

大跨径桥梁 GNSS-RTK 监测数据的 IVMD 与 ICA 联合去噪算法*

熊春宝¹, 刘杰丽¹, 王 猛¹, 熊爱成², 叶作安²

(1. 天津大学建筑工程学院 天津, 300350)

(2. 天津市陆海测绘有限公司 天津, 300304)

摘要 针对全球卫星导航系统(global navigation satellite system, 简称 GNSS)动态差分(real-time kinematic, 简称 RTK)技术对大跨径桥梁进行动态监测时产生的背景噪声问题, 提出了一种改进的变分模态分解(improved variational mode decomposition, 简称 IVMD)联合独立分量分析(independent component analysis, 简称 ICA)的去噪算法。首先, 为自适应确认变分模态分解的分解层数, 提出了基于最小模糊熵稳定准则的 IVMD 算法, 并用一组仿真信号验证了该算法的性能优于添加自适应噪声的完备集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, 简称 CEEMDAN); 其次, 将 IVMD 算法用于一大跨径桥梁的 GNSS-RTK 变形监测数据中进行信噪分离, 基于相关系数和自相关归一化特征构造主要噪声分量, 与原始监测数据组成 ICA 的输入矩阵, 进行解混降噪, 以获得结构最终的振动位移。结果表明, 所提的联合算法能够有效削弱 GNSS-RTK 监测数据中的背景噪声, 去噪效果比 CEEMDAN、IVMD 和 CEEMDAN-ICA 更佳, 可有效应用于大跨径桥梁的结构健康监测中。

关键词 大跨径桥梁; 全球卫星导航系统-动态差分; 变分模态分解; 独立分量分析; 数据去噪

中图分类号 TU196; P228

0 引 言

桥梁是我国交通的关键枢纽, 因其长期受风荷载、外界环境温度变化、车辆荷载及自身材料性能退化^[1]等因素的影响, 可能会在远没有达到设计使用年限时发生不同程度的结构损伤甚至倒塌, 对桥梁进行定期健康监测以保证结构的安全性能至关重要。GNSS-RTK 可全天候高精度实时获取结构的三维位移信息, 已广泛应用于桥梁结构的健康监测中^[2]。但是, 由于卫星、信号传播途径及接收机等的影响, 会产生监测误差, 其中绝大部分误差可以通过 RTK 系统内部差分技术消除, 背景噪声则需通过一定的去噪算法才能被削弱。目前, 以经验模态分解(empirical mode decomposition, 简称 EMD)为基础的系列算法是较常用的去噪算法。EMD 算法可将非平稳、非线性的信号分解为若干个本征模态函数(intrinsic mode function, 简称 IMF)分量, 自适应地进行信号主要成分的分析, 但也存在缺乏理论基础、端点效应及模态混叠^[3]等缺陷。改进算法如

CEEMDAN^[4], 相较于集合经验模态分解(ensemble empirical mode decomposition, 简称 EEMD)和完备集合经验模态分解(complete ensemble empirical mode decomposition, 简称 CEEMD)更能抑制模态混叠, 提升重构精度, 但会产生更多的冗余和虚假分量^[5]。此外, 变分模态分解(variational mode decomposition, 简称 VMD)^[6]也是一种有效的去噪算法, 为一种非递归变分模式的信号分解方法, 可以通过选取合适的分解层数 k 来避免出现模态混叠和虚假分量。文献[7]通过最小样本熵准则确定分解层数, 但缺少定量指标描述样本熵的变化情况。文献[8]利用中心频率混叠熵并设定阈值范围来确定模态数, 适用于滚动轴承故障振动信号特点。文献[9-10]利用智能优化算法选取合适的 k 值, 计算量大且易得到局部最优解。

ICA 是一种不依赖于先验知识的盲源分离方法, 其可以从观测信号中推断出原始独立成分信号的近似估计, 多用于故障诊断、生物医学及语音处理等领域^[11-13], 但 ICA 必须满足观测信号数量不少于

* 国家自然科学基金面上资助项目(61971037)

收稿日期: 2023-09-19; 修回日期: 2023-11-17

源信号数量的前提条件,无法处理单通道信号。在 GNSS 变形监测中,只有一个位移输入信号,却至少存在噪声和振动位移两个输出。文献[14]结合 EMD 与 ICA 算法,削弱了全球定位系统动态变形监测中的多路径效应。文献[15]将快速独立成分分析融入到 EEMD 算法中,成功提取了桥梁结构的模态参数。

以上研究表明,单一的滤波方法难以满足去噪要求。本研究综合考虑 VMD 和 ICA 算法的优点,进行联合去噪,通过最小模糊熵(fuzzy entropy, 简称 FE)稳定准则来确定 VMD 算法中 k 值的选取问题,联合改进的 VMD 与 ICA 算法也可解决单通道的信噪分离问题。利用该算法对天津海河大桥监测数据进行去噪处理,获得结构真实的振动位移信息,并与单一的 IVMD、CEEMDAN 和 CEEMDAN-ICA 算法进行比较,以验证所提算法的去噪效果。

1 基本理论

1.1 VMD 算法

不同于 EMD 所定义的 IMF 分量,VMD 算法定义了约束条件更加严格的本征模态函数 $u_k(t)$ ^[16],其数学表达式为

$$u_k(t) = A_k(t) \cos(\varphi_k(t)) \quad (1)$$

其中: $A_k(t)$ 为信号 $u_k(t)$ 的包络幅值; $\varphi_k(t)$ 为瞬时相位。

假设原始信号 $f(t)$ 被分解为 k 个模态分量,约束条件为各个模态分量之和等于原始信号,同时确保每个模态分量中心频率的带宽之和最小。算法具体步骤如下。

1) 构造变分问题。相应的约束变分表达式为

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s. t. } \sum_k u_k(t) = f(t) \quad (2)$$

其中: ∂_t 为对 t 求导; $\delta(t)$ 为狄利克雷函数; $\{u_k\}$ 、 $\{\omega_k\}$ 分别为分解后第 k 个模态分量和中心频率; $*$ 表示卷积运算; j 为虚数单位。

2) 引入拉格朗日乘法算子 $\lambda(t)$, 将约束变分问题转化为非约束变分问题。增广的拉格朗日表达式为 $L(\{u_k\}, \{\omega_k\}, \{\lambda(t)\}) =$

$$\alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \quad (3)$$

其中: α 为二次惩罚因子。

3) 通过交替方向乘子法求解变分问题,利用模态分量 u_k 和中心频率 ω_k 的迭代式更新各分量和对应中心频率,得到式(2)的最优解时算法终止。

1.2 基于最小模糊熵稳定准则的改进 VMD 算法

VMD 算法虽然能够抑制模态混叠和虚假分量,但需要预设合适的模态分解层数,分解层数过大或过小,都无法得到理想的信号分解效果。为选取合适的分解层数,本研究引入模糊熵^[17]的概念,提出基于最小模糊熵稳定准则的改进 VMD 算法,即 IVMD 算法。

模糊熵是对样本熵的改进。样本熵值缺乏连续性,对阈值的选择比较敏感。模糊熵利用指数函数代替单位阶跃函数,使熵值随参数连续均匀变化,可达到类似于“软阈值”度量的效果^[8],提高了衡量序列复杂性的精度。序列产生新模式的概率越大,其复杂性越高,熵值越大。模糊熵的计算步骤如下。

1) 对长度为 N 的时间序列构造 m 维向量,即

$$X(i) = [x(i), x(i+1), \dots, x(i+m-1)] - x_0(i) \\ (i = 1, 2, \dots, N-m+1) \quad (4)$$

其中: m 为嵌入维数; $x_0(i) = \frac{1}{m} \sum_{k=0}^{m-1} x(i+k)$, 为 m 个连续 $x(i)$ 的均值。

2) 距离 $d_{i,j}^m$ 为时间序列 $X(i)$ 和 $X(j)$ 对应位置元素差值的最大值,其表达式为

$$d_{i,j}^m = \max_{k \in (0, m-1)} |(x(i+k) - x_0(i)) - (x(j+k) - x_0(j))| \\ (i, j = 1, 2, \dots, N-m+1; i \neq j) \quad (5)$$

3) 利用模糊隶属度函数来度量 $X(i)$ 与 $X(j)$ 之间的相似度,即

$$D_{i,j}^m = e^{-\left(\frac{d_{i,j}^m}{r}\right)^n} \quad (6)$$

其中: r 为相似容限阈值,本研究取信号标准差的 0.15 倍; n 为相似容限边界的梯度,一般取 2。

4) 定义函数

$$\phi^m(n, r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left(\frac{1}{N-m-1} \sum_{j=1, j \neq i}^{N-m} D_{i,j}^m \right) \quad (7)$$

5) 增加维数到 $m+1$, 重复上述步骤,得到

$$\phi^{m+1}(n, r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left(\frac{1}{N-m-1} \sum_{j=1, j \neq i}^{N-m} D_{i,j}^{m+1} \right) \quad (8)$$

6) 序列的模糊熵 $FE(m, n, r)$ 为

$$FE(m, n, r) = \lim_{N \rightarrow \infty} (\ln \phi^m(n, r) - \ln \phi^{m+1}(n, r)) \quad (9)$$

当 N 取有限值时, 式(9)可表示为

$$FE(m, n, r) = \ln \phi^m(n, r) - \ln \phi^{m+1}(n, r) \quad (10)$$

VMD 算法将原始信号分解为 k 个由低频到高频排列的 IMF 分量, 计算每个 IMF 分量的 FE 值, FE 取最小值时的 IMF 分量为趋势分量。当 k 值过小时, 信号欠分解, 趋势分量中包含噪声成分较多, 信号序列的随机性大, 模糊熵值相应较大。随着分解层数增大, 趋势分量中有效成分占主导地位, 噪声被充分地分离出去, FE 值变小且趋于稳定。本研究选用相邻分解层数的最小模糊熵比值 $Q(i)$, 并设定阈值 δ 来定量描述 FE 值的稳定情况。定义 $Q(i) = FE_i / FE_{i-1}$, 当从某一分解层数 i 开始, $Q(i)$ 均大于或等于 δ , 可认为最小模糊熵值已经处于稳定状态, 选取 FE 值趋于稳定的转折点所在的分解层数 $i-1$ 作为最佳 k 值。经过大量仿真实验分析, 阈值 δ 取 0.95 较合适。根据该思路, 构建基于最小模糊熵稳定准则的改进 VMD 算法。IVMD 算法流程如图 1 所示。




图 1 IVMD 算法流程

Fig.1 Algorithm flow of IVMD

1.3 ICA 算法

经典 ICA 模型^[18]可表示为

$$X(t) = AS(t) \quad (11)$$

其中: $X(t) = [x_1(t), x_2(t), \dots, x_m(t)]^T$, 为 m 维观测信号; $S(t) = [s_1(t), s_2(t), \dots, s_n(t)]^T$, 为 n 维相互独立的源信号; A 为 $m \times n$ 阶满秩矩阵 ($m \geq n$)。

考虑到观测信号中含有噪声, $X(t)^{[19]}$ 可写成

$$X(t) = \left[S(t) + \sum a_i n_i \right] = \begin{bmatrix} 1 & a_1 & \dots & a_d \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix} \begin{bmatrix} S \\ n_1 \\ \vdots \\ n_d \end{bmatrix} = AS(t) \quad (12)$$

其中: $n_i(t) = [n_1, n_2, \dots, n_d]^T$, 为 d 维噪声分量; a_i 为噪声 n_i 的权重。

源信号 $S(t)$ 受噪声干扰得到观测信号 $X(t)$, ICA 就是在源信号与混合矩阵 A 均未知的情况下, 通过一定的优化准则求解解混矩阵 W , 即 A^{-1} , 从而得到源信号的近似估计 Y 为

$$Y = WX = WAS(t) \approx S(t) \quad (13)$$

由于缺乏先验知识, 经 ICA 所得的源信号会产生幅值不确定的问题, 影响去噪信号的位移大小。利用最小失真准则 (minimal distortion principle, 简称 MDP) 修正解混矩阵 W , 再将修正后的矩阵 W' 与 ICA 的输入观测信号分量相乘, 得到最终的输出独立分量^[19]。其计算公式为

$$\begin{cases} W' = \text{diag}(\text{diag}(W^{-1}))W \\ IC = W'X(t) \end{cases} \quad (14)$$

本研究选用基于负熵最大化的快速独立成分分析实现盲源分离, 详细步骤参见文献[18]。

1.4 IVMD 与 ICA 联合去噪算法

IVMD-ICA 算法流程如图 2 所示。




图 2 IVMD-ICA 算法流程

Fig.2 Algorithm flow of IVMD-ICA

首先, 基于最小模糊熵稳定准则自适应确定最佳分解层数, 并对原始信号进行 IVMD 分解, 得到一系列 IMF 分量; 其次, 根据各 IMF 分量与原始信号的相关系数大小, 结合自相关归一化函数图像特征, 筛选出含噪声成分多的分量重构为 C_1 , 将 C_1 引入虚拟噪声通道, 与原始观测信号 $X(t)$ 组成快速独立成分分析的输入矩阵进行解混降噪, 一维观测信号扩展成了多维, 有效解决了 ICA 算法的欠定问题; 最后, 对 ICA 输出的独立分量 IC_1 利用 MDP 准则消除幅值不确定的影响, 得到最终去噪信号 $X'(t)$ 。

利用信噪比 (signal-to-noise ratio, 简称 SNR) 和均方根误差 (root mean square error, 简称 RMSE) 评价去噪效果, 其数学表达式为

$$SNR = 10 \lg \left\{ \frac{\sum_{i=1}^N X^2(i)}{\sum_{i=1}^N [X(i) - X'(i)]^2} \right\} \quad (15)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N [X'(i) - X(i)]^2} \quad (16)$$

其中: $X(i)$ 为原始信号; $X'(i)$ 为去噪信号; N 为信号数据长度。

2 IVMD 性能分析与对比

本研究选取一组仿真信号来检验 IVMD 算法的性能,仿真信号如图 3 所示。原始信号 $F(t)$ 由正弦信号、余弦信号和信噪比为 7 dB 的噪声分量 $n(t)$ 组成。图 3(a)、(b) 分别显示了纯净信号 $f(t)$ 与加噪信号 $F(t)$ 的时域图像。设采样频率为 100 Hz,采样时间为 10 s,仿真信号表达式为

$$\begin{cases} f_1(t)=7\sin(2\pi\times 1.5t) \\ f_2(t)=3\sin(2\pi\times 10t) \\ f_3(t)=\cos(2\pi\times 20t) \\ F(t)=\underbrace{f_1(t)+f_2(t)+f_3(t)}_{f(t)}+n(t) \end{cases} \quad (17)$$

分别对仿真信号 $F(t)$ 进行 CEEMDAN 与 IVMD 分解,比较 2 种算法的信噪分离效果。仿真信号 CEEMDAN 分解结果如图 4 所示。观察时域图像可知,CEEMDAN 分解出 10 个 IMF 分量和 1 个残余分量 R_n ,产生了大量的冗余和虚假分量。




图 3 仿真信号
Fig.3 Simulated signal

自适应选取分解层数 k 的最优值,对 $F(t)$ 进行 IVMD 分解,预设 IVMD 的分解层数范围为 2~11,其中最大分解层数取 CEEMDAN 自动生成的模式数(即 11 个 IMF 分量)。各个 k 值下的最小模糊熵值及相邻模糊熵比值 $Q(i)$ 见表 1。

由表 1 可知,当 $k\geqslant 5$ 时,所有 $Q(i)$ 均大于 0.95,表明最小模糊熵值基本处于稳定状态,故取分解层数 $k=4$,此时 VMD 分解性能最佳。仿真信号 IVMD 分解结果如图 5 所示。

图 6 为 2 种算法分解的部分 IMF 分量频谱图。由于篇幅限制,这里只给出 CEEMDAN 分解后的前 6 阶和 IVMD 分解后的前 3 阶频谱图。由图可知:与 CEEMDAN 算法相比,IVMD 算法未出现明显的频率泄露和过分解问题,且准确识别出了 $F(t)$ 中的 3 个有效信号频率,去噪也较为充分;CEEMDAN 算法的模式混叠现象严重,10 Hz 的频率分别出现在 $\text{IMF}_2\sim\text{IMF}_4$ 中,且 IMF_2 包含的噪声仍较多。




图 4 仿真信号 CEEMDAN 分解结果
Fig.4 Simulated signal decomposed result by CEEMDAN

表 1 最小模糊熵值及相邻比值(仿真信号分解结果)
Tab.1 Minimum fuzzy entropy and adjacent ratio (simulated signal decomposition result)

k	最小模糊熵值	$Q(i)$	k	最小模糊熵值	$Q(i)$
2	0.288 9	—	7	0.239 1	0.996 4
3	0.265 5	0.919 2	8	0.238 8	0.998 8
4	0.240 6	0.906 3	9	0.238 8	0.999 8
5	0.240 3	0.998 5	10	0.238 6	0.999 3
6	0.239 9	0.998 5	11	0.238 6	1.000 0




图 5 仿真信号 IVMD 分解结果
Fig.5 Simulated signal decomposed result by IVMD




图 6 2 种算法分解的部分 IMF 分量频谱图

Fig.6 The frequency spectrums of some IMF components by two algorithms

为选取主要包含有效信号的 IMF 分量重构,结合各分量与原始信号 $F(t)$ 的相关系数大小和其自相关特征进行综合筛选。相关系数表达式为

$$R = \frac{\sum_{i=1}^N (X(i) - \bar{X})(\text{IMF}(i) - \overline{\text{IMF}})}{\sqrt{\sum_{i=1}^N (X(i) - \bar{X})^2 \sum_{i=1}^N (\text{IMF}(i) - \overline{\text{IMF}})^2}} \quad (18)$$

其中: $X(i)$ 为原始信号; $\text{IMF}(i)$ 为各 IMF 分量。
 $|R| \leq 1$, R 值越大, 则模态分量与原信号的相关性越大。当 $R < 0.3$ 时^[5], 两者为弱相关。2 种算法分解的 IMF 分量与 $F(t)$ 的相关系数见表 2。

图 7 为 2 种算法分解的 IMF 分量的自相关归一化函数。可见, 噪声信号和有效信号的图像峰值均在零点处, 而在其余点上, 噪声信号的幅值快速衰减到非常小, 有效信号的波形则随时间上下波动^[2]。

综合相关系数和自相关归一化函数图像可知: IVMD 分解出的 IMF_3 为有效信息分量, 予以保留, 选择 $\text{IMF}_1 \sim \text{IMF}_3$ 作为 IVMD 的重构信号; CEEMDAN 分解出的 IMF_1 噪声成分多, 故舍弃, 将 $\text{IMF}_2 \sim \text{IMF}_6$ 重构, 作为最终的去噪信号。

表 2 2 种算法分解的 IMF 分量与 $F(t)$ 的相关系数

Tab.2 Correlation coefficients of each IMF component generated by two signal decomposition algorithms with $F(t)$

模态分量	IVMD	CEEM-DAN	模态分量	IVMD	CEEM-DAN
IMF ₁	0.784 7	0.450 7	IMF ₇	—	0.156 6
IMF ₂	0.386 6	0.312 9	IMF ₈	—	0.046 5
IMF ₃	0.265 6	0.417 4	IMF ₉	—	0.082 3
IMF ₄	0.268 0	0.333 4	IMF ₁₀	—	0.070 6
IMF ₅	—	0.443 0	R_n	—	0.048 6
IMF ₆	—	0.765 8			




图 7 2 种算法分解的 IMF 分量的自相关归一化函数

Fig.7 IMF autocorrelation normalization functions decomposed by two algorithms

纯净信号与重构信号如图 8 所示。可知,由 IVMD 处理后的信号与原始纯净信号波形更接近,重构误差更小。因此,IVMD 算法能够提取更多的有效信号,去噪性能优于 CEEMDAN 算法。

为进一步比较 2 种算法在添加不同信噪比噪声时的去噪效果,分别对加入 3、5、7 和 9 dB 信噪比噪声的信号进行定量分析。不同算法的性能评估见表 3。可以看出:经 IVMD 处理的信号,信噪比均大于相同条件下经 CEENDAN 处理的信号,且均方根误差也更小;随着噪声信噪比的增加,2 种算法的降噪水平也随之提升,但 IVMD 降噪效果更加显著。这表明 IVMD 算法能提取更多加噪信号中的有效

信息成分,重构后的信号也与原始信号的误差更小,与上述图像分析结果一致。




图 8 纯净信号与重构信号

Fig.8 The pure signal and recombined signal

表 3 不同算法的性能评估

Tab.3 Performance evaluation for different algorithms

去噪算法	添加噪声信噪比/dB							
	3		5		7		9	
	SNR	RMSE	SNR	RMSE	SNR	RMSE	SNR	RMSE
IVMD	9.862 8	1.769 1	12.152 5	1.373 4	12.274 6	1.321 8	15.769 6	0.889 7
CEEMDAN	7.089 8	2.502 2	8.962 0	2.014 1	10.971 2	1.588 2	12.188 6	1.338 9

3 海河大桥监测实例

3.1 工程概况

天津海河大桥全景如图 9 所示。该桥梁全长为 2 838 m,为钢混组合结构的大跨度斜拉桥,由新旧两座主桥组成且均为独塔双索面。主桥桥面宽为 23 m,“A 型”主塔塔高为 167.3 m,设计为双向 8 车道,行车时速可达 80 km/h。



图 9 天津海河大桥全景

Fig.9 Panoramic view of Tianjin Haihe Bridge

3.2 GNSS-RTK 监测实验

本次实验的现场仪器布置如图 10 所示。实验仪器为海星达 H32 型 GNSS-RTK 接收机,能够同时接收来自 GPS、GLONASS 和 BDS 三星系的信号,其中一台作为基准站,设置在距离大桥约 500 m 的空旷地带,见图 10(a);桥梁跨中设置流动站,见

图 10(b)。采样频率设为 10 Hz,连续监测 5 h。




图 10 现场仪器布置

Fig.10 Field instrument layout

3.3 监测数据处理与分析

选取 600 s 内 GNSS-RTK 监测到的桥梁跨中竖向位移数据进行处理与分析,原始信号如图 11 所示。受背景噪声影响,桥梁振动位移幅值较大,在 $-96\sim77$ mm 之间,“毛刺”现象严重,有效振动位移信息被淹没。

利用 IVMD 算法对原始信号 $X(t)$ 进行分解,预设分解层数 k 在 2~20 之间,不同 k 值下的最小模糊熵值及相邻比值见表 4。依据最小模糊熵稳定准则,选取 $k=9$ 。




图 11 原始信号
Fig.11 The original signal

表 4 最小模糊熵值及相邻比值(实验信号分解结果)
Tab.4 Minimum fuzzy entropy and adjacent ratio
(experimental signal decomposition result)


k	最小模糊熵值	$Q(i)$	k	最小模糊熵值	$Q(i)$
2	0.194 4	—	12	0.024 4	0.987 8
3	0.098 8	0.508 0	13	0.023 6	0.968 3
4	0.097 6	0.988 2	14	0.023 5	0.994 7
5	0.095 4	0.977 6	15	0.023 3	0.992 9
6	0.094 2	0.987 4	16	0.023 2	0.997 0
7	0.031 2	0.331 4	17	0.023 2	0.996 7
8	0.030 6	0.978 4	18	0.023 1	0.997 4
9	0.025 4	0.832 1	19	0.023 1	0.998 1
10	0.025 1	0.987 5	20	0.023 0	0.997 1
11	0.024 7	0.982 6			

IVMD 分解及各 IMF 自相关归一化函数如图 12 所示。图 12(a)为经 IVMD 分解出的 9 个 IMF 分量,计算各分量与原始信号的相关系数,分别为 0.898、0.494、0.205、0.140、0.093、0.087、0.080、0.080 和 0.078。为避免过度去噪,结合图 12(b)所示的各 IMF 分量的自相关特征进行分析,选取 IMF₅~IMF₉ 为主要噪声分量进行重构,并将重构信号引入 ICA 的虚拟通道,与原始信号 $X(t)$ 组成 ICA 的输入矩阵,进行解混降噪,得到独立分量 IC₁与 IC₂。


ICA 输入信号与输出信号如图 13 所示。可以看出,经 ICA 输出的独立分量 IC₁相较于原始信号 $X(t)$,幅值发生了倍数级的变化,这与结构的真实振动位移不相符。为了恢复信号的幅值,采用 1.3 节所提的 MDP 准则。

原始信号与去噪信号如图 14 所示。由图可知,与原始信号相比,振动幅值变小,“毛刺”现象得到改善,有效振动位移更加清晰。

为了对比验证本研究所提 IVMD-ICA 算法的去噪性能,选用单一的 IVMD 算法、CEEMDAN 算法和 CEEMDAN-ICA 联合算法对原始信号进行处



(a) 实测信号IVMD分解
(a) Measured signal decomposed by IVMD



(b) 各IMF自相关函数
(b) Autocorrelation function of each IMF

图 12 IVMD 分解及各 IMF 自相关归一化函数
Fig.12 IVMD decomposition and IMF autocorrelation normalization functions

理,并采用 SNR 和 RMSE 指标定量描述去噪效果。不同算法的降噪结果见表 5。




图 13 ICA 输入信号与输出信号

Fig.13 The input signal and output signal of ICA




图 14 原始信号与去噪信号

Fig.14 The original signal and denoised signal

表 5 不同算法的降噪结果

Tab.5 Noise reduction results of different algorithms

去噪算法	SNR/dB	RMSE/mm
IVMD-ICA	17.002 7	3.711 5
IVMD	15.296 5	4.504 8
CEEMDAN-ICA	14.896 3	4.693 8
CEEMDAN	14.434 3	4.970 6

由表 5 可以看出,IVMD-ICA 算法的信噪比精度相较于其余 3 种方法分别提高了 11.15%、14.14% 和 17.79%,均方根误差精度分别减少了 17.61%、20.93% 和 25.33%。这说明所提算法不仅有效削弱了噪声,还能最大程度地保留有效信息,去噪性能最佳。联合 IVMD-ICA 算法和 CEEMDAN-ICA 算法均优于单一的 IVMD 算法和 CEEMDAN 算法,证明了联合算法的有效性。

4 结 论

1) 本研究提出了 IVMD 算法,在 VMD 的基础上采用模糊熵替代样本熵,通过最小模糊熵稳定准则自适应确认 VMD 的最佳分解层数,并利用一组

仿真信号验证了 IVMD 的有效性和可靠性。与 CEEMDAN 算法相比,IVMD 减少了分解数量,提高了重构精度,信噪分离效果更好。

2) 利用所提的 IVMD-ICA 联合算法对大跨径桥梁的监测数据进行去噪,相较于 CEEMDAN、IVMD 和 CEEMDAN-ICA 算法,其 SNR 最高, RMSE 最小,能够更有效地削弱监测数据中的背景噪声,最大程度地保留有效信息,去噪性能更佳。

3) 利用 GNSS-RTK 实时动态差分监测技术并结合所提出的 IVMD-ICA 联合去噪算法对大跨径桥梁动态变形监测数据进行去噪处理,能够获取更加精准真实的桥梁振动位移信号,为后续结构的动力特性分析打下基础,此方法适用于大跨径桥梁结构的定期健康监测和运营安全维护。

参 考 文 献

- [1] 余加勇,邵旭东,孟晓林,等.联合 GNSS 和加速度计的桥梁结构动态监测试验[J].中国公路学报,2014,27(2): 62-69.
YU Jiayong, SHAO Xudong, MENG Xiaolin, et al. Experimental research on dynamic monitoring of bridges using GNSS and accelerometer[J]. China Journal of Highway and Transport, 2014, 27(2): 62-69. (in Chinese)
- [2] XIONG C B, LU H L, ZHU J S. Operational modal analysis of bridge structures with data from GNSS/accelerometer measurements[J]. Sensors, 2017, 17(3): 436.
- [3] 易文华,刘连生,闫雷,等.基于 EMD 改进算法的爆破振动信号去噪[J].爆炸与冲击,2020,40(9): 75-85.
YI Wenhua, LIU Liansheng, YAN Lei, et al. Vibration signal de-noising based on improved EMD algorithm[J]. Explosion and Shock Waves, 2020, 40(9): 75-85. (in Chinese)
- [4] 张建文,刘洋,张大朋,等.基于 CEEMDAN 与小波自适应阈值的去噪新方法[J].电测与仪表,2018,55(10): 14-18, 33.
ZHANG Jianwen, LIU Yang, ZHANG Dapeng, et al. A new method of combined denoising based on CEEMDAN and wavelet adaptive thresholding [J]. Electrical Measurement & Instrumentation, 2018, 55(10): 14-18, 33. (in Chinese)
- [5] 熊春宝,王猛,尚智,等.基于 ACVMD-WT 法的 GNSS-RTK 高耸结构动态监测与模态分析[J].振动工程学报,2023,36(5): 1223-1233.
XIONG Chunbao, WANG Meng, SHANG Zhi, et al. Dynamic monitoring and modal analysis of the high-rise

- structure by GNSS-RTK based on ACVMD-WT method[J]. Journal of Vibration Engineering, 2023, 36(5): 1223-1233. (in Chinese)
- [6] 鲁铁定, 何锦亮, 贺小星, 等. 参数优化变分模态分解的GNSS坐标时间序列降噪方法[J]. 武汉大学学报(信息科学版), 2024, 49(10): 1856-1866.
- LU Tieding, HE Jinliang, HE Xiaoxing, et al. Parameter optimization variational mode decomposition for GNSS coordinate time series denoising method[J]. Geomatics and Information Science of Wuhan University, 2024, 49(10): 1856-1866. (in Chinese)
- [7] ZHANG Y G, PAN G F. A hybrid prediction model for forecasting wind energy resources[J]. Environmental Science and Pollution Research International, 2020, 27(16): 19428-19446.
- [8] 李可, 牛园园, 宿磊, 等. 参数优化VMD的滚动轴承故障诊断方法[J]. 振动工程学报, 2023, 36(1): 280-287.
- LI Ke, NIU Yuanyuan, SU Lei, et al. Rolling bearing fault diagnosis method based on parameter optimized VMD[J]. Journal of Vibration Engineering, 2023, 36(1): 280-287. (in Chinese)
- [9] LI J N, CHEN W G, HAN K, et al. Fault diagnosis of rolling bearing based on GA-VMD and improved WOA-LSSVM[J]. IEEE Access, 2020, 8: 166753-166767.
- [10] 张伟萍, 付民, 张海燕, 等. 改进的WOA-VMD算法在水声信号去噪中的应用[J]. 中国海洋大学学报, 2023, 53(1): 138-146.
- ZHANG Weiping, FU Min, ZHANG Haiyan, et al. Application of improved WOA-VMD algorithm in underwater acoustic signal denoising[J]. Periodical of Ocean University of China, 2023, 53(1): 138-146. (in Chinese)
- [11] 刘敏, 张英堂, 李志宁, 等. 基于IVMD与改进KELM的发动机故障诊断[J]. 振动、测试与诊断, 2019, 39(4): 875-883.
- LIU Min, ZHANG Yingtang, LI Zhining, et al. Engine fault diagnosis based on independent variational mode decomposition and improved kernel extreme learning machine[J]. Journal of Vibration, Measurement & Diagnosis, 2019, 39(4): 875-883. (in Chinese)
- [12] STEEL A, GARCIA B D, SILSON E H, et al. Evaluating the efficacy of multi-echo ICA denoising on model-based fMRI[J]. Neuroimage, 2022, 264: 119723.
- [13] 夏奎, 李炜, 邱意敏, 等. 基于改进型象群优化算法的BSS方法[J]. 电子测量与仪器学报, 2021, 35(10): 153-160.
- XIA Kui, LI Wei, QIU Yimin, et al. BSS method based on improved elephant herding optimization algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 153-160. (in Chinese)
- [14] 罗飞雪, 戴吾蛟, 唐成盼, 等. 参考经验模态分解-独立分量分析及其在GPS多路径误差处理中的应用[J]. 测绘学报, 2012, 41(3): 366-371.
- LUO Feixue, DAI Wujiao, TANG Chengpan, et al. EMD-ICA with reference signal method and its application in GPS multipath[J]. Acta Geodaetica et Cartographica Sinica, 2012, 41(3): 366-371. (in Chinese)
- [15] 罗焯钊, 陈永高, 李升才. 基于Fast-ICA算法的改进EEMD算法在桥梁工程中的运用[J]. 公路交通科技, 2021, 38(2): 62-72.
- LUO Yeke, CHEN Yonggao, LI Shengcai. Application of improved EEMD algorithm in bridge engineering based on FAST-ICA algorithm[J]. Journal of Highway and Transportation Research and Development, 2021, 38(2): 62-72. (in Chinese)
- [16] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [17] ANEES J, ZHANG H C, BAIG S, et al. Hesitant fuzzy entropy-based opportunistic clustering and data fusion algorithm for heterogeneous wireless sensor networks[J]. Sensors, 2020, 20(3): 913.
- [18] COMON P, JUTTEN C. Handbook of blind source separation: independent component analysis and applications[M]. Oxford: Academic Press Inc., 2010: 208-220.
- [19] 许承权, 范千. 基于ICEEMD-ICA与MDP准则的变形监测数据去噪方法[J]. 武汉大学学报(信息科学版), 2021, 46(11): 1658-1665.
- XU Chengquan, FAN Qian. Denoising method for deformation monitoring data based on ICEEMD-ICA and MDP principle[J]. Geomatics and Information Science of Wuhan University, 2021, 46(11): 1658-1665. (in Chinese)



第一作者简介:熊春宝,男,1964年1月生,博士、教授、博士生导师。主要研究方向为工程结构健康监测。曾发表《Operational modal analysis of bridge structures with data from GNSS/accelerometer measurements》(《Sensors》2017, Vol.17, No.3)等论文。
E-mail: luhai-tj@126.com

通信作者简介:刘杰丽,女,1999年3月生,硕士。主要研究方向为工程结构健康监测。
E-mail: liujieli202102@163.com