

DOI:10.19651/j.cnki.emt.2517850

基于 DSVDD 的高心墙堆石坝监测数据异常检测方法

黄会宝¹ 陈蓉² 陈建康¹ 罗冲³

(1. 四川大学水利水电学院 成都 610065; 2. 国能大渡河流域水电开发有限公司 成都 610041;

3. 四川大学电气工程学院 成都 610065)

摘要: 水库大坝作为具有防洪度汛、水力发电、农业灌溉等重要作用的超大型重要基础设施,一旦发生溃坝将会引发严重灾难,因此对其进行常态化安全监测具有重要意义。但受到测量环境、系统故障和监测对象异常影响,大坝监测数据中会出现各种异常数据,对这些异常监测数据进行检测有利于监测数据的有效分析并及时发现险情,保障水库大坝安全稳定运行。但现存的数据异常检测方法大多只关注数据粗差等异常,忽略了数据缓变异常。因此本文基于深度支持向量描述(DSVDD)方法提出一种缓变异常检测方法,该方法将大坝多维监测参数构建为多维参数样本,并构建自编码器网络利用 DSVDD 方法进行有效训练,将输入样本映射到紧凑的超球体中,以输入样本偏离超球体中心距离作为异常分数实现异常检测。为验证所提方法有效性,本文基于某高心墙堆石坝激光准直监测系统数据将所提方法与其他多类方法进行对比分析,结果证明所提方法具有优异的数据异常检测性能。

关键词: 高心墙堆石坝; 多维监测数据; 异常检测; DSVDD; 缓变异常

中图分类号: TV698.1; TN16 文献标识码: A 国家标准学科分类代码: 570.6020

Anomaly detection method for monitoring data of high core-wall rockfill dams based on DSVDD

Huang Huibao¹ Chen Rong² Chen Jiankang¹ Luo Chong³

(1. College of Water Resources & Hydropower, Sichuan University, Chengdu 610065, China;

2. CHN Energy Dadu River Hydropower Development Co., Ltd., Chengdu 610041, China;

3. College of Electrical Engineering, Sichuan University, Chengdu 610065, China)

Abstract: Reservoir dams, as critical infrastructures for flood control, hydropower generation, and agricultural irrigation, pose significant risks if breached, making regular safety monitoring essential. However, monitoring data often contains anomalies due to environmental factors, system malfunctions, and abnormal behaviors of the monitored objects. Detecting these anomalies is vital for effective data analysis and early risk identification to ensure the dam safety. Existing anomaly detection methods typically focus on gross outliers and overlook subtle, gradual anomalies. This paper proposes a gradual anomaly detection method based on Deep Support Vector Data Description(DSVDD). The method constructs multi-dimensional monitoring parameters as samples and trains an autoencoder using DSVDD to map the input data to a compact hypersphere. The anomaly score is derived from the distance of the input sample from the center of the hypersphere. The proposed method is validated using laser alignment data from a high core-wall rockfill dam, and the results demonstrate its superior performance compared to other methods.

Keywords: high core-wall rockfill dam; multi-dimensional monitoring data; anomaly detection; DSVDD; gradual anomaly

0 引言

水库大坝作为水资源调节和管理的重要基础设施,具有防洪度汛、水力发电、农业灌溉等重要作用。其一旦发生溃坝会对人民安全和国民经济带来严重灾难,因此对其进行常态化安全监测与监控,密切关注其内外在结构形变等

重要参数变化,防止相关事故发生具有重要意义^[1]。

常规的大坝安全监测手段包括内部传感器监测形变、应力、渗流等参数,外部通过 GPS 或者激光监测系统监测位移和形变等。在众多仪器监测过程中,一方面由于测量系统噪声、故障和环境因素影响,测量参数中难免会出现异常数据;另一方面,由于大坝本体的结构异常变化,也会造

成相关监测参数的异常变化。针对这些监测数据,现已有众多学者利用多类方法对其实施异常检测研究,如统计方法、聚类方法、神经网络方法和其他复合方法等。

统计方法如花胜强等^[2]利用中位数和绝对中位数偏差的测值分布检验和Q值法波动率检验对大坝位移监测数据进行异常检测。李子阳等^[3]利用T检验法和Cook距离检验法对大坝引张线位移数据进行异常检测。统计方法具有较强理论基础、模型解释性好,但需要合适的统计模型以及足够的历史数据得出统计规律。

聚类方法不需要预设数据分布类型,能从数据中学习数据分布,当异常数据不在这个分布范围内即可判为异常,如戴领等^[4]基于密度聚类算法,提出兼顾数据整体和局部特性的异常检测方法从而对大坝位移监测参数进行异常检测。类似的,李川洲^[5]提出了基于密度模式的空间聚类算法,该方法通过训练将数据分为若干个数据簇,若某个待检测数据不属于任一数据簇则将其视为异常数据。郑付刚^[6]用Frobenius范数度量大坝形变、水位、温度等数据相似性,再利用局部异常系数方法对数据进行异常检测识别。其他类似方法还有文献[7-8]等。聚类不需要预设统计模型,能发现隐藏的数据结构和数据分布,但在面临复杂数据时拟合能力有限且训练较为困难。

神经网络数据映射能力更强,近年许多学者基于此方法对大坝监测数据进行异常检测。如叶斌^[9]利用长短时记忆网络(long short term memory, LSTM)对坝基渗压数据和拱坝应变数据进行预测,再对预测值与真实值之间的残差进行阈值检测从而实现异常检测。类似的,李川洲^[5]也利用LSTM对大坝渗压计数据进行异常检测,达到了较好检测效果。除此之外,还有利用自编码器(autoencoder, AE)对数据重构后实现异常检测的。如刘鹤鹏等^[10]利用If-Encoder对监测数据进行学习重构,再利用重构数据与监测数据差值作为异常分数从而实现异常检测。Kang等^[11]提出了一个基于记忆增强AE和生成对抗网络的异常检测方法,该方法利用记忆增强AE中的记忆增强模块学习和记忆正常样本的特征,并通过生成对抗网络模型的对抗训练过程放大输入数据与重构数据之间的误差,从而提高异常检测性能。此外,Wang等^[12]提出了一种时空对比学习预训练策略,用于从无标签大坝变形监测数据中提取判别特征,并将预训练的参数转移到目标检测任务中采用先验知识进行模型微调,最后用实际大坝监测参数进行了有效性验证。神经网络方法数据映射能力强、应用灵活性高,针对大坝监测数据能达到较好检测效果,但需依赖于高质量数据进行有效训练。

其他复合方法通过前期信号处理或者特征挖掘,能够避免复杂训练过程。如Zheng等^[13]将大坝监测数据散点图转化为二值图像,用布谷鸟搜索算法提取数据点中的监测过程线,再利用数据点偏移过程线程度作为异常判别依据实现异常检测。李松轩等^[14]通过小波变换和傅里叶变

换剥离原始监测数据中的环境影响趋势成分,再在残差序列中通过3倍标准差阈值方法实现异常检测。张津津^[15]用集成经验模态分解方法对数据进行降噪,用孤立森林和局部异常因子对数据样本进行异常监测,然后将上述异常分数进行加权融合,最后用人工植入异常的大坝渗压数据对所提方法进行了有效性验证。

上述方法大多都是对大坝安全监测的单维度渗压、位移、应力等参数实施异常检测,缺乏从多维度参数间去发掘异常关系或成分,因此熊敏等^[16]利用LSTM对多维度大坝激光准直监测数据进行异常检测,从多维度输入预测单维度参数,再利用残差的3倍标准差实现异常检测。但上述多数方法都侧重于针对监测数据的单个或几个测值粗差点进行检测,缺乏针对缓变异常的研究。缓变异常数据可能来自于传感器或测量系统故障^[17],也可能是监测对象的缓变位移造成^[18]。

针对现有方法对缓变异常的研究不足之处,本文将基于先进的深度支持向量描述(Deep Support Vector Data Description, DSVDD)^[19]提出针对某高心墙堆石坝坝激光准直监测数据的缓变异常检测方法。

1 理论基础

DSVDD主要是训练一个神经网络,使其可以将输入正常数据映射到一个超球体中,或者一个数据簇中,当异常数据输入之后,其特征会映射到超球体之外,或者远离类别中心,从而实现异常检测,这一思想如图1所示。

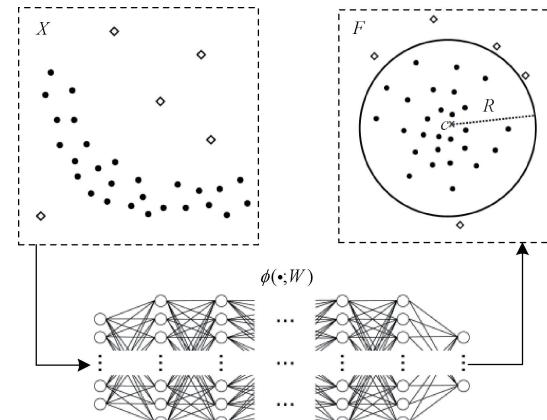


图1 深度支持向量描述示意图

Fig. 1 Deep support vector data description

具体地,定义输入数据空间为 $X \subseteq R^d$,输出空间为 $F \subseteq R^p$,定义神经网络映射函数 $\phi(\cdot; W): X \rightarrow F$,该神经网络层数为 $L \in N$,权重参数为 $W = \{W^1, W^2, \dots, W^L\}$,其中 W^l 表示第 l 层的权重参数。由以上定义可知, $\phi(\cdot; W) \in F$ 即代表权重参数 W 定义的神经网络 ϕ 的映射输出。DSVDD的目标则可以具体描述为学习一组权重参数 W ,使其可以让神经网络 ϕ 将输入数据映射到一个容量最小的超球体空间 F 中。该超球体空间的半径为 R ,中心为

$c \in F$ 。对于给定的一组训练数据 $D_n = \{x_1, x_2, \dots, x_n\} \subseteq X$, 可定义软边界 DSVDD 训练目标如下所示^[19]:

$$\min_{R, W} R^2 + \frac{1}{vn} \sum_{i=1}^n \max\{0, \| \phi(x_i W) - c \|^2 - R^2\} + \frac{\lambda}{2} \sum_{l=1}^L \| W^l \|^2_F \quad (1)$$

该优化目标中, 第 1 项 R 的作用是使得超球体的空间 R 尽量减小, 更加紧凑。第 2 项的目标是使得大部分正常数据点处于超球体之内, 如果数据点在超球体空间外, 则该项会带来惩罚作用。此外由于第 1 项和第 2 项是处于一个矛盾状态, 因此训练过程通常是采用交替更新的方式实现, 并可采用超参数 v 作为这两项优化目标的平衡参数, v 在本文中被设定为 0.1。最后一项则是防止模型过拟合的正则化项。

此外, 若将上述的数据中心 c 纳入训练过程, 则 DSVDD 的超球体在训练过程中会出现超球体坍缩现象, 如网络会倾向于将所有权重参数训练到 0, 使得所有数据收缩到 0 坐标位置。为避免此问题, Ruff 等^[19]引入与 DSVDD 基础网络对应的自编码器方法进行预训练, 在训练收敛后用其特征向量平均值作为数据中心 c , 之后再参考 DSVDD 优化目标式(1)训练。

2 所提方法

本节将提出基于 DSVDD 的缓变异常检测方法, 该方法主要依据大坝多维监测数据特点构建自编码器, 并将多维监测数据重构为多维参数样本, 按 DSVDD 方法流程实施训练和检测。

2.1 基础网络

DSVDD 在训练时需要先利用 AE 进行预训练设置数据中心, 之后再利用编码器作为基础网络实施主训练过程, 将输入数据映射到一个超球体中。为此, 本文根据所用数据设计的自编码器参数如表 1 所示。

表 1 自编码器参数

Table 1 Autoencoder parameter

名称	输入长度	输出长度	其他
编码器	270	128	
	128	64	
	64	32	每层后附加批正则化操作以及激活函 ReLU
解码器	32	64	
	64	128	
	128	270	

2.2 样本构建

为对所提方法进行充分且有效的训练学习, 需要将多维时间序列有效转化为训练样本。大坝单维监测序列时间维度上含有监测对象重要信息, 一些坝体空间位置相近或

结构一体的多维测点数据间的相关关系也能表征部分重要信息。为此本节将多维度大坝监测数据分段取出, 并拼接为单值序列, 作为包含多维信息的多维参数样本, 从而可以保留大坝多维监测数据时间和空间上的重要信息, 以支撑 DSVDD 挖掘更为丰富的数据特征, 实施效果更好的异常检测, 上述样本构建过程如图 2 所示。

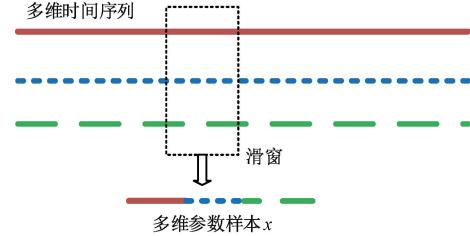


图 2 多维参数样本构建过程示意图

Fig. 2 Schematic diagram of multi-dimensional parameter sample construction process

在图 2 的样本构建过程中, 每个样本标签根据“或”规则确定, 即样本中任一时间点数据为异常, 整个样本标签就设置为异常。在本文后续数据滑窗构建样本过程中, 滑窗宽设置为 30, 步长为 2。

2.3 应用过程

在上述的基础网络和数据准备好之后, 即可对 DSVDD 方法开展训练和测试, 训练过程中首先利用构建的正常样本对表 1 所示的 AE 进行预训练, 预训练损失函数为重构数据与输入数据间的均方差损失函数。预训练完成之后参考 DSVDD 优化目标式(1)对 AE 中的编码器部分进行训练。训练完成得到最优参数后即可对数据进行异常分数计算^[19]:

$$s(x) = \| \phi(x; W^*) - c \|^2 \quad (2)$$

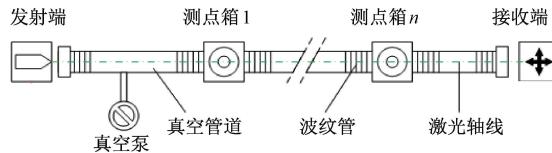
其中, $\phi(\cdot)$ 代表 AE 中的编码器部分, W^* 代表其经过完整训练过程后得到的最优参数。最后, 对异常分数 s 设定合适阈值即可对输入样本完成异常判定。

3 数据介绍

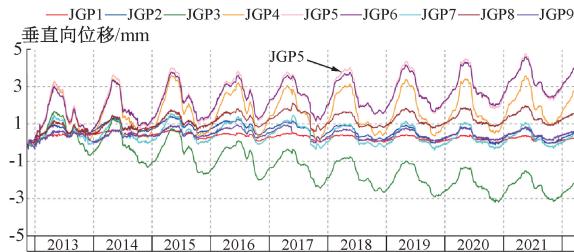
3.1 原始数据

本文基于某高心墙堆石坝真空激光准直监测系统的监测数据进行实验验证。该系统安装于大坝基础廊道内, 横向贯穿整个大坝, 能够实现对大坝结构位移的精确监测。系统的主要组成部分包括激光发射端、接收端、真空管道以及多个分布在不同位置的测点箱。测量系统大致结构如图 3 所示, 激光发射端通过真空管道将激光束传输至各测点箱, 每个测点箱内设置了波带板, 激光束经过这些波带板后在接收端的成像幕上形成光斑。通过对光斑位置的精确量测和分析, 能够计算出各个测点箱在横截面上的位移量, 这些位移数据反映了大坝在水压、温度变化等因素作用下的微小位移情况。

该系统监测的部分数据如图 4 所示, 其中包括 9 个测

图 3 激光准直系统示意图^[16]Fig. 3 Schematic diagram of laser collimation system^[16]

点垂直位移数据, 单个序列包括 2012~2022 年在内的 3 000 多个数据点。

图 4 激光准直系统监测数据^[16]Fig. 4 Laser collimation system monitoring data^[16]

3.2 缓变异常植入

在上述激光准直监测系统中, 大坝坝体结构的局部异常形变和测量系统故障都会造成数据中的缓变异常发生, 由于实测缓变异常数据缺乏, 因此本文对数据进行缓变异常植入, 形成测试数据验证所提方法有效性。具体地, 对 JPG5 测点的末尾段数据进行缓变异常植入。植入异常方式为将 JPG5 中的 3 100~3 200 的 100 个正常数据点(对应 100 天测量信息)按线性比例向下方旋转偏移一定程度, 偏移程度为该段数据首末两点形成的直线与横坐标夹角的一半, 具体如图 5 所示。

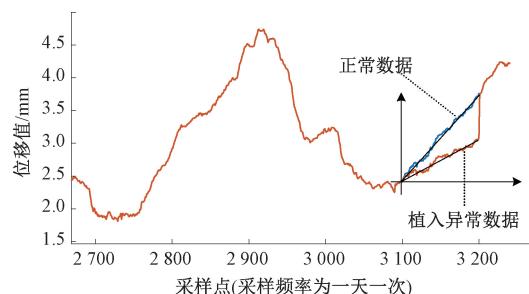


图 5 JPG5 测点异常植入示意图

Fig. 5 JPG5 anomaly injection diagram

4 方法对比

4.1 对比方法介绍

1) 多维 LSTM 异常检测方法^[16], 该方法利用 LSTM 方法以多维度大坝监测数据为输入, 预测特定维度数据, 再利用预测值与监测值的残差作为异常分数, 并设置阈值后实现异常检测, 阈值设定为残差的 3 倍标准差值, 详细方法过程可参考文献^[16]。

2) AE 异常检测方法, 该方法网络结构参数如表 1 所示, 其利用 AE 对多维监测数据进行无监督训练, 训练结束后再利用重构样本与输入样本的均方误差作为异常分数并设定阈值后实现异常检测, 该方法输入与本文所提方法一致, 即按图 2 描述过程构建的多维参数样本。

3) 插值高斯描述 (interpolated Gaussian descriptor, IGD) 异常检测方法。该方法类似于 DSVDD, 所用基础网络与表 1 一致, 训练过程中先将 AE 进行预训练, 再利用 IGD 对应训练策略进一步训练 AE 参数, 使其可将多维监测数据样本映射到高斯分布的超球体中, 并利用特征内插值方法优化模型训练, 从而达到较好检测效果。该方法的输入也为多维参数样本, 训练结束后以异常分数阈值判定实现异常检测, 详细描述如文献^[20-21]所示。

4) 基于 DSVDD 的异常检测方法, 即本文所提方法, 该方法以表 1 所示 AE 为基本网络, 输入数据为多维参数样本, 训练结束后以式(2)计算异常分数, 再设定阈值后实现异常判定。

在上述方法中, 所有数据以图 4 时间轴的前 80% 多维数据作为训练集, 后 20% 为测试集, 其中 JPG5 的 3 100~3 200 数据点按图 5 所示方法植入了缓变异常。此外, 多维度 LSTM 方法的训练参数与原始文献^[16]一致。AE、IGD、所提方法的 AE 预训练 Epoch 设置为 300。IGD、所提方法的主训练过程 Epoch 设置为 250, 训练 Batch size 设置为 16, 训练优化算法采用 Adam。

4.2 对比结果

按上述描述过程训练结束后, 对所有方法的异常检测分数进行受试者特征曲线下面积 (AUC) 对比, AUC 是处于 0~1 的值, 其越大, 证明异常分数中正常数据与异常数据的可分性越好, 能达到的异常检测效果越好。所有方法在测试集中所取得的 AUC 值如表 2 所示。从表 2 中可以看出本文所提方法取得的 AUC 值最高, 证明其具有较好异常检测性能。

表 2 各方法异常分数 AUC

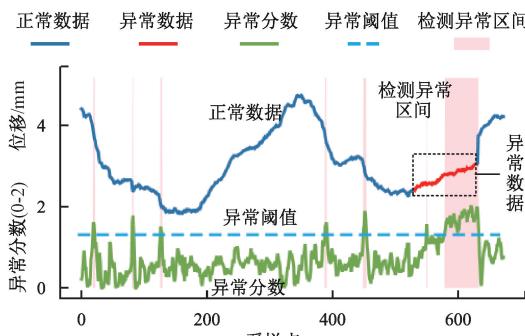
Table 2 Anomaly score AUC for each method %

方法	多维 LSTM	AE	IGD	本文所提方法
AUC	93.43	79.50	94.87	99.50

接着对各个方法的异常检测结果进行直观对比分析。其中多维 LSTM 检测得到的异常分数是与原始时间序列一一对应的时间序列异常分数, 而 AE、IGD 和多维 LSTM 是输入滑窗取样的多个样本检测得到的样本异常分数。为将样本异常分数恢复为时间序列异常分数, 本文以各样本异常分数作为其对应取样时间轴上的末尾两个数据点的异常分数, 如某个样本来源于各维度数据从 30~60 个数据点的滑窗, 则对应时间轴第 59~60 点的时间序列异常分数与该样本异常分数一致, 根据这一规则可以将样本异常分数

恢复为时间序列异常分数。

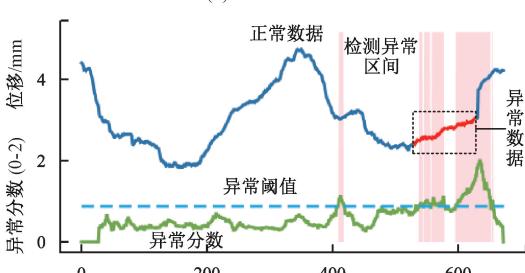
将各方法得到的时间序列异常分数与植入异常的 JPG5 数据段绘制如图 6 所示, 其中多维 LSTM 方法的异常检测阈值为测试样本异常分数的 3 倍标准差值。AE、IGD 和本文所提方法的异常检测阈值设定为训练样本异常分数的 3 倍标准差值。这样的阈值设置能够让各方方法都达到较好的阈值检测效果。利用设置阈值对各异常分数进行阈值检测后得到的异常区间如图 6 中的粉红阴影区域所示。从图 6(a)中可以看出, 多维 LSTM 检测得到的粉色异常区间与实际红色异常数据重合度只有大约一半, 且具有两个较窄的误判区间。从图 6(b)可以看出, AE 方法检测得到了两个较宽的异常区间, 只有右边一个与实际异常数据有小部分重合。从图 6(c)中容易看出, IGD 方法得到的异常区间断续地与异常数据重合, 存在较多未检测到的异常。最后从图 6(d)中的所提方法检测结果可以明显看出, 其得到的粉色异常区间与红色异常数据重合度较高, 只有左边一个极窄的误判区间。经过上述综合对比分析可知,



(a) 多维 LSTM 方法
(a) Multi-dimensional LSTM method



(b) AE 方法
(b) AE method



(c) IGD 方法
(c) IGD method

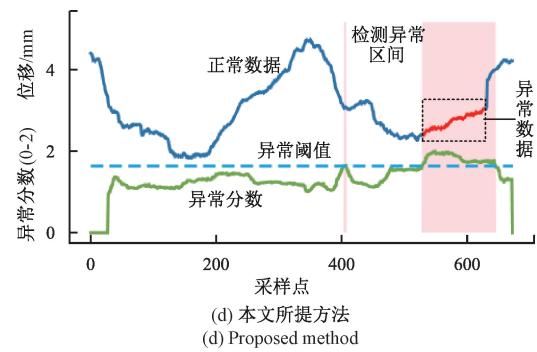


图 6 各方法对 JPG5 数据的异常检测结果

Fig. 6 Anomaly detection results of JPG5 data by each method

所提方法相对其他 3 类方法具有更为优异的异常检测性能。

5 结 论

本文基于 DSVDD 方法提出了针对高心墙堆石坝多维监测数据的缓变异常检测方法。该方法将多维参数重构为多维参数样本, 并构建 AE 以 DSVDD 训练方式将多维参数样本映射到超球体中, 实际应用时以异常数据偏离超球体中心距离作为异常分数, 设定合适阈值便可进行异常检测。为验证所提方法有效性, 本文以高心墙堆石坝真空激光准直监测多维数据为例, 对其植入缓变异常形成测试数据。基于该测试数据将所提方法与其他 3 类方法进行对比, 对比结果证明了所提方法具有优异的异常数据检测性能, 可提高大坝运行安全监测数据的可靠性, 为科学合理评估大坝运行安全提供有力支撑。

参考文献

- [1] 梅天灿, 肖尧, 毛索颖. 基于线结构光的三维垂线位移测量方法 [J]. 仪器仪表学报, 2024, 44 (4): 189-196.
MEI T C, XIAO Y, MAO S Y. A three dimension pendulum line displace measurement method based on linear structured light [J]. Chinese Journal of Scientific Instrument, 2024, 44(4): 189-196.
- [2] 花胜强, 郑慧娟, 陈意, 等. 基于承前序列的坝体位移异常值在线检测方法 [J]. 水力发电, 2021, 47(12): 102-105.
HUA SH Q, ZHENG H J, CHEN Y, et al. Online outlier detection method of dam displacement based on previous sequence [J]. Water Power, 2021, 47 (12): 102-105.
- [3] 李子阳, 郭丽, 马福恒, 等. 基于统计诊断的大坝监测数据合理性检验 [J]. 水利水电科技进展, 2018, 38(5): 71-75.
LI Z Y, GUO L, MA F H, et al. Rationality test of dam monitoring data based on statistical diagnosis [J]. Advances in Science and Technology of Water Resources, 2018, 38(5): 71-75.
- [4] 戴领, 李少林, 刘光彪, 等. 基于 LV-DBSCAN 算法

- 的大坝安全监测数据异常检测[J]. 人民长江, 2024, 55(1): 236-241.
- DAI L, LI SH L, LIU G B, et al. Detection of abnormal values in dam safety monitoring data based on LV-DBSCAN algorithm[J]. Yangtze River, 2024, 55(1): 236-241.
- [5] 李川洲. 基于关联规则和机器学习的大坝监测异常数据自适应识别方法研究[D]. 重庆: 重庆交通大学, 2023.
- LI CH ZH. Research on adaptive identification method for abnormal data of dam monitoring based on association rules and machine learning [D]. Chongqing: Chongqing Jiaotong University, 2023.
- [6] 郑付刚. 基于局部异常系数的混凝土坝变形异常分析方法[J]. 水电能源科学, 2016, 34(6): 103-105, 31.
- ZHENG F G, Abnormal deformation analysis of concrete dam based on local outlier factor[J]. Water Resources and Power, 2016, 34(6): 103-105, 31.
- [7] JI L, ZHANG X, ZHAO Y, et al. Anomaly detection of dam monitoring data based on improved spectral clustering[J]. Journal of Internet Technology, 2022, 23(4): 749-759.
- [8] 张晓. 基于聚类集成的大坝异常数据检测研究[D]. 郑州: 郑州大学, 2021.
- ZHANG X, Research on dam abnormal data detection based on clustering ensemble [D]. Zhengzhou: Zhengzhou University, 2021.
- [9] 叶斌. 基于LSTM模型的大坝安全监测数据异常值检测[D]. 武汉: 长江科学院, 2020.
- YE B, Outlier detection of dam safety monitoring data based on LSTM model[D]. Wuhan: Changjiang River Scientific Research Institute, 2020.
- [10] 刘鹤鹏, 李登华, 丁勇. 基于IF-Encoder的大坝监测异常数据检测算法[J]. 人民黄河, 2024, 46(10): 148-153.
- LIU H P, LI D H, DING Y. Algorithm for detecting abnormal data of dam monitoring based on IF-Encoder [J]. Yellow River, 2024, 46(10): 148-153.
- [11] KANG X, LI Y, ZHANG Y, et al. Anomaly detection in concrete dam using memory-augmented autoencoder and generative adversarial network (MemAE-GAN) [J]. Automation in Construction, 2024, 168: 105794.
- [12] WANG Y, LIU G. Self-supervised dam deformation anomaly detection based on temporal-spatial contrast learning[J]. Sensors, 2024, 24(17): 5858.
- [13] ZHENG S, SHAO C, GU C, et al. An automatic data process line identification method for dam safety monitoring data outlier detection [J]. Structural Control and Health Monitoring, 2022, 29(7): e2948.
- [14] 李松轩, 丁勇, 李登华. 基于影响因子分解法的大坝监测数据异常检测算法[J]. 人民长江, 2023, 54(4): 234-240.
- LI S X, DING Y, LI D H. Detection method for dam abnormal monitoring data based on influencing factor decomposition [J]. Yangtze River, 2023, 54 (4): 234-240.
- [15] 张津津. 土石坝渗流监测数据异常值识别与安全监控方法研究[D]. 西安: 西安理工大学, 2024.
- ZHANG J J. Research on anomaly identification and safety monitoring method of seepage monitoring data of earth-rock dam [D]. Xi'an: Xi'an University of Technology, 2024.
- [16] 熊敏, 江德军, 高志良, 等. 大坝监测数据多维度LSTM异常检测与恢复[J]. 电子测量技术, 2023, 46 (6): 51-56.
- XIONG M, JIANG D J, GAO ZH L, et al. Dam monitoring data multi-dimensional LSTM anomaly detection and recovery [J]. Electronic Measurement Technology, 2023, 46(6): 51-56.
- [17] 刘娇, 程然, 王颖, 等. 基于非线性卡尔曼滤波器的双通道传感器故障检测及隔离方法[J]. 节能技术, 2021, 39(3): 281-284.
- LIU J, CHENG R, WANG Y, et al. Dual-channel sensor fault detection and isolation method based on nonlinear Kalman filter [J]. Energy Conservation Technology, 2021, 39(3): 281-284.
- [18] 李浩. 基于多模融合和数据异常检测的滑坡预测和预警[D]. 徐州: 中国矿业大学, 2023.
- LI H. Landslide prediction and warning based on multi-model fusion and data anomaly detection [D]. Xuzhou: China University of Mining and Technology, 2023.
- [19] RUFF L, VANDERMEULEN R A, GÖRNITZ N, et al. Deep one-class classification [C]. International Conference on Machine Learning. PMLR, 2018: 4393-4402.
- [20] LUO C, WANG J, ZIO E, et al. Unsupervised fault detection of brushless DC motors under multioperating conditions via order hybrid interpolated gaussian descriptor [J]. IEEE/ASME Transactions on Mechatronics, 2024: 1-10, DOI: 10.1109/TMECH.2024.3452429.
- [21] CHEN Y, TIAN Y, PANG G, et al. Deep one-class classification via interpolated gaussian descriptor[C]. AAAI Conference on Artificial Intelligence, 2022, 36 (1): 383-392.

作者简介

- 黄会宝, 博士研究生, 正高级工程师, 主要研究方向为水电工程安全监测与监控。
E-mail: huanghuibao@stu.scu.edu.cn
- 陈蓉, 硕士研究生, 工程师, 主要研究方向为水电工程管理。
E-mail: 156308193@qq.com
- 陈建康, 教授, 博士生导师, 主要研究方向为水工结构工程。
E-mail: scu-jiankang@163.com
- 罗冲(通信作者), 博士研究生, 主要研究方向为装备智能健康评估。
E-mail: luochong33@foxmail.com