

基于 Inception 模块与改进 GRU 的混凝土坝变形预测模型

宋 蕾¹, 雷兆星²

(1. 南昌工学院建筑与环境工程学院, 江西 南昌 330108; 2. 南昌大学工程建设学院, 江西 南昌 330031)

摘要:针对现有基于经典线性回归方法或浅层机器学习技术的混凝土坝变形预测模型在提取环境量因子复杂特征与学习变形-环境量长期依赖关系上的不足,提出了基于 Inception 模块与自注意力机制改进的门控循环单元(GRU)的混凝土坝变形预测模型。该模型综合运用了 Inception 模块的特征提取能力和 GRU 的长期依赖性学习能力,可从不同尺度提取大坝环境量监测序列的特征并进行大坝变形的长期预测,同时通过引入注意力机制,降低了学习多种环境因子特征时的模型过拟合风险。某特高混凝土双曲拱坝工程实例验证结果表明,该模型在典型监测点的预测性能都优于其他常用的浅层或深度学习模型,可用于混凝土坝变形预测。

关键词:混凝土坝;变形预测;深度学习;Inception 模块;门控循环单元

中图分类号:TV698.1⁺1

文献标志码:A

文章编号:1006-7647(2024)06-0100-06

Concrete dam deformation prediction model based on Inception module and improved GRU//SONG Lei¹, LEI Zhaoxing²(1. School of Civil and Environmental Engineering, Nanchang Institute of Science and Technology, Nanchang 330108, China; 2. School of Infrastructure Engineering, Nanchang University, Nanchang 330031, China)

Abstract: Existing deformation prediction models for concrete dams, which rely on classical linear regression methods or shallow machine learning techniques, have significant shortcomings in extracting complex features from environmental factors and in learning the long-term dependencies of deformation-environmental factor relationships. To address this issue, this paper proposes a deformation prediction model based on the Inception module and attention mechanism-enhanced gated recurrent unit (GRU). The proposed model effectively combines the feature extraction capabilities of the Inception module with the long-term dependency learning capabilities of GRU, enabling it to extract features from monitoring sequences of dam environmental factors across different scales and to predict the long-term deformation of the dam. Additionally, by incorporating the attention mechanism, the model reduces the risk of overfitting when learning features from multiple environmental factors. Validation results from an extra-high concrete double-curved arch dam project demonstrate that the proposed model outperforms other common shallow and deep learning models at typical monitoring points, making it suitable for concrete dam deformation prediction.

Key words: concrete dam; deformation prediction; deep learning; Inception module; gated recurrent unit

大坝是保障人民安居乐业、促进国民经济增长与维护区域稳定的重要基础设施,其安全运行对保障人民的生命财产安全具有重要意义^[1-2]。变形是最能直观反映混凝土坝综合服役性态变化的重要监测量之一^[3-7],合理的变形行为分析预测模型对定量分析环境荷载变化的影响、实时研判大坝健康态势和预测工程未来运行行为具有重要价值^[8]。

目前,多种线性回归方法和浅层机器学习方法已在数据驱动的混凝土坝变形行为分析与预测领域得到了广泛的应用^[9-10]。不同于经典的线性回归方

法,诸如极限学习机^[11]、支持向量机^[12]和多层感知机^[13]等浅层机器学习方法能有效缓解大坝变形数据中因结构的复杂性与作用荷载的随机性而产生的非线性特征的影响,从而提高大坝变形行为分析和预测模型的准确性^[14]。然而,较小的网络层数与节点数限制了这些浅层机器学习模型的拟合及预测能力。随着深度学习算法的快速发展,基于新兴深度学习算法的大坝安全监控模型成了研究热点。与浅层学习模型相比,在非线性映射和预测精度要求高的运用场景中,具备多神经元、多网络层的深度学习

模型往往展现出更好的效果^[15]。例如:陈以浩等^[16]基于卷积神经网络(convolutional neural network,CNN)和门控循环单元(gated recurrent unit,GRU)构建了应用于大坝变形预报的大坝变形组合深度学习网络;Yuan 等^[17]综合运用变分模态分解、双支持向量回归和 GRU 建立了混凝土坝变形预测模型;高治鑫等^[18]引入奇异谱分析,并使用多元线性回归-GRU 神经网络组合模型对裂缝开度进行了分析和预测;Park 等^[19]利用 CNN 拟合了大坝结构动态加速度及位移响应与结构应变之间的关系,实现了在应变监测信息不完备情况下的结构长期健康监测。此外,在监测数据特征提取方面,支持向量机、极限学习机、Logistic 回归等浅层学习算法无法自动提取训练数据的特征,其建模精度很大程度上依赖于人为设计的特征^[20]。而深度学习算法采用的是端到端学习模式,可以在多层网络结构中逐层变换输入数据,将样本转移到新的特征空间中来提取训练数据本身的深度隐式特征^[21],并利用这些特征进行预测或分类^[22]。例如:Chen 等^[23]通过二维 CNN 从测点变形值的历史时空面板序列中提取空间特征向量并与大坝变形的环境影响因子相结合,提出了基于空间特征向量的混凝土坝多测点变形预测模型;Xu 等^[24]引入图卷积神经网络从多测点监测序列中提取大坝变形响应特征,提出了基于改进灰狼优化长短时记忆(long short-term memory,LSTM)神经网络与自回归差分移动模型的大坝变形预测组合模型;欧斌等^[25]运用 CNN 提取了监测数据的空间特征并输入到双向长短时记忆网络进行特征融合与变形预测,构建了基于 CNN 和双向长短时记忆网络的大坝变形预测模型。尽管这些深度学习算法的运用有效提高了模型在非线性函数逼近、因子共线性问题处理及特征提取等方面的能力,但复杂的网络结构和有限的训练样本亦提高了模型训练时超参数调整的难度与遇到过拟合问题的风险^[26-28]。

为提取大坝变形与环境量实测数据的多尺度特征,学习环境量因子与大坝变形间的复杂非线性关系及长期依赖性,本文利用 Inception 模块的特征提取能力和 GRU 的长期依赖性学习能力,并加入通道注意力和空间注意力机制,建立了基于 Inception 模块与自注意力机制改进 GRU 的混凝土坝变形预测模型,并用某混凝土双曲拱坝对模型进行验证,以期建立更高精度的大坝变形预测模型提供借鉴。

1 模型构建

1.1 Inception 模块

Szegedy 等^[29]提出的 Inception 模块在构建深度

和宽度较大的模型时具有显著优势,能在提升深度学习网络特征提取效率与准确率的同时降低过拟合风险。Inception 模块通过将不同的卷积层以稀疏并联方式相结合,达到了对机器学习网络深度和宽度的高效扩充,从而能够通过多尺度卷积操作捕获不同尺度的特征信息并提取不同层次的输入特征。在每个 Inception 模块中,同时采用多个不同尺寸的卷积核进行特征提取,通过 Concatenate 层将不同卷积操作的输出结果并联到一起。本文在 Inception 模块前设置数据输入层,在模块中分别连接核大小为 1、3、5 的 3 种卷积层和 1 个最大池化层。值得注意的是,为减少模型参数与降低计算复杂度,分别在核大小为 3 和 5 的卷积块前加入一个核大小为 1 的卷积块来降低通道数,并将核大小为 5 的卷积改为两个核大小为 3 的卷积。这些措施能够在不降低模型精度的前提下减少模型参数,简化模型运算过程。同时,由于池化层可能会导致部分信息丢失,因而省略该网络层,最终得到的 Inception 模块结构如图 1 所示,图中 K 为网络层的卷积核大小, N 为输出通道数。




图 1 Inception 模块结构示意图

1.2 自注意力优化的 GRU 神经网络

针对循环神经网络(recurrent neural network,RNN)在处理长期依赖问题时的不足,Hochreiter 等^[30]提出了一种改进的 RNN,即 LSTM 神经网络。通过新增细胞状态和遗忘门、输入门、输出门 3 种门结构,LSTM 神经网络能够解决长序列建模过程中梯度消失和梯度爆炸的问题。GRU 的提出也是为了解决常规 RNN 梯度消失的问题,GRU 网络同样采用门控机制,但各个单元内的门结构数量缩减至重置门和更新门两种,并移除了 LSTM 神经网络中的细胞状态,减少了模型参数数量与运算所需时间。

在 GRU 网络结构中,更新门和重置门分别控制历史信息保存到当前时间步与历史信息的被遗忘程度,两种门的输出取值范围均为 $[0,1]$ 。基于当前时刻输入向量与上一时刻隐藏状态,经过重置门与

更新门计算,得到当前时刻输出的公式。

为了提高模型对 Inception 模块所提取的特征中更重要信息的关注度,在 GRU 网络中加入自注意力机制。作为注意力机制的重要分支,自注意力机制主要依靠数据内部信息进行注意力交互从而提高神经网络性能^[31]。基于自注意力机制,本文对各隐藏层的输出向量进行加权汇总并结合全连接网络实现大坝变形估计。

1.3 模型构建步骤

本文采用 Inception 模块在多个尺度上对输入数据进行卷积再聚合,提取环境因子时间序列的变化趋势与空间相关性,并利用 GRU 神经网络和注意力机制捕捉时间序列中间隔较大的依赖关系,从而构建一种基于 Inception 模块与自注意力机制改进 GRU 的混凝土坝变形预测模型。具体实现步骤如下:

步骤 1 将水位-温度-时效模型中 n 天的环境量因子组成的监测数据按滑动窗口长度分割为 $n-1$ 个输入矩阵 $X_i(i \in [1, n-1])$,将矩阵 X_i 输入到一维卷积层中,使信息跨通道组合并加入非线性特征,以避免 Inception 模块中原始序列与卷积序列无法拼接。

步骤 2 输入矩阵 X_i 到 Inception 模块中,并将输入数据在多个尺度上进行卷积与串联,从而提取出丰富的输入因子特征。

步骤 3 使用通道注意力与空间注意力机制关注重要的输入因子特征,并忽略不必要的响应。

步骤 4 将 Inception 模块中不同深度 CNN 提取的特征结果矩阵拼接并输入到 GRU 网络层中进行变形-环境量的长期依赖关系学习,同时运用自注意力机制提高网络性能。

步骤 5 将 GRU 输出量通过两层全连接层处理后输出为变形预测值。

模型构建流程如下:输入环境量因子→一维卷积处理→Inception 模块特征提取→通道注意力与空间注意力机制关注重要特征→GRU 网络层学习→自注意力机制优化→输出预测值。

2 实例验证

2.1 工程概况

某水电站拦河坝为混凝土抛物线型双曲拱坝,最大坝高 240 m,坝顶弧长 774.69 m,共由 39 个坝段组成。为监测拱冠、拱肩及 1/4 拱圈等部位的水平变形,坝体内部布置了 8 条倒垂线和 10 条正垂线,共计 20 个测点,并同时采用人工和自动化两种

方式进行监测。采用 TCN08 与 TCN09 变形测点的实测数据对本文所提出模型的预测性能进行验证,选取 2013 年 6 月 1 日至 2017 年 5 月 31 日时间段内的 1460 组监测数据作为训练集进行模型训练,并采用 2017 年 6 月 1 日至 2018 年 6 月 1 日时间段内的 366 组监测数据作为预测集对模型准确性进行检验。选定时间范围内大坝水平变形监测数据及水位变化如图 2 所示(水平变形以向下游方向为正)。




图 2 部分测点变形曲线

由图 2 可知,水位与各监测点径向变形之间存在明显的正相关性,库水位的年周期变化对该拱坝的径向变形变化有着较大影响。当库水位上升时,大坝向下游的径向变形增大;反之,向下游的径向变形减小。同时可以看出,库水位对大坝变形的影响存在一定的滞后性。此外,尽管库水位在高水位运行期保持水位稳定,各监测点径向变形仍有向下游增加的趋势。因此,采用环境因子滑动窗口序列作为大坝变形的输入因子是十分必要的。

由于水位、温度和时间这些环境变量的变化区间不同,甚至不处于同一数量级,模型训练时容易产生梯度震荡及容易达到局部最优值的现象^[32]。为此,需要对每个环境变量时间序列进行标准化处理,计算公式为

$$x' = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (1)$$

式中: x 为原始特征序列值; $x_{\min}$ 为该原始序列的最小值; $x_{\max}$ 为该原始序列的最大值; x' 为标准化处理后的特征序列值。

2.2 模型训练及性能对比分析

模型的输入向量由包括水位、温度和时效因子在内的监测序列组成。其中,水位因子为上游水位的 4 次多项式,温度因子为坝体内 45 个温度计的实测温度及外界气温,时效因子为时间的线性函数和对数函数。

在搭建基于 Inception 模块与自注意力机制改进 GRU 的混凝土坝变形预测模型(以下简称“IGRU 模型”)时,不同的隐藏层层数会导致模型的拟合精度和训练速度有着较大的差异。本文模型采用双层

GRU 网络层,并将迭代次数设置为 100。此外,在率定模型学习率,滑动窗口长度、批处理大小和 GRU 结点数这 4 个超参数时,采用经典启发式搜索方法遗传算法进行寻优处理,从而减轻人力成本并提高模型表征能力。这 4 种超参数的取值范围以及优化结果如表 1 所示。

表 1 超参数取值范围及遗传算法寻优结果		
参数名称	取值范围	优化结果
学习率	[0.001,0.1]	0.007
滑动窗口长度	[7,30]	13
批处理大小	[20,100]	32
GRU 结点数	[10,200]	60

为验证 IGRU 模型相较于现有模型的优势,将其与 LSTM、支持向量机 (support vector machine, SVM) 和极限学习机 (extreme learning machine, ELM) 这些常用模型进行对比,所有模型的输入因子及时间序列长度均相同。此外,采用均方根误差 (root mean squared error, RMSE)、平均绝对误差 (mean absolute error, MAE) 和确定系数 R^2 来定量比较上述模型的预测性能。

各模型的统计指标、变形预测结果以及残差如表 2 和图 3 所示。

模型	TCN08 测点			TCN09 测点		
	RMSE	MAE	R^2	RMSE	MAE	R^2
IGRU	1.664	1.416	0.994	1.520	1.353	0.996
LSTM	3.398	3.026	0.971	2.715	2.546	0.977
SVM	3.745	3.333	0.964	3.112	2.987	0.960
ELM	5.553	5.060	0.922	4.023	3.615	0.944

如图 3 所示,所有模型的预测值都与两个监测点的实测变形值有着一致的变化规律,即这些模型都能很好地反映大坝变形与其解释变量之间的因果关系,能够有效预测大坝变形变化趋势。但与两种基于浅层学习算法的模型,即 SVM 模型和 ELM 模型相比,采用深度学习算法构建的 LSTM 模型和 IGRU 模型具有更好的预测精度,预测结果更接近实测变形曲线,残差值亦更趋近于零。而 SVM 模型和 ELM 模型在大坝变形达到极大值和极小值时的预测结果明显偏离实际变形,残差较大。在两种深度学习模型中,IGRU 模型在预测方面表现最好,能够准确地预测大坝变形具体大小并有效捕捉变形变化过程中的微小波动,残差最小。表 2 中列出的统计指标进一步证明,IGRU 模型具有最好的预测性能,该模型在 TCN08 和 TCN09 测点的 RMSE 和 MAE 均显著小于其他 3 个模型,并具有最大的 R^2 指标,表明 IGRU 模型在逼近非线性关系和提取大坝变形深层特征方面具有明显优势。




图 3 TCN08 与 TCN09 测点不同模型预测结果及残差

3 结 语

本文提出了基于 Inception 模块和自注意力机制改进 GRU 的混凝土坝变形预测模型,该模型通过 Inception 模块深度挖掘了环境因子与变形时间序列的多尺度特征,并使用自注意力机制优化的 GRU 学习两者间的长期复杂耦合关系。工程实例验证结果

表明,相比于浅层学习模型,IGRU 模型能有效逼近大坝变形与其解释变量间复杂的非线性函数关系,从而显著提升模型的预测精度。此外,与基于 LSTM 的深度学习模型相比,引入了 Inception 模块与注意力机制的 IGRU 模型具备更强的多尺度特征提取能力,模型预测性能更好,且更不易陷入过拟合中。IGRU 模型对提升混凝土坝变形预测精度、准确掌握大坝运行状况具有借鉴意义,但相较于经典线性建模方法,采用 IGRU 建立的模型可解释性较差,仍需进一步研究使其能用于坝体变形解释。

参考文献:

[1] 王岩博,顾冲时,石立,等. 基于改进 IGG Ⅲ-ELM 法的混凝土坝变形监测数据粗差识别方法[J]. 水利水电科技进展, 2023, 43 (6): 89-95. (WANG Yanbo, GU Chongshi, SHI Li, et al. Gross error identification method for deformation monitoring data of concrete dams based on improved IGG Ⅲ-ELM method [J]. Advances in Science and Technology of Water Resources, 2023, 43 (6): 89-95. (in Chinese))

[2] 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))

[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] 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))

[5] 杨光,顾昊,刘尚蔚,等. 基于分数阶模式的高拱坝变形安全监控研究构想[J]. 水利水电科技进展, 2022, 42 (5): 85-93. (YANG Guang, GU Hao, LIU Shangwei, et al. Research proposal for deformation safety monitoring of high arch dams based on fractional-order modeling theory [J]. Advances in Science and Technology of Water Resources, 2022, 42 (5): 85-93. (in Chinese))

[6] 周兰庭,邓思源,柳志坤,等. 基于 SSA-LSTM-GF 的混凝土坝变形预测方法[J]. 河海大学学报(自然科学

版), 2023, 51 (2): 73-80. (ZHOU Lanting, DENG Siyuan, LIU Zhikun, et al. Deformation prediction method of concrete dam based on SSA-LSTM-GF [J]. Journal of Hohai University (Natural Sciences), 2023, 51 (2): 73-80. (in Chinese))

[7] 赵二峰,李章寅,袁冬阳. 基于双阶段注意力机制的大坝变形深度学习预测模型[J]. 河海大学学报(自然科学版), 2023, 51 (6): 44-52. (ZHAO Erfeng, LI Zhangyin, YUAN Dongyang. Deep learning model for deformation prediction of dam based on dual-stage attention mechanism [J]. Journal of Hohai University (Natural Sciences), 2023, 51 (6): 44-52. (in Chinese))

[8] 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))

[9] 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))

[10] 苏怀智,李家田. 在役心墙堆石坝非概率可靠度评估与预警方法[J]. 岩石力学与工程学报, 2021, 40 (12): 2526-2534. (SU Huaizhi, LI Jiatian. Non-probabilistic reliability evaluation and safety early warning method for core-wall rockfill dams in service [J]. Chinese Journal of Rock Mechanics and Engineering, 2021, 40 (12): 2526-2534. (in Chinese))

[11] 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, 54 (5): 51-63. (WEI Bowen, LUO Shaoyang, XU Fugang, et al. Combined model of displacement prediction for concrete arch dam based on decomposition and reconstruction of monitoring time series [J]. Advanced Engineering Sciences, 2022, 54 (5): 51-63. (in Chinese))

[12] 魏博文,柳波,徐富刚,等. 融合 PSO-SVM 的混凝土拱坝多测点变形监控混合模型[J]. 武汉大学学报(信息科学版), 2023, 48 (3): 396-407. (WEI Bowen, LIU Bo, XU Fugang, et al. Multi-point hybrid model based on PSO-SVM for concrete arch dam deformation monitoring [J]. Geomatics and Information Science of Wuhan University, 2023, 48 (3): 396-407. (in Chinese))

[13] OUMA Y O, MOALAFHI D B, ANDERSON G, et al. Dam water level prediction using vector AutoRegression, random forest regression and MLP-ANN models based on land-use and climate factors [J]. Sustainability, 2022, 14 (22) :

- [14] 胡越,罗东阳,花奎,等. 关于深度学习的综述与讨论[J]. 智能系统学报,2019,14(1):1-19. (HU Yue,LUO Dongyang,HUA Kui, et al. Overview on deep learning[J]. CAAI Transactions on Intelligent Systems,2019,14(1):1-19. (in Chinese))
- [15] 徐韧,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))
- [16] 陈以浩,李明伟,安小刚,等. 基于混沌云量子蝙蝠 CNN-GRU 大坝变形智能预报方法研究[J]. 哈尔滨工程大学学报,2024,45(1):110-118. (CHEN Yihao,LI Mingwei,AN Xiaogang, et al. Research on the intelligent prediction method of dam deformation based on chaotic cloud quantum bat CNN-GRU[J]. Journal of Harbin Engineering University,2024,45(1):110-118. (in Chinese))
- [17] YUAN Dongyang, GU Chongshi, WEI Bowen, et al. A high-performance displacement prediction model of concrete dams integrating signal processing and multiple machine learning techniques[J]. Applied Mathematical Modelling,2022,112:436-451.
- [18] 高治鑫,包腾飞,李扬涛. 基于 MLR-SSA-GRU 的混凝土坝裂缝开度组合预测模型[J]. 武汉大学学报(工学版),2022,55(7):647-653. (GAO Zhixin,BAO Tengfei, LI Yangtao. Hybrid prediction model of concrete dam crack opening based on MLR-SSA-GRU[J]. Engineering Journal of Wuhan University,2022,55(7):647-653. (in Chinese))
- [19] PARK H S, AN J H, PARK Y J, et al. Convolutional neural network-based safety evaluation method for structures with dynamic responses[J]. Expert Systems with Applications,2020,158:113634.
- [20] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature,2015,521(7553):436-444.
- [21] ZHONG Guoqiang, LING Xiao, WANG Lina. From shallow feature learning to deep learning: benefits from the width and depth of deep architectures[J]. WIREs Data Mining and Knowledge Discovery,2019,9(1):e1255.
- [22] BENGIO Y, COURVILLE A, VINCENT P. Representation learning: a review and new perspectives[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2013,35(8):1798-1828.
- [23] CHEN Zhuoxun, LIU Xiaosheng. Multi-point deformation prediction model for concrete dams based on spatial feature vector[J]. Applied Sciences,2023,13(20):11212.
- [24] XU Guoyan, LU Yuwei, JING Zixu, et al. IEALL: dam deformation prediction model based on combination model method[J]. Applied Sciences,2023,13(8):5160.
- [25] 欧斌,张才溢,傅蜀燕,等. 基于 CNN-BiLSTM 的特高拱坝变形预测模型[J]. 排灌机械工程学报,2024,42(10):1031-1035. (OU Bin,ZHANG Caiyi,FU Shuyan, et al. CNN-BiLSTM-based deformation prediction model for extra-high arch dams[J]. Journal of Drainage and Irrigation Machinery Engineering,2024,42(10):1031-1035. (in Chinese))
- [26] 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.
- [27] ZHAN Mingqiang, CHEN Bo, WU Zhongru. Deformation warning index for reinforced concrete dam based on structural health monitoring data and numerical simulation[J]. Water Science and Engineering,2023,16(4):408-418.
- [28] 康俊锋,胡祚晨,陈优良. 基于布谷鸟搜索算法优化 LSTM 的大坝变形预测[J]. 排灌机械工程学报,2022,40(9):902-907. (KANG Junfeng,HU Zuo Chen, CHEN Youliang. Dam deformation prediction based on optimization of LSTM by using cuckoo search algorithm[J]. Journal of Drainage and Irrigation Machinery Engineering,2022,40(9):902-907. (in Chinese))
- [29] SZEGEDY C, LIU Wei, JIA Yangqing, et al. Going deeper with convolutions[C]//Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston:IEEE,2015:1-9.
- [30] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation,1997,9(8):1735-1780.
- [31] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st Annual Conference on Neural Information Processing Systems (NIPS). Long Beach:IEEE,2017:4-9.
- [32] 陈良捷,魏博文,戴国强,等. 混凝土坝变形监测时序中异常突变值的优化诊断[J]. 水利水运工程学报,2023(4):156-164. (CHEN Liangjie, WEI Bowen, DAI Guoqiang, et al. Optimal diagnosis of abnormal mutation value in deformation monitoring sequence of concrete dam[J]. Hydro-Science and Engineering,2023(4):156-164. (in Chinese))

(收稿日期:2023-11-05 编辑:俞云利)