

物理引导的库岸谷幅变形智能预测模型

陈铭熙¹, 林朋辉¹, 蒋舒², 姜清辉^{2*}

1. 广西大学 土木建筑工程学院, 南宁 530004

2. 武汉大学 土木建筑工程学院, 武汉 430072

摘要: 库岸谷幅持续收缩变形会威胁大坝安全, 因此谷幅变形预测对大坝安全管理至关重要。本文以溪洛渡水电站谷幅变形为研究对象, 提出一种基于物理引导的智能预测模型, 开展谷幅变形预测。基于谷幅变形规律分析, 建立统计回归物理模型 (STPM), 获取不同诱发因素对谷幅变形贡献的位移分量。据此, 以各分量为输入, 联合灰色关联度分析 (GRA)、长短期记忆网络 (LSTM) 和随机森林 (RF), 构建基于物理引导的机器学习预测框架 (STPM-GRA-LSTM-RF), 开展不确定性预测分析。研究结果表明: (1) 溪洛渡谷幅变形主要由黏塑性变形、黏弹性变形和有效应力引起, 对总位移平均贡献率分别为 67.71%、29.75% 及 2.51%; (2) 与 STPM 模型、LSTM 模型、SVM 模型和 XGBoost 模型相比, 本文提出模型的预测精度更高, 并因其考虑了谷幅变形机制, 可靠性显著提升。研究成果为类似库岸高边坡的变形预测与安全管控提供有价值的参考。

关键词: 库岸边坡; 谷幅变形; 位移预测; 统计回归物理模型; 灰色关联度分析; 长短期记忆网络; 随机森林算法

中图分类号: P694

收稿日期: 2025-05-13

Research on Physics-guided Intelligent Prediction Model for Valley Contraction Deformation of Reservoir Bank Slopes

Chen Mingxi¹, Lin Penghui¹, Jiang Shu², Jiang Qinghui^{2*}

1. School of Civil and Architectural Engineering, Guangxi University, Nanning 530004, China

2. School of Civil Engineering, Wuhan University, Wuhan 430072, China

Abstract: Reservoir impoundment-induced valley contraction deformation poses a significant threat to the overall safety of dams, making the prediction of valley width deformation crucial for dam safety management. This study focuses on the valley deformation characteristics of the Xiluodu Hydropower Station and proposes a physics-guided intelligent prediction model to conduct valley deformation forecasting. Based on the analysis of valley deformation patterns, a statistical regression physics-based model (STPM) is developed to quantify the displacement components contributed by individual triggering factors to valley deformation. Building upon this foundation, a machine learning prediction framework (STPM-GRA-LSTM-RF) integrating grey relational analysis (GRA), long short-term memory networks (LSTM), and random forest algorithms (RF) is constructed with displacement components as inputs, incorporating uncertainty analysis in valley deformation prediction. Key findings include: (1) The valley deformation at Xiluodu is primarily caused by viscoelastic deformation, viscoplastic deformation, and effective stress-induced deformation, contributing 67.71%, 29.75%, and 2.51%, respectively, to the total displacement; (2) Compared with the STPM, LSTM, SVM, and XGBoost models, the proposed STPM-GRA-LSTM-RF model delivers higher predictive accuracy, moreover, by incorporating the physico-mechanical mechanisms of valley deformation, it significantly enhances the reliability of the predictions. This research provides valuable insights for deformation prediction and safety control of high reservoir slopes in analogous projects.

Key words: Reservoir bank slope; Valley deformation; Displacement prediction; Statistical regression physics-based model; Grey correlation analysis; Long short-term memory network; Random forest algorithm

基金项目: 广西自然科学基金项目 (No. 2024GXNSFBA010226); 广西科技重大专项 (No. AA23023016); 广西科技基地和人才专项项目 (No. AD23026111); 国家自然科学基金项目 (No. 52509141); 广西青年科技人才工程资助 (No. GXYESS2025142); 广西青苗人才计划项目 (No. ZX02080030324020)。

作者简介: 陈铭熙(1993—), 男, 助理教授, 博士, 主要从事滑坡灾害预测预警与风险评估等方面的教学和科研。ORCID: 0000-0003-3988-8329. E-mail: chenmingxi@gxu.edu.cn

***通讯作者:** 姜清辉(1972—), 男, 教授, 博士生导师, 主要从事高边坡稳定性分析相关工作。E-mail: jqh1972@whu.edu.cn

0 引言

水电站建设是开发水电资源的重要途径,对清洁能源的发展具有重要意义(Rong *et al.*, 2024^[17])。库岸岩体在库水作用下会发生变形,导致峡谷两岸在水平方向上产生相对位移,这种横河方向上变形现象被称为谷幅变形。国内外水电站在蓄水后发生库岸谷幅变形的事件屡见不鲜,如法国 Malpasset、瑞士 Zeuzier、意大利 Beauregard、意大利 Vajont、李家峡、锦屏 I 级、溪洛渡等水电站(Barla and Paronuzzi, 2013^[1]; Duffaut, 2013^[7]; 何柱等, 2018^[9]; 周绿等, 2023^[37])。谷幅变形进一步发展会导致岸坡失稳,威胁大坝的安全。因此,开展库岸边坡谷幅变形趋势预测对大坝的安全风险管理至关重要。

蓄水期库岸边坡谷幅变形机制较为复杂,涉及多种内外因素相互作用的耦合过程,目前尚无统一的定论(Wang *et al.*, 2020^[24])。但总体而言,蓄水期谷幅变形与库水的渗流驱动及劣化效应等因素紧密相关。一方面,在水库蓄水之后,水位上升导致孔隙水压力增加,会降低岩体有效应力,使岸坡岩体产生塑性变形(杨强等, 2015^[28]; 杨雨亭等, 2022^[29]; Wang *et al.*, 2023^[23])。另一方面,库水的物理化学作用会劣化岩体的强度和变形模量,降低岸坡稳定性(Zhang *et al.*, 2023^[31])。在长期浸泡及消落带干湿循环条件下,这种库水劣化效应尤为显著。同时,库水作用引起的变形导致岩体内部的损伤累积,牵引消落带之上岩体发生变形,进一步降低岩体的强度和刚度,加剧谷幅收缩变形(Zhou *et al.*, 2022^[38])。殷跃平^[30]等(2022)系统性研究了边坡下部岩体结构劣化加速岸坡整体演化进程的规律,并总结其典型变形破坏模式为“低高程区岩体劣化—低高程区结构失效—岸坡整体变形失稳”。

目前,依据是否考虑岸坡变形机制,谷幅变形预测主要采用物理预测模型和数据驱动模型两种方法。物理预测模型基于物理力学机制和流变损伤理论,采用数值模拟方法,或建立解析解模型和统计回归物理模型,预测谷幅的长期变形趋势(庄超等, 2019^[35]; Zhou *et al.*, 2022^[38]; Li *et al.*, 2023^[13])。例如, Wang^[24] *et al.* (2020) 采用 TFINE 非线性有限元软件模拟锦屏 I 级水电站坝肩边坡谷幅变形,

计算结果与观测值吻合较好,并提出岩石有效应力原理决定了初蓄期水库库盆的变形。雷峥琦^[11]

(2018)以溪洛渡谷幅为研究对象,选取水头、温度、时效三个影响因子,建立考虑变形机制的统计回归物理模型,结果表明蓄水和温度荷载直接引起的变形量较小,大部分变形为时效变形。物理预测模型的物理意义明确,但边坡演化过程复杂,构建精确的模型较为困难,而数值模拟方法还存在计算耗时的问题。数据驱动模型通常采用时间序列回归分析、人工智能等方法对时序观测数据进行建模,将演化机制隐藏于“黑箱子”中(Gong *et al.*, 2024^[8])。近年来,数据驱动模型因其概念简单、短期预测精度较高而在地质灾害识别与预测中得到广泛应用(Wen *et al.*, 2023^[26]; Zhao *et al.*, 2023^[34]; Wang *et al.*, 2024^[21]; Zhao *et al.*, 2025^[33])。例如, Sun^[19] *et al.* (2020) 应用 EEMD-ITD 和 DE-SFLA-LSSVM 混合模型对溪洛渡谷幅变形开展预测。然而,数据驱动模型存在泛化能力弱、可解释性、物理约束与机理融合等方面存在不足,其可靠性受到一定的质疑(周创兵等, 2025^[36])。一些学者尝试采用可解释性机器学习探讨了外界诱发因素与边(滑)坡变形的因果关系(Li *et al.*, 2024^[12]),但如何将变形机制与观测数据有机融合,开展高效、可靠的谷幅变形预测仍是亟待解决的问题。

地质模型、岩土体参数、观测数据等存在不确定性是影响变形预测可靠性的另一关键要素(仇文岗等, 2022^[32]; 陈铭熙等, 2024^[4])。近年,数据驱动模型中引入不确定性分析,开展水库滑坡位移区间预测和概率预测研究(Ma *et al.*, 2018^[15]; Wang *et al.*, 2023^[22])。在水电站近坝边坡开挖动态变形预测中,一些学者采用贝叶斯更新方法融合地质模型、观测数据和数值模型融合,同步更新模型信息及变形预测结果,以降低预测不确定性(Li *et al.*, 2016^[14]; Sun *et al.*, 2019^[18])。例如, Chen^[5] *et al.* (2022)以四川多诺水电站右岸近坝边坡为例,采用分位数回归求解 Fukui-Okubo 模型,开展边坡失稳时间概率预测并提出临滑预报准则。谷幅变形涉及坝址区内整个河谷边坡系统,演化过程及物理机制更为复杂,因此在变形预测中应考虑不确定性因素的影响,但目前针对谷幅变形概率预测的研究极少。

本文以溪洛渡水电站库岸高边坡谷幅变形为研究对象,在分析变形演化规律的基础上,结合岩石蠕变模型和有效应力理论,提出预测库岸边坡谷幅收缩水平方向变形的统计回归物理模型(STPM)。据此,融合灰色关联度分析法(GRA)、长短期记忆网络(LSTM)、随机森林(RF),构建基于物理引导的机器学习预测模型(STPM-GRA-LSTM-RF),开展库岸边坡谷幅变形的不确定性预测。

1 溪洛渡谷幅收缩变形规律分析

1.1 工程概况

溪洛渡水电站位于四川省雷波县和云南省永善县交界的金沙江上(图1)。该地区处于永盛向斜盆地,盆地四周被背斜及叶竹坪隆起所包围,向斜的轴向北东,其中北西翼地层平缓,倾角为 $10^{\circ}\sim 15^{\circ}$,南东翼较陡,倾角为 $20^{\circ}\sim 35^{\circ}$,盆地北东长35 km,北西宽25 km,面积约750 km²,为一个未被区域断裂切割的、宽缓且相对完整的构造向斜盆地。水电站挡水结构采用双曲拱坝,坝底高程为324.5 m,坝顶高程为610 m,坝高285.5 m。



图1 溪洛渡水库鸟瞰图(来源于 Google Earth)
Fig.1 Aerial view of Xiluodu Reservoir (from Google Earth)

坝址所在地区构造发育,侵蚀强烈,地质条件复杂(图2)。河岸及河床基岩主要由500 m厚的上二叠纪峨眉山玄武岩($P_2\beta$)组成,其上覆约20 m~40 m厚的上二叠纪宣威砂页岩(P_2x),下覆约260 m厚的下二叠纪阳新石灰岩(P_1y)。在玄武岩和石灰岩地层之间有一层薄薄的粘土页岩($P_2\beta_n$),岸坡顶部则为第四纪松散沉积物(Q_4),下伏砂质页岩。其中玄武岩层内发育有13条缓倾角层间以及层内错动带,倾角 $\angle 4^{\circ}\sim 10^{\circ}$,厚度0.5 m~1.8 m,其内充填主要含有玄武岩角砾岩、0.5 cm~3 cm大

小的碎片,抗剪强度低,渗透性强(王昀等,2023^[25]; Chen *et al.*, 2024^[31])。错动带的强渗透性和蠕滑变形,对库岸边坡变形的影响较大(何柱等,2018^[9])。拱坝上下游一共布设9组谷幅测线(图3)监测谷幅变形,其中四组测线位于水库上游,其余测线位于水库下游。




图2 溪洛渡水库地质剖面图
Fig.2 Geological profile of Xiluodu Reservoir




图3 溪洛渡水库谷幅测线布置平面图
Fig.3 Configuration of valley measuring lines for Xiluodu Reservoir

溪洛渡水库于2012年12月开始蓄水,并于2014年9月29日首次抬升至正常蓄水位600 m,其后库水位在550 m~600 m范围内波动,最大变幅50 m。2012~2018年的水库蓄水过程如图4所示。蓄水后,岩体应力出现变化及调整,岸坡谷幅发生持续性的收缩变形,对坝体稳定性构成威胁(庄超等,2019^[35])。截至2018年4月12日,受水库蓄水影响,谷幅收缩已累积较大位移,最大位移超过80 mm,且变形仍在逐渐发展,未达到收敛状态。由于上游水位高,蓄水对岩体变形的影响较大(何

柱等,2018^[9])。因此选取位于上游的VDR03-VDL03(下文简称VD3)和VDR01-VDL01(下文简称VD1)以及下游靠近水电站的VDR05-VDL05(下文简称VD5)为研究对象,将坝址两岸视为一个边坡系统,分析其谷幅收缩水平方向变形特征,并据此预测其变形趋势。




图4 溪洛渡谷幅变形与库水位监测曲线

Fig.4 Monitoring curves of valley deformation and reservoir water level at Xiluodu Reservoir

1.2 库岸谷幅变形特征分析

以最大谷幅变形测线VD3为例,对谷幅收缩变形进行分析。依据水库蓄水过程,谷幅收缩变形可划分为初始蓄水期和正常蓄水期两个阶段(图5),其中虚线代表划分周期时间。




图5 VD3 谷幅变形、变形速率及库水位曲线

Fig.5 Valley deformation, deformation velocity and reservoir water level of the measuring line VD3

(1) 初始蓄水期

初始蓄水期时间为2013年4月至2014年5月,库水位高程从423 m快速升至541 m(死水位高程)。在此期间,随着库水位的升高,死水位以下的岩体从天然状态向饱和状态发展,孔隙水压力增加,导致岩体有效应力降低,岸坡岩体通过蠕变、压缩等变形方式适应应力场的变化,使得谷幅变形速率快速增加;而当库水位稳定在死水位高程时,

岩体内部形成稳定的渗流场,岸坡岩体变形减缓,此时谷幅变形呈现出阶段性的平稳演化特征。

(2) 正常蓄水期

2014年5月至今为正常蓄水期,库水位在死水位(541 m)和正常蓄水位(600 m)之间循环涨落。截至2018年4月,在正常蓄水期间,溪洛渡库区已历经4次库水涨落周期,包括4次高水位期和3次死水位期(图6)。




图6 不同库水条件下VD3谷幅变形时间曲线

Fig.6 Displacement-time curve of the measuring line VD3 under different reservoir water conditions

为研究正常蓄水期库水变幅对岸坡谷幅变形的影响,从原始谷幅变形曲线中扣除初始蓄水期间的变形量,提取正常蓄水期的谷幅变形,并进一步将其分解为高水位期和死水位期的谷幅变形曲线(图6)。对比不同库水条件下谷幅变形曲线可知,高水位期累计变形量可达约47 mm,而死水位期累计变形量仅6 mm左右,高水位期变形速率也比死水位阶段变形速率高,呈现出明显差异。在库水位上升阶段,岩体内部孔隙渗透压力增大,导致岩体有效应力降低。同时,蓄水过程中岩体持续发生时效蠕变及软化效应,进一步削弱其力学强度,三者共同作用加剧谷幅变形发展。当进入库水位下降阶段,水岩接触区域逐渐减少,此时变形主控因素转变为死水位以下长期饱和和岩体所产生的蠕变变形。在整个蓄水周期中,谷幅变形曲线存在少量变形恢复,总体变形趋势却呈现增加态势,表明谷幅变形具有明显的塑性变形特征以及少量弹性变形特征。

综上所述,近坝库岸谷幅的持续变形主要由以下机制驱动:一是库水周期性涨落导致岩体有效应力的改变而引发的变形;二是水岩相互作用而导致岩体产生的蠕变变形和岩体软化变形。

1.3 统计回归物理模型建立

由上述变形特征分析可知,水库蓄水后诱发谷幅收缩变形主要包括岩体的有效应力变形、蠕变变形以及软化变形,据此建立考虑各变形驱动因素的统计回归物理模型,即:

$$\delta_1 = \delta_{11} + \delta_{12} + \delta_{13}, \quad (1)$$

式中, δ_1 为谷幅变形, δ_{11} 为软化变形分量, δ_{12} 为蠕变变形分量, δ_{13} 为有效应力变形分量。

(1) 蠕变及软化变形分量

由于蠕变变形和软化变形分量均具有时效演化特征,因此将二者作为一个整体进行建模。结合谷幅时效变形特征,采用黏塑性模型和黏弹性模型描述该变形分量。

西原模型是典型的黏弹塑性模型,由开尔文体(弹簧与黏壶并联)和宾汉姆体(摩擦滑块与黏壶串联)组成。该模型可以较好地描述岩体蠕变变形过程,尤其在反映流变中的弹-黏弹-黏塑性特性上具有明显优势。在应力小于屈服应力时,只有开尔文体被激活,此时该模型能模拟岩体发生的弹性变形和黏性变形。在应力大于屈服应力时,宾汉姆体被激活,此时该模型能模拟岩体发生屈服后产生的黏塑性变形。西原模型表达式如下:

$$\varepsilon = \begin{cases} \frac{\sigma_0}{k_1} + \frac{\sigma_0}{k_2} \left(1 - e^{-\frac{k_2}{\eta_2} t} \right) & \sigma < \sigma_s \\ \frac{\sigma_0}{k_1} + \frac{\sigma_0}{k_2} \left(1 - e^{-\frac{k_2}{\eta_2} t} \right) + \frac{\sigma_0 - \sigma_s}{\eta_1} t & \sigma \geq \sigma_s \end{cases}, \quad (2)$$

式中, ε 为应变, σ 为应力, k_1 为弹性模量, k_2 为黏弹性模量, η_1 和 η_2 分别为宾汉姆体元件和开尔文体元件的黏滞系数。

为简化分析,西原模型黏塑性部分的变形速率设为定值,从而建立在库水变化条件下岩体的黏塑性变形方程,表达式如下:

$$\delta_{1m} = a_1 t', \quad (3)$$

式中, δ_{1m} 为黏塑性变形的位移量, a_1 为黏塑性变形分量系数, t' 为水位下降累计时间。

鉴于消落带区域岩体是处于持续软化状态的蠕变变形,其物理参数呈现出动态变化,为简化分

析将西原模型中黏弹性模量 k_2 和黏滞系数 η_2 设为定值,黏弹性公式简化如下:

$$\delta_{1k} = b_1 \left[1 - \frac{1}{1 + (t_n/a_2)^{a_3}} \right], \quad (4)$$

式中, δ_{1k} 为某一时刻的蠕变变形, t_n 为库水循环涨落开始后的累计时间, b_1 、 a_2 、 a_3 为黏弹性变形分量系数。

(2) 有效应力变形分量

胡克定律适用于谷幅垂直向变形,并通过泊松比物理含义可以推算得出谷幅水平向变形(公式7)。

$$\varepsilon = \frac{\sigma_d}{E}, \quad (5)$$

$$\delta_o = \nu \varepsilon, \quad (6)$$

式中, σ_d 为有效应力增量, E 为物体变形模量, δ_o 为水平向变形, ν 为泊松比,则库水下降引发的边坡谷幅水平向变形公式为:

$$\delta_{1o} = \nu \frac{\sigma_d}{E}, \quad (7)$$

式中, δ_{1o} 为水平向有效应力变形增量,其中有效应力增量 σ_d 计算公式为:

$$\sigma_d = \rho g (h_0 - h), \quad (8)$$

式中, ρ 为库水密度, g 为重力加速度, h_0 为库水下降期的初始水位, h 为当前库水位。

为简化公式,忽略库水位波动对变形的影响,假定各库水下降期的有效应力增量相等,认为库水下降期的水位与时间线性相关。可得有效应力变形分量公式:

$$\delta_{13} = \sum_{n=1}^4 a_4 \Delta h_n, \quad (9)$$

式中, Δh_n 为第 n 次库水位下降的高差, a_4 为有效应力分量系数。

通过上述分析,预测谷幅变形的统计回归物理模型归纳为:

$$\delta_1 = a_1 t' + b_1 \left[1 - \frac{1}{1 + (t_n/a_2)^{a_3}} \right] + \sum_{n=1}^4 a_4 \Delta h_n. \quad (10)$$

1.4 统计回归物理模型预测结果分析

采用上文提出的统计回归物理模型对谷幅测线 VD1、VD3 和 VD5 进行多元回归分析,并采用 Levenberg-Marquardt 算法进行参数估计。各模型参

数计算结果见表 1，回归分析结果如图 7 所示。由表 1 可知，统计回归物理模型对各谷幅测线的位移时间序列均具有高质量的拟合效果，决定系数 R^2 分别为 0.97、0.97 和 0.96，验证提出模型的有效性。

表 1 统计回归物理模型参数计算结果

Table 1 Calculation results of model parameters in statistical regression physical model

谷幅测线	α_1	α_2	α_3	b_1	α_4	R^2
VD1	0.050	105.649	2.336	23.898	0.015	0.97
VD3	0.067	91.995	2.930	21.885	0.015	0.97
VD5	0.046	113.745	2.636	29.000	0.012	0.96




图 7 谷幅变形拟合结果. (a) VD1; (b) VD3; (c) VD5
Fig.7 The fitting results of valley deformation. (a) VD1;
(b) VD3; (c) VD5

由图 7 可知，黏塑性变形分量、黏弹性变形分量和有效应力变形分量对谷幅变形的贡献值依次

递减。截至 2018 年 4 月，谷幅测线 VD1、VD3 和 VD5 累计的黏塑性变形分量分别约为 52.85 mm、70.82 mm 和 49.62mm，分别约占总变形的 66.89%、74.55%以及 61.69%，平均占比为 67.71%，表明黏塑性变形对谷幅变形影响占据主导地位。黏弹性变形分量对谷幅变形影响次之，其中测线 VD1、VD3 和 VD5 累计的黏弹性变形分量分别为 23.86 mm、21.88 mm 和 28.98 mm，约占总变形 30.20%、23.03%以及 36.03%。VD1、VD3 和 VD5 三条谷幅测线的累计有效应力变形分量分别约为 2.23 mm、2.30 mm 和 1.84 mm，占总变形的 2.82%、2.42%以及 2.28%，在三个变形分量中占比最小。

从谷幅变形的时效演化规律来看，三个分量呈现出差异化的增长模式：黏塑性变形分量随库水位循环涨落而不断演进并逐渐累加，表明其在未来将成为控制谷幅变形发展的主导因素；黏弹性变形分量在经历初始蓄水期的快速增加后而逐渐进入平稳发展阶段；而有效应力变形分量则呈现与库水位循环涨落同步演进的阶跃式变形特征，但对谷幅变形影响较小。

综上所述，提出的统计物理回归模型对谷幅变形的位移时间曲线具有高质量拟合精度，有效地反馈溪洛渡谷幅变形的演化规律。控制谷幅变形的三个分量中，黏塑性变形分量对谷幅变形影响占据主导，黏弹性变形分量次之，有效应力变形分量对谷幅变形影响最小。另外，由图 7 不难发现，拟合值与观测值之间依然存在一定偏差。造成这一误差的主要原因为谷幅变形机制复杂，提出的物理预测模型未能全面反映谷幅变形的演化规律及力学机制。

2 谷幅变形智能预测模型

2.1 智能预测模型框架

由于谷幅变形演化的复杂性，物理预测模型的预测精度相对较低。为了实现更为可靠的库岸边坡谷幅变形预测，本研究联合统计回归物理模型（STPM）、灰色关联度分析（GRA）、长短期记忆网络（LSTM）和随机森林（RF）方法，构建基于物理引导的谷幅变形智能预测模型（STPM-GRA-LSTM-RF），其总体框架的建模流程描述如下（图 8）。




图 8 基于物理引导的谷幅变形预测流程图

Fig.8 Flowchart of physics-guided prediction model for valley deformation

(1) 数据处理及输入选择。输入数据选用 STPM 模型的黏塑性变形分量、弹塑性变形分量和有效应力变形分量，以及库水位作为机器学习的输入数据。库水位作为输入的目的在于增强预测模型对触发因素响应的敏感性。输入预测模型的数据事先进行归一化处理。同时，采用灰色关联度分析（GRA）计算并筛选关联度大于 0.5 的重要特征数据，作为预测模型的输入数据集。

(2) 谷幅变形智能预测模型。采用长短期记忆神经网络（LSTM）对谷幅变形进行预测，并将特征筛选后的数据划分训练集和测试集，开展模型训练及预测分析。

(3) 特征重要性输出。随机森林（RF）通过评估每个输入特征对预测目标的贡献程度来计算特征重要性，明确不同输入特征对模型预测的影响程度。

(4) 模型预测性能评价。采用多种评价指标，

评估 STPM-GRA-LSTM-RF 模型在点预测和区间预测的预测性能。同时，为了验证提出模型的有效性及其优势，预测分析中还采用 STPM 模型、LSTM 模型、支持向量回归模型（SVM）和极限梯度提升模型（XGBoost）四个预测模型与其进行对比分析。

2.2 数据处理及输入选择

2.2.1 归一化处理

数据归一化处理可以消除不同数据之间的量纲和数值量级存在差异的影响，从而加速训练和提升智能预测模型的泛化能力。数据归一化处理公式如下：

$$x'_i = \frac{x_i - x_{\max}}{x_{\max} - x_{\min}}, \quad (11)$$

式中， x_i 为原始数据， x'_i 为归一化后的数据， $x_{\max}$ 和 $x_{\min}$ 分别为原始数据中的最大值和最小值。

2.2.2 灰色关联度分析（GRA）

归一化后的数据集输入 GRA 中，开展关联度计算与筛选，其中黏塑性变形分量、弹塑性变形分量、有效应力变形分量和库水位分量作为比较序列，谷幅变形作为目标序列，若 ξ 大于 0.5 则该比较序列可作为模型输入特征，反之则剔除。灰色关联度计算公式如下：

$$A_{ij} = |x_{ij} - x_{oj}|, \quad (12)$$

$$\xi_{ij} = \frac{d + 0.5c}{A_{ij} + 0.5c}, \quad (13)$$

式中， A_{ij} 为绝对差值矩阵， x_{ij} 为第 i 个比较序列的第 j 个数据点， x_{oj} 为目标序列的第 j 个数据点， ξ_{ij} 为第 i 个比较序列与目标序列在第 j 个数据点的灰色关联度， c 为差值矩阵中最大差值， d 为差值矩阵中最小差值。

2.3 谷幅变形智能预测模型构建

2.3.1 长短期记忆网络（LSTM）

为增强预测可靠性，本研究采用多层 LSTM 网络单元（图 9）堆叠，搭建机器学习框架（图 10）。在模型中，输入层将输入序列数据转换为张量，随后在 LSTM 层中进行训练和处理。LSTM 层中的最高层将其输出传递至全连接层以实现降维，然后输出层生成对谷幅下一时刻变形的预测。LSTM 单元内部结构主要由遗忘门、输入门和输出门组成，具体结构如图 9 所示：

(1) 遗忘门。遗忘门负责决定从先前的状态 C_{t-1} 中筛选信息，以形成当前状态 C_t 。遗忘门的输

出值在 $[0, 1]$ 区间，如果接近 1 则表示保留更多的信息，接近 0 则表示遗忘更多的信息。遗忘门的计算公式为：

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), \quad (14)$$

式中， f_t 为遗忘门输出，其值介于 0 到 1 之间， σ 为 Sigmoid 激活函数，即 $\sigma(x) = 1/(1+e^{-x})$ ， x_t 为当前时刻的输入， h_{t-1} 为上一时刻的隐藏状态， W_f 为权重矩阵， b_f 为偏置向量。

(2) 输入门。输入门当前输入 x_t 对当前状态 C_t 的贡献程度，分为输入门的开启程度和候选状态的计算，其计算公式分别为：

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad (15)$$

$$c_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c), \quad (16)$$

式中， i_t 为输入门的输出， W_i 为输入门的开启程度权重矩阵， W_c 为候选状态权重矩阵， b_i 为偏置向量， b_c 为单元状态的偏置向量， $\tanh$ 为激活函数，即 $\tanh(x) = (e^x - e^{-x}) / (e^x + e^{-x})$ 。

(3) 输出门。输出门管理当前状态 C_t 对隐藏状态 h_t 的影响。输出门的计算公式为：

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \quad (17)$$

$$h_t = o_t \tanh(c_t), \quad (18)$$

式中， o_t 为输出门的输出； W_o 为输出门的开启程度权重矩阵， b_o 为偏置向量， h_t 为当前的隐藏状态。

本研究中，采用 Pytorch 搭建 LSTM 机器学习模型。模型精度受到学习率、批量大小、优化器、损失函数、Dropout、隐藏单元数和隐藏层数等超参数的影响。为了确保模型预测的准确性，通过测试不同超参数组合，找到表现最佳的超参数设置。以 VD1 测线为例，对 epochs、dropout 以及 batch_size 三个超参数进行调试。均方根差（RMSE）对较大的预测误差更为敏感，能反映超参数调整对预测精度的影响，因此选择 RMSE 作为调参效果的衡量指标，调试结果及最终超参数设置如图 11 和表 2 所示。同时，采用自适应矩估计（Adam）优化算法优化预测模型，提升训练效率和精度（Reyad *et al.*, 2023^[16]）。表 2 为各模型超参数的设置值。其中模型输入数据的 80%划分为训练集，剩余 20%用作测试集。LSTM 模型中设置预测时间窗口的大小为

10，即使用 10 个连续的数据样本（每个样本含 4 个特征）来预测下一个变形值。

表 2 超参数设置表

参数	定义	设置值
batch_size	每次训练选取的数据样本数量	64
optimizer	优化调整网络的权重和偏置	Adam
epoch	模型训练时期次数	300~400
dropout	模型训练阶段忽略单元	0.01
hidden_size	隐藏层的维度大小	32、128
损失函数	衡量预测值与真实值的差距	Huber
隐藏层数	神经网络中的中间层	2




图 9 单个 LSTM 单元结构图

Fig.9 Schematic diagram of a single LSTM unit structure




图 10 LSTM 全网络结构图

Fig.10 Rchitecture diagram of the LSTM network




图 11 超参数敏感性分析

Fig.11 Sensitivity analysis of hyperparameters

2.3.2 随机森林 (RF)

随机森林 (RF) 模型擅长处理非线性、过拟合、大样本和特征等问题,泛化能力相对较好 (Sun *et al.*, 2024^[20])。在随机森林 (RF) 中,特征重要性是通过计算所有树中每个特征所带来的不纯度减少的加权平均,得到每棵树在所有节点处对每个特征的不纯度减少量值 (即均方误差的减少量)。具体公式如下:

$$I_j = \frac{1}{T} \sum_{t=1}^T \sum_{m=1}^M \Delta MSE_{t,m,j}, \quad (19)$$

式中, I_j 是第 j 个特征的重要性, T 是随机森林中的决策树的数量, M 是 T 中的所有节点, $\Delta MSE_{t,m,j}$ 是在树 T 中,特征 j 所在的节点 m 分裂时,节点均方误差的减少量。

2.3.3 预测区间

受温度、环境噪音和监测误差等因素的影响,加之边坡变形演化固有的非线性、不确定性和随机性等特征,因此边坡变形预测应考虑不确定性因素的影响。本研究引入区间预测理论来量化表征边坡位移预测中的不确定性问题 (Devore, 2000^[6])。位移预测区间由下式给出:

$$Y_i = y_{oi} \pm \sum_{i=1}^{i+3} t_{\alpha/2, N-D} S \sqrt{1 + \frac{1}{N} + \frac{N(x_i - \bar{x})^2}{N \sum_{i=1}^N x_i^2 - \left(\sum_{i=1}^N x_i\right)^2}}, \quad (20)$$

$$S = \sqrt{\frac{\sum_{i=1}^N (y_i - y_{oi})^2}{N - 2}}, \quad (21)$$

式中, Y_i 为该点处的置信区间上限及下限值, S 为均方误差平均根, y_{oi} 为预测值, $t_{\alpha/2, N-D}$ 为 T 分布, N 为参与预测区间计算个数, D 为自由度, x_i 为时间 (监测开始时间与当前时间的相隔天数), $\bar{x}$ 为平均时间, y_i 为真实值。

2.4 评价指标

采用一套综合的评价指标体系,评估所提出的算法的点预测和区间预测的性能。点预测性能评价采用拟合优度 (R^2)、平均绝对误差 (MAE)、均方误差 (MSE)、均方根差 (RMSE) 和平均绝对百分比误差 (MAPE) 五个指标,度量预测值与观测值之间的接近程度。各点预测评价指标定义如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y_{oi}|, \quad (22)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y_{oi})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (23)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y_{oi})^2, \quad (24)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_{oi})^2}, \quad (25)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - y_{oi}|}{y_i} \times 100\%. \quad (26)$$

区间预测性能评价采用区间预测覆盖率 (PICP)、平均预测区间宽度 (MPIW) 和归一化平均预测区间宽度 (NMPIW) 三个指标,评估预测区间的可靠性。各区间预测评价指标定义如下:

$$\varepsilon_i^{1-\alpha} = \begin{cases} 1, y_i \in [y_{down}, y_{up}] \\ 0, y_i \notin [y_{down}, y_{up}] \end{cases}, \quad (27)$$

$$PICP = \frac{1}{n} \sum_{i=1}^n \varepsilon_i^{1-\alpha}, \quad (28)$$

$$MPIW = \frac{1}{n} \sum_{i=1}^n |y_{down} - y_{up}|, \quad (29)$$

$$NMPIW = \frac{MPIW}{R}, \quad (30)$$

式中, n 为样本数量, $\bar{y}$ 为平均值, y_{up} 和 y_{down} 为第 i 个时间段的区间预测值上限值和下限值。


区间预测评价指标中, PICP 值反映实测值落入预测区间的概率,其范围为 $[0, 1]$ 。PICP 值越大,表示区间对实测值的覆盖程度越高,预测越可靠 (Chang *et al.*, 2024^[2])。NMPIW 用于度量预测区间宽度的相对大小, NMPIW 值越小,表明模型预测区间越紧凑,效果越好。理想情况下,预测区间应尽可能窄 (NMPIW 偏小),并且具有高覆盖概率 (PICP 偏大)。

3 结果与讨论


3.1 灰色关联度计算结果

各谷幅测线灰色关联度计算结果如图 12 所示。其中, WL 代表库水位 (Water Level), VPD 代表黏塑性变形分量 (Viscoplastic Deformation), VED


代表黏弹性变形分量（Viscoelastic Deformation），ESD 代表有效应力变形分量（Effective Stress Deformation），而 VD 则为预测目标，即谷幅变形（Valley Deformation）。由图 12 分析可知，所有谷幅测线的输入特征数据与目标列之间的关联度均超过 0.5，因此所选的四个特征均可作为预测模型的有效输入特征。在这些特征中，黏塑性变形分量（VPD）的灰色关联度计算值最高，其次是黏弹性变形分量（VED）。这一结果与上述变形规律分析中各分量贡献占比一致，进一步验证特征选择的合理性。



(a) VD1 灰色关联度计算结果



(b) VD3 灰色关联度计算结果



(c) VD5 灰色关联度计算结果

图 12 灰色关联度计算结果

Fig.12 Calculation results of grey correlation degree

3.2 变形预测结果及评价

STPM-GRA-LSTM-RF 模型与其它模型的预测位移曲线及预测区间如图 13 和图 14 所示。各预测模型的点预测评价指标如表 3 和图 15 所示。

不同预测模型的预测结果如图 13 和图 14 和所示。各模型的点预测评价指标如表 3 和图 15 所示。各谷幅测线的预测结果显示，STPM 模型预测曲线与监测曲线存在显著偏离，MAE、MSE、RMSE 和 MAPE 值偏高，拟合优度 (R^2) 排第三，与其他预测模型相比，STPM 模型的预测性能一般。对于 LSTM 模型，该模型在捕捉位移演化趋势的能力上有所提升，各评价指标显示其预测性能良好，能够较为可靠地反映谷幅变形发展规律，但在部分监测时期尤其其边坡变形速率快速增加的阶段，其预测偏差仍较大，表明该模型在对突发或急剧变化情况的准确表征和预测仍存在一定挑战。除了在 VD1 测线的预测精度较高外，SVM 模型和 XGBoost 模型在其余测线的预测结果显著偏离监测值，预测效果较差。相比之下，STPM-GRA-LSTM-RF 模型展现出明显的优势。该模型的预测曲线与监测曲线吻合度高，可以准确地预测谷幅变形的演化趋势，其预测区间相对窄且具有高覆盖概率。与其余模型对比，提出模型的 MAE、MSE、RMSE 和 MAPE 值平均降低 54.6%，其 R^2 平均提升 1.67%，证明了融合物理模型预测信息与机器学习模型的预测方法能有效地提升预测的预测精度和可靠性。

为了考虑预测不确定性，本文还针对测试集数据，开展 STPM-GRA-LSTM-RF 模型的区间预测分析，评价指标结果如图 16 所示。所有谷幅测线的 PICP 值均大于 0.90，接近 1，表明除个别数据点外，绝大多数观测值均落在 95% 预测置信区间之内，与图 13 中预测区间（蓝色阴影区）对监测曲线的覆盖情况一致。同时，三条谷幅测线的 MPIW 值和 NMPIW 值计算结果均处于较低水平，显示提出模型的 95% 预测区间可以同时兼顾高覆盖率和适度紧凑性的特点。

此外，本研究在现有位移监测周期基础上，对未来两个蓄水周期的谷幅变形开展预测（图 17）。由图可知，谷幅变形在未来两个蓄水周期内趋于平稳。根据预测结果，测线 VD1、VD3 和 VD5 的估计位移增量分别约为 6.0 mm、9.9 mm 和 5.0 mm。

表 3 点预测评价指标对比

Table 3 Comparison of point prediction evaluation metrics

测线	MAE	MSE	RMSE	MAPE	R ²
VD1 _a	0.99	1.49	1.22	2.24%	0.99
VD1 _b	2.01	6.35	1.49	5.22%	0.97
VD1 _c	2.92	14.25	3.78	6.81%	0.94
VD1 _d	1.43	3.89	1.97	4.83%	0.98
VD1 _e	2.02	6.24	2.50	6.57%	0.97
VD1 _d	2.02	6.24	2.50	6.57%	0.97
VD3 _a	1.18	1.95	1.40	2.22%	0.99
VD3 _b	2.02	7.32	2.71	4.93%	0.98
VD3 _c	3.36	18.51	4.30	6.95%	0.94
VD3 _d	1.67	5.01	2.23	3.61%	0.98
VD3 _e	2.78	11.54	3.40	7.35%	0.97
VD5 _a	0.92	1.38	1.17	1.89%	0.99
VD5 _b	1.72	6.07	2.46	4.51%	0.97
VD5 _c	3.05	15.55	3.94	6.63%	0.93
VD5 _d	1.57	4.34	2.08	3.54%	0.98
VD5 _e	2.77	9.99	3.16	5.11%	0.96

注：a 代表 STPM-GRA-LSTM-RF；b 代表 LSTM 模型；c 代表 SVM 模型；d 代表 XGBoost 模型；e 代表 STPM 模型






图 15 点预测评价指标。(a) VD1；(b) VD3；(c) VD5

Fig.15 Evaluation metrics for point prediction. (a)VD1;

(b) VD3; (c) VD5





图 16 区间预测评价指标

Fig.16 Evaluation metrics for interval prediction




图 13 不同模型预测结果. (a) VDI; (b) VD3; (c) VD5

Fig.13 Prediction results across models. (a) VDI; (b) VD3; (c) VD5




图 14 不同模型预测区间对比.

Fig.14 Comparative analysis of prediction intervals across different models.




图 17 模型外推预测结果. (a) VD1; (b) VD3; (c) VD5

Fig.17 Extrapolated predictive outputs of the model. (a) VD1; (b) VD3; (c) VD5

3.3 预测特征重要性

在变形预测模型训练过程中,由随机森林获取不同特征对模型预测的影响程度,如图 18 所示。由图可知,在三条谷幅测线的预测中,黏塑性变形分量占据主导地位,平均占比 40.33%,进一步验证了溪洛渡谷幅变形主要受黏塑性变形控制。黏弹性变形分量的特征重要性略低于黏塑性变形,平均占比 36.67%。有效应力变形分量在各谷幅测线中所占的比重相对较小,但在模型预测中的作用仍不可忽视,平均占比 20.33%。库水位因素对三条谷幅测线中的重要性最低,表明该模型中,库水位变化对预测结果的影响较为有限,平均占比 2.67%,这一结果与既有研究的结论一致(雷峥琦, 2018^[11])。总体而言,提出的 STPM-GRA-LSTM-RF 模型不仅提升了谷幅变形预测的精度,并因考虑谷幅变形机制,其可靠性显著提升。

3.4 预测模型适用性

STPM-GRA-LSTM-RF 模型、STPM 模型、LSTM 模型、SVM 模型和 XGBoost 模型预测结果的对比分析表明,将物理预测模型的预测信息作为机器学习模型的输入,会显著提升模型的预测精度和可靠性,可以更有效地捕捉谷幅变形的位移趋势。同时,相较于确定性的点预测,本研究采用的区间预测能够更全面地反映预测的不确定性和潜在风险,为预测决策和风险管理提供更丰富的数据信息。在模型可解释性方面,随机森林模型揭示了各影响因素在模型预测中的作用大小,提升机器学习模型的透明度,有助于理解模型的预测依据和特征的重要性。

虽然提出的模型可提升谷幅变形预测的精度和可靠性,但是研究仍存在一些不足之处。例如,本文中所用的溪洛渡谷幅变形监测数据的采样频率较低(1~5 次/月),因此用于模型预测的数据样本相对较少,可能影响机器学习模型的训练效果。在未来进一步研究中,提出模型可通过如下方法进行优化:1) 引入变形模量、黏聚力和内摩擦角等物理力学参数拓展特征维度,丰富数据表征;2) 采用更先进监测技术,获取高频、高精度监测数据,提升监测数据质量,为预测模型提供优质数据输入(Wu et al., 2022^[27]; Zhu et al., 2024^[39]); 3) 开展时空变形预测,如引入时空卷积神经网络捕捉岩体变形的时空关联特征,并开展超参数敏感性及数据

集划分策略的鲁棒性验证,进一步提升预测可靠性(黄发明等, 2025^[10])。

本文提出的模型因考虑了谷幅变形物理机制,具有一定程度的泛化能力。但是,该模型是针对溪洛渡水电站库岸岩质边坡构建。溪洛渡谷幅收缩的主要原因是岩体软化效应及渗流驱动作用,且其响应特征随时间而动态演变。因此,其它工程案例采用该模型开展变形预测,其地质条件和变形主控机制应与本研究对象具有一定相似性。例如,锦屏 I 级水电站左岸边坡在蓄水期的变形规律与溪洛渡谷幅变形存在一定差异(杨强等, 2015^[28]),但总体而言,二者变形趋势及相应规律有相似之处。通过调整预测模型参数(尤其是物理模型参数),本文提出的模型可移植至类似工程案例。




图 18 特征重要性. (a) VD1; (b) VD3; (c) VD5

Fig.18 Importance of features. (a) VD1; (b) VD3; (c) VD5

4 结论

针对溪洛渡谷幅长期变形问题,本文在深入分析在库水涨落条件下谷幅收缩变形演化规律的基础上,提出考虑谷幅变形机制的统计回归物理模型,进而结合灰色关联度分析法(GRA)、长短期记忆网络(LSTM)和随机森林(RF),构建基于物理引导的谷幅变形智能预测模型(STPM-GRA-LSTM-RF)。本文主要结论如下:

(1) 蓄水期溪洛渡谷幅变形的主要原因为库水周期性涨落引发的岩体有效应力变化而引发的变形,以及水岩相互作用使岩体产生长期存在的蠕变变形与软化变形。

(2) 根据溪洛渡谷幅变形规律,构建考虑黏塑性变形分量、黏弹性变形分量和有效应力变形分量的统计回归物理模型。黏塑性变形分量为谷幅变形主导因素,对总位移平均贡献率为 67.71%;黏弹性变形分量次之,对总位移平均贡献率为 29.75%,并逐渐步入平稳发展阶段;有效应力变形分量对总位移贡献比最低,对总位移平均贡献率为 2.51%,并随库水位周期性涨落而呈阶梯式发展。

(3) 与 STPM 模型、LSTM 模型、SVM 模型以及 XGBoost 模型相比,STPM-GRA-LSTM-RF 预测模型的点预测精度更高,各谷幅测线区间预测的覆盖概率平均超过 90%,并且具有较低的预测区间平均宽度,表明提出的方法具有更高的预测精度与鲁棒性,可为谷幅变形预测及坝体稳定性的安全管理提供有价值的参考。

References

[1] Barla, G., Paronuzzi, P., 2013. The 1963 Vajont Landslide: 50th Anniversary. *Rock Mechanics and Rock Engineering*, 46:1267-1270. doi: 10.1007/s00603-013-0483-7

[2] Chang, X.Y., Guo, J., Qin, H., et al., 2024. Single-Objective and Multi-Objective Flood Interval Forecasting Considering Interval Fitting Coefficients. *Water Resources Management*, 38(10):3953-3972. doi: 10.1007/s11269-024-03848-2

[3] Chen, M.X., Feng, A.J., Wei, W., et al., 2024. Statistical Analysis of Long-Term Deformations and Determination of Warning Thresholds for Near-Dam Reservoir Bank Slopes. *Bulletin of Engineering Geology and the Environment*, 83(11):437. doi:

10.1007/s10064-024-03928-y

[4] Chen, M.X., Tao, P.J., Zhou, C.B., et al., 2024. Model Modification of Verhulst Inverse-Function Forecasting Model and Probabilistic Forecast for Landslide Failure Time. *Earth Science*, 49 (05): 1692-1705(in Chinese with English abstract).

[5] Chen, M.X., Wei, W., Jiang, Q.H., 2022. Use of Quantile Regression with Fukui-Okubo Model for Prediction and Early-Warning of Reservoir Bank Slope Failure. *Rock Mechanics and Rock Engineering*, 55(11): 7145-7169. doi: 10.1007/s00603-022-02975-9

[6] Devore, J.L., 2000. Probability and Statistics. *Pacific Grove: Brooks/Cole*.

[7] Duffaut, P., 2013. The Traps Behind the Failure of Malpasset Arch Dam, France, in 1959. *Journal of Rock Mechanics and Geotechnical Engineering*, 5(5): 335-341. doi: 10.1016/j.jrmge.2013.07.004

[8] Gong, W.P., Zhang, S.Y., Juang, C.H., et al., 2024. Displacement Prediction of Landslides at Slope-Scale: Review of Physics-Based and Data-Driven Approaches. *Earth-Science Reviews*, 104948. doi: 10.1016/j.earscirev.2024.104948

[9] He, Z., Liu, Y.R., Yang, Q., et al., 2018. Mechanism of Valley Deformation of Xiluodu Arch Dam and Back Analysis and Long-Term Stability Analysis. *Chinese Journal of Rock Mechanics and Engineering*, 37(S2): 4198-4206(in Chinese with English abstract).

[10] Huang, F.M., Ou, Y.W.P., Jiang, S.H., et al., 2024. Landslide Susceptibility Prediction Considering Spatio-Temporal Division Principle of Training/Testing Datasets in Machine Learning Models. *Earth Science*, 49(05): 1607-1618(in Chinese with English abstract).

[11] Lei, Z.Q., 2018. DDA Analysis on Creep Deformation of Slope Triggered by Reservoir Impoundment. *China Institute of Water Resources and Hydropower*, Beijing(in Chinese with English abstract).

[12] Li, B.Y., Wang, G.L., Chen, L.C., et al., 2024. Analysis of Landslide Deformation Mechanisms and Coupling Effects Under Rainfall and Reservoir Water Level Effects. *Engineering Geology*, 343: 107803. doi: 10.1016/j.enggeo.2024.107803

[13] Li, M.W., Selvadurai, A.P.S., Zhou, Z.F., 2023. Observations and Computational Simulation of River Valley Contraction at the Xiluodu Dam, Yunnan, China. *Rock Mechanics and Rock Engineering*, 56(6): 4109-4131. doi: 10.1007/s00603-023-03269-4

- [14]Li, X.Y., Zhang, L.M., Jiang, S.H., 2016. Updating Performance of High Rock Slopes by Combining Incremental Time-Series Monitoring Data and Three-Dimensional Numerical Analysis. *International Journal of Rock Mechanics and Mining Sciences*, 83: 252-261. doi: 10.1016/j.ijrmms.2014.09.011
- [15]Ma, J.W., Tang, H.M., Liu, X., et al., 2018. Probabilistic Forecasting of Landslide Displacement Accounting for Epistemic Uncertainty: A Case Study in the Three Gorges Reservoir Area, China. *Landslides*, 15: 1145-1153. doi: 10.1007/s10346-017-0941-5
- [16]Reyad, M., Sarhan, A.M., Arafa, M., 2023. A Modified Adam Algorithm for Deep Neural Network Optimization. *Neural Computing and Applications*, 35(23): 17095-17112. doi: 10.1007/s00521-023-08568-z
- [17]Rong, G., Xu, L.D., Yu, S., et al., 2024. The Mechanism of Large-Scale River Valley Deformation Induced by Impoundment at the Baihetan Hydropower Station. *Computers and Geotechnics*, 165: 105898. doi: 10.1016/j.compgeo.2023.105898
- [18]Sun, Y., Huang, J.S., Jin, W., et al., 2019. Bayesian Updating for Progressive Excavation of High Rock Slopes Using Multi-Type Monitoring Data. *Engineering Geology*, 252: 1-13. doi: 10.1016/j.enggeo.2019.02.013
- [19]Sun, M.C., Xu, W.Y., Wang, H.L., et al., 2020. A Novel Hybrid Intelligent Prediction Model for Valley Deformation: A Case Study in Xiluodu Reservoir Region, China. *Computers, Materials and Continua*, 66(1): 1057-1074. doi: 10.32604/cmc.2020.012537
- [20]Sun, Z.G., Wang, G.T., Li, P.F., et al., 2024. An Improved Random Forest Based on the Classification Accuracy and Correlation Measurement of Decision Trees. *Expert Systems with Applications*, 237: 121549. doi: 10.1016/j.eswa.2023.121549
- [21]Wang, D., Zhu, H., Wu, B., et al., 2024. Performance evaluation of underground pipelines subjected to landslide thrust with fiber optic strain sensing nerves. *Acta Geotechnica*, 19(10): 6993-7009. doi: 10.1007/s11440-024-02311-1
- [22]Wang, L.Q., Xiao, T., Liu, S.L., et al., 2023. Quantification of Model Uncertainty and Variability for Landslide Displacement Prediction Based on Monte Carlo Simulation. *Gondwana Research*, 123: 27-40. doi: 10.1016/j.gr.2023.03.006
- [23]Wang, N.T., Liu, L., Shi, T.T., et al., 2023. Study of the Impact of Reservoir Water Level Decline on the Stability Treated Landslide on Reservoir Bank. *Alexandria Engineering Journal*, 65: 481-492. doi: 10.1016/j.aej.2022.10.042
- [24]Wang, S.G., Liu, Y.R., Yang, Q., et al., 2020. Analysis of the Abutment Movements of High Arch Dams Due to Reservoir Impoundment. *Rock Mechanics and Rock Engineering*, 53: 2313-2326. doi: 10.1007/s00603-020-02059-6
- [25]Wang, Y., Yang, Q., Zhang, M., et al., 2023. Study on Mechanism of Reservoir Valley Width Deformation During Impoundment of Xiluodu Arch Dam. *Chinese Journal of Rock Mechanics and Engineering*, 42(05): 1083-1095(in Chinese with English abstract).
- [26]Wen, H., Liu, L., Zhang, J., et al., 2023. A hybrid machine learning model for landslide-oriented risk assessment of long-distance pipelines. *Journal of environmental management*, 342: 118177. doi: 10.1016/j.jenvman.2023.118177
- [27]Wu, P., Tan, D., Lin, S., et al., 2022. Development of a monitoring and warning system based on optical fiber sensing technology for masonry retaining walls and trees. *Journal of Rock Mechanics and Geotechnical Engineering*, 14(4): 1064-1076. doi: 10.1016/j.jrmge.2021.09.013
- [28]Yang, Q., Pan, Y.Y., Cheng, L., et al., 2015. Mechanism of Valley Deformation of High Arch Dam and Effective Stress Principle for Unsaturated Fractured Rock Mass. *Chinese Journal of Rock Mechanics and Engineering*, 34(11): 2258-2269(in Chinese with English abstract).
- [29]Yang, Y.T., Dai, Z.W., Lu, Y.S., et al., 2024. Deformation Characteristics and Stability Changes Characteristics of Reservoir Landslides with Double-Sliding Zones. *Earth Science*, 49(4): 1498-1514(in Chinese with English abstract).
- [30]Yin, Y.P., Huang, B.L., Zhang, Z.H., et al., 2022. Geological Disaster Prevention and Control in the Three Gorges Reservoir Area. Science Press, Beijing(in Chinese).
- [31]Zhang, C., Bai, Q.S., Han, P.H., 2023. A Review of Water Rock Interaction in Underground Coal Mining: Problems and Analysis. *Bulletin of Engineering Geology and the Environment*, 82(5): 157. doi: 10.1007/s10064-023-03142-2
- [32]Zhang, W.G., Gu, X., Liu, H.L., et al., 2018. Probabilistic Back Analysis of Soil Parameters and Displacement Prediction of Unsaturated Slopes Using Bayesian Updating. *Rock and Soil Mechanics*, 43(04): 1112-1122(in Chinese with English abstract).

- [33]Zhao, S., Lin, S.Q., Tan, D.Y., et al., 2025. Smart prediction of rock crack opening displacement from noisy data recorded by distributed fiber optic sensing. *Journal of Rock Mechanics and Geotechnical Engineering*, 17(5): 2619-2632. doi: 10.1016/j.jrmge.2024.09.009
- [34]Zhao, S., Tan, D., Lin, S., et al., 2023. A deep learning-based approach with anti-noise ability for identification of rock microcracks using distributed fibre optic sensing data. *International Journal of Rock Mechanics and Mining Sciences*, 170: 105525. doi: 10.1016/j.ijrmms.2023.105525
- [35]Zhuang, C., Zhou, Z.F., Li, M.W., et al., 2019. Prediction of Valley Shrinkage Deformation in Xiluodu Hydropower Plant Based on the Hydraulic Responses of a Confined Aquifer. *Chinese Journal of Geotechnical Engineering*, 41(08): 1472-1480(in Chinese with English abstract).
- [36]Zhou, C.B., Jiang, Q.H., Yao, C., et al., 2025. Research Progress and Challenges to Studies on Deformation and Stability of High Steep Slopes in Hydropower Projects. *Journal of Hydroelectric Engineering*, 2025, 44(1): 1-17(in Chinese with English abstract).
- [37]Zhou, L., Liu, S.M., Zhang, K., et al., 2024. Review on Development of Valley Deformation Monitoring Technology. *Express Water Resources & Hydropower Information*, 45(10): 50-54(in Chinese with English abstract).
- [38]Zhou, X.P., Pan, X.K., Berto, F., 2022. A State-of-the-Art Review on Creep Damage Mechanics of Rocks. *Fatigue & Fracture of Engineering Materials & Structures*, 45(3): 627-652. doi: 10.1111/ffe.13625
- [39]Zhu, H.H., Gao, Y.X., Chen, D.D., et al., 2024. Interfacial behavior of soil-embedded fiber optic cables with micro-anchors for distributed strain sensing. *Acta Geotechnica*, 19(4): 1787-1798. doi: 10.1007/s11440-023-01956-8
- [11]雷峥琦, 2018. 水库蓄水诱发岸坡蠕变的 DDA 分析. 北京: 中国水利水电科学研究院.
- [25]王昀, 杨强, 张曼, 等, 2023. 溪洛渡拱坝蓄水期谷幅变形驱动机制研究. *岩石力学与工程学报*, 42(05): 1083-1095.
- [28]杨强, 潘元炜, 程立, 等, 2015. 高拱坝谷幅变形机制及非饱和裂隙岩体有效应力原理研究. *岩石力学与工程学报*, 34(11): 2258-2269.
- [29]杨雨亭, 代贞伟, 陆愈实, 等, 2024. 库岸古滑坡复活变形特征及双滑带稳定性响应. *地球科学*, 49(04): 1498-1514.
- [30]殷跃平, 黄波林, 张枝华, 等, 2022. 三峡工程库区地质灾害防治. 北京: 科学出版社.
- [32]仇文岗, 顾鑫, 刘汉龙, 等, 2022. 基于贝叶斯更新的非饱和土坡参数概率反演及变形预测. *岩土力学*, 43(04): 1112-1122.
- [35]庄超, 周志芳, 李鸣威, 等, 2019. 基于承压含水层水力响应的溪洛渡水电工程区谷幅收缩变形预测研究. *岩土工程学报*, 41(08): 1472-1480.
- [36]周创兵, 姜清辉, 姚池, 等, 2025. 水利水电工程高陡边坡变形与稳定性研究进展及挑战. *水力发电学报*, 44(01): 1-17.
- [37]周绿, 刘书明, 张凯, 等, 2024. 谷幅变形监测技术发展综述. *水利水电快报*, 45(10): 50-54

中文参考文献

- [4]陈铭熙, 陶培捷, 周创兵, 等, 2024. Verhulst 反函数预测模型的改进及滑坡时间概率预测 [J]. *地球科学*, 2024, 49(05): 1692-1705.
- [9]何柱, 刘耀儒, 杨强, 等, 2018. 溪洛渡拱坝谷幅变形机制及变形反演和长期稳定性分析. *岩石力学与工程学报*, 37(S2): 4198-4206.
- [10]黄发明, 欧阳慰平, 蒋水华, 等, 2024. 考虑机器学习建模中训练/测试集时空划分原则的滑坡易发性预测建模. *地球科学*, 49(05): 1607-1618.