

基于 VMD-XGBoost-GRU 模型的危岩体变形预测

许秋鸿, 刘晓青

(河海大学水利水电学院, 江苏 南京 210098)

摘要: 针对以往对危岩体监测数据前处理效果不佳的问题, 提出了一种用于危岩体变形预测的 VMD-XGBoost-GRU 组合模型。该模型采用变分模态分解(VMD)和样本熵理论将危岩体变形数据分解成多个子序列, 利用 XGBoost 算法提取重要的模型因子实现特征降维, 通过门控循环单元(GRU)神经网络对危岩体变形进行预测。以某水电站右坝肩陡壁上的危岩体变形预测为例, 将 VMD-XGBoost-GRU 组合模型与 BP、GRU 和 VMD-XGBoost-BP 3 种模型进行对比与分析, 结果表明, VMD-XGBoost-GRU 组合模型在危岩体变形预测方面具有较高精度, 可为危岩体安全稳定状态评价提供技术依据。

关键词: 危岩体; VMD; 样本熵; XGBoost; GRU; 变形预测模型

中图分类号: TV697.2

文献标志码: A

文章编号: 1006-7647(2024)02-0092-07

Deformation prediction of dangerous rock mass based on VMD-XGBoost-GRU model//XU QiuHong, LIU Xiaoqing
(College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China)

Abstract: Aiming at the problem of poor pre-processing of monitoring data of dangerous rock mass in the past, a VMD-XGBoost-GRU combined model was proposed for predicting deformation of dangerous rock mass. The model firstly uses variational mode decomposition (VMD) and sample entropy theory to decompose the deformation data of dangerous rock mass into multiple sub-sequences, then uses extreme gradient lift (XGBoost) algorithm to extract important model factors to achieve feature dimensionality reduction, and finally predicts the deformation of dangerous rock mass through gated recurrent unit (GRU) neural network. Taking the dangerous rock mass on the steep wall of the right abutment of a hydropower station as an example, the VMD-XGBoost-GRU combined model was compared with three other models, namely BP, GRU and VMD-XGBoost-BP. The results show that the VMD-XGBoost-GRU combined model has high precision in predicting the deformation of dangerous rock mass, and can provide technical basis for the evaluation of the safe and stable state of dangerous rock mass.

Key words: dangerous rock mass; VMD; sample entropy; XGBoost; GRU; displacement prediction model

水电站周围若发生危岩体失稳滑动, 可能对水电站安全造成严重影响。对危岩体的安全稳定状态进行分析评价时, 必须准确有效地处理和利用相关监测数据, 选用合适的模型进行预测和分析, 针对可能发生的滑坡灾害及时发出预警, 提高危岩体滑坡危害预防能力。

用监测数据预测变形的研究方法可以分为两大类: 基于传统数学方法的统计预测方法和基于机器学习的智能预测方法。基于传统数学方法的统计预测方法具有操作简单、计算简洁、预测速度快等优点, 但对非线性数据的预测效果较差, 并且无法很好地分析长时间序列数据的内部关系。相对而言, 基

于机器学习的智能预测方法可以更好地处理非线性数据和长时间序列数据, 并且能够通过自我学习发现数据的内在规律和特征^[1-2]。因此目前大多采用机器学习方法分析和预测监测数据。例如: 王雪红等^[3]基于改进粒子群优化算法和反向传播(back propagation, BP)神经网络拟合和预测了大坝顺河向位移值, 拟合效果好, 预测结果的平均相对误差小, 但求解速度较慢, 需要采用改进方法来提高优化效率; 向镇洋等^[4]提出一种基于混合注意力机制与鲸鱼优化算法的双向门控循环网络预测模型, 通过挖掘时序数据中前后信息的动态相关性, 探究了大坝变形的内在影响机理, 模型精度较高; 张才溢

基金项目: 国家重点研发计划项目(2022YFC3005403); 中国电建集团科技项目(DJ-ZDXM-2021-10)

作者简介: 许秋鸿(1999—), 女, 硕士研究生, 主要从事边坡稳定安全监控研究。E-mail: xuqiuHong3156@163.com

通信作者: 刘晓青(1965—), 女, 教授, 博士, 主要从事水工结构计算研究。E-mail: lxqhh@163.com

等^[5]运用自适应粒子群优化算法结合孪生支持向量机模型,探究了拱坝变形与影响因子间复杂的非线性关系,模型预测精度良好。

监测数据复杂度较大时,数据分析和预测会有一定困难,在进行预测前对数据进行一定处理有助于提升预测模型精度^[6-8]。赵鲲鹏^[9]先采用经验模态分解法分解混凝土平板坝水平位移,再通过人工蜂群算法结合人工神经网络模型进行预测,这种组合模型提取和保留了原始数据中的有效信息,具有较高的预测精度。梁智等^[10]通过变分模态分解(variational mode decomposition, VMD)技术将原始历史负荷序列分解,对分解得到的模态函数进行特征分析,再借助深度信念网络分别建立负荷预测模型,提升预测精度的同时能够更好地掌握人们用电行为的不同周期特性。侯回位等^[11]采用集成经验模态分解法处理原始数据序列,并根据子序列的样本熵重构数据,最后利用长短期记忆(long short-term memory, LSTM)网络进行预测,预测精度较高且具有较强鲁棒性。

危岩体变形数据往往是非线性的长时间序列,数据复杂度较大,对数据进行有效的前处理,能够更充分地挖掘出数据的内部关系。本文提出了一种VMD-XGBoost-GRU组合模型,并运用该模型对某水电站右坝肩陡壁上的危岩体变形数据进行预测,同时将预测结果与BP、门控循环单元(gated recurrent unit, GRU)和VMD-XGBoost-BP 3种模型的预测结果进行对比,以期验证该模型的精度和可行性。

1 模型构建

VMD-XGBoost-GRU组合模型的主要实现步骤如下:①采用VMD方法将危岩体变形数据分解为多个子序列,降低数据的复杂度;②利用XGBoost算法提取出对各个子序列具有较大重要性的影响因子,实现特征数据的降维;③构建GRU模型进行预测和训练,将各个子序列的预测值进行重构,得到最终的预测结果。模型的具体预测流程如图1所示。

1.1 时间序列分解

VMD方法是一种自适应非递归的模态分解方法,分解过程可大致分为变分问题的构造和求解两部分^[12]。采用VMD方法对数据进行分解时,模态数 K 的取值会影响分解的效果。若 K 取值较小,数据中的一些重要信息会丢失;若 K 取值较大,同一频率特性的模态分量会分解到不同子序列中,造成模态重叠的问题^[13]。本文借助样本熵对模态数 K 进行选择。样本熵是一种熵理论,可以确定时间序列在单一尺度上的无规则程度和复杂程度。每个子




图1 VMD-XGBoost-GRU组合模型危岩体变形预测流程

序列反映了原始数据不同的特征,故不同子序列的样本熵应存在一定区别。若某 K 值下相邻的两个子序列样本熵过于接近,则可认为此时 K 值过大,存在过度分解出现模态重叠的问题。

1.2 输入变量筛选

相较于大坝安全监测领域,目前对于边坡危岩体变形模型的研究相对较少,且岩土变形机理复杂,通常需要根据实际工程项目具体分析。参考大坝统计模型研究成果^[14-15],结合本文研究的危岩体分布区发育有多条长大裂隙的实际情况,考虑温度和时效为主要影响因素。温度因子选择线性化温度因子 T_i 和多周期的谐波作为影响因子,而时效因子选择 θ 和 $\ln\theta$ 两个常用函数作为影响因子,构建危岩体变形统计模型如下:

$$Y = \sum_{i=1}^8 a_i T_i + \sum_{j=1}^2 \left(b_{1j} \sin \frac{2\pi jt}{365} + b_{2j} \cos \frac{2\pi jt}{365} \right) + c_1 \theta + c_2 \ln \theta \quad (1)$$

式中: Y 为危岩体变形值; $T_1, T_2, \dots, T_8$ 分别表示实测资料中某一时间点当天、前7d、前15d、前30d、前45d、前60d、前90d、前120d的气温平均值; t 为观测日到基准日的累计天数; $\theta = t/100$; a_i, b_{ij}, c_i 为各影响因子的系数。该模型中12个影响因子分别用 $x_1, x_2, \dots, x_{12}$ 表示。

在进行预测前已对数据进行了预处理,通过VMD方法降低了数据复杂度。若在预测时将所有影响因子作为输入变量,输入的影响因子过多或影响因子之间存在多重共线性干扰,会使模型变量冗余,泛化能力降低^[16],因此需要对输入变量进行筛选。

XGBoost是一种基于梯度提升思想的机器学习算法。XGBoost模型通过迭代添加树的方式建立,根据建树结构时,特征被用于叶节点分裂的次数、

特征的平均增益值和特征的平均覆盖率这 3 个指标,计算评价特征重要度^[17-19]。本文采用 XGBoost 算法筛选出对于各子序列重要性较大、相关性较强的影响因子,作为输入变量进行预测。

1.3 GRU 模型预测

GRU 是 LSTM 的一种变体,简化了 LSTM 的模型结构。GRU 合并遗忘门和输入门为一个更新门,用于控制历史信息的保留程度;保留了重置门,用于决定是否结合当前状态和历史信息^[20-23]。GRU 对于时间序列中有效信息的挖掘更具优势,在面对大规模训练样本的情况时,能够在减少预测时间的同时保证预测效果不受明显影响。

本文采用开源深度学习框架 Tensorflow^[24],通过 Python 构建 GRU 深度门控网络模型。模型参数的选择参考相关文献并结合试错法确定,根据预测精度调整参数^[25-28]。GRU 神经网络模块中层数越多,模型的学习能力越强,但是层数过多时又会有难以收敛的问题^[29],本文选择构建层数为 2 层。为增强模型的泛化性,防止过拟合,在每个 GRU 层之后添加一个 Dropout 层,其中 Dropout 参数为 0.1。学习率控制模型训练过程中参数更新速度,取值过小模型训练速度降低,取值过大将难以逼近最优值^[30],经试验最终确定学习率为 0.001。损失函数为 MSE 函数,激活函数选用 ReLU 函数,并采用 Adam 优化器训练模型。选取经过筛选后的影响因子作为模型输入,为避免量纲单位不同造成的影响,输入模型的数据进行归一化处理。通过平均绝对误差(MAE)和均方根误差(RMSE)等指标对预测模型的性能优劣进行评价。

2 工程实例计算与分析

2.1 数据获取

某危岩体位于大坝右岸进水口上方的灰岩陡崖上,距右坝肩最近水平距离 140 m,分布高程 880 ~ 1080 m,灰岩体积约 54.53 万 m³。为监测危岩体变形,在危岩体上部崖面布置了多组多点位移计。为验证本文提出的组合预测模型,本文取编号为 M5Dr2-14 的位移计 2 号和 3 号两个测点作为计算分析对象。两个测点数据时间范围均为自 2009 年 9 月 25 日至 2014 年 5 月 25 日,每个测点共 483 组变形数据。将这些数据按照 8 : 2 的比例划分为训练集和测试集,划分数据有助于评估模型的泛化能力,检验模型在未知数据上的预测能力,提高模型的可靠性。

2.2 数据处理

通过 VMD 方法降低原始变形数据的复杂度,

借助样本熵对 VMD 方法分解的模态数 K 进行选择。以 2 号测点为例,经计算 2 号测点原始变形数据的样本熵为 0.515,不同 K 值对应的子序列样本熵如表 1 所示。

表 1 不同 K 值对应的子序列样本熵

K	子序列 1	子序列 2	子序列 3	子序列 4	子序列 5	子序列 6
2	0.256	1.086				
3	0.247	1.038	1.004			
4	0.147	0.238	0.731	1.229		
5	0.187	0.235	0.670	0.972	1.100	
6	0.089	0.232	0.616	0.679	0.721	0.797

$K=4$ 时高频子序列(子序列 4)样本熵达到最大值; $K>4$ 时,子序列 4 和 5 样本熵过于接近,子序列的样本熵最大值减少。出现该结果是由于过分解出现了模态重叠的现象,并且造成高频随机分量丢失原本的特征信息。因此,为保证分解得到的子序列的可靠度和真实性,确定分解的模态数 K 为 4。其余参数设置为:惩罚因子 $\alpha=2\,000$,噪声容忍度 $\tau=0.01$,收敛判据 $r=10^{-6}$ 。3 号测点采用相同方法进行计算,得到分解的模态数 $K=4$ 。2 号和 3 号测点危岩体变形数据 VMD 分解后的结果分别如图 2 和图 3 所示。




图 2 2 号测点变形值 VMD 分解结果




图3 3号测点变形值 VMD 分解结果

观察图 2 和图 3 的 2 号和 3 号测点变形值 VMD 分解结果,其中子序列 1 主要反映了危岩体变形的长期变化趋势,前期危岩体变形速率较大且变形持续增加,中后期变形仍有一定波动,但变形值增加量相较于前期有所下降。子序列 2 主要反映了危岩体变形的波动特性,受季节性温度变化影响,具有较强的周期性。相较于 2 号测点,3 号测点分解得到的各子序列数据波动性更为明显。

表 2 各子序列影响因子重要度计算结果

影响因子	子序列 1		子序列 2		子序列 3		子序列 4	
	2 号测点	3 号测点	2 号测点	3 号测点	2 号测点	3 号测点	2 号测点	3 号测点
x_1	1.0×10^{-4}	7.0×10^{-4}	1.0×10^{-3}	6.0×10^{-4}	5.7×10^{-2}	1.0×10^{-1}	1.1×10^{-1}	1.1×10^{-1}
x_2	2.0×10^{-4}	1.0×10^{-3}	1.0×10^{-3}	2.0×10^{-4}	1.2×10^{-1}	8.0×10^{-2}	7.8×10^{-2}	1.2×10^{-1}
x_3	1.0×10^{-4}	1.0×10^{-3}	1.0×10^{-3}	6.0×10^{-3}	9.0×10^{-2}	1.4×10^{-1}	1.1×10^{-1}	9.9×10^{-2}
x_4	6.0×10^{-4}	2.0×10^{-4}	4.0×10^{-3}	4.0×10^{-3}	1.1×10^{-1}	1.2×10^{-1}	1.1×10^{-1}	1.2×10^{-1}
x_5	6.0×10^{-4}	9.2×10^{-2}	2.0×10^{-3}	2.0×10^{-4}	1.3×10^{-1}	8.7×10^{-2}	8.2×10^{-2}	1.2×10^{-1}
x_6	9.2×10^{-2}	2.0×10^{-3}	8.0×10^{-3}	1.0×10^{-2}	7.8×10^{-2}	1.3×10^{-1}	9.6×10^{-2}	9.9×10^{-2}
x_7	4.0×10^{-4}	2.0×10^{-3}	6.4×10^{-1}	5.5×10^{-1}	7.5×10^{-2}	3.5×10^{-2}	1.1×10^{-1}	5.9×10^{-2}
x_8	3.0×10^{-4}	3.0×10^{-3}	8.0×10^{-3}	4.0×10^{-3}	1.1×10^{-1}	4.4×10^{-2}	1.1×10^{-1}	8.0×10^{-2}
x_9	4.0×10^{-4}	2.0×10^{-3}	2.0×10^{-1}	2.9×10^{-1}	7.7×10^{-2}	1.1×10^{-1}	6.7×10^{-2}	6.9×10^{-2}
x_{10}	4.0×10^{-4}	2.0×10^{-3}	7.0×10^{-3}	1.0×10^{-3}	9.2×10^{-2}	9.4×10^{-2}	7.5×10^{-2}	6.0×10^{-2}
x_{11}	9.0×10^{-1}	8.9×10^{-1}	1.2×10^{-1}	1.2×10^{-1}	5.3×10^{-2}	5.0×10^{-2}	4.6×10^{-2}	5.0×10^{-2}
x_{12}	1.9×10^{-2}	1.5×10^{-2}	5.0×10^{-3}	9.0×10^{-3}	1.0×10^{-2}	1.1×10^{-2}	1.2×10^{-2}	1.0×10^{-2}

由图 2 和图 3 可以看出,不同的子序列受某种因子或多种因子耦合影响体现出不同的特征信息。通过 XGBoost 算法分别计算筛选出对各子序列重要度较大、相关性较强的影响因子,对数据进行特征降维。其中主要参数为:树的最大深度为 10,学习率为 0.15,迭代次数为 150。各子序列影响因子的重要度计算结果如表 2 所示。由表 2 可以看出,2 号测点的子序列 1 中重要度最大的影响因子为 x_{11} ,其次为 x_6 ;3 号测点的子序列 1 中重要度最大的影响因子为 x_{11} ,其次为 x_5 ;2 号和 3 号测点的子序列 2 中重要度最大的影响因子为 x_7 ,其次为 x_9 ,再次为 x_{11} 。两个测点的子序列 1 和 2 中影响因子的重要度均存在较大差距,故选取重要度明显大于其他因子的影响因子作为输入变量。而两个测点的子序列 3 和 4 中各影响因子的重要度较为接近,综合考虑计算复杂度和预测结果精度,选取重要度大于 0.1 的影响因子作为模型的输入。各子序列筛选后的影响因子如表 3 所示。

2.3 结果分析

将 VMD 方法分解得到的子序列和 XGBoost 算法筛选出的影响因子输入 GRU 深度门控网络进行训练,最后把 4 个预测序列分量累加得到完整的危岩体变形数据。采用 VMD-XGBoost-GRU 组合模型对危岩体变形数据进行预测,结果如图 4 所示。由图 4 可以看出,对于 2 号和 3 号测点,本文提出的 VMD-XGBoost-GRU 组合模型在整个测试集上均有较好的预测性能,变形的预测值与实测值之间的误差较小。为进一步评估本文所提出的 VMD-XGBoost-GRU 组合预测模型应用于危岩体变形预测的性能优劣,将其与 BP、GRU 和 VMD-XGBoost-BP 3 种模型进行对比。选取 MAE 和 RMSE 两个指标进行性能评估,结果见表 4。4 种预测模型得到的实测值与预测值的对比情况如图 5 所示。

表 3 各子序列筛选后的影响因子

子序列	2 号测点	3 号测点
1	x_6, x_{11}	x_5, x_{11}
2	x_7, x_9, x_{11}	x_7, x_9, x_{11}
3	x_2, x_4, x_5, x_8	x_1, x_3, x_4, x_6, x_9
4	x_1, x_3, x_4, x_7, x_8	x_1, x_2, x_4, x_5




图 4 VMD-XGBoost-GRU 组合模型预测结果

表 4 4 种模型预测性能对比

预测模型	MAE		RMSE	
	2 号测点	3 号测点	2 号测点	3 号测点
BP	0.078	0.102	0.094	0.116
GRU	0.072	0.078	0.083	0.099
VMD-XGBoost-BP	0.073	0.082	0.088	0.113
VMD-XGBoost-GRU	0.067	0.073	0.083	0.093




图 5 4 种模型实测值和预测值对比

从表 4 和图 5 可以看出,VMD-XGBoost-GRU 组合模型能够较好地对危岩体 2 号和 3 号测点变形数

据进行预测,在 4 种模型中精度最高,从而验证了模型的可行性。与 2 号测点结果相比,3 号测点分解得到的各子序列数据波动性更为明显,故 3 号测点的预测误差也相对较大。从表 3 可知,2 号和 3 号测点的预测结果都表明 BP 和 GRU 模型结合 VMD 方法和 XGBoost 算法之后预测效果均有所提升。若模型有较多输入的影响因子,不同影响因子之间可能存在多重相关性,冗余信息较多,进而影响预测精度。VMD-XGBoost-GRU 模型在预测前对数据进行处理加工,能够更好挖掘数据的内在信息,进而提高预测模型的精度。

3 结 语

采用 VMD 方法和 XGBoost 算法对危岩体变形数据进行前处理加工,降低了数据的复杂度和影响因子的维度,使深度学习网络的输入更加合理精炼,有助于进一步提升模型的预测精度。VMD-XGBoost-GRU 组合模型能够更好挖掘出长时间序列中的有效信息。将 VMD-XGBoost-GRU 组合模型与 BP、GRU 和 VMD-XGBoost-BP 3 种模型进行对比,结果表明该模型具有较高的精度,验证了利用本文组合模型进行变形预测的可行性,从而为危岩体的安全评价提供了一条重要途径。

参考文献:

[1] 刘开云,乔春生,滕文彦. 边坡位移非线性时间序列采用支持向量机算法的智能建模与预测研究[J]. 岩土工程学报, 2004, 26 (1): 57-61. (LIU Kaiyun, QIAO Chunsheng, TENG Wenyan. Research on non-linear time sequence intelligent model construction and prediction of slope displacement by using support vector machine algorithm[J]. Chinese Journal of Geotechnical Engineering, 2004, 26 (1): 57-61. (in Chinese))

[2] LI Yanlong, YIN Qiaogang, ZHANG Ye, et al. Deformation prediction model of concrete face rockfill dams based on an improved random forest model [J]. Water Science and Engineering, 2023, 16 (4): 390-398.

[3] 王雪红,刘晓青,陶海龙,等. 优化 BP 神经网络的位移预测模型[J]. 水利水电工程学报, 2014 (2): 38-42. (WANG Xuehong, LIU Xiaoqing, TAO Hailong, et al. A displacement prediction model based on improved particle swarm-BP neural network algorithm [J]. Hydro-Science and Engineering, 2014 (2): 38-42. (in Chinese))

[4] 向镇洋,包腾飞,白妍丽,等. 基于混合注意力机制和深度学习的大坝变形预测模型[J]. 水利水电科技进展, 2023, 43 (2): 96-101. (XIANG Zhenyang, BAO Tengfei, BAI Yanli, et al. Dam deformation prediction model based on mixed attention mechanism and deep learning [J]. Advances in Science and Technology of Water Resources,

- 2023,43(2):96-101. (in Chinese))
- [5] 张才溢,傅蜀燕,欧斌,等. 基于 APSO 和 TWSVM 的特高拱坝变形预测模型[J]. 水利水电科技进展,2023,43(4):46-51. (ZHANG Caiyi, FU Shuyan, OU Bin, et al. Deformation prediction model of ultra-high arch dams based on APSO and TWSVM [J]. Advances in Science and Technology of Water Resources,2023,43(4):46-51. (in Chinese))
- [6] 吴慧军,郭超雨,苏承国,等. 基于 EEMD-GRU-MC 的短期风功率组合预测方法[J]. 南方电网技术,2023,17(2):66-73. (WU Huijun, GUO Chaoyu, SU Chengguo, et al. Combined prediction method for short-term wind power based on EEMD-GRU-MC [J]. Southern Power System Technology,2023,17(2):66-73. (in Chinese))
- [7] 张建中,顾冲时,袁冬阳,等. 基于优化 VMD 与 GRU 的混凝土坝变形预测模型[J]. 水利水电科技进展,2023,43(5):38-44. (ZHANG Jianzhong, GU Chongshi, YUAN Dongyang, et al. Deformation prediction model of concrete dams based on optimized VMD and GRU [J]. Advances in Science and Technology of Water Resources, 2023,43(5):38-44. (in Chinese))
- [8] 李文武,石强,王凯,等. 基于变分模态分解和深度门控网络的径流预测[J]. 水力发电学报,2020,39(3):34-44. (LI Wenwu, SHI Qiang, WANG Kai, et al. Runoff prediction based on variational mode decomposition and deep gated network [J]. Journal of Hydroelectric Engineering,2020,39(3):34-44. (in Chinese))
- [9] 赵鲲鹏. 基于 EMD 分解和 ABC-RBF 模型的混凝土平板坝变形监测模型[J]. 三峡大学学报(自然科学版), 2015,37(4):29-33. (ZHAO Kunpeng. Monitoring model of concrete slab dam deformation based on EMD and ABC-RBF neural network model [J]. Journal of China Three Gorges University (Natural Sciences), 2015,37(4):29-33. (in Chinese))
- [10] 梁智,孙国强,李虎成,等. 基于 VMD 与 PSO 优化深度信念网络的短期负荷预测[J]. 电网技术,2018,42(2):598-606. (LIANG Zhi, SUN Guoqiang, LI Hucheng, et al. Short-term load forecasting based on VMD and PSO optimized deep belief network [J]. Power System Technology,2018,42(2):598-606. (in Chinese))
- [11] 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))
- [12] 刘长良,武英杰,甄成刚. 基于变分模态分解和模糊 C 均值聚类的滚动轴承故障诊断[J]. 中国电机工程学报,2015,35(13):3358-3365. (LIU Changliang, WU Yingjie, ZHEN Chenggang. Rolling bearing fault diagnosis based on variational mode decomposition and fuzzy C means clustering [J]. Proceedings of the CSEE,2015,35(13):3358-3365. (in Chinese))
- [13] 徐岩,向益锋,马天祥. 基于粒子群算法优化参数的 VMD-GRU 短期电力负荷预测模型[J]. 华北电力大学学报(自然科学版),2023,50(1):38-47. (XU Yan, XIANG Yifeng, MA Tianxiang. VMD-GRU short-term power load forecasting model based on optimized parameters of particle swarm algorithm [J]. Journal of North China Electric Power University (Natural Science Edition),2023,50(1):38-47. (in Chinese))
- [14] 程黎明,蒋敏,王东. 重力坝外观变形统计模型研究[J]. 中国农村水利水电,2012(1):151-154. (CHENG Liming, JIANG Min, WANG Dong. Research on statistical model of appearance deformation of gravity dams [J]. China Rural Water and Hydropower,2012(1):151-154. (in Chinese))
- [15] 黄耀英,何一洋,沈振中,等. 大坝监测量最佳统计模型优选方法[J]. 水利学报,2022,53(2):154-164. (HUANG Yaoying, HE Yiyang, SHEN Zhenzhong, et al. Optimization method of optimal statistical model of dam monitoring data [J]. Journal of Hydraulic Engineering, 2022,53(2):154-164. (in Chinese))
- [16] 杨杰,胡德秀,吴中如. 大坝安全监控模型因子相关性 及不确定性研究[J]. 水利学报,2004,35(12):99-105. (YANG Jie, HU Dexiu, WU Zhongru, et al. Multiple co-linearity and uncertainty of factors in dam safety monitoring model [J]. Journal of Hydraulic Engineering, 2004,35(12):99-105. (in Chinese))
- [17] 刘波,秦川,鞠平,等. 基于 XGBoost 与 Stacking 模型融合的短期母线负荷预测[J]. 电力自动化设备,2020,40(3):147-153. (LIU Bo, QIN Chuan, JU Ping, et al. Short-term bus load forecasting based on XGBoost and Stacking model fusion [J]. Electric Power Automation Equipment, 2020,40(3):147-153. (in Chinese))
- [18] 刘敬文,白金朋,王建,等. 基于 XGBoost 的初始地应力场修正反演法[J]. 水利水电科技进展,2022,42(2):101-106. (LIU Jingwen, BAI Jinpeng, WANG Jian, et al. A modified inversion method of initial geo-stress field based on XGBoost algorithm [J]. Advances in Science and Technology of Water Resources,2022,42(2):101-106. (in Chinese))
- [19] 李占山,刘兆赓. 基于 XGBoost 的特征选择算法[J]. 通信学报,2019,40(10):101-108. (LI Zhanshan, LIU Zhaoeng. Feature selection algorithm based on XGBoost [J]. Journal on Communications,2019,40(10):101-108. (in Chinese))
- [20] 王鑫,吴际,刘超,等. 基于 LSTM 循环神经网络的故障时间序列预测[J]. 北京航空航天大学学报,2018,44(4):772-784. (WANG Xin, WU Ji, LIU Chao, et al. Exploring LSTM based recurrent neural network for failure time series prediction [J]. Journal of Beijing University of Aeronautics and Astronautics,2018,44(4):772-784. (in

Chinese))

[21] 杨丽,吴雨茜,王俊丽,等. 循环神经网络研究综述[J]. 计算机应用,2018,38(增刊2):1-6. (YANG Li, WU Yuxi, WANG Junli, et al. Research on recurrent neural network[J]. Journal of Computer Applications, 2018, 38 (Sup2):1-6. (in Chinese))

[22] 王增平,赵兵,纪维佳,等. 基于 GRU-NN 模型的短期负荷预测方法[J]. 电力系统自动化,2019,43(5):53-58. (WANG Zengping, ZHAO Bing, JI Weijia, et al. Short-term load forecasting method based on GRU-NN model [J]. Automation of Electric Power Systems, 2019, 43(5): 53-58. (in Chinese))

[23] 黄永涛,刘晓青,季威,等. HCM-PSO-GRU 组合预测模型在大坝变形预测中的应用[J]. 水电能源科学,2021,39(12):120-123. (HUANG Yongtao, LIU Xiaoqing, JI Wei, et al. HCM-PSO-GRU combined prediction model and its application in dam deformation prediction [J]. Water Resources and Power, 2021, 39(12):120-123. (in Chinese))

[24] 郭敏钢,宫鹤. 基于 Tensorflow 对卷积神经网络的优化研究[J]. 计算机工程与应用,2020,56(1):158-164. (GUO Mingang, GONG He. Optimization of convolutional neural network based on Tensorflow [J]. Computer Engineering and Applications, 2020, 56(1):158-164. (in Chinese))

[25] 徐嘉远,邹磊,夏军,等. TVGM-LSTM 耦合模型及其径流模拟效果分析[J]. 水资源保护,2023,39(6):104-110. (XU Jiayuan, ZOU Lei, XIA Jun, et al. TVGM-LSTM coupling model and its runoff simulation effect analysis[J]. Water Resources Protection, 2023, 39(6): 104-110. (in Chinese))

[26] 严帅,熊新. 基于 KPCA 和 TCN-Attention 的滚动轴承退化趋势预测[J]. 电子测量技术,2022,45(15):28-34. (YAN Shuai, XIONG Xin. Prediction of rolling bearing degradation trend based on KPCA and TCN-Attention[J]. Electronic Measurement Technology, 2022, 45(15): 28-34. (in Chinese))

[27] 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))

[28] 罗玮沅,蒋亚楠,许强,等. 基于深度学习的滑坡位移时空预测[J]. 测绘学报,2022,51(10):2160-2170. (LUO Huiyuan, JIANG Yanan, XU Qiang, et al. A spatio-temporal network for landslide displacement prediction based on deep learning [J]. Acta Geodaetica et Cartographica Sinica, 2022, 51(10): 2160-2170. (in Chinese))

[29] 陈振宇,刘金波,李晨,等. 基于 LSTM 与 XGBoost 组合模型的超短期电力负荷预测[J]. 电网技术,2020,44(2):614-620. (CHEN Zhenyu, LIU Jinbo, LI Chen, et al. Ultra short-term power load forecasting based on combined LSTM-XGBoost model [J]. Power System Technology, 2020, 44(2):614-620. (in Chinese))

[30] 徐冬梅,王亚琴,王文川. 基于 VMD-TCN 的月降水量预测模型[J]. 水文,2022,42(2):13-18. (XU Dongmei, WANG Yaqin, WANG Wenchuan. Monthly precipitation prediction model based on VMD-TCN [J]. Journal of China Hydrology, 2022, 42(2):13-18. (in Chinese))

(收稿日期:2023-04-12 编辑:俞云利)

(上接第 65 页)

[11] 韩露. 明渠流条件下桥墩(群)阻水效应实验与数值研究[D]. 上海:上海交通大学,2015.

[12] 余子牛. 平面二维数值模型与桥墩壅水问题的研究[D]. 北京:清华大学,1996.

[13] 吴迪,郭维东,阴云康,等. 佛山市中心组团桥梁群对河道影响的数值分析[J]. 水利水电科技进展,2006,26(1):27-30. (WU Di, GUO Weidong, YIN Yunkang, et al. Numerical analysis of influences of bridge group to be constructed in Foshan City on river courses[J]. Advances in Science and Technology of Water Resources, 2006, 26(1):27-30. (in Chinese))

[14] 王恒山. 沙河密集桥梁群对河道行洪累积效应研究[J]. 人民长江,2016,47(21):4-8. (WANG Hengshan. Study on accumulated effect of high density bridges on flood discharge of Shahe River[J]. Yangtze River, 2016, 47(21):4-8. (in Chinese))

[15] 陈珺,于明田,邓丽华,等. 感潮河道桥梁和码头工程群对行洪累积影响[J]. 水利水电科技进展,2021,41(2):49-56. (CHEN Jun, YU Mingtian, DENG Lihua, et al. Cumulative influence of bridge and wharf engineering groups on flood propagation in tidal rivers[J]. Advances in Science and Technology of Water Resources, 2021, 41(2):49-56. (in Chinese))

[16] 江磊,芦伟宏,胡春燕,等. 码头群密度及非均匀度对近岸区洪水动力特性的影响研究[J]. 水利水电快报,2017,38(11):47-52. (JIANG Lei, LU Weihong, HU Chunyan, et al. Study on the influence of wharf group density and non-uniformity on the flood dynamic characteristics in the nearshore area [J]. Express Water Resources & Hydropower Information, 2017, 38(11):47-52. (in Chinese))

[17] 潘海静. 非淹没大尺度丁坝群对河流系统的累积效应机理研究[D]. 杭州:浙江大学,2018.

[18] 曹晓萌. 丁坝群作用尺度理论及累积效应机理研究[D]. 杭州:浙江大学,2014.

(收稿日期:2023-04-13 编辑:俞云利)