

耦合 GAT 和 TCN 的土石坝渗流监测数据 异常检测模型

廖攀^{1,2}, 李晓庆^{1,2}, 顾昊³, 唐新军^{1,2}

(1. 新疆农业大学水利与土木工程学院, 新疆 乌鲁木齐 830052; 2. 新疆水利工程安全与水灾害防治自治区重点实验室, 新疆 乌鲁木齐 830052; 3. 河海大学水利水电学院, 江苏 南京 210098)

摘要:针对现有土石坝渗流监测数据异常检测模型泛化能力较弱, 只能识别特定类型异常测值而导致模型检测精确率低、误报率高的问题, 提出了一种基于图注意力网络(GAT)机制和时域卷积网络(TCN)的土石坝渗流数据异常检测模型, 该模型通过 GAT 机制对环境分量分配权重, 引入 TCN 提高模型的时序特征提取能力, 以模型的预测误差作为判别异常测值的依据。以西北地区某黏土心墙坝为例, 构造了 6 类异常场景对模型进行检测验证, 结果表明该模型能有效识别出土石坝渗流异常测值, 平均 ROC-AUC 值和 PR-AUC 值分别为 0.948 和 0.968, 能满足工程实际应用需要; 与主流模型相比, 该模型具有更强的监测数据异常检测能力和更强的稳健性。

关键词:土石坝渗流; 大坝安全监测; 异常检测; 图注意力网络; 时域卷积网络

中图分类号: TV698.1

文献标志码: A

文章编号: 1006-7647(2025)06-0085-06

Anomaly detection model for seepage monitoring data of earth-rock dams based on coupled GAT and TCN//LIAO Pan^{1,2}, LI Xiaoping^{1,2}, GU Hao³, TANG Xinjun^{1,2} (1. College of Hydraulic and Civil Engineering, Xinjiang Agricultural University, Urumqi 830052, China; 2. Xinjiang Key Laboratory of Hydraulic Engineering Safety and Water Disasters Prevention, Urumqi 830052, China; 3. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China)

Abstract: Aiming at the problem that existing anomaly detection models for seepage monitoring data of earth-rock dams exhibit weak generalization capability and can only identify specific types of abnormal measurements, leading to low detection accuracy and high false-alarm rates, an anomaly detection model for earth-rock dam seepage monitoring data based on the graph attention network (GAT) mechanism and temporal convolutional network (TCN) is proposed. This model utilizes the GAT mechanism to assign weights to environmental factors, employs the TCN to improve the extraction of temporal features, and identifies abnormal data based on the model's prediction error. Taking a clay-core rockfill dam in northwest China as a case study, six anomalous scenarios were constructed to validate the model. The results show that the proposed model can accurately identify abnormal seepage measurements of earth-rock dams, with average ROC-AUC and PR-AUC values of 0.948 and 0.968, respectively, meeting the requirements of practical engineering applications. Comparative analyses with state-of-the-art anomaly detection models further confirm that the proposed model exhibits superior anomaly detection performance and robustness.

Key words: earth-rock dam seepage; dam safety monitoring; anomaly detection; graph attention network; temporal convolutional network

土石坝是我国已建大坝的主要坝型, 占比超过 90%^[1]。在土石坝的所有破坏模式中, 渗流引起内部侵蚀导致的溃坝占比高达 64%^[2]。因此, 土石坝的渗流安全监控对工程的安全预警和风险评估具有重要意义, 应准确诊断土石坝的安全性态, 识别异常

信号, 并找出潜在风险。

渗流监测序列是一组复杂的多元时空序列, 主要有以下 3 个特征: ①库水位变化是土石坝渗流场变化的主要驱动因素; ②受水库调度影响, 除了大型多年调节水库, 大部分水库的库水位变化没有固定

基金项目:国家自然科学基金黄河水科学研究联合基金(U2243223); 新疆农业大学研究生校级科研创新项目(XJAUGRI2022021)

作者简介:廖攀(1993—), 男, 硕士研究生, 主要从事水库大坝安全监测研究。E-mail: oklbuy@163.com

通信作者:李晓庆(1976—), 男, 副教授, 硕士, 主要从事水工结构及仿真与生态水工学研究。E-mail: lixq_xj@163.com

模式,进而导致渗流监测序列缺少周期性;③由于渗流滞后效应和渗流场的连续性,各测点的时空关联性极为复杂。正常工作的土石坝其渗流场在环境量作用下的响应遵循某种模式,这个模式下的监测数据内部以及与环境量之间存在时空依赖关系^[3-4]。土石坝渗流监测数据的异常检测可基于这些关系判断异常事件与异常测值的发生,进而识别出偏离预期模式的数据。

当前主流土石坝渗流监测数据异常检测方法判别数据异常的准则有两种:①是否超出数据的正常范围;②是否符合当前库水位作用下的预期渗压。基于重构^[5-6]、密度(聚类)^[7-8]和域^[9]的模型使用第一种准则,而基于预测的模型^[10-11]则使用第二种准则。采用第一种准则的模型能准确确定训练集样本的正常域,但当样本容量较小时,对训练集外样本的误报率较高。基于预测的模型分为两类:①利用监测序列自身进行预测,其泛化能力通常较差;②引入环境量(如库水位、降水量等)作为输入数据进行预测,这类模型训练误差较低,且表现出更强的泛化能力。由于土石坝渗流监测数据样本代表性不足且监测序列周期性较弱,以环境量作为解释变量的预测模型更适用于土石坝渗流监测数据的异常检测。

土石坝渗压水位主要受上游库水位、降雨及时间效应的影响,这些环境量为解释渗压水位变化提供了有用的信息。各环境量对渗压水位变化的贡献程度不一,同时大量冗余信息的输入也不利于模型的稳健性。图注意力网络^[12](graph attention network,简称GAT)能够自适应地评估不同输入特征的重要性,并据此对特征进行加权融合,从而实现关键信息筛选与数据压缩的目的,有效提高模型的预测能力。由于滞后效应的存在,渗压水位对环境量变化的响应是滞后的。因此,高阶自回归模型可用于提取历史变化过程的有用时序信息和预测渗压水位。时域卷积网络^[13](temporal convolutional network,TCN)是一维卷积用于时序问题的变体,相对于循环神经网络,兼具计算效率高和捕捉长时依赖关系能力强的特点,可以高效地提供高精度的渗压水位预测。

结合数据特征以及判别准则适用范围,考虑到渗流监测数据样本容量较小的特点,以环境量作为解释变量的基于预测的模型更适用于土石坝渗流监测数据异常检测。为此,本文提出了一种耦合GAT和TCN的土石坝渗流监测数据异常检测模型(以下简称“GAT-TCN模型”),通过GAT对初始输入特征进行选择,借助TCN保持模型对时序信息的长时记忆。工程实例验证结果表明,GAT-TCN模型相比变

分自编码器(variational autoencoder,VAE)、门控循环单元(gated recurrent unit,GRU)、单类支持向量机(one-class support vector machine,OCSVM)和奇异谱分析(singular spectrum analysis,SSA)4个主流模型有更好的监测数据异常检测能力和更强的稳健性。

1 GAT-TCN 模型

1.1 GAT 与 TCN 方法简介

土石坝渗流监测数据具有多变量、强时空关联等特点,需要在建模时兼顾不同变量的重要性及其随时间的变化规律。本文借鉴GAT和TCN的思想来提高土石坝渗流监测数据异常检测模型的精度和稳健性。其中,GAT可通过注意力机制对多种输入变量的重要程度进行自适应加权,从而筛选出对渗压水位变化影响较大的特征;TCN则通过一维卷积捕捉时间序列中的长时依赖关系,提升模型对渗流滞后效应和非平稳特性的刻画能力。二者结合,可在保证模型泛化能力的同时提高对异常测值的识别精度。

1.2 GAT-TCN 模型构建

通过耦合GAT与TCN两种方法,构建GAT-TCN模型:①对大坝上下游水位、降水、气温等多种影响变量进行预处理,利用GAT对输入变量进行权重评估并筛选出关键特征;②将筛选后的特征送入TCN模块提取时间序列特征并预测各测点的渗压水位;③通过对比预测值与实测值的偏差来识别异常测值。该模型充分利用了多源影响因素与历史监测序列之间的时空关联特性,不仅提高了渗流监测数据异常检测的准确率,也增强了对小样本情况下的鲁棒性。

1.3 异常推断

GAT-TCN模型通过分析预测残差实现对异常测值的识别。模型训练完成后,可表征土石坝在不同库水位条件下的正常渗流场响应(渗压水位)。当渗压计实测值显著偏离模型预测值时,可视为渗压计或防渗系统存在异常。假设有 K 个测点, t 时刻的异常得分为 $\sqrt{\frac{1}{K} \sum_{i=1}^K (x_{ti} - y_{ti})^2}$ (式中 x_{ti} 、 y_{ti} 分别为 t 时刻 i 测点的预测值和实测值),异常得分大于某个阈值的时刻被推断为异常发生。阈值的确定通常需要结合专业领域知识,本文使用F1分数最大时的阈值作为异常阈值。

2 监测数据异常检测步骤

GAT-TCN模型的异常检测流程如图1所示,主要包括以下4个步骤:

a. 输入变量确定与预处理。根据坝体渗流特性,选取上下游水位、降水、气温等多种环境量构建输入序列,对上下游水位、温度和降水序列进行滑动平均处理,以体现渗流滞后效应。将输入变量序列和实测渗压数据划分为训练集、验证集和测试集。

b. GAT-TCN 模型构建与参数寻优。利用 GAT 模块对输入变量进行注意力加权,筛选关键特征并形成注意力张量;将该张量输入 TCN 模块提取时间序列特征并预测渗压水位。采用训练集对模型参数进行训练学习,使用超参数优化框架通过验证集确定模型最优参数。

c. 异常得分计算。将测试集数据输入训练好的 GAT-TCN 模型,得到预测渗压水位,与实测渗压水位进行比较,计算均方根误差 (RMSE) 或绝对误差作为异常得分。

d. 异常检测。构建基于预测残差的土石坝渗流数据异常判别标准,设定异常阈值,异常得分大于异常阈值的时刻判定发生异常。




图1 GAT-TCN 模型土石坝渗流监测数据异常检测流程

3 工程实例验证

3.1 工程概况与数据集

以西北某黏土心墙坝为研究对象,该工程最大坝高为 54 m,正常蓄水位为 1330.20 m,总库容为 6560 万 m³。大坝主要监测断面的渗流监测布置见

图 2,其中心墙内 0+090.0 m 和 0+145.0 m 断面分 3 个高程(1280、1290、1305 m)各埋设 9 支渗压计(P01~P18),坝体 0+090.0 m 断面灌浆帷幕前后各埋设了 1 支渗压计(P19 和 P20,用于监测灌浆帷幕防渗效果)。选取 0+090.0 m 断面的 P01~P09 渗压计于 2012 年 8 月 11 日至 2021 年 3 月 5 日的连续监测序列为数据集,数据采集频率为每天 1 次,共计 2361 组,其中前 80%数据作为训练集,后 20%作为测试集,如图 3 所示。环境量数据方面,考虑到该工程地处西北干旱地区,水量补给主要来自季节性融雪,且大坝下游无水,只选用库水位和时间效应作为影响因子,数据的监测时段和采集频率与渗流监测数据相同,并作同样的数据集划分。




图2 黏土心墙坝渗流监测布置(单位:m)




图3 渗压计 P01、P02、P03 监测数据和库水位过程线

由于通信错误、采集信号电压波动或传感器故障等原因,现场采集的监测数据容易出现异常测值。此外,当土石坝的防渗系统完整性发生突变,偏离正常工作状态时,监测数据中也会出现异常测值。本文共考虑了数据跳变、截断异常、防渗失效、噪声污染、转点异常和上下文异常 6 类可能的异常测值,并采用文献[14]中的策略进行测试集上的异常测值注入,以全面评估模型的异常检测性能和稳健性。以截断异常为例,由图 3 的测试集数据可以看出,当库水位不断变化时,渗压测值却保持稳定。实际工程中,上位机宕机、采集单元掉电或渗压计失效时会出现类似的异常测值。

3.2 超参数优化

由于深度学习模型超参数众多,超参数的选取会显著影响模型精度,合理选择超参数非常重要。本文选用 Optuna^[15] 进行基于树结构 Parzen 估计器 (tree-structured Parzen estimator, TPE) 的贝叶斯超参数优化,以便在最小化模型训练成本的同时,达到最优的超参数搜索结果。经过超参数优化确定的 GAT-TCN 模型主要超参数如下:GAT 模块一维卷积核宽度为 7,注意力单元数为 64,GRU 层数为 2,每层单元数为 128;TCN 模块卷积核宽度为 3,卷积核为 128 个,共 2 层卷积;Dense 层单元数为 128。

3.3 模型性能评价

GAT-TCN 模型将异常测值记为正类,正常测值记为负类。正负类的划分取决于异常阈值的大小。根据确定评价指标需要的阈值个数,监测数据异常检测性能评价指标可以分为两类:①单阈值评价指标,包括精确率、召回率、误报率和 F1 分数;②多阈值评价指标,包括受试者工作特征 (receiver operating characteristic, ROC) 曲线及其对应的 AUC-ROC 值、精确率-召回率 (precision-recall, PR) 曲线及其对应的 AUC-PR 值。

为了进一步验证 GAT-TCN 模型的异常检测性能,本文复现或调用了另外 4 种监测数据异常检测模型 (VAE 模型^[6]、GRU 模型^[16]、OCSVM 模型^[9] 和 SSA 模型^[8]) 作为基准模型。这些基准模型涵盖了两种不同的学习范式 (无监督学习和半监督学习) 与 3 种主流方法类型 (基于预测、基于重构和基于域的方法)^[15]。

3.4 结果与讨论

为了评估 GAT-TCN 模型的异常检测性能,以截断异常为例进行分析。图 4 (a) 为测试集上 GAT-TCN 模型输出的异常得分及其对应的异常阈值 (该阈值取为 F1 分数最高时所对应的值),图 4 (b) 给出了在该阈值下 GAT-TCN 模型检测结果的混淆矩阵,用于直观展示其分类准确率与召回率。可以看出,GAT-TCN 模型对截断异常的发生敏感,并在整体上保持了较好的检测性能。表 1 为不同模型异常测值识别结果的评价。由表 1 可知,VAE 具有较高

的召回率,但其精确率不足 0.4,检测效果较差。GRU 模型和 SSA 模型相比于 VAE 模型在精确率上有较大提升,但召回率有所降低,检测过程中有少量的漏判。GAT-TCN 模型综合考虑了环境量变化和深度时序关系,其精确率均高于 0.9。可见 GAT-TCN 模型在土石坝渗流监测数据异常检测的精度、漏判、误判等方面均较传统主流模型具有较好的性能提升。




图 4 GAT-TCN 模型截断异常检测结果

图 5 和图 6 为 GAT-TCN 和 4 个基准模型对 6 类异常场景监测数据异常检测的 ROC 曲线和 PR 曲线。当模型性能优秀时,正负类的异常得分可以被几乎所有阈值完美分隔,此时的 AUC-ROC 接近于 1。GAT-TCN 模型在 6 类异常场景下的 AUC 值平均约为 0.948,能很好地区分渗流监测数据中的正负类。在 PR 曲线中,除了上下文异常外,GAT-TCN 在另 5 类异常场景下均取得了最佳性能。

从图 5 和图 6 还可以看出,基于预测的两种深度学习模型 (GAT-TCN 和 GRU) 整体异常检测能力相比其他 3 种模型更强,说明基于预测的模型更适用于土石坝渗流监测数据异常检测。但是,尽管同为基于预测的模型,GRU 模型的表现不如 GAT-TCN 模型,证实了 TCN 用于时序特征提取的有效性。

VAE 模型以各测点的渗压监测序列作为输入,但该土石坝的渗压监测序列周期性特征不明显,致使 GRU 模型难以捕捉有效的时序依赖关系进行预测,限制了模型整体的异常检测性能。值得注意的是,数据跳变和噪声污染两类异常测值在频域中表现为高频分量,SSA 模型能够较好地对其进行识别,

表 1 不同模型异常测值识别结果评价

异常类型	F1 分数				精确率				召回率			
	GAT-TCN	VAE	GRU	SSA	GAT-TCN	VAE	GRU	SSA	GAT-TCN	VAE	GRU	SSA
数据跳变	0.87	0.19	0.43	0.68	0.94	0.11	0.40	0.92	0.80	0.80	0.46	0.54
截断异常	0.95	0.56	0.81	0.21	0.97	0.41	0.92	0.16	0.94	0.86	0.72	0.31
防渗失效	0.87	0.38	0.73	0.20	0.91	0.24	0.80	0.16	0.83	0.90	0.67	0.25
噪声污染	0.82	0.50	0.48	0.67	0.95	0.36	0.32	0.64	0.72	0.84	1.00	0.71
转点异常	0.99	0.55	0.97	0.64	1.00	0.39	0.96	0.60	0.98	0.92	0.98	0.68
上下文异常	0.99	0.34	0.99	0.77	1.00	0.21	1.00	0.66	0.98	0.98	0.98	0.93




图5 GAT-TCN 模型和基准模型的 ROC 曲线




图6 GAT-TCN 模型和基准模型的 PR 曲线

在 4 种基准模型中异常检测能力最强,但对于其他 4 类异常尤其是截断异常和防渗失效,SSA 模型的异常检测效果最差。

土石坝运行过程中,6 类异常都有可能发生,最优模型须具备应对不同场景的高泛化能力和强稳健性。6 种模型在 6 类异常测试集上的平均 AUC-

ROC 值 和 AUC-PR 值如图 7 所示。从图 7 可以看出,GAT-TCN 模型在 6 类异常场景下的平均 AUC-ROC 值和 AUC-PR 值分别为 0.948 和 0.968,表明其整体异常检测性能优异。此外,其 AUC-ROC 值和 AUC-PR 值的样本标准差分别为 0.035 和 0.022,说明模型性能在不同异常场景下波动小,稳定性高,具备较强的稳健性。相比之下,其余 4 个模型的性能在不同异常场景下差异显著,无法稳定地维持高检测性能。




图 7 GAT-TCN 模型和基准模型在 6 类异常场景下的平均性能

4 结 语

针对土石坝渗流监测数据兼具时序性与多因子影响的特点,本文构建了耦合 TCN 和 GAT 的土石坝渗流监测数据异常检测模型。西北某黏土心墙坝的实例验证结果表明,GAT 模块能自适应地遴选关键影响因子,而 TCN 模块则有效捕捉了渗压监测序列的长时依赖关系。与多种主流模型的对比进一步验证了 TCN-GAT 模型在监测数据异常检测准确率与稳健性方面的优越性,通过融合 GAT 的特征选择能力与 TCN 的时序建模优势,实现了对渗压水位响应模式的准确表征,为土石坝渗流监测数据异常检测提供了一种有效的解决方案,证实了融合环境量变化信息对于提升模型泛化能力的重要价值。

然而,该模型仍存在一定局限性,目前的工作仅基于渗流监测数据进行了验证,未来需在内部变形、应力等更多物理量数据集上测试模型的普适性。此外,试验未考虑异常值注入参数(如噪声方差、异常持续时间等)对监测数据异常检测性能的敏感性,后续研究可对此进行深入分析,以进一步明确模型的适用边界。

参考文献:

[1] 中华人民共和国水利部. 中国水利统计年鉴 2022[M]. 北京:中国水利水电出版社,2022.
[2] 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))
[3] 余红玲,王晓玲,任炳昱,等. 土石坝渗流性态分析的 IAO-XGBoost 集成学习模型与预测结果解释[J]. 水利学报,2023,54(10):1195-1209. (YU Hongling, WANG Xiaoling, REN Bingyu, et al. IAO-XGBoost ensemble learning model for seepage behavior analysis of earth-rock dam and interpretation of prediction results[J]. Journal of Hydraulic Engineering, 2023, 54 (10): 1195-1209. (in Chinese))
[4] 马春辉,侯媛媛,杨杰,等. 基于 RUN-XGBoost 算法的土石坝渗流预测模型[J]. 水利水电科技进展,2024,44(2):72-78. (MA Chunhui,HOU Yuanyuan,YANG Jie, et al. Seepage prediction model of earth-rockfill dams based on RUN-XGBoost algorithm[J]. Advances in Science and Technology of Water Resources, 2024, 44 (2): 72-78. (in Chinese))
[5] 赵新华,范振东,何宇,等. 基于数据重构与孤立森林法的大坝自动化监测数据异常检测方法[J]. 中国农村水利水电, 2021 (9): 174-178. (ZHAO Xinhua, FAN Zhendong, HE Yu, et al. An anomaly detection method for dam automatic monitoring data based on data reconstruction and isolated forest[J]. China Rural Water and Hydropower, 2021(9):174-178. (in Chinese))
[6] 蒋齐嘉,蒋中明,唐栋,等. 基于 SSA-DBSCAN 的边坡安全监测数据粗差探测方法[J]. 长江科学院院报,2022, 39(4): 85-90. (JIANG Qijia, JIANG Zhongming, TANG Dong, et al. Gross error detection of slope safety monitoring data based on SSA-DBSCAN[J]. Journal of Yangtze River Scientific Research Institute, 2022, 39 (4): 85-90. (in Chinese))
[7] SHU X,BAO T,ZHOU Y,et al. Unsupervised dam anomaly detection with spatial-temporal variational autoencoder[J]. Structural Health Monitoring,2023,22(1):39-55.
[8] 屈旭东. 基于智能算法的混凝土坝变形奇异测值诊断与安全监控方法研究[D]. 西安:西安理工大学,2023.
[9] 周叶. 基于新异类检测和支持向量机的水电机组诊断技术研究[D]. 北京:中国水利水电科学研究院,2016.
[10] 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))

(下转第 119 页)

computational comparison of baffled-culvert hydrodynamics for fish passage[J]. Journal of Applied Water Engineering and Research,2018,6(3):191-199.

[10] OURO P, MUHAWENIMANA V, WILSON C A M E. Asymmetric wake of a horizontal cylinder in close proximity to a solid boundary for Reynolds numbers in the subcritical turbulence regime[J]. Physical Review Fluids, 2019,4(10):104604.

[11] 胡彬,水庆象,王大国,等.特征线算子分裂有限元的圆柱绕流大涡模拟[J]. 水利水电科技进展,2017,37(2):27-32. (HU Bin,SHUI Qingxiang, WANG Daguo, et al. Large eddy simulation of flow around circular cylinder combined with characteristic-based operator-splitting finite element method[J]. Advances in Science and Technology of Water Resources,2017,37(2):27-32. (in Chinese))

[12] ZHANG Peipei, GONG Yiqing, CHUA K V, et al. Numerical study of submerged bending vegetation under unidirectional flow[J]. Water Science and Engineering, 2024,17(1):92-100.

[13] 李晗玫,毛劲乔,龚轶青,等.圆柱形植物斑块水动力特性的大涡模拟研究[J]. 水动力学研究与进展 A 辑, 2022,37(1):108-114. (LI Hanmei, MAO Jingqiao, GONG Yiqing, et al. Numerical investigation of hydrodynamic properties of cylindrical vegetation patch using large-eddy simulation [J]. Chinese Journal of Hydrodynamics,2022,37(1):108-114. (in Chinese))

[14] 高欢,龚轶青,毛劲乔,等.基于 LES 的连续分布植物斑块水动力特性研究[J]. 工程科学与技术,2025,57(3):184-191. (GAO Huan, GONG Yiqing, MAO Jingqiao, et al. Study on hydrodynamic characteristics of continuous distribution vegetation patches based on LES [J]. Advanced Engineering Sciences,2025,57(3):184-191. (in Chinese))

[15] DAI Jie, MAO Jingqiao, GONG Yiqing, et al. Effect of triangular baffle designs on flow dynamics and sediment transport within standard box culverts [J]. Journal of Hydrodynamics,2024,36(6):1142-1154.

[16] DAI Jie, GONG Yiqing, WANG Kang, et al. Wake dynamics and turbulence structures of flow past two tandem circular cylinders near a plane wall[J]. Ocean Engineering,2025,334:121575.

[17] KIRKIL G, CONSTANTINESCU G, ETTEMA R. Detached eddy simulation investigation of turbulence at a circular pier with scour hole [J]. Journal of Hydraulic Engineering,2009,135(11):888-901.

[18] SILVA A T, LUCAS M C, CASTRO-SANTOS T, et al. The future of fish passage science, engineering, and practice [J]. Fish and Fisheries,2018,19(2):340-362.

[19] MARRINER B A, BAKI A B M, ZHU D Z, et al. The hydraulics of a vertical slot fishway: a case study on the multi-species Vianney-Legendre fishway in Quebec, Canada[J]. Ecological Engineering,2016,90:190-202.

[20] LUO Qianyu, STOESSERT T, JALALABADI R, et al. Hydrodynamics and turbulence of free-surface flow over a backward-facing step[J]. Journal of Hydraulic Research, 2023,61(5):611-630.

[21] ALFONSI G. Coherent structures of turbulence: methods of education and results [J]. Applied Mechanics Reviews, 2006,59(6):307-323.

(收稿日期:2024-11-29 编辑:俞云利)

+++++

(上接第 90 页)

[11] 宋锦焘,葛佳豪,杨杰,等.基于时空聚类和深度学习的混凝土坝变形异常值识别方法[J]. 水利水电科技进展,2024,44(4):65-71. (SONG Jintao,GE Jiahao, YANG Jie, et al. A method for identifying deformation outliers in concrete dams based on spatio-temporal clustering and deep learning[J]. Advances in Science and Technology of Water Resources,2024,44(4):65-71. (in Chinese))

[12] 王晓玲,李克,张宗亮,等.耦合 ALO-LSTM 和特征注意力机制的土石坝渗压预测模型[J]. 水利学报,2022,53(4):403-412. (WANG Xiaoling, LI Ke, ZHANG Zongliang, et al. Coupled ALO-LSTM and feature attention mechanism prediction model for seepage pressure of earth-rock dam[J]. Journal of Hydraulic Engineering,2022,53(4):403-412. (in Chinese))

[13] HE Y, ZHAO J. Temporal Convolutional networks for anomaly detection in time series[J]. Journal of Physics: Conference Series,2019,1213(4):042050.

[14] AKIBA T, SANO S, YANASE T, et al. Optuna: a next-generation hyperparameter optimization framework [C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York:ACM,2019:2623-2631.

[15] SCHMIDL S, WENIG P, PAPENBROCK T. Anomaly detection in time series: a comprehensive evaluation[J]. Proceedings of the VLDB Endowment,2022,15(9):1779-1797.

[16] HUNDMAN K, CONSTANTINOU V, LAPORTE C, et al. Detecting spacecraft anomalies using LSTMs and nonparametric dynamic thresholding [C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York:ACM, 2018:387-395.

(收稿日期:2024-11-26 编辑:熊水斌)