



引文格式:罗袆沅,蒋亚楠,许强,等.基于最优分解模态和GRU模型的库岸滑坡位移预测研究[J].武汉大学学报(信息科学版),2023,48(5):702-709.DOI:10.13203/j.whugis20200610

Citation: LUO Huiyuan, JIANG Ya'nan, XU Qiang, et al. Displacement Prediction of Reservoir Bank Landslide Based on Optimal Decomposition Mode and GRU Model[J]. Geomatics and Information Science of Wuhan University, 2023, 48(5): 702-709. DOI:10.13203/j.whugis20200610

基于最优分解模态和GRU模型的 库岸滑坡位移预测研究

罗袆沅¹ 蒋亚楠^{1,2} 许 强¹ 唐 斌²

1 成都理工大学地质灾害防治与地质环境保护国家重点实验室,四川 成都,610059

2 成都理工大学地球科学学院,四川 成都,610059

摘要:在滑坡位移综合预测研究中,常因滑坡随机位移分量无法准确提取、最优训练数据集及时效性无法确定等,造成多源监测数据利用不充分、位移预测结果不稳定。鉴于此,引入变分模态分解,在滑坡位移时序分析的基础上,结合门控循环单元递归神经网络,提出一种新型滑坡位移综合预测模型。以三峡库区白水河滑坡为例,选取2003-07—2012-12的位移监测数据和同时期库水位及降雨数据进行分析研究,综合模型预测结果的均方根误差为9.715 mm,判定系数为0.967。对比实验分析表明,该模型在保证高预测精度的同时,在有效预测时长和时效性上同样优势明显,在库岸滑坡位移预测研究中具有很强的应用和推广价值。

关键词:滑坡位移预测;灰狼优化;变分模态分解;门控循环单元

中图分类号:TU196; P642

文献标识码:A

收稿日期:2021-10-26

DOI:10.13203/j.whugis20200610

文章编号:1671-8860(2023)05-0702-08

Displacement Prediction of Reservoir Bank Landslide Based on Optimal Decomposition Mode and GRU Model

LUO Huiyuan¹ JIANG Ya'nan^{1,2} XU Qiang¹ TANG Bin²

1 State Key Laboratory of Geological Hazard Prevention and Geological Environment Protection, Chengdu University of Technology, Chengdu 610059, China

2 School of Earth Sciences, Chengdu University of Technology, Chengdu 610059, China

Abstract: Objectives: The inadequate utilization of multisource monitoring data and the unstable results of displacement prediction are often caused by inaccurate extraction of random components, uncertain optimal training data set and timeliness in the comprehensive landslide displacement prediction study. Methods: On that account, a new landslide prediction model is proposed by integrating the variational mode decomposition with the gated recurrent unit recurrent neural network on the basis of landslide displacement time series analysis. Results: Taking Baishuihe landslide in the Three Gorges Reservoir Area as an example, the monitoring data including displacement and reservoir water level and rainfall data from July 2003 to December 2012 are selected for analysis and research. The root mean square error of the predicted value of the model is 9.715 mm and the coefficient of determination is 0.967. The results show that the model guarantees high prediction accuracy and has obvious advantages in effectiveness and timeliness as well. Conclusion: Therefore, it has a strong application and popularization value in reservoir bank landslide displacement prediction research.

基金项目:国家重点研发计划(2017YFC1501004);四川省科技厅重点研发项目(2020YFS0353, 2020YFG0209);四川省教育厅重点研发项目(18ZA0054);国家重点实验室开放基金(SKLGP2017K016)。

第一作者:罗袆沅,博士生,主要从事地质灾害评价与预测研究。luohuiyuancut@163.com

通讯作者:蒋亚楠,博士,副教授。jiangyanan@cdut.edu.cn

Key words: landslide displacement prediction; grey wolf optimizer (GWO); variational mode decomposition (VMD); gated recurrent unit (GRU)

库岸滑坡的变形演化是一个复杂的非线性过程, 研究库水耦合降雨条件下的滑坡变形响应机制, 建立滑坡位移综合预测预报模型是当前研究热点之一^[1]。需要着重考虑的是: ①如何选择滑坡位移影响因子; ②如何实现滑坡位移的时序分解; ③如何构建高效的滑坡位移预测模型。以上思路的合宜组合可有效提高滑坡位移预测的精度。

引入灰色关联度评估位移分量与影响因子间的关联性^[2], 并据此择取合适的影响因子。为实现滑坡位移的有效分解, 不同于经验模态分解(empirical mode decomposition, EMD)、小波分析等^[3-7]方法, 变分模态分解(variational mode decomposition, VMD)^[8]可根据数据规模实现自适应分解, 具有分解精度高、物理意义明确的优势。因此, 可将 VMD 与时序分析结合起来^[9], 实现滑坡位移分量的有效提取。在此过程中, 其最优分解参数通过引入 Shannon 熵^[10]及灰狼优化(grey wolf optimizer, GWO)算法^[11]进一步确定。

滑坡位移预测模型的选择和设计至关重要, 直接影响位移预测的精度和效率。Chung 等^[12]提出一种缓解梯度爆炸问题的门控循环单元(gated recurrent unit, GRU)递归神经网络, 该网络在训练时间、参数更新及泛化能力方面优于长短记忆(long short-term memory, LSTM)递归神经网络。在经济学、防洪减灾、能源等方面^[13]显现出明显的优势。鉴于此, 将 GRU 应用于滑坡时序预测理论上是可行的。本文以三峡库区典型库岸滑坡——白水河滑坡为研究对象, 择取合适的影响因子, 结合位移时序分析和 VMD, 实现滑坡位移时序的分解, 运用 GRU 神经网络和二次指数组平滑构建滑坡位移预测模型, 探讨了一种具有序贯特性的滑坡位移综合预测分析方法, 为库岸滑坡变形研究提供决策支撑。

1 滑坡位移预测模型

1.1 滑坡位移时序分析

受自身地质条件控制, 滑坡位移在时间线上体现为近似的单增函数, 反映了长期变形趋势。在外界影响因素作用下, 滑坡位移表现为周期性的波动变化。此外, 受随机因素作用, 滑坡位移表现为近白噪声序列。因此, 其时序加法模型

如下:

$$Y_t = T_t + P_t + R_t \quad (1)$$

式中, Y_t 、 T_t 、 P_t 和 R_t 分别为 t 时刻的滑坡位移监测值、趋势项、周期项和随机项。

1.2 VMD

VMD 是一种自适应、非递归的模态变分和信号处理的方法^[8]。它将输入信号分解成多个特定稀疏特性的本征模态函数(intrinsic mode function, IMF)分量, 可提前确定模态分量个数。为保证 IMF 分量具有有限带宽的中心频率、估计带宽之和最小, 且各模态之和等于原始信号, 其约束变分表达式为:

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t [(\delta(t) + j/\pi t) * u_k(t)] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (2)$$

$$\text{且 } \sum_k u_k = x_t$$

式中, K 为模态分量个数; u_k 为分解所得的模态分量; ω_k 为实际中心频率; ∂ 为偏导数符号; $\delta(t)$ 为狄拉克函数; $*$ 为卷积运算符; j 表示虚数; e 为自然常数; x_t 表示输入信号。

引入 Lagrange 乘子 λ 和分解参数 ϵ , 将上述求解问题转变为非约束变分问题, 得到增广 Lagrange 表达式:

$$L(\{u_k\}, \{\omega_k\}, \lambda) =$$

$$\epsilon \sum_k \left\| \partial_t [(\delta(t) + j/\pi t) * u_k(t)] e^{-j\omega_k t} \right\|_2^2 +$$

$$\left\| x(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), x(t) - \sum_k u_k(t) \right\rangle \quad (3)$$

此时, 利用交替方向乘子迭代算法优化得到各模态分量和中心频率, 并搜寻无约束模型鞍点, 求解得到约束模型的最优解, 进而得到模态分量。

由于 VMD 最早被用于复杂数字信号的分解, ϵ 经验值通常为 $K > 3$ 的情况。将其用于滑坡位移分解, 结果将不具有实际物理意义。为获取合适稀疏特征的模态分量, 本文引入 Shannon 熵探讨 ϵ 的取值。Shannon 熵的大小可以反映概率分布的均匀性^[10]。周期项分量的概率分布相对均匀, 稀疏性较强。因此, 使用 Shannon 熵作为适应度函数, 通过 GWO 算法对 ϵ 进行寻优, 以获得概率分布均匀、稀疏性强的周期项, 即可得到滑坡位移的趋势项和随机项。

$$H(p) = -\sum_{i=1}^n p_i \log_2 p_i \quad (4)$$

式中, p_i 为一不确定概率分布。

1.3 GRU 递归神经网络

GRU 使每个递归单元自适应地捕捉不同时间尺度的依赖关系^[12]。采用 GRU 模型对滑坡位移进行预测, 用于处理非线性问题的周期项位移和随机项位移。更新门 z_t 用于控制历史信息的忽略程度, 而重置门 r_t 用于决定输入状态与历史信息的结合程度。若当前时刻 t 的输入为 x_t , 则 GRU 的一次前向计算为:

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (5)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (6)$$

$$\tilde{h}_t = \tanh(W_{\tilde{h}} \cdot [r_t * h_{t-1}, x_t] + b_{\tilde{h}}) \quad (7)$$

式中, σ 为 Sigmoid 激活函数; W 为权重参数; b 为偏差参数; h_{t-1} 和 \tilde{h}_t 分别为上一时间步的隐藏状态和当前时刻的候选隐藏状态。 z_t 、 h_{t-1} 和 \tilde{h}_t 共同决定网络当前时刻的隐藏状态 h_t 。最终, 循环单元的输出为 \hat{y}_t :

$$h_t = z_t * h_{t-1} + (1 - z_t) * \tilde{h}_t \quad (8)$$

$$\hat{y}_t = \sigma(W_o \cdot h_t) + b_o \quad (9)$$

1.4 模型评价指标

在滑坡位移预测研究中, 常采用判定系数 (R^2) 和均方根误差 (root mean square error, RMSE) 作为评价预测模型性能的指标, 计算公式如下:

$$R^2 = 1 - \frac{\sum_{t=1}^N (y_t - \hat{y}_t)^2}{\sum_{t=1}^N (y_t - \bar{y})^2} \quad (10)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2} \quad (11)$$

式中, t 表示时刻; N 为预测时长; y_t 为实际观测值; \hat{y}_t 为预测值; \bar{y} 为预测时长对应原始观测值的平均值。

2 滑坡位移特征分析

2.1 白水河滑坡概况

白水河滑坡为三峡库区中典型的松散堆积层滑坡, 位于三峡大坝以西约 56 km 处, 属湖北省宜昌市秭归县管辖。滑坡总体坡度约为 30°, 平均厚度约为 30 m, 体积约为 $1260 \times 104 \text{ m}^3$; 滑面为残坡积层与基岩接触带, 厚度在 0.9~3.1 m 之间,

其基岩岩性为中厚层砂岩夹薄层泥岩, 产状 15°~36°, 岩层中节理裂隙发育; 滑体物质主要由第四系残坡积碎石土组成, 碎石含量在 20%~40% 之间^[14]。

如图 1 所示, 白水河滑坡上共布设了 11 个 GPS 位移监测点。在预警区内的监测点有 ZG93、ZG118、XD-01、XD-02、XD-03、XD-04, 其累计位移与对应的降雨量和库水位的关系见图 2。每年 5 月—9 月, 库区正值雨季, 水库开闸泄洪, 库水位下降, 滑坡累计位移经历一次阶跃式增长, 表明库水位涨落和降雨联合作用能够明显影响滑坡稳定性。相比之下, 非预警区监测点多年位移变化较小, 年均累计位移量在 35 mm 左右, 且呈直线型。

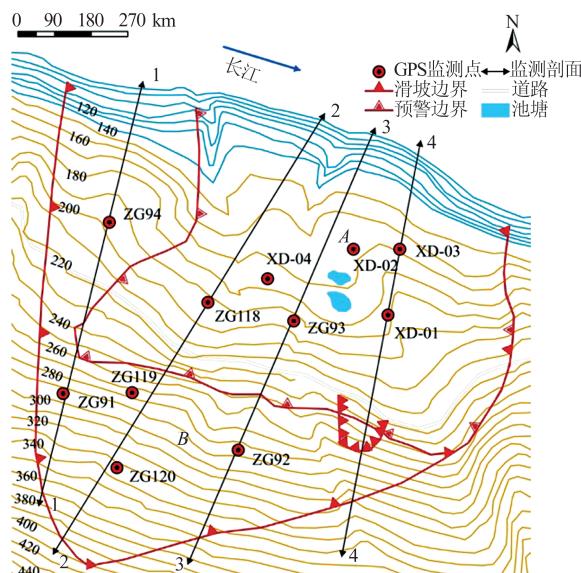


图 1 GPS 点位布设平面图

Fig.1 Layout of GPS Points

2.2 白水河滑坡位移分解

滑坡位移由趋势项、周期项和随机项组成, 并与 VMD 分解所得模态分量的频率分布具有一致的变化规律。因此, 当 $K=3$ 时, 即可得到频率依次增加的 3 个位移分量。库水位和降雨量等影响因子主要作用于滑坡的周期项位移, 呈现出明显的周期性, 但同时也包含随机信息, 作用于随机项位移。同理可设 $K=2$, 即可得影响因子的周期项和随机项。

以周期项的 Shannon 熵为适应度值, 通过 GWO 算法^[11]寻找最优 ϵ 。将白水河滑坡 ZG93 站点的实际观测值作为输入, 设种群大小为 20, 迭代次数为 100, 上下界为 [0.01, 100], 优化所得的 ϵ 值为 0.55, 将其用于 VMD 分解得到趋势项、周期项和随机项位移。

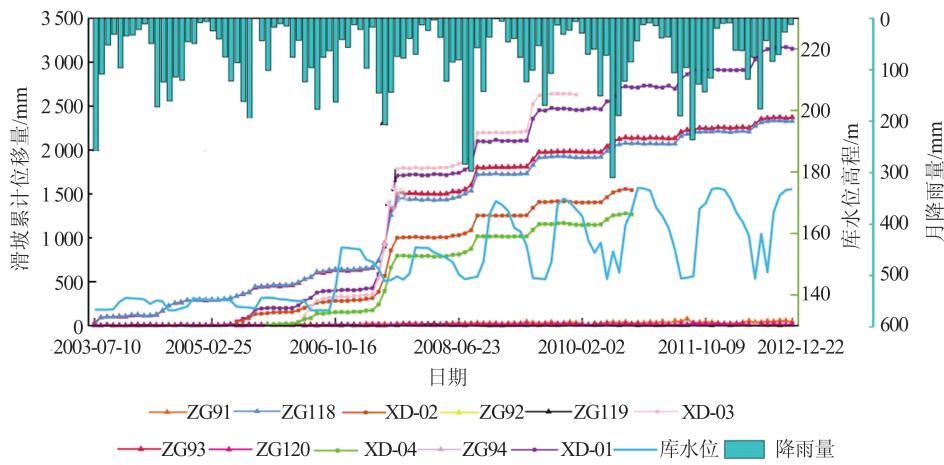


图 2 滑坡累计位移曲线-月降雨量-库水位高程关系图

Fig.2 Curves of Landslide Cumulative Displacement Monthly Rainfall, and Reservoir Water Level Elevation

2.3 滑坡影响因素选取及分解

降雨入渗促使坡体基质吸力趋于零、斜坡容重增加,导致坡体抗剪强度下降,下滑力增大;雨水对已有裂缝的快速入渗,在增强其劈裂作用同时引起地下水位抬升,导致浮托力增加^[2],从而影响滑坡稳定性。如图 3 所示,降雨对滑坡位移的影响具有明显的滞后性,库区于每年 5 月进入雨季并伴有强降雨,而滑坡位移响应则始于 7 月、8 月,呈现出快速增加的趋势。周期项位移与当月和前两个月的累计降雨量具有强相关性,且灰色关联度分别为 0.79 和 0.78,证实了它们在时序上响应关系密切。为避免数据的过度冗余,本文综合选取月降雨量 V_2 和两个月累计降雨量 V_3 表征降雨因素对滑坡位移的影响。

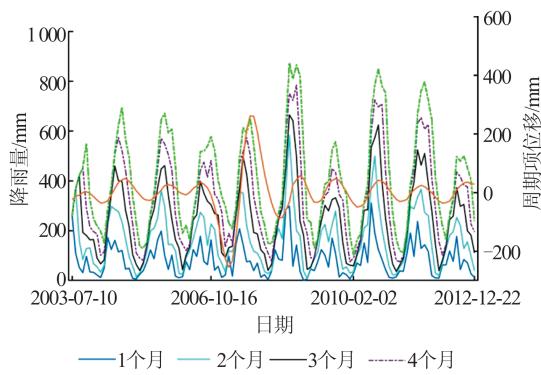


图 3 周期项位移与降雨量关系

Fig.3 Relation Between Periodic Displacement and Rainfall

库水位的周期性变动改变了坡体内的渗流场分布和岩土体的应力状态。库水位下降越快,坡体内外形成的水力梯度越大。沿坡体向外的渗流力极大影响了滑坡体的稳定性,特别是在库

水位下降后期,又遇库区降雨集中期,进一步加速了滑坡的变形破坏。图 4 展示了周期项位移与库水位变化关系,周期项位移的变化对库水涨幅的响应存在滞后性,并具有强相关性。最终选取库水位月平均高程 V_1 、单月变化幅度 V_4 、单月变化速率 V_5 和双月变化幅度 V_6 表征库水位变化对滑坡位移的影响(灰色关联度分别为 0.78、0.81、0.80、0.76)。

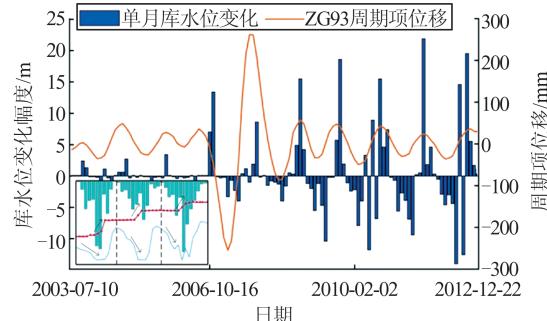


图 4 周期项位移与库水位变化关系

Fig.4 Relation Between Periodic Displacement and Reservoir Water Level Change

同理,设 $K=2$,其他设置同滑坡位移的分解。将影响因子周期项的 Shannon 熵作为适应度值来获得最优分解参数 ϵ ,进而得到随机项。计算得到的 6 个 ϵ 值分别为 0.23、0.99、0.13、0.98、0.11、0.95。

3 滑坡位移预测

3.1 滑坡位移预测流程

结合图 5,可将本文的滑坡位移预测流程概括如下:

- 1) 在滑坡位移时序加法模型的基础上,通过

VMD分解器得到滑坡位移的周期项、趋势项和随机项。

2)结合影响因素的滞后性特征,综合选取影响因子。通过VMD分解器得到影响因子的周期

项和随机项。

3)数据分组模型的构建。基于上述所得数据,以一年为基准,制备各分组模型所需的数据集。

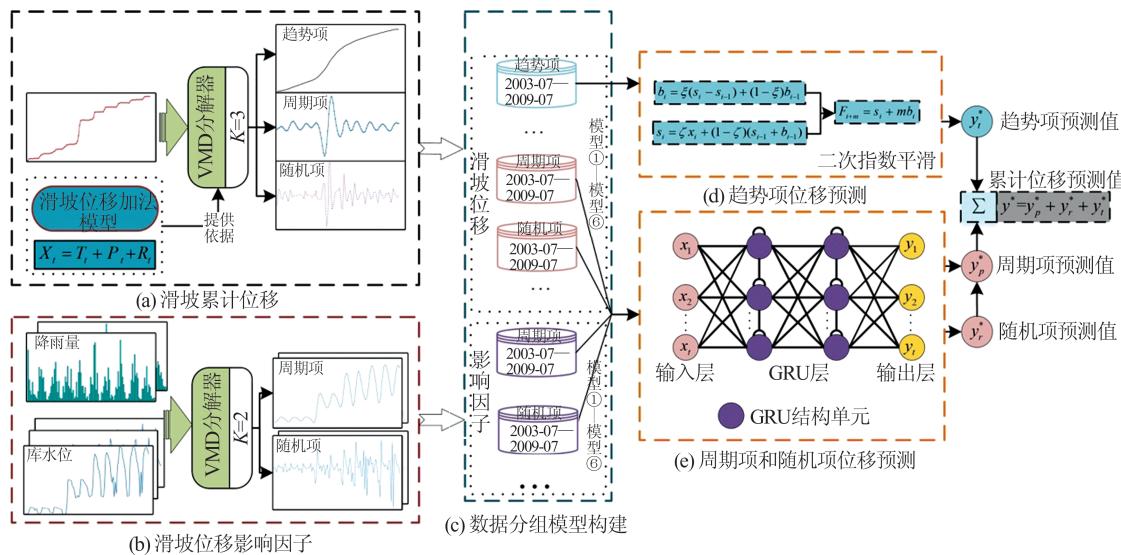


图5 位移预测流程图

Fig.5 Flowchart of Displacement Prediction

4)趋势项位移预测。对趋势项位移进行二次指数平滑法预测,对预测结果进行评价。

5)采用GRU模型对周期项位移和随机项位移进行训练与预测。设置基本参数以初始化模型,输入训练集来训练模型,并代入预测集,通过回归计算获得位移预测值,对结果进行评价。

6)叠加各位移分量的预测值,选取最优预测组合模型,实现滑坡累计位移的预测。

3.2 数据分组模型构建

本文以ZG93站点的地面监测数据为例进行分析和建模研究,包括2003-07—2012-12间的位移据、库水位以及降雨量数据。本文将2003-07—2009-06间的72组数据作为训练集,2009-07—2011-07间的25组数据作为预测集,

预留2011-08—2012-12的17组数据作为验证集。基于训练集数据,以一年为基准,构建了6组具有不同数据量的训练集,如表1所示。利用训练集构建6个训练模型,通过评估预测结果,确定预测模型的最优数据量。考虑到监测数据的时效性,本文采用序贯预测方法实施。

3.3 滑坡位移预测结果

1)趋势项位移预测。二次指数平滑(double exponential smoothing, DES)^[15]作为一种特殊的加权移动平均法,更适用于具有一定趋势的时序预测。通过DES预测得到趋势项预测结果,并计算得到模型的评价指标 R^2 为0.998, RMSE为2.741 mm,结合图6可知,DES具有很好的预测效果。

表1 各分组模型的训练数据

Tab.1 Trained Data of Grouped Models

模型 编号	数据组所属时间						数据 量/条
	2003-07—2004-07	2004-07—2005-07	2005-07—2006-07	2006-07—2007-07	2007-07—2008-07	2008-07—2009-07	
①							✓ 12
②					✓	✓	24
③				✓	✓	✓	36
④			✓	✓	✓	✓	48
⑤		✓	✓	✓	✓	✓	60
⑥	✓	✓	✓	✓	✓	✓	72

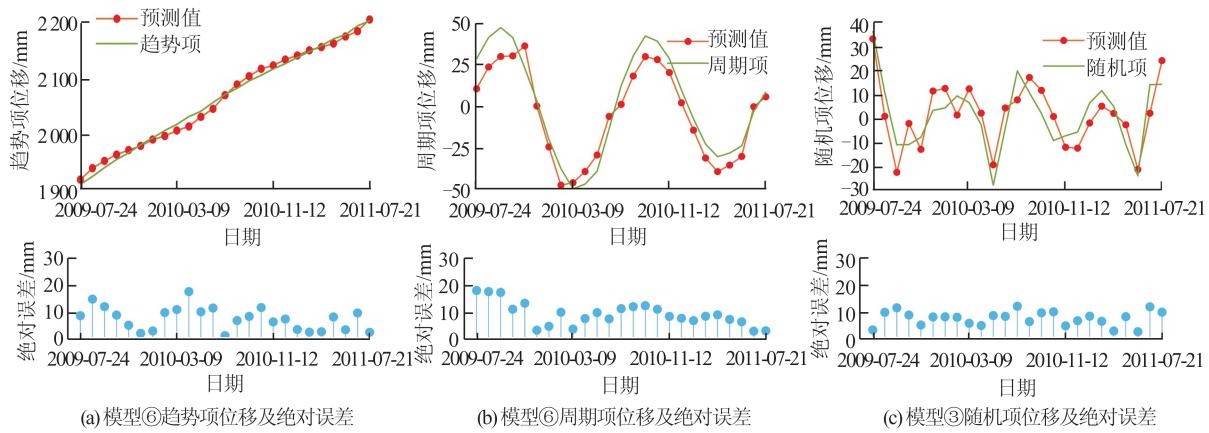


Fig.6 Prediction Result of Each Displacement Component

2) 周期项位移与随机项位移预测。为选取合适的隐藏神经元个数,本文使用模型⑥的周期项数据来进行验证,神经元个数与精度和耗时的关系如表2所示。据此可知,位移预测效果与神经元个数成正比,并在神经元个数为100时,位移预测效果达到最佳,若神经元个数继续增加,则精度降低且耗时增加。因此,本文将实验中各模型的隐藏神经元数设为100。

滑坡位移预测结果如表3所示,对于周期项位移,随着训练集数据量的增大,预测精度也随之增高,且分组模型⑥的预测效果最佳。而对于随机项位移,随着训练集数据量的增大,预测精度先增高后下降,模型③的预测精度最高。以上

结果表明,对于周期性的数据集,GRU 递归神经网络需要足够的训练数据才能得到更好的效果,而对于随机性的数据集,使用适量的数据集就能达到最佳效果。

表2 GRU 神经元个数对比

Tab.2 Comparison of the Number of Neurons of GRU

神经元个数	RMSE/mm	时间/s
20	28.581	55.295
40	19.602	56.638
60	17.988	57.699
80	12.603	60.307
100	10.175	60.649
120	10.894	61.635
140	11.131	62.281

表3 滑坡位移预测结果

Tab.3 Prediction Results of Landslide Displacement

模型编号	周期项位移		随机项位移		累计位移	
	RMSE/mm	R ²	RMSE/mm	R ²	RMSE/mm	R ²
①	21.562	0.503	9.647	0.507	24.165	0.917
②	20.722	0.541	8.729	0.597	26.043	0.904
③	18.741	0.624	8.127	0.651	20.367	0.941
④	14.042	0.789	9.107	0.569	18.582	0.952
⑤	11.171	0.867	9.196	0.552	20.106	0.943
⑥	10.175	0.889	9.468	0.514	18.742	0.951
最优组合					12.301	0.979

3) 滑坡累计位移预测。滑坡位移累计预测值由趋势项、周期项和随机项累加得到。本文以各分量的最优模型为例进行展示,各位移分量预测结果见图6。趋势项预测误差较小且差异不大,周期项预测误差具有一定周期性,而随机项预测误差表现出随机特性,且绝对误差最大不超过18.124 mm。

由表3可知,滑坡累计位移存在随着数据量增

加,预测精度先升高后降低的趋势。在6个模型中,模型④的预测精度最优。在周期项预测中,模型⑥表现最好,结合随机项预测表现最佳的模型③构建滑坡位移最优组合模型,预测结果见图7。虽然不同模型的R²差别不大,但最优组合模型的RMSE明显优于其他模型,包括模型④。因此,选择最优组合模型作为预测模型,此时ZG93站点的RMSE为12.301 mm,R²为0.979。

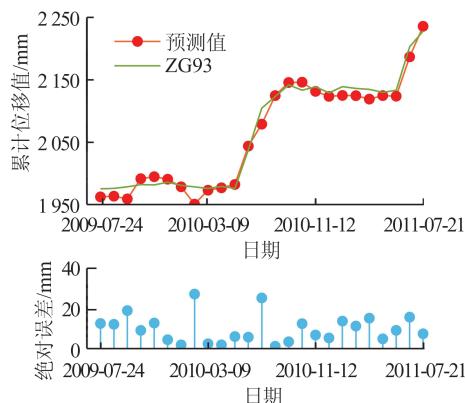


图7 2009-07-24—2011-07-21的滑坡累计位移
预测结果与绝对误差

Fig.7 Prediction Results and Absolute Errors of
Landslide Cumulative Displacements from
24 July 2009 to 21 July 2011

3.4 预测模型的可靠性验证

通过预留的验证集数据对最优组合模型进行精度评定,进一步检验所选模型的优越性。预测结果如图8所示, RMSE 为 9.715 mm, R^2 为 0.967, 说明该模型具有可靠的滑坡位移预测能力。结合目前学者已提出的滑坡位移预测模型,如 GWO-MIC-SVR^[4]、V/S-LSTM^[3]、AMPSO-SVM^[16]、Chaotic DWT-ELM^[17]和 Multi-Chaotic ELM^[18], 通过对比实验结果(表4)可知,本文提出的滑坡位移预测模型在预测时长和精度两个方面兼具优势,可在预测时长为 17 个月时保持 10 mm 以内的预测精度,与 V/S-LSTM 在 8 个月时的精度相差不到 1 mm, 进一步验证了本文方法在滑坡位移预测中的优越性。

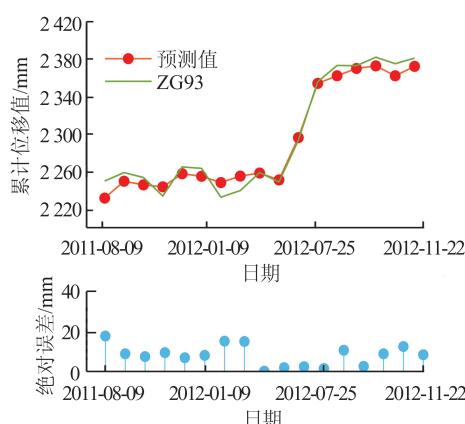


图8 2011-08-09—2012-11-22的滑坡累计位移
预测结果与绝对误差

Fig.8 Prediction Results and Absolute Errors of
Landslide Cumulative Displacements from
9 August 2011 to 22 November 2012

表4 模型预测结果对比

Tab.4 Comparison of Prediction Results
Obtained by Different Models

模型名称	预测时长/月	ZG93 站点的 RMSE/mm
本文模型	17	9.715
GWO-MIC-SVR	18	14.024
V/S-LSTM	8	8.950
AMPSO-SVM	12	11.913
Chaotic DWT-ELM	15	23.330
Multi-Chaotic ELM	20	23.710

4 结语

本文重点研究了降雨联合库水作用下的库岸滑坡位移预测,提出了一种具有序贯特性的综合预测模型。首先选择合适的影响因子,采用 GWO 与 VMD 结合的方法对滑坡位移及其影响因子进行有效分解;然后使用 GRU 模型进行有效预测。通过设计不同的数据分组模型,寻找最优组合预测模型,利用加法模型实现白水河滑坡的累计位移预测。实验结果表明,相较于其他预测方法,本文提出的模型在保证较高的预测精度的基础上,在有效预测时长和时效性上同样具有优势,是一种兼具高性能和实用性的滑坡位移综合预测模型。

致谢:感谢国家冰川冻土沙漠科学数据中心提供滑坡数据。

参考文献

- [1] Du Juan, Yin Kunlong, Chai Bo. Study of Displacement Prediction Model of Landslide Based on Response Analysis of Inducing Factors [J]. *Chinese Journal of Rock Mechanics and Engineering*, 2009, 28(9): 1783–1789. (杜娟, 殷坤龙, 柴波. 基于诱发因素响应分析的滑坡位移预测模型研究[J]. 岩石力学与工程学报, 2009, 28(9): 1783–1789.)
- [2] Li Linwei, Wu Yiping, Miao Fasheng. Prediction of Non-equidistant Landslide Displacement Time Series Based on Grey Wolf Support Vector Machine [J]. *Journal of Zhejiang University (Engineering Science)*, 2018, 52(10): 1998–2006. (李麟玮, 吴益平, 苗发盛. 基于灰狼支持向量机的非等时距滑坡位移预测[J]. 浙江大学学报(工学版), 2018, 52(10): 1998–2006.)
- [3] Feng Feifan, Wu Xueling, Niu Ruiqing, et al. A Landslide Deformation Analysis Method Using V/S and LSTM [J]. *Geomatics and Information Science of Wuhan University*, 2019, 44(5): 784–790. (冯

- 非凡, 武雪玲, 牛瑞卿, 等. 一种 V/S 和 LSTM 结合的滑坡变形分析方法[J]. 武汉大学学报(信息科学版), 2019, 44(5): 784-790.)
- [4] Li Linwei, Wu Yiping, Miao Fasheng, et al. Displacement Prediction of Landslides Based on Variational Mode Decomposition and GWO-MIC-SVR Model[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2018, 37(6): 1395-1406. (李麟玮, 吴益平, 苗发盛, 等. 基于变分模态分解与 GWO-MIC-SVR 模型的滑坡位移预测研究[J]. 岩石力学与工程学报, 2018, 37(6): 1395-1406.)
- [5] Xu S L, Niu R Q. Displacement Prediction of Baijiaobao Landslide Based on Empirical Mode Decomposition and Long Short-Term Memory Neural Network in Three Gorges Area, China[J]. *Computers & Geosciences*, 2018, 111: 87-96.
- [6] Lian C, Zeng Z G, Yao W, et al. Extreme Learning Machine for the Displacement Prediction of Landslide Under Rainfall and Reservoir Level [J]. *Stochastic Environmental Research and Risk Assessment*, 2014, 28(8): 1957-1972.
- [7] Ren F, Wu X L, Zhang K X, et al. Application of Wavelet Analysis and a Particle Swarm-Optimized Support Vector Machine to Predict the Displacement of the Shuping Landslide in the Three Gorges, China [J]. *Environmental Earth Sciences*, 2015, 73(8): 4791-4804.
- [8] Dragomiretskiy K, Zosso D. Variational Mode Decomposition[J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [9] Luo Yiyong, Yao Yibin, Huang Cheng, et al. Deformation Feature Extraction and Analysis Based on Improved Variational Mode Decomposition[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(4): 612-619. (罗亦泳, 姚宜斌, 黄城, 等. 基于改进 VMD 的变形特征提取与分析[J]. 武汉大学学报(信息科学版), 2020, 45(4): 612-619.)
- [10] Jiang Yonghua, Tang Baoping, Liu Wenyi, et al. Feature Extraction Method Based on Parameter Optimized Morlet Wavelet Transform [J]. *Chinese Journal of Scientific Instrument*, 2010, 31(1): 56-60. (蒋永华, 汤宝平, 刘文艺, 等. 基于参数优化 Morlet 小波变换的故障特征提取方法[J]. 仪器仪表学报, 2010, 31(1): 56-60.)
- [11] Mirjalili S, Mirjalili S M, Lewis A. Grey Wolf Optimizer [J]. *Advances in Engineering Software*, 2014, 69: 46-61.
- [12] Chung J, Gulcehre C, Cho K, et al. Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling [EB/OL]. [2020-10-12]. <https://arxiv.org/abs/1412.3555>.
- [13] Gao S, Huang Y F, Zhang S, et al. Short-Term Runoff Prediction with GRU and LSTM Networks Without Requiring Time Step Optimization During Sample Generation [J]. *Journal of Hydrology*, 2020, 589: 125188.
- [14] Lian C, Zeng Z G, Yao W, et al. Multiple Neural Networks Switched Prediction for Landslide Displacement [J]. *Engineering Geology*, 2015, 186: 91-99.
- [15] Zhu X, Xu Q, Tang M G, et al. A Hybrid Machine Learning and Computing Model for Forecasting Displacement of Multifactor-Induced Landslides [J]. *Neural Computing and Applications*, 2018, 30(12): 3825-3835.
- [16] Xu Feng, Fan Chunju, Xu Xunjian, et al. Displacement Prediction of Landslide Based on Variational Mode Decomposition and AMPSO-SVM Coupling Model[J]. *Journal of Shanghai Jiao Tong University*, 2018, 52(10): 1388-1395. (徐峰, 范春菊, 徐勋建, 等. 基于变分模态分解和 AMPSO-SVM 模型耦合的滑坡位移预测[J]. 上海交通大学学报, 2018, 52(10): 1388-1395.)
- [17] Huang F M, Yin K L, Zhang G R, et al. Landslide Displacement Prediction Using Discrete Wavelet Transform and Extreme Learning Machine Based on Chaos Theory [J]. *Environmental Earth Sciences*, 2016, 75(20): 1376.
- [18] Huang Faming, Yin Kunlong, Yang Beibei, et al. Step-Like Displacement Prediction of Landslide Based on Time Series Decomposition and Multivariate Chaotic Model[J]. *Earth Science*, 2018, 43(3): 887-898. (黄发明, 殷坤龙, 杨背背, 等. 基于时间序列分解和多变量混沌模型的滑坡阶跃式位移预测[J]. 地球科学, 2018, 43(3): 887-898.)