 105(1): 783 – 813.
- [6] 黄发明, 殷坤龙, 杨背背, 等. 基于时间序列分解和多变量混沌模型的滑坡阶跃式位移预测[J]. 地球科学, 2018, 43(3): 887 – 898.(HUANG Faming, YIN Kunlong, YANG Beibei, et al. Step-like displacement prediction of landslide based on time series decomposition and multivariate chaotic model[J]. Earth Science, 2018, 43(3): 887 – 898.(in Chinese))
- [7] 宋丽伟. 基于经验模态分解和 LSTM 模型的滑坡位移预测[J]. 人民长江, 2020, 51(5): 144 – 148.(SONG Liwei. Landslide displacement prediction based on empirical mode decomposition and long short-term memory neural network model[J]. Yangtze River, 2020, 51(5): 144 – 148.(in Chinese))
- [8] 邓冬梅, 梁 烨, 王亮清, 等. 基于集合经验模态分解与支持向量机回归的位移预测方法: 以三峡库区滑坡为例[J]. 岩土力学, 2017, 38(12): 3 660 – 3 669.(DENG Dongmei, LIANG Ye, WANG Liangqing, et al. Displacement prediction method based on ensemble empirical mode decomposition and support vector machine regression—A case of landslides in Three Gorges Reservoir area[J]. Rock and Soil Mechanics, 2017, 38(12): 3 660 – 3 669.(in Chinese))
- [9] 李龙起, 王梦云, 赵皓璆, 等. 基于 CEEMDAN-BA-SVR-Adaboost 模型的白水河滑坡位移预测[J]. 长江科学院院报, 2021, 38(6): 52 – 59.(LI Longqi, WANG Mengyun, ZHAO Haoqiu, et al. Predicting displacement of baishuihe landslide using CEEMDAN-BA-SVR-adaboost model[J]. Journal of Yangtze River Scientific Research Institute, 2021, 38(6): 52 – 59.(in Chinese))
- [10] 李 博, 李 欣, 芮 红, 等. 基于变分模态分解和灰狼优化极限学习机的隧道口边坡位移预测[J]. 吉林大学学报: 工学版, 2023, 53(6): 1 853 – 1 860.(LI Bo, LI Xin, RUI Hong, et al. Displacement prediction of tunnel entrance slope based on variational model decomposition and grey wolf optimized extreme learning machine[J]. Journal of Jilin University: Engineering and Technology, 2023, 53(6): 1 853 – 1 860.(in Chinese))
- [11] 李麟玮, 吴益平, 苗发盛, 等. 基于变分模态分解与 GWO-MIC-SVR 模型的滑坡位移预测研究[J]. 岩石力学与工程学报, 2018, 37(6): 1 395 – 1 406.(LI Linwei, WU Yiping, MIAO Fasheng, et al. Displacement prediction of landslide based on variational mode decomposition and GWO-MIC-SVR model[J]. Chinese Journal of Rock Mechanics and Engineering, 2018, 37(6): 1 395 – 1 406.(in Chinese))
- [12] 杨背背, 殷坤龙, 杜 娟. 基于时间序列与长短时记忆网络的滑坡位移动态预测模型[J]. 岩石力学与工程学报, 2018, 37(10): 2 334 – 2 343.(YANG Beibei, YIN Kunlong, DU Juan. A model for predicting landslide displacement based on time series and long and short term memory neural network[J]. Chinese Journal of Rock Mechanics and Engineering, 2018, 37(10): 2 334 – 2 343.(in Chinese))
- [13] GUO Z Z, CHEN L X, GUI L, et al. Landslide displacement prediction based on variational mode decomposition and WA-GWO-BP model[J]. Landslides, 2020, 17(3): 567 – 583.
- [14] 彭 令, 牛瑞卿, 吴 婷. 时间序列分析与支持向量机的滑坡位移预测[J]. 浙江大学学报: 工学版, 2013, 47(9): 1 672 – 1 679.(PENG Ling, NIU Ruiqing, WU Ting. Time series analysis and support vector machine for landslide displacement prediction[J]. Journal of Zhejiang University: Engineering Science, 2013, 47(9): 1 672 – 1 679.(in Chinese))
- [15] 周 超, 殷坤龙, 黄发明. 混沌序列 WA-ELM 耦合模型在滑坡位移预测中的应用[J]. 岩土力学, 2015, 36(9): 2 674 – 2 680.(ZHOU Chao, YIN Kunlong, HUANG Faming. Application of the chaotic sequence WA-ELM coupling model in landslide displacement prediction[J]. Rock and Soil Mechanics, 2015, 36(9): 2 674 – 2 680.(in Chinese))
- [16] 张 俊, 殷坤龙, 王佳佳, 等. 基于时间序列与 PSO-SVR 耦合模型的白水河滑坡位移预测研究[J]. 岩石力学与工程学报, 2015, 34(2): 382 – 391.(ZHANG Jun, YIN Kunlong, WANG Jiajia, et al. Displacement prediction of baishuihe landslide base on time series and pso-svr model[J]. Chinese Journal of Rock Mechanics and Engineering, 2015, 34(2): 382 – 391.(in Chinese))
- [17] 李麟玮. 三峡库区库岸堆积层滑坡位移预测与稳定性评价方法研

- 究[博士学位论文][D]. 武汉: 中国地质大学, 2021.(LI Linwei. Displacement prediction and stability evaluation methods of reservoir colluvial landslides in Three Gorges Reservoir area[Ph. D. Thesis][D]. Wuhan: China University of Geosciences, 2021.(in Chinese))
- [18] 廖 康, 吴益平, 李麟玮, 等. 基于时间序列与 GWO-ELM 模型的滑坡位移预测[J]. 中南大学学报: 自然科学版, 2019, 50(3): 619 - 626.(LIAO Kang, WU Yiping, LI Linwei, et al. Displacement prediction model of landslide based on time series and GWO-ELM[J]. Journal of Central South University: Science and Technology, 2019, 50(3): 619 - 626.(in Chinese))
- [19] 薛 阳, 吴益平, 苗发盛, 等. 库水升降条件下考虑饱和和渗透系数空间变异性的白水河滑坡渗流变形分析[J]. 岩土力学, 2020, 41(5): 1 709 - 1 720.(XUE Yang, WU Yiping, MIAO Fasheng, et al. Seepage and deformation analysis of Baishuihe landslide considering spatial variability of saturated hydraulic conductivity under reservoir water level fluctuation[J]. Rock and Soil Mechanics, 2020, 41(5): 1 709 - 1 720.(in Chinese))
- [20] MIAO F, WU Y, XIE Y, et al. Prediction of landslide displacement with step-like behavior based on multialgorithm optimization and a support vector regression model[J]. Landslides, 2018, (15): 475 - 488.
- [21] 叶振南. 三峡库区白水河滑坡复活机理与活动趋势预测[硕士学位论文][D]. 北京: 中国地质大学(北京), 2014.(YE Zhennan. Reactivation mechanism analysis and dynamic behavior prediction for the Baishuihe landslide in Three Gorges Reservoir Area[M. S. Thesis][D]. Beijing: China University of Geosciences(Beijing), 2014.(in Chinese))
- [22] 张倬元, 王仕天, 王兰生. 工程地质分析原理[M]. 4 版. 北京: 地质出版社, 2016: 276 - 277.(ZHANG Zhuoyuan, WANG Shitian, WANG Lansheng. Principles of engineering geology analysis[M]. 4th ed. Beijing: Geology Press, 2016: 276 - 277.(in Chinese))
- [23] 冯 谕, 曾怀恩, 涂鹏飞. 一种滑动检测算法下的滑坡位移时序分解方法[J]. 长江科学院院报, 2024, 41(3): 126 - 133.(FENG Yu, ZENG Huaen, TU Pengfei. A time series decomposition method of landslide displacement based on sliding detection algorithm[J]. Journal of Yangtze River Scientific Research Institute, 2024, 41(3): 126 - 133.(in Chinese))
- [24] XU T, XU Q, TANG C A, et al. The evolution of rock failure with discontinuities due to shear creep[J]. Acta Geotechnica, 2013, 8(6): 567 - 581.
- [25] 董秀军, 许 强, 唐 川, 等. 滑坡位移-时间曲线特征的物理模拟试验研究[J]. 工程地质学报, 2015, 23(3): 401 - 407.(DONG Xiujun, XU Qiang, TANG Chuan, et al. Characteristics of landslide displacement-time curve by physical simulation experiment[J]. Journal of Engineering Geology, 2015, 23(3): 401 - 407.(in Chinese))
- [26] 陈 浩, 杨春和, 任伟中. 蠕动滑坡变形机制的理论分析与模型试验研究[J]. 岩石力学与工程学报, 2008, 27(增 2): 3 705 - 3 711.(CHEN Hao, YANG Chunhe, REN Weizhong. Theoretical analysis and model test study on deformation mechanism of creep landslide[J]. Chinese Journal of Rock Mechanics and Engineering, 2008, 27(Supp.2): 3 705 - 3 711.(in Chinese))
- [27] 何云明, 吴德伦. 岩质边坡蠕变模型及其蠕变机制研究[C]// 第八次全国岩石力学与工程学术大会论文集. [S. l.]: [s. n.], 2004: 723 - 728.(HE Yunming, WU Delun. Study on the creep model and creep mechanism of rock slope[C]// Proceedings of the Eighth National Congress of Rock Mechanics and Engineering. [S. l.]: [s. n.], 2004: 723 - 728.(in Chinese))
- [28] 齐亚静, 姜清辉, 王志俭, 等. 改进西原模型的三维蠕变本构方程及其参数辨识[J]. 岩石力学与工程学报, 2012, 31(2): 347 - 355.(QI Yajing, JIANG Qinghui, WANG Zhijian, et al. 3D creep constitutive equation of modified nishihara model and its parameters identification[J]. Chinese Journal of Rock Mechanics and Engineering, 2012, 31(2): 347 - 355.(in Chinese))
- [29] DRAGOMIRETSKIY K, ZOZZO D. Variational mode decomposition[J]. ISSE Transactions on Signal Processing, 2014, 62(3): 531 - 544.
- [30] EBERHART R, KENNEDY J. A new optimizer using particle swarm theory[C]// Proceedings of the Sixth International Symposium on Micro Machine and Human Science. Nagoya, Japan: IEEE, 1995: 39 - 43.
- [31] CHEN W T, WANG Z Z, XIE H G, et al. Characterization of surface EMC signal based on fuzzy entropy[J]. ISSE Transactions on Neural Systems and Rehabilitation Engineering, 2007, 15(2): 267 - 272.
- [32] 刘 慧, 谢洪波, 和卫星, 等. 基于模糊熵的脑电睡眠分期特征提取与分类[J]. 数据采集与处理, 2010, 25(4): 484 - 489.(LIU Hui, XIE Hongbo, HE Weixing, et al. Characterization and classification of eeg sleep stage based on fuzzy entropy[J]. Journal of Data Acquisition and Processing, 2010, 25(4): 484 - 489.(in Chinese))
- [33] 吴益平, 张秋霞, 唐辉明, 等. 基于有效降雨强度的滑坡灾害危险性预警[J]. 地球科学: 中国地质大学学报, 2014, 39(7): 889 - 895.(WU Yiping, ZHANG Qiuxia, TANG Huiming, et al. Landslide hazard warning based on effective rainfall intensity[J]. Earth Science—Journal of China University of Geosciences, 2014, 39(7): 889 - 895.(in Chinese))
- [34] 郭 璐, 贺可强, 周 云, 等. 水库型滑坡复合水动力增载位移响应比物理预测模型及其应用[J]. 工程地质学报, 2022, 30(5): 1 561 - 1 572.(GUO Lu, HE Keqiang, ZHOU Yun, et al. Physical prediction

- model and application of compound hydrodynamic displacement response ratio with dynamics increment in reservoir landslide[J]. Journal of Engineering Geology, 2022, 30(5): 1 561 - 1 572.(in Chinese))
- [35] 卢书强, 易庆林, 易 武, 等. 库水下降作用下滑坡动态变形机制分析——以三峡库区白水河滑坡为例[J]. 工程地质学报, 2014, 22(5): 869 - 875.(LU Shuqiang, YI Qinglin, YI Wu, et al. Study on dynamic deformation mechanism of landslide in drawdown of reservoir water level—Take Baishuihe landslide in Three Gorges Reservoir Area for example[J]. Journal of Engineering Geology, 2014, 22(5): 869 - 875.(in Chinese))
- [36] 高晨曦, 刘艺梁, 薛 欣, 等. 三峡库区典型堆积层滑坡变形滞后时间效应研究[J]. 工程地质学报, 2021, 29(5): 1 427 - 1 436.(GAO Chenxi, LIU Yiliang, XUE Xin, et al. Study on deformation lag time effect of typical colluvial landslide in Three Gorges Reservoir Area[J]. Journal of Engineering Geology, 2021, 29(5): 1 427 - 1 436.(in Chinese))
- [37] 肖捷夫. 库水涨落和降雨条件下藕塘滑坡变形演化机制及其预测模型研究[博士学位论文][D]. 武汉: 中国地质大学, 2021.(XIAO Jiefu. Deformation evolution mechanism and displacement prediction model of outang landslide under water level fluctuation and rainfall[Ph. D. Thesis][D]. Wuhan: China University of Geosciences, 2021.(in Chinese))
- [38] 朱智杰, 卢书强, 梅 军. 基于有效降雨量的滑坡位移-降雨相关性研究[J]. 长江科学院院报, 2023, 40(12): 162 - 168.(ZHU Zhijie, LU Shuqiang, MEI Jun. Study on landslide displacement-rainfall correlation based on effective rainfall[J]. Journal of Yangtze River Scientific Research Institute, 2023, 40(12): 162 - 168.(in Chinese))
- [39] 高华喜, 殷坤龙. 降雨与滑坡灾害相关性分析及预警预报阈值之探讨[J]. 岩土力学, 2007, 28(5): 1 055 - 1 060.(GAO Huaxi, YIN Kunlong. Discuss on the correlations between landslides and rainfall and threshold for landslide early-warning and prediction[J]. Rock and Soil Mechanics, 2007, 28(5): 1 055 - 1 060.(in Chinese))
- [40] 李志刚, 张 鑫. CNN-GRU 模型预测高炉煤气产生量[J]. 机械设计与制造, 2022, (4): 69 - 72.(LI Zhigang, ZHANG Xin. CNN-GRU model predicts blast furnace gas production[J]. Machinery Design and Manufacture, 2022, (4): 69 - 72.(in Chinese))
- [41] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2016: 770 - 778.
- [42] HU J, SHEN L, SUN G, et al. Squeeze-and-excitation networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2018: 7 132 - 7 141.
- [43] CHUNG J, GUICEHRE C, CHO K, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[Z]. arXiv Preprint arXiv, 2014, 1412. 3555.
- [44] LEE D H, KIM K. PV power prediction in a peak zone using recurrent neural networks in the absence of future meteorological information[J]. Renewable Energy, 2021, 173: 1 098 - 1 110.
- [45] ROSENBLATT M. Remarks on some nonparametric estimates of a density function[J]. The Annals of Mathematical Statistics, 1956, 27: 832 - 837.
- [46] PARZEN E. On estimation of probability density function and mode[J]. The Annals of Mathematical Statistics, 1962, 33(3): 1 065 - 1 076.
- [47] 郭田丽, 宋松柏, 张 特, 等. 基于两阶段粒子群优化算法的新型逐步分解集成径流预测模型[J]. 水利学报, 2022, 53(12): 1 456 - 1 466.(GUO Tianli, SONG Songbai, ZHANG Te, et al. A new stepwise decomposition ensemble model based on two-stage particle swarm optimization algorithm for the runoff prediction[J]. Journal of Hydraulic Engineering, 2022, 53(12): 1 456 - 1 466.(in Chinese))