

基于混合注意力机制和深度学习的大坝变形预测模型

向镇洋^{1,2},包腾飞^{1,2,3},白妍丽⁴,宋宝钢^{1,2},王瑞婕^{1,2}

(1. 河海大学水文水资源与水利工程科学国家重点实验室,江苏南京 210098; 2. 河海大学水利水电学院,江苏南京 210098; 3. 三峡大学水利与环境学院,湖北宜昌 443002; 4. 甘肃省水利水电勘测设计研究院有限责任公司,甘肃兰州 730000)

摘要:为深度挖掘时序数据中前后信息的动态相关性,探究大坝变形的内在影响机理,有效提高模型预测精度,构建了一种基于混合注意力机制与鲸鱼优化算法(WOA)的双向门控循环网络(BiGRU)预测模型。模型利用WOA对BiGRU进行超参数寻优以有效挖掘变形数据在时间维度的深层信息,并引入融合特征注意力(FATT)和时间注意力(TATT)的混合注意力机制计算各影响因子的贡献率,使模型可视化并提高模型捕捉环境因素动态变化的能力。以某高拱坝为例,将该模型预测结果与多种常用模型预测结果进行对比分析,结果表明该模型预测精度显著提升,贡献率计算符合大坝变形研究成果,验证了模型在大坝变形预测中的优越性与合理性。

关键词:大坝变形预测;深度学习;混合注意力机制;鲸鱼优化算法

中图分类号:TV698.1

文献标志码:A

文章编号:1006-7647(2023)02-0096-06

Dam deformation prediction model based on mixed attention mechanism and deep learning//XIANG Zhenyang^{1,2}, BAO Tengfei^{1,2,3}, BAI Yanli⁴, SONG Baogang^{1,2}, WANG Ruijie^{1,2}(1. State Key Laboratory of Hydrology-Water Resources and Hydraulic Engineering, Hohai University, Nanjing 210098, China; 2. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China; 3. College of Hydraulic & Environmental Engineering, China Three Gorges University, Yichang 443002, China; 4. Gansu Water Resources and Hydropower Survey and Design Research Institute Co., Ltd., Lanzhou 730000, China)

Abstract: In order to deeply mine the dynamic correlation between the front and back information in the time series data, explore the internal influence mechanism of dam deformation, and effectively improve the prediction accuracy of the model, a bidirectional gated recurrent unit (BiGRU) prediction model based on mixed attention mechanism and whale optimization algorithm (WOA) was constructed. WOA was used to optimize the hyperparameters of BiGRU to effectively mine the deep information of deformation data in the time dimension. A mixed attention mechanism that combines factor attention mechanism (FATT) and temporal attention mechanism (TATT) was introduced to calculate the contribution rate of each impact factor, so as to visualize the model and improve the ability to capture the dynamic changes of environmental factors. Taking a high arch dam as an example, the prediction results of this model were compared with those of various commonly used models. The results show that the prediction accuracy of this model is significantly improved, and the calculation of contribution rate is in line with the research results of dam deformation, which verifies the superiority and rationality of the model in dam deformation prediction.

Key words: dam deformation prediction; deep learning; mixed attention mechanism; whale optimization algorithm

大坝是我国国民经济发展的重要组成部分,在防洪、发电等领域发挥着巨大作用^[1],据统计,我国约有9.8万座大坝正在服役,其中,混凝土坝占我国200 m以上大坝的56%^[2]。大坝运行期间受到来自内外因素的复杂荷载作用,一旦溃决将产生无法预估的损失,然而,大多数的坝体结构破坏是一个长期

的动态渐进过程,这使得通过原型观测数据构建监控模型成为大坝安全评估的重要方法。作为最直观可靠的监测数据,变形是判断大坝安全的重要依据。因此,利用历史监测数据建立大坝变形预测模型具有重要意义。

目前,大坝变形预测模型主要分为以统计模型

基金项目:国家重点研发计划(2018YFC1508603);国家自然科学基金重点项目(51739003);浙江省水利水电勘测设计院有限责任公司科技业项目(B2013)

作者简介:向镇洋(1998—),男,硕士研究生,主要从事水工结构安全监控研究。E-mail: xiang_zy@hhu.edu.cn

通信作者:包腾飞(1974—),男,教授,博士,主要从事水工结构及岩土工程安全监控研究。E-mail: baotf@hhu.edu.cn

为代表的常规模型和浅层机器学习模型。多元线性回归 (multivariable linear regression model, MLR) 模型因其结构简单、计算效率高而被广泛应用于实际工程中。例如:Willm 等^[3]提出了一种静水-季节-时间变形预测模型并得到了广泛应用;Penot 等^[4]根据实际气温和周期函数的差异对热力效应进行修正,提出了静水-季节-时间-热力模型。随着计算机理论与技术的发展,浅层机器学习逐渐被应用于大坝变形预测的研究中。例如:徐韧等^[5]建立了基于极端梯度提升 (extreme gradient boosting, XGBoost) 和高斯过程 (Gaussian process, GP) 的大坝变形预测模型;胡德秀等^[6]将稳健估计极限学习机应用于变形监测中,解决了传统模型抗粗差能力弱等问题;Cao 等^[7]提出了一种基于极限学习机的变形预测混合模型,成功解决了大坝变形的波动特征,提高了模型的预测能力。浅层机器学习具有强大的自适应学习能力和非线性映射能力,极大地提高了预测模型的精度,然而浅层机器学习模型未考虑大坝变形的渐进性特征,缺乏对时间维度相关性的关注,泛化能力低,模型预测稳定性较差^[8]。为了改善浅层机器学习模型的局限性,以循环神经网络 (recurrent neural network, RNN) 和长短期记忆 (long short-term memory, LSTM) 网络为代表的深度学习模型开始得到应用。例如:欧斌等^[9]提出了基于 LSTM 网络的混凝土坝变形预测模型;Li 等^[10]结合周期趋势分解法 (seasonal and trend decomposition using loess, STL)、极限树和叠加 LSTM 网络进行了变形预测;侯回位等^[11]利用集合经验模态分解 (ensemble empirical mode decomposition, EEMD) 以及样本熵 (sample entropy, SE) 对变形数据进行分解重构,建立了 LSTM 大坝变形预测模型;Shu 等^[12]基于变分自编码器 (variational auto-encoders, VAE) 与时间注意力 LSTM 网络建立大坝长期变形预测模型,提高了模型的稳定性和有效性。现有模型极大地提升了变形预测精度,为大坝安全监控理论的发展作出了巨大的贡献,但仍存在诸多局限性:①浅层机器学习模型普遍存在泛化能力低、信息挖掘能力弱的缺陷,RNN 模型存在长期依赖、梯度爆炸问题,而 LSTM 模型结构较复杂,在面对大量时序数据时处理速度较慢;②模型超参数众多且对模型拟合程度、预测能力和计算速度具有较大的影响;③现有深度学习模型仅考虑了历史信息,无法兼顾输入信息前后的共同特征;④现有模型大多为黑箱模型,不具备解释模型中大坝变形与输入特征因子以及时间步之间的具体关联能力,同时也不具备适应外部环境因素动态变化的能力。

针对上述模型的不足,本文提出一种基于混合

注意力机制和鲸鱼优化算法 (whale optimization algorithm, WOA) 的双向门控循环网络 (bidirectional gated recurrent unit, BiGRU) 大坝变形预测模型 (以下简称“本文模型”)。为充分挖掘大坝变形时序数据在时间维度的前后关联性且简化模型结构,将 BiGRU 作为基础模型,采用 WOA 对 BiGRU 模型的超参数进行自动寻优,最后采用结合特征注意力 (FATT) 和时间注意力 (TATT) 的混合注意力机制以充分提高模型的可解释性与预测精度。以某混凝土拱坝变形监测数据为例,利用所建立的模型进行预测,并与门控循环网络 (gate recurrent unit, GRU) 模型、BP 网络模型、MLR 模型进行对比研究,以验证本文所建立的模型的有效性。

1 模型构建

1.1 BiGRU 模型

水工建筑物原型观测的实测数据实质上是一个复杂的非线性、非平稳的时间序列数据^[13],RNN 模型的提出有效解决了浅层机器学习模型无法挖掘时序数据内部关联的缺陷,借助循环模块引入了时序概念。LSTM 模型^[14]是一种改进的 RNN 模型,由遗忘门、输入门和输出门组成,通过门控函数的引入,有效解决了传统 RNN 模型中普遍存在的长期依赖、梯度爆炸和消失问题,通过长期的研究,其在大坝安全监控上的有效利用和在较长时序数据预测时的良好性能得到了验证。GRU 模型^[15]与 LSTM 模型具有相似的基础原理和同样出色的使用效果,同样使用门控机制控制输入、记忆等信息,但在结构上将 LSTM 遗忘门和输入门合并为更新门^[16],仅包含更新门和重置门两个门,更新门将上一时间步的信息与当前时间步的输入向量整合在当前隐藏状态中,重置门对上一时刻隐藏状态中的信息进行选择遗忘,与 LSTM 相比,具有超参数较少、结构简单、计算速度快等显著优点,被视为 LSTM 模型的改进。

GRU 模型为从前往后单向传输模式,通常用于解决单一状态变量问题,BiGRU 模型^[17]由传播方向相反的两个 GRU 模型共同组成,输出层数据由两层 GRU 共同决定,适用于解决多因素复杂条件问题。大坝变形受到多种因素及外部环境条件干扰影响,为充分挖掘大坝变形时序数据内的信息,本文采用 BiGRU 模型。

1.2 BiGRU 模型的 WOA 优化方法

当用 BiGRU 模型进行大坝变形预测时,其超参数较多且超参数的选择显著影响了模型精度和收敛速度,为避免手动调参带来的精度下降、效率降低等问题,本文采用 WOA 对 BiGRU 模型进行参数寻优。

WOA 是由 Mirjalili 等^[18]于 2016 年提出的一种模拟座头鲸捕食行为的群体智能优化算法,其主要受到座头鲸种群利用螺旋式上升的泡泡围住猎物的启发^[19]。本文将鲸鱼个体作为优化策略,鲸鱼位置维数作为模型待优化参数数量,在不断的位置更新下获得模型的最优参数组合,具有操作简单、搜索能力强、能够跳出局部最优、收敛速度快等显著优点。WOA 主要包括包围猎物、捕食行为和搜索行为 3 个流程^[20]。

1.3 混合注意力机制的应用

注意力机制是受到人类大脑注意力机制的启发,当人类观察一个环境场景时,大脑往往将确定诸多重点并着重关注,而减少甚至忽略其他不重要的环境信息^[21]。Mnih 等^[22]首次将注意力机制应用于 RNN 中并实现了图像分类,随后其被广泛应用于图像处理、自然语言处理、数据预测等领域。其基本思想是从大量信息中提取有效信息并通过组合函数判断各关键输入对输出结果的影响,根据信息重要性赋予不同的权重,其自适应分配机制在预测模型优化中具有显著优势,增强了模型捕捉环境因子动态变化的能力,提高了预测精度,同时使黑箱模型可视化,提高模型的可解释性。本文构建了将时间注意力机制和特征注意力机制混叠的混合注意力机制,其结构如图 1 所示,根据模型构建的两个 GRU 模块,在第一模块中引入特征注意力机制对输入变量 x_i 进行编码,得到经特征权重分配后的输入因子 h_i 并导入第二模块,在第二模块的解码阶段,引入时间注意力机制,将解码输出的隐藏状态与 softmax 函数导出的时间步权重矩阵结合,最终通过全连接层进行输出。在大坝变形预测中,各影响因子的权重显著影响了预测模型的准确性,随着权重分布的不断更新,模型逐渐接近最佳精度,可以认为此时权重分配达到最科学合理的状态,则该机制在增强模型性能的同时,获得的各因子权重可作为大坝变形影响机理分析的依据。

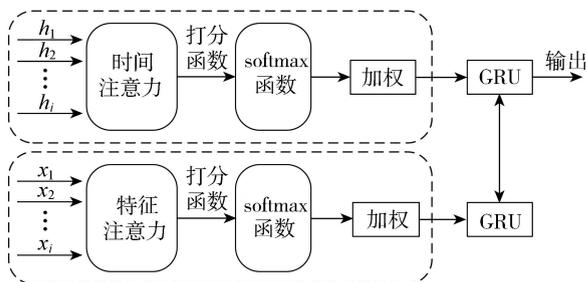


图 1 混合注意力机制结构

1.4 建模流程

采用融合特征维度注意力和时间维度注意力的混合注意力机制,结合 WOA 和 BiGRU 的优点,构建

了本文模型,其流程如图 2 所示,主要包含以下 3 个方面:

a. 原始数据获取与预处理。将获得的原始观测数据进行缺值插补、异常值检测后进行归一化并按照确定比例划分训练集和测试集。

b. 模型构建与训练。将训练集导入模型,通过 WOA 确定超参数并对模型进行训练,利用混合注意力机制分配权重并导出权重矩阵。

c. 模型预测与分析。利用所训练模型对测试集进行预测,对预测结果反归一化并进行预测性能以及影响机制分析。

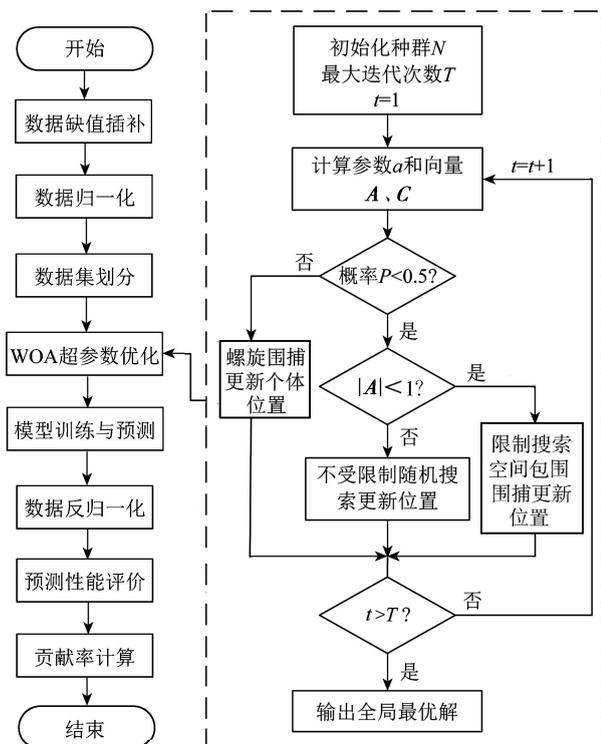


图 2 组合预测模型建模流程

为评价模型预测精度,采用决定系数 (R^2)、均方根误差 (RMSE)、平均绝对误差 (MAE) 3 项指标进行综合判别。

2 模型验证

2.1 工程背景

以西南某混凝土高拱坝为例进行模型验证。该坝为雅砻江控制性工程,属 I 等大(1)型工程,坝顶高程 1885 m,最大坝高 305 m,总装机容量 3 600 MW,总库容 77.6 亿 m^3 ,共 26 个坝段。该坝坝体混凝土于 2009 年 10 月 23 日开始浇筑,2013 年 8 月 30 日首批机组发电,2013 年 12 月 23 日全线浇筑到顶,水库正常蓄水位 1880 m,死水位 1 800 m,校核洪水位 1 882.6 m,2014 年 8 月 24 日首次蓄水至正常蓄水位,之后在死水位与正常蓄水位之间呈年周期变化。

该拱坝坝体及基础共布置 10 组正、倒垂线,其中左右岸坝基、垫座各布置 1 组,5 号、9 号、11 号、13 号、16 号、19 号及 23 号坝段各布置 1 组,共有正垂线 40 条、倒垂线 13 条,其测点布置如图 3 所示,图中,PL 为测点编号。本文选用 2014 年 7 月 25 日至 2018 年 12 月 31 日 PL9-1 测点共 1621 组监测数据建立预测模型,取前 1381 组数据为训练集,后 240 组数据为测试集。选用时间段内水位变化过程线及 PL9-1 测点实测变形变化过程线如图 4 所示。

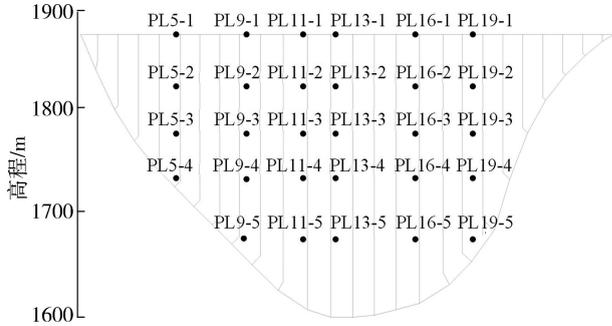


图 3 某拱坝测点布置

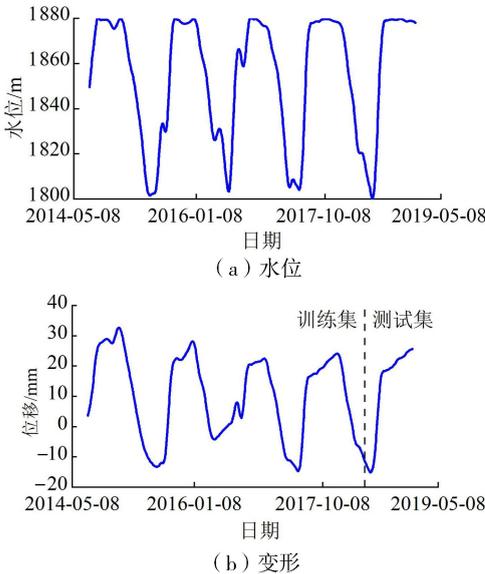


图 4 某拱坝水位和实测变形变化过程线

2.2 数据预处理

根据坝工原理^[13],大坝任一点的位移受到水压力、温度荷载等多种因素作用,按其成因可分为水压分量 δ_H 、温度分量 δ_T 以及时效分量 δ_θ :

$$\delta = \delta_H + \delta_T + \delta_\theta \quad (1)$$

其中

$$\delta_H = \sum_{i=1}^4 a_i (H^i - H_0^i)$$

$$\delta_T = \sum_{i=1}^2 \left[b_{1i} \left(\sin \frac{2\pi it}{365} - \sin \frac{2\pi it_0}{365} \right) \right] +$$

$$\sum_{i=1}^2 \left[b_{2i} \left(\cos \frac{2\pi it}{365} - \cos \frac{2\pi it_0}{365} \right) \right]$$

$$\delta_\theta = c_1 (\theta - \theta_0) + c_2 (\ln \theta - \ln \theta_0)$$

$$\theta = t/100 \quad \theta_0 = t_0/100$$

式中: a_i 、 b_{1i} 、 b_{2i} 、 c_1 、 c_2 为各分量回归系数; H_0 为建模初始日水深; H 为观测日坝前水深; t_0 为始测日到建模初始日累计天数; t 为始测日到观测日累计天数。

综上所述,模型初始输入变量共 10 个,即 H 、 H^2 、 H^3 、 H^4 、 $\sin \frac{2\pi t}{365}$ 、 $\cos \frac{2\pi t}{365}$ 、 $\sin \frac{4\pi t}{365}$ 、 $\cos \frac{4\pi t}{365}$ 、 θ 、 $\ln \theta$ 。对于缺失的数据,采用线性插值进行补充,数据整理后将输入变量及实测数据进行归一化处理并划分训练集和测试集。

2.3 模型训练与预测分析

2.3.1 模型参数确定

本文采用 WOA 对模型训练率、训练次数、最大批数、神经元数量 U_1 和 U_2 、全连接层神经元数量共 6 个参数进行自动寻优,寻优范围分别为 $[0.001, 0.01]$ 、 $[100, 300]$ 、 $[16, 128]$ 、 $[1, 300]$ 、 $[1, 300]$ 和 $[1, 100]$,寻优结果分别为 0.0021、271、92、212、153 和 23。

模型内部参数采用 Adam 函数进行优化,激活函数采用 Relu 函数,选择均方误差 (MSE) 作为损失函数,为防止过拟合,设置舍弃层并取为 0.25。

2.3.2 预测结果分析与评价

运用本文模型对 PL9-1 测点进行训练与预测,预测结果如图 5 所示,可以看出本文模型预测值与实测值拟合程度较高,分布规律基本一致,预测性能良好,稳定性高,鲁棒性强,其预测值基本落在 95% 预测区间。

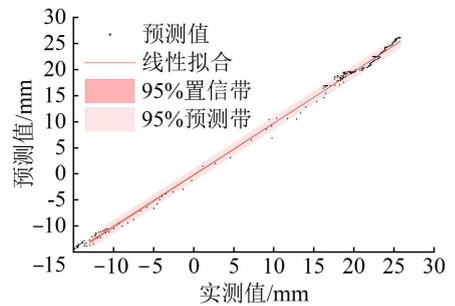


图 5 本文模型预测结果

为验证本文模型的适用程度,与 GRU 模型、BP 模型、MLR 模型进行对比验证,对比结果如图 6 所示。可以看出与 BP 模型和 MLR 模型相比,本文模型和 GRU 模型在预测性能上具有显著的优越性,特别是在拐点和极值点上具有更好的拟合效果,这说明深度学习与浅层机器学习相比,在大坝变形时序数据的预测上能更好地把控环境状态的改变和大坝结构响应的动态特征;与 GRU 模型相比,本文模型拟合程度更高、误差更小,特别是在极值点、变形波动点上更符合实测数据的变化趋势,这表明模型融

合注意力机制后能更好地获取变形量与复杂环境影响因子之间的非线性关系,显著提高局部特征的信息挖掘能力。

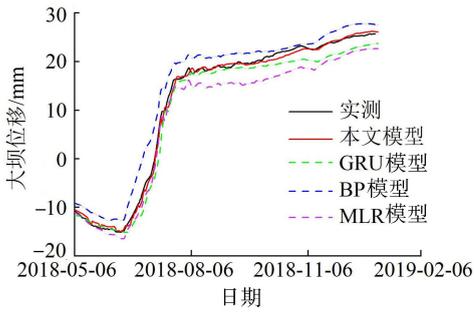


图6 不同模型变形预测结果对比

根据前文拟定评价指标进行计算,结果如表1所示,与其他3种模型相比,本文模型RMSE分别降低了59.61%、73.79%、74.17%,MAE分别降低了59.32%、74.41%、76.05%,图7为各模型残差箱线图,可以看出,本文模型残差波动范围小、均值位于零值附近,整体在零值附近呈现正态分布,综合来看,本文模型预测精度更高、误差更小,具有更强的预测稳定性。

表1 评价指标汇总

模型	R^2	RMSE	MAE
本文模型	0.9980	0.0391	0.0325
GRU模型	0.9820	0.0968	0.0799
BP模型	0.9572	0.1492	0.1270
MLR模型	0.9559	0.1514	0.1357

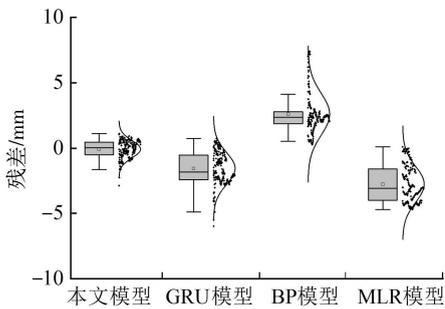


图7 不同模型残差箱线图

2.3.3 影响机制分析

本文引入特征注意力和时间注意力机制,根据计算结果导出权重。根据所得特征注意力权重,将水压分量、温度分量、时效分量分别叠加,温度分量占比48.1%,水压分量占比32.1%,时效分量占比19.8%,可以得出以下结论:①时间步权重逐渐上升,即越接近预测时间,信息所产生的影响越大,最近两步对大坝变形产生的影响超过40%;②在影响大坝变形的因素中,温度分量占比最大,时效分量占比最小,这与之前的相关研究成果一致^[23],进一步证明了本文模型的物理合理性。

3 结语

大坝变形监测研究是大坝安全运行的重要保障,本文针对以往模型中无法充分挖掘大坝变形时序数据的信息、不具备可解释性等问题,提出了基于混合注意力机制和WOA-BiGRU的组合模型。引入BiGRU模型并通过WOA优化模型超参数,兼顾了输入信息的前后关联性,显著提高了模型非线性时序数据的信息挖掘能力,有效解决了模型人工调参的困难,增强了可操作性,提高了模型精度与稳定性。引入混合注意力机制将时间权重和特征权重动态分配,使模型具有适应外部环境因素动态变化的能力,兼具高精度和强解释性的特点。以实际工程为例,对比多种常用预测模型,验证了本模型在大坝变形预测中的可行性与有效性。分析所得权重表明,越接近预测日期,信息重要程度越高;温度效应对大坝变形产生显著影响,水压效应次之,时效影响最小,符合该坝实际情况。

参考文献:

- [1] 吴中如,陈波. 大坝变形监控模型发展回眸[J]. 现代测绘,2016,39(5):1-3. (WU Zhongru, CHEN Bo. A review on development of dam safety monitoring models [J]. Modern Surveying and Mapping, 2016, 39(5): 1-3. (in Chinese))
- [2] JIA Jinsheng. A technical review of hydro-project development in China[J]. Engineering, 2016, 2(3): 302-312.
- [3] WILLM G, BEAUJOINT N. Les méthodes de surveillance des barrages au service de la production hydraulique d'Electricité de France-problèmes anciens et solutions nouvelles[C]//International Commission on Large Dams (ICOLD), 9th Congress on Large Dams. Istanbul: ICOLD, 1967: 529-550. (in French)
- [4] PENOT I, FABRE J, DAUMAS B. Monitoring behaviour [J]. International Water Power & Dam Construction, 2005, 57(12): 24-27.
- [5] 徐初,苏怀智,杨立夫. 基于GP-XGBoost的大坝变形预测模型[J]. 水利水电科技进展, 2021, 41(5): 41-46. (XU Ren, SU Huaizhi, YANG Lifu. Dam deformation prediction model based on GP-XGBoost [J]. Advances in Science and Technology of Water Resources, 2021, 41(5): 41-46. (in Chinese))
- [6] 胡德秀,屈旭东,杨杰,等. 基于M-ELM的大坝变形安全监控模型[J]. 水利水电科技进展, 2019, 39(3): 75-80. (HU Dexiu, QU Xudong, YANG Jie, et al. A safety monitoring model of dam deformation based on M-ELM [J]. Advances in Science and Technology of Water

- Resources,2019,39(3):75-80. (in Chinese))
- [7] CAO Enhua, BAO Tengfei, GU Chongshi, et al. A novel hybrid decomposition-ensemble prediction model for dam deformation[J]. Applied Sciences,2020,10(16):5700.
- [8] LI Yangtao, BAO Tengfei, GAO Zhixin, et al. A new dam structural response estimation paradigm powered by deep learning and transfer learning techniques [J]. Structural Health Monitoring,2022,21(3):770-787.
- [9] 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))
- [10] LI Yangtao, BAO Tengfei, GONG Jian, et al. The prediction of dam displacement time series using STL, extra-trees, and stacked LSTM neural network [J]. IEEE Access,2020,8:94440-94452.
- [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] SHU Xiaosong, BAO Tengfei, LI Yangtao, et al. VAE-TALSTM: a temporal attention and variational autoencoder-based long short-term memory framework for dam displacement prediction [J]. Engineering with Computers, 2022,38(4):3497-3512.
- [13] 吴中如. 水工建筑物安全监控理论及其应用 [M]. 北京:高等教育出版社,2003.
- [14] GRAVES A. Long short-term memory [M] // GRAVES A. Supervised sequence labelling with recurrent neural networks. Berlin:Springer,2012:37-45.
- [15] CHO K, VAN MERRIËNBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [C] // Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. Doha: ACL, 2014: 1724-1734.
- [16] 赵明,董翠翠,董乔雪,等. 基于 BiGRU 的番茄病虫害问答系统问句分类研究 [J]. 农业机械学报,2018,49(5):271-276. (ZHAO Ming, DONG Cuicui, DONG Qiaoxue, et al. Question classification of tomato pests and diseases question answering system based on BiGRU [J]. Transactions of the Chinese Society for Agricultural Machinery,2018,49(5):271-276. (in Chinese))
- [17] 耿浩,孙佳华,李艺,等. 基于 BiGRU-Attention 网络的新型冠状病毒肺炎疫情预测 [J]. 武汉科技大学学报,2022,45(1):75-80. (GENG Hao, SUN Jiahua, LI Yi, et al. Prediction of COVID-19 epidemic based on BiGRU-Attention network [J]. Journal of Wuhan University of Science and Technology, 2022, 45 (1) : 75-80. (in Chinese))
- [18] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software,2016,95:51-67.
- [19] 苏鹏飞,徐松毅,于晓磊. 基于 WOA-LSTM 的窄带通信网络时延预测算法 [J]. 河北工业科技,2022,39(1):9-15. (SU Pengfei, XU Songyi, YU Xiaolei. Network delay prediction algorithm based on WOA-LSTM for narrowband communication networks [J]. Hebei Journal of Industrial Science and Technology,2022,39(1):9-15. (in Chinese))
- [20] 牛培峰,吴志良,马云鹏,等. 基于鲸鱼优化算法的汽轮机热耗率模型预测 [J]. 化工学报,2017,68(3):1049-1057. (NIU Peifeng, WU Zhiliang, MA Yunpeng, et al. Prediction of steam turbine heat consumption rate based on whale optimization algorithm [J]. CIESC Journal,2017,68(3):1049-1057. (in Chinese))
- [21] 任欢,王旭光. 注意力机制综述 [J]. 计算机应用,2021,41(增刊1):1-6. (REN Huan, WANG Xuguang. Review of attention mechanism [J]. Journal of Computer Applications,2021,41(Sup1):1-6. (in Chinese))
- [22] MNIH V, HEES N, GRAVES A, et al. Recurrent models of visual attention [C] // Proceedings of the 27th International Conference on Neural Information Processing Systems. Montreal: ACM,2014:2204-2212.
- [23] REN Qiubing, LI Mingchao, LI Heng, et al. A novel deep learning prediction model for concrete dam displacements using interpretable mixed attention mechanism [J]. Advanced Engineering Informatics,2021,50:101407.

(收稿日期:2022-05-19 编辑:俞云利)

