

基于优化变分模态分解算法的回波信号去噪

王祺*, 王小鹏, 王博辉

兰州交通大学电子与信息工程学院, 甘肃 兰州 730070

摘要 超声流量计的回波信号中通常存在噪声干扰, 导致回波信号难以准确定位。为滤除超声波回波信号中的噪声, 提出了一种基于优化变分模态分解(VMD)算法的信号去噪方法。所提方法首先利用互信息准则的信息熵将遗传算法与 VMD 相关联。然后, 将样本熵作为适应度函数, 自适应性地优化 VMD 算法中的参数组合。最后, 对原始信号进行分解, 利用相关系数计算出有效信号, 并将有效信号进一步去噪后进行重构。仿真结果表明, 所提方法能有效滤除超声波回波信号中的噪声并且能够完整的保留有用信号。

关键词 信号处理; 遗传算法; 互信息准则; 变分模态分解; 信息熵; 相关系数

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP202158.2007001

Echo Signal Denoising Based on Optimized Variational Mode Decomposition Algorithm

Wang Qi*, Wang Xiaopeng, Wang Bohui

School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou, Gansu 730070, China

Abstract The echo signal of ultrasonic flowmeter usually has noise interference, which makes it difficult to locate the echo signal accurately. In order to filter out the noise in the ultrasonic echo signal, a signal denoising method based on the optimized variational modal decomposition (VMD) algorithm is proposed. Firstly, the information entropy of the mutual information criterion is used to associate the genetic algorithm with VMD. Then, the sample entropy is used as the fitness function to adaptively optimize the parameter combination in VMD algorithm. Finally, the original signal is decomposed, the effective signal is calculated through the correlation coefficient, and the effective signal is reconstructed after further denoising. The simulation results show that the proposed method can effectively filter out the noise in ultrasonic echo signal and retain the useful signal completely.

Key words signal processing; genetic algorithm; mutual information criterion; variational mode decomposition; information entropy; correlation coefficient

OCIS codes 070.2575; 150.1135; 120.3930

1 引言

超声波流量计被广泛应用于农业、化工、冶金、医疗等^[1]行业中, 且流量计的精度直接影响工作效率。在实际应用中, 超声波回波信号中夹杂着各类噪声, 特别是在白天阳光会导致信号完全被噪声淹没^[2]。因此, 采用有效去噪方式提取回波信号中的

有效信号是实现超声波流量计高精度测量的关键^[3]。超声波回波信号是一类典型的非平稳、非线性信号^[4]。针对这类信号, 目前采用的去噪方法主要包括小波阈值去噪^[5-7]、经验模态分解(EMD)^[8-10]以及在它们基础上的改进算法。虽然小波阈值去噪可以通过多尺度分析将信号分解为不同的频率分量, 具有良好的时频局部化特性, 但是小波基的选取

收稿日期: 2020-11-23; 修回日期: 2020-12-03; 录用日期: 2021-01-19

基金项目: 国家自然科学基金(61761027)

通信作者: *527466867@qq.com

比较困难, 进而不具备信号的自适应分解。虽然 EMD 解决了小波阈值去噪的自适应性, 可以较好地反应信号的局部频率特征, 但是其存在一些问题, 如理论上缺乏严格的数学证明、算法效率低、存在模态混叠现象、抗噪性能较差。因此, EMD 无法准确提取本征模态函数 (IMF) 分量, 不能有效地将有用信号和噪声分离^[11]。2014 年, Xie 等^[12-15]提出了变分模态分解 (VMD) 自适应信号分解方法, 其对非线性、非平稳信号的处理具有明显优势。该方法在通过迭代搜寻变分模型最优解来确定每个模态的中心频率和带宽的同时, 实现对信号各个分量的有效分离。与 EMD 方法相比, 该方法的运算效率高且具有强大的数学基础, 可解决 EMD 中的模态混叠问题。在实现信号准确分离的同时, 利用自身 Wiener 滤波特性可以获得较好的去噪效果。然而, VMD 算法的分解效果受惩罚因子和分解层数的影响较大。因此, 本文将互信息准则 (MI) 和遗传算法相结合对 VMD 参数进行优化, 在得到最优的参数组合后, 可实现对回波信号的准确分解, 进而达到去噪的目的。

2 变分模态分解

VMD 算法通过迭代搜寻变分模型最优解来确

定每个固有模态分量的中心频率和带宽, 进而实现了信号从低频到高频的有效分离, 其过程就是变分问题的求解过程^[16]。VMD 分解的过程中主要涉及 Wiener 滤波、Hilbert 变换以及频率混合。利用 Wiener 滤波和 Hilbert 变换, 将原始信号的分解问题转换为求解 k 个模态的变分问题。为使每个模态的估计带宽之和最小, 建立约束变分模型, 其表达式为

$$\min_{\{u\}, \{\omega\}} \left\{ \sum_{i=1}^k \left\| \partial_t \left\{ \left[\delta(t) + \frac{j}{\pi t} \right] \times u_i(t) \right\} e^{-j\omega_i t} \right\|_2^2 \right\}, \quad (1)$$

$$\text{s. t. } \sum_{i=1}^k u_k = f(t)$$

式中: $\{u\} = \{u_1, \dots, u_k\}$ 表示 k 个 IMF 分量集; $\{\omega\} = \{\omega_1, \dots, \omega_k\}$ 表示 k 个中心频率集; $\left[\delta(t) + \frac{j}{\pi t} \right] \times u_i(t)$ 表示 $u_i(t)$ 经过 Hilbert 变换得到的解析信号的单边谱; $\left\| \partial_t \left\{ \left[\delta(t) + \frac{j}{\pi t} \right] \times u_i(t) \right\} \cdot e^{-j\omega_i t} \right\|_2^2$ 表示通过计算调制信号梯度范数 L2 的平方估计出的各 IMF 的带宽; $f(t)$ 表示信号; t 为任意时刻。通过引入二次惩罚因子 α 和拉格朗日乘法算子 $\lambda(t)$ 将(1)式中的约束问题转换为非约束变分问题。扩展后的增广拉格朗日表达式^[17]为

$$L\{\{u\}, \{\omega\}, \lambda(t)\} = \alpha \sum_{i=1}^k \left\| \partial_t \left\{ \left[\delta(t) + \frac{j}{\pi t} \right] \times u_i(t) \right\} e^{-j\omega_i t} \right\|_2^2 + \left\| f(t) - \sum_{i=1}^k u_i(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_{i=1}^k u_i(t) \rangle. \quad (2)$$

利用交替乘子方向 (ADMM) 算法^[18]不断更新各个 IMF 的 $u_k^{(n+1)}$ 、 $\omega_k^{(n+1)}$ 、 $\lambda_k^{(n+1)}$, 同时找到(2)式的鞍点并将其作为式(1)式的解。交替寻优 u_k 、 ω_k 和 λ_k 所需的表达式为

$$\hat{u}_k^{(n+1)}(\omega) = \frac{\hat{f}(\omega) - \sum_{i=1}^{k-1} [\hat{u}_i(\omega) + \hat{\lambda}(\omega)/2]}{1 + 2\alpha(\omega - \omega_k)^2}, \quad (3)$$

$$\hat{\omega}_k^{(n+1)} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega}, \quad (4)$$

$$\hat{\lambda}^{(n+1)}(\omega) = \hat{\lambda}^{(n)}(\omega) + \tau \left[\hat{f}(\omega) - \sum_{i=1}^k \hat{u}_i^{n+1}(\omega) \right], \quad (5)$$

式中: $\hat{u}_k^{(n+1)}(\omega)$ 、 $\hat{f}(\omega)$ 、 $\hat{\lambda}(\omega)$ 分别表示 $u_k^{(n+1)}(t)$ 、 $f(t)$ 、 $\lambda(t)$ 对应的傅里叶变换。在迭代计算过程

中, 各分量 u_i 的中心频率是利用功率谱的重心进行估计的。VMD 算法迭代过程为

- 1) 输入原始信号、限制、延迟、模态数、起始中心频率、噪声容限。
- 2) 初始化 $\hat{u}_k^{(1)}(\omega)$ 、 $\hat{\omega}_k^{(1)}$ 、 $\hat{\lambda}^{(1)}(\omega)$ 、 n 。
- 3) 利用(3)式迭代更新 $\hat{u}_k^{(n+1)}(\omega)$ 。
- 4) 利用(4)式迭代更新 $\hat{\omega}_k^{(n+1)}$;
- 5) 利用(5)式迭代更新 $\hat{\lambda}^{(n+1)}(\omega)$, 直到满足条件 $\sum_{i=1}^k \|u_k^{(n+1)}(t) - u_k^{(n)}(t)\|_2^2 / \|u_k^{(n)}(t)\|_2^2 < \epsilon$ 时, 停止循环, 输出 $\hat{u}_k(\omega)$ 、 $\hat{\omega}_k$, 并利用傅里叶变换获得每一个 u_k , 其中 ϵ 是阈值。

2.1 基于互信息准则的 VMD 优化

利用 VMD 算法进行信号分解时, 参数中 α 和 k 对 VMD 的分解结果影响较大。在实际需要分解的

信号中夹杂着各类噪声,而 k 和 α 的取值通常是按照经验来选取的,进而分解结果欠佳。因此,提出利用 MI 对信号分量及原始信号的相关程度进行判断,进而优化 VMD 对信号的分解。

MI 来源于信息熵,不同信号分量的信息熵的计算公式为

$$H(X) = - \sum_{l=1}^k p(x_l) \log_2 [p(x_l)], \quad (6)$$

式中: $p(x_l)$ 是指随机事件 X 为 x_l 的概率。两个变量的 MI 值用两者间不确定度的差值衡量,可以反映两者的相关程度,MI 的表达式^[19]为

$$M(X, Y) = H(Y) - H(Y | X), \quad (7)$$

式中: $H(Y)$ 是 Y 的熵; $H(Y | X)$ 是已知 X 时 Y 的条件熵。由 (7) 式可知,若 $M(X, Y)$ 值越大,则 $H(Y | X)$ 越小,表明 X 与 Y 的相关性越强。对第 l 个信息熵做归一化处理:

$$\delta_l = M_l / \max(M_l). \quad (8)$$

归一化处理后可通过设置阈值 d (一般取 0.5) 来衡量 IMF 各个分量与原始信号的相关程度。当 δ_l 小于阈值时,认为原始信号出现“过分解”(指将有效分量也进行了分解),当 δ_l 大于阈值时,认为对原始信号的分解是有效的,此时可进行下一步分析。

2.2 基于遗传算法的 VMD 优化

利用 VMD 算法对原始信号进行分解时需要

设置参数。在研究过程中发现,如果设置一个参数不变,优化另一个参数,这会忽略两个参数间的相互作用,使得最终结果陷入局部优化的困境。遗传算法是一种智能优化算法,具有较强的全局非线性能力,将遗传算法与 MI 的自适应性相结合,可实现对目标函数(原始信号)的全局优化。利用遗传算法求解优化问题的过程是利用种群搜索技术将种群作为一组问题解,通过对当前种群施加类似生物遗传环境因素的选择、交叉、变异等一系列的遗传操作来产生新一代的种群,并逐步使种群达到包含近似最优解的状态。遗传算法中的种群就是可行解集(目标函数),而适应度函数是用来评价的函数值,故构造一个适应度函数用来作为生成最优解的判决函数尤为重要。本文将样本熵作为适应度函数,样本熵是通过信号中产生新模式的概率大小来衡量时间序列复杂性的,熵值最小时信号的复杂度最低,样本熵的定义为

$$S(m, r) = - \ln \left[\frac{A^m(r)}{B^m(r)} \right], \quad (9)$$

式中: m 是重构维数,取值为 1 或 2,一般令 m 为 1; r 是阈值大小,范围为 $0.1\sigma \sim 0.25\sigma$, σ 是标准差; $A^m(r)$ 和 $B^m(r)$ 是两个信号序列的平均值。基于参数优化的 VMD 去噪流程图如图 1 所示。

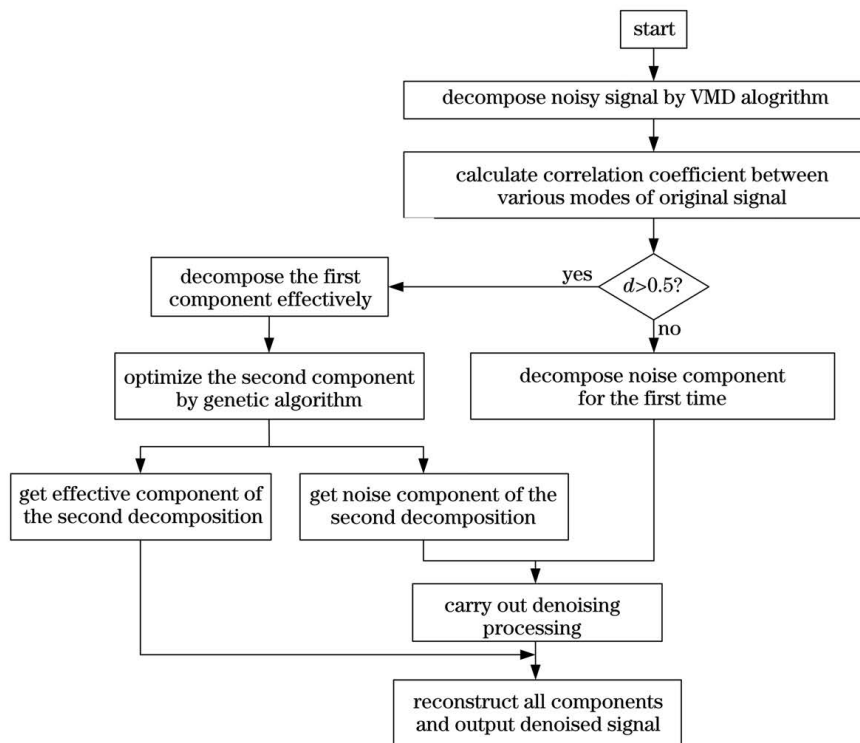


图 1 基于参数优化的 VMD 去噪流程图

Fig. 1 Flow chart of VMD denoising based on parameter optimization

3 实验结果与分析

利用仿真信号对所提方法进行仿真分析,其中仿真信号是模拟了超声波回波信号模型的纯净信号,仿真信号和频谱图如图 2 所示。对纯净的仿真信号进行 EMD 和 VMD 分解,EMD 分解层数为 7,经优化后的 VMD 的参数组合为 $[k, \alpha] = [3, 2985]$,分解结果分别如图 3、4 所示,图中从上到下分别对应原始信号以及各分解层数的模态。从图 3(a)、4(a)中可以发现,EMD 分解的信号分量存在严重的模态混叠现象,而 VMD 方法解决了分解过程中的模态混叠问题。从图 3(b)、4(b)中可以发现,EMD 分解过程中出现了高频分量,说明在分解过程中 EMD 将有效信号分解成了噪声,而 VMD 分解过程中无高频分量。该现象背后的机制是:在 VMD 分解过程中,对各模态分量进行了相关性分析并设定阈值,高于阈值的模态分量成为有效信号分量,低于





图 2 无噪声的超声波回波信号及其频谱。(a)回波信号;(b)频谱

Fig. 2 Noise-free ultrasonic echo signal and frequency spectrum. (a) Echo signal; (b) frequency spectrum
阈值的模态分量成为噪声分量(通常为高频分量),进而可以对有用信号进行重构,实现 VMD 去噪。




图 3 无噪声信号下的 EMD 模态及其频谱。(a)EMD 模态;(b)频谱

Fig. 3 EMD modes and frequency spectra under noise-free signal. (a) EMD modes; (b) frequency spectra

计算出图 2 中信号分量与原始信号的相关性 s ,当 $s > 0.5$ 时,认为分量信号与原始信号相关性较好,并将其作为信号分量保留。当 $s < 0.5$ 时,认为分量信号与原始信号相关性较差,视为噪声分量^[20]。对图 4 所示的 3 组利用 VMD 算法得到的分量与原始信号进行相关性分析,得到 $s_1 = 0.6325$,

$s_2 = 0.5874$, $s_3 = 0.6956$,即三组分量均为低频分量,与频谱图中的结论相同,表明该算法可有效分离低频和高频分量,降低了主观性对实验的影响。

k 的确定具有主观性, k 值过大或过小会造成过分解或欠分解的问题。一般通过分析频谱图中的峰值个数来确定 k ,由于图 2(b)中有两个波峰,因

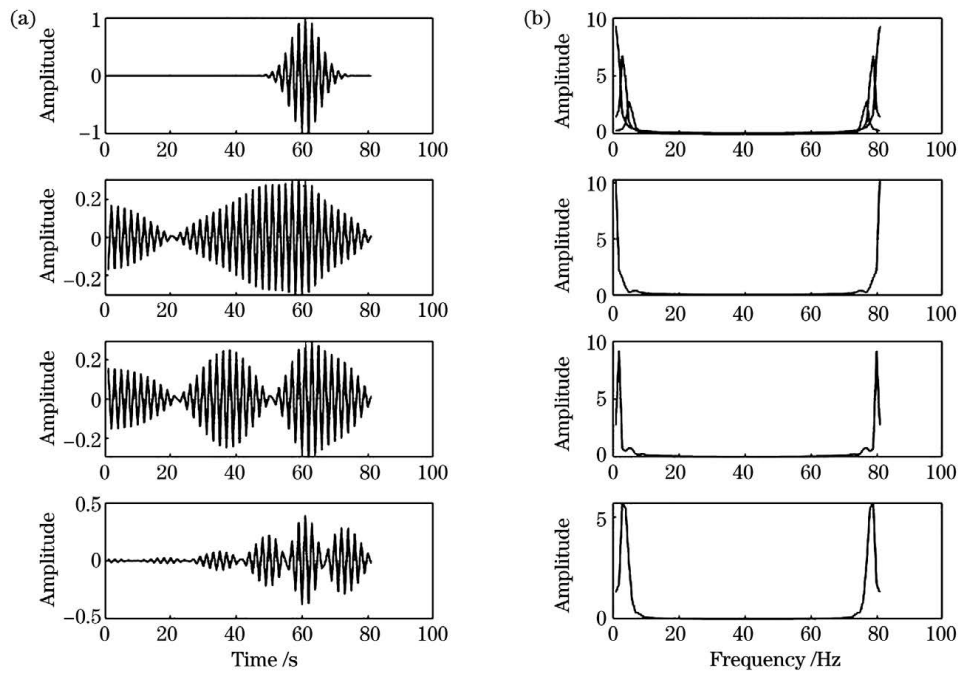


图 4 无噪声信号下的 VMD 模式及其频谱。(a)VMD 模式;(b)频谱

Fig. 4 VMD modes and frequency spectra under noise-free signal. (a) VMD modes; (b) frequency spectra

此可根据经验将 k 设置为 3~10, α 设置为默认值 2500。参数组合分别为 $[k, \alpha] = [4, 2500]$ 、 $[k, \alpha] = [5, 2500]$ 、 $[k, \alpha] = [6, 2500]$ 时, 无噪声信号下的 VMD 模式图及其频谱图如图 5~7 所示。通过图 4~7 的对比可以看出, 传统 VMD 分解存在将有效信号过分解的情况, 而通过优化后寻找出最佳参数组合为 $[k, \alpha] = [3, 3231]$ 的 VMD 算法可准

确将有效信号和噪声进行分离。这表明面对不同噪声时, 传统的 VMD 分解只有固定的参数设置, 不能够根据不同的加噪信号特点自适应性地分解。

在加入不同噪声后信号的熵值会变化, 这就体现出优化后的 VMD 的自适应性, 它可以根据不同的噪声对加噪信号实现最优分解。为对比优化后的 VMD 与 EMD 算法在不同噪声环境下的去噪效

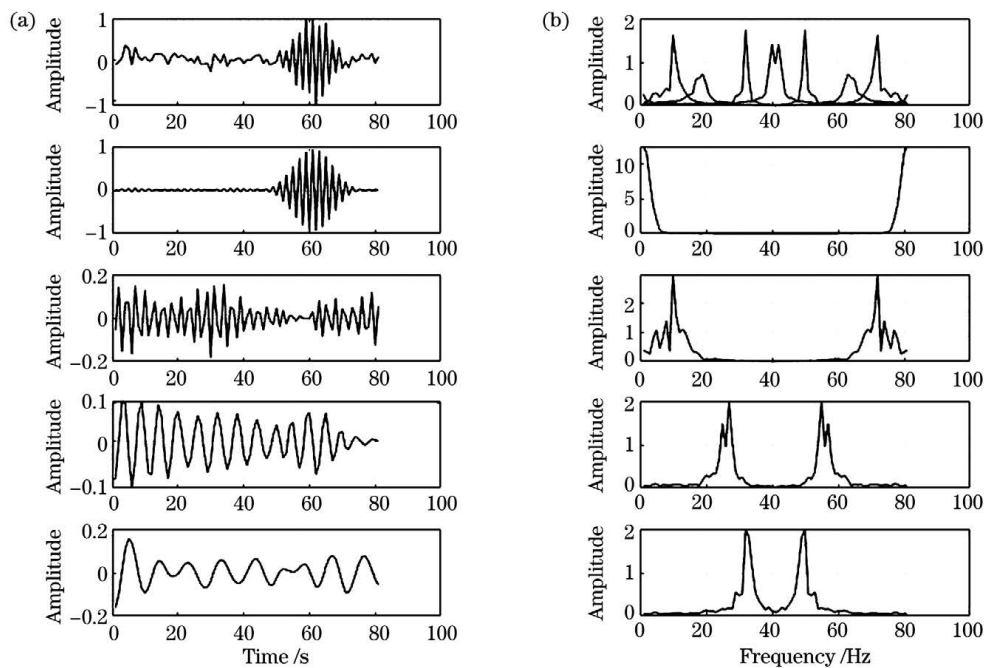


图 5 当 $[k, \alpha] = [4, 2500]$ 时, 无噪声信号下的 VMD 模式及其频谱。(a)VMD 模式;(b)频谱

Fig. 5 VMD modes and frequency spectra under noise-free signal when $[k, \alpha] = [4, 2500]$. (a) VMD modes; (b) frequency spectra

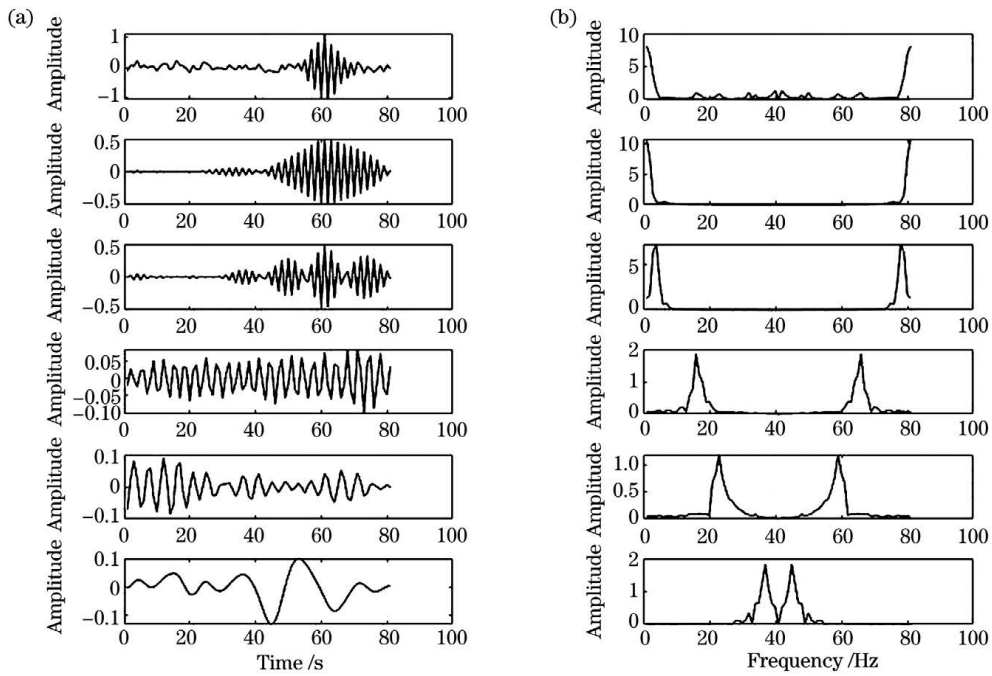


图 6 当 $[k, \alpha] = [5, 2500]$ 时, 无噪声信号下的 VMD 模式及其频谱。(a) VMD 模式; (b) 频谱

Fig. 6 VMD modes and frequency spectra under noise-free signal when $[k, \alpha] = [5, 2500]$. (a) VMD modes; (b) frequency spectra

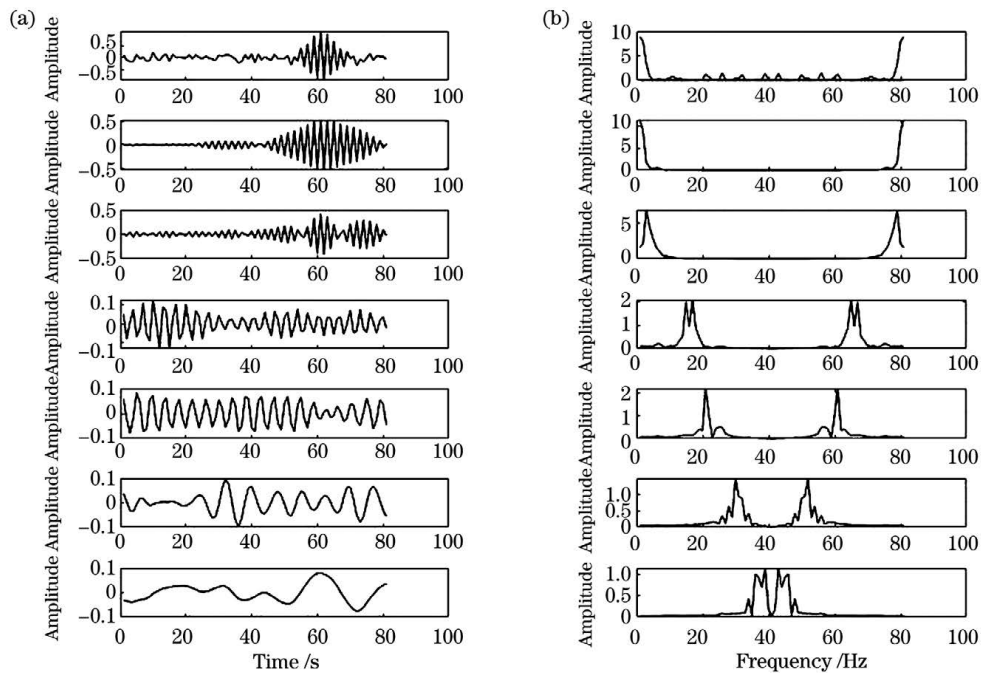


图 7 当 $[k, \alpha] = [6, 2500]$ 时, 无噪声信号下的 VMD 模式及其频谱。(a) VMD 模式; (b) 频谱

Fig. 7 VMD modes and frequency spectra under noise-free signal when $[k, \alpha] = [6, 2500]$. (a) VMD modes; (b) frequency spectra

果, 选择不同的噪声来模拟工业现场的噪声环境, 噪声来源于 SPIB(信号处理信息库)的高斯白噪声、Factory Floor noise1(FFN1)、Factory Floor noise2(FFN2)。

图 8 为在模拟的超声波回波信号中加入信噪比

(SNR)为 20 dB 的高斯白噪声后的仿真信号及其频谱图。原始信号通过优化后得到的优化参数组合为 $[k, \alpha] = [3, 3231]$, 此时, VMD 模式图及其频谱图如图 9 所示, EMD 模式图及其频谱图如图 10 所示。




图 8 加入 SNR 为 20 dB 的高斯白噪声后的超声回波信号及其频谱。(a) 回波信号; (b) 频谱
 Fig. 8 Ultrasonic echo signal and frequency spectrum after adding white Gaussian noise with SNR of 20 dB.

(a) Echo signal; (b) frequency spectrum

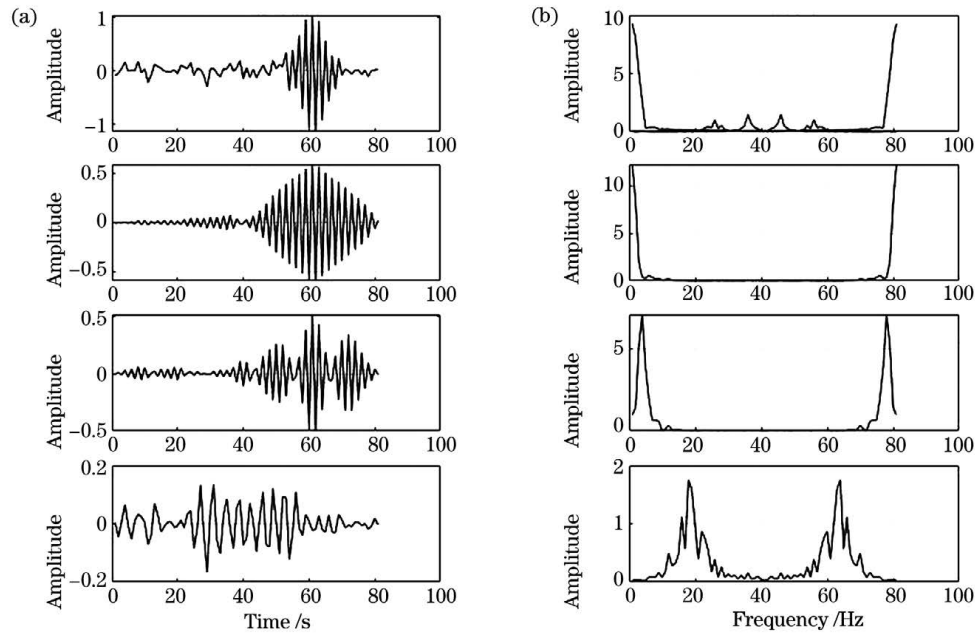


图 9 高斯白噪声下的 VMD 模式及其频谱。(a) VMD 模式; (b) 频谱

Fig. 9 VMD modes and frequency spectra under white Gaussian noise. (a) VMD modes; (b) frequency spectra

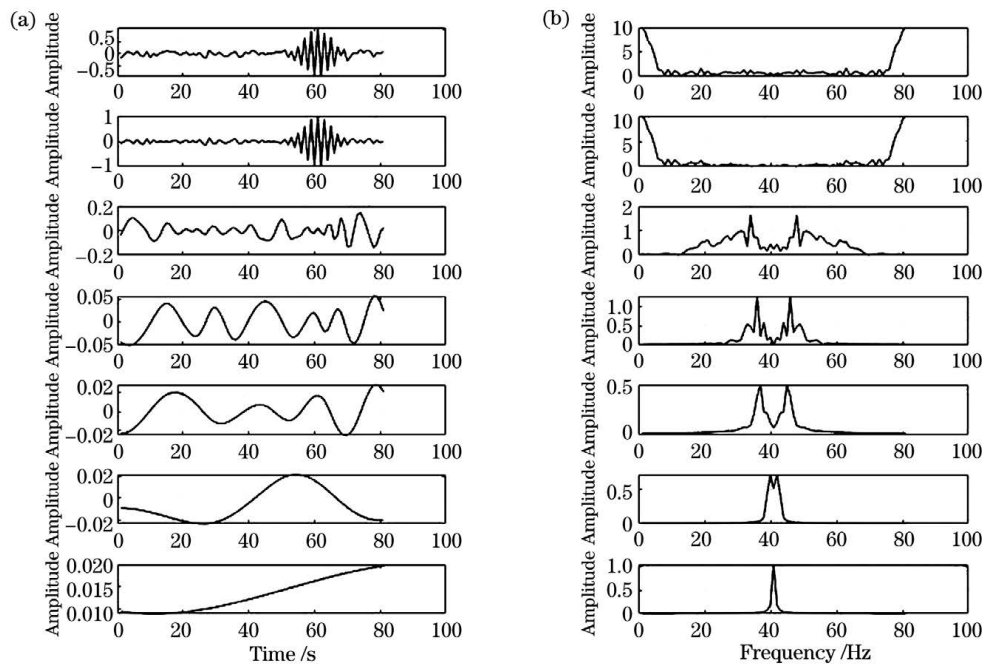


图 10 高斯白噪声下的 EMD 模式及其频谱。(a) EMD 模式; (b) 频谱

Fig. 10 EMD modes and frequency spectra under white Gaussian noise. (a) EMD modes; (b) frequency spectra

在模拟信号的超声波回波信号中加入 SNR 为 15 dB 的 FFN1 后的仿真信号及其频谱图如图 11 所示。原始信号通过优化后得到的优化参数组合为 $[k, \alpha] = [3, 2805]$, 此时, VMD 模态图及其频谱图如图 12 所示, EMD 模态图及其频谱图如图 13 所示。

在原始信号中加入 SNR 为 17dB 的 FFN2 后的仿真信号及其频谱图如图 14 所示。通过优化后得到的优化参数组合为 $[k, \alpha] = [3, 3636]$, 此时, VMD 模态图及其频谱图如图 15 所示, EMD 模态图及其频谱图如图 16 所示。




图 11 加入 SNR 为 15 dB 的 FFN1 后的超声回波信号及其频谱。(a)回波信号;(b)频谱

Fig. 11 Ultrasonic echo signal and frequency spectrum after adding FFN1 with SNR of 15 dB. (a) Echo signal; (b) frequency spectrum

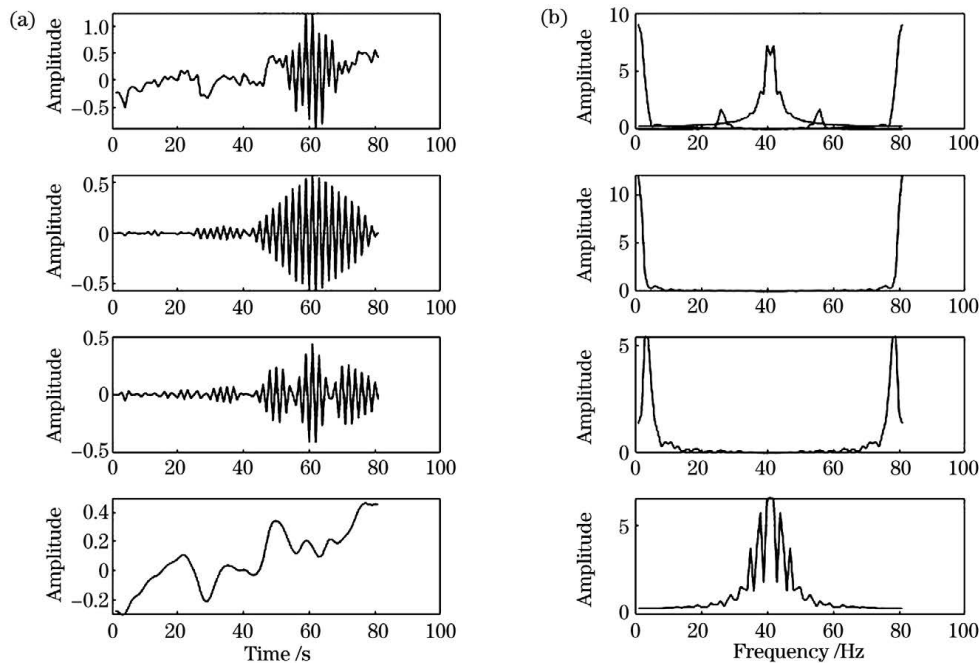


图 12 FFN1 下的 VMD 模态及其频谱。(a)VMD 模态;(b)频谱

Fig. 12 VMD modes and frequency spectra under FFN1. (a) VMD modes; (b) frequency spectra

用核密度估计的方法^[20]得到原始信号和各模态分量的信号分布差异(PDF),通过计算它们之间的相关性来区分分解后的模态是否为相关模态。

利用互相关系数来衡量信号之间的关联程度,对于两个信号 $G_1(t)$ 和 $G_2(t)$,其相关系数的表达式为

$$\rho_{12} = \frac{E \{ \{G_1(t) - E[G_1(t)]\} \{G_2(t) - E[G_2(t)]\} \}}{\sqrt{E \{ \{G_1(t) - E[G_1(t)]\}^2 \} E \{ \{G_2(t) - E[G_2(t)]\}^2 \}}}, \quad (10)$$

式中: $E(\cdot)$ 为均平方积分误差函数(MISE)。显然相关系数满足 $|\rho_{12}| \leq 1$,若 $|\rho_{12}| = 0$,则称两个信号不相关。若 $0 < |\rho_{12}| < 1$,则称两个信号相关。若 $|\rho_{12}| = 1$,则称两个信号完全相关。计算每个模态的相关系数可比较各个模态的相关性。

针对高斯白噪声下的 VMD 的 3 个模态,通过相关性计算得出 IMF1 和 IMF2 的相关系数在 0 到 1 之间,属于相关信号,说明 IMF1 和 IMF2 两个分量为有效信号,只有 IMF3 为无效信号。针对高斯白噪声下的 EMD 模态,通过相关性计算发现,只有

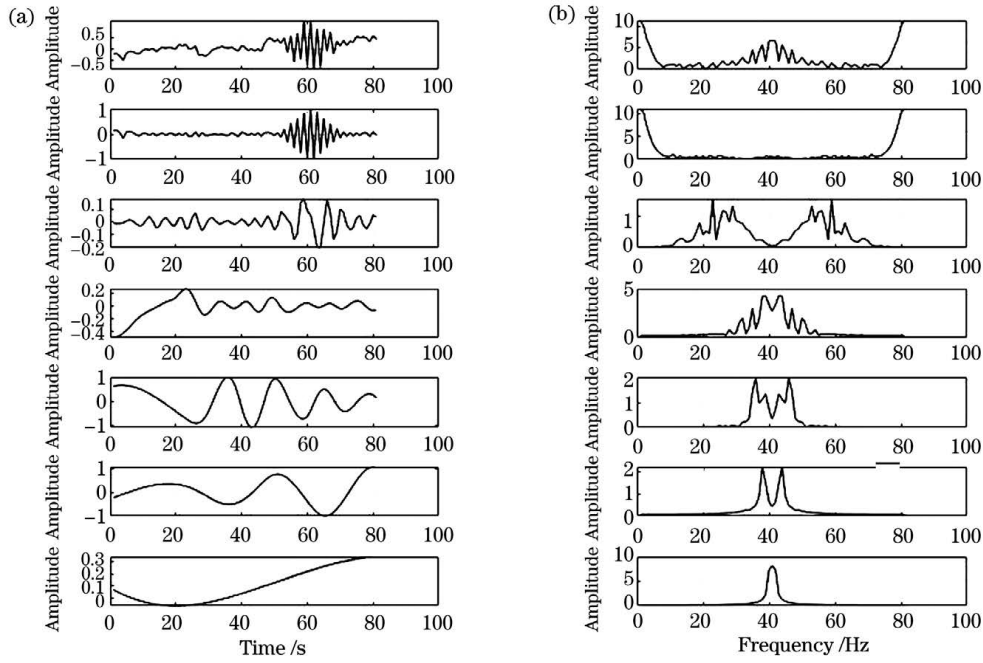


图 13 FFN1 下的 EMD 模态及其频谱。(a) EMD 模态; (b) 频谱

Fig. 13 EMD modes and frequency spectra under FFN1. (a) EMD modes; (b) frequency spectra




图 14 加入 SNR 为 17 dB 的 FFN2 后的超声回波信号及其频谱。(a) 回波信号; (b) 频谱

Fig. 14 Ultrasonic echo signal and frequency spectrum after adding FFN2 with SNR of 17 dB. (a) Echo signal; (b) frequency spectrum

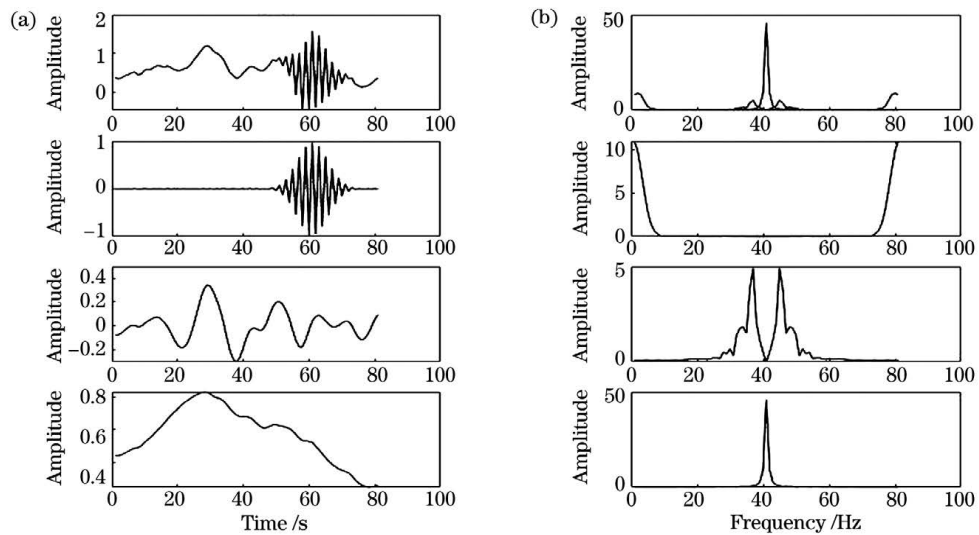


图 15 FFN2 下的 VMD 模态及其频谱。(a) VMD 模态; (b) 频谱

Fig. 15 VMD modes and frequency spectra under FFN2. (a) VMD modes; (b) frequency spectra

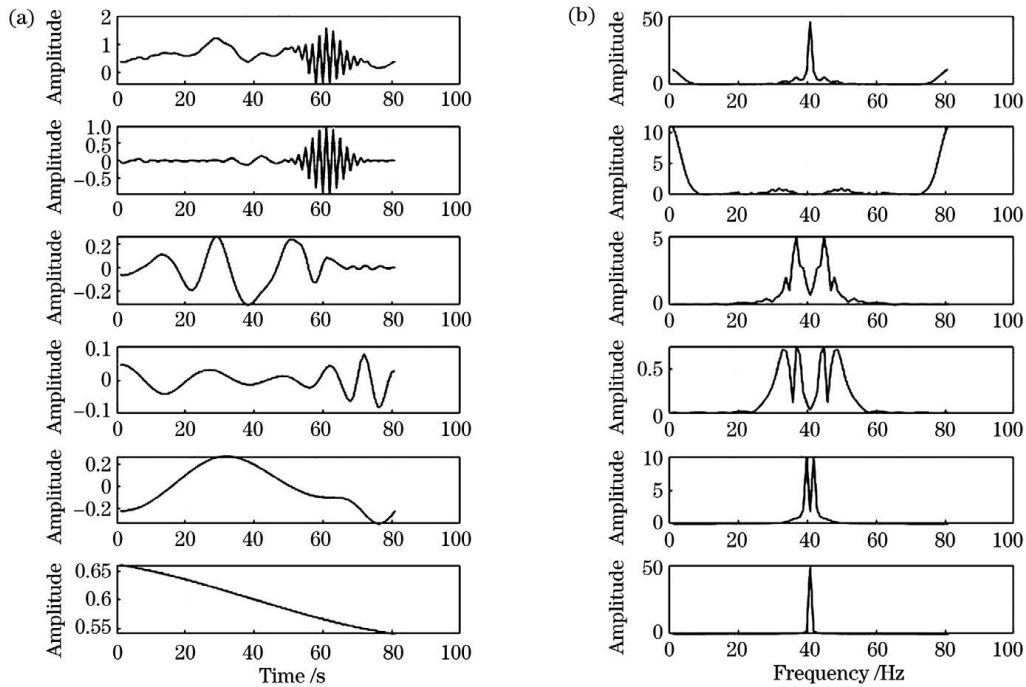


图 16 FFN2 下的 EMD 模式及其频谱。(a) EMD 模式; (b) 频谱

Fig. 16 EMD modes and frequency spectra under FFN2. (a) EMD modes; (b) frequency spectra

IMF1 和 IMF3 为有效信号,其余剩下的分量均为无效信号。

针对 FFN1 下的 VMD 的 3 个模式,通过相关性计算得出 IMF1 和 IMF2 两个分量为有效信号,IMF3 为无效信号。针对 FFN1 下的 EMD 模式,通过相关性计算得出 IMF1、IMF2、IMF4 为有效信号,剩余信号均为无效信号。针对 FFN2 下的 VMD 的 3 个模式,通过相关性计算得出 IMF1 为有效信号,IMF2 和 IMF3 为无效信号。针对 FFN2 下的 EMD 模式,通过相关性计算得出只有

IMF1 为有效信号。可以发现,在不同噪声环境下,优化后的 VMD 的自适应分解效果理想,分解出的有效信号混乱度低,相关性高,而 EMD 分解效果较差。

利用各模式的 PDF 计算得到了 VMD 后的有效信号,由于 VMD 具有 Wiener 滤波特性,因此其会滤除掉高频噪声。然后,选取剩余有效信号进一步去噪进行信号重构。三种噪声模型下的重构信号及频谱如图 17~19 所示。可以看出,去噪后信号平滑,效果理想。




图 17 当加入高斯白噪声时,去噪后的重构信号及其频谱。(a) 重构信号; (b) 频谱

Fig. 17 Denoised reconstructed signal and frequency spectrum when white Gaussian noise is added.

(a) Reconstructed signal; (b) frequency spectrum

为了验证所提去噪算法的实用性,在甘肃兰州某石油化工研究院测试中心进行了实验。对存储罐体加装超声波探头及仪表板,之后通过“HART 猫”将个人计算机(PC)端连接至仪表板,将测试中心现有的放射源流量计与所提的超声波回波信号去噪方法相结合,得到相应的回波信号

及去噪结果,选取其中一部分进行分析。图 20~22 分别为实验中的加噪信号及其频谱、加噪信号的 VMD 模式图及其频谱图、加噪信号的 EMD 模式图及其频谱图。

由图 20 可知现场采集的超声波回波信号包含大量噪声(主要为高斯白噪声),回波的起始位置处




图 18 当加入 FFN1 时,去噪后的重构信号及其频谱。(a)重构信号;(b)频谱

Fig. 18 Denoised reconstructed signal and frequency spectrum when FFN1 is added. (a) Reconstructed signal; (b) frequency spectrum




图 19 当加入 FFN2 时,去噪后的重构信号及其频谱。

(a)重构信号;(b)频谱

Fig. 19 Denoised reconstructed signal and frequency spectrum when FFN2 is added. (a) Reconstructed signal; (b) frequency spectrum




图 20 实验中的加噪信号及其频谱。(a)加噪信号;

(b)频谱

Fig. 20 Noisy signal and frequency spectrum in experiment. (a) Noisy signal; (b) frequency spectrum

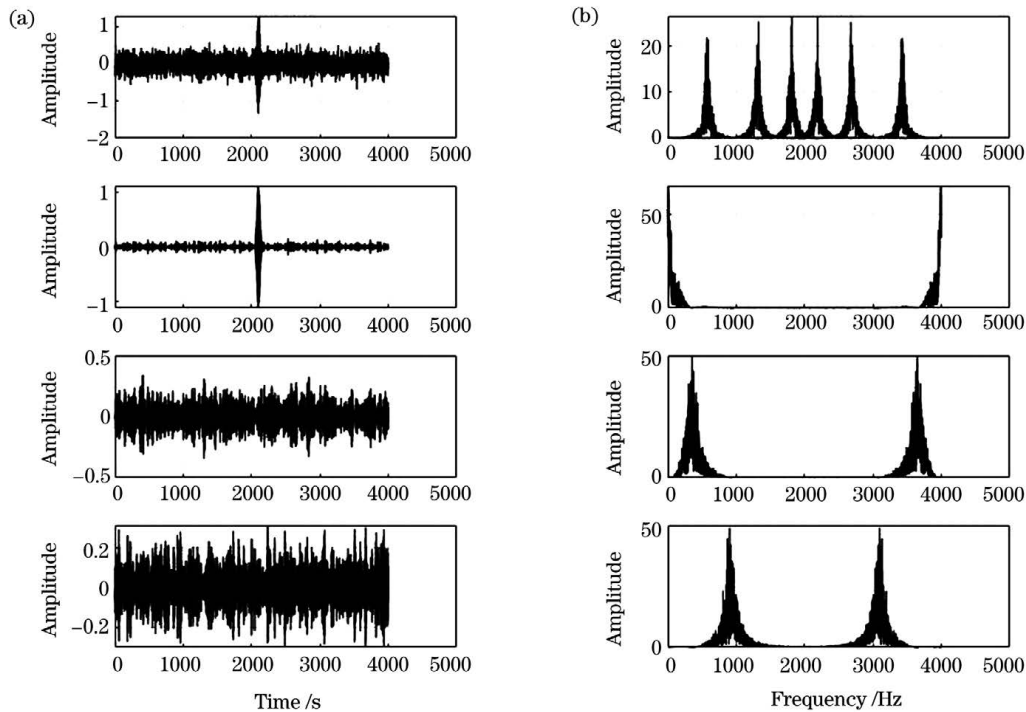


图 21 加噪信号的 VMD 模态及其频谱。(a)VMD 模态;(b)频谱

Fig. 21 VMD modes and frequency spectra of noisy signal. (a) VMD modes; (b) frequency spectra

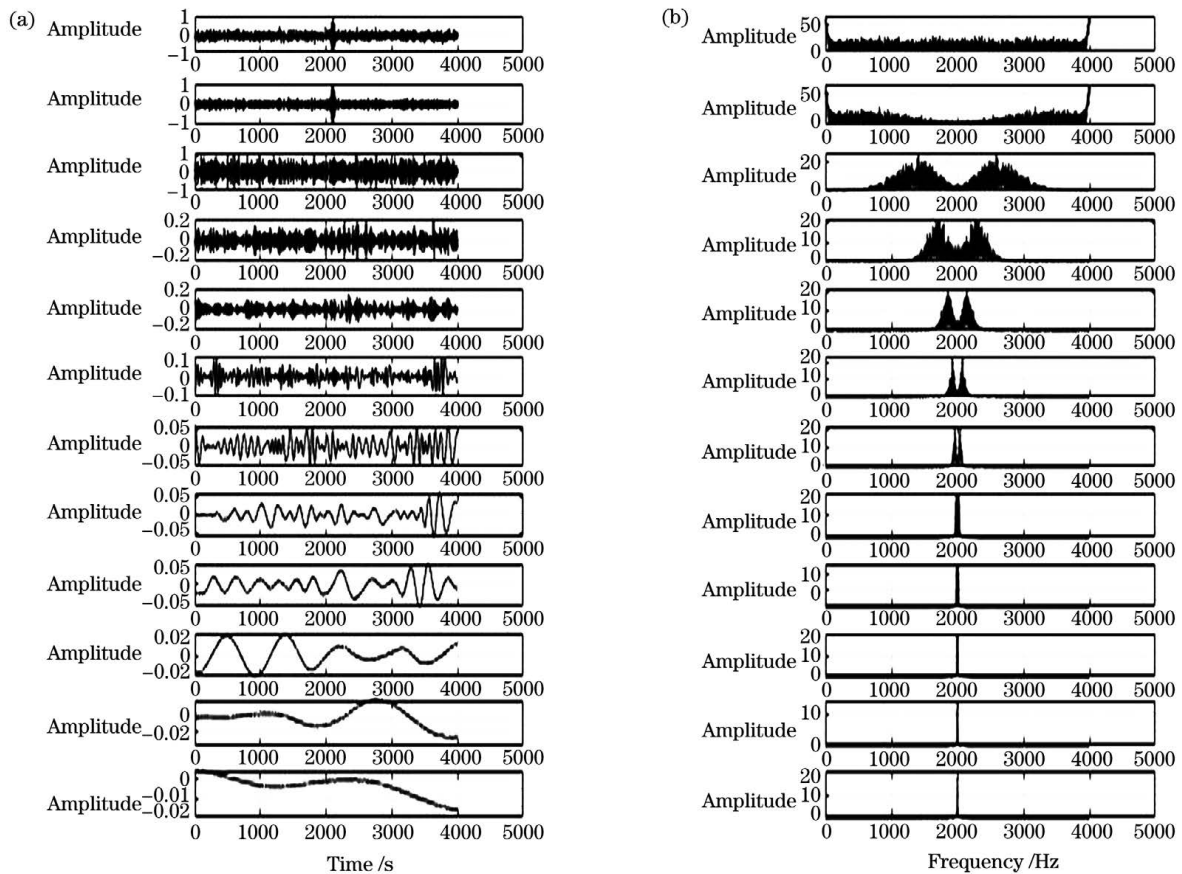


图 22 加噪信号的 EMD 模态及其频谱。(a)EMD 模态;(b)频谱

Fig. 22 EMD modes and frequency spectra of noisy signal. (a) EMD modes; (b) frequency spectra

难以准确定位,影响了检测的精度。对原始信号进行优化后的 VMD 处理后,分解出一个有效分量和两个噪声分量,准确的对原始信号进行了分离。EMD 处理后的分量模态混叠严重,并且将有效分量过分解,分解效果不理想。表 1 为 IMF 分量与原始信号的相关性。

利用 SNR 和均方误差(MSE)来评价小波阈值去噪^[21]、EMD+小波阈值去噪^[22]、集合经验模态分解(EEMD)+小波阈值去噪^[23-24]、传统 VMD+小波阈值去噪方法及所提去噪方法的去噪效果,评价

表 1 IMF 分量与原始信号相关性

Table 1 Correlations between IMF components and original signal

IMF component	Correlation coefficient
IMF1	0.9443
IMF2	0.0076
IMF3	0.0124

指标如表 2 所示。原始信号的 SNR 和 MSE 分别为 8.0654 和 0.1785。

表 2 5 种去噪方法的性能对比

Table 2 Performance comparisons of 5 denoising methods

Denoising method	Wavelet threshold	EMD+wavelet threshold	EEMD+wavelet threshold	VMD+wavelet threshold	Proposed method
SNR	10.0754	12.8064	13.2024	13.3214	14.2134
MSE	0.1123	0.0863	0.0639	0.0596	0.0396

由表 2 可知:所提去噪方法处理后的原始信号信噪比高,均方误差较小,去噪效果较其他方法更为理想。所提方法在有效去噪的同时可保留信号完整,进而可以精确地定位回波信号的起始位置,对流

量的监测较为准确。

4 结 论

提出一种将 MI 与 GA 相结合的优化方法,优

化后的 VMD 算法能够根据不同噪声模型自适应地选择最优参数组合并分解信号,解决了传统 VMD 分解时参数固定导致的分解效果不理想问题。仿真结果表明,在不同噪声环境下,与 EMD 方法相比,优化后的 VMD 算法可以更好地分离有效信号和噪声,分量模态利用率更高。利用 SNR 和 MSE 来评价小波阈值去噪、EMD+小波阈值去噪、EEMD+小波阈值去噪、传统 VMD+小波阈值去噪方法及所提去噪方法的去噪效果,可以发现,所提算法对原始信号的噪声滤除效果更好,重构后的信号平稳且保留了原始信号的特征。

参 考 文 献

- [1] Zhao N N, Hu L, Mao K, et al. The sound field mixing calculation method of ultrasonic volume flowmeter[J]. Journal of Zhejiang University (Engineering Science Edition), 2020, 54(8): 1466-1473.
赵楠楠, 胡亮, 毛凯, 等. 超声波体积流量计声场混合计算方法[J]. 浙江大学学报(工学版), 2020, 54(8): 1466-1473.
- [2] Chang J H, Zhu L Y, Li H X, et al. Noise reduction in lidar signal using correlation-based EMD combined with soft thresholding and roughness penalty [J]. Optics Communications, 2018, 407: 290-295.
- [3] Chen Z, Hu Y Q, Tian S Q, et al. Non-stationary signal combined analysis based fault diagnosis method [J]. Journal on Communications, 2020, 41(5): 187-195.
陈哲, 胡玉其, 田世庆, 等. 基于非平稳信号组合分析的故障诊断方法 [J]. 通信学报, 2020, 41(5): 187-195.
- [4] Wang X D, Zi Y Y, He Z J. Multiwavelet denoising with improved neighboring coefficients for application on rolling bearing fault diagnosis [J]. Mechanical Systems and Signal Processing, 2011, 25(1): 285-304.
- [5] Zhu X H, Chen B R, Li T, et al. Microseismic signal FIR-wavelet joint filtering algorithm and its application[J]. Chinese Journal of Rock Mechanics and Engineering, 2020, 9: 1872-1882.
朱新豪, 陈炳瑞, 李涛, 等. 微震信号 FIR-小波联合滤波算法及应用[J]. 岩石力学与工程学报, 2020, 9: 1872-1882.
- [6] Li X, Wang L X, Duan Z Q. Application of improved adaptive wavelet noise reduction in laser gyroscope signal processing[J]. Laser & Optoelectronics Progress, 2020, 57(21): 210401.
李想, 汪立新, 段志强. 改进自适应小波降噪在激光陀螺仪信号处理中的应用[J]. 激光与光电子学进展, 2020, 57(21): 210401.
- [7] Yang Y, Sha Z, Feng H, et al. Signal processing method of Φ -OTDR technology in early warning and leakage positioning of water pipelines [J]. Laser & Optoelectronics Progress, 2018, 55(4): 040607.
杨洋, 沙洲, 封皓, 等. 输水管道预警与泄漏定位中 Φ -OTDR 技术信号处理法 [J]. 激光与光电子学进展, 2018, 55(4): 040607.
- [8] Hsu C C, Yeh C L, Lee W K, et al. Extraction of high-frequency SSVEP for BCI control using iterative filtering based empirical mode decomposition [J]. Biomedical Signal Processing and Control, 2020, 61: 102022.
- [9] Jiang L H, Fu C, Liu W Q, et al. Lidar backscattering signal denoising method based on adaptive multi-scale morphological filtering and EMD [J]. Infrared and Laser Engineering, 2015, 44(5): 1673-1679.
蒋立辉, 符超, 刘雯箐, 等. 基于自适应多尺度形态滤波与 EMD 的激光雷达回波信号去噪方法 [J]. 红外与激光工程, 2015, 44(5): 1673-1679.
- [10] Yang G L, Liu Y Y, Wang Y Y, et al. EMD interval thresholding denoising based on similarity measure to select relevant modes [J]. Signal Processing, 2015, 109: 95-109.
- [11] Cao Q P, Li Y C, Dong X J, et al. Influence of satellite micro-vibration on signal-to-noise ratio of wind LiDAR [J]. Laser & Optoelectronics Progress, 2020, 57(9): 092802.
曹启鹏, 李永昌, 董小静, 等. 卫星微振动对测风激光雷达信噪比影响研究 [J]. 激光与光电子学进展, 2020, 57(9): 092802.
- [12] Xie D R, Sun H X, Qi J. A new feature extraction method based on improved variational mode decomposition, normalized maximal information coefficient and permutation entropy for ship-radiated noise [J]. Entropy, 2020, 22(6): 620.
- [13] Huang Q Y, Xie L F, Yin G F, et al. Acoustic signal analysis for detecting defects inside an arc magnet using a combination of variational mode decomposition and beetle antennae search [J]. ISA Transactions, 2020, 102: 347-364.
- [14] Jayakumar C, Sangeetha J. Kernellized support vector regressive machine based variational mode decomposition for time frequency analysis of Mirnov coil [J]. Microprocessors and Microsystems, 2020, 75: 103036.
- [15] Zhang Y G, Pan G F, Chen B, et al. Short-term wind speed prediction model based on GA-ANN improved by VMD [J]. Renewable Energy, 2020,

- 156: 1373-1388.
- [16] Bertsekas D P. Multiplier methods: a survey [J]. Automatica, 1976, 12(2): 133-145.
- [17] Karamchandani P, Vennam P, Shah T, et al. Single source impacts on secondary pollutants using a lagrangian reactive puff model: comparison with photochemical grid models[J]. Atmospheric Environment, 2020, 237: 117664.
- [18] Williams P M. Bayesian regularization and pruning using a Laplace prior[J]. Neural Computation, 1995, 7(1): 117-143.
- [19] Tang Y B, Gui W H, Peng T, et al. Prediction method for dissolved gas concentration in transformer oil based on variable selection of mutual information [J]. Chinese Journal of Scientific Instrument, 2013, 34(7): 53-59.
唐勇波, 桂卫华, 彭涛, 等. 基于互信息变量选择的变压器油中溶解气体浓度预测 [J]. 仪器仪表学报, 2013, 34(7): 53-59.
- [20] Shan H F, Li H. Blind separation of hybrid mixture signals based on kernel density maximum entropy approach [J]. Application Research of Computers, 2010, 27(5): 1705-1707.
单会丰, 李宏. 基于核密度最大熵方法的杂系混合信号盲分离 [J]. 计算机应用研究, 2010, 27(5): 1705-1707.
- [21] Lu Z Y, Lu Y M, Xia Z W, et al. Speech signal denoising method based on VMD and wavelet analysis [J]. Modern Electronics Technique, 2018, 41(13): 47-51.
陆振宇, 卢亚敏, 夏志巍, 等. 基于变分模态分解和小波分析的语音信号去噪方法 [J]. 现代电子技术, 2018, 41(13): 47-51.
- [22] Chen Z A, Xiong X, Li Y J. The denoising method of deformation monitoring data based on PSO-DVMD-WT algorithm [J]. Science of Surveying and Mapping, 2020, 45(8): 41-50.
陈竹安, 熊鑫, 李亦佳. PSO-DVMD-WT 的变形信号去噪方法研究 [J]. 测绘科学, 2020, 45(8): 41-50.
- [23] Lu L R, Wang J, Niu X D, et al. Electrocardiogram signal denoising based on cardiac cycle and empirical mode decomposition [J]. Journal of Data Acquisition and Processing, 2020, 35(4): 702-710.
卢莉蓉, 王鉴, 牛晓东, 等. 基于心动周期和经验模式分解的心电信号去噪处理 [J]. 数据采集与处理, 2020, 35(4): 702-710.
- [24] Huang J, Wu Q L, Chen F. Study on energy distribution character about post-disaster rescue signal based on CEEMDAN-WPT denoising [J]. Journal of Nanjing University of Science and Technology, 2020, 44(2): 194-201.
黄金, 吴庆良, 陈帆. 基于 CEEMDAN-WPT 联合去噪的灾后求救信号能量分布特征研究 [J]. 南京理工大学学报, 2020, 44(2): 194-201.