

基于优化VMD与GRU的混凝土坝变形预测模型

张建中^{1,2}, 顾冲时^{1,2}, 袁冬阳^{1,2}, 王岩博^{1,2}

(1. 河海大学水灾害防御全国重点实验室, 江苏 南京 210098; 2. 河海大学水利水电学院, 江苏 南京 210098)

摘要:为提高大坝变形预测精度,基于“分解-重构”思想,采用变形信号处理技术对实测变形加以时频分解,并结合深度学习网络对分解信号分项预测再重构,提出一种基于优化变分模态分解(VMD)与门控循环单元(GRU)的混凝土坝变形预测模型。该模型使用灰狼优化算法(GWO)优化的VMD把原始数据分解为一组最优本征模态分量(IMF),利用GWO优化的GRU网络对每个IMF分量进行滚动预测,通过叠加各个分量的预测结果得到位移序列预测结果,解决了VMD人工选择参数导致分解效果差及GRU人工选择参数影响训练速度、使用效果及鲁棒性等问题。工程实例预测结果表明,该模型的预测误差小,具有良好的预测精度与稳健性。

关键词:变分模态分解;门控循环单元;大坝变形;预测模型

中图分类号:TV698.1

文献标志码:A

文章编号:1006-7647(2023)05-0038-07

Deformation prediction model of concrete dams based on optimized VMD and GRU//ZHANG Jianzhong^{1,2}, GU Chongshi^{1,2}, YUAN Dongyang^{1,2}, WANG Yanbo^{1,2} (1. National Key Laboratory of Water Disaster Prevention, Hohai University, Nanjing 210098, China; 2. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China)

Abstract: In order to improve the accuracy of dam deformation prediction, a concrete dam deformation prediction model with optimized variational mode decomposition (VMD) and gated recurrent unit (GRU) was proposed based on the idea of decomposition-reconstruction, in which the deformation signal processing technology was used to perform time-frequency decomposition on the measured deformation and the deep learning networks was combined to predict and reconstruct the decomposed signals. Grey wolf optimization (GWO) optimized VMD was used to decompose the raw data into a set of optimal intrinsic mode components (IMF), and GWO optimized GRU network was used to perform rolling prediction on each IMF component. By overlaying the prediction results of each component, displacement sequence prediction results were obtained, solving the problems of poor decomposition effect caused by VMD manual parameter selection and the impact of GRU manual parameter selection on training speed, usage effect, and robustness. The prediction results of engineering examples show that the model has low prediction error and good prediction accuracy and robustness.

Key words: variational mode decomposition; gated recurrent unit; dam deformation; prediction model

我国已修建水库大坝近10万座,其不仅发挥了防洪、发电、供水、航运等综合效益,而且对调控水资源时空分布、助力能源结构低碳转型、促进国民经济发展等具有重大意义。在运行期间,水库大坝长期服役安全存在很多风险隐患,再加上一些工程设计和历史遗留等问题,很多工程都面临着安全隐患,一旦失事,将会对下游人民的生命财产安全和水生态安全造成巨大的威胁^[1-2]。安全监测是保证混凝土坝长效服役安全的重要手段^[3-5]。变形作为最能直观反映混凝土坝在外部荷载和内部荷载耦合作用下

运行性态的监测效应量,是安全监测的重点^[6-7]。使用混凝土坝变形监测数据进行合理的变形行为分析及预测,对保障混凝土坝长效服役安全、实时诊断大坝健康态势与预测未来运行行为具有重要意义^[3,8]。

混凝土坝变形监测数据是一种非线性、非稳态特征的时间序列,使用信号分解理论可将其分离成不同频率信号序列^[9-11]。为提高预测精度,通过引入“分解-重构”的思想,将监测数据进行高低频分解,分解成不同频率的子序列,然后分别进行预测、重构^[12-13]。朱宝强等^[14]依据时间序列原理将混凝土

基金项目:国家自然科学基金项目(U2243223,52209159);中国博士后科学基金项目(2023M730934)

作者简介:张建中(1999—),男,硕士研究生,主要从事水工结构安全监控研究。E-mail:1455046455@qq.com

通信作者:顾冲时(1962—),男,教授,博士,主要从事水工结构安全监控研究。E-mail:csgr@hhu.edu.cn

土坝位移序列分解为趋势项与随机项,并用改进的支持向量机(support vector machine, SVM)进行预测;陈俊风等^[15]使用小波分解把原始序列分解成多个子序列,用优化的BP神经网络分别对这些子序列进行预测;徐肖遥等^[16]使用经验模态分解(empirical mode decomposition, EMD)将变形数据分解成多尺度变形分量,结合改进的极限学习机(extreme learning machine, ELM)对变形分量进行预测;马佳佳等^[17]运用集合经验模态分解(ensemble empirical mode decomposition, EEMD)将原始数据分解为不同频率分量,然后分别使用长短期记忆神经网络(long short term memory neural network, LSTM)和多元线性回归对高频和低频分量进行预测;王飞等^[18]采用局部均值分解将变形数据分解成趋势项和随机项,结合相关向量机和整合移动平均自回归模型进行组合预测;张健飞等^[19]使用变分模态分解(variational mode decomposition, VMD)将变形时间序列数据分解成一系列模态分量,采用卷积神经网络对各模态分量建模并预测。

相比于单一方法(如BP^[20]、ELM^[16]、SVM^[21]等)的变形预测模型,以上“分解-重构”变形预测模型具有更好的性能,但其分解及预测方法对模型预测性能有着很大的影响^[19-22]。就位移序列分解方法而言,小波分析分解彻底,但自适应能力不强,分解尺度选取困难,很难获得最优解^[23-24];经验模态分解自适应性强,时频分辨率高,但存在模态混叠等问题^[25];EEMD虽能抑制模态混叠现象,但分解个数随机不可控,需要多次迭代求均值^[26];局部均值分解可缓解端点效应,但在模态混叠方面仍需改进^[27];相比EMD和EEMD等分解方法,VMD拥有更好的鲁棒性,可通过信号的自适应分解,有效缓解EMD模态混叠和解决EEMD分解层数不可控等问题^[21,28]。

就模型预测而言,BP神经网络具有出色的非线性特质,但收敛速度慢^[20];ELM收敛速度快、泛化能力强,但模型稳定性不够理想^[16];SVM拥有很好的学习能力,但模型计算速度比较慢,鲁棒性还需提高^[21];整合移动平均自回归模型在时间序列上有很强的有效性,但只能预测具有线性关系的数据^[18]。而混凝土坝在运行过程中产生的变形监测数据是一种时间序列,循环神经网络(recurrent neural network, RNN)是一种擅长处理各种与时间序列有关的深度学习算法^[29-30]。LSTM和门控循环单元(gate recurrent unit, GRU)在RNN基础上进行改进,是两种特殊的循环神经网络,能有效解决RNN存在的梯度消失等问题,且相比LSTM,GRU具有更少的参数,其训练效率更高^[31-34]。

考虑到“分解-重构”预测模型相比单一模型具有更好的预测性能,本文提出了一种基于优化VMD与GRU的混凝土坝变形预测模型,针对VMD分解参数需人为设置,参数过大或过小都会影响分解效果,GRU超参数的设置直接影响其训练速度、使用效果及鲁棒性等问题^[35-36],引入一种具有结构简单、参数少、求解精度高及收敛速度快等优点的群智能优化算法(grey wolf optimization, GWO)对VMD及GRU的参数进行优化选取,并与GRU、BP神经网络、ELM及VMD-GRU等预测模型进行对比,验证该模型的可靠性与有效性。

1 模型构建

1.1 GWO优化VMD

VMD是一种非迭代、自适应且准正交的信号分解方法。该方法本质上是一种基于希尔伯特变换和混合频率变分问题的自适应维纳滤波器,可以通过循环迭代的方式,搜寻求得变分问题的最优解,基于交替方向乘子法,确定每个本征模态函数(intrinsic mode function, IMF)的中心频率和带宽,由此实现各分量从低频到高频的有效分离,从而得到信号频域的特征信息。惩罚因子 α 和分解模态数 K 是变分模态分解过程中约束带宽的重要参数,决定各模态的能量变化,其取值对最终分解效果的准确性以及后续信号处理有着至关重要的影响,目前VMD参数一般采用人为设置,对数据分解的高效性与精确性有很大的影响,且很难达到最佳分解效果。本文采用GWO对VMD的两个参数 α 和 K 进行优化取值。

排列熵可以反映出信号的复杂程度,计算排列熵可以确定位移序列分解后的复杂程度,故将排列熵作为优化VMD参数的适应度函数,排列熵越小表示VMD分解后序列越有规律,越大表示VMD分解后序列越混乱^[37],故以排列熵取得最小值作为寻优目标,对参数进行优化取值。采用GWO优化VMD的步骤如下:

步骤1 获取大坝原始变形监测数据。

步骤2 算法参数设置。如狼群规模 N 、最大迭代次数 t_{\max} 、参数 α 及 K 的上下限。

步骤3 初始化灰狼位置向量。

步骤4 计算个体适应度值。适应度函数 H_p 的表达式如下:

$$H_p = - \sum_{j=1}^k P_j \ln P_j \quad (1)$$

式中: P_j 指重构后矩阵序列出现的频率; k 为 j 的取值上限。

步骤5 将当前最优个体参数分别保存至 θ 、 β 和 δ 狼的位置向量中。灰狼与猎物之间的距离及第

$t+1$ 代灰狼的位置向量分别如下:

$$D_{\omega} = |C \times X_{pt} - X_t| \quad (2)$$

$$X_{t+1} = X_{pt} - A \times D_{\omega} \quad (3)$$

式中: D_{ω} 为灰狼与猎物之间的距离; X_{pt} 为第 t 代猎物的位置向量; X_t 、 X_{t+1} 分别表示第 t 和第 $t+1$ 代灰狼的位置向量; A 、 C 为系数向量。

步骤6 更新寻优控制因子 A 和 C 及候选狼 ω 的位置向量。 A 、 C 及 ω 狼的位置向量表达式分别如下:

$$A = 2a \times r_1 - a \quad (4)$$

$$C = 2r_2 \quad (5)$$

$$X_{t+1} = (X_1 + X_2 + X_3)/3 \quad (6)$$

式中: a 为控制因子; r_1 、 r_2 是模在 $[0, 1]$ 间的随机向量。

步骤7 迭代终止条件判别。如果 $t < t_{\max}$, 则重复执行步骤 4~6; 否则, 停止迭代, 当前 θ 狼的位置向量 X_{θ} 即为 VMD 参数模型 (α, K) 寻优的结果。

步骤8 输出模型最优参数 (α, K) , 将其代入 VMD 算法分解原始数据, 得到优化后的 IMF 分量。

1.2 GWO 优化 GRU

GRU 是一种特殊类型的 RNN, 相比标准的 RNN, GRU 更完整地描述了监测效应量序列的长短期时序相关性。GRU 主要由重置门和更新门组成, 重置门决定信息被遗忘的程度, 更新门决定上一隐藏状态传递给当前隐藏层多少信息。经过 VMD 分解后, 各个分量的变化规律相比原始数据序列更加平稳, 使用 1 层 GRU 网络神经元即可满足训练要求。隐含层隐含神经元个数 n 与初始学习率 r 是 GRU 网络预测过程中的重要参数, 对模型构建及其预测精度有着至关重要的影响, 目前 GRU 参数一般采用人为设置, 随机性很大, 很难达到最佳预测效果。本文采用 GWO 对 GRU 的 n 、 r 参数进行优化取值, 以提高预测精度。

GWO 优化 GRU 算法步骤与 GWO 优化 VMD 算法步骤基本一致, 不同之处在于 GWO 优化 GRU 时采用均方误差 (E_{MSE}) 作为适应度函数, 以 E_{MSE} 最小值作为寻优目标, 即

$$E_{MSE} = \frac{1}{m} \sum_{i=1}^n (y_i - y'_i)^2 \quad (7)$$

式中: m 为训练样本容量; y_i 为实测变形; y'_i 为训练得到的变形。

1.3 优化 VMD 与 GRU 模型预测流程

根据上述方法原理, 优化 VMD 与 GRU 模型 (以下简称“本文模型”) 的主要实现过程如下: ①利用 GWO 优化求解 VMD 的重要参数 α 及 K , 使用优化的 VMD 把原始数据分解为一组最优 IMF 分量;

②利用 GWO 优化求解 GRU 的重要参数 n 及 r , 使用优化的 GRU 模型对每个 IMF 分量进行时序预测; ③将各 IMF 预测结果叠加, 得到位移序列预测结果。模型预测流程如图 1 所示。

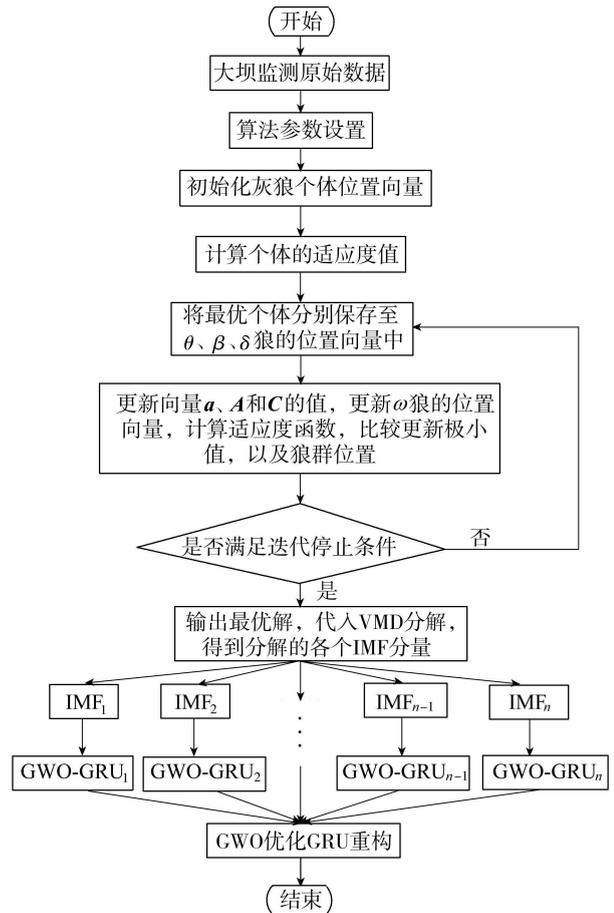


图 1 本文模型预测流程

2 工程实例验证

某特高拱坝正常蓄水位 1 240 m, 总库容 150 亿 m^3 , 坝顶高程 1 245 m, 顶宽 12 m, 坝体共由 43 个坝段组成。为掌握大坝工作性态, 采用垂线法监测坝体水平位移, 垂线测点具体布置情况如图 2 所示。为分析本文模型的有效性 with 合理性, 取 A09-PL-01、A22-IP-01 和 A29-IP-01 共 3 个测点 2010 年 7 月 1 日至 2020 年 2 月 10 日的变形监测数据作为分析对象, 具体监测数据如图 3 所示。

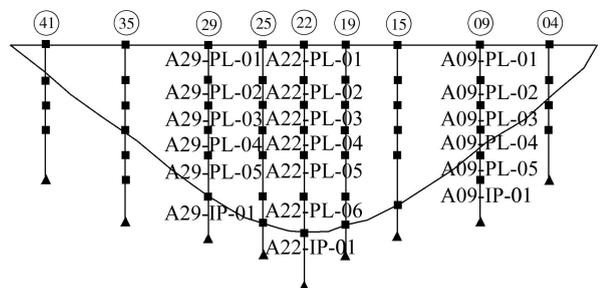


图 2 垂线测点布置

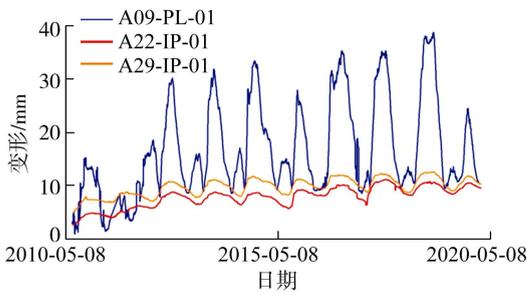


图3 实测位移变形监测数据

2.1 实测序列分解

为避免 VMD 参数随意取值影响分解效果,首先利用 GWO 迭代优化 α 和 K 两个参数,GWO 狼群数量与最大迭代次数分别 10 和 50, α 及 K 的取值区间分别为 $[100,10000]$ 与 $[2,10]$ 。测点 A09-PL-01 的寻优结果为 $\alpha = 6071$ 、 $K = 8$,测点分解结果如图 4 所示。

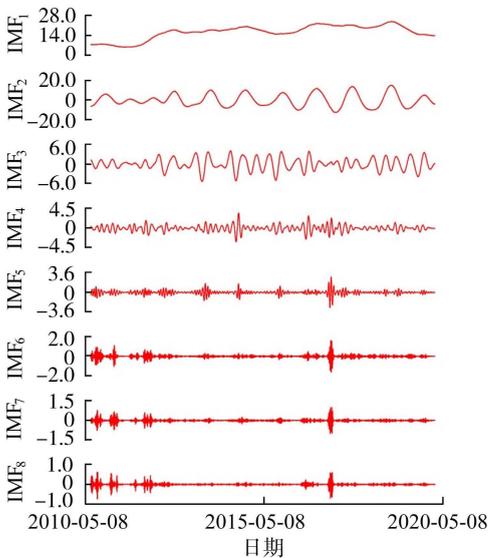


图4 A09-PL-01 测点 GWO 优化 VMD 序列分解

测点的模态分量按从低频到高频的顺序进行排序,测点的 IMF_1 分量是表示大坝变形趋势整体呈上升状态的趋势项;测点的 $IMF_2 \sim IMF_5$ 分量是周期性、平稳强度高的周期项;测点的其余分量是周期性弱、平稳性低的随机项。

2.2 建模预测

将 2010 年 7 月 1 日至 2018 年 9 月 6 日监测数据作为训练集,2018 年 9 月 7 日至 2020 年 2 月 17 日监测数据作为测试集,以测试集的预测性能来验证模型的效果。

为避免 GRU 参数随意取值影响预测效果,使用 GWO 对 GRU 参数 n 及 r 进行参数寻优,以更好地捕获每个 IMF 的趋势进行准确预测,GWO 狼群数量与最大迭代次数分别取 10 和 50,参数 n 、 r 的取值区间分别为 $[2,20]$ 与 $[0.001,0.02]$ 。各个分量参

数 $[n, r]$ 的寻优结果分别为 $[7, 0.017]$ 、 $[13, 0.016]$ 、 $[20, 0.011]$ 、 $[8, 0.010]$ 、 $[17, 0.009]$ 、 $[11, 0.011]$ 、 $[6, 0.020]$ 、 $[14, 0.011]$ 。将优化参数代入 GWO 优化 GRU 进行预测,各分量的预测结果如图 5 所示。

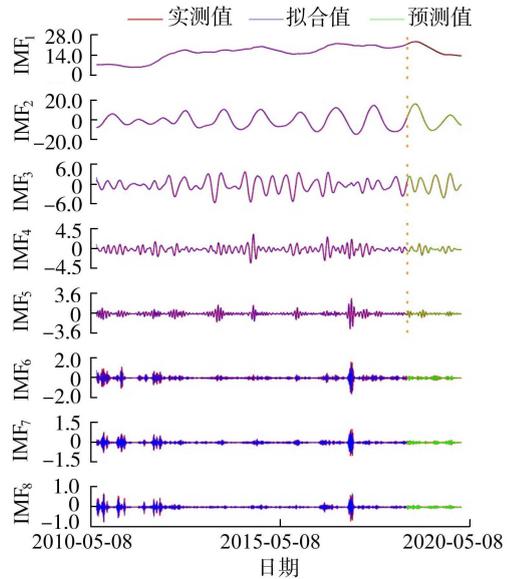


图5 A09-PL-01 测点各 IMF 分量 GWO 优化 GRU 预测结果

从图 5 可以看出,各分量的实测值和预测值的最大误差不超过 0.1 mm,预测误差很小。将测点所包含的各 IMF 分量预测结果叠加,得到测点变形预测结果。同时,为验证本文模型的有效性,同时采用 GRU、BP 神经网络、ELM 及 VMD-GRU 模型等预测方法进行预测,预测结果对比如图 6 所示。

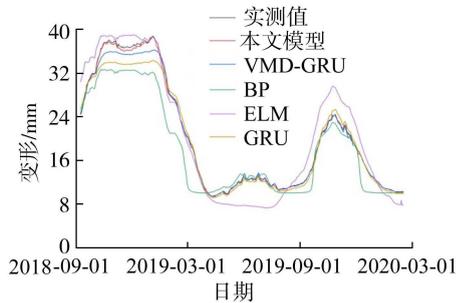


图6 A09-PL-01 测点各模型预测结果对比

2.3 模型对比及精度分析

为进一步验证本文模型的普适性,对 A22-IP-01 和 A29-IP-01 两个测点进行建模预测,结果如图 7 所示。为评估本文模型的预测精度,综合采用决定系数 (R^2)、平均绝对误差 (MAE)、均方根误差 (RMSE) 和平均绝对百分比误差 (MAPE) 作为各测点预测模型预测统计指标,计算结果如表 1 所示。

由图 6 与图 7 可以看出,对于 A09-PL-01、A22-IP-01 和 A29-IP-01 这 3 个测点,5 种预测模型预测值与真实值的变化趋势基本一致,但相比 BP 神经网络、ELM、GRU 以及 VMD-GRU 模型的预测结果,

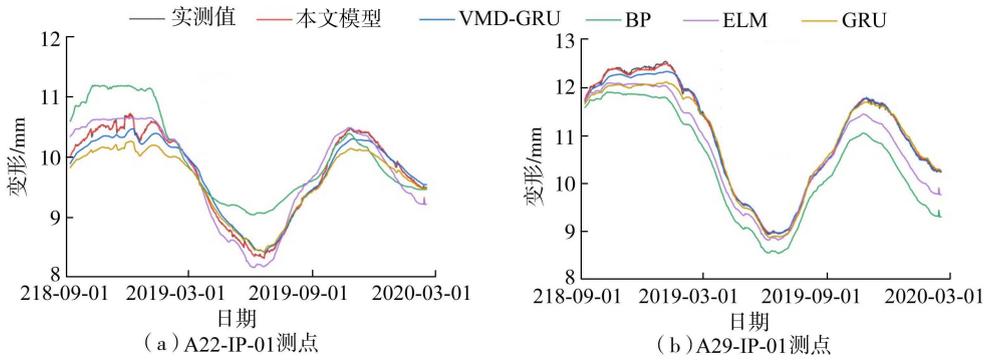


图7 两个测点各模型预测结果对比

表1 各预测模型性能评价指标

测点	模型	R^2	MAE/mm	RMSE/mm	MAPE/%
A09-PL-01	BP	0.8813	2.6246	3.5304	21.13
	ELM	0.9142	2.4417	3.0207	15.08
	GRU	0.9872	0.6741	1.1579	2.30
	VMD-GRU	0.9941	0.4811	0.7874	1.84
	本文模型	0.9996	0.1243	0.1910	0.55
A22-IP-01	BP	0.8245	0.3611	0.4381	1.98
	ELM	0.9434	0.1445	0.1701	1.51
	GRU	0.9069	0.1787	0.2181	1.76
	VMD-GRU	0.9747	0.0961	0.1138	0.09
	本文模型	0.9996	0.0097	0.0139	0.01
A29-IP-01	BP	0.8928	0.5911	0.6258	2.86
	ELM	0.9134	0.2865	0.3320	2.54
	GRU	0.9757	0.1265	0.1759	1.09
	VMD-GRU	0.9926	0.0681	0.0971	0.58
	本文模型	0.9995	0.0194	0.0256	0.17

本文模型的预测值更加接近实测变形值,预测值和实测值基本吻合,模型具有更高的精度。由表1可知,本文模型的MAE、RMSE与MAPE均明显小于BP神经网络、ELM、GRU与VMD-GRU模型。这3个测点本文模型的 R^2 分别为0.9996、0.9996和0.9995,显著接近于1,且明显高于其他4个模型,进一步说明了本文模型预测性能的优良性。由此可以得出,本文模型比GRU、BP神经网络、ELM以及VMD-GRU模型的预测精度更高,有效验证了该模型的普适性与稳健性。

3 结语

采用GWO分别优化VMD及GRU的重要参数,避免人工赋值的不确定性,解决了模型参数选择困难的问题,提高了数据挖掘及非线性处理能力。

基于“分解-重构”的思想,将监测数据进行高低频分解,分解成不同频率的子序列,并结合深度学习网络对其预测再重构,相比单一手段建立的预测模型,预测性能更好;本文模型相比未进行参数寻优的VMD-GRU模型预测精度更高,实例进一步验证了本文模型的有效性、泛化性及准确性。

参考文献:

- [1] 顾冲时,苏怀智,刘何稚.大坝服役风险分析与管理研究述评[J].水利学报,2018,49(1):26-35. (GU Chongshi, SU Huaizhi, LIU Hezhi. Review on service risk analysis of dam engineering [J]. Journal of Hydraulic Engineering, 2018, 49(1): 26-35. (in Chinese))
- [2] 王少伟,顾冲时,包腾飞.基于MSC. Marc的高混凝土坝非线性时时效变形量化的程序实现[J].中国科学:技术科学,2019,49(4):433-444. (WANG Shaowei, GU Chongshi, BAO Tenfei. Program implementation of quantifying the nonlinear time-dependent deformation of high concrete dams based on MSC. Marc [J]. Scientia Sinica Technologica, 2019, 49(4): 433-444. (in Chinese))
- [3] 顾昊,曹文翰,汪程,等.混凝土坝服役性态监测效应量安全监控指标拟定方法[J].水利水电科技进展,2021,41(1):30-34. (GU Hao, CAO Wenhan, WANG Cheng, et al. Safety monitoring index determination for monitoring effect quantity of concrete dams in service [J]. Advances in Science and Technology of Water Resources, 2021, 41(1): 30-34. (in Chinese))
- [4] 赵二峰,顾冲时.混凝土坝长效服役性态健康诊断研究述评[J].水力发电学报,2021,40(5):22-34. (ZHAO Erfeng, GU Chongshi. Review on health diagnosis of long-

- term service behaviors for concrete dams [J]. Journal of Hydroelectric Engineering, 2021, 40 (5): 22-34. (in Chinese))
- [5] 赵二峰, 顾冲时. 碾压混凝土坝安全服役关键技术研究进展[J]. 水利水电科技进展, 2022, 42(1): 11-20. (ZHAO Erfeng, GU Chongshi. Review on key technologies for safe operation of roller compacted concrete dams[J]. Advances in Science and Technology of Water Resources, 2022, 42(1): 11-20. (in Chinese))
- [6] YUAN Dongyang, WEI Bowen, XIE Bin, et al. Modified dam deformation monitoring model considering periodic component contained in residual sequence [J]. Structural Control and Health Monitoring, 2020, 27(12): 2633.
- [7] 张石, 郑东健, 陈卓研. 基于改进 PSO-RF 算法的大坝变形预测模型[J]. 水利水电科技进展, 2022, 42(6): 39-44. (ZHANG Shi, ZHENG Dongjian, CHEN Zhuoyan. Dam deformation prediction model based on improved PSO-RF algorithm [J]. Advances in Science and Technology of Water Resources, 2022, 42(6): 39-44. (in Chinese))
- [8] 袁冬阳, 顾冲时, 顾昊. 严寒地区混凝土重力坝变形行为分析与预测模型[J]. 水利学报, 2022, 53(6): 733-746. (YUAN Dongyang, GU Chongshi, GU Hao. Displacement behavior analysis and prediction model of concrete gravity dams in cold region [J]. Journal of Hydraulic Engineering, 2022, 53(6): 733-746. (in Chinese))
- [9] ZHU Jiaming, LIU Tinpei, CHEN Huayou, et al. A novel decomposition-ensemble approach to crude oil price forecasting with evolution clustering and combined model [J]. International Journal of Machine Learning and Cybernetics, 2019, 10(12): 3349-3362.
- [10] ZHANG Yechi, WANG Jianzhou, LU Haiyan. Research and application of a novel combined model based on multiobjective optimization for multistep-ahead electric load forecasting [J]. Energies, 2019, 12(10): 1-27.
- [11] 魏博文, 袁冬阳, 蔡磊, 等. 基于 BP-ARIMA 的混凝土坝多尺度变形组合预报模型[J]. 水利水运工程学报, 2018(2): 52-60. (WEI Bowen, YUAN Dongyang, CAI Lei, et al. Multi-scale deformation combination forecast model for concrete dam based on BP-ARIMA [J]. Hydro-Science and Engineering, 2018(2): 52-60. (in Chinese))
- [12] 魏博文, 罗绍杨, 徐富刚, 等. 基于监测时序分解再重构的混凝土拱坝位移预测组合模型[J]. 工程科学与技术, 2022(5): 1-13 (WEI Bowen, LUO Shaoyang, XU Fugang, et al. Combination model of deformation prediction for concrete arch dam with residual effective components [J]. Advanced Engineering Sciences, 2022(5): 1-13. (in Chinese))
- [13] 姜宇航, 王伟, 邹丽芳, 等. 基于粒子群-变分模态分解、非线性自回归神经网络与门控循环单元的滑坡位移动态预测模型研究[J]. 岩土力学, 2022, 43(1): 1-12. (JIANG Yuhang, WANG Wei, ZOU Lifang, et al. Research on dynamic prediction model of landslide displacement based on particle swarm optimization-variational mode decomposition, nonlinear autoregressive neural network with exogenous inputs and gated recurrent unit [J]. Rock and Soil Mechanics, 2022, 43(1): 1-12. (in Chinese))
- [14] 朱宝强, 王述红, 张泽, 等. 基于时间序列与 DEGWO-SVR 模型的隧道变形预测方法[J]. 浙江大学学报(工学版), 2021, 55(12): 2275-2285. (ZHU Baoqiang, WANG Shuhong, ZHANG Ze, et al. Prediction method of tunnel deformation based on time series and DEGWO-SVR model [J]. Journal of Zhejiang University, 2021, 55(12): 2275-2285. (in Chinese))
- [15] 陈俊风, 王玉浩, 张学武, 等. 基于小波变换与差分变异 BSO-BP 算法的大坝变形预测[J]. 控制与决策, 2021, 36(7): 1611-1618. (CHEN Junfeng, WANG Yuhao, ZHANG Xuewu, et al. Dam deformation prediction based on wavelet transform and differential mutation BSO-BP algorithm [J]. Control and Decision, 2021, 36(7): 1611-1618. (in Chinese))
- [16] 徐肖遥, 张鹏飞, 蒋剑. 基于 EMD-PSO-ELM 算法的大坝变形预测研究[J]. 软件导刊, 2020, 19(9): 1-5. (XU Xiaoyao, ZHANG Pengfei, JIANG Jian. Research on dam deformation prediction based on EMD-PSO-ELM algorithm and multi factors [J]. Software Guide Software Guide, 2020, 19(9): 1-5. (in Chinese))
- [17] 马佳佳, 苏怀智, 王颖慧. 基于 EEMD-LSTM-MLR 的大坝变形组合预测模型[J]. 长江科学院院报, 2021, 38(5): 47-54. (MA Jiajia, SU Huaizhi, WANG Yinghui. Combinatorial prediction model for dam deformation based on EEMD-LSTM-MLR [J]. Journal of Yangtze River Scientific Research Institute, 2021, 38(5): 47-54. (in Chinese))
- [18] 王飞. 基于局部均值分解和 PSO-RVM-ARIMA 模型的基坑变形预测研究[J]. 河南科学, 2021, 39(10): 1649-1654. (WANG Fei. Prediction of foundation pit deformation based on local mean decomposition and PSO-RVM-ARIMA model [J]. Henan Sciences, 2021, 39(10): 1649-1654. (in Chinese))
- [19] 张健飞, 衡琰. 基于 VMD-PE-CNN 的混凝土坝变形预测模型[J]. 水利水电技术, 2022, 53(11): 100-109. (ZHANG Jianfei, HENG Yan. Deformation prediction model of concrete dam based on VMD-PE-CNN [J]. Water Resources and Hydropower Engineering, 2022, 53(11): 100-109. (in Chinese))
- [20] 黄军胜, 黄良珂, 刘立龙, 等. 基于 EMD-FOA-BP 神经网络的大坝变形预测研究[J]. 水力发电, 2019, 45(2): 106-110. (HUANG Junsheng, HUANG Liangke, LIU Lilong, et al. Study on dam deformation prediction based on EMD-FOA-BP neural network [J]. Water Power, 2019, 45(2): 106-110. (in Chinese))
- [21] 蒋朝云, 李亚, 王海瑞. 灰狼算法优化 VMD 与 SVM 的滚动轴承故障诊断[J]. 农业装备与车辆工程, 2022, 60

- (9):88-92. (JIANG Chaoyun, LI Ya, WANG Hairui. Fault diagnosis of rolling bearing based on grey wolf algorithm optimizing VMD and SVM [J]. Agricultural Equipment & Vehicle Engineering, 2022, 60(9):88-92. (in Chinese))
- [22] 侯回位, 郑东健, 刘永涛, 等. 基于 EEMD-SE-LSTM 的混凝土坝变形监测模型[J]. 水利水电科技进展, 2022, 42(1):61-66. (HOU Huiwei, ZHENG Dongjian, LIU Yongtao, et al. Deformation monitoring model of concrete dams based on EEMD-SE-LSTM [J]. Advances in Science and Technology of Water Resources, 2022, 42(1):61-66. (in Chinese))
- [23] 李润鸣, 包腾飞, 高瑾瑾, 等. 基于小波 EGM-ISFLA-SVR 的大坝变形组合预测模型[J]. 水利水电技术, 2018, 49(5):57-62. (LI Jianming, BAO Tengfei, GAO Jinjin, et al. Wavelet EGM-ISFLA-SVR-based hybrid prediction model for dam deformation [J]. Water Resources and Hydropower Engineering, 2018, 49(5):57-62. (in Chinese))
- [24] 梁月吉, 任超, 刘立龙, 等. 基于 EMD 和 GA-BP 神经网络的大坝变形预测[J]. 桂林理工大学学报, 2015, 35(1):111-116. (LIANG Yueji, REN Chao, LIU Lilong, et al. Dam deformation prediction based on EMD and GA-BP neural network [J]. Journal of Guilin University of Technology, 2015, 35(1):111-116. (in Chinese))
- [25] 王进花, 胡佳伟, 曹洁, 等. 基于自适应变分模态分解和集成极限学习机的滚动轴承多故障诊断[J]. 吉林大学学报(工学版), 2022, 52(2):318-328. (WANG Jinhua, HU Jiawei, CAO Jie, et al. Multi-fault diagnosis of rolling bearing based on adaptive variational modal decomposition and integrated extreme learning machine [J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(2):318-328. (in Chinese))
- [26] 刘永涛, 郑东健, 孙雪莲, 等. 基于 EEMD-RVM 的土石坝渗流量时间序列预测模型[J]. 水利水电科技进展, 2021, 41(3):89-94. (LIU Yongtao, ZHENG Dongjian, SUN Xuelian, et al. Time series prediction model of seepage flow of an earth-rock dam based on EEMD-RVM [J]. Advances in Science and Technology of Water Resources, 2021, 41(3):89-94. (in Chinese))
- [27] 李乾德, 王东, 李啸啸, 等. 改进的 LMD 模型在大坝变形监测数据特征量分离中的运用[J]. 大坝与安全, 2019(4):24-27. (LI Qiande, WANG Dong, LI Xiaoxiao, et al. Application of improved LMD model in characteristic quantity separation of dam deformation monitoring data [J]. Dam & Safety, 2019(4):24-27. (in Chinese))
- [28] GAN Min, PAN Haidong, CHEN Yongping, et al. Application of the variational mode decomposition (VMD) method to river tides [J]. Estuarine, Coastal and Shelf Science, 2021. DOI:10.1016/j.ecss.2021.107570.
- [29] 范鹏飞, 祝福源. 基于 HS 算法优化的 EEMD-RNN 混凝土坝位移预测模型[J]. 中国农村水利水电, 2021, 466(8):180-185. (FAN Pengfei, ZHU Fuyuan. Displacement prediction model of EEMD-RNN concrete dam based on HS algorithm optimization [J]. China Rural Water and Hydropower, 2021, 466(8):180-185. (in Chinese))
- [30] 任秋兵, 沈扬, 李明超, 等. 水工建筑物安全监控深度分析模型及其优化研究[J]. 水利学报, 2021, 52(1):71-80. (REN Qiubing, SHEN Yang, LI Mingchao, et al. Safety monitoring model of hydraulic structures and its optimization based on deep learning analysis [J]. International Journal of Machine Learning and Cybernetics, 2021, 52(1):71-80. (in Chinese))
- [31] PAN Mingyang, ZHOU Hainan, CAO Jiayi, et al. Water level prediction model based on GRU and CNN [J]. IEEE Access, 2020, 8:60090-60100.
- [32] 马延强, 肖军杰, 邵丽蓉, 等. 基于 LSTM 和 GRU 网络融合的印刷车间温湿度预测模型研究[J]. 数字印刷, 2022(3):34-41. (MA Yanqiang, XIAO Junjie, SHAO Lirong, et al. Research on predicting temperature and humidity in printing workshop based on fusion of LSTM and GRU Network [J]. Digital Printing, 2022(3):34-41. (in Chinese))
- [33] 邓思源, 周兰庭, 柳志坤. 基于卡尔曼滤波、分形和 LSTM 的大坝变形趋势分析方法[J]. 水利水电科技进展, 2022, 42(5):121-126. (DENG Siyuan, ZHOU Lanting, LIU Zhikun. Analysis method of dam deformation trend based on Kalman filter, fractal and LSTM [J]. Advances in Science and Technology of Water Resources, 2022, 42(5):121-126. (in Chinese))
- [34] 欧斌, 吴邦彬, 袁杰, 等. 基于 LSTM 的混凝土坝变形预测模型[J]. 水利水电科技进展, 2022, 42(1):21-26. (OU Bin, WU Bangbin, YUAN Jie, et al. LSTM-based deformation prediction model of concrete dams [J]. Advances in Science and Technology of Water Resources, 2022, 42(1):21-26. (in Chinese))
- [35] 段雪滢, 李小腾, 陈文洁. 基于改进粒子群优化算法的 VMD-GRU 短期电力负荷预测[J]. 电工电能新技术, 2022, 41(5):8-17. (DUAN Xueying, LI Xiaoteng, CHEN Wenjie. Improved particles swarm optimization algorithm-based VMD-GRU method for short-term load forecasting [J]. Advanced Technology of Electrical Engineering and Energy, 2022, 41(5):8-17. (in Chinese))
- [36] 赵一钧, 石雷, 齐笑, 等. 基于加强灰狼优化 VMD-DBN 的变压器故障检测[EB/OL]. [2023-08-04]. <http://www.cnki.com.cn/Article/CJFDTotal-DCYQ20210406000.htm>.
- [37] 李宏, 李定文, 朱海琦, 等. 一种优化的 VMD 算法及其在语音信号去噪中的应用[J]. 吉林大学学报(理学版), 2021, 59(5):1219-1227. (LI Hong, LI Dingwen, ZHU Haiqi, et al. An optimized VMD algorithm and its application in speech signal denoising [J]. Journal of Jilin University (Science Edition), 2021, 59(5):1219-1227. (in Chinese))

(收稿日期:2022-10-03 编辑:骆超)