

中文引用格式:唐宇峰,何俚秋,熊清远,等. 基于 PSO-GRU-OL-MRT 的动态滑坡位移实时预测模型[J]. 中国安全科学学报, 2025, 35(12): 70-77.

英文引用格式:TANG Yufeng, HE Liqiu, XIONG Qingyuan, et al. Real-time prediction model for landslide displacement based on PSO-GRU-OL-MRT[J]. China Safety Science Journal, 2025, 35(12): 70-77.

基于 PSO-GRU-OL-MRT 的滑坡位移实时预测模型^{*}

唐宇峰^{1,2}副教授, 何俚秋¹, 熊清远², 熊娅伶², 石砚秋², 胡光忠^{**1}教授

(1 四川轻化工大学 机械工程学院, 四川 宜宾 644005;

2 四川远德安防检测设备有限公司, 四川 自贡 643000)

中图分类号:X928

文献标志码:A

DOI: 10.16265/j.cnki.issn1003-3033.2025.12.0023

基金项目:四川省自然科学基金资助(2022NSFSC1154);企业信息化与物联网测控技术四川省高校重点实验室开放基金资助(2023WYJ04, 2024WYJ01);四川轻化工大学科研创新团队计划项目(SUSE652A004)。

【摘要】 针对静态预测模型难以满足动态滑坡趋势的准确预测,而动态预测模型往往带来计算成本的增加,给实时预测带来困难的问题,提出一种基于粒子群优化算法(PSO)-门控循环单元(GRU)-在线学习(OL)-动态模型重构(MRT)的滑坡位移实时预测模型。首先,结合 PSO 和 GRU 建立静态滑坡预测模型;其次,在静态模型基础上融入 OL 策略,在获取最新监测数据后动态更新和实时预测模型;然后,结合预测精度评价进行小批量 MRT,动态实时预测滑坡趋势;最后,以四川省王耳岩滑坡体为例对比分析多个相关模型。结果表明:OL 和 MRT 法可显著提升预测精度,其中 PSO-GRU-OL-MRT 模型的平均绝对误差(MAE)、绝对百分比误差(MAPE)、均方根误差(RMSE)、拟合优度 R^2 指标分别为 0.795、3.53、1.40、0.954,平均每次预测时间为 25.0 s,具有最高的预测精度;而 GRU-OL-MRT 模型 4 个指标分别为 1.73、7.82、2.54、0.917,平均每次预测时间为 0.496 s,在具有较高预测精度的前提下大幅减少了计算成本。

【关键词】 粒子群优化算法(PSO); 门控循环单元(GRU); 在线学习(OL); 动态模型重构(MRT); 滑坡位移; 实时预测

Real-time prediction model for landslide displacement based on PSO-GRU-OL-MRT

TANG Yufeng^{1,2}, HE Liqiu¹, XIONG Qingyuan², XIONG Yaling²,
SHI Yanqiu², HU Guangzhong¹

(1 School of Mechanical Engineering, Sichuan University of Science & Engineering, Yibin
Sichuan 644005, China; 2 Sichuan Yuande Safety & Security Detection Equipment
Co., Ltd., Zigong Sichuan 643000, China)

Abstract: To address the challenges that static prediction models face in accurately forecasting dynamic landslide trends and the high computational costs associated with dynamic models—which hinder real-time prediction—this study proposes a novel real-time model for landslide displacement prediction. The model

* 文章编号:1003-3033(2025)12-0070-08; 收稿日期:2025-08-06; 修稿日期:2025-10-10

** 通信作者:胡光忠(1972—),男,四川南江人,博士,教授,主要从事安全工程、可靠性设计等方面的研究。E-mail: hgzdhx@163.com。

integrated Particle Swarm Optimization (PSO), a Gated Recurrent Unit (GRU) network, Online Learning (OL), and dynamic Model Retraining (MRT). First, a static landslide prediction model was established by integrating PSO and GRU. Second, an OL strategy was incorporated into the static model, enabling dynamic updates and real-time predictions as new monitoring data were acquired. Then, small-batch MRT was performed based on prediction accuracy evaluation to predict landslide trends dynamically and in real time. Finally, a comparative analysis of several related models was conducted using the Wangeryan landslide in Sichuan Province as a case study. The results indicate that the OL and MRT methods significantly improve prediction accuracy. Specifically, the PSO-GRU-OL-MRT model achieved Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), Root Mean Square Error (RMSE), and R^2 values of 0.795, 3.53, 1.40, and 0.954, respectively, with an average prediction time of 25.0 seconds per instance, demonstrating the highest prediction accuracy. In comparison, the GRU-OL-MRT model yielded values of 1.73, 7.82, 2.54, and 0.917 for the same four metrics, with an average prediction time of 0.496 seconds per instance, significantly reducing computational costs while maintaining relatively high prediction accuracy.

Keywords: particle swarm optimization (PSO); gated recurrent unit (GRU); online learning (OL); dynamic model re-train (MRT); landslide displacement; real-time prediction

0 引 言

我国是地质灾害频发国,每年滑坡等地质灾害都会造成巨大的人员伤亡和财产损失。根据《中国统计年鉴》(2024 版),近 5 年来,我国(不含港澳台地区)共发生地质灾害 28 109 起,其中,滑坡地质灾害共发生 16 209 起,占地质灾害总数的 57.67%^[1]。从灾害规模来看,我国小型地质灾害占地质灾害总数的 92.51%^[2],且此类灾害监测点数量数以万计,若采用多源传感器进行实时监测,在水文地质勘察、工程地质分析,在人力、物力和财力方面均难以实现,因此,往往以部署最重要、最具代表性的位移监测为主,实现大范围、规模化、普及性的监测监控。在此背景下,有效超前预测和研究滑坡位移,能够为滑坡地质灾害预警和人员疏散提供依据,对减少人员伤亡和经济损失具有十分重要的意义。

随着人工智能技术的飞速发展,在线监测与深度学习相结合的超前预测为地质灾害预测预警提供了新思路^[3]。诸如循环神经网络(Recurrent Neural Network, RNN)、长短时记忆神经网络^[4-5](Long Short Term Memory Network, LSTM)、门控循环单元^[6](Gated Recurrent Unit, GRU)等方法,因其在处理时序数据上具有独特优势,在滑坡预测领域得到广泛关注。如唐宇峰等^[7]建立了一种动态残差修正的 LSTM 方法预测滑坡位移;LIN Zian 等^[8]构建了 LSTM 结合全连接(Fully Connected, FC)模型预测累计滑坡位移中的周期性位移;DUAN Gonghao

等^[9]整合降雨和水库水位数,提出了一种多变量 LSTM 滑坡位移预测模型。GIDON 等^[10]使用双向 LSTM 建立了印度梅加拉亚邦滑坡带的实时预警系统;ZHANG Wengang 等^[11]将 GRU 应用于滑坡位移预测,发现 GRU 能够以较少的异常值描绘滑坡周期性位移的变化,能较好地预测数据集集中的局部峰值。同时,为进一步提高模型精度,许多学者还基于优化算法对模型超参数寻优,从而增强模型的滑坡预测性能。如杨伟东等^[12]提出一种基于自适应粒子群、支持向量机(Support Vector Machine, SVM)和 GRU 的组合模型预测滑坡周期项位移;ZHANG Lizhou 等^[13]将粒子群优化算法(Particle Swarm Optimization, PSO)与深度神经网络、卷积神经网络和 GRU 相结合,研究了 PSO 在增强滑坡易发性评估的深度机器学习模型方面的有效性;WANG Yankun 等^[14]采用 PSO 优化了 5 种流行的机器学习方法,并对比了 5 种方法在滑坡位移预测中的性能。GONG Wenping 等^[15]采用 PSO 和最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM)获得点预测结果和滑坡位移区间。总之,现有研究表明:优化算法可有效提高滑坡预测模型的精度。然而,上述研究均基于历史监测数据一次性建立预测模型,模型一旦训练完成后,其模型参数便不会发生变化,即静态模型。相对的,滑坡体具有滑坡趋势变化的动态特性,特别是在滑坡灾害产生前的临滑期,往往会产生与历史位移趋势完全不符的“突变”,导致基于历史信息建立的静态模型产生预测精度不足,

甚至无法有效预测的困难,这对突变期位移的准确预测提出挑战。

基于此,笔者提出一种 PSO-GRU-在线学习(Online Learning, OL)-动态模型重构(Model Re-Train, MRT)的滑坡位移动态预测模型,以期对滑坡的动态实时预测提供一种新思路。

1 PSO-GRU 理论基础

1.1 GRU 基本原理

GRU 是一种 RNN^[16] 的变体,旨在解决传统 RNN 中存在的梯度消失问题,从而更好地处理长序列数据。GRU 与 LSTM^[17] 类似,都是引入门控机制来控制信息流动,但 GRU 结构比 LSTM 更简单,参数更少,因此具有更高的计算效率。

GRU 神经网络由 CHO 等^[18] 提出,包括 2 个门功能:更新门和复位门。更新门用于控制隐藏层状态从前一时刻到当前隐藏层状态的更新量。复位门用于控制隐藏层状态从前一时刻更新到当前可选隐藏层状态的程度,基本原理如图 1 所示。图 1 中, h_{t-1} 为前一个节点传递的隐藏状态, x_t 为当前节点输入信息, z_t 和 r_t 为更新门和复位门, $\tilde{h}_t$ 为候选隐藏状态, σ 为 Sigmoid 激活函数, $\tanh$ 为将实数映射到 $[-1, 1]$ 的双曲正切函数, h_t 为时间 t 的最终隐藏状态。




图 1 GRU 基本工作原理

Fig. 1 Structure circuit of GRU

在 GRU 中,通过 h_{t-1} 和 x_t 来计算 z_t 和 r_t 的信息。其中,更新门决定了先前隐藏状态和当前隐藏状态之间的更新程度,而复位门用于控制从上一时刻更新到当前可选隐藏层状态的程度,分别表示为:

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (1)$$

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (2)$$

式中: W_z 、 U_z 、 W_r 、 U_r 为可供学习的权重矩阵; b_z 和 b_r 分别为更新门和复位门的偏置。

$\tilde{h}_t$ 捕捉 x_t 对隐藏状态的潜在影响,并与 h_{t-1}

一起得到 h_t , 表示为:

$$\tilde{h}_t = \tanh(W_h x_t + U_h h_{t-1} + b_h) \quad (3)$$

$$h_t = (1 - z) \cdot \tilde{h}_t + z \cdot h_{t-1} \quad (4)$$

式中: W_h 和 U_h 为可学习的权重矩阵; b_h 为偏置。

1.2 PSO 算法

PSO 的基本思路是将待求解问题的解描述为粒子,各粒子在 N 维解空间中不断更新以寻求更优解^[19]。其中,个体最优 P 表示该粒子所经过位置中的最优解,而粒子群中最好的粒子位置定义为群体最优 G 。在每次迭代时,每个粒子都会追踪个体最优和群体最优从而进行位置更新,并通过计算适应度重新获取 P 和 G ,从而不断逼近最优解。对某一个粒子 i ,其速度和位置更新方法为:

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (P_{id}^k - X_{id}^k) + c_2 r_2 (G_d^k - X_{id}^k) \quad (5)$$

$$X_{id}^{k+1} = X_{id}^k + V_{id}^{k+1} \quad (6)$$

式中: V_{id} 和 X_{id} 分别为粒子速度和位置; k 为当前迭代次数; $d = 1, 2, \dots, D$; $i = 1, 2, \dots, n$; ω 为惯性权重; D 为空间维数; n 为粒子个数; c_1 和 c_2 为学习因子; r_1 和 r_2 为 $[0, 1]$ 之间的随机数。

1.3 OL

OL 是一种实时深度学习模型训练方法。与传统批量学习不同,OL 中,每接收到新的数据后,会立即根据新数据在小批量样本下基于原有模型进行加强训练并更新参数,从而在极少计算成本下保证模型实时性,提高模型精度。相对于传统批量学习,OL 能够在无需重新训练情况下更迅速地适应新数据,更擅长处理实时数据流以及分布随时间变化的非平稳数据。

2 PSO-GRU-OL-MRT 实时预测模型

为同时满足滑坡预测精度和时效性要求,构建一种基于 PSO-GRU-OL-MRT 的动态滑坡预测模型。该模型可分为 3 个阶段:

1) 初始静态模型构建。初始静态模型是指利用已有历史监测数据训练而建立的模型。由于初始模型构建不对预测实时性产生影响,因此,可容许更大的训练数据量,以更多的计算成本更好地挖掘历史数据信息。在训练时,根据已有监测数据,采用滑窗流转训练方式,每次采用同样数量的滑窗数据预测滑窗后的下一次数据,并使得隐藏状态在窗口间流动,最终以多次流转下均方误差 (Mean Squared

Error, MSE) 的均值为适应度函数, 基于 PSO 对 GRU 的超参数寻优并构建基于 PSO-GRU 的初始静态模型。其中, PSO-GRU 训练流程如图 2 所示。




图 2 PSO-GRU 训练流程
Fig. 2 PSO-GRU training flow chart

通过构建 PSO-GRU 静态模型, 可以充分挖掘滑坡的历史位移趋势, 并作为 OL 的模型依据。

2) OL 阶段。PSO-GRU 的初始静态模型能够拟合滑坡历史位移趋势, 但却难以保证滑坡趋势发生变化时的预测效果, 因此, 加入 OL 方法对动态更新模型、获取边坡最新位移趋势至关重要。然而, OL 会不可避免地增加计算成本, 若保持与静态模型相同的窗口大小, 会显著降低实时预测的效率和可行性。为提升滑坡趋势变化时模型预测的精度和时效性, 提出静态-动态协同训练框架: 在获取初始静态模型后, 通过权重继承机制将模型参数迁移至 OL 阶段, 随后, 每获取一次监测数据 D_t , 都基于包含最新监测数据的小窗口数据对输入的模型进行参数更新。由于每一次更新都是在上一次子模型更新的基础上进行的, 从而实现累计学习。利用 OL 策略, 一方面, 模型参数会随着新监测数据而不断动态更新, 提高了模型预测精度; 另一方面, 因无需重新构建模型, 最大限度减少了计算成本, 保证了预测时效性。

3) MRT 阶段。当边坡位移趋势产生显著变化时, 基于 OL 更新的动态模型可能仍不能满足新的预测需求 (表现为预测精度显著下降)。因此, 加入 MRT 机制: 每获取下一个监测数据 D_{t+1} 后, 则以 OL 窗口大小为初始窗口大小、采用动态滑动窗口的滑窗流转训练方式进行 MRT, 建立新的 PSO-GRU 模型并作为后续 OL 的输入模型。动态滑动窗口, 是指当重构后的模型仍不能满足预测精度要求, 模型会持续减小滑动窗口大小以反映近期滑坡趋势, 直到满足精度要求为止。通过动态窗口的模型重构,

可在滑坡趋势发生较大变化时自动调整模型并识别出近期滑坡趋势, 大大提升滑坡趋势变化时的预测精度。

通过以上 3 部分, 在保证动态预测精度的同时, 大大提高预测效率, 同时, 又在滑坡趋势发生明显变化时进行动态更新, 满足滑坡预测精度和实时性的双重需求。PSO-GRU-OL-MRT 动态实时预测模型的总体流程如图 3 所示。图 3 中, P 为预测所得数据, D 为监测所得数据, t 为当前监测周期数。




图 3 PSO-GRU-OL-MRT 实时预测模型流程
Fig. 3 Prediction flowchart of PSO-GRU-OL-MRT model

3 实时预测模型工程应用及分析

3.1 数据来源

以四川省宜宾市李庄镇王耳岩滑坡为例探讨。该滑坡体地理坐标为东经 $104^{\circ}47'26''$, 北纬 $28^{\circ}46'45.3''$, 坡度为 $20^{\circ} \sim 45^{\circ}$ 。滑坡体后缘为坡体后部山腰处, 体积约 1万 m^3 , 主要威胁对象为滑坡中部公路 50m 及前缘的住户 6户 35人 , 为小型迁移式滑坡。根据现场情况, 实时监测滑坡体位移, 滑坡体和监测点位置如图 4 所示。

2020 年 8 月 26 日 19 时—9 月 11 日 16 时, 共获取 400 组实测数据, 其中每组数据间隔为 1h 。为避免偶然波动引起的影响, 采用三点平均的移动平均法预处理数据, 预处理后的累计位移如图 5 所示。

3.2 模型 c 构建与参数选取

构建初始静态模型: 采用前 250 组数据构建初始模型, 其中, PSO 的参数 $c_1=0.5$, $c_2=0.3$, $\omega=0.9$, 粒子数量为 10, 迭代次数为 5; PSO 优化的 GRU 参




图 4 监测设备安装

Fig. 4 Installation diagram of monitoring equipment




图 5 滑坡位移监测数据

Fig. 5 Displacement monitoring data of landslide

数包括单元数(10~100),学习率(0.000 1~0.1),Dropout 率(0~0.5),L2 正则化强度(0~0.01)。初始模型流转训练次数设置为 5,即每次输入采用 245 个数据进行训练,依次预测最后 5 个位移数据,并以 5 次预测的平均 MSE 值作为 PSO 优化的适应度函数,训练迭代次数为 100。

构建 OL 模型:为保证 OL 的计算效率,OL 流转窗口大小为 50,训练迭代次数为 5。

构建 MRT 模型:当预测值与实测值差值的绝对值大于 5 mm 时,模型进入 MRT,其中 PSO 参数设置和优化的 GRU 参数与构建初始模型时一致。模型重构的流转窗口大小为 50,流转训练次数设置为 5,若重构模型不能达到预测精度,则流转窗口每次减小 5 个数据并重新构建模型,直到数据量小于 20 为止,训练迭代次数设置为 30。

为明确模型中 PSO、OL 和模型动态重构对预测效果的影响,分别采用无 PSO 优化训练的 GRU 静态模型、静态+OL 模型 (GRU-OL)、静态+OL+动态重构模型 (GRU-OL-MRT) 以及基于 PSO 优化的 GRU 的初始静态模型 (PSO-GRU)、静态+OL 模型 (PSO-GRU-OL) 的预测结果进行对比。其中,无 PSO 优化时,GRU 模型的单元数、学习率、Dropout

率、L2 正则化强度分别为 50、0.01、0.25 和 0.005,其他涉及的模型参数均与文中所提模型的设置一致。

3.3 预测结果及性能评价

图 6—图 8 分别为 PSO 优化下 3 种模型与无 PSO 优化的 3 种模型的预测效果对比。从图 6 可以看出,PSO-GRU 模型比单 GRU 模型具有明显优势,这是因为 PSO 找到了更好的 GRU 结构参数,训练的 GRU 模型更为优秀。然而,由于滑坡趋势在后期发生了明显变化,即使是更优的 PSO-GRU 模型也无法适应快速变化的滑坡趋势。




图 6 PSO-GRU 和 GRU 结果对比

Fig. 6 Result comparison between PSO-GRU and GRU




图 7 PSO-GRU-OL 和 GRU-OL 结果对比

Fig. 7 Result comparison between PSO-GRU-OL and GRU-OL

从图 7 和图 8 可以看出,在加入 OL 和模型重构后,滑坡位移预测的精度明显提升。其中,PSO-GRU-OL 模型和 GRU-OL 模型虽然预测的趋势与实测值相符,但由于滑坡趋势的迅速改变,引起了预测值的大幅波动,影响了预测的精确性。而 PSO-GRU-OL-MRT 模型和 GRU-OL-MRT 模型由于引入了重构机制,其预测精度得到大幅提升。然而,当没




图 8 PSO-GRU-OL-MRT 和 GRU-OL-MRT 结果对比
Fig. 8 Result comparison between PSO-GRU-OL-MRT and GRU-OL-MRT

有经过 PSO 优化时,GRU 模型的波动性明显更强,说明超参数不合理会导致的预测性能下降。

为进一步挖掘各模型性能,采用平均绝对误差 (Mean Absolute Error, MAE)、绝对百分比误差 (Mean Absolute Percentage Error, MAPE)、均方根误差 (Root Mean Square Error, RMSE) 及拟合优度 R^2 共 4 种指标对各模型进行定量评价。其中,MAE、MAPE 和 RMSE 越接近 0 表示效果越好, R^2 越接近 1 说明预测越准确^[20]。各模型评价结果见表 1。

计算成本分析:从表 1 中 GRU、GRU-OL、PSO-GRU、PSO-GRU-OL 4 个模型的计算时间对比可以看出,OL 对计算时间的影响非常小,这是因为 OL

表 1 各模型评价指标

Table 1 Evaluation metrics for various models						
模型	MAE	MAPE/%	RMSE	R^2	T/s	τ/s
GRU	17.2	60.4	24.9	0.188	7.25	0.048
GRU-OL	2.42	7.84	4.91	0.840	24.7	0.165
GRU-OL-MRT	1.73	7.82	2.54	0.917	74.4	0.496
PSO-GRU	4.62	16.3	6.83	0.777	7.36	0.049
PSO-GRU-OL	2.07	6.60	3.95	0.871	24.2	0.161
PSO-GRU-OL-MRT	0.795	3.53	1.40	0.954	3746	25.0

注: T 为初始静态模型构建好后,模型进行 150 次预测的总时间; τ 为平均每次预测的时间。

无需重新训练模型,只需要用较少的迭代次数对模型参数进行动态更新,所需的计算成本非常少。而从 GRU-OL、GRU-OL-MRT、PSO-GRU-OL、PSO-GRU-OL-MRT 4 个模型的计算时间对比看出,模型重构对计算成本的影响要大于 OL,这是因为在滑坡趋势发生显著变化时,可能要经过多次批量大小的调整以获取最新的滑坡趋势,因此增加了计算成本。特别是 PSO-GRU-OL-MRT 模型,由于 PSO 在模型重构中要经过多次寻优以找到更优的超参数,因此对计算成本的影响最大。

模型性能分析:经过 PSO 优化的各模型评价指标显著优于未经 PSO 优化的模型性能,而在加入 OL 和 MRT 策略后可进一步提升模型预测精度。其中,PSO-GRU-OL-MRT 模型在 MAE、MAPE、RMSE 及拟合优度 R^2 等 4 个指标上分别达到了 0.795、3.53、1.40、0.954,均为各模型评价中的最优值,充分体现了该模型在预测趋势变化滑坡中的精度优势。同时,PSO-GRU-OL-MRT 模型平均每次预测计算时间为 25.0 s,其运算效率可以实现分钟级的预测,满足大多数工程中实时性的需求。而 GRU-OL-MRT 模型的各项评价指标分别为 1.73、7.82、2.54、0.917,预测精度虽低于 PSO-GRU-OL-MRT 模型,但

由于不需要进行超参数优化,平均每次优化时间仅需 0.496 s,大大节省了计算成本、提升了实时预测性能,因此,可适用于计算能力有限(如嵌入式端计算)的工程项目。

4 结 论

1) PSO 优化可显著提高各预测模型的预测精度,而经过 OL 动态更新后,各模型的各项评价指标均优于未经 OL 的对应模型,说明 OL 具备根据滑坡趋势实时更新模型参数的能力,能够大幅提高预测准确率。

2) 模型重构能更好的适应并预测滑坡趋势的显著变化,其中,PSO-GRU-OL-MRT 模型的 MAE、MAPE、RMSE、 R^2 分别达到 0.795、3.53、1.40、0.954,平均每次预测的时间为 25.0 s,能够达到分钟级的预测效率,在满足滑坡预测实时性需求的同时达到最优的预测精度;而 GRU-OL-MRT 模型的 MAE、MAPE、RMSE、 R^2 分别为 1.73、7.82、2.54、0.917,平均每次预测时间为 0.496 s,更适合计算能力有限条件下的实时预测。

3) 文中研究仅基于滑坡位移时序数据开展了预测研究,尚未考虑水文、气象等多源异构数据对滑

坡位移的动态影响。未来研究将通过多模态数据融合方法,整合降雨、地下水位等环境因子与位移监测数据,以提升预测模型的时空精度、环境适应性和泛化能力。

参 考 文 献

- [1] 国家统计局. 中国统计年鉴(2024)[R]. 北京:中国统计出版社,2024.
- [2] 吴羿君. 小型滑坡的滑坡推力分布及抗滑挡墙结构设计[D]. 成都:西南交通大学,2023.
WU Yijun. Thrust distribution and anti-sliding wall design for small landslides: a case study of Ganluo County[D]. Chengdu: Southwest Jiaotong University, 2023.
- [3] 陈文涛, 杨志全, 朱颖彦, 等. 阿塔巴德滑坡形成条件与诱发机制分析[J]. 中国安全科学学报, 2020, 30(11): 148-155.
CHEN Wentao, YANG Zhiquan, ZHU Yingyan, et al. Analyses on formation conditions and triggering mechanism of Atabad landslide[J]. China Safety Science Journal, 2020, 30(11): 148-155.
- [4] 李丽敏, 郭伏, 温宗周, 等. 基于长短时记忆与多影响因子的滑坡位移动态预测[J]. 科学技术与工程, 2020, 20(33): 13 559-13 567.
LI Limin, GUO Fu, WEN Zongzhou, et al. Dynamic prediction of landslide displacement based on long short time memory and multiple influencing factors[J]. Science Technology and Engineering, 2020, 20(33): 13 559-13 567.
- [5] 林娜, 谭力兵, 张迪, 等. 时序 InSAR 和 LSTM 结合的滑坡形变时空分析与预测方法[J]. 地球信息科学学报, 2024, 26(12): 2 772-2 787.
LIN Na, TAN Libing, ZHANG Di, et al. Spatiotemporal analysis and prediction of landslide deformation combining time-series InSAR and LSTM[J]. Journal of Geo-information Science, 2024, 26(12): 2 772-2 787.
- [6] 何清, 李丽琳, 林子安. 基于 FEEMD-GRU-FC 模型的滑坡位移预测[J]. 人民长江, 2024, 55(7): 108-114.
HE Qing, LI Lilin, LIN Zian. Landslide displacement prediction based on FEEMD-GRU-FC model[J]. Yangtze River, 2024, 55(7): 108-114.
- [7] 唐宇峰, 胡光忠, 周帅. 动态残差修正 LSTM 算法的突发型滑坡位移预测[J]. 中国安全科学学报, 2023, 33(8): 109-116.
TANG Yufeng, HU Guangzhong, ZHOU Shuai. Displacement prediction of sudden landslide based on dynamic residual correction LSTM algorithm[J]. China Safety Science Journal, 2023, 33(8): 109-116.
- [8] LIN Zian, SUN Xiyang, JI Yuanfa. Landslide displacement prediction model using time series analysis method and modified LSTM model[J]. Electronics, 2022, 11: DOI:10.3390/electronics11101519.
- [9] DUAN Gonghao, SUN Yangwei, FU Jie. Landslide displacement prediction based on multivariate LSTM model[J]. International Journal of Environmental Research and Public Health, 2023, 20(2): DOI:10.3390/ijerph20021167.
- [10] GIDON J S, BORAH J, SAHOO S, et al. Bidirectional LSTM model for accurate and real-time landslide detection: a case study in mawiongirim, Meghalaya, India[J]. IEEE Internet of Things Journal, 2024, 11(3): 3 792-3 800.
- [11] ZHANG Wengang, LI Hongrui, TANG Libin, et al. Displacement prediction of Jiuxianping landslide using gated recurrent unit (GRU) networks[J]. Acta Geotechnica, 2022, 17(4): 1 367-1 382.
- [12] 杨伟东, 王再旺, 赵涵卓, 等. 基于 APSO-SVR-GRU 模型的白水河滑坡周期项位移预测[J]. 中国地质灾害与防治学报, 2022, 33(6): 20-28.
YANG Weidong, WANG Zaiwang, ZHAO Hanzhuo, et al. Displacement prediction of periodic term of Baishuihe landslide based on APSO-SVRGRU model[J]. The Chinese Journal of Geological Hazard and Control, 2022, 33(6): 20-28.
- [13] ZHANG Lizhou, ZENG Taorui, WANG Linfeng, et al. Advancing seismic landslide susceptibility modeling: a comparative evaluation of deep learning models through particle swarm optimization[J]. Earth Earth Science Informatics, 2024, 17: 3 547-3 566.
- [14] WANG Yankun, TANG Huiming, HUANG Jinsong, et al. A comparative study of different machine learning methods for reservoir landslide displacement prediction [J]. Engineering Geology, 2022, 298 (3): DOI: 10.1016/j. enggeo. 2022. 106544.
- [15] GONG Wenping, TIAN Shan, WANG Lei, et al. Interval prediction of landslide displacement with dual-output least

