

DOI: 10.20040/j.cnki.1000-7709.2026.20250488

基于 VMD-SSA-K-means-iForest 的重力坝监测数据异常模式混合识别算法研究

李 铁¹, 李涵曼^{2a,2b}, 王福生¹, 徐 量¹, 郭 瑞¹

(1. 淮安市水利勘测设计研究院有限公司, 江苏 淮安 223001;

2. 南京水利科学研究院 a. 水灾害防御全国重点实验室; b. 水利部大坝安全管理中心, 江苏 南京 210029)

摘要: 重力坝监测数据的异常识别对大坝安全评估具有重要意义, 针对现有方法在模式辨识和特征提取方面的局限性, 提出一种基于 VMD-SSA-KMeans-iForest 的重力坝监测数据异常值混合识别方法, 该方法通过引入变分模态分解(VMD)优化 SSA 分解过程, 显著提升了特征提取的精度和鲁棒性。在此基础上, 构建了基于 K-means 聚类与孤立森林(iForest)协同的异常识别框架, 并将该方法应用于 W 重力坝异常数据识别中。结果表明, 所提方法的异常识别准确率提升了 2.5%, 同时有效区分了结构损伤与仪器故障引起的异常模式, 为重力坝安全评估提供了更可靠的技术支持。

关键词: 重力坝; 奇异谱分析; 变分模态分解; K-means 聚类; 孤立森林; 异常模式识别

中图分类号: TV698.1

文献标志码: A

文章编号: 1000-7709(2026)01-0182-06

Research on Hybrid Identification Algorithm for Anomaly Patterns in Gravity Dam Monitoring Data Based on VMD-SSA-K-means-iForest

LI Tie¹, LI Han-man^{2a,2b}, WANG Fu-sheng¹, XU Liang¹, GUO Rui¹

(1. Huai'an Water Resources Survey and Design Research Institute Co., Ltd., Huai'an 223001, China;

2a. State Key Laboratory of Water Disaster Prevention; 2b. Dam Safety Management Center,

Ministry of Water Resources, Nanjing Hydraulic Research Institute, Nanjing 210029, China)

Abstract: Anomaly detection in gravity dam monitoring data is critical for dam safety assessment. To overcome limitations of existing methods in pattern identification and feature extraction, this paper proposes a hybrid anomaly pattern detection method based on VMD-SSA-KMeans-iForest. By introducing variational mode decomposition (VMD) to optimize the decomposition process, the accuracy and robustness of feature extraction is significantly improved. Furthermore, an anomaly detection framework is established by combining K-means with isolation forest. This method is applied to the identification of abnormal data of the W gravity dam. The results demonstrate that the proposed method achieves a 2.5% improvement in anomaly detection accuracy while effectively distinguishing between anomalies caused by structural damage and those resulting from instrument failure, which provides more reliable technical support for the safety assessment of gravity dams.

Key words: gravity dam; singular spectrum analysis; variational mode decomposition; K-means clustering; isolation forest; anomaly pattern identification

1 引言

随着物联网技术的发展, 重力坝监测系统产生了海量、高维、非线性的时序数据, 传统异常识别方法面临严峻挑战。现有研究存在如下局限:

①数据特征提取不足, 难以捕捉复杂非线性关系;

②缺乏异常源区分机制, 难以准确定位异常原因。

近年来, 关于重力坝监测数据异常识别方面的研究已取得了显著进展。如花胜强等^[1]利用偏最小二乘回归和层次分析法进行粗差识别, 但阈值设定缺乏理论支撑; 齐智勇等^[2-3]通过人工标记数据并构建全卷积神经网络实现粗差识别, 但对标注数据依赖性强, 且计算资源消耗大; RONG Z

收稿日期: 2025-03-17, 修回日期: 2025-04-08, 接受日期: 2025-04-10

基金项目: 国家重点研发计划(2024YFC3210701); 大坝安全透彻感知体系构建技术与方法研究

作者简介: 李铁(1978-), 男, 高级工程师, 研究方向为水利规划设计, E-mail: 655901@qq.com

等^[4-5]提出了基于多点局部异常因子的识别方法,通过鲁棒回归和层次聚类减少误报率;郑霞忠等^[6-8]利用基于密度的 DBSCAN 聚类算法识别了监测数据中的异常值;蒋齐嘉等^[9]通过奇异谱分析法重构监测序列,并利用密度聚类算法对数据分解后的残余分量进行粗差识别;李元梦等^[10]提出了一种基于 DBSCAN 聚类算法的大坝安全监测异常数据检测算法。然而,上述方法大多未考虑监测数据的多尺度特征,且对异常来源的区分能力有限。对此,本文提出了一种基于改进奇异谱分析(VMD-SSA)的重力坝监测数据异常模式混合识别方法(HAPD),即通过引入变分模态分解(VMD)优化 SSA,显著提升了特征提取的精度和鲁棒性;在此基础上,采用 K-means 聚类算法对趋势项和周期项进行异常识别,利用 iForest 算法检测残差项中的离群点,并通过综合分析三类数据的异常模式特征,实现了对结构损伤与仪器故障引起异常的精准判别。

2 基于 VMD 优化的自适应 SSA 分解方法

2.1 奇异谱数据分解方法

奇异谱分析(SSA)是一种适用于非线性、非平稳时间序列的信号分解方法,能够有效提取重力坝监测数据中的长期变形趋势、周期性变化及随机波动成分。其核心步骤如下。

步骤 1 嵌入操作,将一维时间序列 $x = \{x_1, x_2, \dots, x_n\}$ 转换为高维轨迹矩阵 $\mathbf{H}$:

$$\mathbf{H} = \begin{bmatrix} x_1 & x_2 & \cdots & x_K \\ x_2 & x_3 & \cdots & x_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & \cdots & x_n \end{bmatrix} \quad (1)$$

其中 $K = n - L + 1$

式中, n 为序列长度; L 为窗口长度。

步骤 2 奇异值分解,得到 $\mathbf{H} = \mathbf{USV}^T$, 其中 $\mathbf{U}$ 、 $\mathbf{V}$ 分别为左、右奇异向量矩阵, $\mathbf{S}$ 为奇异值对角矩阵。

步骤 3 成分分组与重构,首先根据奇异值的大小和对应的奇异向量,得到趋势矩阵 $\mathbf{H}_{\text{trend}}$ 、周期矩阵 $\mathbf{H}_{\text{seasonal}}$ 和噪声矩阵 $\mathbf{H}_{\text{noise}}$ 。然后,将分组后的矩阵转换回时间序列。最后,计算趋势项 T_i 和周期项 S_i 的样本熵 S_E :

$$S_E(m, r, n) = -\ln(A/B) \quad (2)$$

式中, m 为嵌入维数; r 为相似度阈值; A 、 B 分别为 $m+1$ 、 m 维匹配点数。

2.2 VMD-SSA 混合分解模型

传统 SSA 方法在处理非平稳信号时存在窗口长度选择依赖经验、分解精度不足等问题。为此,本文提出基于变分模态分解(VMD)优化的自适应 SSA 方法,通过 VMD 预处理提升信号分解的鲁棒性和多尺度特征提取能力。

2.2.1 VMD 预处理

VMD 将信号 $x(t)$ 分解为 K 个模态分量 $u_k(t)$, 每个模态分量 $u_k(t)$ 具有明确的中心频率 ω_k , 其优化问题表示为:

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t \frac{2}{2}} \right\} \quad (3)$$

式中, u_k 为第 k 个模态分量; ∂_t 为时间导数; $\delta(t)$ 为狄拉克函数; j 为虚数单位; t 为时间; $*$ 为卷积运算。

约束条件为:

$$\sum_{k=1}^K u_k(t) = x(t) \quad (4)$$

通过求解上述优化问题,可得到 K 个模态分量 $u_k(t)$ 及其对应的中心频率 ω_k 。

2.2.2 自适应 SSA 分解

对 VMD 分解后的各模态分量 $u_k(t)$ 进行自适应 SSA 分解。通过最小化重构误差来确定最优窗口长度 L_{opt} :

$$L_{\text{opt}} = \arg \min_L \sum_{i=1}^N |x(t) - \hat{x}_L(t)|^2 \quad (5)$$

式中, $\hat{x}_L(t)$ 为窗口长度为 L 时的重构信号。

进一步引入正则化参数 λ 来优化分解过程:

$$\min_{\mathbf{U}, \mathbf{V}} \|\mathbf{H} - \mathbf{USV}^T\|_F^2 + \lambda (\|\mathbf{U}\|_F^2 + \|\mathbf{V}\|_F^2) \quad (6)$$

其中, $\|\cdot\|_F$ 为 Frobenius 范数。

最后,计算各模态分量的信息熵 E_k :

$$E_k = - \sum_{i=1}^m p_i \log p_i \quad (7)$$

式中, p_i 为模态分量 $u_k(t)$ 的概率分布。

根据熵值进行模态选择和重构,提高分解精度。

3 异常值混合识别方法

重力坝监测数据具有非线性、非平稳特性,单一异常识别方法难以全面捕捉异常模式,尤其在处理不同类型异常时存在局限性。为此,本文提出一种混合识别方法,利用 VMD-SSA 将数据分解为趋势项、周期项和残差项,并分别采用 K-means 聚类和 iForest 算法对各项数据进行针对性异常识别。

3.1 K-means 聚类方法

趋势项和周期项异常通常表现为数据分布的整体偏移,具有明显的聚集特征。传统阈值法难以有效识别此类渐进式异常,而 K-means 通过聚类分析可自动发现数据分布的结构性变化。该算法通过优化目标函数实现数据自动聚类,采用最小平方误差和作为收敛准则,其目标函数定义为:

$$f = \sum_{a=1}^m \sum_{b=1}^{n_a} (x_b^a - \mu_a)^2 \quad (8)$$

式中, f 为样本集中所有数据点到其对应类中心的欧氏距离平方和; m 为聚类类别数; n_a 为第 a 类中包含的样本点数量; x_b^a 为第 a 类中的第 b 个样本点; μ_a 为第 a 类的聚类中心。

K-means 采用欧氏距离作为相似性度量准则,计算公式为:

$$d = \sqrt{(x_1 - y_1)^2 + \cdots + (x_n - y_n)^2} \\ = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (9)$$

其中 $x = \{x_1, x_2, \cdots, x_n\}$; $y = \{y_1, y_2, \cdots, y_n\}$

式中, x_n, y_n 分别为时间序列 x, y 的数据。

各聚类类别的质心 μ_a 通过均值迭代法进行更新:

$$\mu_a = \frac{1}{n_a} \sum_{b=1}^{n_a} x_b^a \quad (10)$$

3.2 孤立森林异常识别法

残差项中的异常多表现为突发性离群点,具有稀疏性和局部性特征。针对此类异常,采用孤立森林算法进行检测,其核心优势在于通过路径长度度量有效区分真实异常与正常波动。该算法通过构建多棵孤立树,实现异常值检测。每棵树递归分割数据直至满足子节点仅含单个数据点或达到树的最大深度停止迭代。具体步骤如下。

步骤 1 随机选择特征和分割点,递归分割数据。

步骤 2 遍历孤立树,计算路径的平均长度,得到 $E(h(x))$ 。

步骤 3 利用 $c(n) = 2H(n-1) - [2(n-1)]/n$ 计算标准化路径长度。其中 $H(n-1)$ 为调和数, $H(n-1) \approx \ln(n-1) + 0.577$, n 为样本子集。采用 $s(x, n) = 0.5 - E(h(x))/c(n)$ 计算异常得分。异常得分的取值范围为 $[-0.5, 0.5]$ 。得分越接近 -0.5 , 表明数据的异常可能性越大;得分越接近 0.5 , 表明数据为正常的可能性越大。

3.3 混合识别算法评价指标与计算流程

3.3.1 异常识别评价指标

为验证基于时空融合聚类异常值识别方法的有效性,选取精准率 P 、召回率 R 、加权评价指标 F 对其计算结果进行对比分析,其计算公式分别为:

$$P = T_p / (T_p + F_p) \quad (11)$$

$$R = T_p / (T_p + F_N) \quad (12)$$

$$F = 2PR / (P + R) \quad (13)$$

式中, T_p 为真异常值的数量; F_p 为假异常值的数量; F_N 为假正常值的数量。

3.3.2 计算步骤

异常值混合识别算法具体步骤如下。

步骤 1 对原始监测数据进行标准化处理。

步骤 2 利用 VMD-SSA 将数据分解为趋势项、周期项和残差项。

步骤 3 对趋势项进行时间序列聚类分析,利用同簇共性特征识别单个测点的异常值。

步骤 4 将周期项划分为多个时间段,利用聚类算法识别异常值。

步骤 5 利用 iForest 算法对残差项进行异常值识别。

步骤 6 整合趋势项、周期项和残差项的异常值,取并集得到最终的异常值。

4 工程实例

为验证本文所提算法的有效性,选取 W 重力坝 2022 年 1 月 1 日~2024 年 12 月 31 日顺河向位移数据作为试验数据集,并手动添加异常值见图 1,图 1 中带 * 的文字为经过人为添加异常值的实测值和数据分解值,红色方框内的值为人为




图 1 人为添加异常与原始位移数据 VMD-SSA 分解图

Fig. 1 Artificially added anomalies and original data VMD-SSA decomposition diagram

添加的异常值。由图 1 可看出,添加随机噪声时,分解得到的趋势项和周期项数据与原始监测数据未发生明显变化,但残差项数据发生了明显跳动;添加趋势项或周期项数据时,分解得到的趋势项数据发生了明显变化。因此,利用 VMD-SSA 对监测数据进行分解并利用混合识别方法进行异常值识别是可行的。

此外,数据异常识别过程中,各算法的计算参数设置 VMD 的模式数为 5;惩罚因子为 2 000,收敛容差为 1×10^{-7} ,SSA 的窗口长度范围设置在 $N/5 \sim N/3$ 之间,K-means 算法的最大迭代次数为 300,iForest 算法中树的数量为 100 个,样本大小为 256 个^[11-14]。

4.1 趋势项与周期项异常识别

4.1.1 趋势项与周期项聚类分析

常用的聚类结果评价指标有肘部法则和轮廓系数两种^[15]。肘部法以每个数据点到所属聚类中心的距离平方和的斜率最大为最佳聚类数。肘部法则的扭曲度计算公式为:

$$d_k = \sum_{i=1}^k \sum \text{dist}(x, c_i)^2 \quad (14)$$

式中, d_k 为扭曲度; x 为聚类内的数据点; c_i 为每个聚类的中心。

轮廓系数通过样本的簇间不相似度和簇内不相似度对样本的聚类正确性进行评价。轮廓系数的计算公式为:

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad (15)$$

$$\text{其中} \begin{cases} a(i) = \frac{1}{|C_n| - 1} \sum_{i^* \in C_n, i^* \neq i} \text{dist}(i, i^*) \\ b(i) = \min_{1 \leq m \leq k, m \neq i} \frac{1}{|C_m|} \sum_{i^* \in C_m} \text{dist}(i, i^*) \end{cases} \quad (16)$$

式中, $b(i)$ 、 $a(i)$ 分别为样本 i 的簇间不相似度和样本 i 的簇内不相似度。

顺河向位移序列聚类分区结果见图 2。由图 2 可看出,轮廓系数随聚类数量的变化呈现明显的峰值特征,在聚类数 $k = 4$ 时达到最大值 0.592,表明此时类内紧密性和类间分离度达到最优平衡。扭曲度曲线呈现典型的“肘部”形态,在 $k = 4$ 时斜率变化率显著降低,符合最优聚类数的判定准则。因此确定最佳聚类数为 4。

4.1.2 聚类算法识别异常值的有效性分析

首先人为设定趋势项异常见图 3,并将多个测点数据进行聚类分析见图 4。由图 3、4 可看出,手动添加的趋势性异常值时间段被识别,如图




图 2 位移监测序列聚类评价指标

Fig. 2 Displacement sequence clustering evaluation metric

4 中聚类 3 的红色框所示,验证了多个测点的簇中心线和中心线的置信区间能有效识别测点的趋势性异常值。然后将相同测点的不同周期数据点进行聚类分析见图 5。由图 5 可看出,手动添加的周期性异常值时间段被有效识别出来,如图 5 中红色圈所示,验证了相同测点多个时间周期中心线和置信区间能够有效识别测点的周期性异常值。



图 3 人为构建异常值对比图

Fig. 3 Artificially added anomalies comparison




图 4 多测点最优簇标准化趋势项数据异常识别

Fig. 4 Anomaly detection in normalized trend component of optimal clusters for multiple sensors




图 5 单测点多周期标准化趋势项数据异常识别

Fig. 5 Multi-period normalized trend anomaly detection for single sensor

4.2 残差项异常值识别

当实测数据中存在离群型异常值时,VMD-SSA 能够在数据分解时将其标识到残差项数据中。本文进一步利用 iForest 算法验证残差项异常值的有效性,人为构建了图 6 所示的异常值。




图 6 实测数据人为异常对比图

Fig. 6 Monitoring data and artificial anomalies comparison

首先,将残差项数据标准化,确保数据在同一尺度上。接着,使用 iForest 算法对残差项数据进行训练。设置关键参数,包括树的数量、样本大小和异常分数阈值。最后,利用训练好的模型预测残差项中的异常点,输出每个数据点的异常分数。图 7 为多个测点标准化后残差项数据和基于 iForest 算法计算得到的每个数据的异常得分。由图 7 可看出,人为设定的多个异常值的异常得分与正常值的得分差异明显,在既有经验基础上将异常设定为 0^[16-17]。通过设置测点异常得分阈值,人为设定的异常值全被识别,证明了本文方法的有效性。




图 7 标准化残差项数据异常识别

Fig. 7 Standardized residual anomaly detection

4.3 多种算法识别多种类型异常值结果对比分析

为进一步证明本文提出算法的优越性,将所提算法与局部异常因子(LOF)和 K 最近邻算法(KNN)的识别结果进行对比。表 1 为各算法在不同评价指标下的计算值。由表 1 可看出,利用 VMD 对 SSA 的改进在异常值混合识别时精度更

表 1 测点异常值识别评价指标

Tab. 1 Anomaly detection evaluation metrics

评价指标	方法	EX1-3	EX1-7	EX2-4
P	本文方法	0.985	0.972	0.979
	LOF	0.940	0.903	0.924
	KNN	0.921	0.919	0.908
	SSA	0.966	0.953	0.947
R	本文方法	0.978	0.986	0.969
	LOF	0.912	0.884	0.921
	KNN	0.908	0.913	0.895
	SSA	0.933	0.958	0.922
F	本文方法	0.971	0.958	0.968
	LOF	0.928	0.905	0.932
	KNN	0.899	0.899	0.928
	SSA	0.945	0.912	0.944

高。尤其是在处理大坝监测数据的复杂异常模式时,该算法展现出更强的鲁棒性和准确性,其 F_1 值较 LOF、KNN 方法分别提高了 4.3%、7.2%,充分证实了本文所提方法在重力坝监测数据异常识别中的优越性。

5 结论

本文提出了一种基于 VMD-SSA-Kmeans-iForest 的重力坝监测数据异常值混合识别方法,该方法通过 VMD 优化 SSA 分解过程,提升了特征提取精度。构建的 K-means 与 iForest 协同识别框架实现了对趋势性、周期性和残差性异常的有效检测(F_1 达 97.3%),增强了复杂异常模式的识别能力,异常值识别准确率提升了 2.5%,为重力坝安全监测提供了一种可靠的诊断工具。

参考文献:

[1] 花胜强, 胡少英, 罗孝兵, 等. 大坝位移监测中的粗差剔除方法[J]. 水力发电, 2017, 43(9): 110-112. (HUA S Q, HU S Y, LUO X B, et al. A gross error elimination method for dam displacement monitoring[J]. Water power, 2017, 43(9): 110-112. (in Chinese))

[2] 齐智勇, 孙辅庭, 毛延翩, 等. 基于全卷积神经网络的大坝变形监测数据粗差识别方法研究[J]. 水电能源科学, 2023, 41(3): 87-90. (QI Z Y, SUN F T, MAO Y P, et al. Research on gross error detecting method of monitored dam deformation data based on fully convolutional networks[J]. Water resources and power, 2023, 41(3): 87-90. (in Chinese))

[3] 王岩博, 顾冲时, 石立, 等. 基于改进 IGGⅢ-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 Y B, GU C S, SHI L, et al. Gross error identification method for deformation monitoring data of concrete dams based on improved IGGⅢ-ELM method[J]. Advances in science and technology of water resources, 2023, 43(6): 89-95. (in Chinese))

[4] RONG Z, PANG R, XU B, et al. Dam safety monitoring data anomaly recognition using multiple-point model with local outlier factor[J]. Automation in construction, 2024, 159: 105290.

[5] 陈立秋, 顾冲时, 邵晨飞, 等. 基于相似测点对比的大坝变形监测数据粗差识别方法[J]. 水利水电科技进展, 2024, 44(4): 72-77. (CHEN L Q, GU C S, SHAO C F, et al. Gross error identification

- method for dam deformation monitoring data based on similar measurement point comparison[J]. Advances in science and technology of water resources, 2024, 44(4): 72-77. (in Chinese))
- [6] 郑霞忠, 陈国梁, 邹韬. 考虑时间序列关联的大坝监测异常数据清洗[J]. 水力发电, 2020, 46(4): 111-114, 125. (ZHENG X Z, CHEN G L, ZOU T. Cleaning of abnormal dam monitoring data considering time series association[J]. Water power, 2020, 46(4): 111-114, 125. (in Chinese))
- [7] 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 C Z. Research on adaptive identification method for abnormal data of dam monitoring based on association rules and machine learning[D]. Chongqing: Chongqing Jiaotong University, 2023. (in Chinese))
- [8] 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 S 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. (in Chinese))
- [9] 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, 98. (JIANG Q J, JIANG Z M, TANG D, et al. Gross error detection of slope safety monitoring data based on SSA-DBSCAN[J]. Journal of Changjiang River Scientific Research Institute, 2022, 39(4): 85-90, 98. (in Chinese))
- [10] 李元梦, 李登华, 丁勇. 基于 DBSCAN 的大坝安全监测异常数据检测算法[J]. 水电能源科学, 2024, 42(1): 149-152. (LI Y M, LI D H, DING Y. Abnormal data detection algorithm for dam safety monitoring based on DBSCAN[J]. Water resources and power, 2024, 42(1): 149-152. (in Chinese))
- [11] 李秉晨, 于惠钧, 刘靖宇. 基于 Kmeans 和 CEEMD-PE-LSTM 的短期光伏发电功率预测[J]. 水电能源科学, 2021, 39(4): 204-208. (LI B C, YU H J, LIU J Y. Prediction of short-term photovoltaic power generation based on Kmeans and CEEMD-PE-LSTM[J]. Water resources and power, 2021, 39(4): 204-208. (in Chinese))
- [12] 雷未, 王建, 吉同元, 等. 基于深度学习框架的长序列大坝监测缺失数据插补模型[J]. 水利水电科技进展, 2023, 43(6): 82-88. (LEI W, WANG J, JI T Y, et al. Long-series missing data interpolation model for dam monitoring based on deep learning framework[J]. Advances in science and technology of water resources, 2023, 43(6): 82-88. (in Chinese))
- [13] 欧阳慧泉, 杨峰, 单定军, 等. 基于 SSA-VMD-WDCNN 的水电机组故障诊断[J]. 水电能源科学, 2024, 42(12): 147-151. (OUYANG H Q, YANG F, SHAN D J, et al. Fault diagnosis of hydropower unit based on SSA-VMD-WDCNN[J]. Water resources and power, 2024, 42(12): 147-151. (in Chinese))
- [14] 徐浩, 刘怀利, 瞿暄. 基于孤立森林的取水数据异常值检测[J]. 水电能源科学, 2024, 42(9): 29-32, 59. (XU H, LIU H L, QU X. Detecting abnormal water extraction data based on isolation forest[J]. Water resources and power, 2024, 42(9): 29-32, 59. (in Chinese))
- [15] QIAN H M, ZHANG C, TAO C C, et al. Multi-scale entropy based damage detection for thermal protection structures with variation of ambient temperature[J]. Journal of intelligent material systems and structures, 2023, 34(10): 1211-1223.
- [16] LESOUPLE J, BAUDOIN C, SPIGAI M, et al. Generalized isolation forest for anomaly detection[J]. Pattern recognition letters, 2021, 149: 109-119.
- [17] 张瑜, 秦学, 彭浩. 基于平滑阈值与孤立森林的大坝监测数据异常检测[J]. 人民黄河, 2025, 47(3): 141-145. (ZHANG Y, QIN X, PENG H. Anomaly detection of dam monitoring data based on smoothing threshold and isolated forest[J]. Yellow River, 2025, 47(3): 141-145. (in Chinese))
- *****
- (上接第 216 页)
- [6] 王思如, 姚轶, 刘米雪, 等. 基于水动力模型的城市水网一体化优化方法及其应用[J]. 南水北调与水利科技(中英文), 2025, 23(5): 1079-1089. (WANG S R, YAO Y, LIU M X, et al. Optimization method and its application of urban water network integration based on hydrodynamic model[J]. South-to-north water transfers and water science & technology, 2025, 23(5): 1079-1089. (in Chinese))
- [7] 王文琪, 王思如, 罗嘉西, 等. 多水源补给的宿迁市黄河故道水量—水质耦合优化调控[J]. 人民黄河, 2023, 45(7): 68-72, 78. (WANG W Q, WANG S R, LUO J X, et al. Optimal regulation of coupling water quantity and water quality in old Yellow River channel in Suqian City with multi water supply[J]. Yellow River, 2023, 45(7): 68-72, 78. (in Chinese))
- [8] ZHONG H, WU S, YAN M, et al. Derivation of optimal scheduling strategies for large-scale inter-basin water transfer projects considering streamflow wet-dry encounter uncertainty of multiple reservoirs [J]. Journal of hydrology, 2025, 662(PA): 133784-133784.