

基于模态分解和分类去噪的大坝变形数据清洗方法

张宏瑞¹, 文丽娟², 曹 昕^{1,3}, 盛金保^{1,3}, 江 超^{1,3}, 祖安君^{1,3}

(1. 南京水利科学研究院大坝安全与管理研究所; 2. 高台县水务局; 3. 水利部大坝安全管理中心)

摘要:为解决大坝变形监测中的数据噪声干扰问题、提高监测数据质量,将灰狼优化(GWO)算法、变分模态分解(VMD)、小波阈值去噪(WTD)和S-G滤波器进行融合,提出了一种基于无监督学习的大坝变形数据清洗方法。该方法利用GWO算法对VMD的分解参数进行自适应寻优,并采用优化后的VMD将变形序列分解为多个本征模态函数(IMF),然后根据各IMF的样本熵对其进行分类,对高频IMF和中低频IMF采用差异化的去噪处理,组合重构得到清洗后的变形数据。某拱坝的实例验证结果表明:该方法在有效消除多频段噪声的同时,较好地保留了变形数据的统计特性,且对不同噪声水平均表现出鲁棒性;去噪后的序列作为训练样本,可提升点-区间预测模型的精度;该方法对不同长度的监测序列均具有良好的适用性。

关键词:大坝变形监测;数据噪声;模态分解;优化算法;分类去噪

中图分类号:TV698.1

文献标志码:A

文章编号:1006-7647(2026)05-0034-08

Dam deformation data denoising method based on modal decomposition and classification-based denoising//Zhang Hongrui¹, Wen Lijuan², Cao Xin^{1,3}, Sheng Jinbao^{1,3}, Jiang Chao^{1,3}, Zu Anjun^{1,3} (1. Dam Safety and Management Department, Nanjing Hydraulic Research Institute; 2. Gaotai County Water Affairs Bureau; 3. Dam Safety Management Center, Ministry of Water Resources)

Abstract: To address the problem of data noise interference in dam deformation monitoring and improve the quality of monitoring data, a dam deformation data cleaning method based on unsupervised learning is proposed by integrating the grey wolf optimizer (GWO) algorithm, variational mode decomposition (VMD), wavelet threshold denoising (WTD), and the Savitzky-Golay (S-G) filter. In this method, the decomposition parameters of VMD are adaptively optimized using the GWO algorithm, and the optimized VMD is employed to decompose the deformation sequence into multiple intrinsic mode functions (IMFs). Then, the IMFs are classified according to their sample entropy, and classification-based denoising is applied to the high-frequency IMFs and the medium- and low-frequency IMFs. Finally, the processed IMFs are reconstructed to obtain the cleaned deformation data. Case validation on an arch dam shows that the proposed method effectively eliminates noise across multiple frequency bands while well preserving the statistical characteristics of the deformation data, and exhibits robustness to different noise levels. The denoised sequence, when used as training samples, can improve the accuracy of the point-interval prediction model. In addition, the method has good applicability to monitoring sequences of different lengths.

Key words: dam deformation monitoring; data noise; modal decomposition; optimization algorithm; classification-based denoising

随着监测感知体系的持续发展,大坝的变形、渗流等结构响应变化能够被有效记录^[1]。监测数据既能实时反馈大坝结构状态,又可作为结构性态诊断和风险识别的基础^[2-3]。然而,受设备质量、环境条件、人为观测误差等多种因素影响,监测数据易被噪声污染,掩盖了大坝的真实行为特征^[4]。因此,

有效清洗变形数据中的噪声对提升监测数据的质量至关重要。

由于结构变形是坝体在水位波动、温度变化、材料老化等内外因素共同作用下的综合响应,变形数据往往呈现非线性和非稳态特性^[5-6]。为此,分析大坝变形行为时通常将原始序列分解为多个独立分量

基金项目:国家自然科学基金项目(52509173);国家重点研发计划项目(2024YFC3210604);中央级公益性科研院所基本科研业务费专项资金项目(Y725004)

作者简介:张宏瑞(2000—),男,硕士研究生,主要从事大坝安全健康诊断研究。E-mail:hrzhang27@foxmail.com

通信作者:江超(1984—),男,正高级工程师,硕士,主要从事水利水电工程安全监测与信息化研究。E-mail:290280772@qq.com

以降低数据复杂度。例如: Xu 等^[7]将位移分解为突变、季节和趋势变化部分,并定量分析了各自的变化规律; Song 等^[8]通过将非平稳信号分解为平稳信号,提出了基于“分解-重组”的缺失数据填补方法。对于去噪问题,数据分解的目的在于准确定位高频噪声成分。经验模态分解(EMD)及其变体^[9-10]能够将数据递归地分解为围绕局部极值的本征模态函数(IMF),但往往无法完全分离不同频率分量,易出现模态混叠和边界振荡现象^[11]。相比之下,变分模态分解(VMD)作为一种自适应分解方法,通过求解变分优化问题来实现序列分解,能够从频域角度更准确地定位和分离不同频率成分^[12]。Luo 等^[13]利用多变量 VMD 分解某拱坝时空变形数据,基于分解序列建立了多输出预测模型,显著提高了点预测精度; Wang 等^[14]通过 VMD 识别了大坝的非突变和突变行为,并结合云模型评估了大坝健康状态。尽管 VMD 在信号分解方面表现出色,但其分解能力高度依赖于两个关键参数(惩罚参数 γ 和模态数 K)^[15],若参数选择不当,易引发过度分解或分解不足问题,限制了方法的实用性^[16]。

除噪声定位外,合理选择去噪方法同样关键。小波阈值去噪(WTD)是小波分析中的经典算法,其原理为通过设定阈值滤除高频信号中的噪声^[17-18];而 Savitzky-Golay (S-G) 滤波器则在时域内实现去噪,能在保留原始信号形状、宽度等特征的基础上提高数据的整体平滑性^[19]。现有研究普遍认为噪声仅存在于高频 IMF 中,对中低频 IMF 则是直接保留,这种简化处理忽略了中低频 IMF 中潜在的干扰成分。

针对上述问题,本文提出了一种基于模态分解和分类去噪的大坝变形数据清洗方法。该方法首先通过灰狼优化(GWO)算法自动确定 VMD 的最优参数组合,避免人工预设参数导致分解结果出现大的偏差,然后针对样本熵分类后的高频 IMF 和中低频 IMF 分别采用 WTD 和 S-G 滤波器进行差异化去噪处理,组合重构得到清洗后的变形数据。该方法的有效性通过在某拱坝径向位移数据和仿真信号序列上的实证分析得到了验证。

1 研究方法

1.1 VMD

VMD 是一种自适应、非递归的信号处理方法^[20]。该方法通过构建变分优化框架,将原始信号 $f(t)$ 分解为 K 个具有不同中心频率和有限带宽的本征模态函数 $u_k(t)$ ($k=1,2,\dots,K$)。具体而言,首先通过希尔伯特变换获得各模态的解析信号,再通过

复指数调制将其频谱搬移至基带,以估计各模态的带宽,然后以各模态估计带宽之和最小为优化目标,并约束所有模态之和等于原始信号。据此建立如下约束变分模型:

$$\begin{cases} \min_{\{u_k(t)\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \|\partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \|^2_2 \right\} \\ \text{s. t. } \sum_{k=1}^K u_k(t) = f(t) \end{cases} \quad (1)$$

式中: ∂_t 为对时间 t 的偏导数算子; $\delta(t)$ 为狄拉克函数; j 为虚数单位; ω_k ($k=1,2,\dots,K$) 为第 k 个模态 $u_k(t)$ 的中心频率。

上述约束变分问题可通过交替方向乘子法进行迭代求解^[20]。VMD 的分解性能主要受惩罚因子 γ 和模态数 K 的影响。当 γ 取值不合理时可能导致模态混叠或过度平滑,而 K 设置不当则可能产生欠分解或冗余模态。因此,本文进一步采用 GWO 算法对这两个关键参数进行自适应寻优。

1.2 GWO 算法

GWO 算法^[21]是一种模拟灰狼群体等级结构和协同捕食行为的群智能优化算法。根据适应度值,将当前种群中的最优、次优和第三优个体分别记为 α 、 β 和 δ 狼,并由三者共同引导其余候选个体更新位置,以逐步逼近最优解。

在第 q 次迭代中,候选个体与 α 、 β 、 δ 狼之间的距离分别表示为:

$$\begin{cases} D_{\alpha,q} = |C_{1,q} \odot X_{\alpha,q} - X_q| \\ D_{\beta,q} = |C_{2,q} \odot X_{\beta,q} - X_q| \\ D_{\delta,q} = |C_{3,q} \odot X_{\delta,q} - X_q| \end{cases} \quad (2)$$

式中: X_q 为第 q 次迭代时候选个体的位置向量; $X_{\alpha,q}$ 、 $X_{\beta,q}$ 、 $X_{\delta,q}$ 分别为当前最优、次优和第三优个体的位置向量; $D_{\alpha,q}$ 、 $D_{\beta,q}$ 、 $D_{\delta,q}$ 为候选个体与 3 种优势个体之间的距离向量; $C_{i,q}$ ($i=1,2,3$) 为系数向量; $\odot$ 表示向量间的逐元素乘积。

进一步根据 3 种优势个体的位置,分别计算候选个体的潜在更新位置:

$$\begin{cases} X_{1,q} = X_{\alpha,q} - A_{1,q} \odot D_{\alpha,q} \\ X_{2,q} = X_{\beta,q} - A_{2,q} \odot D_{\beta,q} \\ X_{3,q} = X_{\delta,q} - A_{3,q} \odot D_{\delta,q} \end{cases} \quad (3)$$

式中: $X_{1,q}$ 、 $X_{2,q}$ 、 $X_{3,q}$ 分别为候选个体在 α 、 β 和 δ 狼引导下得到的潜在更新位置向量; $A_{i,q}$ ($i=1,2,3$) 为控制搜索方向和距离的系数向量。

候选个体在下一次迭代中的位置由上述 3 个潜在位置共同确定:

$$X_{q+1} = \frac{X_{1,q} + X_{2,q} + X_{3,q}}{3} \quad (4)$$

系数向量 $A_{i,q}$ 和 $C_{i,q}$ 分别为:

$$A_{i,q} = a_q (2r_{1i,q} - 1) \quad (5)$$

$$C_{i,q} = 2r_{2i,q} \quad (6)$$

式中: $r_{1i,q}$ 、 $r_{2i,q}$ 为各分量在 $[0, 1]$ 内随机取值的向量; a_q 为随迭代过程由 2 逐渐减小至 0 的控制参数。随着 a_q 减小, GWO 的搜索范围逐渐收缩, 使算法由较大范围的全局搜索逐渐转向当前优势解附近的局部搜索。

1.3 变形数据的自适应模态分解

针对大坝变形数据的非线性和非平稳特性, 前述 VMD 方法能够在频域内实现信号的自适应分解, 而 GWO 算法则可以解决 VMD 参数选择的主观性。在此基础上, 本文构建基于 GWO 优化 VMD 超参数的大坝变形数据分解策略。具体步骤如下:

a. 设定 GWO 的种群规模、最大迭代次数以及 VMD 惩罚因子 γ 和模态数 K 的搜索范围, 并随机初始化灰狼种群。每只灰狼的位置对应一组候选 VMD 参数 (γ, K) 。

b. 利用各候选参数组合对原始变形序列 $f(t)$ 进行 VMD 分解, 并计算分解所得 IMF 的包络熵^[22]。以包络熵作为 GWO 的适应度函数, 适应度值越小, 表明对应参数组合下 IMF 的能量分布越集中、随机性越低。根据各候选解的适应度值确定当前的 α 、 β 和 δ 狼, 并按照式 (2) ~ (6) 更新其余候选个体的位置。

c. 在每次迭代完成后, 更新控制参数并重新计算各候选参数组合的适应度, 直至达到最大迭代次数。最终, 将适应度最优灰狼对应的参数组合确定为 VMD 的最优参数 (γ_{opt}, K_{opt}) , 并利用该参数组合完成大坝变形序列的最终分解。

上述步骤中所涉及的包络熵计算公式为:

$$H_k = - \sum_{i=1}^N p_i \ln p_i \quad (7)$$

$$p_i = E_i / \sum_{j=1}^N E_j \quad (8)$$

式中: H_k 为第 k 个 IMF 的包络熵值; N 为采样点数; E_i 为第 i 个采样点的包络幅值; p_i 为 E_i 归一化后的概率分布。

在获得 VMD 分解结果后, 通过计算各 IMF 的样本熵^[23]来量化其复杂度和随机程度, 以此作为后续去噪方法选择的判据。Dhandapani 等^[24]指出, 熵值大于 0.6 的 IMF 分量随机性较强, 主要包含高频噪声成分, 而熵值小于 0.6 的 IMF 分量规律性较强, 包含主要的变形信息。因此, 本文选择 0.6 作为区分高频 IMF 和中低频 IMF 的样本熵阈值。

1.4 小波阈值去噪

噪声数据通常表现为高不确定性的部分, 对应

波动较大的高频 IMF。本文采用小波阈值去噪 (WTD)^[25]方法处理高频 IMF 分量, 以消除集中在高频部分的噪声分量。WTD 的流程可概括为:

a. 小波分解。选择合适的小波基函数和分解层数, 对高频 IMF 进行多尺度小波分解后得到一系列小波系数, 常见的基函数类型有 Coiflets、Morlet、Daubechies 等。

b. 阈值处理。小波阈值函数包括硬阈值函数和软阈值函数, 其中硬阈值会将小于阈值的小波系数归零, 这可能导致去噪后的信号在某些点上出现伪吉布斯现象, 而软阈值是将超过预设值的小波系数按照固定幅度进行缩减, 重构后的信号具有更好的连续性, 因此本文采用软阈值函数作为小波阈值去噪的阈值函数。

c. 小波重构。对经过阈值处理的小波系数进行逆小波变换, 重构得到 WTD 处理后的高频 IMF。

1.5 S-G 滤波器

S-G 滤波器^[26]是一种基于多项式拟合的平滑滤波技术, 通过在滑动窗口内对数据点进行最小二乘拟合来实现平滑, 对于每个数据点, S-G 滤波器选取其所属滑动窗口内的数据点, 然后用指定阶数的多项式对这些点进行拟合, 最后用拟合多项式在中心点的值作为原始数据点的平滑结果:

$$\hat{x}_j = \frac{1}{L} \sum_{i=-m}^m a_i x_{j+i} \quad (9)$$

式中: $\hat{x}_j$ 为位置 j 处滤波后的信号; a_i 为第 i 个卷积系数; x_{j+i} 为 $j+i$ 处的原始信号; m 为窗口半径; L 为归一化因子, $L = 2m + 1$ 。

相比于移动平均等简单滤波方法, S-G 滤波器在平滑信号的同时能够更好地保持信号的峰值形状和边缘特征, 不会产生明显的峰值展宽或位移, 因此更适用于对中低频 IMF 内干扰信息的平滑处理。

1.6 实施步骤

根据上述理论与方法, 提出一种基于模态分解和分类去噪的大坝变形数据清洗方法, 具体的实施流程如图 1 所示。

2 工程实例验证

2.1 工程背景及数据集

某双曲拱坝始建于 1957 年, 其最大坝高为 45.0 m, 坝顶高程为 239.0 m, 共有 13 个坝段, 大坝下游立面见图 2。为监测大坝的结构安全状况, 坝体内外配置了全面的监测系统, 包括垂线、压力计和渗流测量装置等。首次蓄水后定期采集监测数据并在延迟 48 h 后自动检查测量结果, 如果出现可疑或错误的测量结果, 则重新测量并校准数据, 因此数据




图1 去噪流程




图2 大坝下游立面及监测设施布置(单位: m)

库中存储的监测数据未受到显著噪声干扰,可选作基准测试数据。

为验证所提出方法的去噪能力,选择CB2、CB3测点采集的径向位移数据作为建模对象,数据的时间跨度为2000年1月19日至2012年12月3日,共656组数据。为模拟噪声环境,文中以信噪比^[27]为控制参数,向原始数据中添加噪声,其加噪过程如下:

$$f'(t) = f(t) + n(t) \quad (10)$$

其中

$$n(t) \sim N\left(0, \frac{\bar{x}^2}{10S_{\text{dB}}/10}\right)$$

式中: $f'(t)$ 为加噪后的数据; $f(t)$ 为原始数据; $n(t)$ 为高斯白噪声; $\bar{x}^2$ 为原始数据的均方差; S_{dB} 为预设

的信噪比。由 $n(t)$ 的表达式可知,噪声水平与信噪比呈负相关关系,即 S_{dB} 数值越小,噪声方差越大,对应的噪声水平越高。


为模拟不同程度的噪声,对CB2、CB3测点的原始位移数据分别添加 S_{dB} 为10、15、18 dB的噪声,构建了3种不同含噪水平的数据集,分别记为CB2_10dB、CB2_15dB、CB2_18dB、CB3_10dB、CB3_15dB、CB3_18dB,结果如图3所示。从图3可以观察到,随着信噪比的递减,变形信号的细节特征逐渐被噪声掩盖,数据的随机波动幅度增强,这为方法的鲁棒性验证提供了多层次的测试基准。

2.2 去噪过程分析


以CB3_18dB噪声数据为例介绍该方法的去噪流程。在GWO算法优化参数(γ, K)前,灰狼数量和最大迭代次数分别设为45和15,惩罚因子 γ 和模态数 K 的寻优空间分别为 $[100, 5000]$ 和 $[3, 15]$,构建了以最小化包络熵为适应度函数的VMD参数优化方法,得到的最优参数为 $\gamma = 1404$ 和 $K = 6$,优化后的VMD用于分解CB3_18dB,结果见图4。

从图4(b)可以看出,优化后的VMD将CB3_18dB分解为6个在频域上呈现清晰边界划分的IMF分量,大致分别对应于 $[0, 5]$ 、 $[5, 15]$ 、 $[15, 35]$ 、 $[35, 60]$ 、 $[190, 240]$ 、 $[270, 330]$ 的独立频率区间,有效避免了EMD方法中易出现的模态混叠。图4(a)中高阶IMF(IMF5、IMF6)包含较高的频率和较多毛刺噪声,中低频IMF(IMF1~IMF4)则显示出较低的频率和更清晰的变化模式。进一步计算各IMF的样本熵,IMF1~IMF6的样本熵分别为0.036、0.216、0.446、0.427、0.673和0.632。其中,IMF5和IMF6的样本熵均大于0.6,而IMF1~IMF4均小于0.6,与图4所反映的频率及随机波动特征基本一致。因此,将IMF5和IMF6划分为高频IMF,将IMF1~IMF4划分为中低频IMF,并据此选择相应的去噪方法。

为准确去除噪声,IMF5、IMF6采用WTD,其超



(a) CB2序列



(b) CB3序列

图3 不同含噪水平的数据集




图4 CB3_18dB 的分解结果

参数取值如下:小波基函数选为 Daubechies 4,分解层数为 6;IMF1~IMF4 采用 S-G 滤波器平滑处理,滑动窗口的长度为 7,多项式拟合阶数为 3。重构处理后的 IMF 得到清洗结果,去噪前后的对比见图 5,其中 CB3_去噪后表示去噪后的 CB3 数据。

析发现,含噪数据的峰值较原始数据偏高 14.6%,均值偏差为 2.2%,而去噪后数据的峰值偏差仅为 3.3%,均值偏差降至 1.7%。去噪后的标准差、偏度和峰度与原始数据的偏差分别为 1.0%、1.1%和 2.1%,均明显小于含噪数据的对应偏差,表明去噪结果较好地恢复了 CB3 的整体分布形状。

表1 CB3 去噪前后的统计特征

序列	峰值/mm	均值/mm	标准差/mm	偏度	峰度
CB3	3.9100	-0.3067	2.7154	-0.0947	-1.5048
CB3_18dB	4.4772	-0.2998	2.6487	-0.1061	-1.4346
CB3_去噪后	4.0368	-0.3015	2.7434	-0.0937	-1.4728

2.3 去噪方法对比

为验证本文提出的大坝变形数据清洗方法 (GVWS) 在不同变形测点和不同含噪水平下的性能优越性,选择 EMD-WTD^[28]、EMD-PSO-VMD^[29]、SSA-VMD-DFA^[30] 作为对比方法,并通过均方根误差 (RMSE)、平均绝对误差 (MAE)、决定系数 (R^2) 作为去噪效果的定量评价指标, RMSE、MAE 越小, R^2 越大,则模型的性能越好,量化结果如图 6 所示。

由图 6 可知,随着噪声程度的增加,这 4 种方法的去噪能力均会退化,但相较于对比方法, GVWS 去噪后数据的 RMSE、MAE 更小, R^2 更大,因此和原始数据之间的偏差最小。由此可知,对于非线性和非平稳的大坝变形数据,准确的模态分解以及合适的去噪方法对于去噪性能都有重要影响。此外, GVWS 方法的性能受信噪比的影响最小,这种鲁棒性对于保障不同环境条件下的数据可靠性至关重要。

3 讨论

3.1 预处理对变形预测的影响

数据去噪属于大坝变形建模的预处理环节,为验证数据清洗对变形预测分析的影响,设计了对比




图5 CB3 去噪前后的对比

由图 5(a) 可知,在 18dB 的噪声水平下,变形数据出现波形畸变,且序列中有许多的毛刺,信号失真严重。去噪后,尽管相较于原始数据仍存在微小偏差,但成功复现了变形序列的局部变化情况(如局部放大图所示)。图 5(b) 通过散点关系展示了去噪前后数据间的相关性,可见去噪后散点分布更紧密,与原始数据没有明显偏差。

CB3 去噪前后的统计特征变化见表 1。对比分




图6 去噪方法的性能对比

试验来评估去噪处理对大坝变形点-区间预测性能的改善效果。具体来说,试验基于水压-季节-时间理论构建了极限学习机^[31]预测模型,分别使用 CB3 原始数据、CB3_18dB 噪声数据以及 CB3_去噪后数据作为训练集,使用 CB3 真实变形数据作为测试集,以 2011 年 1 月 3 日为分界点划分训练集和测试集,极限学习机的隐层单元数设置为 50。

为全面评估预测性能,采用 RMSE、MAE、 R^2 评价点预测精度,同时引入平均中心偏差 (MCD) 和预测区间归一化平均宽度 (NMPIW)^[32] 量化区间预测的性能。NMPIW 和 MCD 越小,区间预测的不确定性越低,结果可靠性越高。

不同训练集的点-区间预测性能结果和预测曲线分别见表 2 和图 7。从表 2 和图 7 可以看出,训练数据的质量直接影响模型的预测性能。即使去噪后的预测性能未完全恢复至原始水平,但相较于直接使用含噪数据,训练集去噪后的预测性能明显改善:点预测的 RMSE 降低 2.95%,区间预测的 NMPIW 降低 12.79%。性能的差异可以解释为含噪训练数据掩盖了大坝的实际变形行为,干扰模型对真实变

表2 不同训练集的点-区间预测性能

训练集	点预测			区间预测	
	RMSE/mm	MAE/mm	R^2	MCD/mm	NMPIW
CB3	0.4219	0.3531	0.9418	0.3531	1.0246
CB3_18dB	0.4477	0.3669	0.9345	0.3669	1.3650
CB3_去噪后	0.4345	0.3641	0.9383	0.3641	1.1904




图7 不同训练集得到的预测曲线

形规律的学习,导致预测结果离散度增大;而由于去噪处理能够复现真实数据特征,使模型能够准确捕

捉变形演化模式,从而提高了点预测精度并收窄了预测区间。

3.2 通用性分析

上述试验分析基于特定工程的大坝变形数据展开,为验证该方法在更广泛的大坝监测项目中的去噪通用性,设计了仿真信号进行验证分析。考虑变形、应力、渗流等结构响应主要受上游库水位、温度和时效因素的综合影响^[33],构建的仿真信号采用两组周期项模拟周期性变化的库水位和温度荷载作用,采用两组趋势项模拟时效荷载的作用^[34]。结构响应的仿真序列生成方法为:

$$s = 10\sin\left(\frac{2\pi h}{365}\right) + 5\cos\left(\frac{4\pi h}{365}\right) + \frac{h}{100} + \ln\left(\frac{h}{100}\right)$$

(11)

式中: h 为仿真序列的信号数量。

试验分别选取 1 000、2 000 和 3 000 个信号的仿真序列构建测试样本,向各仿真序列添加信噪比为 18 dB 的高斯白噪声,相关参数设置与 2.2 节相同,去噪前后与原序列的差异大小见表 3。

表 3 去噪前后的各仿真信号评价指标

信号数量	去噪前后	RMSE/mm	MAE/mm	R^2
1 000	去噪前	1.136 8	0.892 0	0.949 7
	去噪后	0.526 8	0.421 0	0.989 2
2 000	去噪前	1.960 4	1.542 7	0.931 8
	去噪后	0.615 2	0.489 0	0.993 3
3 000	去噪前	2.741 6	2.160 3	0.927 3
	去噪后	0.803 8	0.636 3	0.993 8

从表 3 可以发现,所提出的方法在不同长度的仿真序列上均表现出良好的去噪能力。随着序列长度从 1 000 增加到 3 000, RMSE 和 MAE 的改善程度从约 53% 逐步提升至约 70%, R^2 的提升幅度也从 4.16% 增加到 7.17%, 表明该方法对于较长序列具有更显著的去噪效果,同时随着数据量的增加其性能表现更加稳定。

4 结 语

本文提出了一种基于模态分解和分类去噪的大坝变形数据清洗方法,在真实变形监测数据和仿真信号上的验证分析表明:采用 GWO 算法优化 VMD 参数实现了模态自适应分解,优化后的 VMD 将变形序列分解为频率区间清晰的 IMF 分量,有效避免了模态混叠现象;结合 WTD 和 S-G 滤波器的差异化处理,在去除高频噪声的同时消除了中低频分量中的干扰成分,较好地保留了真实变形数据的统计特征和变化规律;在不同的噪声环境下,该方法相较于对比方法具有更强的鲁棒性, R^2 值保持在 0.93 以上;将清洗后的数据用于变形预测建模,区间预测的

NMPIW 和 MCD 更小,降低了变形分析任务的不确定性;该方法对不同长度的序列均具有良好的适应性,且性能指标的改善程度随着序列长度增加而提升。

参考文献:

[1] Najih H, Aboulhassane A, Moustachi O E K. Contributions of artificial intelligence to dam monitoring: a literature review[J]. Asian Journal of Civil Engineering, 2025, 26 (12): 4925-4940.

[2] 葛盼猛,陈波,刘庭赫,等. 基于 KPCA-ICFSFDP-MOGP 的拱坝多测点变形数据预处理及预测方法[J]. 水利水电科技进步, 2023, 43 (4): 92-97. (Ge Panmeng, Chen Bo, Liu Tinghe, et al. Preprocessing and prediction method for multi-point deformation data of arch dams based on KPCA-ICFSFDP-MOGP [J]. Advances in Science and Technology of Water Resources, 2023, 43 (4): 92-97. (in Chinese))

[3] Prakash G, Dugalam R, Barbosh M, et al. Recent advancement of concrete dam health monitoring technology: a systematic literature review[J]. Structures, 2022, 44: 766-784.

[4] 冯燕明,何杨杨,左生龙,等. 大坝安全监测数据降噪的流形学习方法[J]. 水利水电科技进步, 2024, 44 (4): 59-64. (Feng Yanming, He Yangyang, Zuo Shenglong, et al. Manifold learning method for denoising dam safety monitoring data[J]. Advances in Science and Technology of Water Resources, 2024, 44 (4): 59-64. (in Chinese))

[5] 石佳晨,岳春芳,朱明远,等. 基于 CEEMDAN-改进小波阈值的大坝变形数据处理方法[J]. 水利水电科技进步, 2024, 44 (5): 80-86. (Shi Jiachen, Yue Chunfang, Zhu Mingyuan, et al. Dam deformation data processing method based on CEEMDAN and improved wavelet threshold[J]. Advances in Science and Technology of Water Resources, 2024, 44 (5): 80-86. (in Chinese))

[6] 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))

[7] Xu Xiaoyan, Yang Jie, Ma Chunhui, et al. Segmented modeling method of dam displacement based on BEAST time series decomposition[J]. Measurement, 2022, 202: 111811.

[8] Song Jintao, Yang Zhaodi, Li Xinru. Missing data imputation model for dam health monitoring based on mode decomposition and deep learning[J]. Journal of Civil Structural Health Monitoring, 2024, 14 (5): 1111-

- [9] 付思韬,赖宇杰,顾冲时,等. 基于 EEMD-AFSA-CNN 的混凝土坝变形预测模型[J]. 水利水电科技进展,2026,46(1):48-53. (Fu Sitao, Lai Yujie, Gu Chongshi, et al. Concrete dam deformation prediction model based on EEMD-AFSA-CNN [J]. Advances in Science and Technology of Water Resources, 2026, 46(1):48-53. (in Chinese))
- [10] 欧斌,张才溢,陈德辉,等. 基于 EMD-小波阈值-LSTM 模型的混凝土坝变形预测[J]. 排灌机械工程学报,2025,43(4):379-386. (Ou Bin, Zhang Caiyi, Chen Dehui, et al. Deformation prediction of concrete dam based on EMD-wavelet threshold-LSTM model [J]. Journal of Drainage and Irrigation Machinery Engineering, 2025, 43(4):379-386. (in Chinese))
- [11] 丰少伟,柴凯,杨云生. 基于 SVRM 极值延拓的 EMD 端点效应抑制方法[J]. 兵工自动化,2024,43(3):32-37. (Feng Shaowei, Chai Kai, Yang Yunsheng. EMD end effect suppression method based on SVRM extremum extension [J]. Ordnance Industry Automation, 2024, 43(3):32-37. (in Chinese))
- [12] 陈永平,韩韬,邱超,等. 基于调和分析及 VMD-LSTM 混合模型的甬江河口水位预报方法[J]. 河海大学学报(自然科学版),2025,53(2):1-10. (Chen Yongping, Han Tao, Qiu Chao, et al. Water level forecasting method for the Yongjiang River Estuary based on harmonic analysis and VMD-LSTM hybrid model [J]. Journal of Hohai University (Natural Sciences), 2025, 53(2):1-10. (in Chinese))
- [13] Luo Shaoyang, Wei Bowen, Chen Liangjie. Multi-point deformation monitoring model of concrete arch dam based on MVMD and 3D-CNN [J]. Applied Mathematical Modelling, 2024, 125:812-826.
- [14] Wang Yakun, Xiang Yan, Dai Bo, et al. Dam early warning model based on structural anomaly identification and dynamic effect variables selection [J]. Structures, 2025, 74:108507.
- [15] 吴挺玮,潘罗平,安学利. 融合 HO-VMD 的水电机组摆度信号消噪方法[J]. 水力发电学报,2024,43(12):107-115. (Wu Tingwei, Pan Luoping, An Xueli. Noise reduction method of vibration signals from hydroelectric generators based on HO-VMD [J]. Journal of Hydroelectric Engineering, 2024, 43(12):107-115. (in Chinese))
- [16] 许秋鸿,刘晓青. 基于 VMD-XGBoost-GRU 模型的危岩体变形预测[J]. 水利水电科技进展,2024,44(2):92-98. (Xu QiuHong, Liu Xiaoqing. Deformation prediction of dangerous rock mass based on VMD-XGBoost-GRU model [J]. Advances in Science and Technology of Water Resources, 2024, 44(2):92-98. (in Chinese))
- [17] Zhang Caiyi, Fu Shuyan, Ou Bin, et al. Prediction of dam deformation using SSA-LSTM model based on empirical mode decomposition method and wavelet threshold noise reduction [J]. Water, 2022, 14(21):3380.
- [18] Guo Yingjia, You Zongzhe, Wei Bowen. Working mode identification method for high arch dam discharge structure based on improved wavelet threshold-EMD and RDT algorithm [J]. Water, 2022, 14(22):3735.
- [19] Gu Chongshi, Wu Binqing, Chen Yijun. A high-robust displacement prediction model for super-high arch dams integrating wavelet de-noising and improved random forest [J]. Water, 2023, 15(7):1271.
- [20] Dragomiretskiy K, Zosso D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3):531-544.
- [21] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer [J]. Advances in Engineering Software, 2014, 69:46-61.
- [22] 王薇,程忠耀,向延念,等. 基于 RIME-VMD 联合小波阈值的爆破振动信号去噪方法[J]. 铁道科学与工程学报,2026,23(1):465-479. (Wang Wei, Cheng Zhongyao, Xiang Yannian, et al. Blasting vibration signal denoising method based on RIME-VMD combined wavelet threshold [J]. Journal of Railway Science and Engineering, 2026, 23(1):465-479. (in Chinese))
- [23] Liu Mingkai, Wen Zhiping, Su Huaizhi. Deformation prediction based on denoising techniques and ensemble learning algorithms for concrete dams [J]. Expert Systems with Applications, 2024, 238:122022.
- [24] Dhandapani R, Mitiche I, McMeekin S, et al. Enhanced partial discharge signal denoising using dispersion entropy optimized variational mode decomposition [J]. Entropy, 2021, 23(12):1567.
- [25] Chang S G, Yu Bin, Vetterli M. Adaptive wavelet thresholding for image denoising and compression [J]. IEEE Transactions on Image Processing, 2000, 9(9):1532-1546.
- [26] Savitzky A, Golay M J E. Smoothing and differentiation of data by simplified least squares procedures [J]. Analytical Chemistry, 1964, 36(8):1627-1639.
- [27] 朱亦鹏,贾东振,何秀凤. 基于 ICEEMDAN 的 GNSS 大坝变形监测去噪方法[J]. 测绘科学,2025,50(6):64-70. (Zhu Yipeng, Jia Dongzhen, He Xiufeng. Denoising method for GNSS dam deformation monitoring based on ICEEMDAN [J]. Science of Surveying and Mapping, 2025, 50(6):64-70. (in Chinese))
- [28] Li Xue, Gong Zibang, Bao Jinfeng, et al. Intelligent recognition of boulders in shield tunnels based on GPR dataset optimization using SE-EMD-WTD [J]. Journal of Applied Geophysics, 2025, 238:105717.

(下转第 50 页)

- Sciences), 2019, 47(6): 514-522. (in Chinese))
- [20] 王瑞骏, 李阳, 丁占峰. 堆石料流变模型参数敏感性分析的正交试验法[J]. 水利学报, 2016, 47(2): 245-252. (Wang Ruijun, Li Yang, Ding Zhanfeng. The sensitivity analysis of seven-parameter rockfill rheological model based on the orthogonal test method [J]. Journal of Hydraulic Engineering, 2016, 47(2): 245-252. (in Chinese))
- [21] 陈生水, 阎志坤, 傅中志, 等. 特高面板砂砾石坝结构安全性论证[J]. 岩土工程学报, 2017, 39(11): 1949-1958. (Chen Shengshui, Yan Zhikun, Fu Zhongzhi, et al. Evaluation of safety performance of extremely high slab-faced gravel dams [J]. Chinese Journal of Geotechnical Engineering, 2017, 39(11): 1949-1958. (in Chinese))
- [22] 李国英, 米占宽, 傅华, 等. 混凝土面板堆石坝堆石料流变特性试验研究[J]. 岩土力学, 2004, 25(11): 1712-1716. (Li Guoying, Mi Zhankuan, Fu Hua, et al. Experimental studies on rheological behaviors for rockfills in concrete faced rockfill dam [J]. Rock and Soil Mechanics, 2004, 25(11): 1712-1716. (in Chinese))
- [23] 蒋水华, 李典庆, 周创兵, 等. 考虑自相关函数影响的边坡可靠度分析[J]. 岩土工程学报, 2014, 36(3): 508-518. (Jiang Shuihua, Li Dianqing, Zhou Chuangbing, et al. Slope reliability analysis considering effect of autocorrelation functions [J]. Chinese Journal of Geotechnical Engineering, 2014, 36(3): 508-518. (in Chinese))
- [24] Tan Xiaohui, Wang Xue, Khoshnevisan S, et al. Seepage analysis of earth dams considering spatial variability of hydraulic parameters [J]. Engineering Geology, 2017, 228: 260-269.
- [25] Zhu Bin, Pei Huaifu, Yang Qing. Reliability analysis of submarine slope considering the spatial variability of the sediment strength using random fields [J]. Applied Ocean Research, 2019, 86: 340-350.
- [26] 李占超, 侯会静. 大坝安全监控指标理论及方法分析[J]. 水力发电, 2010, 36(5): 64-67. (Li Zhanchao, Hou Huijing. Theory and methods on dam safety monitoring indexes [J]. Water Power, 2010, 36(5): 64-67. (in Chinese))
- [27] Chen Jianyun, Liu Pengfei, Xu Qiang, et al. Seismic analysis of hardfill dams considering spatial variability of material parameters [J]. Engineering Structures, 2020, 211: 110439.
- [28] 马春辉. 基于离散元的堆石料宏细观参数智能反分析及其工程应用研究[D]. 西安: 西安理工大学, 2020.
- [29] 温立峰, 柴军瑞, 许增光, 等. 面板堆石坝性状的初步统计分析[J]. 岩土工程学报, 2017, 39(7): 1312-1320. (Wen Lifeng, Chai Junrui, Xu Zengguang, et al. Preliminary statistical analysis of behavior of concrete face rockfill dams [J]. Chinese Journal of Geotechnical Engineering, 2017, 39(7): 1312-1320. (in Chinese))
- [30] 谢晓华, 李国英. 成屏混凝土面板堆石坝应力变形分析[J]. 岩土工程学报, 2001, 23(2): 243-246. (Xie Xiaohua, Li Guoying. Stress-deformation analysis of Chengping concrete-faced rockfill dam [J]. Chinese Journal of Geotechnical Engineering, 2001, 23(2): 243-246. (in Chinese))
- [31] 朱纯祥, 梁林林, 唐国峰. 莲花混凝土面板堆石坝监测成果分析[J]. 水力发电, 2000(4): 49-52. (Zhu Chunxiang, Liang Linlin, Tang Guofeng. Analysis on the observation results of Lianhua concrete facing rockfill dam [J]. Water Power, 2000(4): 49-52. (in Chinese))

(收稿日期: 2025-05-20 编辑: 熊水斌)

(上接第 41 页)

- [29] Li Chengjun, Wu Yacen, Lin Haijun, et al. ECG denoising method based on an improved VMD algorithm [J]. IEEE Sensors Journal, 2022, 22(23): 22725-22733.
- [30] Xu Deming, Wang Yuan, Huang Jingqi, et al. Multi-step prediction model enhanced by adaptive denoising and encoder-decoder for shield machine cutterhead torque in complex conditions [J]. Tunnelling and Underground Space Technology, 2025, 158: 106398.
- [31] 张宏瑞, 江超, 盛金保, 等. 基于 IJTIL-WELM 的混凝土坝变形自适应预测方法[J]. 水利水电工程学报, 2026(3): 128-137. (Zhang Hongrui, Jiang Chao, Sheng Jinbao, et al. Adaptive method for predicting concrete dam deformation based on IJTIL-WELM [J]. Hydro-Science and Engineering, 2026(3): 128-137. (in Chinese))
- [32] Zhu Qiannan, Chang Pengxia, Zhu Tian, et al. Daily streamflow interval predictions up to 30 days ahead based on multi-timescale nested strategy and multi-objective walrus optimizer [J]. Journal of Hydrology, 2025, 652: 132646.
- [33] Wang Shaowei, Gu Chongshi, Liu Yi, et al. Displacement observation data-based structural health monitoring of concrete dams: a state-of-art review [J]. Structures, 2024, 68: 107072.
- [34] 陈斯煜, 盛金保, 林潮宁, 等. 基于 OVMD 的大坝变形监测数据预处理方法[J]. 水利水运工程学报, 2025(3): 139-147. (Chen Siyu, Sheng Jinbao, Lin Chaoning, et al. A preprocessing method for dam deformation monitoring data based on OVMD [J]. Hydro-Science and Engineering, 2025(3): 139-147. (in Chinese))

(收稿日期: 2025-06-17 编辑: 俞云利)