

大坝安全监测数据降噪的流形学习方法

冯燕明¹, 何杨杨^{2,3}, 左生龙⁴, 张 帅¹, 徐 朗³, 苏怀智^{2,3}

(1. 中国电建集团昆明勘测设计研究院有限公司, 云南 昆明 650032; 2. 河海大学水灾害防御全国重点实验室, 江苏 南京 210098; 3. 河海大学水利水电学院, 江苏 南京 210098; 4. 中国电建集团国际工程有限公司, 北京 100089)

摘要:针对大坝变形、渗流、应力应变等安全监测数据难以避免受到噪声污染,且传统线性降噪方法去噪效果不佳的问题,提出了基于相空间重构与流形学习相组合的大坝安全监测数据非线性降噪方法。该方法在重构大坝安全监测数据时间序列相空间的基础上,通过交叉应用局部切空间排列方法与极大似然估计、自适应邻域等方法,以重构的相空间为桥梁,提取大坝安全监测数据序列深层次信息,得到降噪后的大坝安全监测数据。工程实测数据验证结果表明,相比小波软阈值法和固定邻域-LTSA法,本文提出的方法降噪效果更优,具有一定的工程应用价值。

关键词:大坝安全; 监测数据; 降噪处理; 流形学习; 相空间重构

中图分类号:TV698.1

文献标志码:A

文章编号:1006-7647(2024)04-0059-06

Manifold learning method for denoising dam safety monitoring data/FENG Yanming¹, HE Yangyang^{2,3}, ZUO Shenglong⁴, ZHANG Shuai¹, XU Lang³, SU Huaizhi^{2,3} (1. POWERCHINA Kunming Engineering Corporation Limited, Kunming 650032, China; 2. The National Key Laboratory of Water Disaster Prevention, Hohai University, Nanjing 210098, China; 3. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China; 4. POWERCHINA International Group Limited, Beijing 100089, China)

Abstract: The noise pollution cannot be avoided for dam deformation, seepage, stress-strain, and other safety monitoring data. It is difficult to achieve excellent denoising effect for the traditional linear noise reduction method. On the basis of reconstructing the phase space of dam safety monitoring data time sequences, with the cross application of local tangent space alignment method, maximum likelihood estimate, adaptive neighborhood and other methods, using the reconstructed phase space as a bridge, and through the extraction of deep information of the monitoring data sequences, the denoised data sequences of dam safety monitoring is obtained. Based on the application of prototype test data, it is evident that the noise reduction effect of the method proposed in this paper is superior to that of the wavelet soft-thresholding method and the fixed neighborhood local tangent space alignment (LTSA) method, demonstrating certain value for engineering applications.

Key words: dam safety; measured data; noise reduction; manifold learning; phase space reconstruction

大坝变形、渗流、应力应变等安全监测数据容易受到来自环境因素、仪器误差、采集因素、人工误差等的噪声污染。噪声的存在干扰了真实信号的提取,使得无法辨识出真实信号的特征,甚至导致监测数据无法真实反映大坝实际工作性态。消除大坝安全监测数据中的噪声干扰是科学构建大坝安全监控模型、拟定监控指标的基础^[1]。大坝安全监测数据降噪方法总体可分为线性降噪和非线性降噪两类。大坝监测数据多为具有非平稳特征的非线性时间序列,采用线性降噪方法常难以达到较好的效果。目

前常用的大坝安全监测数据非线性降噪方法有小波分析方法、经验模态分解法等^[2-5]。小波分析方法在时域和频域的分析中具有优良的局部化特性^[6],但其降噪效果很大程度上取决于小波基及分解尺度的选择,这两个元素常采用试算的方法确定,具有较强的主观性。经验模态分解法能够根据所分析的信号自适应生成固有模态函数,具有较高的信噪比和良好的时频聚焦性,但其存在端点效应、拟合过冲、模态混叠等固有缺陷^[7]。

大坝安全监测数据时间序列可视作由混沌系统

基金项目:国家自然科学基金重点项目(52239009);云南省水利水电工程安全重点实验室开放课题基金项目(202302AN360003);中国电力建设股份有限公司重点科技项目(DJ-ZDXM-2021-11)

作者简介:冯燕明(1986—),男,高级工程师,硕士,主要从事水利水电工程安全设计工作。E-mail:541412389@qq.com

通信作者:苏怀智(1973—),男,教授,博士,主要从事涉水工程安全防控与提能延寿研究。E-mail:su_huaizhi@hhu.edu.cn

产生的一维混沌时间序列,可通过恢复混沌系统信息,实现对大坝安全监测数据的预处理^[8]。相空间重构是分析非线性动力学系统的有效方法,将其与流形学习方法结合,能对一维大坝安全监测数据进行深层次的数据挖掘。基于此理念,本文提出了一种大坝安全监测数据时间序列相空间降维去噪的流形学习方法,通过将一维大坝安全监测数据重构至高维相空间,利用流形学习方法中的局部切空间排列(local tangent space alignment, LTSA)算法改进得到的自适应邻域-LTSA 算法获得数据点嵌入在高维空间的低维流形和相应的嵌入映射,进而通过重构主流形和相空间重构逆运算得到降噪后的大坝安全监测数据信息。

1 大坝安全监测数据时间序列的相空间重构

本文利用相空间重构方法将一维大坝安全监测数据时间序列构造为高维相空间,进而基于混沌吸引子在高维相空间中有特定轨迹的特征将有规律的轨迹恢复,通过特征轨迹重组与相空间重构逆运算减少监测数据时间序列中的不确定信息(即噪声)。根据混沌理论,可将监测数据时间序列视为由 n 个变量组成的混沌系统,其中任意分量的演化都和与之相互作用的其他分量存在联系。因此只需研究某一分量,并将其在不同时间延迟点上的值作为不同的分量表征维度,即可重构一个等价的状态空间,从而保存原混沌系统的性质。假设大坝安全监测数据时间序列为 $\{x_i | i=1, 2, \dots, n\}$,可采用导数重构法和坐标延迟重构法重构一个等价的状态空间。导数重构法是用某一变量的各阶导数代替其他变量构建相空间矢量,容易产生误差;坐标延迟重构法则是通过监测数据时间序列 $\{x_i | i=1, 2, \dots, n\}$ 的不同延迟时间 τ 来构建 m 维的相空间矢量 $\mathbf{Y}$ 。本文选用坐标延迟重构法对一维大坝安全监测数据时间序列进行相空间重构。

设 $\mathbf{y}_{im}$ 为相空间矢量 $\mathbf{Y}$ 中的元素,则有:

$$\mathbf{y}_{im} = (x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}) \quad (i=1, 2, \dots, n - (m-1)\tau) \quad (1)$$

式中: n 为变量数; m 为嵌入维数; $n-(m-1)\tau$ 为相点数。

正确选取数据延迟时间 τ 和嵌入维数 m 是重构相空间的关键。若要将有规律的轨迹(即吸引子)从嵌入维空间中恢复过来,延迟坐标的维数必须满足 $m \geq 2d+1$ (d 是动力系统的维数)。由式(1)可看出 m 应取较大值。但由于大坝安全监测数据时间序列包含噪声且长度有限,并且动力系统维数 d 是未知的,若 m 取值过大,吸引子提取的计算量将

大幅度增加,重构后高维相空间中的时间序列受到噪声的影响也会大幅度增大;若 m 取值过小,将失去重构的意义。类似地,若系统的 τ 过大,会导致重构后相空间中各元素间的关联性不强,不能真实反映监测数据时间序列的整体规律;若系统的 τ 过小,则将导致各元素间的相关性过大,使得其不能作为独立变量,造成信息冗余。本文选用 Cao 法和 C-C 法^[9] 分别确定相空间重构的 m 和 τ 。

2 大坝安全监测数据时间序列相空间降维的流形学习方法

借助坐标延迟重构法对大坝安全监测数据时间序列重构至相空间后,将得到一组高维监测数据。流形学习方法认为,此组高维数据分布在含噪声的非线性低维流形上。可利用流形学习中的 LTSA 算法通过一系列变换,获得嵌入在高维空间的低维流形和相应的嵌入映射,实现相空间的降维,从而有效提取出能反映大坝性态的实际效应量,达到良好的非线性降噪效果。

2.1 相空间降维的 LTSA 算法

LTSA 算法是基于局部线性嵌入(locally linear embedding, LLE)提出的一种流形学习算法^[10],其主要思想是:利用数据点近邻区域的切空间来表示局部几何结构,通过局部切空间来保护近邻区域中数据点的局部坐标,在对局部切空间进行重新排列后,得到高维非线性流形的低维表示,从而获得更好的全局坐标系。LTSA 算法能有效解决权重系数的奇异性问题,嵌入精度较高且抗噪性较好。该算法用于大坝安全监测数据时间序列相空间降维处理的主要步骤包括:

步骤 1 抽取大坝效应量时间序列中各数据点的局部信息。在构建每个数据点 $x_i (i=1, 2, \dots, n)$ 的 k 个近邻点向量 $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{ik})$ 后,计算各数据点 $x_i (i=1, 2, \dots, n)$ 邻域的协方差矩阵 $\mathbf{C}_i$:

$$\mathbf{C}_i = \mathbf{X}_i (\mathbf{I} - \frac{1}{k} \mathbf{e} \mathbf{e}^T) \mathbf{X}_i^T \quad (2)$$

式中: $\mathbf{I}$ 为单位向量; $\mathbf{e}$ 为所有元素均为 1 的列向量。

对式(2)进行特征值分解,取前 d 个最大特征值对应的特征向量构成 $\mathbf{V}_i = (\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_d)$,则该数据点邻域的局部切空间坐标可近似表示为

$$\hat{\mathbf{X}}_i = \mathbf{V}_i^T \mathbf{X}_i \left(\mathbf{I} - \frac{1}{k} \mathbf{e} \mathbf{e}^T \right) \quad (3)$$

对每个数据点均作类似处理。

步骤 2 对各数据点进行局部切空间对齐。假设 d 维全局嵌入坐标为 $\mathbf{Y} = (\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_n)$,且 $\mathbf{Y}_i = (\mathbf{y}_{i1}, \mathbf{y}_{i2}, \dots, \mathbf{y}_{ik})$ 为高维空间中各点邻域 $\mathbf{X}_i$ 中相应

元素的嵌入坐标组成的向量,则局部对齐误差计算公式为

$$E_i = \min_{C_i \in \mathbf{R}^d, L_i \in \mathbf{R}^{d \times d}} \|Y_i - (C_i e^T + L_i \hat{X}_i)\|_F^2 = \|Y_i \Phi_i\|_F^2 = \|Y_i S_i \Phi_i\|_F^2 \quad (4)$$

式中: L_i 为转换矩阵; Φ_i 为局部对齐矩阵; S_i 为(0, 1)逻辑矩阵,满足 $Y S_i = Y_i$ 。

步骤3 获取大坝效应量时间序列的全局嵌入坐标。通过最小化局部对齐误差和构建目标函数,以获取全局低维嵌入坐标:

$$\begin{aligned} \min \sum_{i=1}^n E_i &= \min \sum_{i=1}^n \|Y_i S_i \Phi_i\|_F^2 = \\ \min \sum_{i=1}^n \text{tr}(Y S_i \Phi_i \Phi_i^T S_i^T Y^T) &= \\ \min \text{tr}\left(Y \left(\sum_{i=1}^n S_i \Phi_i \Phi_i^T S_i^T\right) Y^T\right) &= \min \text{tr}(Y \Phi Y^T) \end{aligned} \quad (5)$$

约束条件为

$$Y Y^T = I \quad (6)$$

式中 Φ 为全局对齐矩阵, $\Phi = \sum_{i=1}^n S_i \Phi_i \Phi_i^T S_i^T$ 。

对全局对齐矩阵 Φ 作特征值分解,取 Φ 第2个到第 $d+1$ 个最小的 d 个特征值对应的特征向量构成 d 维全局嵌入坐标 $Y = (y_1, y_2, \dots, y_n)$ 。

2.2 本征维数的极大似然估计

经相空间重构后的大坝安全监测数据构成一组高维数据,而相空间中的这组高维数据实际上是位于一个低维非线性流形上,这个低维流形的维数即为此组高维数据的本征维数。在运用流形学习方法进行维数约简时,若选择的本征维数过小,会错误地将有用信号当作噪声,造成有用信号的丢失;若选择的本征维数过大,则会将噪声包含进有用信号中,难以有效地消除噪声。一般情况下,数据的局部几何特征可以通过数据关系表现出来,可利用极大似然估计(maximum likelihood estimate, MLE)方法建立各近邻点之间距离的似然函数,得到本征维数的极大似然估计。具体步骤为:

步骤1 取某一数据点 x , 假设以该点为中心,足够小的 R 为半径的球体范围 $S_x(R)$ 内分布概率 $f(x) \approx$ 常数。 $N_x(t)$ 是落入 $S_x(t)$ 的点数(其中 t 为数据落点与球心距离),则 $\{N_x(t) | 0 \leq t \leq R\}$ 为一个非平稳过程:

$$N_x(t) = \sum_{i=1}^n \{X_i \in S_x(t)\} \quad (7)$$

由式(7)可以看出,对于固定的 n , $\{N_x(t) | 0 \leq t \leq R\}$ 为一个二项随机过程。用泊松公式近似式(7)得到:

$$\lambda(t) = f(x) V_d t^{d-1} \quad (8)$$

式中: V_d 为 d 维单位球体积; $\lambda(t)$ 为 $N_x(t)$ 相对于 t 的变化率。

步骤2 令 $\theta = \lg f(x)$, 建立 $N_x(t)$ 的对数似然函数:

$$L(d, \theta) = \int_0^R \lg \lambda(t) dN_x(t) - \int_0^R \lambda(t) dt \quad (9)$$

在约束条件 $\frac{\partial L}{\partial \theta} = 0, \frac{\partial L}{\partial d} = 0$ 下,取 k 邻域作为小球半径,则有

$$\hat{d}_k(x_i) = \left[\frac{1}{k-1} \sum_{j=1}^{k-1} \lg \frac{T_k(x_i)}{T_j(x_i)} \right]^{-1} \quad (10)$$

式中: $\hat{d}_k(x_i)$ 为各数据点 x_i 利用极大似然估计法计算出的本征维数; $T_k(x_i)$ 为数据点 x_i 与其第 k 个近邻点的欧氏距离。

步骤3 按式(10)计算各数据点的本征维数,并对这 n 个数据点求平均值得到全局本征维数 $\hat{d}_k(x)$:

$$\hat{d}_k(x) = \frac{1}{n} \sum_{i=1}^n \hat{d}_k(x_i) \quad (11)$$

2.3 邻域的自适应选择

LTSA 算法首先需要抽取大坝效应量时间序列的局部信息,根据每个数据点 x_i 的 k 局部邻域构建局部切空间。在利用 LTSA 算法进行流形降维时,构建邻域图是重现流形拓扑结构的关键。若 k 过小,切空间会出现非满秩的情况,使得计算结果出错;若 k 过大,则不能有效识别出局部化线性结构,容易造成局部信息的损失。目前常采用固定邻域的方法进行 LTSA 降维(固定邻域-LTSA 法),但该方法通常只适用于数据点分布均匀的流形,对于数据点分布不均匀、稀疏或含有噪声的情况使用效果不佳。此外,流形曲率和采样密度对各数据点近邻点个数的选择影响较大,流形上曲率小的数据点邻域应较大,反之则邻域应较小;对数据点分布密集的数据点而言,其近邻点应较多,反之则近邻点应较少^[11]。自适应邻域算法的基本思想为:根据各数据点的流形曲率和采样密度,充分考虑该数据点周围点的分布情况,自适应地计算近邻点的个数。由此可以看出,利用该法得到的各个数据点邻域大小是不等的。自适应邻域法考虑了数据点采集的具体情况,相较于固定近邻点个数方法而言更科学。其算法步骤如下:给出初始近邻点个数 k , 设 x_i 的初始 k 个邻近点为 $x_{ij}(j=1, 2, \dots, k)$, 计算各 x_i 与其近邻点 x_{ij} 的平均欧氏距离 $\bar{d}_i$:

$$\bar{d}_i = \sum_{j=1}^k \|x_i - x_{ij}\| / k \quad (i = 1, 2, \dots, n) \quad (12)$$

整个流形结构的平均欧氏距离 $\bar{D}_m$ 为

$$\bar{D}_m = \sum_{i=1}^n \bar{d}_i / n \quad (13)$$

则各数据点的自适应近邻点个数的计算公式为

$$k_i = k_0 \bar{D}_m / \bar{d}_i \quad (14)$$

式中: k_0 为初始近邻点个数, 一般采用试算法确定。

由式(14)可以看出, 各点的自适应近邻点个数 k_i 的大小与 $\bar{d}_i$ 成反比。从现实意义看来, $\bar{d}_i$ 越小, 说明数据点 x_i 的近邻点越密集, 此时 k_i 应取较大值, 才能避免因为邻域间数据缺乏关联而造成整体结构扭曲; $\bar{d}_i$ 越大, 说明数据点 x_i 的近邻点越稀疏, 此时 k_i 取较小值, 能够有效避免错误地将非近邻点作为重构数据选入 x_i 的近邻点。采用上述自适应选择邻域的 LTSA 法即为自适应邻域-LTSA 法。

3 大坝安全监测数据的相空间重构与流形学习组合降噪实现过程

大坝安全监测数据时间序列具有非平稳、非线性的数据特征, 对其进行相空间重构后再利用流形学习方法进行降维能有效识别吸引子所在的低维空间, 从而达到去除数据中噪声的目的, 其实现流程见图 1, 具体步骤如下:

步骤 1 利用相空间重构法对一维大坝安全监测数据进行重构。设该监测数据时间序列为 $\{x_i | i=1, 2, \dots, n\}$, 应用 Cao 法确定相空间重构的嵌入维数 m , 应用 C-C 法确定延迟时间 τ 。设重构后的相空间为: $\mathbf{Y} = (\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_n) \in \mathbf{R}^m$ 。

步骤 2 识别 m 维大坝安全监测数据相空间的主流形。经相空间重构后的大坝安全监测数据 $\mathbf{Y}$ 分布在高维空间中, 为实现该高维数据的可视化, 利

用重构后安全监测各数据点的近邻区域的切空间来近似表示该点的局部几何结构, 其中近邻点的个数选择采用自适应邻域-LTSA 法计算得到。利用极大似然估计方法计算本征维数 d 后, 对局部切空间进行重新排列得到非线性流形的用自然参数刻画的低维表示, 以得到更好的全局坐标系。利用自适应邻域-LTSA 算法通过一系列变换获得嵌入在高维空间(m 维)的低维流形(d 维)和相应的嵌入映射($d < m$), 设计算得到的低维主流形为

$$\mathbf{T} = (t_1, t_2, \dots, t_{N-(m-1)\tau}) \in \mathbf{R}^d \quad (15)$$

步骤 3 重构 m 维大坝安全监测数据主流形。利用 LTSA 算法计算出各数据点 x_i 对应的低维全局坐标 t_i 后, 由低维全局坐标根据式(16)重构高维数据的主流形 $\mathbf{Z} \in \mathbf{R}^{m \times n}$ 。

$$\mathbf{z}_i = \bar{\mathbf{y}}_i + \mathbf{Q}_i \mathbf{L}_i^{-1} (t_i - \bar{t}_i) \quad (16)$$

式中: $\bar{\mathbf{y}}_i, \bar{t}_i$ 分别为矩阵 $\mathbf{Y}$ 和 $\mathbf{T}$ 中元素 y_i 和 t_i 的平均值; $\mathbf{L}_i^{-1}$ 为转换矩阵 $\mathbf{L}_i$ 的广义逆矩阵; $\mathbf{Q}_i$ 为中心化样本矩阵后, 对其进行奇异值分解取得的 d 个最大的右奇异向量。

步骤 4 反求降噪后的一维大坝安全监测数据。此过程实为相空间重构的逆运算, 通过时间延迟重构大坝原始一维安全信号后, 会导致一维时间序列的各元素在重构后的相空间矢量中重复出现, 通过式(17)从 m 维相空间矢量中恢复一维大坝安全时间序列, 此时间序列即为降噪后的大坝安全时间序列。

$$\tilde{x}_i = \frac{1}{C_i} \sum_{\substack{j,k \\ (j,k) \in \{I_i\}}} z_{j,k} \quad (17)$$

式中: $\{I_i\}$ 为时间序列中第 i 个元素在高维相空间数据矩阵中满足条件 $k+(j-1)\tau=i$ 的所有元素下标集合; $k=1, 2, \dots, n-(m-1)\tau$; $j=1, 2, \dots, m$; C_i 为 $\{I_i\}$ 中元素的个数。

4 工程实例验证

某水电站枢纽工程由碾压混凝土重力坝、泄洪消能建筑物、引水发电建筑物等组成。重力坝坝顶高程 1334.00 m, 共有 24 个坝段, 包括左右岸挡水坝段、左右岸中孔坝段和河床溢流坝段。坝顶布置有一套真空激光准直系统, 每个坝段设置 1 个测点, 共 24 个测点, 用于观测大坝上下游方向和垂直方向位移。以该大坝真空激光准直系统顺河向位移 LA13 测点为例, 选取其从 2015 年 1 月 1 日至 2019 年 12 月 31 日的 1670 个监测数据对本文所提出方法进行验证, 其测值过程线如图 2 所示。

采用本文所提相空间重构与自适应邻域-LTSA




图 1 大坝安全监测数据降噪实现过程




图2 LA13 测点顺河向位移原始测值过程线

组合降噪法,按图 1 流程对该监测数据序列进行降噪处理。

步骤 1 对 LA13 测点顺河向位移时间序列进行相空间重构。结合样本实际情况,利用 C-C 法确定延迟时间,取 $\tau=1$,在此基础上,采用 Cao 法确定嵌入维数,如图 3 所示,当 E_1 的取值接近 1 并且逐渐趋于稳定而 E_2 的值不等于 1,此时对应的维数即为最佳嵌入维数,取 $m=4$ 。利用所确定的延迟时间和嵌入维数进行相空间重构,计算相点数 $n-(m-1)\tau=1667$ 。




图3 Cao 法确定嵌入维数

步骤 2 对 LA13 测点带噪一维监测数据时间序列进行相空间重构后,采用极大似然估计方法估算高维空间的本质维数。利用式 (10) 计算得数据点的全局本质维数为 1.984,四舍五入后取整即得到全局本质维数 $d=2$ 。

步骤 3 根据具体测点情况取初始近邻点个数 $k_0=18$,利用自适应邻域-LTSA 算法,通过式 (12) 计算每个数据点 x_i 与其近邻点 $x_{ij}(j=1,2,\dots,k)$ 的平均欧氏距离 d_i ,按式 (13) 计算得整个流形结构的平均欧氏距离为 9.146×10^{-5} ,利用式 (14) 计算每个数据点的近邻点个数。

步骤 4 采用相空间降维的 LTSA 算法取高维空间的低维嵌入,得到低维主流形:

$$T = \begin{bmatrix} -1.508 & -1.385 & \cdots & -1.931 \\ -5.028 & -4.618 & \cdots & -6.439 \end{bmatrix}_{2 \times 1667} \quad (18)$$

步骤 5 由低维全局坐标根据式 (16) 重构高维数据的主流形,并反求降噪后的一维时间序列 Y 。LA13 测点原始监测数据与自适应邻域-LTSA 法降噪后测值过程线见图 4,原始信号及降噪后信号二

维相图如图 5 所示。




图4 LA13 测点测值自适应邻域-LTSA 法降噪结果





图5 原始信号及经自适应邻域-LTSA 法降噪后信号的二维相图

将自适应邻域-LTSA 降噪方法计算结果与固定邻域-LTSA 降噪方法、传统小波软阈值降噪方法的计算结果进行对比分析。利用小波软阈值法和固定邻域-LTSA 法降噪后的 LA13 测点顺河向位移二维相图如图 6 所示,各方法降噪后的信噪比及均方根误差如表 1 所示。


表 1 不同方法降噪效果对比

降噪方法	信噪比/dB	均方根误差/mm
自适应邻域-LTSA 法	28.194	0.111
固定邻域-LTSA 法	27.190	0.131
小波软阈值法	26.032	0.142

对比图 5 和图 6 可以发现,自适应邻域-LTSA 法、固定邻域-LTSA 法和小波软阈值法对大坝安全监测数据降噪均有效果,但自适应邻域-LTSA 法降噪效果更好。结合表 1 分析可知,相较固定邻域-LTSA 法和小波软阈值法,自适应邻域-LTSA 法有较高的信噪比和较低的均方根误差,说明该方法降噪效果更优。



(a) 小波软阈值法



(b) 固定邻域-LTSA 法

图6 小波软阈值法和固定邻域-LTSA 法降噪后信号的二维相图

5 结 语

本文充分考虑大坝安全监测数据时间序列所具有的非平稳、强非线性特征,引入流形学习中的LTSA 算法,以重构的大坝安全监测数据时间序列相空间为桥梁,将LTSA 算法与极大似然估计方法、自适应邻域方法进行融合,应用于大坝安全监测数据时间序列相空间的降维处理,解决了邻域大小和本征维数等的确定问题,发展了基于相空间重构与流形学习相组合的大坝安全监测数据降噪方法。本文提出的自适应邻域-LTSA 法,有效地将混沌吸引子从高维相空间中恢复,实现了大坝安全监测数据时间序列深层次信息的提取,避免了随机分布的非线性噪声干扰。工程实例验证结果表明,与小波软阈值法和固定邻域-LTSA 法相比,采用自适应邻域-LTSA 法进行降噪后的数据有较高的信噪比和较低的均方根误差,降噪效果较优。随着大坝工程服役时间的延长,其安全监测数据量将越来越大,如何充分提升算法的降噪效率有待进一步的探究。

参考文献:

[1] YAO Kefu, WEN Zhiping, YANG Lifu, et al. A multipoint prediction model for nonlinear displacement of concrete dam [J]. Computer-Aided Civil and Infrastructure Engineering, 2022, 37(14): 1932-1952.

[2] 张守平. 软硬折衷阈值小波去噪法在大坝位移监控中的应用[J]. 水电能源科学, 2014, 32(4): 34-36.

(ZHANG Shouping. Application of compromise thresholding wavelet denoising method in safety monitoring of dam displacement [J]. Water Resources and Power, 2014, 32(4): 34-36. (in Chinese))

[3] BEALE C, NIEZRECKI C, INALPOLAT M. An adaptive wavelet packet denoising algorithm for enhanced active acoustic damage detection from wind turbine blades [J]. Mechanical Systems and Signal Processing, 2020, 142: 106754.

[4] LI Bo, ZHANG Lixin, ZHANG Qiling, et al. An EEMD-based denoising method for seismic signal of high arch dam combining wavelet with singular spectrum analysis [J]. Shock & Vibration, 2019, 2019: 4937595.

[5] 侯回位, 郑东健, 刘永涛, 等. 基于EEMD-SE-LSTM的混凝土坝变形监测模型[J]. 水利水电科技进展, 2022, 42(1): 61-66. (HOU Huiwei, ZHENG Dongjian, LIU Yongtao, et al. Deformation monitoring model of concrete dams based on EEMD-SE-LSTM [J]. Advances in Science and Technology of Water Resources, 2022, 42(1): 61-66. (in Chinese))

[6] GOH H H, LIAO Ling, ZHANG Dongdong, et al. Denoising transient power quality disturbances using an improved adaptive wavelet threshold method based on energy optimization [J]. Energies, 2022, 15(9): 3081.

[7] 李冰, 徐笑笑. 变形监测数据降噪方法及其质量评价浅析[J]. 长江信息通信, 2022, 35(5): 57-59. (LI Bing, XU Xiaoxiao. Analysis on de-noising method and quality evaluation of deformation monitoring data [J]. Changjiang Information & Communications, 2022, 35(5): 57-59. (in Chinese))

[8] 杨贝贝. 基于相空间重构的大坝服役性态小波支持向量机预测模型[J]. 水利水电技术, 2016, 47(10): 83-87. (YANG Beibei. Phase space reconstruction-based wavelet support vector machine prediction model for dam service behavior [J]. Water Resources and Hydropower Engineering, 2016, 47(10): 83-87. (in Chinese))

[9] 张雨, 任成龙. 确定重构相空间维数的方法[J]. 国防科技大学学报, 2005, 27(6): 101-105. (ZHANG Yu, REN Chenglong. The methods to confirm the dimension of reconstructed phase space [J]. Journal of National University of Defense Technology, 2005, 27(6): 101-105. (in Chinese))

[10] ZHANG Zhenyue, ZHA Hongyuan. Principal manifolds and nonlinear dimensionality reduction via tangent space alignment [J]. SIAM Journal on Scientific Computing, 2004, 26(1): 313-338.

[11] 李波. 高维数据的流形学习分析方法[M]. 武汉: 武汉大学出版社, 2016.

(收稿日期: 2023-11-15 编辑: 俞云利)