

桥梁监测信号自适应分解重构方法对比分析

单德山¹, 余忠儒¹, 孙榕徽¹, 张二华²

(1. 西南交通大学土木工程学院, 四川 成都 610031; 2. 四川省公路规划勘察设计研究院有限公司, 四川 成都 610031)

摘要: 桥梁结构监测信号的自适应分解重构与降噪是桥梁健康监测领域的重要研究内容。为提供快捷有效的信号时频域降噪方法, 针对 VMD (variational mode decomposition) 类处理方法存在的分解成分数量需预先确定的缺点, 提出了一种自适应变分模态分解重构 (adaptive variational mode decomposition and reconstruction, AVMDR) 方法来执行信号降噪。通过引入 EMD (empirical mode decomposition) 来自适应确定分解成分数量, 然后利用多尺度主成分分析对各阶成分进行降噪并重构。利用带有不同噪声水平的线性平稳、非线性非平稳模拟信号以及 2 座斜拉桥模型实测信号对所提方法的降噪性能进行了验证和对比分析。研究表明: AVMDR 方法的降噪性能优于其他常用方法, 各个降噪性能评价指标均为最优, 且 AVMDR 方法在剔除噪声的同时能够更多地保留结构信息。

关键词: 监测信号; 分解重构; 自适应; 降噪; 评价指标

中图分类号: U448.27 文献标志码: A 文章编号: 1004-4523(2025)05-1036-10

DOI: 10.16385/j.cnki.issn.1004-4523.2025.05.015

Comparative analysis of adaptive decomposition and reconstruction methods for bridge monitoring signals

SHAN Deshan¹, YU Zhongru¹, SUN Ronghui¹, ZHANG Erhua²

(1. School of Civil Engineering, Southwest Jiaotong University, Chengdu 610031, China;

2. Sichuan Highway Planning, Survey, Design and Research Institute Co., Ltd., Chengdu 610031, China)

Abstract: Adaptive decomposition, reconstruction, and denoising of bridge structure monitoring signals are critical parts in the research field of bridge health monitoring. To provide efficient and effective time-frequency domain denoising methods for these signals, an Adaptive Variational Mode Decomposition and Reconstruction (AVMDR) method was proposed for signal denoising, which can overcome the disadvantage of VMD (Variational Mode Decomposition) type methods that the number of decomposition components needs to be determined in advance. The Empirical Mode Decomposition (EMD) method was introduced to adaptively determine the number of decomposition components, and then the Multi-scale Principal Component Analysis (MSPCA) was used to denoise each component and reconstruct the signal. The denoising performance of the proposed AVMDR method was validated and compared using both simulated signals—linear stationary and nonlinear non-stationary signals with varying noise levels—and real signals obtained from two cable-stayed model bridges. The results indicate that the AVMDR method outperforms other commonly used methods in terms of denoising performance, achieving optimal scores across all denoising performance evaluation metrics. Moreover, the AVMDR method can effectively retain more structural information while eliminating noise.

Keywords: monitoring signal; decomposition and reconstruction; adaptive; noise reduction; evaluation index

在桥梁工程领域, 实际桥梁结构的监测信号具有较强的非线性与非平稳特性^[1], 而信号自适应分解方法基于信号本身的特征尺度, 可自适应地将非线性、非平稳信号分解为有限带宽的信号分量^[2]。如何实现快捷有效的桥梁监测信号自适应分解与重构, 进而深度挖掘桥梁结构信息, 一直是桥梁健康监测领域的研究重点。

HUANG 等^[3]提出经验模态分解 (empirical mode decomposition, EMD) 方法, 该方法及其改进方法已广泛应用于桥梁结构监测信号预处理^[4-5]、损伤识别^[6-7]等方面。受监测信号截断、缺失以及相互干扰等因素的影响, EMD 方法不可避免地存在端点效应和模态混叠现象^[8]。尽管国内外学者对该问题进行了深入的研究与探讨, 但还是未能彻底解决^[9]。

收稿日期: 2024-04-17; 修订日期: 2024-06-25

基金项目: 国家自然科学基金资助项目 (51978577)

为弥补 EMD 方法的缺陷, GILLES^[10] 基于小波变换理论框架, 结合信号傅里叶谱的先验分割, 提出了基于经验小波变换 (empirical wavelet transform, EWT) 的信号自适应分解和重构方法。该方法具有坚实的理论基础, 在处理非线性、非平稳信号方面具有很强的自适应能力, 在桥梁结构损伤识别^[11-12]、模态参数识别^[13-14] 等方面被广泛应用。

DRAGOMIRETSKIY 等^[15] 将信号递归分解问题转化为变分优化问题, 在重新定义固有模态函数 (intrinsic mode function, IMF) 后, 提出了一种完全非递归、自适应的非线性、非平稳信号分解方法—VMD (variational mode decomposition)。该方法能有效解决端点效应和模态混叠问题, 被广泛应用于桥梁

车致应变分离^[16]、模态参数识别^[17]、结构损伤识别^[18] 等领域。值得注意的是, EWT 类方法利用频谱分割的边界频率来构造小波滤波器, 而 VMD 类方法以信号分量的中心分量来构造 Wiener 滤波器, 两种方法均需要预先确定 IMF 的分解数量^[19]。

目前, 针对桥梁结构监测信号的自适应分解方法主要包括经验模态分解、小波变换和变分模态分解三大类。LIU 等^[20] 和 CIVERA 等^[21] 分别对机械信号处理和结构健康监测领域的常用信号分解方法进行了对比分析, 明确了各类方法的优缺点。本文在既有研究的基础上, 汇总了 EMD 及其改进方法、EWT 方法、VMD 方法的适用范围和亟需进一步解决的问题, 如表 1 所示。

表 1 不同信号自适应分解方法的比较

Tab. 1 Comparison of different adaptive signal decomposition methods

方法	适用范围	不适用范围	待解决问题
EMD类	瞬时频率具有足够的区分度	相邻瞬时频率之比小于0.75	(1) 计算效率; (2) 分解稳定性; (3) 剔除有色噪声; (4) 有用信号成分的表征。
EWT类	傅里叶谱具有足够的区分度	不同分解成分的傅里叶频谱存在重叠	(1) 频带分割策略; (2) 剔除有色噪声; (3) 有用信号成分的表征。
VMD类	傅里叶谱具有足够的区分度	不同分解成分的傅里叶频谱存在重叠	(1) 确定信号分解成分数量等参数; (2) 剔除有色噪声; (3) 有用信号成分的表征。

VMD 方法^[20-21] 具有坚实的数学理论基础, 同时摆脱了递归筛分剥离信号的分解束缚。VMD 方法不仅具有较高的运算效率和鲁棒性, 还能有效缓解或避免 EMD 类方法带来的模态混叠、端点效应等一系列问题。为此, 本文以 VMD 方法为基础进行自适应改进, 提出一种自适应变分模态分解重构 (AVMDR) 的信号降噪手段。将该方法和 EMD、EEMD (ensemble empirical mode decomposition)、AEMD (adaptive empirical mode decomposition)、EWT 等方法用于信号的分解重构与降噪, 并基于 6 种不同的指标对不同方法的降噪性能进行评价。

1 变分模态分解 VMD 及自适应改进

1.1 变分模态分解

基于变分凸优化数学框架, VMD 将模态分解的约束变分问题表述为^[15]:

$$\begin{aligned} \min_{\{u_k\}, \{\omega_k\}} & \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|^2 \right\} \\ \text{s.t.} & \sum_k u_k = f(t) \end{aligned} \quad (1)$$

式中, $u_k(t)$ ($k=1, 2, \dots, K$) 为分解的限带本征模态函

数 (intrinsic mode function, IMF); ω_k 为 $u_k(t)$ 的中心频率; K 为预先确定的 IMF 分解成分的数量; $f(t)$ 为待分解信号; $\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t)$ 为 $u_k(t)$ 的希尔伯特变换, 用于获得 $u_k(t)$ 的解析信号; $e^{-j\omega_k t}$ 用于将希尔伯特变换结果转移到其基带^[15]; ∂_t 表示计算梯度; j 表示虚数单位。

引入二次惩罚因子 α 和拉格朗日乘法算子 $\lambda(t)$, 将约束变分问题转化为如下式所示的无约束变分问题^[20-21]:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|^2 + \left\| f(t) - \sum_k u_k(t) \right\|^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \quad (2)$$

采用乘法算子交替方向法 (alternate direction method of multipliers, ADMM)^[20-21] 求解式 (2), 得到无约束变分优化的“鞍点”, 即为式 (1) 的模态分解结果。

实现 VMD 算法需确定两个关键参数, 即二次惩罚因子 α 和 IMF 的分解数量 K ^[15]。 α 定义为与测试信号噪声水平相关的特定超参数, 可由贝叶斯先验得到^[15], 其用于平衡分解模态带宽和原信号的重构误差。较大的 α 表明分解模态的带宽较窄, 而较小的 α 则对应较宽的带宽^[20]。在正常运营情况下, 桥梁振动幅度通常较小, 而桥梁所处的环境噪声十分

复杂,可能淹没结构的动态信号。这表明正常运营条件下,桥梁结构实测动态信号属于典型的微弱信号^[1,21]。此外,桥梁结构属于模态密集结构^[21],这表明 α 可取较大的值,一般 $\alpha \geq 1000$,在减少重构误差的同时,还能提高求解的收敛速度^[20-21]。此外,式(1)和(2)中的 K 由测试信号 Fourier 谱的主频数量以及桥梁结构物理先验信息共同决定,这在一定程度上降低了 VMD 方法的适应能力^[20-21]。

1.2 IMF 数量 K 的自适应确定

基于数据驱动的 EMD 类方法尽管存在诸多不足,但其自适应的特点使得该类方法广泛应用于桥梁、机械的信号的处理中^[22-23]。本文将 EMD 的自适应性与奇异值分解相结合,用于确定 VMD 中的 IMF 分解数量 K 。算法流程如下:

(1) 基于 EMD 方法分解信号 $f(t)$ 并中心化,获得数据集 $X = \{IMF(1), IMF(2), \dots, IMF(n)\}$, 其中:

$$IMF(i) = IMF^{(i)} - \frac{1}{n} \sum_{j=1}^n IMF^{(j)} \quad (3)$$

式中, $IMF^{(i)}$ ($i = 1, 2, \dots, n$) 为 EMD 方法得到的 n 个初始分解成分样本集; j 表示索引变量;

(2) 计算 X 的协方差 XX^T 并进行奇异值分解,得到前 n 个奇异值 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$ 。设定主成分累计贡献率 $t \in (0, 1]$, 则 VMD 分解数量 K 由公式 $\sum_{i=1}^K \lambda_i / \sum_{i=1}^n \lambda_i \geq t$ 确定;

(3) 待分解信号 $f(t)$ 经 VMD, 获得 K 个分解成分集合 $\{u_k(t); k = 1, 2, \dots, K\}$ 。

1.3 测试信号的自适应变分模态分解重构

利用 VMD 方法获得的各阶成分不仅包含结构信息,还包含测试噪声。本文引入多尺度主成分分析(multi-scale principle component analysis, MPCA)方法对每一阶分量进行降噪处理^[22]。

(1) 对 $u_k(t); k = 1, 2, \dots, K$ 进行多尺度小波分析;

(2) 在每一阶小波尺度下进行主成分分析,计算各自小波系数协方差矩阵、主成分分量;

(3) 确定主成分数量并计算阈值,提取大于或等于阈值的小波系数;

(4) 对检测到的显著事件在对应尺度下进行组合,由所选分量和阈值重构信号,获得降噪后的本征模态函数 $u_k^d(t)$, 并计算主成分分量;

(5) 对降噪后 $u_k^d(t)$ 进行相关性检验,合并相同动态模式,采用 PCA 选择最终分解分量后,将各分量叠加,获得重构后的降噪测试信号。

将前述信号分解重构流程进行组合,形成桥梁

监测信号自适应变分模态分解重构(AVMDR)方法,信号处理流程如图 1 所示。

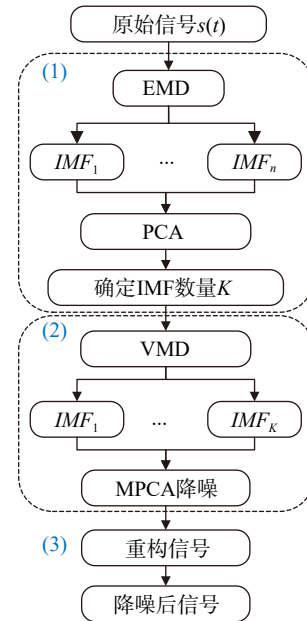


图 1 AVMDR 流程图

Fig. 1 AVMDR flow chart

2 AVMDR 验证

分别采用模拟信号和实测信号验证本文所提的 AVMDR 的有效性。

2.1 模拟信号降噪

在已知的真实信号中添加不同水平的噪声,形成模拟信号。本文分别用 EMD、EEMD、AEMD、EWT 和 AVMDR 对信号进行降噪处理,基于下式所示的 6 个评价指标^[24]对不同方法的降噪性能进行描述:

均方误差 MSE(mean square error):

$$MSE = \frac{1}{N} \sum_{t=1}^N [x(t) - \tilde{x}(t)]^2 \quad (4)$$

平均绝对误差 MAE(mean absolute error):

$$MAE = \frac{1}{N} \sum_{t=1}^N |x(t) - \tilde{x}(t)| \quad (5)$$

信噪比 SNR(signal to noise ratio):

$$SNR = 10 \cdot \lg \left(\frac{\sigma_x^2}{\sigma_{x-\tilde{x}}^2} \right) \quad (6)$$

峰值信噪比 PSNR(peak signal to noise ratio):

$$PSNR = 20 \cdot \lg \left(\frac{\max(x(t))}{\sqrt{MSE}} \right) \quad (7)$$

互相关系数 CCC(cross correlation coefficient):

$$CCC = \frac{\text{cov}[x(t), \tilde{x}(t)]}{\sigma_x \sigma_{\tilde{x}}} \quad (8)$$

互信息 MI(mutual information):

$$MI(\tilde{x}, x) = \sum_{\tilde{x}_i \in \tilde{x}} \sum_{x_i \in x} p(\tilde{x}_i, x_i) \log \left(\frac{p(\tilde{x}_i, x_i)}{p(\tilde{x}_i) p(x_i)} \right) \quad (9)$$

式中, $x(t)$ 和 $\tilde{x}(t)$ 分别表示降噪前、后的信号; N 为信号长度; $\text{cov}[x(t), \tilde{x}(t)]$ 为两信号协方差; $\sigma_{\tilde{x}}$ 、 σ_x 分别为信号 $\tilde{x}(t)$ 、 $x(t)$ 的标准差; $p(\tilde{x}, x)$ 为 $\tilde{x}(t)$ 和 $x(t)$ 的联合概率分布函数; $p(\tilde{x})$ 和 $p(x)$ 分别为 $\tilde{x}(t)$ 和 $x(t)$ 的边缘概率分布函数。

由式 (4)~(9) 可知, MSE 和 MAE 的值越小, 表明方法对实际信号的还原越好; SNR 和 $PSNR$ 的值越大, 表明方法具有更好的信息提取能力; 越大的 CCC 值表明降噪后的信号与理想信号的线性相关性越强; MI 值越大, 表明降噪后信号所包含的有用信息越多。

首先采用线性平稳模拟信号验证所提方法在保留有用信息方面的能力, 接着利用低、高噪声水平的非线性非平稳模拟信号对其降噪性能进行评价与分析。

2.1.1 线性平稳信号

建立含噪声的线性平稳模拟信号^[3], 如下式所示:

$$s(t) = 15\cos\left(2\pi t + \frac{\pi}{3}\right) + 12\cos\left(3\pi t + \frac{\pi}{3}\right) + 12\cos\left(10\pi t + \frac{\pi}{8}\right) + 15\omega(t) \quad (10)$$

式中, $\omega(t)$ 为 (0, 1) 分布的高斯白噪声。

分别采用 EMD、EEMD、AEMD、EWT 和 AVMDR 方法对式 (10) 所示的模拟信号进行分解重构, 并按式 (4)~(9) 计算得到的各降噪指标如表 2 和图 2 所示。由表 2 和图 2 可知, 对于线性平稳信号, EEMD 和 AEMD 的降噪性能均较差, 其重构信号依然有较高水平的噪声残留; EMD 与 EWT 的降噪指标接近, 重构后的信号噪声水平较低, 但重构信号相对于真实信号出现了局部失真; 本文所提 AVMDR 方法的降噪性能最优。

表 2 各方法降噪性能评估指标统计

Tab. 2 Noise reduction performance evaluation index statistics of each method

方法	MSE/%	MAE/%	SNR	PSNR	CCC	MI
EMD	15.96	3.03	12.06	18.56	0.97	0.97
EEMD	22.77	3.80	10.52	17.02	0.96	0.96
AEMD	19.64	3.66	11.16	17.66	0.96	0.96
EWT	13.88	2.81	12.67	19.17	0.97	0.98
AVMDR	2.04	1.14	20.99	27.49	1.00	1.00




图 2 线性平稳信号降噪性能指标对比

Fig. 2 Comparison of noise reduction performance indexes of linear stationary signals

进一步分析可知, 尽管 5 种方法均存在不同程度的“模态混叠”现象^[23], 但经 MPCA 处理后的重构信号受分解过程的“模态混叠”影响较小。分析认为不同方法降噪性能存在差异的主要原因如下:

(1) EEMD 和 AEMD^[20] 在分解过程中均需人为引入白噪声, 期望通过无限次的集合平均来抵消白噪声的影响, 但实际集合平均次数必然有限, 这不仅增加计算成本, 还残留了部分引入的噪声。

(2) EMD 分解时^[20], 需拟合残差信号的上下包络线, 不恰当的拟合容易扭曲分解成分, 致使最终重构信号局部失真。

(3) 采用小波滤波器组的 EWT 方法^[19], 其“母小波”的选择将影响重构波形。另外, EWT 的频谱带宽自适应划分也包含了其对应频带的噪声。

2.1.2 低噪声非线性非平稳信号

构造非线性非平稳模拟信号^[3], 如下式所示:

$$s(t) = 15\cos(2\pi t^2) + 15\omega(t) \quad (11)$$

分别用 EMD、EEMD、AEMD、EWT 和 AVMDR 分解重构式 (11) 信号后, 各方法对应的降噪指标如表 3 及图 3 所示。

表 3 模拟信号 2 的各方法降噪性能指标对比

Tab. 3 Comparison of noise reduction performance index of each method of analog signal 2

方法	MSE/%	MAE/%	SNR	PSNR	CCC	MI
EMD	27.17	4.27	6.25	9.18	0.89	0.89
EEMD	27.92	4.31	6.13	9.06	0.89	0.89
AEMD	30.94	4.44	5.68	8.62	0.87	0.88
EWT	28.04	3.84	6.11	9.04	0.88	0.90
AVMDR	6.59	2.05	12.40	15.34	0.97	0.96

由表 3 和图 3 可知, AVMDR 重构信号的 MSE 值约为其他方法的 1/5, MAE 值为其他方法的 1/2, 但

SNR 和 PSNR 值约为其他方法的 2 倍。其他方法的 CCC 和 MI 值均小于 0.9, 而基于 AVMDR 的值接近

1.0。上述结果表明, 对于低噪声非线性非平稳信号, AVMDR 的降噪效果最优。




图 3 低噪声非线性非平稳信号降噪性能指标对比

Fig. 3 Comparison of noise reduction performance indexes of low noise nonlinear non-stationary signals

对比分析 5 种分解重构方法的结果可以发现, EMD、EEMD、AEMD、EWT 的重构信号均含有较高水平的噪声, 而 AVMDR 的重构信号具有最大的 SNR 值, 这表明其保留了最多的有用信息, 而其他方法的 SNR 值只有 AVMDR 方法的一半。

2.1.3 高噪声非线性非平稳信号

构造非线性非平稳模拟信号^[3], 如下式所示:

$$s(t) = 15\cos[2\pi t + \sin(2\pi t)] + 15\cos(2\pi t^2) + 30\omega(t) \quad (12)$$

对比式 (11) 和 (12), 可知式 (12) 的噪声水平明显更高。表 4 和图 4 展示了 5 种分解重构方法的降噪性能评价指标。由图表信息可知, 在高噪声环境下, AVMDR 的 MSE 和 MAE 值显著小于其他 4 种方法, 而 SNR 和 PSNR 值则显著大于其他 4 种方法。其他 4 种方法的 CCC 和 MI 值不足 0.9, 而 AVMDR 的 CCC

和 MI 值则接近 1.0。相关结果表明, 对于高噪声非线性非平稳信号的降噪, AVMDR 方法相较于其他 4 种方法具有显著优势。另外, 从 SNR 值的表现来看, EMD、EEMD、AEMD、EWT 的重构信号均含有较高水平的噪声, 而 AVMDR 的重构信号的噪声水平相对较低。

表 4 模拟信号 3 的各方法降噪性能指标对比

Tab. 4 Comparison of noise reduction performance index of each method of analog signal 3

方法	MSE/%	MAE/%	SNR	PSNR	CCC	MI
EMD	117.55	8.83	3.74	8.84	0.86	0.87
EEMD	116.94	8.89	3.76	8.86	0.87	0.88
AEMD	104.51	8.31	4.25	9.35	0.89	0.89
EWT	127.55	9.25	3.39	8.49	0.84	0.86
AVMDR	53.91	6.39	7.13	12.23	0.97	0.97




图 4 高噪声非线性非平稳信号降噪性能指标对比

Fig. 4 Comparison of noise reduction performance indexes of strong noise nonlinear non-stationary signals

2.2 实测信号验证

由前述模拟信号的计算结果可知, 本文提出的 AVMDR 信号降噪方法在处理模拟信号时具有明显优势。因此, 本节对全桥模型试验的实测振动信号进行分解重构, 以验证本文所提降噪方法的优势与实用性。

值得说明的是, 实测信号中的真正有用信息未知, 式 (4)~(9) 所示的降噪性能评价指标不再适用。而对于实际多输出的桥梁振动测试信号, 其包含了结构频率、阻尼和振型等信息, 可采用稳定图^[25]来识别结构振动信号中所包含的桥梁信息。因此, 本

节中结合稳定图对 AVMDR 的降噪效果进行验证、对比与评价。

2.2.1 曲线斜拉模型桥

如图 5 所示, 曲线斜拉模型桥为双塔双索面半漂浮结构体系, 其缩尺比为 1/20, 跨度对称布置为 (2.45+4.05+14.25+4.05+2.45) m。主梁曲率半径为 27.5 m, 采用菱形索塔, 共设有 60 对空间布置的斜拉索^[26]。桥梁主梁上分别安装了 14 个竖向加速度传感器和 9 个横向加速度传感器, 采样频率为 256 Hz。图 5 中传感器名称中的首字母 H 和 S 分别表示横向和竖向加速度传感器。

模型桥共进行了 78 个动力工况测试, 图 6 中展示了某测试工况下, 14 个竖向加速度传感器测试数

据经 AVMDR 分解重构后的结果, 该工况为主梁跨中受竖向冲击后的自由衰减。




图 5 曲线斜拉模型桥及加速度传感器布置(单位: cm)

Fig. 5 Curved cable-stayed model bridge and acceleration sensor arrangement (Unit: cm)

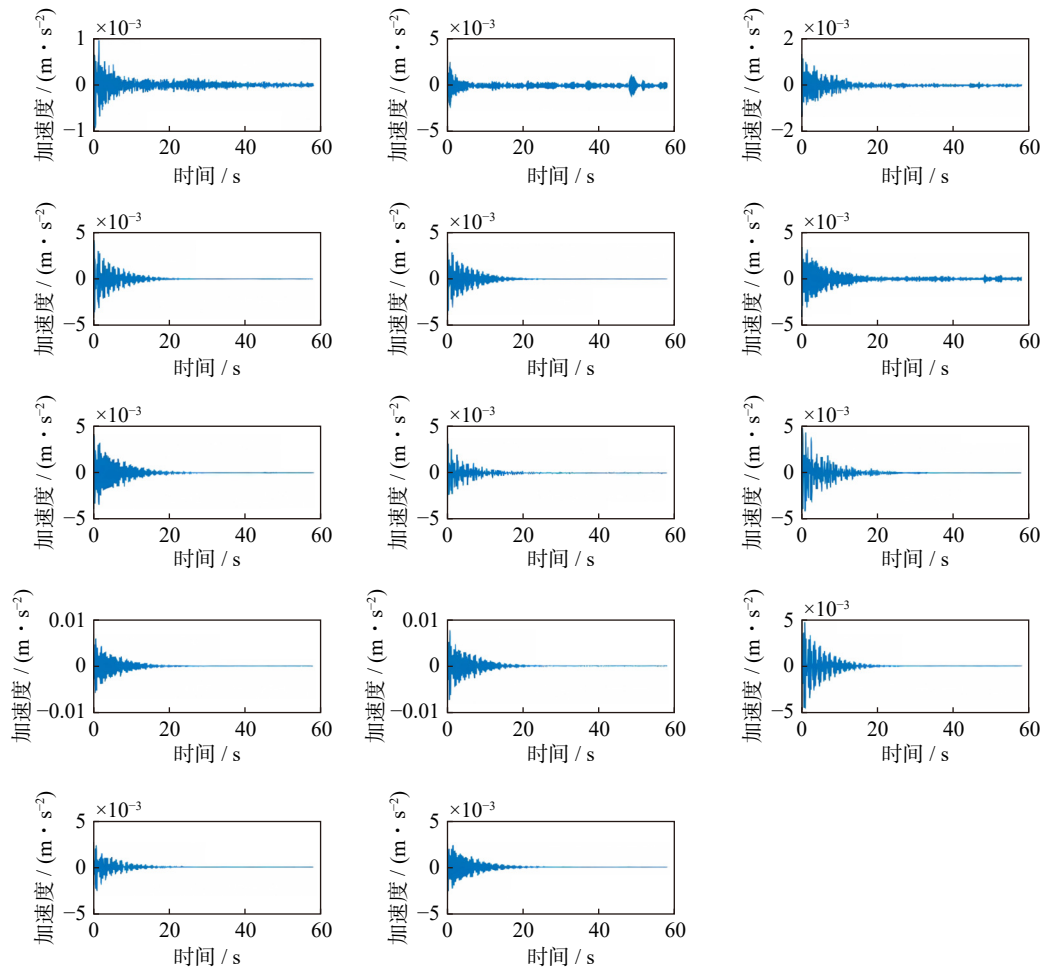


图 6 降噪后的竖向加速度信号

Fig. 6 Vertical acceleration signal after noise reduction

基于该工况下各类方法降噪前、后的 14 条实测加速度数据, 采用随机子空间方法^[27] 识别结构模态

参数。获取原始测试数据以及采用 AVMDR 方法降噪后测试数据的稳定图, 如图 7 所示。图 7 中, 蓝色

稳定轴代表频率稳定;绿色稳定轴代表频率、阻尼比稳定;红色稳定轴代表频率、阻尼比和振型均稳定。基于稳定图的结构模态参数识别方法认为,频率、阻尼比和振型均稳定的结果为可靠结构模态参数^[27]。因此,本文采用红色稳定轴数量为评判指标

来度量获得的结构频率、阻尼比和振型信息的多少。同时,采用有限元理论计算该曲线斜拉桥的竖向模态频率信息,并与识别到的结构模态频率进行对比,如表5所示。表5中同时给出了实测信号经EMD、EEMD、AEMD、EWT分解重构后识别的频率值。

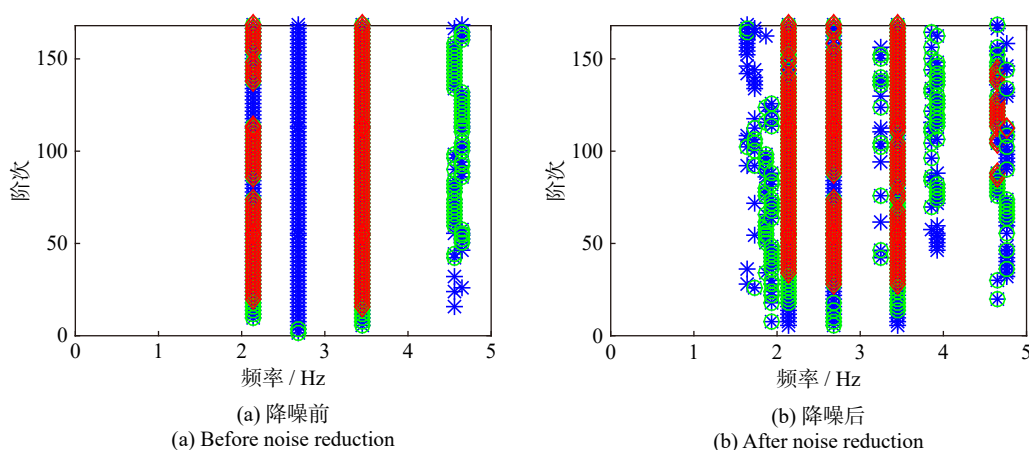


图 7 降噪前、后信号的稳定图

Fig. 7 Stability chart of signal before and after noise reduction

表 5 曲线斜拉桥模型竖向频率识别结果对比

Tab. 5 Comparison of vertical frequency recognition results of curved cable-stayed bridge models

阶次	模态频率/Hz						
	理论值	原始数据	EMD	EEMD	AEMD	EWT	AVMDR
Fr-1	2.14	2.1376	2.1381	2.1381	2.1389	2.1382	2.1391
Fr-2	2.68	—	—	—	—	—	2.6794
Fr-3	3.44	3.4538	3.4535	3.4514	3.4495	3.4509	3.4488
Fr-4	3.96	—	—	—	—	—	—
Fr-5	4.65	—	—	—	4.6497	—	4.6484

从图7中可明显看出,原始信号在0~5 Hz频率范围内,仅包含两条红色稳定轴,即仅可确定结构的二阶频率、阻尼比和振型;而经AVMDR降噪后的信号在0~5 Hz频率范围内,至少存在四条红色稳定轴,即可确定结构的四阶频率、阻尼比和振型。这表明,从AVMDR降噪后的信号中,能识别更多的结构模态,提取更多的结构信息,实测结构频率及阶次和理论值接近且相对应。此外,从表5中可以发现,EMD、EEMD和EWT方法仅能获取二阶结构模态参数,AEMD方法能获取三阶结构模态参数。各类方法在

获取的结构频率数量上存在明显差异,在精度方面却保持统一水平。利用AVMDR方法实测第三阶竖向频率与理论值的最大偏差为0.4%,实测结果与理论值接近,存在的微小差异是理论模型与实际结构的偏差导致的。从识别结果来看,经AVMDR方法处理后,其结果精度与理论计算值更为接近,且能够与数值计算结果的阶次相对应,这从侧面反映了随机子空间方法的稳定性。经AVMDR方法处理后,结构模态参数识别结果在数量上优于未经处理的信号以及其他4种常用方法,能额外识别到第2阶与第5阶结构模态信息,表明该方法具有良好的降噪性能,AVMDR方法可为桥梁结构监测信号的降噪和信息深度挖掘提供便利。

2.2.2 斜拉桥振动台模型

该斜拉桥模型总长32 m,采用双塔和双索面5跨布置,其跨度布置为(2.9+3.6+19+3.6+2.9) m,桥梁模型示意及传感器布置如图8所示。振动台试验模拟荷载工况包括白噪声、场地波和不同振幅的CHICHI波^[25]。主梁的横向结构响应以及桥塔的振动响应由单向压电加速度传感器获取^[25]。本文以CHICHI波




图 8 斜拉桥振动台模型及加速度传感器布置(单位: cm)

Fig. 8 Shaking table model and acceleration sensor arrangement of cable-stayed bridge (Unit: cm)




图 9 降噪后的桥塔振动信号

Fig. 9 Bridge tower vibration signal after noise reduction


激励下的斜拉桥桥塔横向振动响应为例进行说明, 经 AVMDR 降噪后的加速度时程曲线如图 9 所示。

振动台试验中, 结构的输入和输出信号已知, 采用确定随机子空间识别方法从桥塔的振动响应信号中识别结构模态参数^[28]。获取原始数据与降噪后数据的稳定图, 如图 10 所示。同时, 采用有限元理论计算该斜拉桥桥塔的横向模态频率信息, 并与识别到的结构模态频率进行对比, 如表 6 所示。表中同时给出了实测信号经 EMD、EEMD、AEMD、EWT 分解重构后识别的频率值。


表 6 振动台模型桥塔横向频率识别结果对比

Tab. 6 Comparison of transverse frequency recognition results of shaking table model bridge tower

阶次	模态频率/Hz						
	理论值	原始数据	EMD	EEMD	AEMD	EWT	AVMDR
Fr-1	2.63	2.6915	2.6863	2.6693	2.6209	2.6323	2.6190
Fr-2	4.09	4.1170	4.1113	4.1098	4.1093	4.1051	4.1071
Fr-3	8.72	8.6602	8.6698	8.6875	8.7092	8.7023	8.7236
Fr-4	10.12	—	—	—	—	—	—
Fr-5	13.07	—	—	—	13.1421	13.1163	13.1361



(a) 降噪前
(a) Before noise reduction



(b) 降噪后
(b) After noise reduction

图 10 降噪前、后信号的稳定图

Fig. 10 Stability chart of signal before and after noise reduction

由图 10 可知, 在 0~15 Hz 频率范围内, 原始测试

信号稳定图仅可获得 3 阶频率、阻尼比和振型信息, 分别处于 2~4 Hz、4~6 Hz、8~10 Hz 范围内。基于 AVMDR 重构降噪后信号的稳定图可获得 4 阶频率、阻尼比和振型信息, 除原始信号识别的 3 阶模态参数外, 还在 12~14 Hz 频率范围内, 出现新的结构模态成分, 各阶频率分别为 2.6190、4.1071、8.7236 和 13.1361 Hz。AVMDR 方法识别得到的频率值相较于未经处理的数据, 其与理论值更为接近。此外, 从表 6 中可以发现, EMD 与 EEMD 方法处理后的信号只能识别出 3 阶结构模态参数, 和未经处理的信号相当。AEMD 方法和 EWT 方法虽然能额外识别出第 5 阶模态成分, 但是其对于各阶成分的识别精度并不稳定。AVMDR 方法在获取结构模态参数方面不仅具有数量上的优势, 还能在识别精度方面保持较好的稳定性。值得注意的是, 第 4 阶成分由于噪声或者激励原因, 各类方法均未有效识别。实测结构频率及阶次和理论计算值相互对应, 能够正确有效识别出各阶模态频率成分。结合表 6 与图 10 分析结果可知, 桥梁监测信号经 AVMDR 分解重构后, 不仅可使已有的动力指纹信息更为可靠, 还能从噪声污染的实测数据中挖掘更多的结构动力指纹信息。

3 结 论

针对 VMD 方法存在的分解成分数量需预先确定的缺点, 通过引入经验模态分解和多尺度主成分

分析对其进行了自适应改进。全面总结了各类分解重构降噪方法存在的优缺点,基于含噪模拟信号对各类方法的降噪性能进行了全面的分析。对 AVMDR 的实际应用效果进行了评价,主要结论如下:

(1)通过引入经验模态分解和主成分分析,AVMDR 算法可自适应确定分解成分数量,提升了算法的自适应能力和计算效率。

(2)基于模拟信号的对比分析结果发现,AVMDR 的 6 种降噪指标均优于 EMD、EEMD、AEMD、EWT 方法,且其具有相对最高的信噪比。

(3)AVMDR 方法对于实测桥梁监测数据的降噪效果良好,在剔除信号噪声的同时,能够最大程度地保留结构信息。

AVMDR 方法在桥梁结构监测信号的时频域降噪方面展现了巨大的潜力和优势。通过进一步的算法优化来提升其鲁棒性和稳定性,有望在更加广泛的应用场景中发挥重要作用。

参考文献:

- [1] 张二华,单德山,李乔.基于多尺度递归图理论的桥梁微弱信号非线性非平稳检验[J].振动与冲击,2019,38(16):123-128.
ZHANG Erhua, SHAN Deshan, LI Qiao. Nonlinear and nonstationary detection of weak bridge signals based on the multiscale recurrence plot theory[J]. Journal of Vibration and Shock, 2019, 38(16): 123-128.
- [2] VAGNOLI M, REMENYTE-PRESCOTT R. An automatic bridge damage diagnostics method using empirical mode decomposition based health indicators and neuro-fuzzy classification[J]. Structural Control and Health Monitoring, 2022, 29(10): e3027.
- [3] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London Series A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903-995.
- [4] YAN Z, TENG S, LUO W, et al. Bridge modal parameter identification from UAV measurement based on empirical mode decomposition and Fourier transform[J]. Applied Sciences, 2022, 12(17): 8689.
- [5] XIAO F, CHEN G S, ZATAR W, et al. Signature extraction from the dynamic responses of a bridge subjected to a moving vehicle using complete ensemble empirical mode decomposition[J]. Journal of Low Frequency Noise, Vibration and Active Control, 2021, 40(1): 278-294.
- [6] MOUSAVI A A, ZHANG C W, MASRI S F, et al. Damage detection and characterization of a scaled model steel truss bridge using combined complete ensemble empirical mode decomposition with adaptive noise and multiple signal classification approach[J]. Structural Health Monitoring, 2022, 21(4): 1833-1848.
- [7] MOUSAVI A A, ZHANG C W, MASRI S F, et al. Structural damage detection method based on the complete ensemble empirical mode decomposition with adaptive noise: a model steel truss bridge case study[J]. Structural Health Monitoring, 2022, 21(3): 887-912.
- [8] BISHEH H B, AMIRI G G, NEKOOEI M, et al. Damage detection of a cable-stayed bridge based on combining effective intrinsic mode functions of empirical mode decomposition using the feature selection technique[J]. Inverse Problems in Science and Engineering, 2021, 29(6): 861-881.
- [9] DELGADILLO R M, CASAS J R. Bridge damage detection via improved completed ensemble empirical mode decomposition with adaptive noise and machine learning algorithms[J]. Structural Control and Health Monitoring, 2022, 29(8): e2966.
- [10] GILLES J. Empirical wavelet transform[J]. IEEE Transactions on Signal Processing, 2013, 61(16): 3999-4010.
- [11] MOUSAVI A A, ZHANG C W, MASRI S F, et al. Damage detection and localization of a steel truss bridge model subjected to impact and white noise excitations using empirical wavelet transform neural network approach[J]. Measurement, 2021, 185: 110060.
- [12] WANG M Y, SHENG X Z. Combining empirical wavelet transform and transfer matrix or modal superposition to reconstruct responses of structures subject to typical excitations[J]. Mechanical Systems and Signal Processing, 2022, 163: 108162.
- [13] FANG Z, YU J Y, MENG X L. Modal parameters identification of bridge structures from GNSS data using the improved empirical wavelet transform[J]. Remote Sensing, 2021, 13(17): 3375.
- [14] QIN S Q, TANG J, FENG J C, et al. Modal parameter identification in civil structures via Hilbert transform ensemble with improved empirical wavelet transform[J]. Journal of Vibration and Control, 2024, 30(7-8): 1621-1634.
- [15] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [16] DAN D H, ZENG G, PAN R Y, et al. Block-wise recursive sliding variational mode decomposition method and its application on online separating of bridge vehicle-induced strain monitoring signals[J]. Mechanical Systems and Signal Processing, 2023, 198: 110389.
- [17] YANG X M, QU C X, YI T H, et al. Modal analysis of a bridge during high-speed train passages by enhanced variational mode decomposition[J]. International Journal of Structural Stability and Dynamics, 2020, 20(13): 2041002.
- [18] MOUSAVI M, HOLLOWAY D, OLIVIER J C, et al.

- Beam damage detection using synchronisation of peaks in instantaneous frequency and amplitude of vibration data[J]. *Measurement*, 2021, 168: 108297.
- [19] LIU T, LI J, CAI X F, et al. A time-frequency analysis algorithm for ultrasonic waves generating from a debonding defect by using empirical wavelet transform[J]. *Applied Acoustics*, 2018, 131: 16-27.
- [20] LIU T, LUO Z J, HUANG J H, et al. A comparative study of four kinds of adaptive decomposition algorithms and their applications[J]. *Sensors*, 2018, 18(7): 2120.
- [21] CIVERA M, SURACE C. A comparative analysis of signal decomposition techniques for structural health monitoring on an experimental benchmark[J]. *Sensors*, 2021, 21(5): 1825.
- [22] 单德山, 李乔, 黄珍. 桥梁动力测试信号的自适应分解与重构[J]. *振动与冲击*, 2015, 34(3): 1-6.
SHAN Deshan, LI Qiao, HUANG Zhen. Adaptive decomposition and reconstruction for bridge structural dynamic testing signals[J]. *Journal of Vibration and Shock*, 2015, 34(3): 1-6.
- [23] SHAN D S, YU Z R, LONG Q C, et al. Nonlinear and nonstationary detection and quantification of multi-scale measured signals for bridge structure[J]. *Measurement Science and Technology*, 2024, 35(4): 046117.
- [24] RABIE T. Robust estimation approach for blind denoising[J]. *IEEE Transactions on Image Processing*, 2005, 14(11): 1755-1765.
- [25] 单德山, 石磊, 谭康熹. 联合卷积神经网络与长短期记忆深度网络的桥梁损伤识别[J]. *桥梁建设*, 2023, 53(4): 41-46.
SHAN Deshan, SHI Lei, TAN Kangxi. Bridge damage identification based on Joint CNN and LSTM deep network[J]. *Bridge Construction*, 2023, 53(4): 41-46.
- [26] 郭珊. 曲线斜拉桥模型设计及试验研究[D]. 成都: 西南交通大学, 2017.
GUO Shan. Model design and experimental study of curved cable stayed bridge[D]. Chengdu: Southwest Jiaotong University, 2017.
- [27] 单德山, 黄珍, 李乔. 桥梁结构运营模态参数识别方法对比[J]. *桥梁建设*, 2017, 47(5): 24-29.
SHAN Deshan, HUANG Zhen, LI Qiao. Comparison of operational modal parameter identification methods for bridge structures[J]. *Bridge Construction*, 2017, 47(5): 24-29.
- [28] ZHANG E H, WU D, SHAN D S. Novel tensor subspace system identification algorithm to identify time-varying modal parameters of bridge structures[J]. *Structural Health Monitoring*, 2022, 21(4): 1541-1554.

第一作者:单德山(1968—),男,博士,教授。

E-mail: dsshan@163.com

通信作者:余忠儒(1995—),男,博士研究生。

E-mail: zhongru_yu_swjtu@163.com