

# 多时间尺度下库岸阶跃型滑坡位移智能预测

郭飞<sup>1,2</sup>, 胥智臻<sup>1,2</sup>, 胡记磊<sup>\*,1,2</sup>, 章涵<sup>1,2</sup>, 李婧茹<sup>1,2</sup>, 易庆林<sup>1,2</sup>

1. 三峡库区地质灾害教育部重点实验室, 宜昌 443002;  
2. 三峡大学土木与建筑学院, 宜昌 443002

**摘要:** 以三峡库区白家包阶跃型滑坡为例, 选取日、周、旬和月四种时间尺度监测数据, 基于时间序列加法模型分解累计位移为周期项与趋势项, 经灰色关联方法筛选高敏感诱发因子后, 构建经验模态分解与门控循环单元耦合模型, 开展滑坡累积位移预测精度分析。结果表明: 周和旬时间尺度的预测精度显著高于日和月尺度, 且周尺度精度最优; 其预测位移均方根误差较日、月和旬尺度分别降低 56.98%、64.00%和 35.51%, 平均绝对误差分别降低 61.04%、69.07%和 23.72%。机理分析显示, 周尺度采样频率与滑坡对水文因素 7~15 天的滞后响应期相匹配, 可在滤除高频噪声的同时保留关键变形信号。研究证实白家包滑坡变形趋势预测宜采用周监测数据, 成果为三峡库区滑坡灾害“分级变频”预警防控提供科学依据。

**关键词:** 三峡库区; 阶跃型滑坡; 多时间尺度; EEMD 算法; GRU 预测模型

中图法分类号: P642.22;

收稿日期: 2025-12-05

## Multi-time-scale Intelligent Prediction for Reservoir Bank Step-like Landslides Displacement

GUO Fei<sup>1,2</sup>, XU Zhizhen<sup>1,2</sup>, HU Jilei<sup>1,2</sup>, ZHANG Han<sup>1,2</sup>, LI Jingru<sup>1,2</sup>,  
YI Qinglin<sup>1,2</sup>

1. Key Laboratory of Geological Hazards on Three Gorges Reservoir Area, Ministry of Education, Yichang 443002, China;  
2. College of Civil Engineering & Architecture, China Three Gorges University, Yichang 443002, China;

**Abstract:** Taking the Baijiabao step-type landslide in the Three Gorges Reservoir Area as a case study, we selected monitoring data at four time scales (daily, weekly, ten-day interval and monthly), decomposed the cumulative displacement into periodic and trend components based on the additive time series model, screened highly sensitive inducing factors via the grey correlation method, and constructed a coupled model of the Ensemble Empirical Mode Decomposition (EEMD) algorithm and Gated Recurrent Unit (GRU) to analyze the prediction accuracy of landslide cumulative displacement. The results show that the prediction accuracy at weekly and ten-day interval scales is significantly higher than that at daily and monthly scales, with the weekly scale yielding the optimal performance. The root mean square error of displacement prediction at the weekly scale is reduced by 56.98%, 64.00%, and 35.51% compared with that at daily, monthly, and ten-day interval scales, respectively, and the mean absolute error is decreased by 61.04%, 69.07%, and 23.72% accordingly. Mechanism analysis reveals that the sampling frequency of the weekly scale matches the 7–15 days lag response period of the landslide to hydrological factors, which can filter out high-frequency noise while retaining key deformation signals. This study confirms that weekly monitoring data are suitable for predicting the deformation trend of the Baijiabao landslide, and the findings provide a scientific basis for the hierarchical and variable-frequency early warning and control of landslide disasters in the Three Gorges Reservoir Area.

**Key words:** Three Gorges Reservoir Area; Step-like landslide; Multi-time-scale; EEMD algorithm; GRU prediction model

基金项目: 自然资源部地质灾害智能监测与风险预警工程技术创新中心开放基金(TICGM-2024-06); 防灾减灾湖北省重点实验室开放基金(2024XCZX05); 湖北巴东地质灾害国家野外科学观测研究站开放基金(BNORSG-202304); 三峡库区地质灾害教育部重点实验室开放基金(2022KDZ14和 2022KDZ15); 土木工程防灾减灾湖北省引智创新示范基地项目(2021EJD026)

作者简介: 郭飞, 男, 副教授, 博士, 从事滑坡灾害监测与风险分析研究及相关教学工作。E-mail: ybnui.2008@163.com, ORCID: 0000-0003-3006-3478。  
通讯作者: 胡记磊, 男, 副教授, 博士, 从事地震地质灾害风险分析与智能评估研究及相关教学工作。E-mail: hujl@ctgu.edu.cn, ORCID: 0000-0003-4673-0845。

## 0 引言

三峡库区是我国滑坡灾害最为严重的地区之一(Huang *et al.*, 2020; 郭飞等, 2024), 滑坡数量众多, 其中阶跃型滑坡在库区内广泛分布。该类滑坡的位移-时间曲线呈现出明显的“阶跃”式变形特征, 其主要诱因包括季节性降雨、周期性库水位波

动或二者的共同作用(宋琨等, 2022; 许强等, 2008), 同时也受地下水的影响(Cao *et al.*, 2016; Huang *et al.*, 2023)。这种阶跃性变形特征使得每一次位移突增都可能被误判为临滑状态, 从而为滑坡的精准预警与有效防治带来严峻挑战(许强等, 2009; 黄发明等, 2025)。因此, 准确把握滑坡的变形演化阶段并据此采取防灾措施, 对于显著减少人员伤亡与财产损失具有至关重要的现实意义(Demir *et al.*, 2015; He *et al.*, 2024)。

预测精度通常受预测模型性能与数据质量共同制约。目前, 阶跃型滑坡位移预测的研究多聚焦于预测模型的创新与改进, 而往往忽视了不同时间尺度的监测数据对预测精度的影响(Wang *et al.*, 2022)。因此, 有必要开展不同时间尺度的位移预测研究, 而滑坡位移监测的时间尺度也受监测设备的限制和外界因素的影响。与此同时, 滑坡位移监测的时间尺度也受到监测设备能力与外界环境因素的约束。针对外界因素对滑坡变形影响的时间尺度问题, 学者们已开展了大量研究。Keefer 等(1987)年研究旧金山海湾地区降雨与滑坡关系时指出, 前 1-2 月的累积降雨量影响显著, 这一发现成为后续选择月尺度进行位移预测的重要依据(叶润青等, 2021; Yang *et al.*, 2022)。然而, Krkac *et al.* (2016)、Bogaard & Greco(2018)、Roering *et al.*(2015)等研究表明, 降雨对滑坡变形的影响周期通常在 10~30d; 刘广宁等(2011)针对三峡库区的研究也指出, 降雨对滑坡变形的影响时间一般为 7~15d。上述研究显示, 在外界因素驱动下, 滑坡位移的加速发展周期通常短于一个月(Fu *et al.*, 2025; 刘勇等, 2023)。特别是在三峡库区, 滑坡体在周期性库水位涨落与降雨联合作用下, 其响应周期往往更短。随着自动化监测技术在三峡库区的普及, 可获取的位移数据日益丰富, 继续单一地采用月尺度已难以满足阶跃型滑坡高精度位移预测的需求。因此, 系统探究不同时间尺度对滑坡位移预测精度的影响, 对于优化监测方案和提升预测可靠性显得尤为必要。

本文以三峡库区白家包滑坡为典型案例, 基于地表自动化监测数据, 从时间尺度的视角, 深入分析阶跃型滑坡累计位移预测精度与监测频率之间的内在联系。首先, 采用集合经验模态分解 (ensemble empirical mode decomposition, EEMD) 算法将各时间尺度下的累计位移分解为趋势项与周期项; 其次, 引入灰色关联分析 (Grey Relational Analysis, GRA) 定量测度不同时间尺度下降雨、库水位等诱发因子与位移的关联强度, 智能筛选出高敏感输入变量; 最后, 结合门控循环单元 (Gated Recurrent Unit, GRU) 构建耦合预测模型。通过对比分析不同尺度下的拟合优度 ( $R^2$ )、均方根误差 (RMSE) 和平均绝对误差 (MAE) (江文金等, 2023; 程刚等, 2025), 旨在揭示时间尺度效应的物理机制, 并为三峡库区滑坡的“分级变频”监测预警提供科学依据。

## 1 理论与方法

### 1.1 时间序列分析

滑坡累计位移受多种复杂因素影响, 通常表现为非平稳、非线性的时间序列, 直接预测难度较大。为此, 可基于时间序列加法模型, 将累计位移分解为趋势项位移和周期项位移, 分别预测后再叠加, 从而得到最终的累计位移预测值(Yang *et al.*, 2019)。其模型可表达为:

$$Y_t = S_t + T_t \quad (1)$$

式中:  $Y_t$  为累计位移,  $S_t$  为周期项位移,  $T_t$  为趋势项位移。

### 1.2 EEMD-GRU 耦合预测模型构建

针对滑坡位移监测数据的非线性与非平稳特征, 本文构建了基于 EEMD-GRU 的组合预测模型。该模型主要由数据分解、分项预测与结果重构三个核心环节组成。

首先,采用集合经验模态分解(EEMD)算法对不同时间尺度下的滑坡累计位移进行自适应分解。EEMD算法是对传统经验模态分解(EMD)的改进,通过在原始信号中多次加入有限幅值的白噪声并取总体平均,有效克服了EMD算法中常见的模态混叠问题(Fu *et al.*, 2025)。利用EEMD算法,复杂的累计位移序列被分解为若干个具有不同特征尺度的本征模态函数(IMF)和一个残余分量。在本研究中,残余分量单调平滑,物理上对应于受滑坡自身地质条件控制的长期趋势(趋势项位移);而各IMF分量频率较高且波动显著,对应于受降雨、库水位等外界因素驱动的周期性波动(周期项位移)。

其次,针对分解后的各分量特征采用差异化的预测策略。对于趋势项位移,因其变化规律相对简单,采用多项式拟合即可获得高精度预测结果;对于非线性极强的周期项位移,则引入门控循环单元(GRU)神经网络进行深度学习建模。GRU是循环神经网络(RNN)的一种高效变体,它通过引入“重置门”和“更新门”两种门控机制,优化了长短时记忆网络(LSTM)的结构(Guo *et al.*, 2020a; Guo *et al.*, 2020b)。重置门决定了如何将新的输入信息与前面的记忆相结合,而更新门定义了前面记忆保存到当前时刻的量。相比于LSTM,GRU在保证对长序列非线性依赖关系捕捉能力的同时,减少了参数数量,从而显著提升了模型的训练效率与收敛速度。

最后,基于时间序列加法模型原理,将GRU模型输出的周期项预测值与多项式拟合得到的趋势项预测值进行叠加,从而重构出最终的滑坡累计位移预测结果。

### 1.3 灰色关联分析法

灰色关联分析法能够量化因素之间关联程度的强弱。本文利用该方法分析周期项位移与各诱发因子表征指标之间的关联性,以筛选关键预测因子。计算步骤如下(邓冬梅等, 2021):

(1) 设周期项位移为特征序列;诱发因素表征指标为待评价因素序列  $X_i(t)$ , 并进行均值化处理:

$$\begin{cases} X_0(t)D = \{x_0(1)d, \dots, x_0(m)d\} \\ x_0(t)d = \frac{x_0(t)}{x_0} \\ \bar{x}_0 = \frac{1}{m} \sum_{t=1}^m x_0(t), t = 1, 2, \dots, m \end{cases} \quad (2)$$

式中:  $D$  为均值化算子;  $d$  为均值的倒数。

(2) 关联度计算。可计算出任时刻的周期项位移与诱发因素表征指标的关联系数为:

$$\xi_{0i}(t) = \frac{\Delta_{\min} + \rho\Delta_{\max}}{\Delta_{0i(t)} + \rho\Delta_{\max}} \quad (3)$$

式中:  $\Delta_{\max}$  为  $|X_0(t) - X_i(t)|$  的最大值;  $\Delta_{\min}$  为  $|X_0(t) - X_i(t)|$  的最小值;  $\Delta_{0i(t)}$  为  $|X_0(t) - X_i(t)|$  在某一时刻的值;  $\rho$  为分辨系数,通常取 0.5。  $X_0(t)$  与  $X_i(t)$  间的关联度为:

$$\gamma_{0i} = \frac{1}{n} \sum_{t=1}^n \xi_{0i}(t) \quad (4)$$

当  $\gamma_{0i}$  值大于 0.6 时,认为该因素与特征系列密切相关,可作为位移预测的影响因素。

## 2 白家包滑坡概况

### 2.1 地质条件

白家包滑坡位于湖北省秭归县香溪河西岸,距入江口约 2.5km。滑坡地貌呈阶梯状,后缘与前缘较陡,中部相对平缓。滑坡下滑坡度在  $10^\circ \sim 20^\circ$  之间,方向为北偏东  $85^\circ$ ,整体平面形态呈短舌状。滑坡前缘直抵香溪河,高程约为 125~135m,后缘与出露的基岩为界,高程约为 265m,左右两侧分别以山脊下部基岩和

山梁为界，滑坡前缘宽度约为 500m，后缘宽度约为 300m，纵长约为 550m，滑体平均厚度约为 45m，面积为  $2.2 \times 10^5 \text{ m}^2$ ，体积约  $9.9 \times 10^6 \text{ m}^3$ ，属于大型滑坡(尚敏等，2021)，图 1 为白家包滑坡工程地质平面图。

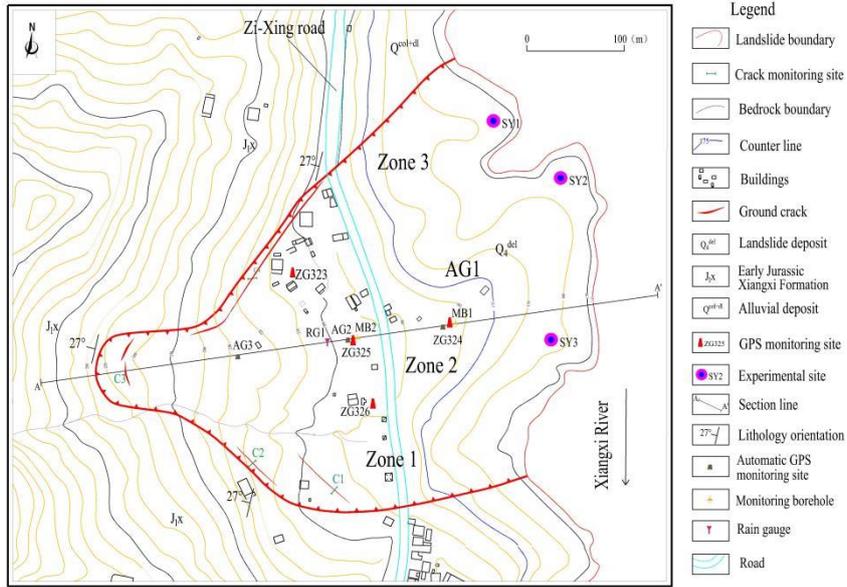


图 1 白家包滑坡工程地质平面图(程刚等，2025)  
Fig.1 Engineering geological plan map of the Baijiabao landslide

白家包滑坡属典型崩坡积成因，滑体物质主要为粉质粘土夹碎块石土。滑带位于崩坡积物与下伏基岩接触面，成分以粉质粘土为主<sup>[6]</sup>。白家包滑坡沿 I-I' 截面地质剖面图如图 2 所示。

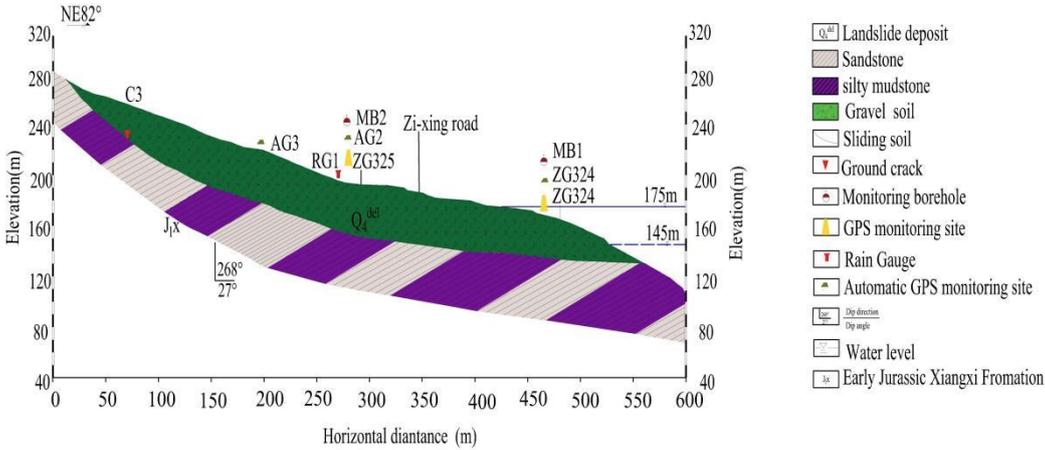


图 2 白家包滑坡地质剖面图  
Fig.2 Geological profile of the Baijiabao landslide

## 2.2 滑坡变形监测

2017 年，白家包滑坡布设了 1 个自动化 GPS 监测示范点，在原有监测墩旁设置了 ZD1、ZD2、ZD3 三个自动化监测点(秦世伟等，2025)。点位布置如图 3 所示。本文选取位于滑坡中后部左侧边界、变形显著的 ZD3 监测点数据作为分析对象，时间跨度为 2017 年 10 月 30 日至 2020 年 1 月 27 日，共计 820 组。



图3 白家包滑坡监测点布置图

Fig.3 Layout of monitoring points at the Baijiabao landslide

### 2.3 监测数据提取

滑坡自动化监测数据包括日累计位移、日降雨量、库水位及地下水位。将原始日数据分别聚合为日、周、旬、月四种时间尺度。本文之所以选取这四种特定的时间尺度，主要基于以下考量：①工程适用性，在三峡库区滑坡监测预警实践中，‘日、周、旬、月’是监测日报、周报、旬报及月报中最标准的统计周期，具有明确的工程应用导向；②物理规律覆盖，现有研究表明降雨与库水位对滑坡变形的滞后时间多集中在 7~30 天(李丽敏等, 2020)，‘周’（7 天）和‘旬’（10 天）恰好处于该敏感时间窗内，能够有效捕捉滑坡对诱发因素的短、中期响应特征，而‘日’和‘月’则分别代表了高频波动与长期趋势(Guo *et al.*, 2025; 黄盛锋等, 2020)。相比于 3 天、5 天等非标准划分，该尺度组合在保证物理意义的同时，更能满足分级预警的实际需求。其中日时间尺度下共提取出 820 组数据，周时间尺度下提取出 117 组数据，旬时间尺度下提取出 82 组数据，月时间尺度下提取出 27 组数据。四个时间尺度下的累计位移、降雨量、库水位及地下水位变化曲线如图 4 所示。可以观察到，随着时间尺度增大，数据量减少，曲线更为平滑，且单个时间尺度内的累积降雨量显著增加。

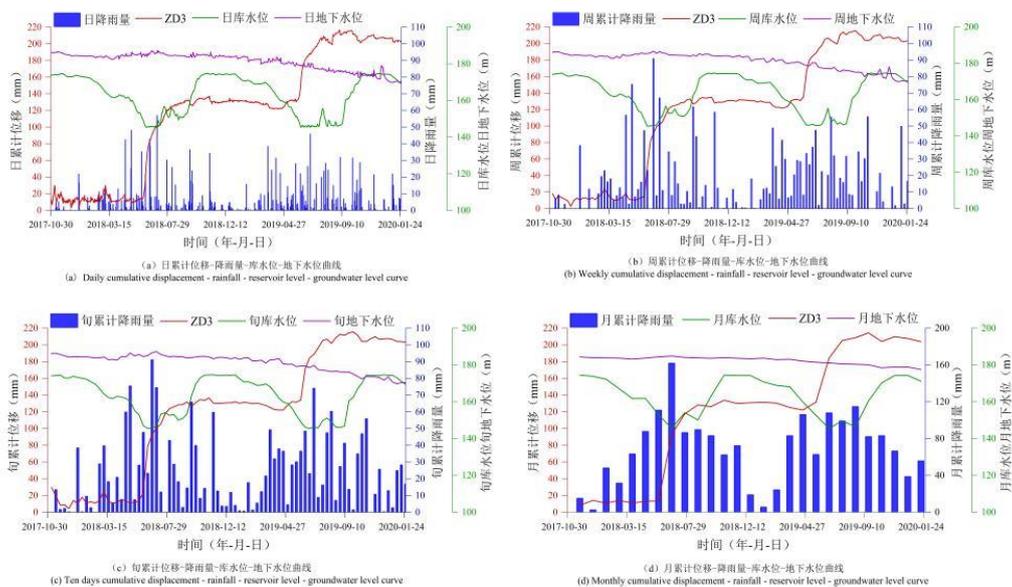


图4 ZD3 监测点累计位移-降雨-库水位-地下水位曲线

Fig.4 Curves of cumulative displacement, rainfall, reservoir water level, and groundwater level at monitoring point ZD3

为确保不同时间尺度预测结果的可比性，所有尺度的训练集与测试集均覆盖相同的时间段。训练集为2017年10月30日至2019年7月21日的数据，测试集为2019年7月22日至2020年1月27日的数据。日监测数据的训练集、测试集分别有630组和190组数据；周监测数据的训练集、测试集分别有90组和27组数据；旬监测数据的训练集、测试集分别有63组和19组数据；月监测数据的训练集、测试集分别有21组和6组数据。

### 3 预测模型

#### 3.1 滑坡累计位移的EEMD分解

采用EEMD算法对各时间尺度下的累计位移进行分解。参考Huang *et al.*(2020)的推荐值，设置噪声标准差系数为0.2，白噪声添加次数为200次。日尺度位移被分解为8个IMF分量和1项残差，而周、旬、月尺度均分解出5个IMF和1项残差。

将不同时间尺度下所分解出的残差项作为趋势项位移，累计位移与趋势项位移的差值作为周期项位移<sup>[17]</sup>。通过叠加趋势项位移与周期项位移叠加，可精确重构原始位移，确保了分解过程的可靠性。四个时间尺度的分解结果如图5所示。

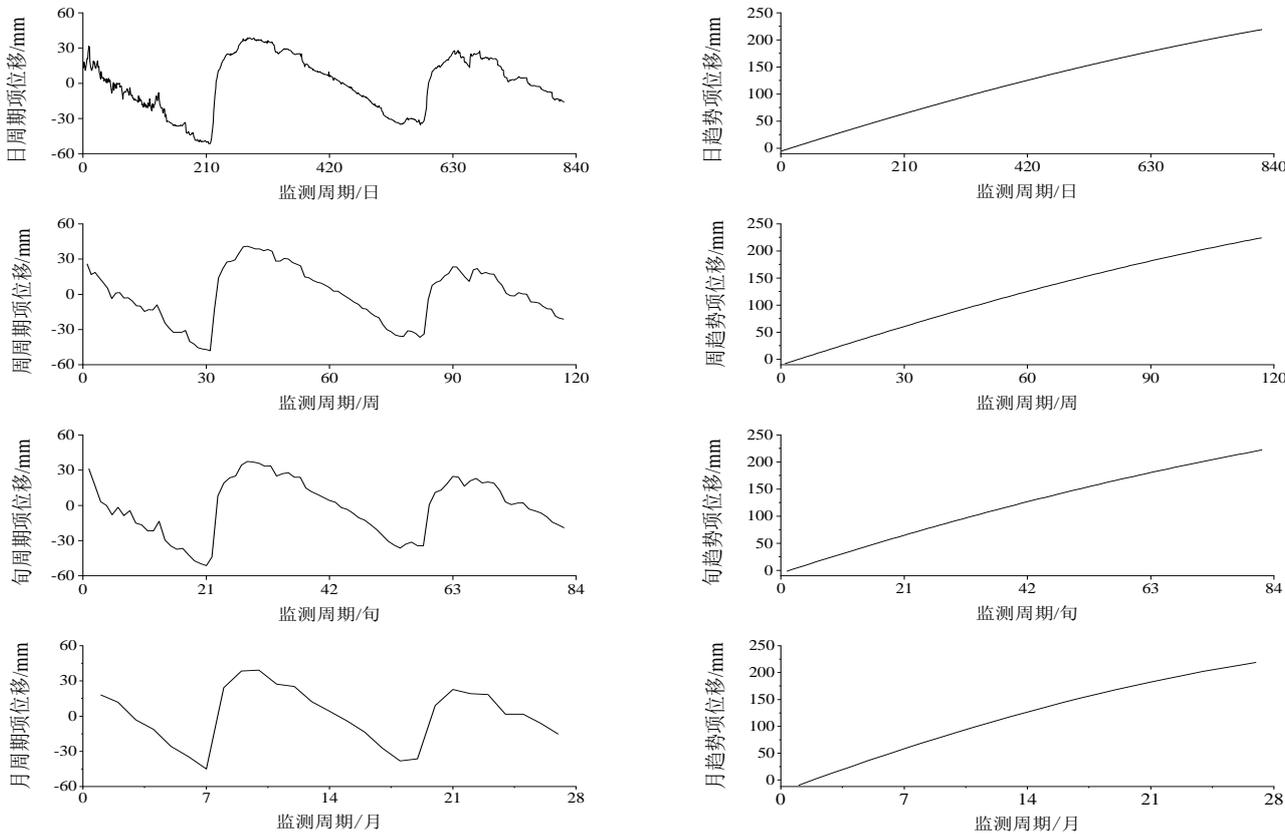


图5 四个时间尺度下累计位移EEMD分解  
Fig.5 EEMD decomposition of cumulative displacement at four time scales

#### 3.2 诱发因素选取

为构建周期项位移的预测模型，需确定其关键诱发因素。考虑到降雨、库水位、地下水及位移变化率是主要影响因素，为每个时间尺度初步选取了9个表征指标作为备选输入变量，如表1所示。

表 1 不同时间尺度的诱发因素表征指标

Table 1 Characterization indicators of inducing factors at different time scales

时间尺度	备选影响因子
日	当日降雨量 (X1)；前两日累计降雨量 (X2)；当日与前两日累计降雨量 (X3)； 当日库水位 (X4)；当日与前一日库水位差值 (X5)； 当日与前一日累计位移差值 (X6)；当日与前两日累计位移差值 (X7)； 当日地下水位 (X8)；当日与前一日地下水位差值 (X9)
周	本周累计降雨量 (Y1)；前两周累计降雨量 (Y2)；本周与前两周累计降雨量 (Y3)； 本周库水位 (Y4)；本周与前一周期库水位差值 (Y5)； 本周与前一周期累计位移差值 (Y6)；本周与前两周累计位移差值 (Y7)； 本周地下水位 (Y8)；本周与前一周期地下水位差值 (Y9)
旬	本旬累计降雨量 (Z1)；前两旬累计降雨量 (Z2)；本旬与前一旬累计降雨量 (Z3)； 本旬库水位 (Z4)；本旬与前一旬库水位差值 (Z5)； 本旬与前一旬累计位移差值 (Z6)；本旬与前两旬累计位移差值 (Z7)； 本旬地下水位 (Z8)；本旬与前一旬地下水位差值 (Z9)
月	本月累计降雨量 (W1)；前两月累计降雨量 (W2)；本月与前两月累计降雨量 (W3)； 本月库水位 (W4)；本月与前一周期库水位差值 (W5)； 本月与前一周期累计位移差值 (W6)；本月与前两月累计位移差值 (W7)； 本月地下水位 (W8)；本月与前一周期地下水位差值 (W9)

为了消除指标定义中的歧义，确保研究的可重复性，本文对表 1 中涉及的‘前两日/周/旬/月’等滞后及累积指标的计算方式进行了统一界定。设定当前监测时刻为  $t$ ，对应的时间尺度（日、周、旬或月）下的降雨量或位移量为  $V_t$ ，则各指标的计算公式定义如下：

当前时段量（如  $X_t, Y_t$  等）：指当前时刻  $t$  发生的各类监测值，即  $V_t$ ；

前两日/周/旬/月累计量（如  $X_2, Y_2$  等）：指当前时刻之前两个时间步长的累积值，不包含当前时刻，计算公式为：

$$\sum_{i=1}^2 V_{t-i} = V_{t-1} + V_{t-2} \quad (5)$$

当前与前两日/周/旬/月累计量（如  $X_3, Y_3$  等）：指包含当前时刻在内的过去三个时间步长的总和，计算公式为：

$$\sum_{i=0}^2 V_{t-i} = V_t + V_{t-1} + V_{t-2} \quad (6)$$

库水位与地下水位差值指标同理，例如‘当日与前一日库水位差值’定义为  $L_t - L_{t-1}$ 。”

分别计算周期项位移时间序列与不同时间尺度的库水位—降雨—地下水位之间的灰色关联度，当分辨系数  $\rho=0.5$  得到的灰色关联度大于 0.6 时，则可以认为该诱发因素表征指标与周期项位移密切相关，将作为 GRU 模型的输入项。计算结果如表 2 所示。由表 2 可知，在日、旬、月尺度下，所有因子的关联度均高于 0.6（除 X9、W9 略低外），表明这些因子与周期项位移关联性强。而在周尺度下，关联度普遍在 0.66-0.71 之间，虽略低于其他尺度，但仍超过 0.6 的门槛值，这表明初选的降雨、库水位、地下水位及位移历史状态等 9 个因子均与滑坡周期项位移存在较强的非线性映射关系。考虑到阶跃型滑坡的变形往往是多物理场耦合作用的结果，贸然剔除符合阈值要求的因子可能导致关键前兆信息的丢失。此外，GRU 模型内部独特的门控机制（重置门与更新门）具备自适应特征加权能力，能够在训练过程中自动识别并抑制冗余信息，有效降低了因特征保留较全而引发过拟合的风险。因此，本文最终保留所有 9 个通过灰色关联度初筛（ $\xi > 0.6$ ）的因子作为预测模型的输入变量，以确保多维度信息的充分融合。

表 2 不同时间尺度的影响因素灰色关联度值

Table 2 Grey correlation degrees of influencing factors at different time scales

日时间尺度		周时间尺度		旬为时间尺度		月时间尺度	
X1	0.8950	Y1	0.6676	Z1	0.9133	W1	0.9186
X2	0.8950	Y2	0.6674	Z2	0.9123	W2	0.9188
X3	0.8950	Y3	0.6676	Z3	0.9129	W3	0.9189
X4	0.8951	Y4	0.6676	Z4	0.9143	W4	0.9183
X5	0.9046	Y5	0.7050	Z5	0.8355	W5	0.8959
X6	0.8946	Y6	0.6674	Z6	0.9052	W6	0.9202
X7	0.8946	Y7	0.6660	Z7	0.9059	W7	0.9200
X8	0.8950	Y8	0.6676	Z8	0.9142	W8	0.9184
X9	0.8815	Y9	0.6601	Z9	0.8970	W9	0.8681

### 3.3 预测模型建立

不同时间尺度下经 EEMD 分解得到的趋势项位移曲线平滑且单调，故采用多项式拟合进行预测。周期项位移的预测是决定累计位移预测精度的关键。

鉴于其复杂的非线性特征，本文选取门控循环单元（GRU）模型对白家包滑坡不同监测频率下的周期项位移进行预测。利用 MATLAB 软件搭建 GRU 模型结构包括：输入层、GRU 层、全连接层、输出层，其中 GRU 层中隐藏单元数为 20，最大迭代次数、最小 batch 值和初始学习率的值分别为 500、10 和 0.01。需要说明的是，模型参数的选取是基于经验试错法（Trial-and-error）确定的。尽管不同时间尺度的训练样本量存在差异，但为了排除模型结构复杂度对预测结果的干扰，确保各时间尺度预测性能的可比性，本文在所有实验中均保持上述模型超参数一致。该参数组合经预实验验证，在不同样本量下均能保证模型收敛并获得较为稳健的预测效果。

## 4 结果分析

### 4.1 趋势项位移预测

四个时间尺度下的趋势项位移均呈现出良好的平滑性和趋势性，采用多项式拟合获得了极高的精度，具体拟合方程及误差指标如表 3 所示。从中可见，趋势项位移的预测误差远小于后续的周期项，说明其预测是可靠且高精度的。

表 3 各监测频率的趋势项位移预测结果

Table 3 Prediction results of trend term displacement at different time scales

时间尺度	拟合方程	R <sup>2</sup>	RMSE (mm)	MAE (mm)
日	$y = -0.00009x^2 + 0.3523x - 5.9294$	1	1.249	0.960
周	$y = -0.0045x^2 + 2.5456x - 11.478$	1	0.317	0.275
旬	$y = -0.0091x^2 + 3.5216x - 5.1754$	1	0.072	0.055
月	$y = -0.1303x^2 + 12.483x - 22.483$	1	0.245	0.211

### 4.2 周期项位移预测

周期项位移反映了滑坡对外界诱发因素的动态响应，波动性大，预测难度较高。将时间尺度下筛选出的 9 个诱发因子作为 GRU 模型的输入，对周期项位移进行预测。预测结果如图 6 所示，评价精度指标见表 4。

从表 4 可以看出，周尺度下的周期项位移预测精度最高，月尺度预测精度最差。这表明适中的时间尺度有助于 GRU 模型更好地学习周期项位移的变化规律。

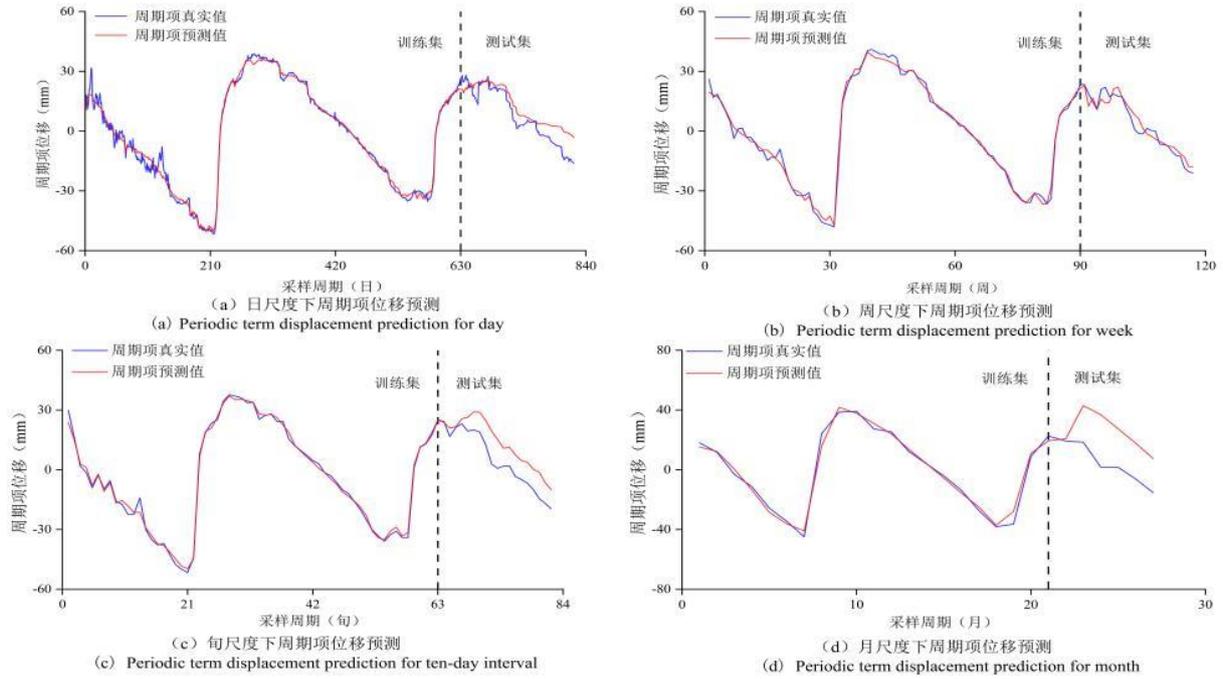


图 6 各时间尺度下滑坡周期项位移预测  
Fig.6 Prediction of periodic term displacement of the landslide at different time scales

表 4 周期项位移预测结果  
Table 4 Prediction results of periodic term displacement

监测频率	R <sup>2</sup>	RMSE (mm)	MAE (mm)
日	0.9651	5.2750	4.6676
周	0.9693	2.7114	2.2465
旬	0.9501	3.9894	2.8059
月	0.80557	7.0372	6.6916

为了进一步探究造成上述精度差异的内在机理, 本文结合 EEMD 分解特征与诱发因子响应特性进行分析: 首先, 从信号分解的频域复杂性来看, 日尺度下的累计位移包含了大量由测量误差或微气象波动引起的高频随机噪声。这也导致在 EEMD 分解中, 日尺度数据分解出了多达 8 个 IMF 分量 (见 3.1 节), 显著高于周、旬、月尺度的 5 个分量。过多的高频 IMF 分量增加了 GRU 模型捕捉主要变形规律的难度, 导致图 6(a) 中的预测曲线呈现出杂乱的震荡特征。其次, 从诱发因子的响应相关性来看, 虽然表 2 显示日尺度的灰色关联度较高, 但这部分 ‘高相关’ 可能包含了降雨事件对地表位移计的瞬时物理冲击或电信号干扰 (伪相关)。相比之下, 周尺度数据相当于对原始信号进行了一次天然的 ‘低通滤波’。它在滤除高频噪声的同时, 保留了滑坡变形对 ‘阶跃期’ 强降雨和库水位下降的真实响应特征 (灰色关联度维持在 0.66-0.71 之间)。图 6(b) 显示, 周尺度的预测曲线既没有日尺度的剧烈噪点, 又比月尺度 (图 6(d)) 更精准地还原了位移台阶的起跳时刻, 从而在 ‘信噪比’ 上达到了最佳平衡, 实现了最优的预测精度。

#### 4.3 累计位移预测

将趋势项与周期项的预测值叠加, 得到最终的各时间尺度累计位移预测结果, 如图 7 和表 5 所示。综合分析图 7 和表 5 可知, 周尺度与旬尺度的累计位移预测效果最优, 其预测曲线与实测值吻合度最高, R<sup>2</sup> 均大于 0.999, 且 RMSE 和 MAE 显著低于日尺度和月尺度。这证实了时间尺度对预测精度存在显著影响: 日尺度过小, 数据噪声和短期波动干扰大, 增加了模型捕捉主要规律的难度; 月尺度过大, 数据量过少, 模型难以充分学习复杂的演化特征。而周、旬等适中尺度能在数据量与序列平滑度之间取得最佳平衡, 从而获得更高的预测精度。

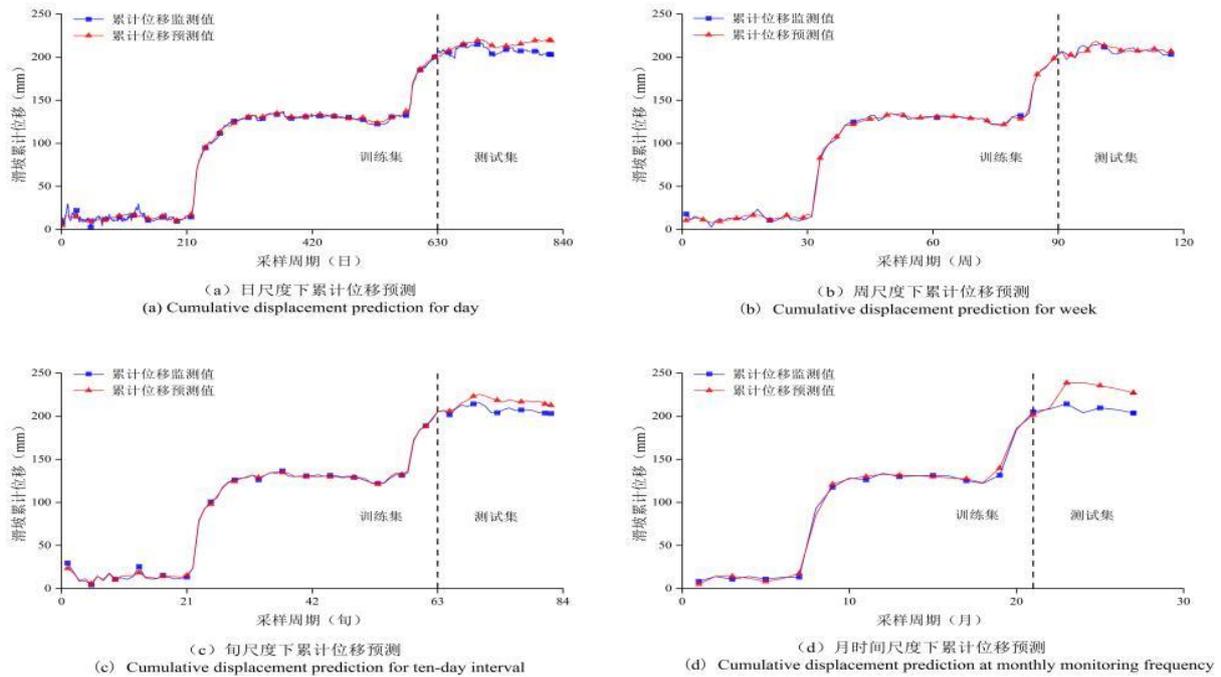


图 7 各时间尺度下滑坡累计位移预测  
Fig.7 Prediction of cumulative displacement of the landslide at different time scales

表 5 累计位移预测结果  
Table 5 Prediction results of cumulative displacement

时间尺度	$R^2$	RMSE ( mm )	MAE ( mm )
日	0.9991	6.0509	5.4875
周	0.9998	2.6032	2.1381
旬	0.9996	4.0369	2.8029
月	0.9985	7.2303	6.9122

值得注意的是，由于时间尺度的不同，测试集中的样本点数量存在显著差异（日尺度 190 个 vs 月尺度 6 个）。虽然样本量悬殊，但由于四个时间尺度均覆盖了相同的测试时段（2019 年 7 月 22 日至 2020 年 1 月 27 日），RMSE 和 MAE 本质上量化了预测出的滑坡变形轨迹与真实轨迹之间的平均物理偏差（mm）。这种物理层面上的偏差在工程应用中具有一致的评价标准，即偏差越小，模型对滑坡运动路径的还原能力越强。此外，本文选用的决定系数（ $R^2$ ）作为一种无量纲的归一化指标，能够有效消除样本量大小对拟合优度评价的影响。综合 RMSE（物理精度）与  $R^2$ （统计拟合度）来看，各时间尺度下的评价结果具有良好的可比性。

## 5 结论

本文基于三峡库区白家包滑坡的自动化监测数据，系统研究了不同时间尺度对阶跃型滑坡累计位移预测精度的影响，通过构建 EEMD-GRU 耦合预测模型，得出以下主要结论：

（1）基于时间序列加法模型与 EEMD 分解，能有效将滑坡累计位移分解为趋势项和周期项。其中，趋势项位移主要受滑坡自身地质条件控制，表现为长期单调增长，采用多项式拟合可实现高精度预测；周期项位移则受外部环境因子波动影响，非线性特征显著。

(2) 利用灰色关联分析筛选出的诱发因子，结合 GRU 模型对周期项位移进行预测，在各时间尺度下均表现出良好性能。其中，周尺度预测效果最佳，其周期项预测的 RMSE 和 MAE 均为各尺度中最低，表明该尺度下的环境因子与位移波动之间的非线性映射关系最为清晰。

(3) 累计位移的最终预测精度强烈依赖于时间尺度，呈现出“周>旬>日>月”的规律。周尺度预测结果最优，其 RMSE 相较于日、月、旬尺度分别降低了 56.98%、64.00% 和 35.51%。其原因在于：日尺度数据虽时间分辨率高，但包含了大量与滑坡整体运动无关的高频随机噪声（测量误差、微气象波动），干扰了模型训练；而月尺度数据虽然平滑，但过度的数据聚合导致关键的“阶跃”启动信号被平滑丢失，无法敏锐捕捉突发变形。

(4) 揭示了最优时间尺度的物理机制。本研究证实，周尺度之所以能成为预测精度的平衡点，根本原因在于其采样频率与滑坡的水文地质响应特征相匹配。白家包滑坡作为典型的涉水堆积层滑坡，其“粉质粘土夹碎石”的物质组成决定了对降雨及库水位变化的响应存在 7~15 天的物理滞后。周尺度（7 天）的采样间隔恰好覆盖了这一固有响应窗口，既有效滤除了日尺度的瞬时噪声，又完整保留了诱发因素驱动滑坡变形的有效信息（高信噪比），从而实现了对阶跃型位移趋势的最精准捕捉。

(5) 本研究成果为三峡库区滑坡的监测预警实践提供了科学依据。建议在实际工程中采取“分级变频”的动态监测策略：在滑坡匀速变形阶段或非雨季，优先采用旬或月尺度数据以降低成本；而在位移阶跃变形期或强降雨季节，应加密至周尺度，利用其在信噪比与响应机理上的双重优势，提供更为稳健可靠的预警依据。

## REFERENCE

- Bogaard, T.A., Greco, R., 2018. Invited Perspectives: Landslide Hydrology: From Hydrology to Pore Pressure Drift. *Natural Hazards and Earth System Sciences*, 18(1): 31-39.
- Cao, Y., Yin, K., Alexander, D.E., et al., 2016. Using an Extreme Learning Machine to Predict the Displacement of Step-like Landslides in Relation to Controlling Factors. *Landslides*, 13(4): 725-736.
- Cheng, G., Wu, Y.F., Cao, D.S., et al., 2025. Research and Application of Artificial Intelligence Algorithms in Landslide Monitoring and Prediction Technology. *Bulletin of Geological Science and Technology*, 44(5): 302-316 (in Chinese with English abstract).
- Demir, G., Aytekin, M., Akgun, A., 2015. Landslide Susceptibility Mapping by Frequency Ratio and Logistic Regression Methods: An Example from Niksa-Resadiye (Tokat, Turkey). *Arabian Journal of Geosciences*, 8(3): 1801-1812.
- Deng, D.M., Liang, Y., Wang, L.Q., et al., 2021. Displacement Prediction Method Based on Ensemble Empirical Mode Decomposition and Support Vector Machine Regression: A Case Study of Landslides in Three Gorges Reservoir Area. *Rock and Soil Mechanics*, 38(12): 3660-3669 (in Chinese with English abstract).
- Fu, X., Zhang, Y., Fu, X., et al., 2025. Deformation Trend Prediction for Hydraulically Driven Landslides in Reservoir Areas: Modeling from High Temporal Resolution Data. *Geoenvironmental Disasters*, 12: 43.
- Fu, Z., Li, D.Q., Wang, S., et al., 2025. Causes of Episodic Movement of the Baijiabao Landslide Based on Multiple-Time Scale Analysis. *Landslides*, 21: 1-15.
- Guo, F., Lai, P., Huang, F.M., et al., 2024. Literature Review and Research Progress of Landslide Susceptibility Mapping Based on Knowledge Graph. *Earth Science*, 49(5): 1584-1606 (in Chinese with English abstract).
- Guo, F., Xu, Z.Z., Hu, J.L., et al., 2025. Forecasting Step-like Landslide Displacement Through Diverse Monitoring Frequencies. *Journal of Mountain Science*, 22(1): 122-141.
- Guo, Z., Chen, L., Gui, L., et al., 2020. Landslide Displacement Prediction Based on Variational Mode Decomposition and WA-GWO-BP Model. *Landslides*, 17(3): 567-583.
- Guo, Z., Chen, L., Yin, K., et al., 2020. Quantitative Risk Assessment of Slow-Moving Landslides from the Viewpoint of Decision-Making: A Case Study of the Three Gorges Reservoir in China. *Engineering Geology*, 273: 105667.
- He, R., Zhang, W., Dou, J., et al., 2024. Application of Artificial Intelligence in Three Aspects of Landslide Risk Assessment: A Comprehensive Review. *Rock Mechanics Bulletin*, 3(4): 15-33.
- Huang, F., Teng, Z., Guo, Z., et al., 2023. Uncertainties of Landslide Susceptibility Prediction: Influences of Different Spatial Resolutions, Machine Learning Models and Proportions of Training and Testing Dataset. *Rock Mechanics Bulletin*, 2: 100028.
- Huang, F.M., Chen, J., Yang, Y., et al., 2025. Review and Prospect of Research on Hazard-Causing Environmental Factors Related to Landslide Susceptibility. *Bulletin of Geological Science and Technology*, 44(2): 14-37 (in Chinese with English abstract).
- Huang, S.F., Chen, Z.B., Zheng, D.Z., 2020. Sensitivity Analysis of Slope Stability Influencing Factors Based on Grey Correlation Method and Strength Reduction Method. *The Chinese Journal of Geological Hazard and Control*, 31(3): 35-40 (in Chinese with English abstract).
- Huang, X., Guo, F., Deng, M., et al., 2020. Understanding the Deformation Mechanism and Threshold Reservoir Level of the Floating Weight-Reducing Landslide in the Three Gorges Reservoir Area. *Landslides*, 17: 2879-2894.
- Jiang, W.J., Leng, X.P., Lin, X., et al., 2023. Landslide Displacement Prediction Based on Time Series and Temporal Convolutional Network. *Science Technology and Engineering*, 23(9): 3672-3679 (in Chinese with English abstract).
- Keefer, D.K., Wilson, R.C., Mark, R.K., et al., 1987. Real-Time Landslide Warning During Heavy Rainfall. *Science*, 238(4829): 921-925.
- Krkac, M., Spoljaric, D., Bernat, S., et al., 2016. Method for Prediction of Landslide Movements Based on Random Forests. *Landslides*, 14(3): 947-960.
- Li, L.M., Guo, F., Wen, Z.Z., et al., 2020. Dynamic Prediction of Landslide Displacement Based on Long Short-Term Memory and Multiple Influencing Factors. *Science Technology and Engineering*, 20(33): 13559-13567 (in Chinese with English abstract).
- Liu, G.N., Chen, L.D., Fu, Y.P., et al., 2011. Influence of Rainfall and Reservoir Water Level Fluctuation on Landslide. *Research of Soil and Water Conservation*, 18(6): 200-203 (in Chinese with English abstract).
- Liu, Y., Li, X.R., Zhan, W.W., et al., 2023. State Affine Transfer Learning Method for Hydrodynamic-Driven Landslides. *Earth Science*, 48(5): 1793-1806 (in Chinese with English abstract).
- Qin, S.W., He, H., Xie, P., et al., 2025. Baijiabao Landslide Displacement Prediction Based on Multivariate CNN-LSTM Neural Network. *Journal of Basic Science and Engineering*, 33(5): 1-13 (in Chinese with English abstract).
- Roering, J.J., Mackey, B.H., Handwerker, A.L., et al., 2015. Beyond the Angle of Repose: A Review and Synthesis of Landslide Processes in Response to Rapid Uplift, Eel River, Northern California. *Geomorphology*, 236: 109-131.
- Shang, M., Liao, F., Ma, R., et al., 2021. Quantitative Analysis of Correlation Between Deformation of Baijiabao Landslide and Reservoir Water Level and Rainfall. *Journal of Engineering Geology*, 29(3): 742-750 (in Chinese with English abstract).

- Song, K., Chen, L.Y., Liu, Y.L., et al., 2022. Dynamic Mechanism of Reactivation Deformation of Deep Ancient Landslide Induced by Rainfall. *Earth Science*, 47(10): 3665-3676 (in Chinese with English abstract).
- Wang, H., Long, G., Liao, J., et al., 2022. A New Hybrid Method for Establishing Point Forecasting, Interval Forecasting, and Probabilistic Forecasting of Landslide Displacement. *Natural Hazards*, 111: 1479-1505.
- Xu, Q., Tang, M.G., Xu, K.X., et al., 2008. Study on Spatial-Temporal Evolution Laws and Early Warning Prediction of Landslides. *Chinese Journal of Rock Mechanics and Engineering*, 27(6): 1104-1112 (in Chinese with English abstract).
- Xu, Q., Zeng, Y.P., 2009. Research on Acceleration Variation Characteristics of Creep Landslide and Early-Warning Prediction Indicator of Critical Sliding. *Chinese Journal of Rock Mechanics and Engineering*, 28(6): 1099-1106 (in Chinese with English abstract).
- Yang, B., Yin, K., Lacasse, S., et al., 2019. Time Series Analysis and Long Short-Term Memory Neural Network to Predict Landslide Displacement. *Landslides*, 16: 677-694.
- Yang, B., Xiao, T., Wang, L., et al., 2022. Using Complementary Ensemble Empirical Mode Decomposition and Gated Recurrent Unit to Predict Landslide Displacements in Dam Reservoir. *Sensors*, 22: 1320.
- Ye, R.Q., Fu, X.L., Guo, F., et al., 2021. Analysis of Deformation Characteristics and Mechanism of Geological Hazards in Three Gorges Reservoir Area During Operation Period. *Journal of Engineering Geology*, 29(3): 680-692 (in Chinese with English abstract).

## 中文参考文献

- 程刚, 吴勇飞, 曹德胜, 等, 2025. 人工智能算法在滑坡监测与预测技术中的研究与应用. *地质科技通报*, 44 (5): 302-316.
- 邓冬梅, 梁焯, 王亮清, 等, 2021. 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. *岩土力学*, 38(12): 3660-3669.
- 郭飞, 赖鹏, 黄发明, 等, 2024. 基于知识图谱的滑坡易发性评价文献综述及研究进展. *地球科学*, 49(5): 1584-1606.
- 黄发明, 陈杰, 杨阳, 等, 2025. 滑坡易发性相关致灾环境因子研究的综述与展望. *地质科技通报*, 44(2): 14-37.
- 黄盛锋, 陈志波, 郑道哲, 2020. 基于灰色关联度法和强度折减法的边坡稳定性影响因素敏感性分析. *中国地质灾害与防治学报*, 31(3): 35-40.
- 江文金, 冷小鹏, 林祥, 等, 2023. 基于时间序列与时间卷积网络的滑坡位移预测. *科学技术与工程*, 23(9): 3672-3679.
- 李丽敏, 郭伏, 温宗周, 等, 2020. 基于长短时记忆与多影响因子的滑坡位移动态预测. *科学技术与工程*, 20(33): 13559-13567.
- 刘广宁, 陈立德, 伏永朋, 等, 2011. 降雨和库水升降对滑坡的影响. *水土保持研究*, 18(6): 200-203.
- 刘勇, 李星瑞, 詹伟文, 等, 2023. 动水驱动型滑坡的状态仿射迁移学习方法. *地球科学*, 48(5): 1793-1806.
- 秦世伟, 何浩, 谢攀, 等, 2025. 基于多变量 CNN-LSTM 神经网络的白家包滑坡位移预测. *应用基础与工程科学学报*, 33(5): 1-13.
- 尚敏, 廖芬, 马锐, 等, 2021. 白家包滑坡变形与库水位、降雨相关性定量化分析研究. *工程地质学报*, 29(3): 742-750.
- 宋琨, 陈伦怡, 刘艺梁, 等, 2022. 降雨诱发深层老滑坡复活变形的动态作用机制. *地球科学*, 47(10): 3665-3676.
- 许强, 汤明高, 徐开祥, 等, 2008. 滑坡时空演化规律及预警预报研究. *岩石力学与工程学报*, 27(6): 1104-1112.
- 许强, 曾裕平, 2009. 具有蠕变特点滑坡的加速度变化特征及临滑预警指标研究. *岩石力学与工程学报*, 28(6): 1099-1106.
- 叶润青, 付小林, 郭飞, 等, 2021. 三峡水库运行期地质灾害变形特征及机制分析. *工程地质学报*, 29(3): 680-692.