第 41 卷 第 2 期
2025 年 6 月

华 南 地 质
South China Geology

Vol.41, No.2, 277−287
Jun., 2025

doi:10.3969/j.issn.2097-0013.2025.02.003

# 考虑时间序列的阶跃型滑坡位移预测——以三峡库区墓坪滑坡为例

闫　巍[1,2], 潘安邦[1,2*], 龙晶晶[1,2], 侯时平[1,2], 高晨曦[1,2], 刘明鑫[1,2]

YAN Wei[1,2], PAN An-Bang[1,2*], LONG Jing-Jing[1,2], HOU Shi-Ping[1,2], GAO Chen-Xi[1,2], LIU Ming-Xin[1,2]

1. 湖北省地质局水文地质工程地质大队, 湖北 荆州 434020;
2. 湖北省地质局资源与生态环境地质湖北省重点实验室, 湖北 武汉 430034

1. Hydrogeology and Engineering Geology institute of Hubei Geological Bureau, Jingzhou 434020, Hubei, China; 2. Hubei Provincial Key Laboratory of Resources and Ecological Environment Geology, Hubei Geological Bureau, Wuhan 430034, Hubei, China

**摘要:** 本文针对三峡库区呈现阶跃式变形特征的滑坡提出一种考虑时间序列的滑坡位移预测模型, 该模型首先采用互补集合经验模态分解方法(Complementary Ensemble Empirical Mode Decomposition, CEEMD)将滑坡的累计位移分解为趋势项和波动项, 然后采用回归模型拟合趋势项位移; 基于滑坡变形特征与诱发因素的响应分析, 采用长短时记忆神经网络(Long Short-Term Memory, LSTM)模型进行波动项位移预测; 最后将各分项预测位移叠加, 实现滑坡累计位移的预测。以三峡库区阶跃型滑坡——墓坪滑坡为例, 本文采用 CEEMD-LSTM 模型进行位移预测, 并与卷积神经网络(Convolutional Neural Networks, CNN)、随机森林(Random Forest, RF)和改进的粒子群优化-支持向量机 (Particle Swarm Optimization-Support Vector Machine, PSO-SVM)等模型的预测结果进行对比分析。结果表明, 与其他常见的机器学习与深度学习模型相比, 考虑时序的 CEEMD-LSTM 模型的预测精度较高, 且在阶跃点的预测优势较为突出。该模型可为实现三峡库区阶跃型滑坡位移实时预测预报提供理论依据和数据支撑。

**关键词:** 阶跃型滑坡; 时间序列; 互补集合经验模态分解; 长短时记忆神经网络; 墓坪滑坡; 三峡库区

**中图分类号:** P694　　**文献标识码:** A　　**文章编号:** 2097-0013(2025)-02-0277-11

**Yan W, Pan A B, Long J J, Hou S P, Gao C X and Liu M X. 2025. Displacement Prediction of Step-like Landslide Considering Time Series: A Case Study of Muping Landslide in the Three Gorges Reservoir Area. *South China Geology,* 41(2): 277−287.**

**Abstract:** A landslide displacement prediction model considering time series analysis is proposed for the landslides with step-like deformation in the China Three Gorges Reservoir area. The model first employs the Complementary Ensemble Empirical Mode Decomposition (CEEMD) method to decompose the cumulative landslide displacement into trend and fluctuation components. A regression model is then used to fit the trend displacement. Based on the response analysis between landslide deformation characteristics and triggering factors, a Long Short-Term Memory (LSTM) model is adopted to predict the fluctuation displacement. Finally, the predicted displacements of each component are superimposed to achieve cumulative landslide

**收稿日期:** 2025-02-13; **修回日期:** 2025-03-25
**基金项目:** 湖北省自然科学基金联合基金项目(JCZRLH202501152)
**第一作者:** 闫巍(1989—), 男, 工程师, 从事水文地质、工程地质勘查及地质灾害勘查、监测、设计工作, E-mail: 262804378@qq.com
**通讯作者:** 潘安邦(1991—), 男, 工程师, 从事水文地质、工程地质勘查及地质灾害勘查、监测、设计工作, E-mail: 362969505@qq.com

displacement prediction. In this paper, the CEEMD-LSTM model is applied to predict the displacement of Muping landslide in the Three Gorges Reservoir area. Taking the step-like the Muping landslide in the Three Gorges Reservoir area as an example, this study applies the CEEMD-LSTM model for displacement prediction and conducts a comparative analysis with the prediction results of other models, including Convolutional Neural Networks (CNN); Random Forest (RF) and the improved Particle Swarm Optimization-Support Vector Machine (PSO-SVM) models. The results demonstrate that compared to other common machine learning and deep learning models, the time series-aware CEEMD-LSTM model achieves higher prediction accuracy and more prominent prediction advantages at step points. This model could provide theoretical foundations and data support for real-time displacement prediction and early warning of a step-like landslide in the Three Gorges Reservoir area.

**Key words:** step-like landslide; time series; Complementary Ensemble Empirical Mode Decomposition; Long Short-Term Memory; the Muping landslide; the Three Gorges Reservoir area

受三峡水库大幅度蓄水、蓄水后库水位周期性涨落、集中降雨等因素的影响，三峡库区大量老滑坡复活并产生了大量新生滑坡、不稳定斜坡等地质灾害，严重影响库区居民、公路和航道水运安全(卢书强等, 2014)。客观真实地记录滑坡的变形演化过程，了解掌握滑坡的现状以及开展滑坡灾害的准确预测是应对滑坡威胁的有效手段。三峡库区开展的“三峡库区滑坡监测数据资源平台建设”项目对库区典型滑坡灾害开展周期性监测预报与防治研究工作，并构建相应的预报预警平台，进而为政府防灾、减灾决策提供及时、准确、科学的手段和依据。提高监测数据处理效率，建立科学的滑坡预报预警模型是目前亟待解决的问题(高睿等, 2024)。

三峡库区的库水浮托力、水库水位骤降时产生的动水压力，以及库水对滑面岩土体的长期软化作用是导致水库滑坡的主要机制(李长冬等, 2020)。同时，在降雨集中季节，大量雨水冲刷滑坡地表并渗入土体，导致抗剪强度下降，并在滑体内部产生渗透力，从而使得滑坡稳定性减弱。因此，三峡库区普遍发育具有阶跃式变形特征的滑坡。针对这类滑坡，相关学者提出将滑坡位移时间曲线分解为反映自身蠕变趋势项位移和响应外界诱发因素波动项位移(徐峰等, 2011)。目前常用的时间序列曲线分解方法包括移动平均法(周浩等, 2024)、小波分析法(马社祥等, 2000)、经验模态分解(Empirical Model Decomposition, 简称 EMD)(Huang N E et al. 1998)、集合经验模态分解(Ensemble Empirical Mode Decomposition, 简称 EEMD)(Wu Z and Huang N E, 2009)和互补集合经验模态分解方法(Complementary Ensemble Empirical Mode Decomposition, 简称 CEEMD)(Yeh et al. 2010)等方法。其中，在进行时间序列分解时，移动平均法可以有效地消除随机波动，显示出长期趋势，但是预测效果过于依赖以往数据；小波分析方法在局部特征提取及处理非平稳信号领域展现出了显著的优越性，但是需要合理确定小波基。相比之下，模态分解方法则可以更好地处理非线性、非平稳的数据。

一般而言，对于典型阶跃式滑坡的时间-位移曲线，利用各种分解算法得到的滑坡趋势项与时间周期具有较好的线性关系。为了得到较好的拟合结果，通常采用多项式等常规函数来对趋势项进行拟合(邓冬梅等, 2017)；而波动项位移由于受外界诱发因素控制，二者之间具有非常复杂的非线性关系。随着非线性理论的兴起，机器学习、深度学习等被广泛用于滑坡位移预测，并且取得了较好的预测效果(Lian C et al. 2012; 张俊等, 2015; Huang F M et al. 2016; 李麟玮等, 2018; Zhu X et al. 2018)。为进一步提高滑坡预测精度，各种改进的机器学习模型、考虑时间序列的长短时记忆神经网络(Long Short-Term Memory, 简称 LSTM)以及基于卷积神经网络(Convolutional Neural Networks, 简称 CNN)的深度学习模型也广泛应用于

滑坡预测领域(姚琦等, 2017; Li C D et al. 2024)。因此, 本文选取互补集合经验模态分解方法(CEEMD)将滑坡的位移分解为趋势项和波动项, 根据趋势项位移的分布特征选取反向传播神经网络(Back Propagation Neural Networks, 简称 BPNN)拟合趋势项位移; 根据波动项位移的非线性特征选取 LSTM 模型预测波动项位移, 并与随机森林(Random Forest, 简称 RF)、改进的粒子群优化-支持向量机模型(Particle Swarm Optimization-Support Vector Machine, 简称 PSO-SVM)等机器学习模型以及基于 CNN 的深度学习模型预测出来的波动项位移值进行对比。最后趋势项位移预测值和波动项位移预测值叠加即可得到累计位移预测值, 实现滑坡位移预测。

## 1 方法介绍

### 1.1 滑坡位移分解

三峡库区部分滑坡在降雨和库水联合作用影响下, 表现出明显的阶跃式变形特征(Long J J et al. 2022)。基于诱发因素的滑坡预测模型认为滑坡累计位移总量包括趋势项位移、波动项位移和随机项位移。可以表示为:

$$A_t = T_t + P_t + R_t \tag{1}$$

式中, $A_t$为$t$时刻的滑坡累计位移值; $T_t$表示趋势项位移, 其受库岸滑坡的固有条件控制, 反映位移的总体演化趋势; $P_t$表示波动项位移, 其受外部诱发因素控制, 表现为周期性的波动; $R_t$表示随机项位移, 通常反映地震等随机因素的影响, 受噪声控制。在实际预测工作中一般不考虑由噪声所引起的误差项, 即认为滑坡位移由波动项和趋势项组成(柳青和易武, 2019)。公式(1)可简化为:

$$A_t = T_t + P_t \tag{2}$$

### 1.2 互补集合经验模态分解方法

对于原始非平稳非线性时间序列, Huang N E et al.(1998)提出采用经验模态分解(EMD)信号处理方法进行分解, 得到各个具有物理意义的本征模函数(Intrinsic Model Function, 简称 IMF)。IMF 分量代表着不同频率和不同尺度的信号。随着分解的进行, 相应的 IMF 的频率变小, 周期增大。各个 IMF 分量为原始时间序列的一组完全展开的正交基, 并且各个分量之和可以近似代替原始的时间序列。然而, 实际监测数据因监测仪器或偶然因素等, 导致 IMF 中存在误差, 削弱了各个 IMF 分量的规律性。因此, Wu Z and Huang N E (2009)提出考虑了噪声影响的集合经验模态分解(EEMD)算法, 通过对原始时间序列加入随机白噪声的方式以减少随机误差的影响。针对 EEMD 方法中存在的残余辅助噪声问题, Yeh et al.(2010)利用误差互补的思想提出了互补集合经验模态分解(CEEMD)算法, 即通过在集合经验模态分解(EEMD)算法分解的基础上加入正负相反的随机白噪声的方式, 对时间序列进行分解(甘柳燕等, 2024), 该算法的分解步骤如下(如图 1 所示):

(1)向原始时间序列中添加相反随机白噪声, 则有:

$$\begin{cases} s_i^{+}(t) = s(t) + w^{(i)}(t) \\ s_i^{-}(t) = s(t) - w^{(i)}(t) \end{cases} \tag{3}$$

其中, $s(t)$为滑坡在时间 $t$ 下的累计位移量; $t$ 为时间($t = 1,2,3,....,L$); $w^{(i)}(t)$为服从正态分布的随机白噪声($i = 1,2,3,...,N$), $N$ 为添加噪声的次数, $\beta$为标准差。一般而言, N 取 100~200; $\beta$取 0.2。

(2)利用经验模态分解(EMD)算法进行分解。

a、分别计算$s_i^{+}(t)$和$s_i^{-}(t)$上下包络线的均值$n_1(t)$, 满足 EMD 分解条件后, 得到 IMF 的第一个分量:

$$IMFs_1^{+}(t) = s_i^{+}(t) - n_1(t) \tag{4}$$

$$IMFs_1^{-}(t) = s_i^{-}(t) - n_1(t) \tag{5}$$

b、计算残余分量$r_1$:

$$r_1^{+}(t) = s_i^{+}(t) - IMFs_1^{+}(t) \tag{6}$$

$$r_1^{-}(t) = s_i^{-}(t) - IMFs_1^{-}(t) \tag{7}$$

c、重复步骤 a 和 b, 得到$s_i^{+}(t)$和$s_i^{-}(t)$的一系列 IMF 分量和残余分量。

(3)对$s_i^{+}(t)$和$s_i^{-}(t)$得到的两组分量分别求平均值, 即可得到最终的 IMFs 分量和残余分量。原始累计位移可表示为:

$$s(t) = \sum_{i=1}^{n} IMFs_i(t) + r(t) \tag{8}$$

因此, 互补集合经验模态分解(CEEMD)算法

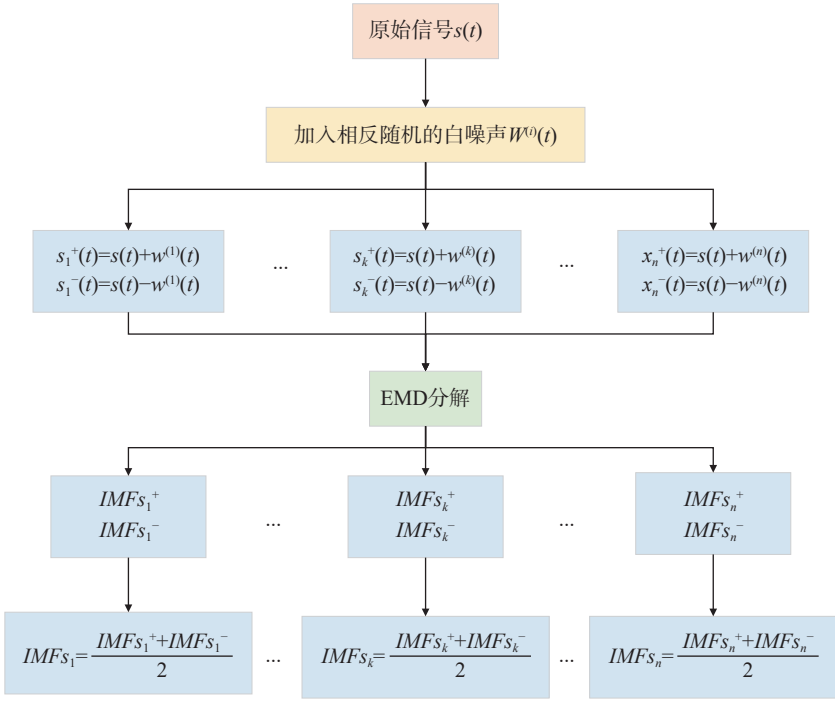


图 1 互补集合经验模态分解（CEEMD）方法计算流程

Fig. 1 The process of Complementary Ensemble Empirical Mode Decomposition (CEEMD) algorithm

分解的滑坡位移分量主要由一个低频分量和多个高频分量两部分组成。其中，低频分量为滑坡位移的趋势项，高频分量之和为滑坡位移的波动项。

### 1.3 长短时记忆神经网络算法

LSTM 算法是循环神经网络（Recurrent Neural Network，简称 RNN）中的一种。由于其出色的性能表现，LSTM 网络已经被广泛应用于考虑时间序列的滑坡预测等领域（Yang B B et al. 2019）。相比于传统的 RNN，LSTM 通过引入输入门、遗忘门和输出门等记忆单元（如图 2 所示），能够很好地处理时间序列数据的长程依赖关系，从而有效地解决了梯度消失和梯度爆炸问题（Hochreiter and Schmidhuber. 1997）。其中，输入门用来决定当前时刻网络的输入数据有多少需要保存到单元状态；遗忘门用来决定上一时刻的单元状态有多少需要保留到当前时刻；输出门用来控制当前单元状态有多少需要输出到当前的输出值。LSTM 记忆细胞的运算流程（杨背背等，2018）如图 2 所示：

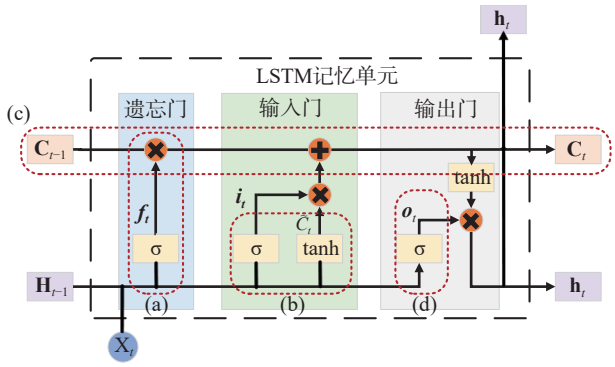


图 2 长短时记忆神经网络（LSTM）记忆单元

Fig. 2 The memory cell of Long Short-term Memory (LSTM) algorithm

（a）从上一时刻输出的$h_{t-1}$和当前时刻的输入$x_t$，通过遗忘门得到$f_t$，过程如下：

$$f_t = \sigma[W_f \cdot (h_{t-1}, x_t) + b_f] \quad (9)$$

其中，$f_t$为 Sigmoid 层的输出标量，$W_f$是当前神经元的权重参数，$b_f$为偏置参数，$\sigma$为 sigmoid 激活函数。区间为 [0,1]，即输出值越接近 1 的信息将被保留，而输出值越接近 0 的信息将被遗忘。

（b）从上一时刻输出的$h_{t-1}$和当前时刻的输入$x_t$，通过输入门得到$i_t$以及通过状态单元得到当前时刻临时状态$\tilde{C}_t$，过程如下：

$$i_t = \sigma[W_i \cdot (h_{t-1}, x_t) + b_i] \quad (10)$$

$$\tilde{C}_t = \tanh[W_C \cdot (h_{t-1}, x_t) + b_C] \quad (11)$$

其中，$i_t$为 Sigmoid 层的输出标量，表示输入门的更新程度，$\tilde{C}_t$用以控制输入的数据。tanh为激活函数。

(c)从上一个细胞结构的单元状态$C_{t-1}$、遗忘门的输出$f_t$、输入门的输出$i_t$以及通过状态单元得到的当前时刻临时状态$\tilde{C}_t$, 得到当前时刻的单元状态$C_t$, 过程如下:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \tag{12}$$

(d)从上一时刻输出的$h_{t-1}$和当前时刻的输入$x_t$, 通过输出门得到$o_t$, 然后结合当前细胞结构的单元状态$C_t$, 得到最终的$h_t$, 过程如下:

$$o_t = \sigma[W_o \cdot (h_{t-1}, x_t) + b_o] \tag{13}$$

$$h_t = o_t \cdot \tanh(C_t) \tag{14}$$

其中, $o_t$为 sigmoid 层的输出标量。

### 1.4 精度评价方法

$R^2$ 是统计学中用于评估回归模型拟合优度的一个指标, $R^2$ 的值越接近 1, 表示回归模型拟合得越好, 自变量对因变量的解释能力越强。

$$R^2 = \frac{SSR}{SST} \tag{15}$$

其中, *SSR* 表示回归平方和, *SST* 表示总平方和。

均方根误差(*RMSE*)、平均绝对误差(*MAE*)和平均偏差误差(*MBE*)通常用来评价模型的整体预测精度。这些指标可以表示为:

$$RMSE = \sqrt{\frac{1}{n}\sum_{t=0}^{n}(\hat{Y}_t - Y_t)^2} \tag{16}$$

$$MAE = \frac{1}{n}\sum_{t=0}^{n}\left|\hat{Y}_t - Y_t\right| \tag{17}$$

$$MBE = \frac{1}{n}\sum_{t=0}^{n}\left(\hat{Y}_t - Y_t\right) \tag{18}$$

其中, $Y_t$表示位移实际值, $\hat{Y}_t$表示位移预测值。*RMSE* 用于测量实际值和预测值之间的偏差; *MAE* 用于测量平均总体预测误差; *MBE* 是衡量预测值与实际值之间误差平均值的一种统计量。一般而言, *RMSE* 和 *MAE* 值越大, 表示误差越大。当预测值普遍高于实际值, *MBE* 为正; 反之, 如果预测值普遍低于实际值, *MBE* 为负, *MBE* 的值越接近 0 则表示预测值与实际值越一致。

## 2 案例分析

### 2.1 墓坪滑坡工程地质概况

本文选取三峡库区墓坪滑坡为研究对象。墓坪滑坡(图 3a)位于香溪河左岸斜坡中下部, 行政区划隶属于湖北省兴山县峡口镇白鹤村 4 组, S312 省道从滑坡后缘穿过, 交通条件较好。墓坪滑坡主滑方向为 270°, 滑坡前缘为香溪河, 高程 135 m; 后缘以省道 S312 为界, 高程 213 m, 前后缘相对高差达 78 m。墓坪滑坡平面上呈舌形, 纵剖面上为凹形, 滑体纵长 205 m, 宽 160 m, 面积 $3.28\times10^4$ m$^2$, 滑体平均厚 8 m, 总体积约为 $26.24\times10^4$ m$^3$, 为中型土质滑坡。滑坡位于秭归向斜的北侧, 如图 3b 所示为墓坪滑坡剖面图, 滑坡岩性为侏罗系中下统聂家山组($J_{1\text{-}2}n$)中厚-厚层状砂岩、粉砂岩和粉砂质泥岩互层, 岩性较坚硬, 力学强度较高, 地层产状 270°∠45°。上覆第四系残坡积堆积物($Q^{el+dl}$)碎石土, 黄褐色, 结构松散-稍密, 据推测厚约 6-10 m, 上下薄, 中间厚, 土石比 3∶7 ~ 4∶6, 碎石成分以砂岩、泥质粉砂岩为主(高晨曦等, 2024)。

### 2.2 墓坪滑坡监测数据分析

墓坪滑坡为三峡库区后续地质灾害防治群测群防监测点。2021 年 4 月, 为进一步监测墓坪滑坡变形趋势, 在滑坡体上共布设了 3 台全自动 GNSS 地表位移监测点, 其编号分别为 GN01、GN02、GN03, 数据采集频次为每小时 1 次; 滑坡体外稳定的山体布设 1 个 GNSS 基准点(编号 JZ1), 共同构成墓坪滑坡 GNSS 监测网(如图 3a 所示)。如图 4 所示为 GN01 监测点地表累积位移日监测值、库水位与日降雨量关系图。从中可以看出, 测点 GN01 的地表位移变形量较大, 截止到 2024 年 7 月 29 日, GN01 的累积位移达到 3 563.304 mm, 且呈现出阶跃变形特征(如表 1 所示)。

a. 2021 年 5 月 7 日至 5 月 22 日库水位由 158.54 m 下降至 151.21 m, 平均下降速率达到 0.39 m/d。2021 年 5 月 11 日至 5 月 17 日出现连续 7 日降雨, 累积降雨量达到 45.8 mm, 5 月 15 日单日降雨量达到最大, 为 18.9 mm。累积位移在 5 月 10 日到 5 月 22 日之间增大, 达到 277.8 mm。结合现场调查和监测数据分析发现, 滑坡右后部位置自 2021 年 5 月开始出现明显拉张裂缝, 并不断扩大(如图 5 所示)。

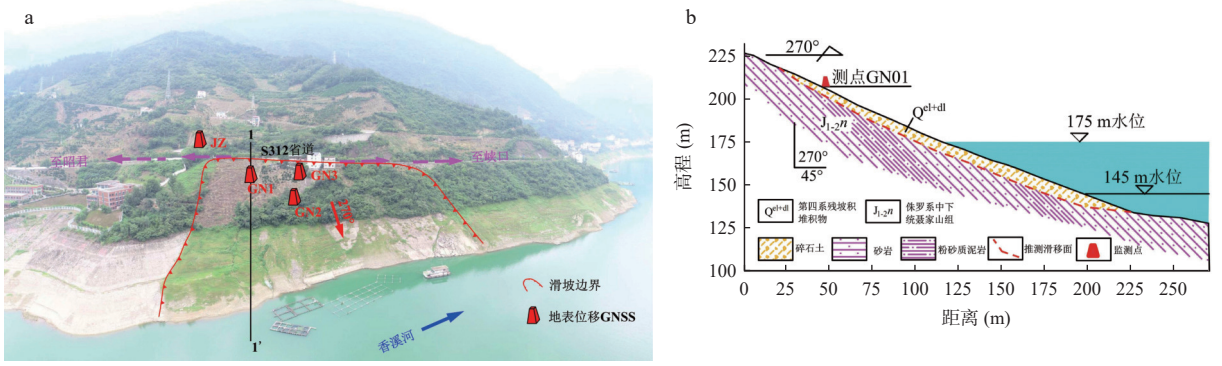


图 3 墓坪滑坡监测点布置图（a）和 1-1’剖面图（b）

Fig. 3 The layout of monitoring points (a) and 1-1’ cross section (b) of Muping landslide

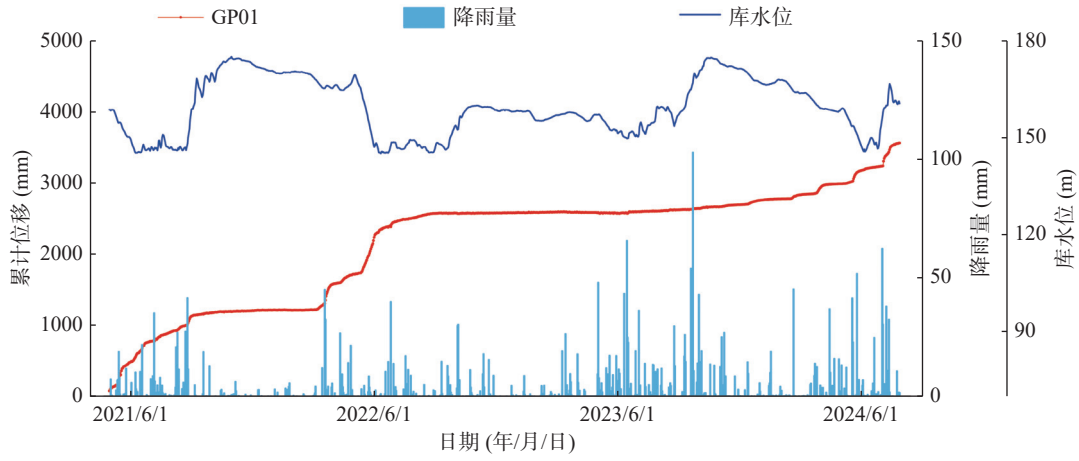


图 4 地表累积位移-日库水位-日降雨量关系曲线

Fig. 4 The relationship curve of accumulative displacement-daily reservoir water level-daily rainfall

**表 1 墓坪滑坡不同阶跃变形阶段的位移、降雨、库水位指标统计表**

**Table 1 Statistical table of displacement, rainfall, and reservoir water level indicators at the step-like deformation stage of the Muping landslide monitoring points**

| 编号 | 起始时间（年/月/日） | 结束时间（年/月/日） | 位移增量（mm） | 累积降雨（mm） | 日最大降雨（mm） | 运行库水位（m） | 库水位平均变化速率(m/d) |
|---|---|---|---|---|---|---|---|
| a | 2021/5/10 | 2021/5/22 | 277.8 | 46.7 | 18.9 | 157.76~152.35 | −0.42 |
| b | 2021/6/4 | 2021/6/23 | 248.6 | 57.3 | 21.8 | 148.77~146.57 | −0.11 |
| c | 2021/8/9 | 2021/8/31 | 198.5 | 154 | 41.6 | 146.17~157.14 | 0.5 |
| d | 2022/3/20 | 2022/3/29 | 256.6 | 84.8 | 45.1 | 165.28~165.39 | 0.11 |
| e | 2022/5/15 | 2022/6/3 | 520.9 | 22.9 | 8.5 | 164.04~147.41 | −0.83 |

图 5 墓坪滑坡中后缘裂缝变形

Fig. 5 Deformation of the rear tensile cracks in the Muping landslide

b. 2021 年 6 月 2 日至 6 月 27 日库水位由 149.5 m 下降至 146.39 m, 平均下降速率达到 0.12 m/d。2021 年 6 月 9 日至 6 月 19 日累积降雨量达到 57.3 mm, 6 月 19 日单日降雨量达到最大, 为 21.8 mm。累积位移在 6 月 4 日到 6 月 23 日增大, 达到 248.6 mm。

c. 2021 年 8 月 9 日至 8 月 31 日库水位由 146.17 m 上升至 157.14 m, 平均上升速率达到 0.5

m/d。2021 年 8 月 9 日至 8 月 27 日累积降雨量达到 154 mm, 8 月 26 日单日降雨量达到最大, 为 41.6 mm。累积位移在 8 月 9 日至 8 月 25 日持续增加、8 月 26 日到 8 月 31 日之间增大, 达到 198.5 mm。

d. 2022 年 3 月 20 日至 3 月 29 日库水位由 165.2 8m 下降至 165.39 m, 平均下降速率达到 0.11 m/d。2022 年 3 月 20 日至 3 月 25 日累积降雨量达到 84.6 mm, 3 月 20 日单日降雨量达到最大, 为 45.1 mm。而累积位移在 3 月 20 日到 3 月 29 日之间增大, 达到 256.6 mm。

e. 2022 年 5 月 18 日至 5 月 28 日累积降雨量达到 22.3 mm, 5 月 25 日单日降雨量达到最大, 为 8.5 mm。而累积位移在 5 月 15 日到 6 月 3 日之间急剧增大, 达到 520.9 mm。

然而在 2023 年 6 月至 9 月, 滑坡并未出现明显变形, 尤其在 2023 年 9 月 23 日和 2023 年 6 月 16 日, 当日降雨量分别达到了 102.87 mm 和 65.63 mm, 但是其累计位移较前一日仅增加了 0.138 mm 和−6.625 mm。初步分析其原因可能是 2023 年汛期库水位变动较为平缓, 并未出现大幅波动。因此, 测点 GN01 变形主要发生在连续降雨与库水位快速下降期间。故降雨和库水位下降联合作用是导致墓坪滑坡变形的主要诱发因素。

## 3 结果与讨论

### 3.1 墓坪滑坡位移分解

基于墓坪滑坡的变形特征, 本文主要选取墓坪滑坡 GN01 的地表累计位移日监测数据进行研究。首先对数据进行预处理, 然后采用 CEEMD 将墓坪滑坡 GP01 监测点从 2021 年 5 月 1 日至 2024 年 7 月 29 日的 GNSS 累计位移值分解为 4 个高频 IMF 分量和一个低频残余分量(RES)(如图 6 所示)。将 RES 分量作为趋势项, 剩余 IMF 分量累加作为波动项。

### 3.2 波动项位移预测

三峡库区滑坡的稳定性受库水位波动和降雨影响较大, 因此库水位和月降雨量等指标被用作波动项位移预测的诱发因素。本文选取 2021 年 5 月 1 日至 2022 年 8 月 1 日诱发因素及波动项位移数据为模型训练集, 2022 年 8 月 2 日至 2024 年 7 月 29 日的诱发因素及波动项位移数据为模型测试集, 根据波动项位移的非线性特征选取考虑时间序列的 LSTM 模型预测波动项位移。将位移预测结果与 RF 模型、改进的 PSO-SVM 等机器学习模型以及基于 CNN 的深度学习模型预测的波动项位移值进行对比。如图 7 和表 2 所示为基于以上不同模型得到的波动项位移预测结果对比及精度对比。从图中可以看出, LSTM 模型的预测结果更接近实际情况, RMSE 为 2.139, MAE 为 1.056, MBE 为 0.162, 相比于常见的机器

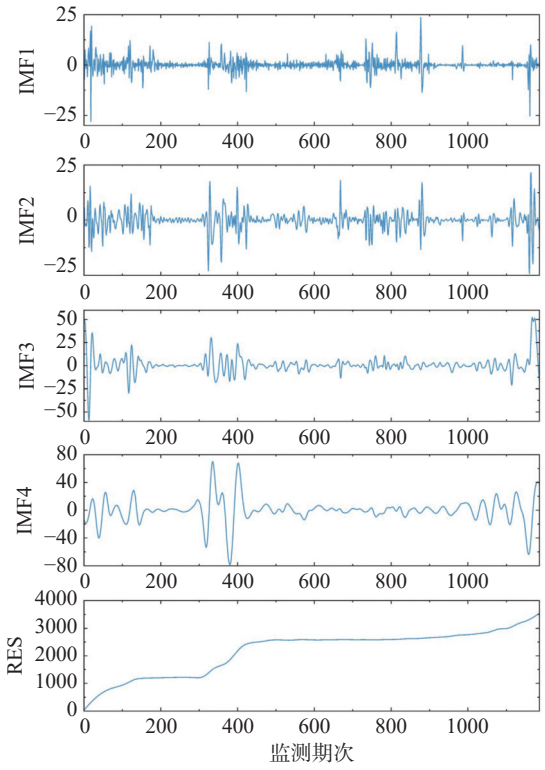


图 6　基于互补集合经验模态分解(CEEMD)方法的墓坪滑坡位移量分解结果

Fig. 6　The decomposition results of Muping landslide cumulation displacement based on CEEMD

**表 2　墓坪滑坡波动项位移预测精度对比**

**Table 2　The precision comparison of periodic displacement prediction for Muping landslide**

| 评价指标 | 预测模型 | | | |
|---|---|---|---|---|
| | LSTM模型 | CNN模型 | RF模型 | PSO-SVM模型 |
| RMSE | 2.139 | 6.163 | 2.514 | 4.241 |
| MAE | 1.056 | 3.254 | 1.474 | 1.592 |
| MBE | 0.162 | −1.386 | −0.231 | −0.281 |

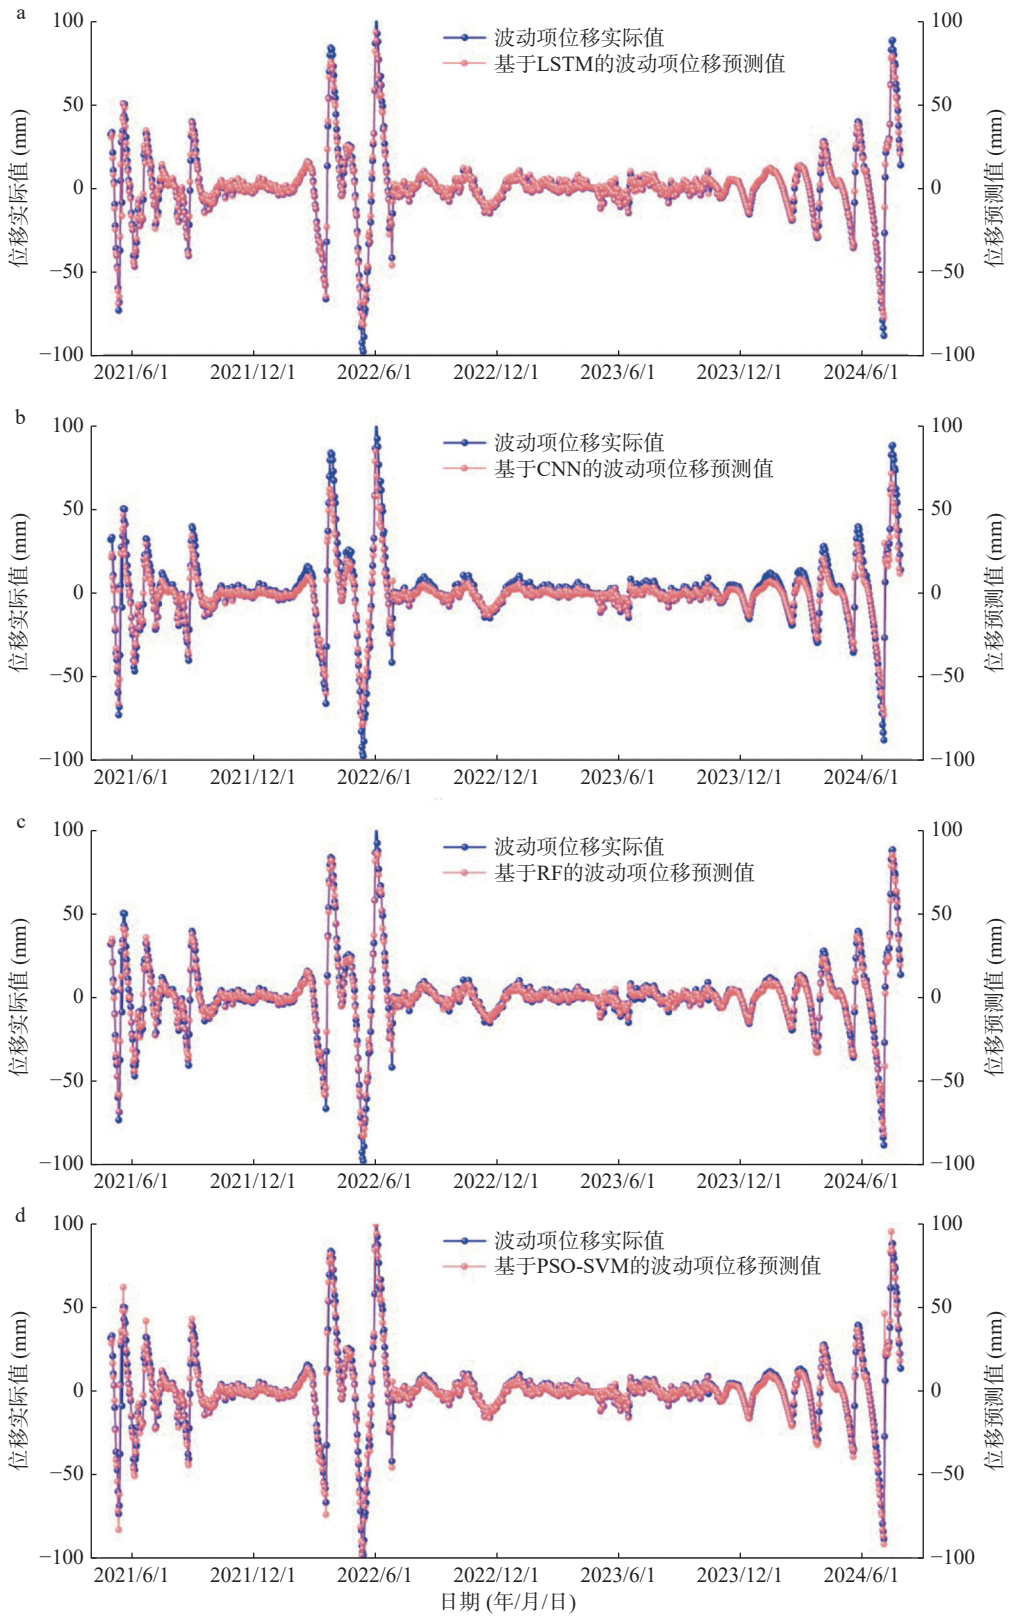


图 7 墓坪滑坡波动项位移预测结果对比

Fig. 7 The comparison of periodic displacement prediction result for Muping landslide

学习(如 RF 和 PSO-SVM)和深度学习(如 CNN)模型,LSTM 模型表现最好,预测精度最高。

### 3.3 趋势项位移预测

如图 6 所示,趋势项表现出平滑递增的趋势,

与时间序列表现为非线性相关, 趋势项变形曲线与 tansig 函数曲线相似。因此, 本文选取 2021 年 5 月 1 日至 2022 年 8 月 1 日的趋势项位移数据为模型训练集, 2022 年 8 月 2 日至 2024 年 7 月 29 日的趋势项位移数据为模型测试集, 采用反向传播神经网络(Back Propagation Neural Network, BPNN)来拟合趋势项位移(刘艺梁等, 2013)。如图 8a 为趋势项位移的预测结果, 计算可得训练集的拟合优度$R^2$为 0.9989, 测试集的拟合优度$R^2$为 0.9977, 趋势项位移预测数据集的 RMSE 为 9.79。

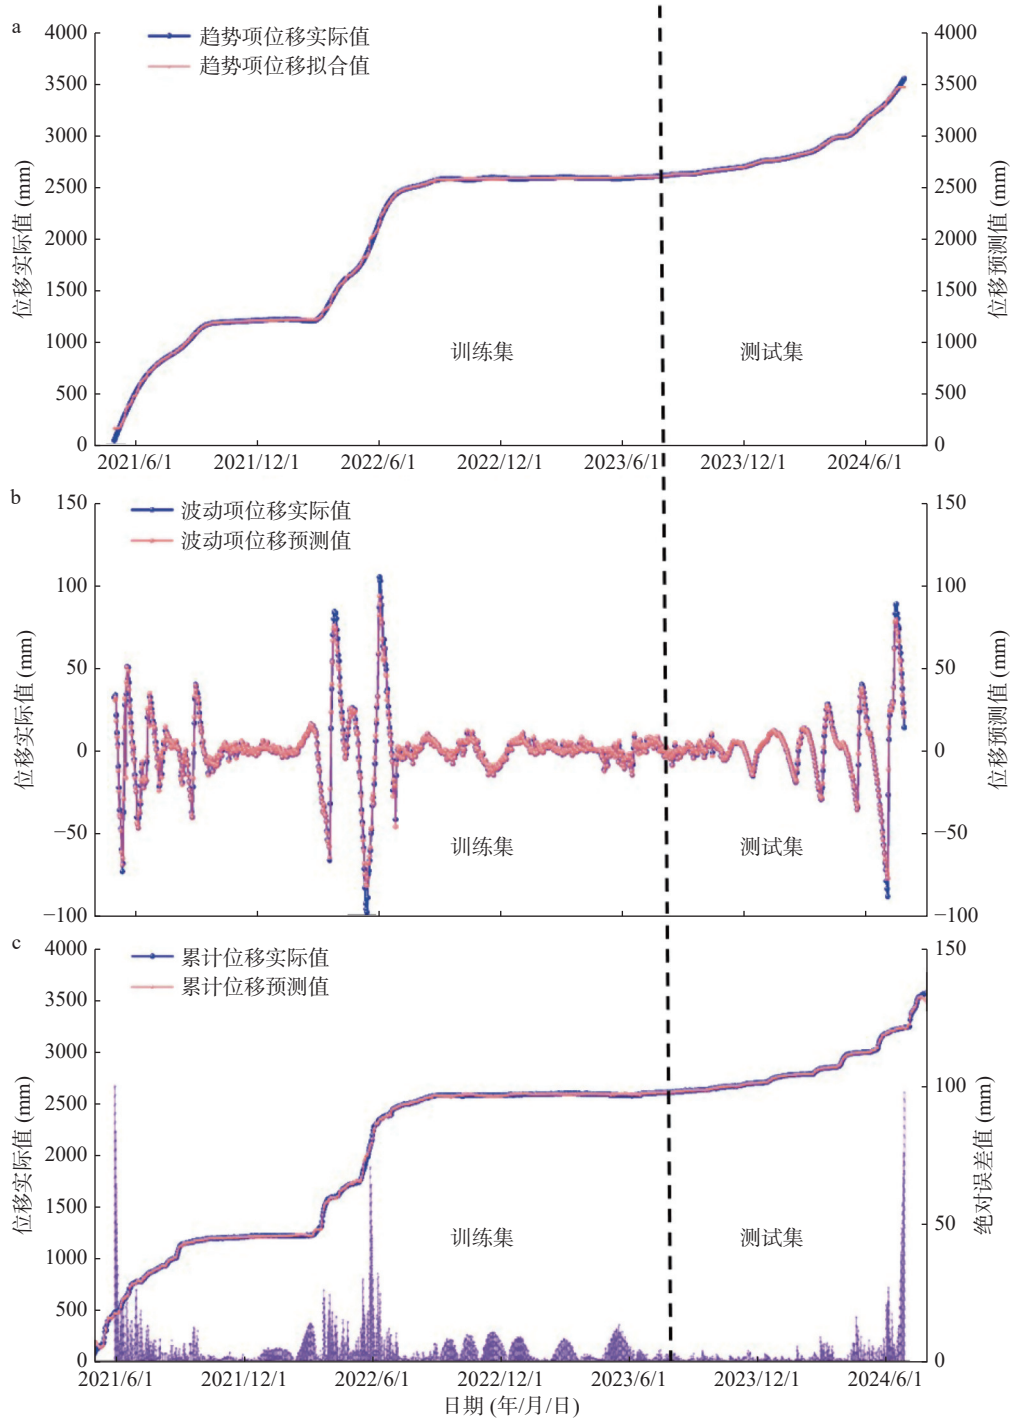


图 8　墓坪滑坡位移预测结果

Fig. 8　Prediction result of the displacement of Muping landslide

a. 趋势项位移预测结果; b. 波动项位移预测结果; c. 累计位移预测结果及绝对误差

结果表明，该模型在给定的数据集上能较好地描述或预测数据的特征和趋势。

### 3.4 累计位移预测

根据时间序列分解原理，将各分项位移预测值叠加，即可得到滑坡累积位移预测值(Zhou C et al. 2018)，如图 8b 所示为基于 LSTM 的波动项位移预测结果，图 8c 为趋势项位移预测结果与波动项位移预测结果累加得到的墓坪滑坡位移预测结果。结果表明：滑坡累积位移预测值与实测值基本一致，RMSE 为 9.367；MAE 为 4.858；MBE 为 0.671，总体预测精度较高且能较好地预测出滑坡位移的阶跃型变化。累积位移预测值的误差最大点第一次出现在 2021 年 5 月 2 日，此时的误差主要受趋势项预测误差的影响，后面两次分别出现在 2022 年 5 月 20 日和 2024 年 7 月 28 日，此时的误差主要受波动项位移预测误差的影响，且均出现在滑坡位移发生跃迁处。

另外，2024 年 5 月，三峡库区库水位从 158.45 m 快速下降至 148.36 m，且 2024 年 5 月 19 日至 20 日兴山县连续降雨，单日累积降雨量分别为 41.5 mm、23.9 mm，布设于兴山县峡口镇白鹤村墓坪滑坡右侧中后部的 GP01，分别于 2024 年 5 月 20 日 22 时、2024 年 5 月 21 日 22 时发出 2 条蓝色预警。分析监测数据可知，2024 年 5 月 21 日监测位移较前一日增加 32.883 mm，基于时序的滑坡位移预测方法得到的 2024 年 5 月 21 日监测位移则较前一日增加 34.882 mm，误差小于 2 mm，结果表明本文提出的方法在滑坡位移预测中表现良好，且对阶跃点的预测精度相对较高。因此，本文提出的 CEEMD-LSTM 预测模型可为实现滑坡准确预测预报提供理论依据和数据支撑。

## 4 结论与展望

针对三峡库区阶跃型滑坡，本文以墓坪滑坡为研究对象，提出了一种基于时间序列的 CEEMD-LSTM 滑坡位移预测模型。

(1)墓坪滑坡主要发生在连续降雨与库水位快速下降期间，因此降雨和库水位下降的联合作用是其变形滑动的主要诱发因素。

(2)与当前通用的机器学习预测模型，如 RF 和 PSO-SVM，以及深度学习模型，如 CNN 等相比，本文提出的基于 CEEMD-LSTM 的模型在阶跃型滑坡位移预测中表现最好，预测值与实际值相对一致，该模型可为三峡库区阶跃型滑坡位移预测提供新的思路。

(3)尽管该模型在阶跃点的预测上表现出相对较高的预测精度，但是滑坡累计位移两次误差最大点均出现在跃迁处，说明该模型在阶跃点的预测上仍可进一步改进，以提升精度。

**参考文献：**


邓冬梅,梁 烨,王亮清,王昌硕,孙自豪,王 聪,董曼曼.2017.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,38(12):3660-3669.

甘柳燕,唐国强,蒋文希,覃良文.2024.基于 CEEMD-LSTM-Adaboost 模型的白糖期货跨期套利策略 [J]. 桂林理工大学学报,44(1):162-167.

高晨曦,石长柏,闫 巍,侯时平,唐 玄,安知利,路永强.2024.堆积层滑坡在库水位变动与降雨共同作用下的阈值研究——以墓坪滑坡为例 [J]. 资源环境与工程,38(1):73-82.

高 睿,张真弼,李立辰,关 鹏.2024.基于 BO-SVM 的滑坡稳定性可解释机器学习预测方法 [J]. 资源环境与工程,38(3):274-284+307.

李长冬,龙晶晶,姜茜慧,付智勇.2020.水库滑坡成因机制研究进展与展望 [J]. 地质科技通报,39(1):67-77.

李麟玮,吴益平,苗发盛,廖 康,张龙飞.2018.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,37(6):1395-1406.

柳 青,易 武.2019.基于诱发因素响应与 BP 神经网络的滑坡位移预测预报 [J]. 三峡大学学报 (自然科学版),41(3):41-45.

刘艺梁,殷坤龙,汪 洋,王 伟.2013.基于经验模态分解和神经网络的滑坡变形预测研究 [J]. 安全与环境工程,20(4):14-17.

卢书强,易庆林,易 武,张国栋,何 祥.2014.库水下降作用下滑坡动态变形机理分析——以三峡库区白水河滑坡为例 [J]. 工程地质学报,22(5):869-875.

马社祥,刘贵忠,曾召华.2000.基于小波分析的非平稳时间

序列分析与预测 [J]. 系统工程学报,(4):305-311.

徐 峰,汪 洋,杜 娟,叶 疆.2011.基于时间序列分析的滑坡位移预测模型研究 [J]. 岩石力学与工程学报,30(4):746-751.

姚 琦,牛瑞卿,赵金童,张 淼.2017.基于经验模态分解-支持向量机的滑坡位移预测方法研究 [J]. 安全与环境工程,24(1):26-32.

杨背背,殷坤龙,杜 娟.2018.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,37(10):2334-2343.

张 俊,殷坤龙,王佳佳,黄发明.2015.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,34(2):382-391.

周 浩,朱平华,蒋宏伟,俞宏艳,沈心怡.2024.逻辑回归优化的静-动态耦合模型在滑坡位移预测中的应用 [J]. 资源环境与工程,38(4):446-456.

Li C D, Long J J, Liu Y, Huang D W. 2024. Landslide Prediction Model Based Upon Intelligent Processing of Multi-Point Monitoring Information: A Review[M]. //Abolmasov B, et al. Progress in Landslide Research and Technology. Springer, Cham.

Lian C, Zeng Z G, Yao W, Tang H M. 2012. Displacement prediction model of landslide based on a modified ensemble empirical mode decomposition and extreme learning machine[J]. Natural Hazards, 66(2): 759-771.

Long J J, Li C D, Liu Y, Feng P F, Zuo Q J. 2022. A multi-feature fusion transfer learning method for displacement prediction of rainfall reservoir-induced landslide with step-like deformation characteristics[J]. Engineering Geology, 297: 106494.

Huang F M, Yin K L, Zhang G R, Gui L, Yang B B, Liu L. 2016. Landslide displacement prediction using discrete wavelet transform and extreme learning machine based on chaos theory[J]. Environmental Earth Sciences, 75: 1376.

Huang N E, Shen Z, Long S R, Wu M C, Shih H H, Zheng Q, Yen N C, Tung C C, Liu H H. 1998. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society: Mathematical, physical and engineering sciences, 454(1971): 903-995.

Hochreiter S, Schmidhuber J. 1997. Unsupervised coding with loco code[C]. Artificial Neural Networks - ICANN '97, 7th International Conference, Lausanne, Switzerland, October 8-10.

Wu Z, Huang N E. 2009. Ensemble Empirical Mode Decomposition: A Noise-saaisted Data Analysis Method[J]. World Scientific, 1: 1-41.

Yeh J R, Shieh J S, Huang N E. 2010. Complementary Ensemble Empirical Mode Decomposition: a Novel Noise Enhanced Data Analysis Method[J]. Advances in Adaptive Data Analysis, 2(2): 135-156.

Yang B B, Yin K L, Lacasse S, Liu Z Q. 2019. Time series analysis and long short-term memory neural network to predict landslide displacement[J]. Landslides, 16(4): 677-694.

Zhou C, Yin K L, Cao Y, Intrieri E, Ahmed B, Catani F. 2018. Displacement prediction of step-like landslide by applying a novel kernel extreme learning machine method[J]. Landslides, 15(11): 2211-2225.

Zhu X, Ma S Q, Xu Q, Xu Q, Liu W D. 2018. A WD-GA-LSSVM model for rainfall-triggered landslide displacement prediction[J]. Journal of Mountain Science, 15(1): 156-166.